

Universidade Federal da Paraíba
Centro de Informática
Programa de Pós-Graduação em Informática

**Um método de reconhecimento de
indivíduos por geometria da mão**

Márcia Valdenice Pereira do Nascimento

João Pessoa - PB
Fevereiro de 2015

Márcia Valdenice Pereira do Nascimento

**Um método de reconhecimento de
indivíduos por geometria da mão**

Dissertação submetida à Coordenação do Curso de Pós
Graduação em Informática da Universidade Federal da
Paraíba como parte dos requisitos necessários para
obtenção do grau de Mestre em Informática.

Área de Concentração: Sistemas de Computação

Linha de Pesquisa: Sinais, Sistemas Digitais e Gráficos

Orientador: Leonardo Vidal Batista

João Pessoa - PB

Fevereiro de 2015

N244u Nascimento, Márcia Valdenice Pereira do.
Um método de reconhecimento de indivíduos por
geometria da mão / Márcia Valdenice Pereira do Nascimento.-
João Pessoa, 2015.
109f. : il.
Orientador: Leonardo Vidal Batista
Dissertação (Mestrado) - UFPB/CI
1. Informática. 2. Biometria. 3. Reconhecimento de
padrões. 4. Reconhecimento de indivíduos. 5. Geometria da
mão. 6. Classificação e verificação.

UFPB/BC


CDU: 004(043)

Ata da Sessão Pública de Defesa de Dissertação de
Mestrado de **Márcia Valdenice Pereira do
Nascimento**, candidata ao título de Mestre em
Informática na Área de Sistemas de Computação,
realizada em 27 de fevereiro de 2015.


1
2
3 Aos vinte e sete dias do mês de fevereiro do ano de dois mil e quinze, às dez horas, no
4 laboratório 1 do Centro de Informática - Universidade Federal da Paraíba, reuniram-se os
5 membros da Banca Examinadora constituída para examinar a candidata ao grau de Mestre
6 em Informática, na área de "*Sistemas de Computação*", na linha de pesquisa "*Sinais,
7 Sistemas e Gráficos*", a Sra. **Márcia Valdenice Pereira do Nascimento**. A comissão
8 examinadora foi composta pelos professores doutores: **Leonardo Vidal Batista (PPGI-
9 UFPB)**, orientador e presidente da Banca, (UFPB), **Thaís Gaudêncio de Rego
10 examinadora interna** e **George Darminton da Cunha Cavalcanti (UFPE)**, examinador
11 externo à Instituição. Dando início aos trabalhos, o professor Leonardo Vidal Batista
12 cumprimentou os presentes, comunicou aos mesmos a finalidade da reunião e passou a
13 palavra à candidata para que a mesma fizesse, oralmente, a exposição do trabalho de
14 dissertação intitulado "*Um Método de Reconhecimento de Indivíduos por Geometria da
15 Mão*". Concluída a exposição, a candidata foi arguida pela Banca Examinadora que emitiu
16 o seguinte parecer: "*aprovada*". Eu, Nadja Rayssa Soares de Almeida, auxiliar em
17 administração, lavrei a presente ata que vai assinada por mim e pelos membros da Banca
18 Examinadora. João Pessoa, 27 de fevereiro de 2015.

19
20
21 
Nadja Rayssa Soares de Almeida


Prof^o Leonardo Vidal Batista
Orientador (PPGI-UFPB)



Prof^o Thaís Gaudêncio de Rego
Examinadora Interna (UFPB)



Prof^o George Darminton da Cunha Cavalcanti
Examinador Externo (UFPE)



Agradecimentos

A Deus, pela vida e por me permitir chegar até aqui.

Aos meus pais e a minha avó Alzira, pelo amor, carinho, apoio e atenção que sempre me dedicaram em todos os momentos da minha vida. Um particular agradecimento à minha mãe, Maria Inácia, que me incentivou a retomar os estudos e iniciar esse projeto.

Ao meu orientador Prof. Leonardo Vidal, pela confiança de que eu pudesse realizar esse trabalho, pela atenção que sempre me dispensou, além dos ensinamentos compartilhados, tão importantes nessa trajetória e certamente para todo o meu futuro profissional.

À minha amiga Klarissa, pela disponibilidade em revisar este trabalho e pelo esmero com que o realizou. A sua ajuda e de seu esposo Pedro Segundo, as correções e sugestões tão pertinentes, foram importantíssimas na construção do texto dessa dissertação.

Ao meu amigo Nicomedes, pela colaboração em várias situações no decurso do mestrado e principalmente pela parceria na elaboração dos artigos científicos, felizmente agraciados com aceitação nos eventos onde foram submetidos.

Ao colega Rafael Brayner, pela sua cooperação e parceria no primeiro ano da pesquisa, enormemente relevantes para os resultados alcançados até aqui.

Aos colegas do grupo VisioLab, Arnaldo e Igor Malheiros, e à professora Thaís Gaudêncio pela colaboração e disponibilidade com que me atenderam sempre que solicitei.

Aos meus colegas da COSIS/TRE-PB, pelo incentivo, em especial ao meu chefe Francisco Gomes que em momento algum fez objeções aos meus pedidos de ajuste de horário, também especial agradecimento à Danielle Vilar, pela sua verdadeira empolgação para que eu realizasse esse trabalho e seu empenho na concessão da minha licença capacitação.

A todos os amigos e familiares que torceram por mim.

Resumo

Nos últimos anos, o reconhecimento de indivíduos por meio de informações biométricas tem sido cada vez mais adotado nas mais diversas aplicações, sejam elas comerciais, governamentais ou forenses. Uma das razões para essa escolha fundamenta-se nas informações biométricas serem mais difíceis de adulterar, compartilhar, ocultar ou extraviar do que outras alternativas como cartões e senhas. Várias características dos indivíduos, sejam físicas ou comportamentais, podem ser utilizadas em um sistema biométrico, como por exemplo, impressão digital, face, voz, íris, forma de andar, impressão palmar, geometria da mão, entre outras. Diversos trabalhos têm explorado esses e outros traços produzindo mecanismos de reconhecimento cada vez mais seguros e precisos, mas nenhum é imune a falhas e ainda há muito a evoluir e a aprimorar nessa área. Com base nisso, esse trabalho apresenta uma nova proposta de reconhecimento biométrico baseado em geometria da mão. Um banco de dados com 100 indivíduos e amostras de ambos os lados das mãos foi utilizado. O processo de extração de características prioriza o conforto do usuário durante a captura e produz segmentação das mãos e dedos com precisão elevada. Ao todo, 84 atributos foram extraídos de cada indivíduo e o método foi avaliado sob a perspectiva de diferentes abordagens de classificação e verificação. Nos testes de classificação, as técnicas de validação cruzada e subamostragem randômica estratificada foram utilizadas. Os experimentos demonstraram resultados competitivos quando comparados a outros métodos do estado da arte em geometria da mão, apresentando 100% de acurácia em diferentes estratégias de classificação e uma taxa EER de 0,75% no processo de verificação.

Palavras-chave: biometria, reconhecimento de padrões, reconhecimento de indivíduos, geometria da mão, classificação, verificação.

Abstract

Over the past few years, recognition by biometric information has been increasingly adopted in several applications, including commerce, government and forensics. One reason for this choice is based on the fact that biometric information is more difficult to falsify, share, hide or misplace than other alternatives like ID cards and passwords. Many characteristics of the individual (physical or behavioral) can be used in a biometric system, such as fingerprint, face, voice, iris, gait, palmprint, hand geometry, and others. Several researches have explored these and other features producing safer and more accurate recognition methods, but none of them are completely fault tolerant and there is still much to evolve and improve in this area. Based on this, this work presents a new approach to biometric recognition based on hand geometry. A database with 100 individuals and with samples of both sides of the hands was used. The feature extraction process prioritizes user comfort during capture and produces segmentation of hands and fingers with high precision. Altogether, 84 features have been extracted from each individual and the method was evaluated from different classification and verification approaches. Classification tests using cross-validation and stratified random subsampling techniques were performed. The experiments demonstrated competitive results when compared to other state-of-the-art methods with hand geometry. The proposed approach obtained with 100% accuracy in different classification strategies and EER rate of 0.75% in the verification process.

Keywords: biometrics, pattern recognition, person recognition, hand geometry, classification, verification.

Conteúdo

LISTA DE FIGURAS	V
LISTA DE TABELAS.....	VII
LISTA DE EQUAÇÕES	IX
LISTA DE ABREVIATURAS E SIGLAS	X
LISTA DE ALGORITMOS.....	XI
INTRODUÇÃO	1
OBJETIVOS	3
ESTRUTURA DO TRABALHO	4
CAPÍTULO 2.....	5
FUNDAMENTAÇÃO TEÓRICA.....	5
2.1 VISÃO GERAL SOBRE RECONHECIMENTO DE PADRÕES	5
2.1.1 <i>Classificação</i>	5
2.1.2 <i>Validação cruzada</i>	6
2.2 MÉTODOS DE CLASSIFICAÇÃO.....	7
2.2.1 <i>K-Vizinhos mais próximos</i>	7
2.2.2 <i>Redes Bayesianas</i>	8
2.2.3 <i>Árvores de decisão</i>	8
2.2.4 <i>Máquinas de Vetores de Suporte</i>	10
2.2.5 <i>Combinação de classificadores</i>	13
2.2.5.1 <i>Bagging</i>	13
2.2.5.2 <i>Boosting</i>	14
2.3 INTELIGÊNCIA DE ENXAMES E O ALGORITMO <i>FIREFLY</i>	15
2.4 VERIFICAÇÃO BIOMÉTRICA.....	16
2.4.1 <i>Taxas de erro no processo de verificação</i>	17
CAPÍTULO 3.....	20
RECONHECIMENTO POR GEOMETRIA DA MÃO: O ESTADO DA ARTE	20
CAPÍTULO 4.....	25
MATERIAIS E MÉTODOS.....	25
4.1 AMBIENTE DE DESENVOLVIMENTO	26
4.2 AQUISIÇÃO DE IMAGENS	26
4.3 PRÉ-PROCESSAMENTO E SEGMENTAÇÃO	27
4.3.1 <i>Limiarização da imagem e extração do contorno da mão</i>	28

4.3.2 <i>Localização de picos e vales dos dedos e outros pontos auxiliares.</i>	29
4.3.3 <i>Delimitação e segmentação precisa de mão e dedos.</i>	32
4.4 EXTRAÇÃO DE ATRIBUTOS	37
4.5 CLASSIFICAÇÃO	40
4.6 VERIFICAÇÃO	43
CAPÍTULO 5	46
RESULTADOS E DISCUSSÕES	46
5.1 AVALIAÇÃO VISUAL DO PROCESSO DE SEGMENTAÇÃO	46
5.2 EXPERIMENTOS DE CLASSIFICAÇÃO	49
5.2.1 <i>Classificação com validação cruzada</i>	49
5.2.1.1 Análise de erros	52
5.2.1.2 Avaliação da combinação de modelos de classificação	56
5.2.1.3 Avaliação do tempo de execução	56
5.2.2 <i>Desempenho dos classificadores em relação ao número de amostras por classe no treinamento</i>	57
5.3 EXPERIMENTOS DE VERIFICAÇÃO	59
5.3.1 <i>Abordagem 1 – distância euclidiana simples</i>	60
5.3.1.1 Caso 1	60
5.3.1.2 Caso 2	61
5.3.1.3 Caso 3:	61
5.3.2 <i>Abordagem 2 – distância euclidiana ponderada</i>	62
5.3.2.1 Caso 1	62
5.3.2.2 Caso 2	64
5.3.2.3 Análise dos pesos dos atributos	65
5.4 COMPARAÇÃO COM OUTROS TRABALHOS	68
CAPÍTULO 6	70
CONSIDERAÇÕES FINAIS	70
REFERÊNCIAS BIBLIOGRÁFICAS	73
APÊNDICE A - DETALHAMENTO DE CLASSES COM ERROS DE CLASSIFICAÇÃO	77
APÊNDICE B - TAXAS EER OBTIDAS NOS EXPERIMENTOS COM <i>FIREFLY</i>	87
APÊNDICE C - PESOS DOS ATRIBUTOS APLICANDO O MÉTODO <i>FIREFLY</i>	89
APÊNDICE D - ARTIGO PUBLICADO	92
APÊNDICE E - ARTIGO ACEITO	93

Lista de Figuras

Figura 1. Uma árvore de decisão para o problema de jogar ou não com base em condições meteorológicas.....	9
Figura 2. Hiperplano de separação entre classes não ótimo.....	11
Figura 3. Hiperplano de separação entre classes gerado pelo SVM.....	11
Figura 4. Processo de verificação. Adaptado de (JAIN; ROSS; PRABHAKAR, 2004)	17
Figura 5. Exemplo de curvas FMR(t) e FNMR(t) com determinação do EER.....	19
Figura 6. Etapas do processo de reconhecimento.....	25
Figura 7. Dispositivo de captura composto por negatoscópio, caixa em MDF e câmera fotográfica. A imagem à esquerda destaca a câmera posicionada sobre a caixa. Fonte: (SILVA, 2013).	26
Figura 8. Mão capturada de um indivíduo com a sua face dorsal e palmar	27
Figura 9. Processo de segmentação da mão. a) Imagem do lado dorsal; b) mão após limiarização; c) contorno extraído; d) pontos para segmentação dos dedos: picos, vales e pontos auxiliares; e) dedos segmentados; f) mão segmentada.....	28
Figura 10. Imagem palmar obtida; após limiarização; e após virada vertical (efeito <i>flip</i>).	29
Figura 11. Contorno S_m rearranjado com percurso iniciando a partir do ponto extremo inferior direito.	30
Figura 12. Posicionamento das mãos. Mãos em uma mesma linha são de um mesmo indivíduo. As mãos com a face palmar (e) e (f) foram viradas verticalmente para uniformizar a ilustração.....	31
Figura 13. Obtenção de segmentos ajustados dos dedos. O segmento inicial AB é obtido a partir dos pontos iniciais (picos, vales e pontos auxiliares) e subdivido nos segmentos AC, CD e DB. Estes por sua vez, são transformados nos segmentos ajustados IJ, JL e LM. Para o polegar o segmento AB é subdividido em AC e CB, gerando os segmentos ajustados IJ e LM.....	32
Figura 14. Processo de definição do segmento ajustado IJ. Da esquerda para direita: segmento AC inicial; AC após redução em 7%; IJ definido a partir dos pontos médios de EF e GH; prolongamento de IJ para interceptar o pico do dedo.....	33
Figura 15. Definição do segmento ajustado LM. a) Definição de LM, caso fosse adotado o mesmo princípio aplicado ao segmento JL; b) Definição de LM como sendo o segmento que divide a primeira falange em duas partes simétricas em relação à extensão do dedo.	34
Figura 16. Evolução do processo para determinar o limite inferior do dedo.	35

Figura 17. Medidas de largura dos dedos.....	38
Figura 18. Ângulos entre segmentos que determinam a inclinação natural dos dedos.	38
Figura 19. Processo para o cálculo da largura da palma da mão. A largura é definida como a norma do segmento ZW.....	39
Figura 20. Ruído no contorno da imagem em decorrência de pelos. À esquerda, a imagem capturada; À direita, o contorno extraído com o ruído no antebraço em destaque; Abaixo, o quadro destacando o ruído na segmentação do antebraço em maior escala.	47
Figura 21. Indivíduo com unhas grandes. Imagem capturada à esquerda e à direita, o resultado da segmentação do contorno.	47
Figura 22. Segmentação de ponta de dedo com ruído. À esquerda, a imagem do dedo capturada e à direita, a segmentação do contorno. A segmentação é apresentada em maior escala para destacar o ruído.....	48
Figura 23. Geração de fenda na ponta do dedo. De cima para baixo: a imagem como foi capturada; o resultado da segmentação; as medidas extraídas, com falha na determinação do primeiro segmento ajustado IJ e, por conseguinte, do ângulo 1, porém sem repercussão sobre a definição dos demais segmentos ajustados e das medidas de largura.	49
Figura 24. Posicionamento inadequado do indivíduo I015. Na imagem à esquerda a amostra A1 conforme foi capturada. Na imagem à direita, a mesma amostra após processamento para evidenciar as sombras, delimitadas por linhas tracejadas.....	53
Figura 25. Posicionamento correto do indivíduo I015. Na imagem à esquerda a amostra A3 conforme foi capturada. Na imagem à direita, a mesma amostra após processamento para evidenciar as sombras.....	54
Figura 26. Desempenho dos classificadores segundo o número de amostras por classe na fase de treinamento. Os testes foram aplicados sobre a base dorsal e separados em grupos com variação de 1 a 6 amostras por classe. É indicada a acurácia alcançada por cada um dos algoritmos em cada grupo de teste.	58

Lista de Tabelas

Tabela 1. Exemplos de funções <i>Kernel</i>	12
Tabela 2. Comparativos de métodos de reconhecimento de indivíduos utilizando geometria das mãos presentes na literatura.	24
Tabela 3. Resultados da classificação usando validação cruzada sobre a base dorsal, com indicação da taxa de acurácia média nos 10- <i>folds</i> e o desvio padrão em relação à média. Os melhores resultados são destacados em negrito.	50
Tabela 4. Resultados da classificação usando validação cruzada sobre a base palmar, com indicação da taxa de acurácia média nos 10- <i>folds</i> e o desvio padrão em relação à média. Os melhores resultados são destacados em negrito.	51
Tabela 5. Resultados da classificação usando validação cruzada sobre a base conjugada, com indicação da taxa de acurácia média nos 10- <i>folds</i> e o desvio padrão em relação à média. Os melhores resultados são destacados em negrito.....	51
Tabela 6. Tempo de execução dos classificadores em segundos, destacando o tempo necessário para treinamento e teste de todas as instâncias da base dorsal. A coluna total exige o somatório do tempo de treinamento e teste para cada método.	57
Tabela 7. EER calculado utilizando a distância euclidiana simples - caso 1, abordagem 1 - em cada uma das 20 iterações e o valor médio final alcançado.....	61
Tabela 8. EER calculado utilizando distância euclidiana ponderada - caso 1, abordagem 2 - nas 20 iterações e comparativo com a abordagem anterior. Em verde os experimentos onde os resultados da abordagem 2 foram superiores aos da abordagem 1 e em vermelho, a situação inversa.	63
Tabela 9. EER calculado utilizando distância euclidiana ponderada - caso 2, abordagem 2 - em cada grupo de teste e comparativo com a abordagem anterior.	64
Tabela 10. Atributos com maior coeficiente de variação de pesos C_v da iteração 20, caso 1	66
Tabela 11. Atributos com menores pesos nos experimentos, considerando as 200 execuções do caso 1 e as 20 execuções do caso 2.....	66
Tabela 12. Atributos com pesos mais significativos nos experimentos, considerando as 200 execuções do caso 1 e as 20 execuções do caso 2	67
Tabela 13. Comparativo entre diferentes propostas de classificação por geometria da mão	68
Tabela 14. Comparativo entre diferentes propostas de verificação utilizando geometria da mão	69

Tabela 15. Taxas EER obtidas nas execuções do caso 1 da abordagem 2	87
Tabela 16. Taxas EER obtidas nas execuções do caso 2 da abordagem 2	88
Tabela 17. Atribuição de pesos aos atributos nos experimentos com <i>Firefly</i>	89

Lista de Equações

Equação 1	7
Equação 2	8
Equação 3	10
Equação 4	10
Equação 5	11
Equação 6	16
Equação 7	38
Equação 8	43
Equação 9	44
Equação 10	44
Equação 11	44
Equação 12	44
Equação 13	45
Equação 14	59
Equação 15	59
Equação 16	62

Lista de abreviaturas e siglas

BMP	<i>Windows Bitmap</i>
DPI	<i>Dots Per Inch</i>
DSLR	<i>Digital Single-Lens Reflex</i>
EER	<i>Equal Error Rate</i>
FAR	<i>False Acceptance Rate</i>
FLR	<i>Fuzzy Lattice Reasoning</i>
FMR	<i>False Match Rate</i>
FNRM	<i>False Non-Match Rate</i>
FRR	<i>False Rejection Rate</i>
GA	<i>Genetic Algorithms</i>
GMM	<i>Gaussian Mixture Model</i>
GNU	<i>General Public License</i>
KKT	<i>Karush-Kuhn-Tucker</i>
KNN	<i>K-Nearest Neighbor</i>
LDA	<i>Linear Discriminant Analysis</i>
LED	<i>Light-Emitting Diode</i>
LMT	<i>Logistic Model Tree</i>
MDF	<i>Medium-Density Fiberboard</i>
PCA	<i>Principal Component Analysis</i>
PSO	<i>Particle Swarm Optimization</i>
RAM	<i>Random Access Memory</i>
SI	<i>Swarm Intelligence</i>
SMO	<i>Sequential Minimal Optimization</i>
SVM	<i>Support Vector Machine</i>
WEKA	<i>Waikato Environment for Knowledge Analysis</i>

Lista de algoritmos

Pseudocódigo 1. Bagging: treinamento e classificação. Adaptado de (WITTEN; EIBE; HALL, 2011).	14
Pseudocódigo 2. Algoritmo <i>Firefly</i>	16
Pseudocódigo 3. Definição do ponto inicial do contorno S_m	30
Pseudocódigo 4. Algoritmo que define P_5	31
Pseudocódigo 5. Algoritmo que ajusta o limite do dedo OP	36

Introdução

Nos últimos anos, o reconhecimento de indivíduos por informações biométricas tem se tornado cada vez mais comum. Esse processo de identificação foi incluído na rotina de acesso a escritórios, terminais bancários, comércio eletrônico, no controle de emissão de passaportes, em investigações criminais, determinação de paternidade e muitas outras aplicações, sejam elas comerciais, governamentais ou forenses.

Em uma sociedade imensamente interconectada, estabelecer a identidade de uma pessoa com alta confiança está se tornando uma tarefa crítica (JAIN; ROSS; NANDAKUMAR, 2011). Por isso, vários são os trabalhos de pesquisa que tentam aprimorar os métodos de reconhecimento, tornando-os cada vez mais seguros e precisos.

Jain e Ross (2008) definem biometria como a ciência que estabelece a identidade de um indivíduo baseada em suas características físicas, químicas ou comportamentais. Como esses identificadores biométricos não podem ser facilmente compartilhados ou extraviados, a biometria tem se tornado um componente essencial na construção de soluções eficazes de identificação pessoal, além do que esses identificadores representam intrinsecamente a identidade corporal dos indivíduos (MALTONI *et al.*, 2000). Corroborando com a ideia, Jain e Ross (2008) afirmam que a biometria estabelece a identidade do indivíduo com base no *que ele é*, ao invés de *o que ele possui* (como um cartão inteligente) ou de *o que ele se lembra ou conhece* (como uma senha).

Em princípio, várias características do ser humano podem ser utilizadas para o reconhecimento em um sistema biométrico. Essas características são referidas por termos diferentes, como traços, indicadores, identificadores, ou modalidades. Cada uma delas apresenta prós e contras em sua escolha, mas, de forma geral, sete fatores devem ser considerados para determinar a adequação a uma aplicação biométrica (JAIN; ROSS; NANDAKUMAR, 2011):

- Universalidade: todos os integrantes do público alvo devem possuir o traço biométrico.
- Singularidade: o traço deve ser distinto para cada indivíduo.
- Permanência: a característica deve ser suficientemente invariante por um período de tempo adequado à aplicação biométrica.
- Mensurabilidade: o traço deve ser extraído e digitalizado utilizando dispositivos adequados que não causem inconvenientes para os usuários.
- Performance: o traço deve possibilitar uma boa precisão no processo de reconhecimento, bem como o tempo de processamento e os recursos computacionais utilizados devem ser adequados à aplicação.
- Aceitação: os indivíduos devem consentir natural e tranquilamente a extração da característica.
- Resistência a fraudes: o traço não deve ser facilmente imitado por um impostor, nem o indivíduo genuíno deveria poder alterá-lo para evitar o reconhecimento.

No que diz respeito às mãos humanas, várias características biométricas podem ser utilizadas, como as já amplamente difundidas impressões digitais, além de impressão palmar, padrões de veias e geometria das mãos; esta última, escopo deste trabalho. Sistemas de reconhecimento pela geometria da mão são baseados nas medições feitas a partir da mão humana, incluindo sua forma, tamanho da palma, comprimentos e larguras dos dedos (JAIN; ROSS; PRABHAKAR, 2004).

O reconhecimento por geometria da mão é considerado de média segurança (SANCHEZ-REILLO; SANCHEZ-AVILA; GONZALEZ-MARCOS, 2000) e a questão da singularidade forma da mão dentro de uma grande população é ainda algo controverso (DUTA, 2009). Igualmente, há que se considerar que as informações geométricas das mãos não são invariantes durante o período de crescimento das crianças e o uso de joias e problemas articulares como a artrite podem ser desafiadores no processo de extração das características (JAIN; ROSS; NANDAKUMAR, 2011).

Entretanto, conforme argumentado por Sidlauskas e Tamer (2008), não está claro que as limitações desse reconhecimento se encontram na geometria da mão em si. A evolução crescente do desempenho dos métodos de reconhecimento que adotam essa abordagem

corroborar a hipótese de que a performance não é limitada pelo conteúdo biométrico das mãos, mas sim pelos próprios algoritmos que extraem e processam esse conteúdo.

Ademais, conforme descrito por Duta (2009), o reconhecimento por geometria da mão pode apresentar uma série de vantagens em comparação com outras modalidades, dentre as quais:

- Forma de captura relativamente conveniente e pouco intrusiva para o usuário.
- A extração das informações pode ser feita com imagens de baixa resolução e os dados extraídos não requerem grande espaço de armazenamento.
- É uma modalidade biométrica bem aceita pelo público em geral, principalmente por não possuir uma conotação criminal.
- Informações biométricas adicionais como impressão palmar e impressão digital podem ser facilmente integradas a um já existente sistema baseado em geometria da mão.

Assim, considerando os desafios dessa modalidade de reconhecimento biométrico, este trabalho propõe um novo método de segmentação e extração de características de mãos e dedos. Para avaliá-lo, testes utilizando estratégias de classificação e verificação são realizados. Além disso, apesar de estudos anteriores que geralmente utilizam apenas um dos lados da mão (palma ou dorso), esse trabalho experimenta a utilização de ambos os lados no processo de reconhecimento, separadamente e em combinação.

Objetivos

O presente trabalho tem como objetivo geral pesquisar, desenvolver e avaliar um novo método de reconhecimento de indivíduos por geometria da mão que possua boa aceitação, bom desempenho computacional e principalmente, elevado grau de confiabilidade.

Para atingir o objetivo geral, os seguintes objetivos específicos pretendem ser alcançados:

1. Definir um processo de captura confortável e de boa aceitação pelos usuários.
2. Pesquisar, desenvolver e avaliar um método preciso de segmentação de mãos e dedos.
3. Extrair atributos que descrevam a geometria da mão de forma satisfatória. Os atributos devem ser invariantes à rotação e ao posicionamento das mãos durante a aquisição das imagens.

4. Submeter o método proposto a diferentes estratégias de classificação e verificação, permitindo, na medida do possível, a comparação com outros trabalhos.
5. Avaliar e comparar diversas técnicas de aprendizado de máquina que respondam satisfatoriamente ao problema em questão.

Estrutura do trabalho

Este trabalho está organizado em seis capítulos e a proposta de cada um deles está descrita a seguir:

- Capítulo 2 - Fundamentação teórica
São descritos neste capítulo importantes conceitos envolvidos no processo de reconhecimento.
- Capítulo 3 - Reconhecimento por geometria da mão: o estado da arte.
Neste capítulo é apresentado um breve histórico sobre geometria da mão e são revisados trabalhos relacionados.
- Capítulo 4 - Materiais e métodos
São examinadas as técnicas aplicadas e descrito o sistema de reconhecimento desenvolvido.
- Capítulo 5 - Resultados e discussões
Utilizado para descrever os experimentos realizados, bem como apresentar e analisar os resultados obtidos.
- Capítulo 6 - Considerações finais
Dedica-se à apresentação das conclusões, delineando as principais contribuições deste trabalho e as sugestões de oportunidades futuras.

Capítulo 2

Fundamentação Teórica

Nesse capítulo são apresentados conceitos importantes relacionados ao processo de reconhecimento proposto, a fim de subsidiar a sua adequada compreensão.

2.1 Visão geral sobre reconhecimento de padrões

O reconhecimento de padrões é uma habilidade natural dos seres humanos. Fazer a distinção entre uma cadeira e uma mesa, entre uma rosa e uma orquídea ou perceber pelo cheiro que a comida está queimando no fogão são habilidades triviais para nós. E esse processo começa bem cedo, estudos sugerem, por exemplo, que um bebê é capaz de reconhecer a voz de sua mãe quando ainda está dentro da barriga (KISILEVSKY *et al.*, 2003).

Essas ações que nos são tão espontâneas, na verdade são processos altamente complexos. Pode-se definir que reconhecer padrões consiste em observar os dados brutos do ambiente, identificar as informações de interesse, processá-las e tomar a decisão sobre em que categoria de padrões as informações melhor se enquadram.

Sistemas de reconhecimento de padrões buscam imitar essa habilidade humana e ainda aprimorá-la, atingindo níveis de reconhecendo que extrapolam a nossa capacidade. Conforme comentado em Duda; Harr e Stork (2001), são amplos e variados os campos de atuação, como reconhecimento de escrita e de gestos, leitura labial, análise geológica, procura de documentos e reconhecimentos de trilhas de bolhas (em câmeras de bolhas) de partículas subatômicas.

2.1.1 Classificação

Tan; Steinback e Kumar (2005) definem classificação como uma tarefa de aprendizagem de uma função alvo f – ou, informalmente, modelo de classificação f – que mapeia um conjunto

de atributos x para uma classe pré-definida e rotulada y . Uma técnica de classificação (ou classificador), por sua vez, é uma abordagem sistemática para construir modelos de classificação a partir de um determinado conjunto de entrada de dados. Exemplos incluem métodos probabilísticos, redes neurais, máquinas de vetores de suporte, classificadores baseados em regras, distâncias e árvores de decisão.

Cada técnica emprega um algoritmo de aprendizagem que procura identificar o modelo que melhor reproduz o relacionamento entre o conjunto de atributos e as classes da entrada de dados (TAN; STEINBACH; KUMAR, 2005). Além de ser uma fiel representação das instâncias de entrada, o modelo proposto deve ser generalista o suficiente para ser capaz de também prever corretamente a que classes pertencem instâncias ainda desconhecidas.

Ao conjunto de entrada com classes conhecidas, denomina-se **conjunto de treinamento** e às instâncias cujas classes desejam-se descobrir, **conjunto de teste**.

2.1.2 Validação cruzada

Uma técnica bastante utilizada para testar um classificador é a validação cruzada. A proposta desse método é repetir várias vezes o processo de classificação para produzir uma estimativa de desempenho do classificador, porém estabelecendo que cada amostra da base de dados seja usada o mesmo número de vezes para treinamento e exatamente uma única vez para teste (TAN; STEINBACH; KUMAR, 2005). Esse processo reduz a variância das estimativas (WITTEN; EIBE; HALL, 2011). O primeiro passo é decidir o número de partições ou *folds*. Seja uma validação cruzada com *K-folds*, onde K é o número de partições, o processo ocorre da seguinte forma:

- A base de dados é dividida em K partes de tamanhos iguais.
- São realizadas K iterações ou rodadas do classificador e em cada uma delas, uma partição diferente é utilizada para teste e as demais para treinamento.
- A média dos resultados individuais é o resultado final da classificação.

Uma variante desse método é a validação cruzada estratificada (do inglês, *Stratified cross-validation*). Esse procedimento garante que ao dividir a base de dados em K partes, cada uma delas tenha aproximadamente a mesma proporção de amostras de cada uma das classes, o que contribui para reduzir ainda mais a variância nas estimativas.

2.2 Métodos de classificação

Extraídos os traços biométricos, o passo seguinte do reconhecimento é a formulação de método que corretamente verifique, identifique ou classifique os indivíduos segundo padrões estabelecidos. Nesse contexto, diversas técnicas de mineração de dados, aprendizado de máquina e estatística podem ser aplicadas para prover o aprendizado e construir o modelo que melhor represente a relação entre as características e os indivíduos que as possuem. A seguir são descritas as principais técnicas aplicadas nos algoritmos de classificação utilizados neste trabalho.

2.2.1 K-Vizinhos mais próximos

Um método de classificação utilizado com bastante frequência é o K-Vizinhos mais próximos (do inglês, *K-Nearest Neighbor* – KNN). Conforme descrito por Faceli *et al.* (2011), neste método, cada objeto representa um ponto em um espaço definido pelos seus atributos e a similaridade entre os objetos é definida pela distância entre eles. Essa distância é calculada com base em uma métrica nesse espaço, como a distância euclidiana, bastante utilizada, e que pode ser definida da seguinte forma:

$$d(X_Q, X_I) = \sqrt{\sum_{i=1}^n (X_Q^i - X_I^i)^2} \quad (1)$$

onde X_Q e X_I são dois objetos que estão sendo comparados, e por sua vez, X_Q^i e X_I^i são atributos desses objetos.

Um caso particular e muito simples do método de vizinhos mais próximos é o 1-NN, de apenas um vizinho ($k = 1$). Nele, a fase de treinamento apenas memoriza as amostras e suas respectivas classes. Na fase de testes, para determinar a classificação de uma amostra, é calculada a distância dessa amostra em relação às demais amostras de treinamento. A classe da instância testada é definida como sendo a classe da amostra de treinamento mais próxima.

Quando $k > 1$, os k vizinhos de treinamento mais próximos da instância testada são selecionados. A classe da instância testada é escolhida por maioria de votos (que podem ser ponderados ou não) entre as classes das k amostras de treinamento.

Para comparar a amostra de testes com as demais amostras de treinamento, por padrão, é realizada uma busca linear. Contudo, essa forma de busca pode se tornar ineficiente para grandes conjuntos de dados. Então, conforme argumentam Faceli *et al.* (2011), estruturas de dados mais sofisticadas, como árvores de busca binária multidimensionais podem ser adotadas nesse caso.

2.2.2 Redes Bayesianas

Redes bayesianas são modelos de representação do conhecimento fundamentados na teoria de decisão bayesiana. Um elemento importante dessa teoria é o teorema de Bayes, o qual define a probabilidade de uma classe y_i dado um valor de um atributo x que tenha sido medido, isto é, a *probabilidade condicional* $P(y_i|x)$ como sendo:

$$P(y_i|x) = \frac{p(x|y_i)P(y_i)}{p(x)} \quad (2)$$

Assim, o teorema de Bayes relaciona a probabilidade *a priori* ou incondicional $P(y_i)$ a uma probabilidade posterior (*a posteriori*) ou condicional $P(y_i|x)$ (DUDA; HARR; STORK, 2001).

Agora, seja x um conjunto de atributos $\{x_1, x_2, x_3, \dots, x_n\}$ condicionalmente independentes, uma rede bayesiana sobre x é uma tupla (S, Θ_s) em que o primeiro componente - a estrutura da rede S - é um grafo acíclico direcionado cujos nós representam os atributos e as arestas representam as dependências diretas entre eles. Um arco entre dois nós denota *influência* ou *correlação* e o conjunto de atributos que influenciam um determinado atributo x_i é usualmente designado por *Pais* de x_i (FACELI *et al.*, 2011). Para cada x_i , existe uma tabela de probabilidade condicional $P(x_i | \text{Pais de } x_i)$ que quantifica a influência dos pais sobre x_i . O conjunto dessas tabelas de probabilidades condicionais constitui, então, a segunda componente da tupla Θ_s .

Ainda, segundo Faceli *et al.* (2011), dado um conjunto de treinamento, o problema de aprendizado consiste em selecionar a hipótese $hc = (S, \Theta_s)$ que produz a classificação com maior acurácia para os dados não conhecidos.

2.2.3 Árvores de decisão

Outra técnica para construir um classificador é a indução de árvores de decisão. Nela, as folhas são as classes possíveis e os demais nós (incluindo a raiz) e as ligações entre eles

determinam as condições de teste sobre os atributos. Na Figura 1 há um exemplo de árvore de decisão que decide se alguém joga ou não com base em condições meteorológicas (atributos): tempo, umidade e vento.




Figura 1. Uma árvore de decisão para o problema de jogar ou não com base em condições meteorológicas.

Para classificar uma instância desconhecida, percorre-se a árvore no sentido da raiz para as folhas com base nos valores dos atributos testados nos sucessivos nós e quando uma folha é atingida, a instância é classificada de acordo com a classe atribuída à folha (WITTEN; EIBE; HALL, 2011).

Uma das vantagens de se construir um classificador como uma árvore de decisão é a facilidade de interpretação do modelo gerado. Ademais, o processo de teste e execução é computacionalmente barato, já que consiste basicamente em um caminho no ramo da árvore que atende às regras estabelecidas. Conforme comentado por Tan; Steinbach e Kumar (2005), no pior caso a complexidade será de $O(w)^1$ onde w é a profundidade da árvore.

Contudo, conforme também argumentam Tan; Steinbach e Kumar (2005), o processo de construção de uma árvore de decisão ótima é um problema *NP-completo*. E nesse processo, com base nos dados de treinamento, é preciso definir:

- Quais os atributos serão utilizados para construção da árvore.
- Qual a melhor forma de divisão dos ramos da árvore.
- Quando a divisão dos nós e o crescimento da árvore devem ser finalizados e se será empregada alguma estratégia de poda. Poucos níveis podem deixar o modelo muito

¹ notação O : limite assintótico superior. Uma explanação detalhada sobre complexidade computacional e notação assintótica está disponível nos capítulos 2 e 3 de (CORMEN *et al.*, 2012).

simplificado (*underfitting*), mas em contrapartida uma árvore com profundidade muito alta pode estar superajustada com perda de generalidade (*overfitting*).

A escolha dos atributos e da melhor forma de divisão busca otimizar algum critério. Um desses critérios é a medida de pureza do nó, assim a escolha da forma de divisão de um nó pai seria aquela que minimizaria a impureza dos nós filhos (TAN; STEINBACH; KUMAR, 2005).

A medida mais popular de impureza é a entropia (DUDA; HARR; STORK, 2001), que é calculada da forma:

$$Entropia(t) = - \sum_{i=1}^c p(y_i|t) \log_2 p(y_i|t) \quad (3)$$

onde $p(y_i|t)$ é a fração do número de instâncias da classe y_i em um dado nó t e c é o número de classes do problema. Por sua vez, para determinar se a divisão é adequada, deve-se comparar o grau de impureza do nó pai (antes da divisão) com o grau de impureza dos nós filhos (depois da divisão). O ganho de informação Δ_{info} é um critério que pode ser usado para determinar a qualidade da divisão (TAN; STEINBACH; KUMAR, 2005):

$$\Delta_{info} = Entropia(pai) - \sum_{j=1}^k \frac{N(filho_j)}{N} Entropia(filho_j) \quad (4)$$

onde N é o número de instâncias no nó pai, $N(filho_j)$ o número de instâncias no nó $filho_j$ e k o número de filhos diretos do nó pai. Algoritmos de indução de árvores de decisão frequentemente escolhem a divisão que maximiza o ganho (TAN; STEINBACH; KUMAR, 2005).

2.2.4 Máquinas de Vetores de Suporte

Em um processo de aprendizagem, um classificador é bem sucedido quando ele consegue distinguir perfeitamente o espaço de amostragem de cada uma das classes existentes. Alguns métodos encontram um hiperplano de separação entre as classes, mas não necessariamente uma solução ótima para o problema, como mostrado na Figura 2.




Figura 2. Hiperplano de separação entre classes não ótimo.

O objetivo das Máquinas de Vetores de Suporte (do inglês, *Support Vector Machines* – SVM) é encontrar uma solução ótima que maximize a margem de separação do hiperplano, sem pontos ou instâncias próximas à fronteira de decisão (Figura 3). Assim, quanto mais distantes estiverem os pontos da fronteira, menor o risco de erro sobre a classificação.




Figura 3. Hiperplano de separação entre classes gerado pelo SVM.

Considerando o caso de separação entre duas classes, seja x um vetor de entrada representando o conjunto de treinamento, conforme Lorena e Carvalho (2007), os pontos de x que se encontram no hiperplano satisfazem a equação:

$$f(x) = w \cdot x + b = 0 \quad (5)$$

onde $w \cdot x$ é o produto escalar entre x e w , w é o vetor normal ao hiperplano, $b/\|w\|$ a distância perpendicular do hiperplano à origem e $\|w\|$, a norma Euclidiana de w . O problema consiste em encontrar w e b , tal que a margem de separação do hiperplano ρ ($2/\|w\|$) seja maximizada.

Outra questão a considerar são as situações em que não é possível separar os dados por um hiperplano. Nesses casos, a partir de uma função *kernel* de transformação, as SVMs mapeiam o vetor de entrada para um novo espaço de maior dimensão e, após essa transformação, o novo espaço deve ser passível de separação linear. A ideia é que quanto maior a dimensão do espaço, mais fácil será torná-lo linearmente separável. Na Tabela 1 a seguir, são listados exemplos de funções *kernel*.

Tabela 1. Exemplos de funções *Kernel*

Tipo	Função <i>Kernel</i> $K(x_i, x_j)$	Parâmetros
Linear	$x_i \cdot x_j$	-
Polinomial	$(\delta (x_i \cdot x_j) + k^d)$	δ, k, d
Base radial RBF	$\exp(-\sigma \ x_i - x_j\ ^2)$	σ
Sigmóide	$\tanh(\delta (x_i \cdot x_j) + k)$	δ, k

Ressalta-se ainda que a solução para maximizar a margem de separação do hiperplano é um problema de otimização quadrático.

O método de Otimização Mínima Sequencial (do inglês, *Sequential Minimal Optimization* – SMO) desenvolvido por John Platt apresenta uma estratégia de decomposição do problema de otimização quadrático original quebrando-o em uma série de menores subproblemas, que por sua vez são resolvidos analiticamente (PLATT, 1999).

O SMO aplica dois multiplicadores de Lagrange em cada passo e o algoritmo pode ser resumido da seguinte forma:

- Encontre um multiplicador de Lagrange α_1 que viole a condição *Karush-Kuhn-Tucker* (KKT) para o problema de otimização. Uma condição KKT é uma condição necessária e suficiente para que a solução de um problema de programação não linear seja ótima.
- Selecione de forma heurística um segundo multiplicador α_2 e então otimize os dois multiplicadores (α_1, α_2) em conjunto.
- Compute um novo limiar b . Se os dados são linearmente separáveis, há um único valor de b que maximiza a margem.
- Repita os passos anteriores até que a condição KKT seja satisfeita. O problema é resolvido quando a condição for satisfeita por todos os multiplicadores.

2.2.5 Combinação de classificadores

Ao se deparar com uma questão ou problema de difícil solução, é naturalmente desejável, se possível, que a decisão seja tomada a partir da opinião de vários especialistas ao invés do julgamento de um só indivíduo. A solução final pode ser o resultado da compilação das considerações individuais ou mesmo o resultado de uma simples votação com escolha da sugestão mais frequentemente proferida.

Esse preceito do cotidiano, em princípio, também pode ser adotado no aprendizado de máquina para o problema de classificação. Conforme comentado por Witten; Eibe e Hall (2011):

"Uma abordagem óbvia para a tomada de decisões mais confiável é combinar a saída de vários modelos diferentes. Várias técnicas de aprendizado de máquina podem fazer isso por meio do aprendizado de um conjunto de classificadores e usando-os em combinação".

2.2.5.1 *Bagging*

Um esquema para combinação de classificadores é o *Bagging - Bootstrap Aggregating*, descrito por Breiman (1996). Ele produz várias amostragens dos dados de treinamento, gerando-as por meio de reposição e remoção de instâncias. Todas as amostragens possuem o mesmo número n de instâncias dos dados originais. Uma determinada instância pode estar presente de forma repetida em uma amostragem, da mesma forma que pode estar ausente em outra.

Na fase de treinamento, o classificador base é aplicado sobre cada amostragem individualmente, gerando um modelo de aprendizado. Na fase de testes, os modelos produzidos são aplicados para classificar cada uma das amostras da base de testes e a classificação final se dá por meio de um esquema de votação uniforme. O esquema pode ser resumido pelo Pseudocódigo 1 a seguir:

Pseudocódigo 1. Bagging: treinamento e classificação. Adaptado de (WITTEN; EIBE; HALL, 2011).

Treinamento

Seja n o número de instâncias nos dados de treinamento.

Para cada uma das t iterações:

 Faça amostragem de n instâncias com substituição.

 Aplique o algoritmo de aprendizagem sobre a amostragem atual.

 Armazene o modelo resultante.

Classificação (de uma instância)

Para cada um dos t modelos:

 Determine a classe da instância de teste usando o modelo.

Retorne a classe que foi prevista o maior número de vezes.

2.2.5.2 Boosting

Retomando o exemplo do cotidiano, uma forma de cooperação para tomada da decisão prescinde que os especialistas se complementem, suprimindo suas deficiências individuais a partir do aprendizado colhido de outros com maior conhecimento sobre determinada parte do problema.

O esquema de *Boosting* nasce dessa ideia: produzir um modelo de classificação mais aprimorado a partir da combinação de modelos mais fracos. Para isso, inicialmente, *boosting* aplica um peso uniforme para cada uma das instâncias de treinamento. Depois, por meio de um processo iterativo, a cada ciclo produz um novo modelo de classificação, ajustando os pesos das amostras de acordo com o desempenho dos classificadores gerados até aquela iteração.

Instâncias classificadas erroneamente têm seus pesos incrementados e instâncias classificadas corretamente têm seus pesos decrementados. Assim, atribuindo maior peso a instâncias tratadas incorretamente por modelos anteriores, *Boosting* incentiva os novos modelos a se tornarem especialistas nessas instâncias (WITTEN; EIBE; HALL, 2011).

Witten; Eibe e Hall (2011) comparam *Boosting* com *Bagging* e afirmam que *Boosting* frequentemente produz modelos de classificação significativamente mais precisos do que aqueles gerados por *Bagging*. Contudo, *Boosting* pode falhar em uma situação prática: ele pode gerar classificações menos precisas do que aquelas produzidas por um único classificador treinado sobre os mesmos dados.

2.3 Inteligência de enxames e o algoritmo *Firefly*

Algumas técnicas de aprendizado de máquina buscam resolver um problema de aprendizado por meio de um processo de otimização, cuja saída consiste em maximizar ou minimizar uma função objetivo. Dentre essas técnicas, aquelas baseadas em algoritmos bioinspirados baseados em populações e meta-heurísticas têm sido bastante difundidas.

Conforme descrito por Serapião (2009), o princípio fundamental desses algoritmos utiliza um método construtivo para a obtenção da população inicial e uma técnica de busca local para melhorar a solução da população, considerando que os indivíduos (soluções) dessa população são evoluídos de acordo com regras especificadas que examinam o intercâmbio de informações entre eles. Esse processo conduz a população em direção à obtenção de uma solução ótima.

Por sua vez, um subconjunto dessas técnicas baseadas em populações é a inteligência de enxames (do inglês, *Swarm Intelligence* – SI). Ela é inspirada no comportamento coletivo de agentes biológicos como peixes, pássaros, abelhas, formigas e outros.

Um desses algoritmos é o *Firefly*, desenvolvido por Xin-She Yang em 2008 e 2009 (YANG, 2008), (YANG, 2009). Ele toma por referência o comportamento de emissão de luz dos vaga-lumes tropicais, uma vez que a intensidade dessa emissão determina a atratividade entre os indivíduos. Resumidamente, o algoritmo *Firefly* estabelece as seguintes regras básicas:

1. Vaga-lumes são unissex, de modo que a atração entre eles é independente do sexo.
2. A atratividade é proporcional ao brilho e ambos diminuem à medida que a distância entre os indivíduos aumenta. Assim, para quaisquer dois vaga-lumes piscantes, o de menor brilho se moverá em direção ao mais brilhante. Se não houver um elemento mais brilhante, o vaga-lume se moverá aleatoriamente.
3. A intensidade do brilho deve estar associada à função objetivo.

Diante dessas três regras, Yang (2009) define os passos básicos do algoritmo no Pseudocódigo 2, a seguir:

Pseudocódigo 2. Algoritmo *Firefly*

```
Função objetivo  $f(x)$ ,  $x = (x_1, \dots, x_d)^T$   
Gere a população inicial de vaga-lumes  $x_i$  ( $i = 1, 2, \dots, n$ )  
A intensidade de luz  $I_i$  de  $x_i$  é determinada por  $f(x_i)$   
Defina o coeficiente de absorção  $\gamma$   
Enquanto ( $t < \text{numero\_máximo\_de\_gerações}$ )  
    para  $i = 1 : n$  (onde  $n$  é o número de vaga-lumes)  
        para  $j = 1 : n$   
            Se ( $I_j > I_i$ ), Mova o vaga-lume  $i$  em direção a  $j$  nas  $D$ -dimensões  
            A atratividade varia com a distância  $r$  via  $e^{-\gamma r}$   
            Avalie as novas soluções e atualize a intensidade de luz  
        Ordene os vaga-lumes e encontre o melhor atual  
Resultados de pós-processamento e visualização
```

Yang (2009) também compara o algoritmo *FireFly* com otimização por enxame de partículas (do inglês, *Particle Swarm Optimization* – PSO) e algoritmos genéticos, com resultados superiores do *Firefly* em relação a essas duas abordagens. Ainda segundo Yang e He (2013), dentre as dezenas de novos algoritmos baseados em SI surgidos nos últimos anos, o *Firefly* tem se mostrado muito eficiente em lidar com problemas multimodais e de otimização global.

2.4 Verificação biométrica

Além de classificar um indivíduo, um sistema de reconhecimento biométrico pode ser usado para verificar a sua identidade. Em biometria, verificação é o processo que decide se um indivíduo é realmente quem ele alega ser. Um sistema de verificação biométrica, portanto, executa o modo de comparação um-para-um, confrontando as características biométricas capturadas do indivíduo com o modelo previamente cadastrado da identidade requerida (MALTONI *et al.*, 2000).

Jain; Ross e Prabhakar (2004) definem formalmente o problema de verificação, ilustrado na Figura 4, como: dado um conjunto de atributos de entrada X_Q e uma identidade reivindicada I , determine se (I, X_Q) pertence à classe w_1 ou w_2 , onde w_1 indica que a reivindicação é verdadeira (indivíduo genuíno) e w_2 , que é falsa (indivíduo é um impostor). X_Q é então comparado a X_I , o *template* ou modelo de I da seguinte forma:

$$(I, X_Q) \in \begin{cases} w_1, \text{ se } S(X_Q, X_I) \geq t \\ w_2, \text{ caso contrário} \end{cases} \quad (6)$$

onde S é uma função de pontuação que mede a similaridade entre X_Q e X_I e t é um limiar pré-definido.




Figura 4. Processo de verificação. Adaptado de (JAIN; ROSS; PRABHAKAR, 2004)

2.4.1 Taxas de erro no processo de verificação

Conforme argumentam Maltoni *et al.* (2000), o que se espera no cenário ideal é que um sistema biométrico sempre ofereça o julgamento correto. Contudo, ele é um sistema de reconhecimento de padrões que inevitavelmente poderá produzir algumas decisões incorretas.

Além do mais, as premissas de singularidade e permanência dos atributos biométricos não são uma verdade absoluta na prática e ainda não se constituem em fatos científicos estabelecidos (JAIN; ROSS; NANDAKUMAR, 2011). Os sistemas biométricos trabalham com as informações digitalizadas extraídas dos traços biométricos e não com os traços físicos em si e nesse processo pode haver variações nas medidas coletadas: seja por imperfeições no processo de captura, mudanças nas condições do ambiente ou mesmo alterações nas próprias características biométricas.

Nesse contexto, algumas medidas de erro podem ser tomadas para avaliar a precisão do sistema de verificação biométrica.

Conforme descrito por Jain, Ross e Prabhakar (2004), seja X_I o *template* cadastrado de um indivíduo I e X_Q , o conjunto de atributos de entrada a ser verificado, formam-se então as seguintes hipóteses:

H_0 : X_Q não advém da mesma pessoa do *template* X_I ;

H_1 : X_Q advém da mesma pessoa do *template* X_I .

Com as seguintes possíveis decisões:

D_0 : a pessoa não é quem ela diz ser — indivíduo é um impostor;

D_1 : a pessoa é quem ela diz ser — indivíduo é genuíno.

A decisão, por sua vez, é tomada da seguinte forma: se a função de pontuação $S(X_Q, X_I)$ é menor que o limiar t , então decide D_0 , caso contrário, decide D_1 .

Com as hipóteses formuladas, têm-se os seguintes tipos de erro:

Tipo I: falso casamento (D_1 é decidido quando H_0 é verdade);

Tipo II: falso não casamento (D_0 é decidido quando H_1 é verdade);

Assim, taxa de falsa aceitação (do inglês, *False Match Rate* – FMR ou *False Acceptance Rate* – FAR) é a probabilidade do tipo I ocorrer, enquanto a taxa de falsa rejeição (do inglês, *False Non-Match Rate* – FNMR ou *False Rejection Rate* – FRR) é a probabilidade do erro tipo II ocorrer, ou seja:

$$\text{FMR} = P(D_1|H_0);$$

$$\text{FNMR} = P(D_0 | H_1).$$

De forma mais rígida, FMR e FAR podem não ser necessariamente sinônimos, assim como FNMR e FRR também não. Conforme esclarecem Jain; Ross e Nandakumar (2011), FMR e FNMR são calculadas como uma proporção do número de tentativas de casamento, já FAR e FRR são métricas em nível de aplicação que medem a proporção de sucesso ou falha nas transações e uma transação pode envolver uma ou mais tentativas de casamento. Entretanto, para os fins deste trabalho, elas podem ser consideradas equivalentes.

Uma medida tomada a partir das duas anteriores e bastante utilizada para comparação de sistemas biométricos é a taxa de erro igual (do inglês, *Equal Error Rate* – EER) que indica a taxa de erro quando $\text{FMR}(t)$ e $\text{FNMR}(t)$ são iguais, sendo t o limiar onde ocorre a igualdade. Essa situação está ilustrada na Figura 5 a seguir:




Figura 5. Exemplo de curvas $FMR(t)$ e $FNMR(t)$ com determinação do EER

Capítulo 3

Reconhecimento por geometria da mão: o estado da arte

Conforme comentado por Sidlauskas e Tamer (2008), a geometria da mão é um meio de autenticação com uma longa história de uso. Alguns dizem que marcas de mãos em pinturas antigas na Caverna de Chauvet, na França, com datação do carbono de 31.000 anos, seriam assinaturas exclusivas deixadas pelos artistas. Esse é, talvez, o primeiro uso de geometria da mão para identificação de indivíduos.

Retornando ao mundo contemporâneo, nos anos de 1970, foi introduzido o primeiro *scanner* comercial de geometria da mão, baseado na patente de Miller (1971). Denominado de Identimat, o dispositivo eletromecânico media o tamanho dos quatro dedos (mínimo, anelar, médio e indicador) e comparava os dados obtidos com medidas previamente cadastradas em um cartão de identificação. Embora outras patentes de dispositivos de identificação com base na geometria da mão tenham sido depositadas no mesmo período, como os trabalhos desenvolvidos por Ernst (1971) e Jacoby; Giordano e Fioretti (1972), o Identimat foi o único que ultrapassou a fase de protótipo (DUTA, 2009), sendo comercializado até 1987.

Mais recentemente, várias pesquisas têm sido desenvolvidas propondo novas estratégias de reconhecimento por geometria da mão. Métodos mais tradicionais exigem a utilização de pinos ou fixadores para estabelecer o correto posicionamento das mãos, como em Sanchez-Reillo; Sanches-Avila e Gonzalez-Marcos (2000). No trabalho deles foram utilizadas imagens de 20 indivíduos, sendo 10 imagens por pessoa. Ainda foram testadas diferentes técnicas de classificação e verificação, as quais incluíram métodos estatísticos baseados em distância e redes neurais. Os experimentos alcançaram uma taxa de até 97% de sucesso na classificação usando Modelos de Mistura Gaussiana (do inglês, *Gaussian Mixture Model* – GMM).

A inclusão de pinos garante um posicionamento uniforme das mãos, simplificando sobremaneira o trabalho de segmentação das imagens. Contudo, pode ser bastante desconfortável para os usuários; indivíduos com artrose, por exemplo, podem ter dificuldades para posicionar as mãos adequadamente nos dispositivos de captura. Trabalhos mais recentes exploram o posicionamento mais natural das mãos, seja sem a imposição dos pinos como em (XIONG *et al.*, 2005), seja inclusive, com as mãos totalmente livres de contato de quaisquer superfícies (MORALES *et al.*, 2008),(DE SANTOS-SIERRA *et al.*, 2011), (GUO *et al.*, 2012).

Xiong *et al.* (2005) analisam as dificuldades e os desafios para realizar o processo de segmentação e extração de atributos sem o auxílio dos pinos para guiar o posicionamento das mãos. No trabalho deles, diversas medidas de largura ao longo dos dedos são extraídas. Uma taxa EER de 2,41% é alcançada no processo de verificação usando 37 medidas por dedo em uma base de dados de 108 pessoas, com cinco imagens por pessoa.

Em (DE SANTOS-SIERRA *et al.*, 2011) são utilizados três bancos de dados de 120, 235 e 287 pessoas. Nesse trabalho também são extraídas medidas de largura ao longo dos dedos, com exceção do polegar. O melhor resultado obtido foi uma taxa EER de aproximadamente 1,4% com a base de 287 indivíduos, 20 medidas extraídas por dedo e quatro amostras de treinamento por pessoa.

Morales *et al.* (2008) comparam infravermelho e iluminação visível na captura das imagens e utilizam uma população de 30 indivíduos, sendo 10 imagens por indivíduo. É alcançada uma taxa de EER de 4,2% utilizando luz infravermelha.

Em (GUO *et al.*, 2012) também é utilizada iluminação infravermelha e são extraídas 34 características entre medidas de largura e comprimento dos dedos. Uma base de dados contendo 6000 imagens de 100 pessoas é utilizada. A classificação é realizada utilizando Máquinas de Vetores de Suporte e o melhor resultado alcançado foi uma taxa de identificação correta de 96,23%.

Uma metodologia utilizando algoritmos genéticos (do inglês, *Genetic Algorithms* – GA) e informação mútua² é proposta por Luque-Baena *et al.* (2013). O trabalho estuda o quão discriminantes são as características geométricas das mãos e mais de 400 atributos são

² Informação mútua é uma medida que avalia a correlação entre duas variáveis aleatórias, quantificando a informação comum entre elas. Maiores informações podem ser obtidas em (COVER; THOMAS, 2006), cap. 2.

extraídos e submetidos a um processo de seleção. Três diferentes bancos de dados de mãos são utilizados, dois deles com posicionamento livre de contato e um terceiro contendo imagens de mãos posicionadas em uma superfície, mas sem pinos. Para classificação foram utilizados três diferentes métodos combinados com GA: K-NN, Análise Linear Discriminante (do inglês, *Linear Discriminant Analysis* – LDA) e SVM. Os experimentos alcançaram até 100% de acurácia na classificação utilizando uma estratégia que combina GA e LDA. Esse resultado foi obtido utilizando a base de dados sem pinos, mas com contato entre a mão e uma superfície. Dessa base foram utilizadas amostras de 144 indivíduos, sendo 10 imagens da mão direita de cada um deles. Os 100% de acerto foram obtidos em dois experimentos, utilizando 34 e 22 atributos selecionados dentre os mais de 400 extraídos. Em seu trabalho, o método também foi submetido a um processo de verificação utilizando as bases sem contato, com uma taxa alcançada de EER entre 4% e 5%.

Em vários trabalhos, pesquisadores combinam geometria da mão com outros métodos de reconhecimento cujos atributos também são extraídos das mãos. Kumar e Zhang (2006) propõem um método que combina geometria da mão e impressão palmar. Os experimentos são realizados a partir de 1000 imagens de 100 pessoas, portanto 10 imagens por indivíduo. A avaliação é feita com base em esquemas de classificação diversos. O melhor desempenho em termos de acurácia, extraindo unicamente características geométricas das mãos foi de 89,6% utilizando árvores de decisão logística (do inglês, *Logistic Model Tree* – LMT) com 23 atributos extraídos. Combinando geometria e impressão palmar, o melhor resultado foi de 98% utilizando SVM.

Outro trabalho de fusão de características biométricas das mãos foi desenvolvido por Savič e Pavešić (2007). Nele são extraídos 14 atributos geométricos mais impressão palmar, impressão digital e dos dedos: indicador, médio, anelar e mínimo. As imagens de 4960 x 5669 pixels e 256 níveis de cinza são obtidos do lado palmar das mãos por meio de um *scanner* com resolução de 600 *dpi*. Uma base com 2000 imagens de 100 pessoas diferentes é utilizada, sendo 10 imagens da mão esquerda e outras 10 da mão direita de cada uma delas. Considerando que as mãos esquerda e direita de um mesmo indivíduo são diferentes, elas também foram consideradas como de pessoas distintas. Assim, ao invés de 100 classes, o trabalho considera 200 classes distintas. Os atributos são extraídos usando LDA e diferentes medidas de similaridade são experimentadas no processo de verificação: correlação normalizada, distância euclidiana e distância Manhattan com e sem pesos. O processo de

reconhecimento com as características combinadas produziu uma taxa EER média de 0,0005%; utilizando apenas geometria da mão foi obtido um EER de 1,51%.

Kanhangad; Kumar e Zhang (2011) propõem um *framework* unificado para verificação de reconhecimento de indivíduos usando dados das mãos. Nesse trabalho, além de atributos 2D (bidimensionais), também são extraídas características 3D (tridimensionais) usando um digitalizador 3D para simultaneamente extrair informações de profundidade e intensidade das imagens. Uma base de dados sem contato contendo dados de 177 indivíduos é utilizada e deles são extraídos geometria da mão (2D e 3D), impressão palmar (2D e 3D) e textura dos dedos. Uma taxa de EER de 0,22% é alcançada com a combinação de todas as características. Utilizando apenas geometria das mãos, tem-se um EER de 6,3%, 3,5%, e 2,3%, respectivamente, para geometria 2D, 3D e (3D + 2D) em conjunto.

Michael; Connie e Teoh (2012), por sua vez, propõem um método de reconhecimento combinando diversas características extraídas das mãos: geometria, impressão palmar, veias palmares, impressão das juntas dos dedos e veias dos dedos. Um dispositivo que conjuga uma câmera de luz visível e outra de infravermelho, lado a lado, é utilizado para captura das imagens. O usuário não tem contato com o dispositivo, mas é exigido que ele disponha a mão a uma distância de 25 cm, com uma margem de tolerância de até 4 cm. Uma base de dados de 136 usuários é utilizada, sendo 36 deles durante a fase de desenvolvimento para definição dos parâmetros do sistema e os demais para a avaliação do método. O desempenho com a fusão das cinco modalidades alcança uma taxa EER de 0%. Usando apenas geometria da mão, a taxa EER obtida é de 3,61%.

O trabalho de Park e Kim (2013), finalmente, consiste em mais uma proposta que adota geometria e padrão vascular das mãos. As imagens são capturas a partir de um dispositivo equipado com uma câmera com LED (do inglês, *Light-Emitting Diode*) infravermelho, um filtro de infravermelho, um espelho e um suporte para a mão com cinco picos determinando o posicionamento. São coletadas imagens do dorso da mão e da sua lateral. Um total de 1300 imagens de 100 indivíduos é utilizado. Destas, três imagens por pessoa foram aplicadas no treinamento e 10 nos testes. O trabalho obteve um EER de 0,06% combinando informações vasculares e geométricas. Utilizando apenas geometria da mão fora alcançado um EER de 1,81%.

Um quadro comparativo abordando esses trabalhos é mostrado na Tabela 2.

Tabela 2. Comparativos de métodos de reconhecimento de indivíduos utilizando geometria das mãos presentes na literatura.

Trabalho	Nº de pessoas	Nº de amostras por pessoa	Outras características além da geometria da mão	Forma de captura	Estratégias para classificação ou verificação	Desempenho
(SANCHEZ-REILLO; SANCHEZ-AVILA; GONZALEZ-MARCOS, 2000)	20	10	--	Com pinos	Métodos baseados em distância e redes neurais, GMM	Acurácia classificação = 97%
(XIONG <i>et al.</i> , 2005)	108	5	--	Sem pinos	Método baseado em distância	EER = 2,41%
(KUMAR; ZHANG, 2006)	100	10	Impressão palmar	Sem pinos	NaiveBayes, C4.5, LMT, SVM, FFN, K-NN	Acurácia classificação = 98%
(SAVIČ; PAVEŠIĆ, 2007)	100	20	Impressão palmar, impressão digital e dos dedos	Sem pinos	Correlação normalizada, distância euclidiana e distância Manhattan	EER = 0,0005%
(MORALES <i>et al.</i> , 2008)	300	10	--	Sem contato	SVM	EER = 4,2%
(KANHANGAD; KUMAR; ZHANG, 2011)	177	10	Impressão palmar (2D e 3D) e textura dos dedos	Sem contato	Medidas de distância e fusão de atributos 2D e 3D	EER = 2,3%
(DE SANTOS-SIERRA <i>et al.</i> , 2011)	287	10	--	Sem contato	Medidas de distância	EER = 1,4%
(GUO <i>et al.</i> , 2012)	100*	6	--	Sem contato	SVM	Acurácia identificação = 96,8%; FAR = 1,85%
(MICHAEL; CONNIE; TEOH, 2012)	136	10	Impressão palmar, veias palmares, impressão das juntas e veias dos dedos	Sem contato	Medidas de distância e fusão em nível de escore (regra da soma e SVM)	EER = 0%
(PARK; KIM, 2013)	100	13	Padrão vascular das mãos	Com pinos	Medidas de distância e fusão em nível de escore, decisão e extração de atributos	EER = 0,06%
(LUQUE-BAENA <i>et al.</i> , 2013)	144*	10	--	Sem pinos	GA, K-NN, LDA, SVM	Acurácia classificação = 100%

* O trabalho utiliza outras bases de dados, mas foi reportada aquela com melhor resultado nos experimentos.

Capítulo 4

Materiais e métodos

Esse capítulo detalha a proposta de reconhecimento de indivíduos por geometria da mão desenvolvida neste trabalho, especificando os materiais e métodos utilizados. Nele, descrevem-se as etapas e atividades do processo de reconhecimento:

1. Aquisição de imagens;
2. Pré-processamento e segmentação;
3. Extração de atributos;
4. Decisão: classificação e verificação.

Na Figura 6 é apresentado um fluxograma do processo.




Figura 6. Etapas do processo de reconhecimento

4.1 Ambiente de desenvolvimento

O método proposto e os experimentos foram executados em um computador com processador Intel Core i7-3630QM, *clock* do processador de 2,40 GHz, 8 GB de memória RAM e Windows 8.

Os algoritmos de pré-processamento, segmentação e extração de atributos foram desenvolvidos utilizando a plataforma Java[®], *Standard Edition Development Kit 7* (JDK 7) e MATLAB[®], versão R2011a. O processo de classificação foi realizado com auxílio da ferramenta WEKA – *Waikato Enviroment for Knowledge Analysis* (HALL *et al.*, 2009), versão 3.7.11, com experimentos codificados em linguagem Java. O processo de verificação também foi desenvolvido em Java.

4.2 Aquisição de imagens

As imagens utilizadas nesse trabalho foram adquiridas a partir de um dispositivo composto por um negatoscópio, uma caixa em MDF e uma câmera fotográfica DSLR, conjunto ilustrado na Figura 7. Esse dispositivo produz um ambiente controlado de iluminação, sem interferências do meio externo. As mãos dos indivíduos foram posicionadas no interior da caixa a partir de uma abertura inferior em um dos lados. Ainda que o posicionamento das mãos fosse delimitado pela área da caixa, não havia pinos ou molduras, permitindo um posicionamento mais livre e confortável para os usuários.



Figura 7. Dispositivo de captura composto por negatoscópio, caixa em MDF e câmera fotográfica. A imagem à esquerda destaca a câmera posicionada sobre a caixa. Fonte: (SILVA, 2013).

As imagens foram capturadas com 5184x3456 pixels em formato *raw* (especificamente, no formato *raw* CR2, da Canon), de modo que nenhum mecanismo de compressão com perdas ou quaisquer outras técnicas de processamento de imagens foram aplicadas durante a aquisição. Cada pixel é representado por 15 bits de informação em cada banda de cor (vermelho, verde e azul).

Esse processo de aquisição foi desenvolvido em projetos anteriores e as imagens utilizadas fazem parte do banco de dados multibiométrico Biopass-UFPB. Para esse trabalho, 1200 imagens da mão esquerda de 100 indivíduos foram utilizadas. De cada indivíduo foram capturadas sete imagens do dorso da mão e outras cinco da face palmar, totalizando deste modo, 12 imagens por pessoa.

Das pessoas incluídas neste estudo, 50 eram do sexo masculino e 50 do sexo feminino, todas com idade entre 16 e 57 anos. Ainda, entre uma captura e outra, o indivíduo retirava a mão do dispositivo e a recolocava novamente, impedindo a geração de amostras com o mesmo posicionamento. Na Figura 8 estão ilustrados dois exemplos, em menor escala, de imagens capturadas de um indivíduo: a imagem da esquerda com o lado dorsal e a da direita com o lado palmar.




Figura 8. Mão capturada de um indivíduo com a sua face dorsal e palmar

4.3 Pré-processamento e segmentação

Finda a captura, segue-se a etapa de pré-processamento, cuja saída é a imagem segmentada com as regiões de interesse para extração das características biométricas.

O processo de pré-processamento e segmentação é dividido nas seguintes tarefas, conforme destacado na Figura 6:

1. Limiarização da imagem e extração do contorno da mão.
2. Localização de picos e vales dos dedos e outros pontos auxiliares.
3. Delimitação e segmentação precisa de mão e dedos.

Essas tarefas estão descritas nas subseções seguintes e ilustradas resumidamente na Figura 9 a seguir.




Figura 9. Processo de segmentação da mão. a) Imagem do lado dorsal; b) mão após limiarização; c) contorno extraído; d) pontos para segmentação dos dedos: picos, vales e pontos auxiliares; e) dedos segmentados; f) mão segmentada.

4.3.1 Limiarização da imagem e extração do contorno da mão.

Inicialmente, as imagens são convertidas do formato *raw* para BMP e depois é adotado um processo simples de recorte de áreas não utilizadas (região das régua e quadro de cores), bem como a diferença entre a imagem da mão e da caixa de MDF vazia, o que resulta na imagem da mão isolada, sem os elementos de fundo.

Em seguida, um processo de limiarização utilizando o método de Otsu (OTSU, 1979) é aplicado. Nele, os pixels da imagem de L níveis de intensidade de cor são particionados em duas classes – C_0 e C_1 – preto e branco, onde uma delas corresponderá ao fundo e a outra, ao objeto, no caso, a mão. O particionamento se dá no limiar de intensidade de cor t , de forma que $C_0 = \{0, 1, \dots, t\}$ e $C_1 = \{t + 1, t + 2, \dots, L\}$, sendo t o limiar ótimo que minimiza a variância intraclasse. O resultado é uma imagem como a da Figura 9 (b).

Após a limiarização, as imagens do lado palmar são viradas – efeito *flip* – verticalmente (Figura 10). O objetivo é que ambas as imagens do lado palmar e dorsal apresentem a mesma orientação, permitindo que a partir desse ponto, todo o processo seguinte seja indiferente à face de captura da imagem.




Figura 10. Imagem palmar obtida; após limiarização; e após virada vertical (efeito *flip*).

O passo seguinte é a extração do contorno. Para isso, a função "*function B = bwboundaries (BW, conn, options)*" do MATLAB® é utilizada (GONZALEZ; WOODS; EDDINS, 2004). Essa função traça os limites exteriores de objetos presentes na imagem binária BW , retornando os contornos B de todos os objetos localizados. Assume-se que o maior contorno extraído S_m é a silhueta da mão e com base nele é gerada uma imagem da mão segmentada conforme exemplificado na Figura 9 (c).

4.3.2 Localização de picos e vales dos dedos e outros pontos auxiliares.

Concluída a tarefa descrita na subseção anterior, segue-se o próximo estágio para encontrar pontos sobre o contorno da mão – picos, vales e outros pontos auxiliares – que possibilitem a delimitação de mãos e dedos. Nesse processo, cinco picos (P_1 , P_2 , P_3 , P_4 e P_5), quatro vales (V_2 , V_3 , V_4 e V_6) e mais três pontos auxiliares (V_1 , V_5 e V_7), em um total de 12 pontos, são

identificados. Pode-se observar o posicionamento desses elementos sobre a silhueta da mão na Figura 9 (d).

Considerando o eixo x para colunas das imagens e o eixo y para linhas, no sentido da esquerda para direita, a função *bwboundaries* retorna o vetor S_m tendo como ponto inicial aquele que apresenta a menor coordenada y . Porém, para que o percurso sobre o contorno seja um caminho único e previsível em todas as imagens, independentemente da rotação da mão nas capturas, os pontos de S_m são rearranjados de modo que o ponto inicial $S_m[0]$ seja sempre o extremo inferior direito (ver Figura 11) e o contorno seja percorrido em sentido horário.




Figura 11. Contorno S_m rearranjado com percurso iniciando a partir do ponto extremo inferior direito.

O ponto inicial $S_m[0]$ será então, aquele cujas coordenadas obedecem às regras descritas no Pseudocódigo 3 a seguir:

Pseudocódigo 3. Definição do ponto inicial do contorno S_m

v_x = vetor com as coordenadas x de S_m ;
 $S_{\max}$ = subconjunto de S_m , onde para cada ponto $P(a, b) \in S_{\max}$, $a = \max(v_x)$;
 v_y = vetor de coordenadas y de $S_{\max}$;
 $S_m[0] = S_{\max}(a, \max(v_y))$;

Depois, o vetor de pontos do contorno S_m passa a ser percorrido à procura dos pontos desejados: um pico é identificado quando o valor da coordenada x , que no percurso de S_m estava diminuindo, começa a aumentar. O vale é encontrado de modo inverso, a partir de uma coordenada x que no percurso aumentava de valor e então começa a diminuir. O sistema

trabalha com margens de tolerância, definidas após experimentações, para evitar que ruídos no contorno ou outros elementos, como pelos, por exemplo, possam ser equivocadamente atribuídos a picos ou vales.

Na Figura 12 são exemplificados alguns posicionamentos de mãos, demonstrando diferentes ângulos de afastamento dos dedos entre uma e outra captura. Especificamente para identificação do pico do polegar (P_5) é adotado um tratamento especial considerando que na maioria das imagens, assim como na Figura 12 (a), o pico do polegar é ou está muito próximo ao ponto de menor coordenada y do contorno. Porém, como há certa liberdade no posicionamento das mãos, algumas imagens apresentam o polegar curvado como ilustrado na Figura 12 (c). Assim, é feita uma escolha entre o ponto encontrado no procedimento padrão (P_{5a}) e aquele com menor coordenada y (P_{5b}), segundo o Pseudocódigo 4 descrito a seguir:

Pseudocódigo 4. Algoritmo que define P_5

```

difx =  $P_{5b}.x - P_{5a}.x$ ;
dify =  $P_{5a}.y - P_{5b}.y$ ;
se dify < difx
     $P_5 = P_{5a}$ ;
senão
     $P_5 = P_{5b}$ ;

```




Figura 12. Posicionamento das mãos. Mãos em uma mesma linha são de um mesmo indivíduo. As mãos com a face palmar (e) e (f) foram viradas verticalmente para uniformizar a ilustração.

Após a identificação dos picos e vales, procede-se à determinação dos pontos auxiliares. O ponto V_1 é computado de modo que a distância entre V_1 e P_1 seja a mesma distância entre P_1 e V_2 . Um procedimento similar é adotado para encontrar os pontos V_5 e V_7 .

4.3.3 Delimitação e segmentação precisa de mão e dedos.

Sucede ao procedimento de localização dos picos e vales dos dedos da mão, descrito na seção anterior, um ajuste fino na localização dos pontos encontrados, de forma a possibilitar uma delimitação precisa dos limites inferiores de cada um dos dedos. Nesse processo, explicado a seguir, também são produzidos segmentos ajustados que determinam a inclinação natural dos dedos.

Para cada um deles, inicialmente, traça-se um segmento de reta AB – destacado na cor verde tracejada na Figura 13, onde A é o pico do dedo e B , o ponto médio entre vales adjacentes (ou entre um vale e um ponto auxiliar, conforme anteriormente descrito). O segmento encontrado é dividido em dois segmentos colineares – AC e CB – no caso do polegar e em três segmentos – AC , CD e DB – nos demais casos. Essa divisão corresponderia, sem requisitos de precisão, às falanges dos dedos.




Figura 13. Obtenção de segmentos ajustados dos dedos. O segmento inicial AB é obtido a partir dos pontos iniciais (picos, vales e pontos auxiliares) e subdividido nos segmentos AC , CD e DB . Estes por sua vez, são transformados nos segmentos ajustados IJ , JL e LM . Para o polegar o segmento AB é subdividido em AC e CB , gerando os segmentos ajustados IJ e LM .

Em seguida, o segmento AC é reduzido em 7%, assegurando que o ponto A fique sempre interno ao dedo e não na ponta da unha. Essa margem de 7% foi definida após experimentações preliminares. Do novo segmento AC, dois segmentos perpendiculares EF (onde $A \in EF$) e GH (onde $C \in GH$) são definidos. Desses segmentos, os pontos extremos E, F, G e H interceptam o contorno de modo que $\{E, F, G, H\} \subset S_m$. Um segmento ótimo IJ que conecta os pontos médios de EF e GH é traçado e substitui AC. IJ é estendido até o ponto I alcançar o contorno novamente, tornando-se o novo pico do dedo. Esse processo é ilustrado na Figura 14.




Figura 14. Processo de definição do segmento ajustado IJ. Da esquerda para direita: segmento AC inicial; AC após redução em 7%; IJ definido a partir dos pontos médios de EF e GH; prolongamento de IJ para interceptar o pico do dedo.

O próximo passo agora é encontrar o segundo segmento ajustado JL em substituição a CD, indicados anteriormente na Figura 13. Como o polegar possui apenas duas falanges, esse segmento não é calculado para o polegar. Assim como no passo anterior, segmentos EF e GH perpendiculares a CD são traçados, agora com $C \in EF$ e $D \in GH$. O segmento JL é definido como o segmento que conecta os pontos médios de EF e GH.

O último segmento ajustado LM que substitui a primeira falange (CB no polegar e DB nos demais dedos) é calculado de forma mais especializada. A definição do segmento a partir de pontos médios de segmentos perpendiculares poderia resultar em um desvio na inclinação do segmento, algo como exemplificado na Figura 15 (a). A fim de evitar essa falha, o segmento ajustado LM é definido como sendo o segmento que divide a primeira falange do dedo em duas partes simétricas em relação à extensão do dedo, resultando no segmento LM indicado na Figura 15 (b).




Figura 15. Definição do segmento ajustado LM. a) Definição de LM, caso fosse adotado o mesmo princípio aplicado ao segmento JL; b) Definição de LM como sendo o segmento que divide a primeira falange em duas partes simétricas em relação à extensão do dedo.

Para obter esse resultado, o seguinte procedimento é aplicado:

1. Define-se um segmento XY ligando os vales adjacentes, ou um vale a um ponto auxiliar, dependendo do dedo em questão.
2. Define-se $\text{min_distancia} = \text{MAXIMO_VALOR_NUMERICO}$;
3. Localiza-se um segmento candidato L'M', onde L' é o ponto médio do segmento GH (definido no passo anterior) e M' é um ponto em XY, no sentido de X para Y, começando em X.
4. Calcula-se Ω , um conjunto de segmentos perpendiculares a L'M' em toda extensão de L'M'.
5. Cada segmento do passo anterior é dividido em dois lados a partir da interseção com L'M'.
6. Define-se $\sum dif$ como a soma da diferença entre os lados dos segmentos em Ω .
7. Se $\sum dif < \text{min_distancia}$
 - a. $LM = L'M'$
 - b. $\text{min_distancia} = \sum dif$
 - c. Retorna ao passo 3, calculando um novo candidato L'M', fazendo M' se aproximar de Y.

Computados os segmentos ajustados, o próximo objetivo é delimitar o começo da primeira falange, ou seja, o limite inferior de cada um dos dedos. Na Figura 16, o processo é exemplificado com a definição do limite para o polegar, sendo aplicado também para todos os demais dedos.




Figura 16. Evolução do processo para determinar o limite inferior do dedo.

Assim, inicialmente, calcula-se um segmento OP perpendicular a LM, onde $M \in OP$ e cujos pontos extremos O e P interceptam o contorno S_m . Depois, esse segmento OP inicial é ajustado para que possa definir precisamente o limite inferior do dedo. O objetivo é procurar um limite ideal que pode estar em direção à palma, se o limite atual tiver sido definido ainda dentro do dedo; ou no sentido inverso: em direção ao pico do dedo, se o OP atual tiver sido definido sobre a mão (como é o caso ilustrado na Figura 16). Com o OP ajustado, LM também é ajustado, fazendo M novamente ser a interseção entre OP e LM. Por fim, como o OP encontrado é a fronteira entre o dedo e a mão, variações no ângulo de abertura dos dedos podem influenciar na forma de OP e isso não é desejado. LM, então, é reduzido em 10% e OP novamente reposicionado – ver OP final na Figura 16. Essa redução foi definida após experimentações, tendo o percentual de 10% se mostrado uma margem de correção razoável.

Esse procedimento é detalhado no Pseudocódigo 5. Nele, considera-se: $\|PQ\|$ como sendo a norma euclidiana de um segmento PQ; $\perp PQ$ um segmento perpendicular a PQ, cujos pontos extremos P e Q interceptam o contorno S_m e $\parallel PQ$ um segmento paralelo a PQ, cujos pontos P e Q também interceptam o contorno S_m .

Pseudocódigo 5. Algoritmo que ajusta o limite do dedo OP.

```
se dedo é polegar
     $XY = \perp IJ$ , com  $J \in XY$ 
senão
     $XY = \perp JL$ , com  $L \in XY$ 
max_largura =  $\|XY\| * 1.4$ 
se  $\|OP\| > largura\_maxima$ 
    Procure um  $O'P' // OP$  no sentido de M para L até que  $\|O'P'\| \leq max\_largura$ 
senão
    Procure um  $O'P' // OP$  na direção de L para a palma enquanto  $\|O'P'\| \leq max\_largura$ 
 $OP = O'P'$ 
Redefina LM, onde M é a interseção entre LM e OP
Reduza LM em 10% no sentido de M para L
 $OP = \perp LM$ , com  $M \in OP$ 
Redefina LM novamente, agora com M sendo o ponto médio de OP
 $OP = \perp LM$ , com  $M \in OP$ 
```

Estabelecido o pico e o segmento limite inferior de cada dedo, define-se um retângulo que circunscreve cada dedo. Por sua vez, esse polígono é utilizado como máscara para delimitar a região de interesse: áreas da imagem fora do retângulo são zeradas e apenas a geometria do dedo em análise é preservada. Após ser realizado esse procedimento para cada um dos dedos, em seguida, faz-se a combinação das imagens individuais, obtendo-se ao final o resultado mostrado na Figura 9 (e).

Finalmente, o processo de segmentação é concluído com a delimitação da mão. Para isso, o seguinte procedimento é aplicado:

1. Calcula-se o comprimento do dedo médio como sendo a soma das normas dos seus segmentos ajustados: $\|IJ\| + \|JL\| + \|LM\|$
2. Define-se um segmento paralelo ao limite inferior do dedo médio e que se distancia dele em 1,2 vezes o seu comprimento. De forma empírica, atribui-se essa distância ao comprimento da palma.
3. Os pontos extremos do segmento encontrado tocam o contorno S_m e este segmento separa a mão do punho.
4. A região após o segmento é eliminada, delimitando a área da mão. Um exemplo do resultado desse processo pode ser visto na Figura 9 (f).

Obviamente, esse método não estabelece de forma exata a fronteira entre a mão e o punho. Todavia, como o limite encontrado é invariante para todas as amostras de um mesmo indivíduo, o processo atende ao propósito desejado.

4.4 Extração de atributos

Nesse trabalho, 14 atributos são extraídos de cada um dos dedos da mão. São eles:

- Área: número de pixels da imagem do dedo.
- Perímetro: número de pixels do contorno.
- Comprimento: soma das normas dos segmentos ajustados.
- Largura inferior: norma do segmento OP.
- Área convexa: área do menor polígono convexo que contém o dedo.
- Excentricidade: excentricidade da elipse de mesmo segundo momento central normalizado da imagem do dedo (HARALICK; SHAPIRO, 1992).
- Tamanho do menor eixo: tamanho em pixels do menor eixo da elipse (mesma elipse descrita acima).
- Tamanho do maior eixo: tamanho em pixels do maior eixo da elipse.
- Seis medidas de largura (largura 1, largura 2, ..., largura 6) calculadas ao longo da extensão do dedo (Figura 17). No caso do polegar, as três primeiras medidas são calculadas como sendo a norma de segmentos de reta equidistantes e perpendiculares ao primeiro segmento ajustado. As outras três medidas restantes são calculadas da mesma forma, só que dessa vez tendo como referência segmentos perpendiculares ao segundo segmento ajustado. Nos demais dedos, todas as medidas são obtidas a partir da norma de segmentos equidistantes e paralelos ao limite inferior OP. Em todos os casos, os pontos extremos dos segmentos tocam o contorno S_m da imagem. Para uma maior eficiência computacional, os pontos dos segmentos que definem a extensão do dedo são calculados usando o algoritmo de Bresenham (BRESENHAM, 1965). Esse algoritmo encontra os pontos de um segmento de reta utilizando apenas operações de aritmética de inteiros e permite que o cálculo de um próximo ponto seja feito de forma incremental, tendo como base os cálculos já realizados para obter o ponto anterior.




Figura 17. Medidas de largura dos dedos.

Ainda, para todos os dedos, com exceção do polegar, mais duas medidas são tomadas:

- Ângulo 1: ângulo entre os segmentos IJ e JL.
- Ângulo 2: ângulo entre os segmentos JL e LM.

Os ângulos entre os segmentos – ilustrados na Figura 18 – são calculados da seguinte forma:

$$\text{angulo } \alpha = \arctan \left| \frac{m_s - m_r}{1 + m_s \cdot m_r} \right| \quad (7)$$

onde m_s e m_r são os coeficientes angulares dos segmentos de reta adjacentes.




Figura 18. Ângulos entre segmentos que determinam a inclinação natural dos dedos.

Esses ângulos não são calculados para o polegar, tendo em vista que ele pode ser articulado livremente e as medidas poderiam ser totalmente influenciadas pela flexão ou rotação adotadas durante a captura.

E para completar os descritores, mais seis medidas são calculadas da mão:

- Área, perímetro, excentricidade e tamanhos do maior e menor eixo da elipse - todos calculados de forma similar aos dedos. A área convexa foi excluída porque pode ser variante a forma de abertura entre os dedos (quanto maior a abertura, maior seria a área);
- Largura da palma (Figura 19): para calcular essa medida, definiu-se um segmento XY que conecta o ponto inicial $O_{\text{mínimo}}$ do limite inferior do dedo mínimo ($OP_{\text{mínimo}}$) ao ponto final $P_{\text{indicador}}$ do limite inferior do dedo indicador ($OP_{\text{indicador}}$). Um segmento ZW paralelo a XY com limites no contorno da mão e distante de $1/3$ do comprimento do dedo médio em relação à XY é calculado. A largura da palma é definida como a norma do segmento ZW.




Figura 19. Processo para o cálculo da largura da palma da mão. A largura é definida como a norma do segmento ZW.

Assim, os 16 atributos de cada um dos quatro dedos (mínimo, anelar, médio e indicador) somados aos 14 atributos do polegar, e mais aos seis atributos da mão, totalizam os 84

atributos que constituem o vetor de características geométricas utilizadas nos processos de classificação e verificação adotados neste trabalho.

4.5 Classificação

Diversos algoritmos de classificação foram avaliados no decurso deste trabalho, contemplando também diferentes técnicas: métodos probabilísticos, métodos de otimização, árvores de decisão, classificadores baseados em distância, entre outros. Ao final, 11 estratégias são testadas e os resultados são demonstrados no capítulo seguinte. A escolha foi motivada pelos resultados satisfatórios obtidos em vários cenários, mesmo em estágios preliminares da pesquisa, além do que alguns métodos foram utilizados em outros trabalhos, possibilitando maior margem de comparação. Ademais, o número vasto de estratégias possibilita avaliar o método de reconhecimento sob a perspectiva de diferentes modelos de aprendizagem.

Segue a relação dos algoritmos utilizados. A descrição do funcionamento de cada um deles está fora do escopo deste trabalho. Apenas a ideia básica do modelo de aprendizagem e as principais técnicas adotadas são mencionadas, bem como os principais parâmetros de configuração para execução. Uma explicação dos métodos sobre os quais se baseiam alguns desses algoritmos pode ser revista no Capítulo 2.

- IBk (AHA; KIBLER; ALBERT, 1991): O algoritmo IBk é uma implementação do classificador K-Vizinhos mais próximos (mencionada na seção 2.2.1). Nele, pode-se definir o número k de vizinhos, o método de busca e a função de distância a ser utilizada. Neste trabalho, utilizou-se a opção com apenas um vizinho mais próximo, busca linear sobre o conjunto de treinamento e distância euclidiana como medida de distância.
- BayesNet (BOUCKAERT, 2008): Implementação de redes bayesianas (vide seção 2.2.2). É possível configurar o algoritmo a ser utilizado para estimativa das tabelas de probabilidade condicional, além do método de escolha da estrutura da rede. No caso deste trabalho, foi utilizada uma estratégia simples de estimativa direta a partir dos dados e o algoritmo K2 (COOPER; HERSKOVITZ, 1992) para a definição da estrutura da rede. De forma resumida, o K2 previamente realiza uma ordenação dos

nós. Inicialmente, nenhum dos nós tem pais. O algoritmo então processa cada nó por vez e, numa estratégia gulosa, procura adicionar pais ao nó processado que maximizem a pontuação da rede. Para evitar sobreajuste do modelo, o número de pais de cada nó pode ser limitado a um valor máximo pré-definido, que foi escolhido como sendo 1 (um), valor pré-configurado na interface do WEKA.

- LibSVM(CHANG; LIN, 2011): LibSVM é uma biblioteca para Máquinas de Vetores de Suporte (vide seção 2.2.4) com implementação para problemas de classificação, regressão e estimativa de distribuição (classificação de uma só classe). Além de especificar o tipo da implementação, pode-se definir a função *kernel* a ser utilizada e se os dados devem ser previamente normalizados. Neste trabalho utilizou-se a função *kernel* linear e os dados de treinamento foram normalizados.
- SMO (PLATT, 1999): SMO é outra implementação para treinamento de Máquinas de Vetores de Suporte que utiliza o algoritmo *Sequential Minimal Optimization* de John Platt. Nele, pode-se indicar se os dados de treinamento devem ser submetidos a algum tipo de filtragem, seja com normalização ou padronização dos dados, além da função *kernel* a ser utilizada. Para esse caso também utilizou-se o *kernel* linear e a normalização dos dados.
- RandomForest (BREIMAN, 2011): Florestas aleatórias (*Random Forest*) são uma combinação de predições de árvores de decisão (vide seção 2.2.3). O algoritmo usa *bagging* (vide seção 2.2.5.1) para amostragem dos dados de treinamento combinado à seleção aleatória de atributos. Dois parâmetros são requeridos: o número de árvores e o número de atributos a serem utilizados. Neste trabalho definiram-se 10 árvores sem indicar um número específico de atributos. Nessas circunstâncias, o algoritmo define o número de atributos como sendo $(\log_2 N) + 1$, onde N é o total de atributos existentes. Assim, com 84 atributos, o número escolhido foi $(\log_2 84) + 1 = 7$.
- RotationForest (RODRIGUEZ; KUNCHEVA; ALONSO, 2006): RotationForest gera um conjunto de classificadores com base na extração de atributos. Conforme descrito por Witten; Eibe e Hall (2011), ele combina *bagging* e extração randômica de atributos (gerando um subespaço de atributos do total de atributos existentes) com

geração de componentes principais para construir um conjunto de árvores de decisão. O conjunto de atributos é aleatoriamente dividido em K subconjuntos disjuntos e Análise de Componentes Principais³ (do inglês, *Principal Component Analysis* - PCA) é aplicado a cada subconjunto. Outros filtros de projeção podem ser aplicados em substituição ao PCA, mas nesse trabalho manteve-se o padrão. O algoritmo base de árvores de decisão adotado foi o RandomForest e definiu-se um total de 10 iterações do método.

- LogitBoost (FRIEDMAN; HASTIE; TIBSHIRANI, 1998): LogitBoost é um algoritmo de *boosting* (vide seção 2.2.5.2), semelhante ao AdaBoost.M1, mas que utiliza um modelo de regressão logística aditiva para determinar a classificação em cada passo. Dentre outros parâmetros, a implementação permite especificar o algoritmo de aprendizado e o número de iterações. Pode-se ainda utilizar validação cruzada para deduzir o número de rodadas. Neste trabalho utilizou-se RandomForest como classificador base e o número de 10 iterações.
- LMT (LANDWEHR; HALL; FRANK, 2005): LMT é um modelo de classificação que combina árvores de decisão com regressão logística nas folhas. O LMT utiliza o algoritmo LogistBoost para produzir um modelo de regressão logística para cada nó da árvore e faz a divisão dos nós aplicando o Ganho de Informação como critério. Para determinar o número de iterações do LogistBoost, o LMT por padrão utiliza validação cruzada, mas um número específico de iterações pode ser indicado previamente. Neste trabalho definiu-se o valor de 30 para o número de iterações. A razão para essa mudança foi que em um dos cenários de testes, apenas uma amostra por classe está disponível na fase de treinamento e com apenas uma amostra não é possível realizar a divisão das partições para validação cruzada.
- AdaBoostM1: AdaBoost.M1 é uma implementação de *boosting* proposta por Freund e Schapire (1996). O algoritmo inicialmente atribui pesos uniformes a todas as instâncias de treinamento, mas em cada iteração, o algoritmo muda o peso das instâncias levando em consideração o erro do conjunto de classificadores construídos previamente. O peso das instâncias classificadas corretamente (classificação mais

³ Uma explicação detalhada sobre PCA está disponível (WITTEN; EIBE; HALL, 2011), capítulo 7.

fácil) é decrementado e incrementado para aquelas classificadas erroneamente (classificação mais difícil). Assim, a cada iteração seguinte, o classificador irá focar nas instâncias mais difíceis de classificar. Nesse trabalho, foram definidas 10 iterações e o método LMT como classificador base.

- FLR (KABURLASOS *et al.*, 2007): Segundo Khezeli e Nezamabadi-Pour (2012), muita atenção tem sido dada recentemente para aplicações da teoria de reticulados ⁴ (do inglês, *lattice theory*). *Lattice* $(L, \leq)$ é um conjunto parcialmente ordenado, de tal modo que quaisquer dois dos seus elementos $a, b \in L$ têm um limite inferior máximo denotado por $a \wedge b$ e um limite superior mínimo, denotado $a \vee b$. Por sua vez, um *fuzzy lattice* é uma tripla $(L, \leq, \mu)$, onde $(L, \leq)$ é um *lattice* clássico (*crisp*) e $(L \times L, \mu)$ é um conjunto *fuzzy* com função de pertinência $\mu: L \times L \rightarrow [0, 1]$ tal que $\mu(a, b) = 1$, se e somente se, $a \leq b$ (KABURLASOS, 2006). *Fuzzy Lattice Reasoning* (FLR) utiliza *fuzzy lattice* na indução de um conjunto de regras a partir dos dados de treinamento.
- Bagging (BREIMAN, 1996): Uma estratégia de *bagging* - explicada no Capítulo 2, seção 2.2.5.1 - também foi adotada. Como classificador base foi definido o algoritmo FLR e 10 como número de iterações.

4.6 Verificação

No processo de verificação foram utilizadas duas abordagens para comparação:

- **Abordagem 1:** a função de pontuação S que mede a similaridade entre a amostra verificada X_Q e o *template* da identidade requerida X_I é obtida a partir da fórmula:

$$S(X_Q, X_I) = \frac{1}{1 + d(X_Q, X_I)} \quad (8)$$

onde d é a distância euclidiana simples entre X_Q e X_I calculada conforme a Equação 1.

- **Abordagem 2:** a função de pontuação S é calculada a partir da Equação 8, só que nesse caso $d(X_Q, X_I)$ é uma distância euclidiana ponderada com atribuição de pesos para os atributos, seguindo a fórmula:

⁴ Uma explicação sobre teoria de reticulados pode ser obtida em (GRATZER, 1971).

$$d(X_Q, X_I) = \sqrt{\sum_{i=1}^n w_i (X_Q^i - X_I^i)^2} \quad (9)$$

Na Equação 9, w_i é o peso relativo do atributo i , ou seja, o peso de i dividido pela soma de todos os pesos.

Por sua vez, esses pesos foram definidos por meio de um processo de otimização utilizando o método *Firefly* (vide seção 2.3) aplicado sobre a base de treinamento. Nele, a função objetivo busca ao mesmo tempo maximizar a variância entre as classes/indivíduos existentes no treinamento e minimizar a variância entre as amostras de uma mesma classe.

A variância entre classes é calculada da forma:

$$\sigma_{inter}^2 = \sum_{c=1}^k \sum_{i=1}^n w_i (\mu_{ci} - \mu_i)^2 \quad (10)$$

onde μ_{ci} é a média do atributo i nas amostras de treinamento da classe c , μ_i é a média geral do atributo i considerando todas as amostras de treinamento e w_i o peso relativo do atributo i .

Já a variância intraclasse é calculada segundo a Equação 11:

$$\sigma_{intra}^2 = \sum_{c=1}^k \sum_{i=1}^n w_i (\sigma_{ci}^2) \quad (11)$$

onde σ_{ci}^2 é a variância do atributo i nas amostras da classe c e w_i o peso relativo do atributo i .

Finalmente, a função objetivo é definida da forma:

$$f_{obj} = \frac{1}{\sigma_{inter}^2} + \sigma_{intra}^2 \quad (12)$$

No que diz respeito aos demais parâmetros do *Firefly*, várias combinações foram experimentadas inicialmente, com a escolha final da seguinte configuração:

- População n de 30 indivíduos (vagalumes). Segundo Yang e He (2013), para a maioria das aplicações pode ser usada uma população de 15 a 100 indivíduos, embora o melhor intervalo esteja entre 25 e 40.
- Número máximo t , de gerações, igual a 30.000. Como a complexidade do algoritmo no pior caso é $O(n^2 t)$, e como n é pequeno, a complexidade é

praticamente linear em termos de t e assim pode-se aplicar um t grande com baixo custo computacional.

- A escala de valores para o problema foi definida entre 0 e 10 de modo que os pesos dos atributos obtidos estão compreendidos nessa faixa de valores.

Em ambas as abordagens, previamente, foi aplicada uma normalização por reescala sobre os atributos, conforme a equação a seguir:

$$V_{norm} = \frac{V_{atual} - min}{(max - min)} \quad (13)$$

onde min e max , são respectivamente, o menor e o maior valores encontrados para o atributo na base de treinamento; V_{atual} é o valor do atributo a ser normalizado e V_{norm} é o resultado do processo.

O resultado do processo de verificação é avaliado medindo a taxa de EER calculada sobre a base de testes. Os dados de testes também são normalizados segundo a Equação 13.

Capítulo 5

Resultados e discussões

Esse capítulo descreve os testes realizados com base nos materiais e métodos comentados no capítulo anterior, bem como apresenta e discute os resultados obtidos.

5.1 Avaliação visual do processo de segmentação

Um processo de segmentação com precisão elevada é fundamental para o sucesso das etapas seguintes do método de reconhecimento. A fim de avaliar essa precisão, foi realizada uma análise visual da segmentação do contorno e do resultado da delimitação de mãos e dedos produzidos neste trabalho. Buscou-se com isso, identificar falhas ou não-conformidades potencialmente causadoras de erros no processo de reconhecimento.

Considerando as 1200 imagens utilizadas, foram identificadas as seguintes situações:

- Ruído no contorno da imagem em decorrência de pelos – presente nas imagens de 9 dos 100 indivíduos. Todavia, esse ruído concentrou-se principalmente na área do antebraço, sem prejuízo para delimitação de mãos e dedos e extração de atributos. Uma das ocorrências onde o ruído é mais expressivo é ilustrada na Figura 20.




Figura 20. Ruído no contorno da imagem em decorrência de pelos. À esquerda, a imagem capturada; À direita, o contorno extraído com o ruído no antebraço em destaque; Abaixo, o quadro destacando o ruído na segmentação do antebraço em maior escala.

- Outra situação é a ocorrência de indivíduos com unhas grandes. Sete pessoas da base de dados apresentavam unhas grandes em pelo menos um dos dedos – um exemplo pode ser visto na Figura 21. Nenhum mecanismo especial foi adotado para identificar e tratar essas ocorrências. Como todas as imagens de um mesmo indivíduo foram obtidas em uma mesma sessão de captura, o comprimento das unhas não influenciou os resultados deste trabalho. Contudo, em um contexto real de reconhecimento, os indivíduos podem apresentar variações no tamanho das unhas em diferentes submissões ao sistema.




Figura 21. Indivíduo com unhas grandes. Imagem capturada à esquerda e à direita, o resultado da segmentação do contorno.

- Segmentação ruidosa das unhas nas pontas dos dedos, decorrente da proximidade em termos de cor com o fundo da imagem. Esse problema ocorreu na segmentação das imagens de 13 indivíduos e um exemplo é apresentado na Figura 22. Ainda assim, o mecanismo de extração de picos e vales, bem como os procedimentos de definição de segmentos ajustados e delimitação de dedos, conseguiram tratar o problema, evitando que ele repercutisse na identificação desses elementos. Uma ressalva, porém, é que a presença de ruído pode requerer um maior número de pixels para descrever o contorno e as medições do perímetro dos dedos e da mão podem ser afetadas, ainda que ligeiramente.




Figura 22. Segmentação de ponta de dedo com ruído. À esquerda, a imagem do dedo capturada e à direita, a segmentação do contorno. A segmentação é apresentada em maior escala para destacar o ruído.

- Além disso, em 16 imagens de cinco indivíduos, a presença de brilho nas unhas ocasionou um ruído mais significativo, gerando fendas na segmentação do contorno. Entretanto, dessas 16 imagens, apenas em duas delas (ambas, imagens de um mesmo dedo) o ruído ocasionou falhas nas etapas seguintes de delimitação de dedos e extração de atributos. Uma dessas imagens é ilustrada na Figura 23.

De modo geral, as falhas na segmentação não parecem, ao menos visualmente, ter prejudicado o processo de extração de atributos, com a ressalva de ocorrências pontuais. De todo modo, mecanismos de atenuação do ruído podem ser adotados procurando garantir a maior precisão possível. E quanto maior a precisão da segmentação e extração de atributos, mais fáceis se tornam os processos classificação e verificação. Processos estes, que são discutidos a seguir.




Figura 23. Geração de fenda na ponta do dedo. De cima para baixo: a imagem como foi capturada; o resultado da segmentação; as medidas extraídas, com falha na determinação do primeiro segmento ajustado IJ e, por conseguinte, do ângulo 1, porém sem repercussão sobre a definição dos demais segmentos ajustados e das medidas de largura.

5.2 Experimentos de classificação

Nos experimentos, para avaliar de forma imparcial o desempenho da classificação de todos os métodos testados, foram utilizadas as técnicas validação cruzada estratificada e subamostragem aleatória estratificada.

5.2.1 Classificação com validação cruzada

Nos testes com validação cruzada foram utilizados 10 *folds* ou partições. Valores entre 5 e 20 partições também foram testados, mas sem apresentar variações relevantes de resultados. Manteve-se o número 10 por ser o mais comumente utilizando. Segundo Witten; Eibe e Hall (2011), extensos testes, em vários conjuntos de dados diferentes com diferentes classificadores, mostraram que 10 é o número certo de divisões para obter a melhor estimativa

de erro, e há também algumas evidências teóricas que corroboram esta afirmação. Ainda que os argumentos não sejam conclusivos, tem se tornado o método padrão em termos práticos.

Nesse trabalho, o desempenho dos métodos de classificação foi avaliado comparando a acurácia dos resultados. Essa medida representa o percentual de instâncias classificadas corretamente por cada um dos classificadores em relação ao total de amostras testadas. A acurácia foi medida sobre três bases de dados:

- Com o lado dorsal da mão, base de 700 imagens, sete por indivíduo.
- Com o lado palmar da mão, base de 500 imagens, cinco por indivíduo.
- Conjugada das duas bases anteriores totalizando 1200 imagens, 12 por indivíduo.

As Tabelas 3, 4 e 5 apresentam os desempenhos obtidos em termos de acurácia, respectivamente, para as bases de 700, 500 e 1200 imagens. Os melhores resultados em cada grupo são destacados em negrito.

Tabela 3. Resultados da classificação usando validação cruzada sobre a base dorsal, com indicação da taxa de acurácia média nos 10-folds e o desvio padrão em relação à média. Os melhores resultados são destacados em negrito.

Método	Nº de Instâncias	Nº de instâncias classificadas corretamente	% Acurácia	% Desvio padrão
AdaBoostM1 + LMT	700	699	99,86	0,45
Bagging + FLR	700	699	99,86	0,45
BayesNet	700	699	99,86	0,45
FLR	700	699	99,86	0,45
IBk	700	700	100,00	0,00
libSVM	700	700	100,00	0,00
LMT	700	699	99,86	0,45
LogitBoost + RandomForest	700	699	99,86	0,45
RandomForest	700	696	99,43	1,00
RotationForest + RandomForest	700	700	100,00	0,00
SMO	700	700	100,00	0,00

Tabela 4. Resultados da classificação usando validação cruzada sobre a base palmar, com indicação da taxa de acurácia média nos 10-folds e o desvio padrão em relação à média. Os melhores resultados são destacados em negrito.

Método	Nº de Instâncias	Nº de instâncias classificadas corretamente	% Acurácia	% Desvio padrão
AdaBoostM1 + LMT	500	494	98,80	1,03
Bagging + FLR	500	499	99,80	0,63
BayesNet	500	497	99,40	0,97
FLR	500	499	99,80	0,63
IBk	500	499	99,80	0,63
libSVM	500	498	99,60	0,84
LMT	500	496	99,20	1,03
LogitBoost + RandomForest	500	497	99,40	0,97
RandomForest	500	489	97,80	1,99
RotationForest + RandomForest	500	499	99,80	0,63
SMO	500	499	99,80	0,63

Tabela 5. Resultados da classificação usando validação cruzada sobre a base conjugada, com indicação da taxa de acurácia média nos 10-folds e o desvio padrão em relação à média. Os melhores resultados são destacados em negrito.

Método	Nº de Instâncias	Nº de instâncias classificadas corretamente	% Acurácia	% Desvio padrão
AdaBoostM1 + LMT	1200	1193	99,42	0,69
Bagging + FLR	1200	1197	99,75	0,40
BayesNet	1200	1194	99,50	0,58
FLR	1200	1195	99,58	0,59
IBk	1200	1199	99,92	0,26
libSVM	1200	1198	99,83	0,35
LMT	1200	1195	99,58	0,59
LogitBoost + RandomForest	1200	1197	99,75	0,40
RandomForest	1200	1182	98,50	0,95
RotationForest + RandomForest	1200	1198	99,83	0,35
SMO	1200	1198	99,83	0,35

Considerando todos os cenários, a taxa de acurácia mínima foi de 97,8%. Analisando apenas a base dorsal, a acurácia mínima obtida foi de 99,43% com média de 99,87%. Dos 11 algoritmos testados com essa base, quatro conseguiram 100% de acurácia e outros seis cometeram apenas um erro de classificação dentre as 700 instâncias testadas. Com a base palmar, a taxa de acurácia média considerando todos os métodos de classificação foi de 99,38%. Com a base conjugada, o melhor resultado foi obtido com o método do Vizinho Mais Próximo: uma instância com classificação incorreta dentre as 1200 amostras testadas.

5.2.1.1 *Análise de erros*

Como podem ser observados nas Tabelas 3 e 4, os resultados com a base dorsal foram mais bem sucedidos do que com a face palmar. Isso porque, neste último, o posicionamento das mãos sobre a superfície não é tão natural e confortável quando na primeira: as saliências dos ossos do braço (cabeça da ulna) e da base dos dedos (metacarpos) dificultam o procedimento de colocar o dorso da mão e as pontas dos dedos ao mesmo tempo em contato com a superfície. Com isso, em várias imagens, os indivíduos deixaram os dedos curvos e com as pontas levantadas em relação ao plano. A extração de medidas geométricas em um plano bidimensional é prejudicada nesse cenário.

O treinamento com ambos os lados das mãos oferece uma compensação ao juntar as amostras melhor posicionadas do lado dorsal com o palmar e como seria esperado, um resultado intermediário entre os dois outros cenários é obtido, conforme demonstrado na Tabela 5.

A classificação com a base dorsal apresentou um número reduzido de erros, com zero ou apenas um erro em 10 dos 11 algoritmos aplicados. Ao total, oito erros distintos foram constatados, sendo quatro deles decorrentes de classificação incorreta para uma mesma instância. Uma avaliação individualizada dos casos, buscando identificar suas causas é mostrada a seguir. Para facilitar o entendimento, os indivíduos ou classes são numerados de I001 a I100 e as amostras de A1 a A7 em cada classe.

- **Erro: E1**

Instância: A1.

Classe correta da amostra: I039.

Classe da predição: I051.

Observações: Polegar na imagem aparece encurvado e as medidas de área, perímetro e comprimento ficaram reduzidas em relação às demais imagens. Contudo, como pode ser verificado no Apêndice A, essas medidas não ficaram mais próximas da classe I051 para justificar o erro. Analisando todos os atributos, a amostra em termos de distância euclidiana se assemelha mais às demais instâncias de I039 do que às instâncias de I051. Possivelmente houve deficiência no modelo gerado pelo classificador.

Estratégias de classificação que produziram o erro: LMT e AdaBoostM1 + LMT.

- **Erro: E2**

Instância: A1.

Classe correta da amostra: I015.

Classe da predição: I052.

Observações: Na imagem, os dedos mínimo, anelar e polegar estão ligeiramente levantados, inclusive com a formação de sombra, como pode ser visto na Figura 24. Dentre eles, o dedo mínimo é o que apresenta maior variação. Nas demais imagens da classe I015, como ilustrado na Figura 25, eles estão posicionados de forma correta, diretamente sobre a superfície. O erro pode ter sido motivado pela falha do posicionamento durante a captura. Como exemplo, o desvio padrão do comprimento do dedo mínimo do indivíduo I015, excluindo essa amostra, é de apenas 2,67. Já a diferença entre o comprimento do dedo mínimo dessa amostra e a média das demais instâncias é de 63,93.

Estratégias de classificação que produziram o erro: FLR e Bagging + FLR.




Figura 24. Posicionamento inadequado do indivíduo I015. Na imagem à esquerda a amostra A1 conforme foi capturada. Na imagem à direita, a mesma amostra após processamento para evidenciar as sombras, delimitadas por linhas tracejadas.




Figura 25. Posicionamento correto do indivíduo I015. Na imagem à esquerda a amostra A3 conforme foi capturada. Na imagem à direita, a mesma amostra após processamento para evidenciar as sombras.

- **Erro: E3**

Instância: A1.

Classe correta da amostra: I015.

Classe da predição: I028.

Observações: Mesma instância do erro E3, agora com atribuição à classe I028.

Estratégia de classificação que produziu o erro: BayesNet.

- **Erro: E4**

Instância: A1.

Classe correta da amostra: I015.

Classe da predição: I025.

Observações: Mesma instância de E2 e E3, agora com atribuição à classe I025.

Estratégia de classificação que produziu o erro: LogitBoost + RandomForest.

- **Erro: E5**

Instância: A1.

Classe correta da amostra: I015.

Classe da predição: I026.

Observações: Mesma instância de E2, E3 e E4, agora com atribuição à classe I026.

Estratégia de classificação que produziu o erro: RandomForest.

- **Erro: E6**

Instância: A2.

Classe correta da amostra: I060.

Classe da predição: I018.

Observações: Mãos de fato parecidas, com dedos curtos e palma pequena. Embora as medidas de 10 atributos estejam mais próximas da classe I018 do que da classe efetiva, utilizando a função de distância com todos os atributos, essa aproximação é compensada e a instância se torna mais próxima da classe correta.

Estratégia de classificação que produziu o erro: RandomForest.

- **Erro: E7**

Instância: A1.

Classe correta da amostra: I095.

Classe da predição: I099.

Observações: Sem aparente falha de segmentação de imagens. Algumas medidas são parecidas, mas a distância de A1 para as demais instâncias de I095 é cerca de um terço da distância para as amostras de I099. Supõe-se, então, deficiência na geração das árvores de decisão do modelo.

Estratégia de classificação que produziu o erro: RandomForest.

- **Erro: E8**

Instância: A4.

Classe correta da amostra: I100.

Classe da predição: I033.

Observações: Mãos podem ser consideradas parecidas, de pessoas do mesmo sexo com dedos curtos e palma pequena. Não foram identificados problemas aparentes na segmentação do contorno e delimitação de mãos e dedos, embora em 13 dos 14 descritores do polegar na amostra A4 tenham sido computadas medidas inferiores em relação às demais amostras de I100. No total, 10 atributos estão mais próximos das medidas de I033, mas assim como nos erros E6 e E7, ao considerar todos os atributos, a amostra ainda está bem mais próxima de I100 do que da classe da predição.

Estratégia de classificação que produziu o erro: RandomForest.

No Apêndice A, são detalhadas as instâncias das classes envolvidas nos erros, indicando também para cada instância classificada incorretamente qual a distância – Equação 1 – em relação às demais amostras do mesmo indivíduo e em relação às amostras da classe predita.

5.2.1.2 Avaliação da combinação de modelos de classificação

Analizando ainda as Tabelas 2, 3 e 4 com os resultados obtidos, pode-se observar também que a combinação de modelos de classificação apresenta uma maior contribuição diante de modelos individuais menos precisos, corroborando então, a ideia da construção de um modelo mais aprimorado a partir de modelos menos eficientes. Como exemplo, a estratégia RandomForest com a base conjugada produziu 18 erros de classificação, mas ao associá-la como classificador base para LogitBoost e para RotationForest, o número de erros caiu para 3 e 2, respectivamente. Comportamento semelhante é observado na classificação da base palmar usando as mesmas estratégias: 11 erros com RandomForest, com redução para apenas três erros com LogitBoost e 1 (um) erro com RotationForest.

Para modelos já bastante eficientes, o ganho é pequeno, nulo ou mesmo negativo em alguns casos (quando o modelo se torna superajustado⁵ aos dados de treinamento). Esse comportamento pode ser observado no classificador FRL sobre as bases, dorsal e palmar, com ocorrência de apenas um erro e sem nenhum incremento de desempenho ao usar Bagging. Na base conjugada, a combinação de Bagging com FLR reduziu em duas ocorrências o número de erros total quando comparado à execução individual do FLR. Na classificação da base conjugada, o método LMT gerou cinco classificações incorretas, mas o AdaBoostM1 executando várias rodadas de LMT produziu um resultado pior, com sete erros de classificação.

5.2.1.3 Avaliação do tempo de execução

Outra questão importante na avaliação dos classificadores é o tempo necessário para execução, desde a geração do modelo de aprendizado até a classificação das amostras de testes. A Tabela 6 mostra uma comparação do tempo de execução dos classificadores aplicados sobre a base de dados com o lado dorsal das mãos. O resultado apresentado é a média de 10 rodadas utilizando validação cruzada tanto para o processo de treinamento,

⁵ Um modelo superajustado aos dados de treinamento é um modelo que representa fielmente os dados de treinamento, mas que pode apresentar perda de generalidade, ou seja, incapacidade de lidar com dados desconhecidos.

quanto para execução dos testes de classificação de todas as instâncias. Os experimentos foram realizados utilizando um computador com a configuração indicada na seção 4.1.

Tabela 6. Tempo de execução dos classificadores em segundos, destacando o tempo necessário para treinamento e teste de todas as instâncias da base dorsal. A coluna total exige o somatório do tempo de treinamento e teste para cada método.

Método	Tempo em segundos		
	Treinamento	Teste	Total
IBk	0,0063	0,0909	0,0972
RandomForest	1,1674	0,0079	1,1753
FLR	1,4104	0,1578	1,5682
BayesNet	1,2685	0,3445	1,6130
Bagging + FLR	13,3643	1,4424	14,8067
RotationForest + RandomForest	15,2213	0,3744	15,5957
LibSVM	28,7587	0,7775	29,5362
LogitBoost + RandomForest	49,1916	0,9268	50,1184
SMO	60,3976	1,0088	61,4064
LMT	220,1498	0,0608	220,2106
AdaBoostM1 + LMT	2012,0697	0,5729	2012,6426

Como pode ser visto na Tabela 6, o método de execução mais rápido (considerando o tempo total) neste caso é o IBk, cerca de 20000 vezes mais rápido que a estratégia mais lenta usando AdaBoostM1 + LMT. Há, contudo, a ressalva de que o desempenho do algoritmo IBk é linearmente dependente do número de amostras de treinamento, o que pode ser computacionalmente custoso para bases de dados muito grandes. Por sua vez, apesar das duas implementações de máquinas de vetores de suporte (LibSVM e SMO) apresentarem resultados semelhantes na classificação dos indivíduos (o que já era esperado), o tempo de resposta deles é diferente: o tempo de treinamento do libSVM corresponde a 48% do tempo de treinamento da implementação SMO para o mesmo cenário de teste.

5.2.2 Desempenho dos classificadores em relação ao número de amostras por classe no treinamento

Para avaliar o desempenho dos classificadores segundo o número de amostras disponíveis por classe na fase de treinamento, o método de subamostragem estratificada foi utilizado. Novamente, a base de dados com o lado dorsal da mão esquerda de 100 pessoas foi utilizada

no experimento. Nesse processo, como há sete amostras ou imagens por classe/indivíduo na base de dados, os classificadores foram testados em grupos usando progressivamente de 1 até 6 amostras por classe para treinamento.

Para garantir a confiança dos resultados, foram executadas 30 rodadas de testes em cada grupo, ou seja, 30 rodadas com uma amostra por classe para treinamento e seis para teste, outras 30 com duas amostras por classe para treinamento e cinco para teste, e assim sucessivamente. Em cada rodada de execução, os dados foram rearranjados aplicando diferentes sementes randômicas. A acurácia de cada classificador em cada grupo de execução é dada pela soma dos desempenhos individuais dividido pela quantidade de iterações. As curvas de aprendizagem são reproduzidas no gráfico da Figura 26.




Figura 26. Desempenho dos classificadores segundo o número de amostras por classe na fase de treinamento. Os testes foram aplicados sobre a base dorsal e separados em grupos com variação de 1 a 6 amostras por classe. É indicada a acurácia alcançada por cada um dos algoritmos em cada grupo de teste.

Os resultados ilustrados na tabela da Figura 26 indicam que as implementações de SVMs (LibSVM e SMO) alcançam uma acurácia de 100% a partir de quatro amostras de

treinamento por classe. O método do vizinho mais próximo (IBk) alcança esse mesmo resultado utilizando seis amostras de treinamento por indivíduo – comportamento semelhante ao obtido com validação cruzada onde também seis amostras por classe são utilizadas na fase de treinamento.

Com apenas uma amostra de treinamento, o melhor resultado é obtido com o método FLR que apresenta uma taxa de acerto na classificação de 99,58%. O método RandomForest é o que apresenta uma curva de maior declividade, com 72,01% de acurácia quando uma amostra é destinada ao treinamento, chegando a 99,20% com 6 amostras. Ademais, uma taxa de acurácia superior a 99% foi alcançada por quatro estratégias quando somente uma amostra por classe é usada no treinamento, cenário este, comum em aplicações comerciais.

5.3 Experimentos de verificação

No processo de verificação, alguns cenários foram elaborados utilizando as abordagens descritas no capítulo anterior. Em todos eles, as comparações um-para-um foram realizadas sobre a base de testes definida em cada caso. Ainda, sendo N o número de indivíduos na base e t o número de amostras por indivíduo, conforme (JAIN; ROSS; NANDAKUMAR, 2011), para gerar uma aceitação verdadeira, um par de amostras de um mesmo indivíduo tem que ser comparado e para gerar uma falsa aceitação, a comparação deve ser feita utilizando amostras de duas pessoas diferentes. Assim, o número de aceitações verdadeiras que podem ser geradas pelo comparador será de:

$$\frac{Nt(t-1)}{2} \quad (14)$$

e o número máximo de aceitações falsas, de:

$$\frac{N(N-1)t^2}{2} \quad (15)$$

Nesse processo, assume-se que a comparação é simétrica, ou seja, comparar a amostra A com B produz o mesmo resultado que a comparação de B com A: $S(A, B) = S(B, A)$.

Com base nas comparações, calcularam-se as taxas de $FRR(t)$ e $FAR(t)$ para valores de t variando entre 0 a 1 e o percentual de EER. Como o número de comparações é finito, as

curvas $FRR(t)$ e $FAR(t)$ não são contínuas e o valor exato de EER pode não existir. Assim, o EER é calculado via um método de aproximação.

Como ilustrado na Figura 5, quando t é 0 (zero), o valor de FAR é alto e o valor de FRR é baixo. Quanto t é 1 (um), ocorre o inverso: um alto valor de FRR e um baixo valor de FAR. Em virtude disso, o processo de determinação do EER, inicia com $t = 0$ até $t = 1$ e variação de t , $\Delta t = 0,1$. Quando o valor de $FRR(t)$ ultrapassa $FAR(t)$ – o que indica que as curvas se cruzaram em momento anterior – Δt é reduzido para $\Delta t / 10$ e t retorna a um passo (limiar) anterior. O processo se repete enquanto $\Delta t \geq 0,001$. Quando $\Delta t = 0,0001$ e novamente o $FRR(t)$ atinge ou ultrapassa o $FAR(t)$, o valor de EER é finalmente determinado calculando-se a média entre $FRR(t)$ e $FAR(t)$ no ponto t .

Os cenários executados e os resultados obtidos são indicados a seguir.

5.3.1 Abordagem 1 – distância euclidiana simples

5.3.1.1 Caso 1

No primeiro caso de teste onde a função de pontuação S - Equação 8 - toma como base a distância euclidiana simples, apenas a base dorsal foi utilizada. Foram destinadas 400 imagens para testes com quatro amostras por indivíduo, e para o treinamento, 300 imagens, sendo três amostras por pessoa. Nesse processo, foram executadas 20 iterações selecionando diferentes conjuntos de dados para treinamento e testes em cada uma delas. O método de subamostragem randômica estratificada foi aplicado para separação das bases.

Em cada iteração foram realizadas 79200 comparações de falsa aceitação e 600 comparações de falsa rejeição.

As 300 imagens de treinamento foram utilizadas apenas para definir a função de normalização, estabelecendo os valores máximo e mínimo de cada atributo. O principal objetivo dessa separação é produzir o mesmo cenário de entrada de teste realizado aplicando a abordagem 2, e assim, possibilitar a comparação.

As taxas de EER obtidas são listadas na Tabela 7. O resultado médio obtido nesse caso foi de 1,31%.

Tabela 7. EER calculado utilizando a distância euclidiana simples - caso 1, abordagem 1 - em cada uma das 20 iterações e o valor médio final alcançado.

Iter.	EER%	Iter.	EER%	Iter.	EER%	Iter.	EER%
1	0,99495	6	1,65593	11	1,33018	16	1,66540
2	0,99811	7	0,66540	12	1,00000	17	1,61364
3	1,16540	8	1,32891	13	1,32702	18	0,83333
4	1,82891	9	1,63384	14	1,32386	19	1,28409
5	1,57765	10	0,99747	15	1,29672	20	1,66098
EER médio							1,30909

5.3.1.2 Caso 2

O segundo caso promove a separação de indivíduos em dois grupos A e B com 50 indivíduos cada: em uma rodada o grupo A é destinado para o processo de treinamento e o grupo B para realização das comparações de testes. Numa rodada seguinte há a troca dos papéis, A para testes e B para o treinamento.

Como nessa abordagem não há necessidade de treinamento prévio, assim como descrito no caso 2, as amostras de treinamento são utilizadas apenas para definir a função de normalização dos atributos.

Usando a base dorsal, cada grupo foi formado por 350 instâncias (50 indivíduos com 7 amostras por indivíduo). Usando o grupo A para testes, obteve-se uma taxa de EER de 1,33% e com o grupo B a taxa obtida foi de 1,24%.

5.3.1.3 Caso 3:

Nesse último caso, utilizaram-se todas as amostras da base para os testes, ou seja, nenhum treinamento foi realizado previamente.

Com a base dorsal de 100 indivíduos e sete instâncias por indivíduo foram geradas 242550 comparações de falsa aceitação e 2100 comparações de falsa rejeição. A taxa de EER obtida nesse caso foi de 1,19%.

Para a base palmar, com 100 pessoas e cinco amostras por pessoa, foram produzidas 123750 comparações de falsa aceitação e 1000 comparações de falsa rejeição e a taxa de EER alcançada foi de 1,29%.

5.3.2 Abordagem 2 – distância euclidiana ponderada

5.3.2.1 Caso 1

Conforme comentado no capítulo anterior, nessa abordagem onde a função de pontuação S toma como base a distância euclidiana ponderada - Equação 9, um processo de otimização utilizando o método *Firefly* foi adotado para definição dos pesos de cada um dos atributos.

A configuração das bases de teste e treinamento foi a mesma adotada no caso 1 da abordagem 1: 400 amostras de testes e 300 amostras de treinamento com 20 iterações do processo, onde a separação das bases em cada iteração foi realizada por meio de subamostragem randômica estratificada.

Contudo, para esse caso, cada uma das 20 iterações foi subdividida em mais 10 execuções. Assim, para um mesmo conjunto de dados de treinamento e teste, o processo de verificação foi executado 10 vezes. A motivação para essas repetições é que diferentes execuções do método de otimização ainda que partindo da mesma entrada de dados, produziam diferentes resultados. Os diferentes pesos obtidos resultavam também em taxas de EER diferentes ao serem aplicados sobre a base de testes. Ainda que a variância entre os resultados individuais tenha sido pequena, preferiu-se realizar um ciclo de execuções e extrair o saldo médio para determinar o resultado final. Na Tabela 8 é listado o EER médio considerando as 10 execuções de cada iteração, bem como os valores mínimo e máximo em cada uma delas e o coeficiente de variação amostral dos resultados em relação à média. O coeficiente de variação de Person C_v é dado pela fórmula:

$$C_v = \frac{s}{\mu} \quad (16)$$

onde s é o desvio padrão amostral e μ a média dos dados.

Ainda, para efeito comparativo, a Tabela 8, coluna Y, também apresenta as taxas EER obtidas sem a atribuição de pesos - caso 1 da abordagem 1 - exibidos previamente na Tabela 7. A diferença entre os resultados alcançados pelas duas abordagens também é demonstrada na coluna (Z).

Tabela 8. EER calculado utilizando distância euclidiana ponderada - caso 1, abordagem 2 - nas 20 iterações e comparativo com a abordagem anterior. Em verde os experimentos onde os resultados da abordagem 2 foram superiores aos da abordagem 1 e em vermelho, a situação inversa.

Iter.	Abordagem 2				% EER Abordagem 1 (Y)	Y - X (Z)	% Ganho Z/Y
	% EER mínimo	% EER máximo	% C_v	% EER médio (X)			
1	0,49621	0,50000	0,27	0,49766	0,99495	0,49729	50,0
2	0,66035	0,81755	7,11	0,67999	0,99811	0,31812	31,9
3	0,99621	1,16667	7,75	1,07544	1,16540	0,08996	7,7
4	0,49937	0,99747	17,63	0,73693	1,82891	1,09198	59,7
5	0,49621	0,50000	0,27	0,49842	1,57765	1,07923	68,4
6	0,65909	0,66667	0,41	0,66433	1,65593	0,99160	59,9
7	0,16667	0,66225	38,67	0,41806	0,66540	0,24735	37,2
8	0,49621	0,66540	10,26	0,51509	1,32891	0,81383	61,2
9	0,49621	0,66604	14,81	0,57992	1,63384	1,05391	64,5
10	0,49495	0,66667	14,59	0,57664	0,99747	0,42083	42,2
11	0,99306	1,29419	11,10	1,10170	1,33018	0,22847	17,2
12	0,49747	0,59785	6,15	0,50878	1,00000	0,49122	49,1
13	0,99495	1,00000	0,15	0,99760	1,32702	0,32942	24,8
14	0,99621	1,16414	5,47	1,02273	1,32386	0,30114	22,7
15	0,99747	1,16667	6,11	1,12323	1,29672	0,17348	13,4
16	0,99684	1,33270	9,80	1,17077	1,66540	0,49463	29,7
17	0,49432	0,83081	21,37	0,66648	1,61364	0,94716	58,7
18	0,99116	1,00000	0,26	0,99514	0,83333	-0,16181	-19,4
19	0,49558	0,50000	0,27	0,49779	1,28409	0,78630	61,2
20	0,49874	0,81124	11,14	0,66263	1,66098	0,99836	60,1
Média	0,67086	0,85032	10,85	0,74947	1,30909	0,55962	42,7

Como pode ser observado, houve ganho na atribuição dos pesos em 19 das 20 iterações. Em média, considerando as 200 execuções (20 iterações com 10 repetições por iteração), o uso dos pesos obtidos com o *Firefly* alcançou uma taxa EER de 0,75% e proporcionou uma redução de 42,7% dessa taxa em relação ao método mais simples. As taxas EER obtidas em cada execução são listadas no Apêndice B.

Obviamente, o processo de otimização agrega um custo à fase de treinamento, que praticamente inexistia na abordagem anterior. Em média, o tempo de treinamento para definição de pesos, considerando as 200 execuções, foi de 99 segundos – procedimento

executado em um computador com a configuração indicada na seção 4.1. Com 100 indivíduos na base de dados, pode-se arredondar para cerca de 1 segundo por indivíduo.

Esse tempo de processamento é bastante satisfatório, considerando-se que os métodos de otimização geralmente demandam um esforço computacional significativo e que esse processo se dá apenas na fase de treinamento, que pode ser realizada *off-line*, sem repercussão nos procedimentos de cadastro ou autenticação dos usuários do sistema biométrico.

5.3.2.2 Caso 2

Esse caso é semelhante àquele de mesmo número na abordagem 1: dois grupos A e B de 50 pessoas cada um, onde em uma iteração o grupo A é utilizado para treinamento e o B para testes e na iteração seguinte ocorre o inverso. A diferença é que cada iteração foi subdividida em 10 repetições assim como no primeiro caso desta abordagem 2.

Na Tabela 9 são mostrados os resultados obtidos e um comparativo com a abordagem 1. A coluna (X) exibe o valor médio de EER nas 10 repetições.

Tabela 9. EER calculado utilizando distância euclidiana ponderada - caso 2, abordagem 2 - em cada grupo de teste e comparativo com a abordagem anterior.

	%EER Abordagem 2 (X)	%EER Abordagem 1 (Y)	Y - X (Z)	% Ganho Z/Y
Grupo A	0,91129	1,32972	0,41844	31,5
Grupo B	0,88644	1,23796	0,35152	28,4
Média	0,89886	1,28384	0,38498	29,9

Assim como no primeiro caso, a atribuição de pesos aos atributos favoreceu o processo de reconhecimento com redução na taxa de erro EER em relação à abordagem 1.

Outra avaliação pertinente é que em razão dos conjuntos de indivíduos de treinamento e testes serem totalmente disjuntos, pode-se considerar que o processo de aprendizado para atribuição de pesos nesse caso é mais difícil que caso 1 da abordagem 2 e que por isso os resultados obtidos podem ser inferiores aos alcançados naquele cenário. De fato, os experimentos demonstraram que o resultado médio do caso 1 desta abordagem 2 foi mais acurado que o obtido no caso 2: taxa de erro EER de aproximadamente 0,75% contra 0,90%. Em contrapartida, o fato de os pesos serem testados em indivíduos diferentes daqueles treinados, ainda mantendo um resultado satisfatório, favorece a hipótese de que eles podem representar a

efetiva importância dos atributos no processo de reconhecimento por geometria da mão, não restrito à base de dados coletada. Esse assunto é tratado na seção a seguir.

5.3.2.3 Análise dos pesos dos atributos

A atribuição de pesos diferenciados aos atributos geométricos visa aumentar a taxa de sucesso no processo de verificação ao mesmo tempo em que possibilita determinar a relevância individual de cada atributo no processo de reconhecimento.

Conforme comentado nas descrições dos casos de testes, os experimentos apresentaram variação de resultados mesmo quando provenientes de uma mesma entrada de dados. A variação de resultado da função objetivo do método *Firefly* nesse contexto foi insignificante, demonstrando uma alta homogeneidade. Por exemplo, a maior variabilidade ocorreu na iteração 20 do caso 1, com valor mínimo de 0,22837925107817805, máximo de 0,23960567583872347 e coeficiente de variação de apenas 1,38%. Os valores de EER obtidos nessa iteração, no entanto, tiveram uma dispersão um pouco maior com valores mínimo e máximo de respectivamente, 0,49874 e 0,81124 e coeficiente de variação de 11,14% como apresentado na Tabela 8.

A maior variabilidade, contudo, foi encontrada na escolha dos pesos dos atributos: utilizando o mesmo exemplo da iteração 20 do caso 1, alguns atributos apresentaram coeficiente de variação superior a 300%. Isso pode evidenciar que o processo de otimização não encontrou um mínimo global, mas vários mínimos locais, ainda assim com bom desempenho em termos de taxa de erro na verificação.

Outro ponto a considerar é que apesar do alto coeficiente de variação, com desvio padrão superior à média em muitas situações, os pesos nesses casos extremos foram muito baixos. Na Tabela 10 são ilustrados os cinco atributos com maior coeficiente de variação do exemplo em análise. O primeiro deles, como pode ser observado, tem peso máximo de 0,000048. Considerando que os pesos assumem valores entre 0 e 10, a influência desse atributo e da variação dos seus pesos sobre o cálculo da função de distância no processo de verificação foi bastante reduzida.

Tabela 10. Atributos com maior coeficiente de variação de pesos C_v da iteração 20, caso 1

Atributo	Peso			
	Mínimo	Máximo	Média	% C_v
Largura 6 anelar	0,000000	0,000048	0,000005	316,23
Área mão	0,000000	0,088790	0,009801	284,45
Largura 5 dedo médio	0,000000	0,094397	0,010813	272,87
1º ângulo mínimo	0,000000	0,000135	0,000018	232,83
Comprimento polegar	0,000000	0,000127	0,000018	229,15

Uma característica interessante é que, apesar da variabilidade, muitos atributos apresentaram pesos extremamente baixos, próximos a zero, em praticamente todas as execuções do método de otimização. Outros, porém, já apresentaram pesos elevados na maioria das execuções, evidenciando em ambos extremos, os menos e mais relevantes atributos no processo de reconhecimento.

Na Tabela 11 são mostrados os 20 atributos com menor peso médio nas 220 execuções do método de otimização com *Firefly* (200 execuções do caso 1 e 20 execuções do caso 2). Desses atributos, seis foram extraídos do polegar e outros sete correspondem a ângulos entre os segmentos ajustados.

Tabela 11. Atributos com menores pesos nos experimentos, considerando as 200 execuções do caso 1 e as 20 execuções do caso 2

Colocação	Atributo	Peso		
		Mínimo	Máximo	Média
84º	Excentricidade mão	0,00000	0,00030	0,00002
83º	1º ângulo anelar	0,00000	0,00050	0,00003
82º	Largura inferior polegar	0,00000	0,00030	0,00004
81º	2º ângulo anelar	0,00000	0,00039	0,00004
80º	1º ângulo mínimo	0,00000	0,00072	0,00004
79º	1º ângulo dedo médio	0,00000	0,00052	0,00005
78º	Largura inferior mínimo	0,00000	0,00068	0,00005
77º	1º ângulo indicador	0,00000	0,00064	0,00005
76º	2º ângulo mínimo	0,00000	0,00049	0,00005
75º	Largura inferior anelar	0,00000	0,00084	0,00006
74º	Perímetro polegar	0,00000	0,00062	0,00006
73º	2º ângulo dedo médio	0,00000	0,00057	0,00007
72º	Menor eixo elipse mão	0,00000	0,00065	0,00007
71º	Maior eixo elipse polegar	0,00000	0,00061	0,00007

70°	Excentricidade polegar	0,00000	0,00108	0,00009
69°	Comprimento polegar	0,00000	0,00072	0,00009
68°	2° ângulo indicador	0,00000	0,00080	0,00011
67°	Largura 6 polegar	0,00000	0,00125	0,00011
66°	Largura 6 mínimo	0,00000	0,03154	0,00037
65°	Largura 2 polegar	0,00000	0,07650	0,00052

Na Tabela 12 são mostrados os 20 atributos com maior média de pesos em todos os experimentos. Pode-se verificar que as medidas de largura se mostraram bons descritores geométricos. Outro ponto a destacar é que nenhuma medida do polegar aparece entre os 20 melhores atributos. O extrato completo de todos os atributos pode ser consultado no Apêndice C.

Tabela 12. Atributos com pesos mais significativos nos experimentos, considerando as 200 execuções do caso 1 e as 20 execuções do caso 2

Colocação	Atributo	Peso		
		Mínimo	Máximo	Média
1°	Largura 2 indicador	1,74487	10,00000	9,42839
2°	Largura 2 dedo médio	1,83726	10,00000	9,38498
3°	Largura 5 indicador	0,99894	10,00000	9,21851
4°	Menor eixo elipse indicador	1,44396	10,00000	9,17321
5°	Largura 4 indicador	1,68283	10,00000	9,05088
6°	Largura 2 anelar	2,20344	10,00000	8,88021
7°	Largura 4 dedo médio	0,97267	9,99983	8,75139
8°	Largura 1 dedo médio	0,00246	10,00000	8,74519
9°	Largura 5 anelar	0,06906	10,00000	8,33166
10°	Menor eixo elipse anelar	1,40278	9,99741	7,82615
11°	Largura 3 indicador	0,00274	9,99726	7,72351
12°	Largura 4 mínimo	0,01728	9,99643	7,53326
13°	Menor eixo elipse mínimo	0,00013	9,99681	7,30331
14°	Largura 1 anelar	0,00191	9,99474	7,07786
15°	Largura 3 anelar	0,00006	9,95206	6,44789
16°	Área convexa indicador	0,00007	9,98235	6,18497
17°	Largura 5 dedo médio	0,00000	9,96223	6,05993
18°	Largura mão	0,00000	9,99991	5,47664
19°	Menor eixo elipse dedo médio	0,00032	9,99287	5,39921
20°	Largura 3 mínimo	0,00000	9,96895	4,80208

Diante desses resultados, experimentou-se realizar um novo processo de verificação tal como o caso 3 da abordagem 1 onde todas as amostras são utilizadas para os testes e todos os atributos têm o mesmo peso. Nesse caso também foi utilizada a base dorsal e duas situações foram testadas:

- Verificação utilizando apenas os 20 atributos com melhores pesos: a taxa EER alcançada nesse cenário foi de 0,81%, com redução de 32% em relação à taxa de 1,19% obtida utilizando todos os atributos.
- Verificação utilizando apenas os 20 atributos com piores pesos. Neste caso a taxa EER obtida foi de 3,76%, resultado bem inferior aos demais cenários experimentados.

5.4 Comparação com outros trabalhos

Na Tabela 13 é apresentado um quadro comparativo de métodos de reconhecimento utilizando geometria da mão existentes na literatura, que também utilizam a abordagem de classificação. São exibidos os melhores resultados em termos de acurácia na classificação de cada uma das propostas elencadas.

Tabela 13. Comparativo entre diferentes propostas de classificação por geometria da mão

Proposta	Nº Indiv.	Nº Atrib.	Método de Classificação	% Acurácia
(SANCHEZ-REILLO; SANCHEZ-AVILA; GONZALEZ-MARCOS, 2000)	20	31	GMM	97,00
(KUMAR; ZHANG, 2006)	100	23	Somente geometria - LMT	89,60
	100	75	Geometria e impressão palmar - SVM	98,00
(LUQUE-BAENA <i>et al.</i> , 2013)	150	22, 34	GA-LDA	100,00
Este trabalho	100	84	IBk, SMO, libSVM e (RotationForest + RandomForest)	100,00

Na Tabela 14 é exibido um comparativo de propostas para o problema de verificação por geometria da mão com resultados demonstrados em termos de taxa EER. Vários dos trabalhos apresentados propõem o uso de geometria da mão em combinação com outros métodos de reconhecimento, mas para que a comparação seja mais adequada, na tabela são apresentados

os melhores resultados alcançados em cada proposta utilizando apenas dados de geometria das mãos.

Tabela 14. Comparativo entre diferentes propostas de verificação utilizando geometria da mão

Proposta	Nº Indivíduos	Contato na captura	% EER
(XIONG <i>et al.</i> , 2005)	108	Sem pinos	2,41
(SAVIČ; PAVEŠIĆ, 2007)	200	Sem pinos	1,51
(MORALES <i>et al.</i> , 2008)	30	Sem contato	4,20
(KANHANGAD; KUMAR; ZHANG, 2011)	177	Sem contato	2,30
(DE SANTOS-SIERRA <i>et al.</i> , 2011)	287	Sem contato	1,40
(MICHAEL; CONNIE; TEOH, 2012)	136	Sem contato	3,61
(PARK; KIM, 2013)	100	Com pinos	1,81
(LUQUE-BAENA <i>et al.</i> , 2013)	137	Sem contato	4,51
Este trabalho	100	Sem pinos	0,75

Os resultados deste trabalho se mostram competitivos diante desse comparativo, embora o uso de diferentes bases de dados, bem como diferentes atributos e algoritmos de aprendizagem para a avaliação experimental impeça conclusões mais precisas.

Capítulo 6

Considerações finais

Este trabalho apresentou uma proposta de reconhecimento de indivíduos por geometria da mão. O método proposto de captura, segmentação e extração de atributos é avaliado utilizando diferentes algoritmos de classificação. A eficácia também é mensurada por meio de um processo de verificação com avaliação de duas abordagens para solução do problema.

Para os experimentos, 1200 imagens da mão esquerda de 100 indivíduos foram consideradas. Diferentemente de outros métodos, neste trabalho, imagens de ambos os lados da mão são empregadas no processo de treinamento e testes, tanto em cenários que as consideram separadamente quanto em conjunto. Para cada indivíduo, 12 imagens são utilizadas, sendo sete da face dorsal e cinco do lado palmar.

Para cada mão, um total de 84 atributos geométricos é extraído. O processo de extração de atributos foi satisfatório, com bom desempenho devido ao êxito nas etapas precedentes de captura, segmentação e delimitação de mãos e dedos.

Nos experimentos de classificação há que se destacar o bom desempenho do método vizinho mais próximo, tanto em termos de acurácia quanto em tempo de execução. Com validação cruzada, apenas uma amostra é classificada incorretamente sobre as bases palmar e conjugada e nenhum erro sobre a base dorsal. Como o aprendizado do método consiste basicamente em memorizar as amostras de treinamento, isso evidencia que os atributos tanto em relevância, quanto em quantidade, se mostram efetivos descritores da geometria da mão, e, por conseguinte, dos indivíduos que as possuem.

No processo de verificação, duas abordagens para comparação foram experimentadas. Uma onde a função de pontuação tinha como base a distância euclidiana simples entre os atributos da amostra testada e da identidade reivindicada e outra com base na distância euclidiana ponderada, estabelecendo-se pesos para os atributos geométricos. A atribuição de pesos, além

de proporcionar um melhor desempenho com redução na taxa de erro, permitiu avaliar a relevância dos atributos extraídos no processo de reconhecimento.

De modo geral, analisando os resultados dos experimentos de classificação e verificação – em termos de taxas de acurácia e EER – pode-se concluir que eles se mostram competitivos, com desempenho próximo ou mesmo superior ao estado da arte para o reconhecimento biométrico por geometria da mão. Contudo, é importante reiterar que a simples comparação de resultados não é precisa, uma vez que cada trabalho apresenta cenários e restrições diversas, seja com diferentes quantitativos de indivíduos ou amostras para treinamento, bem como diferentes formas de iluminação no processo de captura, qualidade das imagens geradas, delimitações sobre o posicionamento das mãos, entre outros.

Ainda vale salientar que diversas oportunidades de melhorias se apresentam com aplicação viável em trabalhos futuros. Dentre elas, um estudo aprofundado de seleção de atributos pode ser realizado, inclusive tendo como ponto de partida os modelos de aprendizagem gerados pelas diversas técnicas de classificação testadas. Esse estudo poderia avaliar também, a correlação entre os atributos, evitando redundâncias.

Em complementação ao que já foi desenvolvido nesse trabalho, novos experimentos podem ser realizados para determinar o grau de importância de cada atributo dentro do conjunto de atributos ideal, ou seja, estabelecer a relevância de cada um deles no processo de reconhecimento. Assim, outros métodos de otimização podem ser acrescentados para comparação com o *Firefly*, como por exemplo, algoritmos genéticos ou outras estratégias de inteligência de enxames. Luque-Baena *et al.* (2013) apresentam um estudo que avalia a qualidade discriminante dos atributos geométricos das mãos e nele um modelo de otimização utilizando GA é utilizado para escolha dos atributos. Eles concluem, por exemplo, que a região do dedo mínimo é a mais adequada para se extrair bons descritores geométricos. Contudo, ainda há carência de mais trabalhos como esse na literatura, que além de ratificar ou confrontar essas conclusões, possam fornecer novas considerações relevantes.

Outra melhoria importante é combinar o método proposto com outras modalidades de reconhecimento biométrico. No capítulo 3, vários trabalhos desse tipo são comentados e os resultados após a fusão são, em todos os casos, bem superiores aos obtidos apenas com geometria da mão. Como esse trabalho já fornece resultados bastante satisfatórios apenas com

geometria, a combinação com outros mecanismos pode produzir soluções ainda mais interessantes.

No que diz respeito à segmentação das imagens, apesar do sucesso no processo - comprovado inclusive pelos resultados obtidos, algumas amostras apresentaram ruído nas pontas das unhas. Ainda que a repercussão desse ruído se restrinja às medidas de perímetro de mãos e dedos, pode haver influência negativa no processo de reconhecimento. Para eliminá-lo, técnicas de filtragem e operações morfológicas como fechamento, poderiam ser experimentadas sobre a região das pontas dos dedos. Ainda, um tratamento específico pode ser incorporado com o recorte da região das unhas que se estende para além das extremidades dos dedos. Isso evitaria que unhas grandes fossem consideradas como parte do contorno, influenciando indevidamente no cálculo de medidas de comprimento dos dedos.

Outro ponto a considerar é que para superar o problema da captura das mãos com a face palmar, um método de aquisição que não envolva o contato com a superfície do dispositivo poderia ser empregado em experiências futuras. Além do melhor aproveitamento da face palmar, um processo de aquisição sem contato é mais amigável e higiênico. Obviamente, ele apresenta outros desafios, inclusive relacionados à própria forma de posicionamento para captura, como por exemplo: garantir que a mão fique estendida e equacionar as possíveis diferenças de aproximação entre a mão e o dispositivo durante as capturas.

Em suma, diante do que foi exposto, pode-se considerar que este trabalho atingiu os objetivos esperados. Não obstante, mais uma contribuição que pode ser destacada é que embora o reconhecimento por geometria da mão ainda seja considerado de média segurança, os experimentos apresentados aqui reforçam os indicativos de que é possível elevar a confiabilidade desse tipo de reconhecimento biométrico.

Referências bibliográficas

AHA, D. W.; KIBLER, D.; ALBERT, M. K. Instance-based learning algorithms. **Machine Learning**, v. 6, n. 1, p. 37-66, 1991.

BOUCKAERT, R. R. Bayesian Network Classifiers in Weka for Version 3-5-7. **University of Waikato**, May 2008. Disponível em: <<http://www.cs.waikato.ac.nz/~remco/weka.bn.pdf>>. Acesso em: 14 nov. 2014.

BREIMAN, L. Bagging predictors. **Machine Learning**, v. 24, n. 2, p. 123-140, 1996.

BREIMAN, L. Random Forests. **Machine Learning**, v. 45, n. 1, p. 5-32, 2011.

BRESENHAM, J. E. Algorithm for computer control of a digital plotter. **IBM Systems Journal**, v. 4, n. 1, p. 25-30, April 1965. ISSN 0018-8670.

CHANG, C.-C.; LIN, C.-J. LIBSVM: a library for support vector machines. **ACM Transactions on Intelligent Systems and Technology**, v. 2, n. 3, April 2011. Article nº. 27.

COOPER, G.; HERSKOVITZ, E. A Bayesian method for the induction of probabilistic networks from data. **Machine Learning**, v. 9, p. 330–347, 1992.

CORMEN, T. H. et al. **Algoritmos Teoria e Prática**. Tradução de Arlete Simille Marques. Rio de Janeiro: Campus, 2012.

COVER, T. M.; THOMAS, J. A. **Elements of Information Theory**. 2. ed. Hoboken, New Jersey: Wiley Series in Telecommunications and Signal Processing, 2006.

DE SANTOS-SIERRA, A. et al. Unconstrained and contactless hand geometry biometrics. **Sensors**, 11, 2011. 10143-10164.

DUDA, R. O.; HARR, P. E.; STORK, D. G. **Pattern Classification**. 2. ed. New York: Wiley-Interscience, 2001.

DUTA, N. A survey of biometric technology based on hand shape. **Pattern Recognition**, p. 2797 - 2806, 2009.

ERNST, R. H. **Hand ID system**. US Patent, nº. 3576537, 1971.

FACELI, K. et al. **Inteligência Artificial: Uma Abordagem de Aprendizado de Máquina**. Rio de Janeiro: LTC, 2011.

FREUND, Y.; SCHAPIRE, R. E. Experiments with a new boosting algorithm. **Thirteenth International Conference on Machine Learning**, 1996. 148-156.

- FRIEDMAN, J.; HASTIE, T.; TIBSHIRANI, R. Additive Logistic Regression: a Statistical View of Boosting. **Annals of Statistics**, v. 28, 1998.
- GONZALEZ, R. C.; WOODS, R. E.; EDDINS, S. L. **Digital Image Processing using Matlab**. New Jersey: Person Prentice Hall, 2004.
- GRATZER, G. **Lattice Theory: First Concepts and Distributive Lattices**. 1. ed. San Francisco, CA: W. H. Freeman, 1971.
- GUO, J. et al. Contact-free hand geometry-based identification system. **Expert Systems with Applications**, v. 39, p. 11728–11736, Oct 2012.
- HALL, M. et al. The WEKA Data Mining Software: An Update. **SIGKDD Explorations**, v. 11, 2009.
- HARALICK, R. M.; SHAPIRO, L. G. Appendix A. In: _____ **Computer and Robot Vision**. Reading, Ma: Addilson-Wesley, 1992.
- JACOBY, I. H.; GIORDANO, A. J.; FIORETTI, W. H. **Personnel identification apparatus**. U.S. Patent N°. 3648240, 1972.
- JAIN, A. K.; ROSS, A. A. Introduction to Biometrics. In: JAIN, A. K.; FLYNN, P.; ROSS, A. A. **Handbook of Biometrics**. New York, NY: Springer, 2008.
- JAIN, A. K.; ROSS, A. A.; NANDAKUMAR, K. **Introduction to Biometrics**. New York, NY: Springer, 2011.
- JAIN, A.; ROSS, A.; PRABHAKAR, S. An introduction to biometric recognition. **IEEE Transactions on Circuits and Systems for Video Technology**, v. 14, n. 1, p. 4–20, 2004.
- KABURLASOS, V. G. **Towards a Unified Modeling and Knowledge-Representation based on Lattice Theory**. Studies in Computational Intelligence. ed. Heidelberg, Germany: Springer, v. 27, 2006.
- KABURLASOS, V. G. et al. Fuzzy lattice reasoning (FLR) classifier and its application for ambient ozone estimation. **International Journal of Approximate Reasoning**, v. 45, p. 152–188, 2007.
- KANHANGAD, V.; KUMAR, A.; ZHANG, D. A unified framework for contactless hand verification. **IEEE Transactions on Information Forensics and Security**, v. 6, n. 3, p. 1014 - 1027 , September 2011.
- KHEZELI, Y. J.; NEZAMABADI-POUR, H. Fuzzy Lattice Reasoning for Pattern Classification Using a New Positive Valuation Function. **Advances in Fuzzy Systems**, v. 2012, January 2012. Article n° 14.
- KISILEVSKY, B. S. et al. Effects of Experience on Fetal Voice Recognition. **Psychological Science**, v. 14, n. 3, p. 220-224, May 2003.
- KUMAR, A.; ZHANG, D. Personal recognition using hand shape and texture. **IEEE Transactions on Image Processing**, v. 15, n. 8, p. 2454–2461, 2006.

- LANDWEHR, N.; HALL, M.; FRANK, E. Logistic Model Trees. **Machine Learning**, v. 59, n. 1-2, p. 161-205, 2005.
- LORENA, A. C.; CARVALHO, A. C. P. L. F. Uma introdução às Support Vector Machines. **Revista de Informática Teórica e Aplicada**, v. XIV, n. 2, 2007.
- LUQUE-BAENA, R. M. et al. Assessment of geometric features for individual identification and verification in biometric hand systems. **Expert Systems with Applications**, v. 40, n. 9, p. 3580–3594, July 2013.
- MALTONI, D. et al. **Handbook of Fingerprint Recognition**. 2^a. ed. London: Springer, 2000.
- MICHAEL, G. K. O.; CONNIE, T.; TEOH, A. B. J. A contactless biometric system using multiple hand features. **J. Vis. Commun. Image R.**, v. 23, p. 1068–1084, 2012.
- MILLER, R. P. **Finger dimension comparison identification system**. U.S. Patent N^o. 3576538, 1971.
- MORALES, A. et al. Comparing infrared and visible illumination for contactless hand based biometric scheme. **International Carnahan conference on security technology, ICCST**, 2008. 191–197.
- OTSU, N. A. Threshold Selection Method from Gray-Level Histograms. **IEEE Transactions on Systems, Man, and Cybernetics**, v. 9, n. 1, p. 62-66, 1979.
- PARK, G.; KIM, S. Hand Biometric Recognition Based on Fused Hand Geometry and Vascular Patterns. **Sensors**, v. 13, n. 3, p. 2895-2910, 2013.
- PLATT, J. C. Fast Training of Support Vector Machines using Sequential Minimal Optimization. In: _____ **Advances in kernel methods**. MA, USA: MIT Press Cambridge, 1999. p. 185 - 208.
- RODRIGUEZ, J. J.; KUNCHEVA, L. I.; ALONSO, C. J. Rotation Forest: A new classifier ensemble method. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 28, n. 10, p. 1619-1630, 2006.
- SANCHEZ-REILLO, R.; SANCHEZ-AVILA, C.; GONZALEZ-MARCOS, A. Biometric identification through hand geometry measurements. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 22, n. 10, p. 1168 - 1171, October 2000.
- SAVIČ, T.; PAVEŠIĆ, N. Personal recognition based on an image of the palmar surface of the hand. **Pattern Recognition**, v. 40, p. 3152 – 3163, 2007.
- SERAPIÃO, A. B. S. Fundamentos de otimização por inteligência de enxames: uma visão geral. **Revista Controle & Automação**, v. 20, n. 3, p. 271-304, 2009.
- SIDLAUSKAS, D. P.; TAMER, S. Hand Geometry Recognition. In: JAIN, A. K.; FLYNN, P.; ROSS, A. A. **Handbook of Biometrics**. New York, NY: Springer, 2008.
- SILVA, A. G. A. **Identificação e Autenticação Multibiométrica por Análise Computacional da Geometria da Mão e da Impressão Palmar**. UFPB. João Pessoa. 2013.

TAN, P. N.; STEINBACH, M.; KUMAR, V. Classification: Basic Concepts, Decision Trees and Model Evaluation. In: _____ **Introduction to Data Mining**. 1^a. ed. Boston, MA, USA: Addison-Wesley, 2005. Cap. 4.

WITTEN, I. H.; EIBE, F.; HALL, M. A. **Data mining. Practical Machine Learning Tools and Techniques**. 3. ed. Burlington, MA: Morgan Kaufmann, 2011.

XIONG, W. et al. Model-guided deformable hand shape recognition without positioning aids. **Pattern Recognition**, v. 38, p. 1651–1664, 2005.

YANG, X. S. **Nature-Inspired Metaheuristic Algorithms**. UK: Luniver Press, 2008.

YANG, X. S. Firefly algorithms for multimodal optimisation. **5th Symposium on Stochastic Algorithms, Foundations and Applications**, 5792, 2009. 169-178.

YANG, X. S.; HE, X. Firefly Algorithm: Recent Advances and Applications. **Int. J. of Swarm Intelligence**, v. 1, n. 1, p. 36 - 50, 2013.

Apêndice A - Detalhamento de classes com erros de classificação

A seguir, detalhamento das classes da base de dados dorsal envolvidas em erros de classificação. Para cada erro, são destacados os atributos da instância classificada erroneamente, comparando-os com os respectivos atributos das demais instâncias da classe, além das instâncias da classe de predição. Ao final, ainda é calculada a distância euclidiana simples entre a instância classificada erroneamente e a demais instâncias comparadas.

Erro E1

C-A	A1	A2	A3	A4	A5	A6	A7	A8	A9	A10	A11	A12	A13	A14	A15	A16	A17
A1	2036490	16432	0,736	2555,1	1729,0	991,1	97262	1771	101497	0,929	807,1	298,8	583,5	186,6	143,6	173,2	172,2
1039 - A2	2051317	16445	0,712	2552,6	1792,1	992,0	98768	1788	101876	0,930	815,2	300,3	588,0	188,1	144,4	170,8	172,8
1039 - A3	2032724	16421	0,717	2522,4	1757,7	990,4	98446	1783	101731	0,930	815,0	298,9	588,6	187,7	144,9	170,4	172,4
1039 - A4	2039377	16458	0,707	2535,0	1792,8	990,5	98744	1777	101956	0,930	816,8	299,8	588,5	188,5	145,1	170,8	173,0
1039 - A5	2053994	16490	0,678	2554,0	1876,6	989,4	101896	1785	107798	0,932	841,3	304,1	601,1	204,4	145,8	172,7	169,5
1039 - A6	2050885	16504	0,681	2549,7	1867,1	986,8	102454	1792	108300	0,934	847,7	303,9	606,9	204,9	144,1	171,4	168,6
1039 - A7	2061967	16521	0,685	2554,7	1860,3	985,3	102858	1804	109590	0,932	845,4	306,6	605,0	208,9	145,8	173,1	169,5
1051 - A1	1981101	16101	0,676	2411,5	1777,3	1019,5	118338	1994	124128	0,936	919,5	324,4	658,9	217,0	155,3	177,1	178,1
1051 - A2	2010360	16260	0,662	2461,0	1844,5	1015,9	123449	2031	129699	0,940	956,7	326,2	686,1	222,3	157,7	175,1	177,3
1051 - A3	2001345	16162	0,639	2448,2	1883,9	1015,9	123097	1979	128832	0,941	961,1	324,1	683,5	221,8	157,4	175,8	175,8
1051 - A4	1994385	16071	0,633	2432,1	1881,8	1013,2	124486	1938	130689	0,942	971,7	325,8	684,9	228,8	157,5	174,2	174,7
1051 - A5	1997983	16127	0,661	2442,6	1833,1	1012,2	119439	1964	125959	0,939	935,3	322,3	667,4	217,8	155,7	176,7	175,8
1051 - A6	1993796	16141	0,654	2427,9	1836,0	1015,7	120285	1986	125575	0,938	936,4	324,0	671,1	220,1	156,0	175,7	175,3
1051 - A7	1996548	16077	0,645	2435,7	1860,5	1015,9	121691	1945	126964	0,941	952,3	322,9	677,4	222,0	156,7	175,0	175,0

A18	A19	A20	A21	A22	A23	A24	A25	A26	A27	A28	A29	A30	A31	A32	A33	A34	A35	A36
168,1	184,4	185,4	3,099	4,145	162009	2352	167291	0,951	1141,9	352,3	828,5	206,7	181,6	187,7	188,7	204,7	217,7	206,7
169,9	185,0	187,1	2,496	2,379	160821	2371	166662	0,952	1146,8	349,3	832,0	210,5	177,5	183,5	187,5	202,6	215,5	204,6
169,2	182,6	184,7	2,871	1,904	162249	2354	166313	0,951	1142,9	352,2	829,5	205,4	180,3	190,4	192,4	204,4	216,4	206,4
168,8	184,4	186,6	3,172	1,752	162681	2356	166900	0,951	1144,1	353,3	829,7	209,5	181,3	190,4	193,5	204,4	216,6	205,4
174,0	185,2	191,0	3,093	4,594	164412	2394	170386	0,952	1160,8	354,4	840,0	223,6	181,4	188,5	189,7	204,0	213,4	211,2
173,1	185,6	192,4	2,540	4,522	164398	2400	171142	0,953	1163,5	354,3	839,1	225,6	180,9	187,5	188,2	205,0	213,2	213,2
175,4	186,5	195,0	2,848	4,691	165563	2407	171336	0,953	1167,9	354,2	844,9	219,9	182,0	189,1	190,3	204,6	213,8	209,7
185,6	192,9	214,1	3,846	1,288	173489	2432	178408	0,949	1171,1	370,3	847,5	228,1	178,3	188,5	198,5	217,9	233,2	232,2
184,6	194,4	212,4	3,151	0,213	175360	2458	180152	0,950	1182,2	369,9	859,3	223,2	179,9	189,0	199,0	219,1	232,2	228,3
183,8	194,1	212,0	2,489	0,380	177934	2462	183254	0,951	1203,3	371,3	867,4	234,5	178,4	187,6	200,3	217,7	232,6	230,4
184,2	198,6	216,6	2,108	0,253	175237	2451	180229	0,950	1181,0	370,5	856,8	226,2	179,7	189,6	200,9	217,2	232,3	230,2
183,4	190,5	213,4	2,075	2,693	177481	2435	182506	0,949	1189,4	373,6	857,3	231,2	178,3	189,7	204,3	217,9	237,5	232,4
183,3	193,2	213,4	1,979	0,841	174264	2445	179450	0,949	1175,1	370,7	851,9	228,4	178,5	188,7	199,9	216,2	233,5	232,5
183,1	194,7	213,1	2,051	0,667	176061	2423	181317	0,951	1191,8	370,2	859,9	230,3	179,0	188,5	199,9	216,7	232,5	231,5

A37	A38	A39	A40	A41	A42	A43	A44	A45	A46	A47	A48	A49	A50	A51	A52	A53	A54
1,370	-0,102	196586	2649	205826	0,957	1301,1	376,6	948,2	222,1	193,0	203,0	207,0	225,1	219,1	214,1	-2,482	-2,816
-0,074	-0,027	194385	2631	203260	0,958	1297,4	373,6	944,8	219,4	190,2	202,3	206,3	224,4	217,4	212,4	-2,460	-2,853
0,753	-0,482	195532	2643	204528	0,957	1297,2	375,9	943,7	223,0	192,8	202,9	205,9	225,1	218,0	213,9	-1,901	-3,195
0,785	-0,302	195472	2652	204743	0,957	1296,2	375,5	943,7	221,4	194,4	204,4	205,4	224,4	218,4	214,4	-2,045	-2,701
0,094	2,277	194211	2628	203535	0,957	1292,7	374,0	940,6	219,3	193,3	203,2	205,2	224,3	215,2	211,3	-1,657	-3,199
-0,277	2,515	194608	2630	203561	0,957	1294,1	374,4	942,6	218,3	191,3	204,2	207,2	225,3	216,2	211,3	-1,712	-2,964
0,008	2,294	196374	2643	205328	0,957	1301,3	375,8	948,7	219,4	194,4	204,4	206,4	225,5	217,5	213,5	-0,989	-3,478
2,311	-0,579	200175	2670	212022	0,952	1281,4	392,4	931,6	242,1	188,1	203,1	215,1	228,1	241,1	238,1	-3,074	-4,566
2,972	-1,295	201427	2678	211488	0,954	1294,1	389,9	939,9	237,3	189,1	203,1	215,2	226,3	239,4	233,3	-2,786	-3,809
2,655	-0,438	199780	2667	210171	0,953	1288,0	388,8	936,2	236,5	187,4	201,4	212,5	226,4	238,5	233,4	-2,546	-4,174
3,146	-0,177	199703	2660	208372	0,953	1285,1	389,0	932,2	234,8	187,6	200,6	213,8	226,7	240,8	230,7	-2,978	-3,041
2,697	-1,824	200736	2675	211902	0,953	1288,6	390,9	937,8	240,0	187,0	200,0	214,0	227,0	241,0	236,0	-2,618	-4,230
2,523	-0,604	200161	2662	210367	0,952	1281,9	391,6	932,4	238,9	187,7	200,8	213,8	229,0	241,9	236,8	-3,043	-3,747
2,890	-0,665	199975	2664	209915	0,953	1283,0	390,7	934,2	240,0	188,0	200,0	214,0	227,0	240,0	237,0	-2,286	-4,145

A55	A56	A57	A58	A59	A60	A61	A62	A63	A64	A65	A66	A67	A68	A69	A70	A71	A72
177124	2450	182684	0,947	1173,5	376,3	851,1	227,4	186,8	207,0	208,1	221,3	226,2	226,2	-4,277	-2,331	113399	1899
178134	2422	183232	0,949	1190,3	373,6	858,1	224,2	185,3	205,6	208,4	222,3	224,2	224,2	-3,310	-2,983	143620	2090

178399	2431	184842	0,949	1190,0	374,4	858,2	226,8	186,9	206,8	208,1	222,6	223,6	223,6	-3,488	-3,080	142166	2095
179336	2445	186214	0,949	1189,6	376,5	857,9	228,0	189,7	207,2	209,4	222,0	223,9	224,9	-3,221	-3,243	147114	2124
180106	2484	189895	0,949	1196,6	377,3	863,8	235,8	189,3	207,7	209,6	222,5	223,2	225,4	-2,923	-3,495	148844	2131
181860	2495	192124	0,949	1202,5	379,7	865,7	238,2	187,3	207,8	213,2	223,7	225,9	226,8	-3,424	-3,995	146738	2133
181695	2488	192014	0,949	1204,3	378,2	866,4	234,8	188,9	207,6	209,8	223,4	224,3	224,3	-3,116	-3,704	146222	2130
173753	2407	176553	0,938	1121,1	387,3	812,0	243,6	176,3	200,8	213,0	229,3	245,7	250,6	-2,109	-1,890	134120	2039
175019	2384	178308	0,940	1132,3	386,1	815,4	242,6	177,8	201,8	213,5	227,1	244,5	253,1	-2,068	-1,712	138583	2158
174952	2404	178462	0,941	1134,3	385,4	816,6	243,6	178,0	202,1	212,5	229,0	239,4	251,8	-1,871	-2,153	138488	2156
173650	2392	176724	0,939	1123,3	385,9	810,1	240,9	178,3	202,1	213,2	227,6	243,1	252,3	-1,954	-1,639	137627	2146
174172	2419	177225	0,939	1123,5	387,9	810,5	245,5	177,3	199,6	213,0	230,2	246,7	253,6	-2,252	-1,615	139642	2115
172569	2393	175828	0,939	1119,6	385,8	806,6	246,2	176,8	200,6	213,0	224,4	244,3	252,5	-2,801	-0,585	139193	2134
174297	2411	177577	0,939	1123,5	387,7	814,1	243,6	176,3	201,8	213,0	229,5	245,7	252,8	-1,922	-1,645	137555	2093

A73	A74	A75	A76	A77	A78	A79	A80	A81	A82	A83	A84	Distância
127014	0,836	718,6	394,5	519,5	274,2	150,6	175,6	201,7	260,7	258,5	266,6	
158580	0,902	923,4	398,1	648,4	293,4	176,1	212,2	237,6	234,8	242,0	263,4	1,1450
154407	0,902	910,7	393,5	642,6	283,5	171,6	211,5	238,6	236,8	240,4	250,7	1,0977
159455	0,903	934,7	401,5	658,0	296,0	172,2	212,5	240,2	238,2	247,4	267,4	1,1704
160665	0,901	939,6	406,9	663,6	304,9	167,0	208,7	239,1	242,7	257,5	279,5	1,2578
160159	0,895	916,2	408,0	649,3	303,5	166,8	206,2	237,0	251,0	256,0	277,2	1,1900
159035	0,899	922,2	404,7	653,6	301,0	164,8	204,8	234,8	247,1	253,5	273,4	1,1883
149660	0,886	860,3	399,1	601,0	287,9	164,6	200,4	233,9	250,4	259,6	268,1	1,4433
156095	0,881	870,4	411,9	617,0	304,9	165,2	197,3	237,8	254,7	266,3	283,8	1,5557
157128	0,881	871,0	412,6	616,1	307,0	166,4	199,9	241,7	254,9	266,5	285,4	1,5942
155436	0,879	865,9	412,5	612,6	309,3	166,4	197,0	238,5	256,8	268,2	286,3	1,6102
157928	0,885	880,4	410,3	619,3	303,3	168,9	201,6	238,7	252,9	264,3	281,3	1,5622
157495	0,881	873,3	412,8	616,5	305,9	166,7	199,6	241,0	256,4	265,0	282,8	1,5442
155006	0,883	869,7	408,5	611,7	300,6	168,5	200,2	241,5	255,2	264,4	278,6	1,5649

* Amostra de I039 classificada como I051

Erro E2

C-A	A1	A2	A3	A4	A5	A6	A7	A8	A9	A10	A11	A12	A13	A14	A15	A16	A17
A1	2166947	16990	0,709	2562,7	1806,6	1011,4	122388	1965	126523	0,934	923,1	329,5	660,9	206,9	164,2	187,0	178,7
I015 - A2	2097136	16914	0,705	2522,3	1788,9	1006,0	127639	2078	132065	0,947	995,0	320,2	721,8	201,6	154,3	176,8	169,5
I015 - A3	2092171	16981	0,697	2509,0	1800,1	1014,7	125925	2089	131447	0,949	999,1	315,1	728,0	198,0	148,7	174,2	168,1
I015 - A4	2107634	17153	0,698	2511,7	1798,3	1016,5	125483	2082	132303	0,948	993,6	316,3	723,6	200,6	151,3	176,8	167,8
I015 - A5	2117365	17076	0,700	2527,5	1805,5	1010,7	127309	2100	134528	0,948	999,1	318,7	728,2	202,1	153,8	179,5	169,3
I015 - A6	2142310	17057	0,697	2531,5	1814,9	1016,0	126163	2102	133745	0,947	993,3	318,6	722,9	205,2	151,9	176,6	166,2
I015 - A7	2153001	17052	0,711	2550,8	1793,3	1022,2	126671	2102	133996	0,947	994,6	319,1	724,6	202,6	153,4	177,1	169,9
I052 - A1	2243869	17889	0,709	2687,2	1893,8	1026,3	131952	2089	136966	0,951	1032,4	318,4	745,4	193,2	159,7	174,6	172,4
I052 - A2	2273554	17932	0,737	2736,0	1848,9	1020,8	135884	2123	141170	0,956	1071,1	315,5	776,2	185,1	154,7	173,7	172,7
I052 - A3	2220738	17808	0,731	2628,7	1793,2	1020,9	131077	2114	136554	0,951	1028,5	317,1	745,3	190,0	159,2	173,8	169,6
I052 - A4	2233770	17836	0,697	2652,5	1902,6	1017,7	133067	2125	139652	0,952	1046,8	319,7	752,6	207,1	157,7	172,9	170,7
I052 - A5	2213409	17782	0,723	2639,9	1822,7	1027,7	130813	2107	136582	0,949	1017,7	319,7	736,3	191,6	163,2	178,3	173,4
I052 - A6	2262984	17748	0,661	2683,0	2014,2	1021,5	137941	2114	145281	0,956	1090,5	319,9	779,3	212,6	158,4	172,8	167,8
I052 - A7	2269387	17782	0,656	2681,2	2024,3	1022,3	137824	2082	145091	0,955	1083,9	321,5	771,7	212,7	160,2	175,4	170,5

A18	A19	A20	A21	A22	A23	A24	A25	A26	A27	A28	A29	A30	A31	A32	A33	A34	A35	A36
200,6	199,6	199,6	0,462	-0,242	186144	2512	192884	0,955	1246,1	370,0	910,3	203,0	182,0	197,0	200,0	224,0	232,0	210,0
191,4	194,5	194,5	0,810	0,710	170666	2438	176570	0,958	1212,7	349,3	887,9	197,1	169,1	183,1	187,1	210,2	219,1	202,1
184,6	187,8	190,9	0,276	4,355	172000	2459	178202	0,958	1223,6	349,0	897,3	197,1	171,1	184,0	186,1	209,1	216,1	201,1
184,1	187,2	193,3	1,355	4,089	173224	2467	179186	0,958	1226,9	350,6	898,7	199,3	172,3	184,3	187,3	208,3	216,3	204,3
185,8	186,8	194,8	1,937	3,975	173140	2468	179142	0,959	1227,8	350,0	900,2	198,0	171,0	185,0	187,0	208,0	216,0	203,0
185,8	187,8	197,0	2,107	4,421	172361	2457	177708	0,958	1222,6	349,7	896,8	197,0	172,0	184,0	189,0	207,0	216,0	203,0
188,3	190,5	195,4	1,588	5,048	173969	2475	179846	0,959	1232,9	350,2	903,9	198,0	171,0	184,0	191,0	209,0	216,0	200,0
177,4	201,5	188,2	0,015	2,206	187481	2576	197712	0,960	1289,2	362,7	934,6	210,8	176,3	192,4	191,6	211,8	231,2	205,7
182,8	193,3	179,7	0,509	1,290	189378	2571	198780	0,961	1306,9	360,0	952,7	196,8	174,6	192,7	192,8	213,1	226,2	200,9
176,7	200,2	187,1	-0,166	3,334	186006	2572	195156	0,959	1275,1	363,3	926,6	208,3	177,2	191,3	190,3	210,3	232,3	210,3
174,8	198,5	195,4	-0,501	3,276	187538	2590	196715	0,959	1285,0	364,2	934,1	214,0	176,6	191,8	192,8	212,0	230,1	210,9
175,3	201,8	188,5	-0,357	4,387	188034	2586	197628	0,958	1275,0	367,5	925,2	213,5	185,5	192,4	190,5	209,4	234,5	213,5
179,5	194,3	194,3	-0,074	2,882	193311	2660	204883	0,961	1325,0	368,1	957,1	235,7	179,4	189,8	186,7	210,7	228,4	223,4
179,9	195,2	195,2	-0,135	3,152	195377	2664	210660	0,960	1333,9	373,0	958,5	251,8	175,7	190,9	188,7	211,5	227,7	232,2

A37	A38	A39	A40	A41	A42	A43	A44	A45	A46	A47	A48	A49	A50	A51	A52	A53	A54	A55
2,864	-0,006	216314	2746	222755	0,958	1368,9	393,7	1002,5	223,2	189,8	207,9	217,1	240,3	238,3	226,3	-4,156	-1,161	192612
2,441	0,346	198674	2657	204791	0,959	1324,4	374,8	969,2	219,1	178,5	194,8	204,0	228,2	228,2	219,1	-3,552	-1,616	182806
2,297	0,883	197688	2660	203298	0,959	1319,5	374,4	966,2	220,7	177,2	193,4	204,5	227,7	226,6	218,7	-3,568	-1,098	182740
2,487	0,238	197994	2668	203224	0,958	1315,1	376,0	965,9	221,5	178,4	194,4	205,4	228,5	227,6	221,5	-2,548	-2,327	180895
2,023	0,649	198898	2667	204074	0,959	1321,5	375,7	969,8	219,2	176,0	195,0	207,2	229,3	227,2	219,2	-2,676	-1,846	180951
2,084	0,627	199797	2653	204104	0,959	1322,0	376,7	968,5	220,3	179,7	195,0	210,1	230,3	226,4	221,3	-1,797	-1,843	183199
2,032	1,069	201535	2669	206193	0,960	1337,7	375,1	979,5	215,5	178,1	196,3	210,4	230,8	224,6	216,5	-2,274	-0,517	183637

-0,017	2,297	203292	2713	213379	0,961	1354,7	373,7	990,5	215,2	182,1	199,2	195,2	229,2	225,2	215,2	-1,128	-0,634	192409
0,376	1,219	207375	2756	218927	0,963	1385,2	372,7	1015,9	213,1	181,1	200,1	199,1	233,1	219,1	210,1	-1,172	-0,549	196346
0,000	1,215	203295	2726	213849	0,961	1354,4	374,5	988,8	220,4	183,3	198,4	196,4	228,4	224,4	217,4	-1,528	-0,931	195258
-0,539	1,871	203846	2730	213929	0,961	1357,2	374,7	992,2	220,1	183,1	199,1	198,1	228,1	224,1	217,1	-1,439	-1,011	194623
0,229	1,444	202451	2720	212129	0,960	1347,2	375,0	984,2	222,0	185,0	198,0	195,0	226,0	226,0	220,0	-1,157	-0,975	194473
-0,350	3,004	204330	2737	214133	0,962	1366,0	372,7	1000,1	217,0	185,0	197,0	196,0	229,0	221,0	215,0	-0,907	-0,759	195681
-1,219	4,567	203833	2732	214151	0,962	1360,4	373,5	996,9	219,0	187,0	199,0	195,0	228,0	221,0	216,0	-1,002	-1,312	194411

A56	A57	A58	A59	A60	A61	A62	A63	A64	A65	A66	A67	A68	A69	A70	A71	A72	A73	A74
2530	200103	0,954	1273,4	380,6	917,3	238,1	182,9	197,8	204,8	234,9	230,5	231,8	-3,547	-2,590	160947	2218	185830	0,921
2474	190161	0,955	1249,2	368,6	899,6	232,5	174,8	191,3	200,8	229,4	221,8	224,0	-2,792	-2,929	157599	2171	173766	0,927
2500	191804	0,955	1242,6	370,4	898,1	237,4	178,5	192,4	201,9	227,9	221,6	222,5	-3,121	-1,894	153840	2170	168323	0,924
2503	187884	0,954	1229,0	369,5	891,7	229,4	177,2	191,8	201,2	228,2	219,9	223,1	-2,631	-3,034	153360	2209	167747	0,922
2494	188055	0,954	1229,8	369,5	891,9	231,2	176,5	192,3	200,8	229,3	220,7	222,9	-2,663	-2,730	153691	2176	168140	0,923
2501	189825	0,955	1242,3	369,1	899,9	231,8	177,1	191,6	203,3	228,6	220,4	224,5	-3,007	-1,670	151788	2167	165780	0,921
2460	189957	0,955	1246,6	369,8	901,3	227,7	179,0	192,9	204,6	227,7	218,2	219,1	-3,180	-0,520	149593	2174	163291	0,917
2620	203196	0,956	1285,1	374,9	934,3	227,9	185,3	202,4	198,5	237,1	215,7	217,7	-2,600	-1,682	162610	2274	173371	0,920
2665	206954	0,958	1306,7	376,3	951,2	230,4	184,8	203,1	202,1	237,4	210,3	220,3	-2,721	-1,242	149447	2176	164377	0,897
2630	205422	0,955	1288,2	380,7	932,1	238,9	187,5	203,0	199,6	237,0	218,5	230,7	-2,574	-1,931	161175	2239	168649	0,919
2614	204765	0,957	1294,0	376,5	937,2	231,1	188,0	202,3	197,9	235,3	215,6	222,9	-2,274	-1,328	167893	2253	177250	0,926
2626	205422	0,954	1278,1	381,8	926,0	240,8	190,4	205,9	198,6	234,8	219,3	230,7	-0,566	-3,716	166827	2210	175489	0,926
2659	209867	0,958	1307,5	376,4	946,7	240,2	190,2	200,7	198,8	235,2	209,2	220,3	-1,485	-2,868	169971	2208	182339	0,930
2643	208715	0,957	1295,3	377,5	938,3	241,2	192,4	202,9	199,7	236,1	210,2	219,4	-1,108	-3,270	166962	2246	179128	0,924

A75	A76	A77	A78	A79	A80	A81	A82	A83	A84	Distância
1028,9	400,6	720,5	281,3	181,1	228,4	249,0	225,7	229,3	254,8	
1030,4	387,0	726,0	266,5	177,9	222,7	246,1	219,9	216,3	238,7	0,8894
1007,7	386,1	715,4	270,0	165,9	206,9	241,6	225,9	225,9	246,7	1,0174
1001,9	387,4	715,1	271,1	164,7	203,7	243,5	227,2	228,1	247,4	0,9897
1008,1	386,8	718,1	273,5	163,4	201,1	242,1	228,0	229,4	251,0	0,9861
992,2	387,1	707,1	272,2	163,6	202,2	238,9	228,6	230,0	247,5	0,9911
976,7	388,7	698,6	276,8	162,8	200,8	238,9	229,3	232,9	252,7	1,0010
1023,2	400,3	726,3	280,4	191,9	222,3	244,6	233,4	233,4	245,5	1,0265
920,2	407,0	664,3	265,8	175,0	203,1	229,1	257,3	239,8	238,9	1,2997
1009,6	397,6	706,2	265,5	197,4	226,6	243,6	235,1	235,5	242,7	1,0178
1057,7	398,8	748,1	275,3	192,9	222,9	240,4	233,6	233,6	251,1	1,0680
1051,0	397,9	740,7	272,7	192,8	226,1	241,4	233,5	234,9	251,6	1,0173
1082,9	398,1	760,8	281,5	190,7	226,3	241,9	231,1	229,7	252,4	1,3195
1050,2	402,0	742,6	286,0	189,4	224,1	242,1	235,0	235,0	250,8	1,4052

* Amostra de I015 classificada como I052

Erro E3

C-A	A1	A2	A3	A4	A5	A6	A7	A8	A9	A10	A11	A12	A13	A14	A15	A16	A17
A1	2166947	16990	0,709	2562,7	1806,6	1011,4	122388	1965	126523	0,934	923,1	329,5	660,9	206,9	164,2	187,0	178,7
I015 - A2	2097136	16914	0,705	2522,3	1788,9	1006,0	127639	2078	132065	0,947	995,0	320,2	721,8	201,6	154,3	176,8	169,5
I015 - A3	2092171	16981	0,697	2509,0	1800,1	1014,7	125925	2089	131447	0,949	999,1	315,1	728,0	198,0	148,7	174,2	168,1
I015 - A4	2107634	17153	0,698	2511,7	1798,3	1016,5	125483	2082	132303	0,948	993,6	316,3	723,6	200,6	151,3	176,8	167,8
I015 - A5	2117365	17076	0,700	2527,5	1805,5	1010,7	127309	2100	134528	0,948	999,1	318,7	728,2	202,1	153,8	179,5	169,3
I015 - A6	2142310	17057	0,697	2531,5	1814,9	1016,0	126163	2102	133745	0,947	993,3	318,6	722,9	205,2	151,9	176,6	166,2
I015 - A7	2153001	17052	0,711	2550,8	1793,3	1022,2	126671	2102	133996	0,947	994,6	319,1	724,6	202,6	153,4	177,1	169,9
I028 - A1	2327430	17724	0,671	2743,8	2035,1	1091,6	130540	2060	138334	0,944	1002,0	329,2	713,1	225,0	163,7	180,7	176,2
I028 - A2	2249906	17313	0,668	2640,2	1964,2	1080,9	129801	1968	135830	0,946	1004,3	325,3	709,5	215,2	163,3	179,4	178,0
I028 - A3	2262827	17437	0,694	2647,2	1905,1	1077,5	130270	2025	136683	0,943	987,3	329,5	704,4	210,2	172,2	187,8	179,8
I028 - A4	2266898	17378	0,667	2641,4	1968,9	1084,1	129947	1989	136480	0,944	998,3	328,0	706,6	220,6	167,2	181,1	177,5
I028 - A5	2256456	17376	0,667	2635,1	1963,6	1079,4	130148	1978	137648	0,944	995,2	328,8	704,7	217,1	172,7	188,0	178,5
I028 - A6	2280031	17377	0,662	2657,6	1992,0	1082,8	130280	1956	138743	0,946	1007,9	327,8	706,4	225,6	170,4	179,8	176,2
I028 - A7	2289952	17544	0,659	2676,7	2013,9	1085,5	132590	2026	142740	0,944	1006,3	331,6	713,2	221,2	176,4	189,4	178,6

A18	A19	A20	A21	A22	A23	A24	A25	A26	A27	A28	A29	A30	A31	A32	A33	A34	A35	A36
200,6	199,6	199,6	0,462	-0,242	186144	2512	192884	0,955	1246,1	370,0	910,3	203,0	182,0	197,0	200,0	224,0	232,0	210,0
191,4	194,5	194,5	0,810	0,710	170666	2438	176570	0,958	1212,7	349,3	887,9	197,1	169,1	183,1	187,1	210,2	219,1	202,1
184,6	187,8	190,9	0,276	4,355	172000	2459	178202	0,958	1223,6	349,0	897,3	197,1	171,1	184,0	186,1	209,1	216,1	201,1
184,1	187,2	193,3	1,355	4,089	173224	2467	179186	0,958	1226,9	350,6	898,7	199,3	172,3	184,3	187,3	208,3	216,3	204,3
185,8	186,8	194,8	1,937	3,975	173140	2468	179142	0,959	1227,8	350,0	900,2	198,0	171,0	185,0	187,0	208,0	216,0	203,0
185,8	187,8	197,0	2,107	4,421	172361	2457	177708	0,958	1222,6	349,7	896,8	197,0	172,0	184,0	189,0	207,0	216,0	203,0
188,3	190,5	195,4	1,588	5,048	173969	2475	179846	0,959	1232,9	350,2	903,9	198,0	171,0	184,0	191,0	209,0	216,0	200,0
184,3	198,6	204,0	0,789	0,327	183233	2595	200948	0,953	1237,1	373,8	895,5	238,8	190,3	195,5	190,4	211,5	230,7	225,6
187,4	201,3	197,7	1,636	-1,033	178282	2510	190748	0,954	1220,3	366,5	882,7	223,6	185,9	195,1	189,8	208,3	231,6	214,6
184,2	201,7	194,1	1,279	-0,315	180105	2513	191473	0,953	1218,8	369,7	881,1	221,2	194,9	196,9	191,9	208,2	232,4	217,1
185,6	200,0	200,8	1,484	-0,217	179164	2518	190906	0,953	1219,6	368,2	882,6	224,9	187,4	194,6	190,5	209,6	232,0	217,8
183,5	200,5	198,3	0,867	1,333	180908	2526	193681	0,953	1222,8	371,3	883,6	230,1	192,2	196,3	191,2	208,5	231,0	220,8
184,8	197,0	204,8	1,466	0,400	179804	2520	192170	0,954	1225,1	368,1	885,5	225,5	187,9	194,0	191,0	209,1	230,6	217,5

184,4	198,3	199,2	0,916	1,368	184333	2585	201678	0,952	1235,1	377,6	890,5	246,4	194,1	197,2	192,1	210,3	231,2	232,1
A37	A38	A39	A40	A41	A42	A43	A44	A45	A46	A47	A48	A49	A50	A51	A52	A53	A54	
2,864	-0,006	216314	2746	222755	0,958	1368,9	393,7	1002,5	223,2	189,8	207,9	217,1	240,3	238,3	226,3	-4,156	-1,161	
2,441	0,346	198674	2657	204791	0,959	1324,4	374,8	969,2	219,1	178,5	194,8	204,0	228,2	228,2	219,1	-3,552	-1,616	
2,297	0,883	197688	2660	203298	0,959	1319,5	374,4	966,2	220,7	177,2	193,4	204,5	227,7	226,6	218,7	-3,568	-1,098	
2,487	0,238	197994	2668	203224	0,958	1315,1	376,0	965,9	221,5	178,4	194,4	205,4	228,5	227,6	221,5	-2,548	-2,327	
2,023	0,649	198898	2667	204074	0,959	1321,5	375,7	969,8	219,2	176,0	195,0	207,2	229,3	227,2	219,2	-2,676	-1,846	
2,084	0,627	199797	2653	204104	0,959	1322,0	376,7	968,5	220,3	179,7	195,0	210,1	230,3	226,4	221,3	-1,797	-1,843	
2,032	1,069	201535	2669	206193	0,960	1337,7	375,1	979,5	215,5	178,1	196,3	210,4	230,8	224,6	216,5	-2,274	-0,517	
3,894	3,929	214586	2786	222983	0,958	1365,3	393,4	990,4	236,9	191,8	201,8	217,8	240,9	235,9	227,9	-2,714	-0,750	
4,050	2,555	212025	2747	220194	0,957	1351,8	391,4	981,5	228,0	189,0	202,0	216,0	241,0	238,0	222,0	-2,199	-0,795	
3,895	1,879	215088	2789	223560	0,956	1355,8	397,3	983,3	242,1	194,0	203,0	220,1	241,1	239,1	230,1	-2,458	-0,547	
3,374	2,779	213449	2785	222184	0,957	1354,2	395,1	982,9	241,0	190,0	202,0	218,0	241,0	238,0	230,0	-2,824	-0,654	
3,823	2,230	213149	2769	221268	0,956	1348,0	395,6	977,4	239,1	192,1	203,1	220,1	241,1	238,1	227,1	-2,262	-0,388	
3,831	2,201	214389	2779	223138	0,957	1358,2	394,9	985,7	237,1	192,1	202,1	220,1	242,1	237,1	226,1	-2,269	-0,990	
3,618	3,182	213488	2774	222051	0,956	1351,8	395,1	981,2	238,0	192,0	203,0	220,0	241,0	236,0	227,0	-2,151	-0,459	

A55	A56	A57	A58	A59	A60	A61	A62	A63	A64	A65	A66	A67	A68	A69	A70	A71	A72
192612	2530	200103	0,954	1273,4	380,6	917,3	238,1	182,9	197,8	204,8	234,9	230,5	231,8	-3,547	-2,590	160947	2218
182806	2474	190161	0,955	1249,2	368,6	899,6	232,5	174,8	191,3	200,8	229,4	221,8	224,0	-2,792	-2,929	157599	2171
182740	2500	191804	0,955	1242,6	370,4	898,1	237,4	178,5	192,4	201,9	227,9	221,6	222,5	-3,121	-1,894	153840	2170
180895	2503	187884	0,954	1229,0	369,5	891,7	229,4	177,2	191,8	201,2	228,2	219,9	223,1	-2,631	-3,034	153360	2209
180951	2494	188055	0,954	1229,8	369,5	891,9	231,2	176,5	192,3	200,8	229,3	220,7	222,9	-2,663	-2,730	153691	2176
183199	2501	189825	0,955	1242,3	369,1	899,9	231,8	177,1	191,6	203,3	228,6	220,4	224,5	-3,007	-1,670	151788	2167
183637	2460	189957	0,955	1246,6	369,8	901,3	227,7	179,0	192,9	204,6	227,7	218,2	219,1	-3,180	-0,520	149593	2174
193723	2514	201581	0,950	1245,9	389,9	890,5	244,4	191,5	208,5	211,7	237,7	240,3	233,6	-2,293	-3,234	151673	2279
192121	2575	200105	0,949	1238,2	389,7	892,7	248,2	186,1	206,5	207,7	234,9	240,9	235,6	-1,329	-3,932	150447	2154
192853	2554	200555	0,948	1229,7	392,0	886,1	242,3	195,8	211,3	211,3	236,3	241,1	234,1	-2,167	-3,551	149053	2119
193537	2561	203976	0,948	1237,1	392,8	891,0	250,1	193,2	211,2	212,2	236,2	240,7	236,5	-2,365	-4,441	149598	2115
194199	2569	204958	0,948	1234,9	394,0	888,0	247,1	199,3	212,6	212,6	236,7	238,9	233,8	-2,203	-4,308	150925	2137
195822	2590	206111	0,949	1244,3	394,1	898,2	246,5	198,9	212,2	211,3	238,2	240,1	232,9	-2,009	-4,032	152896	2177
195686	2561	206555	0,949	1248,8	393,6	898,0	249,9	198,0	210,7	212,6	238,2	239,5	232,8	-2,532	-3,724	154324	2205

A73	A74	A75	A76	A77	A78	A79	A80	A81	A82	A83	A84	Distância
185830	0,921	1028,9	400,6	720,5	281,3	181,1	228,4	249,0	225,7	229,3	254,8	
173766	0,927	1030,4	387,0	726,0	266,5	177,9	222,7	246,1	219,9	216,3	238,7	0,8894
168323	0,924	1007,7	386,1	715,4	270,0	165,9	206,9	241,6	225,9	225,9	246,7	1,0174
167747	0,922	1001,9	387,4	715,1	271,1	164,7	203,7	243,5	227,2	228,1	247,4	0,9897
168140	0,923	1008,1	386,8	718,1	273,5	163,4	201,1	242,1	228,0	229,4	251,0	0,9861
165780	0,921	992,2	387,1	707,1	272,2	163,6	202,2	238,9	228,6	230,0	247,5	0,9911
163291	0,917	976,7	388,7	698,6	276,8	162,8	200,8	238,9	229,3	232,9	252,7	1,0010
177957	0,876	905,4	436,5	645,7	325,7	180,1	214,4	254,2	257,1	265,1	294,3	1,2945
175422	0,891	926,6	420,1	655,4	298,5	181,8	216,8	256,7	248,6	246,5	271,4	0,9542
168802	0,889	909,9	416,9	642,0	295,0	182,1	221,9	263,9	251,4	250,6	269,2	0,9974
170522	0,891	917,1	417,1	646,2	291,4	186,7	223,3	263,5	247,9	244,4	266,5	0,9969
173026	0,891	923,0	418,7	651,6	296,9	184,7	222,2	262,4	249,3	247,1	269,1	1,0309
175240	0,891	930,3	423,2	657,7	309,6	182,9	223,1	262,5	248,5	249,9	276,2	1,0516
177487	0,887	932,2	430,4	655,7	318,2	184,7	222,7	263,0	255,1	258,6	288,4	1,2496

* Amostra de I015 classificada como I028

Erro E4

C - A	A1	A2	A3	A4	A5	A6	A7	A8	A9	A10	A11	A12	A13	A14	A15	A16	A17
A1	2166947	16990	0,709	2562,7	1806,6	1011,4	122388	1965	126523	0,934	923,1	329,5	660,9	206,9	164,2	187,0	178,7
I015 - A2	2097136	16914	0,705	2522,3	1788,9	1006,0	127639	2078	132065	0,947	995,0	320,2	721,8	201,6	154,3	176,8	169,5
I015 - A3	2092171	16981	0,697	2509,0	1800,1	1014,7	125925	2089	131447	0,949	999,1	315,1	728,0	198,0	148,7	174,2	168,1
I015 - A4	2107634	17153	0,698	2511,7	1798,3	1016,5	125483	2082	132303	0,948	993,6	316,3	723,6	200,6	151,3	176,8	167,8
I015 - A5	2117365	17076	0,700	2527,5	1805,5	1010,7	127309	2100	134528	0,948	999,1	318,7	728,2	202,1	153,8	179,5	169,3
I015 - A6	2142310	17057	0,697	2531,5	1814,9	1016,0	126163	2102	133745	0,947	993,3	318,6	722,9	205,2	151,9	176,6	166,2
I015 - A7	2153001	17052	0,711	2550,8	1793,3	1022,2	126671	2102	133996	0,947	994,6	319,1	724,6	202,6	153,4	177,1	169,9
I025 - A1	2164732	16983	0,649	2569,8	1954,9	1033,7	128170	2010	135281	0,941	981,1	331,2	695,5	230,5	161,1	181,2	171,4
I025 - A2	2176700	17185	0,666	2640,1	1970,2	1023,3	128206	2042	134344	0,943	986,5	328,8	706,0	226,4	156,2	178,1	168,3
I025 - A3	2180171	16962	0,622	2577,3	2018,5	1023,6	130261	1973	139070	0,942	994,3	334,7	698,2	240,6	162,6	184,0	170,4
I025 - A4	2181958	17271	0,663	2652,6	1986,4	1023,6	127675	2039	136138	0,942	981,2	330,3	702,2	231,7	152,1	176,7	166,8
I025 - A5	2214237	17179	0,610	2629,8	2083,8	1026,4	131070	1968	139277	0,942	997,5	335,9	698,0	241,4	163,6	181,4	174,2
I025 - A6	2223164	17476	0,662	2721,7	2039,7	1036,3	133381	2019	142821	0,944	1012,0	335,2	715,4	236,3	167,8	185,3	171,4
I025 - A7	2212195	17300	0,659	2666,0	2005,7	1040,3	131778	2016	141314	0,942	998,5	336,0	705,1	237,4	168,1	185,6	171,1

A18	A19	A20	A21	A22	A23	A24	A25	A26	A27	A28	A29	A30	A31	A32	A33	A34	A35	A36
200,6	199,6	199,6	0,462	-0,242	186144	2512	192884	0,955	1246,1	370,0	910,3	203,0	182,0	197,0	200,0	224,0	232,0	210,0
191,4	194,5	194,5	0,810	0,710	170666	2438	176570	0,958	1212,7	349,3	887,9	197,1	169,1	183,1	187,1	210,2	219,1	202,1
184,6	187,8	190,9	0,276	4,355	172000	2459	178202	0,958	1223,6	349,0	897,3	197,1	171,1	184,0	186,1	209,1	216,1	201,1

184,1	187,2	193,3	1,355	4,089	173224	2467	179186	0,958	1226,9	350,6	898,7	199,3	172,3	184,3	187,3	208,3	216,3	204,3
185,8	186,8	194,8	1,937	3,975	173140	2468	179142	0,959	1227,8	350,0	900,2	198,0	171,0	185,0	187,0	208,0	216,0	203,0
185,8	187,8	197,0	2,107	4,421	172361	2457	177708	0,958	1222,6	349,7	896,8	197,0	172,0	184,0	189,0	207,0	216,0	203,0
188,3	190,5	195,4	1,588	5,048	173969	2475	179846	0,959	1232,9	350,2	903,9	198,0	171,0	184,0	191,0	209,0	216,0	200,0
180,4	204,6	216,6	-0,029	0,156	173181	2498	187120	0,954	1207,3	361,3	871,5	233,1	192,1	189,9	177,6	195,0	226,1	223,9
182,6	204,5	214,4	-1,588	0,224	173394	2501	186666	0,955	1207,8	360,1	875,6	226,0	190,5	190,5	179,5	196,6	226,0	219,0
182,6	206,2	223,4	0,470	0,234	176932	2533	192938	0,954	1220,5	366,3	879,1	240,6	196,2	193,3	178,5	196,2	227,3	229,2
181,1	205,7	216,0	-1,642	2,063	175446	2528	188636	0,955	1220,9	362,2	881,4	233,4	185,4	189,3	180,3	197,7	228,3	225,4
186,4	207,8	224,2	0,414	-0,545	182948	2585	201835	0,952	1239,2	380,7	885,9	271,7	191,3	188,1	181,4	201,7	232,7	254,6
185,8	206,1	219,1	-0,514	1,902	181511	2563	198019	0,954	1236,9	371,0	890,5	243,3	198,7	193,6	181,2	198,9	228,7	231,9
186,1	204,1	219,4	0,052	2,010	180365	2533	194011	0,952	1221,3	372,5	878,9	240,4	195,8	195,8	185,6	203,0	233,1	235,3

A37	A38	A39	A40	A41	A42	A43	A44	A45	A46	A47	A48	A49	A50	A51	A52	A53	A54
2,864	-0,006	216314	2746	222755	0,958	1368,9	393,7	1002,5	223,2	189,8	207,9	217,1	240,3	238,3	226,3	-4,156	-1,161
2,441	0,346	198674	2657	204791	0,959	1324,4	374,8	969,2	219,1	178,5	194,8	204,0	228,2	228,2	219,1	-3,552	-1,616
2,297	0,883	197688	2660	203298	0,959	1319,5	374,4	966,2	220,7	177,2	193,4	204,5	227,7	226,6	218,7	-3,568	-1,098
2,487	0,238	197994	2668	203224	0,958	1315,1	376,0	965,9	221,5	178,4	194,4	205,4	228,5	227,6	221,5	-2,548	-2,327
2,023	0,649	198898	2667	204074	0,959	1321,5	375,7	969,8	219,2	176,0	195,0	207,2	229,3	227,2	219,2	-2,676	-1,846
2,084	0,627	199797	2653	204104	0,959	1322,0	376,7	968,5	220,3	179,7	195,0	210,1	230,3	226,4	221,3	-1,797	-1,843
2,032	1,069	201535	2669	206193	0,960	1337,7	375,1	979,5	215,5	178,1	196,3	210,4	230,8	224,6	216,5	-2,274	-0,517
0,717	1,563	198388	2637	213332	0,957	1305,6	379,0	952,7	214,8	199,8	208,8	196,7	224,9	230,9	211,8	-2,777	-5,340
1,230	2,173	198729	2665	213450	0,959	1320,5	375,9	962,3	216,6	195,5	203,6	195,5	225,6	227,6	207,5	-3,475	-3,004
1,878	1,658	200918	2661	216883	0,957	1312,8	381,7	957,7	218,0	203,0	211,9	196,8	225,1	230,1	213,9	-1,818	-5,636
1,355	2,106	199982	2688	214751	0,959	1326,2	377,0	967,0	221,3	193,3	201,2	196,2	226,3	230,3	209,3	-3,997	-2,112
4,091	0,286	202300	2771	228395	0,956	1325,2	380,7	961,3	252,2	203,1	205,0	196,9	222,0	229,1	227,2	-3,079	-6,114
1,929	2,300	202733	2712	218920	0,958	1331,8	380,8	970,2	227,1	201,1	205,1	197,1	227,1	227,1	213,1	-3,799	-2,062
1,413	2,286	203482	2728	219987	0,957	1326,1	384,9	964,2	236,1	198,1	206,1	202,1	223,1	231,1	218,1	-2,987	-2,913

A55	A56	A57	A58	A59	A60	A61	A62	A63	A64	A65	A66	A67	A68	A69	A70	A71	A72
192612	2530	200103	0,954	1273,4	380,6	917,3	238,1	182,9	197,8	204,8	234,9	230,5	231,8	-3,547	-2,590	160947	2218
182806	2474	190161	0,955	1249,2	368,6	899,6	232,5	174,8	191,3	200,8	229,4	221,8	224,0	-2,792	-2,929	157599	2171
182740	2500	191804	0,955	1242,6	370,4	898,1	237,4	178,5	192,4	201,9	227,9	221,6	222,5	-3,121	-1,894	153840	2170
180895	2503	187884	0,954	1229,0	369,5	891,7	229,4	177,2	191,8	201,2	228,2	219,9	223,1	-2,631	-3,034	153360	2209
180951	2494	188055	0,954	1229,8	369,5	891,9	231,2	176,5	192,3	200,8	229,3	220,7	222,9	-2,663	-2,730	153691	2176
183199	2501	189825	0,955	1242,3	369,1	899,9	231,8	177,1	191,6	203,3	228,6	220,4	224,5	-3,007	-1,670	151788	2167
183637	2460	189957	0,955	1246,6	369,8	901,3	227,7	179,0	192,9	204,6	227,7	218,2	219,1	-3,180	-0,520	149593	2174
189353	2559	205728	0,952	1241,6	381,8	899,4	233,3	196,2	213,7	203,2	236,5	216,8	221,0	-0,555	-6,964	160526	2149
189778	2529	203850	0,953	1249,6	379,8	896,5	230,2	198,6	211,2	202,7	237,5	214,4	218,8	-1,008	-5,720	164507	2139
194086	2590	214021	0,952	1262,2	386,1	909,5	243,2	207,2	216,7	205,9	236,0	213,5	218,9	0,497	-8,120	167101	2126
188206	2543	204306	0,953	1250,9	378,0	902,7	232,4	191,3	204,0	199,9	236,5	215,7	220,7	-1,845	-5,575	165795	2172
192936	2554	213158	0,952	1262,8	386,5	898,9	250,9	201,7	212,9	208,8	238,8	219,6	223,2	-0,031	-7,513	170355	2207
192285	2565	210237	0,953	1259,7	383,2	911,5	240,2	200,6	211,4	205,1	237,0	215,5	219,9	0,257	-7,245	166312	2189
189837	2562	205945	0,952	1246,6	381,8	898,5	238,8	199,9	207,5	201,2	236,6	221,1	219,8	-0,169	-5,874	164875	2150

A73	A74	A75	A76	A77	A78	A79	A80	A81	A82	A83	A84	Distância
185830	0,921	1028,9	400,6	720,5	281,3	181,1	228,4	249,0	225,7	229,3	254,8	
173766	0,927	1030,4	387,0	726,0	266,5	177,9	222,7	246,1	219,9	216,3	238,7	0,8894
168323	0,924	1007,7	386,1	715,4	270,0	165,9	206,9	241,6	225,9	225,9	246,7	1,0174
167747	0,922	1001,9	387,4	715,1	271,1	164,7	203,7	243,5	227,2	228,1	247,4	0,9897
168140	0,923	1008,1	386,8	718,1	273,5	163,4	201,1	242,1	228,0	229,4	251,0	0,9861
165780	0,921	992,2	387,1	707,1	272,2	163,6	202,2	238,9	228,6	230,0	247,5	0,9911
163291	0,917	976,7	388,7	698,6	276,8	162,8	200,8	238,9	229,3	232,9	252,7	1,0010
177763	0,911	990,2	407,6	693,4	279,4	207,3	239,1	264,6	226,1	229,7	252,7	1,1971
182921	0,915	1015,6	409,1	704,3	278,5	217,9	249,2	261,2	222,5	233,1	252,2	1,1209
181996	0,915	1019,6	410,9	706,5	274,3	215,7	251,8	265,9	225,2	238,8	253,6	1,3742
186483	0,916	1026,2	411,1	708,0	283,6	212,3	238,9	258,3	227,0	236,9	256,7	1,0848
187723	0,914	1030,5	418,7	715,2	293,5	216,2	252,0	267,0	227,6	240,4	265,9	1,5602
185617	0,912	1016,8	416,0	706,7	291,4	211,5	246,0	261,2	230,4	238,2	264,4	1,2460
181341	0,915	1016,3	410,4	705,0	286,4	209,7	246,0	260,2	227,0	238,3	262,3	1,1494

* Amostra de I015 classificada como I025

Erro E5

C - A	A1	A2	A3	A4	A5	A6	A7	A8	A9	A10	A11	A12	A13	A14	A15	A16	A17
A1	2166947	16990	0,709	2562,7	1806,6	1011,4	122388	1965	126523	0,934	923,1	329,5	660,9	206,9	164,2	187,0	178,7
I015 - A2	2097136	16914	0,705	2522,3	1788,9	1006,0	127639	2078	132065	0,947	995,0	320,2	721,8	201,6	154,3	176,8	169,5
I015 - A3	2092171	16981	0,697	2509,0	1800,1	1014,7	125925	2089	131447	0,949	999,1	315,1	728,0	198,0	148,7	174,2	168,1
I015 - A4	2107634	17153	0,698	2511,7	1798,3	1016,5	125483	2082	132303	0,948	993,6	316,3	723,6	200,6	151,3	176,8	167,8
I015 - A5	2117365	17076	0,700	2527,5	1805,5	1010,7	127309	2100	134528	0,948	999,1	318,7	728,2	202,1	153,8	179,5	169,3
I015 - A6	2142310	17057	0,697	2531,5	1814,9	1016,0	126163	2102	133745	0,947	993,3	318,6	722,9	205,2	151,9	176,6	166,2
I015 - A7	2153001	17052	0,711	2550,8	1793,3	1022,2	126671	2102	133996	0,947	994,6	319,1	724,6	202,6	153,4	177,1	169,9
I026 - A1	2469184	18413	0,668	2936,0	2185,2	1078,2	135314	1963	143035	0,949	1046,6	329,9	735,8	230,1	157,9	180,5	180,5
I026 - A2	2454762	18089	0,667	2876,6	2143,2	1060,2	136463	2047	143979	0,947	1037,8	333,5	738,4	230,2	160,3	180,6	182,0

I026 - A3	2491821	18366	0,663	2938,6	2198,7	1067,2	139029	2015	147628	0,947	1054,4	337,4	741,7	239,2	161,1	181,7	181,7
I026 - A4	2479289	18195	0,682	2901,2	2122,5	1067,2	135138	2073	142574	0,943	1013,8	336,1	723,7	227,2	163,7	185,6	186,5
I026 - A5	2457999	18091	0,674	2832,1	2093,4	1064,5	136020	2066	144615	0,944	1018,7	337,1	727,4	226,4	165,0	189,2	184,7
I026 - A6	2468233	18177	0,663	2877,1	2152,9	1062,1	137606	2055	146932	0,947	1046,8	335,1	741,7	234,7	158,7	180,9	178,7
I026 - A7	2481714	18230	0,659	2880,6	2165,7	1065,7	138894	2053	148072	0,948	1050,0	335,2	745,8	230,0	163,1	184,7	182,5

A18	A19	A20	A21	A22	A23	A24	A25	A26	A27	A28	A29	A30	A31	A32	A33	A34	A35	A36
200,6	199,6	199,6	0,462	-0,242	186144	2512	192884	0,955	1246,1	370,0	910,3	203,0	182,0	197,0	200,0	224,0	232,0	210,0
191,4	194,5	194,5	0,810	0,710	170666	2438	176570	0,958	1212,7	349,3	887,9	197,1	169,1	183,1	187,1	210,2	219,1	202,1
184,6	187,8	190,9	0,276	4,355	172000	2459	178202	0,958	1223,6	349,0	897,3	197,1	171,1	184,0	186,1	209,1	216,1	201,1
184,1	187,2	193,3	1,355	4,089	173224	2467	179186	0,958	1226,9	350,6	898,7	199,3	172,3	184,3	187,3	208,3	216,3	204,3
185,8	186,8	194,8	1,937	3,975	173140	2468	179142	0,959	1227,8	350,0	900,2	198,0	171,0	185,0	187,0	208,0	216,0	203,0
185,8	187,8	197,0	2,107	4,421	172361	2457	177708	0,958	1222,6	349,7	896,8	197,0	172,0	184,0	189,0	207,0	216,0	203,0
188,3	190,5	195,4	1,588	5,048	173969	2475	179846	0,959	1232,9	350,2	903,9	198,0	171,0	184,0	191,0	209,0	216,0	200,0
184,1	200,4	215,3	-0,029	1,640	195758	2591	206045	0,958	1309,0	375,0	945,2	233,3	184,8	199,1	200,0	209,9	230,1	228,2
186,4	201,4	215,8	0,191	1,634	195535	2630	202997	0,957	1296,4	376,5	941,0	227,9	189,1	201,4	198,3	211,6	232,0	224,8
190,9	202,9	219,3	0,307	2,164	198498	2655	209038	0,958	1319,6	378,2	955,0	239,4	184,7	197,3	198,6	214,4	230,9	229,9
186,5	202,6	212,5	0,362	2,137	193097	2630	202053	0,956	1282,0	376,2	930,0	227,6	192,4	201,4	196,5	212,5	231,6	224,6
186,9	202,2	214,7	0,159	2,884	192217	2611	200015	0,956	1280,7	373,7	930,8	220,4	190,2	200,3	196,2	213,5	228,4	219,4
188,1	201,7	218,9	0,354	1,488	194967	2651	203884	0,959	1310,3	372,3	953,1	227,5	182,6	192,8	195,7	213,2	229,7	223,4
189,7	201,1	214,1	-0,130	2,698	195968	2655	206266	0,958	1305,6	375,9	947,9	232,7	187,5	196,8	198,0	216,2	227,6	225,6

A37	A38	A39	A40	A41	A42	A43	A44	A45	A46	A47	A48	A49	A50	A51	A52	A53	A54
2,864	-0,006	216314	2746	222755	0,958	1368,9	393,7	1002,5	223,2	189,8	207,9	217,1	240,3	238,3	226,3	-4,156	-1,161
2,441	0,346	198674	2657	204791	0,959	1324,4	374,8	969,2	219,1	178,5	194,8	204,0	228,2	228,2	219,1	-3,552	-1,616
2,297	0,883	197688	2660	203298	0,959	1319,5	374,4	966,2	220,7	177,2	193,4	204,5	227,2	226,6	218,7	-3,568	-1,098
2,487	0,238	197994	2668	203224	0,958	1315,1	376,0	965,9	221,5	178,4	194,4	205,4	228,5	227,6	221,5	-2,548	-2,327
2,023	0,649	198898	2667	204074	0,959	1321,5	375,7	969,8	219,2	176,0	195,0	207,2	229,3	227,2	219,2	-2,676	-1,846
2,084	0,627	199797	2653	204104	0,959	1322,0	376,7	968,5	220,3	179,7	195,0	210,1	230,3	226,4	221,3	-1,797	-1,843
2,032	1,069	201535	2669	206193	0,960	1337,7	375,1	979,5	215,5	178,1	196,3	210,4	230,8	224,6	216,5	-2,274	-0,517
-1,227	3,645	228217	2857	239712	0,962	1443,8	393,0	1057,9	216,0	194,0	207,0	219,0	242,0	232,0	213,0	-3,317	-1,396
-0,533	2,218	229319	2863	239939	0,962	1446,6	394,5	1058,2	218,2	194,0	208,2	222,2	243,4	233,3	214,2	-3,417	-1,231
-1,222	3,943	232810	2885	242522	0,963	1461,2	395,8	1068,3	217,8	196,7	209,8	221,8	244,9	232,9	212,8	-2,554	-0,520
-0,794	2,943	232677	2880	241186	0,961	1448,9	399,6	1056,0	227,1	200,8	210,9	221,0	244,2	237,3	223,2	-1,213	-1,589
-1,128	3,553	230614	2873	240548	0,962	1446,0	396,7	1055,5	224,4	199,2	208,4	217,3	244,5	232,5	220,4	-2,124	-0,818
-1,991	3,335	229496	2866	241986	0,963	1456,1	392,3	1064,2	215,7	195,6	206,6	216,7	244,8	230,8	211,6	-3,560	-0,955
-1,214	4,419	231385	2879	241974	0,963	1458,7	394,5	1064,8	220,7	197,5	209,6	217,6	243,9	230,7	216,7	-2,693	-0,265

A55	A56	A57	A58	A59	A60	A61	A62	A63	A64	A65	A66	A67	A68	A69	A70	A71	A72
192612	2530	200103	0,954	1273,4	380,6	917,3	238,1	182,9	197,8	204,8	234,9	230,5	231,8	-3,547	-2,590	160947	2218
182806	2474	190161	0,955	1249,2	368,6	899,6	232,5	174,8	191,3	200,8	229,4	221,8	224,0	-2,792	-2,929	157599	2171
182740	2500	191804	0,955	1242,6	370,4	898,1	237,4	178,5	192,4	201,9	227,9	221,6	222,5	-3,121	-1,894	153840	2170
180895	2503	187884	0,954	1229,0	369,5	891,7	229,4	177,2	191,8	201,2	228,2	219,9	223,1	-2,631	-3,034	153360	2209
180951	2494	188055	0,954	1229,8	369,5	891,9	231,2	176,5	192,3	200,8	229,3	220,7	222,9	-2,663	-2,730	153691	2176
183199	2501	189825	0,955	1242,3	369,1	899,9	231,8	177,1	191,6	203,3	228,6	220,4	224,5	-3,007	-1,670	151788	2167
183637	2460	189957	0,955	1246,6	369,8	901,3	227,7	179,0	192,9	204,6	227,7	218,2	219,1	-3,180	-0,520	149593	2174
206974	2690	212864	0,953	1307,2	394,5	953,9	235,9	199,8	210,9	215,8	234,9	237,9	232,0	-2,626	-1,161	169927	2291
205446	2660	211826	0,955	1312,1	391,2	950,2	234,1	194,1	212,5	214,7	236,0	236,3	229,0	-3,882	-1,324	173167	2282
209560	2694	217043	0,954	1319,9	396,8	954,4	242,5	198,2	215,6	219,7	237,4	239,4	227,0	-2,364	-2,551	170316	2309
207739	2644	212618	0,952	1303,1	397,3	943,7	237,5	200,6	214,9	217,8	236,5	241,6	235,5	-1,935	-1,874	171529	2301
206248	2657	212008	0,953	1304,1	394,6	944,8	236,6	198,5	214,0	214,2	238,5	238,5	232,4	-2,882	-1,537	166170	2169
208226	2695	218826	0,955	1330,1	392,8	962,6	242,2	194,4	208,9	212,1	239,0	237,8	228,6	-4,027	-1,955	170539	2223
208267	2679	216994	0,954	1321,5	394,4	955,4	242,7	197,8	214,6	215,5	238,3	237,4	226,0	-2,187	-3,029	171696	2256

A73	A74	A75	A76	A77	A78	A79	A80	A81	A82	A83	A84	Distância
185830	0,921	1028,9	400,6	720,5	281,3	181,1	228,4	249,0	225,7	229,3	254,8	
173766	0,927	1030,4	387,0	726,0	266,5	177,9	222,7	246,1	219,9	216,3	238,7	0,8894
168323	0,924	1007,7	386,1	715,4	270,0	165,9	206,9	241,6	225,9	225,9	246,7	1,0174
167747	0,922	1001,9	387,4	715,1	271,1	164,7	203,7	243,5	227,2	228,1	247,4	0,9897
168140	0,923	1008,1	386,8	718,1	273,5	163,4	201,1	242,1	228,0	229,4	251,0	0,9861
165780	0,921	992,2	387,1	707,1	272,2	163,6	202,2	238,9	228,6	230,0	247,5	0,9911
163291	0,917	976,7	388,7	698,6	276,8	162,8	200,8	238,9	229,3	232,9	252,7	1,0010
181044	0,911	1023,7	422,9	723,5	307,9	192,4	225,0	254,5	252,3	262,6	278,7	1,4103
187922	0,913	1042,5	425,0	729,4	312,9	205,0	233,3	257,2	244,7	256,1	281,3	1,2784
184941	0,909	1022,1	425,2	722,6	309,6	200,4	228,2	253,7	249,6	257,6	276,0	1,5039
184569	0,907	1019,5	428,3	721,0	314,6	196,7	225,9	255,9	253,2	262,6	282,3	1,3338
178638	0,906	995,0	420,3	693,9	301,4	205,1	234,8	261,0	249,7	258,9	266,0	1,2457
183552	0,911	1025,5	422,4	717,8	308,6	201,0	231,0	257,4	248,6	258,6	277,2	1,3909
184166	0,910	1025,8	425,6	719,0	308,8	204,2	234,4	261,3	249,1	256,3	275,8	1,4227

* Amostra de I015 classificada como I026

Erro E6

C - A	A1	A2	A3	A4	A5	A6	A7	A8	A9	A10	A11	A12	A13	A14	A15	A16	A17
A2	2205460	17286	0,699	2511,1	1795,3	1081,2	127566	1980	130079	0,924	909,2	347,8	652,9	220,4	159,7	187,9	196,4
1060 - A1	2256720	17232	0,587	2522,6	2041,5	1124,3	147272	2029	154027	0,935	1029,9	366,0	715,6	265,2	171,9	191,7	203,0
1060 - A3	2300405	17483	0,667	2615,7	1949,9	1106,9	137867	1931	143303	0,941	1013,0	341,7	708,5	225,4	171,2	187,6	190,4
1060 - A4	2326591	17412	0,664	2651,0	1981,6	1112,8	139918	1927	145858	0,941	1024,0	345,2	713,0	234,2	172,6	188,9	191,7
1060 - A5	2285553	17380	0,668	2612,9	1943,8	1107,3	136723	1910	141532	0,939	996,2	343,2	695,7	222,1	170,9	190,1	192,9
1060 - A6	2327216	17467	0,680	2663,9	1954,1	1101,9	135460	1885	140716	0,943	1008,6	334,9	705,8	209,4	170,8	188,6	188,6
1060 - A7	2324339	17319	0,669	2662,2	1978,9	1110,4	137005	1830	140112	0,943	1014,2	336,6	703,8	208,9	167,2	186,3	194,1
1018 - A1	2180188	17088	0,705	2478,9	1759,1	1077,1	127496	2011	134400	0,925	914,8	346,9	653,8	225,9	181,9	197,4	187,0
1018 - A2	2195313	17084	0,697	2484,7	1781,3	1066,5	126473	2033	134020	0,926	912,7	344,3	654,8	220,0	181,2	197,8	184,6
1018 - A3	2203453	17005	0,659	2470,1	1858,8	1050,1	126515	2052	134769	0,929	923,0	342,7	661,9	227,3	182,9	196,5	183,1
1018 - A4	2189464	16967	0,695	2466,9	1774,8	1047,6	124495	2029	131927	0,926	904,1	342,4	650,2	220,9	179,4	198,7	183,6
1018 - A5	2198709	16984	0,651	2459,7	1867,7	1057,4	125849	2052	134944	0,926	913,0	345,7	654,5	235,1	181,2	197,7	182,4
1018 - A6	2204872	17088	0,651	2475,6	1880,0	1068,6	127312	2051	135732	0,926	918,3	347,3	656,0	234,6	182,7	196,0	184,6
1018 - A7	2183042	17036	0,636	2443,9	1886,8	1058,7	125948	2045	134489	0,926	915,2	344,9	655,4	234,2	180,1	193,7	182,0

A18	A19	A20	A21	A22	A23	A24	A25	A26	A27	A28	A29	A30	A31	A32	A33	A34	A35	A36
213,2	224,5	220,4	-2,313	1,738	199537	2525	205774	0,942	1210,9	408,0	875,5	232,4	202,0	215,1	231,2	239,4	260,6	246,5
220,0	228,4	237,7	0,115	1,770	201922	2555	207822	0,947	1245,9	401,4	901,7	231,4	208,1	214,2	225,3	235,5	251,6	232,4
215,4	216,8	207,6	3,844	-1,669	199454	2516	206770	0,949	1252,3	395,4	902,1	226,9	204,1	209,2	215,5	242,7	249,7	226,0
215,1	216,5	213,7	4,183	-1,602	201384	2487	208343	0,951	1268,7	393,9	911,4	225,0	204,7	211,0	216,4	243,0	247,4	218,6
214,9	219,3	212,9	3,350	-0,955	199622	2464	205768	0,948	1245,2	397,8	892,1	228,1	204,7	211,4	219,6	239,8	253,7	233,5
213,6	210,8	196,6	4,341	-1,771	201454	2485	208578	0,951	1272,3	393,2	912,4	225,1	204,8	210,2	216,5	243,5	247,6	218,4
216,0	216,7	207,5	3,063	-2,969	199827	2410	206956	0,949	1258,3	395,4	894,2	231,2	207,5	212,4	216,5	240,2	251,3	229,0
197,4	210,3	218,3	2,902	-0,136	177259	2440	185411	0,941	1141,4	386,8	817,8	234,8	213,8	206,7	207,7	224,8	233,8	236,8
193,5	205,8	217,8	2,449	-0,139	175868	2429	184451	0,940	1133,0	386,6	810,5	236,1	213,1	207,1	208,1	222,1	234,1	240,1
192,3	200,6	216,8	2,071	1,384	178239	2470	188551	0,942	1150,6	387,2	823,9	242,1	212,1	205,1	207,1	220,1	232,1	242,1
191,6	201,7	216,8	1,689	2,246	177828	2457	188404	0,940	1142,4	388,9	816,1	243,2	213,2	207,2	208,2	221,2	233,2	246,2
191,6	202,1	223,7	1,871	0,512	176710	2453	187023	0,940	1138,1	387,8	814,9	243,1	213,1	207,1	208,1	220,1	232,1	245,1
194,1	205,8	222,9	2,595	-0,230	178810	2496	192543	0,940	1147,1	390,9	822,1	250,3	212,3	207,3	208,2	222,3	232,3	248,3
191,8	204,1	223,8	2,009	0,231	176778	2471	189081	0,939	1135,2	390,4	811,8	249,2	211,1	205,1	209,1	222,1	232,1	249,2

A37	A38	A39	A40	A41	A42	A43	A44	A45	A46	A47	A48	A49	A50	A51	A52	A53	A54
-3,198	3,588	216431	2721	224806	0,945	1286,6	420,6	938,4	257,1	194,1	215,1	230,1	257,1	267,1	255,1	-6,943	2,190
-2,060	1,828	218205	2755	226632	0,946	1301,0	419,9	946,0	261,3	195,3	216,3	229,3	257,3	261,3	252,3	-6,294	3,577
2,306	-0,244	220748	2753	230787	0,950	1328,0	415,8	967,0	256,3	198,6	214,7	224,9	258,3	256,3	243,1	-5,278	0,997
1,779	-0,513	220920	2723	231401	0,951	1337,0	412,7	971,6	251,5	198,2	214,7	226,8	256,9	252,7	237,2	-5,422	0,601
1,056	-0,065	218843	2705	228598	0,947	1307,6	418,9	949,8	260,8	199,2	216,6	227,0	257,8	260,8	252,7	-5,824	1,330
2,035	-0,481	221498	2728	231894	0,951	1337,7	414,0	972,3	253,7	198,4	215,9	226,1	257,8	254,7	240,4	-5,133	0,590
2,180	-0,484	219340	2663	228493	0,947	1311,4	419,8	946,2	261,5	200,2	218,5	227,7	256,1	261,5	252,0	-4,674	0,537
1,449	2,917	219552	2743	227552	0,947	1307,5	418,6	945,0	252,0	216,0	213,0	233,0	251,0	253,0	250,0	-6,111	2,179
0,917	3,041	219581	2740	229267	0,947	1307,2	419,8	943,7	254,2	217,0	213,0	233,1	251,2	253,2	253,2	-7,676	3,126
-0,721	5,061	218141	2719	230535	0,947	1305,5	418,9	938,8	254,4	216,7	212,8	232,0	248,3	251,4	255,4	-9,358	2,664
-0,423	5,042	219419	2734	231947	0,947	1309,3	420,7	939,7	257,9	219,1	213,0	232,4	248,7	251,8	256,9	-8,779	1,946
-0,319	5,162	218070	2712	228822	0,946	1299,6	420,1	935,4	256,0	215,4	214,4	234,6	248,9	252,9	257,0	-8,755	3,507
-1,124	6,424	217207	2721	228747	0,947	1298,2	418,9	935,9	253,4	218,1	213,0	232,2	249,3	251,4	253,4	-8,646	1,972
-0,605	6,685	215852	2704	225917	0,946	1287,4	419,2	926,8	255,4	215,1	213,0	234,2	250,5	252,4	255,4	-8,394	3,529

A55	A56	A57	A58	A59	A60	A61	A62	A63	A64	A65	A66	A67	A68	A69	A70	A71	A72
190138	2559	198404	0,937	1169,8	407,2	848,9	262,0	194,0	213,0	218,0	251,0	251,0	251,0	-5,396	0,589	142957	2085
193147	2541	200642	0,941	1192,4	404,7	862,3	254,4	192,4	214,8	220,8	254,4	246,1	245,2	-4,583	2,106	151888	2129
193514	2579	202161	0,941	1195,8	404,5	869,5	256,0	196,0	215,0	218,0	250,0	244,0	243,0	-5,361	1,027	145483	2118
196478	2606	206205	0,942	1212,3	405,8	882,7	260,3	195,9	214,1	220,1	252,2	242,2	243,2	-5,500	1,357	147934	2121
188163	2518	196416	0,937	1160,6	405,1	841,7	257,9	194,4	214,6	217,6	249,8	247,8	248,8	-5,735	1,149	145327	2129
194806	2584	203796	0,942	1204,2	404,7	876,2	258,6	195,2	214,3	217,3	250,6	242,6	243,6	-5,276	1,324	146331	2130
188251	2496	195754	0,938	1163,5	403,6	843,7	255,4	193,2	216,5	219,7	249,3	248,3	247,3	-5,032	1,603	144947	2134
199592	2586	206630	0,932	1175,6	424,8	843,6	272,8	212,4	215,3	229,5	255,7	265,7	273,8	-5,764	4,619	144564	2008
200307	2565	207446	0,931	1173,4	427,8	837,4	278,3	212,8	215,0	232,2	257,9	268,1	277,3	-5,890	5,332	155814	2070
205620	2556	212355	0,936	1214,3	426,0	855,4	277,8	214,5	214,5	232,5	255,3	268,3	275,6	-6,731	2,200	157051	2056
203321	2548	210429	0,934	1191,6	426,8	845,4	279,2	215,0	214,7	233,1	258,0	271,0	278,0	-7,347	4,691	157065	2061
206271	2558	212850	0,937	1216,5	426,4	859,4	278,5	215,8	213,6	232,3	254,8	267,8	276,3	-6,652	2,143	158888	2064
203633	2527	211214	0,935	1203,4	426,4	856,4	275,1	216,9	215,0	230,8	253,0	265,6	274,2	-6,573	1,773	158335	2068
204155	2550	211302	0,936	1207,9	425,0	856,9	276,3	215,2	215,2	230,5	254,8	265,9	274,1	-6,372	2,073	158046	2063

A73	A74	A75	A76	A77	A78	A79	A80	A81	A82	A83	A84	Distância
150062	0,894	890,5	398,4	630,5	270,4	173,5	202,2	250,0	253,9	251,6	256,5	
162136	0,902	945,4	408,6	668,4	298,3	171,3	203,1	253,3	251,5	256,4	273,5	1,0854
153517	0,895	902,3	402,0	638,8	277,8	173,5	201,7	251,3	253,7	251,5	259,1	1,1390
156848	0,901	921,2	399,7	654,1	272,9	175,3	204,0	254,0	251,0	247,5	256,4	1,2336
153516	0,897	906,5	401,4	640,3	280,9	172,8	202,3	249,3	250,4	252,6	262,5	0,9325
154763	0,900	914,0	398,9	642,5	274,1	173,6	203,6	251,5	249,9	247,7	255,7	1,2478
152802	0,894	897,9	402,5	634,7	277,4	174,1	203,7	251,6	252,1	252,7	261,2	1,1477
150918	0,881	867,7	409,8	600,0	263,9	188,2	236,8	260,4	256,3	265,3	269,7	1,2288
162625	0,889	918,1	420,0	642,2	279,0	192,5	242,7	266,1	259,6	270,4	274,0	1,3047

163149	0,888	918,4	422,4	636,6	282,3	198,0	248,2	269,4	261,4	272,3	275,9	1,3155
162863	0,893	927,5	418,0	646,6	274,0	193,9	242,7	266,8	259,6	268,5	269,1	1,2868
166766	0,892	933,2	422,7	647,0	281,0	196,8	249,9	269,7	261,0	271,0	273,2	1,3322
165233	0,890	927,9	423,5	640,3	284,4	198,8	249,7	268,8	261,6	271,0	276,6	1,3080
162415	0,890	925,5	422,0	641,0	283,0	197,3	248,3	268,8	260,2	271,6	275,8	1,3134

* Amostra de I060 classificada como I018

Erro E7

C - A	A1	A2	A3	A4	A5	A6	A7	A8	A9	A10	A11	A12	A13	A14	A15	A16	A17
A1	2022379	16601	0,724	2448,3	1689,3	1005,9	119027	2033	126165	0,943	949,1	315,5	685,1	208,3	161,0	167,1	166,9
I095 - A2	2067987	16663	0,716	2515,9	1757,1	1014,4	122669	2056	129066	0,944	966,9	318,9	698,4	208,4	160,6	166,9	169,1
I095 - A3	2071295	16745	0,730	2558,5	1748,6	996,8	121671	2056	128385	0,946	969,9	315,3	701,2	206,9	160,3	167,6	165,4
I095 - A4	2081930	16668	0,729	2542,6	1740,5	1019,0	120600	2056	126562	0,941	948,8	320,3	686,4	215,1	158,6	167,8	172,9
I095 - A5	2078631	16705	0,728	2539,1	1741,7	1013,4	121435	2059	127414	0,943	956,9	319,1	690,7	211,3	160,1	168,3	171,3
I095 - A6	2088453	16761	0,735	2548,6	1727,1	1013,0	121369	2064	128919	0,944	966,1	318,0	696,2	216,6	159,1	167,3	167,3
I095 - A7	2090250	16825	0,733	2552,1	1734,8	1017,5	121174	2055	128155	0,946	969,3	315,3	700,5	210,4	158,2	164,6	164,6
I199 - A1	2050947	16655	0,699	2551,6	1823,9	985,2	117589	1975	124107	0,948	967,2	309,2	692,8	215,6	146,2	160,6	158,3
I199 - A2	2049526	16657	0,723	2565,8	1771,7	987,1	114007	2013	119075	0,945	936,8	307,1	678,9	206,5	144,2	161,6	158,5
I199 - A3	2048461	16537	0,706	2552,4	1807,3	981,5	114406	1982	119137	0,946	944,7	306,1	681,2	207,1	143,9	160,6	157,5
I199 - A4	2056091	16570	0,710	2563,4	1803,9	984,7	115785	1992	120504	0,947	953,0	306,8	688,5	207,1	145,8	161,6	158,4
I199 - A5	2055612	16615	0,697	2560,3	1836,9	988,7	117045	1995	123559	0,947	964,4	308,9	695,0	216,3	143,3	160,7	157,2
I199 - A6	2053840	16586	0,688	2556,9	1854,8	989,3	115592	1952	122969	0,947	958,5	308,9	686,3	223,0	141,5	158,5	156,3
I199 - A7	2057117	16621	0,692	2571,3	1855,2	987,0	116809	1939	124350	0,947	966,0	309,6	689,7	223,7	143,7	159,8	159,0

A18	A19	A20	A21	A22	A23	A24	A25	A26	A27	A28	A29	A30	A31	A32	A33	A34	A35	A36
168,1	191,8	207,1	2,189	2,368	167579	2458	181149	0,953	1179,0	357,1	854,6	222,4	184,2	179,0	185,2	195,2	226,4	227,5
172,0	195,1	209,4	1,734	2,764	170472	2507	186272	0,954	1200,0	358,3	869,3	228,5	183,0	180,0	183,0	194,2	224,4	227,4
169,5	192,3	205,0	0,986	3,472	172344	2505	184903	0,955	1210,7	357,5	878,3	221,7	183,4	180,3	182,3	196,5	226,7	224,8
171,7	195,7	209,8	0,770	3,379	170468	2480	181363	0,954	1196,1	357,2	866,4	220,3	185,2	182,2	182,2	194,3	227,3	222,3
171,3	194,8	207,4	1,191	2,889	171075	2486	182743	0,955	1202,3	356,6	870,6	218,3	185,2	181,2	182,3	194,2	226,3	222,3
170,4	191,3	210,3	1,515	3,514	170892	2489	184008	0,955	1201,9	357,0	871,0	220,5	184,5	179,4	183,4	194,4	226,5	224,5
170,9	191,8	206,3	0,804	3,212	170363	2477	182718	0,955	1199,5	355,9	870,4	218,7	184,4	180,3	182,5	194,5	225,7	222,8
177,5	183,4	206,6	-1,719	1,815	169761	2560	182216	0,957	1221,5	354,3	891,6	246,2	166,4	177,3	176,6	206,2	207,2	229,0
175,9	181,0	203,4	-1,851	0,787	166597	2535	178602	0,956	1199,6	353,1	877,3	241,3	164,6	177,8	178,5	205,9	208,0	228,1
176,5	181,8	203,0	-1,232	0,694	168893	2550	182159	0,956	1209,9	356,6	881,3	248,1	164,7	176,1	179,0	207,1	210,0	234,8
177,4	181,8	200,8	-1,210	0,552	170176	2556	182935	0,957	1222,1	355,2	891,0	246,9	165,4	176,8	177,5	205,7	208,8	230,2
176,9	181,3	206,4	-1,765	1,296	170659	2575	184433	0,956	1222,7	357,4	892,1	252,0	164,7	175,8	177,8	205,7	209,8	233,6
176,9	181,8	210,0	-3,290	2,974	169159	2560	181923	0,957	1216,4	354,8	887,6	246,1	162,4	174,5	177,7	205,3	209,5	232,8
177,9	180,9	208,4	-2,373	2,393	169918	2551	182088	0,957	1223,3	354,0	893,3	244,7	164,2	176,6	178,5	206,4	207,6	229,2

A37	A38	A39	A40	A41	A42	A43	A44	A45	A46	A47	A48	A49	A50	A51	A52	A53	A54
-0,451	6,893	201178	2669	212307	0,953	1290,4	390,3	937,6	235,0	195,0	190,0	201,0	232,0	250,0	239,0	-4,673	2,469
-1,380	7,770	204958	2704	215535	0,955	1314,3	390,4	956,7	235,1	194,1	190,1	201,1	233,1	250,1	237,1	-4,371	1,956
-0,911	5,776	205786	2702	216464	0,956	1323,7	388,2	963,9	228,0	198,0	192,0	200,0	234,0	245,0	231,0	-3,195	-0,086
-0,138	3,788	204395	2686	214841	0,956	1320,5	385,9	960,3	225,4	198,3	193,4	200,4	230,4	245,4	227,4	-1,580	0,295
-0,445	4,893	204581	2687	215074	0,956	1321,0	386,3	960,5	225,4	197,4	192,4	200,4	231,4	245,4	229,4	-2,703	1,060
-0,657	6,231	206316	2713	216946	0,956	1324,6	389,6	963,5	232,0	195,0	191,0	201,0	234,0	249,0	235,0	-4,315	1,424
-0,394	4,980	205294	2698	216379	0,956	1322,8	387,7	963,5	228,4	195,3	191,3	200,4	232,4	245,4	232,4	-5,383	2,873
-1,674	4,627	203220	2737	210372	0,956	1317,9	387,6	967,2	246,1	182,0	189,0	202,0	235,1	238,1	245,1	-1,875	1,303
-2,690	6,369	201115	2719	208474	0,957	1317,2	383,6	965,7	241,1	177,1	189,1	202,1	233,1	235,1	240,1	-3,303	2,117
-2,859	6,405	204697	2756	211752	0,956	1324,8	389,1	970,2	249,1	178,0	191,0	205,0	236,1	238,1	246,1	-2,329	0,609
-2,130	5,293	204451	2752	211302	0,957	1328,4	386,9	974,1	245,0	179,0	191,0	203,0	235,0	237,0	244,0	-1,889	0,654
-2,713	5,330	203076	2737	210143	0,956	1318,4	387,2	966,1	246,0	182,0	190,0	203,0	235,0	237,0	244,0	-2,221	0,916
-3,817	6,255	201744	2728	209415	0,956	1313,8	386,2	964,3	245,0	179,0	189,0	203,0	234,0	237,0	244,0	-3,438	1,830
-2,314	5,198	201275	2716	208472	0,956	1311,8	385,1	963,6	243,4	179,3	190,3	203,4	234,4	234,4	241,4	-2,435	1,630

A55	A56	A57	A58	A59	A60	A61	A62	A63	A64	A65	A66	A67	A68	A69	A70	A71	A72
171466	2453	178236	0,945	1146,5	375,8	829,1	240,3	180,7	184,7	193,9	229,2	236,3	240,3	1,471	-3,642	119346	1965
174250	2474	182115	0,947	1165,6	375,5	842,9	239,2	184,6	185,6	192,7	229,0	236,2	237,1	2,120	-3,998	122380	1940
173177	2464	183190	0,947	1165,3	373,6	838,3	239,1	186,9	181,8	191,0	227,7	235,0	234,0	2,462	-5,071	120634	1917
171861	2438	179302	0,947	1158,7	371,7	834,8	234,8	185,9	186,7	189,8	225,5	234,8	232,8	2,394	-4,163	119272	1916
172815	2452	179961	0,948	1166,6	371,8	841,5	236,3	180,3	187,3	190,5	226,2	234,2	233,2	2,406	-4,605	121387	1939
171729	2458	178882	0,946	1151,3	374,6	832,5	238,3	184,0	185,0	192,0	227,2	236,3	239,3	1,533	-3,938	118697	1947
172259	2471	180717	0,947	1159,7	373,2	839,1	238,2	184,0	183,0	191,0	226,2	235,1	236,2	2,065	-4,336	122657	2004
166607	2429	171448	0,942	1120,9	375,1	817,4	249,8	172,0	188,1	195,2	222,5	235,6	244,7	-2,484	-1,024	130954	1942
167405	2444	172838	0,943	1126,7	375,5	822,8	250,1	169,2	189,2	194,3	223,8	235,9	246,9	-3,703	-0,936	130253	1923
166605	2441	172918	0,943	1125,3	373,9	823,0	248,8	170,3	189,4	194,4	220,5	233,8	243,9	-2,554	-2,394	127583	1915
166227	2435	172163	0,943	1123,3	373,0	821,7	246,1	170,8	190,8	194,8	222,0	233,0	241,0	-2,953	-1,883	128861	1916
166795	2440	172451	0,944	1127,5	373,5	824,0	247,9	170,3	190,5	193,5	220,8	233,8	243,9	-2,946	-1,343	128744	1922
167084	2442	173072	0,943	1125,9	375,2	821,1	249,8	169,7	190,1	195,2	222,5	234,6	246,6	-3,327	-1,791	126617	1905
166167	2434	171005	0,943	1120,2	374,3	819,7	248,1	169,8	189,8	194,8	222,0	234,0	244,1	-3,128	-1,182	129547	1918

A73	A74	A75	A76	A77	A78	A79	A80	A81	A82	A83	A84	Distância
129487	0,908	846,3	354,4	602,0	241,5	149,6	177,1	193,5	225,3	230,7	238,3	
133647	0,910	864,2	358,3	617,0	254,9	149,6	177,9	195,4	223,8	233,3	244,1	0,3177
131830	0,907	849,0	356,9	602,9	248,6	150,3	178,0	195,0	228,3	233,3	243,6	0,4412
128073	0,906	842,8	356,6	601,5	251,9	151,5	180,3	197,3	222,8	227,2	241,1	0,5212
131124	0,908	852,8	358,2	610,1	252,2	151,0	180,1	197,1	224,0	230,7	243,2	0,4198
130912	0,900	827,4	359,9	591,2	244,8	152,2	178,2	194,6	227,3	234,0	243,0	0,3134
132667	0,906	853,7	361,2	613,2	253,7	152,2	179,9	198,3	225,1	230,9	242,6	0,3774
136663	0,900	872,6	379,6	614,7	275,2	161,3	205,1	227,1	229,1	248,9	259,6	1,0585
136444	0,902	874,7	377,2	614,5	273,4	161,6	202,9	227,9	231,6	249,3	259,9	1,0714
134813	0,901	864,9	374,4	611,5	272,5	158,4	197,0	224,0	227,9	247,0	260,5	1,0432
136107	0,901	868,5	376,1	613,8	273,7	160,1	201,3	224,1	229,8	248,2	260,2	1,0529
135891	0,901	868,8	376,2	615,5	274,1	158,2	200,4	224,0	228,7	247,8	260,6	1,0873
133252	0,900	859,8	373,9	608,2	272,3	158,1	197,1	224,9	228,4	246,8	258,9	1,1412
136356	0,901	869,5	377,5	612,8	273,7	158,9	202,2	224,8	230,6	249,7	261,0	1,1106

* Amostra de I095 classificada como I099

Erro E8

C - A	A1	A2	A3	A4	A5	A6	A7	A8	A9	A10	A11	A12	A13	A14	A15	A16	A17
A4	1861251	15754	0,692	2326,4	1679,3	969,1	98942	1812	107040	0,934	838,4	298,6	604,1	198,2	143,0	163,6	162,3
I100 - A1	1940811	15846	0,649	2400,9	1825,9	999,3	100917	1764	110951	0,933	849,7	305,5	598,5	221,8	145,7	161,3	161,3
I100 - A2	1951323	15802	0,619	2397,2	1882,1	1001,4	101973	1776	111059	0,934	857,8	306,0	602,6	222,0	145,0	157,8	159,2
I100 - A3	1929814	15854	0,636	2378,9	1835,9	1003,3	97853	1703	107103	0,930	830,3	305,3	580,7	225,6	142,1	155,6	159,8
I100 - A5	1928026	15765	0,655	2387,8	1804,7	994,1	102391	1797	111730	0,935	860,0	305,6	606,8	218,9	145,7	160,7	158,7
I100 - A6	1919250	15773	0,669	2377,0	1766,5	996,4	98254	1824	111061	0,927	822,2	307,8	590,6	217,2	147,4	167,1	162,1
I100 - A7	1906284	15702	0,629	2366,6	1839,4	999,0	101381	1694	109643	0,935	860,5	304,5	600,0	219,9	146,4	157,7	159,1
1033 - A1	1846108	15789	0,671	2364,8	1753,8	984,1	98845	1795	105295	0,925	809,7	307,8	579,2	211,2	145,0	172,7	171,8
1033 - A2	1834809	15731	0,686	2339,1	1702,9	975,3	97884	1789	102284	0,924	800,8	305,7	576,0	201,2	140,4	170,8	176,2
1033 - A3	1842705	15728	0,681	2340,3	1713,4	972,3	96648	1786	100937	0,922	788,8	306,2	567,1	200,6	145,0	170,8	173,9
1033 - A4	1865817	15819	0,664	2367,2	1771,1	985,3	97418	1785	102706	0,926	803,3	304,1	576,1	200,3	144,9	173,7	172,8
1033 - A5	1855901	15867	0,660	2373,8	1782,7	989,3	98373	1780	104207	0,925	804,7	306,2	575,5	203,2	149,3	174,0	172,7
1033 - A6	1863841	15727	0,677	2341,5	1723,7	982,7	96032	1789	100578	0,924	792,8	303,3	569,4	199,2	143,8	170,3	171,3
1033 - A7	1854414	15825	0,670	2349,5	1744,8	981,0	97918	1796	103705	0,926	806,5	304,8	578,2	201,8	145,5	172,1	171,1

A18	A19	A20	A21	A22	A23	A24	A25	A26	A27	A28	A29	A30	A31	A32	A33	A34	A35	A36
171,2	181,1	192,8	7,663	5,266	155956	2406	169013	0,948	1118,4	356,5	810,8	248,2	173,2	173,2	182,7	199,4	219,1	238,7
174,1	186,9	209,0	5,761	6,791	155601	2388	164848	0,950	1120,0	351,2	810,2	231,1	173,5	174,5	181,7	197,9	215,8	229,0
173,4	187,0	208,4	4,155	5,186	157696	2421	170459	0,949	1126,6	355,7	815,8	242,6	175,3	175,3	183,6	198,7	218,1	232,4
172,6	186,7	214,3	5,001	5,741	154516	2369	162297	0,950	1116,1	349,5	806,1	230,2	173,3	174,4	181,5	198,8	214,0	227,2
173,7	187,3	208,1	5,282	5,875	156239	2396	166321	0,949	1119,1	353,1	813,6	234,3	174,0	174,9	183,1	198,1	216,2	231,2
176,0	184,1	203,3	8,747	9,215	154992	2379	164797	0,948	1109,2	352,8	806,9	233,0	174,0	175,0	184,0	199,0	216,0	230,0
173,2	187,4	208,6	4,371	5,178	156607	2387	168015	0,950	1129,9	352,4	816,0	238,9	174,3	174,3	181,6	198,1	216,1	230,6
175,0	185,7	199,1	2,808	6,263	146144	2250	151276	0,943	1048,9	348,6	758,1	220,2	172,9	182,0	182,0	200,1	220,2	220,2
174,9	187,6	193,9	1,430	6,162	145215	2232	151303	0,943	1046,1	346,9	754,3	214,1	168,0	179,0	182,0	200,1	222,1	219,1
175,8	188,2	195,5	3,432	4,715	146407	2233	152498	0,941	1039,8	351,2	751,4	218,1	178,1	184,1	184,1	200,1	222,1	221,1
175,0	185,4	193,6	3,391	6,072	147824	2257	153187	0,941	1047,1	353,1	756,1	224,2	175,9	184,0	187,0	201,1	222,1	222,2
174,0	185,7	195,5	3,318	5,974	147960	2262	153519	0,942	1052,2	352,1	760,8	224,2	174,7	184,8	184,7	202,0	221,2	221,2
174,6	185,8	191,9	2,977	4,946	146460	2236	152030	0,941	1038,3	352,0	747,5	220,0	176,0	185,0	186,0	200,0	222,0	223,0
175,2	185,7	193,6	3,485	6,002	147734	2253	153660	0,941	1045,0	353,4	754,5	223,8	177,6	184,7	185,6	200,7	222,8	223,8

A37	A38	A39	A40	A41	A42	A43	A44	A45	A46	A47	A48	A49	A50	A51	A52	A53	A54
1,435	5,325	189337	2613	197276	0,953	1256,1	378,8	920,7	237,1	180,8	185,9	204,0	222,1	236,1	238,1	-1,151	-3,201
2,680	3,076	192664	2632	200100	0,955	1278,4	377,5	935,2	231,4	183,1	187,2	205,2	220,3	233,3	235,3	-1,080	-3,362
2,234	4,917	191498	2603	199037	0,955	1272,1	376,6	929,1	229,3	183,6	187,7	204,0	220,1	234,4	234,4	-1,278	-2,996
2,476	2,337	190392	2614	197896	0,955	1269,0	375,6	929,5	229,2	182,1	187,2	203,2	220,1	231,2	233,2	-1,693	-2,791
2,238	4,367	192092	2624	200383	0,955	1274,7	377,9	933,3	232,6	183,2	186,1	203,4	222,6	235,8	235,8	-1,814	-3,178
1,990	4,055	191960	2603	199159	0,954	1268,4	379,2	927,8	232,6	182,8	186,9	206,3	224,6	236,8	236,8	-1,614	-2,109
2,168	4,070	190416	2609	198014	0,955	1267,9	375,7	928,9	228,6	183,5	186,5	202,6	220,7	232,7	233,6	-1,137	-2,987
2,104	1,621	185221	2551	189053	0,947	1202,3	386,5	863,5	241,3	184,2	199,3	217,2	232,2	235,3	235,3	-3,368	-0,642
1,942	1,586	186227	2559	190210	0,947	1209,2	386,7	866,2	240,6	184,5	199,5	218,5	232,6	237,6	239,6	-3,049	-0,189
2,638	1,369	189160	2570	192413	0,946	1211,0	381,6	867,9	244,7	188,5	201,6	221,7	231,7	239,7	234,8	-2,814	-0,012
2,508	1,544	188304	2578	191568	0,947	1212,6	389,9	871,7	244,3	187,2	201,2	220,3	232,3	236,4	237,4	-2,477	-0,938
2,258	2,497	186119	2552	189297	0,947	1203,1	387,5	865,3	241,2	186,1	201,2	219,1	230,2	236,2	235,2	-2,473	-0,423
2,110	1,019	189508	2585	192579	0,946	1214,8	392,1	870,2	247,1	187,9	201,9	221,0	233,0	239,0	242,1	-2,627	-0,620
2,558	1,018	188372	2578	191748	0,946	1208,1	391,6	865,5	247,2	187,2	202,2	220,2	232,2	238,3	241,3	-2,541	-0,786

A55	A56	A57	A58	A59	A60	A61	A62	A63	A64	A65	A66	A67	A68	A69	A70	A71	A72
162882	2416	168070	0,943	1114,8	372,6	801,8	251,3	168,1	186,6	200,1	215,4	238,0	253,3	0,065	-3,066	117992	1858
164169	2419	168897	0,945	1127,2	370,2	810,9	246,8	169,1	186,3	200,7	215,0	234,4	248,0	-0,094	-3,045	134274	1918
164889	2396	169416	0,944	1129,1	371,1	811,5	246,8	168,7	187,4	201,9	214,6	234,2	248,8	-1,082	-1,684	135325	1950
165624	2442	170045	0,945	1136,1	370,8	819,0	245,8	168,5	186,9	201,1	215,4	235,6	247,9	-0,431	-2,311	131241	1947
162949	2393	168183	0,944	1121,2	370,0	806,7	248,8	168,4	187,4	198,8	212,4	235,4	251,0	-1,021	-2,265	130055	1879

164172	2408	169363	0,945	1129,1	370,6	810,1	248,2	168,1	185,9	198,5	214,0	235,8	250,4	-0,967	-2,254	133085	1895
164756	2430	169190	0,944	1128,0	371,9	812,6	249,7	168,9	188,3	201,6	213,8	234,2	248,5	-0,873	-2,017	129684	1883
160460	2324	169019	0,938	1081,0	375,3	772,7	243,3	177,3	197,9	198,9	223,6	233,1	242,3	-4,659	-4,013	120430	1948
159916	2360	169599	0,940	1090,2	372,1	778,4	244,8	174,2	196,0	199,2	222,9	232,4	234,4	-4,002	-4,860	119448	1937
161711	2357	171443	0,940	1094,3	373,9	778,7	249,2	179,9	196,7	199,9	223,9	229,3	237,8	-4,431	-4,118	121351	1961
162273	2364	171888	0,941	1099,5	373,5	782,1	247,0	180,3	197,7	201,2	223,0	228,1	238,8	-4,693	-3,571	124592	1984
162256	2368	172743	0,940	1098,1	374,7	779,9	250,1	180,6	198,6	199,6	225,2	231,5	236,5	-4,149	-4,800	124062	2002
161280	2346	169704	0,939	1088,6	374,6	773,4	247,0	180,0	197,7	197,7	225,2	231,5	239,8	-5,045	-2,884	119911	1940
161587	2359	170475	0,939	1089,4	374,9	774,9	246,7	179,3	198,0	198,9	223,9	232,4	238,5	-4,398	-3,730	119991	1934

A73	A74	A75	A76	A77	A78	A79	A80	A81	A82	A83	A84	Distância
120394	0,887	795,8	367,2	570,9	246,9	145,0	176,8	212,1	234,8	249,1	253,6	
136678	0,903	884,1	379,2	624,0	263,1	158,4	198,8	228,5	246,1	254,7	249,7	0,7408
138274	0,901	884,4	384,2	628,8	274,1	154,3	194,7	225,8	247,9	259,9	259,9	0,7929
133735	0,898	861,8	379,6	614,1	263,2	152,6	191,7	221,4	246,6	255,2	252,4	0,7785
132237	0,902	865,9	373,8	613,0	257,5	153,0	191,9	221,7	246,1	253,9	249,7	0,6060
135431	0,907	887,5	373,9	627,7	256,9	152,8	193,2	222,9	244,2	254,1	247,0	0,6702
131690	0,904	867,6	371,3	613,8	251,2	153,7	192,1	221,3	242,6	251,2	244,8	0,6819
128387	0,878	805,5	386,1	572,3	298,1	153,4	192,4	225,7	237,3	249,3	276,2	1,1193
127457	0,879	802,1	382,3	570,3	292,3	149,9	188,1	220,7	232,9	242,1	266,2	1,1179
129364	0,878	811,4	387,7	576,5	301,0	149,0	190,9	224,3	237,2	254,2	279,7	1,1747
132892	0,880	825,2	391,4	586,0	303,8	151,2	194,2	227,3	241,9	258,9	284,5	1,1497
133732	0,879	822,0	392,7	585,8	306,0	152,9	193,4	225,3	241,6	261,0	286,0	1,1475
127999	0,879	805,4	383,9	573,0	296,3	148,6	188,9	222,9	234,1	247,5	273,7	1,1478
127737	0,878	803,0	384,5	572,3	296,3	149,3	190,4	222,9	235,5	248,9	273,7	1,0981

* Amostra de I100 classificada como I033

Legenda das colunas						
C - A	Classe - Amostra	A1	Área mão	A2	Perímetro mão	
A3	Excentricidade mão	A4	Maior eixo elipse mão	A5	Menor eixo elipse mão	
A6	Largura mão	A7	Área mínimo	A8	Perímetro mínimo	
A9	Área convexa mínimo	A10	Excentricidade mínimo	A11	Maior eixo elipse mínimo	
A12	Menor eixo elipse mínimo	A13	Comprimento mínimo	A14	Largura inferior mínimo	
A15	Largura 1 mínimo	A16	Largura 2 mínimo	A17	Largura 3 mínimo	
A18	Largura 4 mínimo	A19	Largura 5 mínimo	A20	Largura 6 mínimo	
A21	1° ângulo mínimo	A22	2° ângulo mínimo	A23	Área anelar	
A24	Perímetro anelar	A25	Área convexa anelar	A26	Excentricidade anelar	
A27	Maior eixo elipse anelar	A28	Menor eixo elipse anelar	A29	Comprimento anelar	
A30	Largura inferior anelar	A31	Largura 1 anelar	A32	Largura 2 anelar	
A33	Largura 3 anelar	A34	Largura 4 anelar	A35	Largura 5 anelar	
A36	Largura 6 anelar	A37	1° ângulo anelar	A38	2° ângulo anelar	
A39	Área dedo médio	A40	Perímetro dedo médio	A41	Área convexa dedo médio	
A42	Excentricidade dedo médio	A43	Maior eixo elipse dedo médio	A44	Menor eixo elipse dedo médio	
A45	Comprimento dedo médio	A46	Largura inferior dedo médio	A47	Largura 1 dedo médio	
A48	Largura 2 dedo médio	A49	Largura 3 dedo médio	A50	Largura 4 dedo médio	
A51	Largura 5 dedo médio	A52	Largura 6 dedo médio	A53	1° ângulo dedo médio	
A54	2° ângulo dedo médio	A55	Área indicador	A56	Perímetro indicador	
A57	Área convexa indicador	A58	Excentricidade indicador	A59	Maior eixo elipse indicador	
A60	Menor eixo elipse indicador	A61	Comprimento indicador	A62	Largura inferior indicador	
A63	Largura 1 indicador	A64	Largura 2 indicador	A65	Largura 3 indicador	
A66	Largura 4 indicador	A67	Largura 5 indicador	A68	Largura 6 indicador	
A69	1° ângulo indicador	A70	2° ângulo indicador	A71	Área polegar	
A72	Perímetro polegar	A73	Área convexa polegar	A74	Excentricidade polegar	
A75	Maior eixo elipse polegar	A76	Menor eixo elipse polegar	A77	Comprimento polegar	
A78	Largura inferior polegar	A79	Largura 1 polegar	A80	Largura 2 polegar	
A81	Largura 3 polegar	A82	Largura 4 polegar	A83	Largura 5 polegar	
A84	Largura 6 polegar					

Apêndice B - Taxas EER obtidas nos experimentos com *Firefly*

Na Tabela 15 são listadas as taxas EER obtidas em cada execução do caso 1 da abordagem 2. A coluna It indica a iteração e a coluna R indica a rodada de execução dentro da iteração. Por sua vez, na Tabela 16 são listadas as taxas obtidas no caso 2 da mesma abordagem.

Tabela 15. Taxas EER obtidas nas execuções do caso 1 da abordagem 2

It	R	%EER	It	R	%EER	It	R	%EER	It	R	%EER
1	1	0,49747	6	1	0,66667	11	1	1,29419	16	1	1,32576
1	2	0,49747	6	2	0,66540	11	2	0,99432	16	2	1,25379
1	3	0,49621	6	3	0,66540	11	3	0,99747	16	3	1,16604
1	4	0,49874	6	4	0,66667	11	4	1,13321	16	4	0,99684
1	5	0,49621	6	5	0,65909	11	5	1,16162	16	5	1,16162
1	6	0,50000	6	6	0,66604	11	6	1,16667	16	6	1,16414
1	7	0,49621	6	7	0,66477	11	7	0,99306	16	7	1,33270
1	8	0,49811	6	8	0,66098	11	8	1,28220	16	8	1,16351
1	9	0,49684	6	9	0,66667	11	9	0,99495	16	9	0,99684
1	10	0,49937	6	10	0,66162	11	10	0,99937	16	10	1,14646
2	1	0,66604	7	1	0,16667	12	1	0,49811	17	1	0,59470
2	2	0,66035	7	2	0,49684	12	2	0,49874	17	2	0,66225
2	3	0,66604	7	3	0,66225	12	3	0,50000	17	3	0,77715
2	4	0,66604	7	4	0,49747	12	4	0,49937	17	4	0,83081
2	5	0,66477	7	5	0,32891	12	5	0,49811	17	5	0,66225
2	6	0,66477	7	6	0,49684	12	6	0,50000	17	6	0,82197
2	7	0,66540	7	7	0,62626	12	7	0,59785	17	7	0,49432
2	8	0,81755	7	8	0,32323	12	8	0,49937	17	8	0,49495
2	9	0,66414	7	9	0,31439	12	9	0,49874	17	9	0,49747
2	10	0,66477	7	10	0,26768	12	10	0,49747	17	10	0,82891
3	1	1,16477	8	1	0,49684	13	1	0,99747	18	1	0,99306
3	2	1,00000	8	2	0,49747	13	2	0,99495	18	2	1,00000
3	3	0,99621	8	3	0,49937	13	3	1,00000	18	3	0,99369
3	4	0,99937	8	4	0,49684	13	4	0,99747	18	4	0,99747
3	5	1,00000	8	5	0,66540	13	5	0,99621	18	5	0,99495
3	6	1,16288	8	6	0,49621	13	6	0,99684	18	6	0,99369
3	7	1,16667	8	7	0,50000	13	7	0,99937	18	7	0,99495
3	8	1,10164	8	8	0,50000	13	8	0,99874	18	8	0,99495
3	9	1,16604	8	9	0,50000	13	9	0,99747	18	9	0,99747
3	10	0,99684	8	10	0,49874	13	10	0,99747	18	10	0,99116
4	1	0,75253	9	1	0,66351	14	1	0,99621	19	1	0,49811
4	2	0,49937	9	2	0,64773	14	2	0,99874	19	2	0,50000

4	3	0,66477	9	3	0,66604	14	3	0,99937	19	3	0,49621
4	4	0,66667	9	4	0,49874	14	4	0,99874	19	4	0,49747
4	5	0,76641	9	5	0,49621	14	5	0,99621	19	5	0,49558
4	6	0,99747	9	6	0,66477	14	6	1,00000	19	6	0,49811
4	7	0,82891	9	7	0,49874	14	7	1,16414	19	7	0,49811
4	8	0,74432	9	8	0,49937	14	8	0,99621	19	8	0,49811
4	9	0,78598	9	9	0,50000	14	9	0,99811	19	9	0,49684
4	10	0,66288	9	10	0,66414	14	10	1,07955	19	10	0,49937
5	1	0,50000	10	1	0,66667	15	1	0,99747	20	1	0,66604
5	2	0,49811	10	2	0,61932	15	2	1,00000	20	2	0,66540
5	3	0,50000	10	3	0,49937	15	3	1,16414	20	3	0,66225
5	4	0,49874	10	4	0,49495	15	4	1,16667	20	4	0,66098
5	5	0,49621	10	5	0,66351	15	5	1,16604	20	5	0,66540
5	6	0,49811	10	6	0,66667	15	6	1,16414	20	6	0,66667
5	7	0,49874	10	7	0,50000	15	7	1,16477	20	7	0,81124
5	8	0,49874	10	8	0,66098	15	8	1,14773	20	8	0,66477
5	9	0,49937	10	9	0,49874	15	9	1,16098	20	9	0,49874
5	10	0,49621	10	10	0,49621	15	10	1,10038	20	10	0,66477

Tabela 16. Taxas EER obtidas nas execuções do caso 2 da abordagem 2

Grupo Teste	Rodada	%EER	Grupo Teste	Rodada	%EER
Grupo A	1	0,85423	Grupo B	1	0,85506
Grupo A	2	1,04443	Grupo B	2	0,85423
Grupo A	3	0,95183	Grupo B	3	0,94933
Grupo A	4	0,94933	Grupo B	4	0,76079
Grupo A	5	0,85673	Grupo B	5	0,94683
Grupo A	6	1,03693	Grupo B	6	1,13869
Grupo A	7	0,85673	Grupo B	7	0,94433
Grupo A	8	1,04359	Grupo B	8	0,84923
Grupo A	9	0,95099	Grupo B	9	0,85673
Grupo A	10	0,56810	Grupo B	10	0,70915

Apêndice C - Pesos dos atributos aplicando o método *Firefly*

Na Tabela 17 são apresentadas informações sobre os pesos conferidos aos atributos pelo método de inteligência de enxame *Firefly* nos experimentos realizados. Para cada atributo são listados os valores mínimo e máximo, o valor médio, desvio padrão s e coeficiente de variação C_v com base nas 220 execuções realizadas. Os dados estão ordenados pelo valor médio dos pesos. Por sua vez, os valores possíveis para os pesos pertencem ao intervalo [0, 10].

Tabela 17. Atribuição de pesos aos atributos nos experimentos com *Firefly*

	Campo	Pesos				
		Mínimo	Máximo	Média	s	% C_v
1º	Largura 2 indicador	1,74487	10,00000	9,42839	0,89083	9,4
2º	Largura 2 dedo médio	1,83726	10,00000	9,38498	0,95177	10,1
3º	Largura 5 indicador	0,99894	10,00000	9,21851	1,17578	12,8
4º	Menor eixo elipse indicador	1,44396	10,00000	9,17321	1,38518	15,1
5º	Largura 4 indicador	1,68283	10,00000	9,05088	1,41008	15,6
6º	Largura 2 anelar	2,20344	10,00000	8,88021	1,42316	16,0
7º	Largura 4 dedo médio	0,97267	9,99983	8,75139	1,59642	18,2
8º	Largura 1 dedo médio	0,00246	10,00000	8,74519	1,78018	20,4
9º	Largura 5 anelar	0,06906	10,00000	8,33166	1,85126	22,2
10º	Menor eixo elipse anelar	1,40278	9,99741	7,82615	2,06992	26,4
11º	Largura 3 indicador	0,00274	9,99726	7,72351	2,42395	31,4
12º	Largura 4 mínimo	0,01728	9,99643	7,53326	2,35041	31,2
13º	Menor eixo elipse mínimo	0,00013	9,99681	7,30331	2,47777	33,9
14º	Largura 1 anelar	0,00191	9,99474	7,07786	2,47802	35,0
15º	Largura 3 anelar	0,00006	9,95206	6,44789	2,67102	41,4
16º	Área convexa indicador	0,00007	9,98235	6,18497	2,76895	44,8
17º	Largura 5 dedo médio	0,00000	9,96223	6,05993	3,00049	49,5
18º	Largura mão	0,00000	9,99991	5,47664	4,68693	85,6
19º	Menor eixo elipse dedo médio	0,00032	9,99287	5,39921	2,69655	49,9
20º	Largura 3 mínimo	0,00000	9,96895	4,80208	3,34793	69,7
21º	Área convexa mínimo	0,00000	9,75781	4,71943	2,88889	61,2
22º	Largura 2 mínimo	0,00000	9,78870	4,08626	3,03318	74,2
23º	Área indicador	0,00000	9,96045	4,07183	2,94606	72,4
24º	Comprimento indicador	0,00000	9,88719	4,06455	2,72575	67,1
25º	Área mínimo	0,00006	9,82979	3,65998	2,88135	78,7
26º	Comprimento anelar	0,00000	9,94381	3,52364	2,81339	79,8

27º	Área mão	0,00000	9,86382	3,22362	2,73566	84,9
28º	Largura 1 mínimo	0,00000	9,85685	3,08694	2,69623	87,3
29º	Comprimento mínimo	0,00000	9,73062	2,96234	2,87511	97,1
30º	Área convexa anelar	0,00013	9,63457	2,88407	2,63932	91,5
31º	Largura 6 indicador	0,00016	9,61019	2,86403	2,77687	97,0
32º	Maior eixo elipse indicador	0,00000	9,23130	2,81999	2,70419	95,9
33º	Área anelar	0,00000	9,37024	2,79547	2,49766	89,3
34º	Largura 4 anelar	0,00000	9,07996	2,39350	2,64027	110,3
35º	Maior eixo elipse anelar	0,00000	9,94678	2,27272	2,78126	122,4
36º	Área convexa dedo médio	0,00000	9,99029	1,99172	2,34686	117,8
37º	Largura 5 mínimo	0,00000	9,68168	1,93901	2,50625	129,3
38º	Largura 1 indicador	0,00000	10,00000	1,89143	2,59493	137,2
39º	Largura 5 polegar	0,00000	9,98509	1,66810	2,57223	154,2
40º	Comprimento dedo médio	0,00000	9,94501	1,52752	2,18383	143,0
41º	Largura 3 dedo médio	0,00000	8,99678	1,18723	1,80134	151,7
42º	Maior eixo elipse dedo médio	0,00000	9,98674	1,09263	2,11555	193,6
43º	Largura 4 polegar	0,00000	8,41299	1,00395	1,89047	188,3
44º	Área dedo médio	0,00000	9,84372	0,90116	1,98186	219,9
45º	Largura 6 dedo médio	0,00000	7,04695	0,54469	1,25323	230,1
46º	Maior eixo elipse mínimo	0,00000	6,83372	0,43242	0,98235	227,2
47º	Largura 3 polegar	0,00000	7,29991	0,42470	1,11500	262,5
48º	Menor eixo elipse polegar	0,00000	6,34925	0,35333	1,05454	298,5
49º	Perímetro mão	0,00000	9,50284	0,31572	1,36941	433,7
50º	Perímetro anelar	0,00000	6,48481	0,30970	0,76614	247,4
51º	Largura 6 anelar	0,00000	8,54298	0,30414	1,03155	339,2
52º	Excentricidade indicador	0,00000	8,48387	0,25529	1,22390	479,4
53º	Perímetro indicador	0,00000	4,98963	0,16952	0,53969	318,4
54º	Excentricidade anelar	0,00000	8,54028	0,12352	0,82655	669,2
55º	Maior eixo elipse mão	0,00000	6,81098	0,10935	0,69700	637,4
56º	Perímetro dedo médio	0,00000	3,50144	0,07350	0,32013	435,6
57º	Excentricidade dedo médio	0,00000	2,60682	0,05725	0,24854	434,1
58º	Área polegar	0,00000	1,37187	0,03084	0,14546	471,6
59º	Excentricidade mínimo	0,00000	4,05735	0,03062	0,28298	924,3
60º	Perímetro mínimo	0,00000	1,29522	0,01702	0,10666	626,6
61º	Largura 1 polegar	0,00000	0,60127	0,00441	0,04263	967,8
62º	Largura inferior dedo médio	0,00000	0,30786	0,00313	0,02444	780,4
63º	Área convexa polegar	0,00000	0,33762	0,00178	0,02275	1281,5
64º	Largura inferior indicador	0,00000	0,05859	0,00068	0,00512	747,4
65º	Largura 2 polegar	0,00000	0,07650	0,00052	0,00516	982,6
66º	Largura 6 mínimo	0,00000	0,03154	0,00037	0,00236	643,9
67º	Largura 6 polegar	0,00000	0,00125	0,00011	0,00019	169,7
68º	2º ângulo indicador	0,00000	0,00080	0,00011	0,00016	145,0
69º	Comprimento polegar	0,00000	0,00072	0,00009	0,00014	149,4
70º	Excentricidade polegar	0,00000	0,00108	0,00009	0,00016	181,4

71º	Maior eixo elipse polegar	0,00000	0,00061	0,00007	0,00012	158,1
72º	Menor eixo elipse mão	0,00000	0,00065	0,00007	0,00012	178,1
73º	2º ângulo dedo médio	0,00000	0,00057	0,00007	0,00012	177,7
74º	Perímetro polegar	0,00000	0,00062	0,00006	0,00011	166,2
75º	Largura inferior anelar	0,00000	0,00084	0,00006	0,00010	176,1
76º	2º ângulo mínimo	0,00000	0,00049	0,00005	0,00009	185,2
77º	1º ângulo indicador	0,00000	0,00064	0,00005	0,00009	176,2
78º	Largura inferior mínimo	0,00000	0,00068	0,00005	0,00011	241,6
79º	1º ângulo dedo médio	0,00000	0,00052	0,00005	0,00009	198,8
80º	1º ângulo mínimo	0,00000	0,00072	0,00004	0,00009	221,4
81º	2º ângulo anelar	0,00000	0,00039	0,00004	0,00007	188,6
82º	Largura inferior polegar	0,00000	0,00030	0,00004	0,00007	191,9
83º	1º ângulo anelar	0,00000	0,00050	0,00003	0,00007	211,2
84º	Excentricidade mão	0,00000	0,00030	0,00002	0,00006	234,9

Apêndice D - Artigo publicado

NASCIMENTO, M. V. P.; BATISTA, L. V.; CAVALCANTI JR, N. L. Comparative study of learning algorithms for recognition by hand geometry. **IEEE International Conference on Systems, Man, and Cybernetics**. San Diego, USA, 2014. 423 - 428.

Apêndice E - Artigo aceito

O artigo **A new approach to biometric recognition based on hand geometry**, foi aceito para publicação no **30th ACM/SIGAPP Symposium On Applied Computing (SAC2015)**, a ser realizado no período de 13 a 17 de abril de 2015, em Salamanca, Espanha.