

**DETECÇÃO DO MAL-POSICIONAMENTO ROTACIONAL DE
DEDOS EM DISPOSITIVOS DE CAPTURA DE IMPRESSÕES DIGITAIS
MULTIVISTA SEM TOQUE UTILIZANDO REDES NEURAS ARTIFICIAIS**

CAUÊ ZAGHETTO

**DISSERTAÇÃO DE MESTRADO EM SISTEMAS MECATRÔNICOS
DEPARTAMENTO DE ENGENHARIA MECÂNICA**

**FACULDADE DE TECNOLOGIA
UNIVERSIDADE DE BRASÍLIA**

UNIVERSIDADE DE BRASÍLIA
FACULDADE DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA MECÂNICA

DETECÇÃO DO MAL-POSICIONAMENTO ROTACIONAL DE
DEDOS EM DISPOSITIVOS DE CAPTURA DE IMPRESSÕES DIGITAIS
MULTIVISTA SEM TOQUE UTILIZANDO REDES NEURAIS ARTIFICIAIS

CAUÊ ZAGHETTO

ORIENTADOR: FLÁVIO DE BARROS VIDAL

DISSERTAÇÃO DE MESTRADO EM SISTEMAS MECATRÔNICOS

PUBLICAÇÃO ENM.DM – 96/16

Brasília 25 de Abril de 2016

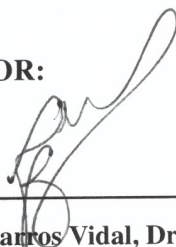
**UNIVERSIDADE DE BRASÍLIA
FACULDADE DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA MECÂNICA**

**DETECÇÃO DO MAL-POSICIONAMENTO ROTACIONAL DE
DEDOS EM DISPOSITIVOS DE CAPTURA DE IMPRESSÕES DIGITAIS
MULTIVISTA SEM TOQUE UTILIZANDO REDES NEURAS ARTIFICIAIS**

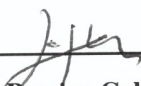
CAUÊ ZAGHETTO

**DISSERTAÇÃO DE MESTRADO ACADÊMICO SUBMETIDA AO DEPARTAMENTO
DE ENGENHARIA MECÂNICA DA FACULDADE DE TECNOLOGIA DA UNI-
VERSIDADE DE BRASÍLIA COMO PARTE DOS REQUISITOS NECESSÁRIOS
PARA A OBTENÇÃO DO GRAU DE MESTRE EM SISTEMAS MECATRÔNICOS.**

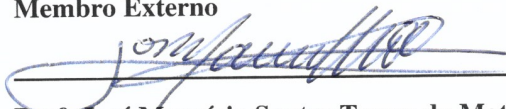
APROVADA POR:



**Prof. Flávio de Barros Vidal, Dr., CIC/UnB
(Orientador)**



**Prof. Luiz Pereira Calôba, Dr., COPPE/UFRJ
Membro Externo**



**Prof. José Maurício Santos Torres da Motta, Ph.D., ENM/UnB
Membro Interno**

**Guilherme Caribe de Carvalho, Ph.D., ENM/UnB
Suplente**

BRASÍLIA, 25 DE ABRIL DE 2016.

FICHA CATALOGRÁFICA

ZAGHETTO, CAUÊ

DETECÇÃO DO MAL-POSICIONAMENTO ROTACIONAL DE DEDOS EM DISPOSITIVOS DE CAPTURA DE IMPRESSÕES DIGITAIS MULTIVISTA SEM TOQUE UTILIZANDO REDES NEURAIAS ARTIFICIAIS [Distrito Federal] 2016.

xiv,74p., 210 x 297 mm (ENM/FT/UnB, Mestre, Sistemas Mecatrônicos, 2016).

Dissertação de Mestrado – Universidade de Brasília, Faculdade de Tecnologia.

Departamento de Engenharia Mecânica

1. Biometria

2. Impressões Digitais

3. Redes Neurais

4. Multivista

I. ENM/FT/UnB

II. Título (série)

REFERÊNCIA BIBLIOGRÁFICA

ZAGHETTO, C. (2016). DETECÇÃO DO MAL-POSICIONAMENTO ROTACIONAL DE DEDOS EM DISPOSITIVOS DE CAPTURA DE IMPRESSÕES DIGITAIS MULTIVISTA SEM TOQUE UTILIZANDO REDES NEURAIAS ARTIFICIAIS, Dissertação de Mestrado em Sistemas Mecatrônicos, Publicação ENM.DM-96/16, Departamento de Engenharia Mecânica, Universidade de Brasília, Brasília, DF, 74p.

CESSÃO DE DIREITOS

AUTOR: Cauê Zaghetto

TÍTULO: DETECÇÃO DO MAL-POSICIONAMENTO ROTACIONAL DE DEDOS EM DISPOSITIVOS DE CAPTURA DE IMPRESSÕES DIGITAIS MULTIVISTA SEM TOQUE UTILIZANDO REDES NEURAIAS ARTIFICIAIS.

GRAU: Mestre

ANO: 2016

É concedida à Universidade de Brasília permissão para reproduzir cópias desta dissertação de mestrado e para emprestar ou vender tais cópias somente para propósitos acadêmicos e científicos. O autor reserva outros direitos de publicação e nenhuma parte dessa dissertação de mestrado pode ser reproduzida sem autorização por escrito do autor.

Cauê Zaghetto

Departamento de Eng. Mecânica (ENM) - FT

Universidade de Brasília (UnB)

Campus Darcy Ribeiro

CEP 70919-970 - Brasília - DF - Brasil

*Ao meu avô Maciste Zagheto. Tudo
começou ali!*

*"What's the point of singing songs if
they'll never even hear you?"*

Sufjan Stevens

AGRADECIMENTOS

*Aos meus pais **Elvira Aparecida Beltramini Zagheto** e **Sidney Zagheto**, que me apresentaram a vida, a maneira de viver e o significado real da palavra amor.*

*Ao meu irmão **Alexandre Zagheto**, que me mostrou que a fragilidade da alma pode ser a força da amizade. Seus caminhos inspiraram o meu caminho e amá-lo me fez e faz melhor.*

*À minha irmã **Letícia Zagheto**, que me apresentou uma maneira de voar sem ter asas. Se eu pudesse voltar no tempo não teria dito aquelas palavras, mas como não posso fazê-lo, peço agora, mais uma vez, perdão.*

*À minha esposa **Daniele Nóbrega Teixeira Arrais Zagheto**, pedaço entrelaçado da minha alma, que me mostrou que não importa o caminho, mas quem está caminhando conosco.*

*À minha filha **Kiara**, "clara" luz da minha vida. Ainda tão pequenina, mas tão grande dentro de mim.*

*À minha cunhada **Sônia Regina Ferreira Zagheto**, que me recebeu e hoje se tornou uma amiga, além, é claro de tomar conta do "Xandin". Se o Lula merece um trono na África, você merece um no céu.*

*Ao meu cunhado **Yuri Nóbrega Teixeira Arrais**, alma única e preciosa que o universo me apresentou. Se eu tivesse um filho, gostaria que ele fosse uma cópia sua. Na verdade, tomo a liberdade de já me sentir realizado.*

*Ao professor **Flávio de Barros Vidal**, que me aceitou, orientou e respeitou, mostrando que há caminho para realizar boa pesquisa sem soberba. Sua dedicação aos alunos impressiona e contagia.*

*Ao professor **Ricardo Lopes de Queiroz**, que abriu para mim a primeira porta para uma árvore de possibilidade.*

*Ao professor **Claudio Maia Porto**, que foi exemplo de mestre. Sem dúvida, foi o melhor professor que tive.*

*Aos meus amigos **Leonardo Valim Craveira**, **Andreu Wilson Pereira Leandro**, **Márcio Gonçalves Nunes**, **Bruno Jannibelli**, **Diego Rocha Granado**, **André Luiz Gonçalves**, **Renata Grehs**, **Alessandro Viana**, **Tiago Nascimento de Carvalho**, **Rodrigo Carvalhal de Carvalho**, **Luiz Henrique Morais Aguiar**, **Rosa Maria Diekn de Queiroz**.*

Por fim, ao povo brasileiro, que cedeu à mim a Universidade de Brasília para que pudesse realizar meus estudos e meu sonho. Prometo retribuir.

RESUMO

DETECÇÃO DO MAL-POSICIONAMENTO ROTACIONAL DE DEDOS EM DISPOSITIVOS DE CAPTURA DE IMPRESSÕES DIGITAIS MULTIVISTA SEM TOQUE UTILIZANDO REDES NEURAS ARTIFICIAIS

Autor: Cauê Zagheto

Orientador: Prof. Flávio de Barros Vidal, Dr., CIC/UnB

Programa de Pós-graduação em Sistemas Mecatrônicos

Brasília, Abril de 2016

Este trabalho apresenta um método baseado em Redes Neurais Artificiais que avalia o mal-posicionamento dos dedos devido à rotação em dispositivos de aquisição de impressões digitais multivista sem toque. O objetivo é determinar se o dedo está rotacionado ou não, uma vez que o adequado posicionamento do dedo é mandatório para garantir altas taxas de correspondência entre impressões digitais. Um conjunto de teste de 9000 imagens adquiridas foi utilizado para treinar, validar e testar um conjunto de classificadores baseados em redes neurais artificiais multicamadas. Até o momento, não existe um método definitivo que abordou o problema da qualidade de impressões digitais em dispositivos de captura que utilizem a tecnologia multivista sem toque, e a detecção da rotação de dedos apresentada neste trabalho é um dos passos que devem ser levados em conta se um futuro método automático para avaliação da qualidade de impressões digitais for considerado. Os resultados médios, mostram que: o classificador identifica corretamente o mal-posicionamento em aproximadamente 98,50% dos casos; e quando o mal-posicionamento é detectado, o ângulo de rotação é corretamente estimado em 95,25% dos casos.

ABSTRACT

ROTATIONAL BAD-POSITIONING DETECTION OF FINGERS ON TOUCHLESS MULTIVIEW FINGERPRINT DEVICES USING ARTIFICIAL NEURAL NETWORKS

Author: Cauê Zaghetto

Supervisor: Prof. Flávio de Barros Vidal, Dr., CIC/UnB

Programa de Pós-graduação em Sistemas Mecatrônicos

This work presents a method based on Artificial Neural Network that evaluates the rotational bad-positioning of fingers on touchless multiview fingerprinting devices. The objective is to determine whether the finger is rotated or not, since a proper positioning of the finger is mandatory for high fingerprint matching rates. A test set of 9000 acquired images has been used to train, validate and test a set of multilayer Artificial Neural Network classifiers. To our knowledge, there is no definitive method that addressed the problem of fingerprint quality on touchless multiview scanners. The proposed finger rotation detection here presented is one of the steps that must be taken into account if a future automatic image quality assessment method is to be considered. Average results show that: our classifier correctly identifies bad-positioning in approximately 98.50% of cases; and if bad-positioning is detected, the rotation angle is correctly estimated in 95.25% evaluations.

SUMÁRIO

1	INTRODUÇÃO	1
1.1	OBJETIVO	2
1.1.1	OBJETIVOS ESPECÍFICOS	2
1.2	ORGANIZAÇÃO DA DISSERTAÇÃO	2
2	BIOMETRIA	3
2.1	TIPOS DE BIOMETRIA	4
2.2	DESEMPENHO DE UM SISTEMA BIOMÉTRICO	8
2.3	AS IMPRESSÕES DIGITAIS	9
2.3.1	BREVE CONTEXTUALIZAÇÃO HISTÓRICA	9
2.3.2	FISIOLOGIA DAS CRISTAS PAPILARES	10
2.4	IDENTIFICAÇÃO DE IMPRESSÕES DIGITAIS	13
2.5	IMPRESSÕES DIGITAIS COM TOQUE	14
2.6	IMPRESSÕES DIGITAIS SEM TOQUE	15
2.6.1	IMPRESSÕES DIGITAIS MULTIVISTA SEM TOQUE	15
2.7	AVALIAÇÃO DA QUALIDADE DE IMPRESSÕES DIGITAIS	16
2.7.1	O PROBLEMA DA PRESSÃO	16
2.7.2	O PROBLEMA DO POSICIONAMENTO	18
3	REDES NEURAIS ARTIFICIAIS	20
3.1	BREVE HISTÓRICO DA EVOLUÇÃO DAS RNAs	20
3.2	INTRODUÇÃO ÀS REDES NEURAIS ARTIFICIAS	21
3.3	REDES NEURAIS <i>feedforward</i> MULTICAMADAS	25
3.4	ALGORITMO DE TREINAMENTO BACKPROPAGATION	26
3.5	ORGANIZAÇÃO DOS SINAIS DE ENTRADA	30
4	METODOLOGIA PROPOSTA	34
4.1	DEFINIÇÃO DO MAL-POSICIONAMENTO	34
4.2	CONSTRUÇÃO DA BASE DE DADOS	36
4.3	PRÉ-PROCESSAMENTO	37
4.4	EXTRAÇÃO DE CARACTERÍSTICAS DISCRIMINANTES	41
4.5	DETALHES SOBRE O PROJETO E A IMPLEMENTAÇÃO DA RNA	42
4.5.1	ARQUITETURA DOS CLASSIFICADORES - CONJUNTO COMUM	43
4.5.2	ARQUITETURA DOS CLASSIFICADORES - CONJUNTO ESPECIAL	47
4.6	MÉTRICAS UTILIZADAS NA ANÁLISE E GERAÇÃO DE RESULTADOS	50
5	RESULTADOS	53

5.1	VISÃO GERAL E ESTRUTURA DA APRESENTAÇÃO DOS RESULTADOS	53
5.2	RESULTADOS DA DETECÇÃO DE ROTAÇÃO DE INDICADORES	54
5.2.1	ROTACIONADO OU NÃO-ROTACIONADO	54
5.2.2	ESTIMAÇÃO DO ÂNGULO.....	54
5.3	RESULTADOS DA DETECÇÃO DE ROTAÇÃO DE MÉDIOS	55
5.3.1	ROTACIONADO OU NÃO-ROTACIONADO	55
5.3.2	ESTIMAÇÃO DO ÂNGULO.....	55
5.4	RESULTADOS DA DETECÇÃO DE ROTAÇÃO DE ANELARES	56
5.4.1	ROTACIONADO OU NÃO-ROTACIONADO	56
5.4.2	ESTIMAÇÃO DO ÂNGULO.....	56
5.5	RESULTADOS DA DETECÇÃO DE ROTAÇÃO DE MÍNIMOS	57
5.5.1	ROTACIONADO OU NÃO-ROTACIONADO	57
5.5.2	ESTIMAÇÃO DO ÂNGULO.....	57
5.6	RESULTADOS DA DETECÇÃO DE ROTAÇÃO DE POLEGARES	58
5.6.1	ROTACIONADO OU NÃO-ROTACIONADO	58
5.6.2	ESTIMAÇÃO DO ÂNGULO.....	59
5.7	RESULTADOS DA DETECÇÃO DE ROTAÇÃO GERAL	60
5.7.1	ROTACIONADO OU NÃO-ROTACIONADO	60
5.7.2	ESTIMAÇÃO DO ÂNGULO.....	61
5.8	DISCUSSÃO DOS RESULTADOS E ANÁLISE COMPARATIVA.....	62
6	CONCLUSÕES E TRABALHOS FUTUROS	67
	REFERÊNCIAS BIBLIOGRÁFICAS.....	69

LISTA DE FIGURAS

1.1	Descrição de um sistema de captura para impressão digital multivista sem toque, utilizando três câmeras (uma central e duas laterais) para captura da área central e lateral da impressão digital.....	1
2.1	Tipos de sistemas biométricos. Figura adaptada de [9].	3
2.2	Classificação dos sistemas biométricos no que tange a sua natureza fisiológica ou comportamental.....	7
2.3	Figura que apresenta cristas e sulcos de uma impressão digital: (a) imagem fotográfica original de uma impressão digital; (b) Resultado da binarização da imagem original; (c) ampliação da imagem original; e (d) ampliação da imagem binarizada. Cristas e vales podem ser observadas com facilidade em (c) e (d).....	11
2.4	Regiões características (quadrados brancos) em impressões digitais.	11
2.5	Um exemplo de cada tipo de impressão digital mais frequente. Figura adaptada do livro <i>Handbook of Fingerprint Recognition</i> [38].	12
2.6	Figura que apresenta minúcias (pontos vermelhos) em uma impressão digital comum.	13
2.7	Exemplo de impressões digitais capturadas (1024×1280 pixels, 8 bits/pixels) por um sistema sem toque com três câmeras: (a) Vista 0; (b) Vista 1; e (c) Vista 2.	15
2.8	Esquema de funcionamento de um sensor FTIR (<i>Frustrated Total Internal Reflection</i>). Esse tipo de sensor é o mais utilizado e tradicional disponível no mercado [38]. É possível notar que os raios de luz oriundos de uma fonte luminosa atravessam o prisma de vidro até atingirem a superfície de contato do dedo com o prisma. Ao atingirem a superfície, os raios de luz refletem em cristas ou vales gerando padronagem distinta (claro ou escuro). Posteriormente passam por uma lente convergente para que todos os raios refletidos atinjam o sensor.	17
2.9	Figura que apresenta problemas tradicionais de mal-posicionamento de dedos em dispositivos com toque.	18

3.1	Representação de uma célula nervosa chamada neurônio, adaptada de [52]. Nesta figura é possível verificar a presença do corpo celular, ou soma, que contém o núcleo da célula bem como a presença de axônios, que são prolongações fibrosas desses núcleos e dendritos que são várias ramificações oriundas do corpo. Um axônio têm comprimento médio de 1 cm a 1 metro e um neurônio conecta-se com outros neurônios (de 10 a 100000) através de conexões chamadas sinapses. Os sinais são propagados de neurônio a neurônio através uma reação eletroquímica. Esse mecanismo é a base do processo de aprendizagem e pensamento vinculado ao cérebro.	21
3.2	Modelo matemático de um neurônio. Independentemente das entradas, a saída normalizada é normalmente apresentada como um número real no intervalo $[0,1]$ ou $[-1,1]$, dependendo da função de ativação.	22
3.3	Quatro tipos clássicos de funções de ativação: (a) <i>threshold</i> , (b) <i>piecewise linear</i> , (c) <i>sigmoid</i> e (d) <i>gaussiana</i>	23
3.4	Representação gráfica da função tangente hiperbólica $\varphi(v) = \tanh(v)$. Apesar dos limites de escala é possível notar que v pertence ao intervalo $]-\infty, +\infty[$ e $\tanh(v)$ pertence ao intervalo $[-1, 1]$	24
3.5	Taxonomia das arquiteturas de redes neurais artificiais inspirada em [53] e [17].	24
3.6	Representação de uma rede neural <i>single-layer</i> . Os círculos de cor cinza apresentados na figura são representações de um neurônio.	25
3.7	Cubo cujos vértices representam as quatro possíveis combinações de 2 bits na forma (x_1, x_2) . Considerando a operação lógica XOR, os pares ordenados inscritos dentro das elipses azuis representam saídas de valor lógico 1 e os inscritos dentro das elipses verdes representam saídas de valor lógico 0.	26
3.8	Exemplo de arquitetura de um <i>perceptron</i> multicamadas. A rede neural apresentada possui uma camada de entrada com 6 sinais, uma primeira camada escondida com n neurônios, uma segunda camada escondida com m neurônios e uma camada de saída com 2 neurônios. Na ilustração os <i>bias</i> foram omitidos com intuito de simplificar a ilustração.	27
3.9	MLP com uma camada de entrada, uma camada escondida e uma camada de saída.	28
3.10	Matriz que apresenta o padrão de entradas esperado por uma RNA com aprendizagem supervisionada.	31

3.11	Exemplo de base de dados para treinamento supervisionado de uma RNA. Na figura é possível notar que a base dados contém 5 amostras, cada amostra com três características discriminativas. As características são utilizadas para montar um vetor de características que é a entrada para a Rede Neural. Destaca-se que o <i>target</i> (classe) de cada amostra não é utilizado para montar o vetor de características, mas apenas para mensurar o quanto a saída da rede é diferente do esperado e calcular o erro. Posteriormente o algoritmo de treinamento <i>backpropagation</i> irá propagar o erro em sentido à entrada da rede reajustando as sinapses de cada neurônio.	31
3.12	Matriz que apresenta um exemplo de base de dados com nove amostras. As amostras apresentam quatro características discriminativas e podem ser classificadas em três classes distintas representadas pelos números -1,0; 0,0; e 1,0.	32
3.13	Os conjuntos de treinamento (a), validação (b) e teste (c) foram organizados intercalando as amostras da base de dados a fim de garantir uma distribuição balanceada.	32
3.14	Conjunto de treinamento (a), conjunto de validação (b) e conjunto de teste (c) normalizados. É possível perceber que todas as amostras possuem amplitude 2. Isso garante a normalização das características (<i>features</i>).	33
4.1	Distribuição das câmeras em um sistema de captura para impressão digital multivista sem toque. Três câmeras (uma central e duas laterais) são utilizadas para captura da área central e lateral da impressão digital.	35
4.2	Ilustração do problema do mal-posicionamento: (a) posição do dedo (cilindro) relativa ao dispositivo de captura (cubo); (b) descritores de movimento (orientação, inclinação, rotação, inserção, translação horizontal e translação vertical) que indicam as formas como o dedo pode estar mal posicionado. Neste trabalho, apenas as distorções devido à orientação e à rotação são levadas em conta.	36
4.3	Identificação dos dedos e possíveis direções de rotações.	36
4.4	Efeito de diferentes ângulos de rotação na Vista 0: (a) não-rotacionado; (b) 90° SH; (c) 90° SAH; e (d) rotacionado em 180°.	37
4.5	Exemplos de imagens não ideais em relação à vista 0: (a) imagem que apresenta um dedo com problema de orientação para baixo; (b) imagem que apresenta um dedo com problema de orientação para cima.	37
4.6	Exemplo simples de rotação de uma imagem em 90° sentido horário e anti-horário. As matrizes representam um exemplo de transformação que resulta na rotação da imagem.	38

4.7	Etapas da correção da orientação inadequada: (a) imagem original do dedo que visivelmente apresenta problema de orientação; (b) imagem binarizada utilizando o método de <i>Otsu</i> ; e (c) resultado após realizada a erosão na imagem binarizada.	39
4.8	Exemplo de resultado da correção da orientação inadequada dos dedos: (a) imagem que apresenta um reta vermelha, obtida a partir da regressão linear; (b) máscara binarizada gerada após a correção; e (c) imagem final obtida após a imagem original ser rotacionada em um ângulo θ	40
4.9	Recuperação da região de interesse (Vista 0): (a) Imagem original; (b) Resultado da binarização; (c) Seleção da Máscara; e (d) área selecionada para o cálculo da média e variância. O mesmo procedimento é aplicado para as vistas 1 e 2.	41
4.10	Dedo projetado em diferentes vistas de uma amostra: (a) Projeção da Vista 0; (b) Projeção da Vista 1; e (c) Projeção da Vista 2. Razões entre as larguras das Vistas 1 e 2 em relação à Vista 0 também podem ser usadas como um parâmetro discriminativo no vetor de características.	42
4.11	Arquitetura proposta para as redes neurais artificiais utilizadas: camada de entrada com 6 neurônios; primeira camada oculta com n neurônios; segunda camada oculta com 15 neurônios; e camada de saída com 2 neurônios (a) ou 4 neurônios (b). Todos os neurônios possuem como função de ativação a tangente hiperbólica.	44
4.12	Arquitetura 3 - Arquitetura proposta para a rede neural artificial utilizada: camada de entrada com 6 neurônios, de x_1 a x_6 ; primeira camada oculta com 20 neurônios; segunda camada oculta com 5 neurônios; e camada de saída com 1 neurônio. Todos os neurônios possuem como função de ativação a tangente hiperbólica.	47
5.1	Gráfico que apresenta as detecções corretas realizadas pelos classificadores propostos para detectar a rotação de dedos. Os verdadeiros positivos são detecções corretas de dedos rotacionados e verdadeiros negativos são detecções corretas de dedos não rotacionados.	65
5.2	Gráfico que apresenta as detecções corretas realizadas por todos os classificadores propostos para detectar os ângulos de rotação dos dedos.	65

LISTA DE TABELAS

2.1	As taxas de erro (FAR e FRR) referentes a quatro sistemas biométricos são apresentadas. Testes foram realizados utilizando bases de dados públicas e diversas condições de operação.	9
4.1	Sumarização das arquiteturas do Cenário 1 apresentando a quantidade de neurônios em cada camada da RNA	46
4.2	Sumarização das arquiteturas do Cenário 2 apresentando a quantidade de neurônios em cada camada da RNA	46
4.3	Sumarização das arquiteturas do Cenário 1 apresentando a quantidade de neurônios em cada camada da RNA	49
4.4	Sumarização das arquiteturas do Cenário 2 apresentando a quantidade de neurônios em cada camada da RNA	49
4.5	Sumarização das arquiteturas do Cenário 1 e 2 apresentando a quantidade de neurônios em cada camada da RNA	49
4.6	Matriz de confusão genérica	50
4.7	Matriz de confusão para duas classes.....	51
4.8	Matriz de confusão com erro total associado	51
5.1	Matriz de confusão rotacionado X não-rotacionado: indicadores.....	54
5.2	Métricas calculadas: indicadores	54
5.3	Matriz de confusão de quatro classes: indicadores	54
5.4	Matriz de confusão rotacionado X não-rotacionado: médios	55
5.5	Métricas calculadas: médios.....	55
5.6	Matriz de confusão de quatro classes: médios	55
5.7	Matriz de confusão rotacionado X não-rotacionado: anelares	56
5.8	Métricas calculadas: anelares.....	56
5.9	Matriz de confusão de quatro classes: anelares	56
5.10	Matriz de confusão rotacionado X não-rotacionado: mínimos	57
5.11	Métricas calculadas: mínimos	57
5.12	Matriz de confusão de quatro classes: mínimos	57
5.13	Matriz de confusão rotacionado X não-rotacionado: polegares	58
5.14	Métricas calculadas: polegares.....	58
5.15	Matriz de confusão rotacionado X não-rotacionado: polegares*.....	58
5.16	Métricas calculadas: polegares*	58
5.17	Matriz de confusão de quatro classes: polegares	59
5.18	Matriz de confusão de quatro classes: polegares*	59
5.19	Matriz de confusão rotacionado X não-rotacionado: geral	60

5.20	Métricas calculadas: geral.....	60
5.21	Matriz de confusão rotacionado X não-rotacionado: geral*.....	60
5.22	Métricas calculadas: geral*	60
5.23	Matriz de confusão de quatro classes: geral	61
5.24	Matriz de confusão de quatro classes: geral*	61
5.25	Tabela comparativa de todos os classificadores propostos: rotacionado X não-rotacionado.....	62
5.26	Tabela comparativa de todos os classificadores propostos: quatro classes	64

LISTA DE SÍMBOLOS

<i>ROI</i>	<i>Region of Interest</i> (Região de Interesse)
<i>RNA</i>	Rede Neural Artificial
<i>NIST</i>	<i>National Institute of Standards and Technology</i>
<i>AFIS</i>	<i>Automated Fingerprint Identification System</i>
<i>EEG</i>	Eletronecefalograma
<i>FAR</i>	<i>False Accept Rate</i>
<i>FRR</i>	<i>False Reject Rate</i>
<i>GAR</i>	<i>Genuine Accept Rate</i>
<i>GRR</i>	<i>Genuine Reject Rate</i>
<i>DPI</i>	<i>Dots Per Inch</i>
<i>CCD</i>	<i>Charge Coupled Device</i>
<i>CMOS</i>	<i>Complementary Metal Oxide Semiconductor</i>
<i>FTIR</i>	<i>Frustrated Total Internal Reflection</i>
<i>FBI</i>	<i>Federal Bureau of Investigation</i>
<i>SH</i>	Sentido Horário
<i>SAH</i>	Sentido Anti-Horário
T_p	<i>True positive</i> (Verdadeiros Positivos)
T_n	<i>True negative</i> (Verdadeiros Negativos)
F_p	<i>False positive</i> (Falsos Positivos)
F_n	<i>False negative</i> (Falsos Negativos)
<i>prel</i>	<i>Positive Reliability</i> (Confiabilidade Positiva)
<i>nrel</i>	<i>Negative Reliability</i> (Confiabilidade Negativa)
<i>sup</i>	<i>Support</i> (Suporte)
<i>sens</i>	<i>Sensitivity</i> (Sensitividade)
<i>spec</i>	<i>Specificity</i> (Especificidade)
<i>tacc</i>	<i>Total accuracy</i> (Precisão Total)
<i>cov</i>	<i>Coverage</i> (Cobertura)
<i>F-measure</i>	Média Harmônica da Confiabilidade Positiva e Sensibilidade
<i>pixel</i>	<i>Picture Element</i>
P_{b_i}	Um Pixel Branco
<i>RNA</i>	Rede Neural Artificial
<i>RNAs</i>	Redes Neurais Artificiais
<i>ANN</i>	<i>Artificial Neural Network</i>
<i>ANNs</i>	<i>Artificial Neural Networks</i>
<i>MLP</i>	<i>Multilayer Perceptron</i> (Perceptron Multicamadas)
w_{ki}	Peso Sináptico vinculado à entrada i de um neurônio k

x_i	Entrada i de um neurônio k
b_k	<i>bias</i> do k -ésimo neurônio de uma RNA
u_k	Soma Ponderada sem adição do <i>bias</i>
v_k	Soma Ponderada com adição do <i>bias</i>
y_k	Saída da função de ativação do neurônio
$\varphi()$	Função de ativação do neurônio
u_j	Campo Local Induzido para cada neurônio j
m	m -ésima iteração do sinal de entrada
$w_{ij}(m)$	Sinapse do neurônio i para o neurônio j da na m -ésima iteração
$R1$	Número de elementos do vetor de entradas
$R2$	Número de neurônios da camada oculta
$R3$	Número de neurônios da camada de saída
f_i	Função de Ativação do neurônio j
t_k	Resultado Esperado também chamado de <i>target</i> no neurônio k
e_k	Erro na saída - Diferença entre o sina esperado e o sinal obtido
δ_k	Gradientes Locais para cada neurônio da camada de saída
δ_j	Gradientes Locais para cada neurônio da camada de oculta
$f'(*)$	Diferenciação da função de ativação em relação ao argumento
η	Taxa de Aprendizagem

1 INTRODUÇÃO

A autenticação biométrica, ou simplesmente biometria, pode ser definida como o reconhecimento automático de um indivíduo com base nas características fisiológicas e comportamentais [1]. Impressão digital, geometria da mão, voz, íris, face, escrita à mão e forma/tempo de digitação no teclado são exemplos de tais características. Diferentes sistemas biométricos requerem tecnologias específicas, dependendo do aspecto fisiológico (ou comportamental) que está sendo usado [2]. No entanto, a biometria baseada em impressão digital é hoje o sistema mais usado e reconhecido pela indústria e academia. Uma grande parte de suas aplicações está associada à identificação civil e investigação criminal. Praticamente, todos os departamentos policiais [3] possuem um Sistema Automático de Identificação de Impressões Digitais (AFIS) - *Automated Fingerprint Identification System* - [4]. Apesar de sua maturidade e ampla divulgação, acredita-se que os algoritmos de aquisição de impressão digital, processamento de imagens e de casamento (*matching*) não estão no seu potencial pleno e definitivo [5]. Dessa forma, uma análise mais cuidadosa mostra que há muito espaço para melhorias, não só para aprimorar o estado da arte dos algoritmos e processamento, mas também para mostrar novas e melhores maneiras de se adquirir a biometria. Neste sentido, destaca-se uma nova tecnologia, a de aquisição de impressões digitais multivista sem toque, ilustrada na Figura 1.1. Esta resolve muitos problemas de *scanners* baseados em toque, mas é suscetível a novos.




Figura 1.1: Descrição de um sistema de captura para impressão digital multivista sem toque, utilizando três câmeras (uma central e duas laterais) para captura da área central e lateral da impressão digital.

O problema mais fundamental desta tecnologia reside no fato de que é preciso garantir o correto posicionamento do dedo em relação às câmeras de aquisição. Este problema surge a partir do fato de que no processo de aquisição, utilizando um dispositivo sem uma superfície

de toque, os dedos estão sujeitos a mais graus de liberdade. Até onde se sabe, não existe um método definitivo que aborda o problema da qualidade da impressão digital para *scanners* multivistas sem toque. Portanto, neste trabalho é apresentado um algoritmo que indica se o dedo foi colocado corretamente ou não, devido à possibilidade de mal-posicionamento rotacional do mesmo. Além da detecção, uma estimação do ângulo de rotação também é realizada. Destaca-se que este é o primeiro passo para a definição de um método de avaliação de qualidade mais completo [6, 7], que pode orientar o processo de aquisição de impressões digitais sem toque no futuro.

1.1 OBJETIVO

Apresentar um sistema capaz de detectar de forma eficiente o mal-posicionamento rotacional de dedos em dispositivos de captura de impressões digitais sem toque utilizando um classificador baseado em redes neurais artificiais.

1.1.1 Objetivos Específicos

Com intuito de apresentar um classificador eficiente capaz detectar a rotação dos dedos, alguns objetivos específicos foram definidos:

- Construir uma base de dados de imagens para treinar, validar e testar o classificador proposto;
- Implementar um algoritmo capaz de segmentar adequadamente as imagens adquiridas a fim de extrair os parâmetros necessários para treinar o classificador proposto;
- Projetar uma rede neural capaz de detectar a rotação dos dedos e, quando detectada, estimar o ângulo de rotação;
- Gerar resultados que possam validar o método proposto.

1.2 ORGANIZAÇÃO DA DISSERTAÇÃO

O referencial teórico necessário para a compreensão deste trabalho pode ser encontrado nos Capítulos 2 e 3 que apresentam um estudo sobre Biometria e Redes Neurais Artificiais, respectivamente. A metodologia proposta para se alcançar os resultados é apresentada no Capítulo 4. Os resultados são apresentados e discutidos no Capítulo 5. Por fim, as conclusões e os trabalhos futuros são discutidos no Capítulo 6.

2 BIOMETRIA

O reconhecimento de indivíduos baseados nas suas características fisiológicas ou comportamentais é o foco da área do conhecimento chamada biometria [8]. A biometria, ou sistema biométrico, abrange tanto sistemas clássicos como impressões digitais obtidas utilizando um dedo banhado em tinta, como sistemas mais modernos como reconhecimento automático de faces, voz, escrita, digitação, gestos, íris, veias e outros (Figura 2.1) . Com o avanço da tecnologia (sensores, algoritmos e sistemas) e dos computadores, formas cada vez mais robustas, eficientes e rápidas de se fazer biometria vêm surgindo.

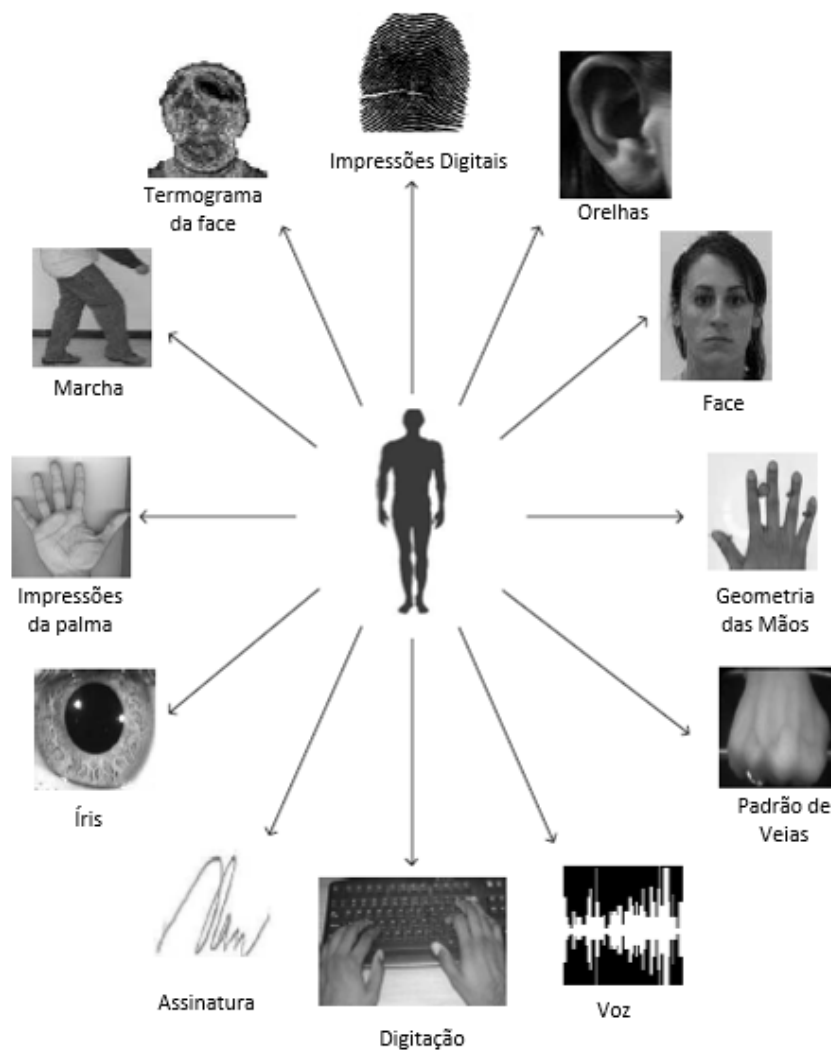


Figura 2.1: Tipos de sistemas biométricos. Figura adaptada de [9].

Apesar de haverem muitos sistemas modernos se candidatando a receber o título de sistema biométrico, é preciso observar que uma alta taxa de correspondência não é suficiente para que sejam caracterizados como tal. Em verdade, sete fatores [9] devem ser levados em consideração, são eles:

1. **Universalidade** - Devem haver traços biométricos comuns a todos os indivíduos;
2. **Singularidade** - Um dado traço biométrico deve ser suficientemente diferente entre indivíduos, possibilitando a distinção;
3. **Permanência** - O traço biométrico utilizado deve ser suficientemente invariante ao tempo. Um traço que sofre alteração considerável em função do tempo não tem valor biométrico considerável;
4. **Mensurabilidade** - Deve ser possível adquirir o traço biométrico de maneira conveniente utilizando equipamentos adequados. Além disso, a informação bruta, sem nenhum pré-processamento, deve estar disponível para análise e extração de um conjunto de características representativas;
5. **Desempenho** - É o nível de acurácia de um sistema biométrico. Os recursos necessários para garantir essa acurácia devem condizer com a aplicação a que se destina;
6. **Aceitabilidade** - Os indivíduos aos quais o sistema será aplicado devem estar dispostos a fornecer seus traços biométricos ao sistema;
7. **Evasibilidade**¹ - Esse fator faz referência a quão fácil é enganar o sistema utilizando artefatos forjados (e.g., dedos falsos) em caso de traços materiais/físicos ou imitar comportamento (e.g., mimetismo) em caso traços comportamentais.

Apesar de idealmente a definição de biometria impor os sete fatores supracitados como condição para que um sistema seja considerado biométrico, na prática não existe algum que atenda perfeitamente todas essas condições [9]. No entanto, destaca-se que existem diversos sistemas biométricos admissíveis para determinadas aplicações e demandas.

2.1 TIPOS DE BIOMETRIA

Em função das necessidades reais de cada aplicação prática, sistemas biométricos distintos podem ser empregados/propostos. Cada sistema apresenta prós e contras e adéqua-se a determinado grau de exigência no que tange aos sete fatores biométricos (citados na Seção anterior). Dentre os diversos tipos de biometria existentes, destacam-se algumas principais, cujas características são apresentadas a seguir:

1. **Impressões Digitais** - As impressões digitais ou impressões dactilares ou ainda impressões papilares vêm sendo utilizadas como tentativa de identificar/reconhecer indivíduos há décadas [10, 11]. São reconhecidas pela sua alta taxa de correspondência [12, 13] e pelo baixo custo de sensores (menos que U\$ 50,00 para maioria dos

¹Tradução da palavra *circumvention* do inglês. É empregada para indicar o quão evasivo (não categórico, dúbio, que facilita a evasão) um sistema biométrico pode ser.

sensores) [11]. São notoriamente o tipo de biometria mais utilizado, seja em dispositivos populares (e.g., laptop, smartphone, registro e ponto de trabalhadores e outros) seja com finalidade governamental associada a identificação civil ou investigação criminal. Mesmo sendo o sistema biométrico mais utilizado atualmente, é possível destacar algumas vulnerabilidades como por exemplo, a necessidade de enorme quantidade de recursos computacionais para realizar a identificação de indivíduos levando em conta as milhões de impressões digitais armazenadas em bancos de dados e o fato de uma pequena fração da população não estar apta à este tipo de biometria por conta de características genéticas, envelhecimento ou condições de trabalho (e.g., trabalhadores manuais que executam atividade que destroem as impressões digitais).

2. **Assinatura** - A maneira com a qual um indivíduo assina um documento é reconhecida como uma característica do indivíduo [14, 15]. A assinatura, que é uma característica comportamental (não fisiológica), é utilizada como mecanismo legal de autenticidade em cartórios, transações bancárias e outros. Destaca-se que por ser uma característica comportamental, sofre alterações com o passar do tempo e que por vezes o mesmo indivíduo produz assinaturas substancialmente diferentes capazes de induzir o sistema a erros de correspondência. Ainda merece destaque o fato de que é possível, com relativa simplicidade e dependendo da assinatura, que falsificadores reproduzam cópias forjadas [16] capazes de enganar esse sistema biométrico (problema da evasibilidade).
3. **Reconhecimento Facial** - O reconhecimento facial é, sem dúvida, o meio mais utilizado por seres humanos para identificarem-se. Um indivíduo é capaz de reconhecer um rosto familiar em um ambiente não controlado em cerca de 100-200 ms (milissegundos) [17]. Sistemas biométricos baseados no reconhecimento da face humana exploram, em geral, características vinculadas à localização e forma de atributos faciais como olhos, sobrancelhas, narizes, lábios e outros. O problema deste tipo de sistema é que quando submetido a condições adversas (e.g., movimentação das pessoas passíveis de identificação, fundo da imagem não apresenta comportamento previsível, ângulos diferentes da mesma face, condições diferentes de iluminação e outros) resulta numa baixa taxa de correspondência. Mesmo considerando o estado da arte no que tange à detecção² (*Viola-Jones*) [18] e ao reconhecimento de faces [19, 20, 21], esse tipo de sistema biométrico ainda está longe da sua forma definitiva e é campo aberto para aprimoramentos [11].
4. **Reconhecimento de Voz** - A biometria baseada em voz é uma combinação de características fisiológicas e comportamentais [22]. Em termos de características fisiológicas é possível destacar a forma das bocas, cordas vocais, nariz e outros. Em termos de características comportamentais é possível destacar o estado emocional, envelhecimento, forma como características do ambiente (umidade e temperatura) influenciam a voz e

²Detecção significa apenas que existe uma face em determinado cenário, não deve ser confundido com reconhecimento ou identificação que carregam consigo o significado de correspondência.

outros. Devido aos fatos supracitados e também devido à ruídos sonoros provenientes de ambientes genéricos, o reconhecimento de voz não é utilizado em larga escala ficando, em geral, restrito a utilizações de menor complexidade [11].

5. **Geometria das Mãos** - A forma geral das mãos, tamanhos dos dedos, espessura dos dedos, área da palma da mão e outras medidas, podem ser utilizadas como características discriminantes entre indivíduos [23]. Um dos maiores problemas neste tipo de biometria é fator permanência, pois a geometria da mão sofre alterações muito relevantes com o envelhecimento do indivíduo, principalmente quando jovem. Apesar de não ser suscetível a problemas vinculados ao ambiente (e.g., seca, umidade e outros), a geometria das mão não é reconhecida como sendo uma biometria que possui traços de singularidades muito discriminativos e, ainda, apresenta problemas relacionados à acessibilidade, uma vez que indivíduos podem apresentar problemas de destreza, joias nos dedos e dificuldades de posicionar adequadamente as mão na posição correta para aquisição [11].
6. **Impressões das palmas das mãos** - De maneira muito semelhante às impressões digitais, as impressões das palmas das mão são compostas por cristas e vales das quais é possível extrair minúcias singulares discriminativas [23]. A maior limitação deste tipo de sistema é que pelo fato da área das palmas das mãos ser maior do que a área das impressões digitais, estas demandam sensores maiores e mais caros. No entanto, com o avanço dos dispositivos de captura de fotografias de alta definição/qualidade é possível vislumbrar um futuro promissor para este tipo de sistema.
7. **Iris** - O reconhecimento de íris pode ser definido como o processo de reconhecer uma pessoa analisando o padrão aleatório da íris desse indivíduo. Sua textura possui minúcias permanentes e discriminativas o suficiente para garantir a singularidade deste tipo de biometria [24]. Apesar de possuir altas taxas de correspondência [11], é um método relativamente invasivo, uma vez que o indivíduo deve posicionar seu olho (frágil e com tendência a ser protegido pelo ser humano) em um *scanner* para aquisição da amostra da íris.
8. **Digitação** - A biometria baseada na maneira com a qual um indivíduo digita em um teclado de computador é chamada em inglês de *keystroke*. Apesar de não ser um sistema biométrico suficientemente discriminativo para obter o traço de singularidade entre todos os indivíduos, é discriminativo o suficiente para permitir, em alguma medida, a identificação de pessoas [25]. Destaca-se que este sistema biométrico é baseado em aspectos comportamentais e não fisiológicos.
9. **Marcha**³ - Esse sistema biométrico é baseado na extração de traços de singularidade a partir da maneira como as pessoas andam (marcham). É um sistema biométrico

³Tradução da palavra *gait* do idioma inglês.

que combina traços comportamentais e fisiológicos. Distingui-se de outros sistemas biométricos pois é capaz de realizar o reconhecimento de indivíduos à distância, por exemplo, em ambientes com câmeras de segurança. Em geral esse tipo de biometria leva em conta a forma da silhueta [26] e padrões de movimentação [27] do indivíduo (e.g., *optical flow*).

10. **Impressões do cérebro**⁴ - Tipo de biometria que permite identificar indivíduos a partir de padrões de eletroencefalograma (EEG) [28]. Neste sistema biométrico, pessoas são apresentadas a situações nas quais existe um padrão de resposta do cérebro associado a determinados estímulos externos (e.g., apresentação de palavras escritas diate dos olhos). Os estímulos provocam reações distintas no cérebro de cada indivíduo e essas reações podem ser impressas e armazenadas em EEGs que se apresentam de forma discriminante o suficiente para que se possa identificar/reconhecer indivíduos. Destaca-se que este sistema biométrico é tanto comportamental quanto fisiológico.

Percebe-se que todos os tipos de sistemas biométricos anteriormente descritos podem ser classificados como fisiológicos, comportamentais ou fisiológicos-comportamentais. A Figura 2.2 resume de forma ilustrativa a classificação dos sistemas biométricos levando em consideração esses aspectos.

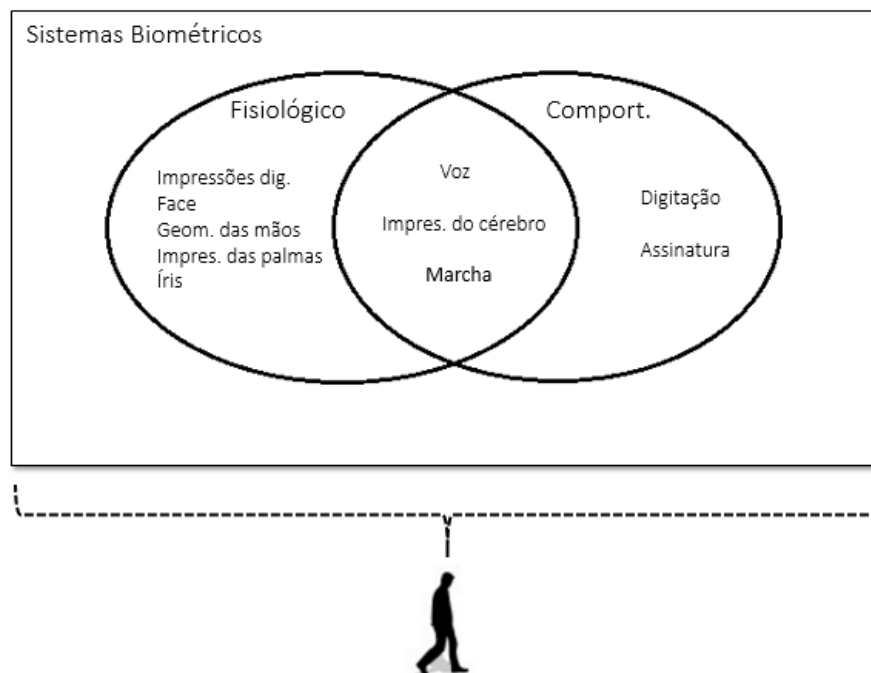


Figura 2.2: Classificação dos sistemas biométricos no que tange a sua natureza fisiológica ou comportamental.

⁴Tradução da palavra *brainprints* do idioma inglês

2.2 DESEMPENHO DE UM SISTEMA BIOMÉTRICO

Diferentemente de um *Person Identification Number* (PIN), que exige um correspondência perfeita entre os números digitados por um usuário e o padrão da senha registrado em um sistema, biometrias não desfrutam desta facilidade. Por limitações dos sensores, características mutáveis (e.g., mudança da face, mudança do timbre da voz, características do ambiente e outros) e limitações dos algoritmos, sistemas biométricos não procuram uma correspondência perfeita, mas sim aproximada. Neste sentido, para avaliar a performance de um sistema biométrico, no que tange a sua taxa da correspondência, algumas métricas formais são definidas. Entre as mais diversas métricas para avaliação de uma biometria, destacam-se quatro em especial [11]:

- **Taxa de falsos aceitos**, também chamada de falsos positivos (*False Accept Rate - FAR*, também chamada de *False Positives*) - Representa a taxa de amostras que foram reconhecidas como verdadeiras, válidas, apesar de não o serem;
- **Taxa de falsos rejeitados**, também chamada de falsos negativos (*False Reject Rate - FRR*, também chamada de *False Negatives*) - Representa a taxa de amostras que foram reconhecidas como falsas, inválidas, apesar de não o serem;
- **Taxa de verdadeiros aceitos**, também chamada de verdadeiros positivos (*Genuine Accept Rate - GAR*, também chamada de *True Positives*) - Representa a taxa de amostras que foram reconhecidas como verdadeiras, válidas e realmente o são;
- **Taxa de verdadeiros rejeitados**, também chamada de verdadeiros negativos (*Genuine Reject Rate - GRR*, também chamada de *True Negatives*) - Representa a taxa de amostras que foram reconhecidas como falsas, inválidas e realmente o são.

De maneira sucinta, é possível afirmar que as métricas *FAR* e *FRR* dizem respeito aos erros cometidos pelo sistema biométrico e as métricas *GAR* e *GRR* dizem respeito aos acertos cometidos pelo sistema. Seja na rejeição ou na aceitação.

Teste públicos recentes, utilizando bases de dados disponíveis para a comunidade científica, comparam quatro (impressões digitais, face, voz, íris) tipos de biometria no que diz respeito às taxas de erro supracitadas. Essa comparação pode ser encontrada na Tabela 2.1. Conforme é possível perceber, as impressões digitais são, até o momento, o tipo de biometria que possui menor taxa de erro associada, apesar das condições severas de teste. Merece destaque os fatos de que íris possui baixa taxa de erro em ambientes controlados e face a maior taxa de erro médio em ambientes gerais.

Diante do exposto até o momento, percebe-se a viabilidade dos sistemas biométricos para aplicações na sociedade atual e, em particular, é possível destacar a biometria baseada em impressões digitais por ser a mais utilizada e confiável até o momento. A seguir, são apresentados detalhamentos deste tipo biometria.

Tabela 2.1: As taxas de erro (FAR e FRR) referentes a quatro sistemas biométricos são apresentadas. Testes foram realizados utilizando bases de dados públicas e diversas condições de operação.

Sistema Biométrico	Test	Condições de Teste	FRR	FAR
Imp. Digit.	FVC 2004 [29]	Rotação e distorção exagerada da pele	2%	2%
Imp. Digit.	FpVTE 2004 [30]	Resultados de operações governamentais dos EUA	0,1%	1%
Face	FRVT 2002 [31]	Variedade de iluminação, ambiente fechado e aberto, tempos diferentes	10%	1%
Voz	NIST 2004 [32]	Texto independente, várias linguas	5-10%	2-5%
Íris	ITIRT 2005 [33]	Ambiente fechado	0,99%	0,94%

2.3 AS IMPRESSÕES DIGITAIS

As impressões digitais ou impressões dactilares ou ainda impressões papilares vêm sendo utilizadas como tentativa de reconhecer indivíduos desde o século XIX [10]. É reconhecida como única disciplina da criminalística que afirma categoricamente seus resultados, diferente de outras formas de identificação que utilizam a abordagem probabilística [10]. Diante deste fato e de outros, algumas vezes as impressões digitais são preferidas em relação até mesmo ao DNA [10]. Dispensando análise mais profunda, é possível afirmar que elas fazem parte da fisiologia do ser humano. Em verdade *Marcelo Malphigi*⁵, no século XVII, mostrou que as impressões digitais são o resultado da união da epiderme com a derme pelas chamadas papilas, que atuam como se fossem pregos, resultando no que ficou conhecido posteriormente como cristas que formam desenhos arabescos⁶ nas superfícies das mão e dos pés.

2.3.1 Breve Contextualização Histórica

Historicamente o homem buscou formas de identificar-se e, por isso, criou métodos que o distinguísse frente aos demais. Num primeiro momento o critério de identificação era essencialmente facial. Posteriormente os nomes das pessoas passaram a ser seguidos pelo nome

⁵Anatomista, fisiólogo, microscopista e histólogo, nasceu em Crevalcore, Itália (1628-1694), tendo aplicado, em sua época, o mais novo ramo da Anatomia, a Histologia, realizando significativas descobertas, entre as quais se encontram os corpúsculos ou proeminências cônicas bípadas, às quais denominou *papilas dérmicas*(1665) [34]

⁶Desenhos de formas abstratas com padronagem geométrica. O termo surgiu durante o século XVII e faz referência à moda árabe.

da província ou região de nascimento (e.g., Leonardo de Vinci⁷). Quando era necessário individualizar ainda mais os indivíduos, seus nomes eram acompanhados pelo nome dos pais, como Jesus, filho de José e Maria. Os sobrenomes surgiram como consequência.

A necessidade de individualização e identificação, há muito tem relevância na história da humanidade [10]. Alguns exemplos merecem destaque, como por exemplo o fato de que herdeiros a tronos eram reconhecidos por meio de testemunhas ou que criminosos eram marcados a ferro, com inserção de parafina fervente na pele ou tatuagens (também utilizadas em campos de concentração nazistas, Segunda Guerra Mundial).

O sistema antropométrico⁸ francês de Alphonse Bertillon foi uma tentativa de solução. De maneira independente os estudos de Malpighi foram retomados por Juan Evangelista Purkinje, William James Herschel, Henry Faulds e especialmente por Sir Francis Galton (sobrinho do naturalista Darwin) [35] que, em 1890, publicou um artigo na revista francesa Nature [36] e, posteriormente, seu livro *The Fingerprint* (1892), onde apresenta as impressões digitais como método de identificação plena de seres humanos.

Inicialmente Galton [10] e posteriormente vários cientistas categorizaram as impressões digitais e formalizaram maneiras de realizar o casamento a partir de sua forma geral e suas minúcias. Na próxima seção serão apresentadas as estruturas e traços que permitem que as impressões digitais sejam utilizadas com finalidades biométricas.

2.3.2 Fisiologia das Cristas Papilares

Cristas papilares são relevos epidérmicos cuja principal função é garantir a rugosidade necessária para que possamos agarrar objetos. Os relevos são acompanhados por sulcos interpapilares ou canais ou ainda vales. A Figura 2.3 apresenta um exemplo de impressão digital no qual se pode perceber a presença das cristas e vales. As cristas formam padronagens características a partir das quais é possível extrair traços biométricos suficientes para identificar indivíduos.

Conforme já mencionado, é possível categorizar impressões digitais. Em especial é possível realizar essa categorização de acordo com a forma geral de suas cristas. Em suma as impressões digitais são divididas em três tipos [36]:

- Sem núcleos nem deltas (arcos);
- Com um núcleo e um delta (laços);
- De dois ou mais deltas, com um ou mais núcleos (Verticilos).

A Figura 2.4 apresenta os dois tipos supracitados que apresentam núcleos e a Figura 2.5 apresenta cinco padrões de impressões digitais que se repetem com maior frequência [37] incluindo as que não possuem núcleo.

⁷Nascido em *Vinci*, um povoado da Toscana italiana.

⁸Método que consiste em registrar medidas corporais com fins de identificação [34].




Figura 2.3: Figura que apresenta cristas e sulcos de uma impressão digital: (a) imagem fotográfica original de uma impressão digital; (b) Resultado da binarização da imagem original; (c) ampliação da imagem original; e (d) ampliação da imagem binarizada. Cristas e vales podem ser observadas com facilidade em (c) e (d).




Figura 2.4: Regiões características (quadrados brancos) em impressões digitais.

Essa categorização inicial das impressões digitais não é suficiente para que indivíduos sejam identificados uma vez que as padronagens apresentadas na Figura 2.5 se repetem com muita frequência em várias pessoas, mas é o primeiro passo quando o método formal de




Figura 2.5: Um exemplo de cada tipo de impressão digital mais frequente. Figura adaptada do livro *Handbook of Fingerprint Recognition* [38].

correspondência [37] entre impressões digitais é empregado. Essa primeira abordagem é relativamente simples e descarta necessidade de avaliação mais criteriosa quando compara impressões digitais de classes diferentes.

Uma vez descartadas as impressões digitais que pertencem a classes diferentes, surge uma fase de maior complexidade que é a comparação de minúcias ou pontos característicos.

Segundo Caballero [10], as minúcias são pontos característicos gerados por "*perturbações naturais de origem fisiológica que registram as cristas papilares em seu caminho paralelo*". A combinação desses pontos característicos, levando em conta suas formas, frequências de aparecimento, distâncias relativas e outros, é suficiente para realizar a correspondência de impressões digitais com baixa taxa de erro [37], conforme já foi apresentado na Tabela 2.1.

Em suma, as minúcias pertencem a três classes: frequentes (e.g., ponto de linha, bifurcação e convergência), pouco frequentes (e.g., encerro, empalme e interrupção) e não frequentes (e.g., transversal, desvio e arpão). As que apresentam maior valor de identificação são não frequentes e pouco frequentes. No entanto, é interessante destacar que as frequentes são as mais utilizadas nos AFIS, exatamente por que são mais fáceis de serem obtidas. Como o objetivo deste trabalho não depende de uma explicação criteriosa de todos os tipos de minúcias, uma análise mais profunda pode ser encontrada na literatura [10, 37, 11, 38].

A Figura 2.6 apresenta algumas minúcias encontradas em uma impressão digital comum. É importante perceber que os pontos característicos destacados exigem que a imagem tenha qualidade mínima se o objetivo é alcançar uma alta taxa de correspondência e baixas taxas de *FAR* e *FRR*. Essa informação merece destaque, pois será parte fundamental deste trabalho uma vez que o método proposto no Capítulo 4, define o primeiro passo que deve ser levado em conta para avaliação da qualidade de impressões digitais multivistas sem toque [6, 7].




Figura 2.6: Figura que apresenta minúcias (pontos vermelhos) em uma impressão digital comum.

2.4 IDENTIFICAÇÃO DE IMPRESSÕES DIGITAIS

Em uma forma simplificada, o processo de identificação de impressões digitais pode ser subdividido em quatro subprocessos: (1) Captura da imagem; (2) Pré-processamento; (3) Extração de Características; e (4) Correspondência das características. A maioria faz uso de técnicas de capturas de imagens nas quais há a necessidade do toque entre o dedo do usuário e o dispositivo de captura utilizado. No entanto, dispositivos que dispensam o contato também vêm sendo propostos. Atualmente o processo de captura é dividido de acordo com o tipo de tecnologia: com ou sem toque do dedo. Se por um lado sistemas em que o toque no sensor se faz necessário já alcançaram um nível de maturidade, por outro, sistemas que utilizam a tecnologia sem toque (*touchless*) ainda estão nos seus primórdios, permitindo ainda diversos avanços no processo de identificação biométrica a partir da impressão digital.

Destaca-se que, independentemente dos sensores, existem três níveis de análise de impressões digitais para que seja realizada a sua identificação [10], a saber:

1. **Nível 1** - Categorização em função das estrutura geral das cristas das impressões digitais;
2. **Nível 2** - Análise das minúcias, pontos característicos, encontrados;
3. **Nível 3** - Avaliação da distribuição de poros dos dedos.

A análise de Nível 1 é simples, mas pouco discriminativa. A análise de Nível 2 é intermediária e apresenta alto grau de confiabilidade e acurácia. A análise de Nível 3, no entanto, é a mais precisa e detalhada [38], mas para que seja realizada demanda *scanners* capazes de

produzir imagens de alta resolução (mínimo de 800 dpi) e algoritmos robustos de extração de características discriminantes. Caballero, em seu livro [10], destaca a importância dos traços biométricos de Nível 3, argumentando que apenas nesse nível é possível afirmar que praticamente não existe probabilidade de erro (1 em 10^{97}).

Neste sentido, obter imagens confiáveis e de boa qualidade torna-se necessário para extrair o máximo potencial deste tipo de biometria. Infelizmente, problemas de ordem prática diminuem a acurácia desse sistema. Como este trabalho explora as limitações dos sensores para propor métodos de garantia da qualidade de impressões digitais, a seguir algumas tecnologias atuais e suas limitações são apresentadas.

2.5 IMPRESSÕES DIGITAIS COM TOQUE

Atualmente diversas aplicações nas áreas forenses, civis e comerciais fazem uso de impressões digitais [39]. Nestes sistemas, a autenticação a partir do uso de imagens digitais das impressões digitais, permitem uma descrição real dos dedos, aumentando a confiabilidade do sistema. Desta feita, o processo de aquisição se torna um passo crucial, interferindo diretamente no desempenho geral do processo de identificação. A maioria dos sistemas atuais empregam tecnologias baseadas no toque do dedo do usuário com o dispositivos de captura, demandando ao usuário pressionar o dedo contra sua superfície.

Dentre os diversos problemas relacionados ao uso deste tipo de tecnologia, podemos citar as distorções e inconsistências causadas durante o processo de captura pela elasticidade da pele. A qualidade da impressão digital obtida pode ser também influenciada pela sujeira, suor, secura excessiva, umidade do ar, temperatura e impressões digitais danificadas (cicatrizes). Também as variações no posicionamento do dedo em cada captura, pode ocasionar em amostras diferentes de imagens capturadas para o mesmo dedo. Em algumas situações, estas desvantagens [11] impõem a necessidade de operadores extremamente especializados e treinados, requerendo maior quantidade de tentativas, elevando o tempo necessário para um processo de captura para todos os dedos. Para o cadastramento de grandes populações, como o cadastramento biométrico eleitoral realizado em 2013 e 2014 no Brasil, demandam de muito tempo para que as impressões digitais capturadas tenham a qualidade necessária para o processo de identificação.

Com o passar dos anos, diversos algoritmos foram propostos para compensar essas limitações das tecnologias baseadas em toque, sendo que em alguns, estas melhorias geram gargalos para melhorias futuras na qualidade da imagem digital proveniente destas impressões digitais capturadas.

2.6 IMPRESSÕES DIGITAIS SEM TOQUE

Atualmente, diversas soluções baseadas na captura de impressões digitais sem toque têm sido desenvolvidas. Todas estas para colaborar no processo de melhoria dos problemas intrínsecos dos sistemas, em que utilizam o toque no sensor durante o processo de captura [2, 40, 41, 42]. A ideia básica de sistemas sem toque é atacar o problema de qualidade da amostra em seu nível fundamental: durante o processo de captura. No caso da utilização destes sistemas, não existe a necessidade do usuário em pressionar o dedo contra uma superfície de contato, evitando os problemas listados anteriormente e, dessa forma, não dependendo da utilização de algoritmos para a melhoria da qualidade da amostra capturada para compensar os problemas causados pela elasticidade da pele humana.

2.6.1 Impressões digitais multivista sem toque

Dentre as soluções tecnológicas disponíveis, a empresa suíça TBS⁹ desenvolveu um dispositivo que utiliza uma metodologia promissora [43]. Este dispositivo combina técnicas baseada na captura da reflexão da imagem do dedo a ser capturado, com um sistema de três câmeras sincronizadas em posicionamentos diferentes (múltiplas vistas). Uma câmera é posicionada para capturar a imagem proveniente do posicionamento normal ao dedo, em que a parte principal da impressão digital está localizada (deltas e bifurcações), a partir de uma câmera central. As outras duas câmeras são posicionadas a 45°, sendo uma no sentido horário (SH) e a outra no sentido anti-horário (SAH). A partir desta abordagem, é garantida a captura sobreposta de todas as áreas da impressão digital capturada. A imagem final é obtida a partir do mosaico formado das três imagens utilizando algoritmos de alinhamento [44]. Nas Figuras 1.1 e 2.7, são apresentadas uma representação esquemática de um sistema de captura sem toque utilizando múltiplas vistas e imagens capturadas por este tipo de dispositivo, respectivamente.




Figura 2.7: Exemplo de impressões digitais capturadas (1024×1280 pixels, 8 bits/pixels) por um sistema sem toque com três câmeras: (a) Vista 0; (b) Vista 1; e (c) Vista 2.

⁹<http://www.tbs-biometrics.com/hardware/>

2.7 AVALIAÇÃO DA QUALIDADE DE IMPRESSÕES DIGITAIS

O desempenho e interoperabilidade dos sistemas biométricos dependem da qualidade do sinal adquirido [45]. Portanto, uma metodologia para a estimação da qualidade das amostras biométricas coletadas é de fundamental importância, principalmente para se obter elevados índices de acerto.

Existe uma grande variedade de tecnologias que realizam a captura da impressão digital. Mesmo com os avanços e aprimoramentos muitos desses sistemas de capturas falham no processo de obtenção de imagens com boa qualidade. Alguns dispositivos de captura podem ser melhores do que outros, sendo até imunes a fatores que afetam diretamente a qualidade da imagem produzida, mas o problema em se obter imagens com boa qualidade ainda permite avanços. Trabalhos recentes descrevem vários problemas que afetam a qualidade da impressão digital, como por exemplo toques com o sensor inconsistentes, não-uniformes e irreprodutíveis [46] e propõem técnicas que resolvem estes problemas ([47, 48, 49]). Neste sentido, levando-se em conta que a avaliação da qualidade de impressões digitais utiliza princípios originários dos sistemas baseados na captura com o toque, propostos pelo *National Institute of Standards and Technology* (NIST) [50], faz-se necessário que os sistemas sem toque se adequem aos mesmos níveis de exigências do sistema com toque. Ainda no que tange aos problemas de qualidade oriundos do processo de aquisição das impressões digitais [10], dois têm importância especial: pressão demasiada ou diminuta; e posicionamento inadequado.

2.7.1 O problema da pressão

Como já mencionado, os dispositivos de captura de impressões digitais baseados em toque, tradicionais, por demandarem que o sujeito pressione seu dedo contra uma superfície de vidro (ver Figura 2.8) geram artefatos e ruídos devido ao emprego de pressão demasiada ou diminuta. Todos os sistemas de captura de impressões digitais baseados no toque do dedo com uma superfície estão sujeitos ao problema supracitado. Os sistemas baseados na tecnologia *Frustrated Total Internal Reflection* (FTIR), cujo esquema detalhado é apresentado na Figura 2.8, são antigos, mas mesmo os sistemas mais modernos [38] (e.g., *optical fiber*, *eletro-optical*, *direct reading*, *multispectral imaging*, *capacitive*, *sweep* e outros) apresentam a mesma limitação no que diz respeito aos artefatos gerados.

Um caso famoso na história da formalização das impressões digitais como meio de identificação unívoca de indivíduos (que levou cerca de 100 anos) merece destaque. Em 1905 os irmãos *Stratton*¹⁰ foram acusados por testemunhas de entrar na propriedade de dois anciãos, o Sr. e a Sra. *Farwor* e matá-los com intuito de roubar as economias do casal que encontravam-se em uma espécie de cofre. Naquela época, o uso das impressões digitais

¹⁰Disponível na internet: <http://www.biografiasyvidas.com/>. Biografias de personalidades históricas e atuais.

como meio de identificação de indivíduos ainda era desconhecido para a população comum e, por isso, os irmãos *Stratton* deixaram descuidadosamente várias impressões digitais latentes no cofre que pertencia às vítimas.

De acordo com [10], o problema é que as impressões digitais coletadas na cena do crime não condiziam de maneira razoavelmente confiável com as impressões digitais coletadas na delegacia. A defesa argumentava que as impressões digitais eram nitidamente distintas e que na verdade provavam a inocência dos criminosos. A promotoria, no entanto, estava convicta de que eram culpados e, pela primeira vez [10], levaram em consideração o fato de que a pressão exercida pelos dedos no momento em que entram em contato com alguma superfície causam distorções que possibilitam a geração de falsos positivos ou falsos negativos. *In loco*, a promotoria fez uma demonstração na qual coletava repetidamente as impressões digitais de vários jurados aplicando níveis de pressão diferentes. Os jurados ficaram convencidos de que dependendo da pressão empregada impressões digitais muito diferentes poderiam ser geradas.

Essa argumentação foi fundamental para que observassem cuidadosamente todas as impressões digitais latentes deixadas pelos criminosos e, depois de uma análise criteriosa, descobriram evidências de similaridades irrefutáveis na impressão digital do polegar direito do irmão mais velho. Os irmãos foram condenados à forca em 23 de maio de 1905. Esse foi o primeiro caso famoso da história que fez uma análise dos artefatos gerados pelo emprego de níveis de pressão diferentes na geração de impressões digitais.




Figura 2.8: Esquema de funcionamento de um sensor FTIR (*Frustrated Total Internal Reflection*). Esse tipo de sensor é o mais utilizado e tradicional disponível no mercado [38]. É possível notar que os raios de luz oriundos de uma fonte luminosa atravessam o prisma de vidro até atingirem a superfície de contato do dedo com o prisma. Ao atingirem a superfície, os raios de luz refletem em cristas ou vales gerando padronagem distinta (claro ou escuro). Posteriormente passam por uma lente convergente para que todos os raios refletidos atinjam o sensor.

Deve ser destacado que casos atuais de identificação errônea de indivíduos ainda ocorrem devido a má qualidade de impressões digitais. Os atentados de 11 de março de 2004 (caso Mayfield) são um bom exemplo. Depois das impressões digitais latentes deixadas na mala que continha os explosivos serem analisadas pelo sistema AFIS norte-americano, 20 candidatos foram listados. O agente norte americano Michael Weiners, especialista em impressões papilares, identificou o norte-americano Brandon Mayfield, advogado convertido ao islamismo, como culpado pela explosão que matou inocentes em Madrid. Posteriormente a polícia da Espanha provou que as impressões digitais pertenciam a Argeliano Daud Ouhane o que fez com que o FBI fosse obrigado a reconhecer publicamente seu erro.

Os dois exemplos supramencionados, Stratton e Mayfield, exemplificam um caso de falso negativo e falso positivo, respectivamente. Isso ressalta a importância da análise e verificação da qualidade de impressões digitais antes de utilizá-las para realizar a identificação de indivíduos. Por fim, é evidente que a variabilidade da pressão durante a captura é um problema exclusivo de scanners com toque. Os dispositivos de captura de impressões digitais sem toque são imunes a esse fator.

2.7.2 O problema do posicionamento

Outro problema fundamental que deve ser levado em consideração quando o assunto é avaliação da qualidade de impressões digitais, é o problema do posicionamento inadequado dos dedos diante dos sensores. A Figura 2.9 mostra problemas já formalizados na literatura quando se trata de dispositivos tradicionais, com toque.




Figura 2.9: Figura que apresenta problemas tradicionais de mal-posicionamento de dedos em dispositivos com toque.

A Figura 2.9 (a) apresenta o problema da **colocação**. Este problema ocorre quando o usuário coloca apenas uma fração do dedo diante da superfície de vidro. Conforme se observa na Figura 2.9 (a), a área útil (região do dedo que contém a impressão digital) adquirida pelo dispositivo é apenas uma fração da área total.

A Figura 2.9 (b) apresenta o problema da **orientação**. Apesar de capturar toda a área útil da impressão digital, gera problemas para os algoritmos de casamento de impressões digitais. Um pré-processamento para corrigir a orientação será necessário.

A Figura 2.9 (c) apresenta o problema da **inclinação**. Nesta situação o usuário inclina o dedo inadequadamente e além de se capturar apenas um fragmento da impressão digital, a pressão aplicada pelo dedo causa distorções consideráveis.

A Figura 2.9 (d) apresenta o problema da **rotação**. Nesta situação pode ser capturada uma imagem do dedo que não possui impressões digitais (e.g., a lateral do dedo).

O problema do mal-posicionamento em dispositivos de captura de impressões digitais multivista sem toque ainda não foi formalizado na literatura. Em verdade, a definição do problema para este tipo específico de dispositivo e algumas soluções, fazem parte da metodologia deste trabalho e poderão ser encontradas no Capítulo 4.

3 REDES NEURAIS ARTIFICIAIS

O estudo das Redes Neurais Artificiais (RNA) é um tópico específico da área de Inteligência Artificial [51, 52]. Dentre as várias subáreas da inteligência artificial, destaca-se aquela que estuda os modelos conexionistas dos quais as redes neurais artificiais fazem parte. A motivação para este estudo vem da área do conhecimento chamada Neurociência que é o estudo do sistema nervoso e especialmente do cérebro [52]. A inspiração oriunda do estudo da Neurociência e das redes neurais biológicas possibilitou numerosos avanços no desenvolvimento de sistemas inteligentes e, em especial, as RNAs vêm sendo utilizadas para resolver uma variedade de problemas tais como reconhecimento de padrões, predição, otimização, controle e outros [53]. Antes de oferecer uma abordagem técnica sobre o assunto, que tem especial importância para o trabalho proposto, vale apresentar um breve histórico da evolução e desenvolvimento das RNAs.

3.1 BREVE HISTÓRICO DA EVOLUÇÃO DAS RNAS

Em 1943, McCulloch e Pitts sugeriram um modelo matemático para o funcionamento do neurônio biológico [54]. O neurônio lógico, nome pelo qual ficou conhecido, nada mais representa que uma célula nervosa (neurônio) com a propriedade de poder estar excitada ou inibida. O estado de excitação ou inibição é determinado pelas chamadas funções de ativações, que serão abordadas mais à frente.

A inspiração para o desenvolvimento das chamadas Redes Neurais Artificiais, ou *Artificial Neural Networks (ANNs)* nasceram a partir do estudo das células nervosas que compõem o cérebro biológico [51], cujo esquema básico pode ser visto na Figura 3.1. Desde muito tempo o cérebro humano foi alvo de interesse de estudo e admiração. Não é por acaso que Aristóteles (335 A.C) escreveu, "*De todos os animais o homem é aquele que apresenta o maior cérebro em proporção ao tamanho de seu corpo*". Uma leitura aprofundada e detalhada sobre neurônios e redes neurais biológicas pode ser encontrada na bibliografia [55].




Figura 3.1: Representação de uma célula nervosa chamada neurônio, adaptada de [52]. Nesta figura é possível verificar a presença do corpo celular, ou soma, que contém o núcleo da célula bem como a presença de axônios, que são prolongações fibrosas desses núcleos e dendritos que são várias ramificações oriundas do corpo. Um axônio tem comprimento médio de 1 cm a 1 metro e um neurônio conecta-se com outros neurônios (de 10 a 100000) através de conexões chamadas sinapses. Os sinais são propagados de neurônio a neurônio através uma reação eletroquímica. Esse mecanismo é a base do processo de aprendizagem e pensamento vinculado ao cérebro.

Após o trabalho pioneiro de McCulloch e Pitts, uma segunda contribuição foi dada por Rosenblatt [56] que apresentou na década de 60 o teorema da convergência dos *perceptrons* e, posteriormente, o trabalho de Minsky e Papert [57] sobre as limitações da utilização de *perceptrons* simples. Os resultados obtidos por Minsky e Papert desencorajaram a continuação do estudo das RNAs e atrasaram a evolução desta área da IA por cerca de 15 anos. Foi somente na década de 80 que vários estudos renovaram o interesse da comunidade científica na área principalmente devidos aos trabalhos de Hopfield, com a abordagem da energia [58] e Werbos com algoritmo de aprendizagem de *perceptrons* multicamadas (*multilayer feed-forward networks*) [59] posteriormente popularizado por Rumelhart [60] em 1986. Um estudo aprofundado acerca da história e evolução das RNAs pode ser encontrado na literatura [61].

3.2 INTRODUÇÃO ÀS REDES NEURAIS ARTIFICIAIS

Uma visão moderna e simplificada [17] define as Redes Neurais Artificiais, ou apenas Redes Neurais, como sendo:

Um processamento massivamente paralelo constituído de unidades de processamento

simples, que possuem a propensão natural para armazenar conhecimento experimental e torná-lo disponível para uso. Assemelha-se ao cérebro em dois aspectos:

1. O conhecimento é adquirido pela rede a partir de um ambiente (experimentação) através de um processo de aprendizagem;
2. Forças de conexão intra-neurônios, conhecidas como pesos sinápticos, são usadas para armazenar o conhecimento adquirido.

Um modelo matemático não linear de um neurônio biológico (chamado na definição anterior de **unidade de processamento simples**) pode ser encontrado na Figura 3.2.

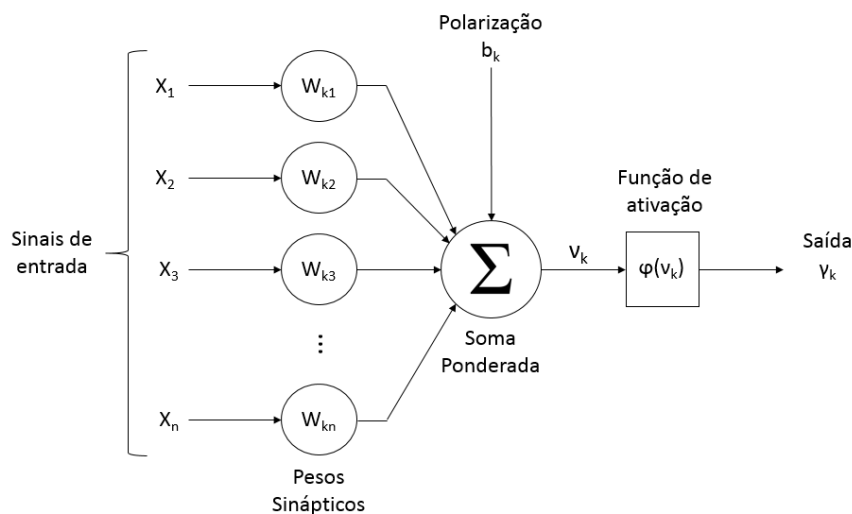


Figura 3.2: Modelo matemático de um neurônio. Independentemente das entradas, a saída normalizada é normalmente apresentada como um número real no intervalo $[0,1]$ ou $[-1,1]$, dependendo da função de ativação.

Neste modelo é possível perceber que o conjunto de estímulos, $x_1, x_2, x_3, \dots, x_n$ são amplificadas ou atenuadas através do uso dos pesos sinápticos $w_{k1}, w_{k2}, w_{k3}, \dots, w_{kn}$ produzindo uma soma ponderada u_k apresentada na equação 3.1. Destaca-se que o uso do índice k indica que trata-se do k -ésimo neurônio de uma rede neural artificial e o uso do índice i indica tratar-se do i -ésimo estímulo aplicado ao neurônio.

$$u_k = \sum_{i=1}^n w_{ki}x_i \quad (3.1)$$

À essa soma ponderada pode ser adicionado um valor externo comumente chamado de *bias* (b_k) que tem o intuito de realizar uma polarização no neurônio. A polarização tem por objetivo elevar ou diminuir de maneira *ad hoc* o valor de u_k fazendo com que um neurônio ative-se mais facilmente ou menos facilmente dependendo do valor de b_k .

A adição do *bias* à soma ponderada u_k gera uma saída v_k (Equação 3.2) que por sua vez é o valor de entrada para a função de ativação $\varphi(v_k)$ conforme se observa na Figura 3.2.

$$v_k = u_k + b_k \quad (3.2)$$

A função de ativação define a saída y_k do neurônio, que é representada pela Equação 3.3. Nota-se que quando existe uma polarização realizada pela inserção de um *bias*, $y_k = \varphi(v_k)$ e que quando não existe polarização, $y_k = \varphi(u_k)$.

$$y_k = \begin{cases} \varphi(v_k), & \text{se } b_k \neq 0 \\ \varphi(u_k), & \text{se } b_k = 0 \end{cases} \quad (3.3)$$

Para completar o entendimento acerca deste modelo do neurônio resta apresentar um detalhamento sobre como agem as funções de ativação. A função de ativação $\varphi(v)$, define a saída de um neurônio em termos do campo local induzido v [17]. Dados um conjunto de entradas, uma distribuição sináptica e um bias, a função de ativação define a saída do neurônio. A Figura 3.3 apresenta gráficos de alguns tipos clássicos de funções de ativação.




Figura 3.3: Quatro tipos clássicos de funções de ativação: (a) *threshold*, (b) *piecewise linear*, (c) *sigmoid* e (d) *gaussiana*.

Ao analisar as funções de ativação apresentadas na Figura 3.3 é possível perceber que todas possuem valores positivos para a saída, em verdade, a saída $\varphi(v)$ é denotada pelo intervalo $[0, 1]$, onde $\{\varphi(v) \in \mathbb{R} \mid 0 \leq \varphi(v) \leq 1\}$ e, em termos teóricos (não aplicáveis computacionalmente), a entrada v é denotada por $\{v \in \mathbb{R} \mid -\infty < v < +\infty\}$. No entanto, como já mencionado, existem funções de ativação que permitem valores negativos para as saídas $\varphi(v)$, essas funções possuem vantagens analíticas em relação àquelas que não o fazem [17]. Uma importante função de ativação que permite saídas $\varphi(v)$ onde $\{\varphi(v) \in \mathbb{R} \mid -1 \leq \varphi(v) \leq 1\}$ é a tangente hiperbólica, denotada por $\varphi(v) = \tanh(v)$. A função tangente hiperbólica, que tem especial importância para a Seção 4, é representada analiticamente pela Equação 3.4 e graficamente na Figura 3.4.

$$\tanh(v) = \frac{e^v - e^{-v}}{e^v + e^{-v}} \quad (3.4)$$

Até o momento, o texto apresentado definiu a estrutura e funcionamento de um único neurônio matemático. Uma formalização sobre o comportamento das entradas, pesos siná-




Figura 3.4: Representação gráfica da função tangente hiperbólica $\varphi(v) = \tanh(v)$. Apesar dos limites de escala é possível notar que v pertence ao intervalo $] -\infty, +\infty[$ e $\tanh(v)$ pertence ao intervalo $[-1, 1]$.

ticos, *bias*, função de soma ponderada e função de ativação foi estabelecida. No entanto, as redes neurais artificiais demandam que vários neurônios sejam conectados de forma especial para que uma rede com capacidade de aprendizagem e armazenamento do conhecimento possa ser formada. Neste sentido podemos observar a Figura 3.5 que apresenta a taxonomia das possíveis arquiteturas de uma RNA. Conforme apresentado, embora haja muitos tipos de arquiteturas de redes neurais artificiais disponíveis na literatura [17, 53, 62, 63], este trabalho foca apenas nas redes neurais chamadas **perceptron multicamadas**, ou **redes neurais feedforward multicamadas**, ou ainda **redes neurais multicamadas alimentadas adiante**, que podem ser encontradas na organização taxonômica apresentada na Figura 3.5.

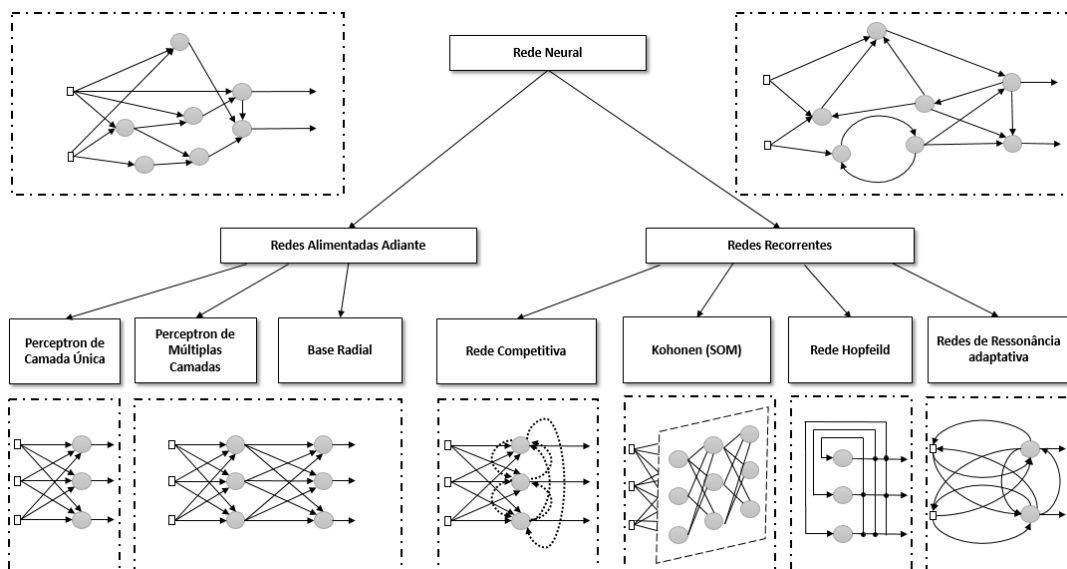


Figura 3.5: Taxonomia das arquiteturas de redes neurais artificiais inspirada em [53] e [17].

Uma explicação mais detalhada acerca das RNA do tipo *perceptron* multicamada é apresentada na próxima seção.

3.3 REDES NEURAIIS *FEEDFORWARD* MULTICAMADAS

As redes neurais podem ser organizadas em camadas. A RNA mais simples deste tipo que pode ser implementada é a de camada única. Um exemplo pode ser encontrado na Figura 3.6, que apresenta uma camada de entrada e uma camada de saída com três neurônios. Cabe destacar que as entradas não são contabilizadas como uma camada de processamento, motivo pelo qual é dito que a RNA é *single-layer* ou, de camada única. É possível notar, ainda, que o fluxo da informação (sinais) é unidirecional, da entrada no sentido da saída, o que faz com que a rede mencionada ganhe o título de *feedforward* ou, alimentada adiante.

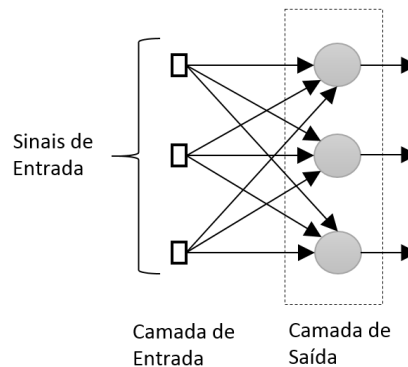


Figura 3.6: Representação de uma rede neural *single-layer*. Os círculos de cor cinza apresentados na figura são representações de um neurônio.

O tipo de RNA supramencionado possui diversas limitações, conforme apresentado nos trabalhos de Minsky e Papert [57]. A principal limitação apresentada diz respeito à incapacidade de classificar padrões de entradas que não são linearmente separáveis [17]. A operação lógica *XOR* é um bom exemplo desta limitação. Considere o quadrado apresentado na Figura 3.7 cujos quatro vértices definidos pelas quatro possíveis combinações de dois bits ($2^2 = 4$ vértices).

De forma matemática a operação lógica *XOR* pode ser expressa conforme a Equação 3.5 que apresenta comportamento não linear. As entradas x_1 e x_2 podem assumir valores lógicos 1 ou 0.

$$y(x_1, x_2) = \begin{cases} 1, & \text{se } x_1 \neq x_2 \\ 0, & \text{se } x_1 = x_2 \end{cases} \quad (3.5)$$

Esse exemplo simples apresenta padrões de entrada não linearmente separáveis. Isso pode ser percebido de maneira prática ao tentar separar os pares ordenados inscritos pelas elipses azuis dos pares ordenados inscritos pelas elipses verdes, na Figura 3.7, traçando uma única reta no plano definido pelos eixos x_1, x_2 . Após algumas tentativas o leitor perceberá que tal tarefa é impossível.




Figura 3.7: Cubo cujos vértices representam as quatro possíveis combinações de 2 bits na forma (x_1, x_2) . Considerando a operação lógica XOR, os pares ordenados inscritos dentro das elipses azuis representam saídas de valor lógico 1 e os inscritos dentro das elipses verdes representam saídas de valor lógico 0.

Em verdade, a não linearidade da operação lógica XOR é um caso especial de um conjunto de outros casos cujas entradas geram saídas cujos valores não podem ser aglutinados univocamente em classes bem definidas através de uma separação linear. Para resolver essa limitação, uma vez que esperar um comportamento linear do mundo real seria simplificar demasiadamente os do universo, é preciso empregar múltiplas camadas.

A Figura 3.8 apresenta um exemplo de arquitetura de um MLP. Nesse tipo de rede neural tem-se mais do que uma camada de neurônios. A camada de entrada representa apenas as unidades sensoriais do sistema nervoso e, ao contrário das camadas ocultas e de saída, não é constituída por elementos computacionais, ou seja, neurônios [17]. As camadas intermediárias, são chamadas de camadas ocultas. A grande vantagem de se implementar uma rede com essa arquitetura é a de que dessa forma é possível lidar com padrões de entrada não linearmente separáveis.

Neste trabalho, o MLP será utilizado como classificador, conforme será visto na Seção 4. Até aqui, definiu-se o arcabouço teórico para que se entenda a arquitetura e organização de um MLP, faltando agora apresentar uma síntese dos algoritmos de treinamento que o tornam capaz armazenar o conhecimento, aprender e raciocinar [17] fazendo com que seja apto a classificar corretamente padrões de entrada linearmente separáveis ou não.

3.4 ALGORITMO DE TREINAMENTO BACKPROPAGATION

O desenvolvimento do algoritmo de treinamento chamado de *backpropagation* representa um marco na área de redes neurais artificiais uma vez que provê um método computacionalmente eficiente para treinamento de um MLP [17]. Esse método vem se mostrando eficiente desde do ano de 1986 quando foi proposto por Rumelhart e McClelland [60]. Na verdade,

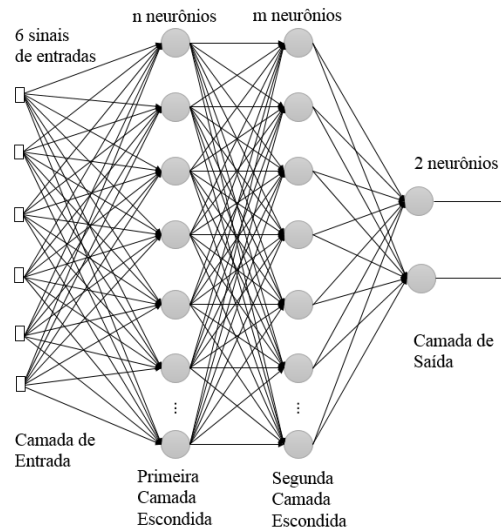


Figura 3.8: Exemplo de arquitetura de um *perceptron* multicamadas. A rede neural apresentada possui uma camada de entrada com 6 sinais, uma primeira camada escondida com n neurônios, uma segunda camada escondida com m neurônios e uma camada de saída com 2 neurônios. Na ilustração os *bias* foram omitidos com intuito de simplificar a ilustração.

foi com o surgimento do algoritmo de treinamento *backpropagation* [17] que a comunidade científica retomou o interesse no estudo de RNAs, que havia sido deixado de lado devido aos resultados pessimistas de Minsky e Papert [57] que demonstraram limitações severas nas RNAs *feedforward* de camada única.

Nas redes de camada única, o ajuste das sinapses e bias não oferece grande dificuldade. No início dos anos 60, os algoritmos de aprendizagem do *perceptron* e a regra de aprendizagem de Widrow-Hoff [64] eram capazes de treinar de forma eficiente estes tipos de rede. No entanto, com os algoritmos até então disponíveis podia-se calcular o erro na última camada, mas não nas camadas intermediárias, o que fazia com que ainda não houvesse forma eficiente para treinar o *perceptron* multicamadas. A solução para este impasse era exatamente o advento do algoritmo de treinamento *backpropagation*.

O algoritmo de treinamento *backpropagation* consiste basicamente de duas etapas:

1. Propagação do sinal para frente. Nesta etapa, um vetor-coluna é aplicado à camada de entrada da rede e seus efeitos são propagados até a saídas da rede, produzido como resposta um número real no caso de um único neurônio na camada de saída, ou um conjunto de números reais no caso da rede neural apresentar um conjunto de neurônios na camada de saída. Durante a propagação, os valores das sinapses e dos bias são mantidos constantes.
2. Retropropagação do erro para trás. Um sinal de erro é obtido através da subtração entre a resposta real e a resposta desejada. Este sinal é então propagado para trás,

realizando o ajuste dos valores sinápticos e bias de maneira que a resposta real da rede se aproxime da resposta desejada.

Mais detalhadamente, considere a Figura 3.9 que apresenta um exemplo de MLP. Destaca-se que um conjunto de padrões é apresentado à rede e para cada padrão são realizados os passos de propagação dos sinais de entrada, o cálculo do erro e a retropropagação.

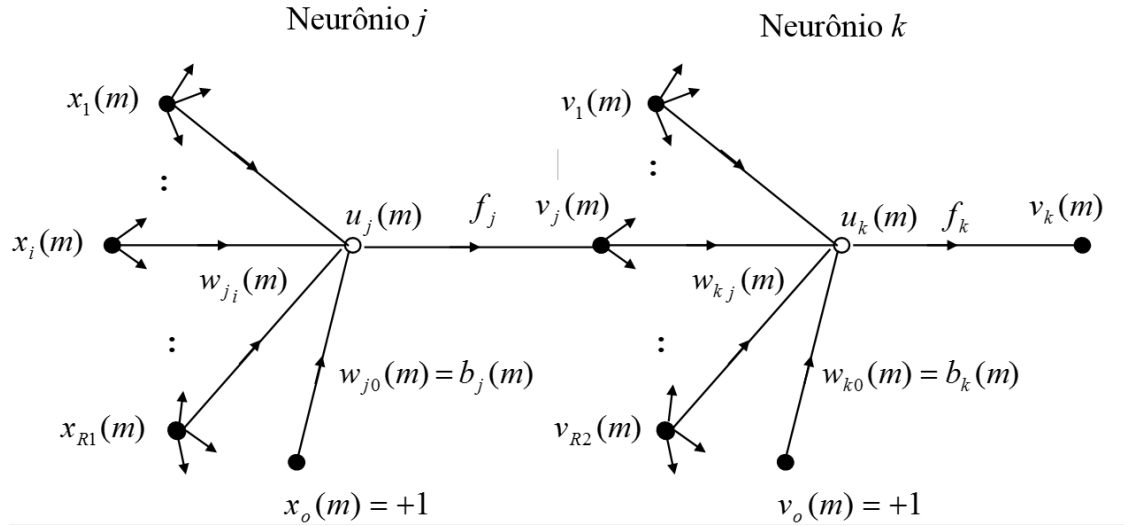


Figura 3.9: MLP com uma camada de entrada, uma camada escondida e uma camada de saída.

A propagação se inicia com o cálculo do chamado campo local induzido $u_j(m)$ para cada neurônio j da camada oculta segundo a Equação 3.6, onde $x_i(m)$ é o elemento i do sinal de entrada na iteração m , $w_{ij}(m)$ é o valor da sinapse que vem do elemento i da camada de entrada para o neurônio j da camada oculta e $R1$ é o número de elementos do vetor de entradas.

$$u_j(m) = \sum_{i=0}^{R1} w_{ij}(m)x_i(m) \quad (3.6)$$

Se $i = 0$ então $x_0(m) = +1$ e $w_{j0} = b_j(m)$, onde $b_j(m)$ é o bias do neurônio j da camada oculta, cuja saída é dada pela Equação 3.7, onde f_j é a função de ativação do neurônio j .

$$v_j(m) = f_j(u_j(m)) \quad (3.7)$$

De maneira similar àquela apresentada na Equação 3.6 o campo local induzido para o neurônio k da camada de saída é dado pela Equação 3.8 onde $v_j(m)$ é a saída do neurônio j da camada oculta na iteração m , w_{kj} é o valor da sinapse que vem do neurônio j da camada oculta para o neurônio k da camada de saída e $R2$ é o número de neurônios da camada oculta.

$$u_k(m) = \sum_{j=0}^{R2} w_{kj}(m)v_j(m) \quad (3.8)$$

Se $j = 0$ então $v_0(m) = +1$ e $w_{k0} = b_k(m)$, onde $b_k(m)$ é o bias do neurônio k da camada de saída, cuja saída é dada pela Equação 3.9 onde f_k é a função de ativação do neurônio k .

$$v_k(m) = f_k(u_k(m)) \quad (3.9)$$

Com o cálculo de $v_k(m)$, a primeira etapa foi concluída, que é processo de propagação do sinal, restando agora realizar a segunda etapa, que é a retropropagação do erro e, conseqüentemente, realizar ajustes das sinapses e *bias*.

O erro $e_k(m)$ é calculado através da subtração do resultado esperado $t_k(m)$ pelo resultado obtido pelo processo de propagação do sinal $v_k(m)$, conforme pode ser visto na Equação 3.10.

$$e_k(m) = t_k(m) - v_k(m) \quad (3.10)$$

Calculado o erro $e_k(m)$, agora é necessário retropropagá-lo ajustando as sinapses e *bias* da rede. O primeiro passo para realizar a retropropagação dos erros é calcular os gradientes [65] locais para cada neurônio.

Para cada neurônio da camada de saída os gradientes são dados pela Equação 3.11 e para cada neurônio da camada escondida os gradientes são dados pela Equação 3.12, onde $R3$ é a quantidade de neurônios da camada de saída.

$$\delta_k(m) = f'_k(v_k(m))e_k(m) \quad (3.11)$$

$$\delta_j(m) = f'_j(v_j(m)) \sum_{k=1}^{R3} \delta_k(m)w_{kj}(m) \quad (3.12)$$

Uma vez calculados os gradientes locais, estes são utilizados para calcular a atualização das sinapses e *bias*. A atualização dos valores das sinapses que ligam os neurônios da camada escondida aos neurônios da camada de saída é realizada segundo a Equação 3.13 e, similarmente, a atualização das sinapses que ligam os sinais da camada de entrada aos neurônios da camada escondida é dada pela Equação 3.14.

$$w_{kj}(m+1) = w_{kj}(m) + \eta v_j(m)\delta_k(m) \quad (3.13)$$

$$w_{ji}(m + 1) = w_{ji}(m) + \eta x_i(m) \delta_j(m) \quad (3.14)$$

Finalmente, os *bias* da camada escondida e da camada oculta são atualizados, respectivamente, pelas Equações 3.15 e 3.16.

$$b_k(m + 1) = b_k(m) + \eta \delta_k(m) \quad (3.15)$$

$$b_j(m + 1) = b_j(m) + \eta \delta_j(m) \quad (3.16)$$

O termo η é a taxa de aprendizagem e $f'(*)$ é a diferenciação em relação ao argumento. Para que a rede neural melhore sua performance é necessário que vários conjuntos de entradas padrão sejam inseridos na camada de entrada e que a propagação e a retropropagação ocorram diversas vezes. Por fim, um critério de parada deve ser criado, visto que o resultado ótimo pode não ser encontrado. Um exemplo de critério de parada é, por exemplo, quando a taxa absoluta da variação do erro médio quadrático para um conjunto de padrões de entrada ter alcançado um valor mínimo desejado.

O algoritmo de treinamento *backpropagation* foi o primeiro a propor um método eficiente para treinamento dos MLPs. Posteriormente vários outros métodos inspirados na sua abordagem surgiram. Em especial há uma variação do algoritmo *backpropagation* muito utilizada chamada de Levenberg-Marquardt [66].

3.5 ORGANIZAÇÃO DOS SINAIS DE ENTRADA

Os sinais de entrada para uma rede neural devem obedecer um padrão. Apesar de haver redes neurais com aprendizagem não supervisionada, neste trabalho apenas as redes supervisionadas são estudadas e utilizadas. Observe a Figura 3.10 que apresenta um modelo em forma de tabela de como os dados devem ser distribuídos para que possam ser utilizados em uma RNA com aprendizagem supervisionada. Nesta tabela é possível notar que cada linha representa uma amostra que servirá de entrada para a rede neural e que cada coluna representa uma *feature*, característica, específica das amostras. A Figura 3.11 apresenta um exemplo de base de dados de treinamento com 5 amostras onde cada amostra possui três características discriminativas. Percebe-se que o vetor de características de cada amostra deve ser transposto para posteriormente ser inserido na RNA.

Para que seja realizado o treinamento da RNA é necessário que a base de dados seja dividida em três conjuntos:

- **Conjunto de Treinamento** - Utilizado para atualizar as sinapses da rede e realizar a aprendizagem;




Figura 3.10: Matriz que apresenta o padrão de entradas esperado por uma RNA com aprendizagem supervisionada.

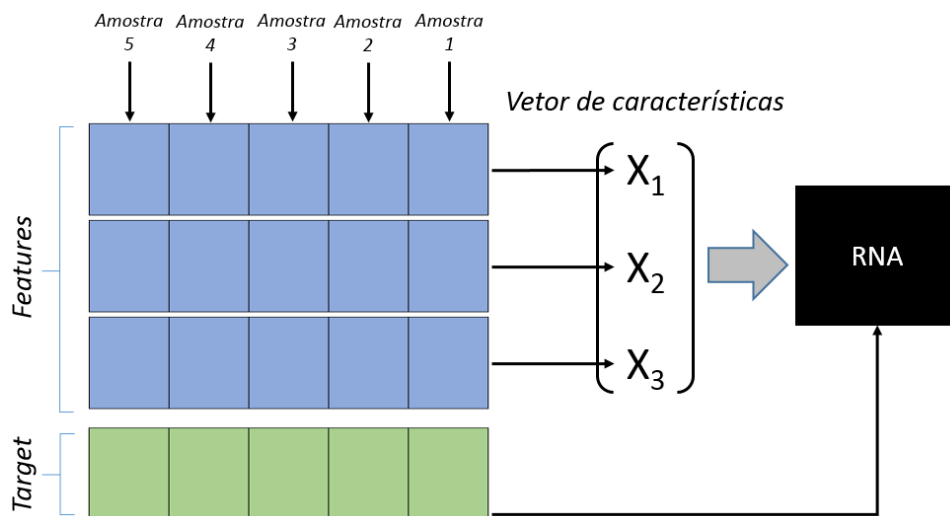


Figura 3.11: Exemplo de base de dados para treinamento supervisionado de uma RNA. Na figura é possível notar que a base dados contém 5 amostras, cada amostra com três características discriminativas. As características são utilizadas para montar um vetor de características que é a entrada para a Rede Neural. Destaca-se que o *target* (classe) de cada amostra não é utilizado para montar o vetor de características, mas apenas para mensurar o quanto a saída da rede é diferente do esperado e calcular o erro. Posteriormente o algoritmo de treinamento *backpropagation* irá propagar o erro em sentido à entrada da rede reajustando as sinapses de cada neurônio.

- **Conjunto de Validação** - Utilizado para evitar o *overfitting* ou super-ajuste do modelo;
- **Conjunto de Testes** - Utilizado para avaliar o desempenho da rede.

Para montar os três conjuntos supramencionados é necessário distribuir de forma inteligente a base de dados. Para entender tal afirmação, considere a Figura 3.12 que apresenta um exemplo de base de dados com 9 amostras.

Base	Feature 1	Feature 2	Feature 3	Feature 4	Classe
Amostra 1	1,0	2,0	1,0	1,0	-1,0
Amostra 2	1,0	2,0	3,0	3,0	-1,0
Amostra 3	1,0	2,0	2,0	1,0	-1,0
Amostra 4	0,0	1,0	2,0	3,0	0,0
Amostra 5	1,0	2,0	3,0	4,0	0,0
Amostra 6	1,0	1,0	2,0	2,0	0,0
Amostra 7	3,0	3,0	2,0	1,0	1,0
Amostra 8	4,0	3,0	2,0	1,0	1,0
Amostra 9	3,0	3,0	2,0	1,0	1,0

Figura 3.12: Matriz que apresenta um exemplo de base de dados com nove amostras. As amostras apresentam quatro características discriminativas e podem ser classificadas em três classes distintas representadas pelos números -1,0; 0,0; e 1,0.

Como a base de dados do exemplo possui 9 amostras, fica evidente que se distribuímos igualmente (que não é a única opção) a quantidade de amostras entre os três conjuntos, cada um ficará com três amostras. No entanto, todos os conjuntos devem ser balanceados para conter amostras que pertençam a todos as possíveis classes em quantidades aproximadamente iguais [67]. Um exemplo de montagem adequada desses conjuntos pode ser encontrada nas Figura 3.13.

Treinenamen.	Feature 1	Feature 2	Feature 3	Feature 4	Classe
Amostra 1	1,0	2,0	1,0	1,0	-1,0
Amostra 4	0,0	1,0	2,0	3,0	0,0
Amostra 7	3,0	3,0	2,0	1,0	1,0

(a) conjunto de treinamento

Validação	Feature 1	Feature 2	Feature 3	Feature 4	Classe
Amostra 2	1,0	2,0	3,0	3,0	-1,0
Amostra 5	1,0	2,0	3,0	4,0	0,0
Amostra 8	4,0	3,0	2,0	1,0	1,0

(b) conjunto de validação

Teste	Feature 1	Feature 2	Feature 3	Feature 4	Classe
Amostra 3	1,0	2,0	2,0	1,0	-1,0
Amostra 6	1,0	1,0	2,0	2,0	0,0
Amostra 9	3,0	3,0	2,0	1,0	1,0

(c) conjunto de teste

Figura 3.13: Os conjuntos de treinamento (a), validação (b) e teste (c) foram organizados intercalando as amostras da base de dados a fim de garantir uma distribuição balanceada.

Após realizada essa distribuição de maneira adequada, é possível normalizar as entradas antes de inseri-las na rede neural. Essa normalização pode ser feita mapeando os valores de cada amostra em uma distribuição de amplitude 2, que fica estabelecida no intervalo $[-1,1]$ [67]. O resultado desta normalização aplicada aos dados anteriores pode ser visto na Figura 3.14

Treinamen.	Feature 1	Feature 2	Feature 3	Feature 4	Classe
Amostra 1	-1,0	1,0	-1,0	-1,0	-1,0
Amostra 4	-1,0	-0,3	0,3	1,0	0,0
Amostra 7	1,0	1,0	0,0	-1,0	1,0

(a) conjunto de treinamento normalizado

Validação	Feature 1	Feature 2	Feature 3	Feature 4	Classe
Amostra 2	-1,0	0,0	1,0	1,0	-1,0
Amostra 5	-1,0	-0,3	0,3	1,0	0,0
Amostra 8	1,0	0,3	-0,3	-1,0	1,0

(b) conjunto de validação normalizado

Teste	Feature 1	Feature 2	Feature 3	Feature 4	Classe
Amostra 3	-1,0	1,0	1,0	-1,0	-1,0
Amostra 6	-1,0	-1,0	1,0	1,0	0,0
Amostra 9	1,0	0,3	-0,3	-1,0	1,0

(c) conjunto de teste normalizado

Figura 3.14: Conjunto de treinamento (a), conjunto de validação (b) e conjunto de teste (c) normalizados. É possível perceber que todas as amostras possuem amplitude 2. Isso garante a normalização das características (*features*).

Após realizar a normalização é possível notar que algumas amostras são repetidas e, portanto, carregam informação redundante (exemplo: *amostra 4* e *amostra 5*). A repetição deve ser descartada e apenas amostras não redundantes devem ser mantidas na base de dados [67]. Finalmente, caso houvesse uma maior quantidade de amostras dentro de cada um dos conjuntos, poderia se efetuar uma permutação aleatória para evitar que muitas amostras da mesma classe fossem inseridas sequencialmente na rede neural, o que poderia resultar numa polarização indesejada.

Nesta parte do trabalho encerra-se a apresentação do referencial teórico que oferece o arcabouço necessário para o entendimento das partes que seguem. No próximo capítulo, detalhes da metodologia proposta são apresentados.

4 METODOLOGIA PROPOSTA

O objetivo deste trabalho é apresentar um método capaz de detectar de forma eficiente o mal-posicionamento rotacional de dedos em dispositivos de captura de impressões digitais multivista sem toque utilizando um classificador baseado em redes neurais artificiais multicamadas.

Para desenvolver o trabalho proposto, algumas etapas foram necessárias:

1. Definir o problema do mal-posicionamento de dedos em dispositivos multivistas de captura de impressões digitais sem toque. Esse problema, apesar de ser bem definido para a tecnologia com toque (ver Seção 2.7.2), não o é para tecnologia sem toque. Uma explicação detalhada pode ser encontrada na Seção 4.1;
2. Construir uma base de dados significativa para que se possa treinar, validar e testar o classificador proposto. Até o momento, não existe nenhuma base de dados pública que tenha sido gerada utilizando a tecnologia multivista sem toque. Uma base de dados de 9000 imagens foi produzida e detalhes sobre a construção desta base podem ser encontrados na Seção 4.2;
3. Desenvolver e validar um método capaz de corrigir problemas de orientação de dedos gerando imagens de saída padrão no que diz respeito à orientação;
4. Detectar problemas de rotação de dedos inseridos em dispositivos de captura de impressão digitais multivistas sem toque e estimar o ângulo de rotação utilizando um classificador baseado em RNAs. Um detalhamento do método pode ser encontrado nas Seções 4.3, 4.4 e 4.5;
5. Apresentar detalhadamente os resultados e realizar uma análise cuidadosa com intuito de validar o método, apresentar suas limitações e indicar caminhos de melhorias. Os resultados detalhados podem ser encontrados no Capítulo 5.

4.1 DEFINIÇÃO DO MAL-POSICIONAMENTO

Conforme mencionado anteriormente, um dos principais problemas vinculados a dispositivos de captura de impressões digitais sem toque é o fato de que pelos dedos terem maior grau de liberdade de movimentação, as imagens adquiridas podem ter pouco valor do ponto de vista biométrico caso os dedos não sejam colocados adequadamente diante das câmeras fotográficas. Neste momento torna-se importante recordar a forma como as três câmeras fotográficas estão distribuídas dentro do dispositivo. A Figura 4.1 apresenta essa distribuição.




Figura 4.1: Distribuição das câmeras em um sistema de captura para impressão digital multivista sem toque. Três câmeras (uma central e duas laterais) são utilizadas para captura da área central e lateral da impressão digital.

A ideia principal desse trabalho é definir o primeiro passo para a criação de um futuro método automático para avaliação da qualidade que possa orientar o processo de aquisição de impressão digitais sem toque. Esse primeiro passo é garantir o posicionamento adequado dos dedos dentro do dispositivo de captura. Utilizando a Figura 4.2 como referência, de agora em diante o correto posicionamento dos dedos dentro de dispositivos de captura de impressões digitais multivista sem toque será verificado se:

- (i) O dedo estiver posicionado ao longo do eixo x , (Fig. 4.2 (a)) cuja direção é definida pelo vetor unitário \hat{i} e que passa pelo centro do orifício do dispositivo; isso garante que nenhum problema de orientação, inclinação, translação horizontal ou vertical (Fig. 4.2 (b)) se apresenta.
- (ii) O centro da impressão digital deve estar apontando (vetor unitário normal) para a direção e sentido $-\hat{k}$ onde a câmera responsável pela vista 0 está posicionada (Fig. 4.1); alternativamente, o centro da unha deve estar apontando (vetor unitário normal) para a direção \hat{k} . Essas condições equivalentes definem um ângulo de rotação θ igual a zero graus em relação à câmera responsável pela vista 0; desta forma garante-se que não haja rotação do dedo.

Apesar dos dedos potencialmente poderem apresentar todos os problemas de posicionamento impróprio ilustrados na Figura 4.2 (b), apenas os problemas de orientação e rotação são abordados neste trabalho. Chama-se atenção para o fato de que o problema da **colocação** em dispositivos com toque (Seção 2.7.2) aqui foi renomeado para problema da **inserção** por motivos de significação. A seguir, uma descrição detalhada da forma como a base de dados foi construída e uma explicação completa do método desenvolvido para resolver os problemas supracitados, serão apresentados.

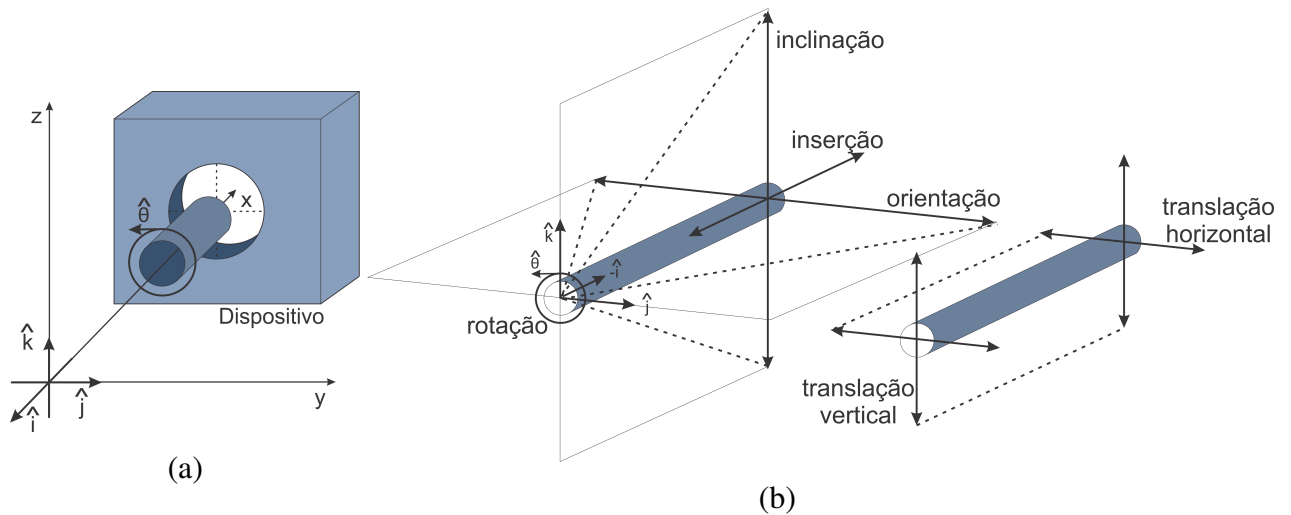


Figura 4.2: Ilustração do problema do mal-posicionamento: (a) posição do dedo (cilindro) relativa ao dispositivo de captura (cubo); (b) descritores de movimento (orientação, inclinação, rotação, inserção, translação horizontal e translação vertical) que indicam as formas como o dedo pode estar mal posicionado. Neste trabalho, apenas as distorções devido à orientação e à rotação são levadas em conta.

4.2 CONSTRUÇÃO DA BASE DE DADOS

Uma vez que o objetivo é avaliar o mal-posicionamento dos dedos em dispositivos de impressão digital sem toque, o primeiro passo é criar um conjunto de testes. As amostras foram adquiridas a partir de 20 voluntários que cederam suas impressões digitais capturadas por um dispositivo com características gerais semelhantes às descritas na Figura 4.1. Amostras provenientes de todos os dedos de ambas as mãos foram coletadas. Aqui, a amostra é definida como um conjunto de três imagens (vista 0, 1 e 2) de cada dedo, como mostrado na Figura 2.7. Todos os dedos (10 dedos) geram 15 amostras cada, o que perfaz um total de 45 imagens por dedo. Portanto, o nosso conjunto de teste é composto por $20 \times 10 \times 15 \times 3 = 9000$ imagens. As 15 amostras de cada dedo são distribuídas da seguinte forma:




Figura 4.3: Identificação dos dedos e possíveis direções de rotações.

- 5 amostras não rotacionadas;
- 5 amostras rotacionadas em 180° ; e
- 5 amostras rotacionadas em 90° sentido horário (SH) ou sentido anti-horário (SAH), dependendo da mão (esquerda ou direita).

Quatro dedos da mão direita (2, 3, 4 e 5) e um dedo da mão esquerda (6) foram rotacionados no sentido horário. Quatro dedos da mão esquerda (7, 8, 9 e 10) e um dedo da mão direita (1) foram rotacionados no sentido anti-horário. Os polegares foram rotacionados no sentido oposto, considerando os outros dedos da mesma mão, devido a razões ergonômicas. A Figura 4.3 identifica cada dedo e os respectivos sentidos de rotação. O efeito dos diferentes sentidos de rotação sobre a vista 0 é exemplificada na Figura 4.4. Conseqüentemente, o conjunto de testes é caracterizado por 500 amostras de dedos rotacionados em 90° sentido horário, 500 amostras de dedos rotacionados em 90° sentido anti-horário, 1.000 amostras de dedos rotacionados em 180° e 1000 amostras de dedos não rotacionados, o que perfaz um total de 3.000 amostras, 9000 imagens.




Figura 4.4: Efeito de diferentes ângulos de rotação na Vista 0: (a) não-rotacionado; (b) 90° SH; (c) 90° SAH; e (d) rotacionado em 180°.

4.3 PRÉ-PROCESSAMENTO

Seguindo a metodologia de aquisição descrita, a base de dados foi criada. É importante ressaltar que não houve qualquer tentativa de controlar o comportamento do usuário no momento da aquisição de forma que o usuário interagiu com o equipamento de maneira autônoma após instruções iniciais. Devido a esse fato, as imagens possuem comportamento diverso não previsível. Dentre os vários problemas que podem ocorrer, destaca-se, neste momento, o da orientação (definido na Seção 4.1). É possível observar na Figura 4.5 que os dedos podem possuir um ângulo de orientação indevida acentuado.




Figura 4.5: Exemplos de imagens não ideais em relação à vista 0: (a) imagem que apresenta um dedo com problema de orientação para baixo; (b) imagem que apresenta um dedo com problema de orientação para cima.

É importante notar que apesar da Figura 4.5 apresentar imagens visualmente desviadas "para cima" e "para baixo", por se tratar do problema de **orientação**, na verdade isso significa que as pontas dos dedos estão desviados ao longo do eixo definido pelo vetor unitário \hat{j} conforme pôde se observar detalhadamente na Figura 4.2 (b) já explicada.

Neste sentido, todas as imagens adquiridas sofrem um pré-processamento antes que sejam extraídas as características discriminantes (*features*) utilizadas para treinamento, validação e teste de RNA proposta para detectar a rotação de dedos. O pré-processamento é dividido em:

- Realizar a binarização da imagem utilizando o método de *Ostu* [68, 69] com intuito de atribuir cor branca ao dedo e cor preta ao fundo da imagem;
- Realizar uma regressão linear [70] utilizando as coordenadas cartesianas dos pixels brancos com intuito de obter o coeficiente angular e linear da reta gerada;
- Posicionar a imagem do dedo adequadamente para remover o problema da orientação inadequada.

Destaca-se ainda, que nenhuma imagem foi descartada da base de dados.

O rotação de imagens é uma técnica já reconhecida e utilizada [71]. Uma imagem pode ser rotacionada em um ângulo arbitrário qualquer. Um exemplo simples pode ser encontrado na Figura 4.6, que apresenta a ilustração da rotação de uma imagem original em 90° SH e 90° SAH.

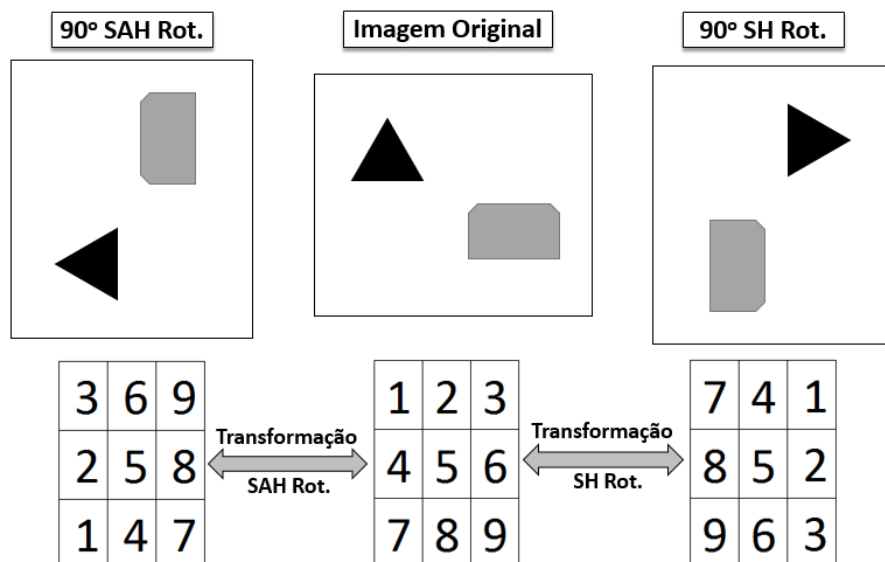


Figura 4.6: Exemplo simples de rotação de uma imagem em 90° sentido horário e anti-horário. As matrizes representam um exemplo de transformação que resulta na rotação da imagem.

Nesta ilustração é possível notar que uma imagem original (representada a título didático por uma matriz 3x3 de números de 1 à 9) pode ser rotacionada 90° em sentido horário ou

anti-horário, realizando simplesmente uma transformação, que consiste na cópia de *pixels* (*Picture Element*) que estão organizados em linhas reordenando-os em colunas, respeitando a direção em que se deseja rotacionar a imagem.

No entanto, imagens (que podem ser entendidas como matrizes) podem ser rotacionadas em um ângulo θ qualquer. A transformação aplicada para rotacionar uma imagem consiste em mapear cada ponto da imagem de coordenadas (x, y) para uma nova localidade espacial (x', y') . As coordenadas cartesianas da localidade resultante da operação de rotação podem ser calculadas pela Equação 4.1.

$$\begin{bmatrix} x' \\ y' \end{bmatrix} = \begin{bmatrix} \cos(\theta) & -\sin(\theta) \\ \sin(\theta) & \cos(\theta) \end{bmatrix} \cdot \begin{bmatrix} x \\ y \end{bmatrix} \quad (4.1)$$

A partir deste momento, uma descrição detalhada do método aplicado para correção do problema da orientação inadequada de imagens da base de dados utilizando a técnica de rotação de imagens descrita, será apresentada. Destaca-se que a técnica de rotação aplicada não deve ser confundida com o problema de rotação de dedos apresentado na Seção 4.1.

Considere a imagem de um dedo da base de dados sem nenhum pré-processamento apresentada na Figura 4.7 (a). A primeira etapa consiste em aplicar o processo de binarização da imagem utilizando o método de *Otsu* [68]. O resultado pode ser visto na Figura 4.7 (b). Por fim utiliza-se a técnica da erosão [72, 71] que aplica um elemento estruturante retangular de dimensões 4×4 na imagem binarizada com intuito de eliminar ruídos gerados pela binarização. O resultado da erosão pode ser encontrado na Figura 4.7 (c).

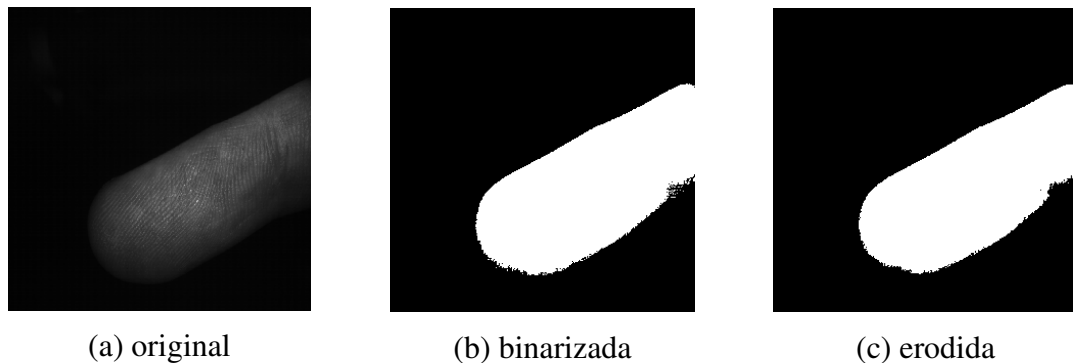


Figura 4.7: Etapas da correção da orientação inadequada: (a) imagem original do dedo que visivelmente apresenta problema de orientação; (b) imagem binarizada utilizando o método de *Otsu*; e (c) resultado após realizada a erosão na imagem binarizada.

A imagem resultante (Figura 4.7 (c)), é formada apenas por *pixels* brancos e pretos onde os brancos representam o dedo. Seja (x_i, y_i) as coordenadas cartesianas de um *pixel* branco P_{b_i} , temos que um *pixel* branco pode ser representado de maneira unívoca por $P_{b_i}(x_i, y_i)$, $\forall \{i \in \mathbb{N}^* \mid i \leq n\}$, onde n é o número de *pixels* brancos da imagem, uma vez que dois

pixels não podem possuir a mesma coordenada espacial.

Neste momento, será realizada uma regressão linear utilizando as coordenadas cartesianas de todos P_{b_i} . O intuito é obter a equação de uma reta (Eq. 4.2) que estima a inclinação do dedo (*pixels* brancos) presente na imagem.

$$\hat{y} = a\hat{x} + b \quad (4.2)$$

Os coeficientes a e b são os coeficientes angular e linear dessa reta, respectivamente. Tais coeficientes foram calculados utilizando as equações 4.3 e 4.4 onde \bar{y} e \bar{x} são as médias das coordenadas cartesianas y e x dos P_{b_i} , respectivamente.

$$a = \frac{\sum_{i=1}^n x_i \cdot y_i - \frac{\sum_{i=1}^n x_i \cdot \sum_{i=1}^n y_i}{n}}{\sum_{i=1}^n x_i^2 - \frac{(\sum_{i=1}^n x_i)^2}{n}} \quad (4.3)$$

$$b = \bar{y} - a\bar{x} \quad (4.4)$$

Um exemplo de resultado da regressão linear pode ser encontrado na Figura 4.8, que apresenta a reta obtida a partir da regressão linear em sobreposição à imagem do dedo binarizada e erodida, bem como o resultado após a correção da orientação.

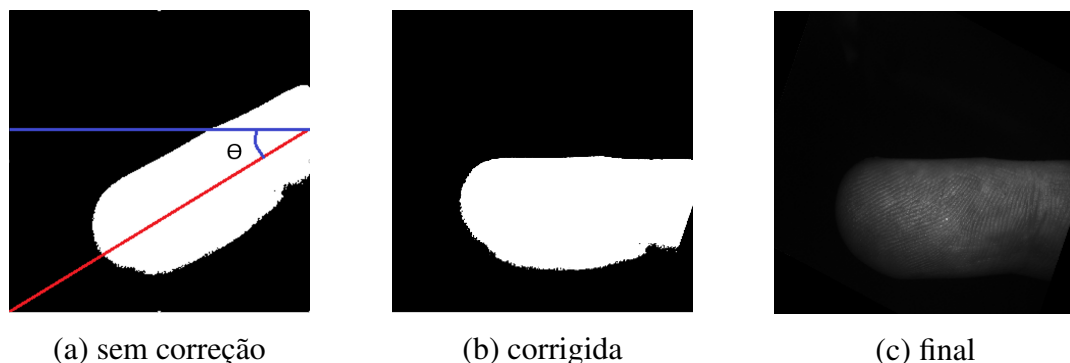


Figura 4.8: Exemplo de resultado da correção da orientação inadequada dos dedos: (a) imagem que apresenta um reta vermelha, obtida a partir da regressão linear; (b) máscara binarizada gerada após a correção; e (c) imagem final obtida após a imagem original ser rotacionada em um ângulo θ .

Após realizado o pré-processamento e corrigido o problema da orientação inadequada das imagens dos dedos, o próximo passo é a extração de características discriminantes para treinamento do classificador proposto para detectar o mal-posicionamento rotacional dos dedos em dispositivos de captura de impressões digitais multivista sem toque.

4.4 EXTRAÇÃO DE CARACTERÍSTICAS DISCRIMINANTES

O próximo passo é definir as métricas que serão utilizados como parâmetros para o classificador. A primeira métrica é a média da área útil em cada vista (m_0, m_1 e m_2). A segunda métrica é a variância destas mesmas áreas úteis (σ_1, σ_2 e σ_3). Nós assumimos que a luminosidade média e a textura irão variar dependendo da porção do dedo a ser fotografado. A unha produz, sem dúvida, diferentes padrões de reflexão em comparação à parte do dedo que contém o núcleo e o delta.



Figura 4.9: Recuperação da região de interesse (Vista 0): (a) Imagem original; (b) Resultado da binarização; (c) Seleção da Máscara; e (d) área selecionada para o cálculo da média e variância. O mesmo procedimento é aplicado para as vistas 1 e 2.

Para calcular os valores destas duas métricas, primeiro uma área útil deve ser delimitada. Inicialmente, aplicamos um processo de binarização com o método de Otsu [68]. Uma vez que o fundo é muito mais escuro do que o primeiro plano, o processo retorna uma segmentação do dedo muito precisa. Em seguida, o elemento de imagem branco mais à esquerda é definido como a ponta de um dedo. Considerando-se que o comprimento do dedo L em pixels pode ser estimado como o número de colunas entre a ponta do dedo (coluna f_c) e a última coluna da imagem, a região de interesse (ROI) é definida como todos os pixels brancos que encontram-se entre f_c e $f_c + L/2$. Procura-se garantir que uma área significativa do dedo esteja representada dentro desta região. Pelo menos a unha ou o núcleo devem ser incluídos. A Figura 4.9 ilustra como a região de interesse é capturada. Além das métricas descritas anteriormente, as razões entre a largura dos dedos projetadas em cada vista também são consideradas. Como mostrado na Figura 4.10 as razões entre as larguras das vistas 1 (w_1) e 2 (w_2) em relação à vista 0 (w_0) podem ser utilizadas como um parâmetro discriminativo.

Uma vez que as métricas são apresentadas, o vetor de características \mathbf{X} é definido. Este vetor, que é a entrada para o classificador, é composto por 6 elementos, de x_1 a x_6 descrito como se segue:

$$\mathbf{X} = \begin{bmatrix} m_1/m_0 & m_2/m_0 & \sigma_1/\sigma_0 \\ \sigma_2/\sigma_0 & w_1/w_0 & w_2/w_0 \end{bmatrix} \quad (4.5)$$




Figura 4.10: Dedo projetado em diferentes vistas de uma amostra: (a) Projeção da Vista 0; (b) Projeção da Vista 1; e (c) Projeção da Vista 2. Razões entre as larguras das Vistas 1 e 2 em relação à Vista 0 também podem ser usadas como um parâmetro discriminativo no vetor de características.

4.5 DETALHES SOBRE O PROJETO E A IMPLEMENTAÇÃO DA RNA

Com intuito de detectar se o dedo está ou não devidamente posicionado durante a aquisição biométrica, uma Rede Neural Artificial é proposta. Como os dedos possuem características geométricas diferentes, classificadores específicos para cada dedo (polegares, indicadores, médios, anelares e mínimos) são propostos com intuito de maximizar os resultados da classificação e, ao final, um (melhor) classificador genérico, para qualquer dedo, também é apresentado. Todos os classificadores são do tipo *Perceptron* Multicamada [73] treinados com o algoritmo de *Levenberg-Marquardt* [66] com quatro camadas: (a) uma camada de entrada, onde nenhum cálculo é realizado; (b) duas camadas intermediárias; e (c) uma camada de saída. A primeira camada consiste simplesmente no vetor \mathbf{X} , definido na equação 4.5 e as camadas intermediárias e a camada de saída são definidas para cada caso (dedo específico).

Em nossos experimentos, dois cenários diferentes foram considerados. Em um primeiro cenário, o classificador apenas indica se existe um mal-posicionamento rotacional do dedo ou não. Em um segundo, caso o classificador tenha detectado mal-posicionamento rotacional, também detecta o ângulo de rotação (90° horário, 90° sentido anti-horário e 180°). Exceto para a camada de entrada, todos os neurônios têm a função de ativação Tangente Hiperbólica. Sabe-se que as redes neurais sem realimentação (*feedforward*) com apenas uma camada oculta podem aproximar satisfatoriamente qualquer função com um número finito de descontinuidades arbitrárias [74]. No entanto, após testes exaustivos, observamos em nossos experimentos que melhores desempenhos foram alcançados com duas camadas ocultas. O Algoritmo 1 demonstra o método utilizado para determinar o número de neurônios na primeira camada oculta das redes neurais propostas para cada classificador. Neste algoritmo é possível perceber que a segunda camada oculta possui sempre 15 neurônios, mas a quantidade de neurônios na primeira camada oculta poderia variar de 20 a 40. Quando um melhor resultado é atingido, a configuração da rede neural é armazenada em arquivo próprio. Destaca-se ainda que para a mesma quantidade de neurônios propostos na primeira camada, os conjuntos de treinamento, validação e teste eram redefinidos várias vezes.

Algoritmo 1: Procedimento para determinar o número de neurônios na primeira camada oculta de cada classificador específico.

```
DEFINE-NEURAL-NETWORK
1   $T = 80$  // True positive threshold.
2  while  $T \leq 90$ 
3       $i = 40$  // neurons on first hidden layer.
4      while  $i \geq 20$ 
5          CREATE( $net, i, 15$ )
              // 15 neurons on second hidden layer.
6          CONFIGURE( $net, inTrain, tgtTrain$ )
              //  $inTrain$  : train set inputs
              //  $tgtTrain$  : train set targets
7           $stop = 0$ 
8           $cont = 0$ 
9           $contMax = 50$ 
10         while NOT( $stop$ ) and  $cont \leq contMax$ 
11              $cont = cont + 1$ 
12             INITIALIZE( $net$ )
13             TRAIN( $net, inTrain, tgtTrain$ )
14             SIMULATE( $net, inTest, outTest$ )
                    //  $inTest$  : test set inputs
                    //  $outTest$  : simulated outputs
15             CONFMAT( $tgtTest, outTest, mat$ )
                    //  $tgtTest$  : test set targets
                    //  $mat$  : confusion matrix
16             if  $mat(allMainDiagElements) > T$ 
17                  $stop = 1$ 
18                 SAVE( $net, i, T$ )
19                  $i = i - 2$ 
20                  $T = T + 2$ ;
```

A partir daqui, o projeto e a arquitetura de cada classificador específico (cada dedo e geral) será apresentado em subseção própria. Destaca-se que por mais que algumas informações se repitam, escolheu-se fazer dessa forma para tornar a consulta e análise mais confortável para o leitor.

4.5.1 Arquitetura dos classificadores - Conjunto Comum

Por apresentarem grandes similaridades no projeto e para evitar redundância demasiada de informações, detalhes dos projetos dos dedos indicadores, médios, anelares e mínimos (chamados de Conjunto Comum) serão apresentados nesta seção.

O subconjunto de ensaio formados por imagens dos dedos indicadores é composto por 600 amostras: 200 (20 indivíduos, 2 dedos diferentes por indivíduo, 5 amostras por dedo) representando a classe de dedos não rotacionados e 400 (20 indivíduos, 2 dedos diferentes por indivíduo, 10 amostras por dedo) representando a classe de dedos rotacionados. Neste caso, cerca de 1/3 de cada classe foi distribuída entre o treinamento, validação e conjunto de teste. O conjunto de treinamento é usado para atualizar as sinapses e biases da rede, o

conjunto de validação é usado para monitorar o processo de formação e evitar super-ajuste. O conjunto de teste é utilizado para avaliar o desempenho da rede e não é utilizado durante o treinamento. O mesmo vale para os demais dedos do Conjunto Comum bem como para o polegar.

A Figura 4.11 apresenta a arquitetura geral das redes utilizadas em todos os classificadores do Conjunto Comum.

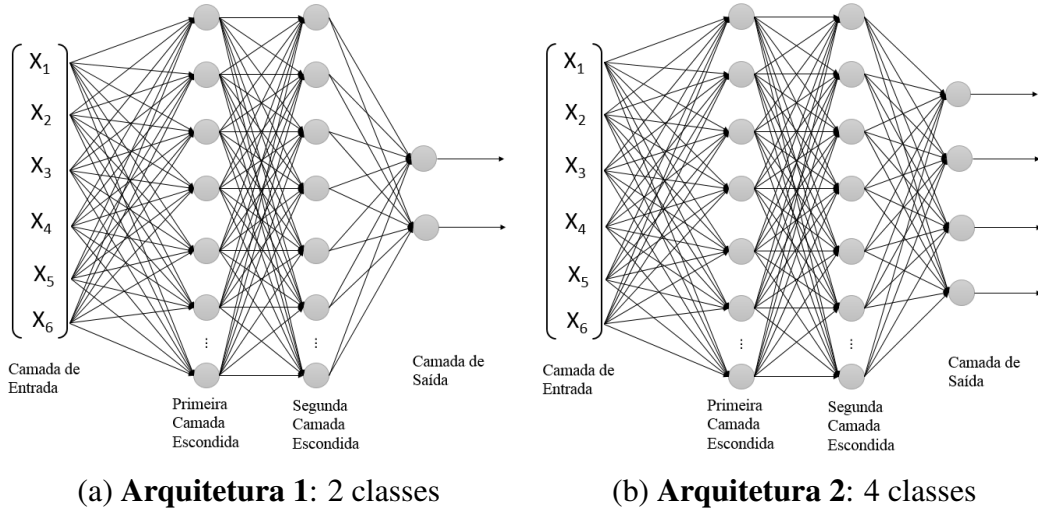


Figura 4.11: Arquitetura proposta para as redes neurais artificiais utilizadas: camada de entrada com 6 neurônios; primeira camada oculta com n neurônios; segunda camada oculta com 15 neurônios; e camada de saída com 2 neurônios (a) ou 4 neurônios (b). Todos os neurônios possuem como função de ativação a tangente hiperbólica.

Destaca-se que conforme apresentado no Algoritmo 1, o número n de neurônios, que formam a primeira camada, pode variar entre 20 e 40, dependendo do desempenho do classificador específico para cada dedo.

Como já mencionado anteriormente, nos experimentos realizados, dois cenários diferentes foram considerados. No primeiro cenário, o classificador indica apenas se o dedo está mal posicionado ou não. Neste caso, a camada de saída possui apenas dois neurônios (Figura 4.11 (a)) e um vetor de saída Φ_1 é associado com uma das duas classes possíveis (*rotacionado/não – rotacionado*), de acordo com a equação Eq. 4.6.

$$classe = \begin{cases} rotacionado, & se \Phi_1 = [1 \ 0]^t \\ não-rotacionado, & se \Phi_1 = [0 \ 1]^t \end{cases} \quad (4.6)$$

No segundo cenário, o classificador detecta o ângulo de rotação (180° , 90° SH, 90° SAH ou 0°). Neste caso, a camada de saída possui quatro neurônios (Figura 4.11 (b)) e um vetor de saída Φ_2 é associado com uma das quatro classes possíveis de acordo com a Equação 4.7.

$$\hat{angulo} = \begin{cases} 180^\circ, & se \ \Phi_2 = [1 \ 0 \ 0 \ 0]^t \\ 90 \text{ SH}, & se \ \Phi_2 = [0 \ 1 \ 0 \ 0]^t \\ 90 \text{ SAH}, & se \ \Phi_2 = [0 \ 0 \ 1 \ 0]^t \\ 0^\circ, & se \ \Phi_2 = [0 \ 0 \ 0 \ 1]^t \end{cases} \quad (4.7)$$

Algumas especificidades acerca dos classificadores de cada dedo do Conjunto Comum são apresentadas a seguir.

4.5.1.1 Especificidades do classificador para indicadores

Conforme justificado anteriormente, depois de testes exaustivos, as arquiteturas finais dos classificadores propostos para dedos indicadores são:

Cenário 1 - rotacionado X não-rotacionado: Rede neural com 6 neurônios na camada de entrada, 34 neurônios na primeira camada oculta, 15 neurônios na segunda camada oculta e 2 neurônios na camada de saída.

Cenário 2 - Ângulos de rotação: Rede neural com 6 neurônios na camada de entrada, 26 neurônios na primeira camada oculta, 15 neurônios na segunda camada oculta e 4 neurônios na camada de saída.

4.5.1.2 Especificidades do classificador para médios

As arquiteturas finais dos classificadores propostos para dedos médios que apresentaram os melhores resultados são:

Cenário 1 - Rotacionado x não-rotacionado: Rede neural com 6 neurônios na camada de entrada, 22 neurônios na primeira camada oculta, 15 neurônios na segunda camada oculta e 2 neurônios na camada de saída.

Cenário 2 - Ângulos de rotação: Rede neural com 6 neurônios na camada de entrada, 24 neurônios na primeira camada oculta, 15 neurônios na segunda camada oculta e 4 neurônios na camada de saída.

4.5.1.3 Especificidades do classificador para anelares

As arquiteturas finais dos classificadores propostos para dedos anelares que apresentaram os melhores resultados são:

Cenário 1 - Rotacionado x não-rotacionado: Rede neural com 6 neurônios na camada de entrada, 34 neurônios na primeira camada oculta, 15 neurônios na segunda camada oculta e 2 neurônios na camada de saída.

Cenário 2 - Ângulos de rotação: Rede neural com 6 neurônios na camada de entrada, 24 neurônios na primeira camada oculta, 15 neurônios na segunda camada oculta e 4 neurônios na camada de saída.

4.5.1.4 Especificidades do classificador para mínimos

As arquiteturas finais dos classificadores propostos para dedos mínimos que apresentaram os melhores resultados são:

Cenário 1 - Rotacionado X não-rotacionado: Rede neural com 6 neurônios na camada de entrada, 26 neurônios na primeira camada oculta, 15 neurônios na segunda camada oculta e 2 neurônios na camada de saída.

Cenário 2 - Ângulos de rotação: Rede neural com 6 neurônios na camada de entrada, 26 neurônios na primeira camada oculta, 15 neurônios na segunda camada oculta e 4 neurônios na camada de saída.

Um resumo das arquiteturas proposta para cada caso específico pode ser encontrado nas Tabelas 4.1 e 4.2.

Tabela 4.1: Sumarização das arquiteturas do Cenário 1 apresentando a quantidade de neurônios em cada camada da RNA

Conjunto Comum				
Cenário 1 - Rotacionado x não-rotacionado				
Arquitetura 1	Camada de Entrada	Primeira Camada Oculta	Segunda Camada Oculta	Camada de Saída
Indicadores	6	34	15	2
Médios	6	22	15	2
Anelares	6	34	15	2
Mínimos	6	26	15	2

Tabela 4.2: Sumarização das arquiteturas do Cenário 2 apresentando a quantidade de neurônios em cada camada da RNA

Conjunto Comum				
Cenário 2 - Ângulos de rotação				
Arquitetura 2	Camada de Entrada	Primeira Camada Oculta	Segunda Camada Oculta	Camada de Saída
Indicadores	6	26	15	4
Médios	6	24	15	4
Anelares	6	24	15	4
Mínimos	6	26	15	4

4.5.2 Arquitetura dos classificadores - Conjunto Especial

O Conjunto Especial diz respeito aos classificadores apenas de polegares e ao classificador geral. Existem dois motivos para essa separação: (1) polegares são dedos largamente utilizados para identificação biométrica e possuem característica geométrica diferente dos demais; e (2) caso não se saiba qual o dedo que está sendo inserido no dispositivo, um classificador geral deve ser utilizado.

Como esses casos são especiais, duas propostas diferentes de redes neurais foram testadas. Uma cuja arquitetura geral já foi apresentada e é semelhante às propostas para o Conjunto Comum (Figura 4.11) e outra mais simples e rápida definida a seguir.

A primeira e a segunda camadas ocultas têm 20 e 5 neurônios, respectivamente. A camada de saída tem um único neurônio. A arquitetura proposta é resumida na Figura 4.12.

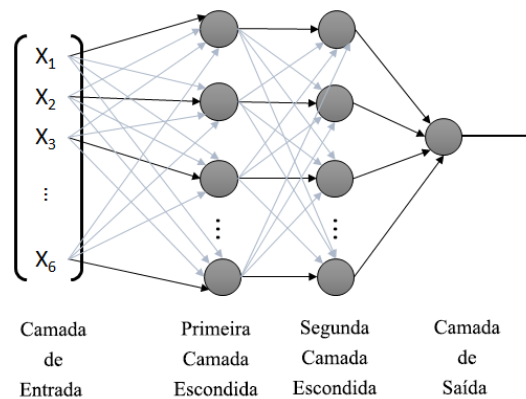


Figura 4.12: **Arquitetura 3** - Arquitetura proposta para a rede neural artificial utilizada: camada de entrada com 6 neurônios, de x_1 a x_6 ; primeira camada oculta com 20 neurônios; segunda camada oculta com 5 neurônios; e camada de saída com 1 neurônio. Todos os neurônios possuem como função de ativação a tangente hiperbólica.

No primeiro cenário, o neurônio da camada de saída retorna $T = -1$ (no caso de rotação) ou $T = 1$ (no caso de correto posicionamento). Quanto ao segundo cenário, os valores de saída são quantificados em um determinado ângulo de rotação α , de acordo com Eq. 4.8.

$$\alpha(T) = \begin{cases} 180^\circ, & \text{se } -1 \leq T \leq -0.65 \\ 90 \text{ SAH}, & \text{se } -0.65 < T \leq 0.05 \\ 90 \text{ SH}, & \text{se } 0.05 < T \leq 0.70 \\ 0^\circ \text{ (não-rotacionado)}, & \text{se } 0.70 < T \leq 1 \end{cases} \quad (4.8)$$

4.5.2.1 Especificidades do classificador geral

O conjunto de testes usado em nossos experimentos é composto por todas as amostras disponíveis: 1000 dedos não rotacionados (20 indivíduos, 10 dedos diferentes por indivíduo, cinco amostras por dedo) e 2.000 dedos rotacionados (20 indivíduos, 10 dedos diferentes por indivíduo, 10 amostras por dedo: todos os dedos rotacionados por 180°, e por 90° SH ou 90° SAH, dependendo de cada dedo). Cerca de 1/3 de cada classe, não-rotacionados e rotacionados (por 180°, 90° SH ou 90° SAH) foi utilizado para compor o conjunto de treinamento, validação e teste da rede neural.

Utilizando a rede neural de arquitetura similar a do Conjunto Comum (Figura 4.11), temos:

Cenário 1 - Rotacionado x não-rotacionado: Rede neural com 6 neurônios na camada de entrada, 30 neurônios na primeira camada oculta, 15 neurônios na segunda camada oculta e 2 neurônios na camada de saída.

Cenário 2 - Ângulos de rotação: Rede neural com 6 neurônios na camada de entrada, 28 neurônios na primeira camada oculta, 15 neurônios na segunda camada oculta e 4 neurônios na camada de saída.

Utilizando a rede neural simplificada (Figura 4.12), temos:

Ambos os cenários, 1 e 2, utilizam a mesma arquitetura que apresenta 6 neurônios na camada de entrada, 15 neurônios na primeira camada oculta, 5 neurônios na segunda camada oculta e 1 neurônio na camada de saída.

4.5.2.2 Especificidades do classificador para polegares

As arquiteturas finais dos classificadores propostos para dedos polegares que apresentaram os melhores resultados e utilizam rede neural similar ao Conjunto Comum são:

Cenário 1 - Rotacionado x não-rotacionado: Rede neural com 6 neurônios na camada de entrada, 26 neurônios na primeira camada oculta, 15 neurônios na segunda camada oculta e 2 neurônios na camada de saída.

Cenário 2 - Ângulos de rotação: Rede neural com 6 neurônios na camada de entrada, 20 neurônios na primeira camada oculta, 15 neurônios na segunda camada oculta e 4 neurônios na camada de saída.

Utilizando a rede neural simplificada (Figura 4.12), temos:

Ambos os cenários, 1 e 2, utilizam a mesma arquitetura que apresenta 6 neurônios na camada de entrada, 15 neurônios na primeira camada oculta, 5 neurônios na segunda camada oculta e 1 neurônio na camada de saída.

Tabela 4.3: Sumarização das arquiteturas do Cenário 1 apresentando a quantidade de neurônios em cada camada da RNA

Conjunto Especial				
Cenário 1 - Rotacionado x não-rotacionado				
Arquitetura 1	Camada de Entrada	Primeira Camada Oculta	Segunda Camada Oculta	Camada de Saída
Polegares	6	26	15	2
Geral	6	30	15	2

Tabela 4.4: Sumarização das arquiteturas do Cenário 2 apresentando a quantidade de neurônios em cada camada da RNA

Conjunto Especial				
Cenário 2 - Ângulos de rotação				
Arquitetura 2	Camada de Entrada	Primeira Camada Oculta	Segunda Camada Oculta	Camada de Saída
Polegares	6	26	15	4
Geral	6	20	15	4

Um sumarização das arquiteturas propostas para os classificadores do Conjunto Especial é apresentada em forma de tabelas. As Tabelas 4.3 e 4.4 apresentam a quantidade de neurônios em cada camada das redes neurais que utilizam as arquiteturas 1 e 2, também utilizadas pelo Conjunto Comum. A Tabela 4.5 apresenta a quantidade de neurônios em cada camada da rede neural específica para o Conjunto Especial. A partir desse ponto deve-se entender **Polegar*** e **Geral*** como sendo classificações de polegares e gerais realizadas pela **Arquitetura 3**, respectivamente.

Tabela 4.5: Sumarização das arquiteturas do Cenário 1 e 2 apresentando a quantidade de neurônios em cada camada da RNA

Conjunto Especial				
Cenário 1 e 2 - Rotacionado x não rotacionado e ângulos de rotação				
Arquitetura 3	Camada de Entrada	Primeira Camada Oculta	Segunda Camada Oculta	Camada de Saída
Polegares*	6	20	5	1
Geral*	6	20	5	1

4.6 MÉTRICAS UTILIZADAS NA ANÁLISE E GERAÇÃO DE RESULTADOS

Nesta seção, um resumo das técnicas e métricas utilizadas para apresentação dos resultados é apresentada. Em suma, utilizou-se matrizes de confusão e métricas derivadas para geração de resultados.

Matriz de confusão geral: A matriz de confusão de uma certa hipótese oferece uma forma efetiva de apresentação dos resultados gerados pelos classificadores propostos. Nesta matriz, encontra-se de forma explícita o número de classificações corretas *versus* o número de classificações incorretas.

Cada entrada da matriz é representada por elementos $E(C_i, C_j)$. Os índices i fazem referência as classes reais (verdadeira) (C_i) e os índices j fazem referência as classes preditas pelo classificador (C_j), conforme pode ser visto na Tabela 4.6. O número de acerto para cada classe se localiza na diagonal principal $E(C_i, C_i)$. Os demais elementos da matriz $E(C_i, C_j)$, $\forall (i \neq j)$, representam os erros cometidos pelo classificador. Conforme se observa na Equação (4.9), o somatório de todos os elementos da matriz de confusão resulta no total de elementos, N , da base de dados, utilizados para testar a rede neural proposta.

$$N = \sum_{i,j=1}^k E(C_i, C_j) \quad (4.9)$$

Tabela 4.6: Matriz de confusão genérica

Classe	Predita - C_1	Predita - C_2	...	Predita - C_k
Real - C_1	$E(C_1, C_1)$	$E(C_1, C_2)$...	$E(C_1, C_k)$
Real - C_2	$E(C_2, C_1)$	$E(C_2, C_2)$...	$E(C_2, C_k)$
\vdots	\vdots	\vdots	\ddots	
Real - C_k	$E(C_k, C_1)$	$E(C_k, C_2)$...	$E(C_k, C_k)$

Para calcular a taxa média relativa de acerto (precisão total ou *accuracy*) do classificador, utilizar-se-á a Equação (4.10) e, similarmente, para calcular a taxa média relativa de erro, a Equação (4.11) ou, alternativamente, a Equação (4.12).

$$TA_{rel} = \frac{\sum_{i=1}^k E(C_i, C_i)}{N} \quad (4.10)$$

$$TE_{rel} = \frac{\sum_{\forall(i \neq j): i,j=1}^k E(C_i, C_j)}{N} \quad (4.11)$$

Tabela 4.7: Matriz de confusão para duas classes

Classe	Predita - C_1	Predita - C_2
Real - C_1	T_p	F_n
Real - C_2	F_p	T_n

Tabela 4.8: Matriz de confusão com erro total associado

Classe	Predita - C_1	Predita - C_2	Taxa de Erro Total
Real - C_1	T_p	F_n	$\frac{F_p+F_n}{T_p+T_n+F_p+F_n}$
Real - C_2	F_p	T_n	

$$TE_{rel} = 1 - TA_{rel} \quad (4.12)$$

Matriz de confusão para duas classes: Ao avaliar a situação onde existem apenas duas classes (e.g., rotacionado ou não-rotacionado), a estrutura da matriz de confusão se apresenta de forma especial. Conforme podemos perceber na Tabela 4.7, é possível criar uma matriz simplificada que se limita a apresentar os verdadeiros positivos (T_p), verdadeiros negativos (T_n), falsos positivos (F_p) e falsos negativos (F_n). Na Seção 2.2, há uma explicação detalhada sobre esses termos. Neste trabalho as métricas supracitadas se distribuem da seguinte forma:

- T_p - Dedos rotacionados que foram classificados corretamente como rotacionados;
- T_n - Dedos não-rotacionados que foram classificados corretamente como não-rotacionados;
- F_p - Dedos não-rotacionados que foram classificados como rotacionados;
- F_n - Dedos rotacionados que foram classificados como não-rotacionados.

Por questão de simplicidade de análise, neste trabalho as matrizes de confusão de duas classes (rotacionado, não-rotacionado) serão apresentadas em conjunto com a taxa (percentual) de erro total do classificador, conforme pode se observar na Tabela 4.8.

A partir da matriz de confusão para duas classes (Tabela 4.7), algumas métricas derivadas relevantes para análise dos resultados serão extraídas. Considerando a hipótese h , que no caso proposto neste trabalho é a hipótese do dedo estar rotacionado dado que suas características discriminantes são definidas pelo vetor apresentado na Equação (4.5), é possível extrair as seguintes medidas: confiabilidade positiva $prel$ (*positive reliability* ou *precision*), confiabilidade negativa $nrel$ (*negative reliability*), suporte sup (*support*), sensibilidade $sens$ (*sensitivity* ou *recall*), especificidade $spec$ (*specificity*), precisão total $tacc$ (*total accuracy*), cobertura cov (*coverage*) e F -measure calculadas a partir das Equações (4.13) à (4.20), respectivamente [75].

$$prel(h) = \frac{T_p}{T_p + F_p} \quad (4.13)$$

$$nrel(h) = \frac{T_n}{T_n + F_n} \quad (4.14)$$

$$sup(h) = \frac{T_p}{T_p + T_n + F_p + F_n} \quad (4.15)$$

$$sens(h) = \frac{T_p}{T_p + F_n} \quad (4.16)$$

$$spec(h) = \frac{T_n}{T_n + F_p} \quad (4.17)$$

$$tacc(h) = \frac{T_p + T_n}{T_p + T_n + F_p + F_n} \quad (4.18)$$

$$cov(h) = \frac{T_p + F_p}{T_p + T_n + F_p + F_n} \quad (4.19)$$

$$F\text{-measure} = \frac{2}{\frac{1}{prel(h)} + \frac{1}{sens(h)}} \quad (4.20)$$

Os resultados contidos no Capítulo 5 apresentarão as matrizes de confusão e métricas supramencionadas para cada caso analisado. A análise comparativa completa pode ser encontrada na Seção 5.8.

5 RESULTADOS

Neste capítulo os resultados experimentais resultantes da metodologia proposta no Capítulo 4 são apresentados. As boas práticas para pesquisa em biometria demandam, entre outras coisas, que as matrizes de confusão, os falsos positivos, falsos negativos, verdadeiros positivos e verdadeiros negativos sejam apresentados de forma unívoca [76]. Neste sentido, para garantir um entendimento claro dos resultados, um detalhamento da estrutura e forma como serão divididos e explicados é apresentado.

5.1 VISÃO GERAL E ESTRUTURA DA APRESENTAÇÃO DOS RESULTADOS

Em consonância com a metodologia proposta e por haver classificadores com diferentes arquiteturas para avaliar a rotação de diferentes dedos das mãos, os testes e resultados foram divididos em categorias:

- **Categoria 1** - Rotacionado × Não-rotacionado: detecção de rotação de cada dedo (polegar, indicador, médio, anelar e mínimo) individualmente utilizando classificadores específicos;
- **Categoria 2** - Rotacionado × Não-rotacionado: detecção de rotação de todos os dedos utilizando um único (melhor) classificador geral.
- **Categoria 3** - Detecção do ângulo de rotação de cada dedo utilizando classificadores específicos; e
- **Categoria 4** - Detecção do ângulo de rotação de todos os dedos utilizando um único (melhor) classificador geral.

A base de dados utilizada, é uma base de dados construída segundo a metodologia apresentada na Seção 4.2. Como mencionado, trata-se de uma base com 3000 amostras, 9000 imagens.

Ressalta-se que nas Seções de 5.2 à 5.7, são apresentados individualmente os resultados de cada um dos classificadores e que a discussão e análise comparativa podem ser encontradas na Seção 5.8. A seguir os resultados são apresentados de acordo com a metodologia contida na Seção 4.6 que apresentou as métricas utilizadas para mensurar o desempenho dos classificadores.

5.2 RESULTADOS DA DETECÇÃO DE ROTAÇÃO DE INDICADORES

Nesta seção os resultados obtidos pelo classificador proposto para detectar a rotação dos dedos indicadores serão apresentados. Detalhes acerca da arquitetura e especificidades do classificador podem ser encontrados na Seção 4.5.

5.2.1 Rotacionado ou não-rotacionado

A Tabela 5.1 apresenta a matriz de confusão com os resultados (em termos percentuais) obtidos pelo classificador quando o intuito é detectar se há ou não rotação dos dedos indicadores posicionados no dispositivo. A Tabela 5.2 apresenta as métricas derivadas calculadas.

Tabela 5.1: Matriz de confusão rotacionado X não-rotacionado: indicadores

		Predito		Taxa de Erro
		Rot.	Não-rot.	Total
Real	Rotac.	98,00%	2,00%	1,33%
	Não-rot.	0,00%	100,00%	

Tabela 5.2: Métricas calculadas: indicadores

prel	nrel	sup	sens	spec	tacc	cov	F-measure
1,0000	0,9804	0,6600	0,9900	1,0000	0,9933	0,6600	0,9950

5.2.2 Estimação do ângulo

Os resultados do classificador proposto para detectar o ângulo de rotação (180° , $90^\circ SH$, $90^\circ SAH$ e 0°) dos dedos indicadores podem ser encontrados na matriz de confusão apresentada na Tabela 5.3. A taxa de acerto relativa (TA_{rel}) referente ao classificador cujos dados são apresentados na Tabela 5.3 é de 0,9900 e a taxa de erro relativa (TE_{rel}) é de 0,0100.

Tabela 5.3: Matriz de confusão de quatro classes: indicadores

Classe		Predito			
		180 rot.	90 SH rot.	90 SAH rot.	Não-rot.
Real	180 rot.	98,50%	0,50%	0,00%	1,00%
	90 SH rot.	0,00%	99,00%	1,00%	0,00%
	90 SAH rot.	0,00%	0,00%	99,00%	1,00%
	Não-rot.	0,50%	0,00%	0,00%	99,50%

5.3 RESULTADOS DA DETECÇÃO DE ROTAÇÃO DE MÉDIOS

Nesta seção os resultados obtidos pelo classificador proposto para detectar a rotação dos dedos médios serão apresentados. Detalhes acerca da arquitetura e especificidades do classificador podem ser encontrados na Seção 4.5.

5.3.1 Rotacionado ou não-rotacionado

A Tabela 5.4 apresenta a matriz de confusão com os resultados (em termos percentuais) obtidos pelo classificador quando o intuito é detectar se há ou não rotação dos dedos indicadores posicionados no dispositivo. A Tabela 5.5 apresenta as métricas derivadas calculadas.

Tabela 5.4: Matriz de confusão rotacionado X não-rotacionado: médios

	Predito			Taxa de Erro
		Rot.	Não-rot.	Total
Real	Rot.	99,75%	0,25%	0,50%
	Não-rot.	1,00%	99,00%	

Tabela 5.5: Métricas calculadas: médios

prel	nrel	sup	sens	spec	tacc	cov	F-measure
0,9950	0,9950	0,6650	0,9975	0,9900	0,9950	0,6683	0,9963

5.3.2 Estimação do ângulo

Os resultados do classificador proposto para detectar o ângulo de rotação (180° , $90^\circ SH$, $90^\circ SAH$ e 0°) dos dedos médios podem ser encontrados na matriz de confusão apresentada na Tabela 5.6. A taxa de acerto relativa (TA_{rel}) referente ao classificador cujos dados são apresentados na Tabela 5.6 é de 0,9933 e a taxa de erro relativa (TE_{rel}) é de 0,0067.

Tabela 5.6: Matriz de confusão de quatro classes: médios

Classe		Predito			
		180 rot.	90 SH rot.	90 SAH rot.	Não-rot.
Real	180 rot.	99,50%	0,00%	0,00%	0,50%
	90 SH rot.	0,00%	100,00%	0,00%	0,00%
	90 SAH rot.	0,00%	0,00%	100,00%	0,00%
	Não-rot.	1,50%	0,00%	0,00%	98,50%

5.4 RESULTADOS DA DETECÇÃO DE ROTAÇÃO DE ANELARES

Nesta seção os resultados obtidos pelo classificador proposto para detectar a rotação dos dedos anelares serão apresentados. Detalhes acerca da arquitetura e especificidades do classificador podem ser encontrados na Seção 4.5.

5.4.1 Rotacionado ou não-rotacionado

A Tabela 5.7 apresenta a matriz de confusão com os resultados (em termos percentuais) obtidos pelo classificador quando o intuito é detectar se há ou não rotação dos dedos indicadores posicionados no dispositivo. A Tabela 5.8 apresenta as métricas derivadas calculadas.

Tabela 5.7: Matriz de confusão rotacionado X não-rotacionado: anelares

	Predito			Taxa de Erro
		Rot.	Não-rot.	Total
Real	Rot.	98,75%	1,25%	1,00%
	Não-rot.	0,50%	99,50%	

Tabela 5.8: Métricas calculadas: anelares

prel	nrel	sup	sens	spec	tacc	cov	F-measure
0,9975	0,9755	0,6583	0,9875	0,9950	0,9900	0,6600	0,9925

5.4.2 Estimação do ângulo

Os resultados do classificador proposto para detectar o ângulo de rotação (180° , $90^\circ SH$, $90^\circ SAH$ e 0°) dos dedos anelares podem ser encontrados na matriz de confusão apresentada na Tabela 5.9. A taxa de acerto relativa (TA_{rel}) referente ao classificador cujos dados são apresentados na Tabela 5.9 é de 0,9850 e a taxa de erro relativa (TE_{rel}) é de 0,0150.

Tabela 5.9: Matriz de confusão de quatro classes: anelares

Classe		Predito			
		180 rot.	90 SH rot.	90 SAH rot.	Não-rot.
Real	180 rot.	97,50%	0,00%	0,00%	2,50%
	90 SH rot.	0,00%	100,00%	0,00%	0,00%
	90 SAH rot.	0,00%	0,00%	100,00%	0,00%
	Não-rot.	2,00%	0,00%	0,00%	98,00%

5.5 RESULTADOS DA DETECÇÃO DE ROTAÇÃO DE MÍNIMOS

Nesta seção os resultados obtidos pelo classificador proposto para detectar a rotação dos dedos mínimos serão apresentados. Detalhes acerca da arquitetura e especificidades do classificador podem ser encontrados na Seção 4.5.

5.5.1 Rotacionado ou não-rotacionado

A Tabela 5.10 apresenta a matriz de confusão com os resultados (em termos percentuais) obtidos pelo classificador quando o intuito é detectar se há ou não rotação dos dedos indicadores posicionados no dispositivo. A Tabela 5.11 apresenta as métricas derivadas calculadas.

Tabela 5.10: Matriz de confusão rotacionado X não-rotacionado: mínimos

	Predito			Taxa de Erro
		Rot.	Não-rot.	Total
Real	Rot.	98,00%	2,00%	2,33%
	Não-rot.	3,00%	97,00%	

Tabela 5.11: Métricas calculadas: mínimos

prel	nrel	sup	sens	spec	tacc	cov	F-measure
0,9849	0,9604	0,6583	0,9800	0,9700	0,9767	0,6633	0,9825

5.5.2 Estimação do ângulo

Os resultados do classificador proposto para detectar o ângulo de rotação (180° , $90^\circ SH$, $90^\circ SAH$ e 0°) dos dedos mínimos podem ser encontrados na matriz de confusão apresentada na Tabela 5.12. A taxa de acerto relativa (TA_{rel}) referente ao classificador cujos dados são apresentados na Tabela 5.12 é de 0,9733 e a taxa de erro relativa (TE_{rel}) é de 0,0267.

Tabela 5.12: Matriz de confusão de quatro classes: mínimos

Classe		Predito			
		180 rot.	90 SH rot.	90 SAH rot.	Não-rot.
Real	180 rot.	97,50%	0,00%	0,00%	2,50%
	90 SH rot.	0,00%	98,00%	2,00%	0,00%
	90 SAH rot.	0,00%	2,00%	98,00%	0,00%
	Não-rot.	3,50%	0,00%	0,00%	96,50%

5.6 RESULTADOS DA DETECÇÃO DE ROTAÇÃO DE POLEGARES

Nesta seção os resultados obtidos pelo classificador proposto para detectar a rotação dos dedos polegares serão apresentados. Detalhes acerca da arquitetura e especificidades do classificador podem ser encontrados na Seção 4.5. Destaca-se que aqui duas abordagens diferentes foram exploradas conforme pode ser observado na Seção 4.5.2 do Capítulo 4. Fica definida a seguinte nomenclatura: **polegar** - classificador do Conjunto Comum (Figura 4.11 (a) e (b)); **polegar*** - classificador específico do Conjunto Especial (Figura 4.12));

5.6.1 Rotacionado ou não-rotacionado

A Tabela 5.13 apresenta a matriz de confusão com os resultados (em termos percentuais) obtidos pelo classificador do Conjunto Comum quando o intuito é detectar se há ou não rotação dos dedos polegares posicionados no dispositivo e a Tabela 5.15 dos os resultados do classificador do Conjunto Especial.

As Tabelas 5.14 e 5.16 apresentam as métricas derivadas calculadas para o classificador do Conjunto Comum e para o classificador do Conjunto Especial, respectivamente.

Tabela 5.13: Matriz de confusão rotacionado X não-rotacionado: polegares

	Predito			Taxa de Erro
		Rot.	Não-rot.	Total
Real	Rot.	99,00%	1,00%	0,67%
	Não-rot.	0,00%	100,00%	

Tabela 5.14: Métricas calculadas: polegares

prel	nrel	sup	sens	spec	tacc	cov	F-measure
1,0000	0,9804	0,6600	0,9900	1,0000	0,9933	0,6600	0,9950

Tabela 5.15: Matriz de confusão rotacionado X não-rotacionado: polegares*

	Predito			Taxa de Erro
		Rot.	Não-rot.	Total
Real	Rot.	97,25%	2,75%	3,00%
	Não-rot.	3,50%	96,50%	

Tabela 5.16: Métricas calculadas: polegares*

prel	nrel	sup	sens	spec	tacc	cov	F-measure
0,9823	0,9461	0,6600	0,9725	0,9650	0,9700	0,6600	0,9774

5.6.2 Estimação do ângulo

Os resultados dos classificadores propostos para detectar o ângulo de rotação (180° , $90^\circ SH$, $90^\circ SAH$ e 0°) dos dedos polegares podem ser encontrados nas matrizes de confusão apresentadas nas Tabelas 5.17 e 5.18. As taxas de acerto relativas (TA_{rel}) referentes ao classificadores cujos dados são apresentados nas Tabela 5.17 e 5.18 são de 0,9850 e 0,9283, respectivamente. As taxas de erros relativas (TE_{rel}) são de 0,0150 e 0,0717, também, respectivamente.

Tabela 5.17: Matriz de confusão de quatro classes: polegares

Classe		Predito			
		180 rot.	90 SH rot.	90 SAH rot.	Não-rot.
Real	180 rot.	97,00%	1,50%	0,00%	1,50%
	90 SH rot.	0,00%	100,00%	0,00%	0,00%
	90 SAH rot.	2,00%	0,00%	98,00%	0,00%
	Não-rot.	0,50%	0,00%	0,00%	99,50%

Tabela 5.18: Matriz de confusão de quatro classes: polegares*

Classe		Predito			
		180 rot.	90 SH rot.	90 SAH rot.	Não-rot.
Real	180 rot.	86,00%	7,00%	3,50%	3,50%
	90 SH rot.	0,00%	97,00%	3,00%	0,00%
	90 SAH rot.	0,00%	0,00%	100,00%	0,00%
	Não-rot.	3,00%	2,50%	0,50%	94,00%

5.7 RESULTADOS DA DETECÇÃO DE ROTAÇÃO GERAL

Nesta seção os resultados obtidos pelo classificador proposto para detectar a rotação de todos os dedos serão apresentados. Detalhes acerca da arquitetura e especificidades do classificador podem ser encontrados na Seção 4.5. Destaca-se que aqui duas abordagens diferentes foram exploradas conforme pode ser observado na Seção 4.5.2 do Capítulo 4. Fica definida a seguinte nomenclatura: **geral** - classificador do Conjunto Comum (Figura 4.11 (a) e (b)); **geral*** - classificador específico do Conjunto Especial (Figura 4.12));

5.7.1 Rotacionado ou não-rotacionado

A Tabela 5.19 apresenta a matriz de confusão com os resultados (em termos percentuais) obtidos pelo classificador do Conjunto Comum quando o intuito é detectar se há ou não rotação dos dedos polegares posicionados no dispositivo e a Tabela 5.21 dos os resultados do classificador do Conjunto Especial.

As Tabelas 5.20 e 5.22 apresentam as métricas derivadas calculadas para o classificador do Conjunto Comum e para o classificador do Conjunto Especial, respectivamente.

Tabela 5.19: Matriz de confusão rotacionado X não-rotacionado: geral

	Predito		Taxa de Erro
	Rot.	Não-rot.	Total
Real	Rot.	96,40%	3,60%
	Não-rot.	3,60%	96,40%
			3,60%

Tabela 5.20: Métricas calculadas: geral

prel	nrel	sup	sens	spec	tacc	cov	F-measure
0,9817	0,9305	0,6427	0,9640	0,9640	0,9640	0,6547	0,9728

Tabela 5.21: Matriz de confusão rotacionado X não-rotacionado: geral*

	Predito		Taxa de Erro
	Rot.	Não-rot.	Total
Real	Rot.	93,00%	7,00%
	Não-rot.	13,10%	86,90%
			3,60%

Tabela 5.22: Métricas calculadas: geral*

prel	nrel	sup	sens	spec	tacc	cov	F-measure
0,9342	0,8612	0,6200	0,9300	0,8690	0,9097	0,6637	0,9321

5.7.2 Estimação do ângulo

Os resultados dos classificadores propostos para detectar o ângulo de rotação (180° , $90^\circ SH$, $90^\circ SAH$ e 0°) dos dedos polegares podem ser encontrados nas matrizes de confusão apresentadas nas Tabelas 5.23 e 5.24. As taxas de acerto relativas (TA_{rel}) referentes ao classificadores cujos dados são apresentados nas Tabela 5.23 e 5.24 são de 0,9497 e 0,8890, respectivamente. As taxas de erros relativas (TE_{rel}) são de 0,0503 e 0,1110, também, respectivamente.

Tabela 5.23: Matriz de confusão de quatros classes: geral

Classe		Predito			
		180 rot.	90 SH rot.	90 SAH rot.	Não-rot.
Real	180 rot.	94,50%	0,70%	0,60%	4,20%
	90 SH rot.	1,20%	95,60%	1,60%	1,60%
	90 SAH rot.	1,00%	1,60%	96,60%	0,80%
	Não-rot.	5,70%	0,00%	0,00%	94,30%

Tabela 5.24: Matriz de confusão de quatros classes: geral*

Classe		Predito			
		180 rot.	90 SH rot.	90 SAH rot.	Não-rot.
Real	180 rot.	86,00%	3,40%	0,90%	9,70%
	90 SH rot.	4,40%	94,40%	0,40%	0,80%
	90 SAH rot.	7,40%	1,60%	89,40%	1,60%
	Não-rot.	10,30%	0,50%	0,40%	88,80%

5.8 DISCUSSÃO DOS RESULTADOS E ANÁLISE COMPARATIVA

Até o momento, foram apresentados os resultados obtidos individualmente para cada dedo e classificador. Nesta seção, uma análise comparativa entre os resultados obtidos é realizada.

A Tabela 5.25, que diz respeito aos resultados dos classificadores propostos para detectar a rotação de dedos (rotacionado X não-rotacionado), apresenta os resultados das métricas confiabilidade positiva (*prel*), confiabilidade negativa (*nrel*), suporte (*sup*), sensibilidade (*sens*), especificidade (*spec*), precisão total (*tacc*), cobertura (*cov*) e *F-measure*. Nesta tabela a primeira coluna contém todos os cenários estudados e a primeira linha todas as métricas calculadas. Em negrito destacam-se os melhores resultados para cada uma dessas métricas. Observando os dados apresentados, algumas evidências merecem destaque:

Tabela 5.25: Tabela comparativa de todos os classificadores propostos: rotacionado X não-rotacionado

	prel	nrel	sup	sens	spec	tacc	cov	F-measure
Polegar	1,0000	0,9804	0,6600	0,9900	1,0000	0,9933	0,6600	0,9950
Polegar*	0,9823	0,9461	0,6600	0,9725	0,9650	0,9700	0,6600	0,9774
Indicador	1,0000	0,9615	0,6533	0,9800	1,0000	0,9867	0,6533	0,9899
Médio	0,9950	0,9950	0,6650	0,9975	0,9900	0,9950	0,6683	0,9963
Anelar	0,9975	0,9755	0,6583	0,9875	0,9950	0,9900	0,6600	0,9925
Mínimo	0,9849	0,9604	0,6533	0,9800	0,9700	0,9767	0,6633	0,9825
Geral	0,9817	0,9305	0,6427	0,9640	0,9640	0,9640	0,6547	0,9728
Geral*	0,9810	0,8612	0,6403	0,9300	0,9602	0,9394	0,6527	0,9548

Os dedos que apresentam o maior resultado para *confiabilidade positiva* são os polegares e indicadores. Isso significa que os classificadores propostos são os melhores no que tange à capacidade de predição de dedos rotacionados. Vale destacar que ambos os dedos são os mais utilizados em leitores biométricos convencionais e, que portanto, são mais relevantes. O resultado é taxativo, uma vez que $prel = 1$ significa que o classificador acertou todos os casos em que indicou a rotação de dedos.

O dedo que apresenta o maior resultado para *confiabilidade negativa* é o médio. Isso significa que o classificador proposto é o melhor no que tange à capacidade de predição de dedos não rotacionados. Conforme pode ser observado $nrel = 0,9950$ o que significa que o classificador acertou 99,50% das vezes que indicou a não-rotação de dedos.

A *sensibilidade* ($sens = 0,9975$) e a *precisão total* ($tacc = 0,9950$) do classificador proposto para os dedos médios apresentam os melhores resultados. Isso significa que o classificador é o melhor para: (a) classificar corretamente dedos cuja amostra real é rotacionada e (b) classificar corretamente, independentemente do fato da amostra real estar rotacionada

ou não. Destaca-se que a precisão total dos polegares ($tacc = 0,9933$) obteve valor muito próximo, digno de nota.

A os valores de *especificidade* dos classificadores de polegares e indicadores apresentaram os melhores resultados. Isso significa que o classificador é o melhor no que tange a capacidade de classificar corretamente amostras reais não rotacionadas. Em verdade, $spec = 1$ significa que o classificador indicou corretamente a classe de todas as amostras reais não rotacionadas.

O *suporte* é uma métrica que apresenta, em termos proporcionas, a quantidade de T_p (dedos rotacionados que foram detectados como rotacionados) em relação ao total de amostras do subconjunto de teste. Também neste caso o classificador proposto para dedos médios apresentou o melhor resultado, $sup = 0,6650$.

A *cobertura* apresenta a proporção de predições de dedos rotacionados diante da quantidade total de elementos do subconjunto de teste. O classificador que mais detectou, em termos relativos, rotações de dedos também foi o classificador proposto para os dedos médios, $cov = 0,6683$.

A *F-measure*, por apresentar a média harmônica da *confiabilidade positiva* com a *sensitividade*, oferece um único número que concatena a ideia do quão certa é a predição do classificador quando indica que um dedo está rotacionado com a medida da quantidade total de indicações acertadas levando em conta o total de classificações. A *F-measure*, no contexto deste trabalho, é a medida mais relevante vinculada aos classificadores. Destaca-se que o classificador de rotação de dedos médios apresentou o melhor resultado ($0,9963$), mas que o classificador de polegares obteve resultado muito próximo ($0,9950$).

De todos os dedos do chamado Conjunto Comum, os dedos mínimos apresentam, em geral, os piores resultados. Provavelmente isso ocorre devido à suas características geométricas. Em outras palavras, o dedo mínimo apresenta forma mais cilíndrica e menos achatada, o que faz com que a classificação, que tira vantagem do fato do dedo ser achatado, obtenha piores resultados.

Classificadores gerais, propostos para classificar todos os dedos, apresentam os piores resultados. Em verdade, apresenta resultados até mesmo inferiores aos dedos mínimos.

Os classificadores específicos/simplificados propostos para o chamado Conjunto Especial apresentaram resultados substancialmente inferiores. Um exemplo disso pode ser visto quando comparamos a *confiabilidade negativa* do classificador geral ($nrel = 0,9305$) com a do classificador geral* ($nrel = 0,8612$).

O classificador genérico utilizado para detectar a rotação de todos os dedos, independentemente do tipo, apresentou $F-measure = 0,9728$ e $tacc = 0,9640$, o que mostra que mesmo na situação na qual não se sabe qual dedo está sendo inserido no dispositivo de captura, o classificador proposto oferece boa capacidade discriminativa, o que corrobora a

eficiência do método proposto neste trabalho para detecção da rotação de dedos. Com isso, encerra-se a análise dos dados referentes a classificação entre rotacionados X não rotacionados.

Analisando agora o caso no qual se deseja não apenas detectar a rotação, mas também estimar o ângulo (180° , $90^\circ SH$, $90^\circ SAH$ e 0°) temos novos resultados. Na Tabela 5.26, é possível encontrar as taxas de acerto e erro relativos dos classificadores propostos para detecção dos ângulos de rotação.

Tabela 5.26: Tabela comparativa de todos os classificadores propostos: quatro classes

	TA_{rel}	TE_{rel}
Polegar	0,9850	0,0150
Polegar*	0,9283	0,0717
Indicador	0,9900	0,0100
Médio	0,9933	0,0067
Anelar	0,9850	0,0150
Mínimo	0,9733	0,0267
Geral	0,9497	0,0503
Geral*	0,8890	0,1110

Resultados detalhados acerca das taxas de acerto e erro particulares de cada classe já foram apresentadas. Neste momento, resta uma pequena comparação onde destaca-se os seguintes fatos:

O classificador que apresentou a maior taxa de acerto relativo, $TA_{rel} = 0,9933$, foi o proposto para detectar o ângulo de rotação de dedos médios.

De todos os dedos analisados individualmente, o classificador que apresentou o pior resultado, $TA_{rel} = 0,9733$, foi utilizado para detectar o ângulo de rotação dos dedos mínimos. Mais uma vez, as características geométricas deste dedo particular influenciaram o resultado.

O classificador geral proposto para detectar o ângulo de rotação de qualquer dedo, vislumbrando uma situação onde não se sabe qual dedo está inserido no dispositivo *a priori*, apresentou taxa de acerto relativa, $TA_{rel} = 0,9497$. Destaca-se que esta taxa de acerto foi substancialmente inferior à taxa de acerto do pior classificador individual (dedos mínimos), o que indica que deve-se optar por classificadores específicos para cada dedo sempre que possível quando o objetivo é estimar o ângulo de rotação.

Por fim, é possível observar no gráfico de barras representado na Figura 5.1 as taxas percentuais de acertos de todos os classificadores, seja quando o classificador detecta a rotação corretamente (verdadeiros positivos), seja quando detecta corretamente dedos não rotacionados (verdadeiros negativos). No gráfico representado na Figura 5.2 é possível encontrar os resultados percentuais de acerto de todos os classificadores propostos para detectar os quatro possíveis ângulos de rotação.




Figura 5.1: Gráfico que apresenta as detecções corretas realizadas pelos classificadores propostos para detectar a rotação de dedos. Os verdadeiros positivos são detecções corretas de dedos rotacionados e verdadeiros negativos são detecções corretas de dedos não rotacionados.




Figura 5.2: Gráfico que apresenta as detecções corretas realizadas por todos os classificadores propostos para detectar os ângulos de rotação dos dedos.

Após analisar cuidadosamente todos os resultados, cabe realizar um último destaque. Os resultados vinculados aos polegares, indicadores e médios, apresentam taxas de acerto muito próximas, ao nível de não se poder afirmar categoricamente qual é o melhor dos três classificadores. No nível diminuto em que se apresentam, essas diferenças podem ser atribuídas à ruído imprevisível. No entanto, fica claro que o método proposto apresenta melhores resultados para os três tipos de dedos supracitados e piores resultados para dedos anelares e mínimos. Essa diferença, a princípio, não se dá por questão de ruído, mas sim por características geométricas dos dedos que tornam os resultados explicitamente piores para esses dois tipos de dedos. É interessante frisar, que os dedos mais utilizados para reconhecimento biométrico são exatamente aqueles para os quais os classificadores propostos apresentam melhores resultados, o que valoriza o método proposto neste trabalho como solução para detecção do mal-posicionamento dos dedos em dispositivos de captura de impressões digitais multivista sem toque.

6 CONCLUSÕES E TRABALHOS FUTUROS

Os métodos para avaliação da qualidade de impressões digitais tradicionalmente utilizados em sistemas com toque, que demandam o contato entre o dedo do usuário e o dispositivo de captura, propostos pelo NIST, não podem ser totalmente estendidos e aplicados para sistemas de impressão digital multivista sem toque. Os sistemas sem contato têm características específicas que devem ser consideradas para se estabelecer uma avaliação adequada da qualidade da impressão digital. O fator mais importante que se deve considerar é em relação à completa ausência de uma superfície de contato, permitindo com que durante o processo de captura o dedo do usuário possua maior grau de liberdade de movimentação.

Este trabalho apresentou uma método baseado na utilização de redes neurais artificiais do tipo MLP, que permite a detecção do mal-posicionamento dos dedos no momento de captura das impressões digitais para sistemas multivistas sem toque. A ideia principal desta proposta concentra-se na definição de um ponto de partida para que metodologias de avaliação da qualidade de impressões digitais para este tipo de sistema possam ser formalizadas.

Os resultados obtidos pelo método proposto neste trabalho alcançaram os seus objetivos, permitindo que fosse detectado, em média, o mal-posicionamento dos dedos em 98,50% dos casos e, detectado o mal-posicionamento, o ângulo de rotação fosse estimado, em média, corretamente em 95,25% dos casos. Os ângulos de rotação foram estimados e agrupados em quatro classes: (a) não-rotacionado; (b) 90° SH (sentido horário); (c) 90° SAH (sentido anti-horário); e (d) rotacionado em 180°.

Os testes realizados utilizaram uma base de dados construída (inérita) de 9000 imagens para treinar, validar e testar o classificador proposto. Essa base é constituída de imagens de dedos obtidas por um dispositivo de captura de impressões digitais multivista sem toque. A base contém imagens heterogêneas com as mais variadas características de iluminação, translação, borramento e contraste, uma vez que não houve tentativa de controlar o usuário no momento da aquisição das imagens. Sendo assim, ficou demonstrado que a metodologia proposta é robusta e capaz de lidar com situações complexas uma vez que estes fatores implicam diretamente na qualidade da imagem capturada e tendem a dificultar o desempenho do classificador.

Como a base de dados contém imagens de todos os tipos de dedos da mão (polegares, indicadores, médio, anelares e mínimos) classificadores específicos para cada um dos tipos de dedos foram propostos, bem como único classificador geral. Os resultados mostram que os classificadores específicos, para cada tipo de dedo, possuem desempenho substancialmente superior ao classificador geral. Isso indica que se o sistema conhece qual é o tipo de dedo que está sendo inserido no dispositivo deve, portanto, optar pelo classificador específico para este tipo de dedo. Destaca-se ainda que por suas características geométricas mais discriminativas

os polegares, indicadores e médios podem ter a rotação detectada com maior facilidade pelo classificador do que os anelares e mínimos.

Em trabalhos futuros serão incluídos estudos de características complementares que permitam uma distinção mais refinada de detecção dos ângulos de rotação das imagens capturadas por este tipo de sensor. Além disso, outras métricas de qualidade podem ser consideradas e suas correlações com o mal-posicionamento rotacional dos dedos podem ser investigadas.

Por fim, um método completo para avaliação da qualidade de impressões digitais obtidas a partir de dispositivos de captura de impressões digitais multivista sem toque pode ser proposto. Esse método definitivo pode levar em consideração diversos fatores como por exemplo: detecção de área útil; detecção de iluminação inadequada; detecção de saturação; detecção de borramento; detecção de serrilhamento; criação do mapa de qualidade de minúcias; e outros. O interessante é perceber que para analisar qualquer um desses fatores, primeiro é necessário garantir que o dedo foi posicionado corretamente dentro do dispositivo e é neste momento que esse trabalho estabelece sua importância na literatura uma vez que definiu o problema do mal-posicionamento, criou uma base de dados de referência e apresentou um método para correção da orientação inadequada e detecção da rotação de dedos dando, assim, o primeiro passo para que outros trabalhos possam ser realizados na área.

REFERÊNCIAS BIBLIOGRÁFICAS

- [1] J. Wayman. A definition of biometrics. In *National Biometric Test Center Colected Works 1997-2000*. San Jose State University, 2000.
- [2] V. Piuri and F. Scotti. Fingerprint biometrics via low-cost sensors and webcams. In *Biometrics: Theory, Applications and Systems, 2008. BTAS 2008. 2nd IEEE International Conference on*, pages 1–6, 29 2008-oct. 1 2008.
- [3] A. Kumar and C. Kwong. Towards contactless, low-cost and accurate 3d fingerprint identification. In *Computer Vision and Pattern Recognition (CVPR), 2013 IEEE Conference on*, pages 3438–3443, June 2013.
- [4] R. Khanna and Weicheng Shen. Automated fingerprint identification system (afis) benchmarking using the national institute of standards and technology (nist) special database 4. In *Security Technology, 1994. Proceedings. Institute of Electrical and Electronics Engineers 28th Annual 1994 International Carnahan Conference on*, pages 188–194, Oct 1994.
- [5] S. Pankanti, S. Prabhakar, and A.K. Jain. On the individuality of fingerprints. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 24(8):1010–1025, Aug 2002.
- [6] C. Zaghetto, A. Zaghetto, F. De B Vidal, and L.H.M. Aguiar. Touchless multiview fingerprint quality assessment: rotational bad-positioning detection using artificial neural networks. In *Biometrics (ICB), 2015 International Conference on*, pages 394–399, May 2015.
- [7] Cauê Zaghetto, Luiz Henrique M Aguiar, Alexandre Zaghetto, and Flávio de Barros Vidal. Projeto e implementação de uma rede neural artificial para detecção do mal-posicionamento rotacional de dedos em dispositivos de captura de impressões digitais multivista sem toque. 2015.
- [8] N. K. Ratha and Venu Govindaraju. *Advances in Biometrics: Sensors, Algorithms and Systems*. Springer-Verlag London, 1 edition, 2008.
- [9] Arun Ross and Anil K Jain. Human recognition using biometrics: an overview. In *Annales Des Télécommunications*, volume 62, pages 11–35. Springer, 2007.
- [10] Samuel Alfonso Delgado Caballero. *Papiloscopia - Certeza ou duvida*. MILLENNIUM, 1 edition, 2012.

- [11] A. K. Jain and S. Pankanti. Automated fingerprint identification and imaging systems. In H. C. Lee and R. E. Gaensslen, editors, *Advances in Fingerprint Technology*, chapter 8. CRC Press, Boca Raton, 2nd edition, 2001.
- [12] Charles L Wilson, R Austin Hicklin, Horold Korves, Bradford Ulery, Melissa Zoepfl, Mike Bone, Patrick J Grother, Ross J Micheals, Steve Otto, Craig I Watson, et al. *Fingerprint vendor technology evaluation 2003: Summary of results and analysis report*. US Department of Commerce, National Institute of Standards and Technology, 2004.
- [13] Dario Maio, Davide Maltoni, Raffaele Cappelli, JimL. Wayman, and AnilK. Jain. Fvc2004: Third fingerprint verification competition. In David Zhang and AnilK. Jain, editors, *Biometric Authentication*, volume 3072 of *Lecture Notes in Computer Science*, pages 1–7. Springer Berlin Heidelberg, 2004.
- [14] V.S. Nalwa. Automatic on-line signature verification. *Proceedings of the IEEE*, 85(2):215–239, Feb 1997.
- [15] L.L. Lee, T. Berger, and E. Aviczer. Reliable online human signature verification systems. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 18(6):643–647, Jun 1996.
- [16] W.R. Harrison. *Suspect Documents: Their Scientific Examination*. Nelson-Hall Publishers, 1 edition, 1981.
- [17] Simon Haykin. *Redes Neurais - Principios e Praticas*. Bookman, 2 edition, 2001.
- [18] Paul Viola and Michael J Jones. Robust real-time face detection. *International journal of computer vision*, 57(2):137–154, 2004.
- [19] Matthew Turk and Alex Pentland. Eigenfaces for recognition. *J. Cognitive Neuroscience*, 3(1):71–86, January 1991.
- [20] F.Z. Chelali, A. Djeradi, and R. Djeradi. Linear discriminant analysis for face recognition. In *Multimedia Computing and Systems, 2009. ICMCS '09. International Conference on*, pages 1–10, April 2009.
- [21] L. Wiskott, J.-M. Fellous, Norbert Kruger, and C. von der Malsburg. Face recognition by elastic bunch graph matching. In *Image Processing, 1997. Proceedings., International Conference on*, volume 1, pages 129–132 vol.1, Oct 1997.
- [22] Joseph P Campbell Jr. Speaker recognition: A tutorial. *Proceedings of the IEEE*, 85(9):1437–1462, 1997.
- [23] Ajay Kumar, David CM Wong, Helen C Shen, and Anil K Jain. Personal verification using palmprint and hand geometry biometric. In *Audio-and Video-Based Biometric Person Authentication*, pages 668–678. Springer, 2003.

- [24] John Daugman. How iris recognition works. *Circuits and Systems for Video Technology, IEEE Transactions on*, 14(1):21–30, 2004.
- [25] Fabian Monrose and Aviel D Rubin. Keystroke dynamics as a biometric for authentication. *Future Generation computer systems*, 16(4):351–359, 2000.
- [26] Liang Wang, Tieniu Tan, Huazhong Ning, and Weiming Hu. Silhouette analysis-based gait recognition for human identification. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 25(12):1505–1518, 2003.
- [27] Lily Lee and W Eric L Grimson. Gait analysis for recognition and classification. In *Automatic Face and Gesture Recognition, 2002. Proceedings. Fifth IEEE International Conference on*, pages 148–155. IEEE, 2002.
- [28] Blair C. Armstrong, Maria V. Ruiz-Blondet, Negin Khalifian, Kenneth J. Kurtz, Zhanpeng Jin, and Sarah Laszlo. Brainprint: Assessing the uniqueness, collectability, and permanence of a novel method for {ERP} biometrics. *Neurocomputing*, 166:59 – 67, 2015.
- [29] Dario Maio, Davide Maltoni, Raffaele Cappelli, Jim L Wayman, and Anil K Jain. Fvc2004: Third fingerprint verification competition. In *Biometric Authentication*, pages 1–7. Springer, 2004.
- [30] Charles L Wilson, R Austin Hicklin, Horold Korves, Bradford Ulery, Melissa Zoepfl, Mike Bone, Patrick J Grother, Ross J Micheals, Steve Otto, Craig I Watson, et al. *Fingerprint vendor technology evaluation 2003: Summary of results and analysis report*. US Department of Commerce, National Institute of Standards and Technology, 2004.
- [31] P Jonathon Phillips, Patrick Grother, Ross Micheals, Duane M Blackburn, Elham Tabassi, and Mike Bone. Face recognition vendor test 2002. In *Analysis and Modeling of Faces and Gestures, 2003. AMFG 2003. IEEE International Workshop on*, page 44. IEEE, 2003.
- [32] Douglas A Reynolds, Thomas F Quatieri, and Robert B Dunn. Speaker verification using adapted gaussian mixture models. *Digital signal processing*, 10(1):19–41, 2000.
- [33] P Jonathon Phillips, Kevin W Bowyer, Patrick J Flynn, Xiaomei Liu, and W Todd Scruggs. The iris challenge evaluation 2005. In *Biometrics: Theory, Applications and Systems, 2008. BTAS 2008. 2nd IEEE International Conference on*, pages 1–8. IEEE, 2008.
- [34] Rafael Lubian U Arias. *Dactiloscopia*. Reus, Madrid, 1 edition, 2002.
- [35] John Berry and David A Stoney. The history and development of fingerprinting. *Advances in fingerprint Technology*, 2:13–52, 2001.

- [36] Francis Galton. Method of indexing finger-marks. *Proceedings of the Royal Society of London*, 49(296-301):540–548, 1890.
- [37] Davide Maltoni. A tutorial on fingerprint recognition. In *Advanced Studies in Biometrics*, pages 43–68. Springer, 2005.
- [38] Davide Maltoni, Dario Maio, Anil K Jain, and Salil Prabhakar. *Handbook of fingerprint recognition*. Springer Science & Business Media, 2009.
- [39] R. Allen, P. Sankar, and S. Prabhakar. Fingerprint identification technology. In J. Wayman, A. Jain, D. Maltoni, and D. Maio, editors, *Biometric Systems: Technology, Design and Performance Evaluation*, chapter 2. Springer, London, 2005.
- [40] R.D. Labati, V. Piuri, and F. Scotti. Neural-based quality measurement of fingerprint images in contactless biometric systems. In *Neural Networks (IJCNN), The 2010 International Joint Conference on*, pages 1–8, july 2010.
- [41] Ruggero Donida Labati, Vincenzo Piuri, and Fabio Scotti. A neural-based minutiae pair identification method for touch-less fingerprint images. In *Computational Intelligence in Biometrics and Identity Management (CIBIM), 2011 IEEE Workshop on*, pages 96–102, april 2011.
- [42] Feng Liu, D. Zhang, Changjiang Song, and Guangming Lu. Touchless multiview fingerprint acquisition and mosaicking. *Instrumentation and Measurement, IEEE Transactions on*, 62(9):2492–2502, Sept 2013.
- [43] G. Parziale. Touchless fingerprinting technology. In Nalini K. Ratha and Venu Govindaraju, editors, *Advances in Biometrics: Sensors, Algorithms and Systems*, chapter 2. Springer, London, 2008.
- [44] D.L. Milgram. Computer methods for creating photomosaics. *IEEE Transactions on Computers*, C-24(11):1113–1119, Nov. 1975.
- [45] M.S. AlTarawneh, W.L. Woo, and S.S. Dlay. Objective fingerprint image quality assessment using gabor spectrum approach. In *Digital Signal Processing, 2007 15th International Conference on*, pages 248–251, July 2007.
- [46] M.A. Olsen, E. Tabassi, A. Makarov, and C. Busch. Self-organizing maps for fingerprint image quality assessment. In *Computer Vision and Pattern Recognition Workshops (CVPRW), 2013 IEEE Conference on*, pages 138–145, June 2013.
- [47] J. Hammerle-Uhl, M. Pober, and A. Uhl. Systematic evaluation methodology for fingerprint-image quality assessment techniques. In *Information and Communication Technology, Electronics and Microelectronics (MIPRO), 2014 37th International Conference on*, pages 1315–1319, May 2014.

- [48] Jana Dittmann and Mario Hildebrandt. Context analysis of artificial sweat printed fingerprint forgeries: Assessment of properties for forgery detection. In *Biometrics and Forensics (IWBF), 2014 International Workshop on*, pages 1–6, March 2014.
- [49] Marek Dusio, Martin Aastrup Olsena, and Christoph Busch. Fingerprint sample quality assessment via ridge line count using laplacian of gaussian edge finding. In *Biometrics and Forensics (IWBF), 2014 International Workshop on*, pages 1–6, March 2014.
- [50] B. Wing. Nist contributions to biometric technology. *IT Professional*, 16(2):38–44, Mar 2014.
- [51] Stuart Russell, Peter Norvig, and Artificial Intelligence. A modern approach. *Artificial Intelligence. Prentice-Hall, Egnlewood Cliffs*, 25:27, 1995.
- [52] Peter Norvig and Stuart Russell. *Inteligência Artificial, 3ª Edição*, volume 1. Elsevier Brasil, 2014.
- [53] Anil K Jain, Jianchang Mao, and KM Mohiuddin. Artificial neural networks: A tutorial. *Computer*, (3):31–44, 1996.
- [54] Warren S McCulloch and Walter Pitts. A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, 5(4):115–133, 1943.
- [55] Søren Brunak and Benny Lautrup. *Neural networks: computers with intuition*. World Scientific, 1990.
- [56] Frank Rosenblatt. Principles of neurodynamics. perceptrons and the theory of brain mechanisms. Technical report, DTIC Document, 1961.
- [57] Marvin Minsky and Seymour Papert. Perceptrons. 1969.
- [58] John J Hopfield. Neural networks and physical systems with emergent collective computational abilities. *Proceedings of the national academy of sciences*, 79(8):2554–2558, 1982.
- [59] Paul Werbos. Beyond regression: New tools for prediction and analysis in the behavioral sciences. 1974.
- [60] David E Rumelhart, James L McClelland, PDP Research Group, et al. Parallel distributed processing: Explorations in the microstructure of cognition, vol. 1-2. *Cambridge, MA*, 1986.
- [61] JA Anderson and E Rosenfeld. Neurocomputing: Foundations of research, 1988. *Cambridge, MA*, page 729.
- [62] Martin T Hagan, Howard B Demuth, Mark H Beale, and Orlando De Jesús. *Neural network design*, volume 20. PWS publishing company Boston, 1996.

- [63] Dan W Patterson. *Artificial neural networks: theory and applications*. Prentice Hall PTR, 1998.
- [64] Bernard WIDROW, Marcian E HOFF, et al. Adaptive switching circuits. 1960.
- [65] James Stewart. *Calculus: early transcendentals*. Cengage Learning, 2015.
- [66] Hao Yu and B. M. Wilamowski. Levenberg–marquardt training. In *Industrial Electronics Handbook, 2nd Edition*, volume 5, pages 12–1. CRC Press, 2011.
- [67] Howard Demuth and Mark Beale. Neural network toolbox for use with matlab. 1993.
- [68] Jing-Hao Xue and D.M. Titterington. t -tests, f -tests and otsu’s methods for image thresholding. *Image Processing, IEEE Transactions on*, 20(8):2392–2396, Aug 2011.
- [69] Nobuyuki Otsu. A threshold selection method from gray-level histograms. *Automatica*, 11(285-296):23–27, 1975.
- [70] David A Freedman. *Statistical models: theory and practice*. cambridge university press, 2009.
- [71] Rafael C Gonzalez and Richard E Woods. *Processamento de imagens digitais*. Edgard Blucher, 2000.
- [72] OpenCV Developers Team. Opencv reference manual, 2012.
- [73] Simon Haykin. *Neural Networks: A Comprehensive Foundation*. Prentice Hall PTR, Upper Saddle River, NJ, USA, 2nd edition, 1998.
- [74] Howard Demuth, Mark Beale, Howard Demuth, and Mark Beale. Neural network toolbox for use with matlab, 1993.
- [75] Sholom M Weiss and Casimir A Kulikowski. Computer systems that learn: classification and prediction methods from statistics. *Neural Networks, Machine Learning, and Expert Systems*, 1991.
- [76] Anil Jain, Brendan Klare, and Arun Ross. Guidelines for best practices in biometrics research. In *IEEE International Conf. Biometrics, Phuket, Thailand*, 2015.