

Classificação e Detecção de Singularidades em Imagens de Impressão Digital Baseada em Redes Neurais Convolucionais

Paulo Ricardo Pereira da Silva



CENTRO DE INFORMÁTICA
UNIVERSIDADE FEDERAL DA PARAÍBA

João Pessoa, 2020

Paulo Ricardo Pereira da Silva

Classificação e Detecção de Singularidades em Imagens de Impressão Digital Baseada em Redes Neurais Convolucionais

Tese de dissertação de mestrado apresentada como requisito para
a obtenção do grau de Mestre pelo Programa de Pós-graduação
em Informática do Centro de Informática
da Universidade Federal da Paraíba

Orientador: Leonardo Vidal Batista

João Pessoa, PB 2020

Catálogo na publicação
Seção de Catalogação e Classificação

S586c Silva, Paulo Ricardo Pereira da.
Classificação e Detecção de Singularidades em Imagens
de Impressão Digital Baseada em Redes Neurais
Convolucionais / Paulo Ricardo Pereira da Silva. - João
Pessoa, 2020.
73 f.

Orientação: Leonardo Vidal Batista.
Dissertação (Mestrado) - UFPB/CI.

1. Biometria. 2. Impressão digital. 3. Redes neurais
convolucionais. I. Batista, Leonardo Vidal. II. Título.

UFPB/BC



UNIVERSIDADE FEDERAL DA PARAÍBA
CENTRO DE INFORMÁTICA
PROGRAMA DE PÓS-GRADUAÇÃO EM INFORMÁTICA



Ata da Sessão Pública de Defesa de Dissertação de Mestrado de Paulo Ricardo Pereira da Silva, candidato ao título de Mestre em Informática na Área de Sistemas de Computação, realizada em 27 de maio de 2020.

1 Aos vinte e sete dias do mês de maio do ano de dois mil e vinte, às quatorze horas, por
2 meio de videoconferência, reuniram-se os membros da Banca Examinadora constituída
3 para julgar o Paulo Ricardo Pereira da Silva, vinculado a esta Universidade sob a
4 matrícula nº 20181001113, candidato ao grau de Mestre em Informática, na área de
5 "Sistemas de Computação", na linha de pesquisa "Sinais, Sistemas Digitais e Gráficos",
6 do Programa de Pós-Graduação em Informática, da Universidade Federal da Paraíba. A
7 comissão examinadora foi composta pelos professores: Leonardo Vidal Batista (PPGI-
8 UFPB) Orientador e Presidente da Banca, Claurton de Albuquerque Siebra (PPGI-
9 UFPB), Examinador Interno, Thais Gaudêncio do Rego (PPGI-UFPB), Examinadora
10 interna, João Janduy Brasileiro Primo, Examinador Externo à Instituição. Dando início aos
11 trabalhos, o Presidente da Banca cumprimentou os presentes, comunicou aos mesmos a
12 finalidade da reunião e passou a palavra ao candidato para que o mesmo fizesse a
13 exposição oral do trabalho de dissertação intitulado: "Classificação e Detecção de
14 Singularidades em Imagens de Impressão Digital Baseada em Redes Neurais
15 Convolucionais". Concluída a exposição, o candidato foi arguido pela Banca Examinadora
16 que emitiu o seguinte parecer: "**aprovado**". Do ocorrido, eu, Ruy Alberto Pisani Altafim,
17 Coordenador do Programa de Pós-Graduação em Informática, lavrei a presente ata que
18 vai assinada por mim e pelos membros da banca examinadora. João Pessoa, 27 de maio
19 de 2020.

Prof. Dr. Ruy Alberto Pisani Altafim

Prof. Dr. Leonardo Vidal Batista
Orientador (PPGI-UFPB)

Prof. Dr. Claurton de Albuquerque Siebra
Examinador Interno (PPGI-UFPB)

Prof. Dr. Thais Gaudêncio do Rego
Examinadora Interna (PPGI-UFPB)

Prof. Dr. João Janduy Brasileiro Primo
Examinador Externo à Instituição

AGRADECIMENTOS

A Deus, por me dar saúde para seguir o meu sonho. À minha mãe, Rosilene Pereira da Silva, por me apoiar e incentivar, desde a minha infância, por acreditar e confiar em mim, por contribuir, tanto para a minha formação acadêmica, quanto para a formação do meu caráter. À minha namorada Andrea Karla Dantas de Almeida, por apoiar durante os momentos difíceis.

Ao meu orientador, Leonardo Vidal Batista, por me dar a oportunidade de aprender e transmitir seus conhecimentos e experiências, tanto científicos quanto pessoais.

Aos meus amigos João Janduy Brasileiro Primo, Iron Araújo de Almeida Júnior e Arnaldo Gualberto Silva, por me ajudarem durante a pesquisa, transmitindo seus conhecimentos, principalmente, o João, que foi coorientador de todo o trabalho.

RESUMO

A Biometria oferece um mecanismo de autenticação confiável utilizando traços (físicos ou comportamentais) que permitam identificar usuários baseados em suas características naturais. O reconhecimento por impressão digital é uma das abordagens biométricas mais utilizadas, visto que sua alta precisão e seu baixo custo tornam os sistemas mais acessíveis e com resultados satisfatórios. No entanto, o reconhecimento por impressões digitais ainda é um problema em aberto, uma vez que erros de falsa aceitação e falsa rejeição ainda são encontrados nos algoritmos de comparação de impressões digitais. Este trabalho propõe um método de classificação e detecção de singularidades em imagens de impressão digital, que baseia-se em redes neurais convolucionais e janela deslizante. A detecção é feita por meio de janela deslizante que percorre uma imagem de entrada e extrai uma subimagem de 50x50 e a passa como argumento para o classificador rotular entre as classes laço, delta e neg ou não singularidade, criando um conjunto de singularidades candidatas para então aplicar uma filtragem e manter apenas as singularidades verdadeiras - o classificador é uma rede neural convolucional e sua arquitetura é semelhante a LeNet, com as primeiras camadas convolucionais e as últimas totalmente conectadas. Para avaliar a efetividade do método proposto e o efeito do realce sobre as imagens, foram utilizadas 2 grupos de bases de dados: o primeiro sem pré-processamento, que é formado pelas bases FVC2000-3, FVC2002-1, FVC2004-1, FVC2006-3, e SPD2010; e o segundo com pré-processamento, que é composto pelas bases FVC2000-3, FVC2002-1, FVC2004-1, FVC2006-3. Os resultados mostraram que o realce não influenciou, de forma significativa, o desempenho na detecção. Sobre o grupo sem pré-processamento, o melhor classificador alcançou acurácia de 99% e média de medida-F de 0,98 para as três classes, e o detector alcançou 0,8 de medida-F e *IoU* mediano de 0,73. E, o melhor classificador sobre o grupo com pré-processamento alcançou acurácia de 99% e média de medida-F de 0,99 para as três classes, e o detector alcançou 0,84 de medida-F e *IoU* mediano de 0,76.

Palavras-chave: Biometria, Impressão digital, Redes neurais convolucionais.

ABSTRACT

Biometry provides a reliable authentication mechanism using physical or behavioral traits to identify users based on their natural characteristics. Fingerprint recognition is one of the most used biometrics approach, since its high accuracy and low cost make the system more affordable and achieve satisfactory results. However, fingerprint recognition is still an open problem, since false acceptance and false rejection errors can be found in matching algorithm. This work proposes methods to classify and detect singularities from fingerprint images, that is based on Convolutional Neural Network and sliding window. The detection is done through sliding window that iterates through a input image and extracts a subimage of 50x50 and pass it as an argument to a classifier that labels between the classes loop, delta and neg or non-singularity, creating a set of candidate singularities and then filtering and keeping only true singularities - the classifier is a convolutional neural network and its architecture is similar to LeNet, with the first convolutional layers and the last are fully connected. To evaluate the performance of the proposed method and the enhancement effect over images, 2 groups of database were used: the first with no pre-processing that is formed of the databases FVC2000-3, FVC2002-1, FVC2004-1, FVC2006-3, and SPD2010; the second one with pre-processing that is formed of the databases FVC2000-3, FVC2002-1, FVC2004-1 and FVC2006-3. The results showed the enhancement did not affect on significantly the performance in detection. Over the group with no pre-processing, the best classifier reached the value 99% of accuracy and 0.98 of average F-score for three classes, and the detector reached 0.8 of F-score and median IoU of 0.73. And the best classifier over the group with pre-processing reached the value 99% of accuracy and 0.99 of average F-score for three classes, and the detector reached 0.84 of F-score and median IoU of 0.76.

Key-words: Biometry, Fingerprint, Convolutional Neural Network.

LISTA DE FIGURAS

1	Ilustração simplificada do processo de comparação de impressões digitais. Na etapa 1, os pequenos detalhes, marcados em verde, são extraídos das imagens A e B. Na etapa 2, a partir dos detalhes extraídos, são formados os grafos, em azul, das imagens A e B. Na etapa 3, apresenta o uso dos atributos complementares, em vermelho, para comparação das imagens A e B.	21
2	Cristas e vales de uma impressão digital.	24
3	Regiões singulares (caixas brancas), com as singularidades destacadas em vermelho, e núcleo ou <i>core</i> (círculos brancos) em imagens de impressão digital.	25
4	As cinco classes mais usadas na classificação de digital (o <i>whorl</i> ou verticilo apresenta duas variações: <i>plain</i> ou circular e <i>twin</i> ou sinuoso).	25
5	Principais tipos de minúcias.	26
6	a) Parte de uma impressão digital, capturada a 1000 DPI, onde os poros ficam bem evidentes; b) Novas cristas; c) vincos e cicatrizes.	26
7	Processos de registro (<i>Enrollment</i>), verificação (<i>verification</i>), e identificação (<i>identification</i>).	27
8	Segmentação da imagem de impressão digital: (a) impressão digital com o <i>foreground</i> (1) e o <i>background</i> (2) destacados; (b) imagem da ROI.	29
9	Resultado da aplicação do filtro contextual iterativo de <i>Gabor</i> - imagem original na coluna da esquerda e o resultado do realce na coluna da direita.	31
10	Uma representação gráfica de um conjunto de filtros de Gabor, com $n_0 = 8$ e $n_f = 3$, $\sigma_x = \sigma_y = 4$	31
11	Imagem de orientação de uma impressão digital calculada sobre uma janela quadrada de tamanho 16x16, em que θ_{ij} corresponde ao ângulo do nó $[i,j]$	32
12	Dificuldades no casamento. As imagens em a) e b) parecem diferentes para uma pessoa despreparada, mas elas são do mesmo dedo. Já as que estão em c) e d) parecem idênticas, mas são de dedos diferentes.	34
13	Processamento digital de imagens e áreas correlatas.	36
14	Diagrama das áreas relacionadas ao <i>deep learning</i>	37
15	Duas das três fases históricas de DL e os termos usados para falar sobre o assunto.	38

16	O aumento das bases de dados digitais ao longo do tempo.	38
17	O aumento do número de conexões por neurônio ao longo do tempo.	39
18	Redução da taxa de erro da competição de reconhecimento de objetos <i>ImageNet</i> ao longo do tempo.	40
19	Arquitetura da LeNet-5, uma rede convolucional para reconhecimento de dígitos.	42
20	Visão Geral do Pré-processamento.	48
21	Exemplos de imagens das bases de dados: (a) FVC2000-3; (b) FVC2000-3 com realce; (c) FVC2002-1; (d) FVC2002-1 com realce; (e) FVC2004-1; (f) FVC2004-1 com realce; (g) FVC2006-3; (h) FVC2006-3 com realce; (i) SPD2010.	49
22	Marcador de singularidades <i>Fingerprint Label Marker</i> . As marcações em azul, verde e vermelho representam as Classes Laço, Delta e Neg, respectivamente.	50
23	Interseção sobre a união (<i>IoU</i>). A região <i>A</i> representa onde o objeto está e a região <i>P</i> representa onde o detector localizou.	52
24	Visão geral do classificador.	53
25	Extração de singularidades por meio do marcador de singularidades <i>Fingerprint Label Marker</i>	54
26	Visão geral do detector. O quadrado azul representa a primeira iteração da janela deslizante, o quadrado laranja representa a segunda iteração com a aplicação do <i>stride</i> sobre a coluna, e o quadrado vermelho representa a iteração da primeira aplicação do <i>stride</i> sobre a linha.	58
27	Imagem errada pelo Classificador 1 sobre o seu conjunto de teste (gabarito classe predita): (a) Neg Laço.	62
28	Imagens erradas pelo Classificador 2 sobre o seu conjunto de teste (gabarito classe predita): (a) Laço Neg; (b) Neg Laço.	65
29	Exemplos de erros de gabarito: (a) Laço gabaritado fora da ROI (FVC2000-3); (b) Laço gabaritado no lugar errado (FVC2002-1); (c) Laço deslocado (FVC2004-1); (d) Laço não gabaritado (FVC2004-1); (e) Laço gabaritado fora da ROI (FVC2006-3); (f) Delta gabaritado na borda da imagem (SPD2010).	66
30	Histograma dos valores de <i>IoU</i> geral do Detector 1 computados sobre todas as bases sem pré-processamento.	69

31	Histograma dos valores de IoU geral do Detector 2 computados sobre todas as bases com pré-processamento.	71
----	--	----

LISTA DE TABELAS

1	Informações sobre as bases de dados	47
2	Quantidade de singularidades extraída por base de dados.	48
3	Matriz de confusão.	50
4	Parâmetros usados no <i>ImageDataGenerator</i>	54
5	Representação dos rótulos (<i>encoding</i>) das Classes Laço, Delta e Neg.	55
6	Sumário do classificador.	55
7	Alguns dos hiper-parâmetros usados no classificador.	56
8	Acurácia dos testes de classificação de singularidades com as imagens sem pré-processamento.	60
9	Média dos valores de medida-F das 3 classes alcançados nos testes de classificação de singularidades com as imagens sem pré-processamento.	60
10	Medida-F (F), precisão (P) e revocação (R) dos testes de classificação de singularidades com as imagens sem pré-processamento do tipo Laço.	60
11	Medida-F (F), precisão (P) e revocação (R) dos testes de classificação de singularidades com as imagens sem pré-processamento do tipo Delta.	61
12	Medida-F (F), precisão (P) e revocação (R) dos testes de classificação de singularidades com as imagens sem pré-processamento do tipo Neg.	61
13	Desempenho dos classificadores de imagens sem pré-processamento baseado na medida-F.	61
14	Matriz de confusão gerada durante o teste do classificador 1.	62
15	Acurácia das 3 classes dos testes de classificação de singularidades com as imagens pré-processadas.	62
16	Média dos valores de medida-F das 3 classes alcançados nos testes de classificação de singularidades com as imagens pré-processadas.	63
17	Medida-F (F), precisão (P) e revocação (R) dos testes de classificação de singularidades com as imagens pré-processadas do tipo Laço.	63
18	Medida-F (F), precisão (P) e revocação (R) dos testes de classificação de singularidades com as imagens pré-processadas do tipo Delta.	63
19	Medida-F (F), precisão (P) e revocação (R) dos testes de classificação de singularidades com as imagens pré-processadas do tipo Neg.	64

20	Desempenho dos classificadores de singularidades para imagens com pré-processamento baseado na medida-F.	64
21	Matriz de confusão gerada durante o teste do Classificador 2.	64
22	Medida-F (F), precisão (P) e revocação (R) do Detector 1.	67
23	Medida-F (F), precisão (P) e revocação (R) do Detector 1 para Classe Laço.	67
24	Medida-F (F), precisão (P) e revocação (R) do Detector 1 para Classe Delta.	68
25	Mediana dos valores de IoU considerando as 2 classes (Geral) e separados pelas Classes Laço e Delta do Detector 1.	68
26	Medida-F (F), precisão (P) e revocação (R) do Detector 2.	69
27	Medida-F (F), precisão (P) e revocação (R) do Detector 2 para a Classe Laço.	70
28	Medida-F (F), precisão (P) e revocação (R) do Detector 2 para a Classe Delta.	70
29	Mediana dos valores de IoU considerando as 2 classes (Geral) e separados pelas Classes Laço e Delta do Detector 2.	70
30	Comparação dos detectores de singularidades por meio da métrica DR ($r = 6$) sobre a Base FVC2002-1 sem pré-processamento.	72
31	Taxa de detecção (DR) e falso alarme (FA) do Detector 1, para diferentes valores de r , sobre a Base FVC2002-1 sem pré-processamento.	72

LISTA DE ABREVIATURAS

SIGLA – NOME COMPLETO

AFIS – Sistema de Identificação Automatizado de Impressões Digitais

CNN - Rede Neural Convolucional

FVC – Competição de Verificação de Impressão Digital

IoU – Interseção sobre a União

PDI – Processamento Digital de Imagens

ROI – Região de Interesse

SP – Ponto Singular

SPD – Competição de Detecção de Pontos Singulares

Conteúdo

1	INTRODUÇÃO	19
1.1	Definição do Problema	20
1.2	Objetivo geral	21
1.3	Objetivos específicos	22
1.4	Estrutura do Trabalho	22
2	CONCEITOS GERAIS	23
2.1	Biometria	23
2.2	Impressão Digital	23
2.3	Sistemas Biométricos	26
2.4	Segmentação	28
2.5	Realce	29
2.6	Matriz de Orientação	32
2.7	Casamento	33
2.8	Fingerprint Verification Competition	34
2.9	Processamento Digital de Imagens	35
2.10	Aprendizagem profunda	36
2.11	Redes Convolucionais	40
3	Trabalhos Relacionados	44
4	MATERIAIS E MÉTODOS	46
4.1	Ambiente de Desenvolvimento	46
4.2	Bases de dados	46
4.3	Marcador de Singularidades	49
4.4	Métricas	50
4.5	Método Proposto	53
4.5.1	Classificação	53
4.5.2	Detecção	56

5	APRESENTAÇÃO E ANÁLISE DOS RESULTADOS	59
5.1	Classificação	59
5.1.1	Imagens sem pré-processamento	59
5.1.2	Imagens com pré-processamento	62
5.1.3	Problemas no gabarito	65
5.2	Detecção	66
5.2.1	Imagens sem pré-processamento	67
5.2.2	Imagens com pré-processamento	69
5.3	Comparação com outros métodos	71
6	CONCLUSÕES E TRABALHOS FUTUROS	73
	REFERÊNCIAS	73

1 INTRODUÇÃO

Desde 1893, o Departamento de Segurança do Reino Unido assume que dois indivíduos não possuem a mesma impressão digital. Pouco depois da descoberta de Alphonse Bertillon, que afirmava que uma pessoa poderia ser identificada a partir de um conjunto de atributos antropomórficos, muitos dos principais departamentos de aplicação da lei perceberam o potencial das impressões digitais na identificação de criminosos reincidentes que usavam outros nomes para, ao ser recapturado, escaparem de penalidades mais severas, aplicadas a reincidentes (ROSS; NANDAKUMAR; JAIN, 2006).

Estes departamentos aderiram à ideia de catalogar as impressões digitais de criminosos no momento de sua prisão para que seus registros estivessem disponíveis em identificações futuras. Ao comparar impressões em cenas de crimes com as que foram catalogadas, as autoridades podiam determinar a identidade de criminosos que haviam sido presos anteriormente. As agências de segurança investiram em um estudo rigoroso das impressões digitais, desenvolvendo métodos científicos para a comparação visual das digitais e instituindo programas para treinamentos de especialistas na área (MALTONI et al., 2009).

Apesar da existência de métodos para aumentar a eficiência da abordagem manual para indexação e comparação das digitais, a crescente demanda para o reconhecimento rapidamente tornou-se avassaladora. O método manual de indexação resultou em uma distribuição enviesada de tipos: muitas digitais eram classificadas em poucos tipos, o que, em última análise, não aumentava substancialmente a eficiência da busca. Os procedimentos de treinamentos eram intensivos e lentos. Além do mais, a grande quantidade de digitais exigia uma atenção cuidadosa para avaliá-las. A monotonicidade e as cargas de trabalho, cada vez maiores decorrentes do aumento da demanda de serviços de reconhecimento das impressões digitais, levaram às pesquisas no sentido de desenvolver um sistema automatizado de reconhecimento.

Estes esforços conduziram o desenvolvimento dos primeiros Sistemas de Identificação Automática de Impressões Digitais (*Automated Fingerprint Identification Systems* - AFIS), aproximadamente 40 anos após o início do uso de impressões digitais para identificação biométrica (MALTONI et al., 2009).

Nas últimas décadas, agências de segurança e outras instituições passaram a adotar rotineiramente a tecnologia de reconhecimento automático de impressões digitais. Mais recentemente, o aumento dos estudos sobre segurança e falsidade ideológica fomentou o uso de tecnologias baseadas em biometria para inúmeras aplicações não forenses. O grande desafio nos AFIS tem sido diminuir erros de verificação e identificação, mantendo um custo computacional aceitável para aplicações práticas. No âmbito nacional, o reconhecimento biométrico vem sendo amplamente utilizado. No Brasil, a emissão de passaporte,

carteiras de identidade e o cadastro das Polícias Civil e Federal contam com sistemas de autenticação biométrica. Além disso, muitas empresas adotam tais sistemas para acesso às suas instalações ou utilização de seus serviços. É o caso de algumas academias de ginástica que usam leitura da impressão digital para controlar o acesso dos seus frequentadores (TSE, 2017). Recentemente a biometria foi implantada no sistema eleitoral do país, com o cadastramento biométrico de dezenas de milhões de eleitores.


Porém, apesar do grande avanço na captura e comparação automática entre impressões digitais, as melhores taxas divulgadas em aplicações reais são de empresas privadas. O conhecimento mais avançado nessa linha de pesquisa encontra-se, até certo ponto, represado em instituições privadas, já que as empresas, em geral, não possuem interesse em publicar seus avanços e descobertas.

1.1 Definição do Problema

No processo de comparação de impressões digitais, por meio de AFIS, os pequenos detalhes locais, marcados em verde na Figura 1, que descrevem o padrão único de descontinuidade de uma impressão digital são extraídos e, normalmente, usados para montar um grafo. No entanto, esses detalhes locais são sensíveis a qualidade da imagem e, devido a presença de ruído, um grafo diferente pode ser produzido, induzindo o algoritmo de casamento de impressões digitais ao erro, elevando a taxa de falsa rejeição e falsa aceitação.

Diante desse cenário, Os atributos descritos pelos padrões globais dos traços em determinadas regiões - marcados em vermelho da Figura 1 -, podem ser usados como informação complementar para adicionar mais precisão ao casamento de impressões digitais. Por exemplo, há impressões digitais que não possuem esses padrões globais e, quando comparadas com outras que apresentam esses padrões, podem auxiliar de maneira substancial a precisão do algoritmo de casamento.

Figura 1: Ilustração simplificada do processo de comparação de impressões digitais. Na etapa 1, os pequenos detalhes, marcados em verde, são extraídos das imagens A e B. Na etapa 2, a partir dos detalhes extraídos, são formados os grafos, em azul, das imagens A e B. Na etapa 3, apresenta o uso dos atributos complementares, em vermelho, para comparação das imagens A e B.



Fonte: Elaboração própria.

Devido ao significativo avanço da área de aprendizagem profunda (*deep learning*, DL) e ao elevado desempenho de redes neurais convolucionais (*Convolutional Neural Network*, CNN) em imagens de baixa qualidade, este trabalho apresenta um método de classificação e detecção de singularidades baseado em CNN e janela deslizante.

1.2 Objetivo geral

O objetivo geral deste trabalho é propor um modelo baseado em CNN para detectar e classificar singularidades em imagens de impressão digital de modo que esses pontos singulares (laço e delta) possam ser usados no casamento de impressões digitais como mais um atributo.

1.3 Objetivos específicos

Os objetivos específicos são:

1. Desenvolver um método que facilite a criação manual do gabarito de singularidades;
2. Criar bases de dados de singularidades;
3. Aumentar a quantidade de imagens dos bancos de dados para melhorar o aprendizado do modelo;
4. Pesquisar e desenvolver um modelo baseado em CNN para classificar singularidades dos tipos laço e delta;;
5. Desenvolver um método baseado no modelo do item anterior para detectar singularidades dos tipos laço e delta;
6. Avaliar o efeito do pré-processamento na classificação e detecção de singularidades.

1.4 Estrutura do Trabalho

Este trabalho foi dividido em mais 4 capítulos: Conceitos Gerais (2), que apresenta as definições dos principais conceitos usados neste trabalho; Trabalhos Relacionados (3); Metodologia (4), que mostra informações sobre o ambiente de desenvolvimento, marcador de singularidades, bases de dados, métricas e a descrição do método proposto neste trabalho; Apresentação e Análise dos Resultados (5), que exhibe todos os resultados obtidos na classificação e detecção, comparação com outros métodos de detecção de singularidades, e algumas considerações sobre eles; por fim, Conclusão e Trabalhos Futuros (6).

2 CONCEITOS GERAIS

Neste capítulo são apresentados os principais conceitos teóricos utilizados na produção deste trabalho, que disserta sobre conceitos gerais relacionados à biometria (Seção 2.1), impressão digital (Seção 2.2), sistemas biométricos (Seção 2.3), etapas da verificação de impressões digitais como segmentação (extração da Região de interesse) (Seção 2.4), realce (Seção 2.5), cálculo da matriz de orientação (Seção 2.6) e casamento (Seção 2.7), a competição de verificação de impressão digital (Seção 2.8), Processamento Digital de Imagens (Seção 2.9), Aprendizagem profunda (*Deep Learning*) (Seção 2.10) e Redes neurais convolucionais (Seção 2.11).

2.1 Biometria

O termo Biometria refere-se, neste contexto, ao uso de características físicas ou comportamentais, tais como face, íris, impressão digital, voz, forma de escrever ou de digitar, e forma de andar, para identificar pessoas. Uma vez que os identificadores biométricos não podem ser facilmente extraviados, forjados, ou compartilhados, métodos de identificação biométricos são considerados mais confiáveis do que métodos baseados em tokens (como *smartcards*) ou senhas (MALTONI et al., 2009). Assim, os sistemas de reconhecimento biométrico estão sendo cada vez mais implantados em um grande número de aplicações reais. Com o uso da Biometria, é possível estabelecer uma identidade baseada em “quem você é”, não em “o que você possui”, como um cartão de identificação, ou “o que você sabe”, como no caso do uso de senhas. Em outros casos, a biometria tem sido usada como aliada aos métodos tradicionais (ROSS; NANDAKUMAR; JAIN, 2006), em sistemas multifatoriais.


Para aumentar a segurança, pode-se ainda utilizar múltiplos traços biométricos, gerando sistemas multibiométricos e multifatoriais. O sucesso de tecnologias baseadas em impressões digitais em aplicações jurídicas, a diminuição do custo de sensores para a captura de impressões digitais, o crescente aumento de poder computacional e o aumento das fraudes ideológicas, onde uma pessoa se passa por outra para obter seus benefícios, resultaram em um aumento expressivo no uso de reconhecimento por impressões digitais. Contudo, além das impressões digitais, outras características como forma da mão, voz, íris e face também tem sido muito utilizadas em sistemas comerciais (MALTONI et al., 2009).

2.2 Impressão Digital

Uma impressão digital é uma reprodução da aparência exterior da epiderme do dedo. A estrutura mais característica da impressão digital é o padrão intercalado de

cristas e vales ou sulcos. Em uma imagem de impressão digital, as cristas são as áreas escuras e os vales são as áreas mais claras (Figura 2). A maior parte das lesões nos dedos, como queimaduras superficiais, abrasões, ou cortes, não surte efeito duradouro na estrutura típica, e o padrão original é majoritariamente reconstruído na pele regenerada (MALTONI et al., 2009).

Figura 2: Cristas e vales de uma impressão digital.




Fonte: (MALTONI et al., 2009).

Os detalhes das cristas são descritos em uma ordem hierárquica de três diferentes níveis: Nível 1 (padrão global de disposição das cristas ou singularidades), Nível 2 (minúcias), e Nível 3 (poros e formatos das cristas) (MALTONI et al., 2009).

No Nível 1 (nível global), as cristas geralmente encontram-se paralelamente em relação às outras, porém existem uma ou mais regiões onde eles assumem formas distintas, essas regiões são chamadas de singularidade - Figura 3. Singularidade pode ser definida como uma estrutura composta de cristas, na qual estas seguem um fluxo padrão, em determinadas regiões ao longo da digital, e podem ser classificadas em laço ou *loop*, *delta* e *whorl* - usualmente, laço, delta e *whorl* são caracterizados pelas formas $\cap$, Δ e O , respectivamente. A Figura 4 mostra as cinco classes mais usadas na classificação de digital, segundo Maltoni (MALTONI et al., 2009): *arch* ou arco plano, *tented arch* ou arco angular, *left loop* ou presilha externa, *right loop* ou presilha interna, e *whorl*¹ ou verticilo.


¹O termo *whorl* é usado tanto para definir o tipo de singularidade (Figura 3) quanto o tipo de impressão digital (Figura 4)

Figura 3: Regiões singulares (caixas brancas), com as singularidades destacadas em vermelho, e núcleo ou *core* (círculos brancos) em imagens de impressão digital.



Fonte: (MALTONI et al., 2009).


Figura 4: As cinco classes mais usadas na classificação de digital (o *whorl* ou verticilo apresenta duas variações: *plain* ou circular e *twin* ou sinuoso).



Fonte: (MALTONI et al., 2009).

No Nível 2 (nível local), há 150 tipos diferentes de minúcias, porém, a maioria delas raramente são encontradas em impressões digitais, pois dependem muito da condição e da qualidade das impressões (MALTONI et al., 2009). No contexto de impressão digital, minúcia significa pequeno detalhe que descreve as várias formas de descontinuidade das cristas - Figura 5. Se uma crista é descontinuada repentinamente, surge uma terminação, caso ela se divida em duas cristas, surge uma bifurcação. Estas são características mais utilizadas na comparação entre duas impressões digitais.


Figura 5: Principais tipos de minúcias.



Fonte: (MALTONI et al., 2009).

No Nível 3, detalhes muito finos podem ser encontrados - Figura 6. Características de dimensão das cristas como largura, formato, contorno das bordas, poros, vincos e cicatrizes podem ser encontrados nesse nível. Apesar de serem características muito distintas, capazes de diferenciar um indivíduo, elas são pouco utilizadas no casamento, pois são necessários sensores de alta resolução (p. ex. 1000 DPI), que são mais caros, para capturar uma imagem de excelente qualidade.

Figura 6: a) Parte de uma impressão digital, capturada a 1000 DPI, onde os poros ficam bem evidentes; b) Novas cristas; c) vincos e cicatrizes.



Fonte: (MALTONI et al., 2009).

2.3 Sistemas Biométricos

Sistemas biométricos são usados para determinar como um indivíduo vai ser reconhecido e podem ser classificados como sistemas de verificação ou sistemas de identificação (MALTONI et al., 2009).


Um sistema de verificação compara uma característica biométrica capturada com outra, que foi previamente capturada pelo sistema, para aceitar ou rejeitar a identidade de um indivíduo, ou seja, ela confirma ou não a identidade de uma pessoa, em uma com-

paração 1 para 1. Durante o processo de verificação (*verification*), é fornecido um identificador (nome do usuário, senha etc.) para confirmar a identidade; o escâner biométrico captura a característica do usuário e a converte em uma amostra (*sample*), que é processada pelo módulo de extração de atributos (*feature extraction*) para produzir um conjunto de atributos, e este é usado na comparação.

Já um sistema de identificação compara uma característica biométrica capturada com todas que estão armazenadas na base de dados, ou seja, uma comparação 1 para N (em que N representa o tamanho da base de dados) para, ou determinar a identidade de um indivíduo, ou que a característica biométrica capturada não está registrada na base de dados do sistema. O processo de identificação (*identification*) é caro computacionalmente quando a base de dados é muito grande, o que requer uma pré-seleção (*pre-selection*) das amostras da base para reduzir a quantidade de amostras a serem comparadas.

Antes que os dois processos supracitados sejam executados, é necessária a criação da base de dados, que faz o registro (*enrollment*) dos modelos biométricos. Durante este processo, a característica biométrica do sujeito é capturada por um escâner biométrico para produzir uma amostra. Normalmente, é verificada a qualidade da amostra para garantir que a amostra adquirida possa ser processada com segurança pelos estágios seguintes. O módulo de extração é usado para produzir um conjunto de atributos, e este é usado pelo módulo de criação de modelos (ou *template creation*) para gerar o modelo biométrico. Este modelo é, então, armazenado na base de dados, com informações adicionais como senha, nome, gênero etc. Uma visão geral dos três processos pode ser vista na Figura 7;

Figura 7: Processos de registro (*Enrollment*), verificação (*verification*), e identificação (*identification*).



Fonte: (MALTONI et al., 2009).

Os processos de registro (*Enrollment*), verificação, e identificação envolvem o uso de cinco módulos (MALTONI et al., 2009):

1. Captura (*capture*): uma representação da característica biométrica é detectada e capturada por um sensor, como um escâner de impressão digital, este equipamento é a parte central deste módulo. A representação de uma característica biométrica capturada é conhecida como amostra, em sistemas baseados em impressão digital, uma amostra é a imagem capturada pelo escâner. Neste módulo, é possível ter outros componentes como teclado e tela para capturar outros dados.
2. Extração de atributos (*feature extraction*): a amostra é processada por um extrator de atributos para gerar uma representação compacta (conjunto de atributos) para facilitar a etapa de casamento (*matching*).
3. Criação do modelo (*template creation*): este módulo organiza um ou mais conjuntos de atributos em um modelo de registro para salvá-lo na base de dados.
4. Pré-seleção e casamento (*pre-selection and matching*): este estágio realiza uma filtragem dos modelos armazenados, quando a base de dados é muito grande, para reduzir o número de comparações na etapa de casamento. O casamento recebe, como entrada, um conjunto de atributos capturados e outro conjunto de atributos registrado na base de dados, e calcula a similaridade entre elas, retornando um valor de similaridade. Caso este valor seja maior que um determinado limiar, o indivíduo é reconhecido, caso contrário, não.
5. Armazenamento de dados (banco de dados): é dedicado a armazenar os modelos biométricos e outras informações demográficas dos usuários. Em algumas aplicações, estas informações são armazenadas em um dispositivo interno, externo ou, até mesmo, em um cartão - que é emitido para o usuário.


2.4 Segmentação

Segmentação é a separação da região da impressão digital da área que a envolve (MALTONI et al., 2009). É a decomposição de uma imagem em seus componentes (*foreground*, área que apresenta cristas e vales, e *background*, o restante da imagem) - Figura 8. É uma das etapas mais importantes na identificação de um indivíduo por meio de AFIS. É a partir dessa subimagem, que segue todo o restante do processo de identificação. Qualquer erro cometido nesse passo pode ser propagado para etapas posteriores, prejudicando todo o processo.

O *foreground* ou região de interesse (*Region of interest*, ROI) é produzido a partir do contato do dedo com o sensor, caracterizado pela presença de um padrão sulcado ou

listrado (característico de uma impressão digital). A região externa à esta é chamada de *background*, ela é caracterizada pelo padrão isotrópico, ou seja, pela uniformidade. Os algoritmos de extração de atributos detectam um número muito elevado de falsas minúcias nas regiões de *background*, assim sendo, a segmentação tem a finalidade de retirar ou pelo menos reduzir esses erros.

Figura 8: Segmentação da imagem de impressão digital: (a) impressão digital com o *foreground* (1) e o *background* (2) destacados; (b) imagem da ROI.



Fonte: Elaboração própria

2.5 Realce

Realce é o processo de recuperação de uma impressão digital. Ele tenta reconstruir áreas danificadas, conectando as cristas que, por vários motivos, estão separadas. O objetivo desse processamento é melhorar a qualidade das imagens de impressões digitais, de modo que propicie bons resultados dos processamentos seguintes (extração de atributos e casamento de impressões digitais). Na literatura, há algumas formas de realçar uma imagem (a nível de pixel, filtragem contextual, multi-resolução etc.), porém, neste trabalho, foi utilizada a filtragem contextual iterativa baseada em filtros de Gabor do trabalho [Turrone, Cappelli e Maltoni \(2012\)](#).

A filtragem contextual é a técnica de realce mais utilizada e baseia-se em filtros contextuais, que, de acordo com o contexto (orientação e frequência locais das cristas), muda suas características. De fato, a forma de onda senoidal das cristas e dos vales é definida por sua orientação e frequência local, que varia suavemente por toda a impressão digital. Um filtro apropriado que é ajustado às frequências e orientação locais pode facilmente remover ruídos indesejados e preservar as estruturas verdadeiras das cristas e vales ([MALTONI et al., 2009](#)).

O filtro de Gabor é definido por uma onda plana senoidal limitado por uma *Gaussiana* (primeiro termo da Equação 1):

$$g = (x, y : \theta, f) = \exp \left\{ -\frac{1}{2} \left[\frac{x_\theta^2}{\sigma_x^2} + \frac{y_\theta^2}{\sigma_y^2} \right] \right\} \cdot \cos(2\pi f \cdot x_\theta) \quad (1)$$

em que θ é a orientação do filtro; $[x_\theta, y_\theta]$ são as coordenadas $[x, y]$ após uma rotação, no sentido horário do eixo cartesiano por um ângulo $90^\circ - \theta$; f é a frequência da onda plana senoidal; σ_x e σ_y são os desvios padrão da *Gaussiana* em cada eixo.


Para aplicar filtros de Gabor em uma imagem, quatro parâmetros devem ser especificados ($\theta, f, \sigma_x, \sigma_y$). A orientação e a frequência são determinadas pelos valores de orientação e frequência locais das cristas. Já na seleção dos valores dos desvios da *Gaussiana* há uma compensação: quanto maior for seus valores, mais robusto o filtro será a ruído, porém também será mais propenso a criar falsas cristas e vales; quanto menor for seus valores, o filtro será menos propenso a criar falsas cristas e vales, mas não será tão robusto a ruído. Para tornar o realce mais rápido, ao invés de calcular os melhores filtros dinamicamente para cada pixel, um conjunto $\{g_{ij}(x, y) \mid i = 1 \dots n_0, \quad j = 1 \dots n_f\}$ de filtros são pré-calculados e armazenados, onde n_0 e n_f são o número de orientações e frequências discretas, respectivamente. Então, cada pixel $[x, y]$ da imagem é convolucionado, no domínio do espaço, com o filtro $g_{ij}(x, y)$. A Figura 10 mostra um exemplo de um conjunto de filtro para $n_0 = 8$ e $n_f = 3$. A Figura 9 mostra o resultado da aplicação do filtro contextual iterativo de Gabor em uma imagem de impressão digital de baixa qualidade.

Figura 9: Resultado da aplicação do filtro contextual iterativo de *Gabor* - imagem original na coluna da esquerda e o resultado do realce na coluna da direita.



Fonte: (MALTONI et al., 2009).

Figura 10: Uma representação gráfica de um conjunto de filtros de Gabor, com $n_0 = 8$ e $n_f = 3$, $\sigma_X = \sigma_y = 4$.




Fonte: (MALTONI et al., 2009).

2.6 Matriz de Orientação

A orientação das cristas e vales no ponto $[x, y]$ é o ângulo θ_{xy} (normalmente varia entre $[0^\circ, 180^\circ]$), que é calculado em uma vizinhança arbitrária centrada no pixel $[x, y]$, formado com o eixo horizontal. A imagem de orientação de uma impressão digital é uma matriz D que representa a orientação das cristas e vales, e cada elemento θ_{ij} , corresponde ao nó $[i, j]$ de uma janela quadrada localizada sobre o pixel $[x_i, y_j]$, representa a orientação média das cristas na vizinhança de $[x_i, y_j]$ (MALTONI et al., 2009) - (Figura 11).

Figura 11: Imagem de orientação de uma impressão digital calculada sobre uma janela quadrada de tamanho 16x16, em que θ_{ij} corresponde ao ângulo do nó $[i, j]$.



Fonte: (MALTONI et al., 2009).

A forma mais simples de se obter a orientação das cristas é por meio do cálculo de gradientes de uma imagem de impressão digital I . O gradiente $\Delta(x, y)$, no ponto $[x, y]$ de I , é um vetor bidimensional $[\Delta_x(x, y), \Delta_y(x, y)]$, onde Δ_x e Δ_y são os componentes derivados de I no ponto $[x, y]$ em relação as direções x e y , respectivamente. O ângulo de fase do gradiente representa a orientação da variação máxima da intensidade, portanto, a orientação θ de uma crista arbitrária que atravessa a região centrada em $[x, y]$ é ortogonal ao ângulo de fase do gradiente em $[x, y]$. Para calcular a orientação θ de uma crista no ponto $[x, y]$, usa-se as máscaras convolucionais (G_x, G_y) de Prewitt para determinar as componentes do gradiente Δ_x e Δ_y , e assim obter o valor de θ por meio da função $\arctang(\frac{\Delta_x}{\Delta_y})$ (MALTONI et al., 2009).

$$G_x = \begin{bmatrix} +1 & 0 & -1 \\ +1 & 0 & -1 \\ +1 & 0 & -1 \end{bmatrix} \quad G_y = \begin{bmatrix} +1 & +1 & +1 \\ 0 & 0 & 0 \\ -1 & -1 & -1 \end{bmatrix}$$

2.7 Casamento

Um algoritmo de casamento compara duas impressões digitais e quantifica o grau de similaridade entre as amostras de entrada. Normalmente, ou retorna um valor entre 0 e 1, que quanto mais próximo de 1 for a pontuação, maior é o grau de similaridade, ou um valor binário, que indica se as duas impressões são ou não do mesmo dedo. Poucos algoritmos operam sobre as imagens de impressões digitais, a maior parte deles usam uma representação das impressões, chamada de *template*, que pode ser obtida na etapa da extração (MALTONI et al., 2009). Portanto, a etapa da extração torna-se ainda mais importante, visto que ela deve produzir um *template* adequado e confiável para o casamento.

Certamente, o casamento é um problema extremamente difícil, visto que há uma grande variação entre amostras do mesmo dedo. Os principais fatores responsáveis por essa variação são: deslocamento, rotação, sobreposição parcial, distorção não linear, variação de pressão, mudanças na condição da pele, ruído, e outros erros gerados na extração. Portanto, digitais do mesmo dedo, às vezes, podem parecer muito diferentes enquanto que as digitais de dedos diferentes podem parecer muito similares (Figura 12). Contudo, a maior ocorrência de erros na comparação é gerada por falhas oriundas da etapa de extração. Os algoritmos de extração de atributos são imperfeitos e geralmente apresentam falhas. Em imagens de baixa qualidade, o processo de extração de minúcias pode resultar em vários erros, por exemplo: detectar falsas minúcias; não detectar minúcias genuínas existentes (MALTONI et al., 2009)

Figura 12: Dificuldades no casamento. As imagens em a) e b) parecem diferentes para uma pessoa despreparada, mas elas são do mesmo dedo. Já as que estão em c) e d) parecem idênticas, mas são de dedos diferentes.



Fonte: (MALTONI et al., 2009).

Apesar de existir muitos algoritmos de casamento na literatura, a maior parte deles só obtêm bons resultados quando a qualidade da amostra é boa. Logo, o problema ainda é um desafio para imagens de baixa qualidade ou para imagens parciais de digitais.

2.8 Fingerprint Verification Competition

A *Fingerprint Verification Competition* (FVC) (DORIZZI et al., 2009) é uma competição internacional que tem o objetivo de avaliar sistemas biométricos. Um subconjunto de impressões digitais é coletado a partir de vários sensores e é disponibilizado aos participantes para testarem seus sistemas localmente. Os concorrentes tem a opção de participar da competição que engloba uma porção maior do processo de identificação (extração e casamento) ou apenas extração ou apenas casamento. Então, os arquivos de cada etapa devem ser disponibilizados separadamente. A avaliação é conduzida a partir desses arquivos sobre um conjunto de banco de dados criado a partir do mesmo conjunto de sensores que criaram o conjunto de testes.

A FVC é organizada pelo *Biometric System Laboratory (University of Bologna)*, *Pattern Recognition and Image Processing Laboratory (Michigan State University)*, *Biometric Test Center (San Jose State University)* e *Biometric Recognition Group - ATVS*

(*Universidad Autonoma de Madrid*). As quatro primeiras edições do FVC foram realizadas em 2000, 2002, 2004, 2006, respectivamente. Esses eventos receberam atenção das comunidades acadêmicas e industriais relacionadas à biometria. Eles estabeleceram uma referência, permitindo que desenvolvedores comparassem seus algoritmos e pudessem observar o estado da arte na área de reconhecimento de impressões digitais (DORIZZI et al., 2009).

Após o evento de 2006, os organizadores da FVC criaram a *FVC-onGoing*, que possui algumas características diferentes em relação às competições anteriores. Agora, não há mais prazos de submissão, a competição está sempre aberta para o registro de novos participantes. Atualmente, a FVC organiza competições para sistemas biométricos que são baseados em outras características, como a face.

2.9 Processamento Digital de Imagens


Uma imagem pode ser compreendida como uma função bidimensional $f(x, y)$, em que x e y são as coordenadas espaciais e o valor de $f(x, y)$ representa o valor de intensidade, vivacidade ou nível de cinza nesse ponto. Quando x e y e sua intensidade assumem valores finitos e discretos, tem-se uma imagem digital (GONZALEZ RC E WOODS, 2006). O processo de digitalização de uma imagem está relacionado a dois conceitos base: amostragem e quantização. O primeiro refere-se ao intervalo de tempo (período amostral (T_a), medido em unidades de tempo ou espaço) que o sinal analógico é capturado - cuja frequência de amostragem é o inverso do período: $f_a = \frac{1}{T_a}$. O segundo refere-se aos valores que o sinal analógico irá assumir no meio digital - normalmente os valores são mapeados para um conjunto discreto $Q = \{-n_q, \dots, -2q, -q, 0, q, 2q, \dots, m_q\}$, com m e n inteiros (para uma quantização uniforme), onde q é o passo de quantização e os valores iq , $i = -n, \dots, -2, -1, 0, 1, 2, \dots, m$ (LV, 2005). O resultado de tais processos é uma imagem digital monocromática, representada na forma:

$$\begin{bmatrix} f(0,0) & \dots & f(0,h-1) \\ \cdot & & \cdot \\ \cdot & & \cdot \\ \cdot & & \cdot \\ f(w-1,0) & \dots & f(w-1,h-1) \end{bmatrix}$$

Os valores de w e h representam o número de linhas e colunas, respectivamente, da imagem digitalizada. Um elemento da matriz que está na i -ésima linha e na j -ésima coluna $f(i, j)$ é chamado de pixel. O número total de níveis de cinza N é determinado no processo de digitalização. O menor valor é 0, e representa o preto, enquanto o maior valor, $N - 1$, representa o branco.

O Processamento Digital de Imagem (PDI) envolve um conjunto de técnicas focadas na análise de dados multidimensionais, na manipulação de imagens por computador, na qual a entrada e a saída do processo são imagens. A Visão Computacional e a Computação Gráfica são disciplinas que estão intimamente ligadas ao PDI. Uma diferença básica entre elas é que na Computação Gráfica, dados são processados para gerar uma imagem na saída; na Visão Computacional ocorre o inverso da computação gráfica, dados são extraídos a partir de imagens (Figura 13). Outros exemplos de áreas correlatas são Inteligência Artificial, Animação, Reconhecimento de Padrões e a Indústria do Entretenimento.

Figura 13: Processamento digital de imagens e áreas correlatas.




Fonte: (LV, 2005).

2.10 Aprendizagem profunda

Antes de falar sobre aprendizagem profunda (*deep learning*, DL) é necessário apresentar algumas definições para entender o contexto em que a DL está inserido. Por exemplo, IA que estuda como máquinas podem agir de forma inteligente, permitindo que elas realizem tarefas humanas. A aprendizagem de máquina (*machine learning*, ML) que é uma subárea da IA, estuda como os sistemas baseados em IA adquirem seu próprio conhecimento a partir da extração de padrões de dados brutos. DL é uma subárea da ML que estuda como computadores constroem conhecimentos complexos a partir conhecimentos mais simples (GOODFELLOW; BENGIO; COURVILLE, 2016).


Figura 14: Diagrama das áreas relacionadas ao *deep learning*.



Fonte: Elaboração própria.

Apesar de parecer uma tecnologia nova, DL surgiu na década de 1940 e por muitos anos não se tornou popular por conta da falta de infraestrutura computacional (*hardware* e *software*) e da disponibilidade de dados para treinamento. Desde seu início, DL passou por três fases de desenvolvimento que utilizavam termos diferentes para referir-se ao assunto: conhecido como cibernética (*cybernetics*) entre as décadas de 1940 e 1960, que apareceu a partir do desenvolvimento das teorias de aprendizagem biológica e implementação dos primeiros modelos - como o *perceptron*, permitindo o treinamento de um único neurônio; conhecido como connexionismo (*connectionism*) ou redes neurais (*neural networks*) entre os anos de 1960 e 1980, essa abordagem apresentou a retropropagação (*backpropagation*) para treinar uma rede neural com uma ou duas camadas; e em 2006 ressurgiu como *deep learning* (Figura 15) (GOODFELLOW; BENGIO; COURVILLE, 2016).


Figura 15: Duas das três fases históricas de DL e os termos usados para falar sobre o assunto.



Fonte: (GOODFELLOW; BENGIO; COURVILLE, 2016).

Esse último grande crescimento ocorreu devido a basicamente 2 fatores: o aumento das bases de dados digitais; e o avanço na infraestrutura dos computadores, ampliação da capacidade de processamento (*software*, CPU e GPU) e de memória dos computadores (GOODFELLOW; BENGIO; COURVILLE, 2016).

Figura 16: O aumento das bases de dados digitais ao longo do tempo.




Fonte: (GOODFELLOW; BENGIO; COURVILLE, 2016).

A popularização dos computadores (celulares, *tablets* etc.) possibilitou a inclusão digital da sociedade e praticamente toda a rotina passou a ser registrada nesses dispositivos, e, como estes estão conectados, torna-se mais fácil centralizar e organizar os dados de maneira apropriada para o uso de aplicações de ML (Figura 16) (GOODFELLOW; BENGIO; COURVILLE, 2016).

A evolução da infraestrutura dos computadores permitiu o crescimento do tamanho das redes neurais e assim problemas mais complexos passaram a ser alvo de estudos, pois o número de conexões por neurônios aumentou (Figura 17) e consequentemente o tamanho das redes neurais, elevando seu desempenho.


Em 2012, aconteceu um dos fatos mais marcantes para o DL, a CNN *AlexNet* venceu por larga vantagem, reduzindo a taxa de erro do até então estado da arte de 26.1% para 15.3% (Figura 18), a maior competição de reconhecimento de objetos *ImageNet Large Scale Visual Recognition Challenge* (ILSVRC) - e desde então, os últimos vencedores dessa competição tem usado CNN. Diante desse cenário, o DL ganhou mercado e as principais companhias de tecnologia do mundo usam DL, incluindo *Google, Microsoft, Facebook, IBM, Baidu, Apple, Adobe, Netflix, NVIDIA* e *NEC* (GOODFELLOW; BENGIO; COURVILLE, 2016).

Figura 17: O aumento do número de conexões por neurônio ao longo do tempo.



Fonte: (GOODFELLOW; BENGIO; COURVILLE, 2016).

Figura 18: Redução da taxa de erro da competição de reconhecimento de objetos *ImageNet* ao longo do tempo.



Fonte: (GOODFELLOW; BENGIO; COURVILLE, 2016).

2.11 Redes Convolucionais

Redes convolucionais ou redes neurais convolucionais (*Convolution Neural Network*, CNN) são um tipo específico de redes neurais que processam dados representados na forma de matriz, como séries temporais (1-D), imagens (2-D) e vídeo (3-D). Como o nome sugere, ao contrário das redes neurais que operam por meio de multiplicação de matrizes, redes convolucionais aplicam um tipo específico de operação matemática linear chamada de convolução (LECUN et al., 1989 apud GOODFELLOW; BENGIO; COURVILLE, 2016).

A operação de convolução é definida pela equação:

$$s(t) = \int x(a)w(\tau - a)da \quad (2)$$

em que, no contexto de redes convolucionais, o primeiro argumento (função x) é conhecido como a entrada da rede, o segundo argumento (função w) é chamado de *kernel* ou máscara convolucional e a saída é normalmente conhecida como mapa de atributo - τ é usado para representar o rebatimento da máscara, que é uma característica importante da convolução (GOODFELLOW; BENGIO; COURVILLE, 2016). Em sua forma discreta, a operação de convolução entre uma imagem bidimensional I e uma máscara K ($I * K$), o $*$ representa a operação convolução, poderia ser definida pela equação:

$$S(i, j) = (I * K)(i, j) = \sum_m \sum_n I(m, n)K(i - m)(j - n) \quad (3)$$

Não é comum usar as Equações 2 e 3 para implementar a convolução, pois as


máscaras não são rebatidas, o que causa uma contradição devido a existência de uma operação semelhante a convolução, a correlação, que se diferencia apenas pelo não rebatimento da máscara - a maioria das bibliotecas de aprendizagem de máquina usam a operação correlação e chamam de convolução (GOODFELLOW; BENGIO; COURVILLE, 2016).

CNN é um dos principais algoritmos bio-inspirados, porém, seu principal campo de inspiração é a neurociência. Os trabalhos de Hubel e Wiesel (HUBEL; WIESEL, 1968 apud GOODFELLOW; BENGIO; COURVILLE, 2016), (HUBEL; WIESEL, 1959 apud GOODFELLOW; BENGIO; COURVILLE, 2016) e (HUBEL; WIESEL, 1962 apud GOODFELLOW; BENGIO; COURVILLE, 2016) estudaram como o sistema visual dos mamíferos funcionam e suas descobertas influenciaram fortemente os modelos de DL. Eles observaram que neurônios de regiões específicas do cérebro de gatos respondem de forma diferente a padrões específicos de luz, como se cada região do cérebro do gato processasse um tipo específico de informação. Segundo Hubel e Wiesel, tudo começa na região do cérebro chamada cortex visual primário (*primary visual cortex*), de um ponto vista simplificado, as imagens são formadas pela luz que chega no olho e ativa a retina. O neurônios da retina aplicam algum pré-processamento na imagem mas não alteram a forma que são representadas. Então, a imagem passa através do nervo ótico e uma região do cérebro chamada núcleo geniculado lateral (*lateral geniculate nucleus*), o principal papel de ambas regiões é conduzir o sinal do olho até o cortex, que está localizada atrás da cabeça.

Uma camada de uma rede convolucional é projetada para capturar três propriedades do cortex (GOODFELLOW; BENGIO; COURVILLE, 2016):

1. O cortex é organizado em um mapa espacial, que é uma estrutura bidimensional que espelha a estrutura da imagem na retina. CNNs capturam essa propriedade por ter seus atributos definidos em termos de mapas bidimensionais;
2. O cortex contém muitas **células simples**, cujas atividades podem ser caracterizadas por uma função linear da imagem em um pequeno campo receptivo espacialmente localizado. As unidades de detecção das CNNs são projetadas para simular essas propriedades de células simples;
3. O cortex contém muitas **células complexas**, que, assim como as células simples, respondem a atributos, porém, as células complexas são invariantes a pequenos deslocamentos da posição do atributo. Esta característica inspira as unidades de *pooling* nas CNNs.

Figura 19: Arquitetura da LeNet-5, uma rede convolucional para reconhecimento de dígitos.



Fonte: (LECUN et al., 1998).

Redes convolucionais tem desempenhado um papel de destaque na história de DL, CNNs foram os primeiros modelos a apresentaram boa performance, muito antes dos modelos de aprendizagem profunda serem considerados viáveis. CNNs foram as primeiras redes neurais a resolver problemas comerciais significativos e até hoje permanecem no foco da indústria e comércio. Em 1990, o grupo de pesquisa de redes convolucionais da AT&T desenvolveu a LeNet (LECUN et al., 1998 apud GOODFELLOW; BENGIO; COURVILLE, 2016), que reconhece caracteres escritos à mão para leitura de cheques - no fim dos anos 1990, esse sistema fazia a leitura de mais de 10% de todos os cheques dos Estados Unidos. Mais tarde, alguns sistemas de Reconhecimento Ótico de Caracteres (*optical character recognition*, OCR) e reconhecimento de caligrafia foram implantados pela *Microsoft* (SIMARD et al., 2003 apud GOODFELLOW; BENGIO; COURVILLE, 2016). Como já foi dito na Seção 2.10, em 2012 após AlexNet vencer a competição *ImageNet* ILSVRC, as CNNs ressurgiram e o interesse comercial aumentou, porém, anos antes, outras CNNs já haviam vencido outras competições de menos impacto. Nos anos seguintes, novos modelos baseados em redes convolucionais venceram a ILSVRC, alguns deles baseados na arquitetura AlexNet (Figura 19) (RUSSAKOVSKY et al., 2015):

1. em 2013, o time Clarifai de Matthew Zeiler e Rob Fergus venceu a tarefa de classificação de imagem com a rede ZFNet;
2. em 2014, o time da *Google* liderado por Christian Szegedy. venceu a tarefa de detecção de objetos com a rede GoogleLeNet. O grupo de Karen Simonyan e Andrew Zisserman do grupo da Universidade de Oxford venceu a tarefa de classificação de imagem com a rede VGG;
3. em 2015, Kaiming He do grupo da *Microsoft* venceu a tarefa de detecção de objetos com a rede ResNet;
4. em 2016, Wanli Ouyang do grupo CUImage venceu a tarefa de detecção de objetos com um comitê (*ensemble*) de modelos e entre eles havia CNN;

5. em 2017, Wanli Ouyang do grupo BDAT venceu a tarefa de detecção de objetos com uma combinação de CNNs.

3 Trabalhos Relacionados

A maioria dos trabalhos descritos na literatura científica baseiam-se na imagem de orientação (Seção 2.6) para calcular a localização e o tipo dos pontos singulares. Os algoritmos de detecção e classificação de singularidades podem ser categorizados como:

1. Baseado no *Poincaré index* (*Plindex*);
2. Baseado no particionamento da imagem de orientação;
3. Baseado em *template*;
4. Baseado na curvatura da orientação de regiões de pontos singulares;
5. Outros.

Um método sofisticado e prático que baseia-se no *Plindex*, um campo vetorial e uma curva que envolve esse campo, foi proposto por Kawagoe e Tojo (1984). Por meio da imagem de orientação, em uma janela deslizante, é calculado o somatório das diferenças dos ângulos de cada pixel em torno de uma vizinhança para determinar o tipo e a localização dos pontos singulares de uma imagem de impressão digital. Há outros trabalhos que utilizam o *Plindex* como parte do processo de detecção e classificação de singularidades, como em (JIN; KIM, 2010; ZHOU; GU; ZHANG, 2007).

Alguns algoritmos agrupam os ângulos da imagem de orientação, de acordo com suas similaridades, formando conjuntos, e estes são separados por linhas que determinam suas fronteiras. As interseções entre essas linhas fornecem a localização das singularidades, como em (RAMO et al., 2001; HUANG; LIU; HUNG, 2007; GUPTA; GUPTA, 2015). Gupta e Gupta (2015) propuseram um método que calcula um conjunto de singularidades candidatas por meio do algoritmo de particionamento da imagem de orientação, esse conjunto é validado pela análise do *Plindex*. Para refinar a localização das singularidades e detectar possíveis deltas que não foram descobertos, é realizado um pós-processamento, e assim, apenas singularidades genuínas são detectadas e classificadas.

Nos métodos baseados em *template*, para cada tipo de singularidade, há um filtro (ou *template*) que é convolucionado sobre a imagem de impressão digital para extrair singularidades, como em (NILSSON; BIGUN, 2003; JAIN et al., 2000). Os algoritmos fundamentados na curvatura da orientação de regiões de pontos singulares são bons para detectar e classificar pontos singulares, visto que as áreas onde encontram-se tais pontos são marcadas pela mudança de orientação, como em (CHEN et al., 2011; QI; LIU, 2014) - porém, esse método é sensível a ruído e falsas singularidades são extraídas.

Há outras formas de extrair singularidades (p. ex. aprendizagem de máquina e modelos matemáticos). Qi e Liu (2014) propuseram um método baseado em um modelo

polinomial complexo (*Zero-pole model*) e uma janela deslizante para detectar e classificar singularidades. *Zero-pole model* da imagem de orientação é essencialmente um polinômio racional complexo cujos *zero* e *pole* são considerados como pontos singulares laço e delta, respectivamente. [Silva et al. \(2017\)](#) propuseram um novo método de classificação e detecção de singularidades baseado na matriz de orientação, eles convertem a matriz de ângulos em imagem e usam um algoritmo de extração de terminação para localizar e classificar singularidades. [Qin et al. \(2017\)](#) apresentaram um método de detecção e classificação de singularidades baseado em redes neurais, que combina CNN e um modelo de probabilidade. Primeiramente eles treinam um classificador com sub-imagens ou blocos rotulados em 3 Classes: Laço, Delta e Não-singularidade. Então, eles usam uma CNN para estimar se o centro de um bloco é uma singularidade ou não. Finalmente, eles aplicam um modelo probabilístico para determinar a posição da singularidade. O trabalho de [Qin et al. \(2017\)](#) serviu de fonte de resultados de métodos de detecção de singularidades, o desempenho desses métodos são apresentados junto com o método proposto neste trabalho.

Todos os métodos que dependem da matriz de orientação para classificar e detectar singularidades são sensíveis a ruídos presentes em imagens de baixa qualidade. Além do custo de ter que calcular a matriz de orientação, os métodos acabam detectando falsas singularidades em imagens de baixa qualidade. Já os métodos que baseiam-se em redes neurais são resistentes a imagens de baixa qualidade, porém, são dependentes de configuração (arquitetura e hiper-parâmetros), gabarito e de quantidade dados para o treinamento.

4 MATERIAIS E MÉTODOS

Este capítulo apresenta as ferramentas e bases de dados utilizadas, assim como a descrição detalhada do método proposto. A Seção 4.1 mostra bibliotecas e o ambiente usados no desenvolvimento deste trabalho. A Seção 4.2 descreve as informações sobre as bases de dados usadas, a Seção 4.3 apresenta o sistema usado para gerar as bases de imagens da Classe Neg. A Seção 4.4 mostra as métricas usadas na avaliação do método proposto neste trabalho, que é apresentado na Seção 4.5.

4.1 Ambiente de Desenvolvimento

Foi utilizada a linguagem de programação *Python* 3.6, junto com a API de rede neural Keras 2.2.0, a biblioteca Tensorflow GPU 1.8.0 e a aplicação *web Jupyter Notebook*, tudo instalado em um computador com processador Intel *CoreTM* i5-3537U 1.8 GHz, 8GB de memória RAM DDR3, placa de vídeo da Nvidia GeForce GT 730M, e sistema operacional Microsoft® Windows 10 de 64 bits.

4.2 Bases de dados

As imagens utilizadas são provenientes das bases de dados:

- (I) FVC2000-3
- (II) FVC2002-1
- (III) FVC2004-1
- (IV) FVC2006-3
- (V) SPD2010

Todas as bases de dados que tem o prefixo FVC (I-IV) foram concedidas pela competição de verificação de impressão digital (*Fingerprint Verification Competition*) (veja na Seção 2.8). De 2000 a 2004, a FVC disponibilizou as imagens das bases de dados usadas em cada edição da competição. Ela gerou 2 conjuntos de imagens, o conjunto A com 800 imagens para teste e o conjunto B com 80 imagens para treino. Todas elas foram coletadas por meio de sensores e geradas a partir de 110 dedos diferentes com 8 amostras por dedo. Em 2006, foram utilizados 112 dedos diferentes com 12 amostras por dedo e 2 conjuntos com 1680 e 120 imagens, do conjunto A e B, respectivamente - veja a Tabela 1. Em todas essas bases, as imagens estão em escala de cinza de 256 níveis e no formato .bmp.

A base de dados [V](#) é fornecida pela primeira competição de detecção de singularidades (*Singular Points Detection*, SPD) realizada em 2010 ([F.](#); [OLIVEIRA](#); [CAMPILHO](#), 2010). São 500 imagens no total, divididas em 2 conjuntos de 290 e 210, teste e treino, respectivamente. Todas elas foram colhidas de homens e mulheres com idade entre 20 e 62 anos, oriundos de sete países, e capturadas por um sensor óptico (Microsoft® Fingerprint Reader - modelo 1033) sem qualquer restrição de pose dos dedos, e estão em escala de cinza de 256 níveis, no formato .bmp e dimensão 355x390. Para essa base de dados, a organização da competição disponibiliza o gabarito das singularidades, coordenadas $[x,y]$ e o tipo (Laço ou Delta), baseado na definição de pontos singulares de Henry ([HENRY](#), 1900).


Tabela 1: Informações sobre as bases de dados

Nome	Tipo de Sensor	Tamanho da Imagem	Resolução	Qtd. Imagens
FVC2000-3	Ótico	448x478	500 dpi	800
FVC2002-1	Ótico	388x374 (142 Kpixels)	500 dpi	800
FVC2004-1	Ótico	640x480 (307 Kpixels)	500 dpi	800
FVC2006-3	Térmico	400x500 (200 Kpixels)	500 dpi	1680
SPD2010	Ótico	355x390	-	500

Fonte: Elaboração própria.

As bases de dados da FVC ([I-IV](#)) passaram por um pré-processamento (*Enhancement* ou realce) para remover ruídos e melhorar a qualidade das imagens - este passo foi realizado pelo *VeryFinger SDK* da empresa [Neurotechnology](#)® (Figura 20). Portanto, as bases de dados foram duplicadas e, para cada uma delas, existe uma pré-processada - a Figura 21 mostra exemplos de imagens pré-processadas e sem pré-processamento. Além da melhoria na qualidade das imagens, o *VeryFinger SDK* extrai informações sobre as singularidades: x, y e *tipo*, em que x, y representam as coordenadas da singularidade e o *tipo* que pode ser Laço ou Delta - como mostra a Tabela 2. Devido a ausência de gabarito de singularidade dessas bases, essas informações extraídas no pré-processamento são usadas como referência no momento de avaliar o desempenho do detector e na geração dos bancos do classificador.

Figura 20: Visão Geral do Pré-processamento.



Fonte: Elaboração própria.


Tabela 2: Quantidade de singularidades extraída por base de dados.

Base de dados	Laço	Delta	Neg ¹
FVC2000-3	793	342	1067
FVC2002-1	846	283	1074
FVC2004-1	864	304	1045
FVC2006-3	1613	737	1102
SPD2010	537	236	1831

¹ Essa classe foi extraída por meio do Marcador de Singularidades (Subseção 4.3)

Fonte: Elaboração própria.

Figura 21: Exemplos de imagens das bases de dados: (a) FVC2000-3; (b) FVC2000-3 com realce; (c) FVC2002-1; (d) FVC2002-1 com realce; (e) FVC2004-1; (f) FVC2004-1 com realce; (g) FVC2006-3; (h) FVC2006-3 com realce; (i) SPD2010.




Fonte: Elaboração própria.

4.3 Marcador de Singularidades

Foi desenvolvida uma ferramenta de código aberto com o objetivo de gerar os bancos de dados para treinar o modelo que classifica singularidades - *Fingerprint Label Marker* (SILVA, 2019). O marcador de singularidades possibilita o usuário marcar, rotular e salvar uma região da imagem original, gerando novas imagens, de menor dimensão, a partir da imagem original - essa região é definida a partir do ponto da imagem que recebe o clique do usuário, ele é usado como ponto central de um quadrado de dimensão 50x50 pixels. Os rótulos de cada imagem marcada pelo usuário depende do botão do mouse que é clicado: o botão esquerdo do mouse marca imagens como Laço (na cor azul); o botão central como Delta (na cor verde) e o direito como Neg (na cor vermelho) - conforme a Figura 22. Todas as imagens geradas pelo usuário são salvas em pastas cujo nome corresponde ao rótulo da classe marcada pelo usuário. Além disso, é gerado um arquivo .txt contendo informações (x , y , rótulo) para cada região definida pelo usuário. Para baixar a ferramenta ou obter mais informações, acesse a página do [Github](#).

Figura 22: Marcador de singularidades *Fingerprint Label Marker*. As marcações em azul, verde e vermelho representam as Classes Laço, Delta e Neg, respectivamente.



Fonte: Elaboração própria.

4.4 Métricas

Neste trabalho é usada matriz de confusão e as métricas de avaliação acurácia (*Acc*), medida-F (*F*) da biblioteca *scikit-learn* (PEDREGOSA et al., 2011), interseção sobre a união (*Intersection Over Union*, *IoU*), taxa de detecção (*detection rate*, *DR*) e taxa de erro de detecção ou falso alarme (*false alarm*, *FA*).

A matriz de confusão é uma tabela que permite visualizar o desempenho de métodos de classificação em que a visão da perspectiva das linhas representa as classes do gabarito e a visão da perspectiva das colunas representa as classes preditas pelo método de classificação - Tabela 3.

Tabela 3: Matriz de confusão.

		Classe Predita	
		Positivo	Negativo
Gabarito	Positivo	VP	FN
	Negativo	FP	VN

Fonte: Elaboração própria.

Os elementos da matriz de confusão VP, FP, FN e VN são verdadeiro positivo, falso positivo, falso negativo e verdadeiro negativo, respectivamente. Estes elementos são usados na formulação das métricas acurácia (Acc) e *medida-F* (F) abaixo.

A acurácia (Acc) é definida por:

$$acurácia = \frac{VP + VN}{VP + FP + FN + VN} \quad (4)$$

Como a acurácia não é uma métrica robusta, foi utilizada a medida-F (F), que é definida por:

$$precisão (P) = \frac{VP}{VP + FP} \quad (5)$$

$$revocação (R) = \frac{VP}{VP + FN} \quad (6)$$

$$medida-F (F) = 2 \times \frac{precisão \times revocação}{precisão + revocação} \quad (7)$$


A *medida-F* varia entre $[0, 1]$ e quanto maiores forem os valores de precisão (P) e revocação (R), maior será o seu valor, indicando que o método alcançou desempenho elevado. Neste trabalho, as Equações 5, 6 e 7 são calculadas por classe e, de forma geral, por meio do cálculo da mediana das 3 classes.

A interseção sobre a união IoU avalia o desempenho de detectores de objetos em imagens. IoU é uma medida baseada em duas áreas demarcadas: a que o objeto está, A , e a predita pelo detector, P ; e é definida por:

$$IoU = \frac{I}{U} \quad (8)$$

em que I e U são a área de interseção e área de união entre A e P , respectivamente. Essa medida varia entre $[0,1]$, quando há um total casamento entre A e P , IoU é igual a 1, e quando não há interseção, IoU é 0 - veja Figura 23. Neste trabalho, as áreas A e P são calculadas por meio de pontos centrais obtidos do gabarito e do detector, respectivamente.

Figura 23: Interseção sobre a união (IoU). A região A representa onde o objeto está e a região P representa onde o detector localizou.



Fonte: Elaboração própria.

A taxa de detecção (DR) baseia-se na distância Euclidiana e é usada para medir a precisão de localização do detector de singularidades. Seja $SP(x, y, t)$ uma singularidade do gabarito e $SP'(x', y', t')$ uma singularidade detectada, dado um valor de distância limite r , se $t = t'$ e $\sqrt{(x - x')^2 + (y - y')^2} < r$, SP' é uma detecção verdadeira, caso contrário, é um erro. A métrica DR é definida por:

$$DR = \frac{DV}{TSG} \quad (9)$$

em que, DV e TSG representam a quantidade de detecção verdadeira e o total de singularidades do gabarito, respectivamente. A taxa de erro de detecção (FA) é definida por:


$$FA = \frac{DF}{TSG} \quad (10)$$

em que, DF e TSG representam a quantidade de detecção falsa e o total de singularidades do gabarito, respectivamente.

4.5 Método Proposto

Este trabalho propõe um método de detecção por meio de classificação de singularidades em imagens de impressão digital baseado em CNN e janela deslizante. Para fazer a detecção, é necessário treinar um modelo que classifique singularidades nas 3 Classes propostas por este trabalho (Laço, Delta e Neg) - Figura 24. As seções seguintes mostram em detalhes como foi desenvolvida a classificação e a detecção de singularidades.

Figura 24: Visão geral do classificador.



Fonte: Elaboração própria.

4.5.1 Classificação

Nesta etapa, foi desenvolvido um modelo para classificar as singularidades em Laço, Delta ou Neg. O treinamento do classificador é dividido em 4 etapas:

1. Baseadas nas informações de singularidades extraídas do pré-processamento do *VeryFinger SDK* da empresa *Neurotechnology*[©], são geradas as bases de dados para as Classes Laço e Delta com imagens de dimensão 50x50;
2. Extração de imagens, dimensão 50x50, de singularidades do tipo Neg por meio do marcador de singularidades *Fingerprint Label Marker* (Seção 4.3);
3. Por meio do *ImageDataGenerator* do *Keras* (CHOLLET et al., 2015), as bases de dados são ampliadas, estaticamente, conforme os parâmetros definidos na Tabela 4;
4. O treinamento do classificador por meio de Rede Neural Convolutiva do *Keras* (CHOLLET et al., 2015).


Tabela 4: Parâmetros usados no *ImageDataGenerator*.

Parâmetro	Valor
<i>rotation_range</i>	180
<i>horizontal_flip</i>	True
<i>vertical_flip</i>	True
<i>zoom_range</i>	0,2

Fonte: Elaboração própria.

A partir das bases da Tabela 1 e por meio do gabarito obtido no pré-processamento, são geradas as bases de dados com imagens de dimensão 50x50 para as Classes Laço e Delta - as imagens da Classe Neg são geradas manualmente por meio do Marcador de Singularidades - Figura 25. Após a criação das bases de dados para as três classes, para aumentar o número de amostras e equilibrar a distribuição de imagens entre as classes, é utilizado, uma única vez de maneira estática ou *offline*, o *ImageDataGenerator* do *Keras* - na Tabela 4, os valores dos parâmetros foram definidos de maneira que não houvesse perda de singularidades, foi usado o valor de 180 no parâmetro *rotation_range* para rotacionar imagens de 0° até 180°, foi habilitado o rebatimento horizontal (*horizontal_flip*) e vertical (*vertical_flip*), e, empiricamente, foi escolhido o valor 0,2 para o parâmetro *zoom_range*, que aplica o zoom sobre as imagens.

Figura 25: Extração de singularidades por meio do marcador de singularidades *Fingerprint Label Marker*.



Fonte: Elaboração própria.

Após a criação das bases aumentadas, é feito o carregamento em memória das imagens (50x50x1), que são particionadas em 3 conjuntos: treino (90%), validação (5%) e teste (5%). Esta divisão é feita pelo método *train_test_split* da biblioteca *scikit-learn* (PEDREGOSA et al., 2011), que o faz de forma aleatória e estratificada, de modo que as proporções das Classes (Laço, Delta e Neg) são mantidas em cada partição. Os rótulos das classes são representados seguindo o formato *one hot encoding* (Tabela 5) e armazenados em um *NumPy Array* (OLIPHANT, 2006). Em seguida, os valores dos pixels das imagens

são convertidos de inteiro para real (*float32*) e normalizados entre $[0,1]$ pela divisão por 255. Os conjuntos das imagens de treino e validação são usados para treinar o classificador, e o de teste para testar e calcular a matriz de confusão e as métricas acurácia (Equação 4), precisão (Equação 5), revocação (Equação 6) e medida-F (Equação 7).

Tabela 5: Representação dos rótulos (*encoding*) das Classes Laço, Delta e Neg.

Classe	Representação
Laço	$[1,0,0]$
Delta	$[0,1,0]$
Neg	$[0,0,1]$

Fonte: Elaboração própria.

Para avaliar o efeito do realce na detecção de singularidades, as nove bases de imagens foram divididas em dois grupos: quatro com e cinco sem pré-processamento. Cada uma delas foi usada para treinar um classificador, o que gerou nove classificadores. Esses nove foram usados para classificar as imagens das bases de seu grupo e assim validar a capacidade de generalização - por exemplo, treina um classificador, conforme Tabelas 6 e 7, com a Base de dados FVC2000-3 sem pré-processamento e testa sobre as demais bases desse grupo sem pré-processamento. No final, para cada grupo, foi escolhido um classificador que é usado para detectar singularidades.

Tabela 6: Sumário do classificador.

Camada	Saída	Filtro	Passo	Param #
Conv2D	(None, 50, 50, 64)	(5, 5)	1	1664
Conv2D	(None, 50, 50, 64)	(5, 5)	1	102464
MaxPooling	(None, 25, 25, 64)	-	(2, 2)	0
Conv2D	(None, 25, 25, 128)	(3, 3)	1	73856
MaxPooling	(None, 12, 12, 128)	-	(2, 2)	0
Dropout	(None, 12, 12, 128)	-	-	0
Flatten	(None, 18432)	-	-	0
Dense	(None, 128)	-	-	2359424
Dense	(None, 3)	-	-	387
Total de parâmetros:				2,537,795

Fonte: Elaboração própria.

Tabela 7: Alguns dos hiper-parâmetros usados no classificador.

Nome	Valor
<i>batch_size</i>	128
<i>epochs</i>	30
<i>kernel_initializer</i>	<i>glorot_uniform</i>
<i>loss</i>	<i>categorical_crossentropy</i>
<i>optimizer</i>	<i>Adam</i>
<i>metrics</i>	<i>accuracy</i>

Fonte: Elaboração própria.

Foram realizados experimentos para encontrar a arquitetura da rede, a configuração dos hiper-parâmetros e o pré-processamento (Tabela 4) mais adequados a solução do problema - esta etapa foi realizada de forma empírica, testando diferentes valores de hiper-parâmetros da Tabela 7 e camadas da rede. Então, após testar algumas configurações diferentes, chegou-se à arquitetura apresentada na Figura 19 e Tabela 6.

4.5.2 Detecção

A detecção de singularidades usa os dois classificadores selecionados, conforme definido na Seção 4.5.1, para localizar as singularidades presentes em imagens de impressão digital com e sem pré-processamento (Figura 26). A seleção do melhor classificador, tanto do grupo com imagens pré-processadas, quanto as sem pré-processamento, baseia-se no valor da mediana e média das Medidas-F produzidas em cada base.

O processo de detecção vai gerar um conjunto de singularidades candidatas em que cada uma está representada na forma $(x, y, rótulo, confiança)$. No final, é aplicado um pós-processamento para filtrar as singularidades verdadeiras, que é baseado na interseção entre as singularidades candidatas e na confiança calculada pelo classificador.

Conforme ilustrado no pseudocódigo do Algoritmo 1, dado um conjunto de imagens de impressão digital I , classificador M , comprimento e altura da janela deslizante w e h , respectivamente, e o passo de deslocamento, ou *stride*, para cada imagem img em M , é chamado o método *janela_deslizante* que retorna uma subimagem *sub_img* de img e suas coordenadas x, y (representando o ponto superior esquerdo) a cada iteração do laço de repetição (Linha 11). Toda *sub_img* passa pelo processo de conversão e normalização aplicada no treinamento de M e é submetida ao seu método *predict*. O retorno deste método representa a confiança ou certeza que M calcula em relação as Classes Laço, Delta e Neg, ou seja, se M computar que *sub_img* é da Classe Laço, o valor da posição 0 do vetor *confianca*, que recebe a saída da função *Softmax* da rede, será mais alto que os demais. É aplicada a operação de arredondamento no vetor *confianca*, pois os valores retornados do método *predict* são do tipo real e os valores que representam as classes são

do tipo inteiro. No final, todas as singularidades candidatas dos tipos Laço ou Delta são armazenadas no vetor *singularidades*.

Como pode ser visto na Figura 26, dependendo do valor do parâmetro *stride*, é comum que uma mesma singularidade seja detectada mais de uma vez e, portanto, é necessário que haja uma filtragem para manter apenas uma - o critério de seleção é baseado na confiança produzida por *M*.


Algoritmo 1 Detecção de singularidades

```

1:  $I \leftarrow imagens$ 
2:  $M \leftarrow classificador$ 
3:  $s \leftarrow 10 / * stride * /$ 
4:  $w \leftarrow 50$ 
5:  $h \leftarrow 50$ 
6:  $Laco \leftarrow [1, 0, 0]$ 
7:  $Delta \leftarrow [0, 1, 0]$ 
8:  $singularidades \leftarrow []$ 
9:
10: for  $img \leftarrow I$  do
11:   for  $(x, y, sub\_img) \leftarrow janela\_deslizante(img, s, (w, h))$  do
12:
13:      $sub\_img \leftarrow converterFloat32(sub\_img)/255$ 
14:      $confianca \leftarrow M.predict(sub\_img)$ 
15:      $classe \leftarrow arredondar(confianca)$ 
16:
17:      $rotulo \leftarrow None$ 
18:     if  $classe = Laco$  then
19:        $rotulo \leftarrow "Laco"$ 
20:     else if  $classe = Delta$  then
21:        $rotulo \leftarrow "Delta"$ 
22:
23:     if  $rotulo \neq None$  then
24:        $singularidades.add(x, y, rotulo, confianca)$ 

```

Figura 26: Visão geral do detector. O quadrado azul representa a primeira iteração da janela deslizante, o quadrado laranja representa a segunda iteração com a aplicação do *stride* sobre a coluna, e o quadrado vermelho representa a iteração da primeira aplicação do *stride* sobre a linha.



Fonte: Elaboração própria.

5 APRESENTAÇÃO E ANÁLISE DOS RESULTADOS

Este capítulo descreve a apresentação e análise dos resultados da classificação e detecção de singularidades. A Seção 5.1 apresenta os resultados, separados pelos grupos com e sem pré-processamento, dos testes de classificação sobre as bases de dados da Tabela 1 e mostra os problemas de gabarito na Seção 5.1.3. A Seção 5.2 mostra o desempenho dos dois detectores selecionados por grupo sobre as bases acima citadas. A Seção 5.3 apresenta resultados comparativos com outros métodos de detecção de singularidades.

5.1 Classificação

Cada base de dados foi usada para treinar um classificador, e como há dois grupos de imagens, foram gerados nove classificadores: cinco para as sem e quatro para imagens com pré-processamento. Para avaliar a capacidade de generalização de todos os classificadores, eles são testados sobre as demais bases de seu grupo. Na classificação, são calculadas as métricas acurácia (Equação 4) considerando as 3 classes (Tabelas 8 e 15) e medida-F (Equação 7) global ou geral (Tabelas 9 e 16) e separada por classe (Tabelas 10-12 e Tabelas 17-19). Além disso, é calculada a matriz de confusão dos 2 melhores classificadores (Tabelas 14 e 21) selecionados para detectar singularidades. É importante destacar que quando um classificador é testado sobre a base de dados em que foi treinado, esse teste é feito sobre o conjunto de teste e não sobre toda a base de dados, portanto, todas as imagens são inéditas para o classificador e as métricas calculadas nesse caso são referentes a esse conjunto.

5.1.1 Imagens sem pré-processamento

De modo geral, os classificadores apresentaram desempenho satisfatório, 60% dos valores de acurácia (Tabela 8) e 60% dos valores medida-F (Tabela 9) são acima de 90%. Observa-se que os classificadores obtiveram os piores resultados sobre a Base SPD2010 e, exceto o treinado sobre ela, a maior acurácia alcançada foi pelo classificador treinado sobre a Base FVC2004-1 e a maior medida-F foi pelos classificadores treinados sobre as Bases FVC2000-3 e FVC2004-1.

Tabela 8: Acurácia dos testes de classificação de singularidades com as imagens sem pré-processamento.

	Teste					
	FVC2000-3	FVC2002-1	FVC2004-1	FVC2006-3	SPD2010	
Treino	FVC2000-3	1	0,97	0,94	0,91	0,76
	FVC2002-1	0,93	1	0,96	0,88	0,76
	FVC2004-1	0,95	0,98	0,99	0,93	0,77
	FVC2006-3	0,86	0,88	0,85	0,99	0,59
	SPD2010	0,85	0,94	0,92	0,86	0,99

Fonte: Elaboração própria.

Tabela 9: Média dos valores de medida-F das 3 classes alcançados nos testes de classificação de singularidades com as imagens sem pré-processamento.

Geral	Teste					
	FVC2000-3	FVC2002-1	FVC2004-1	FVC2006-3	SPD2010	
Treino	FVC2000-3	1	0,96	0,95	0,9	0,75
	FVC2002-1	0,94	1	0,96	0,89	0,74
	FVC2004-1	0,95	0,98	0,99	0,93	0,75
	FVC2006-3	0,86	0,88	0,85	0,99	0,57
	SPD2010	0,85	0,94	0,92	0,86	0,99

Fonte: Elaboração própria.

Fazendo um comparativo entre as duas principais classes, os resultados dos classificadores separados por classe apontam uma pequena superioridade no desempenho sobre a Classe Delta, pois 48% dos valores de medida-F da Classe Delta são superiores a Classe Laço - Tabelas 10 e 11. A Tabela 12 mostra os resultados de medida-f sobre a Classe Neg.

Tabela 10: Medida-F (F), precisão (P) e revocação (R) dos testes de classificação de singularidades com as imagens sem pré-processamento do tipo Laço.

Laço	Teste															
	FVC2000-3			FVC2002-1			FVC2004-1			FVC2006-3			SPD2010			
Treino		F	P	R	F	P	R	F	P	R	F	P	R	F	P	R
	FVC2000-3	1	1	1	0,96	0,97	0,96	0,95	0,94	0,95	0,9	0,9	0,89	0,71	0,91	0,58
	FVC2002-1	0,92	0,88	0,96	1	1	1	0,97	0,96	0,98	0,86	0,77	0,98	0,72	0,93	0,59
	FVC2004-1	0,95	0,94	0,96	0,99	0,99	0,98	0,99	0,99	1	0,92	0,88	0,97	0,69	0,96	0,54
	FVC2006-3	0,86	0,97	0,77	0,9	0,99	0,83	0,89	0,98	0,81	1	1	1	0,48	0,95	0,32
	SPD2010	0,84	0,92	0,78	0,94	0,98	0,9	0,92	0,94	0,9	0,86	0,88	0,84	0,99	1	0,99

Fonte: Elaboração própria.

Tabela 11: Medida-F (F), precisão (P) e revocação (R) dos testes de classificação de singularidades com as imagens sem pré-processamento do tipo Delta.

Delta	Teste															
	FVC2000-3			FVC2002-1			FVC2004-1			FVC2006-3			SPD2010			
Treino	F	P	R	F	P	R	F	P	R	F	P	R	F	P	R	
	FVC2000-3	1	1	1	0,96	0,96	0,96	0,91	0,93	0,9	0,93	0,93	0,94	0,83	0,96	0,73
	FVC2002-1	0,95	0,98	0,92	1	1	1	0,96	0,98	0,94	0,9	0,95	0,86	0,8	0,9	0,72
	FVC2004-1	0,95	0,95	0,94	0,98	0,98	0,99	1	1	1	0,93	0,94	0,92	0,83	0,9	0,77
	FVC2006-3	0,88	0,94	0,83	0,88	0,94	0,83	0,8	0,9	0,72	0,99	0,99	1	0,61	0,94	0,45
	SPD2010	0,85	0,76	0,96	0,94	0,90	0,99	0,91	0,86	0,98	0,87	0,8	0,96	0,99	1	0,98

Fonte: Elaboração própria.

Tabela 12: Medida-F (F), precisão (P) e revocação (R) dos testes de classificação de singularidades com as imagens sem pré-processamento do tipo Neg.

Neg	Teste															
	FVC2000-3			FVC2002-1			FVC2004-1			FVC2006-3			SPD2010			
Treino	F	P	R	F	P	R	F	P	R	F	P	R	F	P	R	
	FVC2000-3	1	1	1	0,97	0,97	0,98	0,96	0,95	0,97	0,88	0,89	0,88	0,75	0,62	0,96
	FVC2002-1	0,94	0,96	0,92	1	1	1	0,96	0,96	0,97	0,89	0,99	0,80	0,72	0,60	0,9
	FVC2004-1	0,97	0,98	0,96	0,98	0,99	0,98	0,99	1	0,99	0,94	0,98	0,90	0,75	0,61	0,97
	FVC2006-3	0,84	0,74	0,98	0,86	0,77	0,99	0,85	0,75	0,98	0,99	1	0,99	0,62	0,46	0,96
	SPD2010	0,87	0,91	0,83	0,95	0,96	0,94	0,93	0,96	0,91	0,85	0,94	0,78	0,99	0,98	1

Fonte: Elaboração própria.

Como mostra a Tabela 13, considerando a mediana e a média dos resultados de medida-F apresentados na Tabela 9, foi selecionado o classificador treinado sobre a Base FVC2004-1 (Classificador 1) para ser usado na detecção de singularidades em imagens sem pré-processamento. O classificador treinado sobre a Base FVC2000-3 apresentou desempenho próximo ao do Classificador 1, no entanto, o treinado sobre a Base FVC2004-1 foi escolhido pelo valor da média das medidas-F.

Tabela 13: Desempenho dos classificadores de imagens sem pré-processamento baseado na medida-F.

	FVC2000-3	FVC2002-1	FVC2004-1	FVC2006-3	SPD2010	Mediana	Média
FVC2000-3	1	0,96	0,95	0,9	0,75	0,95	0,91
FVC2002-1	0,94	1	0,96	0,89	0,74	0,94	0,9
FVC2004-1	0,95	0,98	0,99	0,93	0,75	0,95	0,92
FVC2006-3	0,86	0,88	0,85	0,99	0,57	0,86	0,83
SPD2010	0,85	0,94	0,92	0,86	0,99	0,92	0,91

O Classificador 1 errou apenas uma imagem do conjunto de teste. A matriz de confusão referente a essa execução pode ser vista na Tabela 14. A Figura 28(a) mostra a imagem errada pelo Classificador 1, que foi gabaritada como Neg, porém o Classificador

1 computou como Laço. Esse erro deve ter sido causado por falha do gabarito, pois a imagem (a) apresenta características de Laço e não de Neg.

Tabela 14: Matriz de confusão gerada durante o teste do classificador 1.

		Classe Predita		
		Laço	Delta	Neg
Classe verdadeira	Laço	109	0	0
	Delta	0	76	0
	Neg	1	0	111

Figura 27: Imagem errada pelo Classificador 1 sobre o seu conjunto de teste (gabarito | classe predita): (a) Neg | Laço.



(a)

Fonte: Elaboração própria.

5.1.2 Imagens com pré-processamento

Os classificadores treinados sobre as imagens com pré-processamento apresentaram resultados semelhantes. Na Tabela 15, o desempenho de todos os classificadores é superior a 90%. O mesmo pode ser visto na Tabela 16, na qual todos os valores de medida-F são superiores 0,93. Outro ponto importante nesses resultados é que eles indicam que o pré-processamento favoreceu o desempenho dos classificadores, pois os resultados obtidos sobre as imagens pré-processadas são mais elevados que os das sem pré-processamento.

Tabela 15: Acurácia das 3 classes dos testes de classificação de singularidades com as imagens pré-processadas.

	Teste				
		FVC2000-3	FVC2002-1	FVC2004-1	FVC2006-3
Treino	FVC2000-3	0,99	0,98	0,98	0,94
	FVC2002-1	0,96	0,99	0,98	0,93
	FVC2004-1	0,97	0,98	0,99	0,98
	FVC2006-3	0,96	0,98	0,93	0,99

Fonte: Elaboração própria.

Tabela 16: Média dos valores de medida-F das 3 classes alcançados nos testes de classificação de singularidades com as imagens pré-processadas.

Geral	Teste				
	FVC2000-3	FVC2002-1	FVC2004-1	FVC2006-3	
Treino	FVC2000-3	0,99	0,98	0,97	0,94
	FVC2002-1	0,96	0,99	0,98	0,94
	FVC2004-1	0,97	0,98	0,98	0,99
	FVC2006-3	0,96	0,98	0,99	0,94

Fonte: Elaboração própria.

Observando os resultados dos classificadores separados por classe, nota-se uma pequena superioridade no desempenho sobre a Classe Delta, pois 44% dos valores de medidas-F da Classe Delta é superior a Classe Laço (Tabelas 17 e 18) - a Tabela 19 mostra os resultados de medida-F da Classe Neg.

Tabela 17: Medida-F (F), precisão (P) e revocação (R) dos testes de classificação de singularidades com as imagens pré-processadas do tipo Laço.

Laço	Teste												
	FVC2000-3			FVC2002-1			FVC2004-1			FVC2006-3			
Treino		F	P	R	F	P	R	F	P	R	F	P	R
	FVC2000-3	0,99	0,99	1	0,98	0,97	0,99	0,97	0,97	0,98	0,94	0,94	0,95
	FVC2002-1	0,96	0,97	0,95	0,99	0,99	1	0,98	0,97	0,98	0,94	0,95	0,93
	FVC2004-1	0,97	0,98	0,96	0,98	0,98	0,98	0,98	0,98	0,97	0,99	0,99	0,99
	FVC2006-3	0,95	0,98	0,93	0,98	0,99	0,97	1	1	1	0,94	0,98	0,91

Fonte: Elaboração própria.

Tabela 18: Medida-F (F), precisão (P) e revocação (R) dos testes de classificação de singularidades com as imagens pré-processadas do tipo Delta.

Delta	Teste												
	FVC2000-3			FVC2002-1			FVC2004-1			FVC2006-3			
Treino		F	P	R	F	P	R	F	P	R	F	P	R
	FVC2000-3	0,99	1.00	0,98	0,99	0,99	0,99	0,98	0,98	0,99	0,95	0,97	0,94
	FVC2002-1	0,97	0,99	0,96	1.00	1.00	1.00	0,98	0,99	0,98	0,94	0,97	0,91
	FVC2004-1	0,97	0,98	0,97	0,98	0,98	0,99	0,98	0,97	0,99	0,99	0,99	1.00
	FVC2006-3	0,97	0,97	0,96	0,99	0,98	0,99	0,99	1.00	0,98	0,94	0,97	0,92

Fonte: Elaboração própria.

Usando o mesmo critério do Classificador 1, foi selecionado o classificador treinado sobre a Base FVC2004-1 (Classificador 2) para ser usado na detecção de singularidades em imagens com pré-processamento - Tabela 20. Novamente, o classificador treinado sobre

Tabela 19: Medida-F (F), precisão (P) e revocação (R) dos testes de classificação de singularidades com as imagens pré-processadas do tipo Neg.

Neg	Teste												
	FVC2000-3			FVC2002-1			FVC2004-1			FVC2006-3			
Treino		F	P	R	F	P	R	F	P	R	F	P	R
	FVC2000-3	0,99	0,99	0,99	0,98	0,99	0,98	0,97	0,99	0,96	0,93	0,93	0,94
	FVC2002-1	0,96	0,94	0,98	0,99	1,00	0,99	0,98	0,98	0,98	0,91	0,88	0,95
	FVC2004-1	0,97	0,96	0,98	0,98	0,99	0,98	0,98	0,98	0,98	0,99	1,00	0,99
	FVC2006-3	0,96	0,94	0,99	0,98	0,98	0,99	0,99	0,99	1,00	0,92	0,87	0,97

Fonte: Elaboração própria.

a Base FVC2004-1 conseguiu melhor desempenho que os demais. Não é possível afirmar que essa base seja a melhor para treinar o classificador, pois vai depender do conjunto de imagens usadas no treinamento, que são separadas aleatoriamente.

Tabela 20: Desempenho dos classificadores de singularidades para imagens com pré-processamento baseado na medida-F.


	FVC2000-3	FVC2002-1	FVC2004-1	FVC2006-3	Mediana	Média
FVC2000-3	0,99	0,98	0,97	0,94	0,97	0,97
FVC2002-1	0,96	0,99	0,98	0,94	0,97	0,96
FVC2004-1	0,97	0,98	0,98	0,99	0,98	0,98
FVC2006-3	0,96	0,98	0,99	0,94	0,97	0,96

A Tabela 21 e a Figura 28 apresentam a matriz de confusão e as imagens erroneamente classificadas sobre o conjunto de teste, respectivamente. O Classificador 2 errou a imagem da Figura 29(a), que apresenta característica de Laço na pequena região superior esquerda, porém, a maior parte da imagem tem característica da Classe Neg, o mesmo acontece com a imagem da Figura 29(b), no entanto, apenas o início da região característica da Classe Laço aparece na imagem - esse e outros problemas de gabarito são explicados na Seção 5.1.3.

Tabela 21: Matriz de confusão gerada durante o teste do Classificador 2.

		Classe Predita		
		Laço	Delta	Neg
Classe verdadeira	Laço	108	0	1
	Delta	0	76	0
	Neg	1	0	111

Figura 28: Imagens erradas pelo Classificador 2 sobre o seu conjunto de teste (gabarito | classe predita): (a) Laço | Neg; (b) Neg | Laço.



Fonte: Elaboração própria.


5.1.3 Problemas no gabarito

Em todas as bases há problemas no gabarito, algumas singularidades não estão localizadas precisamente, estão deslocadas alguns pixels, outras que não estão presentes no gabarito (Figura 29(d)), e tem as que estão marcadas erroneamente (Figuras 29(a) e 29(e)). Esses erros confundem o classificador e, conseqüentemente, o detector. Isso se deve ao fato do gabarito ser obtido por meio de outro método, *VeryFinger SDK*, que não é perfeito e está sujeito a falhas - como não havia gabarito disponível para as bases do FVC essa foi a única solução.

Além disso, as singularidades do tipo Neg de todas as bases foram obtidas pelo sistema descrito na Seção 29. O critério de seleção de amostras dessa classe foi: toda região que não tenha interseção com uma singularidade gabaritada, ou seja, todo resto da imagem que não possui singularidade é considerada da Classe Neg. Assim sendo, há problemas nas fronteiras das regiões que possuem singularidades com as demais. Isso é mais evidente na Classe Laço, pois pela definição de Henry (HENRY, 1900) a localização do Laço é na terminação (minúcia) mais interna do núcleo da impressão digital. Portanto, neste trabalho, a localização correta da singularidade do tipo Laço é o ponto central de um quadrado de 50x50 em que no centro há uma minúcia do tipo terminação. Isso implica que se uma região de 50x50 não envolva uma terminação, ela não deve ser considerada uma marcação correta da Classe Laço.

Há algumas marcações de singularidades que não atendem a definição de Henry e foram gabaritadas com deslocamento (Figura 29(c)). Por esse motivo, em alguns casos, a Classe Laço é confundida com a Neg. As regiões próximas ao núcleo da impressão digital são da Classe Neg, mas em alguns casos no gabarito isso não é verdade. Há problemas com a Classe Delta no banco SPD2010, alguns deles estão na borda da imagem e não é possível localizar (Figura 29(f)).

Figura 29: Exemplos de erros de gabarito: (a) Laço gabaritado fora da ROI (FVC2000-3); (b) Laço gabaritado no lugar errado (FVC2002-1); (c) Laço deslocado (FVC2004-1); (d) Laço não gabaritado (FVC2004-1); (e) Laço gabaritado fora da ROI (FVC2006-3); (f) Delta gabaritado na borda da imagem (SPD2010).



Fonte: Elaboração própria.

5.2 Detecção

O método proposto neste trabalho para detectar singularidades é composto de um classificador e como pretende-se avaliar a influência do realce nesse processo, foram selecionados os dois melhores classificadores (Tabelas 13 e 20) baseados na mediana e média das medidas-F obtidas nos testes, o Classificador 1, que é usado pelo Detector 1 para fazer a detecção em imagens sem pré-processamento, e o Classificador 2, que é usado pelo Detector 2 para fazer a detecção em imagens com pré-processamento. Na detecção são calculadas as métricas IoU (Equação 8) (Tabelas 25 e 29) e medida-F (Equação 7) considerando Laços e Deltas (Tabelas 22 e 26) e separadas por classe (Tabelas 23-24 e

Tabelas 27-28). Devido ao uso da técnica janela deslizante, as singularidades precisam ser filtradas para que possibilite o cálculo das métricas de desempenho supracitadas. Após essa filtragem, é criada uma estrutura de dados que armazena as singularidades candidatas de cada imagem por classe (Laço e Delta). Então, percorre-se as singularidades do gabarito (*sp*), que também são separadas por imagem e classe, de modo que é possível saber as singularidades de cada imagem, e as métricas medida-F e *IoU* são computadas entre todas as singularidades candidatas e *sp*. Em geral, mais de uma singularidade candidata apresenta *IoU* positivo e, nesse caso, é selecionada a de maior valor como singularidade verdadeira (VP) e as demais são consideradas FP - não foi usado um valor limite de *IoU* para computar singularidades detectadas como VP, portanto, se houve interseção entre o gabarito e o que foi detectado, foi considerado acerto. No entanto, há casos em que as singularidades candidatas não apresentam *IoU* positivo e, portanto, são contabilizadas como FN.

Na Seção 5.3, o método proposto é comparado, por meio da métrica DR (Equação 9), com outros métodos de detecção de singularidades sobre a Base FVC2002-1 sem pré-processamento.

5.2.1 Imagens sem pré-processamento

discutir mais sobre a revocação e falar que sempre que tem uma singularidade quando tem

Os resultados apresentados na Tabela 22 mostram que o Detector 1 obteve desempenho mais elevado sobre a Base SPD2010, apesar do Classificador 1, usado pelo Detector 1, ter alcançado desempenho mais baixo sobre essa base. Porém, observando a Tabela 25, nota-se que a localização não foi tão precisa quanto a das outras bases, pois o Detector 1 obteve o valor mais baixo de *IoU*.

Tabela 22: Medida-F (F), precisão (P) e revocação (R) do Detector 1.

	FVC2000-3			FVC2002-1			FVC2004-1			FVC2006-3			SPD2010		
	F	P	R	F	P	R	F	P	R	F	P	R	F	P	R
FVC2004-1	0,79	0,66	0,98	0,76	0,62	1	0,75	0,6	1	0,73	0,58	0,98	0,8	0,69	0,96

Fonte: Elaboração própria.

Tabela 23: Medida-F (F), precisão (P) e revocação (R) do Detector 1 para Classe Laço.

	FVC2000-3			FVC2002-1			FVC2004-1			FVC2006-3			SPD2010		
	F	P	R	F	P	R	F	P	R	F	P	R	F	P	R
FVC2004-1	0,77	0,63	0,99	0,72	0,56	1	0,71	0,55	1	0,68	0,52	0,99	0,76	0,62	0,97

Fonte: Elaboração própria.

Tabela 24: Medida-F (F), precisão (P) e revocação (R) do Detector 1 para Classe Delta.

	FVC2000-3			FVC2002-1			FVC2004-1			FVC2006-3			SPD2010		
	F	P	R	F	P	R	F	P	R	F	P	R	F	P	R
FVC2004-1	0,83	0,74	0,97	0,94	0,88	1	0,88	0,8	1	0,86	0,79	0,95	0,91	0,89	0,93

Fonte: Elaboração própria.

O Detector 1 apresentou valor de medida-F (F), em média, superior a 76% (Tabela 22). São resultados satisfatórios, considerando os problemas já relatados com os gabaritos usados no treinamento dos classificadores. Devido ao elevado número de falso positivo, que é causado, principalmente, por erros no gabarito, a medida-F (F) é reduzida. Por outro lado, como mostram os valores da medida revocação (R), o Detector 1 tem desempenho elevado, todos acima de 0,95 (Tabela 22), nas singularidades verdadeiras (verdadeiro positivo) - detecta aproximadamente todas as singularidades verdadeiras em todas as bases. Os resultados de medida-F para Classe Delta (Tabela 23) são superiores a Classe Laço (Tabela 24), o que é esperado, pois os classificadores obtiveram desempenho superior sobre a Classe Delta e há uma quantidade maior de erro no gabarito da Classe Laço em todas as bases.

A Tabela 25 apresenta a mediana dos valores de *IoU* considerando as Classes Laço e Delta (Geral) e separados por Classe (Laço e Delta). Nota-se que as medidas *IoU* da Tabela 25, em geral, são superiores a 0,6, porém, observa-se que todos os valores de *IoU* Laço é inferior a *IoU* Delta e que estes são todos maiores que 0,7 - o que reforça a ideia dos problemas no gabarito da Classe Laço.


Tabela 25: Mediana dos valores de *IoU* considerando as 2 classes (Geral) e separados pelas Classes Laço e Delta do Detector 1.

	FVC2000-3			FVC2002-1			FVC2004-1			FVC2006-3			SPD2010		
	Geral	Laço	Delta	Geral	Laço	Delta	Geral	Laço	Delta	Geral	Laço	Delta	Geral	Laço	Delta
FVC2004-1	0,73	0,72	0,76	0,7	0,68	0,78	0,7	0,67	0,76	0,65	0,6	0,76	0,58	0,52	0,70

Fonte: Elaboração própria.

A Figura 30 mostra a distribuição dos valores de *IoU*, das Classes Laço e Delta, computados sobre todas as bases de imagens sem pré-processamento. Observa-se que a distribuição está deslocada para a direita e que mais da metade dos valores são superiores a 0,5, o que revela que o Detector 1 localizou mais da metade das singularidades acertando pelo menos 50% da região em que foi gabaritada.

Figura 30: Histograma dos valores de IoU geral do Detector 1 computados sobre todas as bases sem pré-processamento.



Fonte: Elaboração própria.

5.2.2 Imagens com pré-processamento

Os valores de medida-F apresentados na Tabela 26 mostram que o Detector 2 alcançou o melhor resultado sobre a Base FVC2000-3, no entanto, obteve a maior precisão de localização sobre a Base FVC2002-1 (Tabela 29). Em geral, considerando os resultados das Tabelas 26 e 29, o Detector 2 atingiu desempenho semelhante sobre todas as bases.

Tabela 26: Medida-F (F), precisão (P) e revocação (R) do Detector 2.

	FVC2000-3			FVC2002-1			FVC2004-1			FVC2006-3		
	F	P	R	F	P	R	F	P	R	F	P	R
FVC2004-1	0,84	0,73	0,99	0,74	0,58	1	0,74	0,6	0,99	0,75	0,62	0,97

Fonte: Elaboração própria.

Tabela 27: Medida-F (F), precisão (P) e revocação (R) do Detector 2 para a Classe Laço.

	FVC2000-3			FVC2002-1			FVC2004-1			FVC2006-3		
	F	P	R	F	P	R	F	P	R	F	P	R
FVC2004-1	0,8	0,66	0,99	0,68	0,52	1	0,69	0,53	1	0,7	0,54	0,99

Fonte: Elaboração própria.

Tabela 28: Medida-F (F), precisão (P) e revocação (R) do Detector 2 para a Classe Delta.

	FVC2000-3			FVC2002-1			FVC2004-1			FVC2006-3		
	F	P	R	F	P	R	F	P	R	F	P	R
FVC2004-1	0,96	0,94	0,98	0,99	0,98	1	0,97	0,94	0,99	0,93	0,94	0,92

Fonte: Elaboração própria.


O Detector 2 obteve valor de medida-F, em média, superior a 75% (Tabela 26), que é um desempenho semelhante ao Detector 1, que foi, em média, superior a 76%. Esse resultado indica que o pré-processamento não influenciou de maneira substancial a detecção de singularidades e que a qualidade das imagens não foi relevante para as CNNs. Assim como o Detector 1, o Detector 2 mantém desempenho superior sobre a Classe Delta e passa por problemas de falso positivo, e, apesar dos valores mais altos de revocação (R), as medidas-F não são elevadas.

Tabela 29: Mediana dos valores de IoU considerando as 2 classes (Geral) e separados pelas Classes Laço e Delta do Detector 2.

	FVC2000-3			FVC2002-1			FVC2004-1			FVC2006-3		
	Geral	Laço	Delta	Geral	Laço	Delta	Geral	Laço	Delta	Geral	Laço	Delta
FVC2004-1	0,72	0,7	0,76	0,76	0,73	0,78	0,75	0,73	0,76	0,72	0,7	0,73

Fonte: Elaboração própria.

Figura 31: Histograma dos valores de IoU geral do Detector 2 computados sobre todas as bases com pré-processamento.



Fonte: Elaboração própria.

A métrica IoU apresentada na Tabela 29 segue o padrão dos resultados do Detector 1 (Tabelas 26, 27 e 28), e mostra que o desempenho do Detector 2 foi superior sobre a Classe Delta. A Figura 31 apresenta o histograma dos valores de IoU do Detector 2 sobre as Classes Laço e Delta. Observa-se que os valores de IoU estão deslocados no sentido positivo do eixo horizontal e que, no geral, são superiores a 0,5. Este resultado revela que o Detector 2 localizou a maioria das singularidades acertando pelo menos 50% da região em que foi gabaritada - resultado semelhante ao obtido pelo Detector 1.

5.3 Comparação com outros métodos

O método de detecção de singularidades proposto neste trabalho foi comparado com quatro métodos apresentados no trabalho de Qin et al. (2017). Entre eles há trabalhos baseado no *Poincare Index* e na matriz de orientação (Seção 2.6) (FAN et al., 2008 apud QIN et al., 2017), (ZHOU; CHEN; GU, 2008 apud QIN et al., 2017), (CHIKKERUR;

RATHA, 2005 apud QIN et al., 2017). O *Poincare Index* é dependente da qualidade da imagem, pois é baseado na matriz de orientação, que é sensível a ruído. Portanto, para que o cálculo dos ângulos seja preciso, as cristas da imagem de impressão digital precisam estar fluidas e conectadas. O outro método é semelhante ao proposto neste trabalho e é baseado em CNN (QIN et al., 2017), que é resistente a imagens de baixa qualidade, mas depende da quantidade de dados de treinamento e da exatidão do gabarito. A Tabela 30 mostra os valores de *DR* e *FA* das Classes Laços e Delta para $r = 6$ sobre a Base FVC2002-1 sem pré-processamento.

Tabela 30: Comparação dos detectores de singularidades por meio da métrica DR ($r = 6$) sobre a Base FVC2002-1 sem pré-processamento.

Método	Taxa de detecção (DR %)		Falso Alarme (FA %)	
	Laço	Delta	Laço	Delta
Qin's (QIN et al., 2017)	95.39	98.26	1.03	4.10
Fan's (FAN et al., 2008 apud QIN et al., 2017)	95.64	96.95	1.88	10.84
Zhou's (ZHOU; CHEN; GU, 2008 apud QIN et al., 2017)	95.78	96.98	2.27	9.97
Chikkerurs (CHIKKERUR; RATHA, 2005 apud QIN et al., 2017)	95.89	92.75	6.93	8.16
Detector 1	34.87	58.66	65.13	41.34

Fonte: Elaborado pelo próprio autor com base em (QIN et al., 2017).

O método de Qin et al. (2017) obteve o desempenho mais elevado, e se destaca pela alta porcentagem de singularidades corretamente detectadas (*DR*) da Classe Delta e pelo baixo percentual de erro (*FA*). O Detector 1 apresentou o desempenho mais baixo entre os trabalhos, pois o limite de distância de 6 pixels é restritivo. Além disso, a técnica de janela deslizante usada para detectar singularidades, neste trabalho, dificulta a precisão de localização de no máximo 5 pixels, pois o valor do passo da janela deslizante (*stride*) é igual a 10 pixels. Como o Detector 1 não usou o mesmo gabarito dos demais concorrentes e a comparação foi feita em apenas uma base de imagens, não é possível afirmar que ele é o pior.

A Tabela 31 apresenta a *DR* e *FA*, considerando as duas classes, para diferentes valores de r . É possível ver que o Detector 1 apresentou uma evolução considerável a partir de $r = 10$. Para $r = 20$, ele começa a apresentar resultados competitivos.

Tabela 31: Taxa de detecção (*DR*) e falso alarme (*FA*) do Detector 1, para diferentes valores de r , sobre a Base FVC2002-1 sem pré-processamento.

Detector 1	$r = 10$				$r = 15$				$r = 20$				$r = 25$			
	DR (%)		FA (%)		DR (%)		FA (%)		DR (%)		FA (%)		DR (%)		FA (%)	
	Laço	Delta	Laço	Delta	Laço	Delta	Laço	Delta	Laço	Delta	Laço	Delta	Laço	Delta	Laço	Delta
	64.54	91.87	35.46	8.13	85.7	97.88	14.30	2.12	94.33	99.29	5.67	0.71	96.45	99.65	3.55	0.35

Fonte: Elaboração própria.

6 CONCLUSÕES E TRABALHOS FUTUROS

Este trabalho apresentou uma ferramenta de criação de gabarito de singularidades para geração de base de dados, propôs métodos classificação e detecção de singularidades baseado em CNN, ambos apresentaram desempenho satisfatório. O método de classificação e detecção de singularidades proposto neste trabalho obteve resultados elevados, porém ela torna o processo de detecção muito custoso devido ao alto consumo de processamento e memória do método de detecção por janela deslizante. A falta de gabarito correto influenciou de maneira substancial os resultados da detecção de singularidades, produzindo alta quantidade de falsos positivos. O realce aplicado sobre as bases de imagens não produziu melhores resultados na detecção de singularidades, o que mostra que métodos baseados em redes neurais são resistentes a imagens de baixa qualidade. A comparação de outros métodos de detecção de singularidades com o proposto neste trabalho (Detector 1) evidenciou que a posição predita da singularidade não foi precisa com o uso do $stride = 10$. Para trabalhos futuros, é interessante buscar gabaritos de singularidades consistentes para melhorar os resultados de detecção e avaliar outras arquiteturas de rede, como a de segmentação semântica que torna o processo de detecção mais eficiente.

REFERÊNCIAS

- CHEN, H. et al. Fingerprint singular point detection based on multiple-scale orientation entropy. *IEEE Signal Processing Letters*, IEEE, v. 18, n. 11, p. 679–682, 2011.
- CHIKKERUR, S.; RATHA, N. Impact of singular point detection on fingerprint matching performance. In: IEEE. *Fourth IEEE Workshop on Automatic Identification Advanced Technologies (AutoID'05)*. [S.l.], 2005. p. 207–212.
- CHOLLET, F. et al. *Keras*. 2015. <https://keras.io>.
- DORIZZI, B. et al. Fingerprint and on-line signature verification competitions at icb 2009. In: SPRINGER. *International Conference on Biometrics*. [S.l.], 2009. p. 725–732.
- F., M.; OLIVEIRA, H. P.; CAMPILHO, A. *SPD2010 - Fingerprint Singular Points Detection Competition Database*. spd, 2010. Disponível em: <http://paginas.fe.up.pt/~spd2010/>. Acesso em: 16 de jan. 2019.
- FAN, L. et al. Singular points detection based on zero-pole model in fingerprint images. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, IEEE, v. 30, n. 6, p. 929–940, 2008.
- GONZALEZ RC E WOODS, R. E. Digital image processing. In: _____. 3rd. ed. [S.l.]: Pearson, 2006. cap. **Introduction**. ISBN 013168728X.
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. *Deep Learning*. [S.l.]: MIT Press, 2016. Disponível em: <http://www.deeplearningbook.org>, Acesso em: 16 de set. 2019.
- GUPTA, P.; GUPTA, P. A robust singular point detection algorithm. *Applied Soft Computing*, Elsevier, v. 29, p. 411–423, 2015.
- HENRY, E. *Classification and Uses of Finger Prints*. [S.l.]: London: Routledge, 1900.
- HUANG, C.-Y.; LIU, L.-m.; HUNG, D. D. Fingerprint analysis and singular point detection. *Pattern Recognition Letters*, Elsevier, v. 28, n. 15, p. 1937–1945, 2007.
- HUBEL, D. H.; WIESEL, T. N. Receptive fields of single neurones in the cat's striate cortex. *The Journal of physiology*, Wiley Online Library, v. 148, n. 3, p. 574–591, 1959.
- HUBEL, D. H.; WIESEL, T. N. Receptive fields, binocular interaction and functional architecture in the cat's visual cortex. *The Journal of physiology*, Wiley Online Library, v. 160, n. 1, p. 106–154, 1962.
- HUBEL, D. H.; WIESEL, T. N. Receptive fields and functional architecture of monkey striate cortex. *The Journal of physiology*, Wiley Online Library, v. 195, n. 1, p. 215–243, 1968.
- JAIN, A. K. et al. Filterbank-based fingerprint matching. *IEEE transactions on Image Processing*, IEEE, v. 9, n. 5, p. 846–859, 2000.
- JIN, C.; KIM, H. Pixel-level singular point detection from multi-scale gaussian filtered orientation field. *Pattern Recognition*, Elsevier, v. 43, n. 11, p. 3879–3890, 2010.

- KAWAGOE, M.; TOJO, A. Fingerprint pattern classification. *Pattern recognition*, Elsevier, v. 17, n. 3, p. 295–303, 1984.
- LECUN, Y. et al. Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, Taipei, Taiwan, v. 86, n. 11, p. 2278–2324, 1998.
- LECUN, Y. et al. Generalization and network design strategies. In: *Connectionism in perspective*. [S.l.]: Citeseer, 1989. v. 19.
- LV, B. Notas de aula da disciplina introdução ao processamento digital de imagens. In: _____. [S.l.: s.n.], 2005. cap. **Introdução**.
- MALTONI, D. et al. *Handbook of fingerprint recognition*. [S.l.]: Springer Science & Business Media, 2009.
- NILSSON, K.; BIGUN, J. Localization of corresponding points in fingerprints by complex filtering. *Pattern Recognition Letters*, Elsevier, v. 24, n. 13, p. 2135–2144, 2003.
- OLIPHANT, T. E. *A guide to NumPy*. [S.l.]: Trelgol Publishing USA, 2006. v. 1.
- PEDREGOSA, F. et al. Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, v. 12, p. 2825–2830, 2011.
- QI, J.; LIU, S. A robust approach for singular point extraction based on complex polynomial model. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops*. [S.l.: s.n.], 2014. p. 78–83.
- QIN, J. et al. Multi-scaling detection of singular points based on fully convolutional networks in fingerprint images. In: SPRINGER. *Chinese Conference on Biometric Recognition*. [S.l.], 2017. p. 221–230.
- RAMO, P. et al. Optimized singular point detection algorithm for fingerprint images. In: IEEE. *Image Processing, 2001. Proceedings. 2001 International Conference on*. [S.l.], 2001. v. 3, p. 242–245.
- ROSS, A. A.; NANDAKUMAR, K.; JAIN, A. *Handbook of multibiometrics*. [S.l.]: Springer Science & Business Media, 2006. v. 6.
- RUSSAKOVSKY, O. et al. ImageNet Large Scale Visual Recognition Challenge. *International Journal of Computer Vision (IJCV)*, v. 115, n. 3, p. 211–252, 2015.
- SILVA, A. et al. A novel approach for fingerprint singularities detection. In: IEEE. *2017 Workshop of Computer Vision (WVC)*. [S.l.], 2017. p. 102–107.
- SILVA, P. *Fingerprint Label Marker*. [S.l.]: GitHub, 2019. Acesso em: 16 de jun. 2019.
- SIMARD, P. Y. et al. Best practices for convolutional neural networks applied to visual document analysis. In: *Icdar*. [S.l.: s.n.], 2003. v. 3, n. 2003.
- TSE. *Biometria*. 2017. Disponível em: <http://www.tse.jus.br/eleicoes/biometria-e-urna-eletronica/biometria-1>. Acesso em: 11 mar. 2017.
- TURRONI, F.; CAPPELLI, R.; MALTONI, D. Fingerprint enhancement using contextual iterative filtering. In: IEEE. *Biometrics (ICB), 2012 5th IAPR International Conference on*. [S.l.], 2012. p. 152–157.

ZHOU, J.; CHEN, F.; GU, J. A novel algorithm for detecting singular points from fingerprint images. *IEEE transactions on pattern analysis and machine intelligence*, IEEE, v. 31, n. 7, p. 1239–1250, 2008.

ZHOU, J.; GU, J.; ZHANG, D. Singular points analysis in fingerprints based on topological structure and orientation field. *Advances in Biometrics*, Springer, p. 261–270, 2007.