

UNIVERSIDADE FEDERAL DE UBERLÂNDIA

FACULDADE DE ENGENHARIA ELÉTRICA

LUCAS EDUARDO RIBEIRO DUARTE

**RECONHECIMENTO DE CÉDULAS REAL USANDO ALGORITMO SURF
(*SPEEDED-UP ROBUST FEATURES*)**

Uberlândia-MG

2019

**RECONHECIMENTO DE CÉDULAS REAL USANDO ALGORITMO SURF
(*SPEEDED-UP ROBUST FEATURES*)**

LUCAS EDUARDO RIBEIRO DUARTE

Orientadora

Prof. Dra. MILENA BUENO PEREIRA CARNEIRO

Trabalho de conclusão de curso apresentado ao colegiado do curso de graduação em Engenharia Eletrônica de Telecomunicações da Universidade Federal de Uberlândia, como parte dos requisitos para a obtenção de título de Graduação em Engenharia Eletrônica de Telecomunicações.

Área de concentração: Processamento Digital de Imagens

Uberlândia - MG

2019

**RECONHECIMENTO DE CÉDULAS REAL USANDO ALGORITMO SURF
(SPEEDED-UP ROBUST FEATURES)**

Trabalho de conclusão de curso
APROVADO pelo colegiado do curso de
graduação em Engenharia Eletrônica de
Telecomunicações Universidade Federal
de Uberlândia.

Área de concentração: Processamento
Digital de Imagens

BANCA EXAMINADORA

Prof. Dra. Milena Bueno Pereira Carneiro
Universidade Federal de Uberlândia

Prof. Dr. Gilberto Arantes Carrijo
Universidade Federal de Uberlândia

Prof. Dr. Antônio Cláudio Paschoarelli Veiga
Universidade Federal de Uberlândia

Uberlândia - MG

2019

AGRADECIMENTOS

A Deus, por ter me guiado em decisões difíceis e me ter dado forças para a conclusão desse trabalho.

À minha família, em incentivar durante a minha vida acadêmica, pelo amor incondicional, sempre me ensinando a tomar decisões corretas com o objetivo e propósito visando sempre um caminho honesto a trilhar. Ao meu irmão por ser o melhor irmão do mundo.

A minha orientadora Prof. Dr. Milena Bueno Pereira Carneiro, pela dedicação e paciência durante a realização desse trabalho. A experiência profissional foi uns dos fatores para o sucesso do trabalho de conclusão de curso.

Aos meus colegas de conclusão de curso. Pela amizade e companheirismo durante essa jornada de curso.

A todas as pessoas que, diretamente ou indiretamente, contribuíram para a execução deste trabalho.

RESUMO

Este trabalho propõe um algoritmo para identificar cédulas da Segunda Família do Real. O foco é desenvolver um algoritmo fácil, mas eficiente, que será útil para reconhecimento de cédulas para ajudar pessoas com deficiência visual. O sistema de reconhecimento é um processo que visa extrair informações significativas de uma determinada imagem. A tecnologia de reconhecimento e detecção de cédulas promete procurar e extrair as marcas visíveis e ocultas na moeda de papel para uma classificação mais eficiente. Cada nota de Real (ex., 2, 5, 10, 20, 50 e 100 reais) possui diferentes características como cor, tamanho e textos. Frequentemente as notas de dinheiro estão embaçadas ou danificadas pelo constante uso, o que dificulta a tarefa de identificação. Por isso, é muito importante selecionar os recursos corretos e o algoritmo adequado para essa finalidade. O método utilizado consiste em um descritor para proporcionar maior rapidez e robustez na extração de pontos de interesse em imagens. Esse método (SURF – *Speed-Up Robust Features*) é baseado na transformada de Haar para reduzir o custo computacional. A principal vantagem da técnica para extração de características é a identificação de pontos de interesse em uma imagem em diferentes escalas e a possibilidade de correspondência entre pontos em imagens distintas. Os resultados experimentais obtidos comprovam a robustez, flexibilidade e eficiência do método proposto.

Palavras-chave: Reconhecimento de cédulas, Deficiência visual, Algoritmo, Descritor, Transformada de Haar, Identificação de pontos de interesse, SURF.

ABSTRACT

This paper proposes an algorithm to identify the *Segunda Família do Real* banknotes. The focus is to develop an easy and efficient algorithm that will be used for paper money recognition in order to help visually impaired people. The recognition system is a process that seeks to extract meaningful information from a particular image. Banknote recognition and detection technology intend to search for and extract the visible and hidden markings in the paper currency for a more efficient sorting. Each Real banknote (eg, 2, 5, 10, 20, 50 and 100 reais) has its own characteristics like color, size and texts. Often, money notes are blurred or damaged by constant use, which makes the identification difficult. Therefore, it is very important to select the right resources and the appropriate algorithm for this purpose. The method used in this work consists of a descriptor to provide greater speed and robustness in the extraction of points of interest on images. The method (SURF – Speed-Up Robust Features) is based on the Haar transform to reduce computational cost. The main advantage of this technique for extraction of characteristics is the identification of points of interest in an image at different scales and the possibility of matching points among them. The experimental results obtained prove the robustness, flexibility and efficiency of the proposed method.

Keywords: Banknotes recognition, Visual impairment, Algorithm, Descriptor, Haar transform, Identification of points of interest, SURF.

LISTA DE ILUSTRAÇÕES

Figura 1: Representações de cédulas da primeira e segunda família do Real.....	4
Figura 2: Imagens de alguns elementos de segurança da cédula de R\$ 100. (a) Marca d'água. (b) Fio de segurança. (c) Quebra-cabeça, (d) Microimpressão. (e) Alto-relevo. (f) Elemento fluorescente.	8
Figura 3: Representação de uma imagem na forma matricial: (a) imagem da cédula de 100 reais; (b) imagem ampliada em uma região de tamanho 5x5; (c) valores da intensidade dos pixels da região 5x5 indicada.	10
Figura 4: Representação das etapas adotadas em sistemas de visão computacional.	11
Figura 5: Etapas de um sistema de reconhecimento de padrões.	13
Figura 6: Representação gráfica da função de diferença de Gaussiana [20].....	15
Figura 7: Exemplo da aplicação da DoG em cada oitava. Imagem adaptada de [23]...	16
Figura 8: Representação gráfica da vizinhança 3x3x3.....	16
Figura 9: Construção do descritor do ponto-chave.	18
Figura 10: Exemplo de soma de imagem integral. [].....	19
Figura 11: Exemplo genérico de filtragem de convolução.	20
Figura 12: Acesso de pixel para filtragem de caixa usando imagem integral.....	21
Figura 13: Exemplo de núcleos gaussianos (à esquerda) vs. aproximação de núcleos gaussianos (à direita).	23
Figura 14: Geração de espaço escala SIFT (esquerda) e SURF (direita).....	24
Figura 15: Exemplo da função gaussiana bidimensional genérica.	26
Figura 16: Crescimento de um filtro de caixa para a aproximação do núcleo gaussiano de D_{yy}	27
Figura 17: Exemplo de interpolação subpixel unidimensional de um ponto de interesse.	30
Figura 18: Filtros caixas de Haar usado no algoritmo SURF.	32
Figura 19: Orientação: À medida que a janela desliza em torno da origem, os componentes das respostas são somados para produzir os vetores mostrados em azul. O maior desses vetores determina a orientação dominante. Imagem retirada de [25].....	32
Figura 20: Exemplo de filtragem de Haar durante a atribuição de orientação.....	33
Figura 21: Imagem de grafite mostrando o tamanho das janelas do descritor orientado em diferentes escalas.	34
Figura 22: Exemplo de geração de descritor SURF.....	35
Figura 23: Exemplo de respostas wavelet de filtros Haar.....	36
Figura 24: Se o contraste entre dois pontos de interesse for diferente (escuro em um fundo claro versus luz em um fundo escuro), o candidato não é considerado uma correspondência valiosa. Imagem retirada de [21].....	37
Figura 25: Teste de repetibilidade do algoritmo SURF, SIFT e PCA-SIFT versus rotação.	41
Figura 26: Fluxograma da metodologia proposta.	44

Figura 27: Pontos de interesse extraídos em uma cédula de dois reais, usando algoritmo SURF.	55
Figura 28: Superfície em relevo da cédula de dois reais de uma função bidimensional.	55
Figura 29: Pontos de interesse extraídos em uma cédula de dois reais, usando algoritmo SURF.	56
Figura 30: a) Ilustra a parte frontal da cédula de dois reais rotacionada (0° e 180°). b) Ilustra a parte oposta da cédula de dois reais rotacionada (0° e 180°).	57
Figura 31: Gráfico de <i>matchings</i> em função dos dois ângulos testados para cada cédula Real- lado anverso.	57
Figura 32: Gráfico de <i>matchings</i> em função dos dois ângulos testados para cada cédula Real - lado reverso.	58
Figura 33: Representação da cédula de dois reais dobrada. a) cédula de dois reais dobrada no lado animal; b) cédula de dois reais dobrada no lado efigie.	59
Figura 34: Pontos de interesse extraídos em cédula dobradas no lado da efigie, usando algoritmo SURF. a) detecção de pontos de interesse em cédula dobrada de 2 reais; b) detecção de pontos de interesse em cédula dobrada de 10 reais.	59
Figura 35: Pontos de interesse extraídos em cédula dobradas no lado do animal, usando algoritmo SURF. a) detecção de pontos de interesse em cédula dobrada de 2 reais; b) detecção de pontos de interesse em cédula dobrada de 10 reais.	60

LISTA DE TABELAS

Tabela 1: Dimensões, temas e cores.....	7
Tabela 2: Elementos de Segurança.....	8
Tabela 3: Tamanhos dos filtros caixa usados para gerar representação de oitavas DoG no SURF.....	28
Tabela 4: Comparação de eficiência do método de busca 3D, de [24]	29
Tabela 5: Comparação de velocidade do algoritmo SURF, SIFT e PCA-SIFT. Tabela adaptada de [31].....	40
Tabela 6: Um resumo de desempenho para invariância à deformação da imagem para SURF, SIFT e PCA-SIFT, de [31].	41
Tabela 7: Grupo de teste para cédula de 2 reais.	45
Tabela 8: Grupo de referência.	46
Tabela 9: Dados técnicos da câmera utilizada para construção do banco de imagens..	47
Tabela 10: Especificação do dispositivo usado nos testes.....	52
Tabela 11: Resultados obtidos para identificação da cédula de dois reais da Segunda Família Real.....	52
Tabela 12: Resultados obtidos para identificação da cédula de cinco reais da Segunda Família Real.....	53
Tabela 13: Resultados obtidos para identificação da cédula de dez reais da Segunda Família Real.....	53
Tabela 14: Resultados obtidos para identificação da cédula de vinte reais da Segunda Família Real.....	53
Tabela 15: Resultados obtidos para identificação da cédula de cinquenta reais da Segunda Família Real.....	53
Tabela 16: Resultados obtidos para identificação da cédula de cem reais da Segunda Família Real.....	54
Tabela 17: Cédula de dois reais da Segunda Família Real - lado anverso.....	65
Tabela 18: Cédulas de dois reais da Segunda Família Real - lado reverso.....	66
Tabela 19: Cédulas de cinco reais da Segunda Família Real - lado anverso.....	67
Tabela 20: Cédulas de cinco reais da Segunda Família Real - lado reverso.....	68
Tabela 21: Cédulas de dez reais da Segunda Família Real - lado anverso.....	69
Tabela 22: Cédulas de dez reais da Segunda Família Real - lado reverso.....	70
Tabela 23: Cédulas de vinte reais da Segunda Família Real - lado anverso.....	71
Tabela 24: Cédulas de vinte reais da Segunda Família Real - lado reverso.....	72
Tabela 25: Cédulas de cinquenta reais da Segunda Família Real - lado anverso.....	73
Tabela 26: Cédulas de cinquenta reais da Segunda Família Real - lado reverso.....	74
Tabela 27: Cédulas de cem reais da Segunda Família Real – lado anverso.....	75
Tabela 28: Cédulas de cem reais da Segunda Família Real – lado reverso.....	76
Tabela 29: Imagens que não representam cédulas Real.....	77

Tabela 30: Resultados do método proposto: nota de dois reais – lado anverso e ambiente claro.....	81
Tabela 31: Resultados do método proposto: nota de dois reais – lado reverso e ambiente claro.....	81
Tabela 32: Resultados do método proposto: nota de cinco reais – lado anverso e ambiente claro.....	82
Tabela 33: Resultados do método proposto: nota de cinco reais – lado reverso e ambiente claro.....	82
Tabela 34: Resultados do método proposto: nota de dez reais – lado anverso e ambiente claro.....	83
Tabela 35: Resultados do método proposto: nota de dez reais – lado reverso e ambiente claro.....	83
Tabela 36: Resultados do método proposto: nota de vinte reais – lado anverso e ambiente claro.....	84
Tabela 37: Resultados do método proposto: nota de vinte reais – lado reverso e ambiente claro.....	84
Tabela 38: Resultados do método proposto: nota de cinquenta reais – lado anverso e ambiente claro.....	85
Tabela 39: Resultados do método proposto: nota de cinquenta reais – lado reverso e ambiente claro.....	85
Tabela 40: Resultados do método proposto: nota de cem reais – lado anverso e ambiente claro.....	86
Tabela 41: Resultados do método proposto: nota de cem reais – lado reverso e ambiente claro.....	86
Tabela 42: Resultados do método proposto: nota de dois reais – lado anverso e ambiente escuro.....	87
Tabela 43: Resultados do método proposto: nota de dois reais – lado reverso e ambiente escuro.....	87
Tabela 44: Resultados do método proposto: nota de cinco reais – lado anverso e ambiente escuro.....	88
Tabela 45: Resultados do método proposto: nota de cinco reais – lado reverso e ambiente escuro.....	88
Tabela 46: Resultados do método proposto: nota de dez reais – lado anverso e ambiente escuro.....	89
Tabela 47: Resultados do método proposto: nota de dez reais – lado reverso e ambiente escuro.....	89
Tabela 48: Resultados do método proposto: nota de vinte reais – lado anverso e ambiente escuro.....	90
Tabela 49: Resultados do método proposto: nota de vinte reais – lado reverso e ambiente escuro.....	90
Tabela 50: Resultados do método proposto: nota de cinquenta reais – lado anverso e ambiente escuro.....	91

Tabela 51: Resultados do método proposto: nota de cinquenta reais – lado reverso e ambiente escuro.	91
Tabela 52: Resultados do método proposto: nota de cem reais – lado anverso e ambiente escuro.	92
Tabela 53: Resultados do método proposto: nota de cem reais – lado reverso e ambiente escuro.	92

SUMÁRIO

1	INTRODUÇÃO	3
1.1	Objetivo	5
1.2	Estrutura do trabalho	5
2	FUNDAMENTOS TEÓRICOS.....	6
2.1	Segunda família do real	6
2.2	Imagem digital	9
2.3	Visão computacional	10
2.4	Reconhecimento de padrões	12
2.4.1	SIFT	14
2.4.2	SURF	18
2.4.3	Correspondência dos pontos de interesse (<i>Interest point matching</i>)	38
2.4.4	Comparando SIFT e SURF	40
3	METODOLOGIA PROPOSTA.....	43
3.1	Criação do banco de imagens	44
3.2	Extração de característica e Matching	47
3.3	Classificação	49
4	RESULTADOS E DISCUSSÕES	51
4.1	Rotação	56
4.2	Oclusão	58
5	CONCLUSÃO.....	61
5.1	Sugestões para trabalhos futuros	61
	REFERÊNCIAS BIBLIOGRÁFICAS	62
	APÊNDICE A - IMAGENS DE CÉDULAS E IMAGENS QUE NÃO REPRESENTAM CÉDULAS REAL UTILIZADAS NOS TESTES	65
	APÊNDICE B – RESULTADOS OBTIDOS NOS TESTES COM MÉTODO UTILIZADO (SURF)	81

1 INTRODUÇÃO

Define-se deficiência visual ou perda visual, a perda ou redução grave e irreversível da função visual que é incorrigível com uso de lentes ou através de cirurgia e que interfere nas tarefas cotidianas[1,2]. A perda visual pode ser instantânea ou ser o resultado de uma deterioração gradativa, em que objetos a grande distância se tornam cada vez mais difíceis de ver [5]. Essa circunstância causa à pessoa dificuldades em realizar atividades rotineiras, como dirigir automóveis, ler, ver filme, socializar ou deslocar-se a pé [2]. A deficiência visual incorpora todas as condições em que existe comprometimento da visão. A Organização Mundial de Saúde divide a deficiência visual em seis graus de acordo com a acuidade visual (AV) da pessoa. Quando a perda de visão é parcial denomina-se visão subnormal. A visão subnormal pode ser ligeira, moderada ou grave. Quando a perda de visão é total ou quase total denomina-se cegueira. A cegueira divide-se em cegueira profunda, quase total e total [3,4]. A maior parte dos cegos possui alguma função visual e percebe luzes, sombras e movimento. Só uma pequena porcentagem é que não apresenta qualquer sensação visual [3].

De acordo com Organização Mundial de Saúde estima-se que há cerca de 285 milhões de pessoas que vivem com algum tipo de deficiência visual, dos quais 39 milhões são consideradas cegos [5]. Segundo dados do IBGE (Instituto Brasileiro de Geografia e Estatística) de 2010, tem-se mais de 35,8 milhões de pessoas com deficiência visual no Brasil, sendo que, mais de 506 mil declaram-se incapazes de enxergar de forma alguma [6].

As pessoas com deficiência visual enfrentam uma série de desafios ao interagir com os ambientes, porque muitas informações são codificadas visualmente. Uma dificuldade específica que uma pessoa cega encontraria é identificar o valor de uma cédula.

A moeda oficial utilizada no Brasil é o Real, que tem como temática a fauna brasileira e também traz no seu averso a efígie da República, que simboliza a personificação da nação brasileira representada por uma mulher. A imagem, inspirada na obra “A liberdade guiando o povo”, de Eugène Delacroix, foi usada para representar a Proclamação da República e tornou-se símbolo do país [7]. As notas de Real da Segunda

Família Real são emitidas em valores R\$ 2, R\$ 5, R\$ 10, R\$ 20, R\$ 50 e R\$ 100. Como mostrado na Figura 1 abaixo.

Figura 1: Representações de cédulas da Primeira e Segunda Família do Real.



Fonte: Imagem retirada de [15].

O Banco Central do Brasil terminou de lançar, em 2013, as últimas cédulas da "Segunda Família do Real", que têm dimensões diferentes. De acordo com informações do Banco Central, as novas notas dificultam a falsificação, "além de promover a acessibilidade aos portadores de deficiência visual" [8]. No entanto, boa parte dos deficientes visuais afirmam que ainda é difícil distinguir as notas de Real por meio do tato, mesmo as cédulas tendo alto relevo e tamanhos diferentes.

Contudo, é extremamente relevante a busca por novas pesquisas científicas direcionadas ao desenvolvimento de recursos de Tecnologia Assistiva para facilitar atividades cotidianas às pessoas com deficiência visual.

1.1 Objetivo

Em síntese, o objetivo geral do projeto é obter uma forma eficaz e simples de reconhecimentos de cédulas da Segunda Família do Real, com auxílio do MATLAB 2017b, para a criação de um programa que ajude pessoas com deficiência visual. Para isso, será relevante o estudo de métodos, técnicas e ferramentas para reconhecimento de padrões de um objeto, com objetivo de diferenciação de características similares, como ocorre nas notas de Real.

Através da realização de vários testes e simulações com cédulas para validação do projeto, será avaliada a confiabilidade do algoritmo na identificação de cédulas de Real.

Sendo assim, este trabalho também tem como meta uma proposta de solução robusta que permite, mesmo em situações com rotação e variação de escala, a detecção e o reconhecimento automático da cédula Real.

Será avaliado ainda, fatores como rotação, oclusão e iluminação com objetivo de determinar suas vantagens e limitações.

1.2 Estrutura do trabalho

Todas as informações produzidas nesse trabalho estão descritas em cada um dos capítulos. Sendo assim, essa monografia está dividida da seguinte forma:

- **Capítulo 2:** Apresenta a fundamentação teórica, descrevendo as principais técnicas de processamento de imagens para o reconhecimento de padrões, além da revisão de alguns conceitos básicos para compreensão do estudo realizado.
- **Capítulo 3:** Apresenta metodologia utilizada para identificar as cédulas reais, através do uso de técnica de detecção, extração de característica e classificação da imagem.
- **Capítulo 4:** Descreve e discute os resultados obtidos através do método utilizado.
- **Capítulo 5:** Conclusões acerca do trabalho explanado e sugestões de trabalhos futuros.

2 FUNDAMENTOS TEÓRICOS

Existem três áreas importantes que tratam imagens: o processamento de imagens, síntese de imagens e a análise de imagens (reconhecimento de padrões). De forma resumida, o processamento de imagens é a área que transforma imagens, a síntese de imagens representa o uso de dados para geração de imagens, já a análise de imagens expõem dados resultante de informação adquiridas em imagens [9]. O reconhecimento de padrões pode envolver técnicas de cada uma dessas áreas. Logo, este Capítulo apresenta os conceitos básicos sobre as cédulas da Segunda Família do Real, características de uma imagem digital, aborda visão computacional e técnicas de extração de características de imagens.



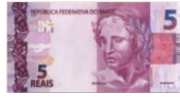









2.1 Segunda família do real

A moeda corrente oficial da República Federativa do Brasil é o Real. Ela foi criado após consecutivas trocas monetárias que fracassaram, o Brasil adotou Real a partir de 1994, que colaborou com redução das taxas de inflação, instituiu uma moeda estável para o país [10]. O órgão responsável por sua emissão é o Banco Central do Brasil.

A Segunda Família do Real foi anunciada em fevereiro de 2010 pelo Banco Central. Porém entrou em circulação as primeiras cédulas, nos valores de R\$ 50 e R\$ 100 [11]. Já no ano de 2012, foram lançadas as cédulas de R\$ 20 e R\$ 10. E finalmente, em 2013, foram incorporadas no mercado as notas de R\$ 2 e R\$ 5.

Uma das características que diferencia as cédulas da Segunda da Primeira Família é que as cédulas da Segunda Família possuem dimensões de acordo com seu valor, além de novos elementos de segurança e marcas táteis em relevo. De acordo com Banco Central, essas medidas foram adotadas para deixar a moeda nacional mais segura e forte, em um contexto internacional [12,13]. Na Tabela 1 apresenta as imagens de cada cédulas da Segunda Família Real, como as dimensões das cédulas, bem como outras características que as distingue, tais como, o tema e a cor predominante.

Tabela 1: Dimensões, temas e cores.

Anverso	Reverso	Dimensões (mm)	Tema	Cor predominante
		121x65	Tartaruga marinha	Azul-marinho
		128x65	Garça	Lilás
		135x65	Arara-Vermelha	Vermelho
		142x65	Mico-leão-dourado	Amarelo
		149x70	Onça-pintada	Bege
		156x70	Garoupa	Azul-turquesa

Além disso, o papel moeda da Segunda Família tem uma textura mais firme e áspera que o papel comum; apresentam marca d'água, quebra-cabeça, microimpressões, elementos fluorescentes, fio de segurança, alto-relevo, número que muda de cor, número escondido e faixa holográfica [14]. Esses elementos de segurança podem variar de acordo com valor da cédula Real, na Tabela 2 abaixo seguem as diferenças. Tabela adaptada de [15].

Tabela 2: Elementos de Segurança.

Valor (R\$)	2	5	10	20	50	100
Marca d'água	X	X	X	X	X	X
Quebra-cabeça	X	X	X	X	X	X
Microimpressões	X	X	X	X	X	X
Elementos fluorescentes	X	X	X	X	X	X
Fio de segurança			X	X	X	X
Alto-relevo	X	X	X	X	X	X
Nº que muda de cor			X	X		
Nº escondido	X	X	X	X	X	X
Faixa Holográfica					X	X

Para fins didáticos, a Figura 2 mostra alguns elementos de segurança (visuais, táteis e ocultos) tratado no trabalho. Vale ressaltar que para observar os seguintes elementos de segurança visuais com maior facilidade é necessário estar contra a luz.

Figura 2: Imagens de alguns elementos de segurança da cédula de R\$ 100. (a) Marca d'água. (b) Fio de segurança. (c) Quebra-cabeça, (d) Microimpressão. (e) Alto-relevo. (f) Elemento fluorescente.



Fonte: Imagens retirada de [15].

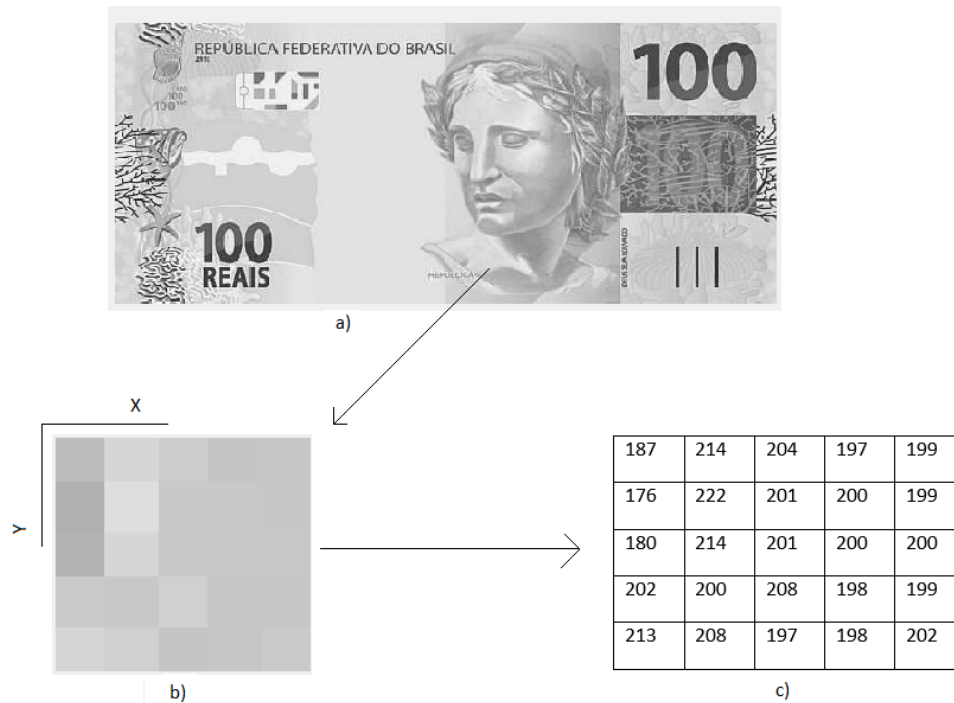
2.2 Imagem digital

Uma imagem monocromática é uma função bidimensional contínua $f(x, y)$, na qual x e y são coordenadas espaciais e o valor de f em qualquer ponto (x, y) é proporcional à intensidade luminosa (brilho ou nível de cinza) no ponto considerado [16]. Como os computadores não são capazes de processar imagens contínuas, a imagem é digitalizada, ou seja, é convertida de contínua (real) por meio da amostragem e quantização para uma representação discreta (digital).

Na forma digital, o valor da função bidimensional discreta $f(x, y)$, é representado por um valor numérico digital quantizado em bits, que assume valores naturais [17]. Imagens em tons de cinza, a cor do pixel é representada como um valor inteiro de 8 bits variando entre 0 a 255, de forma que o valor 0 representa a cor preta e o 255 a cor branca e as outras tonalidades distribuídas nesse intervalo [9].

Uma imagem digital é constituída por um número de elementos finito, cada um com uma determinada localização e valor específicos. Esses elementos são denominados, elementos de imagem ou pixels [16]. A Figura 3 mostra que a representação de uma imagem em tons de cinza é como uma matriz cujas linhas e colunas identificam um ponto na imagem, ou seja, o pixel. Dessa forma o valor de cada célula da matriz é definido pelas coordenadas que o pixel ocupa na matriz e pelo seu valor numérico digital.

Figura 3: Representação de uma imagem na forma matricial: (a) imagem da cédula de 100 reais; (b) imagem ampliada em uma região de tamanho 5x5; (c) valores da intensidade dos pixels da região 5x5 indicada.

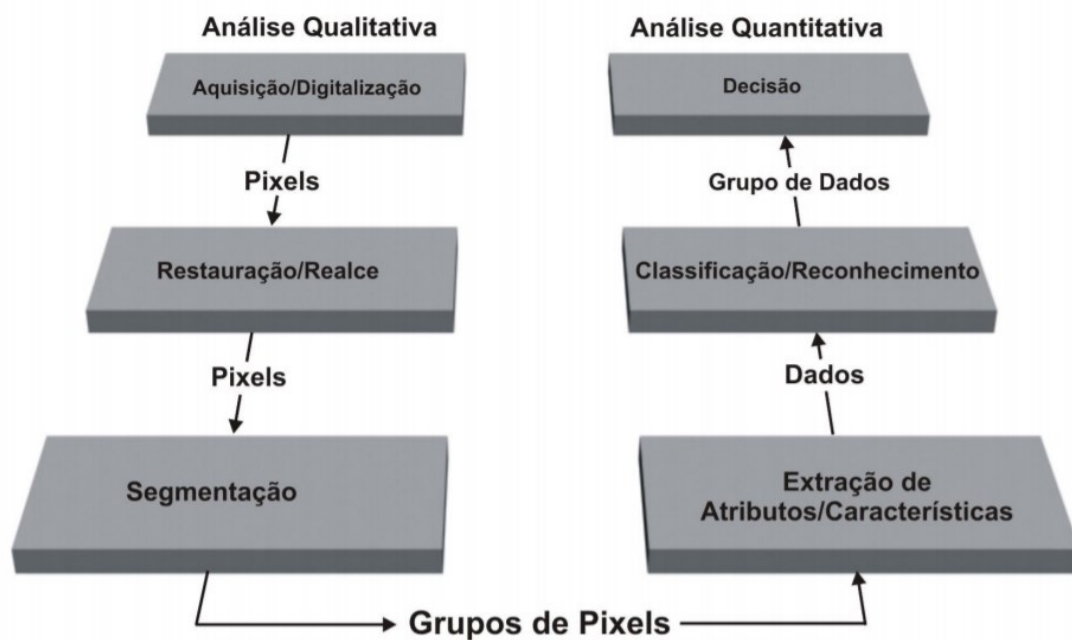


Fonte: Imagem Adaptada de [17].

2.3 Visão computacional

A visão computacional pode ser definida como: Aplicação de métodos e técnicas de processamento e análise de imagens com o objetivo de extrair informações relevantes de imagens digitais, de maneira similar às capacidades biológicas da visão humana e/ou superando tais capacidades [18]. É muito utilizado em reconhecimento de assinaturas, de objetos, de pessoas, de impressões digitais e de placas trânsito. A Figura 4 representa as principais etapas em um sistema de visão computacional: aquisição de imagens, restauração/realce, segmentação, extração de atributos/característica, classificação/reconhecimento e decisão. Dependendo da aplicação, algumas etapas podem ser trocadas de posição, como por exemplo a de realce de imagens ou segmentação.

Figura 4: Representação das etapas adotadas em sistemas de visão computacional.



Fonte: Imagem retirada de [9].

A fase de aquisição da imagem consiste em receber uma imagem, pode ser de dispositivos como: câmeras digitais, scanners e demais sensores. A restauração procura nivelar deficiências específicas, geradas no período de aquisição da imagem, na transmissão ou mesmo em alguma etapa do processamento. O realce é o processo que visa modificar uma imagem para que se tenha melhor resultado no processamento, como destacar detalhes da imagem, falta de contraste, correção de desfoco e até mesmo imagens borradas. A segmentação divide uma imagem em regiões e podem ser usadas para isolar certas regiões de pontos da imagem. A detecção de bordas e limiarização são exemplos de operações de segmentação, principalmente quando a imagem apresenta fundo e objeto bem definidos. A extração de atributos ou características busca obter dados relevantes ou atributos das regiões ou objetos destacados, os tipos de atributos mais comum são dimensões (área, perímetro, centro de gravidade), número de objetos, etc. Já o reconhecimento atribui um rótulo ao objeto com base na análise da sua característica [9].

2.4 Reconhecimento de padrões

O reconhecimento de objetos é uma das principais funções da área de visão computacional e está relacionado diretamente com o reconhecimento de padrões. Um objeto pode ser definido por mais de um padrão (textura, forma, cor, etc.), como é o caso das notas, e o reconhecimento individual de cada um destes padrões pode facilitar o reconhecimento do objeto como um todo [19]. Um padrão é um arranjo de descritores, que constantemente é denotado com o termo “característica”. Uma classe de padrões é uma família de padrões que compartilham propriedades em comum. Os autores indicam ainda que, na prática, os arranjos utilizados são vetores de características para descrições quantitativas, também conhecidos como as *strings*, *feature vector* ou *pattern vector* e as árvores para as descrições estruturais [16].

O reconhecimento de padrões classifica dados visuais numéricos ou simbólicos baseados em informações contidas em bancos de dados de padrões. Muitas técnicas estatísticas e sintáticas têm sido desenvolvidas para classificação de padrões [9]. Sendo assim, o conhecimento de um banco de dados pode ser o detalhamento de regiões de uma imagem na qual se sabe que a informação de interesse pode ser localizada, limitando dessa forma, a busca que precisa ser conduzida na procura de informações [16]. Além de informações relativamente simples, dependendo do problema, a base de conhecimento pode ser mais complexa, envolvendo listas inter-relacionadas de pontos de uma imagem ou até dados de geolocalização em imagens de satélite em alta resolução.

A Figura 5 representa as três etapas importantes para o reconhecimento de objetos. Inicialmente, se faz necessária a extração de características do objeto que são representadas por seus respectivos descritores. Em geral, é importante descrever os padrões com base em características que não possuam correlação e tenham propriedades invariantes à translação, escala e rotação. São exemplos de técnicas o estudo de descritores de fronteira, como Fourier, descritores relacionais, descritores regionais (topológicos) [9]. A utilização dessas técnicas dependerá da aplicação e do tipo de imagem ou objeto a ser descrito. Após obtenção dos padrões que caracterizam o objeto, essas informações são armazenadas como descritores de uma classe de objetos em um banco de dados de padrões e então procede-se à etapa de classificação. Para realizar a classificação, torna-se necessário o uso de alguma técnica de decisão.

Figura 5: Etapas de um sistema de reconhecimento de padrões.



Fonte: Imagem adaptada de [9].

As técnicas de classificação são divididas em duas grandes áreas: estruturais, onde os padrões são descritos de forma simbólica e a estrutura é a forma como estes padrões se relacionam; a outra área é baseada em técnicas que utilizam teoria de decisão, nessa área os padrões são descritos por propriedades quantitativas, como comprimento, textura e área [16]. Já para outros autores como Conci, Azevedo e Leta as técnicas de classificação se dividem em duas áreas básicas: supervisionada e não-supervisionada. Na primeira, um conjunto-padrão de objetos conhecidos pertencentes a diferentes classes é analisado, escolhendo-se os parâmetros ideais para a separação das classes. As técnicas envolvem modelos probabilísticos, representatividade da população a ser treinada e testes com objetos fora do conjunto. Na abordagem não-supervisionada tenta-se estabelecer *clusters* ou agrupamentos naturais no espaço de características. São exemplos as técnicas que usam redes neurais artificiais e lógica *fuzzy*. Por isso, Conci, Azevedo e Leta concluem que o reconhecimento de padrões se relaciona com várias áreas, como, a aprendizagem de máquina, a inteligência artificial, redes neurais, entre outros [9].

No próximo tópico serão mostrados dois algoritmos para extração de características em imagens, como: O SIFT (*Scale-Invariant Feature Transform*) [20] e SURF (*Speed-Up Robust Features*) [21].

2.4.1 SIFT

O algoritmo SIFT (*Scale Invariant Feature Transforms*) foi proposto por Lowe para a extração de características que fossem invariantes, de modo a possibilitar a correspondência de objetos dentro de uma mesma imagem sobre diferentes pontos de perspectiva, após terem sofrido alguma transformação, seja na rotação, iluminação ou escala [20]. A característica de invariância tornou o algoritmo bastante reconhecido, tendo bastante aplicabilidade em diversos contextos de visão computacional e aprendizagem de máquina, como por exemplo, reconhecimento de objetos, mapeamento e navegação de robôs, identificação de digitais [21] e dentre outros.

O algoritmo é baseado numa abordagem em cascata, para obtenção dos descritores é feita em quatro estágios da seguinte forma: detecção de pontos no espaço de escala; aquisição da localização dos mesmos; atribuição de orientação aos pontos chave; e descrição destes pontos [20]. A ordem dos passos do algoritmo é também justificada na prática de que em cada passo o algoritmo vai sendo mais exigente em termos de computação, removendo assim pontos no início e reduzindo o tempo de detecção e descrição dos mesmos.

As etapas do algoritmo são descritas na subsecção 2.4.1.1.

2.4.1.1 Estados de processamento do algoritmo


a) Detecção de extremos no espaço de escala

É realizada identificando potenciais candidatos a pontos de interesse, procurando extremos (valores locais máximos e mínimos), por meio da aplicação da função de diferença Gaussiana (DoG) num espaço de escala de uma pirâmide de imagem, que é construída por meio das chamadas oitavas (*octaves*) [20]. A cada oitava a imagem inicial se torna a imagem cujo valor σ (sigma, fator de Filtro Gaussiano) é o dobro do inicial, ao mesmo tempo a imagem tem sua escala reduzida pela metade.

A aplicação da função de Diferença Gaussiana (DoG), consiste em aplicar Filtros Gaussianos que borram a imagem por meio de um fator σ (sigma) que varia em um intervalo na imagem e em seguida subtrai-la de outra com um valor σ diferente [20]. Na Figura 6 é possível ver o esquema exemplificando a aplicação das diferenças gaussianas,

a cada oitava (*octave*) é aplicado o Filtro Gaussiano com valor σ , em seguida é feita a subtração das imagens que resultam em Diferenças de Gaussiana, a próxima oitava inicia com a imagem que possui o dobro de σ inicial.

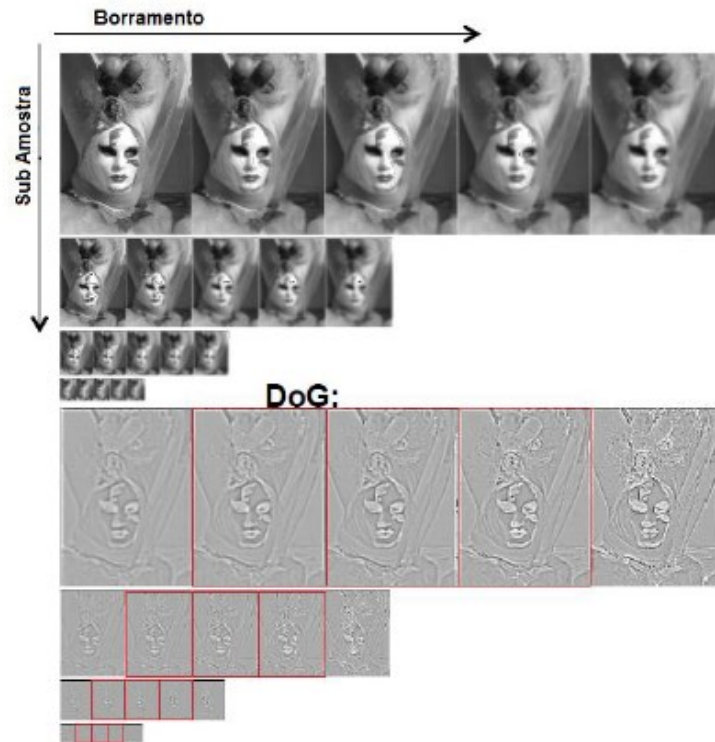
Figura 6: Representação gráfica da função de diferença de Gaussiana [20].



Fonte: Imagens retirada de [20].

Logo após a aplicação da Diferença Gaussiana para cada oitava é realizado a verificação para localizar extremos. Essa procura é realizada para cada intervalo de diferença gaussiana (excluindo a imagem com fator σ mínimo e máximo da oitava), como pode ser representado na Figura 7, onde a procura por extremos é realizada apenas nas imagens dentro do intervalo em vermelho.

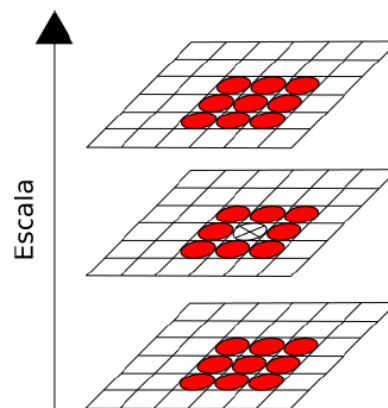
Figura 7: Exemplo da aplicação da DoG em cada oitava. Imagem adaptada de [23].



Fonte: Imagem adaptada de [23].

Para se determinar os possíveis pontos de interesse é feita a análise de cada pixel com seus 26 vizinhos nas diferentes escalas de sigma. A Figura 8 mostra o pixel X marcado, caso esse pixel possua valor maior ou menor que todos os seus adjacentes será um possível ponto de interesse [20].

Figura 8: Representação gráfica da vizinhança 3x3x3.



Fonte: Imagem retirada de [20].

b) Localização dos pontos chave

A localização dos pontos chave utilizando a detecção de extremos gera muitos pontos que, por sua vez, são instáveis. Para determinar com maior precisão a localização e estabilidade dos pontos, se propõe a utilização do cálculo de localização interpolada por meio da expansão quadrática da série de Taylor sobre a função de segunda ordem da Função de Diferença Gaussiana, posteriormente os pontos são filtrados através de um limiar de contraste atribuído, para eliminar pontos com valores inferiores ao mesmo que é realizado por meio do cálculo da expansão da série de Taylor de segunda ordem da função de Diferença Gaussiana [20].

c) Atribuição de orientação


Uma orientação é atribuída para cada ponto-chave para construir os descritores. Monta-se um histograma de orientação para uma região vizinha ao redor do ponto-chave. Cada ponto na vizinhança do ponto-chave é adicionado ao histograma com um determinado peso. Os picos no histograma de orientações correspondem às direções dominantes dos gradientes locais e são utilizados para definir a orientação do ponto-chave. Assim, cada ponto-chave tem quatro dimensões: sua posição x , y , magnitude e orientação [20].

d) Descritor dos pontos chaves

O descritor do ponto-chave é criado computando-se as magnitudes e orientações dos gradientes amostrados (Figura 9) ao redor da localização do ponto-chave.

Para cada imagem, são construídos diversos descritores, cada um referente a um ponto-chave. Quando se aplica a técnica SIFT em uma imagem, tem-se como resultado, portanto, um conjunto de descritores. Estes descritores podem ser, então, usados para se fazer a correspondência da imagem um com a outra.

Figura 9: Construção do descritor do ponto-chave.



Fonte: Imagem retirada de [20].

2.4.2 SURF

O SURF (*Speeded-Up Robust Features*) é também um detector e um descritor de pontos de interesse invariante às operações de escala e rotação. O detector SURF propõe um método baseado na matriz Hessiana que apresenta como sendo mais rápida que o detector de função de Diferença Gaussiana (DoG) e que as abordagens baseadas no laplaciano Harris-Laplace e Hessian-Laplace [21]. Já o seu descritor representa a distribuição das respostas da Wavelet Haar na vizinhança do ponto de interesse.

a) Detecção dos pontos de interesse

O primeiro passo para classificação de imagens é a detecção e caracterização de pontos de interesse [21]. No SURF, isso requer uma série de etapas a serem abordadas abaixo:

(1) Passo 1: Conversão para escala de cinza. O algoritmo SURF trabalha com uma matriz em 2-D que é representada por imagens em tons de cinza. Contudo, qualquer imagem colorida deve ser convertida no formato de intensidade adequado [21].

(2) Passo 2: Imagem Integral. A finalidade da imagem integral é facilitar a filtragem rápida de caixa, que foi introduzida pela primeira vez na visão computacional

por Viola e Jones em 2011 [22]. Nas imagens, a imagem integral representa uma soma cumulativa de intensidade de pixel locais à esquerda e acima de um pixel de destino.

A imagem integral da $ii(x, y)$ é definida como

$$ii(x, y) = \sum_{x' \leq x, y' \leq y} i(x', y') \quad (1)$$

onde $i(x', y')$ representa a intensidade de pixels localizados em todos os índices que satisfazem as desigualdades $x' < x$ e $y' < y$ [22]. Como mostrado na Figura 10, a imagem integral pode ser calculada em toda a imagem muito rapidamente, somando cumulativamente todas as linhas de uma imagem de intensidade e depois todas as colunas.

Figura 10: Exemplo de soma de imagem integral.


Original Matrix	1st: Cumulative Sum Along Rows	2nd: Cumulative Sum Along Columns
21 3 4 4 17	21 24 28 32 49	21 24 28 32 49
23 7 25 11 1	23 30 55 66 67	44 54 83 98 116
4 14 24 23 22	4 18 42 65 87	48 72 125 163 203
23 24 13 20 24	23 47 60 80 104	71 119 185 243 307
16 25 21 24 17	16 41 62 86 103	87 160 247 329 410

Fonte: Imagem retirada de [23].

(3) Passo 3: Filtragem de caixa. Este método é um processo eficiente para calcular a matriz Hessiana em um determinado pixel como descrito na próxima etapa. Esse eficiente processo de filtragem de caixas também é usado para aplicar núcleos de Wavelet de Haar para as etapas de geração de orientação e descritor que será descrita mais adiante [21]. Os filtros de caixa usam uma caixa (ou caixas) definidas em relação a um dado pixel central, com cada caixa tendo pesos [22]. Para esta classe de filtros, a operação de convolução combina linearmente a soma da intensidade de pixel para aquela caixa [23]. Em cada situação, o núcleo é desenvolvido usando caixas com cada pixel na caixa tendo o mesmo peso para conduzir a filtragem em uma imagem, com o centro sendo o

pixel de interesse [23]. Um exemplo básico ilustrando o uso de um núcleo (*kernel*) de convolução para filtrar uma imagem é destacado na Figura 11. Este não é o filtro de caixa utilizado no algoritmo SURF mas é um exemplo básico para mostrar visualmente como um núcleo de convolução genérico funciona [21].


Figura 11: Exemplo genérico de filtragem de convolução.



Fonte: Imagem retirada de [23].

O problema com uso de um kernel de convolução para filtragem é que ele não é computacionalmente eficiente. Um filtro de kernel de convolução 9x9 requer 81 acessos de array e operações para cada pixel central [24]. A carga computacional do método de convolução normal aumenta juntamente com o aumento dos filtros (são necessários filtros crescentes na análise de espaço-escala) [25]. Uma vez que um método mais eficiente é desejado, as propriedades de imagens integrais são usadas para um cálculo de saída do kernel de “filtro de caixa” mais eficiente do que o fornecido pela convolução normal com a imagem de intensidade. Uma referência visual descrevendo um método rápido para calcular integrais de caixa em uma imagem integral [22] é fornecida na Figura 12.

Figura 12: Acesso de pixel para filtragem de caixa usando imagem integral.



Fonte: Imagem retirada de [22].

Observando a Figura 12 assume que as áreas marcadas A, B, C e D são seções de imagem retangulares não sobrepostas adjacentes na imagem integral definida pela equação (2) [22]. A caixa chamada de A de pixels inclui os pixels da borda no canto superior esquerdo. As variáveis $P1, P2, P3$ e $P4$ representam os valores de pixel da imagem integral nos pixels do canto inferior direito da caixa A, B, C e D, respectivamente [22]. A soma de todos os valores de pixel de intensidade contidos na caixa de imagem de intensidade original A pode ser obtida pelo valor no pixel de imagem $P1$. Da mesma forma, a soma de todos os valores de pixel contidos na caixa B é obtida tomando a diferença entre $P2 - P1$. Para a caixa C, usamos $P3 - P1$. Finalmente, para a caixa D, a fórmula é $P4 - (P2 - P1) - P3$ [22]. Este método permite um processo de convolução eficiente entre a imagem e o núcleo da caixa [22]. Este resultado também mostra que apenas quatro pixels de acessos e operações de pixels são necessários para calcular a operação de convolução para uma única caixa, independentemente de seu tamanho [22]. Essa abordagem torna a operação de filtragem de caixa de convolução invariante em relação ao tamanho do núcleo do filtro e reduz drasticamente a complexidade computacional (quanto maior o núcleo do filtro, mais a diminuição proporcional da filtragem da caixa de linha de base). Como será visto, isso pode ser facilmente estendido aos núcleos de filtragem de caixa usados no algoritmo SURF; várias caixas com pesos diferentes podem ser usadas para representar um núcleo. O cálculo requer apenas quatro acessos e operações por caixa [21,24]. No caso em que a borda do filtro de caixa fica fora da imagem integral, os valores atribuídos aos pontos à esquerda e acima da imagem são

definidos como zero. Os pontos à direita e abaixo das imagens são ajustados para a intensidade de pixels da borda mais próxima da imagem integral [26].

Uma operação de interesse no algoritmo SURF é o cálculo da Hessiana para determinar pontos de interesse. Em particular, Fast Hessian é um termo usado por Bay quando ele propôs o algoritmo SURF para descrever seu método para determinar o determinante Hessiano de um pixel central usando uma operação de imagem integral combinada com a abordagem de convolução rápida de filtragem de caixa ilustrada na Figura 12 [21].


A matriz Hessiana $H(f)$ é definida como a matriz quadrada de derivadas parciais de segunda ordem de uma função $f(x, y)$, como proposto por Hesse []. Como o algoritmo SURF opera no espaço 2D (baseado na imagem de intensidade 2D), a matriz Hessiana é dada por [27].

$$H(f) = \begin{bmatrix} \frac{\partial^2 f}{\partial x^2} & \frac{\partial^2 f}{\partial x \partial y} \\ \frac{\partial^2 f}{\partial x \partial y} & \frac{\partial^2 f}{\partial y^2} \end{bmatrix} \quad (2)$$

O determinante da matriz de Hessian é projetado para medir a curvatura do nível de intensidade do pixel na região em torno de um determinado ponto, que é usado para detecção de áreas "blob-like" na abordagem SURF [27]. Na aplicação particular do algoritmo SURF, a função f é o resultado da convolução do nível de intensidade da imagem com um filtro Gaussiano aproximado [21,24]. Cada entrada de segunda derivada no Hessian é construída como um filtro de caixa que é aplicado diretamente aos pontos de amostra de imagem integral usando o método rápido na Figura 12. O resultado dessa técnica de filtragem é calcular as respostas circundantes sobre um determinado pixel para a intensidade da imagem original [24]. Idealmente, o valor do determinante Hessiano é maior para um pixel cercado por regiões com alta curvatura Gaussiana, que é o produto de duas curvaturas principais (ou seja, curvatura 2D) [28]. A aproximação do determinante da matriz de Hessian (ou Fast Hessian como denominado por Bay), é usada para determinar a localização de pontos de interesse. Bay descreve esse processo como detectando estruturas "blob-like" [21,24].

Bay propôs usar os filtros de caixa descritos anteriormente como núcleos para determinar as derivadas parciais Gaussianas de segunda ordem incluídas na matriz Hessiana [21,24]. Vários exemplos de kernel de filtro 9x9 são mostrados na Figura 13 como os gaussianos discretos e cortados à esquerda e as aproximações equivalentes de filtro de caixa usadas em SURF à direita [21,24].

Figura 13: Exemplo de núcleos gaussianos (à esquerda) vs. aproximação de núcleos gaussianos (à direita).




Fonte: Imagem retirada de [21].

(4) Passo 4: Geração de espaço-escala. Fazemos agora uma breve comparação entre os métodos do algoritmo SURF e SIFT para gerar espaço-escala para destacar as diferenças de eficiência [21,24].

No algoritmo SURF, a abordagem adotada por Bay é ligeiramente diferente da adotada por Lowe. Como mostrado à esquerda na Figura 14, Lowe reduziu o tamanho da imagem para cada oitava antes que o núcleo do filtro Gaussiano fosse aplicado iterativamente a escalas dentro de cada oitava para obter a representação da imagem com intensidade suavizada Gaussiana [20]. Em seguida, a representação DoG é obtida tomando a diferença entre duas imagens filtradas Gaussianas adjacentes dentro da oitava para formar a representação DoG [20]. Em contraste, o algoritmo SURF apenas aumenta a escala do filtro e aplica cada filtro à mesma imagem integral exata uma vez (que é uma aproximação da construção do DoG com oitavas inferiores abaixo da amostragem após a filtragem) [21,24]. Um bom contraste visual entre os dois processos de geração de espaço de escala seguido pelos algoritmos SIFT (esquerdo) e SURF (direito) é destacado na Figura 14.

Figura 14: Geração de espaço escala SIFT (esquerda) e SURF (direita).



Fonte: Imagem retirada de [25].

Para o algoritmo SURF, a propriedade de filtro de caixa combinada com uma imagem integral permite que cada caixa de um determinado peso no kernel do filtro seja calculada com apenas quatro acessos e operações de pixel para cada pixel de amostra. Esta etapa reduz muito o custo computacional associado à geração da representação de espaço-escala da imagem [21,24].

Para resumir as diferenças entre os dois algoritmos, SIFT requer uma imagem de intensidade primeiro a ser amostrada por dois, então a imagem tem um filtro Gaussiano aplicado iterativamente cinco vezes. Após cada aplicação do filtro de Gaussiano, uma imagem resultante é retida [20]. Em seguida, as diferenças entre imagens filtradas gaussianas adjacentes são calculadas para criar quatro aproximações DoG dentro de uma única oitava, conforme ilustrado na Figura 6 [20]. Este passo é então repetido para oitavas de escala mais alta através de amostragem descendente da imagem de intensidade e novamente aplicando filtros gaussianos nas escalas dentro da oitava [20].

Em contraste, o SURF usa a imagem integral da imagem de intensidade e aplica quatro operações de filtragem de caixa de tamanho crescente com o método de cálculo rápido mostrado na Figura 12. Nenhuma subtração de imagens de intensidade filtrada é necessária [21,24]. Para as oitavas superiores, dois tamanhos de filtro anteriores são usados (de quatro), portanto, apenas duas operações adicionais de filtragem de imagem são necessárias para formar uma oitava. Cada nível de escala sucessivo tem o kernel de filtro de caixa Fast Hessian aplicado na metade da amostragem (tanto vertical como horizontalmente) [24]. Uma grande parte da economia de custos computacionais em

SURF sobre SIFT é explicada nas diferenças em como as aproximações DoG do espaço em escala para o LoG são geradas [24].

Continuando com o SURF, e analisando à Figura 13, observa que a aproximação do filtro de caixa do núcleo Gaussiano não é uma representação exata de um Gaussiano. Para compensar essa diferença, Bay propôs uma fórmula para calcular o determinante da matriz Fast Hessian que pondera a segunda derivada diagonal com um fator de 0,9

$$\det(H) = D_{xx}D_{yy} - (0.9D_{xy})^2 \quad (3)$$


onde D_{xx} é a resposta da segunda derivada do filtro de caixa horizontal para um dado pixel central de imagem integral, D_{yy} é a resposta de filtro vertical e D_{xy} é a resposta de filtro diagonal [21,24].

A escala equivalente para cada kernel derivado Gaussiano de segunda ordem corresponde à escala base ou ao menor kernel Gaussiano pela aproximação.

$$\sigma_{approx} = CurrentFilterSize \times \frac{\sigma_{BaseFilter}}{BaseFilterSize} \quad (4)$$

onde σ é o desvio padrão gaussiano representado nos filtros de caixa de aproximação da derivada de segunda ordem gaussiana no algoritmo SURF [24].

Figura 15: Exemplo da função gaussiana bidimensional genérica.

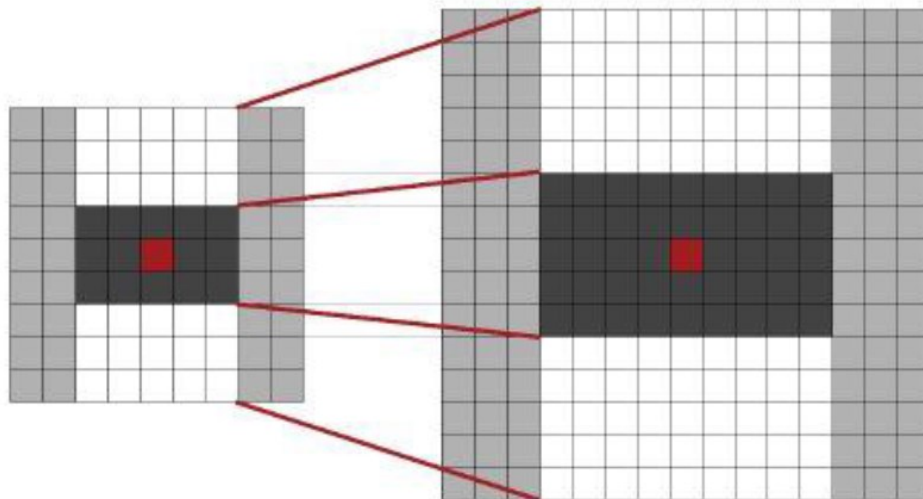


Fonte: Imagem retirada de [25].

O filtro do algoritmo de SURF base de 9x9 corresponde a uma escala gaussiana (desvio padrão) de 1,2 [21,24]; assim, a escala gaussiana equivalente para qualquer filtro pode ser determinada usando a Equação (4). Consulte a Figura 15 para uma representação visual de uma função Gaussiana bidimensional genérica como referência. Este não é a função Gaussiana exata usada no SURF; em vez disso, o algoritmo SURF contém três kernels (núcleos) de filtro que são aproximações de derivações de segunda ordem gaussianas [21,24]. Como a escala de filtro de caixa ou o desvio padrão é aumentado no algoritmo SURF, a estimativa da função gaussiana torna-se maior para calcular a imagem em resolução mais baixa [24].

Para manter uma razão consistente de largura e altura do kernel Gaussiano do filtro de caixa à medida que o filtro aumenta de tamanho, deve-se tomar cuidado para garantir que tudo seja proporcionalmente aumentado, já que o algoritmo SURF está operando em pixels discretos [24]. O aumento nos tamanhos dos filtros é mostrado na Figura 16 e representa uma aproximação da escala Gaussiana de 1,2 e uma escala de dois para o filtro derivado Gaussiano de segunda ordem na direção vertical y [24].

Figura 16: Crescimento de um filtro de caixa para a aproximação do núcleo gaussiano de D_{yy} .



Fonte: Imagem retirada de [24].

Em seguida, o algoritmo cria aproximações de oitavas DoG com os resultados da filtragem da imagem com filtros de caixa de tamanho crescentes. Estes podem ser representados como pirâmides 3D, onde uma imagem 2D é representada em diferentes escalas gaussianas, como na Figura 14. Cada oitava é construída com uma imagem integral 2D borrada por filtros de tamanho crescente para criar cada um dos quatro níveis internos à oitava, com a variável de terceira dimensão considerada o desvio padrão gaussiano de derivada de segunda ordem (escala) usado para desfocar a imagem [21,24]. Cada oitava é amostrada com a metade da taxa da anterior, resultando em um número menor de amostras para oitavas superiores [21,24]. Por exemplo, uma redução de resolução por duas de uma representação de imagem sendo amostrada em cada pixel significa que todas as outras colunas são amostradas horizontalmente e que todas as outras linhas são amostradas verticalmente.

Os tamanhos de filtro usados para construir a representação DoG para as oitavas são destacados na Tabela 3 (em que a taxa de amostragem inicial é selecionada pelo usuário) [26].

Tabela 3: Tamanhos dos filtros caixa usados para gerar representação de oitavas DoG no SURF.

	Tamanho do filtro de caixa				
1 Oitava	9	15	21	27	Amostragem @ taxa de amostragem inicial
2 Oitava	15	27	39	51	Amostragem @ 2x taxa de amostragem inicial
3 Oitava	27	51	75	99	Amostragem @ 4x taxa de amostragem inicial
4 Oitava	51	99	147	195	Amostragem @ 8x taxa de amostragem inicial
5 Oitava	99	195	291	387	Amostragem @ 16x taxa de amostragem inicial

Agora que oitavas são geradas e aproximações DoG dentro de cada oitava foram criadas pelo algoritmo SURF, uma busca 3D para o determinante Hessiano local máximo para a localização dos “pontos de interesse” pode ser realizada [21,24].

(5) Passo 5. Busca por pontos de interesse 3D. Esta busca é conduzida usando uma abordagem de não-supressão máxima (NMS) sobre os vizinhos do espaço 2D nas duas escalas médias de cada oitava e também na vizinhança do espaço-escala adjacente [24]. Ao focar a busca em torno de um único pixel, uma vizinhança de espaço-escala 3x3x3 é usada para determinar se a amostra é um máximo local dentro daquela região de busca [21,24]. Uma representação dos pixels adjacentes no espaço e espaço-escala é fornecida na Figura 8. O pixel central é considerado um máximo local se tiver a intensidade mais alta na região de pesquisa [24]. O pixel central é então comparado a um limite definido pelo usuário e, se exceder o limite e for um máximo local, o pixel é considerado um ponto de interesse [24].

Em seguida, introduzimos o NMS, que é aplicado como parte do processo de procura do máximo local [24]. No algoritmo SURF, o máximo local é encontrado "pesquisando" uma região 3D (novamente x, y e escala) em torno do pixel central com dimensões dadas pela equação (5).

$$(2N + 1)x(2N + 1)x(2N + 1) \quad (5)$$

onde N é o número de pixels diretamente em qualquer direção do eixo $(\pm x, y, \sigma)$ contidos na caixa de pesquisa, onde σ é a variável do eixo da escala [24]. Como mostrado na equação (5) e na Figura 8, a menor vizinhança possível dos vizinhos mais próximos do pixel de interesse é com $N = 1$, que produz uma vizinhança de tamanho $3 \times 3 \times 3$, conforme usado no algoritmo SURF [24]. Uma implementação direta dessa em termos computacionais dispendiosos, já que a busca requer mais cálculos do que o desejado ou necessário, então SURF usa um algoritmo eficiente para pesquisar pelo espaço de escala. Este método rápido é destacado por Bay [24] e Neubeck e Van Gool em [29]. Essa versão mais eficiente do NMS é chamada de “algoritmo de bloco”. Esse algoritmo divide a área de busca em blocos com tamanhos $(2N + 1)x(2N + 1)x(2N + 1)$ [24]. Esses blocos não sobrepostos são pesquisados para encontrar um único máximo local. Se um máximo local no bloco for encontrado, então todos os outros pixels poderão ser ignorados em buscas futuras porque esse pixel já foi determinado como tendo o maior valor em sua vizinhança [29]. As economias de complexidade decorrentes do uso dessa técnica são exibidas na Tabela 4.

Tabela 4: Comparação de eficiência do método de busca 3D, de [24]


Algorithm	worst case	average case
1D Straightfwd	N	$\approx 1 + \ln(N) + \ln(2)$
1D Block	$2 - \frac{1}{N+1}$	$\approx 1 + \ln(2 - \frac{1}{N+1})$
2D Straightfwd	N^2	$\approx 1 + 2 \ln(N) + \ln(2)$
2D Block	$4 - \frac{4}{N+1}$	$\approx 1 + 2 \ln(2 - \frac{1}{N+1})$
3D Straightfwd	N^3	$\approx 1 + 3 \ln(N) + \ln(2)$
3D Block	$\approx 8 - \frac{12}{N+1} - \frac{6}{(N+1)^2}$	$\approx 1 + 3 \ln(2 - \frac{1}{N+1})$

O resultado da abordagem da NMS é que todos os máximos locais mantêm seus valores, todos os outros pontos são definidos como zero e qualquer máximo local que não exceda o valor limite definido pelo usuário também é definido como zero [24]. No algoritmo SURF, há quatro representações DoG por oitava dos resultados filtrados do Fast Hessian, conforme descrito na seção anterior [24]. A parte superior e inferior (maior

e menor escala) DoG dentro de uma oitava são usadas apenas como referência na busca por pontos de interesse para as duas escalas intermediárias [24]; assim, apenas as segunda e terceira camadas em cada oitava podem determinar um ponto de interesse, mas um valor determinante de Hessian mais alto na primeira e quarta camadas pode eliminar um ponto de interesse de ser identificado como máximo local [24].

(6) Passo 6: Determinação de precisão de subpixel. A obtenção da precisão subpixel ocorre através de um método de interpolação quadrática [24]. Os vizinhos diretos do ponto de interesse são considerados (na imagem e no espaço-escala) e uma posição interpolada é encontrada [24]. A partir do algoritmo de busca anterior, já se sabe que os valores determinantes da vizinhança 3D da Hessiana são menores do que o valor obtido para o ponto de interesse, portanto a conclusão é que o valor interpolado fica dentro de uma faixa de 0,5 pixel da localização do ponto de interesse original e não mais perto de um pixel adjacente [24]. Uma função de ajuste parabólico unidimensional usada entre os pixels adjacentes é vista na Figura 17.

Figura 17: Exemplo de interpolação subpixel unidimensional de um ponto de interesse.



Fonte: Imagem retirada de [24].

No exemplo da Figura 17, o máximo local original foi encontrado no pixel p_0 , e os pixels vizinhos p_{-1} e p_1 ao longo do eixo são usados para ajuste quadrático. O máximo interpolado pode ser compensado da localização do pixel de ponto de interesse original.

O máximo é determinado como estando no ponto m da parábola, que está localizado a uma distância fracionária entre p_0 e p_1 [24]. Uma nova posição de subpixel é atribuída ao ponto de interesse detectado com base na localização interpolada m . O mesmo método é usado para a direção y para alcançar uma posição de subpixel para o ponto de interesse [24].

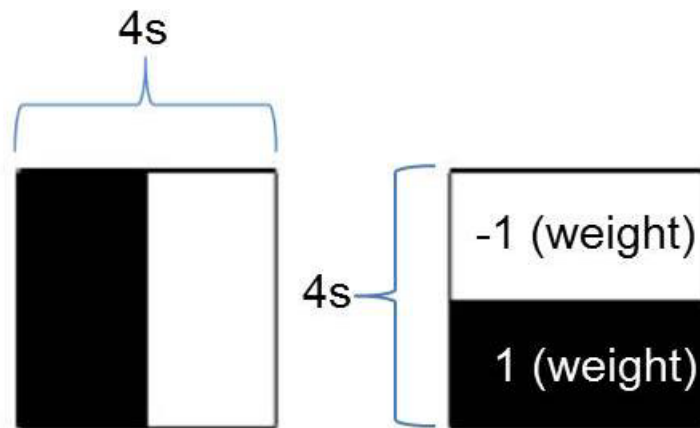
b) Descrição dos pontos de interesse

Para cada ponto de interesse identificado na subseção anterior, precisamos definir um conjunto de descritores que caracterize a área ao redor de cada ponto. O processo usado no algoritmo SURF é descrito nas etapas abaixo.

(1) Passo 1: Atribuição da orientação. O objetivo da etapa de orientação é fornecer um valor direcional para cada atributo que possa ser usado para auxiliar no cálculo de um descritor parcialmente invariante rotacionalmente. O valor de orientação também é uma saída de algoritmo para uso de esquema de correspondência opcional [24]. No algoritmo SURF regular, a orientação do atributo é calculada para a área ao redor do ponto de interesse, a fim de alcançar algum grau de invariância de rotação de recurso detectada. Para alcançar um valor de orientação, uma região de raio $6s$ (com s representando o valor determinante Fast Hessian em um determinado ponto de interesse) em torno da localização do ponto de interesse é definida [21,24]. As wavelets de Haar são geradas como mostrado na Figura 18. Durante a filtragem, esses núcleos são aplicados com o mesmo processo de convolução de filtro de caixa rápida mostrado anteriormente na Figura 12 [21,24].

Em seguida, o algoritmo SURF usa os núcleos do filtro Haar para determinar as respostas no plano (x, y) [21]. Além disso, o tamanho da região de pesquisa é dependente da variável s previamente definida, e o tamanho do núcleo do filtro Haar também é dependente de s com cada lado do núcleo quadrado com comprimento igual a $4s$ [24]. Além disso, respostas específicas de pixels usadas para determinação da orientação são amostradas nos espaçamentos vertical e horizontal s [21,24]. Um exemplo visual de filtro Haar é fornecido na Figura 18.


Figura 18: Filtros caixas de Haar usado no algoritmo SURF.



Fonte: Imagem retirada de [25].

Os filtros de Haar esquerdo e direito mostrados na Figura 18 são usados para determinar as respostas nas direções x e y , respectivamente [21,24]. Quando o método de imagem integral para filtragem de caixa discutido é usado para calcular a resposta em cada amostra, os filtros de convolução de Haar usam apenas seis operações para calcular [25]. Depois que as respostas são plotadas no plano (x, y) de acordo com suas respostas de filtro na direção correspondente, uma região de 60° (por convenção de algoritmo SURF [21,25]) é girada em torno da origem e as respostas que caem dentro dessa área são somadas [24]. O ângulo com o maior valor de respostas somadas é selecionado como a orientação [25]. Uma exibição visual desse processo é mostrada na Figura 19.

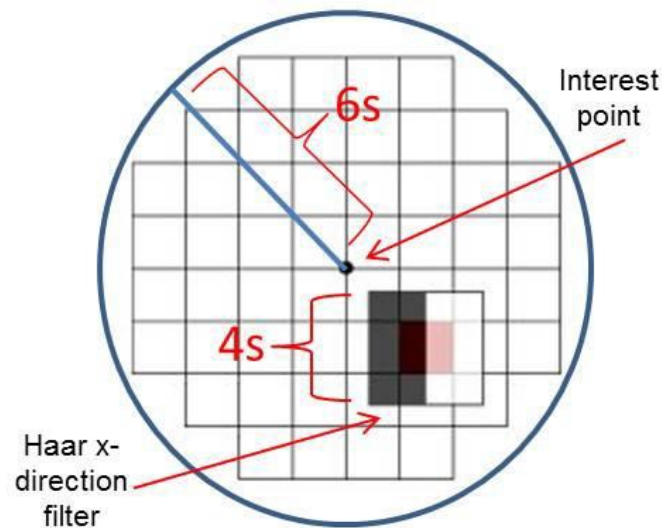
Figura 19: Orientação: À medida que a janela desliza em torno da origem, os componentes das respostas são somados para produzir os vetores mostrados em azul. O maior desses vetores determina a orientação dominante. Imagem retirada de [25].



Fonte: Imagem retirada de 25.

Um exemplo que ilustra o processo de orientação seguido dentro da área de busca ao redor do ponto de interesse é destacado na Figura 20 com o kernel de wavelet de Haar sendo aplicado.

Figura 20: Exemplo de filtragem de Haar durante a atribuição de orientação.



Fonte: Imagem retirada de [20].

Para entender o que é medido pelos filtros de wavelet de Haar, consulte o trabalho realizado na detecção de objetos por Papageorgiou et al. [30]. As wavelets simples usadas no SURF codificam as diferenças nas intensidades médias entre as regiões [30]. Portanto, para os núcleos de Haar que medem as respostas na direção x, uma alta resposta (magnitude) ocorre se houver uma mudança entre intensidades de pixel na direção correspondente de magnitude crescente ou decrescente. Para altas frequências, a soma dos valores absolutos é grande.

Neste ponto do algoritmo, o parâmetro de orientação foi calculado. Até o momento, as coordenadas interpoladas (x, y) , as escalas determinantes Fast Hessian e a orientação do recurso representam o conhecimento cumulativo obtido para cada atributo. Nesse ponto, o próximo passo do algoritmo pode ser executado para determinar o descritor de cada atributo (ou a região ao redor de cada ponto de interesse).

(2) Passo 2: Cálculo da soma do descritor wavelet de Haar. O descritor é usado pelo algoritmo SURF para descrever as propriedades de um recurso que envolve um ponto de interesse [21]. Como dito anteriormente, as regiões de "blob-like" são detectadas pelo detector baseado na Hessiana, então a etapa seguinte é definir as características que descrevem essas regiões. Essa descrição é obtida desenhando um quadrado em torno do ponto de interesse associado e inclinando-o para que o novo eixo x se alinhe com a linha de orientação encontrada na etapa anterior do algoritmo [21,24].

A orientação das regiões quadradas em torno dos pontos de interesse e seus vetores de orientação associados são ilustrados na Figura 21 em uma imagem de grafite.

Figura 21: Imagem de grafite mostrando o tamanho das janelas do descritor orientado em diferentes escalas.



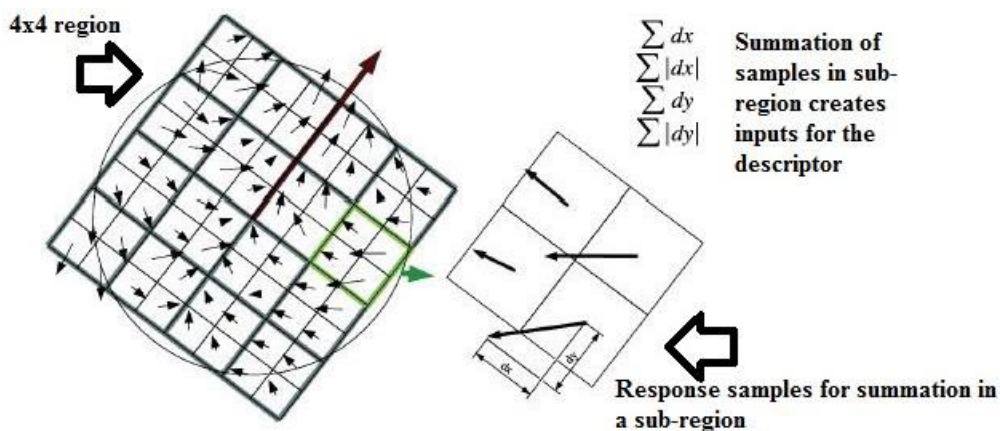
Fonte: Imagem retirada de [21].

Todas as regiões quadradas mostradas na Figura 21 têm lados de comprimento iguais a $20s$, onde s é o valor do determinante da Fast Hessiana do ponto de interesse correspondente [24]. Em seguida, os núcleos de wavelets Haar são construídos para filtragem rápida de convolução com comprimento lateral igual a $2s$ [25]. A região quadrada é então dividida em 4×4 sub-regiões, e cada sub-região é atribuída com comprimento lateral de $5s$ (16 compreendendo a área quadrada total) e filtragem

convolucional usando núcleo de Haar é aplicada dentro de cada sub-região. A informação espacial no descritor final é mantida filtrando as sub-regiões independentemente [24]. Lembre-se de que os filtros Haar e as respostas resultantes são orientados ao longo dos novos eixos que foram determinados na porção de orientação do algoritmo, de modo que as novas direções x e y agora ditam o alinhamento do eixo de geração do descritor. Note que x' está agora alinhado com o vetor de orientação e y' é perpendicular a x' [24]. As respostas resultantes de cada sub-região são ponderadas com um filtro Gaussiano de desvio padrão igual a $3,3s$ para aumentar a robustez às deformações geométricas e erros de localização [25].

Como a principal região em torno do ponto de interesse é dividida em um bloco de 4×4 sub-regiões, há um total de 16 sub-regiões para a área de interesse em torno de um determinado ponto de interesse [24]. Além das duas respostas wavelet do filtro Haar sendo somadas dentro de cada sub-região, o valor absoluto de cada amostra de filtro de Wavelet de Haar também é computado para somas futuras [21,24]. Este processo leva a quatro somatórias dentro de cada sub-região usada para caracterizar padrões, como mostrado na Figura 23. Como existem 16 sub-regiões, o descritor global é um vetor que contém *categorias x sub-regiões* = $4 \times 16 = 64$ entradas diferentes [21,24]. Um exemplo é fornecido na Figura 22, que contém uma região genérica de interesse em que cada sub-região possui duas amostras em cada direção (quatro no total).

Figura 22: Exemplo de geração de descritor SURF.



Fonte: Imagem retirada de [24].


Na Figura 22, todas as 16 sub-regiões (neste caso, com quatro amostras cada) representam uma localização espacial dentro da área em torno do ponto de interesse. As quatro respostas da soma de cada sub-região são colocadas em uma posição consistente no vetor do descritor, o que permite que o descritor carregue a informação espacial da característica [24]. O vetor descritor resultante associado a um determinado atributo de um determinada sub-região é gerado a partir de

$$S_{sub-região\ n} = \left[\sum d_x \cdot \sum |d_x| \cdot \sum d_y \cdot \sum |d_y| \right] \quad (6)$$

O quadrado menor com quatro pontos de amostra mostrados na Figura 22 é um exemplo de uma sub-região.

Para entender como essa abordagem efetivamente define padrões comuns, os valores de soma de resposta Haar do algoritmo SURF para alguns padrões de pixel de amostra são mostrados na Figura 23.

Figura 23: Exemplo de respostas Wavelet de filtros Haar.



Fonte: Imagem retirada de [24].

Por exemplo, os componentes de alta frequência espacial levam a grandes valores obtidos quando somados a valores absolutos de resposta de Haar e valores pequenos para somatórios regulares.


Em contraste, uma mudança gradual na intensidade ao longo do eixo x ou y corresponde a um aumento em ambas as somas no eixo correspondente (Figura 23). Os quatro valores somados permitem a diferenciação de atributos dentro da sub-região.

c) Sinal do laplaciano (*Sign of laplacian*)

Para uma indexação rápida durante a fase de correspondência, o sinal do laplaciano (isto é, o traço de Hessian Matrix) para o ponto de interesse subjacente é incluído. Normalmente, o ponto de interesse é encontrado na estrutura do tipo “blob”. O sinal de laplaciano distingue bolhas brilhantes em fundos escuros da situação inversa [21]. Esse recurso está disponível sem nenhum custo extra de computação, pois já foi calculado durante a fase de detecção. No estágio de correspondência, só comparamos os recursos se eles tiverem o mesmo tipo de contraste, veja na figura 24. Assim, essa informação mínima permite uma correspondência mais rápida e dá um pequeno aumento no desempenho [21]. Bay propôs usar o sinal do Laplaciano em árvores k-dimensionais (k-d) como uma forma significativa de dividir os dados [21].

Figura 24: Se o contraste entre dois pontos de interesse for diferente (escuro em um fundo claro versus luz em um fundo escuro), o candidato não é considerado uma correspondência valiosa.

Imagem retirada de [21].



Fonte: Imagem retirada de [21].

d) Resumo do algoritmo SURF

Os principais passos presentes no algoritmo SURF são dados por [21,24]:

- Conversão da imagem de entrada em escala de cinza;
- Computação da imagem integral;
- Criação de oitavas e níveis de escala para representação do espaço-escala.

- Realização de uma busca por pontos de interesses 3D no espaço-escala e uso de não-supressão máxima.
- Determinação da localização dos subpixels dos pontos de interesse por interpolação quadrática;
- Determinação da orientação do atributo usando a direção dominante da resposta wavelet de Haar ;
- Geração de descritor no eixo alinhado com a orientação do recurso usando respostas wavelet de Haar e seus valores absolutos somados em 16 sub-regiões.

A saída do algoritmo SURF incluiu: descritor de 64 bits, localização das coordenadas (x,y) dos pontos de interesse, ângulo de orientação, determinação do valor do determinante da Fast Hessian e sinal do Laplaciano para cada ponto de interesse [26].

2.4.3 Correspondência dos pontos de interesse (*Interest point matching*)

A correspondência de pontos de interesse é uma parte fundamental de qualquer algoritmo de detecção ou classificação. Se os descritores forem muito grandes ou complexos, a correspondência é dispendiosa e o algoritmo lento. Por outro lado, o desempenho é afetado se os descritores forem muito pequenos e não contiverem informações descritivas suficientes. Além disso, para desenvolver métodos mais eficientes e eficazes de reconhecimento em ambientes desordenados e imagens complexas, é necessário entender como os descritores de recursos são organizados e agrupados e o que esses parâmetros representam. Em cada estágio, compreender as capacidades e limitações do algoritmo de descrição dos pontos de interesse e do detector de pontos de interesse é essencial para avaliar o quão bem ele se aplica ao esquema de correspondência fornecido. Nesta seção, alguns esquemas de correspondência comumente usados para recursos de imagem são descritos.

a) Correspondência do vizinho mais próximo

Introduzimos brevemente o vizinho mais próximo (*nearest neighbor, NN*), a razão de distância dos vizinhos mais próximos (*nearest neighbor distance ratio, NNDR*) e a correspondência de kd-tree. Tanto o NN como o NNDR requerem uma métrica de

distância [34]. A métrica mais comumente usada é a distância euclidiana, mas o uso de métricas de distância ponderadas ou distância de Mahalanobis também é uma opção [34].

No espaço multidimensional, a distância euclidiana é a soma dos quadrados da distância entre as entradas dimensionais [34]. Portanto, para o descritor SURF de 64 pontos, a soma dos quadrados de todos os 64 elementos entre dois descritores fornece a distância euclidiana no espaço de feição. Além disso, existem várias maneiras de mensurar as variáveis, resultando em distâncias euclidianas ponderadas [34].

Para NN correspondência, dois atributos vizinhos correspondem quando não há outros vizinhos com distâncias menores e sua métrica de distância cai abaixo de um limite predeterminado [34]. Na correspondência NN, um atributo pode ter no máximo uma correspondência [34].

Uma alternativa para a abordagem NN é a correspondência NNDR que usa uma relação de distância entre o pixel e seu vizinho mais próximo dividido pela distância até o segundo vizinho mais próximo [34]. O ponto de interesse e o seu vizinho mais próximo são considerados correspondente quando essa relação é inferior a um limiar predeterminado [34].

O algoritmo mais comumente utilizado para a busca de vizinhos mais próximos é a *tree-kd*, ou uma *multi-dimensional search tree* [34]. Esse algoritmo divide as dimensões ao longo de hiperplanos alinhados ao eixo e organiza a árvore para permitir uma eficiência de pesquisa mais rápida [34]. Esse algoritmo funciona bem em buscas de dimensões menores, mas não funciona tão bem quanto com maior dimensionalidade [36].

b) Correspondência por Limiar

A correspondência de limiar avalia dois descritores e os descritores são considerados uma correspondência quando a distância entre eles está abaixo de um limite predeterminado [34]. Com a correspondência de limiares, um descritor pode ter várias correspondências [35], que não estão todas corretas. Além disso, o limite é difícil de definir corretamente e tem utilidade variável, dependendo das propriedades de correspondência de espaço de recurso [34].

2.4.4 Comparando SIFT e SURF

Luo e Oubong compararam o desempenho de SIFT, PCA-SIFT e SURF usando K-vizinhos mais próximos e o consenso de amostra aleatória (*random sample consensus, RANSAC*) para imagens que variam em escala, rotação, desfoque, iluminação e ponto de vista [31].


A técnica análise de componentes principais (*principal component analysis, PCA*) SIFT foi desenvolvida por Yan e Sukthankar como um meio alternativo para determinar o vetor de atributos (ou características) do algoritmo SIFT [32]. Enquanto o algoritmo SIFT usa magnitude e orientação de gradiente de imagem para criar histogramas em amostras ou sub-regiões ao redor do ponto-chave para desenvolver o descritor de ponto de interesse, o PCA-SIFT usa a análise de componentes principais para criar um descritor.

O primeiro critério medido foi o tempo de processamento usando algoritmos OpenCV [32]. O algoritmo SURF supera em muito SIFT e PCA-SIFT em quase quatro ordens de magnitude [32]. Os resultados estão listados na Tabela 5.

Tabela 5: Comparação de velocidade do algoritmo SURF, SIFT e PCA-SIFT. Tabela adaptada de [31].

Items	SIFT	PCA-SIFT	SURF
Total de correspondências	271	18	186
Tempo total (ms)	2.15378×10^7	2.13969×10^7	3362.86

Os testes de invariância de escala mostram que os algoritmos SIFT, PCA-SIFT e SURF possuem grandes discrepâncias. O algoritmo SURF apresenta um desempenho ruim em relação à invariância de rotação, como pode ser visto nos dados da Figura 25.

Figura 25: Teste de repetibilidade do algoritmo SURF, SIFT e PCA-SIFT versus rotação.

Fonte: Imagem retirada de [31].

O SURF supera tanto o desfoque de imagem baixo quanto o moderado e também as alterações de iluminação. Para representar mudanças no ponto de vista, o algoritmo SURF tem melhor performance para mudanças menores, enquanto o algoritmo SIFT ultrapassa o SURF para mudanças médias e o PCA-SIFT para as maiores mudanças [31]. Um resumo de teste de Luo e Oubong é mostrado na Tabela 4. O algoritmo SURF é computacionalmente eficiente e robusto para mudanças de iluminação.

Tabela 6: Um resumo de desempenho para invariância à deformação da imagem para SURF, SIFT e PCA-SIFT, de [31].

Método	Tempo	Escala	Rotação	Desfoque	Iluminação	Ponto de vista
SIFT	comum	melhor	melhor	melhor	comum	bom
PCA-SIFT	bom	comum	bom	comum	bom	bom
SURF	melhor	bom	comum	bom	melhor	bom

Bauer et al. conduziu outro teste de comparação de algoritmos SURF e SIFT com ambos open-source e as implementações de bibliotecas originais [33]. Os autores testaram as transformações de imagem, incluindo rotação, escala, ruído, iluminação e ponto de vista em imagens de objetos ao ar livre e naturais [33]. Eles usaram os critérios de correspondência correta total e a taxa de proporção de correspondências corretas para incorretas, conforme determinado por uma ferramenta que eles escreveram em Python [33].

A conclusão foi que o SIFT tem um desempenho ligeiramente melhor que o SURF, mas os resultados são muito próximos para todos os testes. O SIFT tem uma tendência a detectar mais pontos de interesse, o que os autores consideraram uma desvantagem computacional, porque não houve um aumento correspondente nas correspondências corretas. No geral, os autores concluíram que o SURF foi uma escolha melhor, dada a eficiência computacional e desempenho comparável [33].

3 METODOLOGIA PROPOSTA

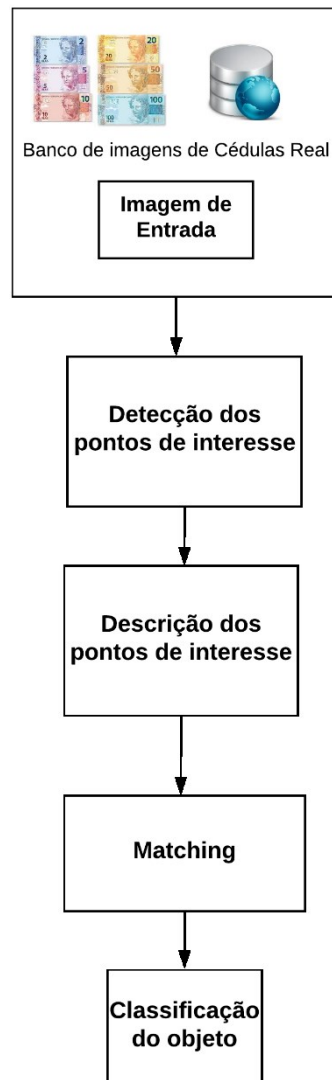
Sabendo que a maioria dos estudos publicados relacionados ao reconhecimento de cédulas são referentes a moedas de outros países, não o Brasil, as abordagens utilizadas não são diretamente aplicáveis às cédulas de Real. Isso acontece devido às diferenças existentes entre as cédulas de cada país, tais como, diferentes tamanhos, diferentes posições para os números, diferentes cores, diferentes fontes de caracteres, diferentes planos de fundos, entre outras.

Um das motivações do presente trabalho é o desenvolvimento de um sistema de reconhecimento de cédulas de Real baseado em identificação de pontos de interesse na imagem e criação de descritores para correspondência entre os pontos identificados.

Como parte inicial da metodologia desenvolvida, foi necessário a construção de um banco de imagens de cédulas de Real da Segunda família. Essa foi uma maneira encontrada para avaliar e testar a proposta do trabalho.

Uma vez criado o banco de imagens, tornou-se necessária a implementação do algoritmo proposto baseado no SURF, que consiste, em quatro fases: A primeira pode ser compreendida como a de detecção dos pontos de interesse, que determina as coordenadas e a escala dos mesmos. A segunda consiste na descrição dos pontos de interesse, que basicamente descreve a orientação dominante para cada um deles. A terceira fase é responsável pelo *matching*, que se trata de encontrar pares de *matching* usando a comparação de descritores obtidos a partir de várias imagens. Por fim, na fase de classificação, torna-se necessário o uso de técnica de decisão para identificação das cédulas.

Todas as etapas mencionadas podem ser vistas esquematicamente no fluxograma da Figura 26, onde as quatro últimas etapas são realizadas na ordem apresentada e em estrutura de cascata, sequenciais.

Figura 26: Fluxograma da metodologia proposta.

Conforme o fluxograma, este capítulo será organizado da seguinte forma. A seção 3.1 detalha como será criado o banco de imagens, ao passo que a seção 3.2 detalha a extração de características e seleção de bons *matching*. Por fim, seção 3.3 traz as abordagens sobre classificação com uso de técnicas de decisão para identificação da cédula.







3.1 Criação do banco de imagens

Para aplicação e avaliação das técnicas propostas, foi elaborado um banco de imagens de cédulas da Segunda Família do Real e dividiu-se em dois grupos: o grupo de teste e o grupo de referência, composto por cédulas de R\$ 2, 5, 10, 20, 50 e 100. O grupo

de teste pode ser observando na tabela 7 para cédula de 2 reais. Ele representa as variações (rotação, oclusão e iluminação) sofridas pelas cédulas, que foi criada para representar uma peculiaridade a ser encontrada durante aplicação de um sistema de reconhecimento de cédulas em situações reais.



A ideia básica é a criação de um banco de imagens que seja capaz de representar as principais situações, mesmo que em um conjunto reduzido, que se aproximam da realidade de uma aplicação prática desse tipo de sistema.

Tabela 7: Grupo de teste para cédula de 2 reais.

	<i>Segunda Família Real</i>
<i>Anverso</i>	
<i>Anverso (180°)</i>	
<i>Anverso (Oclusão)</i>	
<i>Reverso</i>	
<i>Reverso (180°)</i>	
<i>Reverso (Oclusão)</i>	

O grupo de referência é representado na tabela 8. Ele apresenta grande importância na fase de *matching*, que representa pares de correspondentes (*matching*) que são utilizados para comparação dos descritores a partir das imagens do grupo de teste em relação as imagens do grupo de referência, com intuito de identificar qual imagem do grupo de teste tem maior número de correspondência com as imagens do grupo de referência para uma possível classificação.

Tabela 8: Grupo de referência.

	<i>Anverso</i>	<i>Reverso</i>
<i>2 reais</i>		
<i>5 reais</i>		
<i>10 reais</i>		
<i>20 reais</i>		
<i>50 reais</i>		



Por fim, a Tabela 9 lista as configurações da câmera utilizada para a captura das imagens do banco de imagens. No presente estudo foi utilizado um celular da marca Apple modelo Iphone 6.

Tabela 9: Dados técnicos da câmera utilizada para construção do banco de imagens.

Parâmetros	Dados técnicos
Resolução	3264 x 2448 pixel
Câmera traseira	8MP
Modo do foco	Automático
Estabilização	Automático
Zoom digital	5x
HDR	Automático

Lembrando que, a resolução utilizada pelas imagens de teste e de referência foi de 1280 x 960.

3.2 Extração de característica e *Matching*

O trecho de código descrito em Algoritmo 1 mostra como é realizada a extração de característica através do uso de detecção de pontos de interesse e cálculo de descritores usando SURF. Todas as funções de extração e *matching* utilizada no trabalho são de *computer vision Toolbox* do MATLAB 2017b.

A função de detecção de pontos de interesse “*detectSURFFEATURES*” determina as coordenadas e escala de pontos de interesse. Tal função recebe os seguintes parâmetros:

- Uma imagem em escala de cinza (imagem teste ou imagem de referência).

- O limiar (“*MetricThreshold*”) que é um número escalar não negativo que especifica um limite para selecionar os atributos mais fortes.
- Número de oitavas (“*NumOctaves*”) é um inteiro escalar, $\text{NumOctaves} \geq 1$. Aumentando-se esse valor é possível detectar “*blobs*” maiores.
- Níveis de escala (“*NumScaleLevels*”) é um inteiro escalar, $\text{NumScale Levels} \geq 3$. Aumenta-se esse número para detectar mais “*blobs*” em incrementos de escala mais refinados.
- Região de interesse (“ROI”) é um vetor do formato [X Y ALTURA LARGURA], que especifica uma região retangular na qual os cantos serão detectados. [X Y] é o canto superior esquerdo da região.

Este procedimento de detecção de pontos é realizado na imagem da cédula que está em teste e na imagem referência.

Já a função de cálculo de descritores de ponto de interesse (“*extractFeatures*”) basicamente descreve a orientação dominante para cada ponto de interesse através dos cálculos de descritores. Tal função recebe os seguintes parâmetros:

- Duas imagens em tons de cinza. A primeira é apenas a imagem original de teste (*ref_img_gray*) convertida em escala de cinza e a segunda (*ref_pts*) continua sendo a mesma imagem original, porém com a presença de pontos de interesses selecionados.
- “*Upright*” é um escalar lógico. Quando define-se “true”, a orientação dos vetores de atributos não é estimada. Normalmente define-se “true” quando você não precisa dos descritores de imagem para capturar informações de rotação.
- Tamanho do atributo (“*FeatureSize*”) é um inteiro escalar que pode ser definido como 64 ou 128 bits.

Este procedimento também é realizado na imagem da cédula que está em teste e na imagem referência.

O algoritmo 1 apresenta o trecho de código em que é feito o *matching* e seleção de bons *matchings* pela função “*matchFeatures*”. Essa função recebe os seguintes parâmetros:

- Duas imagens em tons de cinza (imagem teste e imagem referência) com seus descritores já calculado.
- Limiar de *matching* (“*MatchThreshold*”) é um T escalar, $0 < T \leq 100$, que especifica o limite de distância necessário para *matching*. Um par de atributos não é correspondido se a distância entre eles for maior que T por cento de uma combinação perfeita. Aumenta-se T para retornar mais correspondências.
- Métrica (“*Metric*”) é uma *string* usada para especificar a métrica de distância.

A função *matchFeatures* encontra a melhor combinação entre os descritores. Como já visto, a função recebe como parâmetros os descritores de cada imagem (imagem teste e imagem de referência) e a matriz de *matches* onde será armazenada a combinação. Depois, esta matriz é convertida em lista encadeada. Logo, são encontradas as distâncias mínimas e máximas entre os descritores da cédula que está em teste para que seja feita seleção de “bons *matchings*”.

Finalmente, se o número de bons *matchings* for inferior ao limiar previamente selecionado, é indicando que são imagens distintas. Caso o número de bons *matchings* seja superior ou igual ao limiar, é indicado que as imagens de teste comparadas as imagens de referências são semelhantes.

Algoritmo 1: Métodos para extração de características e *matching*.

```
%% Extração de Característica
% Detecção dos pontos de Interesse
ref_pts = detectSURFFeatures (ref_img_gray,'MetricThreshold',2000);
% Descrição dos pontos de Interesse
[ref_features, ref_validPts] = extractFeatures (ref_img_gray, ref_pts);
% Matching
[index_pairs, matchmetric2] = matchFeatures (ref_features, I_features);
```

3.3 Classificação

Como já foi dito em seções anteriores, é de extrema importância o uso de técnica de decisão para classificação das cédulas.

No projeto proposto utilizou-se número de *matchings* como medida de comparação para identificação das cédulas.

Para ser ter uma melhor compreensão sobre o método de classificação, foi definido dois limiares de correspondência (*matchings*), para os lados anverso e reverso. Se a soma de todos os números de *matchings* da imagem teste com cada imagem referência (ex 2, 5, 10, 20, 50 e 100 reais) for maior que o limiar de correspondência total do lado reverso, logo essa imagem teste será tratada como uma imagem anverso, caso contrário, ela pode ser reconhecida em posição oposta à normal.

Para casos de imagens teste que não são uma cédula definiu-se um limiar de correspondência total, que representa a soma dos limiares anverso e reverso. Se o limiar de *matching* total for maior que valor fixo definido, pode se dizer que a imagem teste é uma cédula real, senão, não é uma cédula.

Por fim, após ter sido realizada as etapas acima, é necessário identificar o valor de cada cédula real testada. Para isso, como já foi dito anteriormente na seção 3.2, quanto maior número de *matchings* maior a probabilidade das imagens serem semelhantes, com isso definiu-se que quando a imagem teste comparada com cada imagem referência, o algoritmo proposto no projeto indicará o valor da cédula através do grau de correspondência em relação às demais.

Por exemplo, a imagem testada é uma nota de 10 reais, ela será comparada com as demais notas do grupo de referência, com isso será obtido 6 valores distintos de números de *matchings*, desses números um valor tem um grau de correspondência maior do que a dos outros, logo, a imagem de referência que tem maior correspondência será usada para identificar o valor da cédula.

4 RESULTADOS E DISCUSSÕES

Neste Capítulo serão apresentados os resultados experimentais da metodologia proposta, isto é, resultados quantitativos, como grau de classificação de acertos e tempo de resposta.

As imagens de cédulas Real e imagens que não apresentam cédulas Real que foram utilizadas nos testes são apresentadas integralmente no Apêndice A.

Testou-se todas as cédulas em ambiente iluminado com fonte de luz natural, entre os horários de 14:00 às 15:00 e também testou-se no escuro, no mesmo ambiente com pouca iluminação utilizando luz artificial entre os horários das 20:00 às 21:00. Para fins de análise, o experimento foi realizado sobre uma folha A4 branca.

Para avaliação dos resultados, adotou-se os conceitos de especificidade, sensibilidade e acurácia, como métodos para análise dos resultados do Apêndice B. A especificidade é a taxa de verdadeiros negativos e indica a capacidade de um teste excluir corretamente os objetos que não são do grupo. A sensibilidade é a taxa de verdadeiros positivos e indica a capacidade de um teste detectar corretamente os objetos. A acurácia, avalia a proporção entre todos os testes corretos sobre todos os resultados obtidos, é considerada a taxa de verdadeiros positivos e verdadeiros negativos para esta análise [37,38]. Para a mensuração dos resultados, foram utilizadas as expressões abaixo:

$$\textit{sensibilidade} = \frac{x}{x + z} \quad (5)$$

$$\textit{especificidade} = \frac{w}{y + w} \quad (6)$$

$$\textit{acurácia} = \frac{x + w}{x + y + z + w} \quad (7)$$

onde “ x ” corresponde ao número de resultados corretos para cédulas reais; “ y ” corresponde ao número de vezes em que o algoritmo indicou o valor de cédula para uma

Método utilizado (SURF)	2.90	0.95	1.00	0.95	2.68	0.95	1.00	0.95
-------------------------	------	------	------	------	------	------	------	------

Tabela 12: Resultados obtidos para identificação da cédula de cinco reais da Segunda Família Real.

R\$ 5 reais	Ambiente Claro				Ambiente Escuro			
	TMI (s)	SE	ES	AC	TMI (s)	SE	ES	AC
Método utilizado (SURF)	2.77	0.95	1.00	0.95	2.73	0.89	1.00	0.90

Tabela 13: Resultados obtidos para identificação da cédula de dez reais da Segunda Família Real.

R\$ 10 reais	Ambiente Claro				Ambiente Escuro			
	TMI (s)	SE	ES	AC	TMI (s)	SE	ES	AC
Método utilizado (SURF)	2.79	1.00	1.00	1.00	2.76	1.00	1.00	1.00

Tabela 14: Resultados obtidos para identificação da cédula de vinte reais da Segunda Família Real.

R\$ 20 reais	Ambiente Claro				Ambiente Escuro			
	TMI (s)	SE	ES	AC	TMI (s)	SE	ES	AC
Método utilizado (SURF)	2.76	0.83	1.00	0,85	2,75	0,83	1.00	0.85

Tabela 15: Resultados obtidos para identificação da cédula de cinquenta reais da Segunda Família Real.

R\$ 50 reais	Ambiente Claro				Ambiente Escuro			
	TMI (s)	SE	ES	AC	TMI (s)	SE	ES	AC
Método utilizado (SURF)	2.79	0.84	1.00	0.85	2.78	0.84	1.00	0.85

Tabela 16: Resultados obtidos para identificação da cédula de cem reais da Segunda Família Real.

R\$ 100 reais	Ambiente Claro				Ambiente Escuro			
	TMI (s)	SE	ES	AC	TMI (s)	SE	ES	AC
Método utilizado (SURF)	2.85	1.00	1.00	1.00	2.77	0.89	1.00	0.90

Analisando as tabelas, observa-se que para as cédulas de dez reais, tanto no ambiente claro quanto no escuro, o método utilizado obteve taxas consideradas ótimas (1.00) para especificidade, sensibilidade e acurácia. A segunda cédula (Tabela 16) que manteve taxa considerada ótima foi a de cem reais, porém, isso só foi possível no ambiente claro. Por outro lado, as cédulas de vinte reais (Tabela 14) em ambos os ambientes, obteve a menor taxa de sensibilidade e acurácia em relação as demais cédulas. O principal motivo desses resultados é o grau de semelhança entre as cédulas testadas com a imagem referência.

Um fato interessante é que em todas as cédulas o valor da especificidade é ótimo, isso significa que o método utilizado foi capaz de excluir corretamente os objetos que estão fora do grupo.

Ao analisar as tabelas 11, 12, 14, 15 e 16 verifica-se que as métricas de sensibilidade e acurácia sofrem uma redução em seu valor, proporcionando ao algoritmo classificações equivocadas. As principais responsáveis pelos erros obtidos nos testes são as cédulas dobradas, que utilizam apenas as imagens de referência para sua classificação.

Quanto ao tempo médio para identificação (TMI), verifica-se que em ambiente claro ele é maior do que no ambiente escuro. Isso quer dizer que o método utilizado leva um tempo maior (faixa dos milissegundos) para identificar a cédula em um ambiente bem iluminado do que em um local pouco iluminado. Sendo assim, em um ambiente claro o SURF extrai um maior número de pontos de interesse, logo, isso proporciona um tempo maior na computação do algoritmo SURF. Os números de pontos de interesse podem ser observados no Apêndice B.

Para entender melhor a razão do ambiente claro extrair mais pontos de interesse do que um ambiente escuro, segue uma análise. Como já foi mencionado no capítulo


anterior, o algoritmo SURF utiliza informação da imagem em tons de cinza, essa imagem é representada como uma função de duas variáveis (ex., $f(x, y)$).

A Figura 27 ilustra uma cédula de dois reais em um ambiente claro e seus respectivos pontos de interesse encontrados. Quando é necessário caracterizar um objeto, é importante extrair informações de locais que possuam maiores variações de tons de cinza, que normalmente são encontradas nas bordas. Essas variações são mais facilmente observadas na Figura 28. (Que foi obtido pelo software *Interactive_3D_Surface_Plot* desenvolvido por Kai Uwe Barthel).

Figura 27: Pontos de interesse extraídos em uma cédula de dois reais, usando algoritmo SURF.



Figura 28: Superfície em relevo da cédula de dois reais de uma função bidimensional.



A Figura 28 pode ser considerada um relevo, observa-se que os tons mais escuros de cinza representam valores menores e são locais com menor grau de variação. Os mais

claros possuem valores mais altos e representam maior grau de variação. Sendo assim, percebe-se que os locais de bordas sofrem maior variação, logo esses pontos podem ser considerados como pontos de interesse, ao contrário, de locais planos onde as variações são menores. Para encontrar essas taxas de variações na imagem, utiliza-se o conceito de derivadas parciais como já informado no Capítulo 2.

A imagem em ambiente escuro (Figura 29), mostra que as regiões de bordas possuem menor variação entre seus pixels adjacentes em relação ao ambiente claro. Isso faz com que alguns pontos não sejam considerados como pontos de interesse para o algoritmo SURF. Portanto, como resultado, o algoritmo retornará um menor número de pontos de interesse, conforme observado na Figura 29. Para o ambiente claro foram encontrados “428” pontos como mostrado na Figura 27 e para o ambiente escuro na Figura 29 foram encontrados “49” pontos de interesse.

Figura 29: Pontos de interesse extraídos em uma cédula de dois reais, usando algoritmo SURF.



Em geral, obtém-se boas taxas de sensibilidade, especificidade e acurácia com o método utilizado. Nas seções posteriores será analisado o comportamento das cédulas em situações específicas, como rotação e oclusão.

4.1 Rotação

Para o teste de rotação definiu-se dois ângulos 0° e 180° para cada cédula tanto para seu lado anverso e reverso, apresentado conforme mostrado na Figura 30. Nessa seção, para fins de simplificação da análise dos resultados, adotou-se a primeira nota testada de

cada grupo (ex. Nota2f_01, Nota2v_01, Nota5f_01, Nota5v_01 ...) e as cédulas em ambiente claro.

Figura 30: a) Ilustra a parte frontal da cédula de dois reais rotacionada (0° e 180°). b) Ilustra a parte oposta da cédula de dois reais rotacionada (0° e 180°).



Figura 31: Gráfico de *matchings* em função dos dois ângulos testados para cada cédula Real-lado anverso.


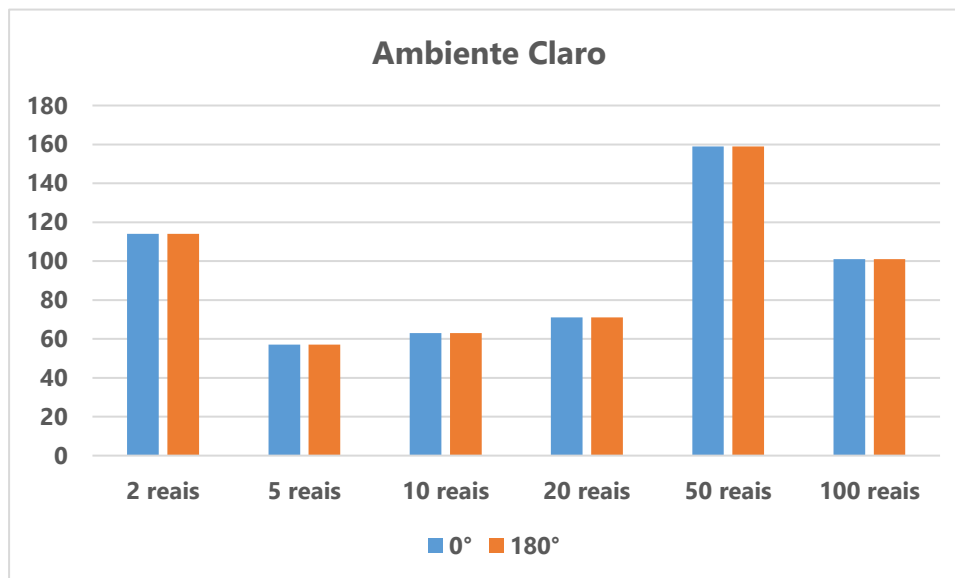


Figura 32: Gráfico de *matchings* em função dos dois ângulos testados para cada cédula Real - lado reverso.



Analisando as Figuras 31 e 32, percebe-se que os dois ângulos testados não ocasionaram nenhuma mudança expressiva no valor do número de correspondência (*matchings*), isso demonstra que o algoritmo SURF se apresentou invariante à rotação. Portanto, não houve nenhuma influência dos dois ângulos na identificação da cédula mantendo o mesmo resultado (ver Apêndice B). Essa interpretação também é válida para o ambiente escuro.

4.2 Oclusão

Para o teste de oclusão utilizou-se cédulas dobradas, com objetivo de avaliar o algoritmo em casos mais próximos da realidade. Um exemplo de cédula dobrada pode ser visualizado na Figura 33.

Figura 33: Representação da cédula de dois reais dobrada. a) cédula de dois reais dobrada no lado animal; b) cédula de dois reais dobrada no lado efigie.



De acordo com os resultados obtidos no Apêndice B, verifica-se que o número de cédulas testadas dobradas no lado da efigie é de 36 cédulas (ambiente claro e escuro). Destas, apenas dezessete cédulas foram classificadas corretamente, ou seja, isso indica uma taxa de acerto 47,2 %. Por outro lado, para as cédulas dobradas no lado do animal, obteve-se uma taxa de acerto de 100 %.

Observando a Figura 34, percebe-se que os pontos de interesse detectados nas cédulas dobradas no lado da efigie são muito similares, o que dificulta a distinção entre as notas, podendo levar a classificação equivocadas resultando uma redução na taxa de acertos.

Figura 34: Pontos de interesse extraídos em cédula dobradas no lado da efigie, usando algoritmo SURF. a) detecção de pontos de interesse em cédula dobrada de 2 reais; b) detecção de pontos de interesse em cédula dobrada de 10 reais.



Por outro lado, analisando o resultado apresentado na Figura 35 para cédulas dobradas no lado do animal, identifica-se que os pontos de interesse detectados são distintos (imagens distintas), facilitando a distinção entre as notas. Consequentemente tem-se maiores taxas de acertos durante a classificação.

Figura 35: Pontos de interesse extraídos em cédula dobradas no lado do animal, usando algoritmo SURF. a) detecção de pontos de interesse em cédula dobrada de 2 reais; b) detecção de pontos de interesse em cédula dobrada de 10 reais.



Conclui-se dessa forma que quanto maior o número de pontos de interesse distintos entre imagens, maior é a chance de classificar uma imagem corretamente, conforme resultados observados no Apêndice B para cédulas dobradas no lado do animal.

5 CONCLUSÃO

Neste trabalho foi utilizado o SURF como método para o reconhecimento de cédulas da Segunda Família do Real a partir de imagens. Dentre as principais dificuldades enfrentadas para a implementação das propostas, destacam-se:

- Falta de material na literatura voltado para as cédulas de Real;
- Características do fundo das cédulas de Real que contém diversos artefatos, o que dificulta a identificação da cédula e sua posterior classificação;
- Existência de variações de orientação e escala das cédulas nas imagens e também fatores ambientes como a sensibilidade em ambientes com diferentes intensidade de luz e desgaste temporal.

A partir dos resultados obtidos, conclui-se que o sistema reconhecimento de cédula Real mostrou desempenho ótimo e cumpre o que foi proposto (robustez em situações de rotação e escala), com algumas limitações no reconhecimento de cédulas oclusas (dobradas). Já o fator de luminosidade, apesar de ter reduzido o número de correspondências das cédulas de ambiente claro para ambiente escuro, teve pouca influência no resultado de classificação. Isso significa dizer que o algoritmo SURF se mostrou imune à variação de intensidade luminosa no ambiente.

5.1 Sugestões para trabalhos futuros

A partir do reconhecimento de cédulas Real usando algoritmo SURF desenvolvido neste trabalho, são propostos alguns trabalhos futuros. Dentre eles tem-se:

- Desenvolvimento de aplicativo.
- Melhoria na identificação de cédulas oclusas.
- Identificação de várias cédulas Real em uma mesma imagem.

REFERÊNCIAS BIBLIOGRÁFICAS

- [1] World Health Organization. *Change the Definition Of Blindness*. Disponível em: <<https://www.who.int/blindness/>>. Acesso em: 08 de janeiro de 2019.
- [2] Centers for Disease Control and Prevention. *Blindness and Vision Impairment*. Disponível em: <<https://www.cdc.gov/healthcommunication/ToolsTemplates/EntertainmentEd/Tips/Blindness.html>>. Acesso em: 08 de janeiro de 2019.
- [3] Barbara Silverstone, Bruce Rosenthal, Mary Ann Lang, eds. (2000). *The Lighthouse Handbook on Vision Impairment and Vision Rehabilitation*. [S.l.]: *Oxford University Press*. p. XIII. ISBN 9780195094893
- [4] Maberley, DA; Hollands, H; Chuo, J; Tam, G; Konkal, J; Roesch, M; Veselinovic, A; Witzigmann, M; Bassett, K (março de 2006). The prevalence of low vision and blindness in Canada. *Eye (London, England)*. **20** (3):3416. PMID 15905873. doi:10.1038/sj.eye.6701879.
- [5] World Health Organization. *Visual impairment and blindness*. 2013. Disponível em: <<https://www.who.int/en/news-room/fact-sheets/detail/blindness-and-visual-impairment>>. Acesso em: 09 de janeiro de 2019.
- [6] Instituto Brasileiro de Geografia e Estatística. *Censo Demográfico 2010*. 2010. Disponível em: <<http://www.ibge.gov.br/home/presidencia/noticias/27062003censo.shtm>>. Acesso em: 09 de janeiro de 2019.
- [7] BRASIL. Governo do Brasil. Real é a moeda corrente no Brasil desde 1994. <<http://www.brasil.gov.br/economia-e-emprego/2009/11/Real-e-a-moeda-corrente-no-brasil-desde-1994>>. Acesso em: 24 de julho 2018.
- [8] BCB. BANCO CENTRAL DO BRASIL. Segunda Família do Real. Disponível em: <<http://www.bcb.gov.br/novasnotas/material-de-apoio.html>>. Acesso em: 24 julho 2018.
- [9] CONCI, A.; AZEVEDO, E.; LETA, F. R. *Computação Gráfica: teoria e prática*. Rio de Janeiro: Elsevier, 2008.
- [10] LEI 9.069, de 29 de junho e 1995. Dispõe sobre o Plano Real, o Sistema Monetário Nacional, estabelece as regras e condições de emissão do REAL e os critérios para conversão das obrigações para o REAL, e dá outras providências. Disponível em: <www.planalto.gov.br>. Acesso em: 09 de janeiro de 2019.
- [11] COMUNICADO no 020392. Divulga o lançamento das cédulas de 50 e 100 reais da Segunda Família de Cédulas do Real, de circulação comum. Banco Central do Brasil, 2010.
- [12] O GLOBO ONLINE. Governo lança as novas notas de real. Disponível em: <<https://oglobo.globo.com/economia/governo-vai-gastar-1-bi-para-fazer-novas-cedulas-3058700>>. Acesso em 09 de janeiro de 2019.

[13] MYNEXTZONE. Novas cédulas do Real começam a ser fabricadas. Disponível em <mynextzone.com>. Acesso em 09 de janeiro de 2019.

[14] BCB. *BANCO CENTRAL DO BRASIL. Moedas*. 2014. Disponível em: <<https://www.bcb.gov.br/?MOEDAFAM2>>. Acesso em: 29 junho 2014.

[15] BCB. BANCO CENTRAL DO BRASIL. Cartilha de Treinamento - Segunda Família do Real. Disponível em:<https://www.bcb.gov.br/novasnotas/assets/downloads/material_apoio/2e5/Cartilha.pdf>. Acesso em 09 de janeiro de 2019.

[16] GONZALEZ, R. C.; WOODS, R. C. *Processamento digital de imagens*. 3. ed. São Paulo: Pearson Prentice Hall, 2010.

[17] MENESES, P. R. et al. *Introdução ao Processamento de Imagens de Sensoriamento Remoto*. Brasília: Universidade Federal de Brasília, 2012.

[18] KUSUMOTO, 2015

[19] MARENGONI, M.; STRINGHINI, D. Tutorial: Introdução à visão computacional usando opencv. *RITA - Revista de Informática Teórica e Aplicada*, v. 16, n. 1, p.125–160, 2009. Citado na página 36.

[20] LOWE, D. G. Distinctive image features from scale-invariant keypoints. *International journal of computer vision*, v. 60, n. 2, p. 91--110, 2004.

[21] BAY,H.; TUYTELAARS, T.;GOOLL.V.Surf: Speeded up robust features. In: In ECCV.[S.1: s.n.], 2006, p.404-417.

[22] P. Viola and M. Jones, “Robust real-time face detection,” *Int. Journal of Computer Vision*, vol. 57, no. 2, pp. 137–154, 2004.

[23] K. Sung and R. Casper, “Application of convolution in image processing with MATLAB,” University of Washington, Seattle, WA, 2013.

[24] H. Bay, “From wide-baseline point and line correspondence to 3D,” Ph.D. dissertation, Eidgenössische Technische Hochschule Zurich, Zurich, Switzerland, 2006.

[25] C. Evans, “Notes on the OpenSURF library,” The OpenSURF Computer Vision Library, Stevenage, UK, 2009.

[26] D. Jan Kroon, “OpenSURF (including image warp),” 06 Oct.2010. [Online]. Available: <http://www.mathworks.com/matlabcentral/fileexchange/28300-opensurf--including-image-warp->. Acesso em 03 de março de 2019.

[27] A. Ben-Menahem, *Historical Encyclopedia of Natural and Mathematical Sciences*, vol. 1, New York: Springer-Verlag Berlin Heidelberg, 2009, p. 1972.

[28] K. Mikolajczyk, T. Tuytelaars, C. Schmid, A. Zisserman, J. Matas, F. Schaffalitzky, T. Kadir and L. Van Gool, “A comparison of affine region detectors,” *Int. Journal of Computer Vision*, vol. 65, no. 1/2, pp. 43-72, 2005.

- [29] A. Neubeck and L. Van Gool, “Efficient non-maximum suppression,” in *18th Conference on Pattern Recognition*, Zurich, Switzerland, 2006.
- [30] C. Papageorgiou, C. Oren and T. Poggio, “A general framework for object detection,” in *Sixth Int. Conf. on Computer Vision*, Washington, DC, 1998.
- [31] L. Juan and O. Gwon, “A comparison of SIFT, PCA-SIFT and SURF,” *Int. Journal of Image Processing*, vol. 3, no. 4, pp. 143–152, 2009.
- [32] K. Yan and R. Sukthankar, “PCA-SIFT: A more distinctive representation for local image descriptors,” in *Proceeding Conf. on Computer Vision and Pattern Recognition*, Washington, DC, 2004.
- [33] J. Bauer, N. Sunderhauf and P. Protzel, “Comparing several implementations of two recently published feature detectors,” in *Proc. of the Int. Conf. on Intelligent and Autonomous Systems*, Toulouse, France, 2007.
- [34] R. Szeliski, *Computer Vision: Algorithms and Applications*, London: Springer, 2010.
- [35] K. Mikolajczyk and C. Schmid, “A performance evaluation of local descriptors,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 27, no. 10, pp. 1615-1630, 2005.
- [36] M. Muja and D. G. Lowe, “Fast approximation nearest neighbor with automatic algorithm configuration,” in *VISAPP Int. Conf. on Computer Vision Theory and Application*, Lisboa, Portugal, 2009.
- [37] WELFER, D. Métodos Computacionais para Identificar Automaticamente Estruturas da Retina e Quantificar a Severidade do Edema Macular Diabético em Imagens de Fundo do Olho. Tese (Doutorado) — Universidade Federal do Rio Grande do Sul, Programa de Pós-Graduação em Computação, Porto Alegre, 2011.
- [38] VEQUETINE, V.; NASCIMENTO, M. Z. do; BRAGA, J. C. Método para auxiliar o reconhecimento de cédulas monetárias pelos deficientes visuais. In: XIII Workshop de Informática Médica. Anais do XXXIII Congresso Nacional da Sociedade Brasileira de Computação. Maceió: [s.n.], 2013.

**APÊNDICE A - IMAGENS DE CÉDULAS E IMAGENS QUE NÃO
REPRESENTAM CÉDULAS REAL UTILIZADAS NOS TESTES**

Tabela 17: Cédula de dois reais da Segunda Família Real - lado anverso.

Nomenclatura	Anverso
Nota2f_01	
Nota2f_02	
Nota2f_03	

Tabela 18: Cédulas de dois reais da Segunda Família Real - lado reverso.




Nomenclatura	Reverso
Nota2v_01	
Nota2v_02	
Nota2v_03	

Tabela 19: Cédulas de cinco reais da Segunda Família Real - lado anverso.

Nomenclatura	Anverso
Nota5f_01	
Nota5f_01	
Nota5f_03	

Tabela 20: Cédulas de cinco reais da Segunda Família Real - lado reverso.

Nomenclatura	Reverso
Nota5v_01	 <p>The image shows the reverse side of a 5 Brazilian Real banknote. The central illustration depicts a heron standing in a marshy area with reeds, and a toucan perched on a branch to the right. The text 'BANCO CENTRAL DO BRASIL' is printed at the top. The denomination '5' is visible in the top left and top right corners. The serial number 'E B 001405128' is printed in red at the top right and bottom left. The words 'CINCO REAIS' are printed at the bottom right.</p>
Nota5v_02	 <p>The image shows the reverse side of a 5 Brazilian Real banknote. The central illustration depicts a heron standing in a marshy area with reeds, and a toucan perched on a branch to the right. The text 'BANCO CENTRAL DO BRASIL' is printed at the top. The denomination '5' is visible in the top left and top right corners. The serial number 'D H 021087109' is printed in red at the top right and bottom left. The words 'CINCO REAIS' are printed at the bottom right.</p>
Nota5v_03	 <p>The image shows the reverse side of a 5 Brazilian Real banknote. The central illustration depicts a heron standing in a marshy area with reeds, and a toucan perched on a branch to the right. The text 'BANCO CENTRAL DO BRASIL' is printed at the top. The denomination '5' is visible in the top left and top right corners. The serial number 'D F 023677976' is printed in red at the top right and bottom left. The words 'CINCO REAIS' are printed at the bottom right.</p>

Tabela 21: Cédulas de dez reais da Segunda Família Real - lado anverso.

Nomenclatura	Anverso
Nota10f_01	
Nota10f_02	
Nota10f_03	

Tabela 22: Cédulas de dez reais da Segunda Família Real - lado reverso.

Nomenclatura	Reverso
Nota10v_01	 <p>The image shows the reverse side of a 10 Real banknote. It features a large parrot on the left and a toucan on the right. The text 'BANCO CENTRAL DO BRASIL' is at the top. The denomination '10' is prominently displayed in the top left and right corners. The serial number 'G G 032874429' is printed in the top right and bottom left. The words 'DEZ REAIS' are at the bottom right.</p>
Nota10v_02	 <p>The image shows the reverse side of a 10 Real banknote. It features a large parrot on the left and a toucan on the right. The text 'BANCO CENTRAL DO BRASIL' is at the top. The denomination '10' is prominently displayed in the top left and right corners. The serial number 'B H 107169504' is printed in the top right and bottom left. The words 'DEZ REAIS' are at the bottom right.</p>
Nota10v_03	 <p>The image shows the reverse side of a 10 Real banknote. It features a large parrot on the left and a toucan on the right. The text 'BANCO CENTRAL DO BRASIL' is at the top. The denomination '10' is prominently displayed in the top left and right corners. The serial number 'F E 027998855' is printed in the top right and bottom left. The words 'DEZ REAIS' are at the bottom right.</p>

Tabela 23: Cédulas de vinte reais da Segunda Família Real - lado anverso.

Nomenclatura	Anverso
Nota20f_01	
Nota20f_02	
Nota20f_03	

Tabela 24: Cédulas de vinte reais da Segunda Família Real - lado reverso.

Nomenclatura	Reverso
Nota20v_01	
Nota20v_02	
Nota20v_03	

Tabela 25: Cédulas de cinquenta reais da Segunda Família Real - lado anverso.




Nomenclatura	Anverso
Nota50f_01	
Nota50f_02	
Nota50f_03	

Tabela 26: Cédulas de cinquenta reais da Segunda Família Real - lado reverso.

Nomenclatura	Reverso
Nota50v_01	 <p>The image shows the reverse side of a 50 Brazilian Real banknote. The left side features a jaguar resting on a log, with the text "BANCO CENTRAL DO BRASIL" and "50" in large red numbers. The right side shows a landscape with a building and a tree, with the text "50" in red and "CINQUENTA REAIS" in black. The serial number "B H 005421145" is printed in red at the top right and bottom left.</p>
Nota50v_02	 <p>The image shows the reverse side of a 50 Brazilian Real banknote. The left side features a jaguar resting on a log, with the text "BANCO CENTRAL DO BRASIL" and "50" in large red numbers. The right side shows a landscape with a building and a tree, with the text "50" in red and "CINQUENTA REAIS" in black. The serial number "C J 020107202" is printed in red at the top right and bottom left.</p>
Nota50v_03	 <p>The image shows the reverse side of a 50 Brazilian Real banknote. The left side features a jaguar resting on a log, with the text "BANCO CENTRAL DO BRASIL" and "50" in large red numbers. The right side shows a landscape with a building and a tree, with the text "50" in red and "CINQUENTA REAIS" in black. The serial number "D J 127261401" is printed in red at the top right and bottom left.</p>

Tabela 27: Cédulas de cem reais da Segunda Família Real – lado anverso.

Nomenclatura	Anverso
Nota100f_01	
Nota100f_02	
Nota100f_03	

Tabela 28: Cédulas de cem reais da Segunda Família Real – lado reverso.







Nomenclatura	Reverso
Nota100v_01	
Nota100v_02	
Nota100f_03	

Tabela 29: Imagens que não representam cédulas Real.

Nomenclatura	
Img_rand_00	
Img_rand_01	
Img_rand_02	

Img_rand_03



Img_rand_04



Img_rand_05




Img_rand_06



Img_rand_07



Img_rand_08



Img_rand_09



Img_rand_10



Img_rand_11



**APÊNDICE B – RESULTADOS OBTIDOS NOS TESTES COM MÉTODO
UTILIZADO (SURF)**

Obs*: NPIIE: Números de Pontos de interesse da imagem de entrada, NPIIR: Números de pontos de interesse da imagem referência.

Tabela 30: Resultados do método proposto: nota de dois reais – lado anverso e ambiente claro.

Anverso	Ambiente claro				
	Tempo (s)	Resultado	Matchings	NPIIE	NPIIR
Nota2f_01	2.894	2 reais	136	594	685
Nota2f_01 (180°)	2.857	2 reais	136	594	685
Nota2f_oc_01 (dobrada)	3.007	2 reais	40	229	685
Nota2f_02	2.792	2 reais	124	523	685
Nota2f_02 (180°)	2.928	2 reais	124	523	685
Nota2f_oc_02 (dobrada)	2.806	2 reais	30	187	685
Nota2f_03	2.902	2 reais	93	438	685
Nota2f_03 (180°)	3.009	2 reais	93	438	685
Nota2f_oc_03 (dobrada)	2.841	Não é cédula	-	-	-
Img_rand_00	2.821	Não é cédula	-	-	-
Img_rand_01	2.769	Não é cédula	-	-	-

Tabela 31: Resultados do método proposto: nota de dois reais – lado reverso e ambiente claro.

Reverso	Ambiente claro				
	Tempo (s)	Resultado	Matchings	NPIIE	NPIIR
Nota2v_01	3.074	2 reais	114	534	739
Nota2v_01(180°)	2.902	2 reais	114	534	739
Nota2v_oc_01 (dobrada)	2.967	2 reais	43	164	739
Nota2v_02	3.066	2 reais	69	450	739
Nota2v_02 (180°)	2.888	2 reais	69	459	739
Nota2v_oc_02 (dobrada)	2.901	2 reais	41	188	739
Nota2v_03	2.967	2 reais	64	374	739
Nota2v_03 (180°)	2.897	2 reais	65	374	739
Nota2v_oc_03 (dobrada)	2.804	2 reais	26	161	739

Tabela 32: Resultados do método proposto: nota de cinco reais – lado anverso e ambiente claro.

Anverso	Ambiente claro				
	Tempo (s)	Resultado	Matchings	NPIIE	NPIIR
Nota5f_01	2.722	5 reais	125	539	665
Nota5f_01 (180°)	2.889	5 reais	124	539	665
Nota5f_oc_01 (dobrada)	2.778	5 reais	19	147	665
Nota5f_02	2.879	5 reais	105	492	665
Nota5f_02 (180°)	2.763	5 reais	105	492	665
Nota5f_oc_02 (dobrada)	2.682	10 reais	-	-	-
Nota5f_03	2.766	5 reais	109	458	665
Nota5f_03 (180°)	2.782	5 reais	109	458	665
Nota5f_oc_03 (dobrada)	2.813	5 reais	19	105	665
Img_rand_02	2.735	Não é cédula	-	-	-
Img_rand_03	2.804	Não é cédula	-	-	-

Tabela 33: Resultados do método proposto: nota de cinco reais – lado reverso e ambiente claro.

Reverso	Ambiente Claro				
	Tempo (s)	Resultado	Matchings	NPIIE	NPIIR
Nota5v_01	2.664	5 reais	57	371	488
Nota5v_01(180°)	2.759	5 reais	57	371	488
Nota5v_oc_01 (dobrada)	2.662	5 reais	41	184	488
Nota5v_02	2.740	5 reais	52	345	488
Nota5v_02 (180°)	3.113	5 reais	52	345	488
Nota5v_oc_02 (dobrada)	2.678	5 reais	41	160	488
Nota5v_03	2.699	5 reais	50	299	488
Nota5v_03 (180°)	2.771	5 reais	50	299	488
Nota5v_oc_03 (dobrada)	2.809	5 reais	31	133	488

Tabela 34: Resultados do método proposto: nota de dez reais – lado anverso e ambiente claro.

Anverso	Ambiente Claro				
	Tempo (s)	Resultado	Matchings	NPIIE	NPIIR
Nota10f_01	2.810	10 reais	125	704	727
Nota10f_01(180°)	2.818	10 reais	124	704	727
Nota10f_oc_01 (dobrada)	2.690	10 reais	38	231	727
Nota10f_02	2.807	10 reais	116	491	727
Nota10f_02 (180°)	2.807	10 reais	116	491	727
Nota10f_oc_02 (dobrada)	2.910	10 reais	21	138	727
Nota10f_03	2.763	10 reais	94	587	727
Nota10f_03 (180°)	2.762	10 reais	95	587	727
Nota10f_oc_03 (dobrada)	2.723	10 reais	30	161	727
Img_rand_04	2.755	Não é cédula	-	-	-
Img_rand_05	2.856	Não é cédula	-	-	-

Tabela 35: Resultados do método proposto: nota de dez reais – lado reverso e ambiente claro.

Reverso	Ambiente Claro				
	Tempo (s)	Resultado	Matchings	NPIIE	NPIIR
Nota10v_01	2.813	10 reais	171	415	558
Nota10v_01 (180°)	2.737	10 reais	172	415	558
Nota10v_oc_01 (dobrada)	2.817	10 reais	87	183	558
Nota10v_02	2.719	10 reais	44	323	558
Nota10v_02 (180°)	2.744	10 reais	44	323	558
Nota10v_oc_02 (dobrada)	2.722	10 reais	23	127	558
Nota10v_03	2.699	10 reais	48	281	558
Nota10v_03 (180°)	3.027	10 reais	48	281	558
Nota10v_oc_03 (dobrada)	2.739	10 reais	30	129	558

Tabela 36: Resultados do método proposto: nota de vinte reais – lado anverso e ambiente claro.

Anverso	Ambiente Claro				
	Tempo (s)	Resultado	Matchings	NPIIE	NPIIR
Nota20f_01	2.817	20 reais	71	493	399
Nota20f_01(180°)	2.723	20 reais	71	493	399
Nota20f_oc_01 (dobrada)	2.743	Não é uma cédula	-	126	399
Nota20f_02	2.899	20 reais	47	324	399
Nota20f_02 (180°)	2.884	20 reais	47	324	399
Nota20f_oc_02 (dobrada)	2.667	Não é uma cédula	-	73	399
Nota20f_03	2.744	20 reais	90	1326	399
Nota20f_03 (180°)	2.722	20 reais	91	1326	399
Nota20f_oc_03 (dobrada)	2.699	Não é uma cédula	-	122	399
Img_rand_06	2.688	Não é uma cédula	-	-	-
Img_rand_07	2.675	Não é uma cédula	-	-	-

Tabela 37: Resultados do método proposto: nota de vinte reais – lado reverso e ambiente claro.

Reverso	Ambiente Claro				
	Tempo (s)	Resultado	Matchings	NPIIE	NPIIR
Nota20v_01	2.798	20 reais	63	601	564
Nota20v_01 (180°)	2.813	20 reais	63	601	564
Nota20v_oc_01 (dobrada)	2.766	20 reais	38	182	564
Nota20v_02	2.770	20 reais	54	343	564
Nota20v_02 (180°)	2.885	20 reais	53	343	564
Nota20v_oc_02 (dobrada)	2.701	20 reais	29	151	564
Nota20v_03	2.750	20 reais	65	363	564
Nota20v_03 (180°)	2.687	20 reais	65	363	564
Nota20v_oc_03 (dobrada)	2.773	20 reais	38	168	564

Tabela 38: Resultados do método proposto: nota de cinquenta reais – lado anverso e ambiente claro.

Anverso	Ambiente Claro				
	Tempo (s)	Resultado	Matchings	NPIIE	NPIIR
Nota50f_01	2.836	50 reais	56	360	514
Nota50f_01(180°)	2.806	50 reais	56	360	514
Nota50f_oc_01(dobrada)	2.782	Não é uma cédula	-	-	-
Nota50f_02	2.725	50 reais	68	362	514
Nota50f_02 (180°)	2.310	50 reais	68	362	514
Nota50f_oc_02 (dobrada)	2.984	Não é uma cédula	-	-	-
Nota50f_03	2.719	50 reais	70	409	514
Nota50f_03 (180°)	2.686	50 reais	70	409	514
Nota50f_oc_03 (dobrada)	2.725	Não é uma cédula	-	-	-
Img_rand_08	2.889	Não é cédula	-	-	-
Img_rand_09	2.784	Não é cédula	-	-	-

Tabela 39: Resultados do método proposto: nota de cinquenta reais – lado reverso e ambiente claro.

Reverso	Ambiente Claro				
	Tempo (s)	Resultado	Matchings	NPIIE	NPIIR
Nota50v_01	2.885	50 reais	159	804	1160
Nota50v_01(180°)	2.995	50 reais	159	804	1160
Nota50v_oc_01 (dobrada)	2.837	50 reais	50	234	1160
Nota50v_02	2.915	50 reais	165	770	1160
Nota50v_02 (180°)	2.778	50 reais	165	770	1160
Nota50v_oc_02 (dobrada)	2.817	50 reais	51	240	1160
Nota50v_03	2.922	50 reais	129	668	1160
Nota50v_03 (180°)	2.821	50 reais	129	668	1160
Nota50v_oc_03 (dobrada)	2.725	50 reais	29	166	1160

Tabela 40: Resultados do método proposto: nota de cem reais – lado anverso e ambiente claro.

Anverso	Ambiente Claro				
	Tempo (s)	Resultado	Matchings	NPIIE	NPIIR
Nota100f_01	2.986	100 reais	79	465	482
Nota100f_01 (180°)	2.860	100 reais	79	465	482
Nota100f_oc_01 (dobrada)	2.837	100 reais	28	143	482
Nota100f_02	3.062	100 reais	96	432	482
Nota100f_02 (180°)	2.862	100 reais	96	432	482
Nota100f_oc_02 (dobrada)	2.896	100 reais	33	168	482
Nota100f_03	2.801	100 reais	80	422	482
Nota100f_03 (180°)	2.701	100 reais	80	422	482
Nota100f_oc_03 (dobrada)	2.889	100 reais	29	135	482
Img_rand_010	2.885	Não é cédula	-	-	-
Img_rand_011	2.870	Não é cédula	-	-	-

Tabela 41: Resultados do método proposto: nota de cem reais – lado reverso e ambiente claro.

Reverso	Ambiente Claro				
	Tempo (s)	Resultado	Matchings	NPIIE	NPIIR
Nota100v_01	2.836	100 reais	101	529	488
Nota100v_01(180°)	2.920	100 reais	101	529	488
Nota100v_oc_01 (dobrada)	2.883	100 reais	53	209	488
Nota100v_02	2.840	100 reais	113	500	488
Nota100v_02 (180°)	2.730	100 reais	113	500	488
Nota100v_oc_02 (dobrada)	2.817	100 reais	46	195	488
Nota100v_03	2.879	100 reais	86	478	488
Nota100v_03 (180°)	2.630	100 reais	86	478	488
Nota100v_oc_03 (dobrada)	2.843	100 reais	41	200	488

Tabela 42: Resultados do método proposto: nota de dois reais – lado anverso e ambiente escuro.

Anverso	Ambiente escuro				
	Tempo (s)	Resultado	Matchings	NPIIE	NPIIR
Nota2f_01	2.528	2 reais	133	474	685
Nota2f_01(180°)	2.049	2 reais	133	474	685
Nota2f_oc_01 (dobrada)	2.777	2 reais	27	133	685
Nota2f_02	2.959	2 reais	110	360	685
Nota2f_02 (180°)	2.890	2 reais	110	360	685
Nota2f_oc_02 (dobrada)	2.628	2 reais	21	132	685
Nota2f_03	2.879	2 reais	83	438	685
Nota2f_03 (180°)	2.851	2 reais	83	438	688
Nota2f_oc_03 (dobrada)	2.686	Não é uma cédula	-	-	-
Img_rand_00	2.800	Não é uma cédula	-	-	-
Img_rand_01	2.780	Não é uma cédula	-	-	-

Tabela 43: Resultados do método proposto: nota de dois reais – lado reverso e ambiente escuro.

Reverso	Ambiente escuro				
	Tempo (s)	Resultado	Matchings	NPIIE	NPIIR
Nota2v_01	2.797	2 reais	108	352	739
Nota2v_01(180°)	2.802	2 reais	107	352	739
Nota2v_oc_01 (dobrada)	2.698	2 reais	47	134	739
Nota2v_02	2.394	2 reais	83	275	739
Nota2v_02 (180°)	2.767	2 reais	83	275	739
Nota2v_oc_02 (dobrada)	2.432	2 reais	34	114	739
Nota2v_03	2.710	2 reais	54	374	739
Nota2v_03 (180°)	2.409	2 reais	53	374	739
Nota2v_oc_03 (dobrada)	2.759	2 reais	22	161	739

Tabela 44: Resultados do método proposto: nota de cinco reais – lado anverso e ambiente escuro.

Anverso	Ambiente Claro				
	Tempo (s)	Resultado	Matchings	NPIIE	NPIIR
Nota5f_01	2.565	5 reais	124	423	665
Nota5f_01(180°)	2.772	5 reais	124	423	665
Nota5f_oc_01 (dobrada)	2.686	5 reais	21	97	665
Nota5f_02	2.647	5 reais	108	412	665
Nota5f_02 (180°)	2.442	5 reais	108	412	665
Nota5f_oc_02 (dobrada)	2.676	Não é uma cédula			
Nota5f_03	2.822	5 reais	139	405	665
Nota5f_03 (180°)	2.775	5 reais	139	405	665
Nota5f_oc_03 (dobrada)	2.855	Não é uma cédula	-	-	-
Img_rand_02	2.723	Não é uma cédula	-	-	-
Img_rand_03	2.680	Não é uma cédula	-	-	-

Tabela 45: Resultados do método proposto: nota de cinco reais – lado reverso e ambiente escuro.

Reverso	Ambiente Claro				
	Tempo (s)	Resultado	Matchings	NPIIE	NPIIR
Nota5v_01	2.729	5 reais	49	209	488
Nota5v_01(180°)	2.755	5 reais	49	209	488
Nota5v_oc_01 (dobrada)	2.677	5 reais	42	140	488
Nota5v_02	2.738	5 reais	56	200	488
Nota5v_02 (180°)	2.748	5 reais	56	200	488
Nota5v_oc_02 (dobrada)	2.640	5 reais	36	114	488
Nota5v_03	2.776	5 reais	48	173	488
Nota5v_03 (180°)	2.784	5 reais	48	173	488
Nota5v_oc_03 (dobrada)	2.728	5 reais	36	109	488

Tabela 46: Resultados do método proposto: nota de dez reais – lado anverso e ambiente escuro.

Anverso	Ambiente escuro				
	Tempo (s)	Resultado	Matchings	NPIIE	NPIIR
Nota10f_01	2.837	10 reais	131	520	727
Nota10f_01(180°)	2.737	10 reais	131	520	727
Nota10f_oc_01 (dobrada)	2.784	10 reais	27	143	727
Nota10f_02	2.873	10 reais	109	421	727
Nota10f_02 (180°)	2.777	10 reais	109	421	727
Nota10f_oc_02 (dobrada)	2.725	10 reais	25	102	727
Nota10f_03	2.814	10 reais	110	440	727
Nota10f_03 (180°)	2.802	10 reais	109	440	727
Nota10f_oc_03 (dobrada)	2.717	10 reais	21	97	727
Img_rand_04	2.690	Não é uma cédula	-	-	-
Img_rand_05	2.650	Não é uma cédula	-	-	-

Tabela 47: Resultados do método proposto: nota de dez reais – lado reverso e ambiente escuro.

Reverso	Ambiente escuro				
	Tempo (s)	Resultado	Matchings	NPIIE	NPIIR
Nota10v_01	2.745	10 reais	103	232	558
Nota10v_01(180°)	2.720	10 reais	103	232	558
Nota10v_oc_01 (dobrada)	2.729	10 reais	57	139	558
Nota10v_02	2.766	10 reais	37	178	558
Nota10v_02 (180°)	2.721	10 reais	37	178	558
Nota10v_oc_02 (dobrada)	2.771	10 reais	21	93	558
Nota10v_03	2.777	10 reais	38	187	558
Nota10v_03 (180°)	2.720	10 reais	38	187	558
Nota10v_oc_03 (dobrada)	2.852	10 reais	29	91	558

Tabela 48: Resultados do método proposto: nota de vinte reais – lado anverso e ambiente escuro.

Anverso	Ambiente escuro				
	Tempo (s)	Resultado	Matchings	NPIIE	NPIIR
Nota20f_01	2.721	20 reais	70	416	399
Nota20f_01(180°)	2.783	20 reais	70	416	399
Nota20f_oc_01 (dobrada)	2.743	Não é uma cédula	-	88	399
Nota20f_02	2.758	20 reais	39	246	399
Nota20f_02 (180°)	2.884	20 reais	39	246	399
Nota20f_oc_02 (dobrada)	2.667	Não é uma cédula	-	32	399
Nota20f_03	2.744	20 reais	84	1029	399
Nota20f_03 (180°)	2.722	20 reais	84	1029	399
Nota20f_oc_03 (dobrada)	2.874	Não é uma cédula	-	54	399
Img_rand_06	2.738	Não é uma cédula	-	-	-
Img_rand_07	2.772	Não é uma cédula	-	-	-

Tabela 49: Resultados do método proposto: nota de vinte reais – lado reverso e ambiente escuro.

Reverso	Ambiente escuro				
	Tempo (s)	Resultado	Matchings	NPIIE	NPIIR
Nota20v_01	2.784	20 reais	61	485	564
Nota20v_01(180°)	2.813	20 reais	61	485	564
Nota20v_oc_01 (dobrada)	2.700	20 reais	37	137	564
Nota20v_02	2.648	20 reais	46	247	564
Nota20v_02 (180°)	2.885	20 reais	46	247	564
Nota20v_oc_02 (dobrada)	2.668	20 reais	20	111	564
Nota20v_03	2.691	20 reais	51	271	564
Nota20v_03 (180°)	2.687	20 reais	50	271	564
Nota20v_oc_03 (dobrada)	2.640	20 reais	26	124	564

Tabela 50: Resultados do método proposto: nota de cinquenta reais – lado anverso e ambiente escuro.

Anverso	Ambiente escuro				
	Tempo (s)	Resultado	Matchings	NPIIE	NPIIR
Nota50f_01	2.790	50 reais	54	252	514
Nota50f_01(180°)	2.732	50 reais	54	252	514
Nota50f_oc_01 (dobrada)	2.834	Não é uma cédula			
Nota50f_02	2.834	50 reais	59	248	514
Nota50f_02 (180°)	2.734	50 reais	59	248	514
Nota50f_oc_02 (dobrada)	2.702	Não é uma cédula			
Nota50f_03	2.735	50 reais	61	237	514
Nota50f_03 (180°)	2.810	50 reais	61	237	514
Nota50f_oc_03 (dobrada)	2.834	Não é uma cédula	-	-	-
Img_rand_08	2.834	Não é uma cédula	-	-	-
Img_rand_09	2.934	Não é uma cédula	-	-	-

Tabela 51: Resultados do método proposto: nota de cinquenta reais – lado reverso e ambiente escuro.

Reverso	Ambiente escuro				
	Tempo (s)	Resultado	Matchings	NPIIE	NPIIR
Nota50v_01	2.746	50 reais	123	434	1160
Nota50v_01 (180°)	2.785	50 reais	123	434	1160
Nota50v_oc_01 (dobrada)	2.713	50 reais	43	141	1160
Nota50v_02	2.885	50 reais	122	438	1160
Nota50v_02 (180°)	2.742	50 reais	122	438	1160
Nota50v_oc_02 (dobrada)	2.769	50 reais	41	134	1160
Nota50v_03	2.737	50 reais	79	348	1160
Nota50v_03 (180°)	2.704	50 reais	79	348	1160
Nota50v_oc_03 (dobrada)	2.736	50 reais	31	122	1160

Tabela 52: Resultados do método proposto: nota de cem reais – lado anverso e ambiente escuro.

Anverso	Ambiente escuro				
	Tempo (s)	Resultado	Matchings	NPIIE	NPIIR
Nota100f_01	2.690	100 reais	72	349	482
Nota100f_01(180°)	2.702	100 reais	72	349	482
Nota100f_oc_01 (dobrada)	2.790	Não é uma cédula	-	-	-
Nota100f_02	2.800	100 reais	97	360	482
Nota100f_02 (180°)	2.792	100 reais	97	360	482
Nota100f_oc_02 (dobrada)	2.912	Não é uma cédula	-	-	-
Nota100f_03	2.773	100 reais	74	366	482
Nota100f_03 (180°)	2.881	100 reais	74	366	482
Nota100f_oc_03 (dobrada)	2.811	100 reais	27	80	482
Img_rand_10	2.879	Não é uma cédula	-	-	-
Img_rand_11	2.872	Não é uma cédula	-	-	-

Tabela 53: Resultados do método proposto: nota de cem reais – lado reverso e ambiente escuro.

Reverso	Ambiente escuro				
	Tempo (s)	Resultado	Matchings	NPIIE	NPIIR
Nota100v_01	2.734	100 reais	83	258	558
Nota100v_01(180°)	2.720	100 reais	83	258	558
Nota100v_oc_01 (dobrada)	2.772	100 reais	51	146	558
Nota100v_02	2.797	100 reais	73	251	558
Nota100v_02 (180°)	2.721	100 reais	72	251	558
Nota100v_oc_02 (dobrada)	2.689	100 reais	48	143	558
Nota100v_03	2.730	100 reais	85	277	558
Nota100v_03 (180°)	2.680	100 reais	85	277	558
Nota100v_oc_03 (dobrada)	2.731	100 reais	48	147	558