

Universidade Federal do Piauí
Centro de Ciências da Natureza
Programa de Pós-Graduação em Ciência da Computação

Reconhecimento de Cédulas Monetárias Falsas para Auxiliar Pessoas com Deficiência Visual

Kenad Wanderson Araújo Silva

Teresina-PI, 22 de Março de 2024

Kenad Wanderson Araújo Silva

Reconhecimento de Cédulas Monetárias Falsas para Auxiliar Pessoas com Deficiência Visual

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Ciência da Computação da UFPI (área de concentração: Visão Computacional), como parte dos requisitos necessários para a obtenção do Título de Mestre em Ciência da Computação.

Universidade Federal do Piauí – UFPI

Centro de Ciências da Natureza

Programa de Pós-Graduação em Ciência da Computação

Orientador: Laurindo de Sousa Britto Neto

Coorientador: Kelson Romulo Teixeira Aires

Teresina-PI

22 de Março de 2024

Kenad Wanderson Araújo Silva

Reconhecimento de Cédulas Monetárias Falsas para Auxiliar Pessoas com Deficiência Visual/ Kenad Wanderson Araújo Silva. – Teresina-PI, 22 de Março de 2024-

61 p. : il. (algumas color.) ; 30 cm.

Orientador: Laurindo de Sousa Britto Neto

Coorientador: Kelson Romulo Teixeira Aires

Dissertação (Mestrado) – Universidade Federal do Piauí – UFPI
Centro de Ciências da Natureza
Programa de Pós-Graduação em Ciência da Computação, 22 de Março de 2024.

1. Reconhecimento de cédulas bancárias falsas. 2. Pessoas com deficiência visual. 2. Visão Computacional. I. Laurindo de Sousa Britto Neto. II. Kelson Romulo Teixeira Aires. II. Universidade Federal do Piauí – UFPI
Centro de Ciências da Natureza
Programa de Pós-Graduação em Ciência da Computação. III. Programa de Pós-Graduação em Ciência da Computação. IV. Reconhecimento de Cédulas Monetárias Falsas para Auxiliar Pessoas com Deficiência Visual

CDU 02:141:005.7

Kenad Wanderson Araújo Silva

Reconhecimento de Cédulas Monetárias Falsas para Auxiliar Pessoas com Deficiência Visual

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Ciência da Computação da UFPI (área de concentração: Visão Computacional), como parte dos requisitos necessários para a obtenção do Título de Mestre em Ciência da Computação.

Trabalho aprovado. Teresina-PI, 22 de Março de 2024:

Laurindo de Sousa Britto Neto
Orientador

Kelson Romulo Teixeira Aires
Coorientador

Felipe Leonel Grijalva Arevalo
Professor Convidado

Rodrigo de Melo Souza Veras
Professor Convidado

Vinícius Ponte Machado
Professor Convidado

Teresina-PI
22 de Março de 2024

Aos meus pais Ana Cândida Sobral Araújo, Lindomar Silva e Maria das Graças de Sousa, por sempre estarem comigo em todos os momentos.

Agradecimentos

Agradeço a Deus.

Agradeço aos meus pais, Ana Cândida Sobral Araújo e Lindomar Silva, por terem incentivado e apoiado a busca pelo conhecimento e terem cultivado em mim a criativadade.

Agradeço a minha mãe e avó, Maria das Graças de Sousa, que mesmo não sendo alfabetizada, me ensinou que o conhecimento é a maior arma do ser humano.

Agradeço ao meu orientador, Laurindo de Sousa Britto Neto, por todos os conselhos, pela paciência e ajuda nesse período.

Agradeço também ao meu coorientador, Kelson Romulo Teixeira Aires, por todos os conselhos, pela paciência e ajuda nesse período.

"O importante é não parar de questionar."
(Albert Einstein)

Resumo

O crime de falsificação de moeda é muito comum no Brasil e no mundo, sendo responsável pelo volume de quase 28,78 milhões de reais falsificados em 2022. Essa modalidade de crime, prevista no código penal, afeta, além da população em geral, os indivíduos com deficiência visual. De acordo com a Organização Mundial de Saúde, em 2022, a população com deficiência visual representa cerca de 2,2 bilhões de pessoas no mundo. Esses indivíduos podem se achar desamparadas, uma vez que as limitações acometidas pela deficiência visual dificultam a identificação dos elementos de segurança contidas em uma cédula monetária verdadeira. Por essa razão, as Tecnologias Assistivas, que são produtos ou equipamentos que visam auxiliar as pessoas com deficiência em suas tarefas diárias, relacionada ao reconhecimento de cédula falsa deveria ser desenvolvida, a fim de auxiliar essas pessoas no seu cotidiano. Em vista disso, o objetivo deste trabalho é desenvolver uma abordagem baseadas em visão computacional para o reconhecimento de cédulas monetárias falsas, com resultados superiores ou equiparados a outras abordagens do estado da arte. Para isso, foi necessário o desenvolvimento de um conjunto de dados de imagens de cédulas brasileiras (cédulas de Real). Ao criar o conjunto de dados, vários desafios foram identificados, as imagens de teste produzidas simulando o mundo real aparecem dobradas, com oclusões parciais em virtude do dedo do fotógrafo que cobre boa parte da cédula. O fundo das imagens são repletos de informações desnecessárias, variação de iluminação, entre outros. Mesmo assim, para esse novo conjunto de dados, foram obtidos resultados que alcançaram 97,1% de acurácia, 100% de precisão, 100% de especificidade, 94,52% de *recall* e 97,18% de *F1-score*, por meio de uma abordagem holística que utiliza para extração de características CNN/RESNET50 e classifica com SVM.

Palavras-chaves: Reconhecimento de cédulas monetárias falsas. Pessoas com deficiência visual. Visão computacional.

Abstract

The crime of counterfeiting currency is very common in Brazil and around the world, being responsible for the volume of almost 28.78 million reais counterfeited in 2022. This type of crime, provided for in the criminal code, affects, in addition to the general population, individuals with visual impairment. According to the World Health Organization, in 2022, the visually impaired population represents around 2.2 billion people in the world. These individuals may feel helpless, since the limitations caused by visual impairment make it difficult to identify the security elements contained in a real monetary note. For this reason, Assistive Technologies, which are products or equipment that aim to assist people with disabilities in their daily tasks, related to fake banknote recognition should be developed in order to assist these people in their daily lives. In view of this, the objective of this work is to develop an approach based on computer vision for recognizing fake currency notes, with results superior to or equivalent to other state-of-the-art approaches. To achieve this, it was necessary to develop a dataset of images of Brazilian banknotes (Real banknotes). When creating the dataset, several challenges were identified, the test images produced simulating the real world appear folded, with partial occlusions due to the photographer's finger covering a large part of the banknote. The background of the images is full of unnecessary information, lighting variations, among others. Even so, for this new data set, results were obtained that reached 97.1% accuracy, 100% precision, 100% specificity, 94.52% *recall* and 97.18 % of *F1-score*, through a holistic approach that uses CNN/RESNET50 to extract features and classify with SVM.

Keywords: Recognition of counterfeit currency notes. Visually impaired people. Computer vision.

Lista de ilustrações

Figura 1 – Artigos identificados por base bibliográfica. 7
Figura 2 – Artigos rejeitados e aceitos no processo de triagem. 8
Figura 3 – Artigos rejeitados e aceitos no processo de extração. 9
Figura 4 – Interesse por ano de publicação dos trabalhos. 18
Figura 5 – Quantidade de trabalhos por origem da moeda utilizada. 19
Figura 6 – Exemplos de imagem extraídas do conjunto de dados DITB: (a) Imagem de uma cédula de 500 rúpias e (b) Imagem de uma cédula de 50 baht (MESHRAM et al., 2020). 24
Figura 7 – Exemplos de imagem extraídas do conjunto de dados BankNote-Net: (a) Imagem de uma cédula de 20 coroas suecas e (b) Imagem de uma cédula de 100 coroas suecas (OVIEDO et al., 2022). 24
Figura 8 – Exemplos de imagem extraídas do conjunto de dados BankNote-Br: (a) Imagem frontal de uma cédula genuína de 2 reais e (b) Imagem posterior de uma cédula genuína de 2 reais. 25
Figura 9 – Exemplos de imagem extraídas do conjunto de dados BankNote-Br: (a) Imagem frontal de uma cédula falsa de 2 reais e (b) Imagem posterior de uma cédula falsa de 2 reais. 26
Figura 10 – Exemplos de imagem extraídas do conjunto de dados BankNote-Br: (a) e (b) Imagens de uma cédula genuína de 2 reais, (c) e (d) Imagens de uma cédula genuína de 5 reais, (e) e (f) Imagens de uma cédula genuína de 10 reais. 27
Figura 11 – Exemplos de imagem extraídas do conjunto de dados BankNote-Br: (a) e (b) Imagens de uma cédula falsa de 2 reais, (c) e (d) Imagens de uma cédula falsa de 5 reais, (e) e (f) Imagens de uma cédula falsa de 10 reais. 28
Figura 12 – Elementos comuns a todas as denominações da Segunda Família do Real(BCB, 2013). 29
Figura 13 – Etapas utilizadas na abordagem proposta. Em verde, a abordagem com melhor resultado. 39
Figura 14 – Exemplos de detecção da região de interesse em uma imagem: (a) Imagem de uma cédula falsa de 100 reais como fotografada e (b) Imagem de uma cédula falsa de 100 reais com após o procedimento de detecção. 39

Figura 15 – Exemplos de detecção da região de interesse em uma imagem: (a) Imagem de uma cédula falsa de 50 reais antes do aumento de dados, (b) Imagem gerada pelo aumento de dados de uma cédula falsa de 50 reais com rotação da imagem aleatório entre 22° e -22°, (c) Imagem gerada pelo aumento de dados de uma cédula falsa de 50 reais com escala de até 20%, (d) Imagem gerada pelo aumento de dados de uma cédula falsa de 50 reais com deslocamento até 25% do comprimento, (e) Imagem gerada pelo aumento de dados de uma cédula falsa de 50 reais com deslocamento em até 25% da altura e (f) Imagem gerada pelo aumento de dados de uma cédula falsa de 50 reais com deslocamento até 25% do comprimento e desfoque utilizando um sigma entre 0 e 3. . 41

Lista de tabelas

Tabela 1 – Bases Bibliográficas e *Strings* de busca. 7
Tabela 2 – Resultados iniciais da busca. 7
Tabela 3 – Resultados divididos pela principal abordagem de extração de características utilizada. 10
Tabela 4 – Resultados divididos pela principal abordagem de classificação utilizada. 18
Tabela 5 – Resumo da Revisão Sistemática. 21
Tabela 6 – Sumarização dos conjuntos de dados encontrados durante a revisão. . . 22
Tabela 7 – Características de segurança em cada denominação. 30
Tabela 8 – Parâmetros utilizados em cada ferramenta de extração de características. 42
Tabela 9 – Parâmetros utilizados em cada ferramenta de classificação de características. 43
Tabela 10 – Resultados da Experimento com descritores CNN/VGG16. 44
Tabela 11 – Resultados do Experimento com descritores CNN/RESNET50. 45
Tabela 12 – Resultados do Experimento com descritores DWT. 45
Tabela 13 – Resultados do Experimento com descritores SIFT. 46

Lista de abreviaturas e siglas

ANFIS	Adaptative Neural Fuzzy Inference System
BCB	Banco Central do Brasil
CNN	Convolutional Neural Networks
DWT	Discrete Wavelet Transformation
FDA	Fischer's Discriminant Analyses
FHD	Fuzzy Hamming Distance
GBC	Gradient Boosting Classifier
HOG	Histograms of Oriented Gradient
HRF	Human-readable features
HSI	HyperSpectral Image
IA	Inteligência Artificial
ILSVRC	ImageNet Large Scale Visual Recognition Competition
IoT	Internet of Things
KNN	K–Neartest Neighbors
LBI	Lei Brasileira de Inclusão
LDA	Linear Discrimant Analysis
MSE	Matched Score Fusion
NN	Neural Network
OCR	Optical Character Recognition
OMS	Organização Mundial da Saúde
PCA	Principal Component Analysis
PRISMA	Preferred Reporting Items for Systematic reviews and Meta-Analyses
ResNet	Residual Network

SIFT	Scale-Invariant Feature Transform
StArt	State of the Art through Systematic Review
SVM	Support Vector Machine
TA	Tecnologia Assistiva
TOV	Tinta Opticamente Variável

Sumário

1 INTRODUÇÃO 1
1.1 Objetivo 3
1.1.1 Objetivos Específicos 3
1.2 Organização do Trabalho 4

2 REVISÃO DA LITERATURA 5
2.1 Metodologia da Revisão da Literatura 5
2.1.1 Definição das questões de pesquisa 5
2.1.2 Definição da palavra-chave 6
2.1.3 Processo de busca 6
2.1.4 Triagem de artigos 8
2.1.5 Processo de seleção dos estudos 8
2.1.6 Extração dos dados e sumarização 9
2.2 Resultados da Revisão da Literatura 9
2.2.1 Abordagens Holísticas 10
2.2.2 Características Morfológicas 13
2.2.3 Características de Segurança 14
2.2.4 Híbridas 17
2.3 Análise dos Resultados da Revisão de Literatura 17

3 MATERIAIS E MÉTODOS 22
3.1 Conjunto de Dados 22
3.1.1 Banknote Authentication Dataset (BAD) 23
3.1.2 Dataset of Indian And Thai Banknotes (DITB) 23
3.1.3 Open Dataset for Assistive Currency Recognition (BankNote-Net) 23
3.1.4 Open Dataset for Recognition of Brazilian Counterfeit Banknotes (BankNote - Br) 25
3.2 Características das Cédulas de Real 26
3.3 Métodos Utilizados para Extração de Características 29
3.3.1 Convolutional Neural Networks (CNN) 30
3.3.2 Discrete Wavelet Transform (DWT) 32
3.3.3 Scale Invariant Feature Transform (SIFT) 32
3.4 Métodos Utilizados para Classificação 33
3.4.1 K–Nearest Neighbors 33
3.4.2 Naive Bayes 34
3.4.3 Support Vector Machine (SVM) 34

3.4.4 Random Forest 35
3.5 Métricas de Avaliação 35

4 ABORDAGEM PROPOSTA 38
4.1 Visão geral dos experimentos realizados 38
4.1.1 Pré-Processamento 38
4.1.2 Aumento de dados 40
4.1.3 Extração de características 40
4.1.4 Classificação de características 42

5 RESULTADOS E DISCUSSÃO 44

6 CONCLUSÕES E TRABALHOS FUTUROS 48

REFERÊNCIAS 50

1 Introdução

A falsificação de dinheiro é um crime rotineiro em muitos países e no Brasil não seria diferente. A fim de disciplinar a prática desse crime, o Código Penal brasileiro definiu, por meio do Decreto Lei n°2848/1940[1], no Artigo 289, o crime de fabricação ou adulteração de cédulas falsas, atribuindo pena máxima de 12 anos e multa. Ainda assim, em 2022, o Banco Central do Brasil (BCB) divulgou por meio de seus dados abertos[2], que foram falsificadas 353.396,00 cédulas monetárias de Real, equivalente a aproximadamente 28,78 milhões de reais. Por fim, recentemente, em 2023, a Policia Federal Brasileira, em parceria com os Correios, realizou a prisão em flagrante de um indivíduo, ao receber envelopes com cédulas falsas (POLÍCIA FEDERAL, 2023).

Esse imenso volume de dinheiro falsificado causa transtornos à população em geral, que, em uma grande parte das vezes, não consegue identificar se o dinheiro é autêntico ou não, devido a profissionalização da confeccção de falsificação pelo crime organizado (COSTA et al., 2011). Dito isso, diversos países enfrentam problemas com a falsificação de suas moedas, levando a Índia, em 2016, a recolher parte de seus exemplares de cédulas, em virtude da falsificação em massa (SINGH, 2017).

Além disso, pessoas com deficiência, em especial pessoas com deficiência visual, são constantemente alvos de golpe por falsificação de cédulas, visto que suas limitações podem dificultar a identificação dos elementos de segurança da moeda (MOMBACH, 2015). Entretanto, até mesmo pessoas sem qualquer deficiência podem se achar excluídos das tecnologias oferecidas pela rede bancária para identificar se suas cédulas são válidas. Afinal, ainda em 2017, apenas 86,5% da população brasileira mantinha algum relacionamento bancário (BCB, 2018).

A Organização Mundial de Saúde (World Health Organization – WHO) estima que no mundo existem 2,2 bilhões de pessoas com deficiência visual, sendo que em um bilhão desses casos a deficiência visual poderia ter sido evitada ou ainda precisa ser tratada (OMS, 2022). Dentro desse um bilhão de casos, estima-se que existem 88,4 milhões de pessoas com cegueira ou com deficiência visual moderada ou grave à distância, devido a erro refrativo não endereçado; 94 milhões com catarata; 8 milhões com degeneração macular relacionada à idade; 7,7 milhões com glaucoma, 3,9 milhões com retinopatia diabética; 826 milhões com deficiência visual de perto causada por presbiopia não tratada (OMS, 2022). Os 1,2 bilhões de casos restantes não possuem tratamento. Esse volume de pessoas com deficiência levou a criação da Lei Brasileira de Inclusão (LBI) que define mecanismos para mitigar as

[1] https://www.planalto.gov.br/ccivil_03/decreto-lei/del2848.htm Acesso em: 02 Jan. 2023
[2] https://www.bcb.gov.br/adm/mecir/dadosabertos/Falsificacao_DadosAbertos.csv Acesso em: 02 Jan. 2023

limitações enfrentadas pelas pessoas com deficiência. Mecanismos esses, frequentemente denominadas como Tecnologias Assistivas (TA) (BRUNO; NASCIMENTO, 2019).

As TA's são ferramentas definidas como produtos ou equipamentos que visam auxiliar as pessoas com deficiência em suas tarefas diárias (OLIVEIRA, 2022). Para as pessoas com deficiência visual, especificamente, TA's equipadas com câmeras podem se utilizar de abordagens em visão computacional para retornar a informação necessária ao usuário para a realização de uma tarefa do cotidiano. Isso é realizado por meio de *feedbacks* táteis ou auditivos, de forma que ele consiga realizar tal tarefa de forma independente. A literatura científica cita várias abordagens propostas que auxiliam pessoas com deficiência visual em diversas tarefas do cotidiano, tais como: detectar e reconhecer obstáculos para navegação em ambientes internos e externos (VALVO et al., 2021), traduzir informações textuais (e.g., texto (VAIDYA; VAIDYA; BHOSALE, 2020), braille (OVODOV, 2021), placas e sinais (KUNENE; VADAPALLI; CRONJE, 2016) etc.), reconhecer gestos (ALASHHAB; GALLEGO; LOZANO, 2022); reconhecer e localizar pessoas (BRITTO NETO et al., 2015; BRITTO NETO et al., 2016; FERREIRA NETO et al., 2021), reconhecer expressões faciais para auxiliá-las na comunicação não verbal (SILVA et al., 2021), reconhecer diversos tipos objetos (e.g., produtos de mercearia (MACHADO et al., 2021a; MACHADO et al., 2021b); jogos analógicos, como xadrez (CZYZEWSKI; LASKOWSKI; WASIK, 2020), baralho (TANAKA; FUJINAMI, 2017); reconhecer comprimidos, drágeas e capsulas (Dias Júnior, 2022) para evitar a ingestão errada de medicamentos; além da identificação de cédulas monetárias (SOUSA et al., 2018; SOUSA et al., 2023)), dentre outras. Entretanto, o foco deste trabalho é auxiliar pessoas com deficiência visual na tarefa de reconhecer quando uma cédula monetária é falsa ou verdadeira.

O Banco Central do Brasil, na tentativa de incorporar uma TA que não dependesse de tecnologias auxiliares, criou a Segunda Família do Real (BCB, 2013) com tamanhos diferentes, baseado na habilidade tátil das pessoas com deficiência visual (TORRES; COSTA; LOURENÇO, 2016), seguindo a tendência de outras cédulas como o Euro. Porém, essa abordagem se mostrou ineficiente para auxiliar no reconhecimento de cédulas falsas (BARBOSA; SILVA, 2021).

Apesar da TA incorporada nas cédulas de reais e com o aumento do uso de soluções de dispositivos de captura de imagem e processamento (BUENO; LUCENA, 2016), se tornou possível o emprego de soluções de visão computacional e outras abordagens com o objetivo de identificar cédulas falsas de forma acessível (SAUSEN; FROZZA, 2022). Um exemplo notável são as abordagens baseadas em Aprendizagem Profunda (*Deep Learning*) (MATSUO et al., 2022) que possuem como fundamento extrair informação relevante de uma massa de dados, gerando modelos úteis para classificação ou agrupamento.

Por fim, para atender as necessidades das pessoas com deficiência visual é necessário incorporar a abordagem em Visão Computacional a um dispositivo *wearable* (PARK;

JAYARAMAN, 2021), ou seja, um dispositivo vestível ou um equipamento que o usuário possa carregar junto ao corpo, como uma peça de roupa. Um exemplo de dispositivo já existente e ao alcance de uma grande parte da população é o *smartphone* (SAUSEN; FROZZA, 2022), que, por meio de seus sistemas embarcados, dispensam o uso de equipamentos especialmente projetados para este fim (PRET, 2014) (e.g., o smartphone pode ser carregado junto ao corpo, em um bolso na camisa, com sua câmera filmando o ambiente à frente do usuário). O sistema *wearable* descrito poderá ser utilizado como uma tecnologia assistiva por um usuário com deficiência visual. Tal sistema usará uma arquitetura cliente-servidor, em que o dispositivo *wearable* funcionará como o cliente e o servidor estará disponível na nuvem. Dessa forma, o processamento mais custoso computacionalmente será totalmente realizado no servidor, economizando os recursos de hardware do dispositivo cliente como bateria, memória e processamento. Além disso, a abordagem proposta poderá ser incorporada também a dispositivos da internet das coisas (*Internet of Things – IoT*) (MARWEDEL, 2021), pois são dispositivos que proporcionam o gerenciamento de dados na *web* em diversos tipos de aparelhos como câmeras, *smart TV*, *smartbands* e *smartwatch*.

1.1 Objetivo

O objetivo deste trabalho é propor uma abordagem em visão computacional para o reconhecimento de cédulas monetárias falsas, com resultados superiores ou equiparados ao estado da arte. Para atingir esse objetivo, foram traçados objetivos específicos a seguir.

1.1.1 Objetivos Específicos

Os objetivos específicos deste trabalho são:

1. Levantamento do estado da arte, bem como a identificação de trabalhos relevantes que se aproximam das questões de pesquisa e do estado da arte em reconhecimento de cédulas monetárias falsas utilizando visão computacional;
2. Construir um conjunto de dados de cédulas monetárias da segunda família do Real;
3. Identificar e utilizar conjuntos de dados disponíveis publicamente de cédulas monetárias de outros países;
4. Desenvolver e implementar novas abordagens para o reconhecimento de cédulas monetárias falsas;
5. Realizar experimentos para validação e avaliação das abordagens propostas, por meio de métricas de avaliação, comparando-as entre si e com outras abordagens do estado da arte, a fim de definir qual das abordagens é melhor avaliada para resolver o problema do reconhecimento de cédulas monetárias falsas.

1.2 Organização do Trabalho

A fim de organizar o trabalho para atender a esses objetivos, essa dissertação foi dividida da seguinte forma: o primeiro capítulo contém a introdução, a fim de indicar os motivadores e contextualizar o tema deste trabalho, o Capítulo 2 apresenta a revisão de literatura, responsável pelo levantamento dos trabalhos correlatos ao tema e organizados de forma a identificar o atual estado da arte. O Capítulo 3 expõe os materiais e métodos utilizados no trabalho, o desenvolvimento de um conjunto de dados próprio, e a descrição de outros conjuntos de dados e ferramentas utilizadas. O Capítulo 4 descreve a abordagem proposta, cujos resultados preliminares são detalhados e discutidos no Capítulo 5. Por fim, o Capítulo 6 concluí este trabalho e relata os trabalhos.

2 Revisão da Literatura

O sistema monetário sempre foi alvo de fraudes e engodos. Utilizado até como arma de guerra, a falsificação de cédulas monetárias nacionais e estrangeiras representam um volume de perdas enormes para o sistema financeiro e impactam a vida de milhares de pessoas diariamente. Frequentemente, novos mecanismos para detectar falsificação são implementados utilizando diversas abordagens, como visão computacional e aprendizagem de máquinas, a fim de classificar e segregar as cédulas legítimas das cédulas adulteradas.

Para a Revisão da Literatura desta pesquisa, buscou-se trabalhos que procuravam identificar notas adulteradas, com enfase em métodos de Visão Computacional. Na Seção 2.1 foi apresentada a metodologia utilizada nesta revisão , na Seção 2.2 foram apresentados os resultados e na Seção 2.3 foi realizada uma discussão sobre tais resultados.

2.1 Metodologia da Revisão da Literatura

No desenvolvimento desta revisão de literatura foi utilizado a ferramenta *State of the Art through Systematic Review* (StArt) (SILVA et al., 2010) para organizar os dados necessários para uma revisão sistemica baseada nas diretrizes de Kitchenham e Charters (KITCHENHAM; CHARTERS, 2007) e na metodologia *Preferred Reporting Items for Systematic Reviews and Meta-Analyses* (PRISMA) (MOHER, 2009), sendo assim, a metodologia foi dividida em cinco etapas:

1. **Planejamento:** Definição das questões de pesquisa e das palavras de busca com base na temática do trabalho, além da definição dos critérios de seleção;
2. **Execução:** Execução da busca em si, utilizando as bibliotecas digitais (bases bibliográficas);
3. **Seleção:** Seleção dos artigos úteis à pesquisa, lendo as partes principais do trabalho e utilizando os critérios de inclusão e exclusão;
4. **Extração:** É lido o trabalho completo, e aplicado novamente o critério de inclusão e exclusão, para reafirmar a relevância para as questões de pesquisa;
5. **Sumarização:** Catalogação e tabulação dos resultados encontrados.

2.1.1 Definição das questões de pesquisa

Durante a revisão da literatura, procurou-se responder a seguinte questão principal da pesquisa: *"Quais abordagens em Visão Computação são utilizadas para reconhecimento*

de dinheiro falso?". Com base na questão de pesquisa inicial, foram elaboradas outras perguntas, que foram aplicadas a cada um dos artigos selecionados na etapa posterior.

1. Qual a abordagem proposta?
2. Quais experimentos foram realizados?
    a) Quais conjuntos de dados foram utilizadas?
    b) Qual pré-processamento foi realizado no conjunto de dados?
    c) Como o conjunto de dados foi dividido?
    d) Quais metodologias e métricas de comparação foram utilizadas?
    e) Quais abordagens foram comparadas?
3. Quais as abordagens com melhores resultados?

Com base nas questões de pesquisas, intencionou-se identificar os trabalhos com melhores resultados, suas vantagens, desvantagens e o conjunto de dados utilizados. Fornecendo um ponto de partida para pesquisadores iniciantes, fundamentando novas abordagens a fim de identificar e classificar cédulas monetárias adulteradas, que possibilite taxas de acurácias relevantes e um baixo custo de implementação, facilitando o acesso à solução. Mesmo almejando, em especial, o conjunto de dados e as abordagens utilizados, procurou-se analisar os resultados alcançados, esperando evidenciar os mais relevantes.

2.1.2 Definição da palavra-chave

A busca foi realizada utilizando *"Counterfeit banknotes detection"*, *"fake banknotes"* e *"fake currency"* a fim de apurar os resultados nos indexadores de pesquisa, selecionando aqueles acessíveis por meio de bases bibliográficas que produziam bons resultados. As bases bibliográficas IEEE[1] , ACM[2] e *ScienceDirect*[3] foram selecionadas pelo volume de seus acervos e relevância no campo de Ciência da Computação. Ao final, os resultados foram importados na ferramentas StArt, que auxiliou no trabalho de identificar artigos científicos duplicados, facilitando o processo de triagem.

2.1.3 Processo de busca

O processo de busca foi refinado de forma a eliminar aqueles que não se encaixavam ao tema proposto, considerando principalmente a aplicabilidade de abordagens de Visão Computacional ao reconhecimento de cédulas falsas. Devido a singularidade do tema,

[1] https://ieeexplore.ieee.org/ Acesso em: 30 Ago. 2022
[2] https://dl.acm.org/search/advanced Acesso em: 30 Ago. 2022
[3] https://www.sciencedirect.com/ Acesso em: 26 Set. 2022

a busca incluiu cédulas estrangeiras e nacionais. Para isso, as buscas foram feitas em inglês, destando-se termos como *"banknotes"* e *"detection"* que significam, respectivamente, *"cédulas bancárias"* e *"detecção"*, conforme demonstrado na Tabela 1:

Tabela 1 – Bases Bibliográficas e *Strings* de busca.

Base bibliográfica	*String de Busca*
IEEE	("All Metadata":"Counterfeit banknotes") OR ("All Metadata":"fake banknotes") OR ("All Metadata":"fake currency")
ACM	[All: "counterfeit banknotes detection"] OR [All: "fake banknotes"] OR [All: "fake currency"]
ScienceDirect	"counterfeit banknotes"OR "fake banknotes"OR "fake currency"

A última busca foi realizada em Setembro de 2022. Dessa forma um número maior de resultados pode ser coletado caso uma nova busca seja feita, já que as bases estão constantemente incrementando seus acervos. A Figura 1 e a Tabela 2 mostram a contribuição de cada base nos resultados de busca. A Tabela 2 possui três colunas, a primeira corresponde à "Base bibliográfica", a segunda coluna, intitulada "Quantidade", corresponde à quantidade de resultados absoluta das bases e a coluna "Percentual" é o percentual dos resultados de busca.

Tabela 2 – Resultados iniciais da busca.

Base Bibliográfica	Quantidade	Percentual(%)
IEEE	33	41,3
ACM	19	23,8
ScienceDirect	28	35,0

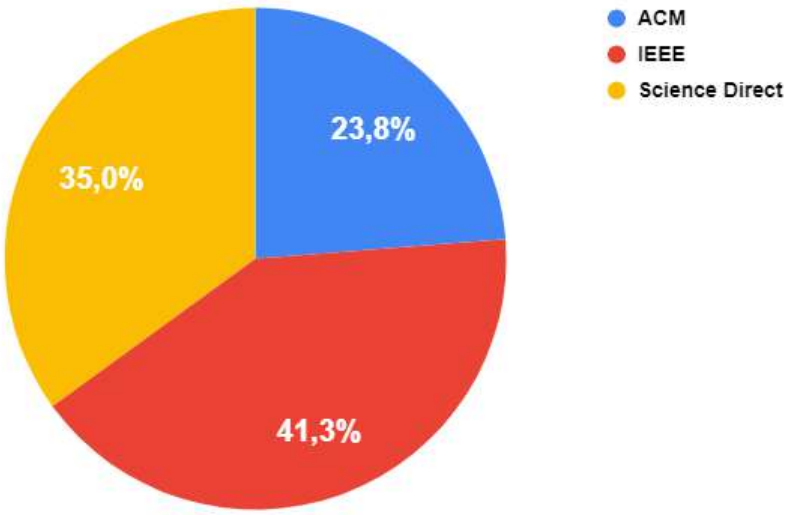


Figura 1 – Artigos identificados por base bibliográfica.

2.1.4 Triagem de artigos

Os critérios de seleção, ou seja, inclusão e seleção, para a etapa de triagem de artigos foram definidos em conformidade com as questões de pesquisa.

Critérios de inclusão

1. Ter acesso por meio público ou institucional ao artigo completo;
2. Tratar de reconhecimento ou classificação de cédulas monetárias falsas.

Critérios de exclusão

1. Não ter acesso ao artigo completo;
2. Tratar apenas de detecção de cédulas monetárias ou do reconhecimento das denominações da cédula;
3. Não ter uma abordagem em visão computacional.

2.1.5 Processo de seleção dos estudos

O processo de seleção ocorreu por meio de uma leitura do título e do resumo de cada artigo encontrado, de modo a identificar a adequação ao critérios de seleção e triagem.

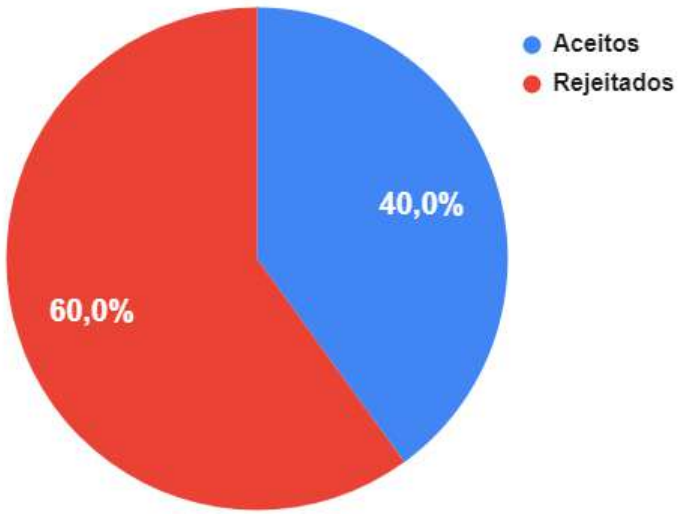


Figura 2 – Artigos rejeitados e aceitos no processo de triagem.

Conforme a Figura 2, na etapa de triagem, 32 resultados (40%) foram aceitos e 48 resultados (60%) foram rejeitados, sendo que entre os 32 resultados, apenas 25 resultados (78,1%) foram aceitos segundo os critérios de inclusão e exclusão. Não foram identificados resultados duplicados.

2.1.6 Extração dos dados e sumarização

Durante a etapa de extração, continuou-se a aplicar os critérios de inclusão e exclusão. Adicionalmente, foi inspecionado as referências de cada trabalho em busca de trabalhos adicionais que pudessem ser relevantes ao projeto.

Após a leitura completa, a base da IEEE resultou em 21 estudos aceitos. A base ACM teve apenas um resultado aceito. A base ScienceDirect da Elsevier resultou em três artigos. Com isso, um total de 25 artigos foram aceitos, ocorrendo em todos os critérios de inclusão e nenhum de exclusão, conforme demonstrado pela Figura 3, com 78,1% dos artigos foram aceitos.

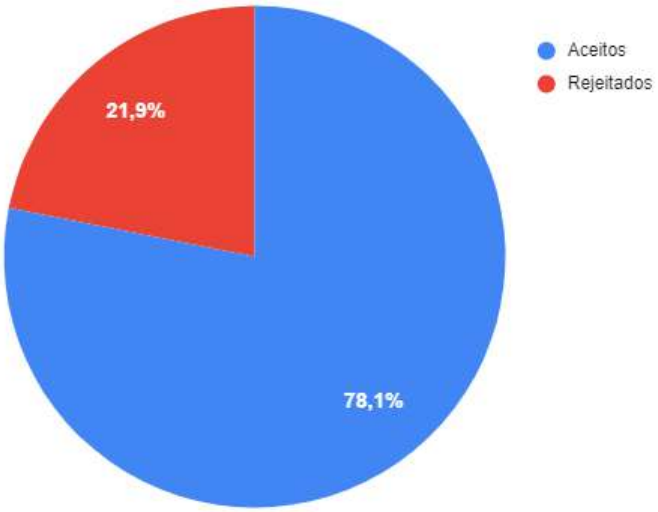


Figura 3 – Artigos rejeitados e aceitos no processo de extração.

2.2 Resultados da Revisão da Literatura

Dentre os artigos aceitos por esta revisão foi selecionada e analisada, primeiramente, uma outra revisão de literatura, escrita por Viraktamath et al. (VIRAKTAMATH et al., 2021), sobre o uso de técnicas de Processamento Digital de Imagens (PDI) para o reconhecimento de cédulas bancárias falsas. Apesar da revisão selecionada ser recente e ter a temática no contexto desta revisão, os autores não realizaram uma revisão sistemática. Além disso, os autores citaram 15 trabalhos que não foram listados nas buscas realizadas nas bibliotecas digitais utilizadas por esta revisão. Por isso, os artigos citados na revisão anterior não foram selecionados como resultados válidos desta revisão. O que justifica a realização desta revisão sistemática de literatura. Apesar disso, é importante ressaltar que esta revisão é complementar a revisão realizada por Viraktamath et al. (VIRAKTAMATH et al., 2021).

Observando os algoritmos de extração de características, percebeu-se que os autores mostravam preferência por quatro estratégias: abordagens holísticas, abordagens baseadas

em características morfológicas, abordagens baseadas em características de segurança e abordagens híbridas. Foram consideradas como abordagens holísticas, todos aqueles que usaram toda a imagem da cédula como entrada (*Discrete Wavelet Transformation* - DWT e *Convolutional Neural Network* - CNN, por exemplo). Foram consideradas como abordagens baseadas em características morfológicas, todos que utilizavam características específicas não direcionadas à prevenção de falsificação (altura e largura, por exemplo). Por outro lado, consideram-se abordagens baseadas em características de segurança, abordagens que usaram características relacionadas ou intencionadas à prevenção de falsificação (marcas d'água e autorrelevo, por exemplo). As abordagens híbridas foram aquelas que mesclaram mais de uma das três abordagens anteriores (usando tanto as características morfológicas como as de segurança, por exemplo). Na Tabela 3, é evidenciado essas preferências, observando que pouquissímos trabalhos se mostraram interessados em mesclar essas características. Os trabalhos restantes foram organizados cronologicamente e de acordo com sua principal abordagem.

Tabela 3 – Resultados divididos pela principal abordagem de extração de características utilizada.

Abordagem Principal	Qtd.Trabalhos
Abordagens Holísticas	13
Características Morfológicas	3
Características de Segurança	7
Híbridas	1

2.2.1 Abordagens Holísticas

Chang, Yu e Yen (CHANG; YU; YEN, 2007) utilizaram *Support Vector Machine* (SVM) (CORTES; VAPNIK, 1995) e *Neural Networks* (NN) (TAKEDA; OMATU, 1995) nos dados resultantes da extração de características de cédulas do Novo Dólar de Taiwan usando o método *Discrete Wavelet Transformation* (DWT) (RAO, 1998). Apesar de ter obtido uma acurácia máxima de 99,01%, utilizando um kernel linear em algoritmo SVM, o conjunto de dados não foi disponibilizado de forma pública.

O artigo de Çelik e Kondiloğlu (ÇELIK; KONDILOğLU, 2015) fez um estudo comparativo entre SVM e NN. O trabalho utilizou um conjunto de dados conhecido e disponível no repositório de aprendizagem de máquina de UCI (DUA; GRAFF, 2017)[4]. O conjunto de dados utilizado foi resultado do algoritmo de compressão *Wavelet Transformed* (CHUN-LIN, 2010) com 1.372 amostras das cédulas de KBA-NotaSys Flowerpower (KBA-NF)[5]. Para o algoritmo SVM foi alcançado uma acurácia de 93,8%. Já para NN foi alcançado uma acurácia de 74,6%.

[4] https://archive.ics.uci.edu/ml/datasets/banknote+authentication Acesso em: 23 Nov. 2022
[5] https://banknote-solutions.koenig-bauer.com/en/design/specimens/ Acesso em: 18 Dez. 2022

O artigo de Costa, Veiga e Sousa (COSTA; VEIGA; SOUSA, 2016) foi o único trabalho dentre os selecionados que usou o descritor *Scale-Invariant Feature Transform* (SIFT) (MORTENSEN; DENG; SHAPIRO, 2005) como mecanismo de extração de características, utilizando algoritmos de reconhecimento de padrão baseado na comparação dos descritores do SIFT entre as cédulas. Eles utilizaram um conjunto de dados com 80 imagens de cédulas de Euro, porém não deixaram o conjunto de dados publicamente disponível. O sistema descrito pelos autores reconheceram 95 cédulas em 80 imagens, não deixando claro a quantidade de cédulas em cada imagem.

Darade e Gidveer (DARADE; GIDVEER, 2016) objetivaram o reconhecimento de cédulas falsas indianas, utilizando não só algoritmo de reconhecimento, mas também um *hardware* específico. A solução de *hardware* utilizou uma câmera acoplada a um microcontrolador para efetuar a captura. Foi utilizado o algoritmo *Principal Components Analysis* (PCA) (ABDI; WILLIAMS, 2010) para extrair características e efetuar a classificação, alcançando uma acurácia de 100%. O conjunto de dados capturado também não foi disponibilizado publicamente.

O trabalho de Lim e Murukeshan (LIM; MURUKESHAN, 2017) utilizou análise espectral para determinar se as cédulas são falsas ou não. Usou uma abordagem baseada em *HyperSpectral Image* (HSI) (EDELMAN et al., 2012) e PCA, aplicados a cédulas de polímero de Singapura, apontando um coeficiente de 99% de confiança. Foram utilizados cinco cédulas verdadeiras para construir a abordagem.

A abordagem de Hoang e Vo (HOANG; VO, 2018) utilizou cédulas do Vietnã, executando uma abordagem baseada em *Convolutional Neural Networks* (CNN) (SZARVAS et al., 2005) para extração de características combinada com SVM para classificação, alcançando uma acurácia de 99,97%. O conjunto de dados com 1.083 amostras utilizado não foi disponibilizado publicamente.

O trabalho de Upadhyaya, Shokeen, Srivastava (UPADHYAYA; SHOKEEN; SRIVASTAVA, 2018) apresentou uma comparação entre Regressão Logistíca (*Logistic Regression* – LR) (WRIGHT, 1995) e *Linear Discriminant Analysis* (LDA) (BALAKRISHNAMA; GANAPATHIRAJU, 1998), com uma acurácia média no conjunto de teste para a LR de 99,2% e para LDA de 98,1%, aplicado ao mesmo conjunto de dados utilizado por Çelik e Kondiloğlu (ÇELIK; KONDILOğLU, 2015).

O trabalho de Pham et al. (PHAM et al., 2020) se baseou na extração de características utilizando CNN. O conjunto de dados utilizado era formado por Dólares Americanos, Euro e Won Sul-Coreano (Won), recortado de forma a extrair duas imagens de regiões específicas da cédulas e submetidos ao CNN e posteriormente classificado. Foram utilizado quatro arquiteturas de CNN (AlexNet (AGARWAL; PATNI; RAJESWARI, 2021), ResNet (PATNAIK; KUMARI; MAHAPATRA, 2020), GoogleNet (MOHAMMED; ÇEVIK, 2022) e VGGNet (CHAN; IM; KE, 2020)), executando quatro testes, sendo que a ResNet

apresentou a melhor acurácia média com 99,16%.

O trabalho de Bastuk et al. (BASTURK et al., 2021) utilizou o mesmo conjunto de dados de Çelik e Kondiloğlu (ÇELIK; KONDILOğLU, 2015), resultado do algoritmo de compreensão DWT, sendo submetidos a um algoritmo de classificação denominado a *Adaptative Neural Fuzzy Inference System* (ANFIS) (JANG, 1993). Foram realizados 30 experimentos com validação cruzada, utilizando o método de agrupamento *Subtractive Clustering* (SB) (PRIYONO et al., 2005) e *Grid Partitioning* (GP) (BENMOUIZA; CHEKNANE, 2019), alcançando uma acurácia média de 99,94% para o primeiro e 100% para o segundo.

A abordagem de Bhatia et al. (BHATIA et al., 2021) fez uma comparação entre três algoritmos de classificação extraindo informações de impressão das cédulas indianas e tailandesas. Eles utilizaram o mesmo conjunto de dados de Çelik e Kondiloğlu (ÇELIK; KONDILOğLU, 2015). Os algoritmos utilizados foram o *K–Neartest Neighbors* (KNN) (LAAKSONEN; OJA, 1996), o SVM e o *Gradient Boosting Classifier* (GBC) (CHAKRABARTY et al., 2019), tendo o KNN o melhor resultado com 99,9% de acurácia.

A abordagem de Desai et al. (DESAI et al., 2021) explorou o uso de CNN para extração de características com *Generative Adversarial Networks* (GAN) (VISHWAKARMA et al., 2020) para classificação. Foi utilizado um conjunto de dados com quatro mil imagens de cédulas indianas, que não ficaram publicamente disponíveis. A abordagem proposta foi comparada com uma abordagem baseada em técnicas de PDI (SINGH; OZARDE; ABHIRAM, 2018) e com uma abordagem CNN. Como resultado, o modelo GAN obteve melhor resultado que o modelo CNN, com *recall* = 90%, precisão = 85,85% e *F1-score* = 88,62%. O modelo CNN obteve *recall* = 86,08%, precisão = 85,85% e um *F1-score* = 85,95%. A melhor abordagem continuou sendo a abordagem baseada em PDI, proposta por Singh et al. (SINGH; OZARDE; ABHIRAM, 2018), com *recall* = 90%, precisão = 94,74% e *F1-score* = 92,30%.

O trabalho de Yadav et al.(YADAV et al., 2021) utilizou o mesmo conjunto de dados utilizado por Çelik e Kondiloğlu (ÇELIK; KONDILOğLU, 2015). Os autores focaram em fazer uma comparação entre diversos algoritmos de classificação, sendo eles: SVM, *Random Forest* (RF) (BELGIU; DRĂGUŢ, 2016), LR, *Naive Bayes* (NB) (RISH et al., 2001), *Decision Tree* (DT) (PRIYAM et al., 2013) e KNN.O KNN foi o algoritmo com melhor acurácia de 99,75%.

O trabalho de Sumalatha, Reddy e Reddy (SUMALATHA; REDDY; REDDY, 2022) utilizaram um conjunto de dados de 247 imagens de cédulas indianas. Usaram uma CNN para fazer a classificação das imagens e extrair características, separando 80% para treinamento e 20% para teste. Utilizaram quatro tipos de CNN diferentes (AlexNet, ResNet, GoogleNet e DarkNet53 (WAREECHOL; CHIRACHARIT, 2021)), gerando dez métricas para compará-las, a saber: Verdadeiros Positivos, Falsos Positivos, Falsos

Negativos, Verdadeiros Negativos, Acurácia, Precisão, *Recall*, *F-measure*, Especificidade e *Youden index*. Durante o experimento, a CNN ResNet teve melhor acurácia com 80,94%.

2.2.2 Características Morfológicas

O trabalho de Sako et al.(SAKO et al., 2007) descreveu um mecanismo de autodefesa para caixas de autoatendimento. A construção do mecanismo de autodefesa conta com três submecanismos: validação de cédulas bancárias, reconhecimento de formulário e caracteres, reconhecimento de objetos. Para a validação das notas, os autores consideram características físicas da cédula, como as dimensões, de forma a facilitar o pré-processamento, pois o objetivo é apenas aceitar documentos que se parecem com notas, não necessariamente genuínas. Para a tecnologia de validação das notas, os autores consideraram duas partes a classificação e validação. Na classificação foram usadas estatísticas de dimensões e características padrões de cada tipo de cédula. Na validação foram selecionados cuidadosamente pontos de observação com pequenos desvios das notas genuínas, que foram separados usando a função discriminante de *Fisher's Discriminant Analises* (FDA) (MIKA et al., 1999). Foi utilizado como métrica a quantidade de falsos negativos. Tal métrica alcançou menos 1%. O conjunto de dados utilizado contava com um vídeo com capturas de dólar americano de 160 horas, que não está publicamente disponível.

Roy, Halder e Garain (ROY; HALDER; GARAIN, 2010) fizeram um estudo com o objetivo de identificar a origem da impressão de cédulas indianas com base em extração de nove características morfológicas, que podem ser classificadas em três categorias como (I) características de nível de cinza, (II) características de cor e (III) características estruturais ou geométricas, a saber: (1) intensidade dominante, (2) contagem de furos (descontinuidades nos traços dos caracteres), (3) média do matiz, (4) contraste, (5) tom chave, (6) média da cor, (7) rugosidade da borda, (8) diferença de áreas e (9) coeficiente de correlação. Primeiramente, a abordagem utilizou o algoritmo K-means (KRISHNA; MURTY, 1999) para separar as cédulas em dois grupos (*clusters*), genuíno ou falso. Em seguida, SVMs foram utilizadas com o objetivo de determinar a localização dos limites de decisão que produzem a separação ótima de classes. Para as SVMs foram considerados dois *kernels*, o polinomial e o RBF. A acurácia da classificação também é verificada com um classificador baseado em NN. É utilizado um *Multi-Layer Perceptrons* (MLP) composto por nove nós de entrada, correspondentes às nove dimensões de um vetor de características. A técnica de impressão é autenticada quando todas as características da cédula passam pelos critérios de autenticidade. Finalmente, uma LDA também é implementada. As características usadas para autenticar a técnica de impressão variam em seu poder de discriminação. Assim, o poder de discriminação de características individuais também é estudado. No final, as características são classificadas com base em seu poder de classificação decrescente e combinadas gradualmente para obter mais acurácia na classificação.

Nos experimentos, como conjunto de dados, foram consideradas 100 amostras genuínas e 100 amostras falsas. O conjunto de 200 amostras é dividido em quatro conjuntos para realizar um experimento quádruplo. A proporção em que as amostras aparecem nos dados de treinamento, validação e teste é de 50%, 25% e 25%, respectivamente. Em cada execução de um experimento, dois conjuntos são considerados como conjuntos de treinamento, os dois conjuntos restantes servem como conjuntos de validação e teste. O conjunto de dados utilizado não foi disponibilizado publicamente. Os resultados com o K-means foram avaliados calculando o número de amostras semelhantes agrupadas versus o número de amostras diferentes contidas nesse grupo, em que obteve uma acurácia média de 92,7%. As SVMs, polinomial e RBF, tiveram resultados semelhantes com acurácia média de 99,9% e 99,6%, respectivamente. A classificação baseada em NN obteve 99,5% de acurácia média. Para o LDA, foram avaliadas as métricas médias de viés, de separabilidade e de erro.

O trabalho de Yeh, Su e Lee (YEH; SU; LEE, 2011) aplicou uma SVM com Múltiplos *Kernel's* (SVM-MK), utilizando como entrada histograma de luminância. As cédulas, de origem de Taiwan, foram particionadas em quatro regiões e então foram extraídas as características mencionadas. O conjunto de dados foi mencionado como tendo sido capturado de uma *webcam*, composto por 99 imagens (70 genuínas e 29 falsas), porém não está publicamente disponível. Houveram experimentos com variações de abordagens de SVM, utilizando múltiplos kernels, com acurácia máxima de 100%.

2.2.3 Características de Segurança

O trabalho de Ionescu e Ralescu (IONESCU; RALESCU, 2005) utilizaram uma abordagem baseada no algoritmo *Fuzzy Hamming Distance* (FHD) (BOOKSTEIN; KLEIN; RAITA, 2001). Tal algoritmo junta as técnicas de Lógica Fuzzy e Distância de Hamming entre dois vetores diferentes. Eles utilizaram como moeda alvo as cédulas de dolar, porém sem um conjunto de dados publicamente disponível, limitando-se a mencionar a resolução (600dpi) e a quantidade de amostras (40 imagens). O algoritmo foi dividido em três etapas: extração de características, treinamento e classificação. A etapa de extração de características utilizou processamento de imagem para extrair sete características de segurança da cédula (dois números de série, quatro marcas d'água e o rosto impresso). O algoritmo foi treinado usando 10%, 50%, 80% e 100% das amostras. Utilizando um *treshold* de 53, o primeiro experimento (10%) alcançou 5% de "Falsos Negativos"e 0% de "Falsos Positivos", para o segundo experimento (50%), foi alcançado 11% de "Falsos Negativos"e 0% de "Falsos Positivos", para o terceiro experimento (80%) foi alcançado 25% de "Falsos Negativos"e 0% de "Falsos Positivos", e no último experimento (100%) alcançou 0% de "Falsos Negativos"e 0% de "Falsos Positivos".

O trabalho de Ahmed et al. (AHMED et al., 2014) se baseou em detectar seis

características de segurança das cédulas de Bangladesh e as classificar com base na presença ou ausência dessas características. Foram consideradas as características de (1) microimpressão, (2) marca d'água, (3) fio de segurança, (4) linhas ultravioleta (UV), (5) tinta opticamente variável (*Optically Variable Ink* – OVI) e (6) tinta iridescente. Essas características foram detectadas usando (1) *Optical Character Recognition* (OCR) (RAMANATHAN et al., 2009); (2) PCA; (3) *Speeded Up Robust Features* (SURF) (BAY et al., 2008); (4) *Canny Edge Detector* (Canny) (CANNY, 1986) e *Hough Line Algorithm* (Hough) (YU et al., 2005); e, (5 e 6)*Color Tracking* (CT) (WEI et al., 2007) com *Contour Analysis* (CA) (SHOTTON; BLAKE; CIPOLLA, 2005) para as tintas; respectivamente. As cédulas eram classificadas como genuínas se obtivessem sucesso no reconhecimento de pelo menos quatro características de segurança, incluindo o sucesso no OCR. Não foi estipulada métrica de avaliação e o conjunto de dados não se encontra disponível.

Rathee et al. (RATHEE et al., 2016), que também usaram características da impressão de segurança de cédulas indianas, utilizaram três características das nove elencadas, quais sejam: linha de segurança, logo RBI, marca de identificação. Essas características foram extraídas utilizando algoritmo de processamento de imagens, em que as imagens adquiridas de câmeras digitais foram divididas em canais de cores. Para cada imagem resultante equivalente a um canal de cor, foi aplicado um filtro de média. Por último, a imagem era reconstruída e cortada na localização onde deveriam estar as caracteristícas desejadas. Utilizaram essas características fundidas por meio de uma abordagem utilizada pelos autores chamada *Matched Score Fusion* (MSE), que agregava uma pontuação a imagem de acordo com as características coletadas, comparando assim o MSE com a cédula autêntica. Foram utilizadas quinze amostras, indicando uma acurácia de 100%. Nenhuma das amostras se encontra publicamente disponível.

Murthy, Kurumathur e Reddy (MURTHY; KURUMATHUR; REDDY, 2016) propuseram uma abordagem baseada em PDI tanto para o reconhecimento da denominação da cédula, quanto para a detecção de características de segurança da cédula para verificação se a cédula é verdadeira ou falsa. Os autores utilizaram, como conjunto de dados de referência, dez amostras de cédulas indianas de cada denominação, não deixando publicamente disponível. De cada cédula, foram capturadas imagens de frente e verso sob a influência da luz natural, luz de fundo branca e luz de fundo ultravioleta (UV) de forma independente. Já para os teste da abordagem, os autores usaram 60 notas de cédulas indianas reais e dez cédulas falsas. Os conjuntos de dados utilizados não estão disponíveis publicamente.

Foram extraídas nove características de segurança da cédula, utilizando valores de referência de uma cédula verdadeira para serem comparados com as cédulas falsas, sendo eles: (1) marca d'água, (2) fio de segurança, (3) imagem latente, (4) micro letras, (5) impressão em talhe doce (alto relevo), (6) marca de identificação, (7) fluorescência, (8) OVI e (9) registro transparente. As características de segurança eram detectadas usando: (1) a

média e desvio padrão da intensidade nas imagens com luz de fundo branca; (2) contagem do número de objetos inteiros na frente e no verso em condições normais e de contraluz; (3) algoritmo para detecção de linhas verticais; (4) OCR; (5) algoritmo de detecção de arestas com Canny; (6) algoritmo para reconhecimento de forma; (7) análise de tonalidade com a aplicação de retroiluminação UV juntamente com o cálculo da intensidade do pixel; (8) análise do matiz (*hue*) sob a influência da luz UV; e, (9) contagem de objetos e OCR nas imagens contra uma luz de fundo branca; respectivamente. A ausência de qualquer uma dessas características indicava que a cédula de entrada era uma nota falsa. Foi relatado uma alta acurácia do modelo, sendo de 100% de acurácia para a classificação da denominação (valor da cédula) e de 90% de acurácia para identificar a autenticidade.

O trabalho de Uddin, Das e Roney (UDDIN; DAS; RONEY, 2016) também considerou as características da impressão de segurança (utilizando três caracteríticas: marca d'água, microimpressão e texto latente), as características de marca d'água e microimpressão foram extraídas utilizando um algoritmo de detecção de borda *Canny* e para o texto latente foi utilizado o algoritmo *Histograms of Oriented Gradient* (HOG) (DALAL; TRIGGS, 2005). Utilizou o algoritmo SVM como classificador e tinha o diferencial de objetivar o uso de algoritmos para *smartphones*, alcançando a acurácia de 100%. Foram usadas 70 cédulas de *Taka bengalli* (Bangladeshi) como conjunto de dados, porém não se encontra publicamente disponível.

A abordagem de Zarin e Uddin (ZARIN; UDDIN, 2019) se baseou na extração de características de impressão de segurança, utilizando OCR, Transformada de Hough (HART; DUDA, 1972) e Reconhecimento de Face (BHELE; MANKAR et al., 2012), como entrada para um algoritmo de classificação SVM, obtendo uma acurácia de 93,33%. O conjunto de dados contou com mil notas de Bangladeshi, porém não se encontra publicamente disponível.

O trabalho de Colaco et al.(COLACO et al., 2021) focou em criar uma estrutura de *software* e *hardware* a fim de dar origem a um equipamento detector de cédulas indianas falsas. O *software* utiliza técnicas de PDI para detecção de doze características de segurança (a quantidade de características varia para cada denominação, sendo as notas de 500 e 2000 rupias as que possuem doze características), a saber: (1) retrato de Mahatma Gandhi no centro, (2) pilar Ashoka, (3) fio de segurança, (4) cláusula de garantia, (5) numeral denominacional com símbolo de rúpias, (6) numeral denominacional em devanagari, (7) linhas de sangria, (8) marca de identificação, (9) ver através do registro, (10) imagem latente do numeral denominacional, (11) micro letras, (11) característica Omron e (12) a impressão no topo da cédula de "*Government of India*".

O *hardware* proposto capturava a imagem da cédula sob a luz. Em seguida, a imagem capturada passava por um processo de segmentação, que realizava quatro tarefas: (1) detecção de bordas com Canny, (2) encontro do contorno (i.e., região de interesse,

region of interest – ROI), (3) desenho das bordas (encontra a larguda e altura da cédula) e (4) recorte (separa o ROI do fundo da imagem). Após a segmentação, a imagem passa pela etapa de extração de características, que depende da quantidade de características que a denominação possui. Assim, para cada denominação, um número mínimo de característica devem ser correspondidas corretamente, caso contrário a cédula é falsa. Por fim, as características extraídas são comparadas, por meio de uma correspondência, com as característica extraídas de uma cédula original de teste. A intensidade de cada característica é medida pela quantidade de pixels brancos com um grau de liberdade de 18%, em virtude da cédula de entrada poder não estar nas melhores condições. Os autores não apresentaram o tamanho do conjunto de dados utilizado, não disponibilizaram o conjunto de dados publicamente, e não comentaram sobre a acurácia alcançada pela abordagem proposta.

2.2.4 Híbridas

Baek et al. (BAEK et al., 2018) utilizaram a maior variedade de cédulas bancárias: o Euro (União Européia), a Rúpia (Indiana) e o Dolar Americano. A abordagem dos autores foram dividas em três classificações distintas, sendo necessária que a cédula seja considera genuína nas três etapas. A primeira etapa chamada de Classificação Global, dividiu a imagem adquirida em doze características (sendo seis médias dos canais RGB de ambos os lados da cédula, média dos três canais de infravermelho e log da média dos três canais de infravermelho) essas características foram então submetidas ao algoritmo de *Bhattacharyya Distance* (CHOI; LEE, 2003). A segunda etapa de classificação foi denominada de Classificação Local, que utilizou as características denominadas como *Human-Readable Features* (HRF) submetidas a um algoritmo de NN e SVM. A última classificação foi denominada de Classificação Paralela utilizava a junção das características das etapas anteriores em um último esforço de classificar as cédulas. Os autores alcaçaram 99,8% de acurácia para notas falsas e 100% para notas genuínas, utilizando um conjunto de dados cuja à quantidade de cédulas totais não foi especificada e nem está publicamente disponível.

2.3 Análise dos Resultados da Revisão de Literatura

Após a leitura de cada trabalho, foi realizada a sumarização das características de cada leitura: a estratégia na extração de características (descrito na Seção 2.2), o ano de publicação, os algoritmos de classificação, as moedas utilizadas e o conjunto de dados. Ademais, percebeu-se que as abordagens de cada trabalho podem ser dividas em: conjunto de dados, estratégia de extração de características e estratégia de classificação.

Conforme a Figura 4, é possível observar a quantidade de trabalhos publicados (eixo y), a respeito do tema no decorrer do tempo, de acordo com o ano de publicação (eixo x),

observando um interesse excepcional nos anos de 2016 e 2021.

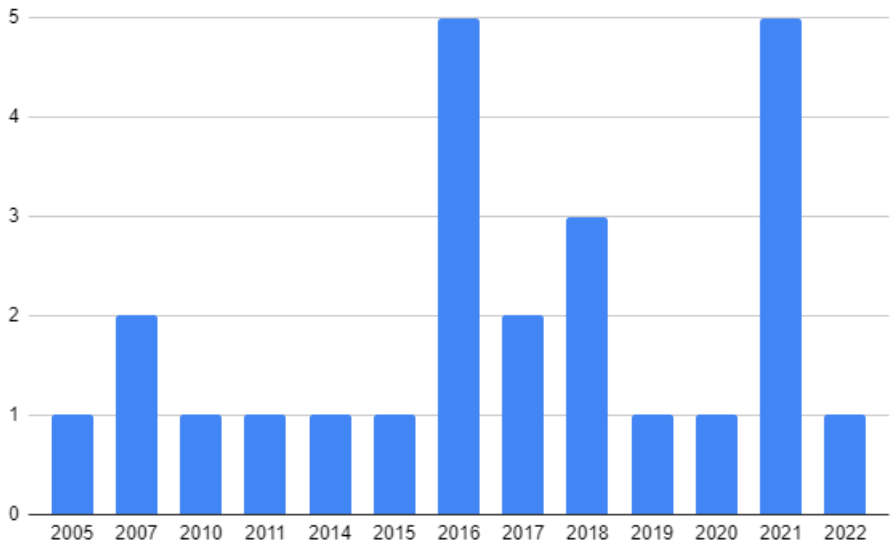


Figura 4 – Interesse por ano de publicação dos trabalhos.

A respeito do algoritmo de classificação, os resultados foram divididos em categorias, de acordo com as abordagens utilizadas, sendo sumarizadas na Tabela 4. Em todas os trabalhos analisados, nenhum apresentou métrica inferior a 80%, seja acurácia ou precisão. Além disso, nos últimos cinco anos, ou seja de 2017 a 2022, dos treze trabalhos publicados, quatro utilizaram CNN e cinco utilizaram SVM. Os trabalhos elencados na Tabela 4 podem ter utilizado mais de uma abordagem.

Tabela 4 – Resultados divididos pela principal abordagem de classificação utilizada.

Abordagem Principal	Qtd.Trabalhos
SVM	9
CNN	5
NN	3
PCA	2
Fuzzy	2
KNN	2
Outras abordagens	9

Além disso, analisando os conjuntos de dados dos trabalhos, segundo o qual consta no gráfico da Figura 5, a quantidade de trabalhos que mencionam a moeda e a porcentagem equivalente, é possível perceber que há um interesse maior pelo tema utilizando como conjunto de dados as cédulas indianas. Além das indianas, foram identificados trabalhos com cédulas de Dólar, Euro, Bangladesh e também cédulas de outros países em menor quantidade (Singapura e Taiwan, por exemplo), mas não foram identificados trabalhos com o Real Brasileiro. Tendo em vista que alguns trabalhos utilizaram mais de uma moeda, percebe-se que alguns trabalhos aparecem em mais de uma fatia do gráfico da Figura 5.

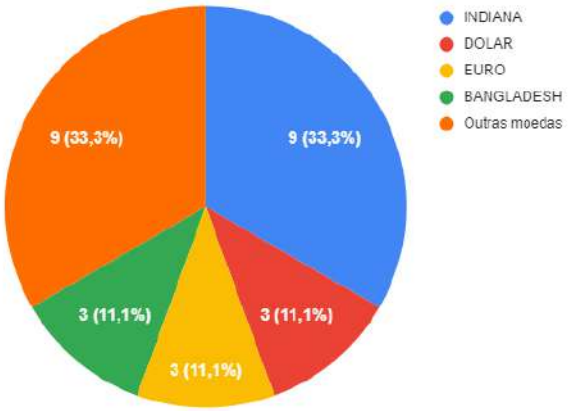


Figura 5 – Quantidade de trabalhos por origem da moeda utilizada.

Tratando-se de conjuntos de dados disponíveis, apenas dois foram diretamente tratados. O primeiro utilizado por cinco trabalhos dos 25 selecionados, refere-se ao conjunto de dados fornecido por Lohweg et al. (LOHWEG et al., 2013) ao *UCI Machine Learning* (DUA; GRAFF, 2017), que tabulou os dados resultantes da abordagem de DWT para uso com algoritmos de aprendizagem. O segundo conjunto de dados foi o fornecido por Meshram et al. (MESHRAM et al., 2020), e citado por um trabalho, que atualmente possui 3.000 imagens, capturadas por *smartphones*, de cédulas indianas e tailandesas (2.000 indianas e 1.000 tailandesas), de diferentes denominações, iluminação e diversos planos de fundo. Em uma busca paralela, foi encontrado também um conjunto de dados relacionado a nenhum dos trabalhos desta revisão, denominado *BankNote-net* (OVIEDO et al., 2022), que é um conjunto de dados público e aberto disponibilizado pela Microsoft. Tal conjunto de dados conta com 17 moedas e 112 denominações, possuindo tanto imagens quanto características extraídas e tabuladas, em um total de 24.816 amostras em diferentes cenários e iluminações. Denominações nesses conjuntos de dados são definidas como a expressão de valor impresso na cédula monetária (FREIRE, 2011).

A fim de traçar o atual estado da arte, pode-se concluir que é necessário mais estudos que utilizem conjunto de dados com cédulas de países de origem mais diversificados, principalmente de países da América Latina (América do Sul e Central). Além disso, se faz necessário trabalhos que explorem abordagens com a utilização de características híbridas. Por fim, apesar das abordagens relatadas terem acurácia acima de 85%, ainda se faz necessário trabalhos com abordagens mais diversificadas, sendo as abordagens baseadas em SVM e a abordagens baseadas em CNN as mais utilizadas. A Tabela 5 apresenta uma sumarização de todos os trabalhos encontrados na revisão de literatura, com exceção do trabalho de (VIRAKTAMATH et al., 2021), que é uma revisão de literatura. Na primeira coluna da Tabela 5, denominada de *"Trabalhos"*, apresenta o trabalho discutido. A segunda coluna da mesma tabela, denominado *"Abordagens"*, especifica de forma resumida qual o principal algoritmo utilizado na abordagem do autor. A terceira coluna, denominada *"Dados"*, apresenta se o conjunto de dados é próprio ou não, e quais cédulas foram utilizadas.

A quarta coluna, denominada *"Comparações"*, apresenta se houve ou não comparação entre abordagens. Por último, a coluna *"Métricas"* apresenta quais métricas foram utilizadas na avaliação das abordagens, informando os resultados obtidos. Em contrapartida aos trabalhos do estado da arte, este trabalho apresenta e desenvolve um novo conjunto de dados com cédulas monetárias de Real Brasileiro, e propõe uma abordagem preliminar baseada no uso de CNN para extração de características e o uso de SVM para classificação de cédulas monetárias de Real.

Tabela 5 – Resumo da Revisão Sistemática.

Trabalhos	**Abordagens**	**Dados**	**Comparações**	**Métricas**
(IONESCU; RALESCU, 2005)	FHD	Próprio, dólar	Sem	Sem
(CHANG; YU; YEN, 2007)	SVM+NN	Próprio, Taiwan	Sem	99,01% de acurácia
(SAKO et al., 2007)	FDA	Próprio	Sem	Falsos Negativos < 1%
(ROY; HALDER; GARAIN, 2010)	K-means, SVM, LDA	Próprio, Indiana	Sem	Acurácia média: SVM = 99,9% e LDA = 93%
(YEH; SU; LEE, 2011)	SVM-MK	Próprio, Taiwan	Sem	100% de acurácia
(AHMED et al., 2014)	OCR, SURF, Canny-Hough, PCA, CA-CT	Próprio, Bangladesh	Sem	Sem
(ÇELIK; KONDILOğLU, 2015)	SVM, NN	UCI, KBANF	SVM, NN	Acurácia: SVM = 93,88% e NN = 74,6%
(COSTA; VEIGA; SOUSA, 2016)	SIFT	Próprio, Euro	Sem	Reconheceu 95 cédulas em 80 imagens
(DARADE; GIDVEER, 2016)	PCA	Próprio, Indiana	Sem	Acurácia de 100%
(MURTHY; KURUMATHUR; REDDY, 2016)	Técnicas de PDI, OCR	Próprio, Indiana	Sem	100% de acurácia para denominação e 90% para autenticidade
(RATHEE et al., 2016)	MSE	Próprio, Indiana	Sem	100% de acurácia
(UDDIN; DAS; RONEY, 2016)	SVM	Próprio, Taka bengali	Sem	100% de acurácia
(LIM; MURUKESHAN, 2017)	HSI+PCA	Próprio, Singapura	Sem	99% de confiança
(BAEK et al., 2018)	NN+SVM	Próprio, Euro, Rúpia, Dólar	Sem	Acurácia de 99,8% de notas falsas e 100% para notas genuínas
(HOANG; VO, 2018)	CNN+SVM	Próprio, Vietnã	Sem	Acurácia de 99,97%
(UPADHYAYA; SHOKEEN; SRIVASTAVA, 2018)	LR e LDA	UCI, KBANF	LR e LDA	Acurácia médida: LR = 99,2% e LDA = 98,1%
(ZARIN; UDDIN, 2019)	SVM	Próprio, Bangladeshi	Sem	Acurácia de 93,33%
(PHAM et al., 2020)	CNN	Próprio, Dólar, Euro, Won	Resnet, AlexNet, GoogleNet e VGGNet	Melhor acurácia média: Resnet = 99,16%
(BASTURK et al., 2021)	ANFIS	UCI, KBANF	SC, GP	Acurácia: SC = 99,94% e GP = 100%
(BHATIA et al., 2021)	KNN, SVM, GBC	UCI, Indiana e Tailandesa	KNN, SVM, GBC	Melhor acurácia: KNN = 99,9%
(COLACO et al., 2021)	Técnicas de PDI	Próprio, Indiana	Sem	Sem
(DESAI et al., 2021)	CNN+GAN	Próprio, Indiana	GAN, CNN, PDI	Melhor PDI: Recall = 90%, Precisão = 94,74% e F1-score = 92,3%
(YADAV et al., 2021)	SVM, RF, LR, NB, DT, KNN	UCI, KBANF	SVM, RF, LR, NB, DT, KNN	Melhor acurácia: KNN = 99,75%
(SUMALATHA; REDDY; REDDY, 2022)	CNN	Próprio, Indiana	AlexNet, Resnet, Googlenet e Darknet53	Melhor acurácia: Resnet = 80,94%

3 Materiais e Métodos

Com base no estudo da literatura apresentado no Capítulo 2, neste capítulo são descritas as ferramentas, conjunto de dados, metodologias e os métodos utilizados na elaboração de uma nova abordagem para a classificação de cédulas monentárias da Segunda Família do Real em verdadeiras e falsas, voltada para o desenvolvimento de uma abordagem em Visão Computacional que possa auxiliar as pessoas com deficiência visual.

3.1 Conjunto de Dados

No decorrer da Revisão Sistemática indicada no Capítulo 2 foram encontrados dois conjuntos de dados utilizados nos trabalhos: o primeiro fornecido por Lohweg et al. (LOHWEG et al., 2013) denominado de *Banknote Authentication Dataset (BAD)* com 1.372 instâncias e o segundo conjunto de dados denominado *Dataset of Indian And Thai Banknotes (DITB)* fornecido por Meshram et al. (MESHRAM et al., 2020) com 3.000 instâncias. Além disso, foi selecionado o conjunto de dados de (OVIEDO et al., 2022) denominado *Open Dataset for Assistive Currency Recognition (BankNote-Net)* com 24.816 instâncias. Cada instância aqui foi descrita como uma entrada de imagem ou conjunto de características que possa ser classificada em genuína ou falsa. A *Tabela 6* sumariza os conjuntos de dados encontrados nesta revisão.

Por não ter sido encontrado trabalho com conjuntos de dados compostos de cédulas brasileiras até o momento deste trabalho, foi produzido um conjunto de dados denominado *Open Dataset for Recognition of Brazilian Counterfeit Banknotes (BankNote-Br)* de produção própria com 368 instâncias, que será disponibilizados publicamente, com acesso restrito, apenas para fins de pesquisa.

Tabela 6 – Sumarização dos conjuntos de dados encontrados durante a revisão.

Nome	Tamanho da amostra	Cédulas falsas	Cédulas verdadeiras	Nacionalidade das cédulas
BAD (LOHWEG et al., 2013)	1.382	762	610	Não especificado
DITB (MESHRAM et al., 2020) [1]	3.000	Não especificado	3.000	Indianas, Tailandesas
BankNote-Net (OVIEDO et al., 2022) [1]	24.861	Não especificado	24.861	Múltiplas nacionalidades (17 países)

[1] Conjunto de dados composto unicamente por cédulas verdadeiras, sendo que quem utilizar esse conjunto de dados devem confeccionar suas próprias cédulas falsas.

3.1.1 Banknote Authentication Dataset (BAD)

O conjunto de dados de Lohweg et al. (LOHWEG et al., 2013), em vez de possuir imagens, possui dados tabulados de características extraídas usando o *Discrete wavelet transform (DWT)* (RAO, 1998), sendo o conjunto de dados doados ao Repositório de Aprendizagem de Máquina UCI (*UCI Machine Learning Repository*) (DUA; GRAFF, 2017) em 16 de Abril de 2013. As imagens utilizadas foram extraídas de cédulas genuínas e falsas, digitalizadas com uma resolução de 600 dpi, em escala de cinza, produzindo imagens finais de 400x400 pixels.

Os dados tabulados possuem quatro características e uma classe, totalizando cinco atributos. As quatro características são: variância (*variance*), assimetria (*skewness*), curtose (*curtosis*) e entropia (*entropy*). Todos números reais e contínuos. O quinto atributo, correspondente a classe, é denominado classe (*class*) sendo 0 (zero) para falso e 1 (um) para verdadeiro. O conjunto de dados possui 762 instâncias de cédulas falsas e 610 instâncias de cédulas verdadeiras.

3.1.2 Dataset of Indian And Thai Banknotes (DITB)

O conjunto de dados de Meshram et al. (MESHRAM et al., 2020) possui 3.000 imagens de cédulas tailandesas e indianas. Sendo 2.000 imagens de notas indianas e 1.000 imagens de notas tailandesas, em diversas condições de iluminação e com diferentes fundos capturados usando a câmera traseira de um *smartphone*. Organizadas por denominação, as cédulas indianas consistem em notas novas e antigas de 10, 20, 50, 100, 200, 500 e 2.000 rúpias. Já as cédulas tailandesas consistem em 20, 50, 100, 500 e 1.000 baht. Os autores não definiram o que significa notas *novas* e *antigas*. O conjunto de dados foi utilizado para o reconhecimento de cédulas, separando a região de interesse de um fundo, com o objetivo de auxiliar pessoas com deficiência.

Na Figura 6 foram apresentadas dois exemplos do conjunto de dados. A Figura 6a representa uma cédula de 500 rúpias, denominada como *antiga* pelo autor. A Figura 6b representa uma nota de 50 Baht tailandeses. Em ambas as figuras é possível verificar um fundo variado multicolorido em um ambiente bem iluminado.

3.1.3 Open Dataset for Assistive Currency Recognition (BankNote-Net)

O conjunto de dados de Oviedo et al. (OVIEDO et al., 2022) possui 24.861 instâncias. Cada instância possui uma imagem e uma entrada tabulada com características extraídas a partir da ferramenta Seeing AI[1]. O conjunto de dados é organizado em 17 moedas e 112 denominações. O autor não especificou a abordagem para captura ou a origem das moedas. Na Figura 7 se observa duas amostras extraídas do conjunto de dados, sendo

[1] https://www.microsoft.com/en-us/ai/seeing-ai Acesso em: 22 Fev. 2023



(a) (b)

Figura 6 – Exemplos de imagem extraídas do conjunto de dados DITB: (a) Imagem de uma cédula de 500 rúpias e (b) Imagem de uma cédula de 50 baht (MESHRAM et al., 2020).

a Figura 7a, uma cédula de 20 coroas suecas com oclusão parcial, e a Figura 7b de 100 coroas suecas também com oclusão parcial. Assim como o DITB, esse conjunto de dados foi utilizado apenas para o reconhecimento de cédulas, sem considerar a classificação em verdadeiro e falso.



(a) (b)

Figura 7 – Exemplos de imagem extraídas do conjunto de dados BankNote-Net: (a) Imagem de uma cédula de 20 coroas suecas e (b) Imagem de uma cédula de 100 coroas suecas (OVIEDO et al., 2022).

3.1.4 Open Dataset for Recognition of Brazilian Counterfeit Banknotes (BankNote - Br)

Conforme a análise de resultados da Revisão Sistemática descrita no Capítulo 2, não foram encontrados trabalhos com um conjunto de dados de cédulas de Real que pudesse ser utilizado neste trabalho. Por essa razão, foi definido um protocolo para a construção desse conjunto de dados, que foi denominado *Open DataSet for Recognition of Brazilian Counterfeit Banknotes (BankNote-Br)* (SILVA; AIRES; NETO, 2024) ou Conjunto de dados abertos para Reconhecimento de cédulas falsas brasileiras.

Para adquirir as imagens foi utilizado um *smartphone* POCO X4 Pro 5G[2]. A escolha de um *smartphone* se deve à facilidade de acesso e a reprodução mais acertiva do dia-a-dia de uma pessoa com deficiência visual. O *smartphone* conta com uma câmera principal de 108 megapixel, com um sensor de 1/1.52", *Dual Native ISO* com pixel de 2,1 nanômetros. Além disso, o processador é um Snapdragon 695 5G com 8 gigabytes LPDDR4x.

As imagens foram capturadas de duas formas: em espaço controlado e em simulação do mundo real. Para o espaço controlado, foram capturadas fotografias em espaço iluminado, em uma distância de 30 a 40 centímetros, de ambos os lados das cédulas, sem dobras e sem oclusões (isto é, detalhes encobertos por outros objetos ou sobreposições). Para as simulações do mundo real, foram capturadas fotografias também a uma distância de 30 a 40 centímetros, sendo seguradas por mãos humanas, parcialmente encobertas ou não, com variação de iluminação e plano de fundo. Na Figura 8 e na Figura 9, observa-se um exemplo das imagens padronizadas, produzidas para fins de treinamento. Na Figura 10 e na Figura 11 é exemplificado as cédulas não padronizadas, utilizadas para fins de teste, simulando o mundo real.



(a) (b)

Figura 8 – Exemplos de imagem extraídas do conjunto de dados BankNote-Br: (a) Imagem frontal de uma cédula genuína de 2 reais e (b) Imagem posterior de uma cédula genuína de 2 reais.

[2] https://www.po.co/global/product/poco-x4-pro-5g/ Acesso em: 25 Jan. 2023



(a) (b)

Figura 9 – Exemplos de imagem extraídas do conjunto de dados BankNote-Br: (a) Imagem frontal de uma cédula falsa de 2 reais e (b) Imagem posterior de uma cédula falsa de 2 reais.

Quanto à denominação das cédulas selecionou-se as notas de 2, 5, 10, 20, 50 e 100 reais. Cédulas com denominação de 200 reais não foram selecionadas para o conjunto de dados, devido a dificuldade em adquiri-lás e por não obedecer aos padrões de acessibilidade[3]. Foram utilizadas 23 cédulas genuínas: 4 cédulas de 2 reais, 3 cédulas de 5 reais, 5 cédulas de 10 reais, 5 cédulas de 20 reais, 3 cédulas de 50 reais e 3 cédula de 100 reais. Também foram criadas as suas contrapartes falsas com as mesmas quantidades em cada denominação. Cada cédula produziu 8 imagens (2 imagens de teste padronizadas e 6 imagens de treinamento não padronizadas), totalizando um total de 368 imagens.

As cédulas foram selecionadas dentre aquelas de circulação cotidiana, sem distinção de idade e ou conservação. As notas utilizadas, após fotografadas em ambiente controlado, foram submetidas ao processo de falsificação próprio, ou seja, foram impressas em papel comum e fotografadas novamente sobre as mesmas contidiçoes das genuínas. Foi utilizada uma impressora multifuncional a laser HP Color LaserJet Pro MFP M479 [4], utilizando uma resolução de 300dpi para impressão em papel A4 75g/m². Após o registro fotográfico, as cédulas falsificadas foram picotadas de forma que ficassem inutilizáveis.

3.2 Características das Cédulas de Real

A fim de facilitar o desenvolvimento deste trabalho, procurou-se entender o conjunto de mecanismos de segurança e acessibilidade das cédulas da Segunda Família do Real. Segundo a cartilha de treinamento do Banco do Central do Brasil (BCB, 2013), a Segunda

[3] https://g1.globo.com/df/distrito-federal/noticia/2020/10/13/nota-de-r-200-defensoria-publica-recorre-a-justica-para-que-banco-central-retire-cedulas-de-circulacao.ghtml Acesso em: 22 Fev. 2023

[4] https://support.hp.com/br-pt/document/c06372830#AbT0 Acesso em: 22 Fev. 2023



(a) (b) (c) (d) (e) (f)

Figura 10 – Exemplos de imagem extraídas do conjunto de dados BankNote-Br: (a) e (b) Imagens de uma cédula genuína de 2 reais, (c) e (d) Imagens de uma cédula genuína de 5 reais, (e) e (f) Imagens de uma cédula genuína de 10 reais.

Família do Real possuem características comuns a todas as denominações e elementos exclusivos de cada denominação.

Os elementos comuns a todas as denominações das moedas são: dimensões (altura e largura), cor e tema. Essas características podem ser definidas como características morfológicas das cédulas de real. Na Figura 12 é possível observar quais elementos estão



(a) (b) (c) (d) (e) (f)

Figura 11 – Exemplos de imagem extraídas do conjunto de dados BankNote-Br: (a) e (b) Imagens de uma cédula falsa de 2 reais, (c) e (d) Imagens de uma cédula falsa de 5 reais, (e) e (f) Imagens de uma cédula falsa de 10 reais.

em cada denominação.

Os elementos de segurança por sua vez são: marca d'água, fio de segurança, quebra-cabeça, alto-relevo, textura do papel, faixa holográfica, número que muda de cor, número escodido, elemento fluorescentes, microimpressões. Alguns desses elementos estão presentes em todas as denominações e outros apenas em algumas. Na Tabela 7 é possível observar

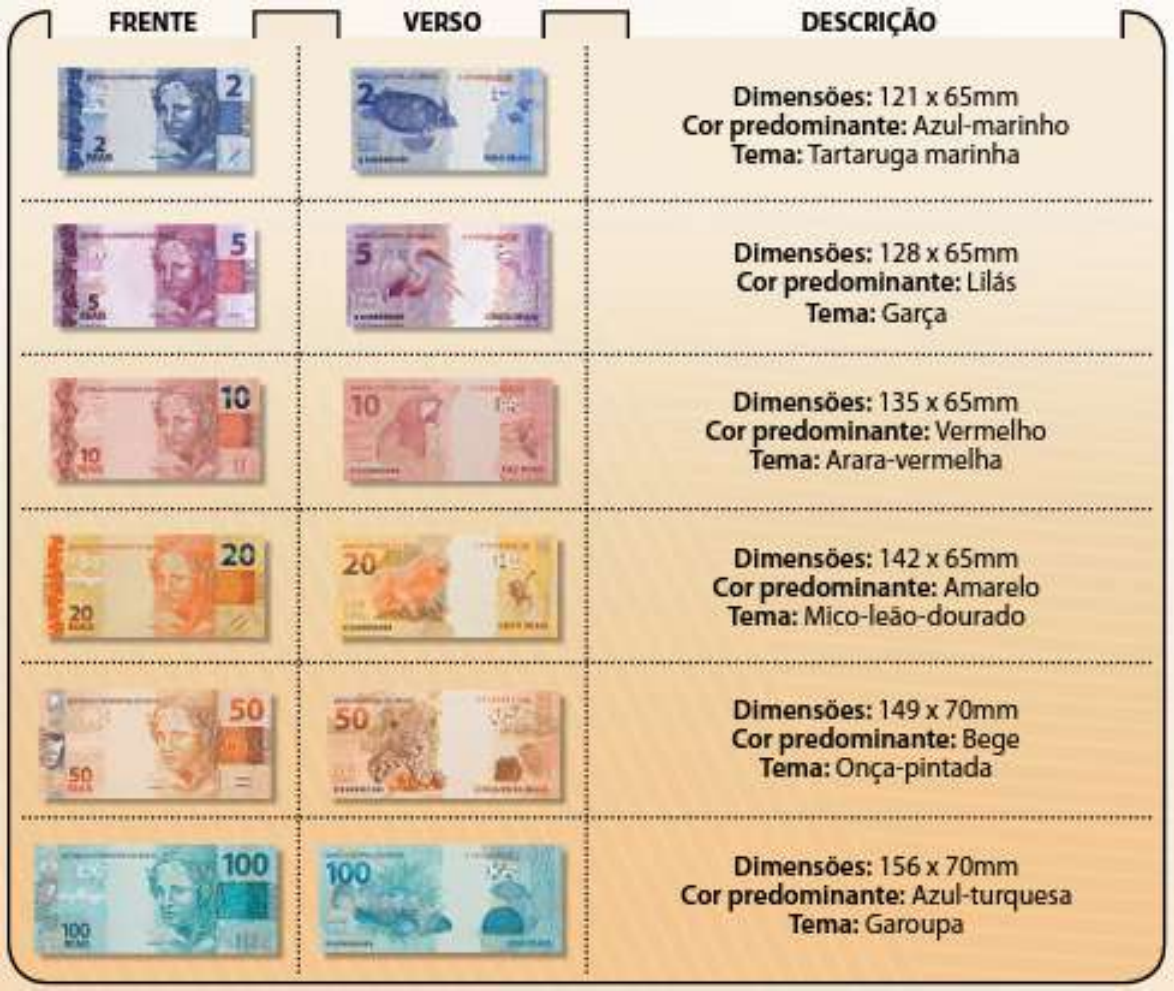


Figura 12 – Elementos comuns a todas as denominações da Segunda Família do Real(BCB, 2013).

quais elementos estão presentes em quais denominações. Nessa tabela se verifica sete colunas, sendo a primeira denominada *"Características"* que indica todas as características que podem estar presentes. As outras colunas possuem denominações (valores) de cada cédula, com os valores *"sim"* e *"não"*. O primeiro representa quando a característica está presente e o segundo quando não está presente.

3.3 Métodos Utilizados para Extração de Características

A extração de características é uma etapa fundamental em muitos problemas de visão computacional, como reconhecimento de objetos, classificação de imagens e detecção de faces. O objetivo da extração de características é gerar uma representação dos dados de entrada que seja significativa para a tarefa em questão (LATIF et al., 2019).

Existem muitos métodos diferentes para extração de características, cada um com suas próprias vantagens e desvantagens (NIXON; AGUADO, 2019). Os métodos mais simples se baseiam em características estatísticas, como o histograma de intensidade ou a

Tabela 7 – Características de segurança em cada denominação.

Características	**R$ 2**	**R$ 5**	**R$ 10**	**R$ 20**	**R$ 50**	**R$ 100**
Marca d'água	sim	sim	sim	sim	sim	sim
Fio de segurança	**não**	**não**	sim	sim	sim	sim
Quebra-cabeça	sim	sim	sim	sim	sim	sim
Alto-relevo	sim	sim	sim	sim	sim	sim
Textura do papel	sim	sim	sim	sim	sim	sim
Faixa holográfica	**não**	**não**	**não**	**não**	sim	sim
Número que muda de cor	**não**	**não**	sim	sim	**não**	**não**
Elementos fluorescentes	sim	sim	sim	sim	sim	sim
Microimpressões	sim	sim	sim	sim	sim	sim

borda. Métodos mais complexos utilizam técnicas de aprendizado de máquina para aprender características mais discriminativas (LATIF et al., 2019). Nesse capítulo iremos relatar alguns algoritmos constantemente utilizados para extração de características mencionados no Seção 2.

3.3.1 Convolutional Neural Networks (CNN)

As Redes Neurais Covolucionais (*Convolutional Neural Networks* – CNN) são algoritmos de Aprendizagem profunda (*Deep Learning*) baseadas em Redes Neurais (*Neural Networks* – NN), utilizadas primordialmente em aplicações de Visão Computacional (SZARVAS et al., 2005). Geralmente, algoritmos de aprendizagem são extremamente dependentes da integridade da representação dos dados (ALZUBAIDI et al., 2021), por não terem essa característica, os algoritmos de CNN se tornaram muito populares, sendo projetadas para aprender características espaciais, como texturas e formas, que melhor representa a classe pretendida (KATTENBORN et al., 2021).

As NN's multicamadas tradicionais costumam ter um peso associado para cada unidade neural em cada camada de sua topologia. Porém a CNN, diferente das redes neurais tradicionais, possui uma topologia mais diversificada, podendo contar com camadas de convolução, camadas de *pooling* e camadas totalmente conectadas (TU et al., 2019). A seguir, é apontado uma breve explicação sobre cada uma dessas camadas:

1. **Camada de Convolução:** Essa camada é responsável por extrair características das imagens de entradas por meio de operações de convoluções (CHAUHAN; GHANSHALA; JOSHI, 2018). Operações de convoluções envolvem o deslizamento de um filtro sobre a imagem de entrada e a multiplicação dos valores do filtro com os pixels correspondentes, destacando características específicas como resultado (ALBAWI; MOHAMMED; AL-ZAWI, 2017);

2. **Camada de Pooling:** As camadas de *pooling* são utilizadas para reduzir a dimensionalidade dos mapas de entradas resultantes da camada de convolução (YU et al., 2014), ajudando a diminuir a quantidade de parâmetros no modelo e diminuindo o risco de *overfitting* (GAVRILOV et al., 2018). O *pooling* pode ser feito por diferentes técnicas, como o *Max Pooling* que seleciona o valor máximo da região (CHRISTLEIN et al., 2019), ou o *Average Pooling* que utiliza a média dos valores em uma região (AL-SABAAWI et al., 2020);

3. **Camada Totalmente Conectada:** São camadas semelhantes aquelas encontradas nas redes neurais tradicionais e são usadas para extrair características para classes de saídas (MA; LU, 2017). Combinam as informações aprendidas em camadas anteriores para atender as demandas de classificação ou regressão (ZHANG et al., 2017).

Atualmente, existem diversas CNN's implementadas, dentre elas:

1. **LeNet:** Foi uma das primeiras CNN's desenvolvidas, estabelecendo as bases para as topologias seguintes, sendo usada para reconhecer dígitos manunscritos (EL-SAWY; EL-BAKRY; LOEY, 2017);

2. **AlexNet:** Foi desenvolvida para trabalhar com imagens em alta resolução, ganhando o desafio *ImageNet Large Scale Visual Recognition Competition (ILSVRC)* (DENG et al., 2012)(ALMISREB; JAMIL; DIN, 2018);

3. **VGGNet:** Foi proposta pela *Visual Geometry Group* da Universidade de Oxford, ficando conhecida pela profundidade e simplicidade. Em outras palavras, a VGGNet conta com várias camadas de convolução em sequência (CHAUDHARI et al., 2021);

4. **GoogLeNet (Inception):** Projetada para melhorar a eficiência e a capacidade de representação das CNN's (AL-QIZWINI et al., 2017). Uma das principais contribuições foi a introdução dos módulos *Inception's* que têm como objetivo capturar diferentes escalas de informações visuais em paralelo, permitindo a aprendizagem de características complexas em várias resoluções (ZHENG; HAN; SOOMRO, 2019);

5. **ResNet:** Abreviação para *Residual Network*, a ResNet foi projetada para superar o desafio de treinar redes neurais profundas, que ao adicionar camadas poderia levar a degradação de desempenho (TARG; ALMEIDA; LYMAN, 2016). Trouxe como principal inovação a criação de "blocos residuais"que são atalhos entre as camadas, permitindo que a rede aprenda caminhos mais eficientes entre os padrões observados (HUANG et al., 2018).

3.3.2 Discrete Wavelet Transform (DWT)

A Transformada Discreta de Wavelet (*Discrete Wavelet Transform – DWT*) é uma técnica matemática usada para analisar e processar sinais e imagens (KUMAR, 2020). Utilizada também em áreas como processamento de sinais, processamento de imagens, compressão de dados, *denoising*, entre outras aplicações (GIRI et al., 2020).

A DWT é baseada em *wavelets*, que são funções matemáticas que podem ser usadas para decompor um sinal em diferentes frequências e escalas (GIRI et al., 2020). Essa transformação é discreta porque opera em um conjunto finito de dados amostrados, ao contrário de outras transformadas contínuas (TOO; ABDULLAH; SAAD, 2019).

Os principais tipos de DWT são:

1. **DWT de uma dimensão (1D-DWT):** Utilizada para processar sinais unidimensionais, como séries temporais ou sinais de áudio. Nessa transformação, o sinal é decomposto em diferentes frequências e resoluções, representando características de alta frequência (detalhes) e baixa frequência (aproximações) (KARADAL et al., 2021).

2. **DWT bidimensional (2D-DWT):** Empregada no processamento de imagens bidimensionais. Nesse caso, a imagem é decomposta em diferentes componentes de frequência e escala, permitindo a representação dos detalhes e da estrutura geral da imagem (KARADAL et al., 2021).

3. **DWT multi-dimensional:** Uma extensão da DWT para mais de duas dimensões, permitindo a aplicação em volumes 3D, como dados de vídeo ou cubos de dados (KARADAL et al., 2021).

Além disso, pode ser implementada utilizando diversas famílias de *wavelets*, como Haar (KANAGARAJ; MUNEESWARAN, 2020), Daubechies (TRABELSI; NOURI; AMMARI, 2023), Coiflets (SAPUTRA; FIRMANSYAH; IRAWAN, 2019), entre outras. Cada família de *wavelets* possui características diferentes, e a escolha da melhor família depende da aplicação específica e dos requisitos do problema. A DWT oferece várias vantagens, como a capacidade de compactar eficientemente dados, identificar características importantes em diferentes escalas e aprimorar a qualidade de sinais e imagens (TOO; ABDULLAH; SAAD, 2019).

3.3.3 Scale Invariant Feature Transform (SIFT)

O *Scale Invariant Feature Transform* – SIFT é um algoritmo de visão computacional publicado por David Lowe em 1999 (LOWE, 1999). Sendo usado principalmente para detectar e descrever pontos de interesse em imagens. Tais pontos são características locais

que são invariantes à escala, orientação e iluminação (WU et al., 2013). O SIFT, portanto, é composto por duas partes distintas: o detector e o descritor (BELLAVIA; COLOMBO, 2020).

O detector SIFT é responsável por encontrar os pontos de interesse na imagem, usando um filtro de diferença de Gaussianas para detectar pontos de máximo ou mínimo do gradiente (LOWE, 1999)(WU et al., 2013). O filtro é aplicado em diferentes escalas, o que permite que o detector encontre pontos de interesse em diferentes tamanhos (BELLAVIA; COLOMBO, 2020). Por outro lado, o descritor SIFT é responsável por descrever os pontos de interesse encontrados pelo detector usando um histograma de gradientes orientados (WU et al., 2013). O histograma é calculado na vizinhança local de cada ponto de interesse, em diferentes direções, o que permite que o descritor capture a orientação do ponto estudado (WU et al., 2013).

O SIFT tem como principais características a sua invariância à escala, orientação e iluminação, que permite que seja flexível e adaptável à diversos cenários de captura da imagem (BELLAVIA; COLOMBO, 2020). Porém como principais desvantagens é apresentado um algoritmo de complexidade computacional alta e sensível a ruídos na imagem (WU et al., 2013). Entre os ruídos que podem interferir no SIFT, temos: o ruído de sal e pimenta, o ruído gaussiano e o ruído de poisson (WU et al., 2013).

3.4 Métodos Utilizados para Classificação

A fim de fundamentar teoricamente esse trabalho com uma visão geral de algumas ferramentas potencialmente úteis para classificação de características relatadas nos trabalhos apresentados, a seguir é apresentado um breve resumo das quatro tecnologias mais utilizadas nos trabalhos relatados na Seção 2.

3.4.1 K–Nearest Neighbors

O algoritmo KNN é um método de aprendizado supervisionado utilizado para classificação e regressão (CUNNINGHAM; DELANY, 2021). Sua ideia fundamental é bastante simples: para classificar um ponto de dados, olhe para os k pontos de dados mais próximos a ele no espaço de características e atribua a classe (no caso de classificação) ou valor (no caso de regressão) mais comum entre esses vizinhos (ALI et al., 2020).

O KNN é conhecido por sua simplicidade e eficácia (CUNNINGHAM; DELANY, 2021). Sua natureza não paramétrica significa que não faz suposições sobre a distribuição dos dados, aprendendo diretamente com o conjunto de treinamento(CUNNINGHAM; DELANY, 2021) (ALI et al., 2020). A sensibilidade à dimensionalidade e a ênfase na proximidade são aspectos cruciais a serem considerados ao aplicar o KNN (ALI et al., 2020).

3.4.2 Naive Bayes

O algoritmo *Naive Bayes* é um método estatístico baseado no Teorema de Bayes, que é utilizado para realizar classificação e aprendizado supervisionado em problemas de machine learning (NARAYAN, 2021). Particularmente eficaz em situações com um conjunto de dados relativamente grande e independente (MASWADI et al., 2021). Este algoritmo é chamado de "ingênuo"(*naive*) porque assume independência entre os recursos (ou características) do conjunto de dados, simplificando o cálculo de probabilidades condicionais (MASWADI et al., 2021).

O algoritmo assume que as características são independentes entre si, dada a classe, por essa razão é considero "ingênuo", uma vez que essa suposição simplifica os cálculos, mas nem sempre reflete a realidade (NARAYAN, 2021). No entanto, continua sendo eficaz em muitos casos práticos, como por exemplo, assistência a decisão (MASWADI et al., 2021) e classificação de texto (REZAEIAN; NOVIKOVA, 2020).

Para realizar a classificação, o algoritmo calcula a probabilidade posterior de cada classe dado um conjunto de características observadas. A classe com a maior probabilidade posterior é então atribuída como a classe prevista (NARAYAN, 2021) (MASWADI et al., 2021). Existem diferentes variantes do *Naive Bayes*, como o *Naive Bayes* Gaussiano (ANAND et al., 2022) para dados contínuos (por exemplo, os descritores de uma imagem por CNN) e o *Naive Bayes* Multinomial (DEWI et al., 2023) para dados discretos (por exemplo, a análise de sentimento).

Em resumo, o *Naive Bayes* é um método poderoso e eficiente para classificação, especialmente em problemas de aprendizado de máquina com grandes conjuntos de dados e onde a independência condicional entre características é uma aproximação razoável.

3.4.3 Support Vector Machine (SVM)

As Máquina de Vetor de Suporte (*Support Vector Machine – SVM*) são algoritmos de aprendizagem de máquina supervisionado, utilizados para problemas de classificação e regressão, com notável eficiência com dados complexos e de alta dimensionalidade (SCHULDT; LAPTEV; CAPUTO, 2004). O objetivo da SVM é encontrar um hiperplano de separação ótimo que maximize a margem entre duas classes diferentes de dados, ou seja, tenta encontrar melhor linha (em problemas binários) ou hiperplano (em problemas multidimensionais) que separe classes distintas (HUANG et al., 2018). Essa linha ou hiperplano é chamado de *vetor de suporte* (CORTES; VAPNIK, 1995).

Existem três principais tipos de SVM's:

1. **SVM de Margem Rígida (Hard Margin SVM):** Assume-se que os dados são lineramente separáveis, com o objetivo de encontrar a reta ou plano que separe essas

classes sem cair na margem (PAN; YAN; ZHENG, 2005). Sensível a *outliers*, pode não funcionar adequadamente quando os dados não são linearmente separáveis (SIFAOU; KAMMOUN; ALOUINI, 2019);

2. **SVM de Margem Suave (Soft Margin SVM):** Permite que alguns pontos caiam na margem, sendo bastante útil quando não possuem classes que são totalmente linearmente separáveis, sendo bem menos sensíveis aos *outliers* (WU; ZHOU, 2005);

3. **SVM com Kernels (Kernel SVM):** É uma variante do SVM que permite a aplicação em dados que não são linearmente separáveis, aplicando um *kernel* sobre o espaço original não separável até torná-ló separável, diminuindo a dimensionalidade (PATLE; CHOUHAN, 2013).

3.4.4 Random Forest

Random Forest é um algoritmo de aprendizado de máquina supervisionado que usa uma combinação de árvores de decisão para fazer previsões (MANZALI; ELFAR, 2023). Cada árvore de decisão é treinada em um conjunto de dados aleatório, e as previsões são feitas por votação ou média das previsões das árvores (MANZALI; ELFAR, 2023)(HATWELL; GABER; AZAD, 2020).

O algoritmo *Random Forest* começa gerando um conjunto de árvores de decisão (HATWELL; GABER; AZAD, 2020). Cada árvore é treinada em um conjunto de dados aleatório, que é gerado a partir do conjunto de dados original (HATWELL; GABER; AZAD, 2020). O tamanho do conjunto de dados aleatório é geralmente definido como um percentual do conjunto de dados original (HATWELL; GABER; AZAD, 2020).

Em seguida, o algoritmo usa as árvores de decisão para fazer previsões. As previsões são feitas por votação ou média das previsões das árvores (MANZALI; ELFAR, 2023).

3.5 Métricas de Avaliação

Em aprendizagem de máquina, as métricas de avaliação são utilizadas para mensurar o desempenho de algoritmos preditores. Essas métricas são importantes para comparar diferentes algoritmos e para avaliar o desempenho de um algoritmo ao longo do tempo.

Nesse trabalho, serão detalhadas as métricas de classificação, sendo abordadas as seguintes: Acurácia, *Recall* (Sensibilidade), Especificidade, *F1 – Score* e Precisão.

A Acurácia mede o número de previsões corretas com relação ao total de elementos de teste (CARVALHO; PEREIRA; CARDOSO, 2019). Muito útil para medir o quão preciso é o modelo no geral, porém pode apresentar um diagnóstico equivocado em modelos cuja as classes estão desbalanceadas (ZHOU et al., 2021). Na Equação 3.1 é demonstrado como

deve ser calculado a Acurácia, na equação **VP** é Verdadeiro Positivo, **VN** é Verdadeiro Negativo, **FP** é Falso Positivo, **FN** é Falso Negativo e **acurácia** é a acurácia resultante do modelo.

$$\text{acurácia} = \frac{\text{VP} + \text{VN}}{\text{VP} + \text{VN} + \text{FP} + \text{FN}} \tag{3.1}$$

O *Recall* ou Sensibilidade mede a capacidade de encontrar exemplos positivos, sendo especialmente importante quando a tendência de não encontrar um positivo é alta (ZHOU et al., 2021). Ou seja, cenários em que não detectar um positivo representa uma perca inaceitável, como por exemplo, modelos de diagnóstico médico. Na Equação 3.2 é demonstrado como a Sensibilidade é calculada, **VP** representam a quantidade de verdadeiros positivo, **FN** representa a quantidade de falsos negativos e **sensibilidade** representa a Sensibilidade total do modelo.

$$\text{sensibilidade} = \frac{\text{VP}}{\text{VP} + \text{FN}} \tag{3.2}$$

A Especificidade é o antônimo do *Recall*, em outras palavras, como o *Recall* mede a capacidade de encontrar todos os exemplares positivos, a Especificidade mede a capacidade de encontrar todos os negativos (ZHOU et al., 2021) (CARVALHO; PEREIRA; CARDOSO, 2019). Na Equação 3.3 indicasse como esse valor é calculado, **VN** é a quantidade de verdadeiros negativos, **FP** é a quantidade de falsos positivos e **especificidade** é o valor total da especificidade.

$$\text{especificidade} = \frac{\text{VN}}{\text{VN} + \text{FP}} \tag{3.3}$$

Por outro lado, a Precisão objetiva quanto dos resultados positivos do modelo, são realmente positivos (ZHOU et al., 2021) (CARVALHO; PEREIRA; CARDOSO, 2019). Em outras palavras, mede o quanto o algoritmo classifica corretamente seus valores positivos. Ou seja, um valor de precisão alto, diz que o algoritmo tem uma boa capacidade de detectar os valores positivos (CARVALHO; PEREIRA; CARDOSO, 2019). Na Equação 3.4 é mostrado como esse valor é calculado, **VP** é a quantidade de verdadeiros positivos, **FP** é a quantidade de falsos positivos e **precisao** é o valor calculado para a precisao.

$$\text{precisao} = \frac{\text{VP}}{\text{VP} + \text{FP}} \tag{3.4}$$

O *F1 – Score* é uma métrica que combina a Sensibilidade com a Precisão, em outras palavras, fornece uma métrica equilibrada entre as duas (CARVALHO; PEREIRA; CARDOSO, 2019). Calculado por meio de uma média harmonica, o *F1 – Score* é bastante útil quando o conjunto de dados possui classes desequilibradas (CARVALHO; PEREIRA; CARDOSO, 2019). Em outras palavras, o *F1–Score* representa a proporção de classificações

corretas, considerados tanto negativos quanto positivos. Na Equação 3.5 é demonstrado como se chega a esses valores, **precisao** representa o valor calculado com a Equação 3.4, **sensibilidade** é o valor calculado com a Equação 3.2 e por último **f1-score** é o valor que representa o *F1–Score*.

$$\text{f1-score} = 2 * \frac{\text{precisao} * \text{sensibilidade}}{\text{precisao} + \text{sensibilidade}} \tag{3.5}$$

4 Abordagem Proposta

Este trabalho propõe uma abordagem a fim de extrair características e classificar imagens de cédulas bancárias em verdadeiras e falsas utilizando o conjunto de dados Banknote-Br (SILVA; AIRES; NETO, 2024) descrito na *Seção 3.1*, segundo a proposta de divisão do conjunto de treinamento e teste proposta pelos autores. Optou-se por utilizar o conjunto de dados Banknote-Br por não haver trabalhos que utilizassem um conjuntos de dados com cédulas bancárias brasileiras para fins de classficação em verdadeiras e falsas.

Além disso, para fins didáticos, foi necessário dissecar o trabalho em quatro etapas, descritas na *Seção 4.1*: pré-processamento, aumento de dados, extração de características e classificação. Durante o pré-processamento foram executados procedimentos necessários a fim de otimizar a classificação das cédulas, em especial, a detecção das cédulas, excluindo o *background* (plano de fundo sem a região de interesse da cédulas) e a padronização das dimensões da imagem.

A etapa de aumento de dados consistiu em gerar novas cédulas, a serem adicionadas ao conjunto de dados original. Na etapa de extração de características, foram utilizadas técnicas de extração dos descritores e características das imagens oriundas das etapas anteriores. Por fim, foi utilizada uma etapa de classificação, em que métodos de classificação das características obtidas da etapa anterior foram utilizados.

Essas etapas foram repetidas diversas vezes, variando a ferramenta de extração de características e a ferramenta de classificação, além de usar uma maior ou menor quantidade de imagens geradas pelo aumento de dados. Porém, a etapa de pré-processamento foi a mesma em todos os experimentos.

4.1 Visão geral dos experimentos realizados

Nesta seção, será apresetada uma visão geral dos experimentos realizados para seleção da abordagem mais adequada para o reconhecimento de cédulas monetárias falsas de Real, conforme Figura 13, sem considerar peculiridades específicas de cada abordagem, como modelo de classificação utilizado, se restrigindo a descrever a macroestrutura dos experimentos. Foi considerado um conjunto de dados de treinamento e teste do Banknote-Br, conforme descrição da *Seção 3.1*.

4.1.1 Pré-Processamento

Durante a etapa do pré-processamento, foi executado o procedimento de detecção das cédulas, separando as regiões de interesse do plano de fundo, a fim de facilitar os

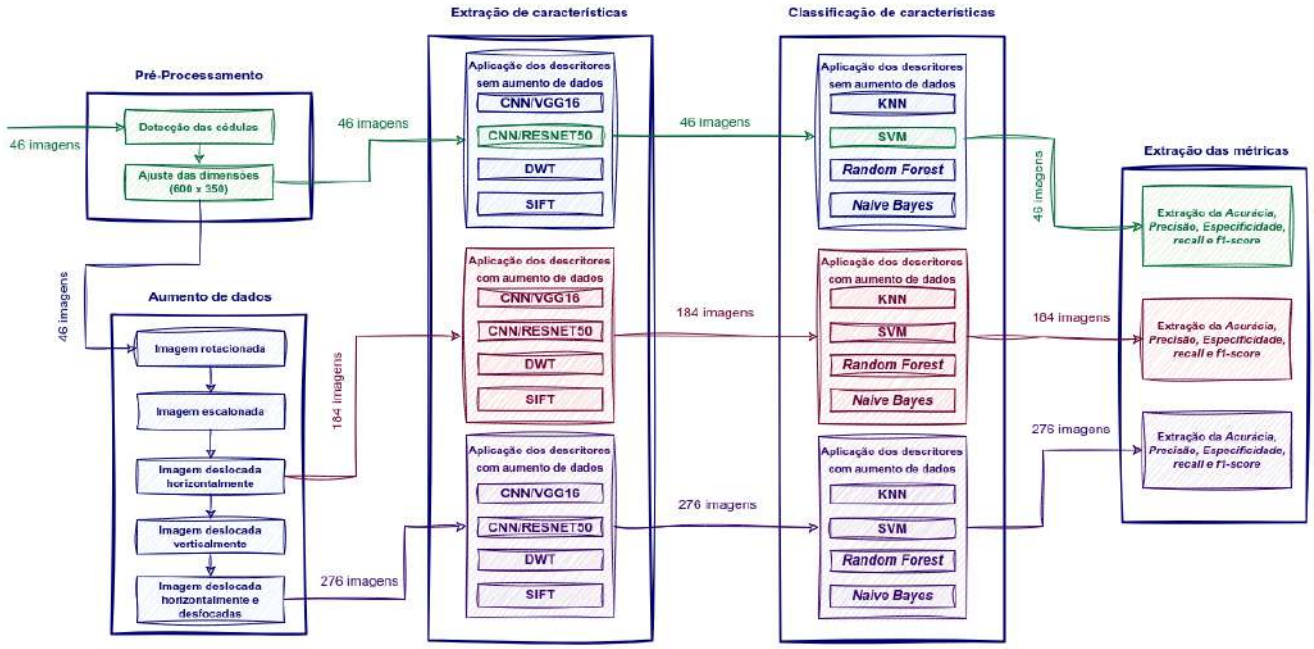


Figura 13 – Etapas utilizadas na abordagem proposta. Em verde, a abordagem com melhor resultado.

procedimentos de extração de características e aumento de dados. Essa detecção foi feita selecionando-se uma região de 600x350 pixels, referente a região que pudesse englobar a cédula inteira. Na *Figura 14*, é exemplificado como a detecção foi feita, a esquerda (*Figura 14a*) representa a figura original assim como foi adquirida, a direita (*Figura 14b*) é apontado a figura após a detecção.



(a) (b)

Figura 14 – Exemplos de detecção da região de interesse em uma imagem: (a) Imagem de uma cédula falsa de 100 reais como fotografada e (b) Imagem de uma cédula falsa de 100 reais com após o procedimento de detecção.

4.1.2 Aumento de dados

Para o aumento de dados foi utilizado a biblioteca do Pyhton *Imgaug* [1] na sua versão 0.4.0, segundo a sua descrição oficial, uma biblioteca responsável por implementar diversos métodos de aumentos de dados em imagem para serem utilizados em experimentos de aprendizagem de máquina.

Para esse fim, cinco estratégias foram utilizadas para gerar novas imagens para o conjunto Banknote-BR, cada estratégia contou com um ou mais algoritmos aplicados a imagem padronizada original para produzir cinco novas imagens que simulam características do conjunto de dados de teste. Para cada experimento posteior desenhado, poderá usar parte ou todas as imagens do conjunto de dados de treinamento aumentado.

A primeira imagem gerada pelo algoritmo de aumento de dados utilizou o algoritmo de rotação, que escolhe uma rotação aleatória entre dois parâmetros, para os fins desse trabalho, considerou-se um valor aleatório entre 22 graus positivos e 22 graus negativos, conforme *Figura 15b*. Para a segunda imagem (*Figura 15c*) gerada pelo algoritmo de aumento de dados, foi utilizado um algoritmo de escala, que escolhe um valor aleatório entre dois fornecidos, para esses algoritmo foi utilizado um valor entre 1.0 e 1.2 (Relativo a um fator de escala de até 20% escolhido aleatoriamente).

A terceira (*Figura 15d*) e quarta (*Figura 15e*) imagens geradas utilizaram deslocamento no eixo horizontal e vertical respectivamente. Em ambas as imagens, o deslocamento representou até 25% da largura ou altura, a depender do eixo. Por último, a quinta imagem (*Figura 15f*) foi gerada com duas estratégias combinadas: assim como a terceira imagem, a imagem foi deslocada em até 25% no eixo horizontal, porém sofreum um desfoque utilizando um filtro Gaussiano com o parâmetro de sigma de 0 a 3.

4.1.3 Extração de características

Para a extração de características, foram utilizadas três ferramentas: DWT, SIFT, CNN. Para os experimentos que utilizaram DWT, foi empregada a implementação da framework em Python *PyWalets* [2] com a família de *wavelet haar*, em um modo de extrapolação de sinal padrão descrito como *symetric* e de nível simples, por fim quatro características foram coletadas: variância, entropia, curtose e assimetria.

Durante as abordagens experimentais que utilizam CNN, duas redes pré-treinadas foram utilizadas: VGG16 e RESNET50. Para ambas as redes, utilizou-se uma rede pré-treinada com o conjunto de dados *ImageNet* [3]. Optou-se por não utilizar as 3 últimas camadas totalmente conectadas no topo da rede, para que se pudesse fazer a transferência

[1] Disponível em: https://imgaug.readthedocs.io/en/latest/, Acessado em: 12 de Jan. de 2024
[2] Disponível em: https://pywavelets.readthedocs.io/en/latest/index.html, Acessado em: 16 de Abr. de 2024
[3] https://www.image-net.org/, Acessado em: 16 de Abr. de 2024



Figura 15 – Exemplos de detecção da região de interesse em uma imagem: (a) Imagem de uma cédula falsa de 50 reais antes do aumento de dados, (b) Imagem gerada pelo aumento de dados de uma cédula falsa de 50 reais com rotação da imagem aleatório entre 22° e -22°, (c) Imagem gerada pelo aumento de dados de uma cédula falsa de 50 reais com escala de até 20%, (d) Imagem gerada pelo aumento de dados de uma cédula falsa de 50 reais com deslocamento até 25% do comprimento, (e) Imagem gerada pelo aumento de dados de uma cédula falsa de 50 reais com deslocamento em até 25% da altura e (f) Imagem gerada pelo aumento de dados de uma cédula falsa de 50 reais com deslocamento até 25% do comprimento e desfoque utilizando um sigma entre 0 e 3.

de conhecimento para a etapa posterior de classificação. Além disso, nenhum modo de *pooling* foi escolhido e não foi necessário uma função de ativação.

Por fim, foi utilizado a implementação padrão do SIFT da biblioteca do *OpenCV* [4]. Para essa implementação, não foram fornecidas máscaras para a extração dos descritores.Na

[4] Disponível em: https://docs.opencv.org/4.x/da/df5/tutorial$_p y_s i f t_i$ntro.html, *Acessadoem* : 17*deAbr.de*2024

Tabela 8, indica-se os parâmetros utilizados no algoritmo, em negrito é indicado aqueles modificados para fins deste trabalho.

Tabela 8 – Parâmetros utilizados em cada ferramenta de extração de características.

Ferramentas	**Parâmetros**
CNN/VGG16	Pesos de treinamento inicial = *'ImageNet'* Modo pooling = nenhuma Função de ativação = nenhuma
CNN/RESNET50	Pesos de treinamento inicial = *'ImageNet'* Modo pooling = nenhuma Função de ativação = nenhuma
DWT	Família das transformadas = *haar* Extrapolação do sinal padrão = *symetric* Nível da transformada = simples (primeiro nível)
SIFT	Máscara utilizada: nenhuma

4.1.4 Classificação de características

Com as características devidamente extraídas, foram tabuladas e submetidas aos algoritmos de classificação selecionados, entre eles: SVM, KNN, Random Forest, Naive Bayes. O objetivo da classificação será classificar em cédulas verdadeiras (Classe 1) e cédulas falsas (Classe 0).

O classificador KNN, por sua vez, utilizou um número de vizinhos(k) igual à 1 e a métrica de distância entre os vizinhos foi defida como *minkowski* com p igual a 2. Além disso, os pesos dos vizinhos, inicialmente, foram atribuídos uniformemente e a função para computar os vizinhos foi atribuída como *auto*, sendo definida no momento do treinamento de acordo com os dados.

Para o algoritmo do SVM, utilizou-se a SVM de tipo C, com tipo de kernel *RBF* (radial) e grau 3 da SVM. Foi utilizado heurística de redução, mas não foi utilizado estimativas de probalidade. Foi considerado uma função de decisão *OVR*. Não foi escolhido um limite de intereções e todas as classes tiveram peso inicial igual a 1. A penalidade por redução C foi de 1 com gamma *scale*. Por fim, a tolerância de convergência do SVM foi de $1e^{-}3$.

O *Random Forest* utilizou apenas 1 estimador (uma única árvore) com profundidade máxima sendo incrementada até que as folhas estejam puras ou contenham o número mínimo de 2. Além disso, o número mínimo de amostras em uma folha é de 1, com critério de divisão *gini*, utilizando a técnica de amostragem *bootstrap*.

Por fim, o *Naive Bayes* utilizou a implementação Gausiana, com matriz de distribuição de probabilidade ajustado de acordo, com o parâmetro de suavização de 1e-9.Além

disso, para todos os algoritmos, foi utilizado a implementação do *SciKit-Learning* (COURNAPEAU, 2007) conforme Tabela 9.

Tabela 9 – Parâmetros utilizados em cada ferramenta de classificação de características.

Ferramentas	**Parâmetros**
KNN	número de vizinhos(k) = 1 distância entre os vizinhos = *minkowski* p = 2 pesos iniciais dos vizinhos = distribuição uniforme função para computar os vizinhos = *auto*
SVM	tipo do kernel = *rbf* grau = 3 heurística de redução = sim estimativas de probabilidade = não função de decisão = *ovr* limite de interações = não escolhido pesos iniciais = 1 penalidade por redução(C) = 1 *gamma* = *scale* tolerância de convergência = 1e^{-}3
Random Forest	número de estimadores = 1 profundidade máxima = até que as folhas foram puras ou mínimo de 2 mínimo de amostras por folha = 1 critério de divisão = *gini* técnica de amostragem = *bootstrap*
Naive Bayes	tipo = gausiano parâmetro de suavização = 1e-9

Após a classificação, algumas métricas foram coletadas, dentre elas: Verdadeiros Positivos, Verdadeiros Negativos, Falsos Positivos e Falsos Negativos. Com essas métricas apuradas, outras métricas foram calculadas, cujas fórmulas foram descritas na *Seção* **??**, ou seja: Acurácia, Especificidade, Precisão, *Recall* e *F1-score*.

5 Resultados e Discussão

Nas Tabelas 10,11,12 e 13 são demonstrados as métricas coletadas: acurácia, precisão, especificidade, *recall* e *f1-score* em cada abordagem. Além disso, foi evidenciando o tamanho do conjunto de treinamento atráves da coluna *"Qtd. Trein."*. Ressalta-se que os experimentos descritos no Capítulo 4 foram executados com e sem aumento de dados. Os resultados com melhores métricas estão em destaque nas tabelas abaixo.

Tabela 10 – Resultados da Experimento com descritores CNN/VGG16.

Classificador	Aumento de dados?	Qtd. Trein.	Acurácia	Precisão	Especificidade	*recall*	*f1-score*
KNN	**não**	**46**	**84,42%**	**68,84%**	**76,24%**	**100%**	**81,55%**
	sim	**184**	**86,59%**	**73,19%**	**78,86%**	**100%**	**84,52%**
	sim	**276**	**86,59%**	**74,64%**	**79,53%**	**98,01%**	**84,77%**
SVM	não	46	69,93%	100%	100%	62,44%	76,88%
	sim	186	64,49%	100%	100%	58,47%	73,80%
	sim	276	58,33%	100%	100%	54,55%	70,59%
Random Forest	não	46	57,61%	41,30%	55,74%	61,29%	49,35%
	sim	186	64,49%	60,14%	63,33%	65,87%	62,88%
	sim	276	58,70%	41,30%	56,45%	63,33%	50,00%
Naive Bayes	não	46	65,22%	94,20%	86,21%	59,63%	73,03%
	sim	186	55,80%	84,78%	63,79%	53,67%	65,73%
	sim	276	57,97%	91,30%	73,91%	54,78%	68,48%

No experimento com descritores CNN/VGG16 (*Tabela 10*), em especial os algoritmos *Random Forest* e *Naive Bayes* tiveram taxas de *recall* e especificidade bem próximas, indicando que houve uma aparente dificuldade em diferenciar as cédulas verdadeiras e falsas. Observa-se que para esses modelos, quando aplicado o aumento de dados, não significou um aumento da taxa de acurácia, ocasionando, de fato, um decréscimo. Quando se trata do algoritmo SVM, é possível perceber que existe um alto grau de Especificidade e Precisão, significando que o modelo é capaz de identificar bem as cédulas verdadeiras e consegue identificar pouco as cédulas falsas. Assim como o *Random Forest* e o *Naive Bayes*, o modelo do SVM não obteve ganho real com o aumento de dados. Por fim, o modelo KNN manteve o padrão discutido no Experimento Piloto, no que diz respeito as suas predições, e diferente dos outros classificadores, se beneficiou do aumento de dados.

A respeito do experimento com descritores CNN/RESNET50 (*Tabela 11*), obteve-se uma substancial melhora da acurácia quando comparado com as abordagens anteriores, principalmente a respeito dos modelos KNN e SVM. Para os outros modelos, não se

Tabela 11 – Resultados do Experimento com descritores CNN/RESNET50.

Classificador	Aumento de dados?	Qtd. Trein.	Acurácia	Precisão	Especificidade	*recall*	*f1-score*
KNN	não	46	96,74%	97,83%	97,78%	95,74%	96,77%
	sim	184	95,65%	97,73%	97,73%	93,75%	95,74%
	sim	276	96,38%	97,83%	97,76%	95,07%	96,43%
SVM	**não**	**46**	**97,10%**	**100%**	**100%**	**94,52%**	**97,18%**
	sim	**186**	**89,13%**	**100%**	**100%**	**82,14%**	**90,20%**
	sim	**276**	**82,25%**	**100%**	**100%**	**73,80%**	**84,92%**
Random Forest	não	46	60,87%	44,20%	58,15%	66,30%	53,04%
	sim	186	51,81%	35,51%	51,37%	52,69%	42,42%
	sim	276	53,99%	31,16%	52,74%	57,33%	40,38%
Naive Bayes	não	46	62,32%	94,93%	85,42%	57,46%	71,58%
	sim	186	56,88%	93,48%	75,68%	53,97%	68,44%
	sim	276	56,88%	94,20%	77,14%	53,94%	68,60%

pode verificar grandes diferenças de performace frente as abordagens anteriores. Ainda em comparação as abordagens anteriores, o aumento de dados não representou melhora ao modelo.

Tabela 12 – Resultados do Experimento com descritores DWT.

Classificador	Aumento de dados?	Qtd. Trein.	Acurácia	Precisão	Especificidade	*recall*	*f1-score*
KNN	não	46	59,78%	65,94%	61,16%	58,71%	51,16%
	sim	184	59,42%	71,01%	62,26%	57,65%	63,64%
	sim	276	58,70%	73,19%	62,24%	56,74%	63,92%
SVM	não	46	69,93%	94,20%	88,73%	63,41%	75,80%
	sim	186	61,23%	97,10%	89,74%	56,54%	71,47%
	sim	276	57,76%	97,10%	86,67%	54,25%	69,61%
Random Forest	não	46	49,28%	94,20%	42,86%	49,62%	65,00%
	sim	186	39,49%	27,54%	41,52%	36,19%	31,28%
	sim	276	48,55%	53,62%	48,39%	48,68%	51,03%
Naive Bayes	não	46	68,84%	92,03%	85,14%	62,87%	74,71%
	sim	186	66,67%	96,38%	91,07%	60,45%	74,30%
	sim	**276**	**80,43%**	**96,38%**	**94,66%**	**73,08%**	**83,13%**

O Experimento com descritores DWT (*Tabela 12*) demonstrou métricas de avaliação ligeramente inferiores comparadas aos seus antecessores, em especial para o KNN, SVM e o *Random Forest*. A respeito do classificador *Naive Bayes*, para essa abordagem, as métricas foram particularmente beneficiadas pelo aumento de dados, demonstrando uam

acurácia superior a 80%.

Por fim, o experimento baseada em descritores SIFT (*Tabela 13*) se demonstrou ineficaz em comparação as outras abordagens, uma vez que sua acurácia total não ultrapassou 60% no melhor caso, é possível perceber por meio da especificidade e *recall* que o modelo não consegue classificar bem nem cédulas verdadeiras, nem cédulas falsas.

Tabela 13 – Resultados do Experimento com descritores SIFT.

Classificador	Aumento de dados?	Qtd. Trein.	Acurácia	Precisão	Especificidade	*recall*	*f1-score*
KNN	não	46	50,72%	64,49%	51,00%	50,57%	56,69%
	sim	184	48,19%	36,23%	48,54%	47,62%	41,15%
	sim	276	48,19%	34,78%	48,57%	47,52%	40,17%
SVM	não	46	52,54%	20,29%	51,54%	57,14%	29,95%
	sim	186	51,09%	18,12%	50,66%	53,19%	27,03%
	sim	276	52,54%	26,09%	51,99%	55,38%	35,47%
Random Forest	não	46	50,36%	25,36%	50,24%	50,72%	33,82%
	sim	186	56,88%	63,04%	57,85%	56,13%	59,39%
	sim	276	49,64%	22,46%	49,77%	49,21%	30,85%
Naive Bayes	não	46	55,80%	57,97%	56,06%	55,56%	56,74%
	sim	186	59,42%	58,70%	59,29%	59,56%	59,12%
	sim	276	58,33%	57,25%	58,16%	58,52%	57,88%

Para as abordagens, cuja acurácia foi menor que 80%, é possível perceber uma dificuldade em diferenciar cédulas falsas e cédulas verdadeiras. Como em todas as abordagens os mesmos classificadores foram utilizados, atribuiu-se essa dificuldade ao descritor empregado. Por exemplo, os experimentos com descritores CNN/VGG16 e CNN/RESNET50, a qual, em ambos os casos, foi empregado o classificador SVM, é possível perceber uma diferença de cerca de 30%, mesmo com aumento de dados. Acredita-se que características inerentes aos modelos, como a topologia, e o conjunto de dados de pré-treinamento, foram os responsáveis pelo melhor desempenho da CNN/RESNET50 frente à CNN/VGG16.

A respeito da abordagem com descritores DWT, não foram encontrados valores de acurácia semelhantes ou próximos aos de Çelik e Kondiloğlu (ÇELIK; KONDILOğLU, 2015), de Bastuk et al. (BASTURK et al., 2021) ou de Bathia et al. (BHATIA et al., 2021), que utilizaram o conjunto de dados BAD (LOHWEG et al., 2013), frente àqueles produzidos por este trabalho, utilizando o BankNote-BR.

Ainda a respeito da abordagem DWT, percebe-se que o classificador *Naive Bayes* se beneficiou do aumento de dados planejado para o treinamento. O aumento de dados foi responsável por um ganho de acurácia, especificidade e *recall* de cerca de 10% para cada uma dessas métricas. Os dados coletados não foram capazes de justificar a diferença

de comportamento frente as outras abordagens, sendo necessários outros experimentos futuros para entender esse comportamento.

Sobre o uso do classificador *Random Forest*, esperava-se um desempenho melhor na abordagem utilizando descritores DWT, visto que a semântica relacionada aos descritores dessas abordagem deveriam favorecer um algoritmo baseado em árvore de decisão, sendo, na verdade, a abordagem com descritores CCN/VGG16 com melhores resultados para esse classificador. Apesar disso, em nenhuma das abordagens, o modelo de classificação *Random Forest* obteve acurácia maior que 65%.

Já o experimento baseado em descritores SIFT foi aquela com menor desempenho relativo, quando comparado a sua acurácia. Porém, suas métricas adjacentes justificam esses valores de acurácia com uma aparente dificuldade de diferenciar cédulas verdadeiras e cédulas falsas. O aumento de precisão e acurácia para o classificador *Naive Bayes* quando aplicado o aumento de dados, indica que um conjunto de dados maior pode ser necessário para essa abordagem.

Finalmente, as abordagens baseadas em CNN, quando utilizadas com SVM, com e sem aumento de dados, obteve o melhor desempenho deste trabalho, principalmente quando poderadas os valores de especificidade e precisão. Esses valores indicam, que apesar do modelo errar, o erro se refere ao classificar uma cédula verdadeira como falsa. Por outro lado, a abordagem baseada em CNN/RESNET50 com classificador KNN também obtive resultados "comparáveis" a abordagem com melhor desempenho, sendo a segunda com melhor desempenho. Os valores de acurácia são comparáveis ao trabalho de Hoang e Vo (HOANG; VO, 2018) que obtiveram uma acurácia 99,97%, enquanto a melhor abordagem proposta com CNN e SVM obteve 97,10 % (Tabela 11), representando uma diferença de 2,87%. Como menção honrosa, entende-se que a abordagem com descritores DWT utilizando o classificador *Naive Bayes*, quando utilizando aumento de dados, e apesar de merecer estudos adicionais, obteve o terceiro melhor desempenho, comparável a primeira abordagem.

6 Conclusões e Trabalhos Futuros

Com base nos trabalhos analisados no Capítulo 2, que trata sobre a revisão de literatura, observou-se que a aplicação de uma gama de técnicas de Visão Computacional e Aprendizagem de Máquina já foram utilizadas, porém sem considerar cédulas brasileiras. Aplicando essas técnicas a um conjunto de dados próprio com cédulas brasileiras (denominado BankNote-Br), como demonstrado no Capítulo 4, observa-se que há uma relação entre a forma como o conjunto de dados é tratado, manipulado e extraído características relevantes de cada cédula e as métricas alcançadas pelas abordagens usadas evidenciadas no Capítulo 5.

Conforme os resultados expostos anteriormente nesta dissertação, mostram que o conjunto de dados de teste, com cédulas que simulam a captura por uma pessoa com deficiência visual, são bem desafiadoras, visto que as cédulas capturadas por um deficiente visual naturalmente podem conter oclusões, entre outros problemas.

A respeito do objetivo geral deste trabalho, destacados no Capítulo 1, que consistia em propor uma abordagem em visão computacional para o reconhecimento de cédulas monetárias falsas, com resultados superiores ou equiparados ao estado da arte, foi alcançado para o conjunto de dados construído (Banknote-Br), obtendo abordagem com potencial para ser utilizado em aplicações para pessoas com deficiência visual: que utilizam o descritor CNN/RESNET50 com classificador SVM, sem aumento de dados.

Além do objetivo geral desse trabalho, cinco objetivos específicos foram destacados no Capítulo 1, sendo o primeiro objetivo específico elencado o levantamento do estado da arte e identificação dos trabalhos relevantes para reconhecimento de cédulas falsas utilizando visão computacional, alcançado por meio da Revisão de Literatura exposta no Capítulo 2. Destaca-se que esse objetivo específico produziu um trabalho submetido a Revista Brasileira de Computação Aplicada - RBCA da Universidade de Passo Fundo.

Como segundo objetivo específico, prospectou-se a possibilidade de criar um conjunto de dados de cédulas da segunda família do Real, apesar de ter sido alcançado no Capítulo 3 por meio do conjunto de dados Banknote-Br, a nova cédula de duzentos reais não foi incluída ao conjunto de dados devido à dificuldade de obtenção de exemplares. O conjunto de dados Banknote-Br conta com 368 imagens, entre verdadeiras e falsas, utilizadas na Abordagem Proposta do Capítulo 4. Além disso, novos trabalhos serão necessários a fim de expandir o conjunto de dados existente e adicionar a cédula de duzentos reais.

A fim de alcançar o terceiro objetivo específico que consistia em identificar e utilizar conjuntos de dados publicamente disponíveis de cédulas monetárias de outros países, alcançados no Capítulo 2 - Revisão de Literatura e detalhados no Capítulo 3

- Materiais e Métodos, foram encontrados três conjuntos de dados: BAD (LOHWEG et al., 2013), DITB (MESHRAM et al., 2020) e BankNote-Net (OVIEDO et al., 2022). Nenhum dos conjuntos de dados foram utilizados diretamente neste trabalho, dois dos conjuntos de dados não possuíam cédulas falsas (DITB e BankNote-Net), que dificultava alcançar o principal objetivo deste trabalho, por essa razão foram descartados para uma abordagem comparativa. Por fim, o conjunto de dados BAD possuía apenas dados tabulados, com trabalhos publicados suficientes para uma "base comparativa" com a Abordagem Proposta (Capítulo 4).

Para os Objetivos Específicos 4, desenvolver e implementar novas abordagens de reconhecimento de cédulas, e 5, realizar experimentos para validação e avaliação das abordagens propostas, foram essenciais para a conclusão do Objetivo Geral deste trabalho relatado anteriormente. Percebeu-se que a escolha de um descritor e um classificador adequados e compatíveis é essencial para bons resultados para a classificação de cédulas monetárias falsas. Em outras palavras, um descritor inadequado ao problema pode representar um problema para a classificação posterior, por melhor que seja o classificador. Além disso, percebeu-se que um processo de aumento de dados mais adequado se faz necessário.

Diante do exposto, conclui-se que o presente trabalho atingiu seus objetivos de maneira exitosa, proporcionando uma análise abrangente e aprofundada sobre a problemática de classificação de cédulas falsas, sendo necessários trabalhos futuros a fim de embarcar em um sistema wearable, como descrito no Capítulo 1, para a realização de experimentos de usabilidade e acessibilidade com pessoas com deficiência visual, por meio de métodos de interação humano-computador. Além disso, serão realizados experimentos para análise, otimização e economia do consumo de recursos do hardware wearable como bateria, memória e processamento.

No decorrer da investigação, foi possível identificar fatores cruciais e nuances que permeiam o problema específico de classificar cédulas falsas, como a limitação da relação descritor-classificador e dificuldade em reconhecer cédulas falsas devido as oclusões inerente a captura por deficiêntes visuais. Mesmo assim, a abordagem metodológica adotada revelou-se eficaz na coleta e interpretação de dados, contribuindo para uma compreensão mais sólida e embasada do tema em foco.

No entanto, é imperativo ressaltar que este estudo representa apenas uma etapa inicial no enfrentamento do desafio particular de auxiliar pessoas com deficiência visual em seu dia a dia, ao lidar com cédulas monetárias produzidas por golpistas. A complexidade inerente ao problema demanda esforços contínuos e investigações aprofundadas, visando aprimorar e expandir as descobertas apresentadas. Assim, este trabalho não apenas oferece uma contribuição valiosa para a compreensão do problema em questão, mas também estabelece uma base sólida para futuras pesquisas e ações direcionadas à resolução efetiva.

Referências

ABDI, H.; WILLIAMS, L. J. Principal component analysis. *Wiley interdisciplinary reviews: computational statistics*, Wiley Online Library, v. 2, n. 4, p. 433–459, 2010. Citado na página 11.

AGARWAL, A.; PATNI, K.; RAJESWARI, D. Lung cancer detection and classification based on alexnet cnn. In: IEEE. *2021 6th International Conference on Communication and Electronics Systems (ICCES)*. [S.l.], 2021. p. 1390–1397. Citado na página 11.

AHMED, Z. et al. Image processing based feature extraction of bangladeshi banknotes. In: *The 8th International Conference on Software, Knowledge, Information Management and Applications (SKIMA 2014)*. [S.l.: s.n.], 2014. p. 1–8. Citado 2 vezes nas páginas 14 e 21.

AL-QIZWINI, M. et al. Deep learning algorithm for autonomous driving using googlenet. In: IEEE. *2017 IEEE Intelligent Vehicles Symposium (IV)*. [S.l.], 2017. p. 89–96. Citado na página 31.

AL-SABAAWI, A. et al. Amended convolutional neural network with global average pooling for image classification. In: SPRINGER. *International Conference on Intelligent Systems Design and Applications*. [S.l.], 2020. p. 171–180. Citado na página 31.

ALASHHAB, S.; GALLEGO, A. J.; LOZANO, M. Á. Efficient gesture recognition for the assistance of visually impaired people using multi-head neural networks. *Engineering Applications of Artificial Intelligence*, Elsevier, v. 114, p. 105188, 2022. Citado na página 2.

ALBAWI, S.; MOHAMMED, T. A.; AL-ZAWI, S. Understanding of a convolutional neural network. In: IEEE. *2017 international conference on engineering and technology (ICET)*. [S.l.], 2017. p. 1–6. Citado na página 30.

ALI, M. et al. Semantic-k-nn algorithm: An enhanced version of traditional k-nn algorithm. *Expert Systems with Applications*, Elsevier, v. 151, p. 113374, 2020. Citado na página 33.

ALMISREB, A. A.; JAMIL, N.; DIN, N. M. Utilizing alexnet deep transfer learning for ear recognition. In: IEEE. *2018 Fourth International Conference on Information Retrieval and Knowledge Management (CAMP)*. [S.l.], 2018. p. 1–5. Citado na página 31.

ALZUBAIDI, L. et al. Review of deep learning: Concepts, cnn architectures, challenges, applications, future directions. *Journal of big Data*, Springer, v. 8, p. 1–74, 2021. Citado na página 30.

ANAND, M. V. et al. Gaussian naïve bayes algorithm: A reliable technique involved in the assortment of the segregation in cancer. *Mobile Information Systems*, Hindawi, v. 2022, 2022. Citado na página 34.

BAEK, S. et al. Detection of counterfeit banknotes using multispectral images. *Digital Signal Processing*, v. 78, p. 294–304, 2018. ISSN 1051-2004. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1051200418300976>. Citado 2 vezes nas páginas 17 e 21.

BALAKRISHNAMA, S.; GANAPATHIRAJU, A. Linear discriminant analysis-a brief tutorial. *Institute for Signal and information Processing*, v. 18, n. 1998, p. 1–8, 1998. Citado na página 11.

BARBOSA, C. A.; SILVA, I. A. da. Aplicativo para a plataforma ios que auxilia pessoas com deficiência visual no manuseio de cédulas de real. Universidade Presbiteriana Mackenzie, 2021. Citado na página 2.

BASTURK, A. et al. Efficient detection of counterfeit banknotes using adaptive network based fuzzy inference systems. In: *2021 13th International Conference on Electrical and Electronics Engineering (ELECO)*. [S.l.: s.n.], 2021. p. 575–579. Citado 3 vezes nas páginas 12, 21 e 46.

BAY, H. et al. Speeded-up robust features (surf). *Computer Vision and Image Understanding*, v. 110, n. 3, p. 346–359, 2008. ISSN 1077-3142. Similarity Matching in Computer Vision and Multimedia. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1077314207001555>. Citado na página 15.

BCB. *Segunda Família do Real: Cartilha de treinamento*. [S.l.]: Banco Central do Brasil, Governo do Brasil, 2013. <https://www.bcb.gov.br/novasnotas/assets/downloads/material-apoio/2e5/Cartilha.pdf>. Citado 4 vezes nas páginas 9, 2, 26 e 29.

BCB. Relatório de cidadania financeira 2018. 2018. Citado na página 1.

BELGIU, M.; DRĂGUŢ, L. Random forest in remote sensing: A review of applications and future directions. *ISPRS journal of photogrammetry and remote sensing*, Elsevier, v. 114, p. 24–31, 2016. Citado na página 12.

BELLAVIA, F.; COLOMBO, C. Is there anything new to say about sift matching? *International journal of computer vision*, Springer, v. 128, n. 7, p. 1847–1866, 2020. Citado na página 33.

BENMOUIZA, K.; CHEKNANE, A. Clustered anfis network using fuzzy c-means, subtractive clustering, and grid partitioning for hourly solar radiation forecasting. *Theoretical and Applied Climatology*, Springer, v. 137, n. 1, p. 31–43, 2019. Citado na página 12.

BHATIA, A. et al. Fake currency detection with machine learning algorithm and image processing. In: *2021 5th International Conference on Intelligent Computing and Control Systems (ICICCS)*. [S.l.: s.n.], 2021. p. 755–760. Citado 3 vezes nas páginas 12, 21 e 46.

BHELE, S. G.; MANKAR, V. et al. A review paper on face recognition techniques. *International Journal of Advanced Research in Computer Engineering & Technology (IJARCET)*, v. 1, n. 8, p. 339–346, 2012. Citado na página 16.

BOOKSTEIN, A.; KLEIN, S. T.; RAITA, T. Fuzzy hamming distance: a new dissimilarity measure. In: SPRINGER. *Annual Symposium on Combinatorial Pattern Matching*. [S.l.], 2001. p. 86–97. Citado na página 14.

BRITTO NETO, L. et al. A kinect-based wearable face recognition system to aid visually impaired users. *IEEE Transactions on Human-Machine Systems*, IEEE, v. 47, n. 1, p. 52–64, 2016. Citado na página 2.

BRITTO NETO, L. d. S. et al. A wearable face recognition system built into a smartwatch and the blind and low vision users. In: SPRINGER. *Enterprise Information Systems: 17th International Conference, ICEIS 2015, Barcelona, Spain, April 27-30, 2015, Revised Selected Papers 17*. [S.l.], 2015. p. 515–528. Citado na página 2.

BRUNO, M. M. G.; NASCIMENTO, R. A. L. d. Política de acessibilidade: o que dizem as pessoas com deficiência visual. *Educação & Realidade*, SciELO Brasil, v. 44, 2019. Citado na página 2.

BUENO, G. R.; LUCENA, T. F. R. Geração cabeça-baixa: saúde e comportamento dos jovens no uso das tecnologias móveis. *Simpósio Nacional ABCiber*, v. 9, p. 573–578, 2016. Citado na página 2.

CANNY, J. A computational approach to edge detection. *IEEE Transactions on pattern analysis and machine intelligence*, Ieee, n. 6, p. 679–698, 1986. Citado na página 15.

CARVALHO, D. V.; PEREIRA, E. M.; CARDOSO, J. S. Machine learning interpretability: A survey on methods and metrics. *Electronics*, MDPI, v. 8, n. 8, p. 832, 2019. Citado 2 vezes nas páginas 35 e 36.

CHAKRABARTY, N. et al. Flight arrival delay prediction using gradient boosting classifier. In: *Emerging technologies in data mining and information security*. [S.l.]: Springer, 2019. p. 651–659. Citado na página 12.

CHAN, K.-H.; IM, S.-K.; KE, W. Vggrenet: a light-weight vggnet with reused convolutional set. In: IEEE. *2020 IEEE/ACM 13th International Conference on Utility and Cloud Computing (UCC)*. [S.l.], 2020. p. 434–439. Citado na página 11.

CHANG, C.-C.; YU, T.-X.; YEN, H.-Y. Paper currency verification with support vector machines. In: *2007 Third International IEEE Conference on Signal-Image Technologies and Internet-Based System*. [S.l.: s.n.], 2007. p. 860–865. Citado 2 vezes nas páginas 10 e 21.

CHAUDHARI, S. et al. Performance analysis of cnn, alexnet and vggnet models for drought prediction using satellite images. In: IEEE. *2021 Asian Conference on Innovation in Technology (ASIANCON)*. [S.l.], 2021. p. 1–6. Citado na página 31.

CHAUHAN, R.; GHANSHALA, K. K.; JOSHI, R. Convolutional neural network (cnn) for image detection and recognition. In: IEEE. *2018 first international conference on secure cyber computing and communication (ICSCCC)*. [S.l.], 2018. p. 278–282. Citado na página 30.

CHOI, E.; LEE, C. Feature extraction based on the bhattacharyya distance. *Pattern Recognition*, Elsevier, v. 36, n. 8, p. 1703–1709, 2003. Citado na página 17.

CHRISTLEIN, V. et al. Deep generalized max pooling. In: IEEE. *2019 International conference on document analysis and recognition (ICDAR)*. [S.l.], 2019. p. 1090–1096. Citado na página 31.

CHUN-LIN, L. A tutorial of the wavelet transform. *NTUEE, Taiwan*, v. 21, p. 22, 2010. Citado na página 10.

COLACO, R. M. et al. Efficient image processing technique for authentication of indian paper currency. In: *2021 International Conference on Computer Communication and Informatics (ICCCI)*. [S.l.: s.n.], 2021. p. 1–8. Citado 2 vezes nas páginas 16 e 21.

CORTES, C.; VAPNIK, V. Support-vector networks. *Machine learning*, Springer, v. 20, n. 3, p. 273–297, 1995. Citado 2 vezes nas páginas 10 e 34.

COSTA, C. M.; VEIGA, G.; SOUSA, A. Recognition of banknotes in multiple perspectives using selective feature matching and shape analysis. In: *2016 International Conference on Autonomous Robot Systems and Competitions (ICARSC)*. [S.l.: s.n.], 2016. p. 235–240. Citado 2 vezes nas páginas 11 e 21.

COSTA, G. R. T. et al. O design das cédulas brasileiras do cruzeiro ao real (1970-2010). Universidade do Estado do Rio de Janeiro, 2011. Citado na página 1.

COURNAPEAU, D. *SciKit-Learning*. 2007. <https://scikit-learn.org/>. [Online; Disponível em: 31/Jan/2024]. Citado na página 43.

CUNNINGHAM, P.; DELANY, S. J. k-nearest neighbour classifiers-a tutorial. *ACM computing surveys (CSUR)*, ACM New York, NY, USA, v. 54, n. 6, p. 1–25, 2021. Citado na página 33.

CZYZEWSKI, M. A.; LASKOWSKI, A.; WASIK, S. Chessboard and chess piece recognition with the support of neural networks. *Foundations of Computing and Decision Sciences*, v. 45, n. 4, p. 257–280, 2020. Citado na página 2.

DALAL, N.; TRIGGS, B. Histograms of oriented gradients for human detection. In: IEEE. *2005 IEEE computer society conference on computer vision and pattern recognition (CVPR'05)*. [S.l.], 2005. v. 1, p. 886–893. Citado na página 16.

DARADE, S. R.; GIDVEER, G. Automatic recognition of fake indian currency note. In: *2016 International Conference on Electrical Power and Energy Systems (ICEPES)*. [S.l.: s.n.], 2016. p. 290–294. Citado 2 vezes nas páginas 11 e 21.

DENG, J. et al. Imagenet large scale visual recognition competition 2012 (ilsvrc2012). *See net. org/challenges/LSVRC*, v. 41, 2012. Citado na página 31.

DESAI, S. et al. Cnn based counterfeit indian currency recognition using generative adversarial network. In: *2021 International Conference on Artificial Intelligence and Smart Systems (ICAIS)*. [S.l.: s.n.], 2021. p. 626–631. Citado 2 vezes nas páginas 12 e 21.

DEWI, C. et al. Multinomial naïve bayes classifier for sentiment analysis of internet movie database. *Vietnam Journal of Computer Science (World Scientific)*, v. 10, n. 4, 2023. Citado na página 34.

Dias Júnior, M. A. P. *Reconhecimento de Formas Farmacêuticas Sólidas para Auxiliar Pessoas com Deficiência Visual*. Dissertação (Mestrado) — Federal University of Piauí, 2022. Citado na página 2.

DUA, D.; GRAFF, C. *UCI Machine Learning Repository*. 2017. Disponível em: <http://archive.ics.uci.edu/ml>. Citado 3 vezes nas páginas 10, 19 e 23.

EDELMAN, G. J. et al. Hyperspectral imaging for non-contact analysis of forensic traces. *Forensic science international*, Elsevier, v. 223, n. 1-3, p. 28–39, 2012. Citado na página 11.

EL-SAWY, A.; EL-BAKRY, H.; LOEY, M. Cnn for handwritten arabic digits recognition based on lenet-5. In: SPRINGER. *Proceedings of the International Conference on Advanced Intelligent Systems and Informatics 2016 2*. [S.l.], 2017. p. 566–575. Citado na página 31.

FERREIRA NETO, G. et al. Age-invariant face recognition to aid visually impaired people. In: SBC. *Anais do XVIII Encontro Nacional de Inteligência Artificial e Computacional*. [S.l.], 2021. p. 95–106. Citado na página 2.

FREIRE, M. V. Moedas sociais: contributo em prol de um marco legal e regulatório para as moedas sociais circulantes locais no brasil. 2011. Citado na página 19.

GAVRILOV, A. et al. Convolutional neural networks: Estimating relations in the ising model on overfitting. In: IEEE. *2018 IEEE 17th International Conference on Cognitive Informatics & Cognitive Computing (ICCI* CC)*. [S.l.], 2018. p. 154–158. Citado na página 31.

GIRI, K. J. et al. Dwt based color image watermarking: a review. *Multimedia Tools and Applications*, Springer, v. 79, p. 32881–32895, 2020. Citado na página 32.

HART, P. E.; DUDA, R. Use of the hough transformation to detect lines and curves in pictures. *Communications of the ACM*, v. 15, n. 1, p. 11–15, 1972. Citado na página 16.

HATWELL, J.; GABER, M. M.; AZAD, R. M. A. Chirps: Explaining random forest classification. *Artificial Intelligence Review*, Springer, v. 53, p. 5747–5788, 2020. Citado na página 35.

HOANG, V.-D.; VO, H.-T. Hybrid discriminative models for banknote recognition and anti-counterfeit. In: *2018 5th NAFOSTED Conference on Information and Computer Science (NICS)*. [S.l.: s.n.], 2018. p. 394–399. Citado 3 vezes nas páginas 11, 21 e 47.

HUANG, S. et al. Applications of support vector machine (svm) learning in cancer genomics. *Cancer genomics & proteomics*, International Institute of Anticancer Research, v. 15, n. 1, p. 41–51, 2018. Citado 2 vezes nas páginas 31 e 34.

IONESCU, M.; RALESCU, A. Fuzzy hamming distance based banknote validator. In: *The 14th IEEE International Conference on Fuzzy Systems, 2005. FUZZ '05.* [S.l.: s.n.], 2005. p. 300–305. Citado 2 vezes nas páginas 14 e 21.

JANG, J.-S. Anfis: adaptive-network-based fuzzy inference system. *IEEE transactions on systems, man, and cybernetics*, IEEE, v. 23, n. 3, p. 665–685, 1993. Citado na página 12.

KANAGARAJ, H.; MUNEESWARAN, V. Image compression using haar discrete wavelet transform. In: IEEE. *2020 5th International Conference on Devices, Circuits and Systems (ICDCS)*. [S.l.], 2020. p. 271–274. Citado na página 32.

KARADAL, C. H. et al. Automated classification of remote sensing images using multileveled mobilenetv2 and dwt techniques. *Expert Systems with Applications*, Elsevier, v. 185, p. 115659, 2021. Citado na página 32.

KATTENBORN, T. et al. Review on convolutional neural networks (cnn) in vegetation remote sensing. *ISPRS journal of photogrammetry and remote sensing*, Elsevier, v. 173, p. 24–49, 2021. Citado na página 30.

KITCHENHAM, B. A.; CHARTERS, S. *Guidelines for performing Systematic Literature Reviews in Software Engineering*. [S.l.], 2007. Disponível em: <https://www.elsevier.com/__data/promis_misc/525444systematicreviewsguide.pdf>. Citado na página 5.

KRISHNA, K.; MURTY, M. N. Genetic k-means algorithm. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, IEEE, v. 29, n. 3, p. 433–439, 1999. Citado na página 13.

KUMAR, A. A review on implementation of digital image watermarking techniques using lsb and dwt. *Information and Communication Technology for Sustainable Development: Proceedings of ICT4SD 2018*, Springer, p. 595–602, 2020. Citado na página 32.

KUNENE, D.; VADAPALLI, H.; CRONJE, J. Indoor sign recognition for the blind. In: *Proceedings of the Annual Conference of the South African Institute of Computer Scientists and Information Technologists*. [S.l.: s.n.], 2016. p. 1–9. Citado na página 2.

LAAKSONEN, J.; OJA, E. Classification with learning k-nearest neighbors. In: IEEE. *Proceedings of international conference on neural networks (ICNN'96)*. [S.l.], 1996. v. 3, p. 1480–1483. Citado na página 12.

LATIF, A. et al. Content-based image retrieval and feature extraction: a comprehensive review. *Mathematical problems in engineering*, Hindawi, v. 2019, 2019. Citado 2 vezes nas páginas 29 e 30.

LIM, H.-T.; MURUKESHAN, V. M. Hyperspectral imaging of polymer banknotes for building and analysis of spectral library. *Optics and Lasers in Engineering*, v. 98, p. 168–175, 2017. ISSN 0143-8166. Disponível em: <https://www.sciencedirect.com/science/article/pii/S014381661730091X>. Citado 2 vezes nas páginas 11 e 21.

LOHWEG, V. et al. Banknote authentication with mobile devices. In: SPIE. *Media Watermarking, Security, and Forensics 2013*. [S.l.], 2013. v. 8665, p. 47–60. Citado 5 vezes nas páginas 19, 22, 23, 46 e 49.

LOWE, D. G. Object recognition from local scale-invariant features. In: IEEE. *Proceedings of the seventh IEEE international conference on computer vision*. [S.l.], 1999. v. 2, p. 1150–1157. Citado 2 vezes nas páginas 32 e 33.

MA, W.; LU, J. An equivalence of fully connected layer and convolutional layer. *arXiv preprint arXiv:1712.01252*, 2017. Citado na página 31.

MACHADO, A. et al. A systematic review on product recognition for aiding visually impaired people. *IEEE Latin America Transactions*, IEEE, v. 19, n. 4, p. 592–603, 2021. Citado na página 2.

MACHADO, A. de L. et al. Grocery product recognition to aid visually impaired people. In: SBC. *Anais do XVII Workshop de Visão Computacional*. [S.l.], 2021. p. 94–99. Citado na página 2.

MANZALI, Y.; ELFAR, M. Random forest pruning techniques: A recent review. In: SPRINGER. *Operations Research Forum*. [S.l.], 2023. v. 4, n. 2, p. 1–14. Citado na página 35.

MARWEDEL, P. *Embedded system design: embedded systems foundations of cyber-physical systems, and the internet of things*. [S.l.]: Springer Nature, 2021. Citado na página 3.

MASWADI, K. et al. Human activity classification using decision tree and naive bayes classifiers. *Multimedia Tools and Applications*, Springer, v. 80, p. 21709–21726, 2021. Citado na página 34.

MATSUO, Y. et al. Deep learning, reinforcement learning, and world models. *Neural Networks*, Elsevier, 2022. Citado na página 2.

MESHRAM, V. et al. *Dataset of Indian and Thai Banknotes*. IEEE Dataport, 2020. Disponível em: <https://dx.doi.org/10.21227/cjb5-n039>. Citado 6 vezes nas páginas 9, 19, 22, 23, 24 e 49.

MIKA, S. et al. Fisher discriminant analysis with kernels. In: IEEE. *Neural networks for signal processing IX: Proceedings of the 1999 IEEE signal processing society workshop (cat. no. 98th8468)*. [S.l.], 1999. p. 41–48. Citado na página 13.

MOHAMMED, A. H. M.; ÇEVIK, M. Googlenet cnn classifications for diabetics retinopathy. In: IEEE. *2022 International Congress on Human-Computer Interaction, Optimization and Robotic Applications (HORA)*. [S.l.], 2022. p. 1–4. Citado na página 11.

MOHER, D. Liberati a, tetzlaff j, altman dg, group tp. *Preferred reporting items for systematic reviews and meta-analyses: the PRISMA statement. PLoS Med*, v. 6, n. 7, p. e1000097–6, 2009. Citado na página 5.

MOMBACH, J. G. Proposta de aplicativo móvel para identificação de cédulas de real por pessoas com deficiência visual. Universidade Federal do Pampa, 2015. Citado na página 1.

MORTENSEN, E. N.; DENG, H.; SHAPIRO, L. A sift descriptor with global context. In: IEEE. *2005 IEEE computer society conference on computer vision and pattern recognition (CVPR'05)*. [S.l.], 2005. v. 1, p. 184–190. Citado na página 11.

MURTHY, S.; KURUMATHUR, J.; REDDY, B. R. Design and implementation of paper currency recognition with counterfeit detection. In: *2016 Online International Conference on Green Engineering and Technologies (IC-GET)*. [S.l.: s.n.], 2016. p. 1–6. Citado 2 vezes nas páginas 15 e 21.

NARAYAN, Y. Comparative analysis of svm and naive bayes classifier for the semg signal classification. *Materials Today: Proceedings*, Elsevier, v. 37, p. 3241–3245, 2021. Citado na página 34.

NIXON, M.; AGUADO, A. *Feature extraction and image processing for computer vision*. [S.l.]: Academic press, 2019. Citado na página 29.

OLIVEIRA, É. G. de. Escola inclusiva: a tecnologia assistiva assimilação, ação e aspectos. *EmRede-Revista de Educação a Distância*, v. 9, n. 2, 2022. Citado na página 2.

OMS. *Blindness and vision impairment*. 2022. <https://www.who.int/news-room/fact-sheets/detail/blindness-and-visual-impairment>. [online] Disponível em 13 de Fev. de 2023. Citado na página 1.

OVIEDO, F. et al. Banknote-net: Open dataset for assistive currency recognition. *https://arxiv.org/pdf/2204.03738.pdf*, 2022. Citado 6 vezes nas páginas 9, 19, 22, 23, 24 e 49.

OVODOV, I. G. Optical braille recognition using object detection neural network. In: *Proceedings of the IEEE/CVF International Conference on Computer Vision*. [S.l.: s.n.], 2021. p. 1741–1748. Citado na página 2.

PAN, C.; YAN, X.; ZHENG, C. Hard margin svm for biomedical image segmentation. In: SPRINGER. *Advances in Neural Networks–ISNN 2005: Second International Symposium on Neural Networks, Chongqing, China, May 30-June 1, 2005, Proceedings, Part III 2*. [S.l.], 2005. p. 754–759. Citado na página 35.

PARK, S.; JAYARAMAN, S. Wearables: Fundamentals, advancements, and a roadmap for the future. In: *Wearable sensors*. [S.l.]: Elsevier, 2021. p. 3–27. Citado na página 3.

PATLE, A.; CHOUHAN, D. S. Svm kernel functions for classification. In: IEEE. *2013 International Conference on Advances in Technology and Engineering (ICATE)*. [S.l.], 2013. p. 1–9. Citado na página 35.

PATNAIK, S.; KUMARI, S.; MAHAPATRA, S. D. Comparison of deep cnn and resnet for handwritten devanagari character recognition. In: IEEE. *2020 IEEE 1st International Conference for Convergence in Engineering (ICCE)*. [S.l.], 2020. p. 235–238. Citado na página 11.

PHAM, T. D. et al. Deep learning-based fake-banknote detection for the visually impaired people using visible-light images captured by smartphone cameras. *IEEE Access*, v. 8, p. 63144–63161, 2020. Citado 2 vezes nas páginas 11 e 21.

POLÍCIA FEDERAL, P. d. *Polícia Federal apreende dinheiro falso*. 2023. <https://www.gov.br/pf/pt-br/assuntos/noticias/2023/01/policia-federal-apreende-dinheiro-falso>. [online] Disponível em 13 de Fev. de 2023. Citado na página 1.

PRET, R. L. O documento e a prova: ordenamento jurídico, validações diplomáticas e a arquivística. *Informação Arquivística*, v. 2, n. 2, 2014. Citado na página 3.

PRIYAM, A. et al. Comparative analysis of decision tree classification algorithms. *International Journal of current engineering and technology*, Citeseer, v. 3, n. 2, p. 334–337, 2013. Citado na página 12.

PRIYONO, A. et al. Generation of fuzzy rules with subtractive clustering. *Jurnal Teknologi*, p. 143â–153, 2005. Citado na página 12.

RAMANATHAN, R. et al. Robust feature extraction technique for optical character recognition. In: IEEE. *2009 International Conference on Advances in Computing, Control, and Telecommunication Technologies*. [S.l.], 2009. p. 573–575. Citado na página 15.

RAO, R. M. *Wavelet transforms: Introduction to theory and applications*. [S.l.]: Pearson Education India, 1998. Citado 2 vezes nas páginas 10 e 23.

RATHEE, N. et al. Feature fusion for fake indian currency detection. In: *2016 3rd International Conference on Computing for Sustainable Global Development (INDIACom)*. [S.l.: s.n.], 2016. p. 1265–1270. Citado 2 vezes nas páginas 15 e 21.

REZAEIAN, N.; NOVIKOVA, G. Persian text classification using naive bayes algorithms and support vector machine algorithm. *Indonesian Journal of Electrical Engineering and Informatics (IJEEI)*, v. 8, n. 1, p. 178–188, 2020. Citado na página 34.

RISH, I. et al. An empirical study of the naive bayes classifier. In: *IJCAI 2001 workshop on empirical methods in artificial intelligence*. [S.l.: s.n.], 2001. v. 3, n. 22, p. 41–46. Citado na página 12.

ROY, A.; HALDER, B.; GARAIN, U. Authentication of currency notes through printing technique verification. In: . New York, NY, USA: Association for Computing Machinery, 2010. (ICVGIP '10), p. 383–390. ISBN 9781450300605. Disponível em: <https://doi.org/10.1145/1924559.1924610>. Citado 2 vezes nas páginas 13 e 21.

SAKO, H. et al. Self-defense-technologies for automated teller machines. In: *International Machine Vision and Image Processing Conference (IMVIP 2007)*. [S.l.: s.n.], 2007. p. 177–184. Citado 2 vezes nas páginas 13 e 21.

SAPUTRA, P.; FIRMANSYAH, R.; IRAWAN, D. Various and multilevel of coiflet discrete wavelet transform and quadratic discriminant analysis for classification misalignment on three phase induction motor. In: IOP PUBLISHING. *Journal of Physics: Conference Series*. [S.l.], 2019. v. 1367, n. 1, p. 012049. Citado na página 32.

SAUSEN, F. S.; FROZZA, R. Aplicativo para auxiliar pessoas com deficiência visual no reconhecimento de cédulas de dinheiro em real com a técnica de redes neurais artificiais. *Revista Brasileira de Computação Aplicada*, v. 14, n. 3, p. 1–16, 2022. Citado 2 vezes nas páginas 2 e 3.

SCHULDT, C.; LAPTEV, I.; CAPUTO, B. Recognizing human actions: a local svm approach. In: IEEE. *Proceedings of the 17th International Conference on Pattern Recognition, 2004. ICPR 2004.* [S.l.], 2004. v. 3, p. 32–36. Citado na página 34.

SHOTTON, J.; BLAKE, A.; CIPOLLA, R. Contour-based learning for object detection. In: *Tenth IEEE International Conference on Computer Vision (ICCV'05) Volume 1*. [S.l.: s.n.], 2005. v. 1, p. 503–510 Vol. 1. Citado na página 15.

SIFAOU, H.; KAMMOUN, A.; ALOUINI, M.-S. Phase transition in the hard-margin support vector machines. In: IEEE. *2019 IEEE 8th International Workshop on Computational Advances in Multi-Sensor Adaptive Processing (CAMSAP)*. [S.l.], 2019. p. 415–419. Citado na página 35.

SILVA, C. et al. *StArt (State of the Art through Systematic Review)*. [S.l.]: Versão, 2010. Citado na página 5.

SILVA, J. M. et al. Facial expression recognition to aid visually impaired people. In: SBC. *Anais do XVII Workshop de Visão Computacional*. [S.l.], 2021. p. 48–53. Citado na página 2.

SILVA, K. W.; AIRES, K. R.; NETO, L. d. S. B. *Open Dataset for Recognition of Brazilian Counterfeit Banknotes(BankNote-Br)*. AVC Lab, UFPI - Universidade Federal do Piauí, 2024. Disponível em: <https://github.com/KenadAraujo/banknote-br>. Citado 2 vezes nas páginas 25 e 38.

SINGH, A. Impact of demonetization on indian economy. *International Journal of Engineering and Management Research (IJEMR)*, Vandana Publications, v. 7, n. 3, p. 785–788, 2017. Citado na página 1.

SINGH, M.; OZARDE, P.; ABHIRAM, K. Image processing based detection of counterfeit indian bank notes. In: *2018 9th International Conference on Computing, Communication and Networking Technologies (ICCCNT)*. [S.l.: s.n.], 2018. p. 1–5. Citado na página 12.

SOUSA, L. P. d. et al. Metodologia de identificação de cédulas monetárias para deficientes visuais. *Revista de Sistemas e Computação-RSC*, v. 8, n. 1, 2018. Citado na página 2.

SOUSA, L. P. d. et al. Evaluation of banknote identification methodologies based on local and deep features. *International Journal of Innovative Computing and Applications*, v. 14, p. 34–45, 2023. Citado na página 2.

SUMALATHA, R.; REDDY, B. J.; REDDY, T. V. R. Identification of fake indian currency using convolutional neural network. In: *2022 6th International Conference on Computing Methodologies and Communication (ICCMC)*. [S.l.: s.n.], 2022. p. 1619–1623. Citado 2 vezes nas páginas 12 e 21.

SZARVAS, M. et al. Pedestrian detection with convolutional neural networks. In: IEEE. *IEEE Proceedings. Intelligent Vehicles Symposium, 2005.* [S.l.], 2005. p. 224–229. Citado 2 vezes nas páginas 11 e 30.

TAKEDA, F.; OMATU, S. High speed paper currency recognition by neural networks. *IEEE Transactions on Neural Networks*, IEEE, v. 6, n. 1, p. 73–77, 1995. Citado na página 10.

TANAKA, N.; FUJINAMI, K. A projector-camera system for augmented card playing and a case study with the pelmanism game. *EAI Endorsed Transactions on Ambient Systems*, European Alliance for Innovation (EAI), v. 4, n. 13, 2017. Citado na página 2.

TARG, S.; ALMEIDA, D.; LYMAN, K. Resnet in resnet: Generalizing residual architectures. *arXiv preprint arXiv:1603.08029*, 2016. Citado na página 31.

TOO, J.; ABDULLAH, A. R.; SAAD, N. M. Classification of hand movements based on discrete wavelet transform and enhanced feature extraction. *International Journal of Advanced Computer Science and Applications*, Science and Information (SAI) Organization Limited, v. 10, n. 6, 2019. Citado na página 32.

TORRES, J. P.; COSTA, C. S. L. d.; LOURENÇO, G. F. Substituição sensorial visuo-tátil e visuo-auditiva em pessoas com deficiência visual: uma revisão sistemática. *Revista Brasileira de Educação Especial*, SciELO Brasil, v. 22, p. 605–618, 2016. Citado na página 2.

TRABELSI, R.; NOURI, K.; AMMARI, I. Enhancing traffic sign recognition through daubechies discret wavelet transform and convolutional neural networks. In: IEEE. *2023 IEEE International Conference on Advanced Systems and Emergent Technologies (IC_ASET)*. [S.l.], 2023. p. 1–6. Citado na página 32.

TU, Z. et al. A survey of variational and cnn-based optical flow techniques. *Signal Processing: Image Communication*, Elsevier, v. 72, p. 9–24, 2019. Citado na página 30.

UDDIN, M. S.; DAS, P. P.; RONEY, M. S. A. Image-based approach for the detection of counterfeit banknotes of bangladesh. In: *2016 5th International Conference on Informatics, Electronics and Vision (ICIEV)*. [S.l.: s.n.], 2016. p. 1067–1072. Citado 2 vezes nas páginas 16 e 21.

UPADHYAYA, A.; SHOKEEN, V.; SRIVASTAVA, G. Analysis of counterfeit currency detection techniques for classification model. In: *2018 4th International Conference on Computing Communication and Automation (ICCCA)*. [S.l.: s.n.], 2018. p. 1–6. Citado 2 vezes nas páginas 11 e 21.

VAIDYA, G.; VAIDYA, K.; BHOSALE, K. Text recognition system for visually impaired using portable camera. In: IEEE. *2020 International Conference on Convergence to Digital World-Quo Vadis (ICCDW)*. [S.l.], 2020. p. 1–4. Citado na página 2.

VALVO, A. L. et al. A navigation and augmented reality system for visually impaired people. *Sensors*, MDPI, v. 21, n. 9, p. 3061, 2021. Citado na página 2.

VIRAKTAMATH, S. V. et al. Review on detection of fake currency using image processing techniques. In: *2021 5th International Conference on Intelligent Computing and Control Systems (ICICCS)*. [S.l.: s.n.], 2021. p. 865–870. Citado 2 vezes nas páginas 9 e 19.

VISHWAKARMA, D. K. et al. Comparative analysis of deep convolutional generative adversarial network and conditional generative adversarial network using hand written digits. In: IEEE. *2020 4th International Conference on Intelligent Computing and Control Systems (ICICCS)*. [S.l.], 2020. p. 1072–1075. Citado na página 12.

WAREECHOL, T.; CHIRACHARIT, W. Recognition of similar gait pattern using transfer learning darknet. In: IEEE. *2021 9th International Electrical Engineering Congress (iEECON)*. [S.l.], 2021. p. 381–384. Citado na página 12.

WEI, Y. et al. Interactive offline tracking for color objects. In: *2007 IEEE 11th International Conference on Computer Vision*. [S.l.: s.n.], 2007. p. 1–8. Citado na página 15.

WRIGHT, R. E. Logistic regression. American Psychological Association, 1995. Citado na página 11.

WU, J. et al. A comparative study of sift and its variants. *Measurement science review*, v. 13, n. 3, p. 122–131, 2013. Citado na página 33.

WU, Q.; ZHOU, D.-X. Svm soft margin classifiers: linear programming versus quadratic programming. *Neural computation*, MIT Press One Rogers Street, Cambridge, MA 02142-1209, USA journals-info . . . , v. 17, n. 5, p. 1160–1187, 2005. Citado na página 35.

YADAV, A. et al. Evaluation of machine learning algorithms for the detection of fake bank currency. In: *2021 11th International Conference on Cloud Computing, Data Science Engineering (Confluence)*. [S.l.: s.n.], 2021. p. 810–815. Citado 2 vezes nas páginas 12 e 21.

YEH, C.-Y.; SU, W.-P.; LEE, S.-J. Employing multiple-kernel support vector machines for counterfeit banknote recognition. *Applied Soft Computing*, v. 11, n. 1, p. 1439–1447, 2011. ISSN 1568-4946. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1568494610000918>. Citado 2 vezes nas páginas 14 e 21.

YU, D. et al. Mixed pooling for convolutional neural networks. In: SPRINGER. *Rough Sets and Knowledge Technology: 9th International Conference, RSKT 2014, Shanghai, China, October 24-26, 2014, Proceedings 9*. [S.l.], 2014. p. 364–375. Citado na página 31.

YU, X. et al. A gridding hough transform for detecting the straight lines in sports video. In: *2005 IEEE International Conference on Multimedia and Expo*. [S.l.: s.n.], 2005. p. 4 pp.–. Citado na página 15.

ZARIN, A.; UDDIN, J. A hybrid fake banknote detection model using ocr, face recognition and hough features. In: *2019 Cybersecurity and Cyberforensics Conference (CCC)*. [S.l.: s.n.], 2019. p. 91–95. Citado 2 vezes nas páginas 16 e 21.

ZHANG, C.-L. et al. In defense of fully connected layers in visual representation transfer. In: SPRINGER. *Pacific Rim Conference on Multimedia*. [S.l.], 2017. p. 807–817. Citado na página 31.

ZHENG, G.; HAN, G.; SOOMRO, N. Q. An inception module cnn classifiers fusion method on pulmonary nodule diagnosis by signs. *Tsinghua Science and Technology*, TUP, v. 25, n. 3, p. 368–383, 2019. Citado na página 31.

ZHOU, J. et al. Evaluating the quality of machine learning explanations: A survey on methods and metrics. *Electronics*, MDPI, v. 10, n. 5, p. 593, 2021. Citado 2 vezes nas páginas 35 e 36.

ÇELIK, E.; KONDILOğLU, A. Detection of fake banknotes with artificial neural networks and support vector machines. In: *2015 23nd Signal Processing and Communications Applications Conference (SIU)*. [S.l.: s.n.], 2015. p. 1317–1320. Citado 5 vezes nas páginas 10, 11, 12, 21 e 46.