

ARTIGO ORIGINAL

Uma revisão sistemática sobre o reconhecimento de cédulas bancárias falsas por meio de visão Computacional

A systematic review on the recognition of counterfeit banknotes using computer vision

Kenad Wanderson Araújo Silva ¹, Kelson Romulo Teixeira Aires ¹, Laurindo de Sousa Britto Neto ¹

¹Departamento de Computação/Universidade Federal do Piauí – DC/UFPI

*kenadwanderson@gmail.com; {kelson, laurindoneto}@ufpi.edu.br

Recebido: 24/11/2023. Revisado: 07/07/2024. Aceito: 31/07/2024.

Resumo

A falsificação de cédulas é um problema real que afeta o mundo inteiro, especialmente as pessoas com deficiência visual e as pessoas sem acesso ao sistema financeiro. Neste trabalho, foi realizada uma revisão sistemática da literatura sobre o reconhecimento de cédulas bancárias falsas com o objetivo de levantar o estado da arte atual, respondendo à seguinte questão de pesquisa: “*Quais abordagens em visão computacional foram utilizadas para reconhecer notas falsas?*”. Como resultado, esta revisão de literatura selecionou 25 artigos, que passaram por critérios de inclusão e exclusão e foram sumarizados de acordo com o ano de publicação, a moeda utilizada e a abordagem utilizada. Finalmente, uma análise desses resultados foi realizada, apresentando perspectivas para pesquisas futuras. Além disso, este artigo descreve alguns conjuntos de dados relatados pela literatura, que contêm imagens de notas falsas e genuínas disponíveis ao público.

Palavras-Chave: Reconhecimento de Cédulas Bancárias Falsas; Pessoas com Deficiência Visual; Visão Computacional.

Abstract

Counterfeiting of banknotes is a real problem that affects the entire world, especially people with visual impairments and those without access to the financial system. In this study, a systematic literature review was conducted on the recognition of counterfeit banknotes with the aim of assessing the current state of the art, addressing the following research question: “*What computer vision approaches have been used to recognize counterfeit banknotes?*”. As a result, this literature review selected 25 articles that underwent inclusion and exclusion criteria and were summarized based on the year of publication, the currency used, and the approach employed. Finally, an analysis of these results was performed, presenting perspectives for future research. Additionally, this article describes some datasets reported in the literature containing images of counterfeit and genuine banknotes available to the public.

Keywords: Counterfeit Banknotes Recognition; Visually Impaired People; Computer Vision

1 Introdução

A falsificação de cédulas monetárias é um crime comum tanto no Brasil quanto no mundo. A conduta de fabricar cé-



Figura 1: Exemplo de alguns atributos de segurança ocultos em cédulas monetárias de Real, que se tornam visíveis quando expostos à luz negra (Diário do Nordeste, 2019).

dulas falsas ou adulterar cédulas verdadeiras é definida como crime no código penal brasileiro, de acordo com o Artigo 289, com pena máxima de 12 anos de prisão e multa (Planalto Federal do Brasil, 1940).

Entretanto, em 2022, o Banco Central do Brasil (BCB) divulgou, por meio dos seus dados abertos, um volume alarmante de 353.396 unidades de cédulas falsificadas, equivalente a 28,78 milhões de reais (BCB, 2022). Mais recentemente, em 2023, a Polícia Federal (PF) do Brasil, com auxílio dos Correios do Brasil, prendeu em flagrante um indivíduo ao receber envelopes contendo cédulas falsas por meio do sistema postal (Polícia Federal do Brasil, 2023).

O grande volume de notas falsas em circulação causa problemas à população em geral, que tem dificuldade em identificar as cédulas adulteradas, devido à profissionalização da confecção do dinheiro falso pelo crime organizado (Costa et al., 2011). Por esse motivo, diversos países enfrentam problemas com a adulteração de suas cédulas monetárias, levando, em 2016, a Índia a retirar de circulação parte de sua moeda devido à falsificação (Singh, 2017).

Além disso, pessoas com deficiência, especialmente a deficiência visual, são alvos constante de golpes com moedas falsas. Isso acontece em virtude das limitações impostas pela deficiência visual, que dificultam a verificação dos atributos de segurança das cédulas monetárias (Mombach, 2015). Entretanto, até mesmo pessoas sem qualquer deficiência podem se sentir excluídas das tecnologias oferecidas pela rede bancária para identificar se suas cédulas são válidas. Afinal, ainda em 2017, 86,5% da população brasileira mantinha algum relacionamento bancário (BCB, 2018). A Fig. 1 apresenta alguns atributos de segurança ocultos em cédulas monetárias de Real, que se tornam visíveis quando expostos à luz negra, onde alguns elementos fluorescentes são aparentes.

No final de 2022, a Organização Mundial de Saúde (World Health Organization – WHO) (OMS, 2022) indicou que existem cerca de 2,2 bilhões de pessoas com deficiência visual. Dessas, aproximadamente um bilhão poderiam ter evitado a deficiência visual com algum tratamento ou ainda precisa ser tratada (OMS, 2022). Estima-se que, entre os casos tratáveis, existam 88,4 milhões de pessoas

com cegueira ou deficiência visual moderada ou grave, devido a erros refrativos não corrigidos, 94 milhões com catarata, 8 milhões com degeneração macular relacionada à idade, 7,7 milhões com glaucoma, 3,9 milhões com retinopatia diabética e 826 milhões com deficiência visual de perto causada pela presbiopia não tratada (OMS, 2022).

Essa quantidade de pessoas com deficiência visual levou à criação da Lei Brasileira de Inclusão (LBI), que estabelece mecanismos para mitigar as limitações enfrentadas por pessoas com deficiência. Esses mecanismos são frequentemente chamados de Tecnologias Assistivas (TA) (Bruno e Nascimento, 2019).

As TAs são ferramentas que auxiliam as pessoas com deficiência, como por exemplo, produtos, equipamentos, dispositivos, entre outros (de Oliveira, 2022). TAs equipadas com câmeras podem utilizar abordagens de visão computacional para retornar a informação necessária ao usuário para realização de uma atividade cotidiana. Isso é realizado por meio de *feedbacks* táteis ou auditivos, de forma que ele consiga realizar tal tarefa de forma independente (de Oliveira, 2022).

Várias abordagens na literatura científica com várias 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 (Lo Valvo et al., 2021), traduzir informações textuais (e.g., texto (Vaidya et al., 2020), braille (Ovodov, 2021), placas e sinais (Kunene et al., 2016), etc.), reconhecer gestos (Alashhab et al., 2022), reconhecer e localizar pessoas (Britto Neto et al., 2015, 2016), reconhecer expressões faciais para auxiliá-las na comunicação não verbal (Silva et al., 2021), reconhecer diversos tipos objetos (e.g., produtos de mercearia (Machado, Veras, Aires e Britto Neto, 2021; Machado, Aires, Veras e Britto Neto, 2021); jogos analógicos, como xadrez (Czyzewski et al., 2020), baralho (Tanaka e Fujinami, 2017), etc.; reconhecer comprimidos, drágeas e cápsulas para evitar a ingestão errada de medicamentos (Chang et al., 2019; Dias Júnior, 2022); além da identificação das denominações de cédulas monetárias (Sousa et al., 2018, 2023)), dentre outras.

Entretanto, o foco deste trabalho é fazer uma revisão sistemática das abordagens em visão computacional relacionadas ao reconhecimento de cédulas falsas, para, futuramente, ser desenvolvida uma abordagem em visão computacional que auxilie, principalmente, pessoas com deficiência visual, mas também qualquer pessoa que tenha a necessidade de reconhecer de cédulas monetárias falsas ou verdadeiras.

O BCB, 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 et al., 2016), seguindo a tendência de outras cédulas monetárias como o Euro. Porém, essa abordagem se mostrou ineficiente para auxiliar no reconhecimento de cédulas falsas (Barbosa e da 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 e Lucena, 2016), tornou-se possível o emprego de soluções de visão computacional e outras abordagens com o objetivo de identificar cédulas falsas de forma acessível (Sausen e Frozza, 2022). Um

exemplo notável são as abordagens baseadas em Aprendizado Profundo (*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 às necessidades das pessoas com deficiência visual é necessário incorporar a abordagem em visão computacional a um dispositivo *wearable* (Park e 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 e 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, por exemplo, 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 em visão computacional 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 TVs*, *smartbands* e *smartwatches*.

O restante deste artigo está organizado da seguinte forma: a Seção 2 detalha a metodologia utilizada nesta revisão sistemática da literatura; a Seção 3 apresenta os resultados desta revisão; a Seção 4 descreve os conjuntos de dados encontrados nos resultados da revisão, que estão disponíveis publicamente; a Seção 5 analisa e discute os resultados encontrados; e, finalmente, a Seção 6 conclui este trabalho.

2 Metodologia da Revisão Sistemática

No desenvolvimento desta revisão de literatura foi utilizada a ferramenta *State of the Art through Systematic Review* (StArt) (Silva et al., 2010) para organizar os dados necessários para uma revisão sistemática baseada nas diretrizes de Kitchenham e Charters (Kitchenham e Charters, 2007) e na metodologia *Preferred Reporting Items for Systematic Reviews and Meta-Analyses* (PRISMA) (Moher, 2009). A metodologia foi dividida em cinco etapas, a saber:

- i. **Planejamento:** Definição das questões de pesquisa e das palavras de busca com base na temática do trabalho, além da definição dos critérios de seleção;
- ii. **Execução:** Execução da busca em si, utilizando as bibliotecas digitais (bases bibliográficas);
- iii. **Seleção:** Seleção dos artigos úteis à pesquisa, lendo as partes principais do trabalho e utilizando os critérios de inclusão e exclusão;
- iv. **Extração:** Leitura do trabalho completo com a aplicação dos critérios de inclusão e exclusão novamente, para

reafirmar a relevância para as questões de pesquisa;

v. **Sumarização:** Catalogação e tabulação dos resultados encontrados.

2.1 Definição das Questões de Pesquisa

Durante a revisão da literatura, procurou-se responder a seguinte questão principal da pesquisa: “Quais abordagens em visão computacional foram utilizadas para o reconhecimento de cédulas monetárias falsas?”. Com base na questão de pesquisa inicial, foram elaboradas outras perguntas, que foram aplicadas a cada um dos artigos selecionados na etapa posterior.

- i. Qual a abordagem proposta?
- ii. Quais experimentos foram realizados?
 - a. Quais conjuntos de dados foram utilizados?
 - 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?
- iii. Quais as abordagens com melhores resultados?

Com base nas questões de pesquisas, procurou-se identificar os trabalhos com os melhores resultados, suas vantagens, desvantagens e quais conjuntos de dados foram utilizados, para fornecer um ponto de partida para pesquisadores iniciantes nesta temática.

2.2 Definição das Palavras-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 Xplore (IEEE) (IEEE, 2022), ACM Digital Library (ACM) (ACM, 2022) e ScienceDirect (ScienceDirect, 2022) da Elsevier foram selecionadas pelo volume de seus acervos e relevância no campo de Ciência da Computação. Ao final, os resultados foram importados na ferramenta StArt, que auxiliou no trabalho de identificar artigos científicos duplicados, facilitando o processo de triagem.

2.3 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 técnicas de Visão Computacional à identificação e classificação de cédulas falsas. Devido a singularidade do tema, a busca incluiu cédulas estrangeiras e nacionais. Para isso, as buscas foram feitas em inglês, utilizando termos como “banknotes” e “detection” que significam, respectivamente, “cédulas bancárias” e “detecção”, conforme demonstrado na Tabela 1.

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 es-

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"

tão constantemente incrementando seus acervos. A Fig. 2 mostra 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.

**Figura 2:** Artigos identificados por base bibliográfica.**Tabela 2:** Resultados iniciais da busca

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

2.4 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.

2.4.1 Critérios de inclusão

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


2.4.2 Critérios de exclusão

- Não ter acesso ao artigo completo;
- Tratar apenas de detecção de cédulas monetárias;
- Não ter uma abordagem em visão computacional.

2.5 Processo de Seleção dos Estudos

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

Conforme a Fig. 3, na etapa de triagem, 32 (40%) resultados foram aceitos e 48 (60%) foram rejeitados, sendo que entre os 32 resultados, apenas 25 (78,1%) foram aceitos segundo os critérios de inclusão e exclusão. Não foram identificados resultados duplicados.

**Figura 3:** Artigos aceitos e rejeitados no processo de triagem.

2.6 Extração dos Dados e Sumarização

Durante a etapa de extração, continuou-se a aplicar os critérios de inclusão e exclusão. Adicionalmente, foram inspecionadas as referências de cada trabalho em busca de trabalhos adicionais que pudessem ser relevantes à revisão.

Após a leitura completa, dos 32 artigos, a base IEEE resultou em 21 estudos aceitos. A base ACM teve apenas um resultado aceito. A base ScienceDirect resultou em três artigos. Com isso, um total de 25 (78,1%) artigos foram aceitos, ocorrendo em todos os critérios de inclusão e nenhum de exclusão, conforme demonstrado pela Fig. 4, com 78,1% dos artigos aceitos.

3 Resultados da Revisão Sistemática

Dentre os artigos aceitos por esta revisão foi selecionada e analisada, primeiramente, uma outra revisão de literatura, escrita por Viraktamath et al. (2021), sobre o uso de técnicas de Processamento Digital de Imagens (PDI) para o reconhecimento de cédulas bancárias falsas. Apesar do trabalho selecionado ser recente e ter a temática no contexto desta revisão, os autores não realizaram uma abordagem




Figura 4: Artigos aceitos e rejeitados no processo de extração.

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 no trabalho de Viraktamath et al. (2021) 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 ao trabalho realizado por 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. 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 auto-relevo, 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, são evidenciadas essas preferências, observando que pouquíssimos trabalhos se mostraram interessados em mesclar essas características. Nesta seção, os resultados da revisão sistemática foram categorizados de acordo com a estratégia utilizada pela abordagem proposta do trabalho selecionado, sendo relatados em ordem cronológica.

Tabela 3: Categorização pela estratégia de extração utilizada.

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

3.1 Holísticas

Chang et al. (2007) utilizaram *Support Vector Machine* (SVM) (Cortes e Vapnik, 1995) e *Neural Networks* (NN) (Takeda e 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 publicamente.

O artigo de Çelik e 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 e Graff, 2017; UDI, 2013). O conjunto de dados utilizado foi resultado do algoritmo de compressão *Wavelet Transformed* (Chun-Lin, 2010) com 1372 amostras das cédulas de KBA-NotaSys Flowerpower (KBA-NF) (Bauer, 2010). Para o algoritmo SVM foi alcançada uma acurácia de 93,8%. Já para NN foi alcançada uma acurácia de 74,6%.

O artigo de Costa et al. (2016) foi o único trabalho dentre os selecionados que usou o descritor *Scale-Invariant Feature Transform* (SIFT) (Mortensen et al., 2005) como mecanismo de extração de características, utilizando algoritmos de reconhecimento de padrão baseado na comparação dos descritores 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 (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 e 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 (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 (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 et al. (2018) apresentou uma comparação entre Regressão Logística (*Logistic Regression* - LR) (Wright, 1995) e *Linear Discriminant Analysis* (LDA) (Balakrishnama e 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 (2015).

O trabalho de 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 das cédulas e submetidas ao CNN e posteriormente classificadas. Foram utilizado quatro arquiteturas de CNN (AlexNet (Agarwal et al., 2021), ResNet (Patnaik et al., 2020), GoogleNet (Mohammed e Çevik, 2022) e VGGNet (Chan et al., 2020)), executando quatro testes, sendo que a ResNet apresentou a melhor acurácia média com 99,16%.

O trabalho de Basturk et al. (2021) utilizou o mesmo conjunto de dados de Çelik e Kondiloğlu (2015), resultado do algoritmo de compreensão DWT, sendo submetidos a um algoritmo de classificação denominado *Adaptive 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 e Cheknane, 2019), alcançando uma acurácia média de 99,94% para o primeiro e 100% para o segundo.

A abordagem de Bhatia et al. (2021) fez uma comparação entre três algoritmos de classificação, extraíndo informações de impressão das cédulas indianas e tailandesas. Eles utilizaram o mesmo conjunto de dados de Çelik e Kondiloğlu (2015). Os algoritmos utilizados foram o *K-Nearest Neighbors* (KNN) (Laaksonen e 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. (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 et al., 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 et al., 2018), com *recall* = 90%, *precisão* = 94,74% e *F1-score* = 92,30%.

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

O trabalho de Sumalatha et al. (2022) utilizou 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 (Warechol e 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%.

3.2 Características Morfológicas

O trabalho de 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, pois o objetivo era aceitar documentos que se pareçam com cédulas bancárias, não necessariamente genuínas. 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 Analyses* (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 et al. (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 e 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 et al. (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%.

3.3 Características de Segurança

O trabalho de Ionescu e Ralescu (2005) utilizaram uma abordagem baseada no algoritmo *Fuzzy Hamming Distance* (FHD) (Bookstein et al., 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 Dólar, 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 *threshold* 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. (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 et al., 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. (2016) também usaram características da impressão de segurança de cédulas indianas. Eles 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 características 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 et al. (2016) propuseram uma abordagem baseada em PDI tanto para o reconhecimento da denominação da moeda, quanto para a detecção de características de segurança da cédula para verificação se o exemplar de estudo é verdadeiro ou falso. Os autores utilizaram, como conjunto de dados de referência, dez amostras de cédulas indianas de cada denominação, não deixando publicamente disponível. De cada amostra, 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 testes 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; respectiva-

Tabela 4: Resumo da Revisão Sistemática

Trabalhos	Abordagens	Dados	Comparações	Métricas
Ionescu e Ralescu (2005)	FHD	Próprio, Dólar	Sem	Sem
Chang et al. (2007)	SVM+NN	Próprio, Taiwan	Sem	99,01% de acurácia
Sako et al. (2007)	FDA	Próprio	Sem	Falsos Negativos < 1%
Roy et al. (2010)	K-means, SVM, LDA	Próprio, Indiana	Sem	Acurácia média: SVM = 99,9% e LDA = 93%
Yeh et al. (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 e Kondiloğlu (2015)	SVM, NN	UCI, KBA-NF	SVM, NN	Acurácia: SVM = 93,88% e NN = 74,6%
Costa et al. (2016)	SIFT	Próprio, Euro	Sem	Reconheceu 95 cédulas em 80 imagens
Darade e Gidveer (2016)	PCA	Próprio, Indiana	Sem	Acurácia de 100%
Murthy et al. (2016)	Técnicas de PDI, OCR	Próprio, Indiana	Sem	100% de acurácia para denominação e 90% para autenticidade
Rathees et al. (2016)	MSE	Próprio, Indiana	Sem	100% de acurácia
Uddin et al. (2016)	SVM	Próprio, Taka bengali	Sem	100% de acurácia
Lim e 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 e Vo (2018)	CNN+SVM	Próprio, Vietnã	Sem	Acurácia de 99,97%
Upadhyaya et al. (2018)	LR e LDA	UCI, KBA-NF	LR e LDA	Acurácia média: LR = 99,2% e LDA = 98,1%
Zarin e Uddin (2019)	SVM	Próprio, Bangladesh	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, KBA-NF	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, KBA-NF	SVM, RF, LR, NB, DT, KNN	Melhor acurácia: KNN = 99,75%
Sumalatha et al. (2022)	CNN	Próprio, Indiana	AlexNet, Resnet, Googlenet e Darknet53	Melhor acurácia: Resnet = 80,94%

mente. 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 et al. (2016) também considerou as características da impressão de segurança (utilizando três características: 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 e 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 bengali* (Bangladesh) como conjunto de dados, porém não se encontra publicamente disponível.

A abordagem de Zarin e Uddin (2019) se baseou na extração de características de impressão de segurança, utilizando OCR, Transformada de Hough (Hart e Duda, 1972) e Reconhecimento de Face (Bhele 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 Bangladesh, porém não se encontra publicamente disponível.

O trabalho de 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 Rúpias 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 largura 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 características devem ser correspondidas corretamente, caso contrário a cédula é falsa. Por fim, as características extraídas são comparadas, por meio de uma correspondência, com as características 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.

3.4 Híbridas

Baek et al. (2018) utilizaram a maior variedade de cédulas bancárias: o Euro (União Europeia), a Rúpia (Indiana) e o Dólar Americano. A abordagem dos autores foram divididas em três classificações distintas, sendo necessária que a cédula seja considerada 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 e 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 e utilizava a junção das características das etapas anteriores em um último esforço de classificar as cédulas. Os autores alcançaram 99,8% de acurácia para notas falsas e 100% para notas genuínas, utilizando um conjunto de dados cuja a quantidade de cédulas totais não foi especificada e nem está publicamente disponível.

Tabela 5: 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 ¹ (Meshram et al., 2020)	3.000	Não especificado	3.000	Indianas, Tailandesas
BankNote-Net ¹ (Oviedo et al., 2022)	24.861	Não especificado	24.861	Múltiplas nacionalidades (17 países)

¹Conjunto de dados composto unicamente por cédulas verdadeiras, sendo que os autores que utilizarem esse conjunto de dados devem confeccionar suas próprias cédulas falsas.

A **Tabela 4** 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 4**, 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.

4 Conjuntos de Dados

No decorrer da revisão sistemática indicada na seção anterior, foram encontrados dois conjuntos de dados utilizados nos trabalhos selecionados e que estão disponíveis publicamente. O primeiro fornecido por [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. \(2020\)](#) 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 5** sumariza os conjuntos de dados encontrados nesta revisão.

4.1 Banknote Authentication Dataset (BAD)

O conjunto de dados de [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 doado ao Repositório de Aprendizagem de Máquina UCI (*UCI Machine Learning Repository*) ([Dua e 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 400 × 400 pixels.



(a)



(b)

Figura 5: 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](#)).



Figura 6: 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).

Os dados tabulados possuem quatro características e uma classe, totalizando cinco atributos. As quatro características são: variância (*variance*), assimetria (*skewness*), curtose (*kurtosis*) 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.

4.2 Dataset of Indian And Thai Banknotes (DITB)

O conjunto de dados de 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 cédulas 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 cédulas novas e antigas.

Na Fig. 5 foram apresentadas dois exemplos do conjunto de dados. A Fig. 5a representa uma cédula de 500 Rúpias, denominada como *antiga* pelo autor. A Fig. 5b representa uma nota de 50 Baht tailandeses. Em ambas as figuras é possível verificar um fundo variado multicolorido em um ambiente bem iluminado.

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

O conjunto de dados de 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 AI¹ com o objetivo de gerar um modelo para reconhecimento de cédulas monetárias para a assistência de pessoas com deficiência visual ou de baixa visão. 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, nem se existiam exemplares de moedas falsas. Na Fig. 6 temos duas amostras extraídas do conjunto de dados, sendo a Fig. 6a, uma cédula de 20 coroas suecas com oclusão parcial, e a Fig. 6b de 100 coroas suecas também com oclusão parcial.

5 Discussão

Após a leitura de cada trabalho, foi realizada a sumarização dos dados conforme a seguir: a estratégia na extração de características (descrito na Seção 3), o ano de publicação, os algoritmos de classificação, as moedas utilizadas e o conjunto de dados.

Tabela 6: Categorização pela abordagem utilizada.

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

Conforme a Fig. 7, 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

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




Figura 7: Interesse por ano de publicação dos trabalhos.

2021.

A respeito do algoritmo de classificação, os resultados foram divididos em categorias, de acordo com as abordagens utilizadas, sendo sumarizadas na Tabela 6. 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 6 podem ter utilizado mais de uma abordagem.

Além disso, analisando os conjuntos de dados dos trabalhos, segundo o qual consta no gráfico da Fig. 8, 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 Fig. 8.

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. (2013) ao UCI Machine Learning (Dua e 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. (2020), e citado por um trabalho, que atualmente possui 3000 imagens de cédulas indianas e tailandesas (2000 indianas e 1000 tailandesas), capturas de smartphones, de diferentes denominações, iluminação e planos de fundo diversos. 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




Figura 8: Categorização pela origem da moeda utilizada.

expressão de valor impresso na cédula monetária (Freire, 2011).

6 Conclusão

A metodologia adotada para revisão da literatura proporcionou uma análise abrangente, incluindo aspectos como estratégias de extração de características, ano de publicação, algoritmos de classificação, moedas utilizadas e conjuntos de dados.

A categorização dos trabalhos de acordo com a abordagem de classificação revelou uma diversidade de métodos empregados. A análise temporal revela um interesse notável nos anos de 2016 e 2021, indicando momentos de destaque na pesquisa sobre classificação de cédulas falsas. Nos últimos cinco anos, observou-se um predomínio de estudos utilizando CNN e SVM, sugerindo uma tendência na escolha de algoritmos de alto desempenho. Quanto aos resultados dos algoritmos de classificação, é relevante observar que os trabalhos apresentarem acurácias acima de 85%, indicando uma consistente robustez dos métodos aplicados. No entanto, ainda é possível melhorar as métricas de avaliação, diversificando mais as abordagens a serem utilizadas.

A análise dos conjuntos de dados utilizados destaca o interesse predominante em cédulas indianas, seguidas por Dólar, Euro e Bangladesh, entre outras, sendo encontrados três conjuntos disponíveis publicamente, que se apresentam como uma valiosa fonte de dados para futuras pesquisas. A ausência de trabalhos que mencionem moedas da América Latina é uma observação significativa, sugerindo uma lacuna de pesquisa nesse contexto específico.

Esta revisão destaca a evolução, as tendências e as lacunas no campo de classificação de cédulas monetárias, oferecendo insights para pesquisadores e profissionais interessados nesse domínio. A diversidade de abordagens, algoritmos e conjuntos de dados analisados reflete a complexidade e a importância crescente dessa área de pesquisa.

Referências

- Abdi, H. e Williams, L. J. (2010). Principal component analysis, *Wiley Interdiscip. Rev. Comput. Stat.* 2(4): 433–459. <https://doi.org/10.1002/wics.101>.
- ACM (2022). Associations for computing machinery, <http://dl.acm.org/search/advanced>. [online] Disponível em 30 de Ago. 2022.
- Agarwal, A., Patni, K. e Rajeswari, D. (2021). Lung cancer detection and classification based on alexnet CNN, 2021 6th ICCES, IEEE, pp. 1390–1397. <https://doi.org/10.1109/ICCES51350.2021.9489033>.
- Ahmed, Z., Yasmin, S., Nahidul Islam, M. e Ahmed, R. U. (2014). Image processing based feature extraction of bangladeshi banknotes, *SKIMA*, pp. 1–8. <https://doi.org/10.1109/SKIMA.2014.7083521>.
- Alashhab, S., Gallego, A. J. e Lozano, M. Á. (2022). Efficient gesture recognition for the assistance of visually impaired people using multi-head neural networks, *Eng. Appl. Artif. Intell.* 114: 105188. <https://doi.org/10.1016/j.engappai.2022.105188>.
- Baek, S., Choi, E., Baek, Y. e Lee, C. (2018). Detection of counterfeit banknotes using multispectral images, *Digit. Signal Process.* 78: 294–304. <https://doi.org/10.1016/j.dsp.2018.03.015>.
- Balakrishnama, S. e Ganapathiraju, A. (1998). Linear discriminant analysis—a brief tutorial, *ISIP* 18(1998): 1–8.
- Barbosa, C. A. e da Silva, I. A. (2021). Aplicativo para a plataforma ios que auxilia pessoas com deficiência visual no manuseio de cédulas de real, *UPM*.
- Basturk, A., Basturk, N. S., Degbedzui, D. K. e Yuksel, M. E. (2021). Efficient detection of counterfeit banknotes using adaptive network based fuzzy inference systems, *ELECO*, pp. 575–579. <https://doi.org/10.23919/ELECO54474.2021.9677736>.
- Bauer, K. . (2010). Kba-notasys flowerpower (kba-nf), <https://banknote-solutions.koenig-bauer.com/en/design/specimens/#>. [online] Disponível em 18 de Dez. 2022.
- Bay, H., Ess, A., Tuytelaars, T. e Van Gool, L. (2008). Speeded-up robust features (surf), *Comput. Vis. Image Underst.* 110(3): 346–359. <https://doi.org/10.1016/j.cviu.2007.09.014>.
- BCB (2013). Segunda família do real: Cartilha de treinamento, <https://www.bcb.gov.br/novasnotas/assets/downloads/material-apoio/2e5/Cartilha.pdf>. [online] Disponível em 13 de Fev. de 2023.
- BCB (2018). Relatório de cidadania financeira 2018.
- BCB (2022). Dados abertos do banco central do brasil, https://www.bcb.gov.br/adm/mecir/dadosabertos/FaIsificacao_DadosAbertos.csv. [online] Disponível em 02 Jan. 2023.
- Belgiu, M. e Drăguț, L. (2016). Random forest in remote sensing: A review of applications and future directions, *ISPRS JPRS* 114: 24–31. <https://doi.org/10.1016/j.isprsjprs.2016.01.011>.
- Benmouiza, K. e Cheknane, A. (2019). Clustered anfis network using fuzzy c-means, subtractive clustering, and grid partitioning for hourly solar radiation forecasting, *Theor. Appl. Climatol.* 137(1): 31–43. <https://doi.org/10.1007/s00704-018-2576-4>.
- Bhatia, A., Kedia, V., Shroff, A., Kumar, M., Shah, B. K. e Aryan (2021). Fake currency detection with machine learning algorithm and image processing, *ICICCS*, pp. 755–760. <https://doi.org/10.1109/ICICCS51141.2021.9432274>.
- Bhele, S. G., Mankar, V. et al. (2012). A review paper on face recognition techniques, *IJARCT* 1(8): 339–346.
- Bookstein, A., Tomi Klein, S. e Raita, T. (2001). Fuzzy hamming distance: a new dissimilarity measure, *CPM*, Springer, pp. 86–97. https://doi.org/10.1007/3-540-48194-X_7.
- Britto Neto, L. d. S., Maike, V. R. M. L., Koch, F. L., Baranauskas, M. C. C., de Rezende Rocha, A. e Goldenstein, S. K. (2015). A wearable face recognition system built into a smartwatch and the blind and low vision users, *ICEIS*, Springer, pp. 515–528. https://doi.org/10.1007/978-3-319-29133-8_25.
- Britto Neto, L., Grijalva, F., Maike, V., Martini, L., Florencio, D., Baranauskas, M., Rocha, A. e Goldenstein, S. (2016). A kinect-based wearable face recognition system to aid visually impaired users, *IEEE THMS* 47(1): 52–64. <https://doi.org/10.1109/THMS.2016.2604367>.
- Bruno, M. M. G. e Nascimento, R. A. L. d. (2019). Política de acessibilidade: o que dizem as pessoas com deficiência visual, *Educação & Realidade* 44. <https://doi.org/10.1590/2175-623684848>.
- Bueno, G. R. e Lucena, T. F. R. (2016). Geração cabeça-baixa: saúde e comportamento dos jovens no uso das tecnologias móveis, *Simpósio Nacional ABCiber* 9: 573–578. <https://doi.org/10.1590/2175-623684848>.
- Canny, J. (1986). A computational approach to edge detection, *IEEE TPAMI* (6): 679–698. <https://doi.org/10.1109/TPAMI.1986.4767851>.
- Chakrabarty, N., Kundu, T., Dandapat, S., Sarkar, A. e Kole, D. K. (2019). Flight arrival delay prediction using gradient boosting classifier, *IEMIS*, Springer, pp. 651–659. https://doi.org/10.1007/978-981-13-1498-8_57.
- Chan, K.-H., Im, S.-K. e Ke, W. (2020). Vggrenet: a light-weight vggnet with reused convolutional set, *IEEE/ACM UCC*, IEEE, pp. 434–439. <https://doi.org/10.1109/UC C48980.2020.00068>.
- Chang, C.-C., Yu, T.-X. e Yen, H.-Y. (2007). Paper currency verification with support vector machines, *IEEE SITIS*, pp. 860–865. <https://doi.org/10.1109/SITIS.2007.146>.

- Chang, W.-J., Yu, Y.-X., Chen, J.-H., Zhang, Z.-Y., Ko, S.-J., Yang, T.-H., Hsu, C.-H., Chen, L.-B. e Chen, M.-C. (2019). A deep learning based wearable medicines recognition system for visually impaired people, *2019 IEEE AICAS*, IEEE, pp. 207–208. <https://doi.org/10.1109/AICAS.2019.8771559>.
- Choi, E. e Lee, C. (2003). Feature extraction based on the bhattacharyya distance, *Pattern Recognit.* **36**(8): 1703–1709. [https://doi.org/10.1016/S0031-3203\(03\)00035-9](https://doi.org/10.1016/S0031-3203(03)00035-9).
- Chun-Lin, L. (2010). A tutorial of the wavelet transform, *NTUEE, Taiwan* **21**: 22.
- Colaco, R. M., Fernandes, R., Reenaz e S, S. (2021). Efficient image processing technique for authentication of indian paper currency, *2021 ICCCI*, pp. 1–8. <https://doi.org/10.1109/ICCCI50826.2021.9402428>.
- Cortes, C. e Vapnik, V. (1995). Support-vector networks, *Machine learning* **20**(3): 273–297. <https://doi.org/10.1007/BF00994018>.
- Costa, C. M., Veiga, G. e Sousa, A. (2016). Recognition of banknotes in multiple perspectives using selective feature matching and shape analysis, *2016 International Conference on Autonomous Robot Systems and Competitions (ICARSC)*, pp. 235–240. <https://doi.org/10.1109/ICARSC.2016.59>.
- Costa, G. R. T. et al. (2011). O design das cédulas brasileiras do cruzeiro ao real (1970–2010).
- Czyzewski, M. A., Laskowski, A. e Wasik, S. (2020). Chessboard and chess piece recognition with the support of neural networks, *Foundations of Computing and Decision Sciences* **45**(4): 257–280. <https://doi.org/10.2478/fc ds-2020-0014>.
- Dalal, N. e Triggs, B. (2005). Histograms of oriented gradients for human detection, *CVPR*, Vol. 1, IEEE, pp. 886–893. <https://doi.org/10.1109/CVPR.2005.177>.
- Darade, S. R. e Gidveer, G. (2016). Automatic recognition of fake indian currency note, *ICEPES*, pp. 290–294. <https://doi.org/10.1109/ICEPES.2016.7915945>.
- de Oliveira, É. G. (2022). Escola inclusiva: a tecnologia assistiva assimilação, ação e aspectos, *EmRede-Revista de Educação a Distância* **9**(2). <https://doi.org/10.53628/emrede.v9i2.805>.
- Desai, S., Rajadhyaksha, A., Shetty, A. e Gharat, S. (2021). CNN based counterfeit indian currency recognition using generative adversarial network, *ICAIS*, pp. 626–631. <https://doi.org/10.1109/ICAIS50930.2021.9395949>.
- Dias Júnior, M. A. P. (2022). *Reconhecimento de formas farmacêuticas sólidas para auxiliar pessoas com deficiência visual*, Master's thesis, Federal University of Piauí.
- Diário do Nordeste, P. d. (2019). Dinheiro falso é enviado pelos correios; dois são presos pela PF, <https://diario donordeste.verdesmares.com.br/seguranca/dinheiro-falso-e-enviado-pelos-correios-dois-sao-presos-p>
[ela-pf-1.2182169](https://doi.org/10.1109/ICCCI50826.2021.9402428). [online] Disponível em 13 de Fev. de 2023.
- Dua, D. e Graff, C. (2017). UCI machine learning repository. <http://archive.ics.uci.edu/ml>.
- Edelman, G. J., Gaston, E., Van Leeuwen, T. G., Cullen, P. e Aalders, M. C. (2012). Hyperspectral imaging for non-contact analysis of forensic traces, *Forensic Sci. Int.* **223**(1–3): 28–39. <https://doi.org/10.1016/j.forsciint.2012.09.012>.
- Freire, M. V. (2011). Moedas sociais: contributo em prol de um marco legal e regulatório para as moedas sociais circulantes locais no brasil.
- Hart, P. E. e Duda, R. (1972). Use of the hough transformation to detect lines and curves in pictures, *CACM* **15**(1): 11–15. <https://doi.org/10.1145/361237.361242>.
- Hoang, V.-D. e Vo, H.-T. (2018). Hybrid discriminative models for banknote recognition and anti-counterfeit, *NAFOSTED NICS*, pp. 394–399. <https://doi.org/10.1109/NICS.2018.8606900>.
- IEEE (2022). Institute of electrical and electronics engineers, <https://ieeexplore.ieee.org/>. [online] Disponível em 30 de Ago. 2022.
- Ionescu, M. e Ralescu, A. (2005). Fuzzy hamming distance based banknote validator, *IEEE FUZZ*, pp. 300–305. <https://doi.org/10.1109/FUZZY.2005.1452410>.
- Jang, J.-S. (1993). Anfis: adaptive-network-based fuzzy inference system, *IEEE TSMC* **23**(3): 665–685. <https://doi.org/10.1109/21.256541>.
- Kitchenham, B. A. e Charters, S. (2007). Guidelines for performing systematic literature reviews in software engineering, *Technical Report EBSE 2007-001*, Keele University and Durham University Joint Report.
- Krishna, K. e Murty, M. N. (1999). Genetic k-means algorithm, *IEEE TSMC B* **29**(3): 433–439. <https://doi.org/10.1109/3477.764879>.
- Kunene, D., Vadapalli, H. e Cronje, J. (2016). Indoor sign recognition for the blind, *SAICSIT*, pp. 1–9. <https://doi.org/10.1145/2987491.2987530>.
- Laaksonen, J. e Oja, E. (1996). Classification with learning k-nearest neighbors, *Proceedings of international conference on neural networks (ICNN'96)*, Vol. 3, IEEE, pp. 1480–1483. <https://doi.org/10.1109/ICNN.1996.549118>.
- Lim, H.-T. e Murukeshan, V. M. (2017). Hyperspectral imaging of polymer banknotes for building and analysis of spectral library, *Opt. Laser Eng.* **98**: 168–175. <https://doi.org/10.1016/j.optlaseng.2017.06.022>.
- Lo Valvo, A., Croce, D., Garlisi, D., Giuliano, F., Giarré, L. e Tinnirello, I. (2021). A navigation and augmented reality system for visually impaired people, *Sensors* **21**(9): 3061. <https://doi.org/10.3390/s21093061>.

- Lohweg, V., Hoffmann, J. L., Dörksen, H., Hildebrand, R., Gillich, E., Hofmann, J. e Schaede, J. (2013). Banknote authentication with mobile devices, *SPIE*, Vol. 8665, pp. 47–60. <https://doi.org/10.1117/12.2001444>.
- Machado, A., Aires, K., Veras, R. e Britto Neto, L. (2021). Grocery product recognition to aid visually impaired people, *WVC, SBC*, pp. 94–99. <https://doi.org/10.5753/wvc.2021.18896>.
- Machado, A., Veras, R., Aires, K. e Britto Neto, L. (2021). A systematic review on product recognition for aiding visually impaired people, *IEEE LATAMT* 19(4): 592–603. <https://doi.org/10.1109/TLA.2021.9448542>.
- Marwedel, P. (2021). *Embedded system design: embedded systems foundations of cyber-physical systems, and the internet of things*, Springer Nature. <https://doi.org/10.1007/978-3-030-60910-8>.
- Matsuo, Y., LeCun, Y., Sahani, M., Precup, D., Silver, D., Sugiyama, M., Uchibe, E. e Morimoto, J. (2022). Deep learning, reinforcement learning, and world models, *Neural Networks*. <https://doi.org/10.1016/j.neunet.2022.03.037>.
- Meshram, V., Thamkrongart, P., Patil, K., Chumchu, P. e Bhatlawande, S. (2020). Dataset of indian and thai banknotes. <https://dx.doi.org/10.21227/cjb5-n039>.
- Mika, S., Ratsch, G., Weston, J., Scholkopf, B. e Mullers, K.-R. (1999). Fisher discriminant analysis with kernels, *SPS Workshop, IEEE*, pp. 41–48. <https://doi.org/10.1109/NNSP.1999.788121>.
- Mohammed, A. H. M. e Çevik, M. (2022). Googlenet cnn classifications for diabetics retinopathy, *HORA, IEEE*, pp. 1–4. <https://doi.org/10.1109/HORA55278.2022.9799971>.
- Moher, D. (2009). Liberati a, tetzlaff j, altman dg, group tp, *Preferred reporting items for systematic reviews and meta-analyses: the PRISMA statement. PLoS Med* 6(7): e1000097–6. <https://doi.org/10.1016/j.ijvsu.2010.02.007>.
- Mombach, J. G. (2015). Proposta de aplicativo móvel para identificação de cédulas de real por pessoas com deficiência visual.
- Mortensen, E. N., Deng, H. e Shapiro, L. (2005). A sift descriptor with global context, *CVPR*, Vol. 1, IEEE, pp. 184–190. <https://doi.org/10.1109/CVPR.2005.45>.
- Murthy, S., Kurumathur, J. e Reddy, B. R. (2016). Design and implementation of paper currency recognition with counterfeit detection, *2016 IC-GET*, pp. 1–6. <https://doi.org/10.1109/GET.2016.7916838>.
- OMS (2022). Blindness and vision impairment, <https://www.who.int/news-room/fact-sheets/detail/blindness-and-visual-impairment>. [online] Disponível em 13 de Fev. de 2023.
- Oviedo, F., Vinnakota, S., Seleznev, E., Malhotra, H., Shaikh, S. e Ferres, J. L. (2022). Banknote-net: Open dataset for assistive currency recognition, *arXiv*. <https://doi.org/10.48550/arXiv.2204.03738>.
- Ovodov, I. G. (2021). Optical braille recognition using object detection neural network, *IEEE/CVF ICCV*, pp. 1741–1748.
- Park, S. e Jayaraman, S. (2021). Wearables: Fundamentals, advancements, and a roadmap for the future, *Wearable sensors*, Elsevier, pp. 3–27. <https://doi.org/10.1016/B978-0-12-819246-7.00001-2>.
- Patnaik, S., Kumari, S. e Mahapatra, S. D. (2020). Comparison of deep cnn and resnet for handwritten devanagari character recognition, *ICCE, IEEE*, pp. 235–238. <https://doi.org/10.1109/ICCE50343.2020.9290637>.
- Pham, T. D., Park, C., Nguyen, D. T., Batchuluun, G. e Park, K. R. (2020). Deep learning-based fake-banknote detection for the visually impaired people using visible-light images captured by smartphone cameras, *IEEE Access* 8: 63144–63161. <https://doi.org/10.1109/ACCESS.2020.2984019>.
- Planalto Federal do Brasil, P. d. (1940). Código penal brasileiro, https://www.planalto.gov.br/ccivil_03/decreto-lei/del2848.htm. [online] Disponível em 02 Jan. 2023.
- Polícia Federal do Brasil, P. d. (2023). Polícia federal apreende dinheiro falso, <https://www.gov.br/pf/pt-br/as-suntos/noticias/2023/01/policia-federal-apreende-dinheiro-falso>. [online] Disponível em 13 de Fev. de 2023.
- Pret, R. L. (2014). O documento e a prova: ordenamento jurídico, validações diplomáticas e a arquivística, *Informação Arquivística* 2(2). <https://doi.org/10.1109/ACCESS.2020.2984019>.
- Priyam, A., Abhijeeta, G., Rathee, A. e Srivastava, S. (2013). Comparative analysis of decision tree classification algorithms, *International Journal of current engineering and technology* 3(2): 334–337.
- Priyono, A., Ridwan, M., Alias, A. J., Rahmat, R. A. O., Hassan, A. e Ali, M. A. M. (2005). Generation of fuzzy rules with subtractive clustering, *Jurnal Teknologi* pp. 143â–153. <https://doi.org/10.11113/jt.v43.782>.
- Ramanathan, R., Nair, A. S., Thaneshwaran, L., Ponmathavan, S., Valliappan, N. e Soman, K. (2009). Robust feature extraction technique for optical character recognition, *ACT, IEEE*, pp. 573–575. <https://doi.org/10.1109/ACT.2009.145>.
- Rao, R. M. (1998). *Wavelet transforms: Introduction to theory and applications*, Pearson Education India.
- Rathee, N., Kadian, A., Sachdeva, R., Dalel, V. e Jaie, Y. (2016). Feature fusion for fake indian currency detection, *INDIACom*, pp. 1265–1270.
- Rish, I. et al. (2001). An empirical study of the naive bayes classifier, *IJCAI EMAL Workshop*, Vol. 3, pp. 41–46.
- Roy, A., Halder, B. e Garain, U. (2010). Authentication of currency notes through printing technique verification, *ICVGIP, ACM*, New York, NY, USA, p. 383–390. <https://doi.org/10.1145/1924559.1924610>.

- Sako, H., Watanabe, T., Nagayoshi, H. e Kagehiro, T. (2007). Self-defense-technologies for automated teller machines, *IMVIP*, pp. 177–184. <https://doi.org/10.1109/IMVIP.2007.20>.
- Sausen, F. S. e Frozza, R. (2022). Aplicativo para auxiliar pessoas com deficiência visual no reconhecimento de cédulas de dinheiro em real com a técnica de redes neurais artificiais, *RBCA* 14(3): 1–16. <https://doi.org/10.5335/rbca.v14i3.13058>.
- ScienceDirect (2022). Sciencedirect, <https://www.sciencedirect.com/>. [online] Disponível em 26 de Set. 2022.
- Shotton, J., Blake, A. e Cipolla, R. (2005). Contour-based learning for object detection, *ICCV*, Vol. 1, pp. 503–510 Vol. 1. <https://doi.org/10.1109/ICCV.2005.63>.
- Silva, C., Zamboni, A., Hernandez, E., Thomazzo, A. D., Belgamo, A. e Fabbri, S. (2010). *StArt*.
- Silva, J. M., Silva, R., Veras, R., Aires, K. e Britto Neto, L. (2021). Facial expression recognition to aid visually impaired people, *WVC*, SBC, pp. 48–53. <https://doi.org/10.5753/wvc.2021.18888>.
- Singh, A. (2017). Impact of demonetization on indian economy, *IJEMR* 7(3): 785–788.
- Singh, M., Ozarde, P. e Abhiram, K. (2018). Image processing based detection of counterfeit indian bank notes, *ICCCNT*, pp. 1–5. <https://doi.org/10.1109/ICCCNT.2018.8493763>.
- Sousa, L. d., Veras, R., Vogado, L. e Britto Neto, L. (2018). Metodologia de identificação de cédulas monetárias para deficientes visuais, *RSC* 8(1).
- Sousa, L., Veras, R., Vogado, L., Britto Neto, L., Silva, R., Araújo, F. e Medeiros, F. (2023). Evaluation of banknote identification methodologies based on local and deep features, *IJICA* 14: 34–45.
- Sumalatha, R., Reddy, B. J. e Venkat Ram Reddy, T. (2022). Identification of fake indian currency using convolutional neural network, *ICCMC*, pp. 1619–1623. <https://doi.org/10.1109/ICCMC53470.2022.9754056>.
- Szarvas, M., Yoshizawa, A., Yamamoto, M. e Ogata, J. (2005). Pedestrian detection with convolutional neural networks, *ITSS IV*, IEEE, pp. 224–229. <https://doi.org/10.1109/IVS.2005.1505106>.
- Takeda, F. e Omatu, S. (1995). High speed paper currency recognition by neural networks, *IEEE TNN* 6(1): 73–77. <https://doi.org/10.1109/72.363448>.
- Tanaka, N. e Fujinami, K. (2017). A projector-camera system for augmented card playing and a case study with the pelmanism game, *EAI Endorsed Trans. Ambient Syst.* 4(13). <https://doi.org/10.4108/eai.17-5-2017.152550>.
- Torres, J., Costa, C. e Lourenço, G. (2016). Substituição sensorial visuo-tátil e visuo-auditiva em pessoas com deficiência visual: uma revisão sistemática, *RBEE* 22: 605–618. <https://doi.org/10.1590/S1413-65382216000400010>.
- Uddin, M. S., Das, P. P. e Roney, M. S. A. (2016). Image-based approach for the detection of counterfeit banknotes of bangladesh, 2016 5th ICIEV, pp. 1067–1072. <https://doi.org/10.1109/ICIEV.2016.7760162>.
- UDI (2013). Banknote authentication data set, <https://archive.ics.uci.edu/ml/datasets/banknote+authentication#>. [online] Disponível em 23 de Nov. 2022.
- Upadhyaya, A., Shokeen, V. e Srivastava, G. (2018). Analysis of counterfeit currency detection techniques for classification model, 2018 4th ICCCA, pp. 1–6. <https://doi.org/10.1109/CCAA.2018.8777704>.
- Vaidya, G., Vaidya, K. e Bhosale, K. (2020). Text recognition system for visually impaired using portable camera, 2020 ICCDW, IEEE, pp. 1–4. <https://doi.org/10.1109/ICCDW45521.2020.9318706>.
- Viraktamath, S. V., Tallur, K., Bhadavankar, R. e Vidya (2021). Review on detection of fake currency using image processing techniques, *ICICCS*, pp. 865–870. <https://doi.org/10.1109/ICICCS51141.2021.9432111>.
- Vishwakarma, D. K. et al. (2020). Comparative analysis of deep convolutional generative adversarial network and conditional generative adversarial network using handwritten digits, 2020 4th ICICCS, IEEE, pp. 1072–1075. <https://doi.org/10.1109/ICICCS48265.2020.9121178>.
- Wareechol, T. e Chiracharit, W. (2021). Recognition of similar gait pattern using transfer learning darknet, *IE-ECON*, IEEE, pp. 381–384. <https://doi.org/10.1109/IEECON51072.2021.9440386>.
- Wei, Y., Sun, J., Tang, X. e Shum, H.-Y. (2007). Interactive offline tracking for color objects, *ICCV*, pp. 1–8. <https://doi.org/10.1109/ICCV.2007.4408949>.
- Wright, R. E. (1995). Logistic regression.
- Yadav, A., Jain, T., Verma, V. K. e Pal, V. (2021). Evaluation of machine learning algorithms for the detection of fake bank currency, *Confluence*, pp. 810–815. <https://doi.org/10.1109/Confluence51648.2021.9377127>.
- Yeh, C.-Y., Su, W.-P. e Lee, S.-J. (2011). Employing multiple-kernel support vector machines for counterfeit banknote recognition, *Applied Soft Computing* 11(1): 1439–1447. <https://doi.org/10.1016/j.asoc.2010.04.015>.
- Yu, X., Lai, H., Liu, S. e Leong, H. (2005). A gridding hough transform for detecting the straight lines in sports video, 2005 IEEE International Conference on Multimedia and Expo, pp. 4 pp.–. <https://doi.org/10.1109/ICME.2005.1521474>.
- Zarin, A. e Uddin, J. (2019). A hybrid fake banknote detection model using ocr, face recognition and hough features, 2019 CCC, pp. 91–95. <https://doi.org/10.1109/CCC.2019.000-3>.
- Çelik, E. e Kondiloğlu, A. (2015). Detection of fake banknotes with artificial neural networks and support vector machines, 2015 23rd Signal Processing and Communications Applications Conference (SIU), pp. 1317–1320. <https://doi.org/10.1109/SIU.2015.7130082>.