

# Metodologia de Identificação de Cédulas Monetárias para Deficientes Visuais

## *Monetary Notes Identification Methodology for Visually Impaired*

Leonardo Pereira de Sousa, Rodrigo de Melo Souza Veras, Luis Henrique Silva Vogado, Laurindo de Sousa Britto Neto

Universidade Federal do Piauí - Brasil

leonardosousa@ufpi.edu.br, rveras@ufpi.edu.br, lhvogado@gmail.com,  
laurindoneto@ufpi.edu.br

**Abstract.** *Worldwide, there is a wide variety of disabled people. It is estimated that a total of 285 million visually impaired people, 39 million blind and 246 million with low vision. The use of Information and Communication Technologies helps disabled people to have independence that is more significant, quality of life and inclusion in social life through the supplementation, maintenance or devolution of their functional capacities. In this context, this paper presents a methodology for banknotes automatic identification that can be widely used by the visually impaired people. For this, a set of four local descriptors, four individual classifiers and two classifier committees were evaluated, which could be used as a basis for the development of applications for the identification of banknotes. The tests performed with images of dollar, euro and real banknotes obtained precision rates of 97%, 91% and 91%, respectively.*

**Resumo.** *Mundialmente, existe uma grande variedade de deficientes. Estima-se um total de 285 milhões de deficientes visuais, sendo 39 milhões cegos e 246 milhões com baixa visão. O uso de Tecnologias de Informação e Comunicação contribui para que deficientes tenham maior independência, qualidade de vida e inclusão na vida social por meio do suplemento, manutenção ou devolução de suas capacidades funcionais. Nesse contexto, este artigo apresenta uma metodologia de identificação automática de cédulas monetárias que poderá ser amplamente utilizada por deficientes visuais. Para isso, foram avaliados um conjunto de quatro descritores locais, quatro classificadores individuais e dois comitês de classificadores, que poderão ser utilizados como base para o desenvolvimento de aplicativos para a identificação de cédulas. Nos testes realizados, obteve-se valores de precisão de 97%, 91% e 91% em cédulas de dólar, euro e real, respectivamente.*

### 1. Introdução

A deficiência visual compromete a visualização e identificação de objetos. Segundo levantamento de 2010 da *World Health Organization* (WHO) [21], existiam cerca de 285 milhões de pessoas com dificuldade de enxergar, sendo que 39 milhões se declararam totalmente cegos.

Com o surgimento de novas tecnologias, houve o aumento de mecanismos para oferecer acessibilidade e inclusão a indivíduos com deficiência. As principais metas são proporcionar benefícios, como uma maior independência e qualidade de vida. O uso de recursos tecnológicos auxilia os deficientes visuais na realização de tarefas, como o uso de computadores para ler jornais, realizar pesquisas acadêmicas, dentre outros.

O reconhecimento de cédulas é um dos problemas mais desafiadores enfrentados por pessoas com deficiência visual, uma vez que constitui um processo essencial no gerenciamento de transações monetárias [7]. Os deficientes possuem grande dificuldade em identificar os valores das cédulas monetárias, complicando a realização de tarefas cotidianas, tais como: pagamentos de contas, realização de compras, operações de serviços bancários, dentre outros. Além disso, o deficiente pode sofrer golpes financeiros.

Neste artigo é proposto um método de identificação automática de cédulas com a aplicação de técnicas de processamento de imagens, visão computacional e reconhecimento de padrões. Para isso, realizou-se levantamento bibliográfico das principais técnicas aplicadas, foram criadas bases de imagens e avaliado um conjunto de quatro descritores locais, quatro classificadores e dois comitês de classificadores. Os testes foram realizados em cédulas de dólar, euro e real. No total, foram realizados 120 testes para identificar os melhores algoritmos para compor o método. Um dos objetivos do trabalho é que os resultados obtidos sejam úteis para a construção, no futuro, de um sistema *wearable*.

O artigo foi organizado da seguinte maneira: a Seção 2 relata os principais trabalhos relacionados ao reconhecimento de cédulas; a Seção 3 faz um breve levantamento das principais técnicas utilizadas; a Seção 4 descreve a metodologia proposta; a Seção 5 ilustra as metodologias de avaliação; a Seção 6 apresenta e discute os resultados obtidos; e finalmente, a Seção 7 conclui o estudo e sugere trabalhos futuros.

## 2. Trabalhos Relacionados

Em Hasanuzzaman *et al.* [8], os autores propuseram uma abordagem para reconhecimento de cédulas usando o descritor *Speeded Up Robust Features* (SURF) [3]. Segundo os autores, o algoritmo SURF é de baixo custo computacional, o que permite a localização rápida dos pontos de interesse. Para a geração das regiões de referência, foram realizados cortes manuais de vários pontos em cada cédula monetária (frente e verso). Neste trabalho, uma cédula é reconhecida se ao menos duas regiões de referências forem identificadas. Nos experimentos realizados, foram utilizados 140 imagens, para treino, de cédulas bancárias de dólar americano, contendo 20 imagens de cada classe (\$1, \$2, \$5, \$10, \$20, \$50 e \$100), e 579 imagens para teste. Sendo as cédulas de mesmo tamanho e imagens das regiões de referência diferenciadas. Como resultado, foi obtido 100% de taxa de verdadeiro positivo (TPR).

Mulmule-Shirkhedkar e Dani [18] realizaram um estudo comparativo dos descritores SURF e *Fast Retina Keypoint* (FREAK) [2], para extração de atributos e classificação de notas de moeda indiana, usando um modelo baseado em regiões de

referência. Para a classificação, foi utilizada a metodologia de força bruta, comparando os descritores da imagem pesquisada com todos os descritores das imagens armazenadas. As cédulas de Rúpias Indianas (INR) utilizadas foram de Rs.5, Rs.10, Rs.20, Rs.50, Rs.100, Rs.500 e Rs.1000. No experimento, eles utilizaram 210 imagens, sendo 30 de cada valor monetário, dividindo o conjunto de imagens da seguinte forma: 60% para treino, 20% para testes e 20% para validação. Os autores obtiveram acurácia de 95,15% para o SURF e de 92,85 para o FREAK.

No trabalho de Costa *et al.* [5], os autores desenvolveram uma aplicação para o reconhecimento de cédulas monetárias de Euro (€). Foram utilizados oito algoritmos de detecção de *Points of Interest* (PoIs) e quatro descritores. Para classificar, os autores avaliaram o uso de busca extensiva e da abordagem heurística *Fast Library for Approximate Nearest Neighbors* (FLANN) [17]. O sistema foi testado com 80 imagens, que continham notas nas condições mais comuns, com diferentes visões em perspectiva, ambientes desordenados, notas parcialmente ocultas e também várias notas por imagem. O melhor resultado foi obtido utilizando o algoritmo *Scale-Invariant Feature Transform* (SIFT) [16] como detector e descritor, e busca extensiva para classificação. O sistema reconheceu com sucesso todas as 95 notas de banco nas 80 imagens de teste. Contudo, os autores relataram que o algoritmo de detecção e descrição SURF é mais adequado para uso em tempo real.

Em Teixeira *et al.* [27], os autores propuseram um aplicativo para reconhecimento de cédulas, empregando o algoritmo SURF na identificação dos PoIs e definição dos descritores. Nesse estudo, foram elaborados dois vetores, um contendo os atributos de cada PoI da imagem, e outro com os seus respectivos descritores. Para a classificação, foi utilizado o classificador *Support Vector Machines - Sequential Minimal Optimization* (SVM-SMO) [23]. Nos testes, foram utilizadas 1440 imagens digitais, sendo 240 para cada cédula monetária da 1ª Família de Real (com exceção da cédula de um real) capturadas em ambiente controlado com iluminação artificial. Para a verificação do experimento foi utilizado o método *n-fold cross validation*. Os resultados atingiram uma taxa 97,9% para o reconhecimento verdadeiro e taxa 2,1% para o reconhecimento falso, mas não ocorreram testes com oclusões parciais, desgaste pelo uso e variação de iluminação.

Oyedotun e Khashman [20] investigaram três estruturas cognitivas hipotéticas, para o reconhecimento de cédulas bancárias, utilizando Redes Neurais Competitivas (*Competitive Neural Network - CNN*) [6]. O sistema implementado reconhece as cédulas com até 75% de oclusão. Nas simulações, foram utilizadas as notas de 1000 Naira (moeda oficial da Nigéria), 200 Naira e 50 Naira. Ele utiliza 100 amostras para cada estrutura, totalizando 300 imagens. Os resultados da simulação, baseados nas taxas globais de reconhecimento, mostraram que o melhor desempenho é obtido na hipótese 1 (86,67%) utilizando 3 sistemas para análise das cédulas, sendo o primeiro para a identificação do lado (frente ou verso) e os dois restantes para a identificação das características da denominação no lado correspondente.

Em Abburu *et al.* [1], os autores propuseram um sistema para o reconhecimento automático da nacionalidade de cédulas de diferentes países. O método proposto é capaz de reconhecer tanto a nacionalidade quanto o valor da cédula. O funcionamento deste

método se dá por meio da identificação do país de origem, utilizando determinadas áreas de interesse predefinidas e, em seguida, extraindo o valor de denominação usando características como tamanho, cor ou texto na nota, dependendo de quanto as notas, sejam diferentes dentro do mesmo país. Foram consideradas as 20 moedas mais negociadas, assim como suas denominações. Para fins de demonstração, foi escolhida a nota canadense de 20 dólares. O sistema proposto obteve uma precisão de 93,3% na realização dos experimentos, identificando adequadamente as nacionalidades das células apresentadas.

É importante salientar que nenhum dos trabalhos citados descreve a maneira como foi criado o vetor de características (assinatura da imagem). Esse é um passo importante, visto que os classificadores recebem como entrada vetores de atributos de mesmo comprimento, enquanto que os algoritmos de detecção de PoIs detectam uma quantidade de pontos diferentes para cada imagem. Dessa forma, uma contribuição deste trabalho é a utilização do cálculo da média dos PoI detectados para a geração da assinatura. Além disso, os experimentos deste trabalho foram realizados em três tipos de cédulas (dólar, euro e real) e, para simular aplicações em ambientes reais, foram utilizadas cédulas rotacionada, particionadas e com inserção de ruídos.

### 3. Fundamentos

Esta seção apresenta um levantamento das principais técnicas aplicadas no desenvolvimento deste trabalho.

#### 3.1. Extração de Características

A detecção dos PoIs deve ser capaz de identificar e extrair regiões que consigam ser invariantes a iluminação, rotação e translação do objeto a ser identificado. Para detectar PoIs e extrair suas características, utilizamos alguns algoritmos propostos no estado da arte.

*Binary Robust Invariant Scalable Keypoints* - BRISK: baseia-se em uma amostra circular, a partir da qual ele calcula as variações de brilho para formar uma cadeia de descritores binários [11]. Esse método leva em consideração a rotação de um PoI a ser descrito, fazendo o uso de uma teoria espaço-escala para adaptar o padrão de amostragem.

*Features from Accelerated Segment Test* - FAST: é um algoritmo de detecção de cantos, proposto com o objetivo de identificar pontos chaves em imagens com uma velocidade superior à do SIFT [16]. Ele não possui informações sobre a orientação dos descritores, e é altamente sensível a ruídos. O algoritmo propõe uma melhora de desempenho utilizando aprendizado de máquina e criação de uma árvore de decisão. A árvore é transformada em código C e compilada. É um método ideal para a extração de recursos em ambientes de recursos limitados [9].

*Maximally Stable External Regions* - MSER: algoritmo proposto por Matas *et al.* [15] com o objetivo de ser robusto diante de mudanças de perspectiva. O MSER foi originalmente utilizado para detecção de características e alinhamento de imagens

estéreo. O algoritmo localiza pontos extremos na imagem e identifica regiões conexas a partir da intensidade do brilho dos pixels. Ele aplica limiares de diferentes valores e detecta regiões de bordas com grande variação de intensidade.

*Speed-Up Robust Features* - SURF: o algoritmo proposto em [3] é inspirado no SIFT, mas com a intenção de ser mais rápido na obtenção e verificação de características. O SURF não realiza a análise em imagens coloridas, somente reconhece imagens em tons de cinza. Esse algoritmo realiza a localização dos PoI e em seguida gera um vetor de características. Como essas informações foram extraídas com base na orientação da região de interesse, o mesmo padrão permanece se a imagem for rotacionada.

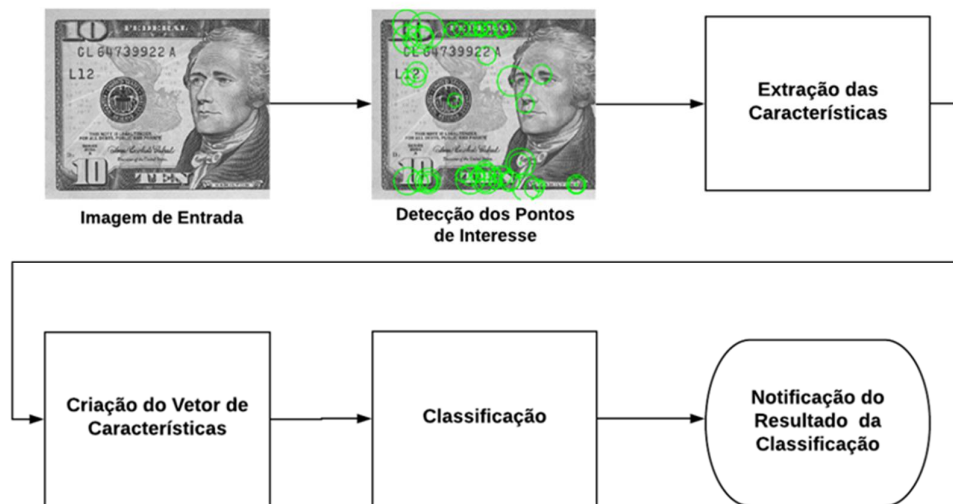
### 3.2. Classificação

Após a detecção e descrição dos PoIs é necessário classificá-los, ou seja, identificar as imagens analisando os atributos definidos pelos descritores. Com esse objetivo, foram utilizados classificadores individuais e comitês para avaliar a performance da metodologia proposta. Foram utilizados os seguintes classificadores individuais, a saber: *Radial Basis Function* (RBF) [19], utilizado com a camada oculta de forma não supervisionada; *Random Tree* (RT) [12], utilizado sem a realização da poda das árvores de decisão e com número de árvores igual a 100; *Multilayer Perceptron* (MLP) [29], utilizado com uma camada oculta; e *Sequential Minimal Optimization* (SMO) [26, 23], executado utilizando uma função de kernel linear.

Para avaliar a metodologia utilizando comitês de classificadores, foram selecionados dois algoritmos existentes no estado da arte. O primeiro e mais popular é o *Random Forest* [4]. Esse é capaz de gerar um conjunto de árvores de classificação, em que cada árvore dá um voto indicando sua decisão sobre a classe do objeto. A classe com o maior número de votos é escolhida para o objeto. Foi utilizado com uma profundidade máxima das árvores ilimitada e com um total de 100 árvores. O segundo é um Comitê Híbrido formado pelos classificadores SMO, MLP e RBF, no qual foi utilizado a classificação por voto majoritário. Cada algoritmo classifica a instância. O rótulo com maior probabilidade, recebe um voto. Se vários rótulos tiverem a mesma probabilidade, todos esses rótulos receberão um voto. Uma vez que todos os classificadores realizaram os testes, o rótulo com a maioria dos votos é selecionado como resultado da instância de teste.

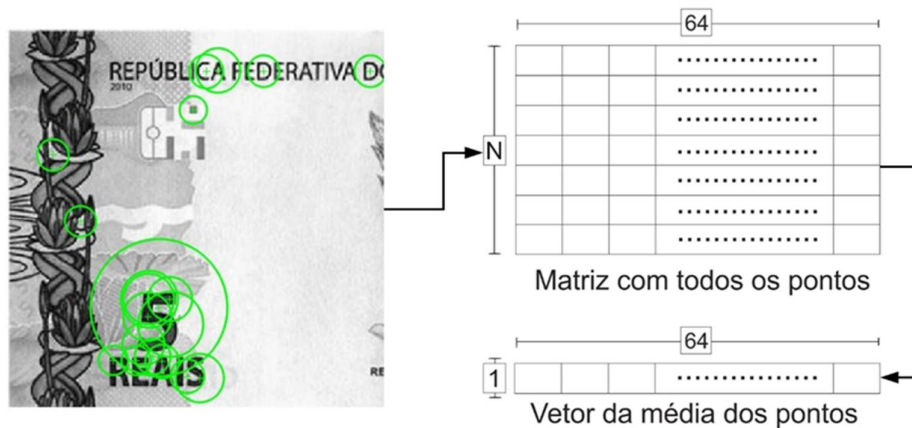
### 4. Método Proposto

Neste trabalho, foi proposto uma metodologia para a identificação automática de cédulas, utilizando detectores e descritores de pontos de interesse e criação do vetor de características. A Figura 1 apresenta o fluxograma do método proposto.



**Figura 1. Diagrama do funcionamento de uma metodologia para o reconhecimento de cédulas**

A imagem de entrada consiste em uma cédula obtida da base de dados. Para extrair as características da imagem, foi utilizado detectores e descritores de pontos de interesse. Uma dificuldade encontrada na utilização dessa abordagem, na etapa de extração, é a grande quantidade de pontos retornados pelos descritores para cada imagem. Cada ponto fornecido retorna um vetor com 64 características para cada ponto de interesse. Formando uma matriz de N linhas por 64 características, conforme ilustrado na Figura 2.



**Figura 2. Exemplo de reconhecimento dos Poi e obtenção do vetor de atributos**

Com o objetivo de referenciar somente um vetor de características para cada imagem, realizou-se o cálculo da média das linhas da matriz, gerando um único vetor para cada imagem, conforme ilustrado na Figura 2. Conseqüentemente, foi incluído no vetor de características uma célula para identificar a classe correspondente. Para a etapa de classificação, foram utilizados classificadores para simular a identificação dos vetores obtidos nas classes correspondentes aos valores de cada cédula monetária.



## 5. Metodologia de Avaliação dos Resultados

Esta seção apresenta as metodologias de avaliação dos resultados aplicados no desenvolvimento deste trabalho.

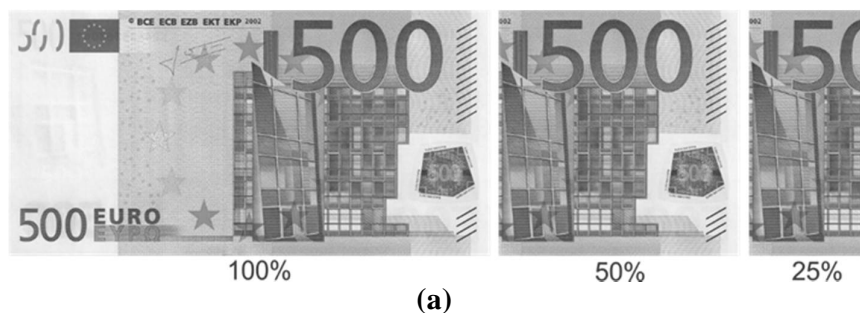
### 5.1. Base de Imagens

Para avaliar os resultados, foi criada uma base de dados para cada uma das moedas. Para cada cédula, gerou-se 56 imagens. No total, as bases de imagem de dólar e euro possuem 392 imagens, enquanto que a de real possui 336 imagens. As imagens das cédulas de dólar foram obtidas por meio de pesquisas na internet. As imagens das cédulas de Euro, foram retiradas do trabalho de Costa *et al.* [5], e as imagens da segunda família de Real, foram adquiridas na *webpage* do Banco Central do Brasil<sup>1</sup>.


A metodologia de criação da base segue 2 passos. Inicialmente, foram utilizadas imagens de frente e verso, variando a posição em horizontal, vertical, rotação em 90° graus a direita, rotação em 90° graus a esquerda e rotação a 180° graus, totalizando 8 imagens de cada valor de notas para cédulas inteiras.

Em aplicações reais, dificilmente será analisada uma cédula inteira. Em vista disso, foram incluídas na base de teste notas divididas ao meio e em quatro partes (Veja a Figura 3(a)). Com isso, obtêm-se um total de 56 imagens de cada classe.

A fim de incrementar as ações de processamento de imagem e testes dos descritores, juntamente com os classificadores, foram elaboradas mais 4 bases de imagens, são elas: 1) com a aplicação do filtro da mediana, usando janela de tamanho [5x5], para simular uma imagem borrada das cédulas (veja Figura 3(b)); 2) com a inserção do ruído “Salt & Pepper” na proporção de 0,05; 3) utilizando a junção do efeito de borramento com a aplicação do ruído; 4) com a junção de todas as bases (boa qualidade, borramento, ruído e borramento com ruído).



<sup>1</sup><http://www.bcb.gov.br/novasnotas/index.html>.



**Figura 3. Exemplo de imagens de notas monetárias apresentadas no banco de dados utilizado nos testes**

## 5.2. Métricas de Avaliação

Neste trabalho foram analisados os dados gerados pelos detectores e descritores nas bases de imagens, utilizando o método de avaliação *10-fold cross validation* [10]. Utilizou-se 90% dos dados para treinamento e o restante para etapa de teste. Nessa etapa, foram processados os arquivos gerados com os PoIs, utilizando os quatro classificadores e os dois comitês avaliados.

Após a realização dos testes, gerou-se uma matriz de confusão, sendo composta por 4 valores: Verdadeiro Positivo (VP), Falso Positivo (FP), Falso Negativo (FN) e Verdadeiro Negativo (VN), a partir desses valores foram computadas as seguintes métricas de avaliação: *Sensibilidade*, Equação 1, que representa a frequência com que o teste detectará o que está sendo testado; *Especificidade*, Equação 2, que representa a frequência com que o resultado negativo está correto; e *Precisão*, Equação 3, que ilustra a proporção de casos que são verdadeiramente de uma classe dividido pelo total de casos classificados como essa classe.

$$\text{Sensibilidade} = \frac{VP}{VP + FN} \quad (1)$$

$$\text{Especificidade} = \frac{VN}{VN + FP} \quad (2)$$


$$\text{Precisão} = \frac{VP}{VP + FP} \quad (3)$$

## 6. Resultados e Discussão


Esta seção apresenta os resultados de validação da análise dos descritores e classificadores, utilizando as bases de imagem de Dólar, Euro e Real. Para essa validação, foram detectados os PoIs das imagens, gerado os arquivos com as informações dos PoIs e os arquivos foram processados pelos classificadores.




De acordo com a Figura 4, referente aos testes executados na base de imagens das cédulas de Dólar, o descritor SURF combinado com o classificador MLP obtiveram a melhor taxa de acerto com um índice de sensibilidade de 0,973, especificidade de 0,996 e precisão de 0,973, vide Figura 4(a), 4(b) e 4(c), respectivamente. O descritor BRISK em conjunto com o classificador RBF apresentou o pior resultado, com um índice de sensibilidade de 0,429, especificidade de 0,905 e precisão de 0,434.



(a) Resultado do cálculo da sensibilidade nas cédulas de Dólar.



(b) Resultado do cálculo da especificidade nas cédulas de Dólar.



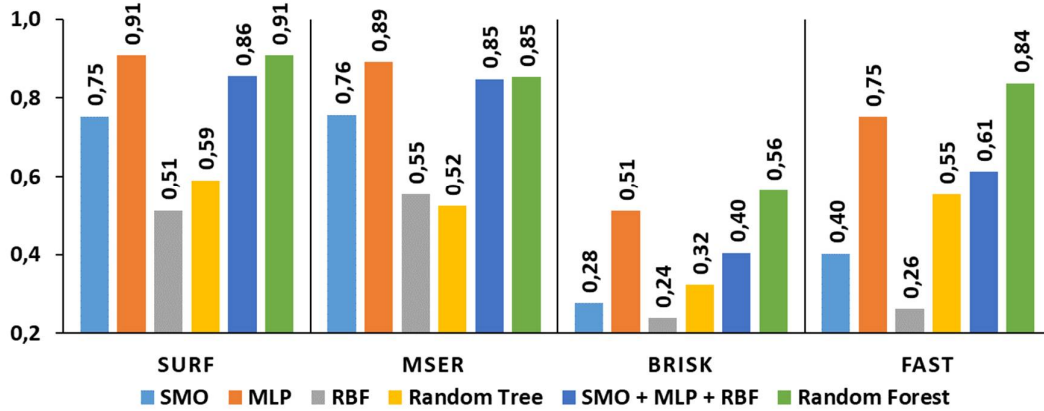
(c) Resultado da cálculo da precisão nas cédulas de Dólar.

Figura 4. Resultado da classificação utilizando cédulas de Dólar.


A Figura 5 apresenta os resultados dos experimentos realizados na base de imagens de Euro. A melhor taxa de acerto foi obtida a partir do conjunto formado pelo descritor SURF e o classificador MLP ou *Random Forest* com um índice de sensibilidade de 0,908, especificidade de 0,985. A melhor precisão foi alcançada pelo classificador *Random Forest* com um índice de 0,908, resultado superior ao obtido pelo classificador MLP, conforme ilustrado na Figura 5(c). O descritor BRISK em conjunto com o classificador RBF apresentou o pior resultado, com um índice de sensibilidade de 0,239, especificidade de 0,873 e precisão de 0,268.

Analisando a Figura 6, referente aos testes executados nas bases de imagens de Real, verificou-se que o descritor SURF obteve o melhor resultado em conjunto com o classificador *Random Forest*, obtendo a maior classificação com um índice de sensibilidade de 0,908, especificidade de 0,985 e precisão de 0,908, vide Figura 6(a), 6(b) e 6(c), respectivamente. O descritor BRISK em conjunto com o classificador RBF permaneceram com o pior resultado, com um índice de sensibilidade de 0,239, especificidade de 0,873 e precisão de 0,268.


De acordo com os testes realizados com os descritores, demonstrou-se que o melhor resultado foi obtido pelo SURF em conjunto com o classificador *Random Forest* (para as cédulas de Real) e o descritor SURF com o classificador MLP (para as cédulas de Dólar e Euro), que obtiveram uma taxa de acerto maior em grande parte dos testes.



(a) Resultado do cálculo da sensibilidade nas cédulas de Euro.




(b) Resultado do cálculo da especificidade nas cédulas de Euro.




(c) Resultado da cálculo da precisão nas cédulas de Euro.


Figura 5. Resultado da classificação utilizando cédulas de Euro



(a) Resultado do cálculo da sensibilidade nas cédulas de Real.



(b) Resultado do cálculo da especificidade nas cédulas de Real.



(c) Resultado da cálculo da precisão nas cédulas de Real.

Figura 6. Resultado da classificação utilizando cédulas de Real

Os testes realizados utilizando comitês não conseguiram superar os resultados obtidos pelo classificador MLP. Contudo, para o uso em sistemas automatizados, é aconselhado o uso do comitê *Random Forest*, pois esse alcançou taxas de acerto bem próximas às taxas do MLP, utilizando tempo de processamento muito inferior ao MLP.

Foram realizados testes combinando dois dos melhores descritores identificados neste estudo, a saber: SURF e MSER. Na comparação ao MSER os resultados melhoraram, contudo não conseguiram obter um índice de classificação superior ao alcançado com o descritor SURF.

## 7. Conclusão

A visão computacional está evoluindo constantemente, tornando-se uma ferramenta que poderá ser utilizada em diferentes áreas, bem como para o auxílio a pessoas com deficiência, auxiliado com o uso das tecnologias assistivas.

Este estudo se destacou dos demais trabalhos relacionados, pois visa a utilização do cálculo da média dos PoI detectados para a geração da assinatura, buscando o melhor descritor e classificador para as cédulas monetárias mais utilizadas mundialmente e de uso nacional. Diferenciou-se também pela forma de análise das cédulas monetárias, buscando identificá-las em diferentes perspectivas, orientações e com oclusões, aumentando o poder de reconhecimento das notas em ambientes não-controlados.

No geral, identificou-se que a abordagem proposta é capaz de reconhecer com precisão a maioria das denominações testadas, com uma taxa de acerto acima de 90%. Foram realizados testes nas bases de imagens em boa qualidade, com borramento, com ruído e borramento com ruído. Nos resultados apresentados, foram ilustrados apenas os testes utilizando a junção de todas as bases, para testar a robustez do método em maior quantidade de imagens e em diferentes situações.

Como trabalhos futuros, espera-se a utilização dos descritores e classificadores analisados em uma classificação automática de cédulas, servindo como base para a criação de aplicações a serem utilizados em dispositivos móveis, que possam auxiliar os deficientes visuais na identificação dos valores das cédulas monetárias. Sugere-se também testes com outras formas de geração das assinaturas e outros descritores em conjunto com classificadores, na tentativa de alcançar resultados melhores.

## Referências

- [1] Abburu, V., Gupta, S., Rimitha, S. R., Mulimani, M., & Koolagudi, S. G. (2017). Currency recognition system using image processing. In Contemporary Computing (IC3), 2017 Tenth International Conference on IEEE, pp. 1-6.
- [2] Alahi, A., Ortiz, R., & Vanderghenst, P. (2012). Freak: Fast retina keypoint. In Computer vision and pattern recognition (CVPR), 2012 conference on IEEE, pp. 510-517.
- [3] Bay, H., Tuytelaars, T., & Van Gool, L. (2006). Surf: Speeded up robust features. In European conference on computer vision, pp. 404-417. Springer, Berlin, Heidelberg.

- [4] Breiman, L. (2001). Random Forests Machine Learning. 45: 5–32. View Article PubMed/NCBI Google Scholar.
- [5] Costa, C. M., Veiga, G., & Sousa, A. (2016). Recognition of banknotes in multiple perspectives using selective feature matching and shape analysis. In *Autonomous Robot Systems and Competitions (ICARSC), 2016 International Conference on IEEE*, pp. 235-240.
- [6] De Castro, L. N., Von Zuben, F. J., & de Deus Jr, G. A. (2003). The construction of a Boolean competitive neural network using ideas from immunology. *Neurocomputing*, 50, pp. 51-85.
- [7] Grijalva, F., Rodriguez, J. C., Larco, J., & Orozco, L. (2010). Smartphone recognition of the US banknotes' denomination, for visually impaired people. In *ANDESCON, 2010 IEEE*, pp. 1-6.
- [8] Hasanuzzaman, F. M., Yang, X., & Tian, Y. (2012). Robust and effective component-based banknote recognition for the blind. *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, 42(6), 1021-1030.
- [9] Jeong, K., & Moon, H. (2011). Object detection using FAST corner detector based on smartphone platforms. In *Computers, Networks, Systems and Industrial Engineering (CNSI), 2011 First ACIS/JNU International Conference on IEEE*, pp. 111-115.
- [10] Kohavi, R. (1995). A study of cross-validation and bootstrap for accuracy estimation and model selection. In *Ijcai*. Vol. 14, No. 2, pp. 1137-1145.
- [11] Leutenegger, S., Chli, M., & Siegwart, R. Y. (2011). BRISK: Binary robust invariant scalable keypoints. In *Computer Vision (ICCV), 2011 International Conference on IEEE*, pp. 2548-2555.
- [12] Liu, F. T., Ting, K. M., Yu, Y., & Zhou, Z. H. (2008). Spectrum of variable-random trees. *Journal of Artificial Intelligence Research*, 32, 355-384.
- [13] Braga, A. D. P., Carvalho, A. P. L. F., & Ludermir, T. B. (2000). *Redes neurais artificiais: teoria e aplicações* (pp. 05-55). Livros Técnicos e Científicos.
- [14] Maia, J. (2010). *Detecção e reconhecimento de objetos usando descritores locais*, Tese de Doutorado. Universidade Federal do Ceará, Fortaleza, 2010.
- [15] Matas, J., Chum, O., Urban, M., & Pajdla, T. (2004). Robust wide-baseline stereo from maximally stable extremal regions. *Image and vision computing*, 22(10), 761-767.
- [16] Mortensen, E. N., Deng, H., & Shapiro, L. (2005). A SIFT descriptor with global context. In *Computer Vision and Pattern Recognition, 2005. CVPR 2005. Computer Society Conference on IEEE*. Vol. 1, pp. 184-190.
- [17] Muja, M., & Lowe, D. G. (2009). Fast approximate nearest neighbors with automatic algorithm configuration. *VISAPP (1)*, pp. 331-340.
- [18] Mulmule-Shirkhedkar, D., & Dani, A. R. (2015). Comparative study of surf and freak descriptor on indian rupee currency notes. In *Information Processing (ICIP), 2015 International Conference on IEEE*, pp. 784-789.



- [19] Musavi, M. T., Ahmed, W., Chan, K. H., Faris, K. B., & Hummels, D. M. (1992). On the training of radial basis function classifiers. *Neural networks*, 5(4), 595-603.
- [20] Oyedotun, O. K., & Khashman, A. (2017). Banknote recognition: investigating processing and cognition framework using competitive neural network. *Cognitive neurodynamics*, 11(1), 67-79.
- [21] Pascolini, D., & Mariotti, S. P. (2012). Global estimates of visual impairment: 2010. *British Journal of Ophthalmology*, 96(5), 614-618.
- [22] Pass, G., Zabih, R., & Miller, J. (1997, February). Comparing images using color coherence vectors. In *Proceedings of the fourth ACM international conference on Multimedia*, pp. 65-73
- [23] Platt, J. C. (1999). 12 fast training of support vector machines using sequential minimal optimization. *Advances in kernel methods*, 185-208.
- [24] Rublee, E., Rabaud, V., Konolige, K., & Bradski, G. (2011). ORB: An efficient alternative to SIFT or SURF. In *Computer Vision (ICCV), 2011 IEEE international conference on IEEE*, pp. 2564-2571.
- [25] Shi, J. (1994). Good features to track. In *Computer Vision and Pattern Recognition, 1994. Proceedings CVPR'94., Computer Society Conference on IEEE*, pp. 593-600.
- [26] Suykens, J. A., & Vandewalle, J. (1999). Least squares support vector machine classifiers. *Neural processing letters*, 9(3), pp. 293-300.
- [27] Teixeira, V. V., Braga, J. C., & do Nascimento, M. Z. (2016). Aplicativo identificador de cédulas para deficientes visuais. *Revista de Informática Aplicada*, 11(1).
- [28] Treiber, M. A. (2010). *An introduction to object recognition: selected algorithms for a wide variety of applications*. Springer Science & Business Media.
- [29] Yan, H., Jiang, Y., Zheng, J., Peng, C., & Li, Q. (2006). A multilayer perceptron-based medical decision support system for heart disease diagnosis. *Expert Systems with Applications*, 30(2), pp. 272-281.