



Reconhecimento automático de cédulas do Real baseado em Máquinas de Vetor Suporte

*Support vector machine implementation to
recognize Brazilian Real bills.*

Ricardo Suyama (ricardo.suyama@ufabc.edu.br)

*Doutor em Engenharia Elétrica pela Universidade Estadual de
Campinas (Unicamp) e professor adjunto da Universidade Federal
do ABC (UFABC).*

Fernando Henrique Gomes Zucatelli (fernandozucatelli@yahoo.com.br)

*Mestre em Engenharia de Mecânica pela Universidade Federal do
ABC (UFABC).*

Nathalia de Paula Silva (nathalia.paula@aluno.ufabc.edu.br)

*Bacharel em Engenharia de Instrumentação, Automação e
Robótica pela Universidade Federal do ABC (UFABC).*

Resumo

Redes neurais e sistemas inteligentes vêm sendo amplamente utilizados em diversas tarefas de identificação de padrões. Neste trabalho, apresenta-se a implementação de um algoritmo inteligente desenvolvido em MATLAB®, com o objetivo de classificar e reconhecer cédulas do Real a partir do uso de uma Máquina de Vetor Suporte. São utilizados dados de treino na rede neural extraídos de diferentes imagens de diversas cédulas, empregando como parâmetros a “razão de maior lado por menor lado” e uma análise da matriz RGB de cores de cada cédula. A classificação das cédulas é feita a partir de uma imagem que contém um grupo aleatório de cédulas. Essas cédulas são identificadas na imagem e, em seguida, tratadas para a extração dos parâmetros e posterior análise e classificação de acordo com a SVM previamente treinada. Os resultados são apresentados por uma matriz de confusão sendo obtidas quarenta e quatro identificações corretas entre as cinquenta amostras apresentadas à rede.

Palavras-chave: Máquina de Vetor Suporte. Reconhecimento de padrões. Identificação de imagens. Função de base radial.

Abstract

Neural networks have been applied to many different pattern recognition tasks. This paper presents an intelligent algorithm implemented in MATLAB®. The aim is to classify and recognize bills of Real currency using a Support Vector Machine. The training data set is extracted from different photos of the bills, employing the extracted parameters of “major and minor side ratio” and RGB colors matrix of each bill. The classification of bills is done from an image which contains a random set of bills; these bills are identified on the image; they are treated to extract the parameters and to analyze and classify them according to the previous trained neural network. Results are presented by an error matrix in which forty-four correct identifications were obtained among fifty samples presented to the neural network.

Keywords: : Support Vector Machine. Pattern recognition. Radial base function. Image identification.

Introdução

O reconhecimento automático de objetos por meio de imagens tem sido um tema de pesquisa recorrente e pode ser considerado um problema central na área de visão computacional. O grande interesse no problema decorre da ampla gama de aplicações que necessitam de métodos eficientes e robustos para o processamento automático das imagens.

No presente trabalho, apresenta-se o problema específico de reconhecimento automático de cédulas monetárias, uma tarefa que pode auxiliar tanto em operações cotidianas de bancos, máquinas de venda automática e caixas eletrônicos como também para auxiliar a identificação de cédulas por pessoas com deficiência visual (TEIXEIRA et al., 2015).

Nesse contexto, diferentes técnicas têm sido propostas na literatura, e várias dessas abordagens se baseiam em técnicas usualmente associadas à área de aprendizado de máquina. Por exemplo, Takeda e Omatu (1994) exploram o uso de redes neurais artificiais para realizar a identificação de cédulas, ideia que também é explorada por Takeda e Nishikage (2000) para a identificação de cédulas do Euro. Teixeira et al. (2015) apresentam uma metodologia baseada em Máquinas de Vetores Suporte (SVM) para realizar a identificação das cédulas de Real; outras propostas que exploram técnicas de aprendizado de máquina para a identificação de cédulas ou outras características presentes nas imagens são encontradas em Zhang (2003), Althafiri et al., (2006), Bertanha et al. (2015), Qian et al. (2006), Higa (2015), Frosini (1996) e Guo (2010).

Embora as ferramentas utilizadas para a identificação das cédulas descritas nos artigos citados anteriormente possuam diferenças entre si, os trabalhos abordam a identificação das cédulas como um problema de classificação de padrões, para o qual a solução é construída seguindo-se basicamente três etapas:

1. Aquisição e pré-processamento dos dados: os dados a serem classificados correspondem às imagens das cédulas, que podem ser pré-processadas para auxiliar as etapas subsequentes do sistema (como aumentar o contraste de cores, ampliar ou reduzir a imagem);
2. Extração de características: a classificação dos padrões normalmente não é realizada diretamente sobre os dados (no caso, a imagem), pois muitas vezes a dimensão dos dados torna o custo computacional proibitivo. Dessa forma, em geral, a classificação é feita a partir de características relevantes extraídas dos dados que permitam diferenciar os padrões – por exemplo, na aplicação de identificação de cédulas, pode-se utilizar a cor e o tamanho das cédulas para determinar o seu valor (HASSANPOUR, 2007), - ou características das bordas dentro da imagem para auxiliar no processo de identificação, de maneira a melhorar o desempenho do classificador mesmo com a presença de distorções na imagem ou rasuras nas cédulas (ALTHAFIRI et al., 2006);
3. Classificação: uma vez extraídas as características, é necessário escolher um método de classificação que seja eficiente para realizar a identificação correta dos padrões. Conforme mencionado anteriormente, técnicas de aprendizado de máquina como redes neurais e máquinas de vetores suporte têm sido aplicadas com sucesso nesse contexto.

Obviamente, há uma infinidade de possibilidades de escolha para cada uma das etapas mencionadas anteriormente, mas, no presente trabalho, procurou-se encontrar uma solução que apresentasse um bom compromisso entre complexidade computacional e desempenho. Nesse sentido, optou-se por realizar a classificação baseada em características simples, como cor e tamanho das cédulas, a fim de não aumentar demasiadamente a complexidade da solução e assim permitir o uso de ferramentas de classificação como as SVMs, que apresentam grande flexibilidade e robustez, atestadas em diferentes trabalhos na literatura.

Assim, a fim de apresentar o método proposto, o artigo foi estruturado da seguinte forma: na Seção 2 apresenta-se a metodologia adotada no trabalho; na Seção 3, são apresentados os resultados e as discussões; e, por fim, na Seção 4, são feitas as conclusões e considerações finais.

Máquinas de Vetores Suporte

As máquinas de vetores suporte, introduzidas por Vapnik (1995, 1998), constituem-se em uma importante ferramenta na área de aprendizado de máquina para a classificação de padrões (HAYKIN, 2001). A partir de um conjunto de dados previamente classificados – uma abordagem de aprendizado supervisionado – o algoritmo de treinamento da SVM obtém um modelo que atribui a cada novo dado apresentado uma das categorias definidas no conjunto de treinamento (THEODORIDIS; KOUTROUMBAS, 2008).

Geometricamente, a operação realizada pela SVM é ilustrada na Figura 1. Os dados de duas classes distintas, representados pelos símbolos \square e \circ , são separados por meio de um hiperplano, que define a fronteira de decisão para a classificação dos novos dados. Embora seja possível identificar uma infinidade de hiperplanos que separam corretamente os dados, o hiperplano ótimo é definido como aquele que maximiza a margem de separação α_0 , isto é, aquele que maximiza a distância entre o hiperplano de separação e os dados de cada classe mais próximos, conforme indicado na Figura 1. A maximização da margem ajuda a minimizar erros de classificação dos novos dados, conferindo grande robustez e capacidade de generalização à SVM. Os dados mais próximos ao hiperplano de separação, que definem a margem de separação, são denominados vetores suporte, justificando assim o nome atribuído à ferramenta.




Figura 1. Disposição de um hiperplano ótimo para padrões linearmente separáveis.

Além disso, uma grande vantagem das SVMs em relação a outros classificadores se refere ao algoritmo de ajuste de seus parâmetros. O hiperplano de separação ótimo é obtido por meio da solução de um problema de otimização convexa com restrições de desigualdade lineares, garantindo assim que não há mínimos locais no processo de otimização – diferentemente do que ocorre no caso de adaptação de outras estruturas não lineares usualmente empregadas para a classificação, como as redes neurais artificiais (HAYKIN, 2001).

Mesmo em cenários nos quais os dados não sejam linearmente separáveis, é possível empregar a SVM para a classificação – de fato, na proposta original de Vapnik, o grande diferencial da técnica reside no fato de ela realizar a classificação de dados não linearmente separáveis. Para isso, os dados devem ser mapeados em um espaço de maior dimensão por meio de funções não lineares, de maneira que os dados transformados sejam linearmente separáveis – situação na qual é aplicada a mesma metodologia para a definição do hiperplano de separação ótimo descrita anteriormente. A escolha do mapeamento utilizado pela SVM está atrelada à seleção de uma função de *kernel* (núcleo), que realiza o produto interno entre os vetores transformados. Dentre as possibilidades para o *kernel* pode-se citar o *kernel* linear – que corresponde a uma SVM linear, conforme descrita anteriormente – o *kernel* polinomial e o *kernel* baseado em funções de base radial (RBF) (HEIMES E VAN HEUVELN, 1998).

As RBFs são uma classe especial de funções que decresce (ou cresce) monotonicamente ao se distanciar do ponto central. Podem ser utilizadas como funções base em qualquer tipo de modelo de regressão não linear e, particularmente, como funções de ativação de redes neurais artificiais (REZENDE, 2003). Na Figura 2, é apresentado um exemplo de arquitetura de rede neural artificial que utiliza funções de base radial gaussiana (φ), disponíveis em uma camada oculta, camada essa que é intermediária em relação às camadas de entrada e saída. As forças de conexões interneurais, caracterizadas como pesos sinápticos \mathbf{w} , são usadas para armazenar o conhecimento adquirido e disponibilizar as respectivas saídas \mathbf{y} (HAYKIN, 2009).

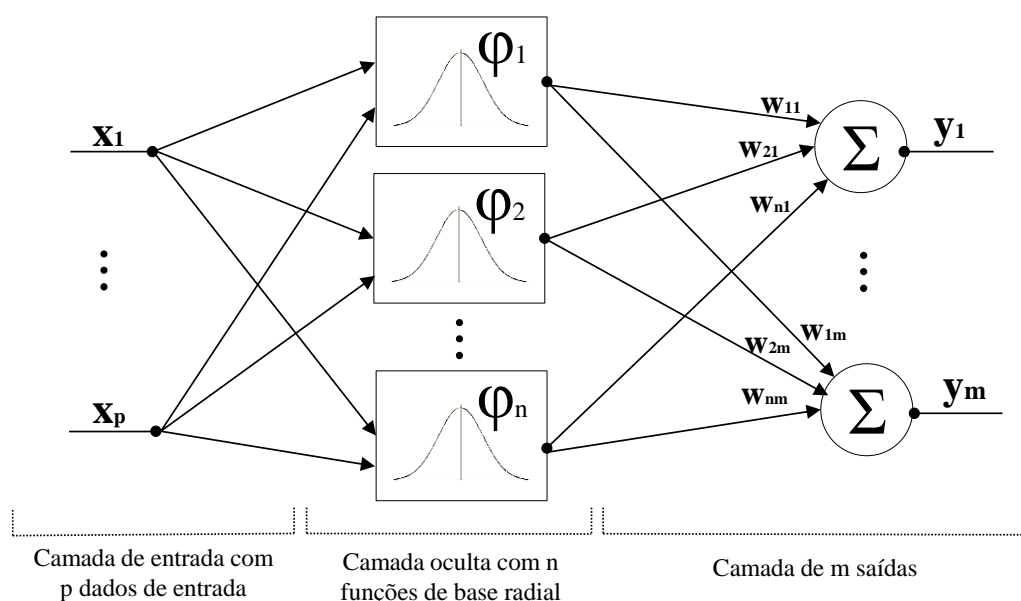


Figura 2. Modelo de rede neural RBF.

Metodologia adotada para classificação das cédulas

Neste trabalho, considerou-se apenas a segunda família de cédulas de Real brasileiro, produzidas a partir de 2010 pelo Banco Central Brasileiro (BCB), que possuem diferentes tamanhos e cores, cujos padrões garantem maior acessibilidade e dificultam falsificações (BCB, 2015).

As imagens das cédulas do Real utilizadas no treinamento da SVM representavam cada cédula com valor identificado e em um arquivo separado, a partir das quais foram extraídas as características para classificação: optou-se por coletar a relação dos lados de cada cédula, que é particular para as cédulas novas do Real, e as cores RGB (*Red-Green-Blue*; em português, Vermelho-Verde-Azul) de cada uma delas.

As imagens a serem classificadas, denominadas como espaço de dados, foram dispostas em diferentes tamanhos e nas orientações vertical e horizontal em uma imagem de tamanho 800 x 600 *pixels*. Desejava-se obter o valor de cada cédula presente na imagem do espaço de dados, o que permitiria, por exemplo, informar os valores de diversas cédulas presentes na imagem a um deficiente visual.

A SVM foi treinada com quatro exemplares de cada verso das cédulas do Real, totalizando 48 imagens em arquivos individuais de um banco de dados. A Figura 3 apresenta o processo de treinamento extra e características relevantes das cores da imagem e sua relação de lados, seguido do treinamento da rede e armazenamento dos resultados para a classificação das cédulas contidas nos espaços de dados.

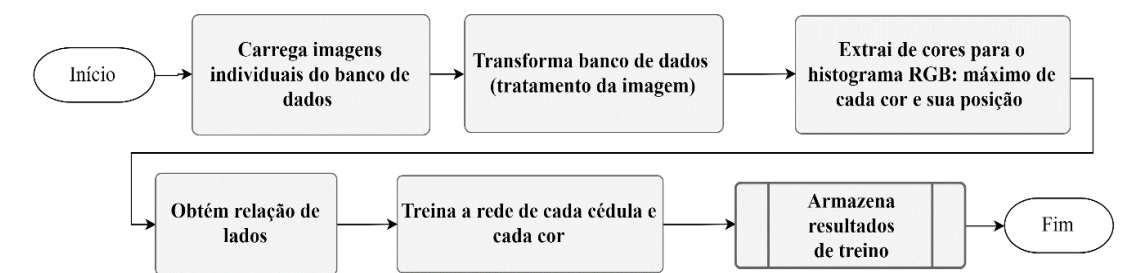


Figura 3. Fluxograma do programa para treino da rede.

A solução completa desenvolvida é composta por quatro módulos com as seguintes funções: (i) *Extrair a Relação dos Lados*; (ii) *Extrair as Cores*; (iii) *Encontrar as Cédulas na Imagem*; (iv) *Classificação por SVM*. Na Figura 3 foram aplicados os módulos (i) e (ii) para a coleta de dados.

O módulo (i), cujos comandos em MATLAB[®] são apresentados entre aspas, consiste em transformar o espaço de dados em escala de cinza (comando “*rgb2gray*” (SONG, 2013)) e, em seguida, transformá-lo em preto e branco (“*im2bw*” (MAHMOOD et al., 2011)), de

modo a obter apenas valores binários usando um valor de limiar que permita separar a cédula do fundo branco. Posteriormente, branco e preto são invertidas (“*not*”) para uso das funções que criam uma estrutura morfológica de formato retangular dentro dela (“*strel*” (ALHADIDI; ZU’BI; SULEIMAN, 2007)), regiões com poucos bits são limpas (“*bwareaopen*”) e a estrutura é fechada (“*imclose*”) até encontrar as bordas. Preenchem-se os possíveis buracos internos (“*imfill*”), de forma que seja possível criar as fronteiras da imagem (“*bwboundaries*”) e extrair as propriedades de cada lado (“*regionprops*”) (MAHMOOD et al., 2011) para finalmente obter a relação dos lados. No caso dos dados de treinamento, essa tarefa se reduz a encontrar a própria borda da imagem.

O módulo (ii) extrai as propriedades de cores a partir de um histograma – conforme exemplos apresentados na Figura 4 para cédulas de R\$ 2 e de R\$ 50 – obtendo o valor máximo de cada cor RGB e a posição desse máximo na escala de 0 a 255 (8 bits).

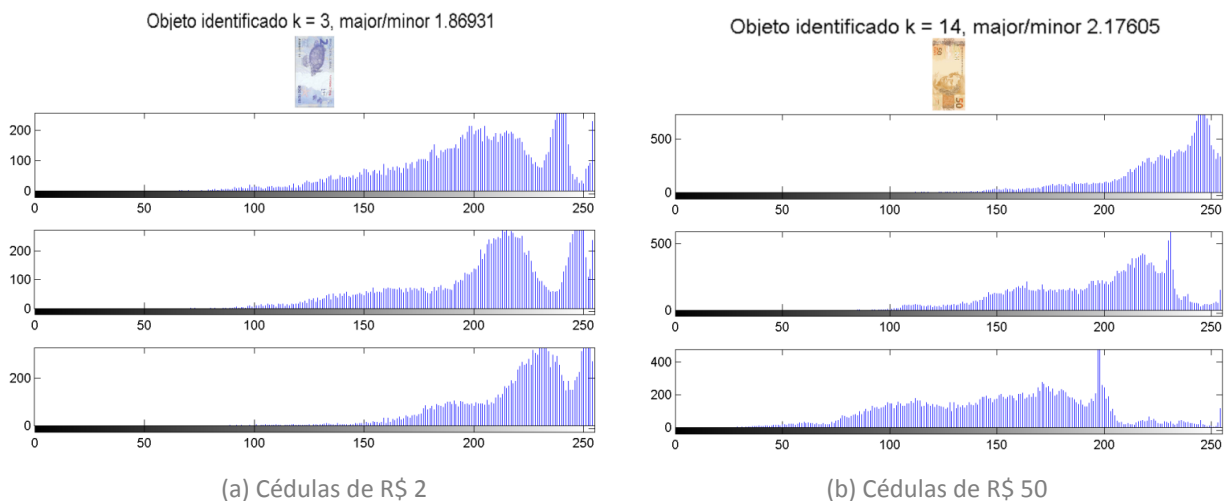


Figura 4. Exemplo de histogramas distintos de cores; a seqüência de cima para baixo é vermelho, verde e azul.

O uso do máximo e sua posição foram testados anteriormente como os únicos critérios de classificação, entretanto sem resultados satisfatórios. Então se optou por usar a relação dos lados como um dos critérios de classificação em combinação com a posição do máximo do histograma de cada cor.

No módulo (iii), o objetivo é realizar a segmentação da imagem, identificando as regiões retangulares da imagem original (Figura 5(a)) nas quais se encontram as cédulas. Para isso, uma vez que o fundo da imagem é sempre mais claro que as cédulas, utiliza-se inicialmente a abordagem de limiar. Os *pixels* da imagem que apresentam uma intensidade menor do que certo limiar (mais escuros) são substituídos por *pixels* da cor preta. Com isso, as regiões onde possivelmente encontram-se as cédulas são destacadas como regiões predominantemente preenchidas com a cor preta (Figura 5(b)).

Eventualmente, alguns *pixels* no interior dessas regiões apresentam cores claras (quando, por exemplo, a imagem original contém pixels de cor mais intensa – mais clara – do que o limiar) e que devem ser “limpos” a fim de que os procedimentos subsequentes de identificação da imagem obtenham resultados corretos. Para isso,

inverteu-se o padrão de cores da imagem pré-processada, de tal forma que as regiões contendo as cédulas são destacadas em branco, o que permite utilizar a função “*strel*” (ALHADIDI; ZU’BI; SULEIMAN, 2007). O resultado é apresentado na Figura 5(c).




Figura 5: operações realizadas no módulo (iii) para localização das cédulas.

A etapa final consiste em determinar as regiões retangulares que contêm as cédulas. Para isso, reutiliza-se o módulo (i) em cada uma das regiões em branco destacadas anteriormente. Com isso, é possível extrair a informação de relação entre as bordas de cada cédula da imagem (Figura 6(a)), bem como a localização da cédula dentro da imagem original (Figura 6(b)). Com a correta identificação dos objetos nas imagens, as respectivas regiões da figura original são destacadas e o seu histograma de cores é extraído com o módulo (ii) para uso posterior pelo classificador.




Figura 6: operações finais do módulo (iii) localizando regiões dos dados para aplicar o módulo (ii).

O módulo (iv) é o classificador baseado em SVMs, e para a maior parte das cédulas foram utilizadas SVMs com *kernels* lineares. Entretanto, após as primeiras visualizações dos dados, notou-se que as notas de R\$ 5 e de R\$ 2 não eram linearmente separáveis, o que implicava em erros de classificação para quaisquer vetores de características utilizados. Por esse motivo, apenas para a classificação dessas cédulas, foram utilizadas SVMs com *kernels* de RBFs.

Para o problema proposto há seis possíveis classes, correspondendo aos seis valores de cédulas. A abordagem escolhida para realizar a classificação com a SVM foi baseada no paradigma “um contra todos”, *i.e.*, a SVM é treinada para determinar se a imagem corresponde a um grupo específico de cédulas ou não. No primeiro caso, a imagem terá valor atribuído e os demais classificadores, mesmo que a classifiquem como do seu

grupo, terão a atribuição de resultado ignorado. Caso contrário, a imagem será analisada pela etapa seguinte de classificação.

Percebeu-se, portanto, que não era eficaz classificar todos os conjuntos entre si simultaneamente, e a sequência de classificação, ilustrada no fluxograma da Figura 7, foi construída para priorizar as características mais excludentes de um conjunto do restante; o critério se baseou em um vetor de características com quatro elementos: os valores da posição do máximo de cada cor R, G e B da imagem e a relação entre os lados do retângulo.

Na Figura 7, para cada nota do espaço de dados, aplica-se o classificador de R\$ 100, que utiliza análise RGB com *kernel* linear; as notas classificadas como R\$ 100 são marcadas com seu respectivo valor de tal forma que o próximo classificador não lhes atribua valor. O próximo classificador é então aplicado ao espaço de dados, porém só pode atribuir valor às cédulas que ainda não foram classificadas. Esse processo ocorre sucessivamente até o último classificador. Salienta-se que o fluxo do programa continua em execução; os classificadores são aplicados a todas as cédulas, apenas ignorando aquelas que já foram classificadas.

As notas de R\$ 100, por exemplo, se separam do conjunto pela predominância do azul e das notas de R\$ 2 pela relação dos lados. Ao terem o seu valor definido, as notas de R\$100 serão ignoradas quando os próximos classificadores forem realizar sua classificação. Segue-se para a nota de R\$ 50, que possui a próxima maior relação de lados com cor distinta do resto do conjunto; depois a de R\$ 10, pela predominância do vermelho; a de R\$ 20, que pela relação dos lados é distinguível das restantes, R\$ 5 e R\$ 2. Essas duas últimas notas, que possuem relações de lado próximas, necessitaram de análise combinada de cores e uso de função radial devido à concentração dos dados distribuídos entre os classificadores SVM, caracterizados como não lineares.

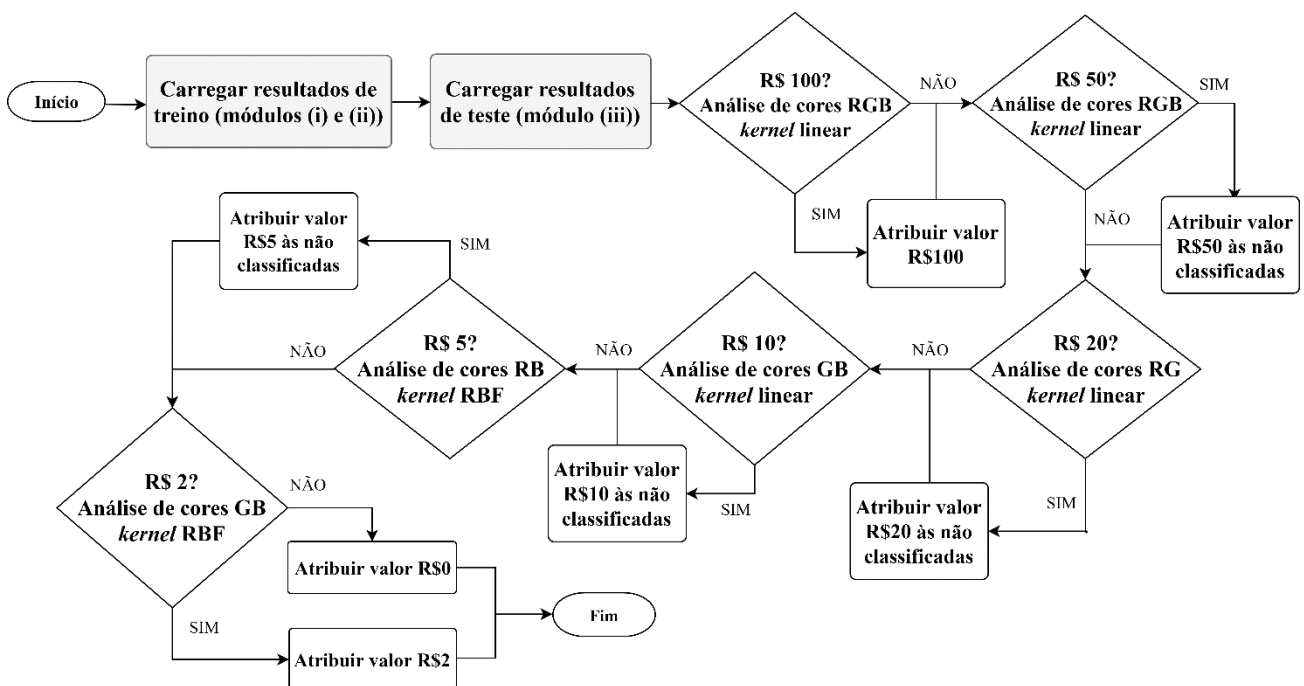


Figura 7. Fluxograma de funcionamento para classificação SVM das cédulas.

A sequência de processamento das diferentes cédulas evita que a análise de características posteriores tenha influência nos resultados, tal como no caso das cédulas de R\$ 2 e de R\$ 100, que são predominantemente azuis, mas têm relações de lados distintas.

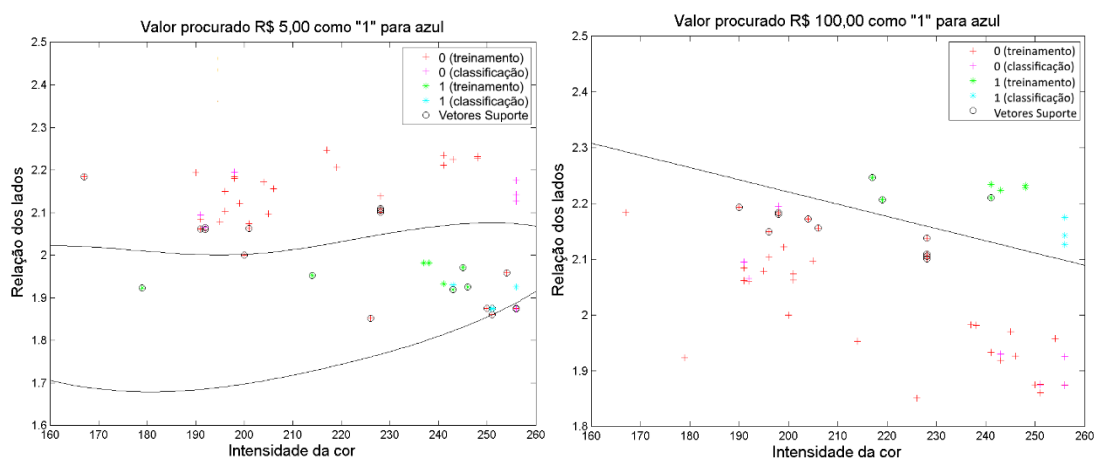
Assumindo que as classificações não detectaram nenhuma das notas entre R\$ 10 e R\$ 100, as escolhas possíveis recaem sobre as cédulas de R\$ 5 e de R\$ 2. A tarefa de diferenciar estas notas, entretanto, mostrou-se consideravelmente mais desafiadora do que as demais. Como ambas as cédulas apresentam relação de lados bastante semelhantes, a diferenciação entre elas é feita, essencialmente, pela informação das cores da imagem. No entanto, embora visualmente as notas apresentem cores distintas, ao analisar os componentes RGB das cores predominantes em ambas as cédulas verificou-se que os valores são próximos entre si e dispostos de forma que dificulta a distinção entre as classes com classificação linear. Por esse motivo, foram os únicos passos nos quais a SVM treinada utiliza uma RBF como *kernel* para a classificação.

Quando o sistema informa que uma cédula foi classificada como R\$ 0, significa que nenhum dos classificadores a reconheceu corretamente. Além disso, ressalta-se que o programa é capaz de classificar cédulas com orientação de 0º, 90º, 180º ou 270º. Outras orientações não foram desenvolvidas e testadas por serem dependentes do programa de extração.

Resultados

Nos testes realizados foram feitas classificações com 50 imagens. Exemplos dos gráficos de treinamento e classificação produzidos pela rede SVM com linear e função de base radial (parâmetro desvio-padrão $\sigma = 1$ da função gaussiana (HAYKIN, 2001, p.292)) encontram-se na Figura 8.

A matriz de confusão da Tabela 1 apresenta os resultados para as 50 amostras testadas, das quais apenas seis foram confundidas (88% de acerto), sendo duas cédulas de R\$ 50 confundidas com a de R\$ 20; duas de R\$ 20 confundidas com a de R\$ 50 e outra de R\$ 20 não foi identificada pelos classificadores sendo-lhe atribuído o valor de R\$ 0, e uma nota de R\$ 10 foi confundida com R\$ 50.



(a) Cor azul R\$ 5 - função radial.

(b) Cor azul R\$ 100 - função linear.

Figura 8: exemplos de classificadores SVM (a) radial e (b) linear.

Tabela 1. Matriz de confusão.

Valor das notas		Expectativa					
		2	5	10	20	50	100
Resultado Obtido	2	10	0	0	0	0	0
	5	0	7	0	0	0	0
	10	0	0	8	0	0	0
	20	0	0	0	5	2	0
	50	0	0	1	2	8	0
	100	0	0	0	0	0	6
	0	0	0	0	1	0	0
Soma		10	7	9	8	10	6

Esses erros indicam que o código deve ser revisado e os classificadores para estes valores alterados para melhor separar os dois casos, cuja semelhança pode ser atribuída à proximidade da relação dos lados e cores próximas, conforme ilustrado na Figura 9, com os resultados de dois dos três erros, como pode ser verificado no texto escrito sobre a imagem que apresenta o resultado escrito diretamente pelo programa para a cédula apresentada na imagem. Além disso, mais testes com mais amostras a serem classificadas devem ser feitos para avaliar a real capacidade da rede em classificar os dados a ela apresentados.

Objeto testado k = 6, major/minor 2.12210
Classificado como nota de R\$ 20,00



(a) Classificação da nota de R\$ 50 como R\$ 20.

Objeto testado k = 6, major/minor 2.15851
Classificado como nota de R\$ 0,00



(b) Classificação de nota não identificada.

Figura 9. Exemplos de erros em cédulas de (a) R\$ 50 e (b) R\$ 20 em espaço de dados distintos.

Considerações finais

Conclui-se que a taxa de acertos da classificação das cédulas do Real foi de 88%, sendo corretamente classificadas 44 cédulas em um total de 50. Os classificadores de R\$ 20 e R\$ 50 ainda trocam alguns resultados entre si. Baseando-se no ocorrido para as notas de R\$ 2 e R\$ 5, pode-se testar a eficácia da classificação com funções radiais para estas duas cédulas. As funções radiais permitiram distinguir melhor as cédulas de R\$ 2 e de R\$ 5 entre si do que as lineares anteriormente utilizadas, permitindo destacar que a classificação é feita de forma melhorada usando as cores principais dos dois modelos, característica que não é possível de ser notada com o classificador linear. Apenas uma cédula de R\$ 20 não foi identificada e os demais erros estão relacionados às trocas de cédulas de R\$ 20 e de R\$ 50 entre si; dessa forma, o refinamento dos classificadores deve ser feito para estes dois elementos.

Com relação aos trabalhos futuros, pretende-se avançar, permitindo que a rede reconheça tanto cédulas novas quanto antigas, diferencie frente e verso, analise cédulas orientadas em posições não ortogonais e reconheça os padrões mesmo quando o modelo de espaço de dados contiver outros objetos além das cédulas, quando o fundo não for branco, e também se houver sobreposição de cédulas. Com isso, pode-se generalizar a rede, ampliando seus padrões de entrada e projetando-se um sistema de reconhecimento mais robusto.

Referências

- ALHADIDI, B; ZU'BI, M. H.; SULEIMAN, H. N. Mammogram breast cancer image detection using image processing functions. *Information Technology Journal*, v.6, n.2, p.217-221, 2007.
- ALTHAFIRI, Ebtessam, et al. Bahraini paper currency recognition. *Journal of Advanced Computer Science and Technology Research*, v. 2, n. 2, p. 104-115, 2012.
- BERTANHA, L. L. et al. Recognition of Brazilian Currency Notes via Feature Point Extraction. In: IX WVC 2013. vol. 9. Anais., Rio de Janeiro, 2013. Disponível em: <http://iris.sel.eesc.usp.br/wvc/Anais_WVC2013/Oral/1/2.pdf>. Acesso em: 06 set. 2016.
- BCB – Banco Central do Brasil. *Segunda Família do Real*. Disponível em: <<http://www.bcb.gov.br/novasnotas/index.html>>. Acesso em: 14 ago. 2015.
- FROSINI, A. et al. A neural network-based model for paper currency recognition and verification, *IEEE Transactions on Neural Networks*, vol. 7, no. 6, pp. 1482-1490, Nov 1996. doi: 10.1109/72.548175
- GUO, J. et. al. A reliable method for paper currency recognition based on LBP, *2010 2nd IEEE International Conference on Network Infrastructure and Digital Content*, Beijing, 2010, pp. 359-363. doi: 10.1109/ICNIDC.2010.5657978
- HASSANPOUR, H. et. al. Feature extraction for paper currency recognition, *Signal Processing and Its Applications, 2007. ISSPA 2007. 9th International Symposium on*, Sharjah, 2007, pp. 1-4. doi: 10.1109/ISSPA.2007.4555366
- MAHMOOD, N.H. et al. Measurement of the area and diameter of human pupil using Matlab. *5th Kuala Lumpur International Conference on Biomedical Engineering 2011*. Springer Berlin Heidelberg, p.686-689. Disponível em: <https://link.springer.com/chapter/10.1007/978-3-642-21729-6_167>. Acesso em: 07 jun. 2017.
- HAYKIN, Simon. *Redes Neurais: princípios e prática*. 2. Ed. Bookman, 2001.
- HAYKIN, Simon. *Neural Networks and Learning Machines*. 3. Ed. Pearson, 2009, pp. 1-46.
- HEIMES F.; VAN HEUVELN B. The normalized radial basis function neural network. *Systems, Man, and Cybernetics, 1998. 1998 IEEE International Conference on*, v.2. p.1609-1614. San Diego, CA, 1998,. doi: 10.1109/ICSMC.1998.728118. Disponível em: <<http://ieeexplore.ieee.org/document/728118/>>. Acesso em: 03 jul. 2016.
- HIGA, J.C.K. Desenvolvimento de técnicas para detecção e reconhecimento automático de números de série para cédulas de Real. 2015. Disponível em: <<http://bdm.unb.br/handle/10483/11047>>. Acesso em: 06 set. 2016.
- QIAN, Ji et. al. A Digit Recognition System for Paper Currency Identification Based on Virtual Instruments. *2006 International Conference on Information and Automation*, Shandong, 2006, pp. 228-233. doi: 10.1109/ICINFA.2006.374117
- REZENDE, S.O. . *Sistemas inteligentes: fundamentos e aplicações*. 1. Ed. Manole, 2003. ISBN 85-204-1683-7
- SONG, Y. et al. Decolorization: Is `rgb2gray()` out?. *SIGGRAPH Asia 2013 Technical Briefs. ACM, 2013*. p. 15. Disponível em: <<http://dl.acm.org/citation.cfm?id=2542374>>. Acesso em: 07 jun. 2017.
- TAKEDA, F.; OMATU, S. A neuro-money recognition using optimized masks by GA. In: *Advances in Fuzzy*

Logic, Neural Networks and Genetic Algorithms. Springer Berlin Heidelberg, 1994. p. 190-201.

TAKEDA, F.; NISHIKAGE, T. Multiple kinds of paper currency recognition using neural network and application for Euro currency, *Neural Networks, 2000. IJCNN 2000, Proceedings of the IEEE-INNS-ENNS International Joint Conference on*, Como, 2000, pp. 143-147 v.2. doi: 10.1109/IJCNN.2000.857888

TEIXEIRA, V.V.et al. Aplicativo identificador de cédulas para deficientes visuais. *Revista de Informática Aplicada*, v. 11, n. 1, 2016. Disponível em: <<http://www.ria.net.br/index.php/ria/article/view/139/151>>. Acesso em: 06 set. 2016.

THEODORIDIS, S.; KOUTROUMBAS, K. *Pattern Recognition*, 4. Ed. Academic Press, 2008.

VAPNIK, V. N. *Statistical Learning Theorv*. John Willey & Sons, 1998.

VAPNIK, V. N. *The Nature of Statistical Learning Theorv*. Springer-Verlag, 1995.

ZHANG, E.H. et. al. Research on paper currency recognition by neural networks, *Machine Learning and Cybernetics, 2003 International Conference on*, 2003, pp. 2193-2197 Vol.4. doi: 10.1109/ICMLC.2003.1259870