

Classificação de Espécies de Pimentas Empregando Análise de Imagens Digitais e Componentes Principais

Silva, P. R. B.¹, Galvão Filho, A. R.¹,
Nogueira, H. V.², Flores, I. S.³, Coelho, C. J.¹

¹Escola de Ciências Exatas e da Computação
Grupo de Pesquisa em Computação Científica
Pontifícia Universidade Católica de Goiás, Goiânia-GO-Brasil

²Instituto de Informática
Universidade Federal de Goiás, Goiânia-GO-Brasil

³Instituto Federal de Goiás, Luziânia-GO-Brasil

Resumo: o objetivo do trabalho é a classificação automática de imagens de pimentas por espécie. A classificação é feita empregando a análise de componentes principais (Principal Component Analysis, PCA) a partir de um conjunto de dados de 345 imagens de pimentas no padrão vermelho, verde e azul (Red, Green, Blue, RGB) obtidas com a câmera JAI AD-080GE. Os resultados obtidos mostram uma acurácia de 72,97% do modelo proposto para classificação das pimentas.

Palavras-chave: Análise de imagem. Reconhecimento de padrões. Análise de componentes principais.

Pepper Species Classification using Principal Component Analysis in Digital Images

Abstract: the goal of this work is automatic classification of pepper images according to their respective species. The classification of peppers is performed by applying principal components analysis (PCA) from a dataset of 345 pepper images in the RBG (Red, Green, Blue) pattern obtained by camera JAI AD-080GE. The results shows an accuracy of 72.97% of the proposed model for pepper classification.

Keywords: Image analysis. Pattern recognition. Principal Componente Analysis.

1 Introdução

O processamento de imagens consiste em processar digitalmente uma imagem (*Digital Image Processing*, DIP) e análise digital de imagem (*Digital Image Analysis*, DIA) [1]. O DIP é dividido nas etapas de pré-processamento, segmentação e pós-processamento onde são realizadas operações sobre os pixels (*picture element*) das imagens com objetivo de adequá-las para a análise [2,3]. A DIA consiste em extrair atributos das imagens tais como características ou quaisquer fatores que auxiliem na detecção de padrões para classificação [4].

Em geral, os métodos utilizados na classificação de imagens identificam semelhanças e diferenças entre diferentes amostras [5]. Tais métodos podem ser divididos em paramétricos e não paramétricos. Os modelos paramétricos pressupõem que as variáveis (colunas da matriz de dados) tenham distribuição normal, ao contrário dos métodos não paramétricos que não utilizam dessa premissa.

DOI 10.18224/arithmos.v1i1.6856

Recebido em:
23/10/2018

Aprovado em:
20/11/2018



Recentemente, a indústria e a agricultura vêm adotando sistemas de classificação automatizados no intuito de aumentar a capacidade produtiva e diminuir custos com mão de obra [6]. Em [7], foram avaliados três métodos de classificação para discriminar *Eucalyptus globulus* e *Eucalyptus nitens* para infravermelho próximo (NIR) coletado das folhas. Dubey e Jalal [8], exploram vários métodos para a classificação de frutas e vegetal e o reconhecimento de doença em frutas. Bajwa [9] usaram a classificação baseada em PCA para classificar os diferentes tipos de uni-camadas e multicamadas de nuvens. Segundo os autores, a PCA consegue identificar diferentes tipos de nuvem com melhor precisão.

Neste cenário, este trabalho apresenta uma classificação de diferentes espécies de pimentas a partir da análise de imagem empregando o modelo não paramétrico de classificação PCA.

2 Material e Métodos

Uma imagem pode ser definida como uma função $f(x,y)$, onde x e y são coordenadas espaciais em um plano bidimensional e f é a intensidade da imagem em um dado ponto (x,y) . As imagens RGB (*Red Green, Blue*, RGB) são compostas de três componentes de imagens, sendo uma para cada cor primária. As três imagens combinadas produzem uma imagem colorida [10].

O pré-processamento utilizado nas imagens consiste no corte das laterais das imagens, esta etapa é feita tomando o cuidado de deixar todas as imagens do mesmo tamanho e sem cortar a região da pimenta, proporcionando uma redução na dimensão das imagens sem perda de informação. Suavização utilizando filtro gaussiano, que elimina ruídos borrando a imagem. A imagem suavizada é convertida para escala de cinza, e é feita a limiarização para a extração da máscara binária que será utilizada para remover os ruídos da imagem original. Em alguns casos, a máscara pode conter pixels de fundo, ou seja, pixels pretos na região da pimenta. Este problema é resolvido através da utilização do filtro de preenchimento de buracos, que utiliza operações de processamento morfológico de imagens. Por fim, é feita a multiplicação pixel-a-pixel da máscara binária pela imagem e a substituição do fundo preto da imagem por um fundo branco [10].

A análise de componentes principais (*Principal Components Analysis*, PCA) [11], é uma técnica cujos principais objetivos são extrair as informações mais importantes de uma tabela de dados, reduzir o conjunto de dados, e simplificar a descrição da matriz de dados [12]. A PCA é amplamente utilizada nos mais diversos campos, de neurociência a computação gráfica [13]. Uma descrição detalhada do funcionamento da PCA pode ser encontrada em [12, 13].

Ao empregar a PCA, as imagens são representadas pelas suas respectivas PCs (*Principal Components*, PC). Como a PCA apresenta cada amostra como um ponto no espaço das componentes principais, é possível relacionar as distâncias destes pontos ao conjunto de pontos que formam as classes. Tal relação permite selecionar as amostras que possuem menores distâncias e associá-las a uma classe. Desta forma, a classificação das amostras em uma espécie de pimenta é feita através do cálculo da distância euclidiana entre as componentes principais da imagem do conjunto de treinamento (PC_{tr}) e as componentes principais da imagem a ser classificada (PC_{im}). Esta operação é descrita na Equação 1

$$d = \sqrt{(PC_{tr1} - PC_{im1})^2 + \dots + (PC_{trn} - PC_{imn})^2} . \quad (1)$$

A operação é realizada para cada imagem do conjunto de treinamento. A espécie da pimenta a ser classificada é definida comparando as distâncias calculadas para cada amostra do conjunto de treinamento. A espécie da amostra de treinamento que tem a menor distância euclidiana em relação à pimenta a ser classificada é escolhida como a espécie da pimenta a ser classificada.

A base de dados utilizada neste trabalho foi construída a partir de 23 diferentes espécies de pimentas. O conjunto das imagens de pimentas foi obtido através de uma câmera multispectral JAI AD-080GE. O mesmo ambiente foi mantido para aquisição das pimentas no intuito de uniformizar as imagens. Apenas para a pimenta Redonda a abertura da câmera foi configurada de modo a visualizar as amostras, pois na configuração padrão não foi possível obter nenhuma imagem da pimenta. Este com-

portamento é justificado pela cor clara da espécie. As imagens utilizadas neste trabalho estão no formato RGB. As imagens originais tem dimensão de 1024*768*3 pixels, após o pré-processamento, a dimensão é de 778*561*3 pixels.

Para classificar as pimentas, o conjunto de imagens de cada espécie foi dividido em um conjunto de treinamento e de teste. O conjunto de treinamento foi construído contendo 15 amostras de cada tipo de pimenta, totalizando 345 pimentas. O conjunto de teste, por sua vez, não pôde contar com a mesma quantidade de amostras de cada tipo de pimenta devido à diferentes quantidades coletadas em campo.

A avaliação da classificação total foi realizada através da sua acurácia, calculando a média da porcentagem de acerto das classificações individuais ponderada pela quantidade de amostras de teste de cada espécie de pimenta. A Equação 2 ilustra o cálculo da acurácia da classificação

$$Acurácia = \frac{\sum_{i=1}^K (q_i * p_i)}{\sum_{i=1}^K (q_i)}, \quad (2)$$

onde q_i é a quantidade de pimentas, p_i é a taxa de classificações corretas, i é o i -ésimo tipo de pimenta classificado e K é o total de tipos de pimenta.

3 Resultados e Discussão

A acurácia do classificador, calculada conforme a Equação (2), foi de 72,97%. Dentre as diferentes espécies de pimentas avaliadas, destacam-se as pimentas Cumari, Cumari Passarinho, Cumari do Pará, Pimenta Bode e Malagueta. Enquanto as primeiras obtiveram todas as amostras de teste classificadas corretamente, o mesmo não aconteceu com a Malagueta, cuja taxa de acerto foi de 0%.

Para entender o comportamento do classificador é preciso observar a distribuição das componentes principais. A Figura 1 mostra a distribuição das amostras de treinamento e teste das pimentas Cumari e Bode (a) e das pimentas Malagueta e Amazonense amarela (b) utilizando apenas as duas PCs mais representativas.

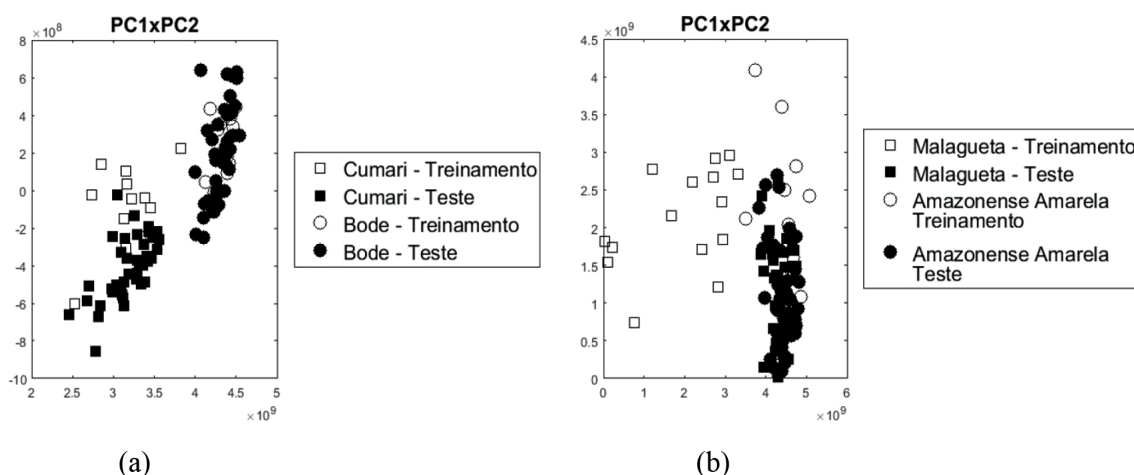


Fig. 1. Treinamento e teste das pimentas

Legenda. (a) Distribuição das componentes principais das pimentas Cumari e Bode, (b) Distribuição das componentes principais das pimentas Malagueta e Amazonense Amarela.

Na Figura 1(a) é possível observar a separação entre as espécies de pimenta, porém, o mesmo comportamento não é observado no caso da pimenta Malagueta, conforme pode ser observado na Figura 1(b). A Figura 1(b) mostra como as amostras da pimenta Malagueta estão espalhadas no plano das duas PCs mais representativas. Adicionalmente, as amostras de teste se sobrepõem às amostras da pimenta Amazonense Amarela, impossibilitando a correta classificação da pimenta Malagueta. Apesar de a ima-

gem apresentar a distribuição das amostras apenas em relação às duas PCs mais significativas, é possível afirmar que o cálculo da distância euclidiana é insuficiente para obter boa acurácia na classificação da pimenta Malagueta.

4 Conclusão

Neste trabalho foi realizada a construção de um banco de dados de pimentas, utilizando imagens obtidas através de uma câmera multiespectral. Tais imagens foram transformadas utilizando a Análise por Componentes Principais e classificadas utilizando a distância euclidiana entre as amostras. Os resultados indicaram que a metodologia empregada pode ser útil na classificação de diversas espécies de pimenta. Apesar das elevadas taxas de erro em alguns casos específicos, a acurácia acima de 70% confirma a utilidade desta estratégia. Contudo, é possível aprimorar a classificação a partir da extração de características das imagens e da utilização de classificadores mais robustos. Como trabalhos futuros, pretende-se detectar características inerentes às diferentes espécies de pimenta e testar classificadores como as Redes Neurais Artificiais.

Referências

1. Jain, A. K.: *Fundamentals of Digital Image Processing*. Prentice Hall, 1989.
2. Blackledge, J. M.: *Digital Image Processing: Mathematical and Computational Methods*. Woodhead Publishing, 2005.
3. Shih, Y, F.: *Image Processing and Mathematical Morphology: Fundamentals and Applications*. CRC, 2011.
4. Pavlidis, T.: *Image analysis*. *Ann. Rev. Comput.Sci.* n. 3; p. 121-46, 1988.
5. Duda, R. O.; Hart, P. E.; Stork, D. G. : *Pattern Classification*, Willey, 2001.
6. Vibhute, A.; Bodhe, S. K.: *Applications of Image Processing in Agriculture: A Survey*. *International Journal of Computer Applications*. v. 52; n. 2; p. 0975 – 8887, 2012.
7. Castillo, R.; Contreras, D.; Freeer, J.; Ruiz, J.; Valenzuela, S.: *Supervised pattern recognition techniques for classification of eucalyptus species from leaves nir spectra*, *J. Chil. Chem. Soc.*, v. 53, n. 4, p. 1709-1713, 2008.
8. Dubey, S. R.; Jalal, A. S.: *Application of image processing in fruit and vegetable Analysis: a review*, *Journal of Intelligent Systems*, v. 24, n. 4, p. 405-424, 2015.
9. Bajawa, I. S.; Naweed, M. S.; Asif, M. N., Hyder, S. I.: *Feature Based Image Classification by using Principal Component Analysis*, *ICGST-GVIP Journal*, ISSN 1687-398X, v. 9, p.11-17, 2009.
10. Gonzales, R., Woods, R.: *Digital Image Processing*, Pearson Prentice Hall, 2007.
11. Hotelling, H.: *Analysis of a complex of statistical variables into principal component*. *The Journal of Educational Psychology*, v. 24, p. 417-441, 1933.
12. Abdi, H.; Williams, L. J.: *Principal component analysis*. *Wiley interdisciplinary reviews: computational statistics*, v. 2, n. 4, p. 433-459, 2010.
13. Shlens, J.: *A tutorial on principal component analysis*. arXiv preprint arXiv:1404.1100, 2014.