

Reconhecimento Automático do Inseto *Diaphorina citri* em Imagens de Microscopia

José Leonardo dos Santos Melo
Pós-Graduação em Computação Aplicada (PGCA)
Departamento de Tecnologia (DTEC)
Universidade Estadual de Feira de Santana (UEFS)
Feira de Santana - BA, Brasil
leomelocomputacao@gmail.com

Michele Fúlvia Angelo
Pós-Graduação em Computação Aplicada (PGCA)
Departamento de Tecnologia (DTEC)
Universidade Estadual de Feira de Santana (UEFS)
Feira de Santana - BA, Brasil
mfangelo@ecomp.uefs.br

Abstract—This paper presents a proposal for the use of computational approaches to image classification of insect *Diaphorina citri*, in microscopy, distinguishing it from other insects commonly found in citrus regions of São Paulo, Brazil. In addition, comparisons will be made between the approaches used and optimization of the proposed classifiers. Extractors local features invariant to rotation and scale will be used along with different approaches bag-of-features and will be classified as machine learning algorithms. This work is a significant step to enable the creation of computational systems that automate the important process of counting these insects.

Keywords—Citriculture, Yellow Sticky Traps, *Diaphorina citri*, Huanglongbing (HLB), Classification of Digital Images, Machine Learning.

Resumo—Este artigo apresenta uma proposta de utilização de abordagens computacionais para a classificação de imagens de microscopia do inseto *Diaphorina citri*, distinguindo-o de outros insetos comumente encontrados em regiões citrícolas de São Paulo, Brasil. Além disso, serão feitas comparações entre as abordagens utilizadas e otimização dos classificadores propostos. Serão utilizados extratores de características locais invariantes à rotação e escala juntamente com diferentes abordagens de bolsas de características e serão classificadas com algoritmos de aprendizagem de máquina. Este trabalho é uma etapa significativa para possibilitar a criação de sistemas computacionais que automatizem o importante processo de contagem desses insetos.

Palavras-chave—Citricultura, Armadilhas Adesivas Amarelas, *Diaphorina citri*, Huanglongbing (HLB), Classificação de Imagens Digitais, Aprendizagem de Máquina.

I. INTRODUÇÃO

O Brasil é o maior produtor mundial de laranja e a sua produção de suco de laranja, na safra 2013/2014 correspondeu a 57,05% de toda produção mundial. A região de produção citrícola de destaque do país é o “cinturão citrícola brasileiro”, localizado nos estados de São Paulo, Paraná e Triângulo Mineiro. Existem diversos estados brasileiros produzindo essa fruta, mas o estado de São Paulo é a maior região produtora de laranja do mundo [1].

Das doenças que surgiram na citricultura mundial e brasileira, o *Greening*, também chamado de *Huanglongbing* (HLB), é a doença que mais preocupa os citricultores e pesquisadores dessa área, pela velocidade que ela se propaga e por provocar severos sintomas. Bactérias *Candidatus Liberib-*

acter causam o HLB, as plantas doentes não tem resistência genética para combatê-lo e o inseto psilídeo dos citros asiático, *Diaphorina citri* Kuwayama, é o principal transmissor no estado de São Paulo, ou seja, é o seu inseto vetor [1]–[4].

Como medida de controle do inseto vetor, armadilhas adesivas amarelas são usadas para a captura do psilídeo dos citros asiático adulto. Elas são presas aos citros e permanecem expostas em pomares por alguns dias. Após o período de exposição, elas são levadas para centros de pesquisa. Nesses locais, os psilídeos dos citros asiáticos capturados são contados manualmente e, então, são estimadas as populações desse inseto nas regiões de onde essas armadilhas foram retiradas [5], [6].

Automatizar a classificação de psilídeos dos citros asiáticos é uma etapa significativa para possibilitar a criação de sistemas computacionais que automatizem o importante processo de contagem desses insetos em armadilhas adesivas amarelas.

Diante do problema apresentado, este trabalho tem como objetivo aplicar e comparar técnicas de classificação automática em imagens de insetos *Diaphorina citri*, distinguindo-os de outros insetos que possam ser capturados por armadilhas adesivas amarelas, através de imagens de microscopia extraídas dessas armadilhas.

Este trabalho contribuirá com a descoberta de um procedimento computacional otimizado para a classificação do *Diaphorina citri* nesse contexto. Esse procedimento possibilitará a criação de sistemas computacionais para a contagem automatizada desse inseto, eliminando assim o erro humano e a lentidão trazida pelo processo manual de contagem.

A. Trabalhos Relacionados

No trabalho de Larios et al. [7] foi utilizada uma abordagem de bolsa de características para automatizar a identificação taxonômica de larvas da ordem Plecoptera. 263 dessas larvas foram coletadas em riachos de Willamette e Cascade Range, próximo a Oregon nos Estados Unidos. Aproximadamente 10 imagens foram obtidas para cada espécie. Essas imagens foram examinadas manualmente e todas as imagens que proporcionavam uma visão dorsal dos insetos, dentro de 30 graus vertical, foram selecionadas para análise. As imagens foram classificadas através de um processo que envolve:

identificação de regiões de interesse, representação dessas características como vetores SIFT (Scale-Invariant Feature Transform), transformação dos vetores SIFT em um histograma de características detectadas e a classificação do histograma por um conjunto de árvores de modelo logístico. Foram aplicados três algoritmos de detecção de regiões: Hessian-affine, Kadir e PCBR (Principal Curvature-Based Region). A construção do livro de código (Codebook) foi realizada através de GMM (Gaussian Mixture Model). Os autores afirmam que seu detector PCBR supera os outros dois descritores e mostram uma acurácia de classificação de 82% para quatro classes e 95% para três classes.

No trabalho de Samanta e Ghosh [8] foi criado um sistema para a classificação de insetos usando CFS (Correlation-based Feature Selection) e IBPLN (Incremental Back Propagation Learning Network). Foi criado um banco de imagens concentrando-se sobre oito maiores pragas (insetos) registradas em diferentes jardins de chá de distritos da Índia. O banco possui 609 imagens pertencentes a oito classes descritas por 11 atributos. A classificação foi realizada utilizando redes neurais artificiais. O estudo demonstrou que o CFS pode ser usado para a redução do vetor de características e a combinação do CFS e IBPLN pode ser usada em outros problemas de classificação.

No trabalho de Mundada e Gohokar [9] foi criado um sistema para detectar moscas brancas e pulgões em culturas infectadas, dentro de estufas. Imagens da folha infectada foram capturadas por câmeras e processadas previamente usando técnicas de processamento de imagens tais como conversão de escala de cores RGB (Red Green Blue) para escala de cinza e filtragem para melhoria das imagens. Na extração de características foram consideradas uma variedade de propriedades de região e de matriz de covariância cinza. Alguns exemplos de propriedades extraídas são: entropia, média, desvio padrão, contraste, energia, correlação e excentricidade. A classificação foi realizada com o uso de SVM (Support Vector Machine). Os autores afirmam que o protótipo do sistema proveu detecção rápida de pragas e teve o mesmo nível de desempenho que uma abordagem manual clássica.

No trabalho de Venugoban e Ramanan [10] foi criado um sistema de classificação de imagens de pragas (insetos) presentes em plantações de arroz. Foram usadas características baseadas em gradientes através da abordagem de bolsa de características. Imagens de 20 classes desses insetos foram obtidas a partir do Google e fotografias cedidas pela Faculdade de Agricultura, Universidade de Jafna, Sri Lanka. As imagens foram classificadas por um sistema que envolveu identificação de regiões de interesse, representação dessas regiões como descritores SURF ou SIFT, criação de Codebooks e classificação dessas características com SVM linear. Além disso, características HOG (Histogram of Oriented Gradient) foram extraídas e classificadas. O algoritmo *Nearest Neighbor* foi utilizado na comparação com o SVM. Os resultados mostraram que o descritor HOG superou os descritores SIFT e SURF. A combinação de SURF e HOG, quando classificados com SVM linear, resultou em aproximadamente 90% de acurácia.

II. MATERIAL E MÉTODOS

O desenvolvimento do trabalho está dividido em 5 etapas: a “Aquisição do Banco de Imagens”, a “Extração de Características”, a “Criação dos Livros de Código e das Bolsas de Características”, “Classificação” e “Otimização dos Classificadores”. Nas subseções a seguir são descritas cada uma destas etapas.

A. Aquisição do Banco de Imagens

Foi utilizado um banco de imagens gerado e fornecido pelo Fundo de Defesa da Citricultura (FUNDECITRUS), instituição de pesquisa, que, no período entre janeiro e abril de 2015, coletou mais de 700 armadilhas adesivas amarelas que estavam posicionadas em diversas regiões citrícolas do estado de São Paulo, Brasil.

Em laboratório, com a utilização de uma câmera fotográfica (Olympus SC30) acoplada a um microscópio (Olympus SZ61) e luminária de led (LED 72T), foram reunidas 379 imagens do *Diaphorina citri* (Figura 1) e 379 imagens de outros insetos (Figura 2) que são, geralmente, capturados em armadilhas adesivas amarelas nessas regiões, formando assim um banco de imagens com uma representativa amostragem da região citrícola paulista. As imagens tem uma ampliação fixa de 0.67x e uma distância focal variável que possibilitasse o enquadramento de um inseto por imagem.

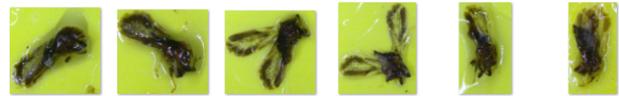


Figura 1. Algumas amostras do banco de imagens do *Diaphorina citri*.



Figura 2. Algumas amostras do banco de imagens dos outros insetos.

Todas as imagens utilizadas foram recortadas de forma a aproximar suas laterais do corpo dos insetos. Esse procedimento computacional será realizado para reduzir a área de fundo da imagem e, conseqüentemente, diminuir a captura de informação ruidosa presente nesses locais.

B. Extração de Características

Rotinas foram executadas para a extração de características invariantes a rotação e escala. Para isso, foram utilizados algoritmos de extração de características SIFT (Scale-Invariant Feature Transform) [11] e SURF (Speeded Up Robust Features) [12]. Testes futuros acrescentarão resultados dos descritores: ORB (Oriented FAST and Rotated BRIEF) [13], BRISK (Binary Robust Invariant Scalable Keypoints) [14] e FREAK (Fast Retina Keypoint) [15].

Os procedimentos de extração de características das imagens executaram as tarefas de: carregar cada imagem na memória,

convertê-la para a escala de cinza, extrair suas características e armazenar o resultado dessas extrações.

Para evitar resultados de classificação tendenciosos, as amostras resultantes das extrações de características foram dispostas em ordem aleatória de forma que essa ordenação pudesse ser reproduzida em todos os testes (ordem pseudo-aleatória).

C. Criação dos Livros de Código e das Bolsas de Características

Na etapa de criação de livros de código (Codebooks) e bolsas de características (Bag-of-Features) [16], as amostras de extrações de características geradas foram divididas em duas partes: 80% das amostras serão utilizadas para a geração de cada livro de código e 20% das amostras serão reservadas para testes finais de classificação, as amostras serão divididas de forma estratificada.

Os livros de código foram criados usando o algoritmo de aprendizagem de máquina não-supervisionada *Mini Batch K-Means*, uma variação do algoritmo *K-Means* que usa amostragem randômica de instâncias em cada iteração. O *Mini Batch K-Means* converge mais rapidamente para seus agrupamentos, mas suas distorções nos grupos aprendidos podem ser maiores que no *K-Means*. Na prática, os resultados são similares e essas distorções são aceitáveis quando a velocidade de execução do algoritmo é um importante requisito do sistema de visão computacional projetado [17], [18].

A quantidade de agrupamentos configurada no *Mini Batch K-Means* foi, inicialmente, de 300 e esse valor de agrupamento permanecerá fixo durante os experimentos para possibilitar comparações adequadas. Essa fixação do número de agrupamentos reduz o número de análises necessárias devido a extensão de combinações de parâmetros possíveis proporcionada pela variação desses grupos. Para cada extrator de características utilizado, serão testadas três abordagens distintas de bolsas de características.

Para a abordagem com melhor resultado, na etapa anterior, serão testados diversos números de agrupamentos diferentes, analisando os resultados em função do percentual de acurácia de classificação.

D. Classificação

As bolsas de características geradas foram utilizadas como entrada para os procedimentos computacionais de classificação. Algoritmos de classificação por aprendizagem de máquina foram utilizados. Algumas escolhas iniciais são os algoritmos *Support Vector Machine* (SVM) e *K Nearest Neighbor* (KNN). O SVM tem ampla utilização em abordagens bem sucedidas de classificação de imagens [19]–[21]. O KNN é um algoritmo simples, uma maneira efetiva de classificar dados e tem sido aplicado com sucesso na classificação de imagens [22], [23]. A validação cruzada foi aplicada aos algoritmos de classificação selecionados para garantir resultados de classificação confiáveis.

O núcleo (kernel) para o algoritmo SVM, escolhido inicialmente, foi o linear. Essa escolha deve-se a simplicidade

de classificação desse núcleo e a diminuição do número de análises comparativas que seriam necessárias pelo uso de outros núcleos.

E. Otimização dos Classificadores

Estratégias de seleção de modelo para o algoritmo de aprendizagem de máquina, que resultar em melhor desempenho nas etapas anteriores, serão executadas na tentativa de melhorar a média de acurácia do classificador. No caso da utilização do algoritmo SVM, podem ser utilizados núcleos diferentes e variações no parâmetro C e gamma como critério de seleção de modelo. No KNN, variações no parâmetro K são possíveis estratégias de otimização dos resultados de acurácia.

III. RESULTADOS PRELIMINARES

Os resultados apresentados são referentes a dois extratores e a dois classificadores testados. Os classificadores criados foram mensurados pela média aritmética das acurácias de 50 iterações de validação cruzada. O cálculo da acurácia é dado pela fórmula [17]:

$$ACC = \frac{TP+TN}{TP+TN+FP+FN}$$

Onde TP (True Positive) representa o número de classificações corretas para a classe positiva (verdadeiro-positivo), TN (True Negative) é o número de classificações corretas para a classe negativa (verdadeiro-negativo), FP (False Positive) é o número de classificações incorretas para a classe negativa (falso-positivo) e FN (False Negative) é o número de classificações incorretas para a classe positiva (falso-negativo).

A Tabela I apresenta os resultados para a abordagem de bolsa de características com características gerais de todos os insetos, a Tabela II apresenta os resultados para a abordagem de bolsa de características criada com características apenas do inseto *Diaphorina citri* e a Tabela III apresenta os resultados para a abordagem com duas bolsas de características concatenadas, onde cada bolsa representa informações de uma das classes. Nessas tabelas, as linhas representam os diferentes extratores de características usados e as colunas mostram a acurácia média com seu desvio padrão e a acurácia alcançada sobre o conjunto de teste final, para os classificadores KNN e SVM.

Em todas as tabelas de resultados, o extrator de características SURF teve melhores médias de acurácia.

Em relação as abordagens de bolsa de características utilizadas, uma pequena melhoria de aproximadamente 1% nas médias de acurácia da abordagem “Geral” para a “Diaphorina” e da “Diaphorina” para a “Duas Classes” foi percebida, em alguns casos. Porém, em relação a minimização de esforço computacional empregado, simplicidade de implementação e menor dimensionalidade de características amostradas, a abordagem que implementa apenas características do inseto *Diaphorina citri* é a escolha adequada.

O classificador SVM teve melhores médias de acurácia para os extratores SIFT e SURF nas três abordagens de bolsa de características testadas (Tabelas I, II e III). Em relação ao conjunto de testes final, o KNN generalizou melhor para o

extrator SURF e o SVM generalizou melhor para o extrator SIFT.

TABELA I

ACURÁCIA DOS CODEBOOKS “GERAL” COM VALIDAÇÃO CRUZADA (50X).

Codebook Geral - 300 Características				
	KNN K=5	KNN Teste Final	SVM C=1	SVM Teste Final
SIFT	83% (+/- 6%)	82%	89% (+/- 5%)	87%
SURF	91% (+/- 5%)	95%	92% (+/- 4%)	88%

TABELA II

ACURÁCIA DOS CODEBOOKS “DIAPHORINA” COM VALIDAÇÃO CRUZADA (50X).

Codebook Diaphorina - 300 Características				
	KNN K=5	KNN Teste Final	SVM C=1	SVM Teste Final
SIFT	84% (+/- 6%)	86%	90% (+/- 5%)	87%
SURF	92% (+/- 4%)	91%	93% (+/- 4%)	89%

TABELA III

ACURÁCIA DOS CODEBOOKS “DUAS CLASSES” COM VALIDAÇÃO CRUZADA (50X).

Codebook Duas Classes - 600 (300 x 2) Características				
	KNN K=5	KNN Teste Final	SVM C=1	SVM Teste Final
SIFT	85% (+/- 6%)	86%	92% (+/- 5%)	88%
SURF	91% (+/- 5%)	93%	94% (+/- 4%)	91%

O resultado obtido utilizando o extrator SURF, bolsas de características com 300 dimensões por classe e classificador SVM com valores de parâmetros padrão (C igual a 1) teve a média de acurácia de 94%. O KNN (K igual a 5) com extrator SURF e bolsa de características geral com 300 dimensões teve a melhor acurácia sobre o conjunto de testes final, generalizando bem com uma acurácia de 95%.

IV. CONCLUSÕES

Nos resultados preliminares, abordagens de bolsa de características compostas por características locais invariantes a rotação e escala (SIFT e SURF) foram utilizadas. A abordagem de bolsa de características com 300 dimensões por classe, extrator SURF e SVM teve a promissora média de acurácia de 94%. A abordagem de bolsa de características gerada apenas com características do inseto *Diaphorina citri*, extrator SURF e SVM teve resultado em 93% de média de acurácia.

Em etapa seguinte desta pesquisa, será analisado o comportamento do desempenho de classificação em função da variação número de núcleos utilizados nos livros de código. Além disso, serão implementados e comparados os resultados de classificação de três novos descritores (ORB, BRISK e FREAK) combinando-os com os classificadores propostos (KNN e SVM linear). A abordagem de classificação que apresentar a melhor média de acurácia será otimizado com o objetivo de alcançar melhores taxas de classificação.

AGRADECIMENTOS

Ao FUNDECITRUS pela disponibilização das imagens dos insetos e pela colaboração técnico-científica.

REFERÊNCIAS

- [1] M. Mendes, *Agrianual 2015: Anuário da Agricultura Brasileira*. Informa Economics FNP, 2015.
- [2] D. C. Teixeira, C. Saillard, S. Eveillard, J. L. Danet, P. I. da Costa, A. J. Ayres, and J. Bové, “‘candidatus liberibacter americanus’, associated with citrus huanglongbing (greening disease) in são paulo state, brazil.” *International Journal of Systematic and Evolutionary Microbiology*, vol. 55, no. Pt 5, pp. 1857–1862, 2005.
- [3] M. F. Neves, V. Trombin, P. Milan, F. Lopes, F. Cressoni, and R. Kalaki, “O retrato da citricultura brasileira,” *CitrusBR*, 2010.
- [4] A. R. Agnelli, “Potencial de agentes indutores de resistência para o controle da bactéria *candidatus liberibacter asiaticus* em plantas cítricas,” Master’s thesis, Fundo de Defesa da Citricultura - FUNDECITRUS, 2011.
- [5] I. Sala, “Avaliação do tempo de exposição em armadilha adesiva amarela e das condições de armazenamento de adultos de diaphorina citri na detecção de *candidatus liberibacter asiaticus*,” Master’s thesis, Fundo de Defesa da Citricultura, 2011.
- [6] J. M. C. d. Oliveira, “Diaphorina citri e *candidatus liberibacter* spp: Associação que coloca em risco a citricultura baiana.” 2013.
- [7] N. Larios, H. Deng, W. Zhang, M. Sarpola, J. Yuen, R. Paasch, A. Moldenke, D. A. Lytle, S. R. Correa, E. N. Mortensen *et al.*, “Automated insect identification through concatenated histograms of local appearance features: feature vector generation and region detection for deformable objects,” *Machine Vision and Applications*, vol. 19, no. 2, pp. 105–123, 2008.
- [8] R. Samanta and I. Ghosh, “Tea insect pests classification based on artificial neural networks,” *International Journal of Computer Engineering Science (IJCES)*, vol. 2, no. 6, 2012.
- [9] R. G. Mundada and V. Gohokar, “Detection and classification of pests in greenhouse using image processing,” *IOSR Journal of Electronics and Communication Engineering*, vol. 5, no. 6, pp. 57–63, 2013.
- [10] K. Venugoban and A. Ramanan, “Image classification of paddy field insect pests using gradient-based features,” *International Journal of Machine Learning and Computing*, vol. 4, no. 1, 2014.
- [11] D. G. Lowe, “Distinctive image features from scale-invariant keypoints,” *International journal of computer vision*, vol. 60, no. 2, pp. 91–110, 2004.
- [12] H. Bay, T. Tuytelaars, and L. Van Gool, “Surf: Speeded up robust features,” in *Computer vision—ECCV 2006*. Springer, 2006, pp. 404–417.
- [13] E. Rublee, V. Rabaud, K. Konolige, and G. Bradski, “Orb: an efficient alternative to sift or surf,” in *Computer Vision (ICCV), 2011 IEEE International Conference on*. IEEE, 2011, pp. 2564–2571.
- [14] S. Leutenegger, M. Chli, and R. Y. Siegwart, “Brisk: Binary robust invariant scalable keypoints,” in *Computer Vision (ICCV), 2011 IEEE International Conference on*. IEEE, 2011, pp. 2548–2555.
- [15] A. Alahi, R. Ortiz, and P. Vanderghyest, “Freak: Fast retina keypoint,” in *Computer Vision and Pattern Recognition (CVPR), 2012 IEEE Conference on*. Ieee, 2012, pp. 510–517.
- [16] C.-F. Tsai, “Bag-of-words representation in image annotation: A review,” *International Scholarly Research Notices*, vol. 2012, 2012.
- [17] G. Hackeling, *Mastering Machine Learning with scikit-learn*. Packt Publishing Ltd, 2014.
- [18] D. Scikit-learn, “Comparison of the k-means and mini batch k-means clustering algorithms,” http://scikit-learn.org/stable/auto_examples/cluster/plot_mini_batch_kmeans.html, 2014, acessado: 2015-04-30.
- [19] O. Boiman, E. Shechtman, and M. Irani, “In defense of nearest-neighbor based image classification,” in *Computer Vision and Pattern Recognition, 2008. CVPR 2008. IEEE Conference on*. IEEE, 2008, pp. 1–8.
- [20] S. Chaplot, L. Patnaik, and N. Jagannathan, “Classification of magnetic resonance brain images using wavelets as input to support vector machine and neural network,” *Biomedical Signal Processing and Control*, vol. 1, no. 1, pp. 86–92, 2006.
- [21] I. Kotsia and I. Pitas, “Facial expression recognition in image sequences using geometric deformation features and support vector machines,” *Image Processing, IEEE Transactions on*, vol. 16, no. 1, pp. 172–187, 2007.
- [22] P. Harrington, *Machine learning in action*. Manning Publications Co., 2012.
- [23] I. Hmeidi, B. Hawashin, and E. El-Qawasmeh, “Performance of knn and svm classifiers on full word arabic articles,” *Advanced Engineering Informatics*, vol. 22, no. 1, pp. 106–111, 2008.