



11º Congresso Interinstitucional de Iniciação Científica – CIIC 2017
02 a 04 de agosto de 2017 – Campinas, São Paulo
ISBN 978-85-7029-141-7

DETECÇÃO DE FRUTOS EM CAMPO POR APRENDIZADO DE MÁQUINA

Andreza Aparecida dos **Santos**¹; Thiago Teixeira **Santos**²

Nº 17603

RESUMO – Métodos de reconhecimento de frutos utilizando diferentes descritores e classificadores foram estudados. Uma base de dados de 1.830 imagens contendo exemplos de bagas de uva e outros padrões foi criada e manualmente anotada. Testes quantitativos demonstraram a identificação automática de bagas de uva com 79% de precisão através da utilização Máquinas de Vetores de Suporte com descritores HOG (Histograma de Gradientes Orientados). Esses resultados evidenciam que a detecção automática de frutos em viticultura possível e pode ser aplicada em metodologias de previsão de safra e em sistemas de agricultura de precisão.

Palavras-chaves: Aprendizado de Máquina, Reconhecimento de Imagens, Viticultura.

1 Autora, Bolsista CNPq (PIBIC): Graduação em Engenharia da Computação, UNICAMP, Campinas-SP; andi.apsantos@gmail.com

2 Orientador: Pesquisador da Embrapa Informática, Campinas-SP; thiago.santos@embrapa.br



11º Congresso Interinstitucional de Iniciação Científica – CIIC 2017
02 a 04 de agosto de 2017 – Campinas, São Paulo
ISBN 978-85-7029-141-7

ABSTRACT – *Methods for fruit recognition using different descriptors and classifiers were studied. A database of 1.830 images with examples of grape berries and other patterns was created and manually labeled. Quantitative tests have shown the automatic identification of grape berries with 79% accuracy using Support Vector Machines with HOG descriptors (Histogram of Oriented Gradients). These results show that automated berries detection in viticulture is possible and can be applied in yield prediction methodologies and precision farming systems.*

Keywords: *Machine Learning, Image Recognition, Viticulture.*

1 INTRODUÇÃO

A automatização do reconhecimento de frutos se configura em uma parte importante para a aplicação de métodos de predição de safra, agricultura de precisão e fenotipagem para melhoramento vegetal, além de ser essencial para automação de outras atividades agrícolas, como técnicas de colheita automática, análise visual das plantas para correção de nutrientes e aplicação de insumos (LEE et. al., 2010).

Devido ao tamanho dos frutos, sensoriamento remoto é inviável e o mais adequado se torna o sensoriamento proximal. Técnicas propostas com utilização de imagens e métodos visão computacional e aprendizado de máquina parecem ser uma alternativa promissora (NUSKE et al, 2011).

Este artigo tem como objetivo aplicar técnicas de reconhecimento em imagens a fim de detectar frutos automaticamente a partir de imagens. Para isso uma base de dados foi criada utilizando-se de detectores e anotação manual e então foram utilizados descritores de características e técnicas de aprendizado de máquina para avaliar o desempenho de classificadores de bagas de uva.

2 MATERIAL E MÉTODOS

2.1 AQUISIÇÃO DA BASE DE DADOS

As imagens utilizadas foram obtidas na Fazenda Guaspari (Espírito Santo do Pinhal – SP), em abril de 2017, por uma câmera digital SLR (Canon® EOS Rebel T3i) de lentes 18-55 milímetros



11º Congresso Interinstitucional de Iniciação Científica – CIIC 2017
02 a 04 de agosto de 2017 – Campinas, São Paulo
ISBN 978-85-7029-141-7

configurada em modo automático. As imagens foram adquiridas de uma distância de aproximadamente 1 metro. As imagens apresentavam frutos de uva da variedade Sirah em diferentes estágios de desenvolvimento e são coloridas, de 8 bits e possuem 5184 x 3456 pixels.

2.2 DETECÇÃO DE CANDIDATOS

A detecção de candidatos visa encontrar imagens que são possíveis localizações de bagas de uvas. Devido a forma das bagas, optou-se por utilizar detectores capazes de identificar regiões circulares na imagem a partir de seus pixels.

Quatro detectores foram estudados, entre eles a Transformada Circular de Hough (YUEN et. al., 1990), também utilizada por Roscher et al. (2014) na detecção de bagas de uva. Outros quatro detectores foram utilizados: Determinante da Hessiana (DoH), Laplaciano da Gaussiana (LoG) e Diferença de Gaussianas (DoG) (TUYTELAARS; MIKOLAJCZYK , 2007).

Como resultado, a Transformada Circular de Hough apresentou melhores resultados tanto na detecção de uvas quanto na delimitação melhor ajustada de cada baga, ou seja, a baga inteira é isolada, tornando-se o detector escolhido para produzir um conjunto de 1.830 regiões candidatas de, então redimensionadas para 32 x 32 pixels. Todos os candidatos foram classificados manualmente, identificando-se 608 amostras da classe 1 (“Uva”) e 1.232 amostras da classe 2 (“Não-Uva”). Esse conjunto de 1.830 amostras é o que compõe a base de dados utilizada nesse experimento.

2.3 DESCRITORES UTILIZADOS

Para a elaboração dos testes, foram testados dois tipos de vetores de características: pixels da representação em escala de cinza, e também outros baseados no Histograma de Gradientes Orientados

O Histograma de Gradientes Orientados, ou HOG (DALAL;TRIGGS, 2005), é um descritor que representa um objeto por meio da distribuição da direção de suas bordas, na forma de um histograma da orientação dos gradientes na imagem. Para as amostras de uva, cada imagem de 32 x 32 pixels foi dividida em uma grade de 16 células com 8 x 8 pixels cada uma, sendo avaliadas 9 direções diferentes. (Figura 1)



3 CLASSIFICAÇÃO E AVALIAÇÃO


Para construir os classificadores, foram testadas as técnicas de Máquinas de Vetores de Suporte (*Support Vector Machines, ou SVMs*), *K Vizinhos mais próximos (K nearest neighbors, ou KNNs)*, Naïve Bayes, Árvore de Decisão e Regressão Logística.

Os dados das amostras foram aleatoriamente separados em um conjunto de treinamento (80% do total) e um conjunto de testes (20% do total). O número de amostras de testes e de treinamento de cada classe estão indicados na Tabela 1.

Tabela 1. Separação das amostras de teste e treinamento.

Conjunto	Amostras de Uva	Amostras de Não-Uva	Total
Treinamento	980	978	1958
Teste	236	254	490

Figura 1. Amostras das classes Uva e Não-Uva e seus descritores HOG





11º Congresso Interinstitucional de Iniciação Científica – CIIC 2017
02 a 04 de agosto de 2017 – Campinas, São Paulo
ISBN 978-85-7029-141-7

A partir dos dados, foram construídos os descritores utilizados, como indicado na sessão 2.3. Diversas combinações de parâmetros dos classificadores foram testadas sobre o conjunto de treinamento de modo que os parâmetros que gerassem os melhores resultados fossem selecionados para a avaliação final sobre o conjunto de teste. Em seguida foi realizado o treinamento dos classificadores utilizando o conjunto de testes e computado os dados de precisão, cobertura e F1-score adquiridos. O F1-score é a média harmônica entre as taxas de precisão de cobertura de uma classe, e funciona como um indicador para uma avaliação geral de um método de classificação.

4 IMPLEMENTAÇÃO

Para os detectores DoH, LoG e DoG, foram utilizadas as implementações disponíveis na biblioteca scikit-image (WALT et. al., 2014) e para a implementação da Transformada Circular de Hough foi utilizada a fornecida pela biblioteca OpenCV. Para o descritor HOG foi utilizado a implementação encontrada na biblioteca scikit-image (WALT et. al., 2014). As implementações dos classificadores Máquinas de Vetores de Suporte, K vizinhos mais próximos, Naïve Bayes, Árvore de Decisão e Regressão Logística utilizadas estão disponíveis na biblioteca scikit-learn (PEDREGOSA et. al., 2011).

5 RESULTADOS E DISCUSSÃO

Os resultados da classificação de frutos utilizando o conjunto de teste em escala de cinza com Máquinas de Vetores de Suporte, K-vizinhos, Naïve Bayes, Árvore de Decisão e Regressão Logística estão indicados nas tabelas 2 a 6, a seguir.

Tabela 2. Resultados da classificação das amostras de teste para Píxeis + SVM

Classe	Precisão	Cobertura	F1-Score	Suporte
Uva	0.73	0.73	0.73	236
Não- uva	0.75	0.75	0.75	254
Média/total	0.74	0.74	0.74	490

Tabela 3. Resultados da classificação das amostras de teste para Píxeis + K-VIZINHOS



11º Congresso Interinstitucional de Iniciação Científica – CIIC 2017
02 a 04 de agosto de 2017 – Campinas, São Paulo
ISBN 978-85-7029-141-7

Classe	Precisão	Cobertura	F1-Score	Suporte
Uva	0.72	0.85	0.78	236
Não- uva	0.83	0.70	0.76	254
Média/total	0.78	0.77	0.77	490

Tabela 4. Resultados da classificação das amostras de teste para Píxeis + NAÏVE BAYES

Classe	Precisão	Cobertura	F1-Score	Suporte
Uva	0.74	0.65	0.69	236
Não- uva	0.71	0.79	0.75	254
Média/total	0.72	0.72	0.72	490

Tabela 5. Resultados da classificação das amostras de teste para Píxeis + ÁRVORE DE DECISÃO

Classe	Precisão	Cobertura	F1-Score	Suporte
Uva	0.69	0.69	0.69	236
Não- uva	0.71	0.71	0.71	254
Média/total	0.70	0.70	0.70	490

Tabela 6. Resultados da classificação das amostras de teste para Píxeis + REGRESSÃO LOGÍSTICA

Classe	Precisão	Cobertura	F1-Score	Suporte
Uva	0.71	0.75	0.73	236
Não- uva	0.76	0.72	0.74	254
Média/total	0.74	0.73	0.73	490

Para melhorar os resultados, foi avaliado o desempenho dos classificadores quando combinados com o descritor HOG das amostras. Os resultados da classificação de frutos utilizando os descritores HOG se encontram nas tabelas 7 a 11.

Tabela 7. Resultados da classificação das amostras de teste para SVM + HOG



11º Congresso Interinstitucional de Iniciação Científica – CIIC 2017
02 a 04 de agosto de 2017 – Campinas, São Paulo
ISBN 978-85-7029-141-7

Classe	Precisão	Cobertura	F1-Score	Suporte
Uva	0,80	0,75	0,77	236
Não- uva	0,78	0,83	0,80	254
Média/total	0,79	0,79	0,79	490

Tabela 8. Resultados da classificação das amostras de teste para K-VIZINHOS + HOG

Classe	Precisão	Cobertura	F1-Score	Suporte
Uva	0,84	0,69	0,76	236
Não- uva	0,75	0,87	0,81	254
Média/total	0,79	0,79	0,78	490

Tabela 9. Resultados da classificação das amostras de teste para NAÏVE BAYES + HOG

Classe	Precisão	Cobertura	F1-Score	Suporte
Uva	0,71	0,81	0,76	236
Não- uva	0,80	0,86	0,74	254
Média/total	0,76	0,75	0,75	490

Tabela 10. Resultados da classificação das amostras de teste para ÁRVORE DE DECISÃO + HOG

Classe	Precisão	Cobertura	F1-Score	Suporte
Uva	0,72	0,72	0,72	236
Não- uva	0,74	0,74	0,74	254
Média/total	0,73	0,73	0,73	490

Tabela 11. Resultados da classificação das amostras de teste para REGRESSÃO LOGÍSTICA + HOG

Classe	Precisão	Cobertura	F1-Score	Suporte
Uva	0,75	0,75	0,75	236



11º Congresso Interinstitucional de Iniciação Científica – CIIC 2017
02 a 04 de agosto de 2017 – Campinas, São Paulo
ISBN 978-85-7029-141-7

Não- uva	0,77	0,77	0,77	254
Média/total	0,76	0,76	0,76	490

Comparando os resultados, é possível notar que há um ganho significativo de desempenho obtido com a utilização do Histograma de Gradientes Orientados em relação aos pixels originais, com um aumento de precisão e cobertura da classe uva para a maioria dos classificadores e com aumento de desempenho em todas as configurações.

Analisando o ganho por classificadores, podemos concluir que o SVM e o K-vizinhos combinado com o HOG obtiveram os melhores resultados, com aumento de 5% na precisão, na cobertura e no F1-score médios, saindo de 74% e indo para 79% (SVM) para todos os parâmetros. No âmbito da cobertura da classe uva, o uso do HOG com SVM apontou um aumento de 2%.

As Figura 2 a seguir exibe alguns dos resultados de detecção de bagas utilizando-se a combinação HOG e SVM. As regiões marcadas com quadrado azul representam todas as amostras utilizadas no conjunto teste. Regiões marcadas em verde representam acertos na classificação da amostra pelo classificador e regiões marcadas em vermelho representam erros na classificação.

6 AGRADECIMENTOS

A autora agradece ao CNPq pela concessão da bolsa para a realização dessa pesquisa de Iniciação Científica. A autora agradece também à equipe da Fazenda Guaspari por autorizarem a aquisição de imagens para a base de dados utilizada nessa pesquisa.

Figura 2. Resultados da detecção para HOG + SVM



11º Congresso Interinstitucional de Iniciação Científica – CIIC 2017
02 a 04 de agosto de 2017 – Campinas, São Paulo
ISBN 978-85-7029-141-7



7 REFERÊNCIAS

DALAL, N.; TRIGGS, B. Histograms of oriented gradients for human detection. Proceedings - 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, CVPR 2005, I, p. 886–893, 2005. ISSN 1063-6919

LEE, W. S. et al. Sensing technologies for precision specialty crop production. Computers and Electronics in Agriculture, v. 74, n. 1, p. 2–33, 2010. ISSN 01681699.

NUSKE, S. et al. Yield estimation in vineyards by visual grape detection. In: IEEE International Conference on Intelligent Robots and Systems. [S.l.: s.n.], 2011. p. 2352–2358. ISBN 9781612844541. ISSN 2153-0858.

PEDROGOSA, F. et. al. Scikit-learn: Machine learning in Python. Journal of Machine Learning Research, v. 12, p. 2825-2830, 2011.

ROSCHER, R. et al. Automated image analysis framework for high-throughput determination of grapevine berry sizes using conditional random fields. Computers and Electronics in Agriculture, Elsevier B.V., v. 100, p. 148–158, 2014. ISSN 01681699.

TUYTELAARS, T.; MIKOLAJCZYK, K. Local Invariant Feature Detectors: A Survey. R in Computer Graphics and Vision, v. 3, n. 3, p. 177–280, 2007. Foundations and Trends ISSN 1572-2740.

WALT, S. van der et al. Scikit-image: image processing in Python. PeerJ, v. 2, p. e453, 6 2014. ISSN 2167-8359.

YUEN, H. et al. Comparative study of Hough Transform methods for circle finding. Image and Vision Computing, v. 8, n. 1, p. 71–77, 1990. ISSN 02628856.