

Algoritmo JSEG para segmentação de folhas dos cafeeiros

Jeferson de Souza Dias¹, Francisco Fambrini², José Hiroki Saito¹

¹Centro Universitário Campo Limpo Paulista (UNIFACCAMP)
CEP: 13231-230 – Jardim América – Campo Limpo Paulista, SP – Brasil

²Faculdade de Tecnologia de Limeira (UNICAMP)
CEP: 13484-332 – Jardim Nova Itália – Limeira, SP – Brasil

jsdiasp@gmail.com, fambrini@unicamp.br, saitojosehiroki@gmail.com

Abstract. *Brazil is the largest coffee producer in the world, and then there are many challenges to maintain the high quality and purity of the beans. Thus, our proposal is to create a tool to help agronomists to detect the problems, through the resources of computer science, area of computer vision. Using the knowledge of Artificial Neural Networks, and image segmentation algorithms, such as JSEG, we are investigating a method for segmenting digital images of coffee trees to detect diseases. This proposal intends to detect the leaf region of the image to be used to recognize diseases such as Rust and Cercospora, which are the main illnesses in coffee trees.*

Resumo. O Brasil é o maior produtor de café do mundo, com isso há muitos desafios para manter a qualidade e a pureza dos grãos. Dessa forma, a nossa proposta é criar uma ferramenta para ajudar os agrônomos na detecção dos problemas nas lavouras cafeeiras, através dos recursos da ciência da computação na área de visão computacional. Utilizando os conhecimentos das redes neurais artificiais e segmentação de imagens, tais como algoritmo JSEG, estamos investigando um método para segmentação das imagens digitais para fazer a segmentação de árvores cafeeiras e detectar doenças. Esta proposta pretende utilizar a região foliar da imagem para a detecção de doenças como Ferrugem e Cercóspera, que são as principais doenças nos cafeeiros.

1. Introdução

Trabalhos na área de aplicação de recursos computacionais para a melhoria das produções nas lavouras têm sido realizados frequentemente. Nesse sentido, Sorte (2019) desenvolveu um trabalho sobre o reconhecimento de doenças dos cafeeiros através da análise das folhas dos pés de café, utilizando-se de redes neurais artificiais convolucionais e *Deep Learning*. Cavani et al. (2007) utilizou técnicas de visão computacional para a segmentação da imagem dos pés das laranjeiras com o uso do algoritmo JSEG e classificação dos segmentos utilizando o *perceptron* multicamadas. Andrade (2010) utilizou técnicas de visão computacional para fazer classificação de castanhas brasileiras, para melhorar o produto final, determinando o tempo certo do cultivo. Pagudpud (2019) descreve um trabalho sobre o uso de *smartphones* para reconhecimento de doenças ou insetos nas plantações de café. Metre (2013) desenvolveu um trabalho sobre a classificação das plantas através das suas características morfológicas, fazendo comparação aos outros métodos existentes. Diversos outros trabalhos fazendo uso do

algoritmo JSEG também tem sido publicados, como o de Fambrini et al. (2018), que fez a aplicação desse algoritmo implementado para a finalidade de identificação de elementos da rede elétrica.

O Brasil detém o primeiro lugar em produção de café no mundo totalizando 47% da produção mundial da espécie arábica (EMBRAPA, 2020). Temos vários problemas que estão relacionados à plantação e desenvolvimento do cafeeiro, tais como combater as pragas, as doenças e outros fatores que podem diminuir consideravelmente a vida útil e a produção dos pés de café. Neste trabalho propõe-se uma ferramenta que possa contribuir a favor dos técnicos que estão em campo para ajudar na busca de anomalias que podem ocorrer nas plantações, evitando perdas nas lavouras dos cafeeiros. Propõe-se desenvolver um sistema que realiza a captura de imagens na lavoura cafeeira com o uso de veículos como tratores ou mesmo VANTs (Veículos Aéreo Não Tripulados), depois fazer o processamento das mesmas, desde a segmentação das imagens, detecção das regiões foliares do cafeeiro, e das principais doenças como a Ferrugem e a Cercospora (Sorte, 2019).

O restante do texto está subdividido nas seguintes seções: 1) na Seção 2, é feita uma síntese sobre o algoritmo de segmentação JSEG; 2) na Seção 3, é apresentada a proposta de pesquisa e metodologia; na Seção 4, são apresentados os resultados obtidos; e na Seção 5, as conclusões e trabalhos futuros.

2. Algoritmo JSEG

A segmentação subdivide a imagem em regiões ou objetos constituintes, e o nível de detalhes depende do problema a ser resolvido. Por exemplo, em inspeção automática de placas eletrônicas, o objetivo está em analisar a imagem na linha de produção e determinar a falta de componentes, conexões danificadas (Gonzalez, 2008).

O algoritmo de segmentação baseado em imagens J , denotado JSEG, foi proposto por Deng e Manjunath (2001). É um método não-supervisionado de segmentação de regiões de textura baseada em textura de cores, que consiste em duas etapas independentes: 1) quantização de cores e 2) segmentação espacial, como ilustrado pelo diagrama da Figura 1 (a). Na primeira etapa, as cores da imagem são quantizadas em certo número de classes, e cada pixel recebe um rótulo correspondente à classe atribuída. Essa imagem resultante de rótulos de classes é denotada mapa de classes. Na segunda etapa Figura 1 (b), é realizada a segmentação espacial, na qual é inicialmente obtida uma imagem denotada J , utilizando-se de janelas locais aplicadas a cada posição do mapa de classes. Essa imagem J possibilita a localização de posições centrais e de contorno dos segmentos a serem obtidos. Após a obtenção da imagem J é realizado o crescimento de regiões a partir das posições centrais. O tamanho das janelas locais determina o número máximo de pixels nos segmentos obtidos.

Seja Z o conjunto de todos os N pontos de dados num mapa de classes, entendendo pontos de dados como sendo as posições no espaço bidimensional (x,y) . Seja $z = (x,y)$, $z \in Z$, e m a média desses pontos de dados. Supõe-se que Z é classificada em C classes, Z_i , $i = 1, \dots, C$. Seja m_j a média dos N_j pontos de dados de uma classe Z_j . Se S_T é a variância total dos pontos de Z dado por $S_T = \sum_{z \in Z} \|z - m\|^2$, e S_W é a soma das variâncias S_i dos pontos pertencentes à mesma classe, i , ou seja $S_W = \sum_{i=1}^C S_i = \sum_{i=1}^C \sum_{z \in Z_i} \|z - m_i\|^2$, definimos J pela equação (1):

$$J = (S_T - S_W)/S_W \quad (1)$$

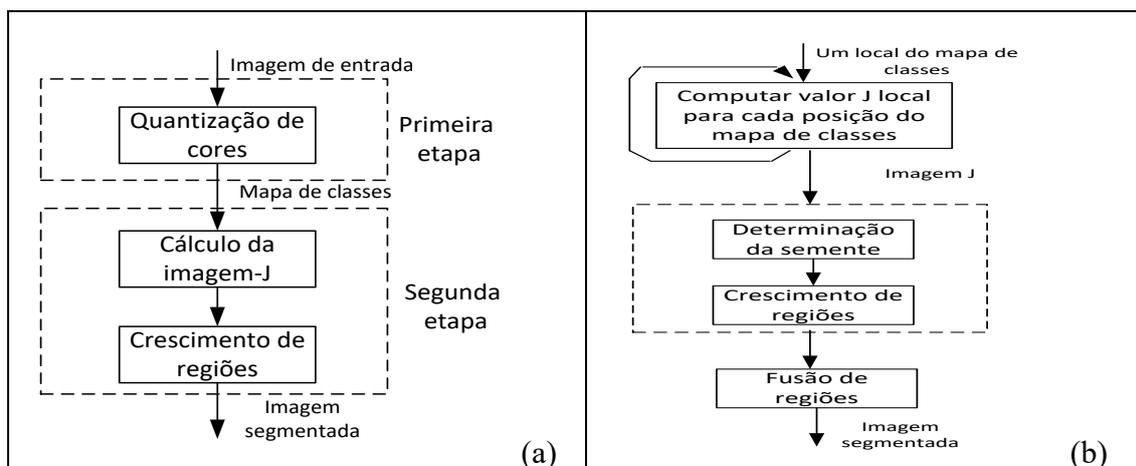


Figura 1 – Diagrama de fluxo do algoritmo JSEG

Quando uma imagem tem várias regiões de cores homogêneas, as classes de cores são mais separadas uma da outra e o valor de J é grande. Se todas as classes de cores são uniformemente distribuídas sobre uma imagem inteira, o valor de J tende a ser pequeno. Seja agora, calcular J sobre cada região segmentada ao invés do mapa de classes inteiro e definir o \bar{J} pela equação (2):

$$\bar{J} = \frac{1}{N} \sum_k M_k J_k \quad (2)$$

onde J_k é o J calculado sobre a região k , M_k é o número de pontos da região k , N é o número total de pontos no mapa de classes, e a somatória é sobre todas as regiões do mapa de classes. Agora propõe-se \bar{J} como critério de minimização sobre todas as formas de segmentação da imagem dado o número de regiões. Para um número fixo de regiões, uma melhor segmentação tende a ter um menor valor de \bar{J} . Se a segmentação é boa, cada região segmentada contém poucos rótulos de classes de cor distribuídos uniformemente e o valor J resultante para aquela região é pequeno. Portanto, \bar{J} também é pequeno. Quando o valor mínimo de $J = 0$, a minimização global de \bar{J} para a imagem inteira não é prática pois temos milhões de formas de segmentar. Contudo, observa-se que J , se aplicada a uma área local do mapa de classes, é também um bom indicador de se aquela área está dentro de uma região ou perto dos contornos. Podemos construir uma imagem cujos valores de pixels correspondem à J calculados sobre pequenas janelas centradas nos pixels. Por conveniência, temos as imagens J e os valores de pixels correspondentes como valor J locais. Quanto maior o valor de J local, mais provável que o pixel correspondente esteja perto de uma região de contorno. A imagem J é como um mapa geográfico 3D contendo elevações e vales, que representam as regiões de contorno e interior, dos segmentos, respectivamente.

3. Proposta de Pesquisa

Este trabalho tem como objetivo desenvolver um sistema, que a partir de imagens obtidas com o auxílio de veículos como tratores ou VANTs, realiza a segmentação da imagem, para que possamos fazer um diagnóstico de anomalias na parte foliar de cafeeiros. O diagrama da Figura 2 ilustra as etapas. Após a aplicação da segmentação, os segmentos são classificados por uma rede neural do tipo *perceptron*, a fim de detectar as regiões foliares. Numa etapa final, uma outra rede neural detecta as doenças Ferrugem e Cercóspora, nos segmentos foliares. O banco de imagens, de 100 imagens de 2322x4128

pixels, foi obtido pelos autores deste trabalho, utilizando câmeras RGB de celulares, de árvores cafeeiras a aproximadamente um metro de distância.

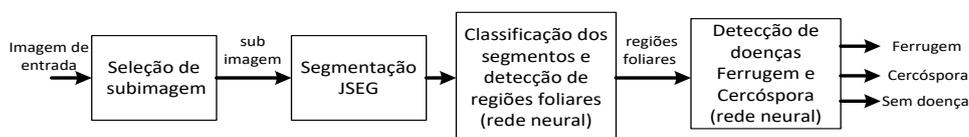


Figura 2 - Proposta de Pesquisa

4. Resultados

Foram realizados 10 experimentos, conforme mostra a Tabela 1, onde temos a subimagem e a dimensão dela na aplicação do algoritmo JSEG, e o número de segmentos obtidos por escala. Nota-se que o número de segmentos varia de acordo com a imagem, sendo que na escala 1, o número de segmentos é menor e na escala 4, esse número é maior. O tamanho da janela na escala 1 é de 9x9 pixels, na escala 2, 17x17, na escala 3, 33x33 e na escala 4, 65x65. Para o processamento do algoritmo JSEG, foi usada a implementação desenvolvida e aplicada no trabalho de Fambrini et al. (2018).

Tabela 1. Experimentos e o número de segmentos obtidos.

Experimentos	Imagem		Número de Segmentos por Escala			
	Subimagem	Dimensão	1	2	3	4
Exp1		901x559	14	43	117	387
Exp2		666x400	7	26	67	226
Exp3		617x382	11	30	87	252
Exp4		616x411	8	33	134	398
Exp5		421x279	4	18	54	172
Exp6		446x315	4	16	52	175
Exp7		574x384	7	25	82	235
Exp8		582x354	8	30	87	267
Exp9		620x374	5	22	66	231
Exp10		630x371	7	35	105	361

Como o resultado da segmentação utilizando o algoritmo JSEG varia de acordo com a aplicação, foi feito um estudo para verificar a média e a variação do número de segmentos obtidos. Assim, na Tabela 2 é mostrado o número de segmentos obtidos para cada uma das escalas, para mesma subimagem do experimento 10. Nota-se que os números de segmentos para o Experimento 10, podem ser representados com os respectivos desvios por $(6,90 \pm 0,32)$ na escala 1, $(32,60 \pm 1,78)$ na escala 2, $(104,60 \pm 4,84)$ na escala 3 e $(362,80 \pm 6,39)$ na escala 4.

A Figura 3(a) refere-se a uma ilustração dos segmentos obtidos no Experimento 6, escala 1, onde 4 segmentos foram obtidos. Nota-se que devido a um número pequeno de segmentos, as regiões contêm misturas de folhas, não adequadas para a classificação posterior de identificação de regiões foliares.

Tabela 2. Média e desvio padrão do número de segmentos para o experimento 10.

Escala	Número de Segmentos										Média	Desvio padrão
	7	7	7	7	7	7	7	7	7	6		
1	7	7	7	7	7	7	7	7	7	6	6,90	0,32
2	34	35	34	32	31	32	35	32	31	30	32,60	1,78
3	98	105	98	108	102	108	107	112	108	100	104,60	4,84
4	361	361	361	361	357	364	368	375	368	352	362,80	6,39

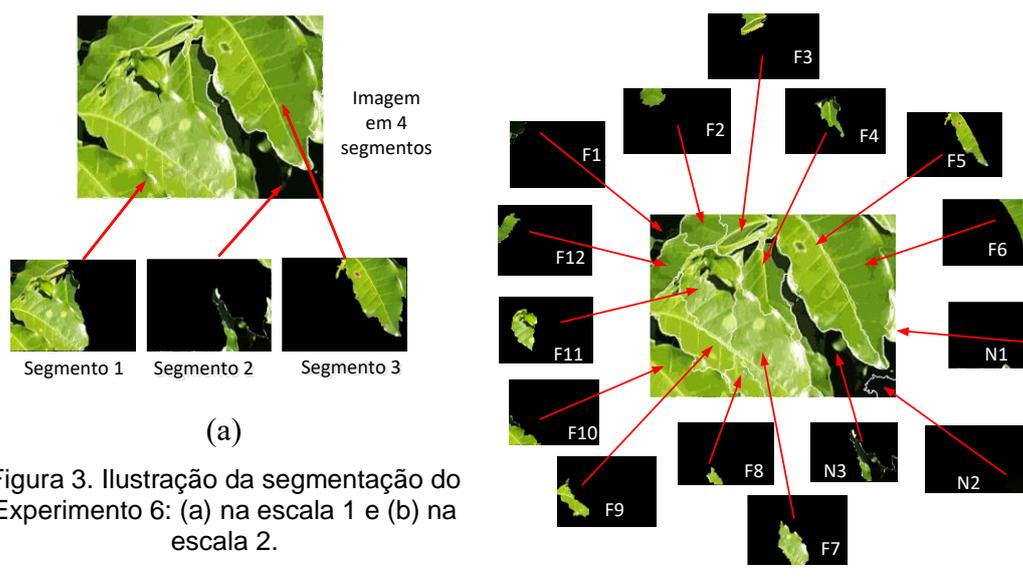


Figura 3. Ilustração da segmentação do Experimento 6: (a) na escala 1 e (b) na escala 2.

A Figura 3(b) refere-se ao resultado de segmentação do mesmo Experimento 6, na escala 2, onde 15 segmentos foram obtidos. Esse resultado mostrou-se mais adequado para a detecção de regiões foliares do que o resultado anterior. Nessa figura, os segmentos rotulados de F1 a F12 são correspondentes às regiões foliares, e os segmentos N1, N2 e N3, são regiões não foliares. A classificação de regiões foliares e não foliares nesse caso foi realizada por um especialista. Num trabalho posterior essa classificação deverá ser realizada por uma rede neural, com aprendizado supervisionado, sendo que os atributos a serem utilizados para o treinamento serão os histogramas normalizados das cores dos segmentos, excluindo a cor do fundo.

A Figura 4 (a) ilustra um dos segmentos obtidos para o Experimento 6, na escala 2, o segmento F5, onde é possível identificar a doença Cercóspora e a Figura 4 (b) mostra um segmento onde se verifica sinais da doença Ferrugem, segmento F7. A etapa de identificação de doenças em folhas cafeeiras deve ser realizada por uma rede neural, com treinamento supervisionado, o que deve ser implementada numa etapa posterior.

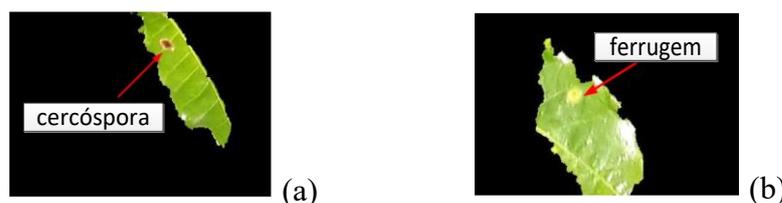


Figura 4. Partes segmentadas com doenças: (a) cercóspora e (b) ferrugem.

5. Conclusão

Este trabalho teve como finalidade o desenvolvimento de um sistema que faz a captura de imagens de cafeeiros, segmentação dessas imagens utilizando o algoritmo JSEG, e posterior classificação dos segmentos, para a detecção das partes foliares. Foi possível obter resultados e propor para um segundo momento a classificação dos segmentos obtidos e a verificação das anomalias que os cafeeiros podem ter ou estar sofrendo, com isso trazer mais ferramentas técnicas para os especialistas no campo. Pesquisas futuras referem-se à parte de classificação das partes segmentadas, com a detecção de regiões foliares, e posteriormente da detecção das principais doenças.

6. Referências

- Andrade, R.G., 2010. *Classificação das castanhas do Brasil por origem e seleção de suas amêndoas utilizando visão computacional*. São Paulo: USP - Universidade de São Paulo.
- Cavani, F. A., Sousa, R. V., Porto, A. J. V., Tronco, M. L., 2007. *Segmentação e classificação de imagens de laranjeiras utilizando JSEG e Perceptron multicamadas*. Laboratório de Simulação e Controle, EESC, USP, São Carlos, SP, Brasil e Instituto de Biociências, Letras e Ciências Exatas, UNESP, São José do Rio Preto, SP, Brasil.
- Deng Y. e Manjunath, B.S., 2001. *Unsupervised Segmentation of Color-Texture Regions in Images and Video*. Hewlett-Packard Laboratories. Palo Alto, CA and Department of Electrical and Computer Engineering, University of California, Santa Barbara, CA.
- EMBRAPA - Empresa Brasileira de Pesquisa Agropecuária, 2020. *Notícias - Estudos socioeconômicos e ambientais*. [Online] Available at: <https://www.embrapa.br/busca-de-noticias/-/noticia/50525698/producao-dos-cafes-do-brasil-da-especie-arabica-corresponde-a-47-da-mundial> [Acesso em 25 06 2020].
- Fambrini, F.; Iano Y.; Caetano, D.G.; Rodriguez, A.A.D.; Moya, C.; Carrara, E.; Rangel, A.; Cabelo, F.C.; Zubem, J.V.; Cura, L.M.D.V.; Destro-Filho, J.B.; Campos, J.R.; Saito, J.H., 2018. GPU Cuda JSEG Segmentation Algorithm associated with Deep Learning Classifier for Electrical Network Images Identification, *Procedia Computer Science*, Vol. 126, pp. 557-565.
- Gonzalez, R.C., Woods, R.E., 2008. *Digital Image Processing*. 4^a ed. New York: Pearson Education.
- Metre, V., Ghorpade, J., 2013. *An Overview of the Research on Texture Based Plant Leaf*. Pune: Computer Engineering Department - Pune University - India.
- Pagudpud, M.V., 2019. *Exploring the Smartphone Manipulation Skills in a Coffee Farming Community Using Clustering Algorithm*. Philippines: Quirino State University.
- Sorte, L.X.B., 2019. *Métodos Computacionais para Reconhecimento de doenças em folhas cafeiras*. Campo Limpo Paulista - SP: Centro Universitário Campo Limpo Paulista (UNIFACCAMP).