

Aplicação do pré-processamento de imagens para otimização do reconhecimento de padrões na detecção de deficiência nutricional em espécies vegetais

Fabricio Alves Silva¹
Eduardo Pelli¹
Heverton de Paula¹
Henrique Carlos Fonte Boa Carvalho¹
Ludmila Neves Nogueira¹

¹ Universidade Federal dos Vales do Jequitinhonha e Mucuri – UFVJM
Campus JK Rodovia MGT 367 - Km 583, nº 5000, Alto da Jacuba – 39100-000 – Diamantina
– MG, Brasil

fabricioasv@gmail.com, pelli@ufvjm.edu.br, heverton.floresta@gmail.com,
henriquefbc@gmail.com, ludnogueira@gmail.com

Abstract.

Plants require mineral elements from the ground for their survival. When these minerals are lacking or insufficient, characterizes the nutritional deficiency of the plant. Efficient detection of this deficiency is of great value to the agricultural sector, it allows an initial knowledge in order to fix the problem, conserving thus the production of the cultivation. There are basically two ways of identifying these deficiencies: foliar diagnosis, which analyzes the portion of nutrients in leaves; and visual diagnosis, which visually compares a sample with a known pattern. Generally these techniques are practiced by professionals in a manually way. However, when the amount of samples to be analyzed becomes very large, the precision to correctly detect deficiencies decreases and the working time is increased. In this context, the application of the technology can be helpful in order to ease these problems. For visual diagnosis, artificial vision systems that seek to imitate the human senses in order to recognize patterns in a database of digital images are applied. However, as the obtainment of the database is done manually, some cares for the environment are usually not considered and the images end up having problems such as blurring, shadows and little or too much light. Aiming to correct these problems, techniques for preprocessing the images are taken. The present study aimed to evaluate techniques for preprocessing digital images applied on a database beholding photographs of the cerrado plant species with and without nutritional deficiency used by a classifier. 6 preprocessing techniques were applied (histogram equalization using the HSV color model and using the RGB model, filter exposure, Median filter, and contrast enhancement of Otsu thresholding) and a combination (Filter Exposure and Median Filter). On each pre-processed basis, K-Nearest Neighbor classifier was applied, which was based on features selected by Relief metric. The results show improvements of about 2.04% to 5.45% on applying the classifier using the preprocessed images compared to the original database. The technique of histogram equalization HSV was the one with best results (Increase \cong 5.45%). Furthermore, the implementation of the classifier using the pre-processed images were faster compared to the use of the original database.

Keywords: pre-processing;, digital images, pattern recognition pré-processamento, imagens digitais, reconhecimento de padrões

1. Introdução

Todas as plantas necessitam de minerais absorvidos do solo para sua sobrevivência, sendo essenciais para o seu desenvolvimento. A falta desses minerais pode acarretar prejuízos no seu desenvolvimento.

Segundo Júnior et al. (2010) a detecção de forma efetiva destas deficiências é essencial para o setor agrícola, pois essa informação serve como base para uma intervenção ou o estudo de medidas preventivas de controle do problema.

As técnicas mais utilizadas para realizar a detecção de deficiências nutricionais são diagnose foliar e diagnose visual. A diagnose foliar consiste em analisar o tecido das folhas das plantas para identificar a proporção dos nutrientes necessários para seu desenvolvimento. Essa análise acontece durante períodos diferentes da vida da cultura. Já a diagnose visual, compara visualmente aspectos como textura, tamanho e coloração de unidades (folha, raízes, frutos, entre outros) da planta, a fim de identificar um padrão (FAQUIN, 2002). De acordo com Malavolta (2006), a folha é a principal característica analisada, pois é a região da planta onde acontecem os principais processos metabólicos enfatizando as características visuais da espécie.

Para diagnose visual, um exemplo de automatização é a utilização de Sistemas de Visão Artificial. Estes sistemas procuram se assemelhar ao sentido visual humano para reconhecer padrões de características presentes em imagens digitais, obtidas por meio de *scanners*, fotografias, câmeras de vídeo, entre outros equipamentos, e tomar decisões a respeito destas informações (MILANO; HONORATO, 2010).

Os Sistemas de Visão Artificial, são Técnicas de Processamento Digital de Imagens (PDI). Pode-se observar que essas técnicas quando usadas apresentam resultados satisfatórios, como no trabalho de Júnior et al. (2010) apresentou melhora de cerca de 40% na identificação de problemas de praga no cultivo de soja com base na análise de imagens digitais de folhas da espécie em relação a outros métodos da literatura e no trabalho de Andrade, Rocha e Canteri (2000) que utilizaram imagens digitais das folhas de plantas para quantificar o percentual da área afetada por doenças e deficiência nutricional em espécies de milho e cana-de-açúcar.

Segundo Zúñiga (2012), a maioria das abordagens de visão artificial podem ser divididas em três fases: aquisição, seleção e classificação. É importante ressaltar que, quando uma das fases não é executada de maneira correta, o resultado pode ser afetado de forma negativa.

A fase de aquisição de dados merece uma atenção especial entre as demais, uma vez que a coleta e obtenção de imagens digitais das amostras são realizadas de forma manual e em muitos casos cuidados como padronização e controle de ambiente não são considerados. Sendo assim, o resultado são imagens com fundos distintos, diferentes níveis de luminosidade, tonalidade, posicionamento distinto, sombra exacerbada, entre outros ruídos.

Para tentar minimizar estes defeitos, pode-se aplicar técnicas de pré-processamento de imagens sobre a base de dados a fim de eliminar ou enfatizar características desejadas.

Este trabalho teve como objetivo avaliar a aplicação de técnicas de pré-processamento de imagens sobre uma base dados de espécies nativas do cerrado contemplando fotografias de folhas que apresentam deficiência e folhas normais.

2. Referencial Teórico

De acordo com Bianchi (2006), Reconhecimento de Padrões é uma área de pesquisa que tem como objetivo classificar e categorizar dados em classes, de acordo com características semelhantes. Existem duas formas de se classificar um padrão: o reconhecimento supervisionado, quando a classificação é baseada em um conjunto de padrões já estabelecidos; e o reconhecimento não supervisionado, quando não há interferência externa e o sistema não possui informações conhecidas como forma de entrada.

O Reconhecimento de Padrões em imagens possui várias aplicações onde a visão computacional normalmente é o objetivo. Esses sistemas são denominados Sistemas de Visão Artificial e trabalham com imagens digitais. Imagem digital é a representação de imagens em sistemas automatizados. Existem trabalhos com essa abordagem voltados para área de detecção de doenças em espécies vegetais, como apresentado em Lima et al. (2012), Giandoni e Gambarato (2011) e Santos (2009).

Segundo Zúñiga (2012), para solucionar problemas de visão artificial, é necessário realizar

os passos definidos no diagrama apresentado na Figura 1:

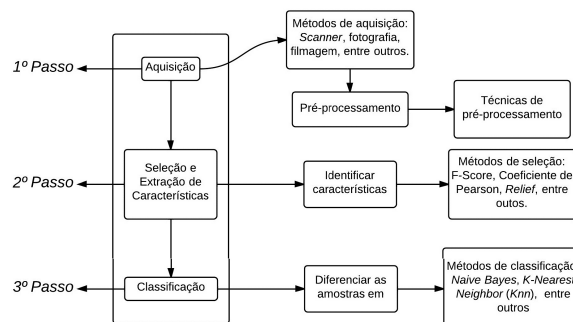


Figura 1: Fluxograma do funcionamento de um Sistema de Visão Artificial

A primeira etapa (Figura 1), define-se a forma de obtenção e o tipo dos dados que serão analisados. Vários métodos de aquisição de imagem geram imagens digitais: *scanner*, fotografia, filmagem, entre outros. Nessa etapa acontece o pré-processamento dos dados, que consiste em utilizar técnicas de pré-processamento de imagens para aumentar ou diminuir algumas características das imagens (características relevantes ou irrelevantes)..

Na segunda etapa (Figura 1) são identificadas quais características da base de dados são mais relevantes para classificar e agrupar os dados em classes distintas. Para tarefa de seleção pode-se citar os métodos *F-Score*, Coeficiente de Correlação de *Pearson* e *Relief*.

Segundo Duda, Heart e Stork (2001), o método *F-Score* disponibiliza uma medida dada pela distância entre as médias das distribuições de duas características (C_1 e C_2) em relação às suas variâncias. Quanto maior é o valor do *F-Score*, mais discriminativa é a característica (SILVA, 2010). Já o Coeficiente de Correlação de *Pearson* é um índice de relevância que mede o grau de relação entre duas distribuições (DUDA; HEART; STORK, 2001).

Outro método de seleção é o *Relief*. Diferente dos métodos *F-Score* e Coeficiente de Correlação de *Person* que são lineares e analisam apenas uma amostra em relação as outras por vez, o método *Relief* é multivalorado. Isso se deve ao fato do método avaliar várias instâncias (k), definidas como vizinhos, ao mesmo tempo. A relevância dos vizinhos é dada pela distância euclidiana (SANTANA, 2010).

Na terceira etapa ocorre a classificação, que consiste em utilizar as características obtidas na fase de seleção para diferenciar as amostras em classes. Para esta tarefa Guyon et al. (2006) citam como exemplo o classificador uni-valorado *Naive Bayes* e o classificador multivalorado *K-Nearest Neighbor (Knn)*. Estes classificadores são geralmente utilizados para auxiliar tarefas de Reconhecimento de Padrões (ROCHA, 2010).

Segundo Wanderley e Braga (2010), um classificador *bayesiano* se baseia no teorema de *Bayes* que calcula a probabilidade de qualquer evento A_1, A_2, \dots, A_n que quando unidos compõem um espaço amostral ou classe. De posse das probabilidades das classes e a verossimilhança entre elas, é possível adicionar e excluir indivíduos em cada uma.

Já o classificador *K-Nearest Neighbor*, *K*-vizinhos mais próximos, ou simplesmente *Knn*, assume que as amostras se encontram em um espaço n -dimensional onde n são as amostras e K o número de vizinhos de uma amostra. Diferente de outros métodos, as amostras são classificadas de acordo com características dos K -vizinhos mais próximos (DUDA; HEART; STORK, 2001). Para obter a relação de uma amostra com seus vizinhos é utilizada a distância euclidiana que calcula a proximidade entre eles (SOUZA, 2013).

O valor de K determina a quantidade de vizinhos que serão avaliados para classificar um indivíduo. Segundo Souza (2013), deve-se evitar: valores pares de K ; $K = 1$, para que a

classificação não caia em mínimos e máximos locais; $K = 9$, para não analisar muitas classes diferentes.

As imagens digitais são representações de imagens tridimensionais para o meio bidimensional. A tecnologia denominada Imagem Digital proporciona meios para o armazenamento, transmissão, geração e recuperação de imagens em sistemas computacionais.

As imagens digitais podem ser obtidas através de vários aparelhos como câmeras digitais, scanners, aparelhos de raios-X, radares, entre outros dispositivos.

No plano computacional, as imagens digitais podem ser armazenadas como imagens *bitmap*. Essas imagens são armazenadas como uma série de dígitos binários: 0 (zero) e 1 (um). Esses dígitos podem ser representados como uma matriz de *bits* binários que se agrupam em pequenos grupos para formarem um *pixel* (elemento da imagem). Cada *pixel* representa uma intensidade de luz e uma tonalidade de cores. Ao agrupar os *pixels* a imagem é formada (MACHADO; SOUKI, 2004).

Quando se agrupam 8 *bits*, é possível representar 256 valores, gerando 1 *byte*. A quantidade de *bits* presentes em cada *pixel* de uma imagem *bitmap* de acordo com sua representação de cores são apresentados na Tabela 1:

Tabela 1: Quantidade de *bits* por *pixel* em imagens *bitmap*

Modelo de cor	Quantidade de bits por pixel
Branco e Preto	1 bit
Tons de cinza	8 bits (256 níveis de cinza diferentes)
RGB	24 bits (16,7 milhões de cores)

De acordo com Silva (2001), a base de um trabalho de processamento de imagens digitais é a transformação dos *pixels* originais em frequências que representam a distribuição dos tons de cinza da imagem em relação aos *pixels*. Essa representação é denominada Histograma de cores.

Conforme Faria (2010), um histograma pode revelar várias informações sobre uma imagem. Com uma visão global, se o histograma é estreito, independente do ponto de agrupamento, pode-se afirmar que a imagem é pouco visível, uma vez que a diferença entre os tons de cinza é pequena.

3. Material e métodos

Os dados foram obtidos por meio de 100 fotografias de folhas de espécies nativas do cerrado contemplando plantas com deficiência nutricional e plantas normais. Foram utilizadas duas câmeras, sendo uma *Sony DSC HX1* com 9 *megapixels* e uma *Panasonic Lumix FZ-35* com 12 *megapixels*. Das imagens, 50% foram folhas normais (*FN*) e 50% são folhas com deficiência (*FD*) sendo que para cada *FN* existe uma *FD* da mesma espécie. Como tentativa de controlar o ambiente e aplicar o mesmo fundo para todas as fotografias, cada uma foi obtida posicionando a folha sob uma cartolina de cor preta.

Foram aplicadas as técnicas de pré-processamento: Equalização de Histogramas utilizando o modelo de representação cores *HSV*; Equalização de Histogramas utilizando o modelo de representação de cores *RGB*; Filtro de Exposição; Filtro de Mediana; Realce de Contraste; Limiarização de *Otsu*; e uma combinação com a aplicação do Filtro de Exposição e em seguida o Filtro de Mediana.

Para cada técnica de pré-processamento utilizada foi criado um diretório com o mesmo nome da técnica que armazenou as imagens resultantes da sua aplicação sobre a base de dados original, como demonstrado no Figura 2:

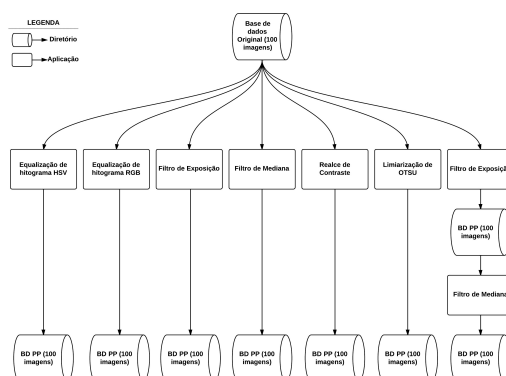


Figura 2: Fluxograma da aplicação das técnicas de pré-processamento sobre a base de dados original

De posse de todas as 800 imagens, sendo 100 imagens originais e 700 pré-processadas, o próximo passo foi obter os valores para seleção de características e aplicar o classificador. Essa etapa pode ser dividida em 4 passos como demonstrado na Figura 3:

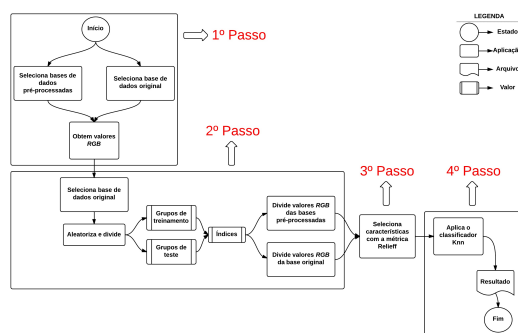


Figura 3: Fluxograma da aplicação das técnicas de pré-processamento sobre a base de dados original

O primeiro passo, demonstrado na Figura 3, foi a obtenção de valores dos histogramas das componente *R*, *G* e *B* de cada imagem das bases de dados.

No segundo passo (Figura 3), as imagens de cada base de dados foram identificadas por um índice, aleatorizadas e divididas em dois grupos: treinamento e teste. A aleatorização e divisão das bases de dados foram necessárias para que a cada nova execução demonstrada pelo fluxograma (Figura 3), o método *Relief* utilizasse diferentes imagens para identificar características e o *Knn* concebesse novos resultados. Além disso, o grupo de treinamento foi utilizado pelo classificador como modo de aprendizado para tomar suas decisões e o grupo de testes para avaliar seu julgamento (MORAIS, 2010).

Com o intuito de assegurar o mesmo ambiente de teste para execução do *Knn* utilizando as bases de dados pré-processadas e a base original, os índices selecionados para os grupos de treinamento e teste de todas as bases de dados, foram baseados na aleatorização da base de dados original.

O terceiro passo foi a seleção de características. Foi aplicado o método *Relief* que utilizou o grupo de treinamento para selecionar as regiões mais significativas dos histogramas, sendo cada um compreendido pelos valores: $0 \leq R \leq 256$; $257 \leq G \leq 512$; $513 \leq B \leq 758$.

No quarto passo (Figura 3), foi aplicado o classificador *K-Nearest Neighbor (Knn)*, com valor de $K = 3$, que utilizou as características selecionadas pelo *Relief* para selecionar as regiões do grupo de treinamento e do grupo de teste.

Foi definida a quantidade de 50 iterações para execução do fluxo apresentado pela Figura 3. Ao final de cada iteração, os resultados do classificador utilizando cada base de dados foram salvos em arquivos separados com os nomes referentes as técnicas de pré-processamento.

Após a execução das 50 iterações, foi calculada a média e o desvio padrão dos 50 resultados obtidos com a execução do classificador para cada base pré-processada.

Por fim, o fluxo apresentado pela Figura 3 foi executado com duas alterações. Na primeira apenas uma base de dados foi selecionada por vez no primeiro passo. Na segunda a divisão dos grupos de treinamento e teste foi feita a partir da base de dados de entrada. O objetivo foi obter e comparar o tempo total da execução das 50 iterações para o classificador utilizando a base de dados original e as bases pré-processadas.

4. Resultados e Discussões

Os resultados obtidos com a aplicação do classificador *Knn* sobre as bases de dados pré-processadas pelas técnicas propostas são apresentados na Tabela 2 abaixo:

Tabela 2: Resultados obtidos após aplicação de 50 iterações do classificador *Knn* sobre as bases de dados original e pré-processadas

Base de dados	Média da Acurácia	Desvio Padrão da Acurácia
Sem pré-processamento	73.3	10.3
Equalização de histograma HSV	77.3	7.1
Filtro de exposição e Filtro de Mediana	76.0	8.4
Realce de contraste	75.7	7.3
Otsu	75.7	7.3
Filtro de exposição	75.7	8.2
Equalização de histograma RGB	75.5	8.6
Filtro de Mediana	74.8	9.6

Como demonstrado na Tabela 2, a execução do classificador que obteve melhor resultado foi com a utilização da base de dados pré-processada pela técnica de Equalização de Histograma utilizando o modelo de cores *HSV*. Essa superação em relação as demais técnicas, ocorreu por dois motivos:

Dentre as técnicas de manipulação de histogramas aplicadas neste trabalho (Realce de Contraste *HSV*, Equalização de Histogramas *RGB* e Equalização de Histogramas *HSV*) a técnica de Equalização de Histogramas *HSV* foi a realizou a melhor distribuição das frequências dos tons de cinza do histograma proposto, como encontrado nos trabalhos de Gomes (2013) e Pereira e Rafael (1992) que utilizaram a técnica de equalização para nivelar os histogramas de imagens de plantas medicinais.

Como a técnica de Equalização de Histogramas *HSV* realiza modificações apenas na componente *V*, referente a luminância, e não altera as componentes referentes a tonalidade de cores (*H* e *S*), algumas características que eram identificadas pelo método *Relief* continuaram sendo selecionadas além dos novos atributos.

5. Conclusão

A aplicação do classificador *Knn* utilizando as bases de dados pré-processadas e aplicando a métrica *Relief* como seleção de características, alcançaram uma melhora de aproximadamente 2,04% a 5,45% se comparado a execução do *Knn* com a base sem pré-processamento.

Dentre as técnicas avaliadas, a Equalização de Histogramas utilizando o modelo de cores *HSV* foi a que atingiu o melhor resultado, apresentando uma melhora de aproximadamente 5,45% no resultado do classificador.

Além disso, foi possível perceber que a execução do *Knn* sob uma base de dados pré-processada pela técnica de Filtro de Exposição e em seguida pelo Filtro de Mediana, obteve melhor resultado se comparado a utilização das mesmas técnicas processadas separadamente.

Por fim, o tempo de execução do *Knn* com as bases de dados pré-processadas foram menores em relação a utilização da base original. Esse fato ocorreu pois os tamanhos, em *bytes*, das bases pré-processadas foram diminuídos. A relação da redução do tamanho e do tempo de execução foi inversamente proporcional para todas as bases de dados. A execução do *Knn* com a base pré-processada pelo método Filtro de Exposição apresentou menor tempo de execução (redução de $\cong 17\%$) e maior redução de tamanho (redução de $\cong 86\%$) em relação a utilização da base original.

6. Trabalhos Futuros

Para estudos futuros, podem ser aplicadas mais técnicas de pré-processamento sobre uma base de dados com fotografias de folhas de espécies vegetais e posteriormente avaliado a precisão do classificador *Knn* sobre as bases pré-processadas.

Em relação às técnicas avaliadas, pode-se realizar mais combinações para avaliar se o resultado da combinação de técnicas seguirá a mesma resolução do arranjo do Filtro de Exposição e do Filtro de Mediana e se a ordem de aplicação interfere de forma positiva ou negativa.

Referências

- ANDRADE, E. C. de; ROCHA, J. C. F. da; CANTERI, M. G. Análise de imagens de folhas para estimativa de severidade de doenças em plantas. p. 6, Outubro 2000.
- BIANCHI, M. F. de. *Extração de características de imagens de faces humanas através de Wavelets, PCA e IMPCA*. Dissertação (Mestrado), 2006.
- DUDA, R. O.; HEART, P. E.; STORK, D. G. *Pattern Classification*. 2. ed. [S.l.: s.n.], 2001.
- FAQUIN, V. *Diagnose do estado nutricional das plantas*. 77 p. Curso de Pós-Graduação "Lato Sensu" (Especialização) a Distância: Fertilidade do Solo e Nutrição de Plantas no Agronegócio., 2002.
- FARIA, D. *Análise e Processamento de Imagem*. Dissertação (Mestrado), 2010.
- GIANDONI, A. L. T.; GAMBARATO, R. L. Desenvolvimento de uma ferramenta computacional para a detecção do oídio das folhas de seringueira. v. 2, n. 2, Fevereiro 2011.
- GOMES, B. A. T. Desenvolvimento de um software que auxiliou estudo de característica visual de plantas medicinais. Outubro 2013.
- GUYON, I. et al. *Feature Extraction: Foundations and applications*. [S.l.: s.n.], 2006.
- JÚNIOR, A. C. de N. et al. Detecção automática da Área foliar danificada da soja através de imagens digitais. p. 8, 2010.
- LIMA, J. R. de et al. Comparação de histogramas de imagens digitais para determinação de similaridade em sementes de milho. v. 4, n. 2, p. 106–112, Agosto 2012. ISSN 2176-7270.
- MACHADO, A. W.; SOUKI, B. Q. Simplificando a obtenção e a utilização de imagens digitais scanners e câmeras digitais. v. 9, n. 4, p. 133–156, Julho - Agosto 2004.

MALAVOLTA, E. *Manual de Nutrição Mineral de Plantas*. [S.l.: s.n.], 2006.

MILANO, D. de; HONORATO, L. B. *Visão computacional*. 2010.

MORAIS, E. C. *Reconhecimento de Padrões e Redes Neurais Artificiais em Predição de Estruturas Secundárias de Proteína*. Tese (Doutorado), Março 2010.

PEREIRA, A. S.; RAFAEL, J. A. *Processamento de imagem em medicina*. v. 5, p. 23–27, 1992.

ROCHA, H. P. Seleção clonal de características rankeadas por filtros univariados para classificação de tipos de leucemia aguda. p. 7, Julho 2010.

SANTANA, G. A. Seleção de sondas relevantes para classificação da leucemia utilizando o método relief e análise em componentes principais. p. 6, 2010.

SANTOS, A. P. de O. *Desenvolvimento de descritores de imagens para reconhecimento de padrões de plantas invasoras (folhas largas e folhas estreitas)*. Dissertação (Mestrado), 2009.

SILVA, A. M. e. *Curso Processamento digital de imagens de satélite*. Outubro 2001. Acessado em 14 de junho de 2014. Disponível em: <www.cartografia.org.br>.

SILVA, A. P. A study about gene expression monitoring in classification of cancer. p. 6, 2010.

SOUZA, R. T. *Avaliação de classificadores na classificação de radiografias de tórax para o diagnóstico de pneumonia infantil*. Dissertação (Mestrado), Setembro 2013.

WANDERLEY, M. F. B.; BRAGA, A. de P. Seleção de características baseada em análise da Área abaixo da curva de roc de classificadores kde-bayesianos. p. 5, Julho 2010.

ZÚÑIGA, A. M. G. *Instituto de Ciências Matemáticas e de Computação*. Dissertação (Mestrado), Março 2012.