

# APLICAÇÃO DE TÉCNICAS DE MACHINE LEARNING NA DETECÇÃO DE PRESENÇA DE DOENÇAS NA FOLHA DO CAFEIEIRO

L. R. FERREIRA<sup>1</sup>, M. L. BEGNINI<sup>2</sup>

<sup>1</sup>Universidade de Uberaba, Departamento de Engenharia Química

<sup>2</sup> Universidade de Uberaba, PPG – Mestrado Profissional em Engenharia Química

**RESUMO** – Atualmente a tecnologia está presente em diversas áreas, inclusive na agricultura, onde se transformou em ferramenta indispensável na tomada de decisão. O monitoramento agrícola tem proporcionado uma análise da lavoura de forma mais precisa, proporcionando iniciativas de forma preventiva. Um dos principais recursos é a análise de imagens. Com a intenção de colaborar na detecção de doenças nas folhas das árvores do café surgiu este trabalho. Foram armazenadas imagens de folhas de café saudáveis e folhas de café que apresentam doenças, essas duas categorias já seriam suficientes para apresentar um resultado de semelhança durante a análise de outra folha qualquer, porém, pode ocorrer que a imagem a ser analisada não tenha nenhuma ligação com folhas de café, então, uma terceira categoria de imagens foi criada e denominada “outras”. As imagens são armazenadas em pastas distintas e para o teste foram analisadas 80 imagens em cada grupo, caso algum grupo tenha menos imagens que o outro o programa levará em conta a pasta com a menor quantidade de imagens e selecionará a mesma quantidade nas demais pastas para realizar o estudo. Uma nova imagem que não faz parte dos grupos já armazenados como banco de referências é apresentada ao algoritmo e então começa um processo que analisa todas as imagens saudáveis entre elas, todas as imagens com sinais de doença entre elas e todas as imagens diversas também entre elas. Diante das comparações entre cada imagem do grupo com as demais do próprio grupo é possível chegar à matriz de confusão, que apresenta o percentual de semelhança entre as imagens de cada grupo. Após a utilização da função bag-of-feature do software MatLab, um histograma é gerado representando um vocabulário de características analisadas pela função, então, a imagem a ser comparada é identificada como semelhante a um dos grupos do banco de imagens por meio das funções: `categoryClassifier=trainImage` e `CategoryClassifier(trainingSets, bag)`; utilizando o recurso de treinamento em outra função : `evaluate(categoryClassifier, trainingSets)`; Após esse processo é apresentada a classificação da imagem em questão, como doente, saudável ou outra. A análise permite identificar as semelhanças entre as imagens e, portanto, pode ser utilizada para distinguir diferentes doenças não só na folha do café, mas em outros tipos de cultivo. Mediante identificação será possível indicar qual a química, técnica agrícola ou outra solução profissional que seja ideal para o tratamento da planta.

Palavras-chave: Café, *Machine Learning*, MatLab, Imagens, Doenças

**ABSTRACT** – *Currently, technology is present in several areas, including agriculture, where it has become an indispensable tool in decision-making. Agricultural monitoring has provided a more accurate crop analysis, providing preventive initiatives. One of the main features is an image analysis. With the intention of collaborating in the detection of diseases in the leaves of coffee trees, this work emerged.*

*Images of healthy coffee leaves and coffee leaves that have been stored were stored, these two categories are already sufficient to present a similar result during the analysis of any other leaf, however, it may happen that the image to be analyzed does not have any link with coffee leaves, so a third category of images was created and named “others”. The images are stored in different masses and for the test 80 images were analyzed in each group, if any group has fewer images than the other, the program will take into account the folder with the least amount of images and will select the same amount in the other masses for carry out the study. A new image that is not part of the groups already stored as a reference bank is presented to the algorithm and then a process begins that analyzes all the healthy images – among them, all the images with signs of disease among them and all the miscellaneous images as well. between them . In view of the comparisons between each image of the group with the others of the group itself, it is possible to arrive at the confusion matrix, which presents the percentage of similarity between the images of each group. After using the characteristic function of the MatLab software, a histogram is generated, a vocabulary of characteristics analyzed by the function, then, the image to be compared is identified as similar to one of the image bank groups through the functions: categoryClassifier = trainImage and CategoryClassifier (trainingSets, bag); using the training feature in another function: evaluate (categoryClassifier, trainingSets); After this process, the classification of the image in question, such as sick, healthy or other, is presented. An analysis allows to identify similarities between the images and, therefore, can be used to distinguish different diseases not only in the coffee leaf, but in other types of cultivation. Upon identification, it will be possible to indicate the chemistry, agricultural technique or other professional solution that is ideal for the treatment of the plant.*

*Keywords: Coffee, Machine Learning, MatLab, images*

## **1. INTRODUÇÃO**

Os empresários agrícolas, mais especificamente os cafeicultores, devem intensificar suas ações para a adoção de novas práticas de gestão, incorporando em seus processos a utilização da tecnologia de informação (TI), pois ela possibilita, dentre outros benefícios, prover as informações necessárias à tomada de decisão. Sendo o café um produto historicamente importante no agronegócio brasileiro, é de interesse estudar a adoção de TI por parte dos empresários do setor cafeeiro (SANTOS e JESUS, 2005).

A cultura do café pode ser acometida por várias patologias desde o viveiro, ou seja, fase de incubação da muda de café, até o campo, onde o pé de café pode estar em fase de desenvolvimento e/ou produção. Tais doenças contribuem para a quebra na produção e na qualidade do fruto, que por consequência, produzirá um produto ruim e de difícil aceitação no mercado, gerando prejuízo ao produtor (CARVALHO, DA CUNHA e SILVA, 2012).

As aplicações do algoritmo de máxima verossimilhança (Maxver) são bastante conhecidas na literatura de sensoriamento remoto, estando este algoritmo presente em vários sistemas de “softwares” de processamento de imagens; e frequentemente, é usado como rotina de classificação padrão contra o qual outros algoritmos de classificação são comparados. Este algoritmo identifica a forma, o tamanho e a orientação das amostras de treinamento (VIEIRA, 2000).

O último Censo Agropecuário do Instituto Brasileiro de Geografia e Estatística (IBGE) mostrou que 1,5 milhão de produtores rurais acessam dados por meio de dispositivos eletrônicos, número 1.900% superior ao de 10 anos atrás, o que revela boa adesão às soluções digitais. “A digitalização de processos, entretanto, demanda infraestrutura telecomunicações na área rural, ainda reduzida no Brasil. É nosso calcanhar de aquiles” (ZAPAROLLI, 2020).

O processamento de imagens consiste na aplicação de técnicas que possam representar uma determinada imagem com o objetivo de extrair mais facilmente informações nela presente, esse processo busca representar a imagem de modo que o resultado final seja adequado para uma aplicação concreta e específica.

Com os Histogramas se torna possível o reconhecimento de padrões, que estão geralmente ligados às necessidades de uma interface de comunicação entre pessoas e máquinas, por meio de linguagens naturais e a construção de máquinas inteligentes que possam realizar pequenas tarefas como se fossem humanos.

No desenvolvimento deste projeto a simples aproximação do reconhecimento de padrão já pode ser considerada suficiente para tomada de decisão, porém, a porcentagem relacionada a essa aproximação deve estar o mais próximo possível dos 100% para aceitação.

Utilizando um algoritmo de aprendizado supervisionado, executado sobre um conjunto expressivo de amostras, um modelo de classificação é definido de tal maneira que seja possível classificar dados de entrada desconhecidos a partir desse modelo (BROWNLEE, 2016).

O aprendizado de máquina é composto de algoritmos orientados por dados, ou seja, são os dados de entrada que informam qual é a resposta ideal.

Neste projeto o algoritmo classificou em um grupo as imagens consideradas “doentes”, em outro grupo as imagens consideradas “saudáveis” e por fim as imagens chamadas de “outras”, uma vez que o treinamento acontece de forma recursiva buscando semelhanças entre as imagens do próprio grupo, e ao apresentar uma imagem de entrada ao sistema o mesmo consegue identificar suas características como mais semelhantes a um dos grupos já treinados.

## 2. MATERIAL E MÉTODOS

O “*Bag of Features*” é um método em visão computacional com raízes em uma técnica clássica para classificação de texto conhecida como “*Bag of Words*” (*BoW*) [SEBASTIANI 2002].

Fazendo uso do software MATLAB, uma imagem que será avaliada é carregada para uma variável denominada “imgbusca”, enquanto as pastas que contém o banco de imagens são carregadas para uma outra variável “imgSets”, preservando a estrutura das pastas e de forma recursiva, além disso, a referida função permite armazenar os dados de uma imagem em um objeto no MatLab sem precisar carregá-las na memória, ou seja, foram utilizadas no ‘*Workspace*’.

*Sintaxe:*

```
imgbusca = 'caso3.jpg'; imgSets =  
imageSet('C:\Projeto','recursive');
```

Quando uma imagem é carregada para o ambiente do MatLab a mesma é associada a uma variável. No exemplo abaixo a variável “img” foi preenchida por uma imagem do banco de teste e o resultado foi uma matriz.

*Sintaxe:* `img = read(caso2.jpg)`

Assim, com as imagens carregadas, o treinamento de cada categoria foi realizado por meio da função “trainingSets” e as imagens válidas de cada pasta foram contadas, pois, o programa utiliza sempre como referência a pasta com menor número de elementos e então seleciona o mesmo número nas demais, tal procedimento é realizado para que o número de imagens em cada categoria seja exatamente igual

Por meio da função “*Bag-Of-Features*” as imagens são identificadas em seus grupos e utilizando um vocabulário com 1000 pontos avaliados em cada imagem, a função é capaz de detectar as semelhanças entre elas.

Foi gerado o histograma que permite avaliar os diferentes pontos em cada imagem analisadas pelo software conforme a quantidade estipulada no vocabulário da função de padrões.

Deste modo, a quantidade de pontos analisados nas imagens reflete diretamente no histograma gerado pelo MatLab, quando mais detalhes analisados em uma imagem, o que chamamos de vocabulário da imagem, mais detalhes são apresentados no histograma, a ponto que se torna necessário a sua exibição em maior escala para visualização.

Por meio de uma matriz de confusão, é possível comparar imagens do mesmo grupo e também com os demais grupos, um índice de semelhança é estabelecido para cada grupo.

Fazendo uso da matriz de confusão foi possível estipular uma porcentagem de precisão que o método comparativo pode alcançar, neste caso foi possível chegar a 98% de precisão.

Finalmente após a classificação, é possível gerar o resultado, onde o algoritmo apontou qual grupo de imagens mais se assemelhava à imagem em análise naquele momento.

Etapas:

- Análise de Requisitos
- Escolha do software (MatLab)
- Seleção de imagens para compor o banco de imagens

- Desenvolvimento do algoritmo
- Ajustes no algoritmo e nas imagens do banco
- Resultados
- Conclusão

Os estudos e o desenvolvimento do código envolveram principalmente as técnicas dos métodos de classificação “BagOfWord” e “*Bag-Of-Features*”.

Código fonte:

```
clear all; close all;
imgbusca = 'caso3.jpg';
```

```
imgSets = imageSet('C:\Projeto','recursive'); minSetCount
= min([imgSets.Count]); trainingSets =
partition(imgSets,minSetCount,'randomize');
[trainingSets.Count]
```

```
bag
bagOfFeatures(trainingSets,'VocabularySize',1000,'PointSelection','Detector')
```

```
img = read(imgSets(1), randi(imgSets(1).Count));
featureVector = encode(bag,img); figure
subplot(3,2,1); imshow(img); subplot(3,2,2);
bar(featureVector); title('Ocorrencia Visual');
xlabel('Indice Visual'); ylabel('Frequencia');
```

```
img = read(imgSets(2), randi(imgSets(2).Count));
featureVector = encode(bag,img);
subplot(3,2,3); imshow(img); subplot(3,2,4);
bar(featureVector); title('Ocorrencia Visual');
xlabel('Indice Visual'); ylabel('Frequencia');
```

```
img = read(imgSets(3), randi(imgSets(3).Count));
featureVector = encode(bag,img); subplot(3,2,5);
imshow(img); subplot(3,2,6);
bar(featureVector);
title('Ocorrencia Visual');
xlabel('Indice Visual');
ylabel('Frequencia');
```

```
img = imread(fullfile('C:\analisar',imgbusca));
featureVector = encode(bag,img); figure
subplot(3,2,1); imshow(img); subplot(3,2,2);
bar(featureVector); title('Ocorrencia
Visual'); xlabel('Indice Visual');
ylabel('Frequencia');
```

```
categoryClassifier = trainImageCategoryClassifier(trainingSets, bag);
confusionMat = evaluate(categoryClassifier, trainingSets);
```

```
imgteste = imread(fullfile('C:\analisar',imgbusca)); figure
```

```
imshow(imgteste)
[labelIdx, scores] = predict(categoryClassifier, imgteste);
categoryClassifier.Labels(labelIdx)
```

### 3. RESULTADOS E DISCUSSÃO

A aplicação do algoritmo pode ser modificada conforme o banco de imagens a ele apresentado, o que torna possível a identificação de outros objetos ou produtos como a cana de açúcar, a soja, o algodão e não só a folha do café.

O primeiro passo que buscava a identificação entre folha saudável e folha doente era imprescindível para comprovar que outros grupos de imagens também possam utilizar o algoritmo para treinamento, classificando por exemplo grupos de tipos de doenças, neste caso, ao invés do algoritmo retornar simplesmente se a planta está ou não doente, o mesmo é capaz de identificar qual grupo de doenças e então recomendar conforme estudos laboratoriais, quais os produtos químicos devem ser utilizados no combate à doença.

Todos estes aspectos são melhorias e aprimoramentos que o algoritmo permite realizar em estudos futuros, assim como, as aplicações de novas tecnologias, como por exemplo transformá-lo em um código para web ou que possa se tornar um aplicativo para smartphone, onde o usuário poderia através de uma câmera capturar imagem de uma folha qualquer e o sistema identificar a doença logo em seguida.

Foi possível notar que as funções de inteligência artificial utilizadas no MatLab são sensíveis às configurações aplicadas, no caso da função “*Bag-Of-Features*” por exemplo, o vocabulário utilizado na função diz respeito à quantidade de características a serem analisados em cada imagem do banco.

Outro pronto observado é que a medida que o banco de imagens vai ficando maior, com uma quantidade maior de fotos, a quantidade de pontos analisados deve ser também aumentada, para que a análise seja perfeita, caso contrário serão muitas imagens e poucos pontos analisados em cada uma delas, o que pode ocasionar erros por semelhança de detalhes.

Em testes do início do projeto o número de imagens era pequeno, apenas 30 por grupo, então, não havia necessidade de avaliar uma grande quantidade de características por imagem, e com apenas 200 pontos analisados já era possível identificar o grupo correto, mas, à medida em que o banco de imagens foi alimentado com mais figuras, passando para 80 em cada grupo, foi necessário aumentar para 1000 o número de características analisadas por foto, para que, o algoritmo não resultasse em erros ao analisar imagens muito semelhantes.

Também é possível mudanças no algoritmo de forma que, ao identificar uma nova imagem como semelhante a um dos grupos de imagens do banco, o mesmo possa copiá-la para a respectiva pasta, alimentando ainda mais o banco de imagens, ressaltando que, no início do algoritmo já existe uma função que antes do processo de treinamento dar início, seleciona a mesma quantidade de imagens em cada pasta ou grupo para não causar pesos diferentes na análise, ou seja, é importante que o número de imagens seja sempre igual em todas as categorias do banco.

Tal aprimoramento faria com que o sistema fosse capaz de “aprender” cada vez mais, não só com as imagens já apresentadas, mas a cada teste realizado com figuras novas classificadas e posteriormente incorporadas ao banco de imagens.

Resultados gerados após a execução do código fonte:

*ans =*

*80 80 80*

*Creating Bag-Of-Features from 3 image sets.*

----- \*

*Image set 1: doentes.*

*\* Image set 2: outros.*

*\* Image set 3: saudavel.*

*\* Selecting feature point locations using the Detector method.*

*\* Extracting SURF features from the selected feature point locations.*

*\*\* detectSURFFeatures is used to detect key points for feature extraction.*

*\* Extracting features from 80 images in image set 1...done. Extracted 12566 features.*

*\* Extracting features from 80 images in image set 2...done. Extracted 14743 features. \**

*Extracting features from 80 images in image set 3...done. Extracted 17631 features.*

*\* Keeping 80 percent of the strongest features from each image set.*

*\* Balancing the number of features across all image sets to improve clustering.*

*\*\* Image set 1 has the least number of strongest features: 10053.*

*\*\* Using the strongest 10053 features from each of the other image sets.*

*\* Using K-Means clustering to create a 1000 word visual vocabulary.*

*\* Number of features : 30159*

*\* Number of clusters (K) : 1000*

*\* Initializing cluster centers...100.00%.*

*\* Clustering...completed 33/100 iterations (~0.42 seconds/iteration)...converged in 33 iterations.*

*\* Finished creating Bag-Of-Features*

*bag =*

*bagOfFeatures with properties:*

VocabularySize: 1000  
StrongestFeatures: 0.8000  
PointSelection: 'Detector'  
Upright: 1

*Warning: MatLab has disabled some advanced graphics rendering features by switching to software OpenGL. For more information, click here.*

*Training an image category classifier for 3 categories.*

----- \*

*Category 1: doentes*

*\* Category 2: outros*

*\* Category 3: saudavel*

*\* Encoding features for category 1...done.*

*\* Encoding features for category 2...done.*

*\* Encoding features for category 3...done.*

*\* Finished training the category classifier. Use evaluate to test the classifier on a test set.*

*Evaluating image category classifier for 3 categories.*

-----

*\* Category 1: doentes*

*\* Category 2: outros*

*\* Category 3: saudavel*

*\* Evaluating 80 images from category 1...done.*

*\* Evaluating 80 images from category 2...done.*

*\* Evaluating 80 images from category 3...done.*

*\* Finished evaluating all the test sets.*

*\* The confusion matrix for this test set is:*

*PREDICTED*

<i>KNOWN</i>	<i> doentes</i>	<i>outros</i>	<i>saudavel</i>	
				<i>doentes</i>
<i>/</i>	<i>0.99</i>	<i>0.00</i>	<i>0.01</i>	<i>outros</i>
<i>0.01</i>	<i>0.99</i>	<i>0.00</i>	<i>saudavel</i>	<i>/ 0.00</i>
<i>0.04</i>	<i>0.96</i>			

*\* Average Accuracy is 0.98.*





*ans =*

*'doentes'*

O objetivo do trabalho foi alcançado uma vez que se propôs a construção de um algoritmo de identificação de imagens e comparação entre um grupo considerado doente e outro saudável por meio das técnicas de Redes Neurais, mais especificamente utilizando “*Machine Learning*” para o reconhecimento de padrões.

Já comprovada a eficácia do software MatLab em soluções que envolvam inteligência artificial e a importância da aplicação das *Machine Learning* em todos os seguimentos de desenvolvimento de softwares que possam colaborar com a tomada técnicas de decisão, pode-se notar que as técnicas são perfeitamente aplicáveis ao tema proposto.

A precisão da análise das características das funções de *Machine Learning* se mostrou surpreendente após os ajustes necessários para criação dos histogramas, uma vez que, mesmo diante de diferentes cores, luminosidade, perspectivas ou outras influências que uma figura pode conter, o resultado foi assertivo.

Foi possível confirmar a eficiência do método bag-of-feature que se mostrou eficaz na classificação das fotos e foi capaz de identificar uma nova imagem como semelhante à um dos grupos.

Obviamente que as imagens para o banco foram previamente selecionadas e algumas delas foram descartadas por estarem em má qualidade ou até mesmo em distâncias de foco muito diferentes, seria muito mais complexo identificar a doença em uma foto panorâmica, por exemplo, por isso, é necessário a pré-seleção de fotos realmente válidas para os grupos em questão.

Na possibilidade de alimentar o banco de imagens com cada imagem testada e classificada pelo algoritmo deve-se considerar um acompanhamento das imagens testadas com intuito de preservar o bom funcionamento do algoritmo e garantir que somente imagens corretas sejam carregadas para as devidas pastas com imagens semelhantes.

O atual trabalho possibilita o desenvolvimento futuro de aplicativos para Smartphones ou Websites através da tradução do algoritmo (código-fonte) para uma linguagem de programação web.

Será possível identificar qual doença mais provável dentro de grupos de doenças préestabelecidas e não somente como folha doente ou não, a partir de então, recomendar tratamentos químicos preventivos ou pesticidas conforme indicações químicas para cada tipo de doença.

#### 4. CONCLUSÃO

O resultado esperado foi alcançado, uma vez que, o algoritmo consegue realizar a tarefa de classificação por padrões através do uso de “*Machine Learning*” com aprendizado supervisionado.

A aplicação do algoritmo pode ser modificada conforme o banco de imagens a ele apresentado, o que torna possível a identificação de outros objetos ou produtos como a cana de açúcar, a soja, o algodão e não só a folha do café.

Para o pequeno agricultor uma ferramenta como essa se torna fundamental para identificar não só no cafeeiro, mas também em outros tipos de cultivo, caso a ferramenta permita, pois, o mesmo conseguirá agir no combate das doenças de forma mais rápida podendo evitar gastos com profissionais e testes de identificação das doenças.

#### AGRADECIMENTOS

Os autores agradecem à Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG).

#### 5. REFERÊNCIAS

BROWNLEE, J. **Master *Machine Learning Algorithms***: Discover how They Work and Implement Them from Scratch. [s.n.], 2016.

CARVALHO, Vicente L.;DA CUNHA, Rodrigo L.;SILVA, Nathan R.N. **Alternativas de Controle de Doenças do Cafeeiro**. Coffee Science, 2012.

SANTOS, Marcos Eduardo dos. JESUS, José Carlos dos Santos. **Fatores que comprometem a adoção de tecnologia de informação em empresas cafeeiras**, 2011.

SEBASTIANI, F. **Machine learning in automated text categorization**. ACM computing surveys (CSUR), 2002.

VIEIRA, C. A. O. Accuracy of remotely sensing classification of agricultural crops: A comparative study. Nottingham: University of Nottingham, 2000

ZAPAROLLI, Domingos. **Agricultura 4.0**. Revista Pesquisa, 2020