

Determinação do Índice de Lesões em Imagens de Folhas Cafeeiras usando tNM modificado

Paulo da Cruz Cardim, Lucas Ximenes Boa Sorte, José Hiroki Saito

Faculdade de Campo Limpo Paulista - UNIFACCAMP
Campo Limpo Paulista - SP, Brasil

pcruzcardim@gmail.com, lucasxbs@yahoo.com.br,
saitojosehiroki@gmail.com

Abstract. *The tNM (tolerance Nearness Measure) is a normalized measure of how much two images are similar, using TNS (Tolerance Near Set). In the other hand, there is a problem to detect diseases in coffee leaves, such as Cercospora and Rust, that affects the productivity of this important commodity. This work proposes a method to detect these two coffee leaf diseases in coffee leaf images using a modified tNM, and KNN (K Nearest Neighbors) classification algorithm. Preliminary experiments showed that the proposed method is feasible.*

Resumo. *tNM (tolerance Nearness Measure) é a medida normalizada de quanto duas imagens são similares, usando TNS (Tolerance Near Set). No entanto, existe ainda um problema de detectar doenças em folhas cafeeiras, tais como Cercospora e Ferrugem, que afetam a produtividade desse importante produto. Este trabalho propõe um método para detectar essas duas doenças em imagens de folhas cafeeiras, usando um tNM modificado, e o algoritmo de classificação de K vizinhos mais próximos, KNN (K Nearest Neighbors). Experimentos preliminares mostraram que o método proposto é viável.*

1. Introdução e Contextualização

A teoria dos conjuntos próximos com tolerância, *Tolerance Near Sets (TNS)*, permite a atribuição de um índice de similaridade entre duas imagens, denominado tNM (*tolerance Nearness Measure*) [Peters, 2009]. Esta técnica foi utilizada por Deivid [Deivid 2019] para a comparação de imagens de regiões centrais de cidades localizadas nos diversos continentes. Uma outra aplicação possível de TNS é a comparação de imagens, na detecção de possíveis anomalias, por exemplo, doenças em folhas vegetais. Exemplos dessas doenças que se apresentam na lavoura cafeeira, são a Cercosporiose e a Ferrugem, que geram uma série de prejuízos na lavoura cafeeira.

Sorte [Sorte 2019] desenvolveu pesquisas relativas ao uso de redes neurais convolucionais para a detecção dessas doenças, baseadas diretamente nas imagens das folhas com anomalias, além do uso de técnicas de detecção de atributos estatísticos de textura como a energia, contraste, homogeneidade e correlação, atributos binários locais (*Local Binary Pattern*, LBP) e posterior classificação com redes neurais progressivas.

O presente trabalho descreve uma modificação do tNM para determinar o índice de lesão em imagens de folhas cafeeiras, afetadas por doenças como Cercosporiose e Ferrugem, comparando imagens de teste com imagens compostas por subimagens de regiões da folha cafeeira completamente lesionadas.

O restante do texto se organiza da seguinte maneira. A Seção 2 apresenta as bases matemáticas de *Near Sets*, *Tolerance Near Sets*, e a medida de proximidade com

tolerância (*tNM*). A Seção 3 refere-se ao método proposto usando um *tNM* modificado para a detecção de doenças em imagens de folhas cafeeiras, e também o método de classificação. Finalmente, na Seção 4 são descritas as metodologias, banco de imagens a serem utilizados e os próximos passos para o trabalho proposto.

2. Teoria Near sets, Tolerance Near Sets e *tNM*

Segundo a teoria de *Near Sets*, objetos perceptíveis são objetos que podem ser percebidos através de órgãos de sensibilidade humana. Os sistemas perceptíveis são referentes aos objetos perceptíveis e um conjunto de funções de prova que os descreve.

Um sistema perceptível (O, F) consiste de um conjunto não vazio de objetos perceptíveis O e um conjunto não vazio F de funções de prova de valores reais ϕ [Henry, 2010], $\phi \in F \mid \phi : O \rightarrow R$.

2.1 Descrição do objeto, Indiscernibilidade e Indiscernibilidade Fraca

Seja (O, F) , um sistema perceptível, e $B \subseteq F$, um conjunto de funções de prova. Então, a descrição de um objeto perceptível $X \in O$ é dada pelo vetor de atributos da equação 1:

$$\phi_B(x) = (\phi_1(x), \phi_2(x), \dots, \phi_l(x), \dots, \phi_l(x)), \quad (1)$$

onde: " l " é o comprimento do vetor $\phi_B(x)$, e $\phi_i(x)$ é uma função de prova.

Um objeto X e um objeto Y são indiscerníveis, se para $B \subseteq F$, existe a relação de indiscernibilidade \sim_B definida pela equação 2:

$$\sim_B = \{(x, y) \in O \times O \mid \forall \phi_i \in B. \phi_i(x) = \phi_i(y)\}, \quad (2)$$

ou seja, X e Y possuem os mesmos valores para todas as funções do conjunto B .

Um objeto X está fracamente próximo de um objeto Y dentro do sistema perceptível (O, F) , se $x \in X$ e $y \in Y$, e existe $\phi_i \in F$ tal que $\phi_i(x) = \phi_i(y)$, satisfazendo a relação de indiscernibilidade fraca, \cong_B , conforme equação 3:

$$\cong_B = \{(x, y) \in O \times O \mid \exists \phi_i \in F. \phi_i(x) = \phi_i(y)\} \quad (3).$$

2.2 Tolerance Near Sets (TNS)

Para um sistema perceptível (O, F) e $B \subseteq F$, a relação de tolerância $\cong_{B, \epsilon}$ é dada pela equação (4), em que " $\| \cdot \|_2$ " representa a norma L^2 .

$$\cong_{B, \epsilon} = \{(x, y) \in O \times O \mid \| \phi_B(x) - \phi_B(y) \|_2 \leq \epsilon\}, \quad (4)$$

A relação de tolerância é associada à definição de *Tolerance Near Sets* (TNS), ou seja, dois objetos X e Y são considerados próximos com tolerância, quando a distância, calculada pela norma L^2 , entre os seus vetores de atributos, for menor ou igual a um valor épsilon (ϵ) de tolerância.

2.3 Classificação

Apesar do TNS sugerir algoritmos de classificação para as subimagens obtidas das imagens X e Y a serem comparadas [Deivid, 2019], o KNN (do inglês *K Nearest Neighbors*), proposto por Fukunaga e Narendra [Fukunaga et al., 1975], que considera K vizinhos mais próximos, se apresenta como uma opção para a classificação das subimagens, apesar de obter classes disjuntas, diferente do TNS que obtém classes sobrepostas.

Quando se deseja classificar um dado objeto de teste, calcula-se a distância desse objeto com os objetos previamente rotulados em classes, e são escolhidos os K vizinhos mais próximos desse objeto. Como esses K vizinhos são previamente rotulados, é possível contar o número de vizinhos mais próximos em cada classe. Aquela classe, que tiver o maior número de vizinhos mais próximos do objeto, determina o rótulo do objeto. Dois itens importantes no KNN são como calcular a distância entre os objetos e o próprio valor de K. O valor de K deve ser ímpar para não haver empate, porém, um valor muito grande pode tornar o algoritmo lento, dependendo da quantidade de objetos a serem classificados. Para calcular as distâncias, dentre várias possibilidades, a mais comumente utilizada é a distância Euclidiana.

2.4 Tolerance Nearness Measurement (tNM)

A medida de proximidade com tolerância (*Tolerance Nearness Measure, tNM*) foi introduzida por Henry e Peters [Henry, 2010]. A Figura 1 ilustra o princípio do cálculo de *tNM*, onde dois objetos (imagens) X e Y são considerados para comparação. Ambas as imagens são subdivididas em 16 subimagens e essas subimagens são classificadas em quatro classes C_1, C_2, C_3 e C_4 , sendo H o conjunto dessas classes. O cálculo do *tNM* é obtido em função dessa classificação.

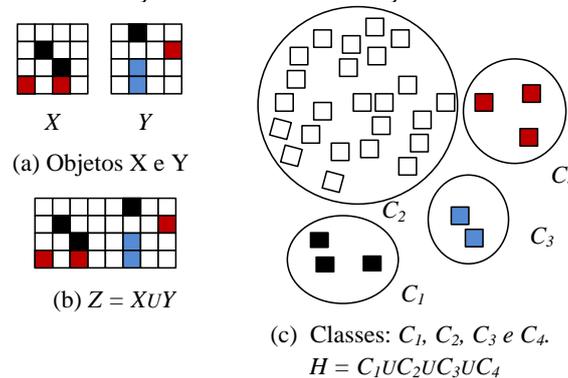


Figura 1. (a) duas imagens X e Y, subdivididos em 16 subimagens, (b) $Z = XUY$, conjunto de todas as subimagens, e (c) as quatro classes $H = \{C_1, C_2, C_3$ e $C_4\}$.

A definição de medida de proximidade pode ser resumida no seguinte, com (O, F) um sistema perceptível, com $\varepsilon \in \mathbb{R}$, e X e Y objetos disjuntos de modo que $Z = XUY$. Então a medida de proximidade *tNM* entre os dois objetos é dada pela equação 5:

$$tNM_{\cong B, \varepsilon}(X, Y) = \frac{\sum_{C \in H_{\cong B, \varepsilon}(Z)} \left(|C| \frac{\min(|C \cap X|, |C \cap Y|)}{\max(|C \cap X|, |C \cap Y|)} \right)}{\left(\sum_{C \in H_{\cong B, \varepsilon}(Z)} |C| \right)} \quad (5)$$

Na equação 5, o numerador corresponde ao somatório do tamanho de cada classe, $|C|$, multiplicado pela razão entre a mínima e a máxima ocorrências, das subimagens nas duas imagens consideradas. O denominador consiste no somatório do tamanho de todas as classes consideradas.

Para calcular o numerador do exemplo da Figura 1, considerando-se unitário o tamanho de cada subimagem, o tamanho da classe C_1 é igual a 3, pois nessa classe contém 3 subimagens. A mínima ocorrência da classe C_1 , entre as duas imagens é 1, na imagem Y, e a máxima ocorrência é 2, na imagem X, portanto a razão entre a mínima e a máxima ocorrências é $\frac{1}{2}$, assim, o resultado é $3 \times \frac{1}{2}$ para a classe C_1 . Aplicando o mesmo procedimento para as demais classes, obtemos para o numerador $3 \times \frac{1}{2} +$

$24 \times \frac{12}{12} + 2 \times \frac{0}{2} + 3 \times \frac{1}{2} = 27$. O denominador é dado pelo somatório do tamanho de todas as classes, que no caso é igual a 32, portanto o valor de tNM resultante é de $\frac{27}{32} = \sim 0,84$.

3. Detecção de Doenças em Folhas Cafeeiras usando tNM Modificado

A pesquisa proposta consiste no uso do tNM com modificação para a detecção de doenças em imagens de folhas cafeeiras.

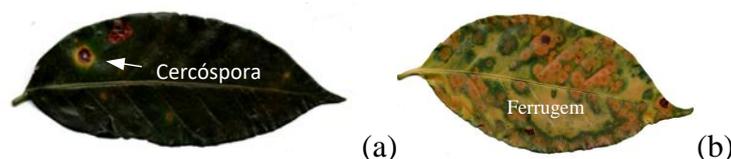
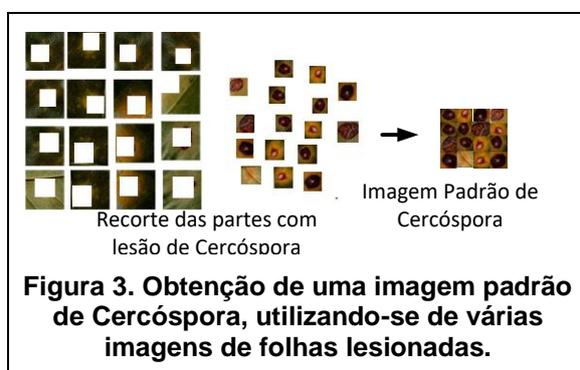


Figura 2. Folhas cafeeiras afetadas por: (a) Cercospora e (b) Ferrugem.

A Cercospora é uma doença provocada por um fungo *Cercospora Coffeicola*, a lesão necrótica contém um centro escuro circundado por um halo amarelado, conforme pode ser visto na Figura 2 (a). As folhas afetadas caem rapidamente e os galhos secam, causando uma redução na produtividade, diminuindo a qualidade da fruta. Gerando uma intensa queda de folhas que impede o crescimento da planta [Pereira, 2008].

Uma outra doença comum em folhas cafeeiras é a ferrugem, causada pelo fungo *Hemileia Vastatrix*, caracterizada pela lesão que causa a queda de folhas, afetando a produtividade. Normalmente, cerca de 35% de toda a plantação é afetada quando as condições climáticas são propícias para a doença, e em épocas prolongadas de seca, a queda pode chegar a 50% [Kushalappa, 1984]. A Figura 2 (b) ilustra uma folha cafeeira afetada pela ferrugem, que diferentemente da Cercospora se espalha ao longo da folha.

A pesquisa se propõe a comparar imagens de folhas com ou sem lesões com imagens padrões com lesões. Para a construção das imagens padrões com lesões, pretende-se isolar a parte da folha cafeeira com lesão das duas doenças, em várias subimagens e formar imagens compostas: 1) imagem padrão de Cercospora e 2) imagem padrão de Ferrugem. A Figura 3 é uma ilustração da obtenção de uma imagem padrão de Cercospora, utilizando várias imagens de folhas com lesão e a Figura 4, de uma imagem padrão de Ferrugem.



3.1 Procedimento do tNM Modificado

O procedimento tNM modificado é ilustrado pela Figura 5, em que uma imagem de teste X é comparada com uma imagem Y padrão de Cercospora, obtido pelo procedimento descrito. Cada uma das imagens é subdividida em subimagens de mesmo tamanho, e o conjunto dessas subimagens é classificado. No exemplo, foram obtidas duas classes em que $C_{lesões}$ é constituída de subimagens com lesões de Cercospora e

C_{saud} é constituída de subimagens de partes aparentemente saudáveis da folha, sendo $H = \{C_{saud}, C_{lesões}\}$.

Aplicando-se a equação 5, de cálculo do tNM, o numerador é obtido para a classe $C_{lesões}$, sendo $|C_{lesões}| = 16 + 3 = 19$, o total de subimagens, considerando-se cada subimagem com tamanho 1. A razão entre a menor e maior intersecção com X e Y é dada por $\frac{3}{16}$. Para a classe C_{saud} , o resultado é zero pois as subimagens saudáveis só existem em X. Portanto, $tNM = \left(19 \times \frac{3}{16}\right) / 32 = 0,11$. Esse resultado indica que 11% da imagem X é lesionada pela doença.

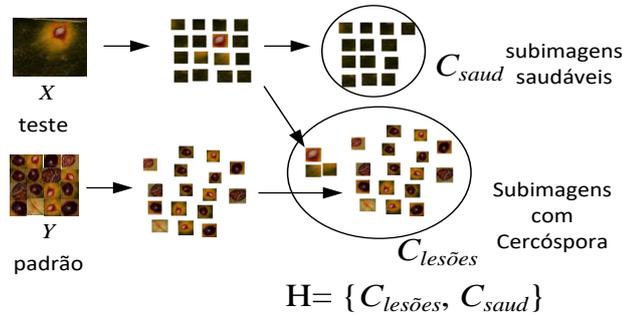


Figura 5. Ilustração do tNM modificado para a detecção de Cercóspera.

Considerando-se que o procedimento sempre vai comparar uma imagem de teste X com uma certa porcentagem de lesão, com uma imagem padrão da doença Y, o cálculo de tNM pode ser simplificado, precisando calcular apenas a razão de menor e maior intersecção em X e Y, para essa classe, conforme equação 6:

$$tNM_{modificado}(X, Y) = \frac{|C_{lesões}| \frac{\min(|C_{lesões} \cap X|, |C_{lesões} \cap Y|)}{\max(|C_{lesões} \cap X|, |C_{lesões} \cap Y|)}}{(\sum_{C \in H} |C|)} \quad (6)$$

4 Metodologia de Trabalho, Resultados Preliminares e Conclusões

Quanto às imagens a serem utilizadas, estas serão modificações das utilizadas por Sorte [Sorte, 2019], obtidas de uma fazenda cafeeira pertencente ao Instituto Federal do Sul de Minas Gerais, Departamento de Agricultura, Muzambinho-MG, digitalizadas na resolução de 300 dpi, de onde as imagens de partes lesionadas de dimensão 128x128 foram obtidas. As modificações consistem na seleção das partes lesionadas em imagens menores de 58x58 pixels, conforme ilustradas na Figura 6, em três categorias.

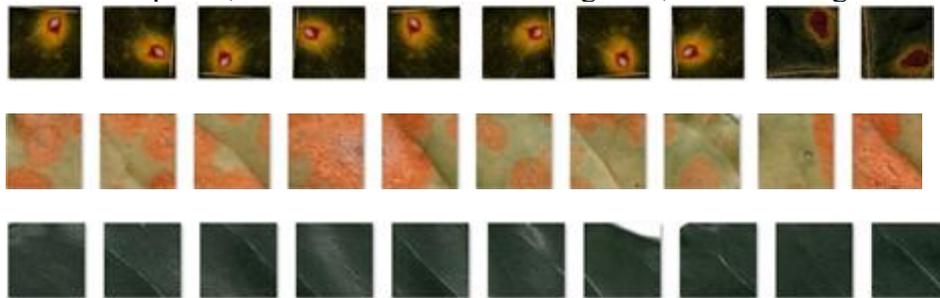


Figura 6. (superior) amostras de imagens com Cercóspera, (intermediário) imagens com Ferrugem, e (inferior) amostras de folhas saudáveis.

Em seguida devem ser construídas as imagens padrões para as lesões de Cercóspera e Ferrugem, obtendo as subimagens dessas lesões, conforme descrito na Seção 3. Os testes devem ser realizados, para cada imagem selecionada, subdividindo-a em subimagens na mesma dimensão das subimagens das imagens padrões.

A classificação das subimagens X e Y, no procedimento do tNM modificado, pode utilizar como funções de prova, os próprios pixels, bem como atributos de textura obtidos dessas subimagens. Os atributos de textura estatísticos como a energia, correlação, contraste e homogeneidade, podem ser obtidos usando a matriz GLCM (*Gray Level Cooccurrence Matrix*), proposta por Haralick [Haralick et al., 1973]. Um outro tipo de atributo, denominado de padrões locais binários (Local Binary Pattern, LBP), proposto por He e Wang (He et al., 1990) também pode ser utilizado.

Para a avaliação dos resultados obtidos, pretende-se utilizar o coeficiente Kappa, proposto por Jacob Cohen [Cohen, 1960], além dos índices comumente usados como de sensibilidade ou revocação.

Como experimentos preliminares, foram construídos três imagens padrões: de Cercospora, Ferrugem e folhas saudáveis, aplicado o tNM_{modificado} para o cálculo do índice de lesões em imagens de folhas de teste. O resultado mostrou a viabilidade do método proposto, porém, um conjunto de experimentos com uma quantidade grande de amostras de imagens são necessários para maiores conclusões.

Como continuidade do trabalho, os procedimentos mencionados devem ser seguidos, as medidas de tNM_{modificado} devem ser realizadas para um número significativo de amostras e calculados os coeficientes Kappa e os índices de acerto no reconhecimento de doenças cafeeiras.

Referências

- [Cohen, 1960] Cohen, Jacob. (1960). A Coefficient of Agreement for Nominal Scales – Educational and Psychological Measurement. *Educational and Psychological Measurement* **20** (1): 37–46.
- [Deivid et al., 2019]. Deivid, A. P. S.; Lima, D.C.; Saito, J.H. (2019). Tolerance Near Set and tNM Application in City Images. *ICCS (International Conference on Computer Science), LNCS 11537*, pp. 564-579.
- [Fukunaga et al., 1975] Fukunaga, K.; Narendra, P. M. (1975) A branch and bound algorithm for computing k-nearest neighbors. *IEEE Transactions on Computers*, v. 100, n. 7, p. 750–753, 1975.
- [Haralick et al., 1973] Haralick, R. M.; Shanmugan, K.; Dinstein, I. (1973) Textural Features for Image Classification, *IEEE Transactions on Systems, Man, and Cybernetics*, n. 6, p. 610-621.
- [He et al., 1990] He, Don-Chen, Li Wang. (1990). Texture Unit, Texture Spectrum, and Texture Analysis. *IEEE Trans. on Geoscience and Remote Sensing* **28** (4): 509-512.
- [Henry 2010] Henry, C. J. (2010) Near sets: theory and applications. *PHD thesis, University of Manitoba, Canada*.
- [Kushalappa et al., 1984] Kushalappa, A.C., M.Akutsu, S.H. Oseguera, G.M.Chaves et al. (1984). “Equations for Predicting the Rate of Coffee Rust Development Based on Net Survival Ratio for Monocyclic Process of Hemileia Vastatrix [Coffea Arabica].” *Fitopatologia Brasileira (Brazil)*.
- [Pereira, 2008] Pereira, Cassiano Spaziani, Rubens José Guimarães, Edson Ampélio Pozza, and Adriano Alves da Silva. (2008). “Controle de Cercosporiose e da Ferrugem do Cafeeiro com Extrato Etanólico de Própolis” *Ceres* **55**(5): 369-376.
- [Peters 2009] Peters, J. F. (2009). Tolerance near sets and image correspondence. *International Journal of Bio-Inspired Computation*, 1(4), 239-245.
- [Sorte, 2019]. Sorte, L.X.B. (2019). Métodos Computacionais para Reconhecimento de Doenças em Folhas Cafeeiras. *Dissertação de Mestrado*, Centro Universitário Campo Limpo Paulista, Campo Limpo Paulista-SP.