

## **Uma metodologia para identificação de características de mangas baseada em “*Tolerance Near Sets*” utilizando descritores de textura e cor**

*Diego Saqui<sup>1</sup>, José Hiroki Saito<sup>1,2</sup>, Lúcio A. de C. Jorge<sup>3</sup>, Rodrigo B. Piassi<sup>3</sup>*

<sup>1</sup> Departamento de Computação - DC, Universidade Federal de São Carlos - UFSCar, São Carlos, SP, Brasil, [diego.saqui@dc.ufscar.br](mailto:diego.saqui@dc.ufscar.br).

<sup>2</sup> Faculdade Campo Limpo Paulista - FACCAMP - Campo Limpo Paulista, SP, [saito@dc.ufscar.br](mailto:saito@dc.ufscar.br)

<sup>3</sup> Embrapa Instrumentação Agropecuária, São Carlos, SP, Brasil, [lucio.jorge@embrapa.br](mailto:lucio.jorge@embrapa.br), [rodrigopiassi@outlook.com](mailto:rodrigopiassi@outlook.com)

### **RESUMO**

Este artigo propõe o uso de “*Tolerance Near Sets*” com informações de textura e cores para classificação automática de cor e problemas de mangas, tais como danos mecânicos, exposição solar, entre outros. Este trabalho é parte de um projeto maior que tem o objetivo de avaliar automaticamente a manga por uma série de características. A metodologia explorada consiste em três fases: pré-processamento, geração de classes e classificação de novas mangas. Testes foram realizados e os resultados demonstraram que a abordagem pode ser utilizada para esse propósito.

**PALAVRAS-CHAVE:** *Tolerance Near Sets*, *Near Sets*, Agrupamento, Classificação.

### **ABSTRACT**

This paper proposes the use of *Tolerance Near Sets* with information about texture and color for automatic classification of mango color and other problems, such as mechanical, sun exposure, and others. This work is part of a larger project which proposes evaluating the mango through various features. The methodology consists of three phases: preprocessing, clustering of classes, and classification of new mangoes. Tests were performed and the results demonstrated that the approach can be used for this purpose.

**KEYWORDS:** *Tolerance Near Sets*, *Near Sets*, Clustering, Classification.

### **INTRODUÇÃO**

A análise de características de frutas é importante para identificar aspectos de maturidade, qualidade ou diferenciação de frutas no cenário de fruticultura (CEAGESP, 2005; ZAWBAA,

2014; ARIVAZHANGAN *et al.*, 2010; SENG e MIRISAE, 2009). Essas operações estão sujeitas a erros de especialistas, sendo, portanto importante o uso de tecnologias que possibilitem a realização dessas tarefas automaticamente. Para esse fim, a visão computacional apresenta soluções para estudos de frutas (KOSLOWSKI *et al.*, 2013).

Um exemplo de aplicação com mangas é o estudo realizado na Companhia de Entrepostos e Armazéns Gerais de São Paulo (CEAGESP) no Brasil, no processo de determinação da qualidade de mangas. Atualmente, a qualidade da manga é avaliada de forma manual, com a participação de especialistas e existe o interesse de automatização. Para avaliação o estado de maturidade, características que indicam podridão, danos mecânicos, danos por radiação solar, entre outros podem ser utilizados (CEAGESP. 2005).

Muitos sistemas de classificação de frutas são baseados em cores (ROCHA *et al.*, 2010; KOSLOWSKI *et al.*, 2013), formas (ZAWBAA, 2014), textura (ARIVAZHAGAN *et al.*, 2010) e tamanhos de frutas (SENG e MIRISAE, 2009). Tais sistemas são utilizados para identificação de diferentes tipos de frutas. Trabalhos que utilizam cores para classificação de frutas concentram aplicações que envolvem a identificação da maturidade ou características relacionadas à qualidade das frutas (BRAUN *et al.*, 2014). Descritores de textura em imagens podem ser utilizados para discriminar diferentes padrões de imagens através da dependência de intensidade entre os pixels e seus vizinhos (KARTIKEYAN; SARKAR, 1991).

Em Zawbaa (2014) é proposto um sistema de reconhecimento automático e classificação de diferentes frutas. Nesse trabalho são utilizadas características de forma e cores. O sistema é composto por um (a) pré-processamento onde as imagens são redimensionadas para 90 x 90 pixels com o propósito de reduzir o seu índice de cor; (b) extração de características onde é utilizado o *scale invariant feature transform* (SIFT) e informações de forma e cor para gerar um vetor de características; e (c) classificação dos tipos de frutas onde são utilizados o *K-Nearest Neighborhood* (KNN) e *Support Vector Machine* (SVM).

Em Seng e Mirisae (2009) cores são utilizadas para um processo de reconhecimento de tipos de frutas. O método de classificação é baseado no KNN e utiliza o modelo RGB (do inglês *Red - Green - Blue*) na classificação de cores. Na maioria dos trabalhos apresentados até aqui, os descritores de imagens são utilizados separadamente para análise, tais como média de cores em diferentes padrões, informações sobre textura, entre outros, porém existem trabalhos que fazem a combinação de descritores.

ARIVAZHAGAN *et al.* (2010) utilizam a combinação de descritores de cores e textura para identificação de frutas. Nesse trabalho os autores destacam que a combinação de diferentes tipos de descritores pode trazer resultados significativos. Para cores foram utilizados

as variáveis do padrão HSV e para textura os parâmetros estatísticos como média, desvio padrão, as derivadas dos componentes H e S, assimetria e curtose. Após a extração de todos os descritores de interesse de algumas amostras de frutas em uma base de dados. Com os dados armazenados é possível realizar o processo de classificação. Para esse trabalho como critério de comparação entre imagens de amostra e novas imagens foi utilizado o cálculo de distância mínima. Experimentos realizados nesse trabalho demonstraram que a combinação de descritores no processo de classificação permite a obtenção de melhores resultados.

Como observado nos trabalhos apresentados é comum a utilização de diferentes métodos como o SVM, KNN e *K-Means*, porém neste trabalho é considerada a utilização da metodologia de *Near Sets* explorando sua capacidade e aplicabilidade. A metodologia *Near Sets* tem sido citada como uma abordagem que permite operar com diferentes tipos de descritores em imagens. Descritores de textura, forma e em cores podem ser utilizados para identificar padrões com essa metodologia. *Near Sets* provê as formalidades para identificar, comparar e medir a semelhança de objetos com base em suas características. *Tolerance Near Sets* (TNS) é uma extensão de *Near Sets* que permite operar com uma relação de tolerância que consequentemente se aproxima a situações reais (HENRY, 2012).

Em Silva *et. al.* (2014) TNS é explorada no contexto de detecção de explosões solares em imagens obtidas por técnicas de radioastronomia. Nessa aplicação são utilizados padrões de textura, tais como energia, entropia, contraste, homogeneidade e correlação. O procedimento de classificação é constituído por 2 fases. Na primeira fase é determinado um conjunto de sub-imagens de explosões solares convertidas em níveis de cinza. Com o uso de funções de descrição, são obtidos os descritores de textura. As sub-imagens, através de seus descritores, foram comparadas umas com as outras com o uso de norma  $L_2$ . O resultado dessa norma é ainda comparado com um limiar de tolerância indicando se as imagens são de mesma classe. Com esse procedimento foi estabelecido um conjunto de classes de explosões solares. Na segunda fase novas imagens são classificadas conforme as classes determinadas na etapa anterior. Nessa etapa são utilizados os descritores de textura, a norma  $L_2$  e o limiar de tolerância como parâmetros de comparação. Os resultados apresentados com o uso dessa metodologia foram comparados com a técnica de *K-Means* e foram significativos.

Com base nos trabalhos apresentados e a metodologia de TNS, no presente artigo é apresentada uma nova abordagem para detecção e classificação de características de mangas em imagens, visando a utilização desta abordagem na avaliação de qualidade de mangas comercializadas no CEAGESP. Este trabalho explora a metodologia de TNS e a combinação de descritores de textura e cores, e os detalhes são discutidos nas seções posteriores.

## MATERIAL E MÉTODOS

Nesta seção são apresentados os recursos e metodologias utilizadas no desenvolvimento deste trabalho. Primeiramente são discutidas as teorias de *Near Sets* e *Tolerance Near Sets*, e então são apresentados os detalhes do desenvolvimento da metodologia proposta para este trabalho.

### *Near Sets*

*Near Sets* é um fundamento teórico que descreve que dois conjuntos contendo objetos são similares, se eles esses objetos contêm características em comum, ou seja, a similaridade é determinada pela comparação de características dos objetos desse conjuntos (SILVA, 2014).

*Near Sets* é um *framework* matemático e opera como a percepção humana, considerando que conjuntos de objetos são similares se tiverem características comuns (HENRY, 2012). Os principais conceitos de *Near Sets* são:

- Um objeto é algo do mundo real que pode ser percebido e descrito por suas características, por exemplo, pixels de imagens obtidas por câmeras que podem ser discriminadas por descritores. Objetos de amostra são aqueles que podem ser previamente conhecidos e os de entrada são novos que devem ser comparados com os de amostra.
- A função de descrição é responsável por retornar um valor que representa uma característica (descritores em imagens) perceptível do objeto. O conjunto dessas funções é responsável pela descrição do objeto.
- Um sistema perceptivo  $\langle O, F \rangle$  consiste de um conjunto não vazio ' $O$ ' de objetos de amostra e um conjunto não vazio ' $F$ ' de funções reais/descrição  $\varphi \in F$  tal que  $\varphi: O \rightarrow \mathbb{R}$ . Sistemas perceptivos são aplicados na classificação de novos objetos.
- A descrição do objeto é um vetor composto por um conjunto de funções de descrição ' $B$ ', sendo que  $B \subseteq F$ . O vetor de descrição de um objeto perceptual  $x \in O$  é apresentado na equação (1)

$$\varphi B(x) = (\varphi 1(x), \varphi 2(x), \dots, \varphi i(x), \dots, \varphi l(x)), \quad (1)$$

onde é ' $l$ ' o tamanho do vetor  $\varphi B$ , e cada  $\varphi i(x)$  em  $\varphi B(x)$  uma função de descrição que é parte da descrição do objeto  $x \in O$ . Esse vetor permite descrever objetos conforme suas características.

- A relação de indiscernibilidade perceptual determina a diferença entre as características dos objetos que estão sendo comparados. A relação de indiscernibilidade perceptual ' $\sim B$ ' é representada na equação (2).

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

Essa relação permite determinar a equivalência entre objetos e criar classes que possuem características semelhantes. É importante determinar a relação de indiscernibilidade perceptual fraca ' $\simeq B$ ', que é representada na equação (3).

$$\simeq B = \{(x, y) \in O \times O : \exists \phi_i \in B, \phi_i(x) = \phi_i(y)\}. \quad (3)$$

Diferentemente da relação de indiscernibilidade perceptual que considera a similaridade entre objetos com base em todas características, essa relação indica que a similaridade pode ser indicada por apenas algumas características.

- *Tolerance Near Sets (TNS)* fornece uma base matemática para a definição de similaridade entre um par de objetos. Essa definição é dada por um espaço de tolerância que é um grau de relaxamento para uma relação de indiscernibilidade. Um espaço de tolerância  $\langle X, \xi \rangle$  é constituído de uma relação de tolerância ' $\xi$ ' sobre  $X \subseteq O$  ( $\xi \subseteq X \times X$ ) que é reflexiva ( $\forall x \in X, x \xi x$ ) e simétrica ( $\forall x, y \in X, \text{ se } x \xi y \text{ então } y \xi x$ ). Sendo  $\xi \in R$ , para cada  $B \subseteq F$  a relação de tolerância perceptual é definida conforme a equação (4)

$$\xi_{B, \varepsilon} = \{(x, y) \in O \times O : \|\phi(x) - \phi(y)\|_2 < \varepsilon\}. \quad (4)$$

Essa relação em conjunto com as outras definições são utilizadas na metodologia proposta, onde a aplicação e os resultados são apresentados nas seções seguintes (HENRY, 2012).

### ***Metodologia desenvolvida***

A metodologia utilizada neste trabalho segue os princípios de *Tolerance Near Sets* sendo baseada na abordagem utilizada em Silva *et. al.* (2014), porém junto aos descritores de textura, também considera descritores de cores. A metodologia desenvolvida consiste de 3 fases que são apresentadas e discutidas a seguir:

#### **Fase 1 – Pré-processamento:**

Na fase 1 é realizado o pré-processamento das imagens, onde são consideradas 200 imagens de mangas de tamanho 800x600 em diferentes condições. 100 dessas imagens foram

utilizadas para gerar 1000 sub-imagens de amostras de tamanho 30x30 pixels. As outras 100 imagens (objeto de entrada em *Near Sets*) foram utilizadas para validação do sistema.

Ainda na etapa de pré-processamento, foi realizado a extração de descritores das imagens de amostra que foram utilizadas no processo de comparação de imagens. As funções que fazem a extração desses descritores no contexto de *Near Sets* são as funções de descrição.

Para informações referentes a cores, foi considerado a média de 'L', 'a' e 'b' do espaço de cores 'Lab'. Para informações referentes a textura, foram considerados alguns dos descritores de Haralick, tais como Contraste, Correlação, Entropia, Energia e Homogeneidade (HARALICK, SHANMUGAM E DISTEIN, 1973).

### Fase 2 – Agrupamento e geração de classes

Com o conjunto de sub-imagens de amostra, um processo de treinamento é realizado utilizando conceitos de *Tolerance Near Sets*. Nesse processo cada sub-imagem do conjunto de amostra é comparada com todas outras. Para essa comparação o cálculo de distância euclidiana é aplicado aos descritores de média dos atributos 'Lab' em conjunto aos descritores de Haralick. O resultado da distância euclidiana é utilizado na relação de indiscernibilidade perceptual fraca (*Near Sets*). De acordo com uma relação de tolerância é indicado se duas sub-imagens são de mesma classe ou não. Um exemplo do resultado da aplicação da distância euclidiana para um limiar de tolerância 0.11, entre uma amostra das sub-imagens consideradas é apresentada na Tabela 1. Na Tabela 1 a coluna 1 e a linha 1 indicam as imagens relacionadas, e as outras linhas e colunas a distância para cada par de imagens.

Tabela 1 – Resultado da aplicação de distância euclidiana entre pares de sub-imagens

# Sub-imagem	1	2	3	4	5	6	7
1	0,0000						
2	0,1214	0,0000					
3	0,0192	0,1046	0,0000				
4	0,5649	0,4825	0,5480	0,0000			
5	0,1412	0,1451	0,1428	0,5781	0,0000		
6	0,2342	0,1691	0,2167	0,3361	0,2865	0,0000	
7	0,2505	0,1932	0,2337	0,3215	0,3050	0,0269	0,0000

Na Tabela 1, por exemplo, é possível observar que a distância calculada para as sub-imagens '2' e '3' são menores que um limiar de valor 0.11, isso significa que essas sub-imagens pertencem a uma mesma classe. Para um limiar de 0.009 nenhuma dessas sub-imagens seriam agrupadas em uma classe. Para o limiar 0.11 as sub-imagens '3' e '1' também possuem a distância menor, ou seja, as imagens '3' e '1' irão pertencem a mesma classe, porém antes é necessário uma nova verificação: Como a imagem '3' já estava em uma classe com a imagem

'2', deve-se observar a relação entre a imagem '1' e '2', se elas tiverem uma distância menor que o limiar de 0.11, as imagens '1', '2' e '3' estariam na mesma classe, porém como as sub-imagens '1' e '2' não tem a distância menor que o limiar é realmente necessário criar uma nova classe com as sub-imagens '3' e '1'. Por final, as imagens '6' e '7' também possuem uma distância menor que o limiar 0.11 e constituem uma nova classe.

Durante o processo de geração de classes, elas são nomeadas automaticamente com um número em cada classe. Esse procedimento é importante no contexto de *Near Sets* sendo notado um comportamento de aprendizagem não-supervisionada e agrupamento (*clustering*). Ao final dessa fase, para cada classe são estipulados os valores médios e os erros amostrais com base nos descritores de cada sub-imagens que as compõem. Esses novos valores, junto a cada classe, são armazenados em arquivos e utilizados para agilizar no processo de classificação de novas sub-imagens. Nesse momento o especialista pode acessar as classes de sub-imagens gerada e nomeá-las de acordo com as imagens classificadas.

### **Fase 3 - Classificação**

Essa fase consiste em classificar uma nova manga. Novas mangas são particionadas como no processo de agrupamento e geração de classes gerando sub-imagens do tamanho 30x30 e desconsiderando sub-imagens que constituem o fundo. Cada sub-imagem é classificada de acordo com as amostras de treinamento utilizando os valores médios e erros amostrais. Os valores médios e erros amostrais de cada classe são utilizados como critério de decisão para estabelecer a relação de indiscernibilidade entre as sub-imagens. Dessa forma, se a sub-imagem que está sendo classificada não estiver dentro da média com seus respectivos erros médios para cada descritor ela não é considerada naquela classe. Sempre que uma sub-imagem é comparada com as classes existentes a informação da distância euclidiana é guardada. Com todas informações de distância obtidas a classe que rotula a nova sub-imagem é a que representa a menor distância. Um exemplo do processo de classificação de uma manga é apresentado na Figura 1, onde é possível visualizar uma parte de uma manga classificada com alguns rótulos já estabelecidos, como 721 que indica uma classe com coloração verde e que apresenta problemas na manga, 11 que indicam classes de cores vermelha e verde mescladas, entre outras.

Figura 1 - Exemplo de partes de uma manga classificadas usando classes gerados por *Tolerance Near Sets*.

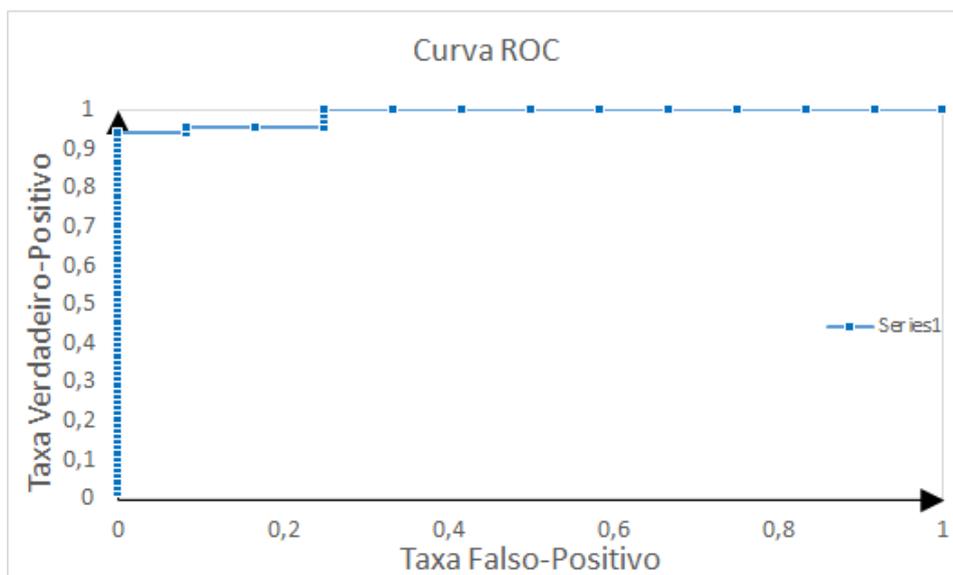
1047-C	893-C	893-C	1241-C	0-	963-C	1047-Verde/Vermelho 1251-Verde/Vermelho
1262-C	290-C	332-C	1040-C	345-C	1188-C	313-Verde/Vermelho 665-Verde C
11-C	1262-C	1058-C	1214-C	345-C	0-	1262-Verde 11-Verde/Vermelho
1037-C	0-	1259-C	936-C	345-C	1241-C	1037-Verde/Vermelho 701-Verde/Verm/Amarel
701-C	0-	1260-C	938-C	345-C	1241-C	666-Problema 647-Problema
666-C	647-C	316-C	1111-C	345-C	1241-C	590-Verde 689-Verde Escuro
647-C	721-C	260-C	1066-C	928-C	893-C	345-Vermelha 893-Vermelho C
590-C	721-C	721-C	1278-C	1039-C	1214-C	230-Verde 721-Problema
689-C	280-C	551-C	1278-C	1253-C	1038-C	

## RESULTADOS E DISCUSSÕES

Para validação da abordagem foi observada a relação do limiar de tolerância utilizado e as classes geradas. Para um limiar de 0.05 o sistema é capaz de gerar 257 classes e para um limiar de 0.1 foram geradas 1363 classes. Foi observado que o limiar de 0.05, faz com que a classificação seja mais restrita, gerando classes com um número de sub-imagens menor e que boa parte das sub-imagens não sejam classificadas. A vantagem da utilização de um limiar de tolerância menor é maior velocidade no processo de treinamento e que devido ao número de classes geradas ser menor em relação ao limiar de tolerância maior, o processo de classificação de novas imagens é mais rápido. A desvantagem de um limiar de tolerância menor é que os dados ficam muito ajustados ao conjunto de treinamento (caracterizando *'overfitting'*), e nem sempre classificando um número suficiente de sub-imagens em uma imagem de uma manga. Para ambos os limiares é notável um número alto de classes geradas. Para diminuir esse número, um processo de junção de classes semelhantes pode ser utilizado.

Outra observação em relação aos testes foi obtida por meio de dados falso-positivos e verdadeiro-positivos. Considerando o limiar de tolerância de 0.11 (por não sofrer *overfitting*), para uma classificação com 88 sub-imagens de mangas foram classificadas de alguma forma 80 sub-imagens. Das 80 sub-imagens, 68 com valores verdadeiro-positivos (classificações corretas) e 12 com valores falso-positivos (classificações de forma errada). Com o conjunto de dados corretamente (verdadeiro-positivos) e erroneamente (falso-positivos) classificados, o resultado da avaliação nesse critério é apresentado no gráfico de Característica de Operação do Receptor (do inglês *Receiver Operating Characteristic - ROC*) apresentado na Figura 2.

Figura 2 - Curva ROC para classificação com a abordagem proposta e um limiar de tolerância de 0.11.



No gráfico da Figura 2 é possível observar que a taxa de valores verdadeiro-positivo foi maior que 0,9 e a taxa de falso-positivo foi que menor que 0,25 que podem ser considerados bons resultados no processo de classificação.

Com uma observação empírica foi notado que os 12 valores falso-positivos normalmente estavam relacionados com classes de sub-imagens de cantos de mangas. Empiricamente, foi observado que o sistema é capaz de classificar corretamente imagens com cores mescladas como uma mesma imagem parcialmente verde e parcialmente vermelho.

### CONCLUSÕES E TRABALHOS FUTUROS

Este artigo explora e propõe a utilização da metodologia *Tolerance Near Sets* para o agrupamento, reconhecimento e classificação de imagens através de textura e cores. Com o propósito de validar a metodologia em condições reais, foi estabelecido um sistema com o objetivo de classificação de cores e identificação de problemas em partes de mangas. Esse sistema irá compor uma aplicação maior que têm o objetivo de avaliar mangas analisando diversas características. Durante os testes do sistema e abordagem, foi realizado uma análise dos dados por curva ROC onde a metodologia por *Tolerance Near Sets* apresentou bons resultados. Dentre as imagens classificadas corretamente, o sistema foi capaz de classificar imagens mescladas (parcialmente verde e parcialmente vermelha) e que continham algum tipo de problema na fruta da manga que são características importantes. Desta forma, os resultados apresentados foram considerados significativos, permitindo ainda melhorias com a utilização de novos descritores.

Em trabalhos futuros, pretende-se explorar a utilização de novos descritores, analisar e explorar o comportamento do limiar de tolerância, e ainda comparar a metodologia de *Tolerance Near Sets* com outras abordagens da literatura.

### AGRADECIMENTOS

Agradecemos o Laboratório de Imagens da EMBRAPA Instrumentação e ao CNPq com os projetos de nºs 310310/2013-0 e 403426/2013-8 por proporcionarem recursos para o desenvolvimento desta pesquisa.

### REFERÊNCIAS

- ARIVAZHAGAN, S.; SHEBIAH, R. N.; NIDHYANANDHAN, S. S.; SELVA, S. 2010. "Fruit Recognition using Color and Texture Features" *Journal of Emerging Trends in Computing and Information Sciences*. Vol. 1, 2010.
- BRAUN, C. J.; CHAN, E. K-F.; GARVEY, G. S.; JONES, C. M.; JUST, B. J.; KNISKERN, J. M.; MEIN, J. R.; OSBORN, T. C.; POPPEL, P. M.J.A. "Selection of mature fruit color in pepper plants". US20140380516 A1 25 de Dez de 2014. Requerimento.
- CEAGESP. "Programa Brasileiro para Modernização da horticultura". Normas de Classificação de Manga. 2005.
- HENRY, C. J. "Perceptual Indiscernibility, Rough Sets, Descriptively Near Sets, and Image Analysis". *Transactions on Rough Sets XV*. Springer Berlin Heidelberg, 2012, pp. 41-121.
- KARTIKEYAN, B.; SARKAR, A. "An identification approach for 2-D autoregressive models in describing textures" *Graphical Models and Image Processing*, vol.53, 1991.
- KOSLOWSKI, M. A.; SANTOS, F. G.; BORBA, G. B.; GAMBA, H. R.. "Fruits Classification Using MPEG-7 Descriptors from Image Patches". IX Workshop de Visão Computacional (WVC 2013). 2013.
- ROCHA, A.; HAUAGGEB, D. C.; WAINERA, J.; GOLDENSTEINA, S. "Automatic fruit and vegetable classification from images". *Elsevier Computer and Electronics in Agriculture (COMPAG)*. Vol. 70, pp. 96-104. 2010.
- SENG, W. C.; MIRISAE, S. H.; "A new method for fruits recognition system". *Electrical Engineering and Informatics*. ICEEI 2009, Vol. 01, 2009.
- SILVA, G. P. L.; LLAPA, E.; CECATTO, J. R.; SAITO, J.H.; PETERS, J. F.; RAMANNA, S.; NICOLETTI, M.C. Solar flare detection system based on tolerance near sets in a GPU-CUDA framework. *Knowledge-Based Systems*, Volume 70, pp. 345-360, 2014.
- ZAWBAA, M. H. "Automatic Fruit Image Recognition System Based on Shape and Color Features". *Advanced Machine Learning Technologies and Applications*. s.l.: Springer International Publishing, 2014, pp. 278-290.