

*Empresa Brasileira de Pesquisa Agropecuária*

*Embrapa Instrumentação*

*Ministério da Agricultura, Pecuária e Abastecimento*

# **Tecnologias Pós-Colheita em Frutas e Hortaliças**

**Editor Técnico**

*Marcos David Ferreira*

**Embrapa Instrumentação**

**São Carlos, SP**

**2011**

Exemplares desta publicação podem ser adquiridos na:

**Embrapa Instrumentação**

Rua XV de Novembro, 1452

Caixa Postal 741

CEP 13560-970 - São Carlos - SP

Fone: (16)2107-2800

Fax: (16)2107-2902

www.cnpdia.embrapa.br

E-mail: sac@cnpdia.embrapa.br

**Comitê de Publicações da Embrapa:**

**Presidente:** João de Mendonça Naime

**Membros:** Débora Marcondes Bastos Pereira Milori,

Sandra Protter Gouvea,

Washington Luiz de Barros Melo,

Valéria de Fátima Cardoso

**Membro Suplente:** Paulo Sérgio de Paula Herrmann Junior

**Supervisor editorial:** Marcos David Ferreira

**Revisor de texto:** Deusdedit Ferreira de Menezes

**Normalização bibliográfica:** Valéria de Fátima Cardoso

**Capa:** Pedro Campaner Hernandes

**Tratamento de ilustrações:** Pedro Campaner Hernandes

**Fotos da Capa:** Marcos David Ferreira

**Editoração:** Roger Luciano Lucke (arte.com)

**Impressão e acabamento:** Suprema Gráfica

1ª edição

1ª impressão (2011): tiragem 400

**Todos os direitos reservados.**

A reprodução não-autorizada desta publicação, no todo ou em parte,  
constitui violação dos direitos autorais (Lei no 9.610).

CIP-Brasil. Catalogação-na-publicação.

**Embrapa Instrumentação**

---

T255      Tecnologias pós-colheita em Frutas e Hortaliças. / Marcos David Ferreira editor. – São Carlos:  
Embrapa Instrumentação, 2011.  
286 p.

ISBN: 978-85-86463-30-3

1. Pós-Colheita. 2. Fisiologia. 3. Beneficiamento. 4. Classificação e comercialização. 5.  
Nanotecnologia. 6. Embalagens e revestimentos comestíveis. 7. Minimamente  
processado. 8. Legislação. I. Ferreira, Marcos David.

**CDD 21 ED 631.55**  
**631.56**

---

## **Capítulo 7**

---

# **Uso de Sistemas de Imagem para Classificação de Frutas e Hortaliças**

Lúcio André de Castro Jorge  
Danilo Scavacini Gonçalves  
Pedro Ivo de Castro Oyama  
Marcos David Ferreira

---





## 1. Introdução

Produtos agrícolas geralmente podem ser distinguidos pela cor, forma e textura. De forma geral, pessoas treinadas possuem percepção visual capaz de determinar a qualidade dos frutos, grãos e hortaliças. Apesar do avanço tecnológico, a classificação de frutos de forma visual e manual ainda é amplamente praticada. Por outro lado, a crescente demanda pela qualidade dos alimentos por parte dos consumidores, bem como a exigência de instituições de proteção ao consumidor quanto à qualidade de produtos alimentícios, seja ele processado ou *in natura*, tem levado ao aumento do desenvolvimento de máquinas seletoras automáticas para identificar e remover todos os contaminantes: vidro, pedras, insetos, produtos estragados, matéria vegetal, etc. Além disso, a seleção ótica permite maior padronização do produto, com remoção de itens disformes.

Dentre os vários métodos disponíveis para avaliação da qualidade dos alimentos, a visão computacional tem se destacado, especialmente para a extração e quantificação de modo não destrutivo das características que têm relevância direta para a avaliação de sua qualidade e controle.

Os sistemas computadorizados de visão servem para avaliar rapidamente atributos de qualidade dos alimentos, principalmente as características externas, tais como cor, textura, forma, tamanho, superfície, etc. Também, recursos avançados de visão computacional permitem "ver" dentro de um produto e examinar atributos relevantes na qualidade normalmente indisponíveis para avaliadores humanos. Com rápidos avanços no hardware eletrônico e nas tecnologias de imagem, o custo, eficácia e velocidade de sistemas de visão computacional têm melhorado significativamente fazendo com que muitos sistemas sejam propostos na indústria de alimentos. As operações de avaliação de qualidade de alimentos com base em sistemas automáticos permitem alta produção e altas taxas de transferência de requisitos da indústria do setor.


Novos avanços em termos de detecção de defeitos com o emprego de imagens hiperespectrais tendem a desenvolver ainda mais este processo e trazer inovações adicionais aos sistemas computadorizados no processamento de alimentos; no entanto, ainda serão exigidos intensa pesquisa e trabalho de desenvolvimento de novos algoritmos e técnicas de processamento.

O tamanho, o custo e a complexidade dos sistemas de visão para classificação variam, dependendo dos frutos, da forma de separação e da complexidade do sistema ótico. Máquinas são empregadas para classificação desde pequenas sementes de mostarda, grãos de arroz até produtos vegetais frescos e congelados (ervilha, feijão verde, couve-flor, etc) e, também frutas e hortaliças, como maçãs ou batatas. As sementes são geralmente classificadas em uma única máquina, ou mesmo em um conjunto de máquinas com esteiras com capacidade, por exemplo, de 16 toneladas/h (320mil objetos/s). Entre os produtos que podem ser classificados por máquinas de classificação automática incluem-se sementes, café, arroz, cereais de pequeno porte, nozes e leguminosas; vegetais frescos, congelados e desidratados; cerejas (com e sem talos), azeitonas, tomates; camarão; biscoitos e confeitaria. Materiais como pedras, paus e matéria orgânica devem ser removidos, bem como produtos com defeitos, tais como descoloração e casca danificada, dentre outros.

## 2. Sistema de visão computacional

Visão computacional, também conhecida como visão da máquina ou de processamento de imagem de computador, é a ciência que desenvolve as bases teóricas e algoritmos pelos quais a informação útil sobre um objeto ou cena pode ser automaticamente extraída e analisada a partir de uma imagem observada, conjunto de imagens ou vídeos. É um ramo da inteligência artificial e simula o processo da visão humana quando olha um objeto e percebe suas características espectrais com base na luz refletida do objeto quando iluminado por luz natural ou artificial. Assim, em essência, a tarefa de um computador do sistema de visão é a de simular o processo humano de percepção visual.

Essencialmente, um sistema de visão computacional é composto de uma unidade de processamento, análoga ao cérebro humano, um sensor ou câmera, análogo ao olho humano, um sistema de iluminação que facilita a captura da imagem, um sistema de digitalização da imagem e um monitor para se observar os processamentos, como pode ser observado na Figura 1.




**Figura 1:** Sistema de Visão Computacional Padrão (adaptado de PANIGRAHI; GUNASEKARAN, 2001).

Uma máquina típica de visão aplicada na classificação de grãos e frutos pode ser observada na Figura 2. Em geral é composta de:

- um sistema alimentador;
- sistema ótico;
- processos para ejetar os rejeitos;
- sistemas de processamento de imagens.

Na Figura 3 pode ser observada uma máquina típica utilizada na classificação de grãos em uma beneficiadora e na Figura 4 pode ser observado um sistema de classificação em larga escala, em uma unidade de beneficiamento de batata. Pode-se verificar em ambas que o sistema de processamento é fechado e possui iluminação dedicada.




**Figura 2:** Sistema de Classificação por Cor (BEE; HONEYWOOD, 2002).





**Figura 3:** Exemplo de uma máquina classificadora de grãos (BEE; HONEYWOOD, 2002).



**Figura 4:** Exemplo de uma máquina classificadora de frutos com detalhe da câmara de iluminação (LEEMANS; KLEYNEN, 2008).

Um sistema de visão computacional envolve uma série de etapas, que podem ser agrupadas em três grupos principais:

- *aquisição de imagem*, que lida com questões como componentes de iluminação, tipos de câmeras, formas de digitalização, etc,
- *processamento de imagem*, que engloba pré-processamento, segmentação, extração de características, etc;
- *análise da imagem*, o que implica reconhecimento de imagem e interpretação.

Todas essas áreas são importantes para o sucesso de um sistema de visão por computador.

## 2.1 Aquisição da imagem

A aquisição de imagens é um processo extremamente importante para sistemas de classificação automática. Esta requer muito cuidado para que se consiga adquirir os padrões a serem identificados. Imagens mal adquiridas, ou com resolução baixa, mesmo que disponham de excelente técnica de processamento, não são possíveis de serem analisadas, pois a informação é adquirida na aquisição e


melhorada no processamento. Caso ela não tenha sido adquirida, por alguma falha na iluminação, na resolução ou por ruídos, não é possível ser criada no processamento. Os tipos de câmeras e de iluminação definem o sistema de visão computacional. A seguir descrição dos itens componentes para o processo de aquisição de imagem.

## Imagem digital

Uma imagem, segundo Gonzalez e Woods (2010), pode ser definida como uma função bidimensional,  $f(x, y)$ , onde  $x$  e  $y$  são as coordenadas no plano,  $f$  é a amplitude em um determinado ponto de  $x$  e  $y$ , que é chamado de intensidade ou nível de cinza, ou cor. O ponto é denominado de *pixel* ou *picture element*.

As imagens são geradas por processos físicos e as intensidades ou cores representam valores proporcionais aos da radiação de energia eletromagnética capturados pelo sensor utilizado. Esses valores do espectro eletromagnético são utilizados para análise dos produtos. A luz refletida pelo produto em análise é capturada pelas câmeras que armazenam os comprimentos de onda constituintes do sinal. Em geral, as imagens são digitalizadas usando-se um detector adequado e enviadas para o computador para processamento. Os sensores podem ser diferenciados dependendo da faixa do espectro eletromagnético para o qual foi projetado.

Na Figura 5, podem ser observados todo o espectro eletromagnético e as respectivas faixas de comprimento de o



**Figura 5:** Espectro eletromagnético (MOREIRA, 2001).

Os sensores são classificados no espectro visível, quando são sensíveis aos comprimentos de onda de 400nm até 750nm. Nesta categoria, destacam-se as câmeras fotográficas convencionais, que registram a refletância no espectro visível. No entanto, nem toda alteração de cor caracteriza um produto com defeito, pois as variações de cor são muito típicas em produtos alimentícios, como frutas ou hortaliças. Muitas vezes, os defeitos são identificados em outras faixas do espectro. Certos defeitos não visíveis (bactérias, por exemplo) podem ser observados apenas quando houver uma excitação especial, medindo-se assim a fluorescência do material e não a sua refletância.

## Refletância espectral

A radiação solar, ao incidir sobre uma superfície, interage com ela, resultando em três frações: parte absorvida, parte transmitida e parte refletida. A parte refletida é, então, a radiação que chega até o sistema sensor. Na realidade, todos objetos e produtos refletem a radiação eletromagnética.

O termo refletância refere-se à quantidade adimensional da energia que é refletida pelos alvos. Em outras palavras, é um termo utilizado para referir a razão da radiação eletromagnética refletida pela incidente.



Seu valor varia de zero a um e pode ser expresso em porcentagem, uma vez que é adimensional.

O comportamento espectral de plantas varia de acordo com o estágio vegetativo. Em áreas agrícolas, como soja, trigo, cevada, etc, essa variação dá-se do plantio até a fase de completo desenvolvimento vegetativo, quando o solo é quase totalmente coberto pela cultura. No caso de frutos ou produtos agrícolas, também varia o comportamento espectral em função da maturação, características do fruto, bem como outras características químicas e físicas.

Para que se entenda o processo de classificação de frutos, é necessário que se entenda o significado do comportamento espectral de diferentes alvos nas faixas do visível, infravermelho próximo e médio, e que se entenda a interação da radiação solar com a vegetação e frutos nessas regiões do espectro eletromagnético.

Uma das principais formas de análise e classificação de produtos agrícolas mede as trocas energéticas entre o alvo e o meio ambiente. Essas medidas são feitas por sensores, que são dispositivos capazes de detectar e registrar o fluxo de energia radiante, em determinadas faixas do espectro eletromagnético, que é refletido ou emitido por objetos numa forma passível de ser interpretada pelo homem (STEFFEN, 1995). Toda a teoria fundamenta-se na pressuposição de que os alvos, naturais ou artificiais, refletem ou emitem a radiação eletromagnética (REM) de modo peculiar, o que permite sua identificação. Esse fato peculiar de refletir ou emitir a REM é denominado de assinatura espectral ou comportamento espectral (STEFFEN, 1995).

Toda metodologia de análise de grãos e frutos fundamenta-se na porção refletida ou emitida da energia eletromagnética, expressas em termos de refletância e emitância.

As variações de cores em frutos são principalmente devidas a três famílias de pigmentos, clorofilas, carotenoides e antocianinas, responsáveis pelo verde, vermelho-amarelo e vermelho para azul-violeta, respectivamente. O conhecimento detalhado da composição de pigmentos de frutos permite a avaliação dos efeitos da pós-colheita, identificando tratamentos para manutenção da cor, qualidade e aumento da vida útil de frutos e vegetais e produtos derivados.


Na região visível do espectro eletromagnético (400 a 700 nm ou 0,4 a 0,7 $\mu$ m), a radiação solar é também conhecida por radiação fotossinteticamente ativa. Ao incidir sobre a vegetação, é absorvida pelos pigmentos fotossintetizantes no mesófilo foliar. Os pigmentos que ocorrem em maior parte são as clorofilas **a** e **b** e, em menor parte, os carotenoides, as xantofilas e as antocianinas. Desse modo, a reflectância apresenta um pico em torno de 0,53  $\mu$ m na região do verde, e picos de absorção nas regiões do vermelho e do azul. O vermelho é um intervalo do espectro eletromagnético no qual existe uma relação inversamente proporcional entre a intensidade da radiação eletromagnética (REM) refletida e a quantidade de clorofila presente no vegetal. Isso é um fator muito importante para a distinção de estresses e avaliação de hortaliças (MOREIRA, 2001).

Em contraste, na região do infravermelho próximo do espectro eletromagnético (700 a 1300 nm ou 0,7 a 1,3 $\mu$ m), verifica-se que a energia é fortemente refletida e transmitida pelas folhas, devido às descontinuidades do índice de refração na estrutura do mesófilo foliar. Nessa região do espectro, a reflectância depende da estrutura interna da folha e resulta do forte contraste entre os índices de refração do conteúdo celular (rico em água) e do espaço intercelular (rico em ar), que provoca reflexões e refrações da REM no interior da folha. Dessa forma, quanto mais denso e vigoroso o vegetal, maior a superfície de interface células/ar, o que acarreta um aumento das reflexões e refrações da REM e, conseqüentemente, maior reflectância nesta porção do espectro eletromagnético (MOREIRA, 2001).

No infravermelho médio (1300 a 2500 nm ou 1,3 a 2,5 $\mu$ m), as propriedades ópticas da folha e de frutos são muito afetadas pelo seu conteúdo de água, ou seja, a água presente no interior promove alta absorção nesse comprimento de onda (MOREIRA, 2001). Todos esses efeitos da reflectância espectral



nesses comprimentos de onda mencionados acima podem ser observados na Figura 6.




**Figura 6:** Curva de reflectância de uma planta e fruto (MOREIRA, 2001).

São diversos os fatores que podem influenciar o comportamento espectral. Em geral, mudanças nesse comportamento são mais influenciadas por um fator dominante. Entretanto, numa análise mais criteriosa, pode-se perceber que, além do fator dominante, há outros fatores interferindo.

As propriedades ópticas das folhas e frutos também mudam de acordo com a sua fase de desenvolvimento, ou seja, de acordo com a idade e maturação. Assim sendo, na maturação, ocorre um decréscimo da reflectância na região do visível e um aumento na região do infravermelho próximo, devido à existência de um maior número de espaços aéreos intercelulares no mesófilo das folhas maduras. No início da senescência, e em razão da degradação das clorofilas, ocorre uma menor absorção da radiação solar e, conseqüentemente, aumento da reflectância na região do visível; posteriormente, com o avanço gradativo da senescência, observa-se a degradação dos carotenos e morte das células. Nessa fase, ocorre um aumento dos espaços aéreos intercelulares das folhas e, conseqüentemente, aumento da reflectância no infravermelho próximo. Durante o crescimento das plantas, a reflectância no visível e no infravermelho médio decresce e a reflectância no infravermelho próximo aumenta. Durante a senescência, o contrário desse fenômeno é observado (MOREIRA, 2001).

O espectro infravermelho é sensível aos constituintes químicos, proteínas, umidade, óleo de produtos alimentícios, podendo ser vista a distribuição de constituintes do alimento.

Aspectos, como espécies, variedades, incidência de pragas e doenças, afetam a energia refletida. A escolha adequada de sensores pode registrar essas alterações. Um exemplo típico de diferentes respostas espectrais pode ser observado na Figura 7: em (a), o fruto pode ser visualizado na região do visível, em (b) na região do infravermelho, em (c) com fluorescência e em (d) com ultravioleta. Percebe-se que todas as imagens evidenciam diferentes padrões, o que pode auxiliar na identificação da classificação de injúrias.





**Figura 7:** Citrus (a) visível, (b) infravermelho, (c) fluorescência e (d) ultravioleta (BLASCO et al., 2007).

## Iluminação

Na espectrofotometria convencional, é realizada a medição espectral das superfícies sob condições controladas de iluminação. No entanto, na prática industrial, muitas vezes, adequar as máquinas de classificação a condições ideais de iluminação não é uma tarefa simples. Iluminação difusa esférica é a mais adequada para iluminar uniformemente o item em análise.

Não obstante os progressos na análise e no processamento de imagens, o tipo de câmera e sistema de iluminação pode afetar a qualidade dos resultados da aplicação de sistemas de visão computacional. Com iluminação adequada, a discriminação de características será mais bem efetuada reduzindo o tempo de processamento e os requisitos especiais de hardware.

Portanto, é quase sempre mais barato melhorar a iluminação do que melhorar os algoritmos de processamento de imagem. Produtos alimentícios são heterogêneos, orientados aleatoriamente, e podem apresentar muitas variações de reflexão. Por isso, é necessário analisar individualmente os frutos na câmara de luz controlada evitando-se que os frutos se toquem, se sobreponham, que não haja oclusão e sombras durante a aquisição da imagem.

Seleção de fontes de luz e configurações adequadas para as fontes de luz são requisitos básicos num sistema de visão computacional. A geometria do sistema de imagem deve ser bem conhecida, especialmente, para as medições de dimensão dos frutos.

A opção de iluminação frontal é mais adequada para a obtenção de características da superfície de um produto, enquanto a iluminação traseira é melhor para identificar danos.

A luz utilizada para iluminar os produtos a serem classificados é fundamental para uma correta avaliação. Muitos tipos de iluminação, com diferentes intensidades, podem ser encontrados. Fontes de luz e níveis adequados são essenciais para as condições de obtenção de resultados confiáveis da avaliação. Uma iluminação uniforme, livre de sombras é fundamental para o tipo de análise realizada nas classificadoras, inclusive permitindo perceber superfícies texturizadas. Para a avaliação de cor, a reflexão especular da fonte deve ser minimizada. Isso pode ser garantido com uma fonte de luz posicionada verticalmente, distribuída de forma difusa. Sistemas de regulação do fluxo luminoso devem permitir operar entre 750 e 1200 lux, faixa típica para produtos alimentícios. Uma intensidade de 807 a 1614 lux é recomendada para a avaliação de produtos frescos. A correção da cor segundo alguns padrões de iluminação garante a temperatura de cor<sup>1</sup> adequada para cada caso, sendo a temperatura de cor 6500K recomendada pela norma British Standard (BS950) para substituir a luz do dia para tarefas visuais de avaliação e de correspondência de cores. No entanto, a luz artificial *Daylight*, que inclui um componente ultravioleta, e a *Northlight*, que não contém tal componente, são atualmente consideradas os padrões mais próximos adequados para as máquinas classificadoras. Esses padrões são amplamente utilizados em indústrias onde a avaliação da cor é fundamental. A qualidade espectral da luz deve aproximar à luz do dia sob um céu moderadamente nublado, à temperatura de cor de 6770 K, equivalente ao iluminante C, ou 6500 K, equivalente a D65; a luz solar direta deve ser evitada (MACDOUGALL, 2002).

## Fluorescência

Muitos produtos, quando irradiados com luz ultravioleta (350 nm), ou mesmo outros comprimentos de onda, possuem a propriedade de emitir uma luz denominada de fluorescência, que pode ser usada na classificação (Figura 7c). Essa técnica foi originalmente utilizada para a remoção de grãos de café verde, variedade arábica, que apresentavam defeito tipo “ardido”, bem como na classificação de amendoins e

<sup>1</sup> Temperatura de cor. Expressa a aparência de cor da luz emitida pela fonte de luz, utilizando Kelvin (K) como unidade de medida. Quanto mais alta a temperatura de cor, mais clara é a tonalidade de cor da luz. Por exemplo, luz quente ou fria não está relacionada ao calor físico da lâmpada, mas sim, à tonalidade de cor que ela apresenta ao ambiente.



amêndoas. No entanto, os efeitos de fluorescência ocorrem em tempos muito curtos e dependem das circunstâncias e do tempo decorrido desde a colheita do produto.

A fluorescência da clorofila em hortaliças se tornou um parâmetro importante de análise em virtude de que qualquer variação na planta decorrente de doenças, pragas ou qualquer adversidade provoca alterações em seu teor. As moléculas de clorofila absorvem a energia luminosa (fótons) e alteram temporariamente as suas configurações eletrônicas. Esses pigmentos passam do estado fundamental singlete para um estado excitado singlete com tempo de vida característico da ordem de  $10^{-8}$ s. Após esse período, esta energia pode ser dissipada através de três processos:

- Dissipação fotoquímica: onde a energia luminosa é utilizada para os processos fotoquímicos da fotossíntese;
- Fluorescência: onde ocorre a emissão de radiação na região do visível;
- Dissipação não fotoquímica: onde ocorre a produção de calor na forma de radiação infravermelha.


A fluorescência da clorofila se tornou um parâmetro importante de análise em virtude de que qualquer variação na planta decorrente de doenças, pragas ou qualquer adversidade provoca alterações em seu teor.

Além das clorofilas, as plantas superiores possuem uma série de compostos orgânicos que apresentam a propriedade de fluorescer quando excitados com luz ultravioleta ou visível, por exemplo, carotenoides e xantofilas. Dessa forma, a emissão de fluorescência das hortaliças é um espectro rico em informações de vários compostos químicos.

Por ser uma técnica altamente sensível e rápida, ela é uma ferramenta interessante no estudo de processos químicos, físicos e orgânicos que ocorram nas plantas e frutos.

### Imagem hiperespectral

Imagem hiperespectral combina as técnicas de imagens com a espectroscopia para simultaneamente adquirir ambas, informação espectral e espacial de um objeto. Assim, um sistema típico pode ser visualizado na Figura 8. Cada pixel numa imagem representa em vez de uma imagem de cor RGB - sistema de cores aditivas RGB sendo as siglas referentes às abreviaturas de *Red* (vermelho), *Green* (verde) e *Blue* (azul) - um espectro de bandas espectrais.



**Figura 8:** Formação de uma imagem hiperespectral (GOWEN et al., 2007).

A imagem hiperespectral é o grande avanço do momento em termos de sensor; permite varrer o espectro eletromagnético desde o visível até o infravermelho, com até 300 bandas de 3nm de resolução espectral.



## 2.2 Processamento da imagem


O avanço no processamento de imagens, com novos algoritmos sendo disponibilizados a cada dia, tem viabilizado diversas aplicações.

As etapas básicas do processamento podem ser resumidas em: pré-processamento, segmentação e extração de características. O pré-processamento é responsável por realçar as qualidades da imagem adquirida, eliminação de ruídos e distorções. As correções podem ser efetivadas nas tonalidades ou cores da imagem e são em geral dependentes do contexto. A segmentação de imagens refere-se à divisão da imagem em partes constituintes, que podem ser regiões com características similares, por exemplo, mesma cor, ou delimitadas por alguma borda. Trata-se de uma parte fundamental nos sistemas de visão computacional e é totalmente dependente da condição de iluminação que foi utilizada na aquisição. Em geral, numa aplicação, a segmentação manual é mais fácil de ser implementada, enquanto que a automática depende fortemente da qualidade da aquisição da imagem. Uma imagem segmentada apresenta separação de regiões nitidamente identificadas, por exemplo, regiões com alteração do fruto, com colorações atípicas etc. A extração de atributos é realizada em cada região ou objeto segmentado na imagem. Por exemplo, as medidas de comprimento e largura do frutos identificados ou segmentados na imagem. Essa extração de atributos é utilizada para classificar os produtos nos sistemas de visão computacional.

Uma das características mais usadas nos sistemas de classificação é a segmentação por cores, sendo necessário conhecer as formas de representar e trata-las. Sendo assim, neste capítulo serão apresentados os dois modelos de cor mais utilizados em classificação de alimentos.


### Modelos de cor

O modelo RGB é um sistema de cores aditivas. Esse é provavelmente o modelo de cores mais conhecido, sendo muito usado para captura e impressão de imagem em meio digital, como monitores, escâneres, TVs, câmeras digitais, etc. O modelo RGB parte do princípio de que preto é ausência de cor, e branco é a presença de todas as cores. Para representar as diversas cores, adiciona-se uma quantidade de vermelho, verde e azul ao preto, e sempre que os valores forem iguais, o resultado será uma cor em escala de cinza. De acordo com Gonzalez e Woods (2010), todas as cores desse modelo são representadas por um cubo, onde as oito extremidades são a representação das cores vermelha, amarela, verde, ciano, azul, magenta, branca e preta. A diagonal que parte da origem (branco) até a extremidade mais distante do cubo (preto) forma uma escala de cinza, como mostra a Figura 9.



**Figura 9:** Cubo RGB (GONZALEZ; WOODS, 2010).

O modelo mais utilizado por técnicos que trabalham com cores de frutos e hortaliças é o CIELab. Também conhecido por CIE  $L^* a^* b^*$ , as cores podem ser representadas pelo gráfico tridimensional da Figura 10. A cor da amostra é determinada pela sua posição espacial no gráfico expresso em LAB. Esse sistema separa a cor por três variáveis: L, que representa a iluminação (brilho) da imagem;  $a^*$ , que é a variação de verde até vermelho; e  $b^*$ , que representa a variação de amarelo para azul. O valor de L varia de 0 que é o preto até 100, que é o branco, enquanto  $a^*$  e  $b^*$  variam de -120 até 120. Como o valor de uma cor varia aumentando a sua tonalidade do centro para as bordas, é possível notar que a saturação será maior ao longo de seu contorno. Logo, nota-se que o modelo CIELab consegue definir claramente todas as cores.



**Figura 10:** CIELab representação tridimensional (GONZALEZ; WOODS, 2010).

O modelo RGB é o padrão de aquisição das imagens. Outros modelos deverão ser obtidos por conversão. Para converter de RGB para CIELab, é necessário passar pela transformação para CIE XYZ. Sendo assim, inicialmente é realizada a seguinte conversão:

$$X = 0.412453.R + 0.357580.G + 0.180423.B$$

$$Y = 0.212671.R + 0.715160.G + 0.072169.B$$

$$Z = 0.019334.R + 0.119193.G + 0.950227.B$$

E então utilizando-se esses valores, é possível converter para CIELab.

$$L = 116.f \left( \frac{Y}{Y_n} \right) - 16$$

$$a = 500, \left| f\left(\frac{X}{X_n}\right) - f\left(\frac{Y}{Y_n}\right) \right| \qquad b = 200, \left| f\left(\frac{Y}{Y_n}\right) - f\left(\frac{X}{X_n}\right) \right|$$

O cálculo do componente  $f(q)$  tem dependência direta com o valor de  $q$ . Para  $q$  maior que 0.008856,  $f(q) = q^{1.8}$ . Para os demais valores de  $q$ , a fórmula será expressa da seguinte forma:  $f(q) = 7.787 \cdot q + 0.137931$ .

Todas essas conversões devem ser calculadas dependendo do iluminante considerado. Neste caso, é o D65.

### Extrator de características

Para que uma máquina possa entender o que é um objeto contido em uma imagem, é necessário



extrair características do objeto contido na imagem para servir de padrão. As principais características que são extraídas da imagem são: cor, forma e textura. Para a descrição da cor, são utilizados vários padrões, como os já citados neste trabalho: RGB e CIELab.

Para extrair características de forma, são utilizadas técnicas como: descritores de forma e momentos da imagem. As técnicas de momentos de Hu, Assinatura e Descritores de Fourier são as mais utilizadas para caracterizar a forma de objetos. A seguir, descrição dessas técnicas.

### **Momentos**

Momentos é uma técnica para descrição de forma em imagens 2D baseada nos momentos estatísticos. Para sua aplicação, é necessário inicialmente realizar a binarização da imagem, separando a imagem do seu fundo. Para binarizar a imagem, pode ser utilizada qualquer técnica que faça a segmentação dos objetos a serem medidos.

Para descrição da imagem, os momentos mais utilizados são os momentos regulares, que são descritos pela seguinte fórmula:

$$M_{pq} = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} x^p y^q f(x,y) dx dy$$

$M_{00}$  representa a área do objeto na imagem. Para imagem digital, utiliza-se a seguinte fórmula:

$$m_{pq} = \sum_{i=0}^{n_x} \sum_{j=0}^{n_y} i^p j^q f(i,j)$$

Esse momento é o mais usado, todavia é dependente de escala, posição e orientação. Para evitar que o resultado dependa desses fatores, existem modificações que são realizadas antes de chegar ao momento final, por exemplo, o uso dos momentos centrais, que torna o resultado invariante quanto à posição. Esse cálculo é feito usando a seguinte fórmula:

$$\mu_{pq} = \sum_{i=0}^{n_x} \sum_{j=0}^{n_y} (i - x_c)^p (j - y_c)^q f(i,j)$$

Onde  $x_c$  e  $y_c$  representam o pixel central do objeto na figura, e são calculados com as seguintes fórmulas:

$$x_c = \frac{m_{10}}{m_{00}} \quad y_c = \frac{m_{01}}{m_{00}}$$

Tornando invariante a escala, tem-se:

$$\eta_{pq} = \frac{\mu_{pq}}{(\mu_{00})^y}$$

A teoria da invariância algébrica e as combinações relativas e absolutas de momentos que são invariantes à posição (translação), à orientação (rotação) e ao tamanho (escala), foram alterados por HU (1962), chegando a sete momentos que são invariantes aos fatores citados, ou seja, têm os mesmos resultados

para a imagem original e para as imagens que sofreram rotação, translação e alteração na escala. Esses momentos são conhecidos com momentos de Hu:

$$\varphi_1 = \eta_{20} + \eta_{02}$$

$$\varphi_2 = (\eta_{20} - \eta_{02})^2 + 4\eta_{11}^2$$

$$\varphi_3 = (\eta_{30} - 3\eta_{12})^2 + (3\eta_{21} - \eta_{03})^2$$

$$\varphi_4 = (\eta_{30} - \eta_{12})^2 + (\eta_{21} + \eta_{03})^2$$

$$\varphi_5 = (\eta_{30} - 3\eta_{12})(\eta_{30} + \eta_{12})[(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{12})^2] \\ + (3\eta_{31} - \eta_{12})(\eta_{21} + \eta_{03})[3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2]$$

$$\varphi_6 = (\eta_{20} - \eta_{02})[(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2] + 4\eta_{11}(\eta_{30} + \eta_{12})(\eta_{21} + \eta_{03})$$

$$\varphi_7 = (3\eta_{21} - \eta_{03})(\eta_{30} + \eta_{12})[(\eta_{30} - \eta_{12})^2 - 3(\eta_{21} - \eta_{03})^2] \\ + (\eta_{30} - 3\eta_{12})(\eta_{21} + \eta_{03})[3(\eta_{30} - \eta_{12})^2 - (\eta_{21} + \eta_{03})^2]$$

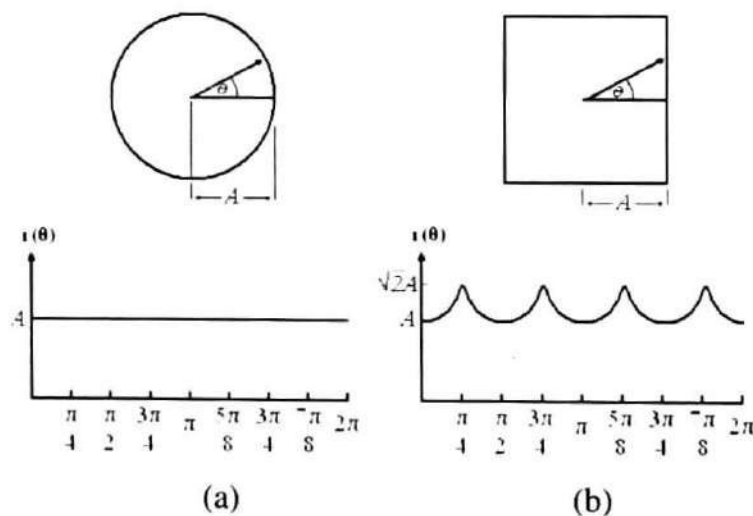
Esses sete valores são utilizados para caracterizar os objetos medidos.

### Assinatura

Gonzalez e Woods (2010) descrevem assinatura como sendo uma descrição 1D da borda de uma imagem 2D. Essa representação pode ser feita criando-se um gráfico que representa a distância entre o centroide de uma figura e os pontos da borda de forma sequencial.

Todavia utilizando-se essa técnica, o resultado será invariável quanto à posição, mas pode variar de acordo com a orientação e a escala. Para resolver o problema de orientação, pode-se escolher um ponto inicial a partir de uma referência, como o ponto mais próximo do centroide, ou o ponto mais longe dele. Essa técnica exige um processamento computacional mais intenso, mas retorna um resultado mais adequado.

Na Figura 11, são apresentadas as assinaturas para um círculo e um quadrado.



**Figura 11:** Assinatura (GONZALEZ; WOODS, 2010).



## Descritores de Fourier

Um dos mais populares métodos para representação de forma de imagens é o dos Descritores de Fourier (FD), utilizado para aplicações de visão computacional e reconhecimento de padrões (GONZALEZ; WOODS, 2010). Sua principal vantagem é a invariância em relação à translação, rotação e escala do objeto observado. Em outras palavras, esses valores são independentes da distância entre a câmera e o objeto, do tamanho do objeto, a posição onde o objeto está localizado na imagem e a rotação em torno do eixo óptico.

A ideia básica desta abordagem consiste na representação da forma, em termos de um sinal 1D ou 2D, calculando os FDs utilizados na transformada de Fourier. Os descritores FDs devem ser obtidos por:

- Um sinal unidimensional a partir da imagem, como:  $f(t) = x(t) + jy(t)$  com  $x(t)$  e  $y(t)$  sendo os valores das coordenadas ( $x, y$ ) no ponto  $t$  e  $j$  o número de colunas;
- Um vetor contendo apenas os pontos que delimitam a borda da imagem de forma ordenada;
- E, por último, aplica-se:

$$F(u) = \frac{1}{N} \sum_{t=0}^{N-1} f(t) e^{\frac{-2i\pi ux}{N}}$$

Onde  $N$  representa o número de pontos utilizados para representar o decorrer da borda da imagem,  $f(t)$  é a função unidimensional utilizada para representar a imagem.  $F(u)$  irá representar os FDs onde  $u$  pode variar de 1 até  $N$ .

## Descritores de textura

Textura é uma das principais características utilizadas na classificação e reconhecimento de padrões contidos em imagens nos sistemas de classificação. Ela é caracterizada pelo padrão de variação dos tons de cinza dos pixels ao longo da imagem, que se repetem de maneira regular ou aleatória. Assim, é possível segmentar uma imagem com um padrão, e com isso identificar outros tipos de objetos em uma imagem.

As texturas definem uniformidade, densidade, aspereza, regularidade, intensidade, além de outras características da imagem.

## 2.3 Análise da imagem

Existem várias técnicas na literatura para detecção automática de hortaliças e frutas, lesões presentes, áreas superficiais e volume, baseadas na análise de cor e forma. A seguir, a descrição de algumas dessas técnicas.

Pazoti et al. (2005) descrevem técnicas de análise de curvatura por processamento de imagens para identificar esporos do fungo *Guignardia citricarpa*, ou pinta preta, em produção de citros comercialmente. A avaliação 3D de forma e tamanho de citros é descritos por Ding et al. (2000). Em Lana et al. (2006), foram medidas alterações de cor devido à maturação de tomates. Assim, também, em outros produtos a cor recebe especial atenção (MENDOZA et al., 2006). Vários frutos têm sido avaliados com diferentes algoritmos de análise de imagens e apresentam resultados bastante animadores na utilização desta técnica para a determinação de danos causados por diferentes agentes (RIQUELME et al., 2008).

A análise morfológica de fungos aparece também em vários trabalhos (DIEGUEZ-URIBEONDO et al., 2004) mostrando a grande utilidade de técnicas de processamento de imagens na identificação de alterações em frutos. Alguns trabalhos aparecem também usando imagens multiespectrais ou hiperespectrais, como no caso de estudo de defeitos comuns em citros (BLASCO et al., 2007; GÓMEZ-SANCHIS et al., 2008), em morangos (ELMASRY et al., 2007) e em maçãs (ARIANA, 2006). Um sistema usando infravermelho próximo para seleção de tâmaras numa esteira industrial é descrita por Lee et al. (2008).



Em estudos com batata, o processamento de imagens começa desde a colheita no campo, como mostra Nieuwenhuizen et al. (2007), no qual se usam sistemas inteligentes para separação de plantas invasoras da batata.

Inspeção automática para seleção de classes de batata por máquinas de visão computacional utilizando-se tamanho, forma e cor têm sido reportada (PUN, 1991; HEINEMANN et al., 1996; PATHARE et al., 1993; TAO et al., 1990; TAO et al., 1995). Em batata-doce, Mummert (2004) desenvolveu um sistema de visão para a classificação por forma e tamanho. Lefebvre et al. (1994) desenvolveram um sistema de visão completo para classificação de batatas.

Um sistema de visão de alta velocidade para a inspeção de batatas foi desenvolvido por Noordam et al. (2000). O sistema classifica batatas por tamanho, forma e defeitos externos, tais como danos mecânicos, esverdeamento, dentre outros. Para isso, usa um uma câmera colorida de 3-CCD. Em vez de usar mais câmeras para visualizar o tubérculo em todos os ângulos, usa espelhos para obter uma vista de 360 graus da batata. Esse equipamento possui capacidade de 12 ton/h, usando um sistema de processamento de imagens capaz de processar 50 batatas/s. Para segmentação das imagens, esse sistema utiliza a Análise do Discriminante Linear em combinação com um classificador pela distância de Mahalanobis (GONZALEZ; WOODS, 2010). A classificação de forma usa os descritores de Fourier. Atributos como a área, excentricidade e momentos centrais são usados para discriminar os defeitos por cor similares.

A segmentação por cor, através de uma rede neural multicamadas e classificadores clássicos para inspeção de cor, foram comparados por Deck et al. (1995) e por Zhou et al. (1998). Os sistemas são capazes de classificar por tamanho, peso, diâmetro transversal, forma e cor. A discriminação por cor separa batatas boas e verdes apenas. Até mesmo batata frita tem sido estudada com imagens, como mostra Noordam et al. (2004).

### 3. Exemplos de sistemas de classificação de frutos e hortaliças

A Embrapa Instrumentação tem desenvolvido sistemas de classificação para uso em unidades de beneficiamento ou mesmo para pesquisa.


Destacam-se a máquina de classificar café QUALICAFÉ e a máquina de classificar batatas MACARENA - Máquina de Classificação e Análise por Redes Neurais Artificiais -apresentadas a seguir.

#### 3.1 Máquina para classificação automática de grãos de café - QUALICAFÉ

Está sendo desenvolvida uma máquina para a classificação automática de grãos de café, denominada QUALICAFÉ, que utiliza um sistema de visão computacional para amostras de grãos de café para laboratório, com base nos atributos de cor e forma.

##### *Exemplos de padrões de grãos a serem classificados*

Na Figura 12 são apresentados os padrões mais comuns presentes nas amostras de grãos de café a serem classificados em laboratório. Destacam-se os grãos ardidos, brocados, presença de paus, pedras, grãos quebrados, cascas, películas etc, conforme Figura 12(a) a (s).




**Figura 12:** Classes de grãos e impurezas. (a) ardido, (b) brocado, (c) cabeça, (d) coco, (e) concha, (f) fava escura, (g) marago, (h) melado, (i) película, (j) perfeito, (k) pergaminho, (l) preto, (m) preto-verde, (n) quebrado, (o) secador, (p) verde, (q) paus, (r) pedras e (s) cascas.

Estes padrões estão sendo desenvolvidos em parceria com a Cooperativa Regional de Cafeicultores de Guaxupé Ltda. - COOXUPÉ - com a experiência de especialistas da cooperativa.

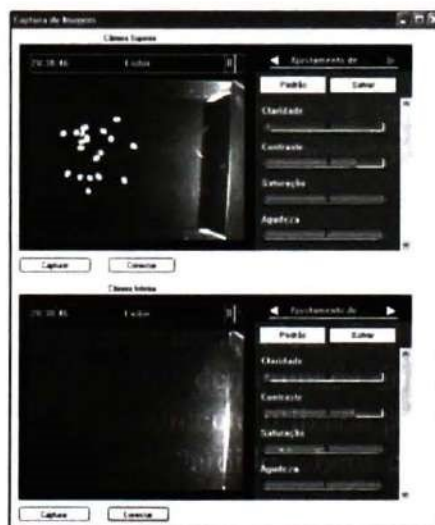
### Aquisição de imagens

Para a aquisição de imagens das amostras de grãos de café com iluminação padrão, foi desenvolvida uma máquina de classificação (Figura 13), composta de uma bandeja de vidro – onde são depositados os grãos sob condições controladas de luz. A bandeja é iluminada por duas lâmpadas fluorescentes de 20W por cima e duas por baixo, duas câmeras de vídeo posicionadas cerca de 60cm da amostra. A câmera de vídeo utilizada é do tipo IP e é conectada ao computador, que executa o software através de uma interface Gigabit Ethernet. As imagens são capturadas diretamente pelo software e são salvas no formato JPG com resolução de 1280x1024 pixels.



**Figura 13:** (a) Diagrama da máquina de classificar café e (b) Foto da primeira versão construída.

Na Figura 14, pode ser observada a tela de captura da imagem, onde são possíveis ajustes de brilho, contraste e iluminação da amostra.



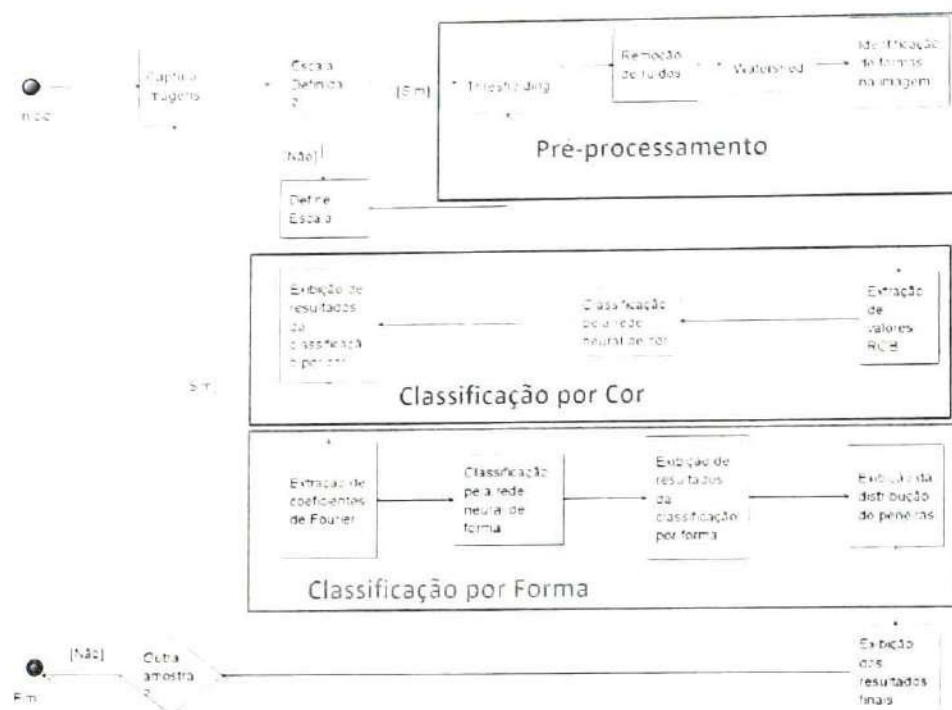
**Figura 14:** Interface de controle de aquisição.



## Processamento das imagens

O Qualicafé foi dividido em módulos: pré-processamento, classificação por cor, por forma e por tipo de grão, conforme descrito no diagrama da Figura 15.

Todos os processos de classificação se baseiam numa rede neural do tipo *Multilayer Perceptron* (MLP), sendo utilizados algoritmos de aprendizado de máquina implementados em Java.



**Figura 15:** Diagrama de blocos do Software de análise do Qualicafé.

## Pré-processamento

A primeira etapa de processamento é a identificação de grãos e impurezas presentes na amostra. Esta identificação é feita através do contorno de cada objeto encontrado na imagem. Para a identificação dos contornos, primeiramente é feita a segmentação da imagem pela aplicação de um simples *Thresholding*, algoritmo que classifica cada pixel da imagem como fundo ou objeto, através da comparação do valor do pixel em escala de cinza com um valor adotado como limiar - o *threshold*. Com a separação do fundo dos objetos, a imagem é então binarizada. Utilizam-se os processos morfológicos de erosão e dilatação, a fim de se eliminar possíveis ruídos. Visando separar grãos que estejam encostados um no outro, podendo gerar problemas na contagem de grãos, é executado o algoritmo de *watershed*. Para cada pixel 'objeto' da imagem, é calculada a sua distância ao pixel 'fundo' mais próximo. Então, são definidos os pontos com as distâncias máximas locais e cada um desses pontos é dilatado até que se chegue à borda do objeto ou à borda da região de outro ponto que está sendo dilatado. Dessa forma, cada uma das regiões provenientes de um ponto dilatado define um objeto diferente. A partir da imagem binarizada, é finalmente executado um algoritmo para identificar as diferentes formas e se extrair os pixels de seus contornos.

Na Figura 16, pode ser visualizada uma imagem de saída do processo de identificação de grãos. Nesta imagem, os contornos dos grãos são pintados de verde e numerados sequencialmente. A rotulação é armazenada juntamente com os pixels localizados nos seu interior.

Para se trabalhar com as dimensões reais dos objetos durante a análise por forma, foi desenvolvida uma ferramenta para a indicação da escala da imagem, através da qual se desenha uma linha sobre a imagem e informa-se a distância real que ela representa.





**Figura 16:** Objetos identificados e rotulados.

### Classificação por cor

A análise de cor dos grãos de café é feita para se distinguir grãos bons de grãos com certos tipos de defeito, como: grãos verdes, pretos, pretos-verdes, ardidos, etc. Essa análise se baseia no reconhecimento de padrões de cor presentes nos grãos, visto que certos defeitos são identificados por uma cor característica do grão, ou de uma parte dele, como, o tom mais esverdeado, que é comum nos grãos-verdes e manchas marrons nos grãos melados. Da mesma forma, as sementes perfeitas também têm uma coloração característica que as definem.

Sendo assim, cada um dos defeitos passíveis de serem identificados pela análise de cor foi associado a uma classe, que, juntamente com a classe de grão perfeito formam o conjunto de padrões a serem reconhecidos pela rede neural. As classes são: ardido, brocado, casca, coco, fava escura, melado, pau, pedra, película, perfeito, pergaminho, preto, preto-verde, secador e verde. A MLP foi definida com três atributos de entrada: as componentes de cor R, G e B.

Para cada uma das classes, foram capturadas imagens de amostras contendo grãos da classe em questão para a execução do treinamento da rede. Foram utilizadas janelas selecionadas manualmente sobre a imagem, cujas áreas apresentavam a coloração característica do defeito do grão (Figura 17), ou um padrão de saudável. Para cada um dos pixels que compõem essas áreas, foi determinado o valor médio de R, G e B, com base nos pixels vizinhos. Esses valores foram então utilizados como entrada para a MLP no seu treinamento. Para cada classe foram coletados cerca de 8.000 pixels.



**Figura 17:** Seleção de amostra em um grão para treinamento da MLP.

A classificação dos grãos de uma amostra é feita passando-se, como entrada para a MLP treinada, os valores médios de R, G e B de cada um dos *pixels* do grão com seus vizinhos. Conforme os *pixels* são

classificados, eles são pintados na imagem da amostra com uma cor diferente para cada classe, de modo que os padrões de cor que constituem o grão sejam facilmente identificados, como exibido na Figura 18. Quando todos os *pixels* de um grão tiverem sido classificados, a classe atribuída ao maior número de *pixels* é definida como a classe do grão.

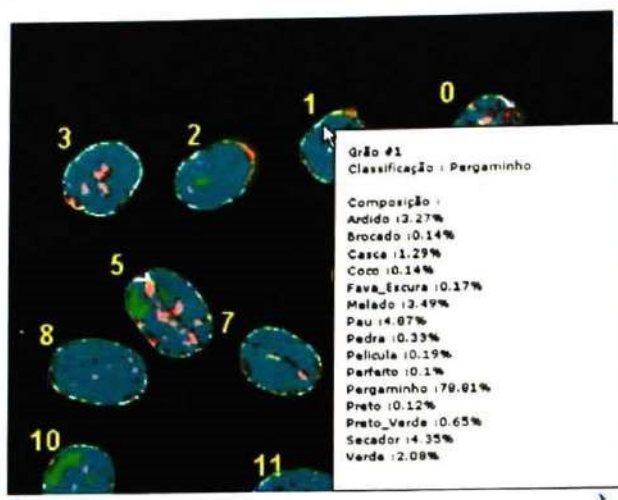


Figura 18: Resultado de uma classificação por cor.

### Descritores de forma utilizados

Para que a MLP possa realizar o reconhecimento de padrões de forma, foram utilizados alguns descritores de forma:


**Assinaturas:** a distância de um ponto da borda até o seu centro de massa. Os valores foram normalizados pelo maior valor, de forma que cada um variasse entre 0 e 1. Foram utilizados 36 valores, separados entre si de 10°. Juntamente com as assinaturas, também foram utilizados o comprimento e a largura da forma, em milímetros.

**Descritores de Fourier:** Descritores de Fourier representam a borda de uma região como uma função periódica que pode ser expandida em uma série de Fourier. Uma característica típica dos descritores de Fourier é que, geralmente, a forma geral da figura é relativamente bem definida a partir de alguns dos termos de menor ordem da expansão. Para este projeto, optou-se por usar os 40 primeiros coeficientes para se definir as formas.

Na Figura 19 podem ser observados exemplos de assinatura e descritores de Fourier para cada tipo de contorno estudado.

A comparação dos modelos consistiu no treinamento de duas MLPs para o reconhecimento de grãos perfeitos, grãos quebrados, paus e pedras, cada uma utilizando-se de um dos modelos. Então, as MLPs foram utilizadas na classificação de amostras com grãos conhecidos, para que finalmente pudessem ser calculadas suas taxas de acerto.





**Figura 19:** Assinatura e Descritor de Fourier.

A MLP treinada com assinaturas, largura e comprimento teve uma taxa de acerto de cerca de 80%, enquanto que na treinada com descritores de Fourier, a taxa foi de cerca de 60%. Portanto, o primeiro modelo foi o adotado.

### Classificação por forma

As impurezas de uma amostra de grãos de café podem ser facilmente reconhecidas através de suas formas, que estão fora do padrão que as sementes apresentam. Como exemplo, podem-se citar os paus, que apresentam um contorno fino e comprido, ou as pedras, que são pequenas e têm um contorno irregular. A análise de forma também é capaz de indicar grãos com defeitos, como os quebrados, que naturalmente são menores e não possuem o característico formato arredondado de uma semente perfeita. Seguindo essas premissas, foi utilizada uma MLP para reconhecer os padrões de forma dos objetos presentes na imagem de uma amostra e indicar de qual classe de grão ou impureza esses padrões são característicos.

Essa MLP foi configurada com 38 atributos, dos quais 36 são assinaturas, uma é a largura e a outra, o comprimento (ambos em milímetros) do grão a ser classificado, e 10 classes: cabeça, casca, coco, concha, marago, pau, pedra, perfeito, pergaminho e quebrado. Analogamente ao treinamento da MLP de cor, o da de forma foi feito capturando-se imagens contendo grãos ou impurezas de uma classe específica e, então, extraindo-se seus contornos para serem utilizados no cálculo das assinaturas, dos comprimentos e das larguras. Foi coletado um conjunto de cerca de 60 formas para cada uma das classes.

Além de indicar os padrões de forma presentes, também é gerado um histograma com a distribuição dos grãos por peneira, uma classificação utilizada pelas cooperativas de café. Em geral, essa classificação é feita por um jogo de peneiras, que separa os grãos pela forma e pelo tamanho. As peneiras têm crivos com diversas medidas e dois formatos diferentes: podem ser oblongos, para separar os cafés mocas, ou circulares,

para separar os cafés chatos. As medidas dos crivos das peneiras são dadas em frações de 1/64 de polegada e o número da peneira corresponde ao numerador da fração. Por exemplo: peneira 19 = 19/64 de polegada.

Com as MLPs devidamente treinadas, foram utilizados conjuntos de grãos fornecidos pela Cooxupé em diversos testes, com o intuito de se validar os métodos desenvolvidos.

### Identificação dos objetos

Constatou-se que o processo de reconhecimento de formas na imagem apresenta algumas falhas, como ilustrado na Figura 20. A mais perceptível acontece na presença de objetos com coloração muito escura, visto que uma porção deles é rotulada como parte do fundo no processo de segmentação, resultando na extração de formas diferentes das reais. Outro problema ocorre na execução do algoritmo de *watershed*, que, algumas vezes, divide a forma de um único objeto em várias (o que ocorre com frequência com os paus) e em certas ocasiões, traça erroneamente a fronteira entre dois objetos que se encostam. Essas falhas se devem principalmente ao sistema de iluminação da amostra, que não distribui a luz homogeneamente e ao fato de a superfície sobre a qual a amostra é depositada ter uma tonalidade de cor próxima a de certos objetos de interesse.

Apesar das falhas, de modo geral o algoritmo de reconhecimento de objetos se mostrou muito eficiente. Posicionando-se a amostra na faixa da bandeja onde a iluminação é mais homogênea e são gerados menos reflexos, são detectados praticamente todos os objetos (com exceção das formas muito escuras - defeito que pode ser corrigido alterando-se a cor do fundo usado).




Figura 20: Deficiências na identificação de objetos.

Foram conduzidos testes para a obtenção da distribuição por peneira em três amostras de grãos, cada uma proveniente de um processo de separação por peneira com crivos diferentes. As peneiras em questão eram 15, 17 e 19. Nos três casos pôde-se perceber uma maior concentração em torno da furação utilizada na separação, a qual também apresentou em todos os casos o maior número de ocorrências. A Figura 21 mostra o histograma obtido da amostra da peneira 19.





Figura 21: Distribuição por peneira de uma amostra de peneira 17.

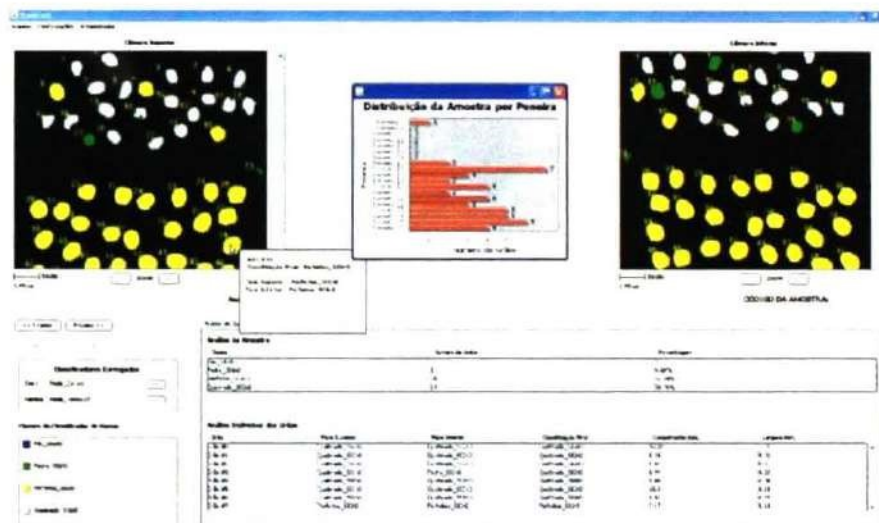


Comparando-se as classificações geradas pelo *software* com as reais classes presentes nas amostras, observou-se que foi possível distinguir entre impurezas – paus e pedras – e grãos, sejam eles com defeitos ou não, com uma acurácia satisfatória. Dado que a presença de impurezas na amostra exerce uma depreciação no café muito maior que os grãos defeituosos, essa característica indica um importante resultado. Na Figura 22, é mostrado um exemplo de classificação, na qual essa distinção é notada. Em verde, estão os objetos corretamente classificados (como paus, pedras ou grãos) em pelo menos uma das duas análises, de cor e de forma; e, em vermelho, aqueles cujas classificações não foram corretas em nenhuma delas.



**Figura 22:** Acertos de classificação de grãos e impurezas a) pedras b) paus c) grãos.

A interface implementada no Qualicafé mostra a classificação do grão, tomado por cima e por baixo, como pode ser observado na Figura 23.



**Figura 23:** Tela de Resultados por análise.

Este trabalho buscou desenvolver um software que substituísse o atual processo manual de classificação de grãos de café por um método automático, mais eficiente e confiável. Os resultados obtidos mostraram que as atuais técnicas de processamento de imagem são capazes de extrair da imagem de um grão informações suficientes para definir sua forma e coloração, alguns dos atributos utilizados por especialistas humanos para classificar os grãos. Também se pode concluir que, com as classificações geradas pelas redes neurais é possível fazer o reconhecimento de padrões de forma satisfatória.


Mesmo com as dificuldades geradas pela iluminação não adequada, que acarreta grandes limitações em ambos os processos classificatórios, foi possível se obter bons resultados preliminares – distinguir grãos de impurezas e identificar certas classes com um acerto significativo – sugerindo que uma melhora no sistema de iluminação ampliará o substancialmente o potencial do método. O sistema de iluminação está sendo redesenhado.

### 3.2 Máquina de classificação e análise por redes neurais artificiais - MACARENA

A MACARENA é um sistema de visão computacional para a inspeção de batatas, visando à classificação por cor, tamanho, forma e volume identificando os defeitos mais comuns, buscando melhoria da eficiência do sistema de comercialização já existente. Possui classificação por cor, tamanho e forma possibilitando uniformidade e agregação de valor, identificação e eliminação de defeitos e produtos fora do padrão comercial.

#### Exemplos de padrões de defeitos e formas a serem classificados








A batata pode conter defeitos que alteram sua cor e forma, podendo ser divididos em graves e leves. Esses defeitos podem ser causados por diferentes problemas, tendo como principais: doenças, pragas, distúrbios fisiológicos e danos mecânicos (Figura 24).



**Figura 24:** Defeitos severos, leves e variáveis (CEAGESP, 2001).

De acordo com o tamanho do tubérculo são padronizadas classes com base no diâmetro transversal em milímetros (mm) (CEAGESP, 2001), conforme Figura 25.




 I > 70 mm	 II > 42 até 70 mm	 II.1 > 42 até 50 mm	
 II.2 > 50 até 70 mm	 III > 33 até 42 mm	 IV > 28 até 33 mm	 V até 28 mm

**Figura 25:** Classificação de batatas segundo o tamanho (CEAGESP, 2001).


### Aquisição de imagens e protótipo implementado

O sistema de inspeção proposto consiste de uma unidade de alimentação do tubérculo através de uma esteira, a unidade de visão, onde foi desenvolvido um sistema de iluminação e visão proporcionando obtenção de imagens e além disso uma unidade de rejeição para separação do tubérculo não classificado, conforme Figura 26.



**Figura 26:** Diagrama do protótipo para aquisição e análise das imagens, sendo (1) esteira; (2) motor movimentação esteira; (3) câmara fechada com controle de iluminação; (4) computador; (5) controlador de eliminação de defeitos e (6) motor para controlar ejeção de defeitos.

O sistema desenvolvido para aquisição e testes de classificação é apresentado na Figura 27.



**Figura 27:** Protótipo (Máquina de Classificação e Análise por Redes Neurais – MACARENA) construído para classificação – Visão Geral do Sistema. No sentido horário: Equipamento com detalhe do painel elétrico; Câmara interna para captura de imagens; Detalhe da esteira; Painel elétrico em detalhe.

Na Figura 28, podem ser observadas tomadas da máquina em operação para classificação de batata consumo por tamanho e defeitos.

O software foi desenvolvido com uma janela principal para visualização e acompanhamento do funcionamento da máquina, e uma janela especial para treinamento da rede neural.

A preparação para o treinamento consiste na escolha de partes boas e ruins da imagem. Das áreas selecionadas são extraídas as características assinaladas, que então são passadas para o vetor de treinamento da rede neural.




**Figura 28:** Classificação de batata no protótipo de classificação - Máquina de Classificação e Análise por Redes Neurais – MACARENA. Em sentido horário: Visão geral do equipamento; Equipamento em detalhe de classificação; Batata em classifica-ção; Batata em



classificação para defeitos.

Com as amostras escolhidas, devem-se verificar as opções de treinamento, como taxa de aprendizado e número de ciclos. Após “treinada” a rede neural, é permitido gravá-la em um arquivo e usá-la posteriormente. Na Figura 29, pode ser vista a tela de treinamento do software desenvolvido.



**Figura 29:** Janela de treinamento e seleção de partes boas e partes ruins na imagem.

A janela principal contém controles que visualizam os frames originais e processados, permitindo o acompanhamento da batata na máquina e seu processamento. Através dessa janela, são escolhidas opções como: câmera e rede neural utilizadas, quantidade de pontos de amostra e porcentagem de aceitação.


Conforme a batata é processada, informações sobre seu processamento, quantidade de batatas, forma e quantidade de pontos ruins são mostradas na janela para acompanhamento (Figura 30).



**Figura 30:** Janela principal de acompanhamento.

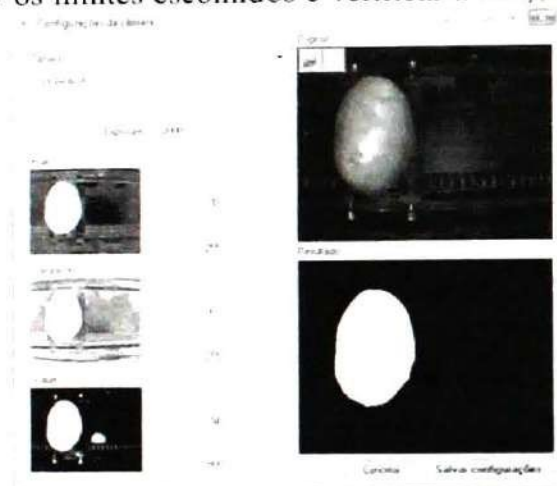
Para a seleção da rede neural há uma janela específica que permite o carregamento de diversas redes simultaneamente. Nesta janela, observam-se as características para as quais a rede foi treinada, a quantidade de amostras, topologia e gráfico do erro, podendo ser exportados para um arquivo .csv os valores que

compõem este último (Figura 31).




**Figura 31:** Informações para escolha da rede neural.

A escolha da câmera e suas configurações é realizada por uma interface acessível na janela principal do software. Essa interface provê opções para a escolha dos limites inferior e superior das componentes H,S e V, que auxiliam no isolamento da batata na imagem. O usuário pode carregar uma imagem, ou capturar um frame, para aplicar os limites escolhidos e verificar a imagem resultante (Figura 32).



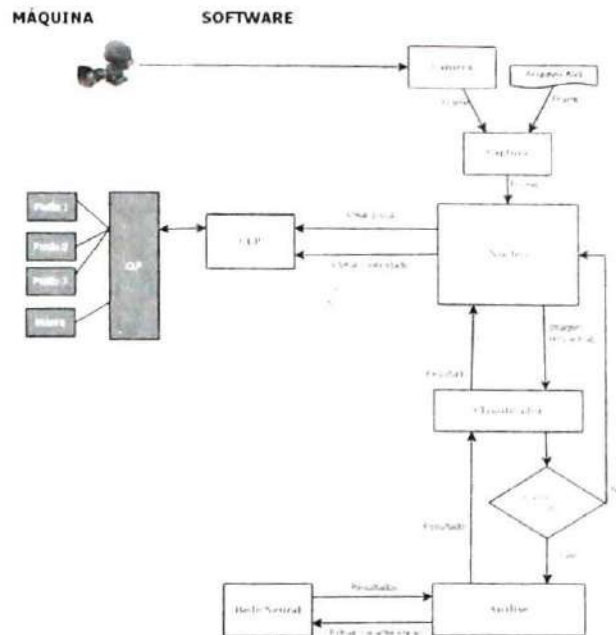
**Figura 32:** Escolha dos limites para as componentes HSV e imagem resultante.

Ao começar a análise na janela principal, o software inicia a captura dos frames e verificação da existência da batata. Assim que a batata é detectada, o software é programado para capturar três frames em determinados intervalos de tempo, visando capturar toda a extensão da batata. Esses três frames são analisados individualmente, e os resultados são unidos para a classificação (Figura 33).



**Figura 33:** Três capturas da mesma batata em diferentes posições.

Após o processamento de todos os frames e classificação da batata, o software envia sinais para o CLP da máquina através do cabo serial, os quais definem qual pistão será ativado. O fluxograma do sistema pode ser observado na Figura 34.



**Figura 34:** Fluxograma do sistema.

### Extração de características utilizadas

As características de cor, ou momentos de cor, são representações que descrevem uma imagem: grande parte da distribuição de cores em uma imagem é capturada pelos momentos de cor. Neste trabalho, a imagem é analisada por pequenas janelas com 9 pixels de largura e altura. O primeiro momento é a cor média, que representa a média dos valores de R, G e B dos pixels na janela escolhida. O segundo momento é o cálculo do desvio padrão, e o terceiro é o cálculo da assimetria. Suas fórmulas para um canal de cor são as seguintes:

$$u = \frac{1}{MN} \sum_{i=1}^N \sum_{j=1}^M x_{ij} \quad (\text{Cor média})$$

$$\sigma = \sqrt{\frac{1}{MN} \sum_{i=1}^N \sum_{j=1}^M (x_{ij} - u)^2} \quad (\text{Desvio padrão})$$

$$S = \sqrt[3]{\frac{1}{MN} \sum_{i=1}^N \sum_{j=1}^M (x_{ij} - u)^3} \quad (\text{Assimetria})$$

Onde  $x$  é o valor do componente de cor no pixel da coluna  $i$  e linha  $j$ .  $N$  é o tamanho da largura da imagem; e  $M$  o tamanho de sua altura. Neste trabalho, utilizou-se o espaço de cor RGB, o que implica obter três valores para cada momento, nove no total.

## Textura

A análise de textura desempenha um papel importante na identificação e classificação de imagens. Através dela, é possível identificar características espaciais e padrões que se repetem ao longo de regiões da imagem. Foi utilizada a matriz de co-ocorrência de níveis de cinza, que representa a ocorrência de cada nível de cinza em diferentes posições e direções (GONZALEZ; WOODS, 2010). Para o cálculo dessa



matriz, são considerados dois pixels: um de referência e um vizinho. Esses pixels são separados por uma distância  $d$ , que pode ser valor um, dois, ou qualquer outro valor. Neste trabalho foi utilizada a distância um (Figura 35). A posição do pixel vizinho não depende apenas da distância, mas também de uma direção  $\theta$ , sendo necessário definir qual a direção que será utilizada para o cálculo das ocorrências. As direções podem ser laterais ou diagonais. Para este trabalho, usou-se a direção  $\theta$  com valor 0.

135°	90°	45°
180°	Pr	0°
225°	270°	315°

**Figura 35:** Pixel de referência Pr e possíveis direções do pixel vizinho.

A imagem original é dividida de acordo com seus componentes de cor, que neste caso são três (R, G e B), cada componente gerando uma imagem em nível de cinza. A matriz é calculada a partir dessas imagens, gerando uma matriz de coocorrência para cada componente.

Com a matriz coocorrência, é possível extrair características que permitem identificar texturas e regiões da imagem. Neste trabalho, foram utilizadas as características de homogeneidade, energia, contraste e entropia; as fórmulas para seus cálculos são as seguintes:

$$\text{Homogeneidade} = \sum_{i=1}^G \sum_{j=1}^G \frac{p(i,j)}{1+|i-j|}$$

$$\text{Energia} = \sum_{i=1}^G \sum_{j=1}^G p(i,j)^2$$

$$\text{Contraste} = \sum_{i=1}^G \sum_{j=1}^G |i-j|^2 p(i,j)^2$$

$$\text{Entropia} = \sum_{i=1}^G \sum_{j=1}^G p(i,j) \log(p(i,j))$$

Onde  $p(i,j)$  é o valor da matriz de coocorrência na posição  $ij$ , e  $G$  é a dimensão da matriz, que é igual à quantidade de níveis de cinza das imagens utilizadas. Considerando-se uma imagem R,G e B, são geradas três matrizes de coocorrência, das quais extraem-se quatro características, resultando em um total doze características de textura por imagem.

#### 4. Conclusão

Neste capítulo constam informações necessárias para o entendimento de um sistema de classificação por imagem de frutos e hortaliças. Procurou-se descrever em detalhe este sistema, finalizando com aplicações práticas, e exemplos para café e batata.

#### Referências

BEE, S. C.; HONEYWOOD, M. J. Colour sorting for the bulk food industry. In: MACDOUGALL, D. B.

**Colour in food:** improving quality. Cambridge: Woodhead publishing, 2002. p. 115-142.

BLASCO, J.; ALEIXOS, N.; MOLTO, E. Computer vision detection of peel defects in citrus by means of a region oriented segmentation algorithm. **Journal of Food Engineering**, Essex, v. 81, p. 535–543, 2007.

CEAGESP (São Paulo). **Classificação da Batata “in natura”**. Programa Brasileiro para a Melhoria dos Padrões Comerciais e Embalagens de Hortigranjeiros, São Paulo, 2001. 4 p.

DIEGUEZ-URIBEONDO, J.; GIERZ, G.; BARTNICKI-GARC, S. Image analysis of hyphal morphogenesis in Saprolegniaceae (Oomycetes). **Fungal Genetics and Biology**, Orlando, v. 41, p. 293–307, 2004.

DING, W.; NESUMI, H.; TAKANO, Y.; UKAI, Y. Quantitative evaluation of the three-dimensional fruit shape and size of Citrus species based on spherical harmonic descriptors. **Euphytica**, Wageningen, v. 114, p. 103–115, 2000.

DECK, S. H.; MORROW, C. T.; HEINEMANN, P. H.; SOMMER, J. Comparison of a neural network and traditional classifier for machine vision inspection of potatoes”. **Applied engineering in agriculture**, St Joseph, v. 11, p. 319-326, 1995.

ELMASRY, G.; WANG, N.; ELSAYED, A.; NGADI, M. Hyperspectral imaging for nondestructive determination of some quality attributes for strawberry. **Journal of Food Engineering**, Essex, v. 81, p. 98–107, 2007.

GOWEN, A. A.; O'DONNELL, C. P.; CULLEN, P. J.; DOWNEY, G.; FRIAS, J. M. Hyperspectral imaging: an emerging process analytical tool for food quality and safety control. **Trends in Food Science & Technology**, Cambridge, v.18, n. 12, p. 590–598, 2007.

GOMEZ-SANCHIS, J.; MOLTO, E.; CAMPS-VALLS, G.; GOMEZ-CHOVA, L.; ALEIXOS, N.; BLASCO, J. Automatic correction of the effects of the light source on spherical objects. An application to the analysis of hyperspectral images of citrus fruits. **Journal of Food Engineering**, Essex, v. 85, p. 191–200, 2008.

GONZALEZ, R. C.; WOODS, R. E. **Processamento digital de imagens**. 3. ed. São Paulo: Pearson, 2010. 624 p.

HEINEMANN, P. H.; PATHARE, N. P.; MORROW, C. T. An automated inspection station for machine-vision grading of potatoes. **Machine vision and Applications**, New York, v. 9, p. 14-19, 1996.

HU, M. K. Visual Pattern Recognition by Moment Invariants. **IRE Transactions on Information Theory**, New York, v. 8, p. 179–187, 1962.

LANA, M. M.; TIJSKENS, L. M. M.; THEIJE, A.; HOGENKAMP, M.; VAN KOOTEN, O. Assessment of changes in optical properties of fresh-cut tomato using video image analysis. **Postharvest Biology and Technology**, Amsterdam, v. 41, p. 296–306, 2006.

LEE, D. J.; SCHOENBERGER, R.; ARCHIBALD, J.; McCOLLUM, S. Development of a machine vision system for automatic date grading using digital reflective near-infrared imaging. **Journal of Food Engineering**, Essex, v. 86, n. 3, p. 388-398, 2008.



- LEEMANS, V.; KLEYNEN, O. Quality Evaluation of Apples. In: SUN, D-W. **Computer Vision Technology for Food Quality Evaluation**. [S. l.]: Elsevier: Academic press, 2008. 583 p.
- LEFEBVRE, M.; ZIMMERMAN, T.; BAUR, C.; GUGERLI, P.; PUN, T. Potato Operation: automatic detection of potato diseases. In: MEYER, G. E.; DESHAZER, J. A. (Ed.). **Optics in agriculture, forestry, and biological processing**. Boston, Massachusetts: SPIE, 1994. (Proc. SPIE 2345).
- MACDOUGALL, D. B. **Colour in food: Improving quality**. Cambridge: Woodhead publishing, 2002. p. 115-142.
- MENDOZA, F.; DEJMEK, P.; AGUILERA, J. M. Calibrated color measurements of agricultural foods using image analysis. **Postharvest Biology and Technology**, Amsterdam, v. 41, p. 285-295, 2006.
- MOREIRA, M. A. **Fundamentos do sensoriamento remoto e metodologias de aplicação**. São José dos Campos: INPE, 2001. 208 p.
- MUMMERT, C. N. **The development of a machine vision system to measure the shape of a sweetpotato root**. 2004. Thesis (Master of Science) - Faculty of North Carolina State University, Raleigh, 2004.
- NIEUWENHUIZEN, A. T. ; TANG, L. ; HOFSTEE, J. W.; MULLER, J.; VAN HENTEN, E. J. Colour based detection of volunteer potatoes as weeds in sugar beet fields using machine vision. **Precision Agriculture**, Dordrecht, v. 8, p. 267-278, 2007.
- NOORDAM, J. C.; TIMMERMANS, A. J. M.; OTTEN, G. W.; ZWOL, B. H. van. **A Colour Vision System for high speed Sorting of Potatoes**. Warwick: Agrotechnological Research Institute, 2000.
- NOORDAM, J. C.; BROEK, V. D.; BUYDENS, L. M. C. Perspective of inline control of latent defects and diseases on French Fries with multispectral imaging. In: BENNEDSEN, B. S. (Ed.). **Monitoring food safety, agriculture, and plant health**. Bellingham: SPIE, 2004. (Proceedings of SPIE-the International Society for Optical Engineering).
- PANIGRAHI, S.; GUNASEKARAN, S. Computer vision. In: GUNASEKARAN, S. (Ed.). **Nondesctructive food evaluation: techniques to analyze proeprties and quality**. New York: Marcel Dekker, 2001. p. 39-98.
- PATHARE, N. P.; HEINEMANN, P. H.; MORROW, C. T.; DECK, S. Automated inspection station for grading of potatoes. In: INTERNATIONAL SUMMER MEETING OF THE ASAE, Spokane, Washington, 1993. [**Proceeedings...** S. l.: s. n.], 1993.
- PAZOTI, M. A.; GARCIA, R. E.; PESSOA, J. D. C.; BRUNO, O. M. C. **Electronic Journal of Biotechnology**, [S. l.], v. 8, n. 3, 2005. DOI: 10.2225/vol8-issue3-fulltext-1.
- PUN, T; LEFEBVRE, M.; GIL, S.; BRUNET, D.; DESSIMOZ, J. D.; GUGERLI, P. The Potato Operation: Computer vision for agricultural robotics. In: SPIE CONF. ON ADVANCES IN INTELLIGENT ROBOTIC SYSTEMS, 1991, Boston, **Proceedings...** [S. l.: s. n.], 1991.
- RIQUELME, M. T.; BARREIRO, P.; RUIZ-ALTISENT, M.; VALERO, C. Olive classification according to external damage using image analysis. **Journal of Food Engineering**, Essex, v. 87, p. 371-379, 2008.

STEFFEN, C. A. **Reflectância**. São José dos Campos: INPE, 1995. (INPE 5638. PUD/070).

TAO, Y.; MORROW, C. T.; HEINEMANN, P. H.; SOMMER, H. J. Automated machine vision inspection of potatoes. In: INTERNATIONAL WINTER MEETING OF THE ASAE, 1990, Chicago, Illinois. [**Proceedings...** S. l.: s. n.], 1990.

TAO, Y.; HEINEMANN, P. H.; VARGHESE, Z.; MORROW, C. T.; SOMMER, H. J. Machine vision for colour inspection of potatoes and apples. **Transactions of the ASAE**, St. Joseph, v. 38, p. 1551-1561, 1995.

ZHOU, L.; CHALANA, V.; KIM, Y. PC-based machine vision system for real-time computer-aided potato inspection. **International journal of imaging systems and technology**, [S. l.], v. 9, p. 423-433, 1998.