

UNIVERSIDADE FEDERAL DO PARANÁ

JÉSSICA KEHRIG FERNANDES

**APLICAÇÃO DE TÉCNICAS DE ANÁLISE DE IMAGEM PARA AVALIAÇÃO DE
PARÂMETROS EM ALIMENTOS**

**CURITIBA
2011**

JÉSSICA KEHRIG FERNANDES

**APLICAÇÃO DE TÉCNICAS DE ANÁLISE DE IMAGEM PARA AVALIAÇÃO DE
PARÂMETROS EM ALIMENTOS**

Dissertação apresentada ao Programa de Pós-Graduação em Tecnologia de Alimentos do setor de Tecnologia da Universidade Federal do Paraná, como parte dos requisitos exigidos para a obtenção do título de Mestre em Tecnologia de Alimentos.

Orientador: Dr. Marcelo Kaminski Lenzi

CURITIBA

2011

Fernandes, Jéssica Kehrig

Aplicação de técnicas de análise de imagem para avaliação de parâmetros em alimentos / Jéssica Kehrig Fernandes. – Curitiba, 2011.

77 f. : il.; tab.

Dissertação (mestrado) – Universidade Federal do Paraná, Setor de Tecnologia, Programa de Pós-Graduação em Tecnologia de Alimentos.

Orientador: Marcelo Kaminski Lenzi

1. Azeite - Espectrofotometria. I. Lenzi, Marcelo Kaminski. II. Título.

CDD 664.362

JÉSSICA KEHRIG FERNANDES

APLICAÇÃO DE TÉCNICAS DE ANÁLISE DE IMAGEM PARA
AVALIAÇÃO DE PARÂMETROS EM ALIMENTOS

Dissertação aprovada como requisito parcial para obtenção do grau de Mestre no Programa de Pós-Graduação em Tecnologia de Alimentos, da Universidade Federal do Paraná, pela Comissão formada pelos professores:


Orientador: Prof. Dr. MARCELO KAMINSKI LENZI
Setor de Tecnologia, UFPR


Prof. Dr. LUIZ FERNANDO DE LIMA LUZ JUNIOR
Setor de Tecnologia, UFPR


Prof.^a Dr.^a LUCIANA IGARASHI MAFRA
Setor de Tecnologia, UFPR

Curitiba, 10 de dezembro de 2011.

DEDICO ESTE TRABALHO

Aos meus pais, Luiz Carlos Fernandes e Sônia Regina Kehrig Fernandes, que me auxiliaram nos momentos mais difíceis, dando bons conselhos, com todo seu amor e carinho, para que o caminho tomado fosse o melhor dentre as opções.

Ao meu querido irmão, Augusto Kehrig Fernandes, que sempre esteve ao meu lado nos melhores e piores momentos, nas risadas, brincadeiras e agora nas conquistas.

Aos meus avós Pedro Bernardo Kehrig, Helena Back Kehrig e Sebastiana, que são como meus pais, os quais colaboraram em minha educação, com sua enorme sabedoria.

Ao meu querido companheiro Jair Glaeser, que mesmo estando longe durante a execução deste trabalho, me apoiou e deu forças para que nos momentos difíceis não desistisse, além de me compreender muito bem em todos os momentos.

AGRADECIMENTOS

A Deus, por ter me guiado na tomada de decisões.

A meu orientador, Prof. Dr. Marcelo Kaminski Lenzi, pelos conhecimentos compartilhados, dedicação, apoio, paciência, compreensão, incentivo e esforço para que este trabalho fosse desenvolvido nas melhores condições possíveis.

Aos professores. Dr. Arion Zandona Filho e Dra. Rosemary Hoffman Ribani, por compartilharem suas idéias, participando da banca de qualificação deste trabalho.

A Ana Paula Pitarello por colaborar com as discussões relativas ao resultado do Espectro UV-VIS.

Ao PGEAL pela oportunidade de realização deste trabalho e à CAPES/REUNI pelo apoio financeiro concedido.

Ao Secretário do PGEAL, Paulo Roberto Krainski, pelo excelente trabalho realizado, pela responsabilidade, pela paciência, pelo apoio, pela consideração e pelas ótimas conversas.

A colega Edielly Alves, pela paciência em repassar seus conhecimentos pertinentes ao assunto deste trabalho, pela troca de idéias e por auxiliar no início do desenvolvimento deste trabalho.

Aos colegas Vitor Renan da Silva e Fabiane Hamerski, pela paciência nas disciplinas, pelo ensinamento e principalmente pelo exemplo.

Aos amigos, Hayana Juliani Mimura Sanquetta, Giovanna Doná, Eduarda Molardi, Alexandre Moser pelos momentos alegres compartilhados, pelo incentivo e principalmente pela força nos momentos de dificuldade, enfim pela amizade pactuada que com certeza permanecerá em meu coração.

As amigas Priscilla Dos Santos Gaschi, Michele Cristiane Mesomo e Paola Dos Santos Gaschi, com quem tive a oportunidade de conviver, dividindo o mesmo teto, pela aprendizagem adquirida, pelo conhecimento agregado, pela paciência, pelo apoio, enfim

pela amizade, vocês estarão sempre comigo, pois bons amigos são para sempre, independente dos caminhos seguidos.

RESUMO

Atualmente o azeite de oliva desperta um interesse de consumo em todas as classes sociais devido aos benefícios de saúde relacionados aos componentes deste óleo, os quais atuam principalmente na prevenção de doenças coronarianas. Devido a esta grande disseminação social, começam a surgir diversas técnicas de adulteração desse produto, pois o seu valor comercial é alto quando comparado aos óleos comestíveis mais utilizados como, por exemplo, óleo de soja, por isso técnicas que caracterizam o azeite de oliva em sua forma pura e suas misturas comerciais são importantes no setor de alimentação. Algumas literaturas apresentam diferentes técnicas de caracterização de azeite de oliva se detendo principalmente as adulterações com óleos comestíveis de valor comercial mais baixo, apresentando bons resultados para faixa de adulteração de 1 a 5%. Portanto o objetivo deste trabalho foi desenvolver uma técnica que faz uso da análise de imagem associada ao Espectro UV-VIS para caracterização do azeite de oliva e misturas deste com óleo de soja. Todas as amostras foram utilizadas em sua forma comercial, sem nenhum tratamento prévio, misturas variando de 0% a 100% de azeite de oliva foram efetuadas com óleo de soja (intervalo de 10%) baseando-se sempre em sua fração mássica, sendo então submetidas a tomada de fotografias e obtenção das absorbâncias no Espectro UV-VIS. As fotografias obtidas foram processadas por um software desenvolvido em linguagem Delphi, de onde pode se obter os dados referentes as cores da imagem, no sistema RGB. Todos os dados obtidos nesta etapa foram correlacionados as absorbâncias em determinados comprimentos de onda, possibilitando assim o desenvolvimento de modelos estatísticos para a predição dos componentes da mistura. Com o acoplamento do espectro UV-VIS a técnica de análise de imagem foram desenvolvidos modelos lineares com dois, três, quatro, cinco, seis e sete parâmetros, os quais conseguiram descrever a concentração das misturas de 0% a 100% na fração mássica de azeite de oliva. Foi utilizado também uma amostra para validação do procedimento proposto, a qual possuía uma fração mássica de 25% de azeite de oliva, todos os modelos também puderam predizer essa amostra, contudo de acordo com os resultados o modelo com três parâmetros demonstrou melhor desempenho apresentando menor erro na previsão. Os modelos lineares que utilizam somente a análise de imagem (componentes R, G e B), descreveram bem as concentrações até 70% da fração mássica de azeite de oliva, portanto, estas técnicas digitais são promissoras para o monitoramento on-line/in-line de misturas de azeite de oliva comerciais.

Palavras-chave: Azeite de oliva, análise de imagem, espectrofotometria, mistura

ABSTRACT

Currently olive oil awakening a consumption interest in all social classes because of health benefits related to the components of this oil, which act mainly on the prevention of coronary heart disease. Due to this great social dissemination, several techniques are beginning to emerge of adulteration of the product, as its commercial value is high compared to most commonly used edible oils, for example, soybean oil, so techniques that characterize the olive oil in its pure form and their commercial mixtures are important in the food sector. Some literatures have different techniques for the characterization of olive oil, halting mainly edible oil adulteration with low commercial value, with good results for tampering range from 1 to 5%. Therefore, the purpose of this study was to develop a technique that makes use of image analysis combined with UV-VIS spectrum for characterization of olive oil and mixtures of soybean oil. All samples were used in its commercial form, without any previous treatment, mixtures ranging from 0% to 100% olive oil were made with soybean oil (10% range) based is always in its mass fraction, and then subject to taking photographs and obtaining the absorbance spectrum in the UV-VIS. The pictures obtained were processed by software developed in Delphi, where you can obtain the data for the image colors in the RGB system. All data were correlated at this stage the absorbance at certain wavelengths, thus enabling the development of statistical models for the prediction of the mixture. With the coupling of the UV-VIS spectrum technique of image analysis have been developed linear models with two, three, four, five, six and seven parameters, which successfully describe the concentration of mixtures of 0% to 100% in mass fraction of olive oil. A sample was also used to validate the proposed procedure, which had a mass fraction of 25% olive oil, all models were also able to predict this sample, however the results according to the model with three parameters showed a better performance exhibited low error in forecasting. The linear models that use only the image analysis (R, G and B) described well the concentration up to 70% of the mass fraction of olive oil, therefore, these techniques are promising for digital monitoring on-line/in-line mixtures of olive oil business.

Keywords: Olive Oil, Image Analysis, Mixture, Spectroscopy

LISTA DE ILUSTRAÇÕES

FIGURA 3.1 – PASSOS FUNDAMENTAIS EM PROCESSAMENTO DE IMAGENS DIGITAIS.....	14
FIGURA 3.2 – UMA APROXIMAÇÃO (ZOOM) PARA EXEMPLIFICAÇÃO DOS PIXELS.....	17
FIGURA 3.3 – CUBO DE CORES (MODELO RGB).....	20
FIGURA 4.1 – CÂMARA PARA AQUISIÇÃO DAS FOTOGRAFIAS.....	26
FIGURA 5.1 – MISTURAS DE AZEITE DE OLIVA.....	27
FIGURA 5.2 – COMPORTAMENTO DO COMPONENTE R EM FUNÇÃO DA COMPOSIÇÃO.....	28
FIGURA 5.3 – COMPORTAMENTO DO COMPONENTE G EM FUNÇÃO DA COMPOSIÇÃO.....	29
FIGURA 5.4 – COMPORTAMENTO DO COMPONENTE B EM FUNÇÃO DA COMPOSIÇÃO.....	29
FIGURA 5.5 – ESPECTRO UV-VIS PARA DIFERENTES COMPOSIÇÕES.....	35
FIGURA 5.6 – GRÁFICO DE CORRELAÇÕES ENTRE DADOS.....	36
FIGURA 5.7 – RESÍDUOS DA PREDIÇÃO DOS MODELOS DE 02 PARÂMETROS DA TABELA 5.8.....	42
FIGURA 5.8 – RESÍDUOS DA PREDIÇÃO DOS MODELOS DE 03 PARÂMETROS DA TABELA 5.9.....	43
FIGURA 5.9 – COMPARAÇÃO DAS PREDIÇÕES DOS MODELOS PARA AMOSTRA COM CONCENTRAÇÃO DE 25%.....	49

LISTA DE TABELAS

TABELA 5.1 – VALORES DE ABSORBÂNCIA PARA COMPRIMENTOS DE ONDA SELECIONADOS.....	30
TABELA 5.2 – MATRIZ DE CORRELAÇÕES.....	31
TABELA 5.3 – ESTATÍSTICA DESCRITIVA: COMPONENTE R.....	32
TABELA 5.4 – ESTATÍSTICA DESCRITIVA: COMPONENTE G.....	33
TABELA 5.5 – ESTATÍSTICA DESCRITIVA: COMPONENTE B.....	34
TABELA 5.6 – MODELO DE DOIS PARÂMETROS.....	58
TABELA 5.7 – MODELO DE TRÊS PARÂMETROS.....	62
TABELA 5.8 – MELHORES MODELOS DE DOIS PARÂMETROS.....	38
TABELA 5.9 – MELHORES MODELOS DE TRÊS PARÂMETROS.....	39
TABELA 5.10 – ANÁLISE DE IMAGEM DA AMOSTRA TESTE.....	45
TABELA 5.11 – DADOS PARA VALIDAÇÃO DO MODELO: 25% DE MASSA DE AZEITE DE OLIVA.....	45
TABELA 5.12 – PREDIÇÃO DOS MODELOS DE DOIS PARÂMETROS USANDO DADOS DA TABELA 5.11.....	46
TABELA 5.13 – PREDIÇÃO DOS MODELOS DE TRÊS PARÂMETROS USANDO DADOS DA TABELA 5.11.....	47

SUMÁRIO

1. INTRODUÇÃO	10
2. OBJETIVOS	12
3. REVISÃO DE LITERATURA	13
3.1 ANÁLISE DE IMAGEM.....	13
3.2 FUNDAMENTOS DE IMAGENS DIGITAIS	16
3.3 PROCESSAMENTO DE IMAGENS COLORIDAS	18
3.3.1 Modelo de cores.....	19
3.3.2 Modelo RGB de cores	19
3.4 ANÁLISE DE IMAGEM EM ALIMENTOS.....	21
4. MATERIAL E MÉTODOS	25
4.1 MATERIAIS.....	25
4.2 MÉTODOS.....	25
5. RESULTADOS E DISCUSSÕES	27
5.1 AMOSTRAS DE AZEITE DE OLIVA.....	27
5.2 CARACTERIZAÇÃO.....	27
5.3 MODELAGEM	31
5.4 VALIDAÇÃO	44
6. CONCLUSÃO	50
REFERÊNCIAS	51
APÊNDICE	58

1. INTRODUÇÃO

Atualmente o azeite de oliva desperta um interesse de consumo em todas as classes sociais devido aos benefícios de saúde relacionados aos componentes deste óleo, os quais atuam principalmente na prevenção de doenças coronarianas. Devido ao seu consumo disseminado entre a população, este produto de grande valor agregado, pode ser o foco de possíveis adulterações, com óleos mais baratos como o óleo de soja. Por isso técnicas rápidas e eficientes que caracterizam este tipo de óleo são importantes no setor de alimentação.

A partir de 1960, devido ao início da utilização dos computadores digitais técnicas associadas a este advento começaram a se desenvolver, como as técnicas de análise de imagem e com isso aplicações nas mais diversas áreas, por exemplo, na medicina, astronomia, geologia, indústria e outras, auxiliando na resolução de problemas (DAVIES, 2009).

A objetividade, consistência e eficiência nos processos, quando aplicados a matrizes pouco complexas podem justificar a implantação das técnicas computacionais de processamento de imagem, na indústria de alimentos, já que esta preza por uma excelente qualidade. (DU;SUN, 2004)

Entretanto, a avaliação dos parâmetros de qualidade e classificação dentro de uma indústria de alimentos geralmente é realizada, visualmente por pessoal treinado e especializado, mas questões que envolvem o meio e o indivíduo podem afetar significativamente o julgamento destes parâmetros, tornando este subjetivo.

Portanto, destaca-se nos últimos anos a utilização das técnicas de processamento digital de imagem, ou de forma mais ampla emprego da visão computacional na indústria de alimentos, para avaliação das características de determinado produto ou matéria-prima, informações estas utilizadas, por exemplo, para classificação e avaliação de qualidade. Leemans, Magein e Destain (2002) utilizaram o método de análise de imagem, com base nos parâmetros de geometria, cor, textura e detalhes relacionados ao cálice e pedúnculo, para detecção de defeitos em maçãs de duas variedades, Jonagold

e Golden Delicious, obtendo um percentual de 72% e 78% de acerto, respectivamente, na classificação destas.

A utilização de técnicas de análise de imagem na indústria de alimentos baseia-se em algumas características dos alimentos, como por exemplo: cor, ferramenta útil para indicar modificações durante o processamento dos alimentos; análise do tamanho do alimento que possibilita avaliação das variações e transformações no decorrer do processamento (pode ser relacionado com o rendimento do produto); análise de forma utilizada principalmente para avaliação da aceitação dos consumidores (variações durante o processamento) e textura a qual está relacionada com as características sensoriais e propriedades químicas e físicas dos alimentos (ZHENG; SUN; ZHENG, 2006a).

Levando em consideração a necessidade de controle de qualidade mais efetivo, minimizando os erros gerados por pessoas e suas impressões sobre os aspectos relacionados aos alimentos, *in natura* e processados, o presente trabalho visa utilizar a análise de imagem digital, para identificar características em misturas de azeite de oliva e óleo de soja.

2. OBJETIVOS

Este trabalho tem por objetivo principal a aplicação da análise de imagem para avaliação de parâmetros em alimentos, fazendo uso de informações digitais da imagem, principalmente os relativos a cores, associando estas a características físicas ou químicas de misturas (azeite de oliva/óleo de soja).

Para atingir o objetivo principal do trabalho as seguintes etapas foram realizadas:

1. Estudo de técnicas de processamento, análise de imagens e suas aplicações em alimentos;
2. Implantação de um programa de aquisição e tratamento de imagens utilizando Delphi 6;
3. Levantamento dos métodos utilizados a cada tarefa, bem como, os materiais e instrumentos para realizar a predição das características;
4. Validação do sistema de análise de imagem por meio de testes experimentais, levando em consideração a importância da análise estatística dos resultados.

3. REVISÃO DE LITERATURA

3.1 ANÁLISE DE IMAGEM

O processamento de imagens digitais tem por objetivo principal melhorar características de uma imagem para a visualização e interpretação humana, tal função abrange uma ampla escala de hardware, software e fundamentos teóricos (GONZALES;WOODS, 2000).

Dentro das técnicas do processamento digital de imagens, temos uma classificação que se dá a partir da redução progressiva da quantidade de informações manipuladas.

Baixo nível, os dados de entrada são pixels da imagem original e os dados de saída representam propriedades da imagem na forma de valores numéricos associados a cada pixel. No processamento de nível médio, este conjunto de valores produz como resultado uma lista de características; e no processamento de alto nível produz a partir dessas características uma interpretação do conteúdo da imagem (FACON, 1993).

A análise de imagem pode estar relacionada com a tecnologia de visão computacional, que é um método de aquisição e análise de uma imagem de uma cena/objeto real por computadores e outros dispositivos a fim de obter informações para controlar máquinas ou processos (SUN, 2004).

A análise de imagem envolve diversas etapas, como aquisição da imagem, pré-processamento, segmentação, representação e descrição, reconhecimento e interpretação. Estes passos devem ser desenvolvidos com cautela, pois são subseqüentes e uma falha no início pode não ser corrigida nos próximos passos, tendo assim um resultado final insatisfatório (GUNASEKARAN, 1996). O fluxograma de um sistema de processamento de imagem é demonstrado na Figura 3.1.

- Aquisição da imagem

Esta etapa inicial consiste em adquirir uma imagem digital, ou digitalizar uma imagem pré-existente.

Nesta etapa estão envolvidos fatores como: a escolha do sensor, o conjunto de lentes a utilizar, as condições de iluminação, a resolução,

dentre outros (FILHO; NETO, 1999). Uma iluminação apropriada, alta qualidade óptica e circuitos eletrônicos são fundamentais na aquisição de imagens de qualidade (GUNASEKARAN, 1996).

Uma aquisição de imagem de alta qualidade pode ajudar a reduzir a complexidade e o tempo das etapas subseqüentes de processamento, que pode diminuir o custo do sistema de processamento de imagem (DU; SUN, 2004).

- Pré-processamento

A fim de melhorar a qualidade de uma imagem, operações precisam ser executadas para remover ou diminuir degradações sofridas pela imagem durante sua aquisição. Nesta etapa pode-se suprimir distorções que não são necessárias e melhorar as características de interesse para uma posterior aplicação específica (DU; SUN, 2004).

O melhoramento da imagem é importante para garantir um bom desempenho nos processos posteriores, filtragem, realce, processamento de cor são itens que podem compor esta etapa de processamento, gerando assim a possibilidade de uma imagem de qualidade superior há inicial.

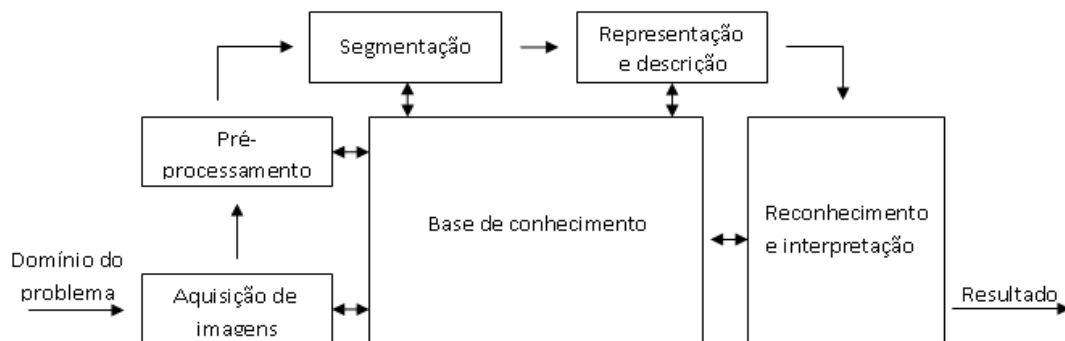


FIGURA 3.1 – PASSOS FUNDAMENTAIS EM PROCESSAMENTO DE IMAGENS DIGITAIS [Fonte: (GONZALEZ; WOODS, 2000)]

- Segmentação

Consiste em dividir uma imagem em suas partes constituintes ou objetos de interesse.

Em geral, a segmentação automática é uma das tarefas mais difíceis no processamento de imagens digitais. Um procedimento de

segmentação robusto favorece substancialmente a solução bem sucedida de um problema de imagem, por outro lado, algoritmos de segmentação fracos ou erráticos quase sempre provocam falha no processamento (GONZALEZ; WOODS, 2000).

- Representação e descrição

Os dados provenientes da etapa de segmentação podem ser representados por fronteiras ou regiões completas. A representação por fronteira é adequada quando o interesse se concentra nas características de forma externa, tais como cantos ou pontos de inflexão, já a representação por regiões completas é adequada quando o interesse se concentra em propriedades internas, tais como textura. A descrição procura extrair características que resultem em alguma informação quantitativa de interesse ou que sejam básicas para discriminação entre classes de objetos (GONZALEZ; WOODS, 2000).

- Reconhecimento e interpretação

Reconhecimento é o processo que atribui um rótulo a um objeto, baseado na informação fornecida pelo seu descritor. Já a interpretação envolve a atribuição de significado a um conjunto de objetos reconhecidos (GONZALEZ; WOODS, 2000).

- Base de conhecimento

Todas as tarefas das etapas, descritas anteriormente, pressupõe a existência de um conhecimento sobre o problema a ser resolvido, armazenado em uma base de conhecimento, cujo tamanho e complexidade podem variar (FILHO; NETO, 1999).

Além de guiar a operação de cada módulo de processamento, a base de conhecimento também controla a interação entre os módulos para tomada de decisões (GONZALEZ; WOODS, 2000).

Requisitos para tomada de decisões incluem a capacidade de extrair informações pertinentes de um fundo de detalhes irrelevantes, a capacidade de generalizar este conhecimento e aplicá-lo em diferentes

circunstancia, e a capacidade de fazer inferência a partir de informações incompletas (GUNASEKARAN, 1996).

3.2 FUNDAMENTOS DE IMAGENS DIGITAIS

3.2.1 Representação de Imagens Digitais

Uma imagem é definida como uma representação espacial de um objeto ou cena (GUNASEKARAN, 1996). A orientação do sistema de coordenadas mais utilizada no processamento de imagem é com a origem do sistema localizada no canto superior esquerdo. Essa localização preferencial para o canto superior esquerdo, com eixo y invertido em relação ao padrão da matemática, é herdada dos próprios dispositivos de visualização, onde a primeira linha a ser redenhada na tela é a do topo, que segue o padrão de escrita ocidental, da esquerda para a direita e de cima para baixo.

Como um computador não é capaz de processar imagens contínuas, pois este trabalha com números discretos, se faz necessário que as imagens sejam, primeiramente, convertidas em números na forma de matriz como arranjos bidimensionais de pontos. Para fazer a conversão de imagem em números, a imagem, como se observa na Figura 3.2, é subdividida em uma grade, contendo milhões de quadrados de igual tamanho, sendo cada um deles associado a um valor numérico da intensidade da cor naquele ponto. Cada quadrado na imagem é denominado *pixel* (elemento de imagem) (ALBUQUERQUE, 2002). Os valores desses *pixels* representam uma discretização da intensidade luminosa captada por uma determinada área, variando em valores ou porcentagem, dependendo do espaço de cor utilizado (GONZALEZ; WOODS, 2000).

3.2.2 Definição Matemática de Imagem

O termo *imagem* refere-se à função bidimensional de intensidade da luz $f(x,y)$, onde x e y denotam as coordenadas espaciais e o valor de f em qualquer ponto (x,y) é proporcional ao brilho (ou níveis de cinza) da imagem

naquele ponto. Como a luz é uma forma de energia, $f(x,y)$ deve ser positiva e finita, isto é (GONZALEZ; WOODS, 2000),

$$0 < f(x,y) < \infty. \quad (3.1)$$




FIGURA 3.2 – UMA APROXIMAÇÃO (ZOOM) PARA EXEMPLIFICAÇÃO DOS PIXELS

A função $f(x,y)$ pode ser caracterizada pelo produto de dois componentes: iluminância (quantidade de luz que incide sobre o objeto) e propriedades de reflectância (quantidade de luz que o objeto reflete), sendo representadas por $i(x,y)$ e $r(x,y)$, respectivamente (GONZALEZ; WOODS,2000). Matematicamente tem-se:

$$f(x,y) = i(x,y) \cdot r(x,y) \quad (3.2)$$

$$0 < i(x,y) < \infty \quad (3.3)$$

$$0 < r(x,y) < 1. \quad (3.4)$$

A intensidade de uma imagem f nas coordenadas (x,y) define o nível de cinza (l), naquele ponto. A determinação do intervalo é dada pelas equações de 3.2 à 3.4.

$$L_{min} \leq l \leq L_{max}. \quad (3.5)$$

O intervalo $[L_{min}, L_{max}]$, é denominado escala de cinza, onde todos os valores intermediários são tons de cinza, variando entre o branco e o negro.

Assim, uma imagem digital $f(x, y)$ pode ser representada por uma matriz (eq. 3.6), cujos os índices de linha e coluna identificam um ponto (pixel) da imagem e representam o nível de cinza naquele ponto (GRANDO, 2005).

$$f(x, y) = \begin{bmatrix} f(0,0) & f(0,1) & \dots & f(0, M-1) \\ f(1,0) & f(1,1) & \dots & f(1, M-1) \\ \vdots & \vdots & \ddots & \vdots \\ f(N-1,0) & f(N-1,1) & \dots & f(N-1, M-1) \end{bmatrix} \quad (3.6)$$

3.3 PROCESSAMENTO DE IMAGENS COLORIDAS

A cor é uma percepção visual que resulta da detecção da luz após a interação com um objeto.

Embora o processo seguido pelo cérebro humano na percepção de cores seja um fenômeno físico-psicológico que ainda não é completamente compreendido, a natureza física das cores pode ser expressa numa base formal suportada por resultados experimentais e teóricos (GONZALEZ; WOODS, 2000).

Segundo Gonzalez e Woods (2000), quando um feixe de luz solar passa através de um prisma de vidro, o feixe de luz emergente não é branco, mas sim um espectro contínuo de cores variando do violeta ao vermelho, feito este descoberto por Sir Isaac Newton.

O uso de cores em processamento de imagens é motivado por dois fatores principais: primeiramente, em análise de imagens automatizada, a cor é um descritor poderoso que freqüentemente simplifica a identificação do objeto e a extração de uma cena, e em segundo lugar, em análise de imagens desempenhada por seres humanos, a motivação para o uso de cores é que o olho humano pode discernir milhares de tons e intensidades de cores, comparando a cerca de apenas duas dúzias de tons de cinza (GONZALEZ; WOODS, 2000).

Na análise de imagem para produtos alimentícios, a cor é um influente e poderoso descritor que muitas vezes simplifica a extração do objeto e identificação de uma imagem, tendo uma aplicação de medida objetiva bem sucedida em alimentos como frutas, grãos, carnes e vegetais. Características de cor podem ser extraídas através da análise de cada pixel dentro dos limites estabelecidos (DU; SUN, 2004).

3.3.1 Modelo de cores

O propósito de um modelo de cores é facilitar a especificação das cores em alguma forma padrão e de aceite geral, essencialmente, um modelo de cor é uma especificação de um sistema de coordenadas tridimensionais e um subespaço dentro deste sistema onde cada cor é representada por um único ponto (GONZALEZ; WOODS, 2000).

Um sistema de cores é um modelo que explica as propriedades ou comportamento das cores num contexto particular. Não existe um sistema que explique todos os aspectos relacionados à cor (AZEVEDO; CONCI, 2003).

Por isso, são utilizados sistemas diferentes para ajudar a descrever as diferentes características da cor que são percebidas pelo ser humano. Existem vários sistemas de cores como: CIE-XYZ, RGB, HSV, CIELAB e CIELUV (MACHADO, 2006).

O universo de cores que podem ser reproduzidas por um sistema é chamado de espaço de cores, sendo este definido como um método formal, necessário para se quantificar as sensações visuais das cores, que podem assim ser mais precisamente especificadas (AZEVEDO; CONCI, 2003).

3.3.2 Modelo RGB de cores

O modelo RGB possui como primárias as cores aditivas vermelhas (R), verdes (G) e azuis (B), este modelo baseia-se na sensibilidade do olho, e usa um sistema de coordenadas cartesianas R, G, B, cujo subespaço de interesse é o cubo unitário apresentado na Figura 3.3 (AZEVEDO; CONCI, 2003).

O cubo apresenta os valores de RGB nos três cantos; ciano, magenta e amarelo estão nos outros três cantos; preto está na origem e branco está no canto mais distante da origem. Neste modelo, a escala de cinza, estende-se do preto até o branco ao longo da linha juntando estes dois pontos, e as cores são pontos sobre ou dentro do cubo, definidas por vetores estendendo-se a partir da origem.

Assume-se que todos os valores de cor foram normalizados, de modo que o cubo representado é unitário, portanto, todos os valores de R, G e B são assumidos estar no intervalo de [0,1] (GONZALEZ; WOODS, 2000).

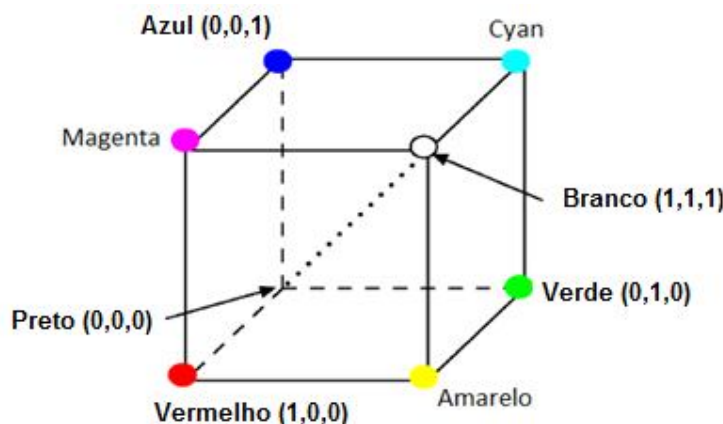


FIGURA 3.3 – CUBO DE CORES (MODELO RGB)

As cores nesse sistema podem ser expressas da forma (MACHADO, 2006):

$$C_{\lambda} = r.R + g.G + b.B. \quad (3.7)$$

Este modelo está intimamente associado às superfícies emissoras de luz, é por esta razão que este modelo é utilizado quase que universalmente pelos equipamentos que manipulam a emissão de luz, tais como os monitores e os televisores a cores, os filmes fotográficos e cinematográficos, e as gravações em vídeo baseiam-se também no modelo RGB (MACHADO, 2006).

Tradicionalmente, as implementações do modelo RGB nos sistemas gráficos empregam valores inteiros entre 0 e 255 para exprimir o valor da intensidade de cada componente, em vez de valores reais normalizados entre 0 e 1. Devido ao fato de que o processamento de valores inteiros é muito mais rápido do que o processamento de valores reais, desde os primeiros sistemas

gráficos, além de que a notação com inteiros é mais simples de escrever e aprender do que a notação com valores reais fracionários. A discretização, em 256 valores de intensidade, é mais do que o suficiente para o olho humano, pois este consegue distinguir entre um mínimo de 16 intensidades na zona do azul, e um máximo de 23 intensidades na zona do amarelo (LOPES, 2008).

No modelo RGB a representação utilizada é a de 8 bits para cada canal de informação, fazendo um total de 24 *bits* por *pixel*. Com isso é possível gerar mais de 16 milhões de cores diferentes (KOYA, 2001).

Em alimentos este modelo já foi aplicado em: maçãs para predição da quantidade de açúcar, segmentação de defeitos (LEEMANS; MAGEIN; DESTAIN et. al. 1999; STEINMETZ et. al., 1999); carne bovina para determinação da maturidade esquelética e mistura contida (HATEM; TAN; GERRARD, 2003; ZHENG; SUN; ZHENG, 2006b); macarrão para avaliação da aparência e cor (HATCHER; SYMONS; MANIVANNAN, 2003); classificação de pizzas segundo propagação do molho (DU; SUN, 2005).

3.4 ANÁLISE DE IMAGEM EM ALIMENTOS

Pesquisas vêm ocorrendo na área de análise de imagem desde 1980, e tem tido um desenvolvimento crescente e rápido (DAVIES, 2009). Segundo Gunasekaran (1996), a indústria alimentar é um dos segmentos que mais cresce com relação às aplicações das técnicas de visão computacional. Nesta área tais métodos são relevantes e úteis, não somente para avaliar produtos *in natura* como frutas, legumes e grãos, mas também animais e produtos processados em seus estágios finais de produção (DAVIES, 2009).

Sendo o mercado alimentício muito competitivo, as indústrias e agricultores preocupam-se em oferecer produtos que chamem a atenção de seus consumidores tanto por suas características sensoriais, como por sua qualidade, fator este que é de suma importância. O controle de qualidade, nestes setores, geralmente, ainda é realizado visualmente por pessoal treinado, o que pode tornar a avaliação tendenciosa, já que o “instrumento” utilizado para inspeção pode sofrer influencia de fatores externos, afetando assim a credibilidade dos resultados.

Devido à precisão e consistência na avaliação da qualidade e classificação dos alimentos, o processamento de imagem desempenha um papel cada vez mais importante, eliminando assim a subjetividade das inspeções manuais (DU; SUN, 2004).

O processamento digital de imagem quando aplicado a alimentos, faz uso de características como: textura, cor, tamanho, forma, etc., para analisar os parâmetros desejados, possibilitando assim a classificação ou a avaliação da qualidade de acordo com os padrões desejados.

Segundo Narendra e Hareesh (2010), a utilização desta tecnologia para avaliação da qualidade dos alimentos processados, frutas e vegetais é a área que possui maior potencial, pois a análise pode ser baseada em um padrão de exigência pré-existente, agindo sob condições controladas e automatizadas.

O estudo de maçãs utilizando a visão computacional tem atraído muito interesse e reflete o progresso desta tecnologia para inspeção de frutas. A tecnologia tem sido utilizada para tarefas como classificação de forma, detecção de defeitos, classificação de qualidade e classificação de variedades (BROSNAN; SUN, 2002).

Leemans, Magein e Destain (2002) utilizaram o método de análise de imagem, com base nos parâmetros de geometria, cor, textura e detalhes relacionados ao cálice e pedúnculo, para detecção de defeitos em maçãs de duas variedades, Jonagold e Golden Delicious, obtendo um percentual de 72% e 78% de acerto, respectivamente, na classificação. Sendo este percentual de acerto muito bom para uma técnica simples e recém desenvolvida.

Xiabo, Jiewen e Yanxiao (2007), detiveram-se somente no parâmetro cor, para classificação de maçãs de acordo com os padrões de classificação da China. Paulus e Schrevens (1999) utilizaram a análise de imagem para classificar maçãs de acordo com seus tamanhos, comprovando através de testes estatísticos que seres humanos tem dificuldades e variações ao classificar maçãs de acordo com seu tamanho. Quevedo *et. al* (2009b) aplicaram a visão computacional para análise da cinética do escurecimento enzimático em fatias de maçã, o qual permitiu calcular a taxa do escurecimento enzimático, com 14,3 vezes maiores do que as calculadas pelo método tradicional. Podendo demonstrar a objetividade do método, sendo que

provavelmente o método tracional subestima os valores de taxa de escurecimento enzimático.

Thybo *et. al.* (2004), avaliou a textura de batatas cozidas de diferentes variedades, sendo esta uma característica sensorial importante, e optou pelo método da visão computacional por este ser não invasivo e não destrutivo. Roculli *et. al.* (2007) mudaram o foco e avaliaram o efeito de fatores que inibem o escurecimento enzimático, utilizando também batatas, mas estas minimamente processadas.

Durmus *et. al.* (2010) empregaram a análise de imagem, para avaliação do tamanho de diferentes variedades de sementes de leguminosas, utilizando parâmetros geométricos, justificando ser de grande importância para cálculos de secadores em engenharia, processos de germinação, etc.

Quanto se refere a utilização das técnicas de análise de imagem em tomates, encontra-se aplicação das técnicas de análise de imagem para a caracterização celular do pericarpo, efeitos da temperatura de armazenamento e estágio de maturação em fatias de tomates, e medição de atributos qualitativos para classificação (DEVAUX *et. al.* 2008; LANA; TIJSKENS; KOOTEN, 2006; JAHNS; NIELSEN; PAUL, 2001).

Também se pode citar a avaliação da qualidade de morangos (NAGATA; TALLADA, 2005); e estudo da cinética do escurecimento enzimático em bananas (QUEVEDO *et. al.* 2009b9), aplicando estas técnicas de visão computacional.

Além das aplicações para frutas e vegetais, citadas acima, produtos processados e carnes também já foram utilizados como matéria de estudo, alguns destes serão relatados a seguir. A pesquisa desenvolvida por Lu, Shatadal e Gerrard (2000), teve como objetivo avaliar o potencial da tecnologia de visão computacional para avaliação da cor de lombo suíno fresco.

Alguns pesquisadores empregaram a técnica de análise de imagem para descrição quantitativa da gordura intramuscular em porcos, a classificação da gordura contida em carne bovina, e a maturidade da carne bovina com base na ossificação da cartilagem nas vértebras torácicas, todos estes utilizaram como parâmetro principal ou único a cor (FAUCITANO *et. al.* 2005; CHEN *et. al.*, 2010; HATEM; TAN; GERRARD, 2003)

Jackman et. al. (2008), avaliaram a qualidade da carne fornecida ao consumidor, segundo algumas características como cor, distribuição de gordura e textura. Cernadas, Durán e Antequera (2002), usaram para caracterização de presuntos curados Ibéricos a análise de imagem.

Em alguns produtos processados a quantificação e a distribuição de alguns ingredientes podem ser também avaliadas pelo método de processamento de imagem, como por exemplo: distribuição de ingredientes em coberturas de pizza, distribuição e quantificação de ingredientes em queijos pasteurizados, quantificação e distribuição de áreas marrons e oleosas em batatas fritas, avaliação da cor durante todo o tempo de fritura de batatas fritas em diferentes temperaturas (SUN, 2000; JELINSKI *et. al.*, 2007; ROMANI *et. al.*, 2009; PEDRESCHI *et. al.*, 2006). A utilização da técnica computacional para a avaliação destes produtos ajuda a melhorar a qualidade dos produtos comercializados, por apresentarem resultados de forma rápida e consistente.

A utilização das técnicas de análise de imagem está se difundindo cada vez mais entre os pesquisadores da área de alimentos, surgindo assim a possibilidade de aplicação para os mais diversos produtos e para diferentes propósitos de avaliação.

Esta técnica apresenta como vantagens a obtenção de uma resposta rápida, uma ótima relação de custo/eficiência, é objetiva, precisa e consistente, além de se tratar de um método não destrutivo e não invasivo da matéria prima em questão (SUN, 2000; BROSANAN; SUN, 2004; CHEN; CHAO; KIM, 2002).

Em contrapartida, questões relacionadas à imagem podem afetar negativamente os resultados, como qualidade e iluminação do ambiente.

A seguir, é reportado um trabalho envolvendo o caso abordado neste trabalho.

Furferi, Carfagni e Daou (2007) apresentam um software baseado na combinação de uma rede neural artificial (*Artificial neural network - ANN*) e um método numérico para avaliação do nível de acidez e de peróxidos em azeite de oliva durante um processo contínuo de extração. Como resultado tem-se que o software é uma ferramenta útil para estimar a qualidade do óleo de oliva através de dois parâmetros, acidez e índice de peróxido, com erro dentro de 10-15%. Além de a estimativa ser dada em tempo real, reduz a utilização de análises químicas, técnicas que podem elevar o custo e levam tempo.

4. MATERIAL E MÉTODOS

4.1 MATERIAIS

As matérias primas foram utilizadas em sua forma comercial, sem nenhum tratamento prévio, sendo: Azeite de Oliva Extra Virgem (acidez máxima 0,4%, primeira prensa a frio) e Óleo de Soja (geneticamente modificado a partir *Agro bacterium sp.* e antioxidantes TBHQ e ácido cítrico). Sendo suas características de composição citadas acima somente para um melhor esclarecimento, não influenciando de forma significativa nas etapas do estudo. Todas as amostras foram provenientes de um único lote e num curto intervalo de tempo.

4.2 MÉTODOS

Inicialmente, prepararam-se as amostras para análise, sempre se baseando em sua fração mássica, onde as matérias primas, azeite de oliva e óleo de soja, foram misturadas com uma variação de 0% a 100%, com intervalo de 10%, sendo então, onze amostras de concentração mássica diferentes. Além destas onze amostras, mais uma foi preparada contendo uma concentração conhecida, a qual será utilizada para validação do sistema, totalizando assim doze amostras ao final do estudo.

Após o preparo das amostras, estas foram transferidas para cubetas de poliestireno, para facilitar a aquisição das imagens.

A próxima etapa consistiu na aquisição das imagens digitais, a qual foi possibilitada através de uma máquina fotográfica, Sony Cyber-shot®, com 7.2 Mega pixels. Para tentar minimizar o fator iluminação sobre as amostras, utilizou-se uma câmara de coloração interna branca Figura 4.1, onde a fonte de iluminação foi constante durante a tomada das fotografias.




FIGURA 4.1 – CÂMARA PARA AQUISIÇÃO DAS FOTOGRAFIAS

Posteriormente, foi obtido um espectro de varredura (190nm a 900nm) de todas as doze amostras, utilizando o equipamento: Cary 100 Scan UV-Visible Spectrophotometer, do Departamento de Química da Universidade Federal do Paraná.

Foram selecionadas para a análise dos resultados as absorbâncias de quatro comprimentos de onda referentes aos picos e três referentes aos vales do espectro das amostras, os quais apresentaram maior desvio padrão entre si.

Para a análise de imagem, foi desenvolvido um programa em Delphi 6, facilitando a aquisição dos valores de cores no sistema RGB para todas as amostras em questão, através das fotografias.

Os dados foram tratados estatisticamente pelo Software Statistica (estimação de parâmetros) e Software R.

5. RESULTADOS E DISCUSSÕES

5.1 AMOSTRAS DE AZEITE DE OLIVA

A Figura 5.1 apresenta a fotografia das misturas de azeite de oliva utilizadas para análise e decomposição da cor, bem como para análise espectrofotométrica de UV-VIS. Na figura 5.1 são indicados os percentuais de azeite de oliva, bem como uma mistura teste a ser utilizada para validação do método.




FIGURA 5.1 – MISTURAS DE AZEITE DE OLIVA

5.2 CARACTERIZAÇÃO

Nesta etapa do estudo, foi utilizado um software desenvolvido, pelo autor deste trabalho com o auxílio de seu orientador, em linguagem DELPHI para decomposição da cor. Assim, para a imagem de cada cubeta, foi selecionada uma área com 12272 pixels, gerando os componentes referentes à cor R (red), G (green) e B (blue) para cada mistura. O software armazenou os dados para análise estatística de cada componente de todas as amostras. A Tabela 5.3 apresenta a estatística descritiva básica da componente R, ao passo que a Figura 5.2 ilustra o comportamento desta variável em função do aumento da concentração de azeite de oliva na mistura. Ressalta-se que na Figura 5.2, são apresentados os box-plot para cada ponto do gráfico, permitindo verificar a qualidade da análise de imagem, tendo em vista a pequena dispersão dos dados. Análises similares foram conduzidas para os componentes de cor G e B.

Os resultados referentes à cor G podem ser vistos da Tabela 5.4 e na Figura 5.3. Em relação ao componente B, os resultados estão disponíveis na Tabela 5.5 e na Figura 5.4. Ao serem considerados os comportamentos em função da concentração do azeite de oliva na mistura, observa-se que o componente R e o componente G possuem um maior grau de linearidade ao longo de sua faixa de variação, quando comparado ao componente B, pois este a partir da concentração 70% possui variação mínima.




FIGURA 5.2 – COMPORTAMENTO DO COMPONENTE R EM FUNÇÃO DA COMPOSIÇÃO




FIGURA 5.3 – COMPORTAMENTO DO COMPONENTE G EM FUNÇÃO DA COMPOSIÇÃO




FIGURA 5.4 – COMPORTAMENTO DO COMPONENTE B EM FUNÇÃO DA COMPOSIÇÃO

As amostras apresentadas na Figura 5.1 foram analisadas em um espectrofotômetro de UV-VIS para auxiliar a caracterização da mistura de azeite de soja e azeite de oliva. A Figura 5.5 apresenta os espectros brutos para todas as composições. Para fins de modelagem, foram selecionados

quatro picos e três vales em comprimentos de onda cuja absorvância apresentasse maior variância, indicando uma melhor diferenciação e evitando sobreposição de informações. A Tabela 5.1 apresenta os valores de absorvância para os comprimentos de onda selecionados.

TABELA 5.1 – VALORES DE ABSORBÂNCIA PARA COMPRIMENTOS DE ONDA SELECIONADOS

Massa	ABS374 (vale)	ABS416 (pico)	ABS427 (vale)	ABS455 (pico)	ABS460 (vale)	ABS483 (pico)	ABS670 (pico)
0	0,5067	0,2844	0,2025	0,0973	0,0870	0,0649	0,0649
10	0,6949	0,5486	0,4106	0,2669	0,2480	0,197	0,1194
20	0,7554	0,7444	0,5764	0,4347	0,4087	0,3382	0,1810
30	0,7362	0,8454	0,6747	0,5626	0,5324	0,4552	0,2378
40	0,8364	1,0668	0,8624	0,7460	0,7081	0,6099	0,3092
50	0,9548	1,3494	1,0999	0,9789	0,9300	0,8041	0,3942
60	1,0028	1,4551	1,1913	1,0700	1,0171	0,8814	0,4291
70	1,0936	1,7002	1,3998	1,2769	1,2149	1,0546	0,5052
80	1,1959	1,9269	1,5988	1,4733	1,4017	1,2202	0,5780
90	1,2778	2,1111	1,7649	1,6400	1,5602	1,3622	0,6418
100	1,3700	2,3018	1,9442	1,8206	1,7335	1,5172	0,7116

Os estudos de modelagem terão por objetivo a determinação de equações capazes de descrever o percentual de azeite de oliva nas misturas a partir das componentes R, G, B e as absorvâncias nos comprimentos de onda 374nm, 427nm, 455nm, 460nm, 483nm, 670nm. Desta forma, torna-se importante avaliar a correlação entre as variáveis. A Figura 5.6 apresenta a matriz de gráficos de correlação, ao passo que a Tabela 5.2 apresenta os valores dos coeficientes de correlação entre as variáveis.

TABELA 5.2 – MATRIZ DE CORRELAÇÕES

	Massa	R	G	B	ABS 374	ABS 416	ABS 427	ABS 455	ABS 460	ABS 483	ABS 670
Massa	1,00	-0,98	-1,00	-0,94	0,99	1,00	1,00	1,00	1,00	1,00	1,00
R	-0,98	1,00	0,99	0,87	-0,98	-0,98	-0,98	-0,99	-0,99	-0,99	-0,99
G	-1,00	0,99	1,00	0,93	-0,99	-0,99	-0,99	-0,99	-0,99	-0,99	-0,99
B	-0,94	0,87	0,93	1,00	-0,92	-0,94	-0,93	-0,93	-0,93	-0,93	-0,93
ABS374	0,99	-0,98	-0,99	-0,92	1,00	1,00	1,00	0,99	0,99	0,99	0,99
ABS416	1,00	-0,98	-0,99	-0,94	1,00	1,00	1,00	1,00	1,00	1,00	1,00
ABS427	1,00	-0,98	-0,99	-0,93	1,00	1,00	1,00	1,00	1,00	1,00	1,00
ABS455	1,00	-0,99	-0,99	-0,93	0,99	1,00	1,00	1,00	1,00	1,00	1,00
ABS460	1,00	-0,99	-0,99	-0,93	0,99	1,00	1,00	1,00	1,00	1,00	1,00
ABS483	1,00	-0,99	-0,99	-0,93	0,99	1,00	1,00	1,00	1,00	1,00	1,00
ABS670	1,00	-0,99	-0,99	-0,93	0,99	1,00	1,00	1,00	1,00	1,00	1,00

Analisando-se os resultados, observa-se que a variável dependente, percentual mássico de azeite de oliva, apresenta forte correlação com as absorvâncias e os componentes da análise de imagem. Desta forma, modelos lineares entre estas variáveis devem ser capazes de fazer a predição adequada da composição da mistura.

5.3 MODELAGEM

Foram desenvolvidos modelos matemáticos lineares, considerando todas as possíveis combinações entre as variáveis independentes, sendo os três componentes de cor R, G, B e as absorvâncias nos comprimentos de onda selecionados 374nm, 416nm, 427nm, 455nm, 460nm, 483nm, 670nm. A função objetivo para estimação de parâmetros foi a de mínimos quadrados, dada pela equação 5.1

$$\sum_{i=1}^{NE} (massa_i^{EXP} - massa_i^{MOD})^2 \quad (5.1)$$

TABELA 5.3 – ESTATÍSTICA DESCRITIVA: COMPONENTE R

Componente	Dados	Média	Mediana	Moda	Valor Mínimo	Valor Máximo	Quartil Inferior	Quartil Superior	Desvio Padrão (Medida)	Desvio Padrão (Média)	Assimetria	Curtose
R0	12272	173,03	173	173	164	182	172	174	1,98	0,0179	0,204	0,293
R10	12272	171,52	171	171	161	180	170	173	2,03	0,0183	0,124	-0,077
R20	12272	171,19	171	171	162	178	170	173	2,05	0,0185	-0,279	0,248
R30	12272	167,66	168	167	159	176	166	169	1,88	0,0170	0,093	0,616
R40	12272	165,13	165	166	131	175	163	167	2,63	0,0237	-0,053	2,624
R50	12272	163,51	164	164	154	171	162	165	2,05	0,0185	-0,099	0,162
R60	12272	160,17	160	160	147	169	159	162	2,11	0,0191	-0,124	0,023
R70	12272	157,81	158	158	150	166	157	159	1,72	0,0156	-0,122	0,306
R80	12272	154,52	155	154	138	163	154	156	1,59	0,0144	-0,180	1,842
R90	12272	150,20	150	150	137	159	149	152	2,08	0,0187	-0,282	0,810
R100	12272	144,97	145	145	134	155	143	147	2,44	0,0221	-0,120	0,163

TABELA 5.4 – ESTATÍSTICA DESCRITIVA: COMPONENTE G

Componente	Dados	Média	Mediana	Moda	Valor Mínimo	Valor Máximo	Quartil Inferior	Quartil Superior	Desvio Padrão (Medida)	Desvio Padrão (Média)	Assimetria	Curstose
G0	12272	189,79	190	189	182	198	189	191	1,82	0,0165	0,193	0,148
G10	12272	185,60	186	186	176	195	185	187	1,66	0,0150	-0,045	0,319
G20	12272	182,07	182	182	174	190	181	183	1,66	0,0150	0,077	0,445
G30	12272	177,21	177	177	169	185	176	178	1,54	0,0139	-0,089	0,981
G40	12272	174,07	174	175	140	185	172	176	2,66	0,0240	-0,093	2,219
G50	12272	171,86	172	171	165	181	170	173	2,02	0,0183	0,078	-0,290
G60	12272	167,99	168	168	158	177	167	169	1,74	0,0157	-0,002	0,358
G70	12272	165,35	165	165	158	173	164	166	1,61	0,0145	0,135	0,152
G80	12272	161,72	162	161	145	169	161	163	1,63	0,0147	-0,082	1,532
G90	12272	156,92	157	157	145	165	156	158	2,02	0,0182	-0,277	0,696
G100	12272	150,88	151	151	139	160	149	152	2,38	0,0215	-0,201	0,366




FIGURA 5.5 – ESPECTRO UV-VIS PARA DIFERENTES COMPOSIÇÕES

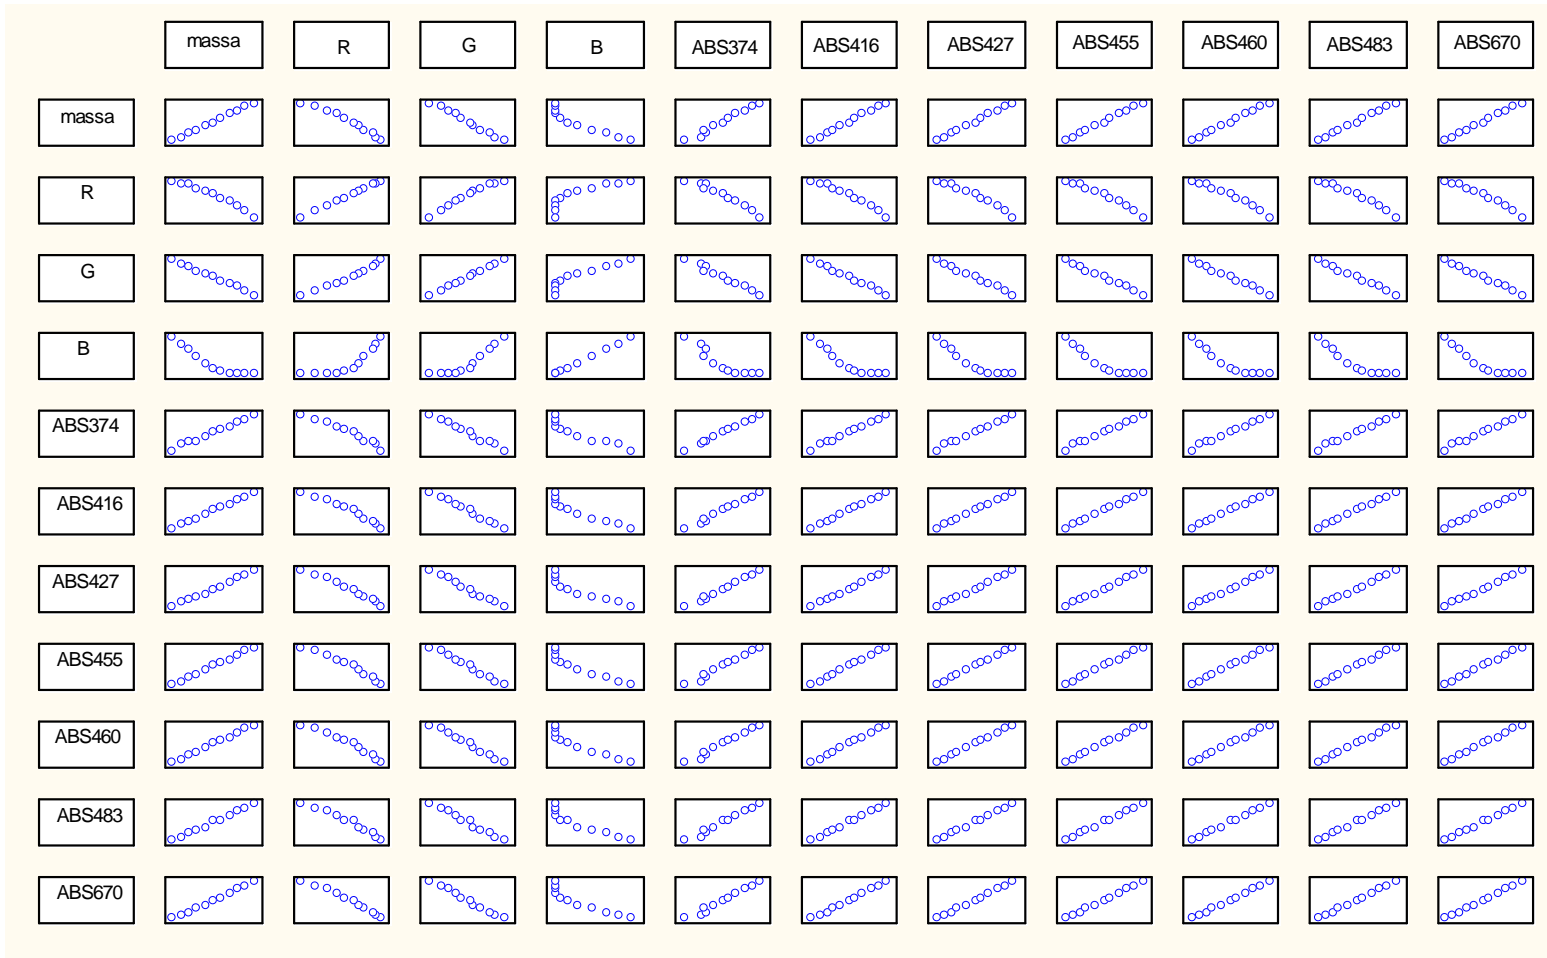


FIGURA 5.6 – GRÁFICO DE CORRELAÇÕES ENTRE DADOS

A estimação de parâmetros foi feita no software STATISTICA, usando o pacote de estimação não linear. Em todas as simulações foi utilizado o método de Levenberg-Marquadt (LEVENBERG, 1944) e (MARQUARDT, 1963) sendo adotado um único critério de convergência dado por 10^{-6} e a estimativa inicial de todos os parâmetros foi 10^{-1} .

Para análise, os modelos foram classificados conforme a quantidade de parâmetros, além de terem sido simuladas todas as combinações possíveis. Sendo que as classes são utilizadas para diferenciar o conjunto de possíveis combinações, facilitando a diferenciação e interpretação dos dados. Por exemplo, para modelos com dois parâmetros é possível obter as seguintes classes, resultando em 55 modelos:

- Classe 1: massa = $a_0 + a_1 \cdot \text{ABS}_m$ (Total: 07 modelos)
- Classe 2: massa = $a_0 \cdot \text{ABS}_m + a_1 \cdot \text{ABS}_n$; $m \neq n$ (Total: 21 modelos)
- Classe 3: massa = $a_0 \cdot \text{COR}_p + a_1 \cdot \text{ABS}_m$ (Total: 21 modelos)
- Classe 4: massa = $a_0 \cdot \text{COR}_p + a_1 \cdot \text{COR}_q$; $p \neq q$ (Total: 03 modelos)
- Classe 5: massa = $a_0 + a_1 \cdot \text{COR}_p$ (Total: 03 modelos)

Onde: m,n: comprimento de onda = 374, 416, 427, 455, 460, 483, 670

p, q: cor = R (Red); G(Green); B(Blue)

Para modelos com três parâmetros, obtém-se 165 modelos divididos em:

- Classe 1: massa = $a_0 + a_1 \cdot \text{COR}_p + a_2 \cdot \text{COR}_q$; (03 modelos)
- Classe 2: massa = $a_0 + a_1 \cdot \text{COR}_p + a_1 \cdot \text{ABS}_m$ (21 modelos)
- Classe 3: massa = $a_0 + a_1 \cdot \text{ABS}_m + a_1 \cdot \text{ABS}_n$; (21 modelos)
- Classe 4: massa = $a_0 \cdot \text{COR}_p + a_1 \cdot \text{COR}_q + a_2 \cdot \text{COR}_s$ (01 modelos)
- Classe 5: massa = $a_0 \cdot \text{COR}_p + a_1 \cdot \text{COR}_q + a_2 \cdot \text{ABS}_n$; (21 modelos)
- Classe 6: massa = $a_0 \cdot \text{COR}_p + a_1 \cdot \text{ABS}_m + a_2 \cdot \text{ABS}_n$ (63 modelos)
- Classe 7: massa = $a_0 \cdot \text{ABS}_m + a_1 \cdot \text{ABS}_n + a_2 \cdot \text{ABS}_o$; (35 modelos)

Onde: m, n, o: comprimento de onda = 374, 416, 427, 455, 460, 483, 670

p, q, s: cor = R (Red); G(Green); B(Blue)

A Tabela 5.6 (em apêndice) apresenta todas as simulações referentes a modelos de dois parâmetros. Sendo que para fins de modelagem, o parâmetro

foi considerado significativo quando o valor estimado, em módulo, é maior que o seu respectivo desvio padrão. A Tabela 5.7 (em apêndice) apresenta todas as simulações referentes a modelos de três parâmetros. Ressalta-se que os modelos são apresentados classificados a partir do valor da função objetivo da estimação de parâmetros. Para cada modelo, é mencionada a significância estatística do parâmetro.

A partir das Tabelas 5.6 e 5.7 foram selecionados os modelos que para cada classe apresentaram menor valor da função objetivo e todos os parâmetros significativos.

Uma análise estatística dos melhores modelos com dois parâmetros é apresentado na Tabela 5.8. São apresentados também os valores estimados para os parâmetros, bem como a covariância paramétrica.

Observa-se que o modelo de Classe três apresentou menor valor da função objetivo, bem como menores valores percentuais de desvio padrão paramétrico e também baixa covariância paramétrica. O modelo da Classe dois, que considera apenas absorbâncias, apresenta um valor para função objetivo pequeno, no entanto, a variância e covariância paramétrica são consideráveis. Desta forma, observa-se que modelos mistos levaram à melhor predição, provavelmente pelo fato dos componentes R, G e B representarem uma informação mais globalizada sobre a amostra, diferentemente das absorbâncias que são específicas para cada comprimento de onda.

TABELA 5.8 – MELHORES MODELOS DE DOIS PARÂMETROS

Modelos Classe 1	
$Massa = a_0 + a_1 \cdot ABS_{670}$	Função Objetivo: 19,34 $R^2 = 0,998$ $R = 0,999$ $a_0 = - 8,0970 \pm 0,925376$ $a_1 = + 153,1712 \pm 2,143286$ Covariância $_{a_0-a_1} = -1,74236$
Modelos Classe 2	
$Massa = a_0 \cdot ABS_{455} + a_1 \cdot ABS_{460}$	Função Objetivo: 15,57 $R^2 = 0,998$ $R = 0,999$ $a_0 = - 691,171 \pm 124,2507$ $a_1 = + 783,943 \pm 130,6696$ Covariância $_{a_0-a_1} = - 16235,7$

Modelos Classe 3	
Massa= $a_0 \cdot B + a_1 \cdot ABS460$	Função Objetivo: 14,56 $R^2 = 0,998$ $R = 0,999$ $a_0 = - 0,02760 \pm 0,004754$ $a_1 = + 57,58674 \pm 0,380916$ Covariância $_{a_0-a_1} = - 0,000425$
Modelos Classe 4	
Massa= $a_0 \cdot G + a_1 \cdot B$	Função Objetivo: 1794 $R^2 = 0,836$ $R = 0,914$ $a_0 = + 0,473708 \pm 0,035652$ $a_1 = - 0,562538 \pm 0,073728$ Covariância $_{a_0-a_1} = - 0,001888$
Modelos Classe 5	
Massa= $a_0 + a_1 \cdot G$	Função Objetivo: 87,71 $R^2 = 0,992$ $R = 0,996$ $a_0 = + 516,9256 \pm 13,98614$ $a_1 = - 2,7270 \pm 0,08150$ Covariância $_{a_0-a_1} = - 1,1373$

A Tabela 5.9 apresenta os resultados referentes aos melhores modelos com três parâmetros.

Em função do maior número de parâmetros, espera-se um menor valor da função objetivo para estes modelos, como pode ser observado no modelo da Classe cinco. Novamente, destaca-se que modelos envolvendo os componentes da análise de imagem R, G e B levam à parâmetros com menor desvio padrão percentual.

Ressalta-se a escolha de modelos com dois e três parâmetros por apresentarem uma maior verossimilhança e evitar uma possível sobre parametrização cuja consequência pode ser o ajuste de erros experimentais.

TABELA 5.9 – MELHORES MODELOS DE TRÊS PARÂMETROS

Modelos Classe 1	
Massa= $a_0 + a_1 \cdot R + a_2 \cdot B$	Função Objetivo: 32,73 $R^2 = 0,997$ $R = 0,998$ $a_0 = + 458,0915 \pm 21,95804$ $a_1 = - 2,4607 \pm 0,14173$ $a_2 = - 0,1784 \pm 0,02027$

	Covariância _{a0-a1} = - 3,1098 Covariância _{a0-a2} = + 0,3821 Covariância _{a1-a2} = - 0,00250
<hr/>	
Modelos Classe 2	
	Função Objetivo: 14,36 R ² =0,998 R =0,999 a0 = + 113,4428 ± 63,41639 a1 = - 0,6160 ± 0,33214 a2 = + 46,9862 ± 7,35177 Covariância _{a0-a1} = - 21,061 Covariância _{a0-a2} = - 464,129 Covariância _{a1-a2} = + 2,4282
Massa=a0+a1·G+a2·ABS460	
<hr/>	
Modelos Classe 3	
<i>NENHUM DOS MODELOS APRESENTOU TODOS OS PARÂMETROS SIGNIFICATIVOS</i>	
<hr/>	
Modelos Classe 4	
<i>NENHUM DOS MODELOS APRESENTOU TODOS OS PARÂMETROS SIGNIFICATIVOS</i>	
<hr/>	
Modelos Classe 5	
	Função Objetivo: 12,44 R ² =0,998 R =0,999 a0 = + 0,5547 ± 0,277813 a1 = - 0,5546 ± 0,256664 a2 = + 145,5607 ± 3,110822 Covariância _{a0-a1} = - 0,071296 Covariância _{a0-a2} = - 0,736703 Covariância _{a1-a2} = + 0,674913
Massa=a0·R+a1·G+a2·ABS670	
<hr/>	
Modelos Classe 6	
	Função Objetivo: 15,11 R ² =0,998 R =0,999 a0 = - 0,0466 ± 0,01020 a1 = - 58,6601 ± 24,97077 a2 = + 121,0319 ± 30,02383 Covariância _{a0-a1} = - 0,218949 Covariância _{a0-a2} = + 0,26269 Covariância _{a1-a2} = - 749,664
Massa=a0·B+a1·ABS416+a2·ABS427	
<hr/>	
Modelos Classe 7	
	Função Objetivo: 17,08 R ² =0,998 R =0,999 a0 = + 66,764 ± 55,02281 a1 = - 126,429 ± 88,63829 a2 = + 126,469 ± 30,16051 Covariância _{a0-a1} = - 4867,42 Covariância _{a0-a2} = + 1608,31 Covariância _{a1-a2} = - 2627,19
Massa=a0·ABS416+a1·ABS427 +a2·ABS483	
<hr/>	

A Figura 5.7 apresenta os resíduos da predição dos melhores modelos com dois parâmetros.

Observa-se que o melhor modelo, Classe três, também é o que apresenta menores resíduos para misturas com percentual de azeite oliva superior a 90%, levando a resíduos menores que 0,5.

Deve-se ressaltar que como a escala original é de 0-100, os resíduos são expressos em percentual. Desta forma, o modelo da Classe três leva a previsões com desvio na faixa de 0,5% para a composição da mistura, fato que leva uma objetividade e consistência na obtenção da fração mássica.

Observa-se que o uso dos componentes da análise de imagem acoplada à absorvância é mais atrativo do que apenas o uso de valores de absorvância para a predição da composição das misturas, como pode ser notado ao serem comparados os resíduos do modelo da Classe 03 com os resíduos dos modelos da Classe 01 e 02.

Os resíduos da predição dos melhores modelos com três parâmetros são apresentados na Figura 5.8. Observa-se que para misturas com percentual de azeite oliva superiores a 90%, os modelos da Classe seis e da Classe sete apresentam as melhores predições, novamente ressaltando a importância dos componentes da análise de imagem. Por outro lado, para misturas comerciais na região de 50%, o modelo da Classe um apresenta melhores predições, mais especificamente, inferior a 1%.

Assim sendo, verifica-se que o uso de análise de imagem, uma técnica de baixo custo, melhora os resultados de predição de composição de misturas de azeite de oliva.

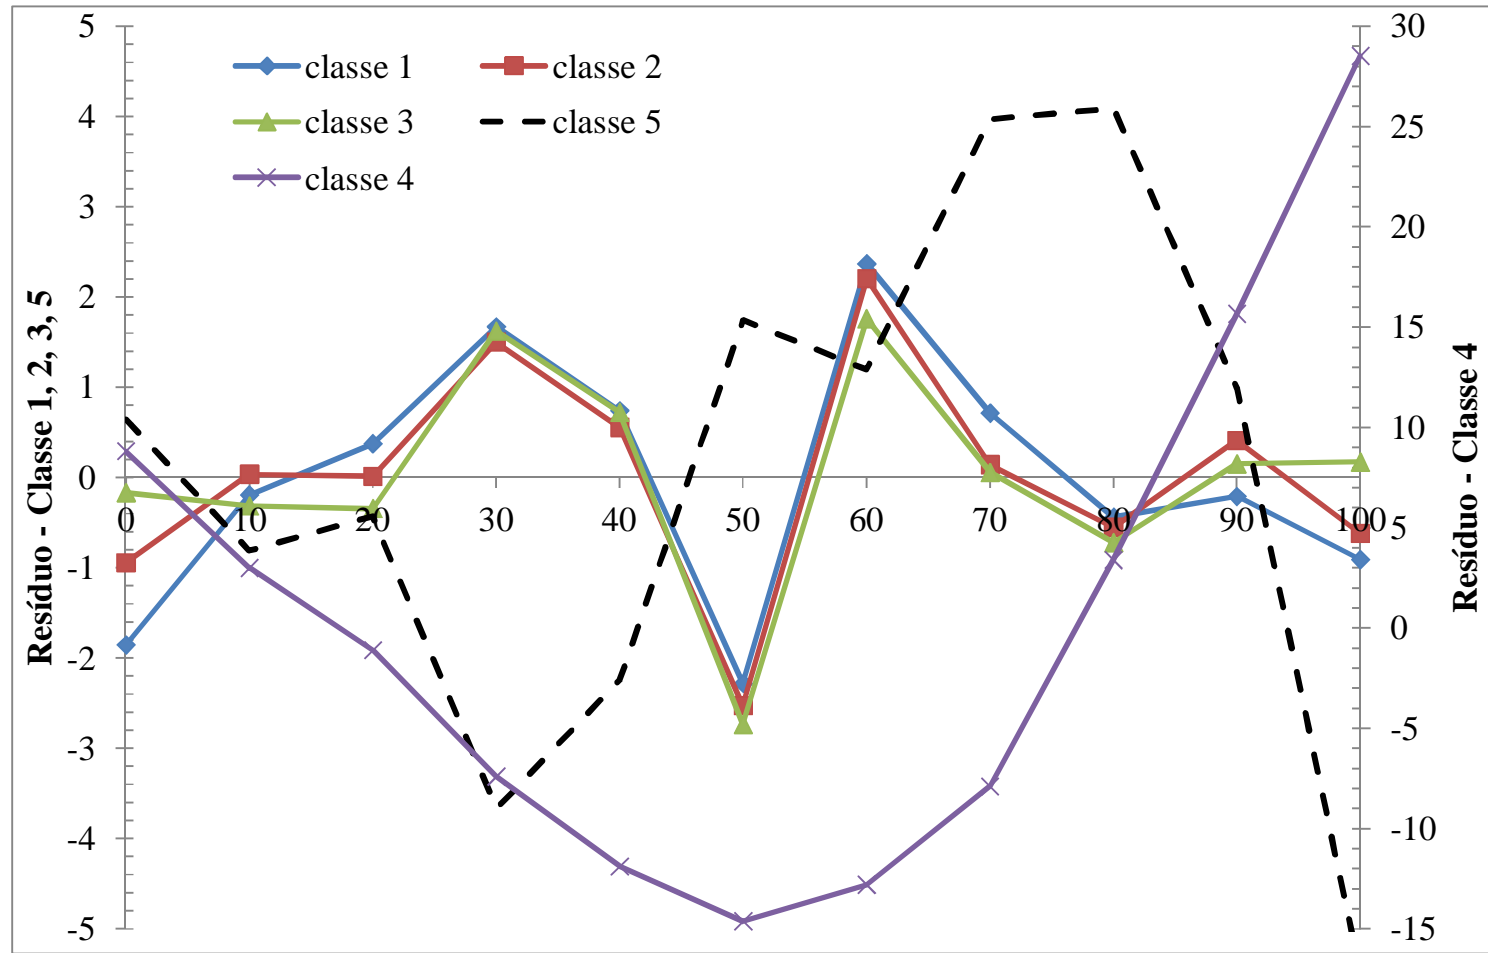


FIGURA 5.7 – RESÍDUOS DA PREDIÇÃO DOS MODELOS DE 02 PARÂMETROS DA TABELA 5.8

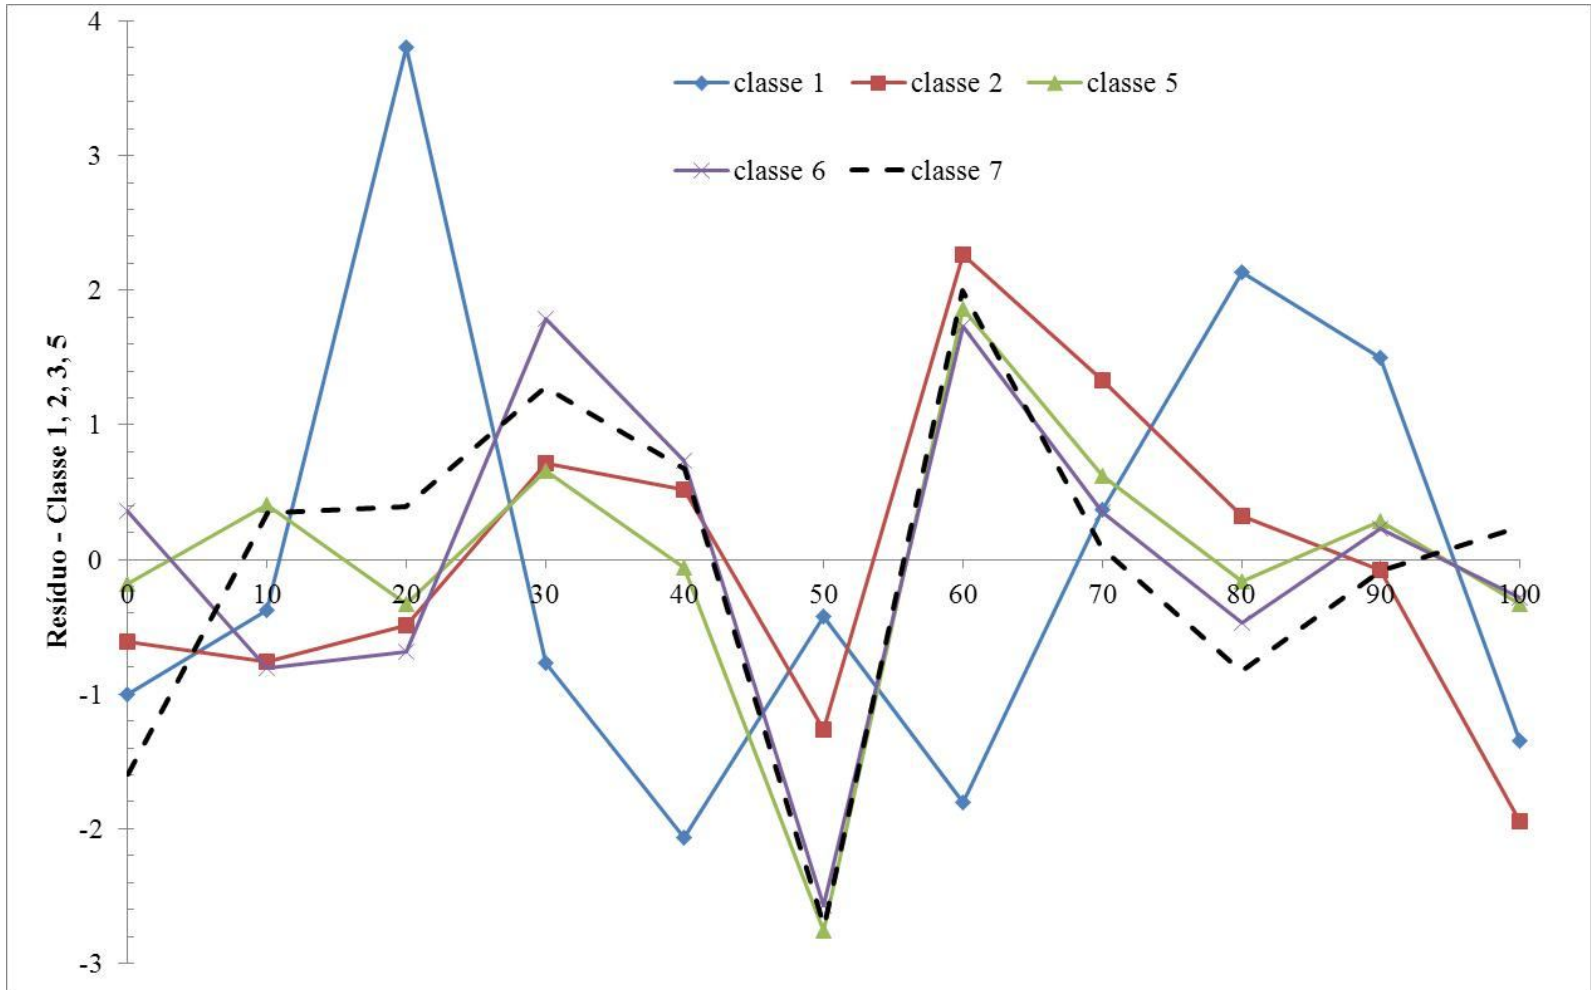


FIGURA 5.8 – RESÍDUOS DA PREDIÇÃO DOS MODELOS DE 03 PARAMETROS DA TABELA 5

Com intuito de validação da técnica, foi feita uma mistura teste com composição 25% de azeite de oliva a qual também foi fotografada e analisada com o software para decomposição de cor nos componentes R, G e B, bem como foi realizada uma análise espectrofotométrica de UV-VIS. Os dados referentes à análise estatística da imagem são apresentados na Tabela 5.10. A Tabela 5.11 apresenta os valores de absorvância para os comprimentos de onda selecionados para a modelagem. O desvio-padrão da predição do modelo é calculado com base em ISFER *et al.* (2010), assim, o desvio padrão da predição dos modelos de dois parâmetros é dado pela equação 5.2, ao passo que para os modelos de três parâmetros é dado pela equação 5.3.

$$s_{massa} = \sqrt{\left(\frac{\partial massa}{\partial a_0}\right)^2 \cdot s_{a_0}^2 + \left(\frac{\partial massa}{\partial a_1}\right)^2 \cdot s_{a_1}^2 + 2 \cdot \left(\frac{\partial massa}{\partial a_0}\right) \cdot \left(\frac{\partial massa}{\partial a_1}\right) \cdot s_{a_0-a_1}^2} \quad (5.2)$$

$$s_{massa} = \sqrt{\left(\frac{\partial massa}{\partial a_0}\right)^2 \cdot s_{a_0}^2 + \left(\frac{\partial massa}{\partial a_1}\right)^2 \cdot s_{a_1}^2 + \left(\frac{\partial massa}{\partial a_2}\right)^2 \cdot s_{a_2}^2 + 2 \cdot \left(\frac{\partial massa}{\partial a_0}\right) \cdot \left(\frac{\partial massa}{\partial a_1}\right) \cdot s_{a_0-a_1}^2 + 2 \cdot \left(\frac{\partial massa}{\partial a_0}\right) \cdot \left(\frac{\partial massa}{\partial a_2}\right) \cdot s_{a_0-a_2}^2 + 2 \cdot \left(\frac{\partial massa}{\partial a_1}\right) \cdot \left(\frac{\partial massa}{\partial a_2}\right) \cdot s_{a_1-a_2}^2} \quad (5.3)$$

As predições e os respectivos desvios padrão são apresentados na Tabela 5.12 para os modelos de dois parâmetros e na Tabela 5.13 para os modelos de três parâmetros. Ressalta-se que os valores das variáveis independentes (R, G, B, ABS374, ABS416, ABS455, ABS460, ABS483, ABS670) foram considerados com desvio padrão desprezíveis.

TABELA 5.10 – ANÁLISE DE IMAGEM DA AMOSTRA TESTE

RGB	Dados	Média	Mediana	Moda	Valor Mínimo	Valor Máximo	Quartil Inferior	Quartil Superior	Desvio Padrão - Medida	Desvio Padrão - Média	Assimetria	Curstose
Rteste	12272	168,64	169	169	159	177	167	170	2,05	0,0185	-0,077	-0,112
Gteste	12272	181,42	181	181	172	189	180	182	1,57	0,0142	-0,095	0,836
Bteste	12272	119,59	120	120	110	129	119	121	1,76	0,0158	-0,267	1,083

TABELA 5.11 – DADOS PARA VALIDAÇÃO DO MODELO (25% DE MASSA DE AZEITE DE OLIVA)

Massa	R	G	B	ABS374	ABS416	ABS427	ABS455	ABS460	ABS483	ABS670
Teste	168,64	181,42	119,59	0,70299	0,76925	0,61418	0,50627	0,47885	0,40993	0,21887

TABELA 5.12 – PREDIÇÃO DOS MODELOS DE DOIS PARÂMETROS

Classe	Modelos	Predição
1	Massa= $- 8,0970 + 153,1712 \cdot \text{ABS670}$ $s_{massa} = \sqrt{(1)^2 \cdot (0,925376)^2 + (\text{ABS670})^2 \cdot (2,143286)^2 + 2 \cdot (1) \cdot (\text{ABS670}) \cdot (-1,74236)}$	25,43 ± 0,56
2	Massa= $- 691,171 \cdot \text{ABS455} + 783,943 \cdot \text{ABS460}$ $s_{massa} = \sqrt{(\text{ABS455})^2 \cdot (124,2507)^2 + (\text{ABS460})^2 \cdot (130,6696)^2 + 2 \cdot (\text{ABS455}) \cdot (\text{ABS460}) \cdot (-16235,7)}$	25,47 ± 0,39
3	Massa= $- 0,02760 \cdot B + 57,58674 \cdot \text{ABS460}$ $s_{massa} = \sqrt{(B)^2 \cdot (0,004754)^2 + (\text{ABS460})^2 \cdot (0,380916)^2 + 2 \cdot (B) \cdot (\text{ABS460}) \cdot (-0,000425)}$	24,27 ± 0,56
4	Massa= $0,473708 \cdot G - 0,562538 \cdot B$ $s_{massa} = \sqrt{(G)^2 \cdot (0,035652)^2 + (B)^2 \cdot (0,073728)^2 + 2 \cdot (G) \cdot (B) \cdot (-0,001888)}$	18,67 ± 6,1
5	Massa= $516,9256 - 2,727 \cdot G$ $s_{massa} = \sqrt{(1)^2 \cdot (13,98614)^2 + (G)^2 \cdot (0,08150)^2 + 2 \cdot (1) \cdot (G) \cdot (-1,1373)}$	22,2 ± 1,3

Nota: Os dados utilizados para os cálculos são provenientes da Tabela 5.11

TABELA 5.13 – PREDIÇÃO DOS MODELOS DE TRÊS PARÂMETROS

Classe	Modelos	Predição
1	Massa= 458,0915 – 2,4607·R – 0,1784·B $s_{massa} = \sqrt{\frac{(1)^2 \cdot (21,95804)^2 + (R)^2 \cdot (0,14173)^2 + (B)^2 \cdot (0,02027)^2 + 2 \cdot (1) \cdot (R) \cdot (-3,1098) + 2 \cdot (1) \cdot (B) \cdot (0,3821) + 2 \cdot (R) \cdot (B) \cdot (-0,00250)}{}}$	21,79 ± 0,99
2	Massa= 113,4428 – 0,616·G + 46,9862·ABS460 $s_{massa} = \sqrt{\frac{(1)^2 \cdot (63,41639)^2 + (G)^2 \cdot (0,33214)^2 + (ABS460)^2 \cdot (7,35177)^2 + 2 \cdot (1) \cdot (G) \cdot (-21,061) + 2 \cdot (1) \cdot (ABS460) \cdot (-464,129) + 2 \cdot (G) \cdot (ABS460) \cdot (2,4282)}{}}$	24,19 ± 0,73
3	NENHUM DOS MODELOS APRESENTOU TODOS OS PARÂMETROS SIGNIFICATIVOS	
4	NENHUM DOS MODELOS APRESENTOU TODOS OS PARÂMETROS SIGNIFICATIVOS	
5	Massa= 0,5547·R – 0,5546·G + 145,5607·ABS670 $s_{massa} = \sqrt{\frac{(R)^2 \cdot (0,277813)^2 + (G)^2 \cdot (0,256664)^2 + (ABS670)^2 \cdot (3,110822)^2 + 2 \cdot (R) \cdot (G) \cdot (-0,071296) + 2 \cdot (R) \cdot (ABS670) \cdot (-0,736703) + 2 \cdot (G) \cdot (ABS670) \cdot (0,674913)}{}}$	24,79 ± 0,79
6	Massa= – 0,0466·B – 58,6601·ABS416 + 121,0319·ABS427 $s_{massa} = \sqrt{\frac{(B)^2 \cdot (0,01020)^2 + (ABS416)^2 \cdot (24,97077)^2 + (ABS427)^2 \cdot (30,02383)^2 + 2 \cdot (B) \cdot (ABS416) \cdot (-0,218949) + 2 \cdot (B) \cdot (ABS427) \cdot (0,26269) + 2 \cdot (ABS416) \cdot (ABS427) \cdot (-749,664)}{}}$	23,64 ± 0,66
7	Massa= 66,74·ABS416 – 126,429·ABS427 + 126,469·ABS483 $s_{massa} = \sqrt{\frac{(ABS416)^2 \cdot (55,02281)^2 + (ABS427)^2 \cdot (88,63829)^2 + (ABS483)^2 \cdot (30,16051)^2 + 2 \cdot (ABS416) \cdot (ABS427) \cdot (-4867,42) + 2 \cdot (ABS416) \cdot (ABS483) \cdot (+1608,31) + 2 \cdot (ABS427) \cdot (ABS483) \cdot (-2627,19)}{}}$	25,55 ± 0,45

Nota: Os dados utilizados para os cálculos são provenientes da Tabela 5.11

A Figura 5.9 apresenta a comparação das predições do modelo para amostra de 25%. Observa-se que apenas dois modelos, Classe 1 – 2 parâmetros e Classe 5 – 3 parâmetros contêm o valor teórico da predição em seu intervalo considerando apenas o desvio padrão. No entanto, ressalta-se que o modelo Classe 5 – 3 parâmetros apresenta melhor resultado pois o valor 25 está aproximadamente no centro do intervalo, o modelo em si apresenta menor valor da função objetivo, o que caracteriza predições com maior verossimilhança. Desta forma, ressalta-se que o uso da análise de imagem permitiu uma melhor caracterização da composição de misturas de azeite de oliva e óleo de soja, quando comparado apenas ao uso de medições de absorvância em análises espectrofotométricas de UV-VIS. Tal fato pode ser comprovado pela comparação das predições dos modelos de três parâmetros da Classe 5 com predição $24,79 \pm 0,79$ e Classe 7 com predição $25,55 \pm 0,45$.




FIGURA 5.9 – COMPARAÇÃO DAS PREDIÇÕES DOS MODELOS PARA AMOSTRA DE 25

6. CONCLUSÃO

Neste trabalho foram obtidos dados experimentais de misturas de azeite de oliva e óleo de soja, com variação em sua concentração mássica, através da espectrofotometria UV-VIS e componentes da imagem, a fim de avaliar a utilização das técnicas de análise de imagem na predição de concentração das misturas.

Os modelos desenvolvidos para atingir este objetivo, demonstram que ao utilizar os variáveis referentes ao componente da imagem e as variáveis referentes às absorvâncias juntamente, atinge-se um melhor desempenho na predição das concentrações, fato que pode ser comprovado pela predição do modelo de três parâmetros classe 5 e pelo modelo de três parâmetros classe 7, $24,69 \pm 0,79$ e $25,55 \pm 0,45$, respectivamente. Isto pode ser justificado pelo fato de que as informações provenientes da análise de imagem representam a amostra de forma mais globalizada, diferentemente das absorvâncias que são específicas para cada comprimento de onda.

Este trabalho pode demonstrar que a técnica de análise de imagem digital tem caráter promissor na indústria alimentícia, pois apresentou resultados objetivos e consistentes de forma rápida podendo auxiliar no desenvolvimento de sensores in-line e on-line auxiliando assim o controle automatizado de processos, tudo isto com técnicas simples.

REFERÊNCIAS

ALBUQUERQUE, M. P.; ALBUQUERQUE, M. P. **Processamento de Imagens: Métodos e Análises**. Centro Brasileiro de Pesquisas Físicas – CBPF/MCT-RJ, 2002.

AZEVEDO, E.; CONCI, A. **Computação Gráfica: Teoria e Prática**. Rio de Janeiro: Elsevier, 2003.

BRASIL. Lei nº7.678, de 08 de nov. de 1988, referente à produção, circulação e comercialização do vinho e derivados da uva e do vinho, e dá outras providências. **Diário Oficial [da] República Federativa do Brasil**, Poder Executivo, Brasília, DF, 08 de nov. 1988. Disponível em: extranet.agricultura.gov.br. Acesso em: 10 de jun. 2011.

BRASIL. Resolução RDC nº270, de 23 de set. de 2005 da Agência Nacional de Vigilância Sanitária do Ministério da Saúde. Aprova o Regulamento Técnico referente a Óleos Vegetais, Gorduras Vegetais e Creme Vegetal. **Diário Oficial [da] República Federativa do Brasil**, Poder Executivo, Brasília, DF, 23 set. 2005. Seção 1, nº 184, p.372-3. Disponível em: www.anvisa.gov.br. Acesso em: 10 nov. 2010.

BRASIL. Decreto nº6.871, de 04 de jun. de 2009. Regulamenta a Lei nº8.918, de 14 de jul. de 1994 referente à padronização, classificação, registro, inspeção, produção e fiscalização de bebidas. **Diário Oficial [da] República Federativa do Brasil**, Poder Executivo, Brasília, DF, 04 de jun. 2009. Disponível em: www.planalto.gov.br. Acesso em: 22 de jun. 2011.

BROSNAN, T.; SUN, W. Inspection and grading of agricultural and food products by computer vision systems – a review. **Computers and Electronics in Agriculture**, v.36, p.193-213, 2002.

BROSNAN, T.; SUN, W. Improving quality inspection of food products by computer vision – a review. **Journal of Food Engineering**, v.61, p.3-16, 2004.

CERNANDAS, E. DURÁN, M. L.; ANTEQUERA, T. Recognizing marbling in dry-cured Iberian ham by multiscale analysis. **Pattern Recognition Letters**, v.23, p.1311-1321, 2002.

CHEN, K. et. al. Color grading of beef fat by using computer vision and support vector machine. **Computers and Electronics in Agriculture**, v.70, p.27-32, 2010.

CHEN, Y. R.; CHAO, K.; KIM, M. S. Machine vision technology for agricultural applications. **Computers and Electronics in Agriculture**, v.36, p.173-191, 2002.

DAVIES, E.R. The application of machine vision to food and agriculture: a review. **The Imaging Science Journal**, v.57, p.197-217, 2009.

DEVAUX, M.F. *et.al.* Macro-vision and grey level granulometry for quantification of tomato pericarp structure. **Postharvest Biology and Technology**, v.47, p.199-2009, 2008.

DU, C.; SUN, W. Recent developments in the applications of image processing techniques for food quality evaluation. **Trends in Food Science & Technology**, v.15, p.230-249, 2004)

DU, C.; SUN, W. Pizza sauce spread classification using colour vision and support vector machines. **Journal of Food Engineering**, v.66, p.137-145, 2005.

DU, C.; SUN, W. Learning techniques used in computer vision for food quality evaluation: a review. **Journal of Food Engineering**, v.72, p.39-55, 2006.

DURMUS, E.F. *et. al.* Size properties of legume seeds of different varieties using image analysis. **Journal of Food Engineering**, v.99, p.445-441, 2010.

FACON, J. **Processamento e análise de imagem**. Cordoba: Universidad nacional, 1993.

FACUCITANO, L. *et. al.* Application of computer image analysis to measure pork marbling characteristics. **Meat Science**, v.69, p.537-543, 2005.

FILHO, O. M.; NETO, H.V. **Processamento Digital de Imagens**. Rio de Janeiro: Brasport, 1999.

FURFERI, R.; CARFAGNI, M.; DAOU, M. Artificial neural network software for real-time estimation of olive oil qualitative parameters during continuous extraction. **Computers and Electronics in Agriculture**, v.55, p.115-131, 2007.

GONZALEZ, R. C.; WOODS, R. E. **Processamento de Imagens Digitais**. São Paulo: Edgard Blucher, 2000.

GRANDO, N. **Segmentação de imagens tomográficas visando a construção de modelos médicos**. 113f. Dissertação (Mestrado) – Programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial, CEFET-PR, Curitiba, 2005.

GUNASEKARAN, S. Computer vision technology for food quality assurance. **Trends in Food Science & Technology**, v.7, p.245-256, 1996.

JACKMAN, P. et. al. Prediction of beef eating quality from colour, marbling and wavelet texture features. **Meat Science**, v.80, p.1273-1281, 2008.

HATCHER, D. W.; SYMONS, S. J.; MANIVANNAN, U. Developments in the use of image analysis for the assessment of oriental noodle appearance and colour. **Journal of Food Engineering**, v.61, p.109-117, 2004.

HATEM, I.; TAN, J.; GERRARD, D. E. Determination of animal skeletal maturity by image processing. **Meat Science**, v.65, p.999-1004, 2003.

ISFER,L.A.D; LENZI,M.K.; LENZI,E.K. Identification of biochemical reactors using fractional differential equations, **Latin American Applied Research**, v. 40, p.193-198, 2010.

JAHNS, G.; NIELSEN, H. M.; PAUL, W. Measuring image analysis attributes and modelling fuzzy consumer aspects for tomato quality grading. **Computers and Electronics in Agriculture**, v.31, p.17-29, 2001.

JELINSKI, T.; DU, C.; SUN, W.; FORNAL, J. Inspection of the distribution and amount of ingredients in pasteurized cheese by computer vision. **Journal of Food Engineering**, v.83, p.3-9, 2007.

KONOPKA, I.; KOZIROK, W.; ROTKIEWICZ, D. Lipids and carotenoids of wheat grain and flour and attempt of correlating them with digital image analysis of kernel surface and cross-sections. **Food Research International**, v.37, p.429-438, 2004.

KOYA, T. K. **Sistema Automático para Contagem das Células do Sangue**. (Dissertação de mestrado). Universidade Federal do Rio Grande do Sul – UFRGS, Porto Alegre, 2001)

LANA, M. M.; TIJSKENS, L. M. M.; KOOTEN, O. Effects of storage temperature and stage of ripening on RGB colour aspects of fresh-cut tomato pericarp using video image analysis. **Journal of Food Engineering**, v.77, p.871-879, 2006).

LEEMANS, V.; MAGEIN, H.; DESTAIN, M.-F. On-line Fruit Grading according to their External Quality using Machine Vision. **Biosystems Engineering**, v.83, p.397-404, 2002.

LEEMANS, V.; MAGEIN, H.; DESTAIN, M. F. Defect segmentation on 'Jonagold apples using colour vision and a Bayesian classification method. **Computers and Electronics in Agriculture**, v.23, p.43-53, 1999.

LEVENBERG, K. A method for the solution of certain problems in least squares. **Quarterly of Applied Mathematics**, v.2, p.164-168, 1944.

LOPES, J. M. B. **Cor e luz**.47f. Texto (Disciplina de Computação Gráfica) – Licenciatura em Engenharia Informática e de Computadores, Instituto Superior Técnico, Universidade Técnica de Lisboa, 2008.

LOUKA, N. *et al.* A novel colorimetry analysis used to compare different drying fish processes. **Food Control**, v.15, p.327-334, 2004.

LU, J. *et al.* Evaluation of pork color by using computer vision. **Meat Science**, v.56, p.57-60, 2000.

MACHADO, A. M. L. **Extração automática de contornos de edificações utilizando imagem gerada por câmara digital de pequeno formato e dados lidar**. 213f. Tese (Doutorado em Ciências Geodésicas) – Setor de ciências da Terra, Universidade Federal do Paraná, Curitiba, 2006.

MARQUARDT, D. An algorithm for least-squares estimation of nonlinear parameters. **SIAM Journal on Applied Mathematics**, v.11, p.431-441, 1963.

MARTIN, M. L. G. M. *et al.* Measuring colour appearance of red wines. **Food Quality and Preference**, v.18, p.862-871, 2007.

NAGATA, M.; TALLADA, J.G. Quality Evaluating of Strawberries. **Computer Vision Technology for Food Quality Evaluation**, p.265-287, 2008.

NARENDRA, V. G.; HAREESH, K. S. Quality Inspection and Grading of Agricultural and Food Products by Computer Vision – a review. **International Journal of Computer Applications**, v.2, p.43-65, 2010.

O'SULLIVAN, M. G. *et al.* Evaluation of pork colour: prediction of visual sensory quality of meat from instrumental and computer vision methods of colour analysis. **Meat Science**, v.65, p.909-918, 2003.

PAULUS, I.; SCHREVEENS, E. Evaluating and Modelling the Size Classification of Apples. **J. agric. Engng. Res.**, v.74, p.411-419, 1999.

PAULUS, I.; BUSSCHER, R.; SCHREVEENS, E. Use of Image Analysis to Investigate Human Quality Classification of Apples. **J. Agric. Engng Res.**, v.68, p.341-353, 1997.

PEDRESCHI, F. *et al.* Development of a computer vision system to measure the color of potato chips. **Food Research International**, v.39, p.1092-1098, 2006.

QUEVEDO, R. *et. al.* Description of the kinetic enzymatic browning in banana (*Musa Cavendish*) slices using non-uniform color information from digital images. **Food Research International**, v.42, p.1309-1314, 2009a.

QUEVEDO, R. *et. al.* Quantification of enzymatic browning in apple slices applying the fractal texture Fourier image. **Journal of Food Engineering**, v.95, p.285-290, 2009b.

ROCCULI, P. *et. al.* Effects of the application of anti-browning substances on the metabolic activity and sugar composition of fresh-cut potatoes. **Postharvest Biology and Technology**, v.43, p.151-157, 2007.

ROMANI, S. *et. al.* Image characterization of potato chip appearance during frying. **Journal of Food Engineering**, v.93, p.487-494, 2009.

SILVA, L. C.; PEREIRA, A.; PUNCHIHEWA, A. **Food Classification using Color Imaging**. Texto – Institute of Information Sciences and Technology, Massey University, New Azealand, [20--].

STEINMETZ, V. *et al.* On-line Fusion of Colour Camera and Spectrophotometer for Sugar Content Prediction of Apples. **J. Agric. Engng Res.**, v.73, p.207-216, 1999.

SUN, W. Inspecting pizza topping percentage and distribution by a computer vision method. **Journal of Food Engineering**, v.44, p.245-249, 2000.

SUN, W. Computer vision – na objective, rapid and non-contact quality evaluation tool for the food industry, editorial. **Journal of Food Engineering**, v.61, p.1-2, 2004.

THYBO, A. K. *et. al.* Prediction of sensory texture quality attributes of cooked potatoes by NMR-imaging (MRI) of raw potatoes in combination with different image analysis methods. **Journal of Food Engineering**, v.61, p.91-100, 2004.

XIABO, Z.; JIEWEN, Z.; YANXIAO, L. Apple color grading based on organization feature parameters. **Pattern Recognition Letters**, v.28, p.2046-2053, 2007.

YAM, K. L.; PAPADAKIS, S.E. A simple digital imaging method for measuring and analyzing color of food surfaces. **Journal of Food Engineering**, v.61, p.137-142, 2004.

ZHENG, C.; SUN, D.W.; ZHENG, L. Recent developments and applications of image features for food quality evaluation and inspection – a review. **Food Science & Technology**, v.17, p.642-655, 2006a.

ZHENG, C.; SUN, W.; ZHENG, L. Recent applications of image texture for evaluation of food qualities – a review. **Trends in Food Science & Technology**, v.17, p.113-128, 2006b.

ZHENG, C.; SUN, W.; ZHENG, L. Correlating colour to moisture content of large cooked beef joints by computer vision. **Journal of Food Engineering**, v.77, p.858-863, 2006c.

APÊNDICE

TABELA 5.6 – MODELOS DE DOIS PARÂMETROS

Modelos Classe 1	
Massa= $a_0+a_1 \cdot \text{ABS670}$	Função Objetivo: 19,34 $R^2 = 0,998$ $R = 0,999$ Parâmetros significativos
Massa= $a_0+a_1 \cdot \text{ABS483}$	Função Objetivo: 20,23 $R^2 = 0,998$ $R = 0,999$ Parâmetros significativos
Massa= $a_0+a_1 \cdot \text{ABS460}$	Função Objetivo: 20,54 $R^2 = 0,998$ $R = 0,999$ Parâmetros significativos
Massa= $a_0+a_1 \cdot \text{ABS455}$	Função Objetivo: 21,22 $R^2 = 0,998$ $R = 0,999$ Parâmetros significativos
Massa= $a_0+a_1 \cdot \text{ABS427}$	Função Objetivo: 30,66 $R^2 = 0,997$ $R = 0,998$ Parâmetros significativos
Massa= $a_0+a_1 \cdot \text{ABS416}$	Função Objetivo: 34,58 $R^2 = 0,996$ $R = 0,998$ Parâmetros significativos
Massa= $a_0+a_1 \cdot \text{ABS374}$	Função Objetivo: 206,4 $R^2 = 0,981$ $R = 0,990$ Parâmetros significativos
Modelos Classe 2	
Massa= $a_0 \cdot \text{ABS455}+a_1 \cdot \text{ABS460}$	Função Objetivo: 15,57 $R^2 = 0,998$ $R = 0,999$ Parâmetros significativos
Massa= $a_0 \cdot \text{ABS427}+a_1 \cdot \text{ABS460}$	Função Objetivo: 18,94 $R^2 = 0,998$ $R = 0,999$ Parâmetros significativos
Massa= $a_0 \cdot \text{ABS374}+a_1 \cdot \text{ABS460}$	Função Objetivo: 19,09 $R^2 = 0,998$ $R = 0,999$ Parâmetros significativos
Massa= $a_0 \cdot \text{ABS374}+a_1 \cdot \text{ABS455}$	Função Objetivo: 19,56 $R^2 = 0,998$ $R = 0,999$

	Parâmetros significativos
Massa= $a_0 \cdot \text{ABS427} + a_1 \cdot \text{ABS455}$	Função Objetivo: 19,65 $R^2 = 0,998$ $R = 0,999$
	Parâmetros significativos
Massa= $a_0 \cdot \text{ABS374} + a_1 \cdot \text{ABS483}$	Função Objetivo: 19,77 $R^2 = 0,998$ $R = 0,999$
	Parâmetros significativos
Massa= $a_0 \cdot \text{ABS427} + a_1 \cdot \text{ABS483}$	Função Objetivo: 20,22 $R^2 = 0,998$ $R = 0,999$
	Parâmetros significativos
Massa= $a_0 \cdot \text{ABS374} + a_1 \cdot \text{ABS427}$	Função Objetivo: 20,58 $R^2 = 0,998$ $R = 0,999$
	Parâmetros significativos
Massa= $a_0 \cdot \text{ABS416} + a_1 \cdot \text{ABS460}$	Função Objetivo: 20,84 $R^2 = 0,998$ $R = 0,999$
	Parâmetros significativos
Massa= $a_0 \cdot \text{ABS374} + a_1 \cdot \text{ABS416}$	Função Objetivo: 20,87 $R^2 = 0,998$ $R = 0,999$
	Parâmetros significativos
Massa= $a_0 \cdot \text{ABS455} + a_1 \cdot \text{ABS483}$	Função Objetivo: 21,28 $R^2 = 0,998$ $R = 0,999$
	Parâmetros significativos
Massa= $a_0 \cdot \text{ABS416} + a_1 \cdot \text{ABS483}$	Função Objetivo: 21,42 $R^2 = 0,998$ $R = 0,999$
	Parâmetros significativos
Massa= $a_0 \cdot \text{ABS483} + a_1 \cdot \text{ABS670}$	Função Objetivo: 21,54 $R^2 = 0,998$ $R = 0,999$
	Parâmetros significativos
Massa= $a_0 \cdot \text{ABS416} + a_1 \cdot \text{ABS455}$	Função Objetivo: 21,84 $R^2 = 0,998$ $R = 0,999$
	Parâmetros significativos
Massa= $a_0 \cdot \text{ABS460} + a_1 \cdot \text{ABS483}$	Função Objetivo: 22,96 $R^2 = 0,997$ $R = 0,998$
	Parâmetros significativos
Massa= $a_0 \cdot \text{ABS374} + a_1 \cdot \text{ABS670}$	Função Objetivo: 23,37 $R^2 = 0,997$ $R = 0,998$
	Parâmetros significativos
Massa= $a_0 \cdot \text{ABS416} + a_1 \cdot \text{ABS670}$	Função Objetivo: 51,76

	$R^2 = 0,995$ $R = 0,997$ Parâmetros significativos
$Massa = a_0 \cdot ABS416 + a_1 \cdot ABS427$	Função Objetivo: 54,62 $R^2 = 0,995$ $R = 0,997$ Parâmetros significativos
$Massa = a_0 \cdot ABS460 + a_1 \cdot ABS670$	Função Objetivo: 26,76 $R^2 = 0,997$ $R = 0,998$ Parâmetros significativos
$Massa = a_0 \cdot ABS455 + a_1 \cdot ABS670$	Função Objetivo: 30,66 $R^2 = 0,997$ $R = 0,998$ Parâmetros significativos
$Massa = a_0 \cdot ABS427 + a_1 \cdot ABS670$	Função Objetivo: 71,07 $R^2 = 0,993$ $R = 0,996$ Parâmetros significativos
Modelos Classe 3	
$Massa = a_0 \cdot B + a_1 \cdot ABS460$	Função Objetivo: 14,56 $R^2 = 0,998$ $R = 0,999$ Parâmetros significativos
$Massa = a_0 \cdot B + a_1 \cdot ABS455$	Função Objetivo: 14,64 $R^2 = 0,998$ $R = 0,999$ Parâmetros significativos
$Massa = a_0 \cdot B + a_1 \cdot ABS483$	Função Objetivo: 14,69 $R^2 = 0,998$ $R = 0,999$ Parâmetros significativos
$Massa = a_0 \cdot B + a_1 \cdot ABS670$	Função Objetivo: 15,60 $R^2 = 0,998$ $R = 0,999$ Parâmetros significativos
$Massa = a_0 \cdot G + a_1 \cdot ABS670$	Função Objetivo: 18,64 $R^2 = 0,998$ $R = 0,999$ Parâmetros significativos
$Massa = a_0 \cdot R + a_1 \cdot ABS670$	Função Objetivo: 19,70 $R^2 = 0,998$ $R = 0,999$ Parâmetros significativos
$Massa = a_0 \cdot G + a_1 \cdot ABS483$	Função Objetivo: 19,95 $R^2 = 0,998$ $R = 0,999$ Parâmetros significativos
$Massa = a_0 \cdot G + a_1 \cdot ABS460$	Função Objetivo: 20,11 $R^2 = 0,998$

	R =0,999 Parâmetros significativos
Massa= $a_0 \cdot R + a_1 \cdot ABS483$	Função Objetivo: 20,33 $R^2 = 0,998$ R =0,999 Parâmetros significativos
Massa= $a_0 \cdot R + a_1 \cdot ABS460$	Função Objetivo: 20,60 $R^2 = 0,998$ R =0,999 Parâmetros significativos
Massa= $a_0 \cdot G + a_1 \cdot ABS455$	Função Objetivo: 20,75 $R^2 = 0,998$ R =0,999 Parâmetros significativos
Massa= $a_0 \cdot R + a_1 \cdot ABS455$	Função Objetivo: 21,30 $R^2 = 0,998$ R =0,999 Parâmetros significativos
Massa= $a_0 \cdot B + a_1 \cdot ABS427$	Função Objetivo: 25,53 $R^2 = 0,997$ R =0,998 Parâmetros significativos
Massa= $a_0 \cdot G + a_1 \cdot ABS427$	Função Objetivo: 29,02 $R^2 = 0,997$ R =0,998 Parâmetros significativos
Massa= $a_0 \cdot R + a_1 \cdot ABS427$	Função Objetivo: 30,40 $R^2 = 0,997$ R =0,998 Parâmetros significativos
Massa= $a_0 \cdot G + a_1 \cdot ABS416$	Função Objetivo: 31,78 $R^2 = 0,997$ R =0,998 Parâmetros significativos
Massa= $a_0 \cdot R + a_1 \cdot ABS416$	Função Objetivo: 32,91 $R^2 = 0,997$ R =0,998 Parâmetros significativos
Massa= $a_0 \cdot B + a_1 \cdot ABS416$	Função Objetivo: 45,80 $R^2 = 0,995$ R =0,997 Parâmetros significativos
Massa= $a_0 \cdot R + a_1 \cdot ABS374$	Função Objetivo: 178,3 $R^2 = 0,983$ R =0,991 Parâmetros significativos
Massa= $a_0 \cdot G + a_1 \cdot ABS374$	Função Objetivo: 163,8 $R^2 = 0,985$ R =0,992 Parâmetros significativos

Massa= $a_0 \cdot B + a_1 \cdot ABS374$	Função Objetivo: 246,2 $R^2 = 0,977$ $R = 0,988$ Parâmetros significativos
Modelos Classe 4	
Massa= $a_0 \cdot G + a_1 \cdot B$	Função Objetivo: 1794 $R^2 = 0,836$ $R = 0,914$ Parâmetros significativos
Massa= $a_0 \cdot R + a_1 \cdot B$	Função Objetivo: 1813 $R^2 = 0,835$ $R = 0,913$ Parâmetros significativos
Massa= $a_0 \cdot R + a_1 \cdot G$	Função Objetivo: 3418 $R^2 = 0,689$ $R = 0,830$ Parâmetros significativos
Modelos Classe 5	
Massa= $a_0 + a_1 \cdot G$	Função Objetivo: 87,71 $R^2 = 0,992$ $R = 0,996$ Parâmetros significativos
Massa= $a_0 + a_1 \cdot R$	Função Objetivo: 349,5 $R^2 = 0,968$ $R = 0,983$ Parâmetros significativos
Massa= $a_0 + a_1 \cdot B$	Função Objetivo: 1266 $R^2 = 0,884$ $R = 0,940$ Parâmetros significativos

TABELA 5.7 – MODELOS DE TRÊS PARÂMETROS

Modelos Classe 1	
Massa= $a_0 + a_1 \cdot R + a_2 \cdot B$	Função Objetivo: 32,73 $R^2 = 0,997$ $R = 0,998$ Parâmetros significativos
Massa= $a_0 + a_1 \cdot G + a_2 \cdot B$	Função Objetivo: 59,72 $R^2 = 0,994$ $R = 0,997$ Parâmetros significativos
Massa= $a_0 + a_1 \cdot R + a_2 \cdot G$	Função Objetivo: 87,31 $R^2 = 0,992$ $R = 0,996$ Parâmetro a_1 não significativo
Modelos Classe 2	
Massa= $a_0 + a_1 \cdot B + a_2 \cdot ABS483$	Função Objetivo: 13,35 $R^2 = 0,998$

	R =0,999 Parâmetro a0 não significativo
Massa=a0+a1*B+a2*ABS670	Função Objetivo: 13,95 R ² =0,998 R =0,999 Parâmetro a0 não significativo
Massa=a0+a1*B+a2*ABS460	Função Objetivo: 14,31 R ² =0,998 R =0,999 Parâmetro a0 não significativo
Massa=a0+a1*G+a2*ABS460	Função Objetivo: 14,36 R ² =0,998 R =0,999 Parâmetros significativos
Massa=a0+a1*B+a2*ABS455	Função Objetivo: 14,44 R ² =0,998 R =0,999 Parâmetro a0 não significativo
Massa=a0+a1*G+a2*ABS670	Função Objetivo: 14,48 R ² =0,998 R =0,999 Parâmetros significativos
Massa=a0+a1*G+a2*ABS455	Função Objetivo: 14,77 R ² =0,998 R =0,999 Parâmetros significativos
Massa=a0+a1*G+a2*ABS483	Função Objetivo: 14,85 R ² =0,998 R =0,999 Parâmetros significativos
Massa=a0+a1*G+a2*ABS416	Função Objetivo: 17,33 R ² =0,998 R =0,999 Parâmetros significativos
Massa=a0+a1*R+a2*ABS670	Função Objetivo: 18,86 R ² =0,998 R =0,999 Parâmetro a0 e a1 não significativos
Massa=a0+a1*R+a2*ABS483	Função Objetivo: 19,87 R ² =0,998 R =0,999 Parâmetro a0 e a1 não significativos
Massa=a0+a1*R+a2*ABS460	Função Objetivo: 20,49 R ² =0,998 R =0,999 Parâmetro a0 e a1 não significativos

Massa= $a_0+a_1*R+a_2*ABS455$	Função Objetivo: 21,16 $R^2 = 0,998$ $R = 0,999$ Parâmetro a_0 e a_1 não significativos
Massa= $a_0+a_1*B+a_2*ABS427$	Função Objetivo: 21,44 $R^2 = 0,998$ $R = 0,999$ Parâmetros significativos
Massa= $a_0+a_1*B+a_2*ABS416$	Função Objetivo: 30,15 $R^2 = 0,997$ $R = 0,998$ Parâmetros significativos
Massa= $a_0+a_1*R+a_2*ABS427$	Função Objetivo: 30,35 $R^2 = 0,997$ $R = 0,998$ Parâmetro a_0 não significativo
Massa= $a_0+a_1*R+a_2*ABS416$	Função Objetivo: 30,39 $R^2 = 0,997$ $R = 0,998$ Parâmetro a_0 não significativo
Massa= $a_0+a_1*G+a_2*ABS374$	Função Objetivo: 61,83 $R^2 = 0,994$ $R = 0,997$ Parâmetros significativos
Massa= $a_0+a_1*B+a_2*ABS374$	Função Objetivo: 127,8 $R^2 = 0,988$ $R = 0,994$ Parâmetros significativos
Massa= $a_0+a_1*R+a_2*ABS427$	Função Objetivo: 145,7 $R^2 = 0,986$ $R = 0,993$ Parâmetros significativos
Modelos Classe 3	
Massa= $a_0+a_1*ABS455+a_2*ABS460$	Função Objetivo: 15,19 $R^2 = 0,998$ $R = 0,999$ Parâmetro a_0 não significativo
Massa= $a_0+a_1*ABS416+a_2*ABS670$	Função Objetivo: 18,76 $R^2 = 0,998$ $R = 0,999$ Parâmetro a_1 não significativo
Massa= $a_0+a_1*ABS374+a_2*ABS460$	Função Objetivo: 18,87 $R^2 = 0,998$ $R = 0,999$ Parâmetros a_0 e a_1 não significativos
Massa= $a_0+a_1*ABS427+a_2*ABS460$	Função Objetivo: 18,93 $R^2 = 0,998$ $R = 0,999$

	Parâmetros a0 e a1 não significativos
Massa= $a_0+a_1*ABS374+a_2*ABS427$	Função Objetivo: 19,10 $R^2 = 0,998$ $R = 0,999$ Parâmetro a0 não significativo
Massa= $a_0+a_1*ABS460+a_2*ABS670$	Função Objetivo: 19,18 $R^2 = 0,998$ $R = 0,999$ Parâmetros a1 e a2 não significativos
Massa= $a_0+a_1*ABS427+a_2*ABS670$	Função Objetivo: 19,26 $R^2 = 0,998$ $R = 0,999$ Parâmetro a1 não significativo
Massa= $a_0+a_1*ABS455+a_2*ABS670$	Função Objetivo: 19,27 $R^2 = 0,998$ $R = 0,999$ Parâmetros a1 e a2 não significativos
Massa= $a_0+a_1*ABS374+a_2*ABS455$	Função Objetivo: 19,33 $R^2 = 0,998$ $R = 0,999$ Parâmetros a0 e a1 não significativos
Massa= $a_0+a_1*ABS374+a_2*ABS455$	Função Objetivo: 19,34 $R^2 = 0,998$ $R = 0,999$ Parâmetros a0 e a1 não significativos
Massa= $a_0+a_1*ABS483+a_2*ABS670$	Função Objetivo: 19,34 $R^2 = 0,998$ $R = 0,999$ Parâmetros a0, a1 e a2 não significativos
Massa= $a_0+a_1*ABS427+a_2*ABS455$	Função Objetivo: 19,64 $R^2 = 0,998$ $R = 0,999$ Parâmetros a0 e a1 não significativos
Massa= $a_0+a_1*ABS374+a_2*ABS483$	Função Objetivo: 19,77 $R^2 = 0,998$ $R = 0,999$ Parâmetros a0 e a1 não significativos
Massa= $a_0+a_1*ABS374+a_2*ABS416$	Função Objetivo: 19,94 $R^2 = 0,998$ $R = 0,999$ Parâmetro a0 não significativo
Massa= $a_0+a_1*ABS427+a_2*ABS483$	Função Objetivo: 20,01

	$R^2 = 0,998$ $R = 0,999$ Parâmetros a_0 e a_1 não significativos
$Massa = a_0 + a_1 * ABS455 + a_2 * ABS483$	Função Objetivo: 20,15 $R^2 = 0,998$ $R = 0,999$ Parâmetros a_0 , a_1 e a_2 não significativos
$Massa = a_0 + a_1 * ABS416 + a_2 * ABS483$	Função Objetivo: 20,20 $R^2 = 0,998$ $R = 0,999$ Parâmetros a_0 e a_1 não significativos
$Massa = a_0 + a_1 * ABS460 + a_2 * ABS483$	Função Objetivo: 20,21 $R^2 = 0,998$ $R = 0,999$ Parâmetros a_1 e a_2 não significativos
$Massa = a_0 + a_1 * ABS416 + a_2 * ABS460$	Função Objetivo: 20,29 $R^2 = 0,998$ $R = 0,999$ Parâmetros a_0 e a_1 não significativos
$Massa = a_0 + a_1 * ABS416 + a_2 * ABS455$	Função Objetivo: 21,01 $R^2 = 0,998$ $R = 0,999$ Parâmetros a_0 e a_1 não significativos
$Massa = a_0 + a_1 * ABS416 + a_2 * ABS427$	Função Objetivo: 30,49 $R^2 = 0,997$ $R = 0,998$ Parâmetro a_1 não significativo
Modelos Classe 4	
$Massa = a_0 * R + a_1 * G + a_2 * B$	Função Objetivo: 1753 $R^2 = 0,840$ $R = 0,916$ Parâmetros a_0 e a_1 não significativos
Modelos Classe 5	
$Massa = a_0 * R + a_1 * G + a_2 * ABS670$	Função Objetivo: 12,44 $R^2 = 0,998$ $R = 0,999$ Parâmetros significativos
$Massa = a_0 * R + a_1 * B + a_2 * ABS483$	Função Objetivo: 13,54 $R^2 = 0,998$ $R = 0,999$ Parâmetro a_0 não significativo
$Massa = a_0 * G + a_1 * B + a_2 * ABS483$	Função Objetivo: 13,60 $R^2 = 0,998$

	R =0,999 Parâmetros a0 não significativo
Massa=a0*G+a1*B+a2*ABS670	Função Objetivo: 13,65 R ² =0,998 R =0,999 Parâmetros significativos
Massa=a0*R+a1*B+a2*ABS670	Função Objetivo: 13,76 R ² =0,998 R =0,999 Parâmetros significativos
Massa=a0*R+a1*B+a2*ABS460	Função Objetivo: 14,40 R ² =0,998 R =0,999 Parâmetro a0 não significativo
Massa=a0*G+a1*B+a2*ABS460	Função Objetivo: 14,42 R ² =0,998 R =0,999 Parâmetro a0 não significativo
Massa=a0*R+a1*B+a2*ABS455	Função Objetivo: 14,52 R ² =0,998 R =0,999 Parâmetros a0 e a1 não significativos
Massa=a0*G+a1*B+a2*ABS455	Função Objetivo: 14,5444 R ² =0,998 R =0,999 Parâmetro a0 não significativo
Massa=a0*R+a1*G+a2*ABS460	Função Objetivo: 14,86 R ² =0,998 R =0,999 Parâmetros significativos
Massa=a0*R+a1*G+a2*ABS455	Função Objetivo: 15,13 R ² =0,998 R =0,999 Parâmetros significativos
Massa=a0*R+a1*B+a2*ABS427	Função Objetivo: 20,71 R ² =0,998 R =0,999 Parâmetros significativos
Massa=a0*G+a1*B+a2*ABS427	Função Objetivo: 20,72 R ² =0,998 R =0,999 Parâmetros significativos
Massa=a0*R+a1*G+a2*ABS427	Função Objetivo: 24,07 R ² =0,997 R =0,998 Parâmetros significativos
Massa=a0*R+a1*B+a2*ABS416	Função Objetivo: 28,10 R ² =0,997

	R =0,998 Parâmetros significativos
Massa= $a_0 \cdot G + a_1 \cdot B + a_2 \cdot ABS416$	Função Objetivo: 28,15 $R^2 = 0,997$ R =0,998 Parâmetros significativos
Massa= $a_0 \cdot R + a_1 \cdot G + a_2 \cdot ABS416$	Função Objetivo: 29,96 $R^2 = 0,997$ R =0,998 Parâmetros a_0 e a_1 não significativos
Massa= $a_0 \cdot R + a_1 \cdot B + a_2 \cdot ABS460$	Função Objetivo: 14,40 $R^2 = 0,998$ R =0,999 Parâmetro a_0 não significativo
Massa= $a_0 \cdot R + a_1 \cdot B + a_2 \cdot ABS374$	Função Objetivo: 104,6 $R^2 = 0,990$ R =0,995 Parâmetros significativos
Massa= $a_0 \cdot G + a_1 \cdot B + a_2 \cdot ABS374$	Função Objetivo: 107,9 $R^2 = 0,990$ R =0,995 Parâmetros significativos
Massa= $a_0 \cdot R + a_1 \cdot G + a_2 \cdot ABS374$	Função Objetivo: 148,2 $R^2 = 0,986$ R =0,993 Parâmetro a_0 não significativo
Modelos Classe 6	
Massa= $a_0 \cdot B + a_1 \cdot ABS483 + a_2 \cdot ABS670$	Função Objetivo: 13,43 $R^2 = 0,998$ R =0,999 Parâmetros a_1 e a_2 não significativos
Massa= $a_0 \cdot B + a_1 \cdot ABS374 + a_2 \cdot ABS483$	Função Objetivo: 13,67 $R^2 = 0,998$ R =0,999 Parâmetro a_1 não significativo
Massa= $a_0 \cdot B + a_1 \cdot ABS460 + a_2 \cdot ABS670$	Função Objetivo: 13,71 $R^2 = 0,998$ R =0,999 Parâmetros a_1 e a_2 não significativos
Massa= $a_0 \cdot B + a_1 \cdot ABS455 + a_2 \cdot ABS670$	Função Objetivo: 13,76 $R^2 = 0,998$ R =0,999 Parâmetros a_1 e a_2 não significativos
Massa= $a_0 \cdot B + a_1 \cdot ABS427 + a_2 \cdot ABS483$	Função Objetivo: 14,08 $R^2 = 0,998$

	R =0,999 Parâmetro a1 não significativo
Massa= $a_0 \cdot B + a_1 \cdot \text{ABS416} + a_2 \cdot \text{ABS483}$	Função Objetivo: 14,10 $R^2 = 0,998$ R =0,999 Parâmetro a1 não significativo
Massa= $a_0 \cdot B + a_1 \cdot \text{ABS455} + a_2 \cdot \text{ABS483}$	Função Objetivo: 14,40 $R^2 = 0,998$ R =0,999 Parâmetros a1 e a2 não significativos
Massa= $a_0 \cdot B + a_1 \cdot \text{ABS460} + a_2 \cdot \text{ABS483}$	Função Objetivo: 14,40 $R^2 = 0,998$ R =0,999 Parâmetros a1 e a2 não significativos
Massa= $a_0 \cdot B + a_1 \cdot \text{ABS455} + a_2 \cdot \text{ABS460}$	Função Objetivo: 14,46 $R^2 = 0,998$ R =0,999 Parâmetros a0, a1 e a2 não significativos
Massa= $a_0 \cdot B + a_1 \cdot \text{ABS374} + a_2 \cdot \text{ABS460}$	Função Objetivo: 15,53 $R^2 = 0,998$ R =0,999 Parâmetro a1 não significativo
Massa= $a_0 \cdot B + a_1 \cdot \text{ABS416} + a_2 \cdot \text{ABS460}$	Função Objetivo: 14,55 $R^2 = 0,998$ R =0,999 Parâmetro a1 não significativo
Massa= $a_0 \cdot B + a_1 \cdot \text{ABS427} + a_2 \cdot \text{ABS460}$	Função Objetivo: 14,55 $R^2 = 0,998$ R =0,999 Parâmetro a1 não significativo
Massa= $a_0 \cdot B + a_1 \cdot \text{ABS416} + a_2 \cdot \text{ABS455}$	Função Objetivo: 14,60 $R^2 = 0,998$ R =0,999 Parâmetro a1 não significativo
Massa= $a_0 \cdot B + a_1 \cdot \text{ABS427} + a_2 \cdot \text{ABS455}$	Função Objetivo: 14,61 $R^2 = 0,998$ R =0,999 Parâmetro a1 não significativo
Massa= $a_0 \cdot B + a_1 \cdot \text{ABS374} + a_2 \cdot \text{ABS455}$	Função Objetivo: 14,63 $R^2 = 0,998$ R =0,999 Parâmetro a1 não significativo
Massa= $a_0 \cdot B + a_1 \cdot \text{ABS374} + a_2 \cdot \text{ABS670}$	Função Objetivo: 15,00 $R^2 = 0,998$ R =0,999 Parâmetro a1 não significativo

$Massa=a_0*B+a_1*ABS416+a_2*ABS427$	Função Objetivo: 15,11 $R^2 =0,998$ $R =0,999$ Parâmetros significativos
$Massa=a_0*R+a_1*ABS455+a_2*ABS460$	Função Objetivo: 15,24 $R^2 =0,998$ $R =0,999$ Parâmetro a_0 não significativo
$Massa=a_0*G+a_1*ABS455+a_2*ABS460$	Função Objetivo: 15,31 $R^2 =0,998$ $R =0,999$ Parâmetro a_0 não significativo
$Massa=a_0*B+a_1*ABS416+a_2*ABS670$	Função Objetivo: 15,38 $R^2 =0,998$ $R =0,999$ Parâmetro a_1 não significativo
$Massa=a_0*B+a_1*ABS427+a_2*ABS670$	Função Objetivo: 15,57 $R^2 =0,998$ $R =0,999$ Parâmetro a_1 não significativo
$Massa=a_0*B+a_1*ABS374+a_2*ABS427$	Função Objetivo: 16,95 $R^2 =0,998$ $R =0,999$ Parâmetros significativos
$Massa=a_0*G+a_1*ABS416+a_2*ABS670$	Função Objetivo: 17,90 $R^2 =0,998$ $R =0,999$ Parâmetro a_1 não significativo
$Massa=a_0*G+a_1*ABS427+a_2*ABS670$	Função Objetivo: 18,52 $R^2 =0,998$ $R =0,999$ Parâmetro a_1 não significativo
$Massa=a_0*G+a_1*ABS460+a_2*ABS670$	Função Objetivo: 18,54 $R^2 =0,998$ $R =0,999$ Parâmetros a_1 e a_2 não significativos
$Massa=a_0*G+a_1*ABS374+a_2*ABS670$	Função Objetivo: 18,55 $R^2 =0,998$ $R =0,999$ Parâmetro a_1 não significativo
$Massa=a_0*G+a_1*ABS455+a_2*ABS670$	Função Objetivo: 18,60 $R^2 =0,998$ $R =0,999$ Parâmetro a_1 e a_2 não significativos
$Massa=a_0*G+a_1*ABS483+a_2*ABS670$	Função Objetivo: 18,61 $R^2 =0,998$ $R =0,999$

	Parâmetros a1 e a2 não significativos
Massa= $a_0 \cdot R + a_1 \cdot \text{ABS374} + a_2 \cdot \text{ABS460}$	Função Objetivo: 18,84 R ² =0,998 R =0,999 Parâmetros a0 e a1 não significativos
Massa= $a_0 \cdot R + a_1 \cdot \text{ABS427} + a_2 \cdot \text{ABS460}$	Função Objetivo: 18,93 R ² =0,998 R =0,999 Parâmetros a0 e a1 não significativos
Massa= $a_0 \cdot G + a_1 \cdot \text{ABS427} + a_2 \cdot \text{ABS460}$	Função Objetivo: 18,93 R ² =0,998 R =0,999 Parâmetros a0 e a1 não significativos
Massa= $a_0 \cdot R + a_1 \cdot \text{ABS416} + a_2 \cdot \text{ABS670}$	Função Objetivo: 19,01 R ² =0,998 R =0,999 Parâmetro a1 não significativo
Massa= $a_0 \cdot G + a_1 \cdot \text{ABS374} + a_2 \cdot \text{ABS460}$	Função Objetivo: 19,05 R ² =0,998 R =0,999 Parâmetros a0 e a1 não significativos
Massa= $a_0 \cdot R + a_1 \cdot \text{ABS374} + a_2 \cdot \text{ABS427}$	Função Objetivo: 19,19 R ² =0,998 R =0,999 Parâmetro a0 não significativo
Massa= $a_0 \cdot R + a_1 \cdot \text{ABS374} + a_2 \cdot \text{ABS455}$	Função Objetivo: 19,30 R ² =0,998 R =0,999 Parâmetros a0 e a1 não significativos
Massa= $a_0 \cdot R + a_1 \cdot \text{ABS460} + a_2 \cdot \text{ABS670}$	Função Objetivo: 19,44 R ² =0,998 R =0,999 Parâmetros a1 e a2 não significativos
Massa= $a_0 \cdot G + a_1 \cdot \text{ABS374} + a_2 \cdot \text{ABS455}$	Função Objetivo: 19,52 R ² =0,998 R =0,999 Parâmetros a0 e a1 não significativos
Massa= $a_0 \cdot R + a_1 \cdot \text{ABS455} + a_2 \cdot \text{ABS670}$	Função Objetivo: 19,57 R ² =0,998 R =0,999 Parâmetros a1 e a2 não

	significativos
Massa= $a_0 \cdot G + a_1 \cdot \text{ABS427} + a_2 \cdot \text{ABS455}$	Função Objetivo: 19,60 R ² =0,998 R =0,999 Parâmetros a0 e a1 não significativos
Massa= $a_0 \cdot R + a_1 \cdot \text{ABS427} + a_2 \cdot \text{ABS670}$	Função Objetivo: 19,61 R ² =0,998 R =0,999 Parâmetro a1 não significativo
Massa= $a_0 \cdot R + a_1 \cdot \text{ABS427} + a_2 \cdot \text{ABS455}$	Função Objetivo: 19,65 R ² =0,998 R =0,999 Parâmetros a0 e a1 não significativos
Massa= $a_0 \cdot R + a_1 \cdot \text{ABS483} + a_2 \cdot \text{ABS670}$	Função Objetivo: 19,67 R ² =0,998 R =0,999 Parâmetros a0, a1 e a2 não significativos
Massa= $a_0 \cdot R + a_1 \cdot \text{ABS455} + a_2 \cdot \text{ABS460}$	Função Objetivo: 19,70 R ² =0,998 R =0,999 Parâmetro a1 não significativo
Massa= $a_0 \cdot R + a_1 \cdot \text{ABS374} + a_2 \cdot \text{ABS483}$	Função Objetivo: 19,75 R ² =0,998 R =0,999 Parâmetros a0 e a1 não significativos
Massa= $a_0 \cdot G + a_1 \cdot \text{ABS374} + a_2 \cdot \text{ABS483}$	Função Objetivo: 19,75 R ² =0,998 R =0,999 Parâmetros a0 e a1 não significativos
Massa= $a_0 \cdot G + a_1 \cdot \text{ABS455} + a_2 \cdot \text{ABS460}$	Função Objetivo: 15,31 R ² =0,998 R =0,999 Parâmetro a0 não significativo
Massa= $a_0 \cdot G + a_1 \cdot \text{ABS374} + a_2 \cdot \text{ABS427}$	Função Objetivo: 19,77 R ² =0,998 R =0,999 Parâmetro a0 não significativo
Massa= $a_0 \cdot G + a_1 \cdot \text{ABS416} + a_2 \cdot \text{ABS483}$	Função Objetivo: 19,84 R ² =0,998 R =0,999 Parâmetros a0 e a1 não significativos
Massa= $a_0 \cdot G + a_1 \cdot \text{ABS427} + a_2 \cdot \text{ABS483}$	Função Objetivo: 19,85 R ² =0,998

	R =0,999 Parâmetros a0 e a1 não significativos
Massa=a0*G+a1*ABS460+a2*ABS483	Função Objetivo: 19,90 R ² =0,998 R =0,999 Parâmetros a1 e a2 não significativos
Massa=a0*G+a1*ABS455+a2*ABS483	Função Objetivo: 19,92 R ² =0,998 R =0,999 Parâmetros a0, a1 e a2 não significativos
Massa=a0*G+a1*ABS416+a2*ABS460	Função Objetivo: 20,01 R ² =0,998 R =0,999 Parâmetros a0 e a1 não significativos
Massa=a0*R+a1*ABS427+a2*ABS483	Função Objetivo: 20,06 R ² =0,998 R =0,999 Parâmetros a0 e a1 não significativos
Massa=a0*R+a1*ABS455+a2*ABS483	Função Objetivo: 20,24 R ² =0,998 R =0,999 Parâmetros a0, a1 e a2 não significativos
Massa=a0*R+a1*ABS416+a2*ABS483	Função Objetivo: 20,31 R ² =0,998 R =0,999 Parâmetros a0 e a1 não significativos
Massa=a0*R+a1*ABS460+a2*ABS483	Função Objetivo: 20,32 R ² =0,998 R =0,999 Parâmetros a1 e a2 não significativos
Massa=a0*R+a1*ABS416+a2*ABS460	Função Objetivo: 20,36 R ² =0,998 R =0,999 Parâmetros a0 e a1 não significativos
Massa=a0*R+a1*ABS374+a2*ABS416	Função Objetivo: 20,48 R ² =0,998 R =0,999 Parâmetro a0 não significativo
Massa=a0*G+a1*ABS374+a2*ABS416	Função Objetivo: 20,61 R ² =0,998

	R =0,999 Parâmetro a0 não significativo
Massa=a0*G+a1*ABS416+a2*ABS455	Função Objetivo: 20,68 R ² =0,998 R =0,999 Parâmetros a0 e a1 não significativos
Massa=a0*B+a1*ABS374+a2*ABS416	Função Objetivo: 20,74 R ² =0,998 R =0,999 Parâmetro a0 não significativo
Massa=a0*R+a1*ABS416+a2*ABS455	Função Objetivo: 21,11 R ² =0,998 R =0,999 Parâmetros a0 e a1 não significativos
Massa=a0*G+a1*ABS416+a2*ABS427	Função Objetivo: 29,00 R ² =0,997 R =0,998 Parâmetros a1 e a2 não significativos
Massa=a0*R+a1*ABS416+a2*ABS427	Função Objetivo: 30,39 R ² =0,997 R =0,998 Parâmetros a1 e a2 não significativos
Modelo Classe 7	
Massa=a0*ABS416+a1*ABS455+a2*ABS460	Função Objetivo: 14,97 R ² =0,998 R =0,999 Parâmetro a0 não significativo
Massa=a0*ABS374+a1*ABS455+a2*ABS460	Função Objetivo: 14,98 R ² =0,998 R =0,999 Parâmetros a0, a1 e a2 não significativos
Massa=a0*ABS427+a1*ABS455+a2*ABS460	Função Objetivo: 15,03 R ² =0,998 R =0,999 Parâmetro a0 não significativo
Massa=a0*ABS455+a1*ABS460+a2*ABS483	Função Objetivo: 15,26 R ² =0,998 R =0,999 Parâmetro a2 não significativo
Massa=a0*ABS455+a1*ABS460+a2*ABS670	Função Objetivo: 15,43 R ² =0,998 R =0,999 Parâmetro a2 não significativo
Massa=a0*ABS416+a1*ABS427+a2*ABS460	Função Objetivo: 16,67

	R ² =0,998 R =0,999 Parâmetros significativos
Massa=a0*ABS416+a1*ABS427+a2*ABS483	Função Objetivo: 17,08 R ² =0,998 R =0,999 Parâmetros significativos
Massa=a0*ABS416+a1*ABS427+a2*ABS455	Função Objetivo: 17,15 R ² =0,998 R =0,999 Parâmetros significativos
Massa=a0*ABS374+a1*ABS416+a2*ABS670	Função Objetivo: 17,37 R ² =0,998 R =0,999 Parâmetros significativos
Modelos Classe 7	
Massa=a0*ABS427+a1*ABS460+a2*ABS483	Função Objetivo: 17,98 R ² =0,998 R =0,999 Parâmetros a1 e a2 significativos
Massa=a0*ABS374+a1*ABS416+a2*ABS483	Função Objetivo: 18,15 R ² =0,998 R =0,999 Parâmetro a1 não significativo
Massa=a0*ABS374+a1*ABS416+a2*ABS460	Função Objetivo: 18,35 R ² =0,998 R =0,999 Parâmetros a1 e a2 não significativos
Massa=a0*ABS374+a1*ABS416+a2*ABS455	Função Objetivo: 18,60 R ² =0,998 R =0,999 Parâmetros a1 e a2 não significativos
Massa=a0*ABS374+a1*ABS427+a2*ABS670	Função Objetivo: 18,85 R ² =0,998 R =0,999 Parâmetro a2 não significativo
Massa=a0*ABS374+a1*ABS460+a2*ABS670	Função Objetivo: 18,88 R ² =0,998 R =0,999 Parâmetro a2 não significativo
Massa=a0*ABS374+a1*ABS460+a2*ABS483	Função Objetivo: 18,93 R ² =0,998 R =0,999 Parâmetros a1 e a2 não significativos
Massa=a0*ABS427+a1*ABS460+a2*ABS670	Função Objetivo: 18,94

	$R^2 = 0,998$ $R = 0,999$ Parâmetro a_2 não significativo
$Massa = a_0 * ABS374 + a_1 * ABS427 + a_2 * ABS460$	Função Objetivo: 18,94 $R^2 = 0,998$ $R = 0,999$ Parâmetros a_0 , a_1 e a_2 não significativos
$Massa = a_0 * ABS374 + a_1 * ABS455 + a_2 * ABS670$	Função Objetivo: 19,24 $R^2 = 0,998$ $R = 0,999$ Parâmetro a_2 não significativo
$Massa = a_0 * ABS427 + a_1 * ABS455 + a_2 * ABS483$	Função Objetivo: 19,46 $R^2 = 0,998$ $R = 0,999$ Parâmetros não significativos
$Massa = a_0 * ABS374 + a_1 * ABS427 + a_2 * ABS455$	Função Objetivo: 19,54 $R^2 = 0,998$ $R = 0,999$ Parâmetros a_0 , a_1 e a_2 não significativos
$Massa = a_0 * ABS374 + a_1 * ABS455 + a_2 * ABS483$	Função Objetivo: 19,56 $R^2 = 0,998$ $R = 0,999$ Parâmetros a_0 , a_1 e a_2 não significativos
$Massa = a_0 * ABS374 + a_1 * ABS427 + a_2 * ABS483$	Função Objetivo: 19,61 $R^2 = 0,998$ $R = 0,999$ Parâmetros a_0 , a_1 e a_2 não significativos
$Massa = a_0 * ABS427 + a_1 * ABS455 + a_2 * ABS670$	Função Objetivo: 19,64 $R^2 = 0,998$ $R = 0,999$ Parâmetro a_2 não significativo
$Massa = a_0 * ABS374 + a_1 * ABS483 + a_2 * ABS670$	Função Objetivo: 19,70 $R^2 = 0,998$ $R = 0,999$ Parâmetro a_2 não significativo
$Massa = a_0 * ABS374 + a_1 * ABS416 + a_2 * ABS427$	Função Objetivo: 19,77 $R^2 = 0,998$ $R = 0,999$ Parâmetros a_1 e a_2 não significativos
$Massa = a_0 * ABS427 + a_1 * ABS483 + a_2 * ABS670$	Função Objetivo: 20,16 $R^2 = 0,998$ $R = 0,999$ Parâmetros a_0 e a_2 não significativos

Massa= a_0 *ABS416+ a_1 *ABS460+ a_2 *ABS483	Função Objetivo: 20,53 R ² =0,998 R =0,999 Parâmetros não significativos
Massa= a_0 *ABS455+ a_1 *ABS483+ a_2 *ABS670	Função Objetivo: 20,57 R ² =0,998 R =0,999 Parâmetros a_0 e a_2 não significativos
Massa= a_0 *ABS416+ a_1 *ABS460+ a_2 *ABS470	Função Objetivo: 20,75 R ² =0,998 R =0,999 Parâmetro a_2 não significativo
Massa= a_0 *ABS416+ a_1 *ABS483+ a_2 *ABS670	Função Objetivo: 21,00 R ² =0,998 R =0,999 Parâmetros a_0 e a_2 não significativos
Massa= a_0 *ABS460+ a_1 *ABS483+ a_2 *ABS670	Função Objetivo: 21,14 R ² =0,998 R =0,999 Parâmetros a_0 e a_2 não significativos
Massa= a_0 *ABS416+ a_1 *ABS455+ a_2 *ABS483	Função Objetivo: 21,27 R ² =0,998 R =0,999 Parâmetros não significativos
Massa= a_0 *ABS416+ a_1 *ABS455+ a_2 *ABS670	Função Objetivo: 21,79 R ² =0,998 R =0,999 Parâmetro a_2 não significativo
Massa= a_0 *ABS416+ a_1 *ABS427+ a_2 *ABS670	Função Objetivo: 43,73 R ² =0,996 R =0,998 Parâmetros significativos