



DIMAS SAMID LEME

**SISTEMA COMPUTACIONAL PARA
INTEGRAÇÃO DE DADOS NA ANÁLISE DE
CAFÉS ESPECIAIS**

LAVRAS – MG

2016

DIMAS SAMID LEME

**SISTEMA COMPUTACIONAL PARA INTEGRAÇÃO DE DADOS NA
ANÁLISE DE CAFÉS ESPECIAIS**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Engenharia de Sistemas e Automação, área de concentração em Avaliação e Modelagem de Sistemas, para a obtenção do título de Mestre.

Orientador

Dr. Bruno Henrique Groenner Barbosa

Co-orientadora

Dra. Rosemary Gualberto Fonseca Alvarenga Pereira

LAVRAS – MG

2016

**Ficha catalográfica elaborada pelo Sistema de Geração de Ficha Catalográfica da Biblioteca
Universitária da UFLA, com dados informados pelo(a) próprio(a) autor(a).**

Leme, Dimas Samid.

Sistema Computacional para Integração de Dados na Análise
de Cafés Especiais / Dimas Samid Leme. – Lavras : UFLA, 2016.
140 p.

Dissertação (mestrado acadêmico)—Universidade Federal de
Lavras, 2016.

Orientador(a): Bruno Henrique Barbosa.

Bibliografia.

1. Café Torrado. 2. Análise Sensorial. 3. Sistema de Visão
Computacional. 4. Redes Neurais Artificiais. 5. Banco de Dados. I.
Universidade Federal de Lavras. II. Título.

DIMAS SAMID LEME

**SISTEMA COMPUTACIONAL PARA INTEGRAÇÃO DE DADOS NA
ANÁLISE DE CAFÉS ESPECIAIS**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Engenharia de Sistemas e Automação, área de concentração em Avaliação e Modelagem de Sistemas, para a obtenção do título de Mestre.

APROVADA em 04 de Março de 2016.

Dr. Danton Diego Ferreira	UFLA
Dr. Flávio Meira Borém	UFLA
Dr. Giovani Bernardes Vitor	UTC

Dr. Bruno Henrique Groenner Barbosa
Orientador

LAVRAS – MG

2016

*A meus pais
José e Olívia,
E à minha querida
Joelma.*

DEDICO

AGRADECIMENTOS

Senhor Deus, agradeço pelo Sr. ter colocado em meu caminho pessoas boas e generosas. Agradeço pela vida e saúde, agradeço pelo crescimento intelectual e espiritual. Agradeço!

Agradeço aos meus pais pelo amor incondicional; agradeço minha amada Joelma pela ajuda e compreensão durante o desenvolvimento das etapas deste projeto.

Agradeço a todos do INCT-Café / INOVACAFÉ, funcionários, alunos, professores e pesquisadores que colaboraram de forma direta ou indireta para a execução e aplicação deste trabalho. Sem esquecer da Emanuelle pela cooperação no projeto de forma direta.

Agradeço aos Professores Bruno H. Groenner Barbosa e Rosemary G. F. A. Pereira pela orientação, dedicação, amizade e confiança depositada ao longo deste projeto.

Agradeço à Fundação de Amparo à Pesquisa do Estado de Minas Gerais – FAPEMIG pelo apoio financeiro e na aprovação deste projeto.

Agradeço por fim à Universidade Federal de Lavras, por meio do programa de Pós-Graduação em Engenharia de Sistemas e Automação – PPGESISA, pela oportunidade de aprimorar meus conhecimentos técnicos.

RESUMO

A tonalidade na cor do café torrado varia em decorrência do objetivo de produção, todavia existe um padrão internacional para o grau de torra utilizado em análises sensoriais, e este é mensurado por meio de um equipamento de alto custo que, em alguns modelos, não permite armazenamento de seus resultados em um sistema de integração de dados. Os sistemas de Visão Computacional surgem como alternativas para uma rápida análise, armazenamento e integração com outros dados acerca do café, objetiva-se com este trabalho a construção de um sistema de visão computacional para identificação das diferentes tonalidades nos grãos de café torrados e moídos. Para isso, foi realizada uma conversão do padrão de cores RGB de câmeras digitais para parâmetros em L^* , a^* e b^* de cada pixel da imagem digital, obtendo assim uma média de todos os pixels da amostra. Para a criação do sistema de visão foram utilizados: uma estrutura metálica fechada, sistema de iluminação padronizados por LED's, uma câmera digital acoplada em sua parte superior e *software* processador das imagens implementado com modelos de regressão polinomiais e redes neurais artificiais para aproximação de uma função que represente o grau de torra das amostras fotografadas. Para construção do modelo de transformação de espaços de cores, foi utilizado um banco de dados de cartelas de cores e 150 amostras de café torrados em diferentes tonalidades para treinamento de uma rede neural artificial. Por meio dos resultados obtidos, verificou-se que o modelo possui boa acurácia com uma baixa divergência. Ademais, foram desenvolvidas aplicações Android/iOS para cadastro de dados da saca, dados de análise física e análise sensorial definidos pela Associação Americana de Cafés Especiais (SCAA). Estas aplicações também permitem coletas de temperatura das amostras e envio a uma plataforma integrada com um baixo custo de implantação, se comparada a outras ferramentas disponíveis.

Palavras-chave: Café torrado, análise sensorial, sistema de visão computacional, Redes Neurais Artificiais, Banco de Dados, aplicação Android.

ABSTRACT

The shade of color of roasted coffee varies in light of the production objective. However, there is an international standard for the degree of roasting used in sensorial analyses, measured by means of a high costing equipment that, in some models, does not allow storing the results in a data integration system. The Computational View systems emerge as alternatives for a quick analysis, storage and integration with other data concerning coffee. Thus, the objective of this work is the construction of a computational view system for identifying the different shades of roasted and milled coffee grains. For this, a conversion of the RGB color standards of digital cameras was performed for parameters L^* , a^* and b^* of each pixel of the digital image, obtaining an average of all pixels of the sample. For creating the computational view system a closed metallic structure, illumination system standardized by LEDs, a digital camera attached in its superior side and processing software of the images implemented with polynomial regression models and artificial neural networks for approximating a function that represents the most accurate roasting degree of the photographed samples were used. For constructing the transformation model of color spaces, a databank of color charts and 150 samples of roasted coffee in different shades for training an artificial neural network were used. With the results obtained, it was verified that the model presents good accuracy with low divergence. Furthermore, Android/iOS applications we developed for registering sac data, physical and sensorial analysis data defined by the American Association of Special Coffees (SCAA). These applications also allow taking the temperature of samples and posting to an integrated platform with low implementation cost if compared to other tools available.

Keywords: Roasted coffee, sensorial analysis, computational view system, Artificial Neural Networks, Databanks, Android application.

LISTA DE FIGURAS

Figura 1 Uma planta de café arábica com seus frutos, sementes verdes, e seus grãos torrados.....	22
Figura 2 Região olfativa com gases ou vapores	29
Figura 3 Diferentes áreas com maior sensibilidade de sabores.....	31
Figura 4 Modelo de visão computacional.....	37
Figura 5 Modelo tridimensional RGB	40
Figura 6 Representação do modelo de coordenadas cartesianas para CIELab	41
Figura 7 Diagrama de definição de modelagem	45
Figura 8 Áreas e subáreas da Inteligência Computacional	47
Figura 9 Modelo de Neurônio biológico.....	48
Figura 10 Conector eletrônico lógico definido por McKulloch e Pitts.....	50
Figura 11 Adaptação do modelo Perceptron definido por Rosenblatt (1958).....	51
Figura 12 Hardware Arduino UNO	55
Figura 13 Sensor de temperatura LM-35	56
Figura 14 Módulo bluetooth HC-05	57
Figura 15 Organização do fluxo de etapas para programação em App Inventor	59
Figura 16 Representação dos conceitos do modelo relacional	62
Figura 17 Exemplo de chave estrangeira	63
Figura 18 Exemplo de integridade em chaves estrangeiras	64
Figura 19 Componentes que fazem parte da Plataforma de Integração de Informações desenvolvidas neste trabalho	66
Figura 20 Plataforma para aquisição de imagens	68
Figura 21 Cartelas utilizadas para identificação do modelo de transformação de espaço de cores.....	69
Figura 22 Colorímetro utilizado para as medições de $L^*a^*b^*$ das cartelas de cores.....	69
Figura 23 Intensidade das cores CIELab das cartelas escolhidas, (a) luminância pelo número de amostras, (b) cores verde ao vermelho pelo número de amostras, (c) cores azul ao amarelo pelo número de amostras	70
Figura 24 Discos de cores Agtron utilizado para coleta de dados	71

Figura 25 Distribuição L^* , a^* , b^* , das cartelas e dos discos Agtron no espaço tridimensional, sendo as medições dos discos apresentadas em "o" e as das cartelas em "+"	72
Figura 26 Equipamento Agtron modelo M-BASIC II utilizado para coleta de dados de amostras de café torrado inteiros e moídos.....	73
Figura 27 Amostras das escalas de cores estudadas para grãos de cafés torrados	75
Figura 28 Amostras torradas e moídas do material de estudo	76
Figura 29 Visão superior do módulo de aquisição de temperatura.....	78
Figura 30 Visão inferior do módulo de aquisição de temperatura.....	78
Figura 31 Aparelho <i>Tablet</i> utilizado para receber a aplicação Android	79
Figura 32 Aparelho notebook utilizado para suportar a aplicação WampServer como Banco de dados.....	80
Figura 33 Menu de configuração da ferramenta WampServer (esquerda), janela de configuração com banco de dados criado	81
Figura 34 Sequência utilizada para construção do modelo de transformação RGB-CIELab	83
Figura 35 Estruturas das Redes Neuras Artificiais utilizadas na transformação RGB para CIELab	84
Figura 36 Disposição das amostras de grãos de café inteiro, (a) disposição do recipiente contendo a amostra na câmara escura e (b) imagem recortada.....	85
Figura 37 Disposição das amostras de grãos de café moído, (a) disposição do recipiente contendo a amostra na câmara escura e (b) imagem recortada.....	86
Figura 38 Estruturas das Redes Neuras Artificiais utilizadas na transformação CIELab em escala Agtron	89
Figura 39 Temperatura captada com sensor de temperatura LM35, e transmitida via bluetooth para aplicação android em tempo real	92
Figura 40 Diagrama do circuito eletrônico do módulo de aquisição de temperatura.....	92
Figura 41 Ilustrações do dispositivo implementado e acoplado ao braço do avaliador por uma pulseira de velcro	94
Figura 42 Diagrama de organização das etapas da aplicação INCAFE para cadastro de novas sacas	95

Figura 43 Diagrama de organização das etapas da aplicação FISICAFE para análise física	97
Figura 44 Diagrama de organização das etapas da aplicação LEGUSTA para análise sensorial.....	99
Figura 45 Teste de Tukey (95% de confiança) aplicado nos erros médios quadráticos de validação obtidos pelas redes com 5, 10 ou 15 neurônios escondidos.....	103
Figura 46 Comparação dos resultados estimados em L^* , a^* e b^* , para amostras de grãos inteiros e grãos moídos	104
Figura 47 Comparação dos erros entre os modelos de aproximação de amostras inteiras	106
Figura 48 Relação entre Agtron estimado pelo modelo neural e o Agtron medido pelo equipamento de cada amostra.....	107
Figura 49 Distribuição dos erros do modelo neural para estimativa do Agtron em grãos	107
Figura 50 Comparação dos erros entre os modelos de aproximação de amostras moídas	108
Figura 51 Comparação dos três menores erros dos modelos de aproximação de amostras moídas	109
Figura 52 Relação entre Agtron estimado pelo modelo polinomial quadrático e o Agtron medido pelo equipamento de cada amostra	110
Figura 53 Distribuição dos erros do modelo de regressão polinomial em escala de cinza para estimativa do Agtron em grãos moídos	110
Figura 54 Janelas da aplicação INCAFE, onde (a) representa a janela inicial, (b) mensagem de indicação de envio dos dados ao sistema, (c) lista com dados cadastrados, (d) seleção de um campo para alteração, (e) exibição dos valores do café selecionado, e em (f) a versão final com o campo de local de origem alterado	112
Figura 55 Janelas da aplicação FISICAFE, onde (a) representa a janela inicial com campos preenchidos, (b) seleção das classes de café, (c) confirmação do envio dos dados ao sistema, (d) lista das amostras cadastradas e seleção de um código para ajuste de correções.....	113

Figura 56 Janelas da aplicação LEGUSTA, onde (a) representa a janela inicial, (b) mensagem de indicação de envio dos dados ao sistema, (c) lista com dos nomes de avaliadores cadastrados, (d) início da primeira etapa de avaliação contendo nome do avaliador selecionado, (e) pontuações realizadas mediante alteração nos controles deslizantes, e em (f) envio dos dados para o banco da primeira amostra	115
Figura 57 Esboço do diagrama entidade/relacionamento desenvolvido para nortear os testes no Banco de Dados	116
Figura 58 Amostra de curva de torra confrontada com uma linha ideal de torra.....	119
Figura 59 Curva de torra obtida pelo software do módulo de captura de temperaturas Sistrad.....	120

LISTA DE TABELAS

Tabela 1 Classificação de volatilidade de aromas do café.....	30
Tabela 2 Pontuação dos atributos de qualidade	36
Tabela 3 Classificação sensorial definida pela SCAA.....	36
Tabela 4 Porcentagem de impurezas retirados das amostras	74
Tabela 5 Erros das RNAs com 5 neurônios na camada oculta, obtidos por meio da equação (8).....	102
Tabela 6 Erros das RNA's com 10 neurônios na camada oculta, avaliados segundo equações de Léon et al. (2006)	102
Tabela 7 Erros das RNA's com 15 neurônios na camada oculta, avaliados segundo equações de Léon et al. (2006)	102
Tabela 8 Relação das entidades e variáveis armazenadas.....	117

LISTA DE SIGLAS

AG	Algoritmos Genéticos
RNA	Redes Neurais Artificiais
PG	Programação Genética
UFLA	Universidade Federal de Lavras
SGBD	Sistema de Gerenciamento de Banco de Dados
ABIC	Associação Brasileira de Industrias do Café
CONAB	Companhia Nacional de Abastecimento
SCAA	Specialty Coffee Association of America
CQI	Coffee Quality Institute
IFT	Institute of Food Technologists
BSCA	Brazilian Specialty Coffee Association
IDE	Integrated Development Environment
RGB	Sistemas de cores aditivas: Red, Green and Blue.
CIE	International Commission on Illumination
L*a*b*	Sistema de cores da CIE: Lightness and space color
TIFF	Modelo de formato de arquivo raster.
NEF	Nikon Electronic Format
RAW	Modelo de formato de arquivo sem tratamento (CRU)
MIT	Massachusetts Institute of Technology
WI FI	wireless fidelity (IEEE 802.11)

SUMÁRIO

1	INTRODUÇÃO	17
2	Objetivos.....	21
2.1	Objetivo Geral	21
2.2	Objetivos específicos.....	21
3	REFERENCIAL TEÓRICO	22
3.1	Café Arábica.	22
3.2	Qualidade do café	23
3.3	Aspectos econômicos e comerciais do café	24
3.4	O Processo de Torração do café	25
3.5	Análise Sensorial.....	27
3.5.1	O Aroma.....	28
3.5.2	O Sabor.....	30
3.5.3	Metodologia SCAA de Avaliação	32
4	SISTEMAS COMPUTACIONAIS	37
4.1	Visão Computacional	37
4.1.1	Espaço de cores	39
4.2	Modelos de regressão	41
4.2.1	Modelos polinomiais.....	42
4.2.2	Modelos Neurais	46
4.2.2.1	Aprendizado Biológico	47
4.2.2.2	Aprendizado Computacional.....	50
4.3	Sistemas Embarcados.....	54
4.3.1	Arduino.....	54
4.3.2	Sensor de temperatura	55
4.3.3	Transmissor Bluetooth.....	56
4.3.4	APP Inventor	58
4.4	Sistema de Gerenciamento de Banco de Dados	60
4.4.1	Chaves primária e estrangeiras.....	62
4.4.2	Integridades	63
5	MATERIAIS E MÉTODOS.....	65
5.1	Plataforma de Integração de Informações	65
5.1.1	Estrutura	65
5.2	Materiais.....	67
5.2.1	Sistema de visão computacional e reconhecimento de padrões... 67	
5.2.2	Cartelas de cores e histograma.....	68

5.2.2.1	Amostras de café.....	73
5.2.3	Sistemas embarcados	76
5.2.3.1	Módulo de aquisição de temperatura	77
5.2.3.2	Aplicativo para dispositivos Android	79
5.2.3.3	Servidor de Banco de Dados.....	80
5.3	Métodos	81
5.3.1	Sistema de visão comp. e de reconhecimento de padrões	81
5.3.1.1	Modelo de transformação de espaços de cores	82
5.3.1.2	O modelo de regressão de tonalidade de torra.....	85
5.3.2	Sistemas embarcados	91
5.3.2.1	Módulo de aquisição de temperatura	91
5.3.2.2	Aplicativos para dispositivos Android.....	93
5.3.2.3	Banco de Dados.....	100
6	RESULTADOS E DISCUSSÕES	101
6.1	Modelo de transformação de espaço de cores	101
6.2	Modelo de regressão para escala Agtron.....	105
6.2.1	Grãos torrados inteiros	105
6.2.2	Grãos torrados e moídos.....	108
6.3	Aplicativos Android/iOS.....	111
6.3.1	Aplicativo INCAFÉ	111
6.3.2	Aplicativo FISICAFÉ	113
6.3.3	Aplicativo LEGUSTA	114
6.4	Banco de Dados.....	116
6.5	Curva de torra	119
7	CONCLUSÕES E IMPACTOS NA QUALIDADE DO CAFÉ	121
	REFERÊNCIAS.....	Erro! Indicador não definido.
	ANEXOS.....	133

1 INTRODUÇÃO

O café é o segundo produto mais importante na pauta das exportações agrícolas, constituindo uma das mais importantes fontes de renda para a economia brasileira. O estado de Minas Gerais destaca-se no cenário brasileiro como o maior produtor, com participação de 51,59% do café produzido no país (COMPANHIA NACIONAL DE ABASTECIMENTO - CONAB, 2014).

Segundo a Associação Brasileira da Indústria do Café - ABIC (2014), o café é responsável por cerca de 70% da renda das propriedades rurais do Sul de Minas. Todavia, a importância econômica e social da cafeicultura como geradora de renda e empregos está diretamente relacionada com a qualidade do mesmo. Alguns dos fatores de influência desta qualidade incluem gênero, variedade, clima, método de colheita, tipo de pré-processamento, condições de armazenamento, cor dos frutos colhidos e até a tonalidade da torra.

É notório que o café é indispensável para o consumidor mundial, que a cada dia se torna mais exigente em relação ao sabor, aroma e higiene do produto que consome. Esta exigência não é diferente no Brasil.

Segundo pesquisas recentes da Associação Brasileira de Indústrias do Café (ABIC), os brasileiros, inclusive os de baixa renda, estão cada vez mais buscando cafés com melhores qualidades. Segundo a associação, em 2014, 16% dos consumidores já experimentaram em casa, cafés Premium, superiores ou *gourmet* (ABIC, 2014).

O segmento de cafés especiais representa, hoje, cerca de 13% do mercado internacional da bebida. O valor de venda atual para alguns cafés diferenciados tem um sobrepreço, que varia de 30% a 40% a mais em relação ao café considerado convencional. Em alguns casos, pode ultrapassar a barreira dos 100% (BRAZIL SPECIALTY COFFEE ASSOCIATION - BSCA, 2005).

O reconhecimento da qualidade do café brasileiro estimula a busca por melhores tecnologias e aperfeiçoamento de processos para a produção da bebida. Para isto, é importante a atualização das indústrias quanto à tecnologia de torração, moagem e empacotamento. A torra de grãos de café constitui um dos estágios de processamento do café mais carentes de informação no Brasil. A maioria dos estudos sobre o processo de torração é relativa aos cafés de países como Colômbia, México e Quênia (SANTOS et al., 2015).

A seleção do tempo e da temperatura adequada a torração depende principalmente das características físicas e químicas dos grãos crus, do teor de umidade inicial e da taxa de transferência de calor. Desta forma, o controle de variáveis como tamanho dos grãos da amostra, cor de grãos, temperatura e tempo são de fundamental importância para melhor adequação dos processos industriais.

Neste sentido, a análise sensorial é uma etapa importante para a validação dos processos envolvidos nas etapas anteriores à produção da bebida, indicando ou não suas especialidades. Em muitos casos, essa análise é realizada com uma planilha impressa onde o avaliador pontua cada amostra em diversos critérios e, em seguida, um técnico digitaliza essa planilha para a realização de cálculos estatísticos, o que torna o processo bastante antiquado.

Durante o processo de degustação, o avaliador deve analisar vários aspectos como a fragrância do pó, temperatura da água, período de esfriamento, aroma da bebida, dentre outros; além disso, executar a limpeza da colher de prova após cada sucção.

A temperatura da água é considerada um fator de discriminação de sabores, pois os açúcares se pronunciam mais fortemente em temperaturas um pouco mais baixas, cerca de 40~30°C, segundo a SCAA. Indicando assim, a importância de seu controle na análise

Com intuito de organizar, catalogar e buscar agregar valor às diferentes etapas dos processos de análise de cafés, foi proposto e aprovado um projeto de desenvolvimento de uma plataforma de integração de dados acerca de cafés tratados pelo Instituto Nacional de Ciência e Tecnologia do Café (INCT-CAFÉ), localizado no campus da Universidade Federal de Lavras UFLA. Este projeto, intitulado "Gestão em Ciência, Tecnologia e Inovação: Plataforma digital para classificação, análise física e microestrutural de café", coordenado pela Professora Doutora Rosemary Gualberto, tem como cerne as seguintes etapas:

- elaborar um banco digital de dados de tonalidades de cor do café beneficiado que possibilite o enquadramento de amostras nos critérios de classificação;
- avaliar a qualidade de diferentes tipos de café segundo atributos físicos;
- produzir uma plataforma de classificação instrumental acoplada a sistema computacional;
- utilizar a plataforma de classificação em cafés do Programa de Certificação do Estado de Minas Gerais.

A produção da plataforma de análise física dos grãos de café exercerá um forte impacto nos diferentes segmentos do setor cafeeiro, por ser um instrumento científico e de inovação tecnológica que subsidiará de forma objetiva as avaliações qualitativas do café.

Como ponto inicial, foi desenvolvido um modelo de classificação de padrões de cores em grãos crus através de modelos computacionais aplicados a fotografias tiradas de um conjunto de 120 amostras. O modelo apresentou poder de classificação de 100% de distinção entre amostras nas cores *Bluish-Green*, *Green*, *Cane-Green*, *Whitish*, definidas pela Associação Americana de Cafés Especiais (SCAA).

Este trabalho seguiu essa linha de caracterização por modelos computacionais para grãos de café torrados, inteiros e moídos, visando adquirir mais dados para preenchimento de um Banco de Dados relacional.

A possibilidade de caracterização de diferentes níveis de torra por meio de imagens fotográficas possibilita, de imediato, uma grande redução dos custos de implementação se comparadas aos modelos comerciais. Além de permitir uma integração em tempo real com um sistema de armazenamento e controle.

Ademais, ferramentas desenvolvidas para aplicações Android/iOS pretendem reduzir o tempo de avaliação e ajudar os avaliadores a escolherem, dentre uma listagem de tipos de fragrância, aroma e sabor, aquelas que mais se pronunciaram em determinada amostra catalogada anteriormente na classe de cor cru e torrada.

Pretende-se assim, construir um modelo estruturado de base de dados que futuramente possibilite uma fonte de consulta para novas análises acerca do controle de qualidade.

2 OBJETIVOS

2.1 Objetivo Geral

Construir uma plataforma para captura, organização, armazenamento e análise de dados e informações referentes aos cafés especiais de concursos realizados no Pólo Tecnológico em qualidade do Café, da Universidade Federal de Lavras – UFLA.

2.2 Objetivos específicos

- a) implementar e comparar diferentes técnicas de inteligência computacional para classificação de cores em grãos de café torrados;
- b) desenvolver uma aplicação computacional para dispositivos móveis que possibilite representar o processo de análise sensorial definido pelo Concurso Mineiro de Cafés Especiais;
- c) modelar e implementar um dispositivo de medição de temperatura das xícaras durante o processo de degustação que esteja em sincronismo com a aplicação;
- d) implementação de modelos de comunicação web com servidor de dados online, para disponibilizar informações em tempo real.

3 REFERENCIAL TEÓRICO

O referencial teórico abaixo foi dividido em duas partes, a primeira aborda questões relacionadas ao café, e a segunda aborda informações relacionadas aos sistemas computacionais.

3.1 Café Arábica.

A planta café é um gênero da família *Rubiaceae* que possui diversas espécies, sendo as mais importantes comercialmente a *Coffea arabica* L.(Fig. 1), e a *Coffea canéfora* L., popularmente chamada de robusta, que é a sua variedade mais produtiva. A planta ocorre em regiões tropicais do planeta, entre os trópicos de Câncer e Capricórnio, podendo variar muito em aparência de acordo com a região (BANKS; MCFADDEN; ATKINSON, 1999; SIVETZ; DESROSIER, 1979).




Figura 1 Uma planta de café arábica com seus frutos, sementes verde e seus grãos torrados

O café arábica se destaca dentre estas duas por apresentar atributos de qualidade superior, sendo deste modo mais valorizado em todo o mercado do café. É a principal espécie produzida no Estado de Minas Gerais, em decorrência da aptidão climática favorável para seu desenvolvimento (ABIC, 2014).

No Brasil, mais do que um hábito nacional, o café é parte integrante da construção da identidade nacional e na história econômica do país (SCHMIDT, 2009).

Sua preparação consiste na extração do sabor e aroma de grãos torrados e moídos por meio de água quente e filtragem. Contudo, alguns cuidados devem ser tomados como a proporção de pó, a quantidade de água utilizada, o correto grau de moagem, o método de preparo, a temperatura da água e o tempo de contato entre a água e o pó. De acordo com a SCAA (SPECIALTY COFFEE ASSOCIATION OF AMERICA - SCAA, 2012), os cafés especiais são definidos na xícara.

3.2 Qualidade do café

O histórico de fortalecimento do mercado de cafés com melhores padrões de qualidade nasceu em conjunto com a revolução industrial Norte Americana de 1850. Esta tornou favorável a elaboração de produtos com melhores qualidades em larga escala, além de iniciar a corrida de patentes referentes ao “*Modus Operandi*” de produção da bebida (SCAA, 2012).

Em 1864, *Jabez Burn* recebeu a primeira patente de um modelo de torrador, equipamento comercial que permite carregar e descarregar grãos sem ser retirado do fogo, aumentando consideravelmente a produção e reduzindo custos.

Após alguns anos, em 1916, é concedida a *Joules La Page* a patente de um moedor de café que corta ao invés de esmagar os grãos de café, tornando o processo de moagem uniforme.

Em 1974, *Erna Knutsen*, cunha o termo “*Specialty Coffee*” para descrever as características de uma alta e limitada qualidade do café.

Em 1978, a Comissão Brasileira de Normas e Padrões para Alimentos aprovou a resolução que fixava padrões de qualidade e identidade para alimentos e bebidas, incluindo o café. Surge assim a divisão classificatória quanto ao tipo, bebida, peneira e cor.

Em 1982, quarenta membros do Comércio Internacional do Café (ICC), incluindo *Erna Knutsen*, se reuniram para discutir sobre possibilidades de melhoria na obtenção, armazenamento e venda de cafés especiais, o que fez surgir os requerimentos e leis da *Specialty Coffee Association of America* – SCAA. Em 1996 foi criado o *Specialty Coffee Institute* (atualmente chamada de *Coffee Quality Institute*), uma organização sem fins lucrativos que trabalha a nível internacional para melhorar a qualidade da bebida e a vida das pessoas envolvidas na produção.

A SCAA se tornou a maior associação de comércio de café do mundo, com mais de 2.600 filiados em mais de 40 países (SCAA, 2012).

3.3 Aspectos econômicos e comerciais do café

O café sempre teve alta participação no agronegócio brasileiro, sendo o segundo produto de maior exportação agrícola. De acordo com a CONAB (2014), a primeira estimativa para produção da safra cafeeira (espécies arábica e conilon), em 2015 indica que o país deverá colher entre 44,11 e 46,61 milhões de sacas de 60 quilos de café beneficiado.

AABIC (2014), estima que o consumo de café em 2016 volte a crescer de forma mais intensa. A diversidade de produtos oferecidos com uma maior qualidade e, muitos deles certificados pelo PQC – Programa de Qualidade do Café da ABIC – tem mantido o interesse dos consumidores. Grandes marcas e marcas regionais ou locais, nas grandes cidades e diversas regiões, principalmente Nordeste e Centro-Oeste, são responsáveis pela reconhecida melhoria da qualidade do café desde os produtos para o dia-a-dia, Tradicionais, Fortes e Extra Fortes, até os cafês *Gourmet*.

3.4 O Processo de Torração do café

O gosto e o aroma que caracterizam a bebida do café são resultantes da combinação de centenas de compostos químicos produzidos pelas reações que ocorrem durante a torração. A torração do café cru é um processo de pirólise brando, durante o qual ocorrem diversas transformações químicas. O grau destas modificações depende, principalmente, da estabilidade de diversos componentes do café cru e do calor aplicado durante o processo de torração. Neste processo, o café perde lentamente no início e mais rapidamente no final, a coloração verde até atingir a coloração escura. Com a elevação da temperatura de torração, os grãos têm um aumento do seu volume e como consequência a dispersão de gases, assim desenvolve-se o aroma de café torrado (OLIVEIRA et al., 2012).

Durante o processo de torração, ocorrem três etapas distintas: secagem, pirólise e resfriamento. No início do processo de torração, o grão de café possui cerca de 8 a 13% de água. Os grãos ao serem expostos a altas temperaturas durante o ato de torração chegam a faixas de 220°C e 280°C, o que ocasiona a evaporação da água (SILVA; HERNANDEZ, 2008). Conforme o modelo de torrador utilizado nos primeiros minutos de torra (2 a 5 minutos, podendo chegar até 8) o maior percentual de umidade é evaporado. Com oito minutos

aproximadamente, ocorre o início do escurecimento, com a transformação da cor verde para amarela, em temperatura entre 127°C a 188°C. Assim a formação da tonalidade marrom clara ocorre entre 11 e 12 minutos e a temperatura é elevada para 200°C. Ao se atingir 14 minutos, na temperatura de cerca de 210°C, o escurecimento continua e a tonalidade é transformada em um marrom mais escuro. Em 16 minutos os grãos chegam à temperatura de cerca de 232°C, e a tonalidade torna-se marrom escura (JANSEN, 2006).

Muitos compostos do grão cru atuam como precursores e/ou participam de uma série de reações, como as de caramelização ou de Maillard, e outras degradações químicas que ocorrem durante o processo de torração e que contribuem para a alteração do sabor e aroma do café torrado (JANSEN, 2006).

A intensidade dessas alterações dependerá do grau de torração do café, que pode ser calculado por alguns métodos. O mais popular, mas provavelmente o menos preciso, é pela comparação visual dos grãos e definição de padrões de intensidade entre clara média e escura. Outro modelo é a utilização de equipamentos especializados como os da marca Agtron. Neste equipamento é utilizado um feixe de luz infravermelho para escanear uma amostra de grãos torrados e em seguida a transforma em um valor numérico que representa o grau de torração estes valores geralmente variam entre 25 e 95. Quanto menor o valor, mais escura é a amostra.

A composição dos grãos torrados está intimamente relacionada a qualidade final da bebida do café, pois o grau de torração evidencia e/ ou esconde inúmeras propriedades destes (MENDONÇA, 2005). Assim para a confirmação dessas qualidades se faz necessário a utilização de análise especializada.

3.5 Análise Sensorial

A análise sensorial é uma disciplina científica utilizada para evocar, medir, analisar e interpretar reações das características dos alimentos e outros materiais da forma como são percebidos pelos sentidos da visão, olfato, paladar, tato e audição (COBUCCI, 2010).

Segundo Manfungás (2007), a análise sensorial avalia as características organolépticas dos alimentos através das percepções identificadas pelo sentido humano. As percepções são as respostas frente às características dos alimentos, são o reflexo da realidade. Podem ser mais ou menos representativas, dependendo da aplicação ou não de métodos de análise destas respostas. Assim essa consiste na coleta de dados subjetivos, transformando-os em dados objetivos, por meio de ferramentas estatísticas.

A qualidade sensorial de um alimento não é uma característica própria do alimento e sim o resultado da interação entre o alimento e o homem. É função tanto dos estímulos procedentes dos alimentos quanto das condições fisiológicas, psicológicas e sociológicas do indivíduo ou grupo de indivíduos que avaliam o alimento, no contexto ambiental em que estão inseridos o indivíduo e o próprio alimento (COBUCCI, 2010). Desta forma pode-se perceber que a qualidade sensorial varia de pessoa para pessoa e depende das experiências, da expectativa, do grupo étnico e de preferências individuais.

São fatores determinantes para a qualidade sensorial das características do alimento como aparência, sabor, textura, forma, método de preparo, custo e sazonalidade. Também estão presentes as características do indivíduo associadas à idade, sexo, se fumante, entre outras.

É importante considerar o uso de testes sensoriais como ferramenta para desenvolvimento de novos produtos, controle de matéria-prima, comparação de

produtos, investigação do envelhecimento e vida comercial, avaliação da aceitação e preferência de consumidores (STONE; SIDEL, 2004).

Embora se apresente como uma avaliação subjetiva, a análise sensorial, ainda é o método de determinação mais utilizado no processo de caracterização qualitativa do café. A classificação sensorial do café pode ser feita por meio da “prova de xícara” (BSCA, 2005). A prova de xícara é importantíssima para a classificação do café, sendo um dos parâmetros utilizados para definir a qualidade do produto. Esta avaliação é feita por degustadores, em função do gosto, olfato e sensores da língua com a bebida (TOLEDO; BARBOSA, 1998). Os principais atributos sensoriais analisados são o aroma, acidez, amargor, corpo, sabor, doçura e impressão global da bebida. A qualidade sensorial do café é definida pela medida da intensidade e equilíbrio desses atributos (BORÉM; MARQUES; ALVES, 2008).

Esta metodologia foi aprimorada com a colaboração de degustadores e pesquisadores brasileiros, até resultar na folha de prova que é utilizada atualmente, na qual são pontuados diversos atributos de qualidade. Sendos dois desses os mais importantes: o aroma e o gosto.

3.5.1 O Aroma

O aroma corresponde aos estímulos nos receptores localizados dentro da membrana nasal. Estes são estimulados pelos compostos químicos que contêm partículas voláteis de hidrogênio, carbono, nitrogênio, oxigênio ou enxofre, que entram em contato por meio da inalação ou deglutição, exemplificado na Figura 2.

Milhares de aromas podem ser caracterizados pelo cérebro através dos sensores da membrana nasal, sendo que uma pessoa pode distinguir entre 2000 a

4000 odores em média. A membrana possui entre 10 a 20 milhões de sulcos receptores.




Figura 2 Região olfativa com gases ou vapores
Fonte: Adaptado de Só Biologia (2014)

Quando dois ou mais gases estão presentes simultaneamente, eles podem produzir um dos resultados listados:

- a) surgimento de um novo odor através da mistura de características de cada;
- b) identificação dos dois odores, sendo que um prevalece como principal;
- c) identificação dos dois odores alternadamente sem imposição;
- d) um odor pode mascarar o outro;
- e) um odor pode neutralizar o outro;

Em relação ao café, todas estas características podem ocorrer simultaneamente.

Enquanto um odor primário não é definido, sensações de odores em cafês podem ser agrupadas em categorias genéricas. Estas categorias são baseadas em componentes naturais conhecidos como frutas, flores, madeira, etc., conforme descrito na Tabela 1.

Tabela 1 Classificação de volatilidade de aromas do café

AROMAS		
Mais voláteis	Moderadamente voláteis	Menos voláteis
Floral	Nozes	Fermentado
Frutado	Caramelo	Apimentado
Ervas	Chocolate	Queimado

Fonte: SCAA (2009)

3.5.2 O Gosto

A gustação é a sensação de gosto sentida pelo palato, membrana mucosa que cobre a língua e cujo estímulos são dados por químicos solúveis.

De modo geral, a língua pode detectar quatro gostos básicos: doce, salgado, azedo e amargo, conforme apresentado na Figura 3.

- a) doce: perceptível por soluções de açúcares, alcoóis e combinações de alguns compostos. São perceptíveis inicialmente por papilas gustativas localizadas na extremidade inferior da língua (próximo aos dentes);
- b) salgado: é conferido por compostos como os cloretos, brometos, iodetos nitratos e sulfetos. São perceptíveis pelas chamadas papilas foliares localizadas nos lados anteriores a extremidade e laterais da língua;
- c) acidez: podem ser exemplificados por soluções de ácido cítricos, e ácidomálico (maçã). São perceptíveis por papilas em forma de cogumelos achatados localizadas na região central e laterais da língua;

- d) amargor: são característicos dos solúveis derivados de quinina, cafeína e outros alcaloides. Percebido primeiramente por papilas situadas na região posterior da língua.

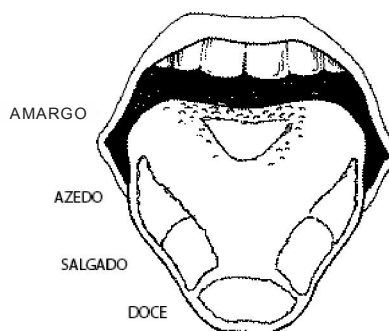


Figura 3 Diferentes áreas com maior sensibilidade de sabores

Fonte: Adaptado de Taste...(2014)

As sensações durante o processo de degustação combinam todos estes sabores básicos, ressaltando que três: doce, salgado e amargo, tendem a dominar.

O termo acidez é utilizado para definir cafés que estejam oxidados. Cafés azedos produzem uma sensação única e desagradável na bebida, também encontrado em vinhos vermelhos (em processo de vinagre), chás com excesso de umidade ou cervejas. Fermentações indesejáveis são as principais causas de aparecimento e intensidade deste atributo.

As percepções de gostos básicos e sabores dependem não somente das propriedades químicas e físicas das substâncias que estimulam os receptores da gustação e olfato, mas também das condições fisiológicas e psicológicas do ser humano (BLUNDELL; ROGERS, 1991).

Conforme Della Lucia, Minin e Carneiro (2006), a análise sensorial apresenta algumas desvantagens, como o custo envolvido para o

desenvolvimento do experimento, além da dependência de fatores ambientais e emocionais relacionados ao instrumento de medida, o homem.

Assim, a análise física dos grãos de café pode ser usada como uma ferramenta auxiliar da análise sensorial, proporcionando maior conjunto de informações sobre o café. Este modelo vem sendo aplicado no desenvolvimento e melhoramento de produtos, controle de qualidade, estudos sobre armazenamento e desenvolvimento de processos.

Em programas de controle de qualidade, essa interação (análise física e sensorial) tem sido usada para medir a qualidade do alimento no âmbito global (físico e químico), também uma equipe pode dar respostas que indicarão a preferência do consumidor, diferenças entre amostras, seleção do melhor processo e determinação do grau ou nível de qualidade do produto (MORAES, 1993).

3.5.3 Metodologia SCAA de Avaliação

Segundo a SCAA (2009), a especialidade de um café é definida por aspectos físico-químicos, que ativam a inteligência sensorial humana proporcionando prazer ao consumo. Assim, um possível indicativo de especialidade pode ser obtido por meio da coloração adequada dos frutos no momento da colheita, ausência de anomalias na semente e sabor diferenciado.

O método de análise sensorial definido pela SCAA é realizado por profissionais treinados e credenciados como juízes (SCAA – *Certified Cupping Judge*), para avaliação de cafés. O protocolo desenvolvido pelo Comitê de Normas Técnicas permite seguir os passos mais indicados para avaliação sensorial.

O protocolo define desde normas e recomendações de utensílios, equipamentos e ambientes adequados para a avaliação, como também o prazo de

descanso entre a torra e a degustação (mínimo de 12 horas), e o tempo de torração de 8 a 12 minutos, dependendo da temperatura e origem do café.

Para a realização da análise sensorial, é recomendável a utilização de 5 xícaras para cada amostra para verificação da uniformidade da bebida do café em relação aos atributos de sabor, finalização, acidez e corpo.

Antes do processo de moagem do café, o protocolo SCAA recomenda queo moinho deva ser aferido, para que o tamanho das partículas moídas passe com 70% do volume por peneira de furos *20mesh* (0,841 mm). A água a ser utilizada para a filtragem deve ser insípida, inodora e de boa procedência, e sua temperatura máxima deve ser de 93°C com variância de 1°C para mais ou para menos.

A água é adicionada diretamente ao café até encher as xícaras, com teor ideal de sólidos dissolvidos entre 125-175 (cerca de 8,25g de café por 150ml de água). As xícaras devem ser vedadas e aguarda-se um período de 3 minutos para a retirada da crosta, aproveitando-se para captar as notas aromáticas nesse momento.

O processo de pontuação deve ser realizado em temperaturas diferentes. A avaliação tem início a 70°, cerca de 9 minutos após a adição de água, a avaliação da bebida deve começar. A bebida é sugada para a boca de tal forma que cubra a maior área possível, especialmente a língua e o palato alto, pois os vapores convergem à área retro nasal na sua intensidade máxima.

Com a continuação do esfriamento, quantificam-se a acidez, corpo e equilíbrio são os próximos a serem quantificados. Quando a temperatura da bebida se aproxima da temperatura do ambiente, a doçura, a uniformidade e a ausência de defeitos são avaliados. Utiliza-se a seguinte ordem para avaliações dos atributos:

- a) *Fragrância e Aroma*: as amostras em pó devem ser avaliadas em até 15 minutos após a moagem do café. Depois da hidratação do pó com água a 93°C forma-se uma crosta, que é mantida intacta, durante 4 minutos, para a primeira percepção dos compostos voláteis em vapor. Após os 4 minutos, são realizadas as rupturas das crostas para uma nova avaliação do aroma, assim como no momento da sucção do café.
- b) *Sabor*: a análise gustativa é iniciada com a retirada da espuma sobrenadante, 8 a 10 minutos após a adição de água. O extrato de café é sugado junto com oxigênio, com objetivo de encobrir toda língua, palato alto e fornecer vapores à área retro nasal. O sabor é um dos atributos de maior peso no julgamento, sendo analisadas intensidade e qualidade.
- c) *Finalização*: após a avaliação do sabor, ao expelir o café, a qualidade e a persistência dos resíduos que ficam na boca é avaliado como finalização ou *aftertaste*.
- d) *Acidez*: após a avaliação da qualidade da finalização do café, a acidez é verificada. Várias categorias são analisadas (cítrica, málica, fosfórica, acética e láctica), bem como sua intensidade.
- e) *Corpo*: com a verificação da acidez, o corpo da bebida se observa pela intensidade de percepções táteis do líquido na boca. A viscosidade da bebida do café denota quantidade de carboidratos e sólidos solúveis presentes.
- f) *Equilíbrio*: constitui a sinergia dos sabores, finalização, acidez e corpo, de forma a verificar se ocorre um bom equilíbrio, o que reflete na pontuação. Eles podem se complementar em harmonia ou contrastar-se.

- g) *Uniformidade*: retrata a igualdade entre todas as xícaras do lote, em todos os atributos avaliados. A cada uma das cinco xícaras que esteja desuniforme por sabor, finalização, acidez, corpo, xícara com defeito e/ou diferença de doçura, dois pontos são penalizados.
- h) *Xícara Limpa*: identificadores de penalização, quando NÃO há uma das xícaras limpas. Também é penalizada a amostra com menos dois pontos.
- i) *Doçura*: refere-se objetivamente à intensidade da sensação de doce da bebida. A xícara que apresentar um intenso amargor indesejável, proveniente da origem do café, cultivar, ou por processo depreciativo da qualidade (ex: cafés com fermentação indesejável, retirando a doçura da bebida) é penalizada com dois pontos.
- j) *Impressão Global*: reflete a coerência em relação a avaliação sensorial feita pelo provador. Expressa principalmente o julgamento pessoal.
- k) *Defeitos*: no final da ficha de avaliação sensorial da SCAA, os defeitos são avaliados de duas maneiras, sendo a soma destes defeitos subtraída da soma total após a avaliação sensorial:
- *Defeitos Leves*: referem-se a um sabor desagradável de menor intensidade, atribuindo-se a penalização de dois pontos por xícara que evidenciá-los.
 - *Defeitos Graves*: referem-se a presença de características sensoriais inaceitáveis, como exemplo, fermentações indesejáveis, atribuindo-se a penalização de quatro pontos por xícara que evidenciá-los.

Estas características sensoriais são avaliadas dentre diferentes amostras, utilizando-se um formulário impresso (Anexo D) composto pelos atributos de fragrância/aroma, sabor, finalização, acidez, corpo, balanço e geral. Notados por

divisões de valores em $\frac{1}{4}$ de ponto (0,25) entre os inteiros “6” a “10”, como apresentado na Tabela 2.


Tabela 2 Pontuação dos atributos de qualidade

Escala de Qualidade			
6.00 – Bom	7.00 – Muito Bom	8.00 - Excelente	9.00 - Excepcional
6.25	7.25	8.25	9.25
6.50	7.50	8.50	9.50
6.75	7.75	8.75	9.75

Fonte: SCAA(2012)

Após a soma dos resultados pode-se obter o grau de qualidade definido de acordo com a Tabela 3.

Tabela 3 Classificação sensorial definida pela SCAA



Fonte: SCAA (2012)

4 SISTEMAS COMPUTACIONAIS

O objetivo de um sistema computacional é o desenvolvimento de paradigmas ou algoritmos que requeiram máquinas para aprimorar tarefas cognitivas, para as quais os humanos são atualmente melhores (SAGE, 1990). Serão apresentados os modelos de visão computacional, os modelos de regressão linear, polinomial e neural, bem como os sistemas computacionais embarcados desenvolvidos neste trabalho.

4.1 Visão Computacional

Um sistema de visão computacional é basicamente composto por uma câmera digital para aquisição de imagem, um padrão de iluminação e um software para processamento e análise de imagem (BROSNAN; SUN, 2003). Um exemplo é mostrado na Figura 4.




Figura 4 Modelo de visão computacional
Fonte: Adaptado de Wu e Sun(2013)

Esse modelo de ferramenta tem por objetivo quantificar cores em diversos alimentos, utilizando para isso equipamentos de fácil acesso a um custo razoável (MENDOZA; DEJMEK; AGUILERA, 2006; SEGNINI; DEJMEK; ÖSTE, 1999; VALOUS et al., 2009).

O uso de sistemas de visão computacional para análises de alimentos tem crescido desde a última década como demonstra os trabalhos de Leon et al. (2006), Shafiee et al. (2014), Valous et al. (2009) e Zhang et al. (2014). Esses trabalhos também relatam que os sistemas computacionais têm por objetivo substituir os colorímetros comuns por modelos que possuem câmeras digitais coloridas, podendo ser chamados de colorímetro digitais.

Ainda segundo os autores, a razão de escolha de um sistema de visão computacional para quantizar alimentos deve-se ao fato de que colorímetros não são muito apropriados quando se trata de amostras em grandes superfícies, por fazerem medições em pequenas áreas por vez, e também quando se trata de amostras não homogêneas.

Existem atualmente diversos modelos na literatura, e algumas aplicações podem ser vistas em: carne bovina (LARRAÍN; SCHAEFER; REED, 2008), carne suína (SUN et al., 2011), peixe (YAGIZ et al., 2009), suco de laranja (FERNÁNDEZ-VÁZQUEZ et al., 2011), vinhos (MARTIN et al., 2007), cervejas (LACHENMEIER, 2007), batatas chips (PEDRESCHI et al., 2011), banana (MENDOZA; AGUILERA, 2004), e grãos de café (SANZ-URIBE; GIRALDO; TASCÓN, 2008).

O modelo de transformação de espaço de cores (RGB para CIELAB), pode ser implementado com estruturas lineares e não lineares, com estimativas de parâmetros pelos mínimos quadrados (SÖDERSTRÖM; STOICA, 1989), modelos de transformada direta (HUNT, 1991), e modelos não lineares baseados em técnicas de inteligência computacional, como as Redes Neurais Artificiais (HAYKIN, 2009).

No entanto, para uma quantificação correta de cores, deve-se primeiro definir o espaço de cores a ser utilizado pelo sistema de visão computacional.

4.1.1 Espaço de cores

O olho humano distingue as cores basicamente pela diferença de intensidade e tonalidade da reflexão da luz. Para isso, os cones da retina possuem picos de sensibilidade em três espectros de frequências, curta (cor azulada, 420-440 nm), média (esverdeada, 530-540 nm), e longa (avermelhadas, 560-580 nm) (HUNT, 1995).

Todavia, para orientação em modelos computacionais, estas diferentes sensibilidades são processadas por hardwares, que realizam a aquisição de imagens, armazenamento e exibição. Estes podem “sentir” as diferentes cores mesmo com uma pequena variação de cor/brilho. Portanto, são comumente utilizados na avaliação de alimentos durante sua fabricação. Um exemplo pode ser encontrado no trabalho de Lana, Tijskens e Kooten (2005), que estudaram as mudanças de coloração em relação a temperatura e tempo de armazenamento de tomates.

Segundo Russ (1999), o modelo padrão em estudos de variação em cores é o RGB (*Red, Green, Blue*). Este modelo utiliza um espaço de cores tridimensionais e, para cada eixo do sistema de coordenadas cartesianas, ele representa cada uma das cores, como apresentado na Figura 5. Entretanto, segundo a International Commission on Illumination (1986), este modelo não deve ser empregado para a construção de modelos de processamento de imagens e visão computacional, pois para uma mesma cor no padrão RGB, podem existir diferentes coordenadas cartesianas, isso dependendo das especificações utilizadas pela fabricante e do modelo da câmera fotográfica utilizada.




Figura 5 Modelo tridimensional RGB
Fonte: Mac Developer Library(2014)

Objetivando a construção de um modelo internacional, em 1931, o CIE elaborou o sistema colorimétrico de escala XYZ, que representa as cores de acordo com a sua cromaticidade (eixos x e y), e a sua luminância (eixo z). Esta estrutura tem sua origem na transformação matemática da luz de acordo com seu comprimento de onda, baseada na capacidade humana de enxergar as cores em sua totalidade. Em 1976, este modelo foi reformulado com as componentes L^* , a^* , b^* , ou CIELab (Figura 6), no qual a cor é localizada por três valores:

- a) **L**, a luminância, expressa em porcentagem (0 para preto e 100 para branco);
- b) **a** e **b**, para os espectros de cores que vão respectivamente do verde ao vermelho e do azul ao amarelo, com o intervalo padrão de -120 a 120.




Figura 6 Representação do modelo de coordenadas cartesianas para CIE Lab

Fonte: Frich (2014)

O modelo CIE Lab cobre assim o espaço visível pelo olho humano e representa-o de maneira uniforme, ao contrário dos minicubos em RGB. Além de ser independente de qualquer tecnologia gráfica, garantindo assim, que uma cor será vista da mesma maneira por qualquer equipamento. Contudo, a implementação deste modelo não é devesas intuitiva (INTERNATIONAL COMMISSION ON ILLUMINATION, 1986).

4.2 Modelos de regressão

Uma das tarefas mais importantes do modelo de aprendizagem de máquinas é a regressão. Nessa etapa é definida uma função de distribuição de dados de entrada conforme as saídas desejadas, buscando assim replicar um modelo específico. Um exemplo é a busca de uma função que represente o comportamento de um medidor de torra baseado em uma população de amostras.

As regressões podem ser obtidas basicamente por dois modelos, o linear e o polinomial. Na regressão linear a função que deve ser aprendida é uma relação linear entre entrada e saída. Modelos lineares são simples, tratáveis matematicamente e bastante úteis. No entanto, para solução de problemas mais complexos, deve-se empregar modelos não lineares. A seguir, dois tipos de modelos são apresentados: os modelos polinomiais e os modelos neurais.

4.2.1 Modelos polinomiais

De forma geral, os modelos consideram a relação existente entre dados observados de entrada do modelo e dados observados de saída. Ou seja, todos os dados estão disponíveis, o que falta é uma função que os relacione corretamente.

O modelo polinomial pode ser exemplificado por uma hipótese de função, f , cujas entradas são os valores de X , definido por:

$$X = [x_1, x_2, x_3 \dots x_n], (1)$$

sendo que $X \in \mathbb{R}^{m \times n}$, em que m é o número de observações (amostras) e n é o número de entradas.

Como saída deste modelo, é obtido um conjunto de valores Y , apresentado por:

$$Y = f(X, \theta) = \theta_0 + \theta_1 * x_1 + \theta_2 * x_2 + \theta_3 * x_3 \dots + \theta_n * x_n + e, (2)$$

ou, na forma matricial,

$$Y = X\theta + e, (3)$$

em que e , é o erro de observação do modelo (ruído ao obter os dados e modelá-los), e θ são as variáveis, parâmetros do modelo, que se deseja ajustar. Dessa forma, a função f é chamada de linear nos parâmetros.

A qualidade da estimação é dependente da natureza do ruído, da estrutura do modelo, do tipo de aplicação e da “riqueza” da informação contida

nas medidas. Para tornar a resposta mais precisa, é útil definir o somatório do quadrado dos erros para o ajuste dos parâmetros da função polinomial:

$$S = \sum_{i=1}^n \xi_i^2 = \sum_{i=1}^n (W - f(X, \theta))^2, \quad (4)$$

em que W é a saída desejada, observada no sistema que se deseja replicar.

Uma forma de obter os parâmetros do modelo que minimizam o somatório dos erros quadráticos, apresentado na Eq. 5, é utilizando o estimador de mínimos quadrados. Pois este possui uma fácil implementação e garante o encontro do ponto de ótimo global (melhor ajuste para o conjunto de todas as entradas), considerando a estrutura do modelo e os dados utilizados.

Para obtenção dos parâmetros do modelo, θ , utilizando o algoritmo de Mínimos Quadrados (MQ), a seguinte expressão deve ser realizada:

$$\theta = [X^T X]^{-1} X^T W, \quad (5)$$

onde uma matriz $[X^T X]^{-1} X^T$, conhecida como matriz pseudoinversa, é multiplicada por W . No entanto, para aplicação do algoritmo, deve-se garantir que a matriz $[X^T X]^{-1}$ seja não singular.

A definição da estrutura das entradas a serem utilizadas em X , é uma etapa muito importante no processo de modelagem do sistema real, pois a quantidade de entradas utilizadas define a flexibilidade do mesmo ao tentar explicar a relação entre a entrada e a saída do sistema a ser modelado.

A flexibilidade de um modelo está diretamente relacionada com sua complexidade. Os modelos polinomiais menos complexos, conseqüentemente menos flexíveis, são os modelos lineares, em que as entradas observadas, (x_1, x_2, \dots) são utilizadas diretamente na matriz X .

Quando esses modelos lineares não são suficientes para explicar as relações entre entradas e saída do sistema, é necessário o uso de funções não lineares, ou polinomiais. Nos modelos polinomiais, uma forma de inserir a não linearidade no mesmo é transformando as entradas por meio de funções não lineares. Por exemplo, um modelo polinomial não linear pode ser obtido elevando as entradas ao quadrado como: (x_1^2, x_2^2, \dots) , e também utilizando termos cruzados como $((x_1 * x_2) + (x_1 * x_n) + \dots)$, fazendo com que o modelo fique mais flexível. Deste modo, o termo de não linearidade do modelo foi considerado de grau 2, podendo ser acrescido mais graus caso as estruturas ainda mais flexíveis sejam desejadas.

As principais etapas envolvidas para a definição da escolha de um modelo de regressão são apresentadas na figura 7. Esta definição pode ser basicamente dividida nas etapas: coleta de dados, escolha do modelo, definição da sua estrutura, estimação dos seus parâmetros e validação.

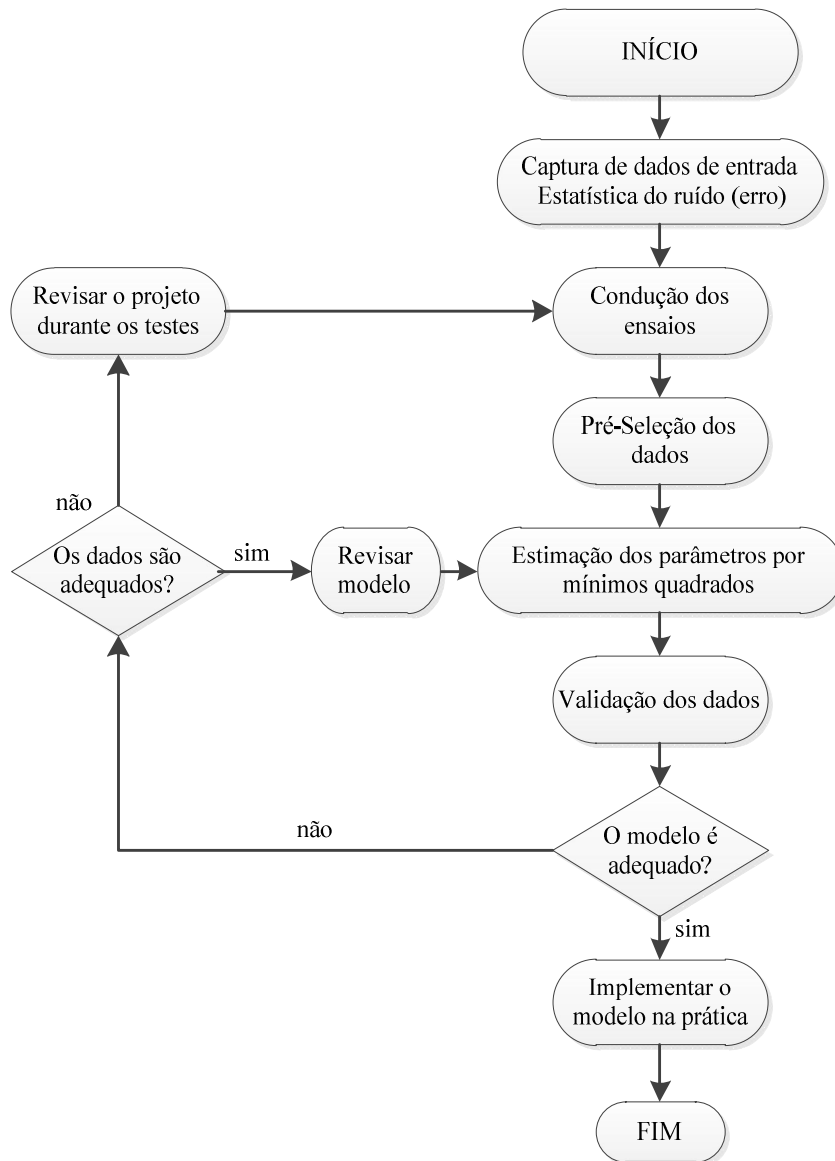


Figura 7 Diagrama de definição de modelagem
Fonte: Adaptado de Coelho e Coelho(2004)

4.2.2 Modelos Neurais

Na seção anterior, os modelos polinomiais foram introduzidos. Apesar destes permitirem a modelagem de sistemas não lineares, a escolha adequada de sua estrutura, como o grau de não linearidade e o número de entradas necessárias para obtenção de um bom modelo pode ser uma tarefa difícil, fazendo com que o modelo necessite de um número grande de amostras para seu alinhamento.

Uma forma de evitar o trabalho inerente à escolha da estrutura do modelo polinomial não linear é o uso de modelos neurais, ou seja, as Redes Neurais Artificiais (RNA). Estas são consideradas aproximadoras universais de funções por meio de processamento paralelo, isso significa que podem aproximar qualquer função real contínua sem que seja necessária a escolha específica de termos não lineares como entradas, como no caso de modelos polinomiais.

As RNA abrangem o campo da Ciência da Computação ligado à Inteligência Computacional (Figura 8), que implementa modelos matemáticos que se assemelham à possibilidade de adaptação através da interação com o meio externo. Tem como propriedade mais importante a capacidade de aprender por intermédio de exemplos (treinamento) e fazer inferências sobre o que aprendeu, melhorando gradativamente o seu desempenho.

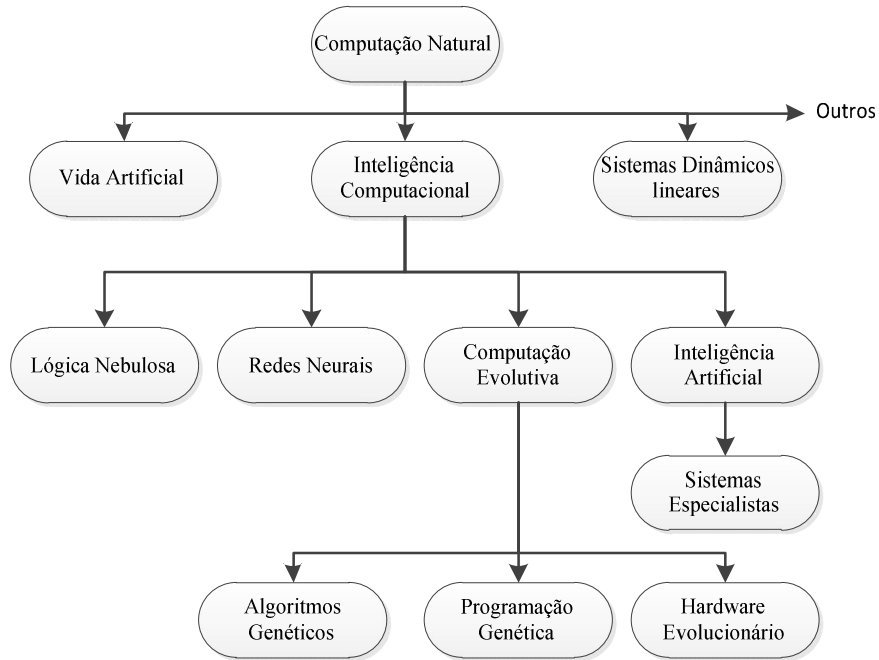


Figura 8 Áreas e subáreas da Inteligência Computacional
 Fonte: Adaptado deCastro eZuben(2004)

Segundo Bocanegra (2002), Redes Neurais Artificiais são estruturas computacionais construídas com base no funcionamento do cérebro e seus neurônios, com o objetivo de simular nos computadores a capacidade de aprendizagem do cérebro humano.

Neste sentido, para entender o funcionamento de uma RNA, é importante conhecer o aprendizado biológico, tema abordado a seguir.

4.2.2.1 Aprendizado Biológico

Um neurônio é uma célula biológica responsável por armazenar conhecimento, sendo formado basicamente por três segmentos distintos com

funções específicas e complementares: corpo, dendritos e axônio. Uma representação do neurônio é apresentada na Figura 9.




Figura 9 Modelo de Neurônio biológico
Fonte: Gopixpic(2014)

Os dendritos captam os estímulos recebidos em um determinado período de tempo e os transmitem ao corpo do neurônio, onde são processados, quando tais estímulos atingirem determinado limite (ou limiar), o corpo da célula envia um novo impulso que se propaga pelo axônio e é transmitido às células vizinhas por meio de sinapses.

Sinapses são junções em que um terminal (axônio) faz contato com um dendrito de outro neurônio. Estas podem ser elétricas ou químicas (maioria). Estes contatos geram ondas de corrente elétrica excitatórias ou inibitórias que constituem a informação que o neurônio processará. Os impulsos passam pela sinapse através de neurotransmissores, que promovem a entrada de sódio no neurônio, provocando inversão de cargas elétricas e a condução de um impulso nervoso no neurônio estimulado (MIRANDA-VILELA, 2006). O processo pode se repetir em várias camadas de neurônios, constituindo assim o cérebro humano.

Segundo Braga, Carvalhoe Ludermir(2000), o cérebro humano é responsável pelo que se chama de emoção, pensamento, percepção e cognição, assim como pela execução de funções sensório-motoras e autônomas. Além

disso, tem a capacidade de reconhecer padrões e relacioná-los, usar e armazenar conhecimento por experiências, além de interpretar observações para solução de tarefas.

O aprendizado é um conceito de difícil definição, entretanto, de fundamental importância para a construção de um sistema dotado de capacidade de aprendizado de máquina.

Segundo Osório e Bittencourt (2000), a capacidade de aprender está diretamente relacionada aos seguintes itens:

1. adaptação e mudanças de comportamento de forma a evoluir (melhorar segundo alguns critérios). Um sistema biológico ou artificial, que não seja capaz de evoluir ou de mudar seu comportamento diante de novas situações que lhe são propostas é um sistema sem inteligência;
2. correção dos erros cometidos no passado, de modo a não repeti-los no futuro. Este item está diretamente relacionado ao anterior, o sistema deve modificar seu comportamento caso o comportamento atual não satisfaça a algum tipo de exigência (onde a sobrevivência deve ser um dos quesitos mais importantes a serem considerados nos seres vivos);
3. otimização e melhoria da performance do sistema como um todo. O aprendizado pode implicar em uma mudança do comportamento que busque: a economia de energia gasta para realizar uma tarefa, a redução do tempo gasto numa tarefa, etc. Em relação a otimização, se faz necessário lembrar que se pode ter requisitos opostos, onde pode-se maximizar ou minimizar custos de acordo com algum tipo de critério;
4. interação com o meio, pois é através deste contato com o mundo que o cerca, no qual é possível trocar experiências e/ou realizar experiência, que novos conhecimentos são adquiridos;
5. representação do conhecimento adquirido. O sistema deve ser capaz de armazenar uma massa muito grande de conhecimentos, e isto requer uma forma de representar estes conhecimentos que permita ao sistema explorá-los de maneira conveniente. Como os recursos são limitados, é necessário ter uma maneira de guardar conhecimentos e regras gerais, pois guardar tudo seria muito difícil (exige

muita memória, dificulta o uso pela lentidão da consulta aos conhecimentos).

Seguindo estas designações é possível a representação de um modelo implementado em meios computacionais.

4.2.2.2 Aprendizado Computacional

Em 1943, Warren S. McCulloch, neurocientista, e Walter Pitts, matemático, publicaram um artigo intitulado “*A logical calculus of the ideas immanent in nervous activity*”, em um periódico de Matemática e Biofísica. Neste trabalho McCulloch e Pitts tentavam entender como o cérebro é capaz de produzir padrões de alta complexidade, utilizando-se apenas de células básicas interligadas (neurônios). Estas células foram modeladas no artigo como conectores eletrônicos lógicos, como mostrado na Figura 10. Assim surgia o termo “*Neurônio Artificial*”.




Figura 10 Conector eletrônico lógico definido por McCulloch e Pitts
Fonte: Adaptado de McCulloch e Pitts(1943)

Em 1949, Donald Hebb desenvolve um modelo de aprendizagem para o neurônio ajustando matematicamente os pesos de entrada (HEBB, 1949). Este sistema foi nomeado "*Regra de Hebb*", que é utilizado até os dias atuais em sistemas de treinamento de RNA:

Vamos assumir que a persistência ou repetição de uma atividade reverberatória tende a induzir mudanças celulares duradouras que promovem estabilidade. Assim, quando um axônio da célula A está próxima o suficiente para excitar a célula B e repetidamente ou persistentemente segue fazendo com que a célula dispare, algum processo de crescimento ou alteração metabólica ocorre em uma ou ambas as células, de forma que aumente a eficácia de A, como uma das células capazes de fazer com que B dispare (HEBB, 1949, p. 132-133).

Em 1959, Frank Rosenblatt propôs um novo modelo de neurônio, denominado *perceptron*, e o arranja em forma de rede composta em duas camadas (ROSEMBLAT, 1958). A primeira camada (considerada a entrada) é constituída por valores constantes durante o treinamento, ficando o aprendizado restrito ao ajuste dos pesos da segunda camada (considerada a saída).

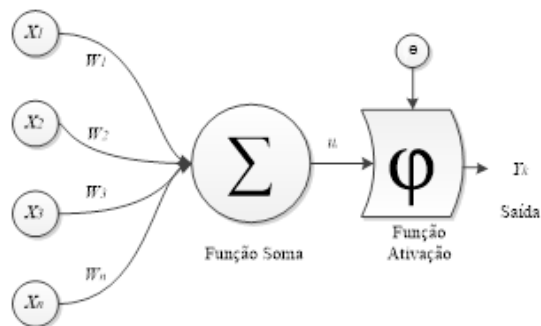


Figura 11 Adaptação do modelo Perceptron definido por Rosenblatt (1958)
Fonte: Adaptado de Braga, Carvalho e Ludermir(2000)

O modelo *perceptron*(Fig. 11)é, portanto, descrito por um conjunto de *n*entradas,sendo paracada entrada é multiplicada por um determinado peso, e em seguida os resultados são somados e comparados a um limiar.

Com base na Figura 11, é possível elencaralguns dados importantes na estrutura do neurônio:

- a) os pesos sinápticos, representado pela letra (W), são valores numéricos multiplicativos das entradas, que representa sua intensidade. O papel do peso (W_n) é multiplicar o sinal (X_n) na entrada da sinapse (n). Este peso é positivo se a sinapse for excitatória e negativo se a sinapse associada for inibitória;
- b) no somatório (*função soma*) são adicionadas as entradas ponderadas por cada peso correspondente:

$$u = \sum_{i=1}^n W_i x_i .(6)$$

- c) o limiar (*Threshold*), θ , tem papel determinante na saída do neurônio. Sua função é controlar o ajuste de uma função de ativação (φ), podendo ser de tipos linear ou não, como tangente hiperbólica logística, para a obtenção de desempenho desejado na rede. A saída da função de ativação é dada por:

$$y = \varphi(u + \theta) .(7)$$

onde u é a saída do combinador linear de entrada e θ é o limiar; φ é a função de ativação; e y é o sinal de saída do neurônio.

No entanto, o *perceptron* isolado não é capaz de executar algumas tarefas, tais como detecção de paridade, conectividade e simetria, as quais formam uma ampla gama de funções matemáticas. Obrigando a interligação em redes *perceptron* de múltiplas camadas para solução de problemas matemáticos mais complexos. Porém, o treinamento destas redes não é uma tarefa trivial, e, somente a partir de 1986, com a publicação de Hopfield e com a formulação do algoritmo de treinamento de retropropagação de erro (do inglês

backpropagation), foi possível o treinamento adequado destas redes (RUMELHART; HINTON; WILLIAMS, 1986).

Segundo Ribeiro e Centeno (2002) treinar uma rede neural significa ajustar a sua matriz de pesos, de forma que o vetor de saída coincida com um certo valor desejado para cada valor de entrada, de maneira supervisionada ou não. No aprendizado supervisionado, a saída desejada do modelo é conhecida e utilizada como forma de aferir quão ajustada aos dados a rede está. No aprendizado não supervisionado, apesar da saída poder ser conhecida, ela não é utilizada durante o processo de ajuste de parâmetros da rede.

O algoritmo de treinamento supervisionado baseado em retropropagação é utilizado para treinar redes multicamadas ou redes MLP (do inglês *Multi-Layer Perceptron*), permitindo ajustes de pesos sinápticos em cada uma de suas camadas, minimizando assim o erro médio quadrático entre suas saídas e as saídas desejadas. A característica principal desse algoritmo é a maneira interativa pela qual os erros são propagados para trás, isto é, a partir da camada de saída.

Galo (2000) resume este processo de treinamento em duas fases distintas. Na primeira, um vetor de treinamento, com a respectiva saída desejada é apresentado à rede e propagado através de suas camadas para computar uma saída para cada elemento de processamento. As saídas dos nós da última camada são, então, comparadas com as saídas desejadas (supervisionado), e a partir disso são calculados os termos de erro. A segunda fase envolve um retrocesso, ou seja, uma passagem de volta através da rede a partir da última camada, durante a qual o erro é repassado para cada elemento de processamento e os pesos correspondentes são convenientemente alterados. Em um treinamento bem-sucedido, este erro diminui com o aumento do número de iterações e o procedimento converge para um conjunto estável de pesos.

4.3 Sistemas Embarcados

Segundo Carro e Wagner (2003), os sistemas embarcados estão presentes em praticamente todas as atividades humanas e, com os baixos custos tecnológicos atuais, tendem a aumentar sua presença no cotidiano das pessoas. Um bom exemplo de tais sistemas são os computadores portáteis, também conhecidos como celulares *smart phones*.

Projetar sistemas eletrônicos é extremamente complexo, por envolver grandes desafios de sensibilidade na captura de sinais, comunicação entre dispositivos, respostas *just-in-time*, etc. Uma possibilidade para automação é utilizar-se de dispositivos de prototipação testados por instituições certificadoras confiáveis, como o Arduino, descrito a seguir.

4.3.1 Arduino

O projeto Arduino teve início na cidade de *Ivrea* na Itália em 2005, com o intuito de desenvolver projetos escolares a um custo menor do que outros sistemas de prototipagem disponíveis naquela época. O sucesso do projeto foi sinalizado com o recebimento de uma menção honrosa na categoria Comunidades Digitais em 2006, pela *Prix Ars Electronic* (Prêmio das artes eletrônicas, Linz-Austrália). Estima-se que já foram vendidas mais de 500 mil placas em todo o mundo (ARDUINO, 2015).

O Arduino é uma plataforma de prototipagem eletrônica de hardware livre, projetada com um microcontrolador Atmel AVR, com linguagem de programação padrão, essencialmente C/C++. O objetivo do Arduino é criar ferramentas acessíveis, flexíveis, com baixo custo e fáceis de serem usadas por profissionais e amadores.

O *hardware*, apresentado na Figura 12, consiste em um microcontrolador Atmel AVR de 8 bits com componentes complementares para facilitar a programação e a incorporação para outros circuitos. A grande maioria das placas inclui um regulador de tensão linear de 5 volts, um oscilador de cristal de 16 MHz e utilizam a série de chips megaAVR, principalmente os Atmega8, ATmega168, ATmega328 e o ATmega1280.

O *Software*, Arduino IDE, é uma multiplataforma escrita em Java, derivada dos projetos *Processing* e *Wiring*, possuindo a capacidade de ser programado em C/C++/Java/Python.




Figura 12 Hardware Arduino UNO
Fonte:MIT App-Inventor(2014)

4.3.2 Sensor de temperatura

Atualmente existem diversos sensores de temperatura para os mais diversos usos. Todavia, talvez nenhum seja de tão simples manuseio e tão pequena exigência eletrônica para que funcione, quanto ao circuito eletrônico

modelo LM-35 da *Texas Instruments*, pois o circuito é de simples organização, necessitando do sensor propriamente dito, um sistema amplificador de sinal e de uma interface que realizará a leitura gráfica (Arduino).

O LM-35 possui encapsulamento similar aode um transistor como ilustrado na Figura 13.



Figura 13 Sensor de temperatura LM-35
Fonte: Webtronico (2015)

O circuito possui uma vantagem sobre os modelos calibrados em kelvin, pois o circuito amplificador não necessita subtrair sua tensão de saída para obtenção da escala em Celsius, tornando o processo de obtenção de dados mais preciso ($\frac{1}{4}$ de Grau).

A abrangência para medição de temperatura cobre a faixa entre -55 a +150 °C.

4.3.3 Transmissor Bluetooth

O padrão Bluetooth, também conhecido como padrão IEEE 802.15.1, é baseado em transmissão de dados sem fio por ondas de rádio de baixa potência.

A tecnologia Bluetooth é resultado da cooperação de diversas empresas, tendo sido inicialmente concebida para substituir cabos de conexão entre dispositivos eletrônicos, buscando assim promover uma solução de baixo custo e baixo consumo de energia principalmente para as redes locais, substituindo cabos de dispositivos portáteis e transportáveis num raio de até 10 metros.

Segundo Tanenbaum (2003), o padrão possui esta nomenclatura em homenagem ao rei viking Harald Blaatand Bluetooth II (949-981), por ter conquistado a Dinamarca e a Noruega sem utilizar a navegação por cabos.

Um exemplo é o módulo concebido pela empresa canadense DK Electronics®, modelo HC-05 classe 2, com alcance de até 10 metros e funcionamento em 3 ou 5 Vcc. O fluxo de dados suportado é de 9600 à 115200 bits por segundo, podendo ser empregado como responsável pela conexão (*handshake*), ou como escravo de outros dispositivos.

Sua instalação é simples, bastando conectá-lo ao Arduino e executar uma aplicação de testes. Ele também possui um sistema de login com nome de usuário e senha para maior segurança das comunicações. Na Figura 14 está uma imagem deste módulo.




Figura 14 Módulo bluetooth HC-05
Fonte: Webtronico (2015)

Por ser um hardware muito pequeno, com 4,5 cm de comprimento por 2,2 cm de largura, pode ser facilmente integrado a equipamentos portáteis como o Arduino. Seu consumo médio é de 25 mA/h, o que permite uma autonomia de cerca de 4 horas, se alimentado por uma bateria de 9 volts. Sua antena helicoidal

(dourada) permite operações em ambiente com outros dispositivos de RF, como Wi-Fi, sem perder a eficiência, proporcionando assim maior segurança e confidencialidade.

4.3.4 APP Inventor

O *App Inventor* é uma plataforma para criação de aplicativos para o sistema operacional Android baseada na web, que provê uma interface visual de programação em blocos, tem como objetivo permitir que qualquer pessoa, mesmo sem um profundo conhecimento de codificação, possa construir aplicativos para o Android (Google) ou iOS (Apple). A ferramenta utiliza um editor baseado em funções, que é programado a partir da biblioteca *Open Blocks*, para a linguagem de programação Java (Figura 15).

O *App Inventor* aplica os conceitos de computação em nuvens, o que permite que os usuários possam acessar e programar seus projetos de modo independente da plataforma, sem a necessidade de instalar e configurar todo o ambiente de desenvolvimento e, independente do local, oferece ao usuário maior flexibilidade para desenvolver seus aplicativos.

A primeira versão *trial* do *App Inventor* foi lançada em julho de 2010, pelo Google e a versão oficial foi lançada em dezembro de 2010. Inicialmente a plataforma pertencia e era mantida pelo Google, que em 2011 abriu mão do projeto e financiou a criação do *The MIT Center for Mobile Learning*, que passou a desenvolver e manter o serviço. A versão do *App Inventor* do MIT foi lançada em março de 2012, e atualmente se encontra na versão 2.35 (19/11/2015).

Até maio de 2014, havia 87 mil usuários ativos semanalmente no serviço e 1,9 milhões de usuários registrados em 195 países, num total de 4,7 milhões de aplicativos criados (MIT APP-INVENTOR, 2015).

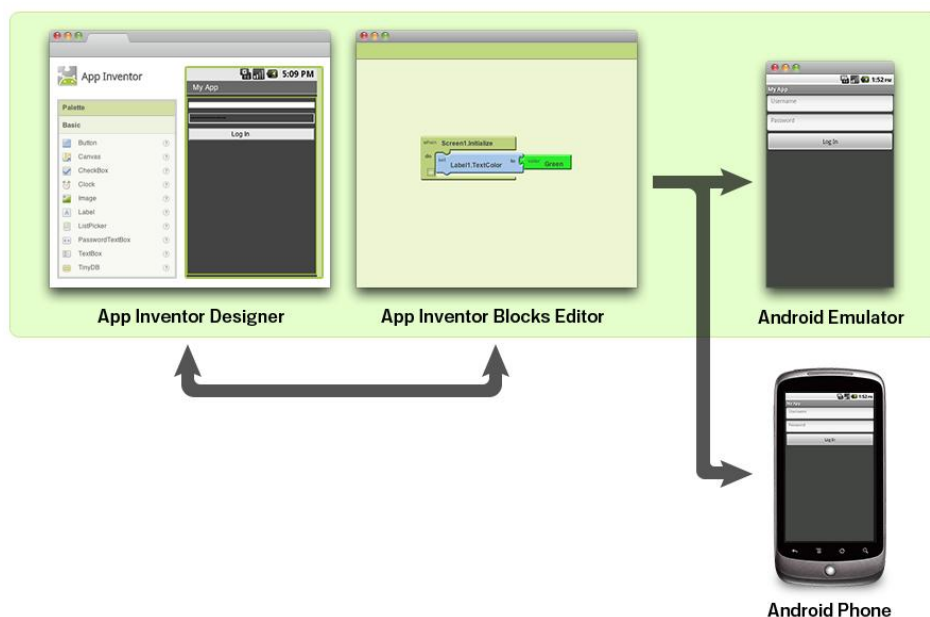


Figura 15 Organização do fluxo de etapas para programação em App Inventor
 Fonte: MIT App-Inventor (2014)

Segundo Lecheta(2010), o mercado de celulares está crescendo cada vez mais, e como consequência, cresce as possibilidades para mobilidade de seus usuários que cada vez mais procuram por dispositivos com novos recursos, como câmeras com alta resolução, maior tamanho dos displays, maiores resoluções de tela, maior autonomia de bateria e maior desempenho.

Com essa crescente evolução da mobilidade, os setores científicos sentiram a necessidade de incorporar aplicações em dispositivos móveis para agilizar suas pesquisas e também integrar os diversos dados existentes. Alguns exemplos dessas possibilidades podem ser encontrados em Pereira e Silva (2009).

4.4 Sistema de Gerenciamento de Banco de Dados

O Sistema de Gerenciamento para Banco de Dados (SGBD), por essência, permite que Bancos de Dados sejam corretamente compartilhados por muitos usuários e aplicações utilizando manuseio de armazenamento e estratégias de otimização. Conforme descrito em Neves (2002), é necessário manter sempre os dados para executar as tarefas de leitura a partir do banco de dados, preservando sua integridade. São alguns exemplos de Sistemas de Gerenciamento de Banco de Dados de relacionamento por conexão entre tabelas: Oracle, Interbase, SQL Server, Firebird, Ingress, Sysbase, PostgreSQL, MySQL, dentre outros. Entre as principais características destes sistemas, destacam-se:

- a natureza “autocontida” (armazenamento e esquemas);
- a independência entre programas e dados;
- a abstração dos dados;
- uso de restrições de usuário para acesso aos dados;
- permitir backup e recuperação de estrutura e de dados;
- flexibilidade em mudanças de sistemas;
- redução do tempo de desenvolvimento das aplicações;

Os SGBD de relacionamento (relacional), são aplicados em projetos com diversas necessidades por serem concisos, completos, anti-redundantes e consistentes internamente. Ainda de acordo com Neves (2002), estes são os melhores modelos de estruturação de Banco de Dados desenvolvidos para armazenamento de informações em formato hexadecimal (números e letras).

O modelo relacional revelou-se ao longo dos anos, ser o modelo mais flexível e adequado ao solucionar os vários problemas que se colocavam ao nível da concepção e implementação da base de dados. A estrutura fundamental do modelo relacional é a relação. Uma relação é constituída por um ou mais atributos (campos ou células de uma tabela), que traduzem o tipo de dados a armazenar. Cada instância do esquema (linha) designa-se por uma tupla (registro da tabela). O modelo relacional implementa estruturas de dados organizadas em relações (tabelas). Porém, para o correto funcionamento do banco, algumas restrições devem ser impostas para evitar aspectos indesejáveis no modelo relacional, tais como, repetição de informações, incapacidade de representação de parte de dados e perda de informações. As restrições foram definidas como monitoramento da integridade referencial, criação de chaves, monitoramento da integridade de junções de relações.

Segundo Elmasri e Navathe (2005), o modelo relacional representa o banco de dados como uma coleção de relações informalmente semelhantes a uma tabela de valores, ou, até certo ponto, a um arquivo de registros plano.

Quando uma relação é comparada a uma tabela de valores, cada linha da tabela representa uma coleção de valores de dados relacionados. O nome das tabelas e os nomes das colunas são utilizados para auxiliar na interpretação do significado dos valores em cada linha.

Na terminologia formal do modelo relacional, uma linha é chamada de tupla, o título da coluna é o atributo e a tabela é chamada de relação. O tipo de dado que descreve o conteúdo das células de uma coluna é denominado domínios da relação. Ilustrado na Figura 16.

Atributos

cod_cafe	pto_fisica	umidade	L	a
Carmopolis_2513	87	112	85.7	-12.5
SantaRita_2513	79	98.8	85	-121
Carmopolis_2514	79	123	85.77	12.5
Itajuba_1313	99	100	80	12

Tupla
 Relação
 D

Figura 16 Representação dos conceitos do modelo relacional

4.4.1 Chaves primária e estrangeiras

Um banco de dados é composto por diversas tabelas que armazenam os dados operacionais dos sistemas que são implementados. Dependendo do tipo e quantidade de dados que se deseja armazenar, são criados mais de um banco, um para cada domínio da aplicação. E suas restrições de integridades e referencial, gerenciadas por conexões entre bancos por meio de chaves de endereçamento.

Uma chave de endereçamento primário corresponde a uma ou várias colunas de uma tabela que não possuem valores duplicados em sua relação. E uma chave estrangeira corresponde a uma ou várias colunas de uma tabela em que os valores estejam identificados como chaves primárias de uma outra tabela. A chave estrangeira é desta forma um mecanismo que define os relacionamentos em um banco de dados relacional (DATE, 2000).

Uma chave estrangeira é um conjunto de atributos de uma relação cujos valores correspondem a valores de alguma chave candidata em outra relação. Por exemplo, avaliadores e análise sensorial, quando é realizada uma análise em determinada amostra de café, é necessário que esta esteja vinculada a um avaliador, assim um avaliador deve ser associado a um código que é chave primária na tabela avaliador e chave estrangeira na tabela análise sensorial. Este

atributo é então considerado chave estrangeira neste relacionamento. As chaves estrangeiras são ferramentas poderosas para a manutenção da integridade do banco de dados. A Figura 17 apresenta um exemplo de chave estrangeira.



Figura 17 Exemplo de chave estrangeira

4.4.2 Integridades

Segundo Date (2000), a integridade refere-se à precisão ou correção de dados em um Banco de Dados. Neste contexto a integridade significa semântica, e são consideradas as restrições que representam o significado dos dados e não estes em si. São considerados dois tipos principais a de entidade e a referencial.

A restrição de integridade de entidade é especificada em relações individuais e declara que nenhum valor da chave primária pode ser nulo. Isso se justifica porque o valor da chave primária sendo nula, implica que não poderemos identificar nenhuma tupla (ELMASRI; NAVATHE, 2005). Por exemplo, no caso de um avaliador ter uma chave ID nula, uma ou mais avaliações não poderão ser identificadas corretamente.

A restrição de integridade referencial é especificada entre duas relações e utiliza para manter a consistência entre tuplas dessas relações. Informalmente, a restrição de integridade referencial declara que uma tupla em uma relação que se refere a uma outra relação, deve ser referida a uma tupla existente naquela relação (ELMASRI; NAVATHE, 2005). Isso é ilustrado na Figura 18, onde o exemplo da chave estrangeira é configurado para que se um avaliador (ID ou

Nome) for removido, todastuplas das avaliações relacionadas a ele também serão removidas em cascata, isso garantirá sua integridade referencial.



Figura 18 Exemplo de integridade em chaves estrangeiras

Num passado recente a escolha de qual SGBD utilizar em uma aplicação dependia fundamentalmente de questão técnicas e dos valores cobrados por suas licenças comerciais. Atualmente isso não é mais uma realidade devido ao surgimento de diversos SGBD integrados, gratuitos e *Open source*.

Software livre é uma realidade cada vez mais constante no mundo da informática. O mesmo fato ocorreu com banco de dados. Com um mercado de sistemas proprietário bastante consolidado, incluindo as grandes empresas com o Oracle, IBM e Microsoft, os Banco de Dados livres, tais como MySQL e PostgreSQL, já se destacam soluções de problemas de baixo custo, implantados em multinacionais e instituições de ensino.

O MySQL foi escolhido para o desenvolvimento deste projeto por ser um sistema Gerenciador de Banco de Dados Relacional completo, de fácil implementação e validação e por ser um sistema grátis/livre.

5 MATERIAIS E MÉTODOS

5.1 Plataforma de Integração de Informações

A etapa do projeto da plataforma abordada neste trabalho tem como diretriz a criação de um sistema integrado para classificação de café, utilizando métodos instrumentais de análise digital de imagens de amostras por meio de visão computacional para reconhecimento de padrões. Além disso, outro objetivo é integrar todas as informações de análises físicas, químicas e sensoriais em uma única base de dados. A seguir, a estrutura da plataforma abordada neste trabalho é apresentada.

5.1.1 Estrutura

A estrutura da plataforma, ilustrada na Figura 19, possui os seguintes equipamentos/etapas enumerados conforme a ordem de implementação:




Figura 19 Componentes que fazem parte da Plataforma de Integração de Informações desenvolvidas neste trabalho

- I. sistema de Visão Computacional e de reconhecimento de padrões responsável por caracterizar cor em CIELab dos cafés torrados (em grãos e moídos), e por estimar seu valor de tonalidade de torra (Agtron);
- II. módulo para aquisição de temperaturadas xícaras durante a análise sensorial. A temperatura das amostras deve ser monitorada com o objetivo de orientar os avaliadores em suas pontuações finais;
- III. aplicações Android que permitam catalogar as amostras de café, exibir as curvas de torra aplicadas as amostras, bem como receber as pontuações das análises sensoriais por meio de uma representação da planilha de pontuação SCAA. Além disso, a aplicação envia informações para o servidor de banco de dados.
- IV. aplicação para aquisição do gráfico de torrae envio ao Banco de Dados (data / hora / temperatura);
- V. servidor de Banco de Dados implementado responsável por receber, organizar e disponibilizar os dados das amostras de café analisadas.

Com a criação desse servidor, espera-se alimentar uma base de dados para uso de pesquisas futuras em qualidade de cafés.

5.2 Materiais

Nesta seção, serão apresentados os materiais necessários para a construção do sistema de reconhecimento de padrões de torra em cafés (grãos e moídos). Este sistema é basicamente composto por:

- um sistema de aquisição de imagens;
- um modelo de transformação de espaço de cores (RGB para $L^*a^*b^*$);
- modelos de regressão para cálculo do valor do grau de torra das amostras de cafés, sendo um modelo para amostras em grãos e um modelo para amostras moídas.

Assim, serão apresentadas nesta seção, além do sistema de aquisição de imagens, as amostras de cafés e cartelas de cores utilizadas para implementação dos referidos modelos.

5.2.1 Sistema de visão computacional e reconhecimento de padrões

Neste trabalho, o sistema compacto da empresa Major Science (Fig.20), foi utilizado para a aquisição das imagens das amostras de café. Este sistema é composto por:

- I. uma câmera digital modelo G-12/Canon (Canon, EUA), de 12 Megapixels, para captura de imagens em alta resolução.
- II. painel de interruptores para as duas lâmpadas de LED de luz-branca com três watts cada, posicionadas nas laterais superiores;

- III. um display digital de 8" polegadas TFT, com resolução de 800x600 conectado a saída HDMI da câmera para melhor visualização dos objetos fotografados;
- IV. amostras a serem fotografadas, dispostas em fundo negro para minimizar efeitos de reflexo.



Figura 20 Plataforma para aquisição de imagens

A câmera fotográfica é posicionada a 40cm acima das amostras, com a configuração de ajuste para luz fluorescente branca sem flash automático, com distância focal de abertura de diafragma da lente igual a 60 (f/60), tempo de exposição 1/10s e velocidade de captura igual a ISO 160. Todas as fotos utilizaram sua maior resolução e foram salvas sem compressão e com a extensão CR2 (padrão para as câmeras Canon).

5.2.2 Cartelas de cores e histograma

Um banco de dados foi construído com 106 fotos de cartelas de tinta acrílico fosco, cartelas estas cujas cores foram escolhidas inicialmente, por comparações visuais, e posteriormente confrontadas com os discos Agtron para

confirmação de sua semelhança. Este banco de dados é utilizado para construção do modelo de transformação de espaço de cores, do padrão RGB para $L^*a^*b^*$. Algumas cartelas são apresentadas na Figura 21.




Figura 21 Cartelas utilizadas para identificação do modelo de transformação de espaço de cores

A partir de um colorímetro Minolta modelo CR 300 (Figura 22), foram realizadas 3 coletas dos valores de L, a e b para cada cartela, com baixa variação entre os pontos, sendo que a média dessas medições foi considerada como o valor final da cor da cartela no padrão CIELab, tentando assim, minimizar ao máximo o erro das medidas.



Figura 22 Colorímetro utilizado para as medições de $L^*a^*b^*$ das cartelas de cores
Fonte: Minolta (2015)

As cartelas foram escolhidas de forma a obter ampla faixa de cores que cubra as possíveis cores do objeto de pesquisa deste trabalho, conforme pode ser constatado pelas distribuições dos valores de L^* , a^* e b^* das cartelas e dos discos Agron da Figura 23.




Figura 23 Intensidade das cores CIELab das cartelas escolhidas, (a) luminância pelo número de amostras, (b) cores verde ao vermelho pelo número de amostras, (c) cores azul ao amarelo pelo número de amostras

Para a justificativa de se utilizar as cartelas de cores, foram utilizados os discos de cores do equipamento Agtron modelo M-BASIC II (Fig. 26), que possui 8 diferentes cores com seus respectivos valores em escala Agtron (Fig. 24), estes servem de auxílio visual para adequação das amostras no intervalo de torra desejado. Os discos possuem no verso a sua numeração de escala Agtron correspondente com intervalos de 95 a 25. Os valores de CIE L^* , a^* , b^* desses discos foram obtidos pelo equipamento colorímetro CR 300 (Fig. 22), para guiar quais cartelas seriam mantidas na melhor caracterização do modelo.




Figura 24 Discos de cores Agtron utilizado para coleta de dados

Os valores em CIELab do banco de cartelas utilizado como entrada do modelo de transformação neural foi confrontado com os discos Agtron para verificação da abrangência das cores. A figura 25 ilustra as coordenadas CIELab




Figura 25 Distribuição L^* , a^* , b^* , das cartelas e dos discos Agtron no espaço tridimensional, sendo as medições dos discos apresentadas em "o" e as das cartelas em "+"

Em azul (marcador •), estão as coordenadas dos oito discos Agtron, em valores crescentes de escala, da direita para esquerda (25, 35, 45, 55, 65, 75, 85, 95). Em vermelho (marcadores em +), são representados os valores de cores para cada cartela fotografada. Nota-se que os discos também foram utilizados com cartelas para treinamento, visando melhorar ainda mais o modelo.

Os valores da escala Agtron para todas as amostras (inteiro/moído) foram coletados pelo equipamento modelo M-BASIC II (Figura 26), que foi calibrado para cada uma das 300 amostras (150 em grãos moídos e 150 em grãos inteiros), para garantir a obtenção do valor mais correto.



Figura 26 Equipamento Agtron modelo M-BASIC II utilizado para coleta de dados de amostras de café torrado inteiros e moídos

5.2.2.1 Amostras de café

Para a obtenção do banco de amostras a ser utilizado para identificação dos modelos de regressão (tonalidades de torra), foram selecionadas amostras de cafés arábica, da região da Serra da Mantiqueira de Minas Gerais (Carmo de Minas). Os frutos da safra de 2014 foram processados por via seca (seca) e via úmida (cereja descascado) os grãos beneficiados foram armazenados em embalagens herméticas com injeção de CO₂ (BOREM et al., 2013; RIBEIRO et al., 2011), para melhor conservação das características físicas dos grãos crus (incluindo a cor).

Os dados de cores dos grãos crus foram adquiridos utilizando o sistema de reconhecimento de padrões de cores, desenvolvido também pelo autor deste trabalho, e publicado em conjunto com Oliveira et al. (2016). Obtendo-se as tonalidades verde e verde-azulada, para amostras de pós-colheita via seca e via úmida, respectivamente.

Em seguida, foi medida sua umidade por um equipamento da marca Agrológic, modelo AL-1000, apresentando valores 10,2% e 8,7% para as amostras de pós colheita via seca e úmida, respectivamente.

Realizou-se a separação dos defeitos dos grãos sadios segundo tamanho e formato dos mesmos, seguindo o protocolo internacional para tratamento de cafés especiais (SCAA, 2009), separando os grãos de peneira 16 e acima sem defeitos. A Tabela 4 ilustra a porcentagem de impurezas retiradas do montante total das amostras tratadas.

Tabela 4 Porcentagem de impurezas retirados das amostras

	Natural (kg)	Cereja descascado (kg)
Utilizado	12,0	13,5
Defeitos	0,662	0,867
Total	5,52%	6,42%

Para a torração, foram selecionadas 150 amostras (75 de cada tipo de processamento de pós-colheita), contendo 150 gramas cada medida com balança de precisão da marca GEHAKA, modelo BG-2000 II. As amostras foram torradas utilizando um torrador de prova da marca PROBAT LEOGAP (modelo TP2), com controle de exaustão automático e medidor de temperatura analógico.

A temperatura inicial de torração para todas as amostras foi de 150°C. Para a obtenção das diferentes tonalidades, o tempo de retirada de cada amostra foi de 7,5 min., 8 min., 8,5 min., 9 min., 9,5 min., 10 min., 10,5 min., 11 min., 11,5 min. e 12 min., mantendo-se próximas as temperaturas de retirada para todas as bateladas (Adotou-se uma ventilação média e um tamanho de chama de média a alta). As películas finas foram retiradas, e após resfriamento, as amostras foram embaladas em sacos plásticos e armazenadas em câmara fria por um período de 24 horas de descanso.

A variação dos tempos possibilitou a obtenção de uma maior diversidade de cores nas amostras de torra dentro do espectro de cores desejado para o treinamento do modelo. Algumas das amostras são apresentadas na Figura 27, onde pode se observar uma ampla faixa de tonalidades nos grãos torrados.

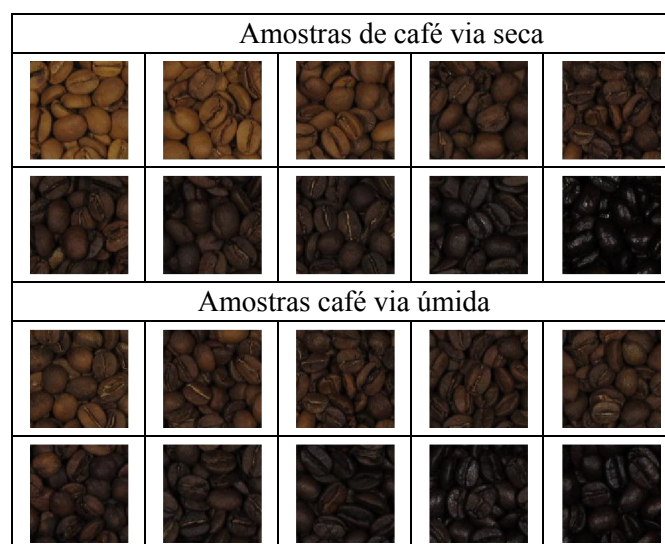


Figura 27 Amostras das escalas de cores estudadas para grãos de cafés torrados

Após a obtenção dos materiais de estudo para grãos inteiros, cada amostra foi moída utilizando-se o equipamento da marca Probat®, modelo Guatemala730, com valor de granulometria de 3,5micrômetros.

As amostras dos grãos moídos obtidos dos grãos inteiros são ilustradas na Figura 28.




Figura 28 Amostras torradas e moídas do material de estudo

5.2.3 Sistemas embarcados

Nesta seção, serão apresentados os materiais utilizados para construção dos protótipos para integração das informações da plataforma. Estes protótipos são utilizados durante o processo de análise sensorial, sendo separados em três tópicos:

- módulo de aquisição de temperatura, utilizado para aferir a temperatura da xícara de café durante a análise sensorial;
- aplicativo para dispositivos Android para catalogação e pontuação das amostras de cafês na análise sensorial;
- servidor de Banco de Dados para armazenamento dos dados para posterior análise

5.2.3.1 Módulo de aquisição de temperatura

Para a aquisição de temperatura na faixa desejada ($20^{\circ}\text{C} \sim 93^{\circ}\text{C}$), e variâncias permitidas pelo protocolo SCAA ($\pm 1^{\circ}\text{C}$), e com possibilidade de transmissão de dados via *bluetooth*, foram selecionados os seguintes materiais:

- um Arduino UNO (Processador ATmega32u4), que possui uma entrada analógica de 10bits de resolução e uma taxa de amostragem inferior a 1s, características importantes para o projeto;
- um módulo Bluetooth RS232 HC-05 para transmissão dos dados de temperatura para o aplicativo Android;
- um sensor de temperatura LM35 T0-92 que abrange a medição de temperatura dentro da faixa de -55°C a $+150^{\circ}\text{C}$.
- um conector para bateria 9V, com autonomia de uso em cerca de 2 horas para todo o conjunto.
- uma *Protoboard* de 400 pontos;

Nas Figuras 29 e 30 encontram-se os materiais utilizados para a prototipação do módulo de aquisição de temperatura.




Figura 29 Visão superior do módulo de aquisição de temperatura




Figura 30 Visão inferior do módulo de aquisição de temperatura

A Figura 29, apresenta-se, na região superior, o módulo *Bluetooth* plugado ao *Protoboard*. As conexões com o sensor de temperatura (à direita), e

ao controlador Arduino são filtradas com dois resistores, um de $1k5 \Omega$ e outro de $2k2 \Omega$ para manutenção da corrente segundo as recomendações do fabricante. A Figura 30 apresenta a vista inferior do protótipo, onde estão localizadas as conexões dos terminais analógico/digital e a da conexão para alimentação 9V (esquerda inferior). O protótipo é alimentado por uma bateria de 9V 450MA/h com autonomia de cerca de 3 horas.

5.2.3.2 Aplicativo para dispositivos Android

Para verificação dos dados de temperatura enviados pelo protótipo, foi utilizado um *tablet* da marca Samsung, modelo Galax TabP-1000(Figura 31),conectado via *Bluetooth* à aplicação do Arduino, para receber suas atualizações de temperatura e assim comparar com outros termômetros analógicos para sua validação.



Figura 31 Aparelho *Tablet* utilizado para receber a aplicação Android

Estet *tablet* também foi utilizado para os teste das aplicações *Android* desenvolvidas para catalogar as amostras de café e os dados de análise física.

5.2.3.3 Servidor de Banco de Dados

O servidor de Banco de Dados da plataforma foi implementado utilizando-se da ferramenta WampServer, desenvolvido pela PHP Team, e distribuído de forma gratuita. É utilizado para instalar rapidamente os softwares PHP 5, MySQL e Apache, disponibilizando suporte ao uso de scripts em PHP, para envio e recebimento de dados pela *Web*.

A instalação foi feita sobre um notebook SONY VAIO, figura 32, com Sistema Operacional Microsoft Windows 7 X64, conectado pela rede cabeada, com protocolo de comunicação IPV4 fixo.



Figura 32 Aparelho notebook utilizado para suportar a aplicação WampServer como Banco de Dados

A ferramenta também permite que sejam criadas funções de busca, chaves entre tabelas, gráficos e relatórios. A Figura 33 apresenta o menu de contexto e a representação dos dados no modelo MySQL implementado.

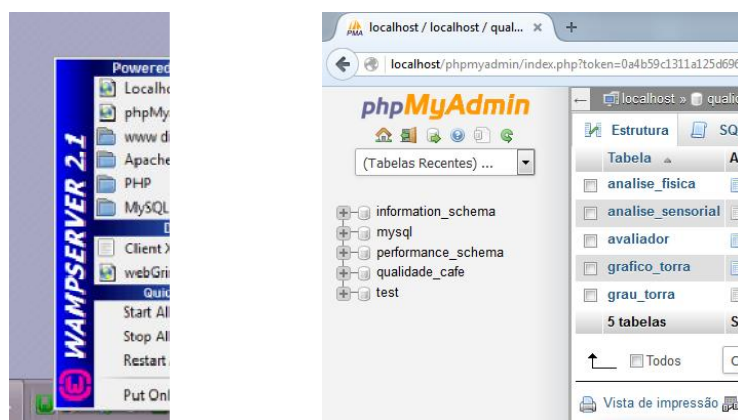


Figura 33 Menu de configuração da ferramenta WampServer (esquerda), janela de configuração com banco de dados criado

5.3 Métodos

Os métodos utilizados neste tópico contemplam todas as estruturas para o processamento de amostras de café recebidas pela plataforma, sua caracterização quanto ao código das amostras, quantidade, dados de curva de torração, pontuação da análise sensorial, temperatura de prova e envio destas informações ao Banco de Dados online.

5.3.1 Sistema de visão computacional e de reconhecimento de padrões

Para a criação do sistema de visão computacional e de reconhecimento de padrões, é necessário a criação de um modelo de conversão de espaço de cores em RGB para CIELab e um modelo de regressão para estimação da tonalidade de torra dos cafés. Assim, as próximas seções apresentarão os métodos utilizados para construção destes modelos.

5.3.1.1 Modelo de transformação de espaços de cores

A metodologia utilizada para a identificação do modelo de transformação é descrita na Figura 34, com os seguintes passos:

- I. seleção de cartelas de cores próximas as tonalidades de cores de grãos torrados. Foram utilizadas 106 cartelas de amostras de tinta em acrílico fosco com o objetivo de obter um escopo de cores que abrangesse toda as tonalidades de terra utilizadas neste trabalho. Alguns exemplos são ilustrados na Figura 17;
- II. registro das imagens das cartelas de cores utilizando o formato sem compressão da câmera (.CR2);
- III. conversão das imagens para o formato TIFF em 16 bits, que serão recortadas, utilizando o software Adobe Photoshop®;
- IV. importação das imagens recortadas no formato TIFF para o Ambiente de Desenvolvimento Integrado MatLab®, que retorna uma matriz tridimensional de cada imagem, correspondendo aos valores em RGB;
- V. mensuração dos valores de $L^*a^*b^*$ de cada cartela utilizando o colorímetro Minolta CR 300 (Figura 18). Para cada valor, foi feita uma triplicada e calculado a média como resultado final da cartela;
- VI. estimação do modelo de transformação, utilizando o software MATLAB®, com base na utilização dos valores fotografados (RGB), como entrada e seus respectivos valores do colorímetro, em CIE $L^*a^*b^*$, com saída.

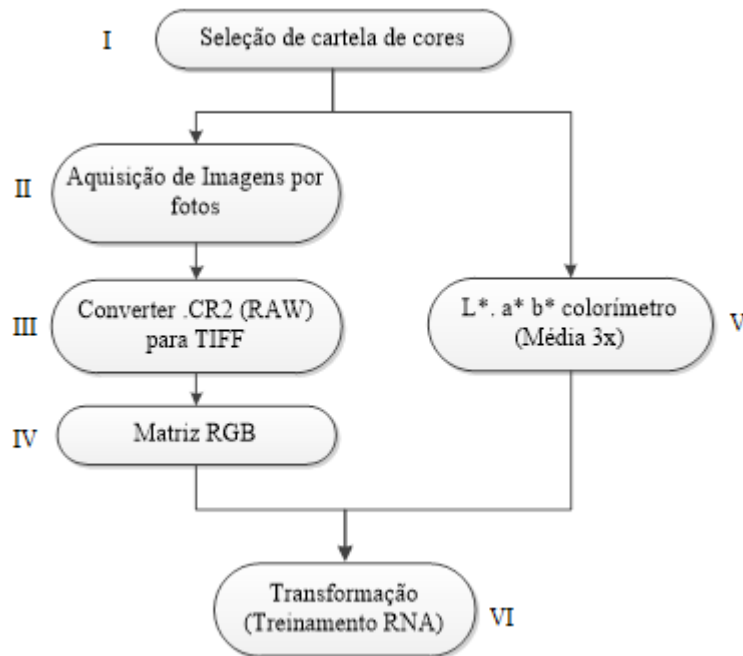


Figura 34 Sequência utilizada para construção do modelo de transformação RGB-CIELab

Para este trabalho, foi implementada uma Rede Neural Artificial do tipo *feed-forward* (Fig. 35), composta por uma camada oculta contendo 5 neurônios com função de ativação não-linear (tangente hiperbólica), e um neurônio em sua camada de saída. O treinamento da rede seguiu-se com base no algoritmo *Levenberg-Marquardt* apresentado em (HAYKIN, 2009). O modelo em rede foi escolhido devido à sua maior eficiência, se comparado a outros modelos, contudo, diferentemente de (LEÓN et al., 2006). Este trabalho implementou 3 Redes Neurais distintas, uma para cada componente (L^* , a^* ou b^*). Este mesmo procedimento foi adotado em (OLIVEIRA et al., 2016).

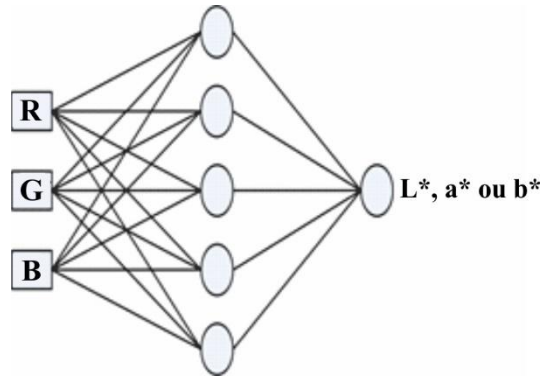


Figura 35 Estruturas das Redes Neuras Artificiais utilizadas na transformação RGB para CIELab

Fonte: Elaborado pelo autor

Os erros de aproximação para cada uma das redes, foram calculados com base nas equações descritas em Leon et al.(2006),os valores obtidos em cada transformação são tratados separadamente:

$$\bar{e} = \frac{e_L + e_a + e_b}{3}, \quad (8)$$

em que,

$$e_L = \frac{1}{N} \sum_{i=1}^N \frac{|L_i^* - \hat{L}_i|}{\Delta L},$$

$$e_a = \frac{1}{N} \sum_{i=1}^N \frac{|a_i^* - \hat{a}_i|}{\Delta a}, \quad (9)$$

$$e_b = \frac{1}{N} \sum_{i=1}^N \frac{|b_i^* - \hat{b}_i|}{\Delta b},$$

onde os termos ΔL , Δa e Δb referem-se ao comprimento dos intervalos de variação de cada componente do espaço de cor CIELab, ou seja, como $0 \leq L \leq 100$, $-120 \leq a \leq 120$ e $-120 \leq b \leq 120$, $\Delta L = 100$ e $\Delta a = \Delta b = 240$.

Após o treinamento da RNA relacionando os valores da conversão RGB para CIELab de cada cartela, com os valores obtidos pelo colorímetro especialista, é possível a implementação do sistema de classificação.

Após a construção do modelo de transformação, e obtidos os resultados em valores de L^* , a^* , b^* das amostras, a próxima etapa é a implementação do modelo de regressão para caracterizar as amostras em sua escala Agtron.

5.3.1.2 O modelo de regressão de tonalidade de torra

As 300 amostras de café torrado (150 em grãos e 150 moídos) foram dispostas em recipiente plástico preto (18 cm diâmetro), no centro da câmara escura, sob uma superfície preta, conforme mostrado nas Figuras 36/37 (a).

As imagens fotografadas das amostras foram recortadas e convertidas em formato TIF pelo software Adobe Photoshop® (mantendo-se a resolução e padrão de cores da câmera). Em seguida carregadas no Matlab e sua região de interesse recortada de forma que todas as amostras possuíssem o mesmo tamanho final, conforme mostra as Figuras 36/37 (b).



Figura 36 Disposição das amostras de grãos de café inteiro, (a) disposição do recipiente contendo a amostra na câmara escura e (b) imagem recortada



Figura 37 Disposição das amostras de grãos de café moído, (a) disposição do recipiente contendo a amostra na câmara escura e (b) imagem recortada

Todas as imagens recortadas, já em formato TIF (matriz RGB), foram submetidas a duas transformações:

- conversão de RGB para CIELab, por meio do modelo de transformação neural obtido. Dessa forma, cada amostra possui um valor médio de L, a e b;
- conversão da imagem em cores RGB para imagem em escalas de cinza utilizando a função *rgbtogray*, que obtém um índice médio estimado da imagem pela função $(I = 0.2989 * R + 0.5870 * G + 0.1140 * B)$ do software Matlab®.

Com os valores da escala Agtron (obtidos do M-BASIC II), juntamente com os de CIELab (convertidos das fotos em RGB), e os de intensidade em escala de cinza (obtidos das fotos em RGB), para cada amostra, foram implementados modelos de regressão linear, polinomiais e um modelo neural, para cada tipo de amostra (grão ou moído), totalizando assim doze modelos. De forma geral, dois problemas foram abordados:

- identificação de modelo para transformação do valor médio de $L^*a^*b^*$ da amostra para Agtron;
- identificação de modelo para transformação do valor médio em escala de cinza da imagem da amostra para Agtron.

A obtenção de um modelo que transforme valores no espaço CIELab para Agtron se justifica por duas razões: i- a obtenção de uma equação matemática que relacione estas duas importantes entidades, podendo ser utilizada por outros usuários que consigam a obtenção dos valores de CIELab de suas amostras por outros métodos; ii- tentativa de encontrar modelos com boa acurácia ao utilizar uma entrada composta por três valores para estimar uma saída de uma dimensão.

Já a obtenção de um modelo que relacione valores de escala de cinza da imagem com o valor de Agtron das amostras é interessante no sentido de implementação do modelo em dispositivos de baixo custo. A obtenção de imagens em escala de cinza pode ser realizada por dispositivos simples e o processamento dos dados pode ser feito com uma menor demanda de processamento computacional. Como a escala Agtron é fortemente relacionada com o brilho (ou luminescência) da imagem, conjectura-se que bons resultados podem ser obtidos ao usar apenas escala de cinza para sua estimação.

Os seis modelos utilizados para solução desses problemas foram:

1. Modelo polinomial linear com regressores baseados no valor médio da imagem no padrão CIELab:

$$PL_{cor} = \begin{bmatrix} L_1, a_1, b_1, 1 \\ L_2, a_2, b_2, 1 \\ L_3, a_3, b_3, 1 \\ \cdot \\ \cdot \\ \cdot \\ L_n, a_n, b_n, 1 \end{bmatrix} x \begin{bmatrix} \theta_1 \\ \theta_2 \\ \theta_3 \\ \theta_4 \end{bmatrix}, (10)$$

2. Modelo polinomial quadrático com regressores baseados no valor médio da imagem no padrão CIELab:

$$PQ_{cor} = \begin{bmatrix} L^2_1, a^2_1, b^2_1, L_1, a_1, b_1, L_1 a_1, L_1 b_1, a_1 b_1, 1 \\ L^2_2, a^2_2, b^2_2, L_2, a_2, b_2, L_2 a_2, L_2 b_2, a_2 b_2, 1 \\ L^2_3, a^2_3, b^2_3, L_3, a_3, b_3, L_3 a_3, L_3 b_3, a_3 b_3, 1 \\ \cdot \\ \cdot \\ \cdot \\ L^2_n, a^2_n, b^2_n, L_n, a_n, b_n, L_n a_n, L_n b_n, a_n b_n, 1 \end{bmatrix} x \begin{bmatrix} \theta_1 \\ \theta_2 \\ \theta_3 \\ \cdot \\ \cdot \\ \cdot \\ \theta_{10} \end{bmatrix}, (11)$$

3. Modelo de Rede Neural Artificial:

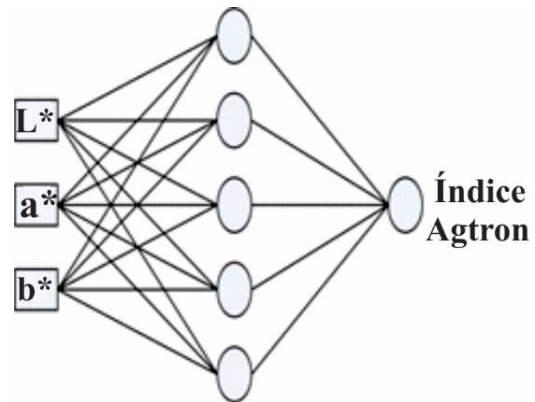


Figura 38 Estruturas das Redes Neurais Artificiais utilizadas na transformação CIELab em escala Agtron

4. Modelo polinomial linear com regressores baseados na medida de escala de cinza média da imagem

$$PL_{cinza} = \begin{bmatrix} \text{Ind}_{1,1} \\ \text{Ind}_{2,1} \\ \text{Ind}_{3,1} \\ \cdot \\ \cdot \\ \cdot \\ \text{Ind}_{n,1} \end{bmatrix} x \begin{bmatrix} \theta_1 \\ \theta_2 \end{bmatrix}, (12)$$

5. Modelo polinomial quadrático com regressores baseados na medida de escala de cinza média da imagem:

$$PQ_{cinza} = \begin{bmatrix} \text{Ind}_1^2, \text{Ind}_1, 1 \\ \text{Ind}_2^2, \text{Ind}_2, 1 \\ \text{Ind}_3^2, \text{Ind}_3, 1 \\ \cdot \\ \cdot \\ \cdot \\ \text{Ind}_n^2, \text{Ind}_n, 1 \end{bmatrix} x \begin{bmatrix} \theta_1 \\ \theta_2 \\ \theta_3 \end{bmatrix}, \quad (13)$$

6. Modelo polinomial cúbico com regressores baseados na medida de escala de cinza média da imagem:

$$PC_{cinza} = \begin{bmatrix} \text{Ind}_1^3, \text{Ind}_1^2, \text{Ind}_1, 1 \\ \text{Ind}_1^3, \text{Ind}_2^2, \text{Ind}_2, 1 \\ \text{Ind}_1^3, \text{Ind}_3^2, \text{Ind}_3, 1 \\ \cdot \\ \cdot \\ \cdot \\ \text{Ind}_1^3, \text{Ind}_n^2, \text{Ind}_n, 1 \end{bmatrix} x \begin{bmatrix} \theta_1 \\ \theta_2 \\ \theta_3 \\ \theta_4 \end{bmatrix}, \quad (14)$$

Os modelos polinomiais foram ajustados utilizando o estimador de Mínimos Quadrados, Eq. (6), enquanto que o modelo neural foi estimado utilizando o algoritmo de retro-propagação do erro com ajuste de pesos da rede via procedimento bayesiano (*trainbr*).

Esses modelos foram desenvolvidos tanto para imagens de grãos de cafés torrados inteiros, quanto para imagens de cafés torrados moídos (6 modelos para cada tipo de imagem). Para comparação do desempenho dos modelos, as amostras foram ordenadas aleatoriamente e separadas, sendo 120 (80%) utilizadas para treinamento e 30 (20%) para validação (em cada execução). Foram calculados os parâmetros de cada modelo e verificados os erros de treinamento e de validação, com seus respectivos desvios e erros médios absolutos, para o total de 2000 execuções.

5.3.2 Sistemas embarcados

Nesta seção, os métodos utilizados para construção do módulo de aquisição de temperatura e do aplicativos para Android são apresentados.

5.3.2.1 Módulo de aquisição de temperatura

A medição de temperatura do café de degustação é realizada por meio do sensor LM-35. Para aferição da temperatura, o sensor é imerso na xícara de café, de forma que a temperatura interna do café seja obtida. A Fig. 36 apresenta a xícara de café com o sensor de temperatura submerso.




Figura 39 Temperatura captada com sensor de temperatura LM35, e transmitida via bluetooth para aplicação android em tempo real

Esse sensor está conectado ao controlador Arduino UNO, que processa a informação do sensor e a envia para a aplicação Android por meio de comunicação *Bluetooth*. Para conexão ao Arduino, o circuito eletrônico, apresentado na Figura 39, foi desenvolvido.

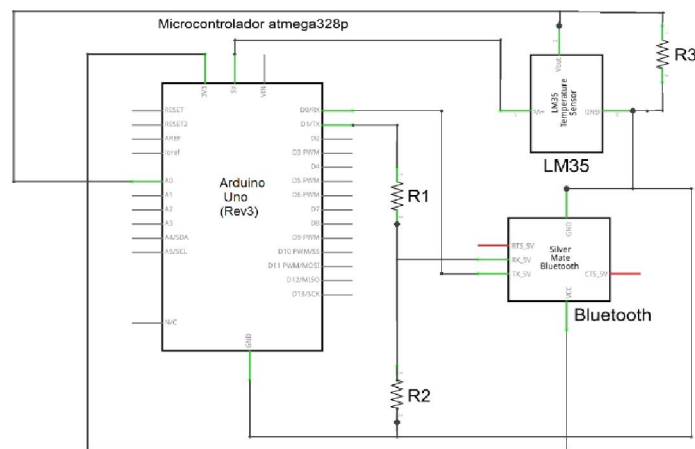


Figura 40 Diagrama do circuito eletrônico do módulo de aquisição de temperatura

O sensor de temperatura LM35 deve ser alimentado com tensão entre 4V e 20V na entrada +Vs. Neste projeto a alimentação utilizada é de 5V, provenientes do próprio Arduino. A tensão de saída (medição), do LM35 deve ser ligada a uma das entradas analógicas do Arduino, sendo que a entrada analógica A0 do mesmo foi utilizada para este fim. O resistor R3, de 10k Ω , é conectado à saída do LM35 para que não ocorram variações bruscas na leitura do sensor, causadas por oscilações de tensão.

Assim como no LM35, a alimentação do módulo Bluetooth também é realizada por meio da fonte interna de 5V do Arduino. Para receber dados do Arduino, como o módulo utilizado neste projeto (RS232 HC-05) trabalha com nível de sinal de 3.3v, um divisor de tensão deve ser implementado para não danificar o componente. Esta tarefa é executada pelos resistores R1 (1.5k Ω) e R2 (2.2k Ω), conectados entre as portas RX (recepção) do módulo *Bluetooth* e a porta TX (transmissão) do Arduino. Por fim, o pino de transmissão (TX) do módulo, responsável por enviar sinais para o Arduino, deve ser ligado ao pino RX do mesmo.

5.3.2.2 Aplicativos para dispositivos Android

Foi desenvolvida nesta etapa do trabalho três aplicações. A primeira para a catalogação de amostras recebidas pelo projeto (origem, código, quantidade, local armazenado). A segunda para catalogação das características físicas (pontuação física, umidade, L*a*b* grão cru, classe de cor). A terceira para representar a planilha de pontuação da SCAA, utilizada atualmente no processo de avaliação sensorial de cafés especiais (AnexoD). O objetivo é facilitar e diminuir o tempo necessário para avaliação, além de obter os dados da análise das amostras já em formato eletrônico.

As aplicações podem ser executadas em *smartphones* ou *tablets* com Sistema Operacional Android ou iOS (bastando alterar a compilação). A ferramenta utilizada foi a MIT App Inventor 2 (beta), atualização de novembro de 2015, versão nb146j.

A aplicação de análise sensorial poderá ser utilizada em modo horizontal, acoplada ao braço do avaliador (Figura 41), por meio de uma pulseira com presilha em velcro a ser confeccionada com as medidas do aparelho, cujo objetivo é permitir que a mão fique livre para outras tarefas, e o avaliador não tenha mais que carregar papéis, prancheta e canetas.

Estes valores serão em seguida enviados via internet (wi-fi) para um banco de dados que armazenará as notas de cada avaliador.




Figura 41 Ilustrações do dispositivo implementado e acoplado ao braço do avaliador por uma pulseira de velcro

A figura 42 apresenta um fluxograma com as etapas executadas pelo aplicativo INCAFE, para cadastro de cafés da plataforma, entre elas, pode-se destacar:

- cadastro de um código da saca. Este código é uma referência da saca de café que será armazenada para futuras análises de amostras;

- cadastro de origem. A amostra devera conter o nome do município ou fazenda do qual a amostra foi enviada;
- quantidade em kg. Cadastro do peso total em Quilogramas da amostra;
- local de armazenamento. Descrição do local e da prateleira utilizada para armazenamento da amostra em câmara fria;
- comunicação via WI-FI. Envio dos dados cadastrados para o Banco de Dados.

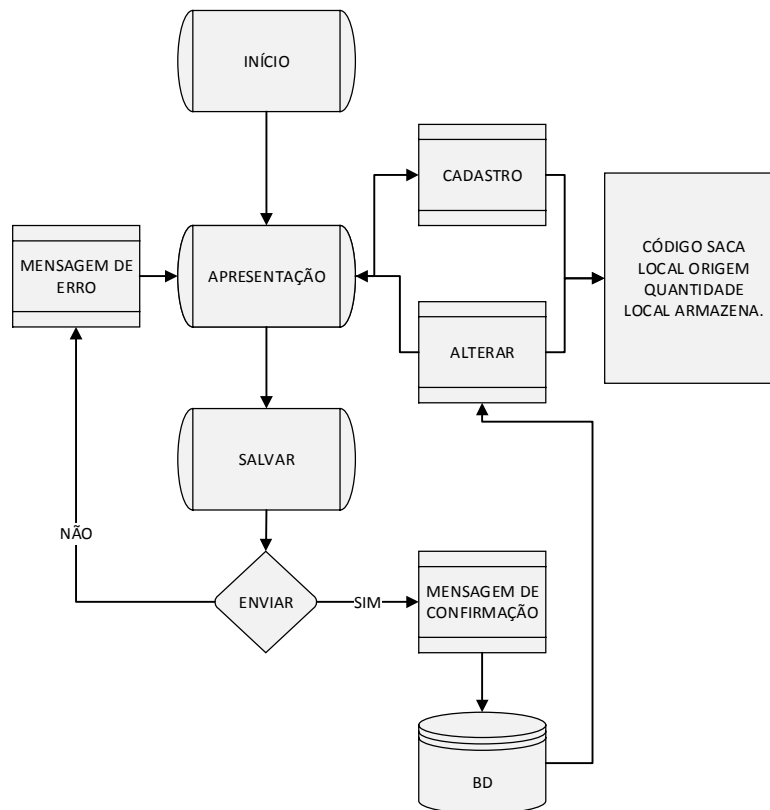


Figura 42 Diagrama de organização das etapas da aplicação INCAFE para cadastro de novas sacas

A figura 43 apresenta um fluxograma com as etapas executadas pelo aplicativo FISICAFÉ, para análises físicas e, entre elas pode-se destacar:

- cadastro de um código da amostra. Este código é uma referência da amostra de café que será armazenada;
- pontuação física. Cadastro do valor recebido após a análise física das amostras (catação);
- umidade. Valor do teor de água da amostra;
- L^* , a^* , b^* - valor do padrão de cor das amostras adquiridas mediante fotografia dos grãos crus;
- classe de cor, resultado da avaliação de cores em CIELab da amostra;
- comunicação via WI-FI. Envio dos dados cadastrados para o Banco de Dados.

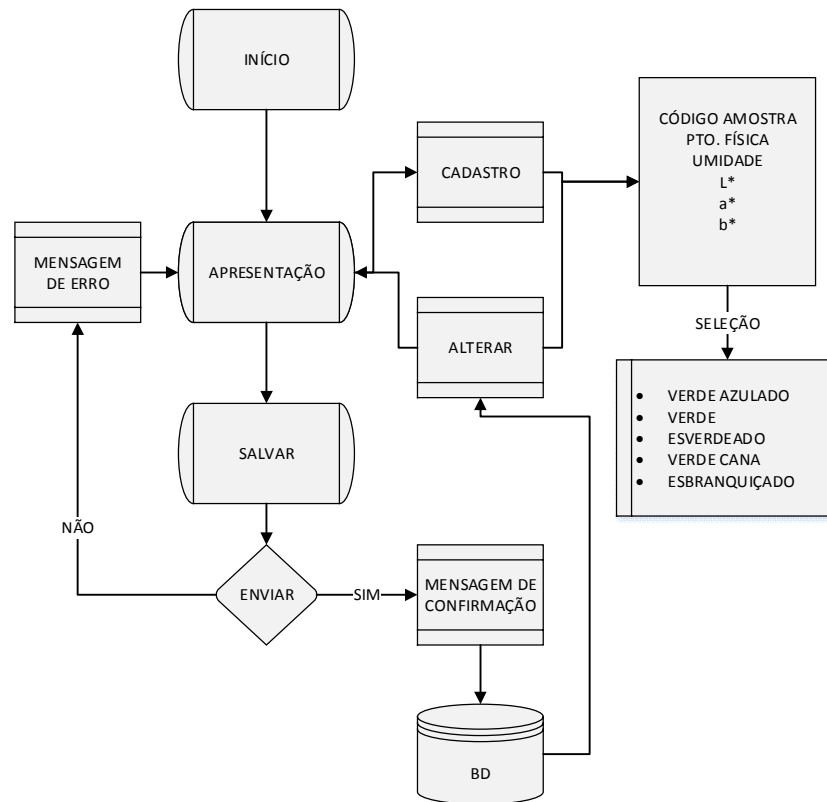


Figura 43 Diagrama de organização das etapas da aplicação FISICAFE para análise física

Fonte: Elaborado pelo autor

A figura 44 apresenta um fluxograma com as etapas executadas pelo aplicativo LEGUSTA, para análise sensorial, entre elas, pode-se destacar:

- comunicação via *bluetooth* com o módulo de temperatura. Esta temperatura deverá ser apresentada ao avaliador durante o processo de análise sensorial;
- comunicação via wi-fi com o banco de dados. As notas de cada categoria serão enviadas de forma unívoca para o servidor;

- campos de pontuação da amostras. Estas notas são apresentadas sequencialmente para a o avaliador, seguindo a abrangência da planilha com adicional de categorias pré-definidas de aroma, fragrância e de sabor;
- botões de salvar e de envio. A cada etapa o avaliador poderá salvar as notas de cada amostra, e ao final das provas realizar o envio de todas as notas ao servidor. Em cada etapa são exibidas mensagens de confirmação do envio ou, em caso de erro, das mensagens de alertas, com o tipo de erro (tratamento de exceções).

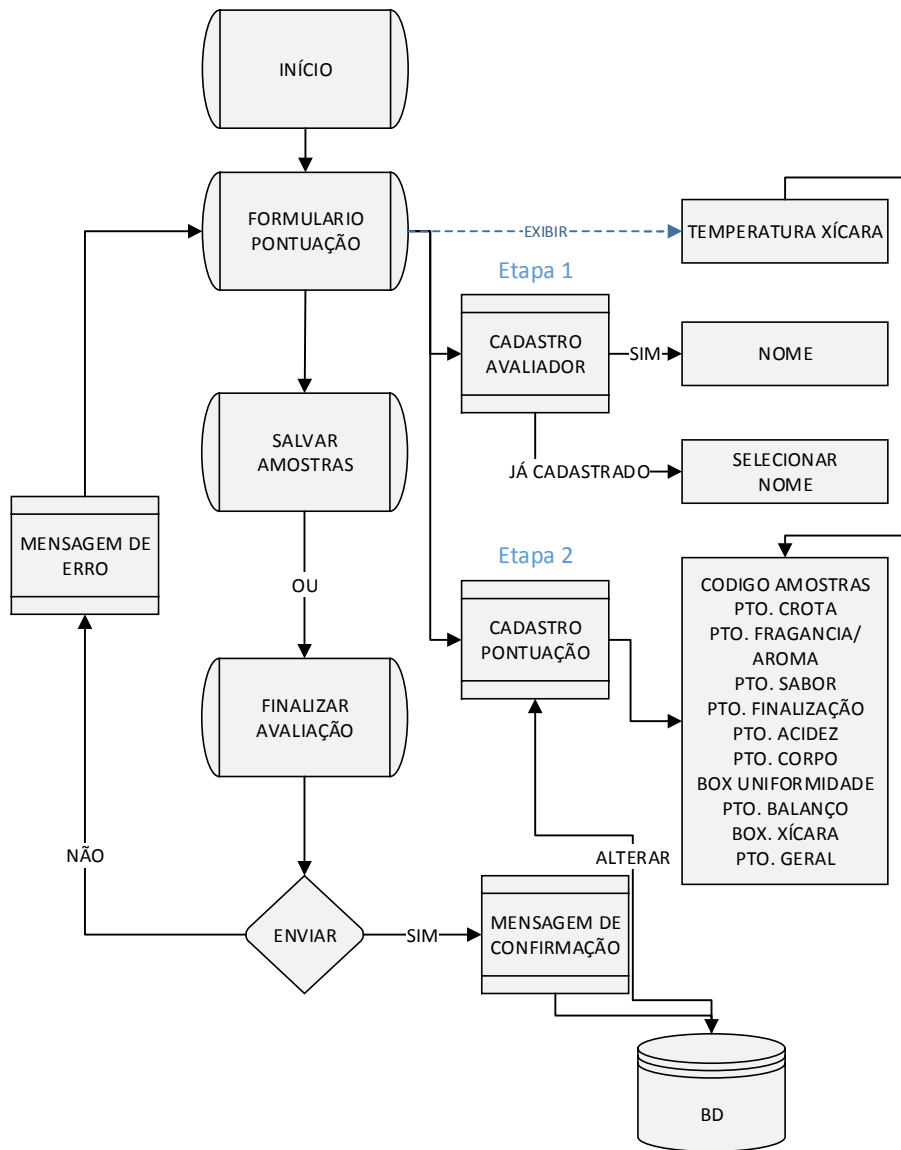


Figura 44 Diagrama de organização das etapas da aplicação LEGUSTA, para análise sensorial

5.3.2.3 Banco de Dados

Optou-se neste trabalho pela utilização de dispositivos portáteis com comunicação sem fio, devido ao requisito de mobilidade exigido durante o processo de Análise Sensorial. O protocolo estudado para a comunicação foi IEEE 802.11 (WI-FI). O protocolo *Bluetooth* é utilizado somente para envio das temperaturas das xícaras para a aplicação Android LEGUSTA.

Os valores de cadastro do usuário, de pontuações são organizados em formato de matriz, em um arquivo virtual no aparelho, para em seguida serem enviados (Anexo B). Esta transação foi implementada para ser atômica (termo utilizado em transações de banco de dados, onde todos os dados são atualizados ou nenhum dado é modificado).

A transmissão para o Banco de Dados utiliza *scripts* com linguagem de programação PHP para iniciar a sessão, capturar os valores dos campos da aplicação, encapsular e enviar. Em caso de erro, uma mensagem é exibida com o tipo do erro. Os *scripts* responsáveis pelo cadastro, alteração e exibição de dados das aplicações estão no anexoD.

6 RESULTADOS E DISCUSSÕES

Os resultados e discussões estão divididos em seistópicos, conforme os objetivos deste trabalho:

- modelo de transformação de espaço de cores (RGB para CIELAB);
- modelos de regressão para estimativa da tonalidade de cor de torra do café (Agtron);
- aplicações desenvolvidas para celulares *Android*, para inserção de dados referentes a catalogação de amostras de café;
- arquitetura de Banco de Dados utilizada;
- protótipo de aquisição de temperatura das xícaras de café;
- protótipo de aquisição de temperatura do torrador.

6.1 Modelo de transformação de espaço de cores

O modelo de transformação de espaço de cores adotado neste trabalho é formado por três redes MLP cujas entradas são os valores de RGB e a saída é ou CIE L* ou CIE a* ou CIE b*. O primeiro passo para construir esse modelo é a definição do número de neurônios de sua camada intermediária. Assim, foram treinadas e validadas 2000 redes neurais (com diferentes conjuntos de treinamento), para cada uma das três opções de saída, utilizando modelos com 5, 10 ou 15 neurônios.

As tabelas 5, 6 e 7 apresentam os erros de treinamento e de validação para as redes com 5, 10 e 15 neurônios na camada intermediária, respectivamente.

Tabela 5 Erros das RNAs com 5 neurônios na camada oculta, avaliados segundo equações de Léon et al. (2006)

n° = 5	Erro Treinamento (%)	Erro Validação (%)
RNA 1 (L)	0,9011±0,7768	1,6884±0,9300
RNA 2 (a)	0,2207±0,2601	0,2892±0,1098
RNA 3 (b)	0,3735±0,3674	0,4734±0,4031
\bar{e}	0,4984	0,8170

Também foram calculados os erros médios quadráticos de treinamento e validação em cada topologia, seus valores são 1,6435 e 2,5670 quando utilizados 5 neurônios, 1,6494 e 2,6412 quando utilizados 10 neurônios e 1,8718 e 2,9553 quando 15 neurônios foram empregados.

Tabela 6 Erros das RNA's com 10 neurônios na camada oculta, avaliados segundo equações de Léon et al. (2006)

n° = 10	Erro Treinamento (%)	Erro Validação (%)
RNA 1 (L)	0,9291±0,7698	1,6840±0,6713
RNA 2 (a)	0,2220±0,2555	0,3245±0,2782
RNA 3 (b)	0,3537±0,2706	0,5238±0,3301
\bar{e}	0,5016	0,8441

Tabela 7 Erros das RNA's com 15 neurônios na camada oculta, avaliados segundo equações de Léon et al. (2006)

n° = 15	Erro Treinamento (%)	Erro Validação (%)
RNA 1 (L)	1,0887±0,7330	1,8209±0,8756
RNA 2 (a)	0,2341±0,1841	0,3878±0,9957
RNA 3 (b)	0,3693±0,5200	0,6002±0,9156
\bar{e}	0,5640	0,9363

Como forma de comparar o desempenho das redes de diferentes topologias foi aplicado o Teste de Tukey, com nível de confiança de 95%, sob os

erros médios quadráticos de validação obtidos pelas 2000 redes treinadas. O resultado deste teste é apresentado na figura 45.

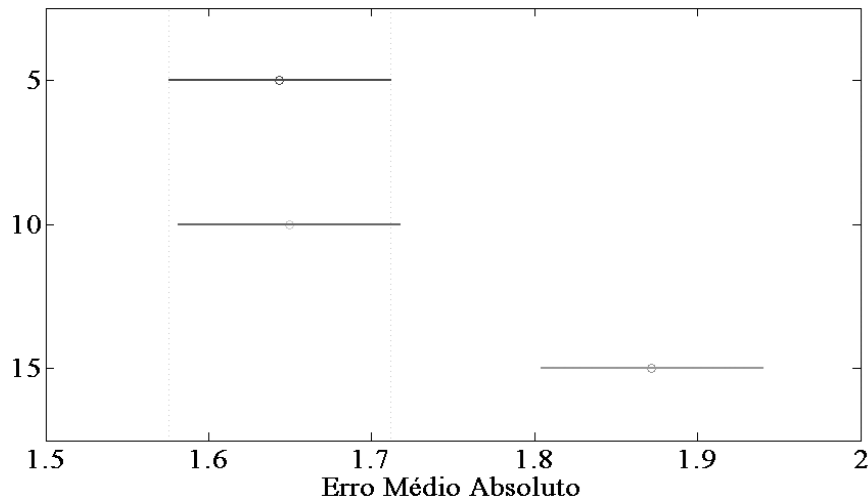


Figura 45 Teste de Tukey (95% de confiança) aplicado nos erros médios quadráticos de validação obtidos pelas redes com 5, 10 ou 15 neurônios escondidos

A partir do teste de Tukey realizado, verificou-se que as Redes Neurais com 5 neurônios na camada oculta obtiveram, com menor custo computacional, melhores resultados de aproximações. Assim, foi definido que o modelo de transformação de espaço de cores é composto por três redes MLP com 5 neurônios escondidos cada.

Em acordo com Judd (1933), o índice de variação do espaço CIELab é dada por:

$$\Delta E_{ab}^* = \sqrt{(\Delta L^*)^2 + (\Delta a^*)^2 + (\Delta b^*)^2}, \quad (15)$$

O modelo de transformação desenvolvido neste trabalho obteve o valor de 1,6434. Segundo Brainard(2003) e Frishman(2005), o olho humano é capaz

de distinguir cores somente com valor superior a 2,2 nessa equação. Deste modo, o modelo de conversão estimado é considerado robusto por atingir distinção de cores comparável à capacidade humana.

A Figura 46 apresenta as 150 amostras convertidas em CIELab, em vermelho (marcador em •), as de grão torrados inteiros e em azul (marcador em +) as mesmas amostras após a moagem. Nota-se que o modelo de conversão é capaz de distinguir as divergências de cores existentes.

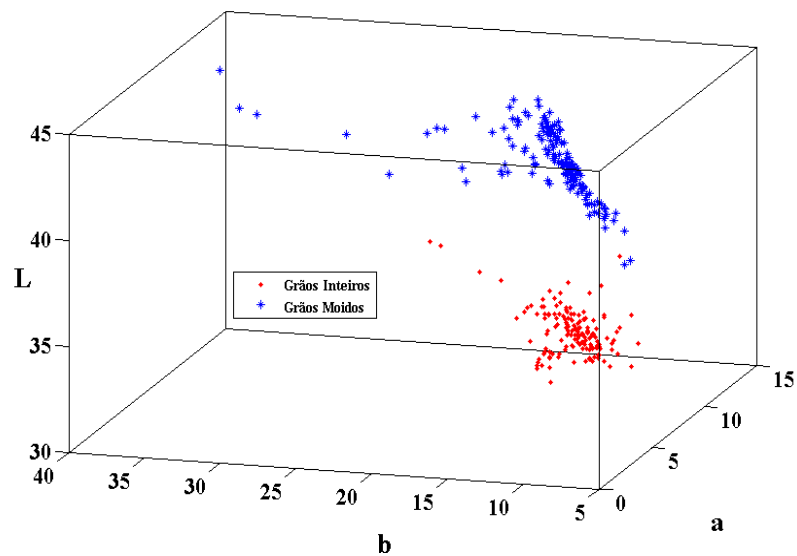


Figura 46 Comparação dos resultados estimados em L^* , a^* e b^* , para amostras de grãos inteiros e grãos moídos

Em geral, a tonalidade dos grãos inteiros é mais escura do que as dos moídos, devido a presença de fragmentos de películas internas que não escureceram homoganeamente durante a torra, e se destacam após o processo de moagem.

6.2 Modelo de regressão para escala Agtron

Conforme apresentado na seção 5.3.1, dois problemas foram abordados para estimativa da tonalidade de torra por imagem digital(utilizando imagens em cores ou utilizando imagens em escalas de cinza).

Foram realizadas 2000 execuções para cada um dos 6 modelos citados, e seus resultados são apresentados separadamente, por tipo de amostra (inteiros ou moídos)

6.2.1 Grãos torrados inteiros

Para comparar o desempenho dos modelos de regressão propostos, em grãos inteiros, o teste de Tukey foi novamente utilizado com nível de confiança de 95% nos erros médios quadráticos de validação. A figura 47 exhibe o teste, onde o eixo vertical apresenta, de cima para baixo: o modelo de regressão linear para amostras em cores, Equação(10), modelo de regressão linear em escala de cinza Equação (12), a rede neural em cores (Fig. 38), os modelos de regressão polinomial de grau 2 (Equação11) em cores e para amostras em escala de cinza grau 2 e 3 (Equações 13 e 14), conforme descritos na metodologia.




Figura 47 Comparação dos erros entre os modelos de aproximação de amostras inteiras

De acordo com a figura é possível observar que o modelo em RNA apresentou, de forma significativa, o menor erro, sendo portanto, definida como modelo de estimação da tonalidade de torra (Agtron) a partir de valores de CIELab para grãos inteiros. Para aplicação prática do estimador de Agtron, é necessário escolher uma entre as 2000 redes treinadas. A partir da análise do desempenho de todas as redes, foi escolhida aquela cujo fator R^2 foi de 0,99 para o erro médio quadrático. A Figura 48 apresenta a correlação entre o valor estimado por esta rede e o medido pelo equipamento, e a figura 49 apresenta o histograma do erro para esta rede.




Figura 48 Relação entre Agtron estimado pelo modelo neural e o Agtron medido pelo equipamento de cada amostra

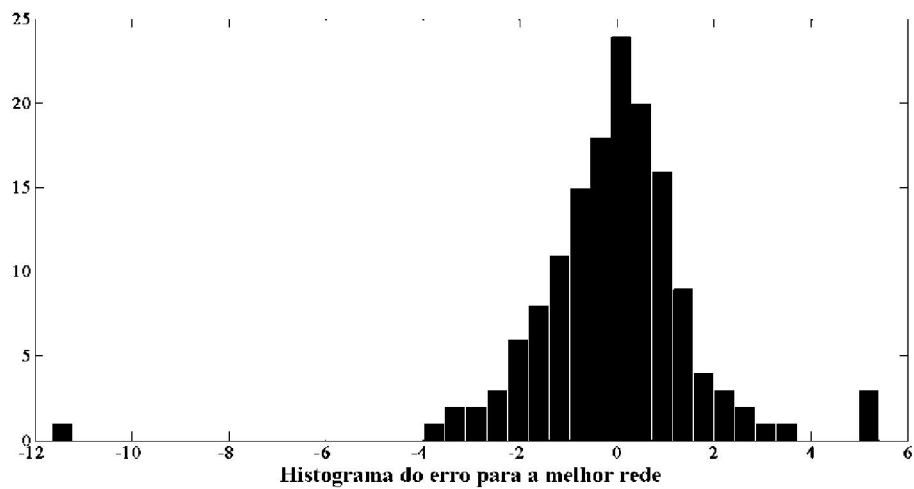


Figura 49 Distribuição dos erros do modelo neural para estimativa do Agtron em grãos inteiros

6.2.2 Grãos torrados e moídos

A figura 50exibe o teste de comparações múltiplas para as amostras de grãos moídos. O eixo vertical apresenta, de cima para baixo: o modelo de regressão linear para amostras coloridas, o modelo polinomial de grau 2 para amostras coloridas, a rede neural, os modelos de regressão linear e polinomial de grau 2 e 3, para amostras em escala de cinza.

Obteve-se como resultados desses modelos, um maior acerto pelo modelo de aproximação polinomial em escala de cinza. Com valor médio próximo a 0,93.




Figura 50 Comparação dos erros entre os modelos de aproximação de amostras moídas

A partir da figura 50, constatou-se que, com nível de confiança de 95%, o modelo polinomial quadrático em escala de cinza foi o que obteve menor erro médio.

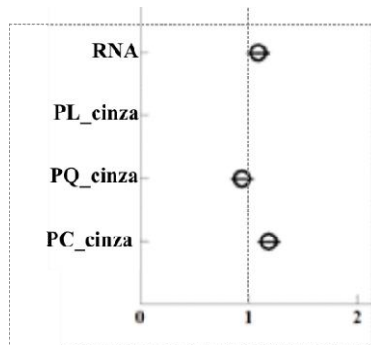


Figura 51 Comparação dos três menores erros dos modelos de aproximação de amostras moídas

Como resultado, foi definido o modelo polinomial quadrático em escala de cinza para estimação do valor de tonalidade (Agtron) de grãos moídos. Esse modelo é expresso por:

$$\hat{Agtron} = (-2,83918 \cdot 10^{-7} * IndBW^2) + (0,015514 * indBW) - (43,851466)$$

em que *IndBW* é o índice que representa o valor obtido pela transformação da imagem em RGB em escala de cinza. Este índice normalmente varia entre 34 e 115,7 para grãos inteiros, e entre 31 e 157 para grãos moídos.

A figura 52 apresenta o resultado dos erros para cada amostra fotografada, utilizando a função polinomial em escala de cinza desenvolvida acima. O desvio padrão do erro para o modelo escala de cinza acima foi de 1,30, e o desvio para a rede 1,84. O R^2 foi igual a 0,9975 para este modelo.




Figura 52 Relação entre Agtron estimado pelo modelo polinomial quadrático e o Agtron medido pelo equipamento de cada amostra




Figura 53 Distribuição dos erros do modelo de regressão polinomial em escala de cinza para estimativa do Agtron em grãos moídos

A altura das barras verticais indicam o número de amostras, e o valor do erro dessas amostras é dado por sua posição horizontal no gráfico. É possível notar um afunilamento próximo do valor zero, indicando bom ajuste do modelo.

6.3 Aplicativos Android/iOS

6.3.1 Aplicativo INCAFÉ

A aplicação desenvolvida para o cadastro de novas amostras (sacas), de café ao projeto foi nomeada de INCAFÉ, em referência a preposição *in* do Inglês, que significa dentro, como alusão ao ingresso dos dados no sistema.

Ao iniciar a aplicação é exibida a janela contendo os campos de cadastro do código da saca de café, o local de origem, a quantidade em quilos e o local de armazenamento da saca. São apresentadas duas opções ao usuário, a primeira é o cadastro dos dados e a segunda a possibilidade de listar sacas já cadastradas anteriormente (Fig. 54). Após o preenchimento dos campos e um clique no botão Salvar (a), é apresentada uma mensagem de *feedback* ao usuário (b). A tela em (c) é apresentada após o usuário selecionar a opção de listar. Ao selecionar um exemplo em (d), o software retorna à janela de cadastro (e) onde o usuário poderá realizar ajustes ou correções nos dados anteriormente cadastrados, bastando para isso alterar o(s) campo(s) desejado e selecionar a opção de salvar (f).

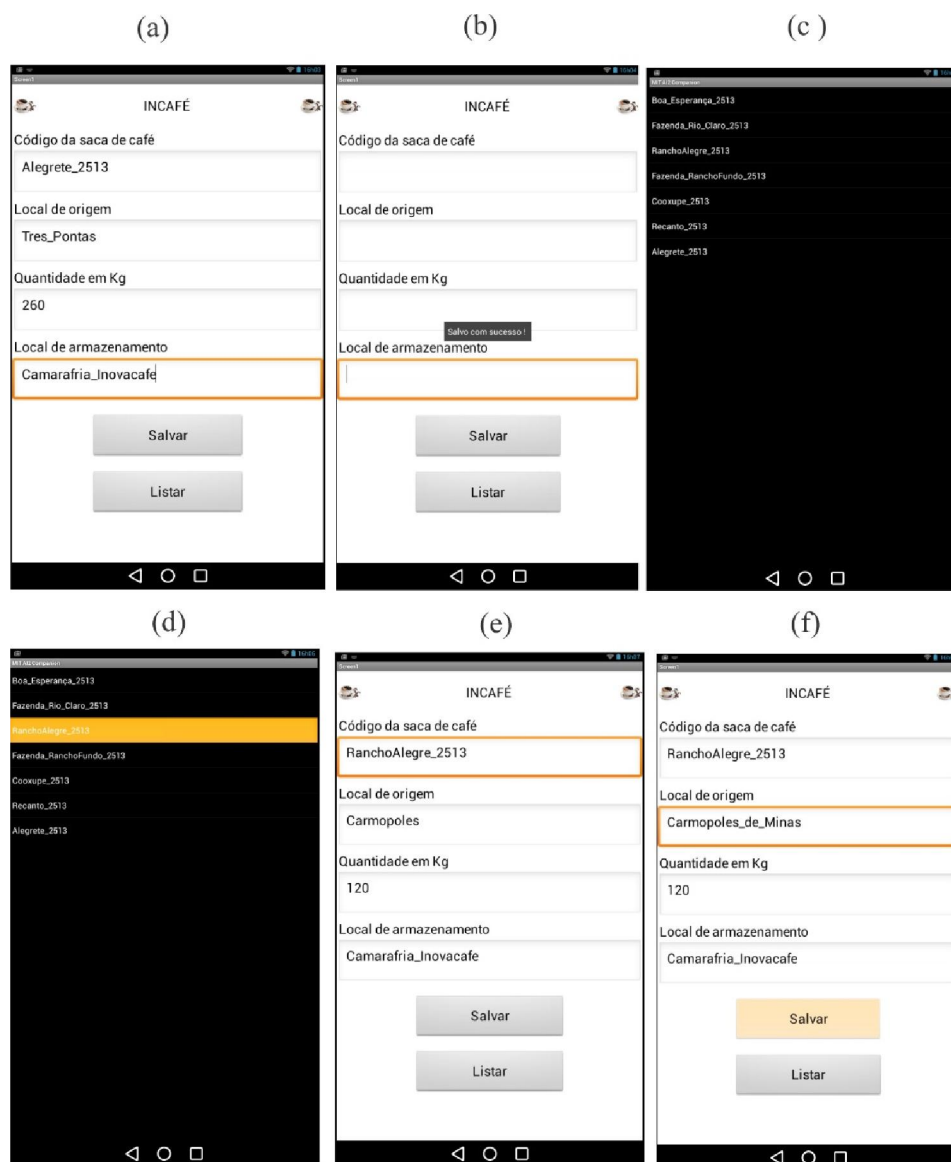


Figura 54 Janelas da aplicação INCAFÉ, onde (a) representa a janela inicial, (b) mensagem de indicação de envio dos dados ao sistema, (c) lista com dados cadastrados, (d) seleção de um campo para alteração, (e) exibição dos valores do café selecionado, e em (f) a versão final com o campo de local de origem alterado

6.3.2 Aplicativo FISICAFÉ

A aplicação desenvolvida para o cadastro das pontuações obtidas durante o processo de análise física de amostras de café foi nomeada de FISICAFÉ, significando a junção das palavras física e café.

Ao iniciar a aplicação (Fig. 55), é exibida uma janela contendo os campos de cadastro de código das amostras, pontuação física, umidade, valor de L^* , valor de a^* , valor de b^* e classe das amostras. Os valores de CIEL*, a^* , b^* e o da classe devem ser preenchidos conforme o resultado da aplicação de classificação de amostras de grão cru por meio de fotografias.

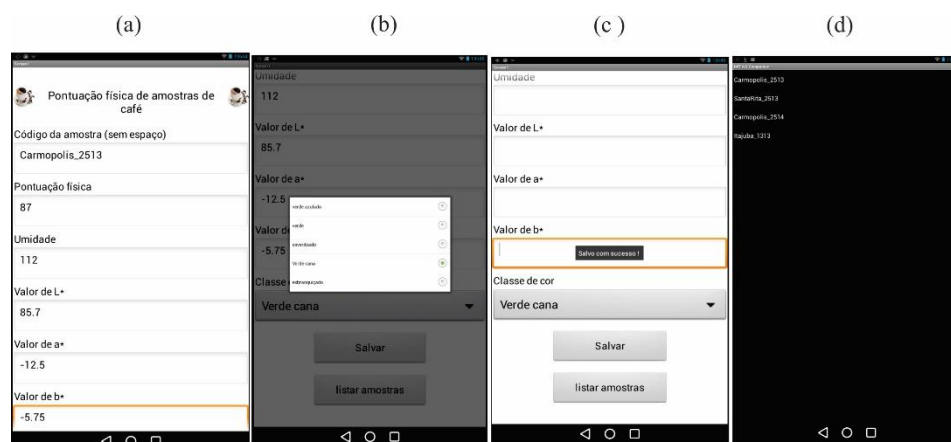


Figura 55 Janelas da aplicação FISICAFÉ, onde (a) representa a janela inicial com campos preenchidos, (b) seleção das classes de café, (c) confirmação do envio dos dados ao sistema, (d) lista das amostras cadastradas e seleção de um código para ajuste de correções

6.3.3 Aplicativo LEGUSTA

A aplicação desenvolvida para o cadastro das pontuações obtidas durante o processo de análise sensorial de amostras de café foi nomeada de LEGUSTA, abreviação do termo latino para “você gosta? ”.

Ao iniciar a aplicação (Fig. 56) é exibida uma janela com os campos para cadastro de usuário (a), onde pode-se selecionar o cadastro de um novo avaliador preenchendo o campo nome e clicando em cadastrar (b), ou selecionar um já cadastrado anteriormente na aba nomes (c). Após esta etapa, é apresentada uma nova janela com o nome do avaliador selecionado anteriormente, o código da amostra avaliada, os controles deslizantes para as pontuações de crosta, fragrância, aroma, finalização, acidez, corpo, balanço, (d) e (e). A figura (f) apresenta os *checkboxes* para seleção de xícaras desuniformes e xícaras com doçuras irregulares.



Figura 56 Janelas da aplicação LEGUSTA, onde (a) representa a janela inicial, (b) mensagem de indicação de envio dos dados ao sistema, (c) lista com dos nomes de avaliadores cadastrados, (d) início da primeira etapa de avaliação contendo nome do avaliador selecionado, (e) pontuações realizadas mediante alteração nos controles deslizantes, e em (f) envio dos dados para o banco da primeira amostra

As aplicações desenvolvidas podem ser facilmente ajustadas conforme as necessidades dos concursos.

6.4 Banco de Dados

As aplicações Android utilizam um modelo de formulário para captura dos dados a serem enviados para o SGBD. Todos os campos de pontuação foram implementados em um modelo entidade-relacionamento com as estruturas que se julgarem necessárias para armazenamento e relacionamento das entidades.

Inicialmente foi desenvolvido o modelo conceitual baseado em múltiplas entidades em um único Banco, e verificou-se a aplicabilidade das técnicas de modelagem orientada a relacionamentos, ilustradas na Fig. 57.

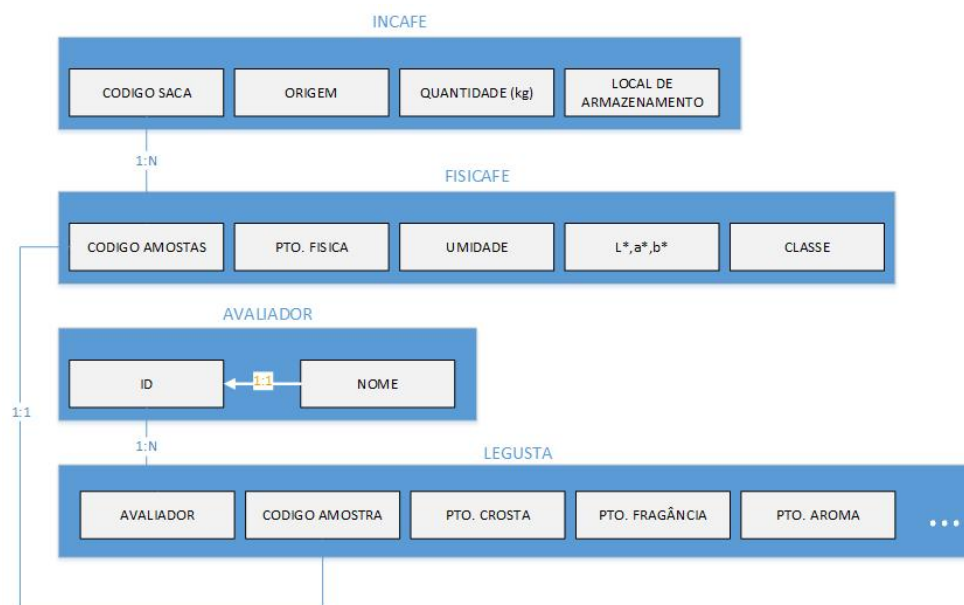


Figura 57 Esboço do diagrama entidade/relacionamento desenvolvido para nortear os testes no Banco de Dados

Nota-se que os códigos das amostras estão diretamente relacionados com as sacas cadastradas inicialmente. Desta maneira o Banco de Dados é capaz de armazenar praticamente todos os dados relacionados ao processamento de informações relacionadas as amostras de café. Abaixo são indicadas as variáveis de cada entidade.

Tabela 8 Relação das entidades e variáveis armazenadas

INCAFE	
cod_saca	Código da saca de café recebida pelo projeto
origem	Dados de origem deste café
quantidade	Quantidade em kg
local	Local de armazenagem das sacas
FISICAFE	
cod_cafe	Código da amostra retirada da saca cadastrada
pto_fisica	Pontuação recebida pela análise física (catação)
umidade	umidade retirada dos grãos crus da amostra
L	Valo de l* recebidos pela aplicação de análise g. cru
a	Valo de a* recebidos pela aplicação de análise g. cru
b	Valo de b* recebidos pela aplicação de análise g. cru
classe	Valor indicada pela aplicação de análise grãos crus
AVALIADOR	
ID	Identificador numérico auto incrementado pelo B.D.
nome	Nome do avaliador cadastrado pela aplicação LEGUSTA
LEGUSTA	
nome_avaliador	Nome do avaliador responsável pela análise sensorial
cod_amostra	Código da amostra que será analisada
pto_crosta	Pontuação recebida da crosta de café
pto_fragancia	Pontuação recebida pela fragrância
pto_sabor	Pontuação para sabor da amostra
pto_finalizacao	Pontuação para a finalização
pto_acidez	Pontuação da acidez
int_acidez	Pontuação da intensidade da acidez
pto_corpo	Pontuação dada ao corpo da amostra

niv_corpo	Pontuação de nível de corpo
uni1	Caixa de marcação <i>on/off</i> para uniformidade da xícara 1
uni2	Caixa de marcação <i>on/off</i> para uniformidade da xícara 2
uni3	Caixa de marcação <i>on/off</i> para uniformidade da xícara 3
uni4	Caixa de marcação <i>on/off</i> para uniformidade da xícara 4
uni5	Caixa de marcação <i>on/off</i> para uniformidade da xícara 5
balanco	Pontuação do nível de balanço entre as xícaras
su1	Caixa de marcação <i>on/off</i> para sujeira da xícara 1
su2	Caixa de marcação <i>on/off</i> para sujeira da xícara 2
su3	Caixa de marcação <i>on/off</i> para sujeira da xícara 3
su4	Caixa de marcação <i>on/off</i> para sujeira da xícara 4
su5	Caixa de marcação <i>on/off</i> para sujeira da xícara 5
doc1	Caixa de irregularidade <i>on/off</i> em doçura da xícara 1
doc2	Caixa de irregularidade <i>on/off</i> em doçura da xícara 2
doc3	Caixa de irregularidade <i>on/off</i> em doçura da xícara 3
doc4	Caixa de irregularidade <i>on/off</i> em doçura da xícara 4
doc5	Caixa de irregularidade <i>on/off</i> em doçura da xícara 5
pto_geral	Pontuação geral recebida pela amostra analisada
tmp_xicara	Envio da temperatura da xícara no momento da análise
TORRA	
cod_amostra	Código da amostra de café (mesmo da analisada)
tempo	dados de amostragem de tempo em segundos
temperatura	temperatura da massa da amostra coletados no tempo
DADOS TORRA	
cod_amostra	Código da amostra analisada pela aplicação de torra
agt_inteiro	Valor de Agtron estimado pela aplicação de g. inteiros
l_int	Valor de L* de grãos inteiros da aplicação de g. inteiros
a_int	Valor de a* de grãos inteiros da aplicação de g. inteiros
b_int	Valor de b* de grãos inteiros da aplicação de g. inteiros
agt_moido	Valor de Agtron estimado pela aplicação de g. moídos
l_moi	Valor de L* de grãos inteiros da aplicação de g. moídos
a_moi	Valor de a* de grãos inteiros da aplicação de g. moídos
b_moi	Valor de b* de grãos inteiros da aplicação de g. moídos

6.5 Curva de torra

Os dados de acompanhamento das curvas de torração foram obtidos de um equipamento da marca Atilia®, por meio de uma interface de comunicação serial (USB), *full gauge controls* Sistrad (Versão 4.11), responsável pela captura das temperaturas de massa e de temperatura ambiente do torrador.

A aquisição da temperatura foi ajustada para que a cada cinco segundos seus valores fossem enviadas ao Banco por meio de um notebook acoplado ao torrador. Deste modo, é possível a comparação em tempo real com uma curva de torra idealizada anteriormente. Um exemplo é ilustrado na Fig. 58, onde uma linha com $x=y$ foi adicionada ao gráfico para ilustrar uma possível referência da torra, contudo neste caso não houve o ajuste de chama ou ventilação para aproximar a torra da reta.




Figura 58 Relação de dados obtidos do torrador (linha grossa), com dados sobrepostos conforme necessidade (linha fina).

O gráfico foi elaborado na ferramenta Matlab da empresa MathWorks para uma melhor exibição dos valores de tempo e temperatura, além de permitir uma visualização em tempo real comparada com outras curvas de torra. Estas características não foram obtidas ao se utilizar o modo de plotagem direto da ferramenta Sistrad do torrador, como ilustrado na figura 58.




Figura 59 Curva de torra obtida pelo software do módulo de captura de temperaturas Sistrad
Fonte: Sistrad (2015)

As curvas de torra armazenadas no banco possuem identificação de código da amostra torrada. O mesmo código é aplicado a mostra analisada sensorialmente, o que permite futuras analogias para a caracterização das bebidas.

7 CONCLUSÕES E POSSÍVEIS IMPACTOS NA GESTÃO DE DADOS ACERCA DE CAFÉS

As características de coloração para torração de cafés variam em decorrência de sua destinação final, todavia, existem padrões internacionais que direcionam o grau de torra em processos de análises sensoriais, e este é aferido por meio de equipamentos de alto custo que, em alguns casos, não permitem o armazenamento automático de seus valores em um arquivo ou Banco de Dados a baixos custos de implantação.

O armazenamento das informações de coloração permite ao avaliador definir melhor as características de determinado café, além de validar a curva de torra exigida pelo padrão utilizado.

Uma maneira de atacar este problema é o desenvolvimento de sistemas de informações integradas utilizando módulos de baixo custo, combinados com modelos de visão computacional por fotografias de amostras, que permitam uma rápida, porém confiável, caracterização de objetos.

Desta forma, objetivou-se neste trabalho construir uma plataforma de captura, organização, armazenamento e análise de dados para processos referentes a análises sensoriais de cafés a baixo custo e em módulos distintos. Foram implementadas diferentes técnicas de inteligência computacional para adequação de valores obtidos por um equipamento fotográfico, como os obtidos por equipamentos homologados para esta tarefa. Visando melhorar a aquisição de dados para o sistema, foram também desenvolvidas várias aplicações para dispositivos móveis Android/iOS, por plataforma de desenvolvimento de softwares aberta e de fácil alterações, responsáveis por coletar informações referentes ao cadastro de sacas de café, local de armazenamento, classificação de

cor para grãos crus, curva de torra, classificação de grau de torra e análise sensorial.

Os modelos de visão computacional utilizaram um padrão de cores desenvolvido pela *International Commission of Illumination* (CIELab), considerado mais adequado que o conhecido padrão RGB, pois esse foi desenvolvido para representar de maneira uniforme o espaço de cores visíveis pelo olho humano.

A caracterização de cores de imagens fotografadas em CIELab, utilizou-se de dois processos iniciais, sendo o primeiro de conversão de RGB em LAB, responsável pela mudança do espaço de cores da câmera fotográfica para o utilizado nos modelos, e o segundo de regressão em escala Agtron, onde os modelos são treinados e validados para representar os equipamentos utilizados para aferir o grau de torra em escala Agtron.

A obtenção do modelo de conversão se justifica por duas razões i- a obtenção de uma equação matemática que relacione os padrões de cores, podendo ser utilizada por outros usuários que consigam a obtenção dos valores de CIELab de suas amostras por outros métodos; ii- tentativa de encontrar modelos com boa acurácia ao utilizar uma entrada composta por três valores para estimar uma saída de uma dimensão (CIELab, Agtron).

O modelo de regressão utilizado teve para treinamento vários exemplos de cores de amostras de grãos de café torrado inteiro e moído com seis tipos distintos de aproximadores de função (representando o equipamento Agtron). Os aproximadores foram implementados considerando as diferenças encontradas por cores de amostras (3 modelos) e também por tonalidades em escala de cinza (3 modelos).

Como resultados, foram selecionados dois modelos com os melhores resultados para retratar o equipamento Agtron via fotografias de amostras de café. Com o modelo de visão computacional construído, foi possível obter, com

alto grau de confiança, os valores de CIELab e de escala Agtron de novas amostras de café torrado.

As aplicações Android/iOS desenvolvidas no trabalho utilizaram modelos de formulários com caixas de texto, caixas de marcação e barras de nível para retratar ao máximo os modelos que utilizam tabelas impressas (anexo D), estes modelos podem ser facilmente alterados caso haja a necessidade de adição de novos parâmetros e seus dados são enviados ao banco por meio de conexão wi-fi, possibilitando assim, acesso ao Banco de Dados das aplicações em qualquer lugar que possua uma conexão com a internet.

O acompanhamento dos parâmetros de torra e grau de moagem são aspectos fundamentais para a manutenção da qualidade da bebida. O ponto de torra ideal, que revelará todo sabor e aroma tem a cor como característica fundamental, implicando diretamente na análise sensorial. Ao armazenar estes dados em um banco será possível integrar e extrair muitas outras informações por meio de mineração de dados, um exemplo que pode ser aplicado a definição de novas curvas de torra para elevar determinadas características de um determinado café.

8 PUBLICAÇÕES

Abaixo são apresentados, em ordem cronológica, os resumos e artigos publicados durante a realização deste trabalho.

SAMID LEME, D.; BARBOSA, B. H. G.; PEREIRA, R. G. F. A. Aplicação de comitês de Redes Neurais para a classificação de grãos de café. In: CONGRESSO DE PÓS-GRADUAÇÃO DA UFLA, 22., 2013, Lavras. **Anais...** Lavras: UFLA, 2013. Disponível em: <http://www.apg.ufla.br/resumos/resumo_2013/html/titulo.html>. Acesso em: 10 nov. 2015.

SANTOS, J. P. M. et al. Prototipação de aplicação portátil para otimização do processo de degustação de cafés especiais. In: CONGRESSO DE PÓS-GRADUAÇÃO DA UFLA, 23., 2014, Lavras. **Anais...** Lavras: UFLA, 2014. Disponível em: <http://www.apg.ufla.br/resumos/resumo_2014/html/resumo/#sistemas>. Acesso em: 10 nov. 2015.

SAMID LEME, D. et al. Plataforma digital para mensuração de grãos de café especiais: escala Agtron obtida através de fotografias. In: SIMPÓSIO DE PESQUISA DOS CAFÉS DO BRASIL, 9., 2015, Curitiba. **Anais...** Curitiba, 2015. Disponível em: <<http://www.sbicafe.ufv.br/handle/123456789/3518>>. Acesso em: 10 nov. 2015.

OLIVEIRA, E. M. et al. A computer vision system for coffee bean classification based on computational intelligence techniques. **Journal of Food Engineering**, Essex, v. 171, p. 22-27, Feb. 2016. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0260877405007934>>. Acesso em: 10 nov. 2015.

REFERÊNCIAS

- ARDUINO. **Getting started with Arduino**. Disponível em: <<https://www.arduino.cc/en/Guide/HomePage#>>. Acesso em: 2 mar. 2015.
- ASSOCIAÇÃO BRASILEIRA DA INDÚSTRIA DE CAFÉ. **Indicadores da indústria de café no Brasil**. Brasília, 2014. Disponível em: <<http://www.abic.com.br/publique/cgi/cgilua.exe/sys/start.htm?sid=61#consf2014.2>>. Acesso em: 4 ago. 2015.
- BANKS, M.; MCFADDEN, C.; ATKINSON, C. **The world encyclopedia of coffee**. London: Lorenz Books, 1999. 256 p.
- BLUNDELL, J. E.; ROGERS, P. J. Hunger, hedonic and the control satiation and satiety. In: FRIEMAN, M. I.; TORDOFF, M. G.; KARE, M. R. (Ed.). **Chemical senses**. New York: M. Decker, 1991. v. 4, p. 127-148.
- BOCANEGRA, C. W. R. **Procedimentos para tornar mais efetivo o uso das redes neurais artificiais em planejamento de transportes**. 2002. 97 p. Dissertação (Mestrado em Engenharia Civil) - Universidade de São Paulo, São Carlos, 2002.
- BORÉM, F. M. et al. Evaluation of the sensory and color quality of coffee beans stored in hermetic packaging. **Journal of Stored Products Research**, Amsterdam, v. 52, p. 1-6, Jan. 2013.
- BORÉM, F. M.; MARQUES, E. R.; ALVES, E. Ultrastructural analysis damage in parchment Arabica coffee endosperm cells. **Biosystems Engineering**, Saint Joseph, v. 99, n. 1, p. 62-66, Jan. 2008.
- BRAGA, A. de P.; CARVALHO, A. C. P. L. F.; LUDERMIR, T. B. **Redes neurais artificiais: teoria e aplicações**. Rio de Janeiro: Livros Técnicos e Científicos, 2000. 226 p.
- BRAINARD, D. H. Color appearance and color difference specification. In: SHEVELL, S. K. (Ed.). **The science of color**. 2nd ed. Amsterdam: Elsevier, 2003. p. 191-216.
- BRASIL SPECIALITY COFFEE ASSOCIATION. **Cafés especiais**. 2005. Disponível em: <<http://bsca.com.br/cafes-especiais.php>>. Acesso em: 10 abr. 2015.

BROSNAN, T.; SUN, D. W. Influence of modulated vacuum cooling on the cooling rate, mass loss and vase life of cut lily flowers. **Biosystems Engineering**, Saint Joseph, v. 86, n. 1, p. 45-49, Sept. 2003.

CARRO, L.; WAGNER, F. R. Sistemas computacionais embarcados. In: JORNADAS DE ATUALIZAÇÃO EM INFORMÁTICA, 22., 2003, Campinas. **Anais...** Campinas: Sociedade Brasileira de Computação, 2003. p. 45-94.

CASTRO, L. N. de; ZUBEN, F. J. von. From biologically inspired computing to natural computing. In: _____. **Recent developments in biologically inspired computing**. London: Idea Group, 2004. chap. 1, p. 1-8.

COBUCCI, R. M. A. **Análise sensorial**. Goiânia: PUC-GO, 2010. 16 p. Apostila.

COELHO, A. A. R.; COELHO, L. dos S. **Identificação de sistemas dinâmicos lineares**. Florianópolis: UFSC, 2004. 181 p.

COMPANHIA NACIONAL DE ABASTECIMENTO. **Acompanhamento da safra brasileira: café**. Brasília, 2014. 55 p.

DATE, J. C. **Introdução a sistemas de bancos de dados**. Rio de Janeiro: Campus, 2000. 865 p.

DELLA LUCIA, S. M.; MININ, V. P. R.; CARNEIRO, M. J. D. S. **Análise sensorial de alimentos: estudos com consumidores**. Viçosa, MG: UFV, 2006. 332 p.

ELMASRI, R.; NAVATHE, S. B. **Sistemas de banco de dados**. 4th ed. São Paulo: A. Wesley, 2005. 730 p.

FERNANDEZ-VAZQUEZ, R. Visual and instrumental evaluation of orange juice color: a consumers' preference study. **Journal of Sensory Studies**, Westport, v. 26, n. 6, p. 436-444, Dec. 2011.

FRICH, A. **Color management guide**. Disponível em: <<http://www.color-management-guide.com/color-spaces.html>>. Acesso em: 11 abr. 2014.

FRISHMAN, L. J. Basic visual processes. In: GOLDSTEIN, E. B. (Ed.). **Blackwell handbook of sensation and perception**. Blackwell: J. Wiley, 2005. p. 53-91.

GALO, M. L. B. T. **Caracterização ambiental do Parque Estadual Morro do Diabo através de dados e técnicas de Sensoriamento remoto: abordagem utilizando redes neurais artificiais.** 2000. 205 p. Tese (Doutorado em Ciências da Engenharia Ambiental) - Universidade de São Paulo, São Carlos, 2000.

GOPIXPIC. **Human neuron.** Disponível em: <<http://www.gopixpic.com/>>. Acesso em: 10 maio 2014.

HAYKIN, S. S. **Neural networks and learning machines.** 3rd ed. Ottawa: Pearson, 2009. 916 p.

HEBB, D. O. **The organization of behaviour: a neuropsychological theory.** New York: J. Wiley, 1949. 335 p.

HUNT, R. W. G. **Measuring color.** 2nd ed. New York: E. Horwood, 1991. 323 p.

HUNT, R. W. G. **The reproduction of colour.** 5th ed. London: Fountain, 1995. 724 p.

INTERNATIONAL COMMISSION ON ILLUMINATION. **Colorimetry.** 2nd ed. Cambridge: CIE, 1986. Disponível em: <<http://www.cie.co.at/S>>. Acesso em: 15 jul. 2014.

JANSEN, G. A. **Coffee roast magic-art-science physical changes and chemical reactions.** Munich: GmbH, 2006. 72 p.

JUDD, D. B. Standard observer and coordinate system for colorimetry. **Journal of the Optical Society of America**, Rochester, v. 23, n. 10, p. 359-373, 1933.

LACHENMEIER, D. W. Rapid quality control of spirit drinks and beer using multivariate data analysis of Fourier transform infrared spectra. **Food Chemistry**, London, v. 101, n. 2, p. 825-832, 2007.

LANA, M. M.; TIJSKENS, L. M. M.; KOOTEN, O. van. Effects of storage temperature and fruit ripening on firmness of fresh cut tomatoes. **Postharvest Biology and Technology**, Amsterdam, v. 35, n. 1, p. 87-95, 2005.

LARRAIN, R. E.; SCHAEFER, D. M.; REED, J. D. Use of digital images to estimate CIE color coordinates of beef. **Food Research International**, Barking, v. 41, n. 4, p. 380-385, 2008.

LECHETA, R. R. **Google android: aprenda a criar aplicações para dispositivos móveis com o Android SDK**. 2. ed. São Paulo: Novatec, 2010. 608 p.

LEÓN, K. et al. Color measurement in L*a*b* units from RGB digital images. **Food Research International**, Barking, v. 39, n. 10, p. 1084-1091, Dec. 2006.

MAC DEVELOPER LIBRARY. **Color spaces**. Disponível em: <https://developer.apple.com/library/mac/documentation/GraphicsImaging/Conceptual/CSintro/CSintro_colorspace/CSintro_colorspace.html>. Acesso em: 20 jan. 2014.

MANFUGÁS, J. E. **Evaluación sensorial de los alimentos**. Ciudad de La Habana: Universitária, 2007. 116 p.

MARTIN, M. L. G. M. et al. Measuring colour appearance of red wines. **Food Quality and Preference**, Barking, v. 18, n. 6, p. 862-871, Sept. 2007.

MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **The Bulletin of Mathematical Biophysics**, Chicago, v. 5, n. 4, p. 115-133, 1943.

MENDONÇA, C. V. do C. E. **Caracterização química e físico-química de cafés (*Coffea arabica* L.) despulpados pré-secos em aerador e terreiro**. 2005. 112 p. Tese (Doutorado em Ciências dos Alimentos) - Universidade Federal de Lavras, Lavras, 2005.

MENDOZA, F.; AGUILERA, J. M. Application of image analysis for classification of ripening bananas. **Journal of Food Science**, Chicago, v. 69, n. 9, p. 471-477, Dec. 2004.

MENDOZA, F.; DEJMEK, P.; AGUILERA, J. M. Calibrated color measurements of agricultural foods using image analysis. **Postharvest Biology and Technology**, Amsterdam, v. 41, n. 3, p. 285-295, Sept. 2006.

MINOLTA. **Products and models**. Disponível em: <<http://sensing.konicaminolta.com.br/products/cr-400-410-chroma-meter-difference-with-colorimeter/>>. Acesso em: 4 out. 2015.

MIRANDA-VILELA, A. L. Sinapses. **Biologia e Materiais Didáticos**, São Paulo, 2006. Disponível em: <<http://www.afh.bio.br/nervoso/nervoso2.asp#tiposneuro>>. Acesso em: 4 ago. 2015.

MIT APP-INVENTOR. **About US:** what is MIT App Inventor? Disponível em: <<http://appinventor.mit.edu/explore/about-us.html>>. Acesso em: 1 out. 2015.

MIT APP-INVENTOR. **Connect your phone or tablet over Wi-Fi.** Massachusetts, 2014. Disponível em: <<http://appinventor.mit.edu/explore/ai2/setupdevice-wifi.html>>. Acesso em: 23 ago. 2014.

MORAES, M. A. C. M. **Métodos para avaliação sensorial dos alimentos.** 8. ed. Campinas: UNICAMP, 1993. 93 p.

NEVES, D. L. F. **PostgreSQL: conceitos e aplicações.** São Paulo: Érica, 2002. 192 p.

OLIVEIRA, E. M. et al. A computer vision system for coffee beans classification based on computational intelligence techniques. **Journal of Food Engineering**, Essex, v. 171, p. 22-27, Feb. 2016.

OLIVEIRA, P. D. et al. Aspectos fisiológicos de grãos de café, processados e secados de diferentes métodos, associados à qualidade sensorial. **Coffee Science**, Lavras, v. 8, n. 2, p. 211-220, abr./jun. 2012.

OSÓRIO, F.; BITTENCOURT, J. R. Sistemas inteligentes baseados em redes neurais artificiais aplicados ao processamento de imagens. In: WORKSHOP DE INTELIGÊNCIA ARTIFICIAL, 1., 2000, Santa Cruz do Sul. **Anais...** Santa Cruz do Sul: UNISC, 2000. 1 CD-ROM.

PEDRESCHI, F. et al. Computer vision classification of potato chips by color. **Journal of Food Process Engineering**, Westport, v. 34, n. 5, p. 1714-1728, 2011.

PEREIRA, L. C. O.; SILVA, M. L. da. **Android para desenvolvedores.** Rio de Janeiro: Brasport, 2009. 240 p.

RIBEIRO, F. C. et al. Storage of green coffee in hermetic packaging injected with CO₂. **Journal of Stored Products Research**, Oxford, v. 47, n. 4, p. 341-348, Oct. 2011.

RIBEIRO, S. R. A.; CENTENO, J. A. S. Clasificación del uso del suelo utilizando redes neurales y el algoritmo maxver. **Innovación**, Santiago de Chile, v. 14, n. 1, p. 55-60, 2002.

ROSEMBLAT, F. The perceptron: a probabilistic model for information storage and organization in the brain. **Psychological Review**, Washington, v. 65, n. 6, p. 386-408, 1958.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning internal representation by error propagation. In: RUMELHART, D. E.; MCCLELLAND, J. L. (Ed.). **Parallel distributed processing: explorations in the microstructure of cognition**. Cambridge: MIT, 1986. p. 318-362.

RUSS, J. C. **Image processing handbook**. Boca Raton: CRC, 1999. 771 p.

SAGE, A. P. **Concise encyclopedia of information processing in systems and organization**. New York: Pergamon, 1990. 548 p.

SANTOS, D. et al. Fatores críticos de competitividade na cadeia produtiva do café no Brasil e o mercado de cápsulas de café. **Revista Jovens Pesquisadores**, São Paulo, v. 12, n. 1, p. 3-23, jan./mar. 2015.

SANZ-URIBE, J. R.; GIRALDO, P. J. R.; TASCÓN, C. E. O. Algorithm to identify maturation stages of coffee fruits. In: WORLD CONGRESS ON ENGINEERING AND COMPUTER SCIENCE, 2008, San Francisco. **Proceedings...** San Francisco: IEEE, 2008. p. 167-174.

SCHMIDT, P. et al. Avaliação da qualidade de cafés torrados e moídos embalados a vácuo. **Revista de Biologia e Ciências da Terra**, Campina Grande, v. 9, n. 1, p. 31-40, 2009.

SEGNINI, S.; DEJMEK, P.; ÖSTE, R. A low cost video technique for color measurement of potato chips. **Food Science & Technology**, London, v. 32, n. 4, p. 216-222, June 1999.

SHAFIIEE, S. et al. Honey characterization using computer vision system and artificial neural networks. **Food Chemistry**, London, v. 159, p. 143-150, Sept. 2014.

SILVA, L. A.; HERNANDEZ, E. M. Classification of breast masses using a committee machine of artificial neural networks. **Journal of Electronic Imaging**, Washington, v. 17, n. 1, p. 1-10, Jan./Mar. 2008.

SITRAD. **Software para controle da temperatura**. Disponível em: <<http://www.sitrad.com.br/>>. Acesso em: 30 abr. 2015.

SIVETZ, A. W.; DESROSIER, N. W. **Coffee technology**. Westport: AVI, 1979. 716 p.

SÓ BIOLOGIA. **Comunicação neural**. Disponível em: <<http://www.sobiologia.com.br>>. Acesso em: 12 maio 2014.

SPECIALTY COFFEE ASSOCIATION OF AMERICA. **History**. Long Beach, 2012. Disponível em: <<http://www.scaa.org/?page=history>>. Acesso em: 26 out. 2014.

SPECIALTY COFFEE ASSOCIATION OF AMERICAN. **Protocols: cupping specialty coffee**. Long Beach, 2009. 7 p

STÖDERSTRÖM, T.; STOICA, P. **System identification**. New York: Prentice-Hall, 1989. 238 p.

STONE, H.; SIDEL, J. L. **Sensory evaluation practices**. 3rd ed. Davis: Elsevier Academic, 2004. 377 p. (Food Science and Technology, International Series).

SUN, F. X. et al. Determination of beer color using image analysis. **Journal of the American Society of Brewing Chemists**, Saint Paul, v. 62, n. 4, p. 163-167, July 2004.

SUN, X. et al. Predicting fresh beef color grade using machine vision imaging and support vector machine (SVM) analysis. **Journal of Animal and Veterinary Advances**, Oxford, v. 10, n. 12, p. 1504-1511, 2011.

TANEMBAUM, A. S. **Redes de computadores**. 4. ed. São Paulo: Campus, 2003. 955 p.

TASTE, smell, and touch: lecture notes. Disponível em: <<http://www-psych.stanford.edu/~lera/psych15s/notes/lecture11/>>. Acesso em: 13 mar. 2014.

TOLEDO, J. L. B. de; BARBOSA, A. T. **Classificação de degustação de café**. Brasília: SEBRAE, 1998. 91 p. (Série Agronegócio).

VALOUS, N. A. et al. Colour calibration of a laboratory computer vision system for quality evaluation of pre-sliced hams. **Meat Science**, Barking, v. 81, n. 1, p. 132-141, Jan. 2009.

WEBTRONICO. **Informações sobre LM-35**. Disponível em:
<http://www.webtronico.com/lm35-sensor-de-temperatura.html?filter_name=lm35>. Acesso em: 28 abr. 2015.

WU, D.; SUN, D. W. Colour measurements by computer vision for food quality control: a review. **Trends in Food Science & Technology**, Cambridge, v. 29, n. 1, p. 5-20, Jan. 2013.

YAGIZ, Y. et al. Comparison of Minolta colorimeter and machine vision system in measuring colour of irradiated Atlantic salmon. **Science of Food and Agriculture**, London, v. 89, n. 4, p. 728-730, Mar. 2009.

ZHANG, B. et al. Principles, developments and applications of computer vision for external quality inspection of fruits and vegetables: a review. **Food Research International**, Barking, v. 62, p. 326-343, Aug. 2014.

ANEXOS

ANEXO A –*Software* em Arduino para recebimento, controle e envio das temperaturas das xícaras

```
// inicialização das variáveis base
int sensor = 0;
int leitura = 0;
float temp = 0;
// inicio da função de comunicação
void setup(){
  Serial.begin(38400); //Inicia Comunicação Serial pela porta 38400
  delay(1000);
}
// inicio da função de leitura em loop infinito
void loop(){
  leitura = analogRead(sensor);
  temp = (leitura * 0.00488); // ajuste da sensibilidade de leitura
  temp = temp *100; // ajuste do valor a ser exibido
  Serial.print("Temperatura: "); //Envia via Bluetooth
  Serial.println(temp);
  Serial.print(" °C "); // envio do character representando Celcius
  delay(5000); // delay de 5 segundo para atualizar o envio
```

ANEXO B –Variáveis implementadas para cada entidade no Banco de Dados:

Cadastro de sacas

#	Nome	Tipo	Agrupamento (Collation)	Atributos	Nulo	Omissão	Extra
1	cod_saca	varchar(30)	utf8_unicode_ci		Não	None	
2	origem	varchar(30)	utf8_unicode_ci		Não	None	
3	quantidade	float			Não	None	
4	local	varchar(30)	utf8_unicode_ci		Não	None	

Análise física

<input type="checkbox"/>	1	cod_cafe	varchar(30)	latin1_swedish_ci		Não	None
<input type="checkbox"/>	2	pto_fisica	int(3)			Não	None
<input type="checkbox"/>	3	umidade	float			Não	None
<input type="checkbox"/>	4	L	float			Não	None
<input type="checkbox"/>	5	a	float			Não	None
<input type="checkbox"/>	6	b	float			Não	None
<input type="checkbox"/>	7	classe	int(1)			Não	None

Análise de torra

#	Nome	Tipo	Agrupamento (Collation)	Atributos	Nulo	Omissão	Extra
1	cod_cafe	varchar(30)	latin1_swedish_ci		Não	None	
2	agt_int	float			Não	None	
3	L_int	float			Não	None	
4	a_int	float			Não	None	
5	b_int	float			Não	None	
6	agt_moi	float			Não	None	
7	L_moi	float			Não	None	
8	a_moi	float			Não	None	
9	b_moi	float			Não	None	

Cadastro de avaliador

Nome	Tipo	Agrupamento (Collation)	Atributos	Nulo	Omissão	Extra
id	int(3)			Não	None	AUTO_INCREMENT
nome	varchar(30)	utf8_unicode_ci		Não	None	

Gráfico de torra

#	Nome	Tipo	Agrupamento (Collation)	Atributos	Nulo	Omissão	Extra
1	tempo	float			Não	None	
2	temperatura	float			Não	None	

Análise Sensorial

#	Nome	Tipo	Agrupamento (Collation)	Atributos	Nulo	Omissão	Extra
1	nome_avaliador	varchar(30)	utf8_unicode_ci		Não	None	
2	cod_amostra	varchar(20)	utf8_unicode_ci		Não	None	
3	crosta	float			Não	None	
4	fragancia	float			Não	None	
5	sabor	float			Não	None	
6	finalizacao	float			Não	None	
7	acidez_pto	float			Não	None	
8	acidez_int	float			Não	None	
9	corpo_pto	float			Não	None	
10	corpo_niv	float			Não	None	
11	uni1	varchar(1)	utf8_unicode_ci		Não	None	
12	uni2	varchar(1)	utf8_unicode_ci		Não	None	
13	uni3	varchar(1)	utf8_unicode_ci		Não	None	
14	uni4	varchar(1)	utf8_unicode_ci		Não	None	
15	uni5	varchar(1)	utf8_unicode_ci		Não	None	
16	balanco	float			Não	None	
17	suj1	varchar(1)	utf8_unicode_ci		Não	None	
18	suj2	varchar(1)	utf8_unicode_ci		Não	None	
19	suj3	varchar(1)	utf8_unicode_ci		Não	None	
20	suj4	varchar(1)	utf8_unicode_ci		Não	None	
21	suj5	varchar(1)	utf8_unicode_ci		Não	None	
22	doc1	varchar(1)	utf8_unicode_ci		Não	None	
23	doc2	varchar(1)	utf8_unicode_ci		Não	None	
24	doc3	varchar(1)	utf8_unicode_ci		Não	None	
25	doc4	varchar(1)	utf8_unicode_ci		Não	None	
26	doc5	varchar(1)	utf8_unicode_ci		Não	None	
27	pto_geral	float			Não	None	

ANEXO C – Códigos em PHP para comunicação entre aplicação Android e Banco de dados para envio, leitura e alteração de informações cadastradas para a aplicação de cadastro de sacas.

```
// Envio de dados ao banco qualidade_café para a entidade cadastro_saca
<?php
    $codigo=$_GET['cod_saca'];
    $origem=$_GET['origem'];
    $quantidade=$_GET['quantidade'];
    $local=$_GET['local'];

    $conexao = mysql_connect('localhost','root','root');

mysql_select_db('qualidade_cafe',$conexao);

    $sql = "insert into cadastro_saca (cod_saca, origem, quantidade, local) values
('$codigo','$origem','$quantidade','$local)";

    $resultado = mysql_query($sql) or die ("Erro: " . mysql_error());

    if($resultado)
        echo "ok";
    else
        echo "0";
?>
```

```
// Leitura dos dados do banco qualidade_cafe para a entidade cadastro_saca
segundo o código da saca selecionado
<?php
    $conexao = mysql_connect('localhost','root','root');

mysql_select_db('qualidade_cafe',$conexao);

mysql_query("SET NAMES 'utf8'");
    mysql_query('SET character_set_connection=utf8');
    mysql_query('SET character_set_client=utf8');
    mysql_query('SET character_set_results=utf8');

    $sql="select * from cadastro_saca";

    $resultado = mysql_query($sql) or die ("Erro: " . mysql_error());

    // Obtém o resultado de uma linha como um objeto
    while($linha = mysql_fetch_object($resultado))
        echo $linha->cod_saca."#";
    echo "^";
?>
```

```
// Alteração dos dados do banco qualidade_cafe para a entidade cadastro_saca  
segundo o código da saca selecionado
```

```
<?php
```

```
    $cod_saca=$_GET['cod_saca'];
```

```
    $conexao = mysql_connect('localhost','root','root');
```

```
    mysql_select_db('qualidade_cafe',$conexao);
```

```
mysql_query("SET NAMES 'utf8'");
```

```
mysql_query('SET character_set_connection=utf8');
```

```
mysql_query('SET character_set_client=utf8');
```

```
mysql_query('SET character_set_results=utf8');
```

```
$sql="select * from cadastro_saca where cod_saca like '$cod_saca'";
```

```
$resultado = mysql_query($sql) or die ("Erro: " . mysql_error());
```

```
while($linha = mysql_fetch_object($resultado)){
```

```
    echo $linha->cod_saca."#";
```

```
    echo $linha->origem."#";
```

```
    echo $linha->quantidade."#";
```

```
    echo $linha->local."#";
```

```
    }
```

```
    echo "^";
```

```
?>
```

ANEXO D –Matriz de pontuação SCAA



COFFEE CUPPING DATA SHEET

Name: _____
Date: _____

Quality Coffee Grades	
95 - Outstanding	75 - Very Good Commercial
90 - Specialty	70 - Good
85 - Specialty	65 - Good

Sample #	Fragrance/Aroma	Uniformity	Clean Cup	Sweetness	Flavor	Acidity	Body	Aftertaste	Balance	Overall	Total Score
	10 Dry 9 Break 8 7 6	10 8 6 4 2 ZERO	10 8 6 4 2 ZERO	10 8 6 4 2 ZERO	10 8 6 4 2 ZERO	10 9 8 7 6	10 9 8 7 6 Intensity Low High 	10 9 8 7 6 Level Thin Heavy 	10 9 8 7 6	10 9 8 7 6	Defects (subtract) Taint=2 Fault=4 #Cups Intensity [] X [] = [] Final Score []
Roast Level of Sample	Notes:										
Sample #	Fragrance/Aroma	Uniformity	Clean Cup	Sweetness	Flavor	Acidity	Body	Aftertaste	Balance	Overall	Total Score
10 Dry 9 Break 8 7 6	10 8 6 4 2 ZERO	10 8 6 4 2 ZERO	10 8 6 4 2 ZERO	10 8 6 4 2 ZERO	10 9 8 7 6	10 9 8 7 6 Intensity Low High 	10 9 8 7 6 Level Thin Heavy 	10 9 8 7 6	10 9 8 7 6	Defects (subtract) Taint=2 Fault=4 #Cups Intensity [] X [] = [] Final Score []	
Roast Level of Sample	Notes:										
Sample #	Fragrance/Aroma	Uniformity	Clean Cup	Sweetness	Flavor	Acidity	Body	Aftertaste	Balance	Overall	Total Score
10 Dry 9 Break 8 7 6	10 8 6 4 2 ZERO	10 8 6 4 2 ZERO	10 8 6 4 2 ZERO	10 8 6 4 2 ZERO	10 9 8 7 6	10 9 8 7 6 Intensity Low High 	10 9 8 7 6 Level Thin Heavy 	10 9 8 7 6	10 9 8 7 6	Defects (subtract) Taint=2 Fault=4 #Cups Intensity [] X [] = [] Final Score []	
Roast Level of Sample	Notes:										