

**UNIVERSIDADE FEDERAL DO PARANÁ**  
**EDUARDO DE ANDRADE**

**CLASSIFICAÇÃO DE CORES DE EMBALAGENS DE DEFENSIVOS**  
**AGRÍCOLAS UTILIZANDO REDES BAYESIANAS**

**CURITIBA**  
**2013**

**EDUARDO DE ANDRADE**

**CLASSIFICAÇÃO DE CORES DE EMBALAGENS DE DEFENSIVOS  
AGRÍCOLAS UTILIZANDO REDES BAYESIANAS**

Dissertação apresentada ao Curso de Pós-Graduação em Engenharia Elétrica. Área de Concentração em Sistemas Eletrônicos, Departamento de Engenharia Elétrica da UFPR, como parte das exigências para obtenção do título de mestre em Engenharia Elétrica.

Orientador: Dr. Prof. Gideon Villar Leandro  
Co-orientador: Dr. Prof. João da Silva Dias

**CURITIBA**

**2013**

---

A553c

Andrade, Eduardo de

Classificação de cores de embalagens de defensivos agrícolas utilizando redes bayesianas / Eduardo de Andrade. – Curitiba, 2013.  
95f. : il. color. ; 30 cm.

Dissertação (mestrado) - Universidade Federal do Paraná, Setor de Tecnologia, Programa de Pós-graduação em Engenharia Elétrica, 2013.

Orientador: Gideon Villar Leandro -- Co-orientador: João da Silva Dias.  
Bibliografia: p. 90-95.

I. Reconhecimento de padrões. 2. Redes Bayesianas. 3. Produtos agrícolas. I. Universidade Federal do Paraná. II. Leandro, Gideon Villar. III. Dias, João da Silva. IV. Título.

CDD: 006.42

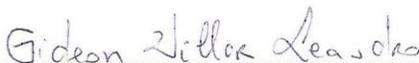
---

## TERMO DE APROVAÇÃO

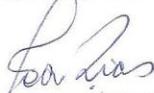
Eduardo de Andrade

### Classificação de Cores de Embalagens de Defensivo Agrícola Utilizando Redes Bayesianas

Dissertação apresentada como requisito parcial para obtenção do grau de  
Mestre no Programa de Pós-Graduação em Engenharia Elétrica da  
Universidade Federal do Paraná.



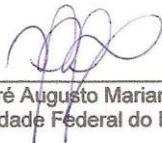
Prof. Dr. Gideon Villar Leandro – Orientador  
Universidade Federal do Paraná



Prof. Dr. João da Silva Dias – Co-orientador  
Universidade Federal do Paraná



Prof. Dr. Eduardo Parente Ribeiro – Convidado  
Universidade Federal do Paraná



Prof. Ph. D. André Augusto Mariano – Convidado  
Universidade Federal do Paraná



Profa. Dra. Lucia Valeria Ramos de Arruda – Convidada  
Universidade Tecnológica Federal do Paraná

Curitiba, 28 de Agosto de 2013

## AGRADECIMENTOS

É inefável o sentimento de gratidão que se asila no âmago de meu ser e se extravasa pelo meu eu, mas as palavras que aqui são colocadas eu dedico a todos as pessoas que contribuíram na conclusão deste trabalho.

Agradeço em especial...

...A Deus por ter nos criado simples e ignorantes, concedendo-nos a possibilidade de trilhar o caminho da evolução de maneira livre, individual e única.

Ao meu pai, Wanderley, pela força, sugestões, conversas que deram início a este trabalho e incentivo incondicional em todos os momentos da minha vida. Minha mãe Cleusa por sua dedicação maternal e compreensão ilimitadas. Ambos, forjando meu caráter e esculpindo minha moral, sempre com desvelos de ternura e compaixão. Ao meu irmão Felipe, pela formidável convivência fraternal e empréstimo do 'escritório' sempre que se fazia necessário.

Ao meu professor orientador Prof. Dr. Gideon Villar Leandro, pela confiança em mim depositada desde a apresentação da proposta do projeto. Pela sua condução nas atividades desempenhadas durante o programa de mestrado, por compartilhar seu conhecimento, apontamentos e observações.

Ao professor co-orientador Prof. Dr. João da Silva Dias, por sempre apresentar excelentes explicações, extremamente solícito, disposto e disponível. Sua determinação e persistência motivaram-me muito na conclusão do trabalho.

Ao Prof. Dr. Eduardo Parente Ribeiro, que em diversas ocasiões brindou-me com acertadas observações e sugestões acerca do trabalho proposto, e ao Prof. Ph. D. André Augusto Mariano, pelas críticas e sugestões sempre válidas.

Aos professores do Programa de Pós Graduação em Engenharia Elétrica da UFPR, em especial ao Prof. Dr. Alessandro Zimmer e Prof. Dr. Alexandre Rasi Aoki, pelas inolvidáveis aulas e material de pesquisa disponibilizado.

Ao meu supervisor Jefferson Chochi Zembovici, pela compreensão em todos os momentos complicados e por ter me permitido assumir o compromisso do mestrado.

Ao meu colega Adriel, pela sincera amizade e ótimas conversas.

## Elevação

*“Escuta, alma querida,  
Aceita as aflições e as lágrimas da vida,  
Por agentes de acesso à Esfera Superior...  
Mágoa, queixa, revolta e rebeldia  
Lembram muralhas sob a noite fria  
Furtando o coração à luz do amor.*

*Se a prova te retalha a alma sincera,  
Perdoa, faze o bem, trabalha e espera  
Aprendendo da estrada em derredor...  
Tudo o que vive e sonha, sofre e ama,  
Dos astros do Infinito aos vermes sob a lama,  
Dando-se à elevação do futuro melhor...*

*O Sol potente que nos ilumina  
É um gigante em perpétua disciplina,  
Varando lutas que desconhecemos,  
Por mais se lhe arremesse lixo à face,  
Brilha em silêncio como se explicasse  
Que só o amor domina os Céus Supremos...*

*Corre a fonte da penha ao chão da serra,  
Depois, ganhando o vale, faz da terra  
Verdejante celeiro em garbos de jardim...  
Pelo bem que constrói, de segundo a segundo,  
Muitas vezes recolhe os detritos do mundo,  
Mas beija lodo e pedra e canta mesmo assim!...*

*O carvão na lareira acende a chama,  
O tronco mutilado não reclama,  
A estrada se aprimora aguentando tratores...  
No trigo triturado o pão puro se asila,  
Cria-se a porcelana em fogo sobre a argila,  
O roseiral podado dá mais flores!...*

*Assim também, alma querida e boa,  
Não recuses a dor que aperfeiçoa,  
Se nos espanca os sonhos, teus e meus...  
Golpes, tribulações, angústias, tempestade  
São recursos da vida erguendo a Humanidade  
Para a Bênção de Deus.”*

*Maria Dolores*

## RESUMO

O método empregado atualmente na classificação da cor de embalagens de defensivos agrícolas consiste na inspeção visual humana. Todavia a quantidade de embalagens recebidas mensalmente nas centrais de recolhimento e o grau de toxicidade da embalagem tornam esse trabalho exaustivo, insalubre e suscetível a falhas. O presente trabalho demonstra que através da aquisição de uma imagem digital da embalagem é possível realizar a classificação baseada na sua cor. O trabalho de classificação de cores de embalagens de defensivos agrícolas em um ambiente computacional é um problema de difícil modelagem devido principalmente a: *i)* grande quantidade de informações que devem ser filtradas na imagem; *ii)* às variações de luminosidade do ambiente; *iii)* sujeira ou informação impressa que podem ser percebidos como ruído; *iv)* alta similaridade das características de cor das embalagens. Entendendo que as características de cor de cada imagem apresentam-se de forma imprecisa, propõe-se neste trabalho a utilização do raciocínio probabilístico para realizar a classificação de cor, através de uma Rede Bayesiana. A metodologia de avaliação da embalagem, proposta neste trabalho, aborda desde a aquisição e processamento da imagem até a definição resultado final. Os resultados apresentados neste trabalho estimulam a aplicação de um sistema automatizado para realizar classificação de cor das embalagens de defensivos agrícolas. Sob condições ideais de iluminação o sistema conseguiu atingir o acerto de 100% na classificação das embalagens.

Palavras chave: reconhecimento de cores, Redes Bayesianas, HSL, separação de embalagens.

## **ABSTRACT**

Human visual inspection is the used method to classify color of pesticide packages. However, the package amount received monthly by the recycling plants and the toxicity degree of those packages, turn this work into an exhausting, unhealthy and failure susceptible process. The present work demonstrates that by acquiring a digital image of the package it is possible to perform the classification based on its color. The color classification of pesticide packages in a computing environment is a hard problem to solve, due to large amount of information to be filtered in the image, ambient lighting variations, noise that may be contained in the image and high similarity of the packages characteristics. Understanding that the color characteristics of each image are shown inaccurately, it is proposed by this work the use of probabilistic reasoning to perform color sorting through a Bayesian Network. The classification methodology proposed by this work, deal since from image acquisition and processing until final result acquisition. After image processing process, the image data are presented to a Bayesian Network that returns the result. The result presented on this work encourages the application of an automated system to perform the classification of pesticide packages. Under a standard pattern of illumination condition, the system was able to classify correctly all package samples.

Keywords: color recognition; Bayesian Network; HSL; package separation.

## LISTA DE FIGURAS

Figura 1	Alguns dos produtos produzidos à partir da reciclagem de embalagens. Fonte: INPEV (2013).....	29
Figura 2	Embalagens já classificadas para encaminhamento à central de reciclagem. Fonte: ADDCS - depósito Guarapuava/PR. ....	31
Figura 3	Embalagens COEX (esquerda) e PEAD (direita). Fonte: o próprio autor. ....	32
Figura 4	Cores das embalagens de defensivos agrícolas. Fonte: o próprio autor. ....	33
Figura 5	Detalhe do gargalo, (b) detalhe do rótulo das embalagens de defensivos agrícolas. Fonte: o próprio autor. ....	34
Figura 6	Pixels em uma imagem tons de cinza. ....	36
Figura 7	Pixels em uma imagem colorida.....	37
Figura 8	Faixa espectral visível. Adaptado de Umbaugh (2010). ....	38
Figura 9	Captura dos fótons através do fotodiodo. Adaptado de BENGTTSSON (2008). ....	39
Figura 10	Filtro Bayer (BAYER, 1976).....	40
Figura 11	Filtro Bayer atuando para permitir a captura da faixa de frequência de onda desejada. Adaptado de BENGTTSSON (2008). ....	41
Figura 12	Deslocamento dos elétrons através das fases do barramento metálico. Adaptado de BENGTTSSON (2008). ....	42
Figura 13	<i>On chip lens</i> : lentes que auxiliam no direcionamento da luz. Adaptado de BENGTTSSON (2008). ....	42
Figura 14	Etapas do processamento digital de imagens. Adaptado de Gonzalez & Woods (1998). ....	44
Figura 15	Modelo RGB. Adaptado de Umbaugh (2010).....	47
Figura 16	Modelo HSL. Adaptado de Umbaugh (2010).....	48
Figura 17	Exemplo de erosão de A por B. Adaptado de MARQUES FILHO & VIEIRA NETO (1999). ....	51
Figura 18	Representação de um SE. Adaptado de Dias (2013).....	58

Figura 19	Exemplo de uma Rede Bayesiana com 5 nós. Fonte: o próprio autor. .....	61
Figura 20	TPC do nó "HUE". Fonte: o próprio autor.....	63
Figura 21	Rede classificadora <i>Naive Bayes</i> . Fonte: o próprio autor.....	65
Figura 22	Curvas ROC de uma embalagem Branco Leitoso. Fonte: o próprio autor.....	69
Figura 23	Processos executados pelo sistema. Fonte: o próprio autor.....	71
Figura 24	Imagem original adquirida através da <i>webcam</i> . Fonte: o próprio autor. .....	73
Figura 25	Imagem após subtração do fundo. Fonte: o próprio autor.....	75
Figura 26	Imagem final que será avaliada pelo sistema. Fonte: o próprio autor.	75
Figura 27	Rede classificadora de cores. Fonte: o próprio autor. ....	77
Figura 28	Estados do nó <i>EMBALAGEM</i> , após alimentação dos nós de entrada ( <i>HUE</i> , <i>SAT</i> , <i>LUM</i> ) com as informações de um pixel obtido da imagem de uma embalagem Branca Leitosa. Fonte: o próprio autor. ....	78
Figura 29	Estabilidade na percentagem de pixels classificados como Azuis com base na variação das condições de iluminação de uma embalagem da classe Azul. Fonte: o próprio autor.....	87
Figura 30	Falta de estabilidade na percentagem de pixels classificados como BN e CZ com base na variação das condições de iluminação de uma embalagem da classe Branca Natural. Fonte: o próprio autor. ....	88

## LISTA DE TABELAS

Tabela I	Percentual de tipo de material recolhido em 2012 na ADDCS em Guarapuava no Paraná. ....	30
Tabela II	Tabela de contingência .....	66
Tabela III	Representatividade da classe na imagem de uma embalagem Branca Natural.....	79
Tabela IV	Quantidades de imagens utilizadas no treinamento.....	81
Tabela V	Sensibilidade do sistema.....	82
Tabela VI	Vetores de classificação médios de cada classe. ....	83
Tabela VII	Quantidades de imagens utilizadas na fase de teste .....	84
Tabela VIII	Taxa de acerto do sistema em condições ideais de iluminação.....	84
Tabela IX	Parâmetros da RNA .....	85
Tabela X	Taxa de acerto para cada classe, na avaliação sem variação nas condições de iluminação. ....	86
Tabela XI	Resultados individuais de cada classe.....	86

## LISTA DE ABREVIATURAS E SIGLAS

ADDCS	Associação de Distribuidores de Defensivo do Centro Sul
BC	Base de conhecimento
CCD	<i>Charged Coupling Device</i>
CMOS	<i>Complementary Metal-Oxide-Semiconductor</i>
COEX	Coextrusado
DAG	<i>Directed Acyclic Graph</i>
HSL	<i>Hue, Saturation, Luminosity</i> (tonalidade, saturação, luminosidade)
IA	Inteligência Artificial
inpEV	Instituto Nacional de Processamento de Embalagens Vazias
PEAD	Polietileno de Alta Densidade
PNRS	Política Nacional de Resíduos Sólidos
RB	Rede Bayesiana
RGB	<i>Red, Green, Blue</i> (vermelho, verde, azul)
RNA	Redes Neurais Artificiais
SE	Sistema Especialista
TPC	Tabela de Probabilidades Condicionais

## LISTA DE SÍMBOLOS

$\theta$	Operação de erosão
<i>AM</i>	Embalagem amarela
<i>AZ</i>	Embalagem azul
<i>B</i>	Azul
<i>BL</i>	Embalagem branco leitoso (opaco)
<i>BN</i>	Embalagem branco natural (translúcido)
<i>CZ</i>	Embalagem cinza
<i>G</i>	Verde
<i>H</i>	Tonalidade
<i>Im</i>	Imagem digital
<i>ImFundo</i>	Imagem de fundo
<i>L</i>	Luminosidade
<i>R</i>	Vermelho
<i>S</i>	Saturação
<i>VR</i>	Embalagem verde
<i>VE</i>	Embalagem verde escuro

## SUMÁRIO

1.	INTRODUÇÃO.....	16
1.1.	IDENTIFICAÇÃO DO PROBLEMA .....	18
1.2.	RECONHECIMENTO DE CORES .....	19
1.3.	TRABALHOS RELACIONADOS .....	20
1.4.	OBJETIVOS .....	21
1.4.1.	OBJETIVO GERAL.....	21
1.4.2.	OBJETIVOS ESPECÍFICOS .....	22
1.5.	CONTRIBUIÇÕES.....	22
1.6.	ESTRUTURA DO TRABALHO.....	23
2.	EMBALAGENS.....	24
2.1.	LOGÍSTICA REVERSA.....	25
2.2.	LEGISLAÇÃO.....	27
2.3.	AUTOMATIZAÇÃO DA RECICLAGEM.....	28
2.4.	EMBALAGENS DE DEFENSIVOS AGRÍCOLAS.....	28
2.4.1.	TIPOS DE EMBALAGENS DE DEFENSIVOS .....	32
2.4.2.	CORES DAS EMBALAGENS DE DEFENSIVOS.....	33
2.4.3.	SISTEMA DE CLASSIFICAÇÃO .....	34
3.	VISÃO COMPUTACIONAL .....	35
3.1.	IMAGEM DIGITAL.....	36
3.2.	AQUISIÇÃO DE IMAGEM DIGITAL .....	37
3.2.1.	SENSOR CCD .....	43
3.2.2.	SENSOR CMOS .....	43
3.3.	PROCESSAMENTO DE IMAGENS DIGITAIS.....	43
3.4.	FORMATOS DE REPRESENTAÇÃO DE COR .....	46
3.4.1.	MODELO RGB.....	46
3.4.2.	MODELO HSL.....	47
3.5.	PRÉ-PROCESSAMENTO.....	50
3.6.	SEGMENTAÇÃO DE IMAGENS.....	51
3.7.	EXTRAÇÃO DE CARACTERÍSTICAS.....	52

4.	INTELIGÊNCIA COMPUTACIONAL.....	53
4.1.	UM BREVE HISTÓRICO SOBRE IA.....	53
4.2.	SISTEMAS INTELIGENTES .....	56
4.3.	SISTEMAS ESPECIALISTAS .....	57
4.3.1.	AQUISIÇÃO E REPRESENTAÇÃO DO CONHECIMENTO .....	59
4.4.	REDES BAYESIANAS .....	60
4.4.1.	ESTRUTURA DAS REDES BAYESIANAS .....	61
4.4.2.	CLASSIFICADORES BAYESIANOS.....	64
4.4.3.	CLASSIFICADOR <i>NAIVE-BAYES</i> .....	64
4.5.	AVALIAÇÃO DO DESEMPENHO DOS TESTES.....	65
4.5.1.	TABELA DE CONTINGÊNCIA .....	66
4.5.2.	CURVA ROC.....	68
5.	METODOLOGIA.....	70
5.1.	AQUISIÇÃO DE IMAGENS.....	72
5.2.	PRÉ-PROCESSAMENTO E SEGMENTAÇÃO.....	73
5.3.	AMOSTRAGEM DOS PIXELS .....	75
5.4.	CONVERSÃO RGB PARA HSL .....	76
5.5.	CLASSIFICAÇÃO DOS PIXELS .....	77
5.6.	CLASSIFICADOR DE CORES.....	79
6.	RESULTADOS E DISCUSSÕES.....	81
6.1.	TREINAMENTO DO SISTEMA .....	81
6.2.	TESTES .....	84
6.2.1.	PRIMEIRA AVALIAÇÃO.....	84
6.2.2.	SEGUNDA AVALIAÇÃO .....	85
7.	CONCLUSÃO.....	89
7.1.	TRABALHOS FUTUROS .....	90
	REFERÊNCIAS .....	92

## 1. INTRODUÇÃO

A agricultura tem sido desenvolvida pelo ser humano desde os mais remotos períodos históricos. O momento exato em que os primeiros indivíduos iniciaram o cultivo de espécies vegetais é desconhecido, já que este fato é anterior à origem da própria história escrita, mas admite-se que ela tenha surgido em diversos lugares do globo ao mesmo tempo. Isso ocorreu possivelmente na época em que as antigas civilizações começaram a ocupar os vales e várzeas no período neolítico. Esses primeiros indivíduos perceberam que quando algumas sementes ou grãos colhidos para sua alimentação eram enterrados, eles poderiam dar origem a plantas iguais às que as originaram (ALVES FILHO, 2002).

Desde então o ser humano vem aprendendo a trabalhar a terra a seu favor, buscando métodos de cultivo mais aprimorados e expandindo a área de cultivo de acordo com a demanda. Expansão essa que, até o século XIX, foi um dos principais métodos de aumento da produção. No entanto, devido à diminuição da oferta de terras disponíveis e viáveis para realizar o plantio, surgiu uma tendência na busca pelo aumento produtivo utilizando o mesmo espaço físico (SILVA & COSTA, 2012). A população global em contínuo crescimento causou um reflexo direto na demanda por produtos derivados do meio agrícola. Esse crescimento alavancou as pesquisas científicas para o desenvolvimento de métodos, insumos e implementos agrícolas cada vez mais eficientes. No último século houve um significativo aumento de produção, que se deve principalmente aos métodos de mecanização do campo, sistemas de irrigação, qualificação dos trabalhadores no setor agrícola, técnicas de melhoramento genéticos das plantas e a utilização de defensivos agrícolas (JAMES, 2011).

O defensivo agrícola é amplamente utilizado para maximizar os resultados quantitativos e qualitativos no meio agrícola. Esse tipo de produto tem sido utilizado no mundo inteiro com o objetivo de suprir as demandas do mercado através do aumento da capacidade produtiva, protegendo a cultura contra pestes e pragas que poderiam causar a perda parcial ou total do plantio. As perdas relacionadas com pestes e pragas são calculadas, por alguns estudos científicos, em torno de 30 a 40% da produção (SILVA & COSTA, 2012).

Métodos de controle de pragas e pestes através da utilização de compostos químicos foram registrados em escrituras gregas e romanas há mais de 3.000 anos. Os compostos orgânicos como, por exemplo, a nicotina também há muito tempo já tinham suas propriedades pesticidas conhecidas (ALVES FILHO, 2002).

Na Europa do século XIX, compostos inorgânicos à base de metais tóxicos, tais como cobre, enxofre e mercúrio foram largamente empregados no controle de fungos (SILVA & COSTA, 2012). Além destes, nas primeiras décadas do século XX foram utilizados compostos à base de flúor, arsênico, selênio, chumbo, bórax e sais de zinco. Estes compostos, que apresentam elevado grau de toxicidade, caracterizaram a primeira geração de defensivos agrícolas.

Devido aos avanços nas pesquisas na área da química, inseticidas desenvolvidos através de síntese química começaram a ser produzidos na década de 1930. Mas é a partir da Segunda Guerra Mundial que ocorreu um acentuado crescimento nas pesquisas na indústria da síntese química. Os pesquisadores dessa área concentraram esforços no desenvolvimento de substâncias sintéticas que acabaram por produzir grande impacto nos campos da agricultura e saúde pública. A utilização de produtos sintéticos foi o que caracterizou a segunda geração de defensivos agrícolas.

Na década de 60, por conta da preocupação com a saúde pública e impactos ambientais, surge a terceira geração de defensivos agrícolas que é caracterizada pelo menor grau de toxicidade e maior eficiência, sendo preciso aplicar menores quantidades do produto para uma mesma área plantada.

A quarta geração de defensivos agrícolas é caracterizada pela sofisticação dos modos de ação e especificidade de aplicação. Os compostos químicos produzidos atuam sobre determinada doença ou praga, não comprometendo toda a fauna e flora. Sendo mais específicos e proporcionando alta capacidade de degradação ambiental, reduzem os riscos à saúde humana (ALVES FILHO, 2002).

Apesar das vantagens obtidas através do uso do defensivo agrícola, ela gera um resíduo que, se não tratado corretamente, pode causar danos à saúde humana e danos ambientais (BIGATÃO, 2009).

O Brasil possui a Lei nº. 9.974/2000 que regulamenta a gestão pós-consumo de embalagens vazias de defensivos agrícolas. Essa lei foi instituída com a intenção de garantir que esses produtos sejam destinados ao processo de reciclagem ou destruição, evitando que sejam descartados de forma incorreta e provoquem danos ambientais. Nesse cenário surge o conceito de logística reversa, onde as empresas precisam criar mecanismos de rastreabilidade e técnicas de recolhimento de suas embalagens (COMETTI & ALVES, 2010). O Instituto Nacional de Processamento de Embalagens Vazias (inpEV) foi criado pela associação de fabricantes de defensivos agrícolas com o intuito de atender a essa política de recolhimento, que exige dos fabricantes, distribuidores, produtores rurais e poder público a responsabilidade sobre a destinação final das embalagens vazias.

O cumprimento das responsabilidades de cada elo dessa cadeia implica em centenas de milhares de embalagens vazias de defensivos agrícola recolhidas mensalmente, em todo o país, nas centrais de recolhimento do inpEV. Os produtores rurais, ou cooperativas de produtores, entregam as embalagens vazias, de diversas cores, misturadas em um único carregamento. Para realizar a reciclagem, há a necessidade de separá-las de forma que possam ser destinadas ao processo correspondente ao tipo da embalagem. Atualmente essa classificação é realizada de forma manual, sendo que, através da observação da característica de cor da embalagem, um técnico determina a classe a que a embalagem pertence.

### **1.1. IDENTIFICAÇÃO DO PROBLEMA**

A demanda crescente por alimentos e o avanço nas técnicas agrícolas tem impulsionado a utilização de defensivos agrícolas e por consequência aumentado o volume de embalagens recebidas nas centrais de recolhimento do inpEV. As tarefas de recolhimento, classificação e encaminhamento para reciclagem das embalagens representam um custo que é dividido entre todos os elos do sistema de recolhimento. Existe também o agravante da embalagem vazia, mesmo lavada, ser um produto que apresenta riscos à saúde humana e riscos ambientais.

Portanto, quanto mais rápido for o processo de destinação final da embalagem, menor será o impacto socioambiental e menores serão os custos operacionais com classificação, armazenamento e destinação final.

Apesar de haver um grande crescimento nas pesquisas de sistemas de visão na área computacional, a classificação de embalagens de defensivos agrícolas ainda é realizada manualmente através de inspeção visual humana. À primeira vista, esse procedimento parece uma tarefa relativamente fácil, pois o técnico já conhece as cores e possui as faculdades, físicas e cognitivas, necessárias para classificá-la. No entanto, devido ao volume de embalagens, esse trabalho é exaustivo e repetitivo, o que torna o processo suscetível a falhas. Um sistema automatizado que realize essa tarefa pode apresentar resultados melhores que o processo manual no que se refere à velocidade e precisão na etapa de classificação, além de não estar sujeito às consequências advindas do trabalho nessas condições insalubres.

## **1.2. RECONHECIMENTO DE CORES**

Reconhecer uma cor em um objeto ou uma imagem é uma tarefa trivial para um ser humano, no entanto, num ambiente computacional ela pode não ser tão simples quanto aparenta. O sistema visual humano possui receptores que produzem estímulos nervosos que são transmitidos ao cérebro causando a sensação de visão. Essa sensação visual é interpretada de maneira inconsciente pelo cérebro e a ela é atribuído um significado. O significado é representado por adjetivos como azul, rosa, verde-claro, amarelado, etc. Essas mesmas informações, quando capturadas por sensores digitais, e apresentadas em um ambiente computacional criam uma imagem digital. A imagem digital armazena, em um vetor bidimensional, os valores pertinentes aos sinais capturados pelo sensor de imagem digital, e essa é a principal informação utilizada por um sistema de visão computacional. Essa informação apresenta-se de maneira imprecisa e normalmente com ruídos. Não obstante, a quantidade de informações trazidas normalmente contém mais dados do que o necessário à resolução do problema, sendo necessário, em alguns casos, filtrar a informação desejada. Dessa forma,

antes mesmo de classificar os dados obtidos é necessário realizar um processamento para extrair a porção relevante e representá-la através de critérios objetivos e mensuráveis, para que dessa forma esses dados possam ser utilizados na obtenção da informação desejada. Com esses dados adquiridos, o próximo passo é a classificação, de maneira que a sua interpretação possa trazer um resultado útil e com significado. Essa interpretação pode ser realizada de diversas maneiras, como, por exemplo, análises estatísticas, técnicas de IA, entre outras. A escolha da técnica depende em grande parte das características do problema abordado.

### **1.3. TRABALHOS RELACIONADOS**

Diversos setores da indústria vêm obtendo bons resultados da aplicação de sistemas de visão computacional para realizar separação e classificação de objetos. Sistemas de classificação de cores ou objetos em imagens digitais são pesquisados em diversas áreas do conhecimento e estão cada vez mais presentes no ramo industrial. As ferramentas computacionais evoluíram no que tange a sua capacidade de processamento e tornaram-se acessíveis em termos de custo, favorecendo o desenvolvimento e aplicação desse tipo de sistema. Há exemplos desse avanço no segmento agroindustrial com a classificação de frutas, onde há a necessidade de realizar a conferência do padrão de qualidade do produto que será disponibilizado ao consumidor (SIMÕES & COSTA, 2003). Na área de segurança existem trabalhos que utilizam as imagens digitais para extrair informações do veículo, como cor e marca (BUTZKE *et al.*, 2008). No segmento de reciclagem existem trabalhos que realizam a classificação de embalagens vazias de refrigerante (CONNOLLY, 1995). Na área de ferramentas computacionais interativas existem trabalhos que buscam a identificação de cores e formas de objetos para realizar o controle da máquina (MASUTANI *et al.*, 2013). Existem ainda trabalhos no setor de engenharia ambiental, que através dos recursos de análise das características de imagens digitais auxiliam os processos de sensoriamento remoto (LIMA *et al.*, 2005).

Nos trabalhos relacionados com reconhecimento de padrões em imagens digitais, existem diversas ferramentas diferentes que podem ser aplicadas. Mesmo assim, essas várias ferramentas computacionais possuem uma característica em comum que é a capacidade de lidar com informações inexatas, ou com ruídos nos dados coletados ou dados fora de um padrão conhecido. Para lidar com esse tipo de informação podem ser utilizados Sistemas Especialistas (SE). Os SE conseguem armazenar o conhecimento específico sobre um problema, e através de uma ferramenta computacional que realize o processamento do conhecimento chega a um resultado útil e com significado (REZENDE, 2003).

Dentre as várias ferramentas computacionais utilizadas em SE, podem ser destacadas as Redes Neurais Artificiais (RNA), Lógica Nebulosa (Lógica Fuzzy) e Redes Bayesianas.

Essas técnicas vêm sendo estudadas e desenvolvidas no intuito de aprimorar a qualidade dos produtos e serviços, e são baseadas principalmente na maneira em que os especialistas humanos realizam a tomada de decisões.

Neste trabalho a ferramenta escolhida é a Rede Bayesiana. Ela utiliza o raciocínio probabilístico para determinar o resultado da classificação fornecendo uma base para a tomada de decisão. Através da análise dos dados presentes no domínio, tabelas condicionais que armazenam valores probabilísticos são definidas e associadas aos eventos e determinam o grau de crença no resultado (CHARNIAK, 1991).

Podem-se citar entre as diversas aplicações, no âmbito do diagnóstico médico, trabalhos que auxiliam a tomada de decisão dos profissionais e também realizam diagnóstico de doenças (SANTANA, 2005; SIMÕES, 2001). Também há trabalhos que mostram o emprego das Redes Bayesianas como sistemas de classificação (SILVA, 2006).

## **1.4. OBJETIVOS**

### **1.4.1. OBJETIVO GERAL**

No intuito de minimizar o contato dos operadores com a embalagem de defensivos agrícolas através da automatização de parte do processo de

classificação, o presente trabalho apresenta um sistema para a classificação das cores das embalagens utilizando o processamento de imagens digitais e técnicas de inteligência artificial.

O principal objetivo deste trabalho é desenvolver um modelo de classificação de cor das embalagens vazias de defensivos agrícolas. A técnica escolhida foi um classificador bayesiano.

#### **1.4.2. OBJETIVOS ESPECÍFICOS**

O objetivo principal deste trabalho será obtido através de:

- caracterização da cor das embalagens que viabilize o processo de identificação automática da cor;
- concepção de um classificador de cores utilizando Redes Bayesianas;
- integração de ferramentas computacionais para realizar a segmentação, extração de características e reconhecimento de cor predominante de um objeto;
- concepção de um sistema de classificação de embalagens que minimize o contato do técnico com a embalagem no processo de triagem.

#### **1.5. CONTRIBUIÇÕES**

Este trabalho apresenta uma pesquisa sobre caracterização e classificação de cores em imagens digitais num ambiente computacional. Nele são abordados desde os primeiros passos de aquisição de uma imagem digital, segmentação do objeto alvo, até a classificação da cor da embalagem. A pesquisa aborda o processo de aquisição de imagens; a representação dessas informações num meio digital; a extração das informações relevantes através da segmentação da imagem; a extração do conhecimento dessas informações; e a classificação das cores através de um sistema de classificação.

O sistema proposto foi construído de forma modular, por isso, em cada módulo é possível agregar funções ou utilizar a ferramenta para outros fins. Ao classificador de cores, por exemplo, poderão ser adicionadas outras classes (cores), através de dados de treinamento para aumentar o escopo do classificador.

## **1.6. ESTRUTURA DO TRABALHO**

Este trabalho está organizado da seguinte forma: no capítulo 2 é apresentado o conceito de embalagem, logística reversa e as embalagens de defensivos agrícolas que serão estudadas pelo trabalho proposto, bem como o sistema de classificação atual baseado na classificação manual. No capítulo 3 são apresentadas algumas características de sistemas de visão e os materiais e métodos de aquisição de imagem mais difundidos, bem como modelos de representação de imagens digitais em um ambiente computacional. O capítulo 4 fala sobre sistemas baseados em conhecimento, apresenta a Rede Bayesiana e aborda como o raciocínio probabilístico pode ser utilizado para resolver problemas como o apresentado neste trabalho. A metodologia proposta para resolver o problema é apresentada no capítulo 5. Nele será apresentado o método de extração das características da embalagem e como elas são tratadas pela Rede Bayesiana para retornar um resultado útil e com significado. Os resultados são apresentados no capítulo 6. Finalmente ao final deste trabalho são apresentadas a conclusão e as propostas para trabalhos futuros.

## 2. EMBALAGENS

Uma embalagem é um elemento ou conjunto de elementos utilizados para conter um produto temporariamente. Suas funções são: proteção do produto durante movimentação e transporte, conservação do conteúdo, exibição de informações sobre condições de armazenamento, e informações sobre consumo e manipulação (MOURA & BANZATO, 1997). Além dessas características elas podem apresentar, estrategicamente, funções logísticas e comerciais para facilitar o armazenamento, promover a venda e fornecer valores de reutilização aos clientes. O formato, tamanho e material utilizado na fabricação das embalagens são características que diferem de acordo com o processo produtivo e o conteúdo que será armazenado.

Segundo LEITE (2003), as embalagens são classificadas em três tipos:

- **embalagens primárias ou de contenção:** são as embalagens que estão em contato direto com o produto;
- **embalagens secundárias:** são o agrupamento de certo número de produtos ou embalagens primárias;
- **embalagens de utilização:** são agrupamentos de embalagens secundárias em largas unidades para fins de manuseio.

As pesquisas em Engenharia de Produção visam tradicionalmente aperfeiçoar os processos produtivos com fluxo direcionado ao consumidor. O principal objetivo é maximizar a eficiência produtiva para atingir um lucro mínimo aceitável. A escolha do tipo da embalagem é um fator decisivo para contribuir de forma positiva no alcance desse objetivo. Os processos e materiais vêm, ao longo do tempo, sendo estudados e replanejados de forma que a maior eficiência seja atingida (MURARO *et al.*, 2006).

No entanto, nem sempre apenas a eficiência visando o lucro é o principal desencadeador de um avanço tecnológico. Algumas vezes para atender a uma tendência industrial ou atender legislação local vigente em relação à produção de determinados produtos, alguns processos produtivos são reestudados e reestruturados. Um exemplo dessa reestruturação é o gerenciamento do produto

gerado após consumo, de forma que eles sejam reintegrados no processo produtivo ou destinados ao seu final de forma ambientalmente sustentável. A linha de pesquisa que procura soluções para o fluxo inverso (pós-consumo do cliente à fonte produtora) chama-se logística reversa. A logística reversa é uma linha de pesquisa da Engenharia da Produção que trabalha com os processos relacionados com o retorno das embalagens ao processo produtivo. Nela são estudadas soluções para recuperar valores de alguma natureza com base no produto do pós-consumo (FORLIN & FARIA, 2002). Nesse segmento as pesquisas que visam aperfeiçoar os processos de reciclagem ganham força, gerando uma demanda por desenvolvimento de novos métodos, sistemas e ferramental que possam contribuir nesse aprimoramento.

Os conceitos mais detalhados da logística reversa e como eles se relacionam com o trabalho proposto serão apresentados neste capítulo, bem como a legislação vigente atualmente no Brasil, que trata sobre a responsabilidade das indústrias e consumidores em relação ao produto pós-consumo. A automatização dos processos de reciclagem vem ganhando espaço no mercado industrial, e sobre ela são apresentados alguns aspectos relevantes em relação ao trabalho proposto. Adiante, o foco é direcionado às embalagens de defensivos agrícolas, definindo os tipos de embalagens e especificando as diferenças entre elas. O processo de recolhimento e classificação no qual as embalagens de defensivos agrícolas são submetidas é descrito de forma detalhada na última seção deste capítulo.

## **2.1. LOGÍSTICA REVERSA**

A adoção de materiais que possam ser reciclados ou reutilizados, tal como plásticos, metais ou vidro é uma tendência crescente na indústria. Essa tendência cria um cenário onde existe a demanda de pesquisas no âmbito da logística do recolhimento e reaproveitamento dos produtos após o consumo. A logística reversa é um segmento da logística empresarial que planeja, opera e controla o fluxo e as informações logísticas correspondentes ao retorno dos bens de pós-venda e pós-consumo ao ciclo de negócios ou ao ciclo produtivo (LEITE, 2003).

Do ponto de vista econômico os processos de logística reversa têm trazido consideráveis retornos positivos à indústria em geral (MURARO *et al.*, 2006). Esses retornos impulsionam novas pesquisas para aprimorar os materiais, métodos, sistemas e ferramental propiciando soluções para os problemas existentes nos sistemas de reciclagem e reaproveitamento de produtos. O reaproveitamento dá-se através do retorno do bem pós-consumo ao processo produtivo ou pela obtenção de valores econômicos obtidos com sua venda. Além dos retornos econômicos também existem outras vantagens que advêm das pesquisas nessa área.

Um dos setores mais favorecidos é o setor ambiental. Quanto mais um produto é reutilizado ou reciclado, menos matéria-prima virgem será necessária para produzir um novo produto, diminuindo a exploração de recursos naturais renováveis ou não. Na questão cultural, contribui para o desenvolvimento sustentável criando uma consciência de responsabilidade individual pelo resíduo gerado. O valor agregado ao resíduo também proporciona um maior cuidado pelo usuário. Os processos de logística reversa contribuem para a aplicação da ação chamada 3Rs: Reduzir, Reutilizar e Reciclar. Em relação à questão social, a aplicação da logística reversa pode criar novos empregos na cadeia produtiva, uma vez que uma nova rota logística é criada. Além de todos esses setores ainda há o marketing que também recebe benefícios advindos da aplicação de métodos sustentáveis. A imagem da empresa é beneficiada nas campanhas comerciais, através dos selos e certificados tais como Carbono Neutro, Selo Verde, entre outros, creditados por entidades ligadas às questões ambientais ou empresas certificadoras (BSI BRASIL, 2013; MAX AMBIENTAL, 2013).

As embalagens de defensivos agrícolas são gerenciadas através de um sistema de logística reversa que realiza a recuperação de valores com base nas embalagens recolhidas, através de uma cadeia que envolve fabricantes, distribuidores, produtores rurais e poder público. Esse processo é abordado com mais detalhes nas próximas seções.

## 2.2. LEGISLAÇÃO

Apesar de ser uma tendência emergente, nem sempre a iniciativa de buscar um sistema sustentável como parte de seu sistema produtivo surge da vontade das próprias indústrias. Os processos sociais e ambientais sustentáveis são normalmente diferentes dos processos tradicionais, pois devem levar em consideração os custos ambientais no processo. Através da regulamentação os governos parametrizam os objetivos e impulsionam os setores industriais a desenvolverem tecnologias para adequar seus sistemas produtivos a uma consciência sustentável.

No Brasil, há poucos anos, houve a aprovação da Lei nº. 12.305/2010, que institui a Política Nacional de Resíduos Sólidos (PNRS) (BRASIL, 2010). Essa lei prevê a prevenção e a redução da geração de resíduos, através de principalmente acordos setoriais com a indústria fabricante, importadores, comerciantes ou distribuidores. Do outro lado entram os serviços públicos de limpeza, mecanismos de logística reversa e incentivo à atuação de associações ou cooperativas que realizem a separação, reutilização e reciclagem dos resíduos. Até 2014, as indústrias deverão estar adequadas a essa lei, e há uma expectativa de que a demanda por tecnologias que auxiliem os processos de logística reversa cresça.

No âmbito das embalagens de defensivos agrícolas, já existe desde o ano 2000 a regulamentação da comercialização desse produto. A Lei nº. 9.974/2000 regulamenta a gestão pós-consumo de embalagens vazias de defensivos agrícolas. Através desta lei, o Governo Federal definiu os parâmetros de venda, consumo e destinação final dos produtos.

Após a regulamentação surgiu uma demanda em pesquisas por tecnologias que criem instrumentos que auxiliem e aperfeiçoem o processo de reciclagem e reutilização. Essa demanda abriu campo para a atuação das diversas engenharias que, através do estudo em suas áreas de atuação, podem desenvolver e aplicar ferramentas de auxílio aos sistemas de reciclagem. Um exemplo desse desenvolvimento tecnológico é o Projeto Triturador (INPEV, 2013), onde foi desenvolvida uma máquina responsável por triturar as embalagens no intuito de reduzir o volume ocupado no seu armazenamento.

### **2.3. AUTOMATIZAÇÃO DA RECICLAGEM**

Sistemas automatizados para encher, rotular e lacrar embalagens são amplamente pesquisados em diversos setores industriais. A automatização é aplicada aos processos produtivos no intuito de maximizar a velocidade de produção e minimizar erros e custos. Existem diversas ferramentas e estudos de caso demonstrando a aplicabilidade desses processos na manufatura de produtos (RUDEK *et al.*, 2001). No entanto, na área de reciclagem, existem poucos trabalhos aplicados à classificação e separação de embalagens. Grande parte das embalagens retornáveis é recolhida e separada manualmente, através de cooperativas de coletores e empresas de reciclagem. Nesse trabalho realizado em grande parte manualmente, os trabalhadores entram em contato com diversos tipos de resíduos. No caso das embalagens de defensivos agrícolas, o resíduo é tóxico.

### **2.4. EMBALAGENS DE DEFENSIVOS AGRÍCOLAS**

A partir da regulamentação da distribuição e recolhimento das embalagens de defensivos agrícolas, as indústrias fabricantes reuniram-se e fundaram o Instituto Nacional de Processamento de Embalagens Vazias (INPEV). Essa entidade sem fins lucrativos foi criada com o objetivo de organizar e coordenar o recolhimento de embalagens vazias de defensivos agrícolas. As indústrias fabricantes, juntamente com os distribuidores, agricultores e poder público, realizam a tarefa de recolher as embalagens vazias e realizam a sua destinação final. Portanto, o sistema fica dividido em quatro elos. O primeiro elo é o produtor rural. Os agricultores têm o dever de realizar a lavagem da embalagem logo após a utilização. Para evitar o reaproveitamento de qualquer natureza a embalagem deve ser inutilizada através de um furo feito normalmente no fundo da embalagem. Após esse processo a embalagem pode ficar armazenada na propriedade e, em no máximo um ano após a compra, deve ser entregue em uma das centrais de recolhimento disponíveis. Nesse ato, o agricultor recebe um documento para comprovar a entrega. O segundo elo do sistema é o distribuidor. Sua responsabilidade é informar, no ato da venda, o local de devolução ao produtor

rural. Ele também é responsável por disponibilizar e gerenciar a central de recolhimento através de associações de distribuidores. Também deve emitir o comprovante de entrega das embalagens e orientar o produtor rural e a sociedade, conscientizando sobre a importância do sistema de recolhimento. As indústrias produtoras dos defensivos agrícolas são responsáveis por recolher as embalagens nas centrais de recolhimento, para que elas sejam enviadas ao processo correto de destinação final: reciclagem ou incineração. O poder público fiscaliza o processo em todos os seus elos, emite as licenças de funcionamento para cada central de recolhimento, de acordo com os órgãos competentes de cada estado, e apoia as iniciativas de orientação e educação da sociedade.

As embalagens de defensivos agrícolas recolhidas são reaproveitadas no processo produtivo ou incineradas. Quando lavadas e armazenadas corretamente logo após a utilização, elas podem ser recicladas para tornarem-se novas embalagens de defensivos agrícolas ou então utilizadas para criar novos produtos. Os produtos produzidos são: cruzeta de poste de transmissão de energia, caixa para massa de cimento, caixa de bateria automotiva, embalagens para óleo lubrificante, tubos para esgoto, caçamba e rodas plásticas para carrinhos de mão, conduítes corrugados, dutos corrugados, caixa para fiação elétrica, barricas plásticas e tampas para novas embalagens de defensivos agrícolas (Figura 1). Quando não podem ser reaproveitadas elas são encaminhadas para incineração.



Figura 1 – Alguns dos produtos produzidos à partir da reciclagem de embalagens. Fonte: INPEV (2013).

Existem embalagens de tamanhos, cores e tipos variados. As cores normalmente variam de acordo com o tipo de defensivo que estão contidos nas embalagens. Os principais materiais utilizados são respectivamente: plástico e metal.

Durante todo o ano de 2012, 37.379 toneladas de embalagens vazias foram recebidas nas centrais de recolhimento em todo o país (INPEV, 2013). Essas embalagens são entregues em centrais de recolhimento espalhadas por todo o país. As centrais de recolhimento são responsáveis por receber não somente a embalagem vazia, mas também as tampas e as caixas onde as embalagens são armazenadas. As centrais são de responsabilidade dos distribuidores de defensivos agrícolas. Em Guarapuava, no Paraná, a central da Associação de Distribuidores de Defensivos do Centro Sul (ADDCS) é responsável por receber as embalagens da região central do Estado do Paraná. Essa central recebeu 383,4 toneladas de embalagens vazias durante o ano de 2012. O percentual de cada tipo material recolhido pela ADDCS Guarapuava em 2012 é apresentado na Tabela I.

Tabela I - Percentual de tipo de material recolhido em 2012 na ADDCS em Guarapuava no Paraná.

Tipo de embalagem	Percentual
Poliétileno de Alta Densidade (PEAD)	49,70%
Coextrusado (COEX)	18,10%
Plástico misto	10,60%
Metal	2,20%
Alumínio	0,20%
Papelão	16,50%
Tampas limpas	2,70%

Fonte: ADDCS (2012)

Dentre todos os materiais recolhidos nas centrais, o sistema proposto neste trabalho realiza a classificação das embalagens plásticas do tipo Poliétileno de Alta Densidade (PEAD) e as do tipo Coextrusado (COEX). As diferenças entre esses dois tipos são detalhadas na próxima seção deste capítulo.

Normalmente as cooperativas de produtores rurais, ou o próprio produtor rural, realizam a devolução de embalagens de defensivos agrícolas num único

carregamento e todas misturadas. Assim, cabe ao técnico que as recebeu realizar a separação por cor e tipo de embalagem. Para que sejam enviadas ao processo de reciclagem pertinente, há a necessidade de separá-las de acordo com o seu tipo e cor. Quando as embalagens não são lavadas logo após a utilização, o defensivo contamina a embalagem, impossibilitando a sua utilização. Nesse caso a embalagem deve ser incinerada. Enquanto a embalagem não for destinada ao processo final continua atuando como agente contaminante. O defensivo que nela estava encerrado ainda permanece apresentando riscos, mesmo após o uso e a lavagem, e esse defensivo pode contaminar o meio ambiente. As embalagens ficam todas armazenadas em um galpão (Figura 2), aguardando classificação e encaminhamento à central de reciclagem.



Figura 2 - Embalagens já classificadas para encaminhamento à central de reciclagem. Fonte: ADDCS - depósito Guarapuava/PR.

No processo de reciclagem os funcionários que realizam a classificação utilizam todo o aparato de segurança, mas mesmo assim estão sujeitos às consequências do manuseio desses produtos (BIGATÃO, 2009).

### 2.4.1. TIPOS DE EMBALAGENS DE DEFENSIVOS

Dentre as embalagens plásticas de defensivos agrícolas, dois tipos serão estudados neste trabalho: Polietileno de Alta Densidade (PEAD) e o Coextrusado (COEX). Ambas as embalagens são fabricadas com o PEAD, que além de conter o produto, funciona como uma barreira, que dificulta a fuga de gases, vapores de água e orgânicos pelas paredes do recipiente (Figura 3).



Figura 3- Embalagens COEX (esquerda) e PEAD (direita). Fonte: o próprio autor.

A diferença entre o PEAD e o COEX é que este último possui um revestimento plástico interno que impede o contato do conteúdo com a embalagem. Essa película é transparente, porém perceptível através da visualização da porção interna do gargalo da embalagem, e reflete a luz. Ela possui características que impedem a permeabilidade, evitando a oxidação e oferecendo maior estabilidade e durabilidade do produto envasado.

Cada tipo de embalagem possui um método de reciclagem diferente. O revestimento interno da embalagem COEX precisa ser tratado antes que a porção PEAD da embalagem possa ser aproveitada. Quando uma embalagem COEX entra no sistema de reciclagem PEAD, pode ocasionar prejuízo ao processo e ao maquinário que realiza a reciclagem. Portanto, as embalagens devem ser corretamente separadas antes de serem enviadas ao destino final. Quando a carga é encaminhada à empresa de reciclagem, é realizada uma nova conferência do lote recebido. Nessa análise, técnicos treinados observam se as embalagens recebidas são realmente do tipo especificado no lote. Caso um limite máximo de

quilos por tonelada de embalagens entregues incorretamente seja ultrapassado, a empresa recicladora emite um Relatório de Não Conformidade (RNC), e cobra as despesas pela reclassificação desse lote. Isso representa uma despesa extra à central de recolhimento, tornando o custeio do sistema ainda mais caro.

#### 2.4.2. CORES DAS EMBALAGENS DE DEFENSIVOS

As embalagens de defensivos agrícolas são classificadas por tipo e cor, portanto a cor é uma das características relevantes no momento da separação.

As cores das embalagens de defensivos agrícolas que serão classificadas pelo sistema proposto neste trabalho são sete: Amarelo, Azul, Verde, Verde Escuro, Branco Leitoso, Branco Natural e Cinza (Figura 4).



Figura 4 - Cores das embalagens de defensivos agrícolas. Fonte: o próprio autor.

As embalagens das classes: Amarelo, Azul, Verde, Verde Escuro, Branco Leitoso e Cinza são opacas. Já a embalagem da classe Branco Natural é translúcida.

As embalagens normalmente possuem rótulo e tampa. A tampa é destinada a um processo de reciclagem diferente da embalagem, portanto é removida no início da etapa de classificação e armazenada em um container próprio. O rótulo da embalagem pode permanecer colado nela durante o processo (Figura 5 (b)), e em algumas embalagens, as informações são impressas na própria embalagem.



Figura 5 – (a) Detalhe do gargalo, (b) detalhe do rótulo das embalagens de defensivos agrícolas. Fonte: o próprio autor.

Normalmente os rótulos, bulas e lacres colados ou impressos na embalagem são removidos antes do processo de separação. No entanto, para evitar que esse tipo de informação atrapalhasse o processo de classificação, optou-se, neste trabalho, por utilizar imagens do gargalo da embalagem. Em algumas embalagens, também há um lacre protetor que, em alguns casos, pode permanecer grudado no gargalo da embalagem (Figura 5 (a)).

#### **2.4.3. SISTEMA DE CLASSIFICAÇÃO**

O sistema de classificação atual é realizado de forma totalmente manual. Através da análise visual da embalagem de defensivo agrícola um técnico realiza a separação em cestos. Posteriormente, o conteúdo dos cestos é prensado e encaminhado para a empresa de reciclagem em grandes sacolas chamadas *bigbags*. À primeira vista, esse procedimento parece uma tarefa relativamente simples, pois o técnico já conhece as cores e possui as faculdades, físicas e cognitivas, necessárias para classificá-la. No entanto, devido ao grande volume classificado esse processo transforma-se num trabalho exaustivo e repetitivo, o que o torna suscetível a falhas, além de ser insalubre.

A capacidade visual humana vem sendo estudada há vários anos. Ela é alvo de pesquisas que tentam incorporá-la em sistemas computacionais, e a utilização desse tipo de sistema vem tornando-se uma tendência em diversos setores industriais (RUDEK *et al.*, 2001).

### 3. VISÃO COMPUTACIONAL

O olho humano é um complexo órgão responsável por capturar e focalizar a luz, transformando-a em sinais elétricos que são transmitidos ao cérebro e finalmente traduzidos em imagens (LAMB, 2011). A capacidade visual humana é uma importante faculdade sensorial que fornece respostas rápidas e detalhadas sobre o ambiente, propiciando subsídios para a tomada de decisão em um prazo muito curto de tempo.

Visão computacional é a ciência que busca reproduzir essa capacidade visual humana na máquina, através de técnicas de processamento de dados e ferramentas computacionais. O campo de atuação dessa ciência é bastante vasto, e têm trazido grandes contribuições nas áreas onde é aplicada. Dentre as áreas que receberam contribuições das pesquisas em sistemas de visão destacam-se a medicina, sistemas de produção, manufatura, astronomia, robótica, segurança, multimídia e entretenimento, entre outras (RUDEK *et al.*, 2001).

A principal informação utilizada por sistemas de visão computacional é a imagem digital. A maneira como essa imagem é adquirida e processada depende principalmente do objetivo do projeto e o conhecimento de um especialista é normalmente considerado durante a construção de um sistema desse gênero. Apesar das ferramentas computacionais existentes terem evoluído significativamente no campo tecnológico, ainda existem problemas que um sistema de visão deve tratar. Esses problemas estão normalmente relacionados com dificuldades com controle da luminosidade do ambiente, contraste, posicionamento e ângulo de obtenção da imagem (RUDEK *et al.*, 2001).

Neste capítulo será apresentada a definição de imagem digital, o procedimento de aquisição, e como ela pode ser utilizada num sistema computacional. Também serão abordados os sensores de imagens digitais mais difundidos na atualidade e como eles transformam a luz, um sinal analógico, em um sinal digital. Adiante são abordadas técnicas de representação da imagem em um meio computacional e métodos de processamento dos dados armazenados na imagem. Finalmente, ao final deste capítulo, são abordadas as técnicas de processamento de imagens utilizadas por este trabalho.

### 3.1. IMAGEM DIGITAL

No meio computacional, uma imagem digital pode ser descrita pela função  $im(x,y)$ , onde  $x$  e  $y$  são as coordenadas. Em cada posição de  $im$ , determinadas por  $x$  e  $y$ , está representada a intensidade luminosa capturada naquele ponto. Os valores de  $x$ ,  $y$  e  $im$ , são discretos e finitos (FARIA, 2010). Cada elemento contido é chamado pixel (*picture element*) (UMBAUGH, 2010). Para simplificar o processamento no meio computacional a imagem digital é normalmente definida como uma matriz.

De forma sucinta, pode-se entender que uma imagem digital é um determinado número de amostras de sinal capturado (luz), organizadas em uma matriz que possui um tamanho definido. Em cada posição dessa matriz está um pixel e, neste pixel, está armazenada a informação da intensidade luminosa medida naquele ponto.

Em uma imagem tons de cinza são armazenados apenas os valores relacionados com a intensidade luminosa. Esse valor varia entre 0 e 255, portanto podem ser representados 256 tons de cinza possíveis (Figura 6).

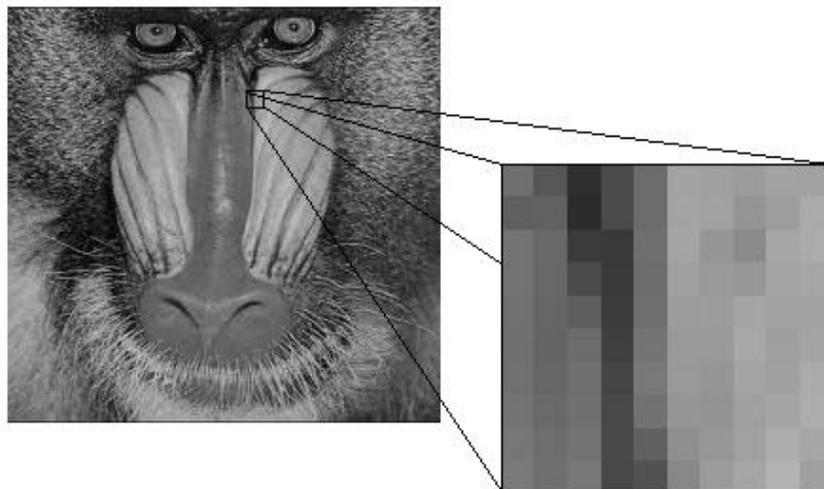


Figura 6 – Pixels em uma imagem tons de cinza.

Já em imagens coloridas, existem normalmente três canais de cor (Vermelho (R), Verde (G) e Azul (B)). Os valores de cada um desses canais variam entre 0 e 255. Portanto o número de cores possíveis salta para 16.581.375

(255 (R) x 255 (G) x 255 (B)) (Figura 7) (UMBAUGH, 2010). Dessa forma são necessárias três matrizes para armazenar a intensidade de cada um dos canais de cor.

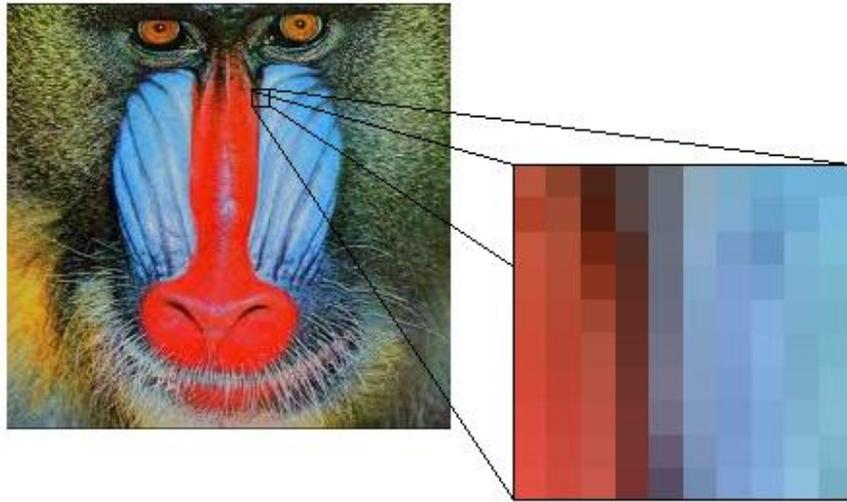


Figura 7 – Pixels em uma imagem colorida.

### 3.2. AQUISIÇÃO DE IMAGEM DIGITAL

A luz é uma radiação eletromagnética que está compreendida em determinada faixa de frequência que é chamada de espectro visível. Essa faixa de frequência do espectro visível é composta por fótons capazes de sensibilizar um olho humano normal. Os comprimentos de onda associados ao espectro visível estão compreendidos entre 400 nm e 700 nm (Figura 8). O espectro pode ainda ser dividido em subfaixas, as quais representam as cores, que vão do vermelho ao violeta, passando pelo laranja, amarelo, verde e azul (UMBAUGH, 2010). Conhecendo o comprimento da onda e a velocidade da luz, é possível encontrar a frequência de cada subfaixa. Em termos de frequência os valores do espectro visível estão compreendidos entre aproximadamente 400 THz e 750THz.

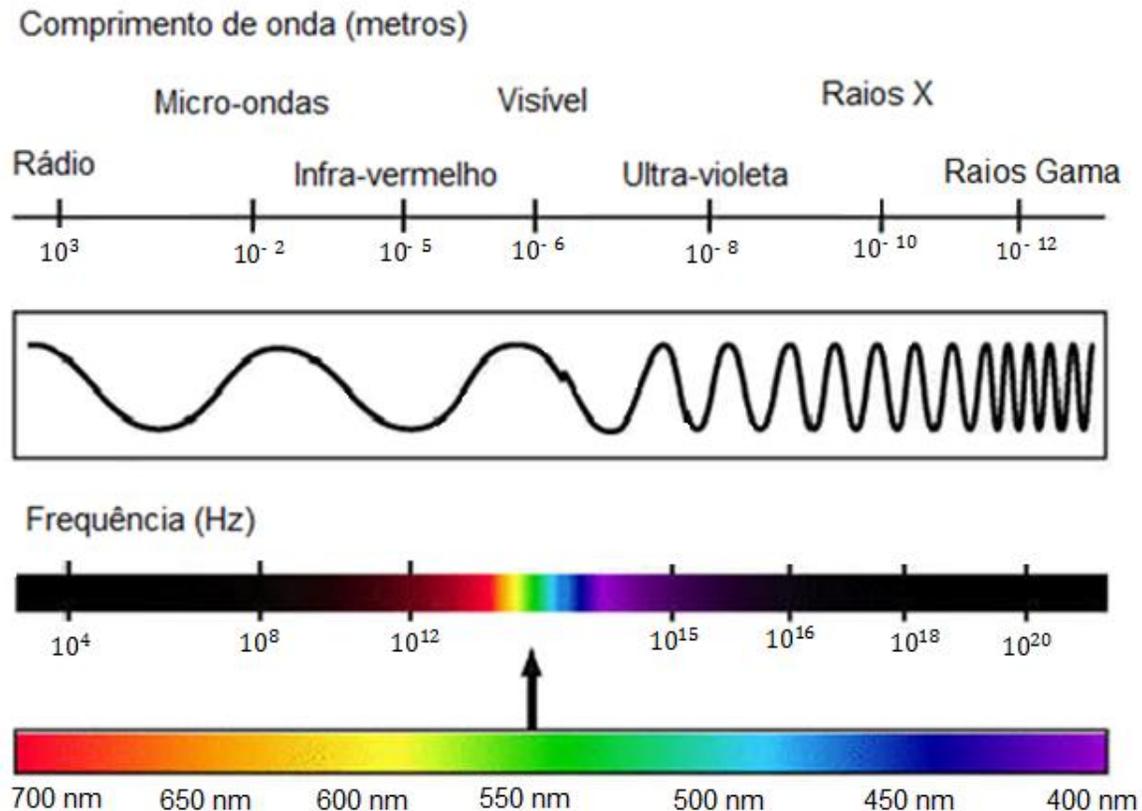


Figura 8 - Faixa espectral visível. Adaptado de Umbaugh (2010).

O processo pelo qual os seres humanos enxergam ocorre através da percepção da luz refletida ou emitida por um corpo. Essa luz é captada pelos receptores existentes nos olhos, que são os cones e os bastonetes. Mas não apenas eles são os responsáveis por proporcionar a sensação da visão. O sistema visual humano é composto também por um complexo sistema de transmissores e processadores de informações. A luz é captada em receptores que produzem estímulos nervosos que são transmitidos ao cérebro, onde são processados e causam a sensação de visão (SIMÕES, 2001).

A mesma imagem observada por um olho humano também pode ser capturada por um sistema eletrônico e representada num ambiente computacional. Isso é possível através de um processo de captura de dados com sensores analógicos que recebem as informações (luz) e através de um circuito eletrônico convertem os sinais analógicos capturados em sinais digitais para que estes sejam tratados em um ambiente computacional.

Os sensores digitais de imagem mais difundidos comercialmente capturam a luz em um tipo especial de semicondutor feito de silício. O sensor é composto por uma matriz de fotodiodos estrategicamente posicionados e que recebem uma onda de frequência visível. Nesse processo eles são estimulados a converter os fótons em elétrons, transformando a luz em energia, num processo similar ao dos painéis solares. Esses elétrons são coletados num barramento de potencial até que o período de captura esteja finalizado, e após esse período eles são transferidos a um registrador do tipo *serial shift register* e finalmente convertidos em tensão (BAKSHI, 2008).

O fotodiodo é geralmente referenciado como um pixel no sensor. Ele é o principal elemento de um sensor digital de imagem. Sua sensibilidade é relacionada com a carga máxima que pode ser acumulada por ele, junto com a eficiência de conversão dos fótons em elétrons e a habilidade do dispositivo em armazenar esses elétrons sem perda. A recepção conforme mostrado na Figura 9 irá fornecer uma imagem em escala de cinza, uma vez que cada fotodiodo armazena elétrons gerados por fótons de várias faixas de frequência, não permitindo saber qual a faixa de frequência gerou aqueles elétrons.

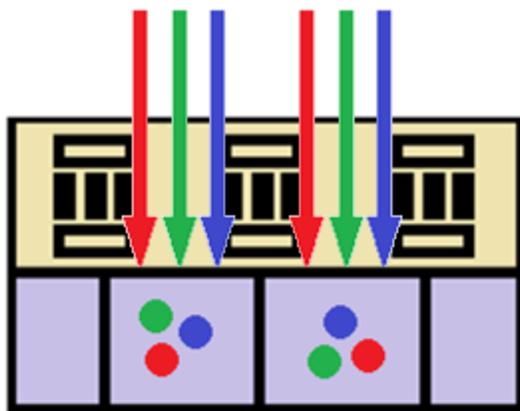


Figura 9 - Captura dos fótons através do fotodiodo. Adaptado de BENGTTSSON (2008).

Para capturar imagens coloridas cada fotodiodo deve capturar apenas uma determinada faixa de frequência. Frequência esta que deve estar relacionada com uma cor conhecida. Para realizar esse processo de captura da frequência

desejada foi desenvolvido um sistema de filtro de frequência que é posicionado logo acima do fotodiodo, de forma que somente a cor desejada seja capturada.

O filtro de cores mais conhecido é o filtro Bayer (Figura 10). Esse filtro é organizado em uma matriz que permite a passagem da luz de determinada faixa de frequência, associada às cores verde, vermelho e azul (50% verde, 25% vermelho e 25% azul). O sistema utiliza o dobro de filtros verdes devido à percepção visual humana, que é mais sensível às mudanças nos tons de verde do que às outras cores (SCHUBERT, 2006). A opção por essas cores deve-se ao fato delas serem as três cores primárias aditivas. Através da combinação entre elas é possível representar todas as outras cores.

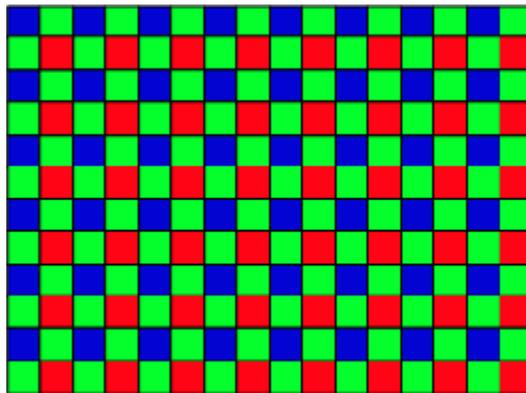


Figura 10 - Filtro Bayer (BAYER, 1976).

O filtro Bayer (BAYER, 1976) fica posicionado logo acima da placa que contém os fotodiodos, permitindo que dessa forma apenas a onda relacionada com a cor do filtro passe por ele (Figura 11).

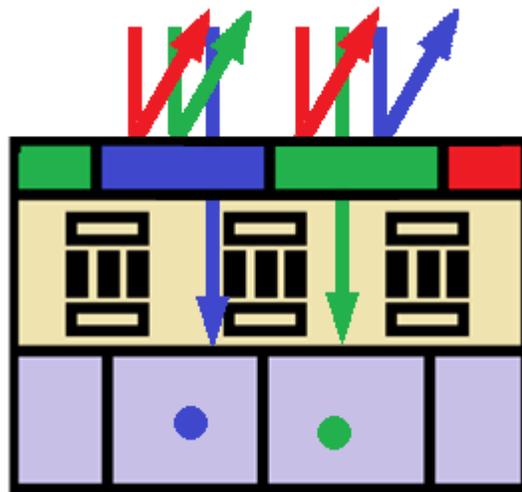


Figura 11 - Filtro Bayer atuando para permitir a captura da faixa de frequência de onda desejada. Adaptado de BENGTSOON (2008).

Nos sensores também existem componentes responsáveis por gerenciar o transporte dos elétrons capturados. Esse componente de transporte é constituído por trilhas metálicas chamadas *metal wiring*, e que ficam normalmente sobre os fotodiodos. Nos sensores *Charged Coupling Device* (CCD), essas trilhas funcionam com fases de tensão que são alternadas de acordo com a necessidade de deslocamento dos elétrons no sistema (BAKSHI, 2008). Os elétrons capturados por cada fotodiodo ficam armazenados logo abaixo de cada um dos barramentos. Através da troca da fase de cada barramento, o elétron é direcionado para um *serial shift register*, de onde posteriormente é retirado e convertido em sinal de tensão, que é recebido por um conversor Analógico Digital (AD) e que o transforma em um sinal digital que pode ser interpretado em um ambiente computacional (Figura 12). Em sensores do tipo *Complementary Metal-Oxide-Semiconductor* (CMOS), o acesso aos dados armazenados no fotodiodo é realizado diretamente, sem a necessidade de transportá-los (HOLST & LOMHEIM, 2011).

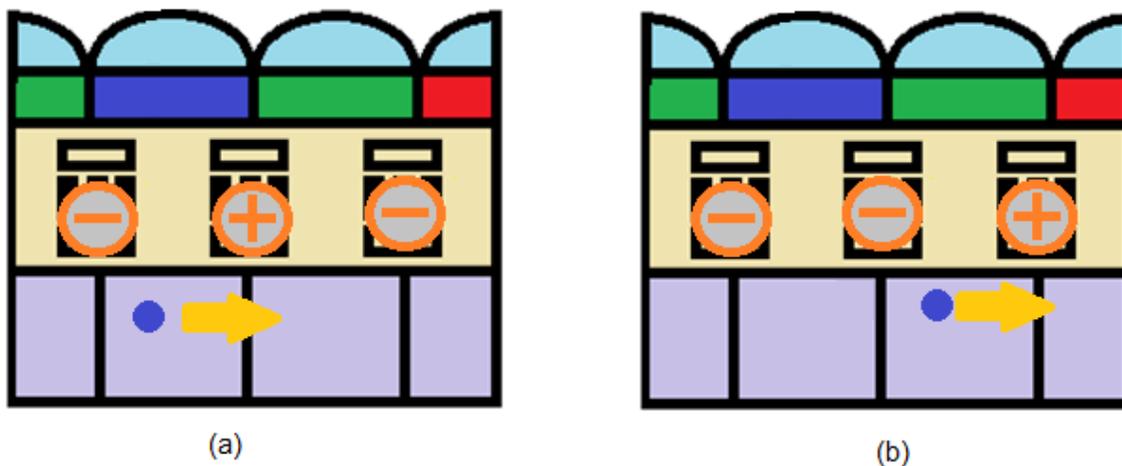


Figura 12 - Deslocamento dos elétrons através das fases do barramento metálico. Adaptado de BENGTTSSON (2008).

Nos sensores de imagens digitais nem toda a área física disponível pode capturar os fótons. Isso ocorre por conta da sua estrutura física, que é constituída por malhas metálicas e demais componentes necessários ao seu funcionamento. Para atenuar esse problema, alguns sensores possuem um sistema de microlentes que atuam no desvio da direção da luz, maximizando a quantidade de fótons que entram em contato com o fotodiodo (HOLST & LOMHEIM, 2011). Essas microlentes são chamadas “*on chip lens*” (Figura 13).

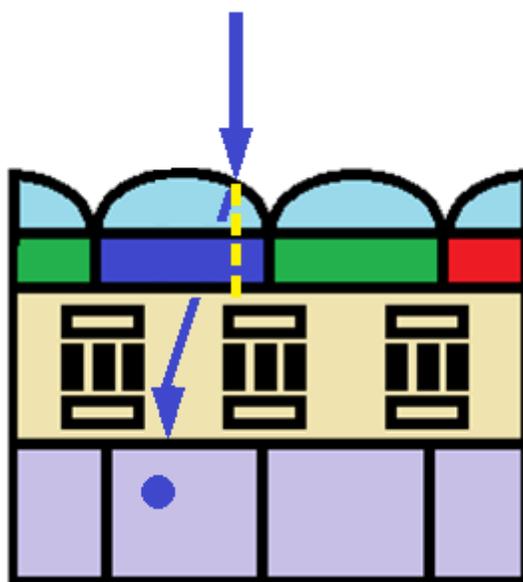


Figura 13 - *On chip lens*: lentes que auxiliam no direcionamento da luz. Adaptado de BENGTTSSON (2008).

Os sensores mais amplamente divulgados atualmente são o sensor *Charged Coupling Device* (CCD) e o *Complementary Metal-Oxide-Semiconductor* (CMOS).

### **3.2.1. SENSOR CCD**

Os sensores CCD tem seu nome derivado da forma como a carga é lida depois de realizada a captura da imagem. Devido ao modo de produção deste sensor, ele é capaz de transportar a carga através de si mesmo sem comprometer a qualidade da imagem. A primeira linha do sensor é transportada para um registrador do tipo *Serial Shift Register* (SSR), e em seguida a informação é enviada a um conversor Analógico Digital (AD) para que a informação analógica seja transformada em informação digital para ser tratada pelo computador (BENGTSSON, 2008).

As vantagens desse sensor são: pouco ruído na imagem, grande qualidade de imagens. As desvantagens são: custo de produção e alto consumo energético comparado ao sensor CMOS.

### **3.2.2. SENSOR CMOS**

O sensor CMOS tem o nome derivado por seu modo de produção, sendo produzido em placas de silício. Cada pixel possui um ou mais transistores. O sistema de leitura do sensor CMOS é mais rápido do que o CCD, e permite a leitura de cada pixel individualmente devido ao formato de sua construção. Esse sensor apresenta como vantagens o baixo consumo energético, custo de produção baixo e processamento rápido das informações. Os pixels podem ser acessados individualmente. A desvantagem desse sensor é a alta quantidade de ruído, pois os transistores ocupam área física sobre o sensor, diminuindo a capacidade de captura (BENGTSSON, 2008).

## **3.3. PROCESSAMENTO DE IMAGENS DIGITAIS**

Uma imagem digital fornece diversas informações sobre o objeto ou ambiente analisado. No entanto, dependendo do problema abordado, nem todas

as informações são relevantes, ou apresentam-se no formato ou com as condições de obtenção desejadas. Portanto, a dificuldade torna-se o processamento e extração das informações relevantes. Segundo Gonzalez & Woods (1998), existem algumas etapas fundamentais no processamento digital de imagens, que podem ser visualizadas na Figura 14.

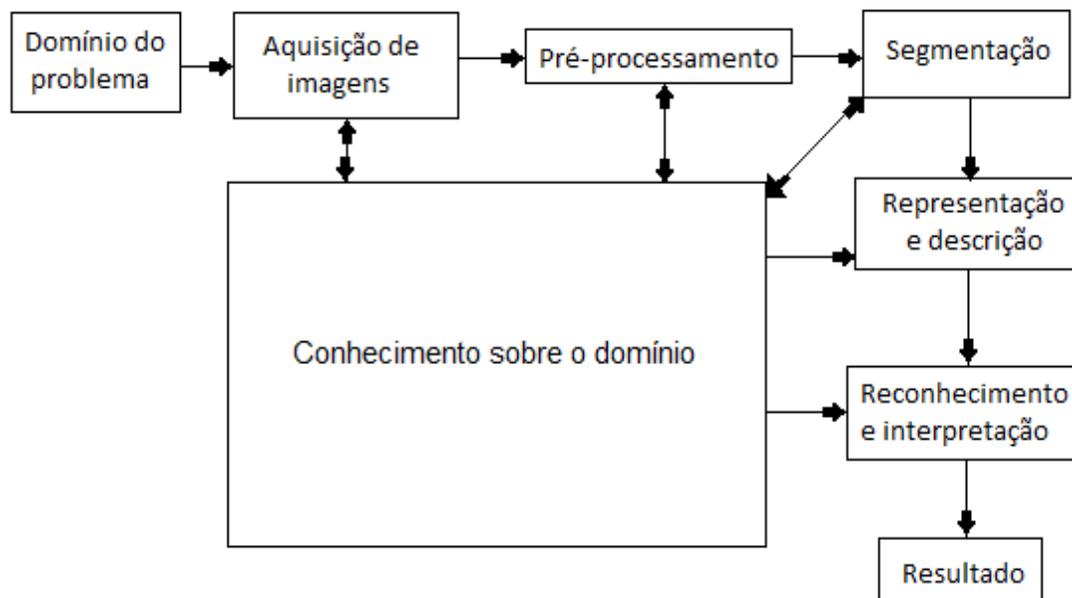


Figura 14 - Etapas do processamento digital de imagens. Adaptado de Gonzalez & Woods (1998).

Essa representação genérica é apresentada de maneira similar por outros autores (WEEKS, 1996; UMBAUGH, 2010). Os processos executados em cada uma dessas etapas diferem de acordo com o problema abordado. No entanto, é comum que esses processos computacionais realizem tarefas que facilitem a extração das características relevantes da imagem.

A **aquisição de imagens** representa a etapa de obtenção da imagem digital através de alguma fonte. Essa fonte pode ser definida como os equipamentos de *hardware* que são utilizados para a captura da imagem, tal como câmeras, computadores e sistema de iluminação (RUDEK *et al.*, 2001). A câmera é responsável pela coleta da imagem do ambiente. Normalmente nela já existe uma placa digitalizadora com um *software* específico que captura e armazena as informações relevantes. Posteriormente essas informações são enviadas ao computador, através de um barramento de comunicação que pode ser, por

exemplo, uma placa de vídeo ou um barramento USB. Neste trabalho a opção foi utilizar uma câmera *webcam* que é conectada ao computador através de um barramento USB.

Na etapa de **pré-processamento** são aplicados os filtros desejados no intuito de aumentar a eficiência do processamento que será realizado posteriormente. Nesta etapa são executados, dependendo do problema abordado, procedimentos de realce de cores e bordas, redução de ruídos, correção de luminosidade, contraste e demais operações que possam auxiliar os processos seguintes. Para executar esse pré-processamento existem diversas ferramentas como, por exemplo, operações de matemática morfológica, filtros gaussiano, de detecção de borda, entre outros (MARQUES FILHO & VIEIRA NETO, 1999). A aplicação de um algoritmo que utiliza operador morfológico neste trabalho tem o objetivo de reduzir ruídos que podem interferir na extração do fundo, no processo de segmentação de imagem. O operador escolhido foi o de erosão.

Na etapa de **segmentação** a imagem digital é dividida em partes ou objetos de acordo com características normalmente pré-determinadas. Esse processo é realizado com o intuito de diminuir o custo computacional durante o processamento. Exemplos de redução de quantidade de informações irrelevantes à solução do problema são: segmentação do objeto (*foreground*) e do fundo (*background*), redução da gama de cores em uma imagem, segmentação por regiões, entre outras. Neste trabalho é utilizado um algoritmo de extração de fundo, que será apresentado com mais detalhes mais adiante neste capítulo.

A etapa de **representação e descrição** irá processar os objetos segmentados, obtendo deles as características que serão relevantes para a próxima etapa de processamento, como por exemplo, formato, tamanho, cor, posição na imagem entre outras. As informações subjetivas são transformadas em critérios objetivos e mensuráveis que podem ser analisados, comparados e etc.. Essa etapa é extremamente dependente das anteriores, pois as características observadas no objeto são extraídas da imagem segmentada, que para seu ótimo desempenho depende também da forma e das condições de iluminação onde a imagem foi capturada. Eventualmente, para ganhar velocidade de processamento, nem todas as características ou todos os pixels disponíveis precisam ser

avaliados. Neste trabalho foi desenvolvido um método de amostragem para adquirir as informações de cor da embalagem de defensivo.

Por fim na etapa de **reconhecimento e interpretação**, o sistema atribui ao objeto um significado. Essa ação é realizada com base nas informações recebidas da etapa anterior, nos dados da base de conhecimento e no raciocínio executado pela ferramenta de interpretação. A ferramenta de inferência utilizada neste trabalho é o raciocínio probabilístico, e o conhecimento fica armazenado na Rede Bayesiana, na forma de tabelas de probabilidade condicional (TPC).

### 3.4. FORMATOS DE REPRESENTAÇÃO DE COR

Em imagens de tons de cinza, a informação armazenada nos pixels é relacionada apenas com a intensidade luminosa obtida naquele ponto. Dependendo da aplicação, esta informação já é suficiente, como por exemplo, para reconhecimento de caracteres e leitura de códigos de barras. Em imagens coloridas, o pixel armazena a informação sobre a cor representada, e essa é a principal informação utilizada neste trabalho. Existem diversos modelos de representação de cores no meio computacional. Neste trabalho foram estudados o modelo RGB e o modelo HSL. O modelo HSL é uma conversão direta do modelo RGB. Ambos os modelos serão detalhados a seguir.

#### 3.4.1. MODELO RGB

O nome RGB é proveniente da concatenação das primeiras letras de cada uma das cores que compõe o modelo: *Red*, *Green* e *Blue*. Essa representação é muito difundida no meio computacional, e nela cada pixel da imagem é representado por três bytes com valores variando entre 0 e 255. Os três bytes representam as coordenadas de um ponto num plano tridimensional e esse ponto representa a cor (Figura 15). Esses valores representam o brilho para cada canal de cor (UMBAUGH, 2010). O valor **R** armazena o brilho para a cor vermelha, **G** é responsável por armazenar o valor de brilho de verde e **B** armazena o valor de brilho da cor azul. As três cores desse modelo são cores primárias aditivas, e

através da combinação de seus valores é possível representar 16.581.375 (255 x 255 x 255).

Nessa representação as três componentes são fortemente correlacionadas, sendo que qualquer modificação de cor implica normalmente na alteração das três componentes (GONZALES & WOODS, 1992).

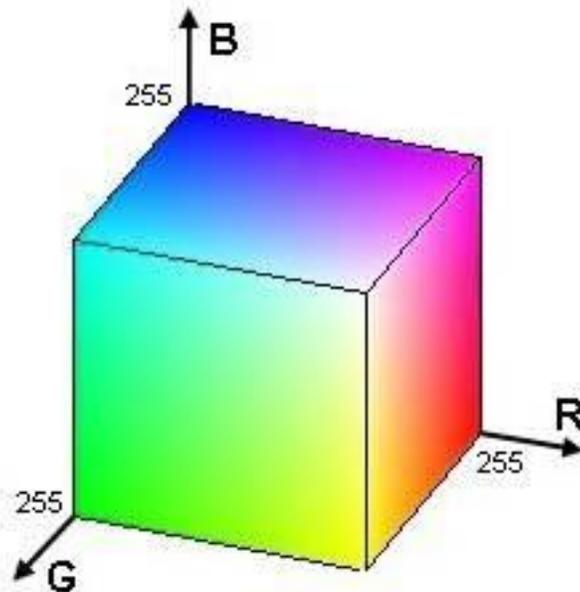


Figura 15 - Modelo RGB. Adaptado de Umbaugh (2010).

Devido ao fato da cor ser formada por três componentes dependentes, essa representação não é tão intuitiva, pois para formar cores mais claras ou mais escuras faz-se necessário alterar uma ou mais componentes simultaneamente.

O classificador escolhido para o trabalho de reconhecimento de cor necessita que as variáveis sejam independentes entre si. Dessa forma buscou-se um modelo de representação de cores que possuísse essa característica.

### 3.4.2. MODELO HSL

Outro modelo de representação de cor é o modelo HSL (*hue*, *saturation*, *luminosity*, ou tonalidade, saturação, luminosidade). É uma representação onde o valor de luminosidade não é relacionado com a informação de cor, e os valores de

saturação e tonalidade são relacionados com o processo pelo qual os seres humanos percebem as cores (LIMA *et al.*, 2005).

Na representação HSL, a componente tonalidade (*hue*) refere-se ao comprimento de onda mais próximo do observado em relação à faixa espectral visível pelos humanos. O valor da tonalidade varia de 0° a 360°, representando um círculo de cores, onde a cada 120° encontra-se uma cor primária. Em 0° tem-se a cor vermelha, em 120° encontra-se a cor verde e aos 240° a cor azul. Em alguns sistemas esse valor pode estar normalizado entre 0 e 1. Apenas a componente tonalidade já é suficiente para definir uma cor, com exceção do branco, preto, e as variações entre os dois, que são o cinza-claro, cinza e o cinza-escuro. A saturação refere-se à pureza da cor, ou a quantidade de luz branca que está misturada à cor dominante. Quanto mais saturada for uma cor, mais pura ela será. Juntamente com a componente tonalidade, representa a característica cromática da cor. A componente luminosidade indica o grau de brilho do pixel, sem definir a sua cor. Ela representa a quantidade de luz que é refletida ou emitida pelo objeto. Essa componente define a característica acromática da cor. Juntando as características cromáticas (tonalidade e saturação) com as acromáticas (luminosidade) tem-se a descrição completa de uma cor (UMBAUGH, 2010).

A Figura 16 mostra a representação do modelo HSL num plano tridimensional.

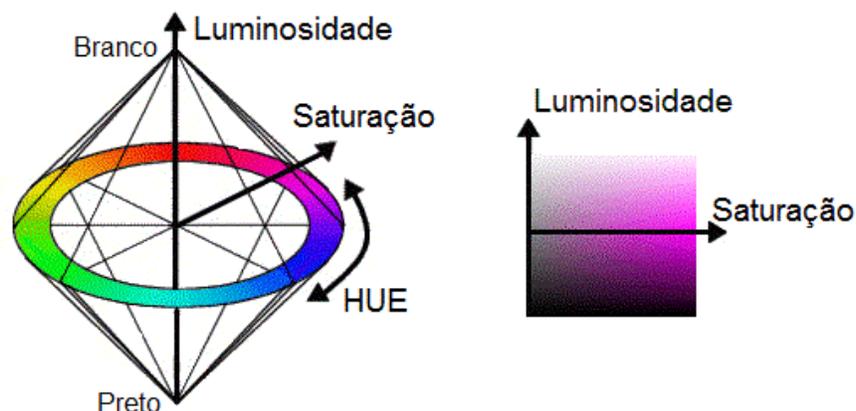


Figura 16 - Modelo HSL. Adaptado de Umbaugh (2010).

A opção pela escolha do modelo HSL neste trabalho baseia-se no fato da representação HSL ser próxima à percepção humana das cores, facilitando a

interpretação dos valores e pelo fato das variáveis serem condicionalmente independentes.

Assim, neste trabalho, a cor será descrita com base nas três variáveis obtidas pelo método HSL, tonalidade (*hue*), saturação (S), e luminosidade (L).

O modelo HSL é uma conversão do modelo RGB, realizado através de cálculos matemáticos. Os cálculos matemáticos utilizados neste trabalho são apresentados a seguir:

Sendo  $IM$ , uma imagem de  $x$  por  $y$  pixels. O pixel contido em  $IM(x,y)$  possui as componentes no formato RGB, portanto ele contém três valores: R, G e B. Inicialmente os valores de R, G e B são normalizados entre 0 e 1, e armazenados em  $R'$ ,  $G'$  e  $B'$ , respectivamente, conforme equações (3.1), (3.2) e (3.3).

$$R' = R/255 \quad (3.1)$$

$$G' = G/255 \quad (3.2)$$

$$B' = B/255 \quad (3.3)$$

Na sequência, o maior valor, o menor valor e a diferença entre os dois são obtidos conforme equações (3.4), (3.5) e (3.6). Esses valores são utilizados para realizar os cálculos de cada componente da representação HSL.

$$C_{max} = \max(R', G', B') \quad (3.4)$$

$$C_{min} = \min(R', G', B') \quad (3.5)$$

$$\Delta = C_{max} - C_{min} \quad (3.6)$$

Com base nos valores obtidos anteriormente, as componentes H, S e L são calculadas conforme equações (3.7), (3.8) e (3.9):

$$H = \begin{cases} 60^\circ \times \left( \frac{G' - B'}{\Delta} \bmod 6 \right), & \text{se } C_{max} = R' \\ 60^\circ \times \left( \frac{B' - R'}{\Delta} + 2 \right), & \text{se } C_{max} = G' \\ 60^\circ \times \left( \frac{R' - G'}{\Delta} + 4 \right), & \text{se } C_{max} = B' \end{cases} \quad (3.7)$$

$$S = \begin{cases} 0, & \text{se } \Delta = 0 \\ \frac{\Delta}{1 - |2L-1|}, & \text{se } \Delta \neq 0 \end{cases} \quad (3.8)$$

$$L = \frac{(C_{max} - C_{min})}{2} \quad (3.9)$$

### 3.5. PRÉ-PROCESSAMENTO

Dentre as diversas técnicas de pré-processamento existentes este trabalho utiliza a morfologia matemática. A morfologia matemática refere-se ao estudo da estrutura matemática dos objetos presentes em uma imagem digital. Ela pode ser aplicada na resolução de diversos problemas de processamento de imagem, dentre eles: realce, filtragem, segmentação, detecção de bordas, esqueletização e afinamento (MARQUES FILHO & VIEIRA NETO, 1999). As operações da matemática morfológica são normalmente aplicados em imagens binárias.

Segundo MARQUES FILHO & VIEIRA NETO (1999), o princípio básico da morfologia matemática está na extração das informações relativas à geometria e à topologia de uma imagem, pela transformação através de outro conjunto completamente definido, chamado de elemento estruturante.

Existem diversas operações de matemática morfológica, porém este trabalho irá utilizar apenas a operação de erosão. Esta operação apaga pixels da imagem que não estão dentro de um padrão determinado pelo elemento estruturante. O objetivo do uso desta operação é remover ruídos que podem ser erroneamente detectados como *foreground* no processo de segmentação da imagem, descrito na próxima seção.

Sendo  $A$  uma imagem e  $B$  o elemento estruturante, a erosão de  $A$  por  $B$  é expressa pela interseção de  $A$  e  $B$ . Ela é denotada por  $A \ominus B$  ou  $A \cap B$ , e definida como:

$$A \ominus B = \{x | (B)_x \subseteq A\} \quad (3.10)$$

o que indica que a erosão de  $A$  por  $B$  resulta no conjunto de pontos  $x$  tais que  $B$ , transladado de  $x$ , está contido em  $A$  (Figura 17).

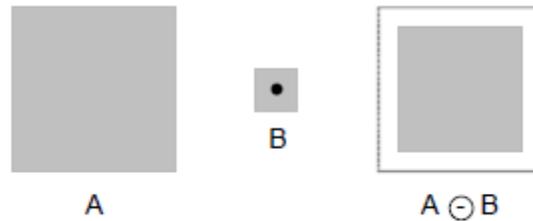


Figura 17 - Exemplo de erosão de A por B. Adaptado de MARQUES FILHO & VIEIRA NETO (1999).

### 3.6. SEGMENTAÇÃO DE IMAGENS

Uma imagem digital é normalmente composta por milhares de pixels. Muitos deles contêm informações irrelevantes ao processo ao qual a imagem será submetida. Uma técnica para remoção de informações irrelevantes é a segmentação por subtração do fundo. Essa segmentação é realizada com o intuito de discriminar o objeto alvo da análise na imagem digital (*foreground*), do fundo da imagem (*background*).

A segmentação para subtração de fundo utilizada neste trabalho é definida por:

$$Im = ImFundo - ImEmbalagem \quad (3.11)$$

onde:  $ImEmbalagem$  = imagem adquirida da câmera;  $ImFundo$  = imagem referente ao fundo; e  $Im$  = diferença entre as imagens.

A imagem  $Im$  obtida passa por um processo de binarização, onde os pixels com valor de intensidade inferior a determinado limiar são convertidos para 0 e os com valor superior são convertidos para 1. Dessa forma obtém-se uma máscara que é submetida à operação de erosão para remoção de ruídos. Posteriormente ela é aplicada sobre a imagem original ( $ImEmbalagem$ ), resultando na imagem segmentada, que agora contém apenas informações sobre o objeto desejado.

Esta técnica é rápida e de simples implementação. Porém, uma desvantagem deste método de segmentação é que a cor do fundo deve ser significativamente diferente da cor do objeto avaliado para que um resultado aceitável seja obtido. No entanto, em ambientes controlados isso é factível.

### **3.7. EXTRAÇÃO DE CARACTERÍSTICAS**

Após realizar a segmentação da imagem, diversas informações podem ser extraídas da imagem. Com os objetos discriminados na imagem é possível realizar a classificação de cor, forma, textura e em alguns casos até mesmo tomar a medida real do objeto analisado. As características que devem ser extraídas variam de acordo com o problema abordado e da ferramenta computacional que será utilizada para realizar a avaliação. Neste trabalho, as informações extraídas são relacionadas com a cor do pixel do objeto entendido e segmentado como embalagem na imagem digital.

Dentre as diversas técnicas de reconhecimento de padrões disponíveis, neste trabalho, foi escolhida a abordagem através da Inteligência Artificial (IA) na avaliação das características.

## **4. INTELIGÊNCIA COMPUTACIONAL**

A Inteligência Artificial (IA) têm por objetivo reproduzir em uma máquina a capacidade humana de raciocinar sobre um problema que exigiria do ser humano alguma perícia sobre o domínio (NASCIMENTO JR. & YONEYAMA, 2004). A ideia da construção de máquinas inteligentes acompanha o ser humano há diversos anos, e com o advento do computador, na década de 40, surgiram os meios necessários para atingir esse objetivo de maneira consistente.

A definição de IA é bastante ampla e permite diversas interpretações, que em alguns casos são conflitantes ou circulares (NAVEGA, 2001). Dentre as definições propostas na literatura especializada, optou-se por destacar algumas que apresentam uma relação mais próxima com o trabalho proposto:

- IA é o estudo de como fazer os computadores realizarem tarefas que são atualmente desempenhadas melhor por pessoas (RICH, 1983);
- IA é a área dedicada ao estudo de sistemas computacionais que sejam capazes de reproduzir algumas das capacidades mentais humanas (NILSSON, 1996);
- IA é o ramo da engenharia cujo objetivo é desenvolver sistemas computacionais que resolvem um problema de maneira parecida com o especialista humano (RABUSKE, 1995).

Inicialmente, neste capítulo, será apresentada uma breve revisão sobre a história da IA. Em seguida são apresentados os conceitos sobre sistemas inteligentes e sistemas especialistas que se relacionam com o presente trabalho. Posteriormente são abordados os fundamentos básicos das Redes Bayesianas, sua estruturação e a utilização das redes como um sistema especialista utilizado como classificador.

### **4.1. UM BREVE HISTÓRICO SOBRE IA**

Ao longo do seu desenvolvimento as pesquisas em IA trouxeram inúmeras contribuições à sociedade. Atualmente os sistemas inteligentes estão cada vez mais presentes no cotidiano, instaladas em ferramentas complexas, como por

exemplo, sistemas de apoio à decisão na área médica (SIMÕES, 2001; SANTANA, 2005), e até mesmo em modernos telefones celulares (APPLE INC., 2013). Isso se deve ao fato de muitos pesquisadores terem contribuído ao longo dos anos nas pesquisas e construção das ferramentas na área da IA. O histórico da IA é marcado por fases de otimismo e pessimismo. Em certos períodos havia grandes expectativas por parte de pesquisadores e investidores, e em outras imperava o pessimismo do “inverno da IA” (também conhecido como “*AI Winter*”) (RUSSELL & NORVIG, 2003).

Foi na década de 40 que se iniciaram as pesquisas de IA em ambientes computacionais. O computador moderno possibilitava executar uma quantidade enorme de cálculos de maneira muito rápida, viabilizando avaliar estratégias de ação usando combinações de possibilidades através de simulações. O computador foi uma herança da Segunda Guerra Mundial, cujo principal objetivo era possibilitar a criação de mecanismos de defesa ou ataque eficientes com base nas simulações e nos cálculos realizados. Essas simulações eram realizadas através da inclusão de variáveis e regras, e o sistema devolvia um resultado. Paralelamente, os avanços nas pesquisas da área de neurologia mostravam que o cérebro era composto por uma rede de neurônios que transmitia a informação através de pulsos elétricos. Tentou-se então criar, através do computador, um cérebro artificial. Em 1943, Warren McCulloch e Walter Pitts idealizaram uma rede composta por neurônios artificiais, dando início a visão conexionista da IA (MCCULLOCH & PITTS, 1943). Nessa época também foram levantadas diversas questões de ordem filosófica e ética sobre o comportamento de uma máquina inteligente em relação ao ser humano (TURING, 1950).

Na década de 50 as pesquisas ficaram concentradas em questões de raciocínio lógico-matemático automático e representação simbólica de conhecimento. Os sistemas criados eram destinados a resolver problemas de álgebra e comprovação de teoremas matemáticos. Nessa mesma década também foram escritos os primeiros jogos de computador (NASCIMENTO JR. & YONEYAMA, 2004). Em 1951, baseado no trabalho de McCulloch & Pitts, Marvin L. Minski construiu o primeiro simulador de redes neurais artificiais.

O final da década de 50 e começo da década de 60 foram marcados pelo grande otimismo por parte dos pesquisadores e investidores, que dispensaram consideráveis quantias para acelerar as pesquisas. Havia a hipótese de que uma máquina com um comportamento completamente inteligente estava perto de ser construída. Em 1958, Frank Rosenblatt propôs o conceito de redes neurais tipo *perceptron*, e em 1960 o conceito de mínimos quadrados foi utilizado por B. Widrow e M. E. Hoff Jr. na criação do modelo ADALINE (*Adaptive Linear Element*) (NASCIMENTO JR. & YONEYAMA, 2004). Na linha psicológica foram desenvolvidos programas com o intuito de interpretação de linguagem. Em 1965 L. A. Zadeh introduziu o conceito de conjuntos nebulosos e propôs a Lógica Nebulosa (Lógica *Fuzzy*) na análise de sistemas complexos e auxílio a tomada de decisão. Os pesquisadores acreditavam que era possível representar a interpretação da linguagem humana através do raciocínio computacional. Em 1969, M. Minski e S. Papert publicaram um livro onde eram demonstradas limitações na utilização das redes tipo *perceptron*, pois o algoritmo de treinamento conhecido à época não conseguia classificar conjuntos não lineares. Aliado a isso os pesquisadores começaram a encontrar diversos problemas que iam desde poder computacional limitado até a dificuldade de representar deduções lógicas no sistema (NASCIMENTO JR. & YONEYAMA, 2004).

A década de 70 foi uma fase difícil para os pesquisadores de IA. As linhas de pesquisa psicológicas e conexionistas enfrentavam problemas para apresentar bons resultados na resolução de problemas simples, e os investimentos em IA foram reduzidos drasticamente.

Na década de 80, com uma abordagem mais modesta, surge o conceito de Sistema Especialista (SE). Esses sistemas tem o objetivo de resolver problemas específicos numa determinada área do conhecimento. A eficiência desses sistemas reacendeu o interesse comercial e novos investimentos começaram a ser feitos em pesquisas de IA. A Lógica Nebulosa começou a ser empregada em controles de automação no segmento industrial em larga escala. Nessa mesma década as pesquisas na linha de IA conexionista trouxeram novos avanços no segmento de redes neurais, como a rede proposta por J. J. Hopfield em 1982. Também nesse ano foi publicado o trabalho de T. Kohonen, sobre mapas auto-

organizáveis. O conceito de *Reinforcement Learning* para treinamento de Redes Neurais foi apresentado em 1983, e o método de treinamento com *Back-Propagation* foi desenvolvido em 1986 (NASCIMENTO JR. & YONEYAMA, 2004). No entanto no final da década, os computadores desktop começaram a ganhar bastante poder e velocidade, e ficaram mais baratos do que os *mainframes* necessários para rodar esses sistemas, gerando um novo inverno da IA. Da década de 90 em diante alguns dos objetivos de IA foram alcançados e a tendência é a divisão em agentes inteligentes (WILD *et al.*, 2011). Com a popularização do computador os sistemas computacionais começaram a ficar presentes cada vez mais no cotidiano.

## 4.2. SISTEMAS INTELIGENTES

A utilização de Sistemas Inteligentes (SI) é uma tendência crescente em todo o mundo. Esses sistemas realizam tarefas específicas de maneira similar a um operador humano. Eles possuem a capacidade de representar o conhecimento sobre determinado domínio de aplicação e de raciocinar utilizando esse conhecimento para chegar a um resultado útil e com significado (REZENDE, 2003). As características básicas de um sistema inteligente são: a capacidade de raciocínio, através da aplicação regras de inferência a um conjunto de dados disponível; a aprendizagem à partir dos acertos e erros durante a leitura dos dados de entrada; e reconhecer padrões nos dados apresentados ao sistema (VASCONSELOS & MARTINS JUNIOR, 2004). Sua aplicação na solução de diversos problemas demonstra que as máquinas são capazes, sob certas condições, de raciocinar e agir de forma parecida com o ser humano, causando um efeito de admiração do usuário em relação ao sistema (WILD *et al.*, 2011).

As principais diferenças entre um sistema tradicional e um sistema inteligente são: sua organização; a maneira de representar o conhecimento sobre o domínio da aplicação; o processamento dos dados; e impressão que causam ao usuário do sistema (REZENDE, 2003).

Sistemas tradicionais trabalham com o armazenamento e processamento algorítmico de dados sobre determinado evento. Sistemas inteligentes

armazenam, processam e geram resultados úteis e com significado, baseados no conhecimento armazenado em sua base de conhecimento.

Os dados sobre determinado evento são registros puros e mensuráveis. A interpretação desses dados, analisados em determinados contextos gera a informação. A comparação e combinação das informações em múltiplas ligações, que gerem resultados úteis e com significado é o conhecimento sobre determinada área (REZENDE, 2003). Os SI realizam essa análise e são capazes de extrair conhecimento das informações obtidas dos dados. No entanto, nem todos os problemas na área de IA são de fácil modelagem, pois a resolução de problemas complexos, onde há a necessidade de um conhecimento especializado, mostrou que os sistemas computacionais também precisariam saber o que o especialista humano soubesse sobre determinado domínio de aplicação. Nesse contexto é que surgem os sistemas especialistas.

### **4.3. SISTEMAS ESPECIALISTAS**

Os Sistemas Especialistas (SE) são o foco de pesquisas nas mais diversas áreas do conhecimento. Esse tipo de sistema é normalmente utilizado quando há uma alta complexidade na formulação de uma ferramenta computacional genérica, ou quando é necessária uma grande quantidade de conhecimento específico de um especialista para resolver o problema (REZENDE, 2003).

Nem todos os SE apresentam a mesma estrutura, mas pode-se dizer que a maioria é formada basicamente por dois componentes principais. A Base de Conhecimento (BC), que contém os conhecimentos associados ao domínio da aplicação e um Motor de Inferência (MI), responsável por raciocinar empregando a estratégia de um especialista no domínio da aplicação (REZENDE, 2003). Outros componentes podem ser adicionados na estrutura do sistema, como por exemplo: a interface com o usuário, memória de trabalho e também uma base de dados para consultas (Figura 18).

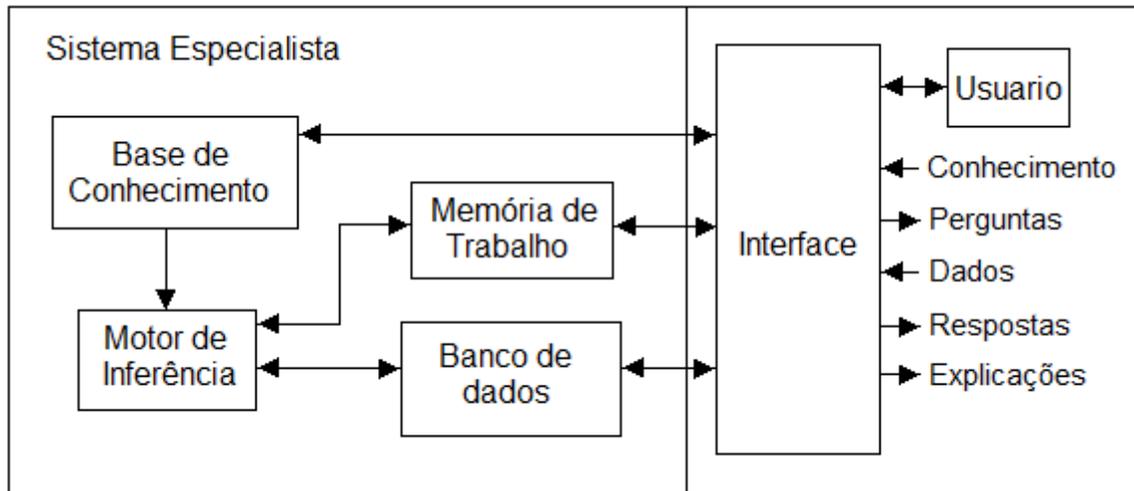


Figura 18 - Representação de um SE. Adaptado de Dias (2013).

Cada um dos componentes exibidos na Figura 18 é apresentado com mais detalhes a seguir.

- Base de conhecimento (BC):** A base de conhecimento é responsável por armazenar todos os conhecimentos relativos ao domínio da aplicação. O conhecimento pode ser adquirido através da consulta à determinada base de dados ou definido explicitamente por um especialista do domínio da aplicação. O conhecimento é representado por uma linguagem de representação que permita ao motor de inferência realizar o raciocínio necessário. Neste trabalho a BC é a estrutura organizacional da Rede Bayesiana e as suas probabilidades condicionais armazenadas numa Tabela de Probabilidades Condicionais (TPC).
- Motor de inferência (MI):** O motor de inferência realiza o raciocínio à partir do processamento da linguagem de representação do conhecimento armazenado na base de conhecimento. Ele representa a forma de manipular o conhecimento contido na base de conhecimento. A linguagem de representação do conhecimento na BC e os métodos empregados pelo MI influenciam de forma significativa no custo computacional requerido pelo sistema. Neste

trabalho a inferência é realizada através da aplicação do raciocínio probabilístico, aplicando o Teorema de Bayes de probabilidade condicional.

- **Interface do usuário:** A interface com o usuário permite que usuários façam consultas ao SE. As respostas do sistema são dirigidas a ele através desta interface. Ela também pode interagir com especialistas humanos, para realizar processos de modificação ou adição de conhecimentos na base.
- **Memória de trabalho (MT):** Na memória de trabalho ficam armazenadas as informações fornecidas pelos usuários, conclusões intermediárias e sequências executadas pelo sistema até que o sistema encontre uma conclusão para o problema. Nem todas as técnicas de representação do conhecimento possuem esse módulo. Ele é uma característica dos SE baseados em Regras de Produção, por exemplo.
- **Base de dados (BD):** A base de dados é de onde o sistema pode obter mais informações para realizar as sequências nos processos inferência.

#### 4.3.1. AQUISIÇÃO E REPRESENTAÇÃO DO CONHECIMENTO

O processo de aquisição do conhecimento é dependente da técnica de representação desse conhecimento. Ele pode ser feito utilizando o conhecimento informado por especialistas, arquivos de dados, bancos de dados e até mesmo a codificação de maneira computadorizada.

Segundo Rezende (2003), a representação do conhecimento pode ser entendida como uma forma sistemática de estruturar e codificar o que se sabe sobre uma determinada aplicação. Ela deve ser compreensível ao ser humano, abstrair-se dos detalhes de como funciona internamente o processador de conhecimento que o processará e ser generalizável.

Existem diversas maneiras de representar o conhecimento, e a definição dessa maneira está intrinsecamente ligada ao tipo de problema a ser abordado. Neste trabalho o tipo de representação adotado é o probabilístico.

#### 4.4. REDES BAYESIANAS

Sistemas especialistas probabilísticos possibilitam que o conhecimento de um especialista sobre o domínio da aplicação possa ser utilizado para calcular a probabilidade de um determinado evento, o qual, não se pode medir a frequência com que ocorre. Portanto, uma vantagem do raciocínio probabilístico é que ele permite tomar decisões mesmo quando não há informações suficientes para provar que uma ação será bem sucedida. Essa insuficiência de informações pode advir de duas origens: complexidade ou impossibilidade de aquisição de dados.

Uma Rede Bayesiana constitui um modelo de representação de dependências entre variáveis presentes em uma distribuição conjunta de probabilidade. Ela é composta por uma parte qualitativa e uma parte quantitativa. A parte qualitativa designa a composição estrutural da rede, ou seja, o seu formato gráfico, que é composta por nós que representam as variáveis aleatórias da distribuição e arcos que identificam as relações de dependência causais entre essas variáveis. O armazenamento do conhecimento dá-se através de uma distribuição conjunta de probabilidade e da intensidade das relações entre suas variáveis, e ambas representam a parte quantitativa.

As Redes Bayesianas possuem este nome por utilizarem nos seus cálculos as fórmulas de probabilidade condicional e probabilidade condicional conjunta do Teorema de Bayes (4.1).

$$P(A | B) = \frac{P(B | A)P(A)}{P(B)} \quad P(A | B) = \frac{P(B | A, E)P(A | E)}{P(B | E)} \quad (4.1)$$

, onde  $P(A)$  e  $P(B)$  são as probabilidades a priori de  $A$  e  $B$ , e  $P(B | A)$  e  $P(A | B)$  são as probabilidades a posteriori de  $B$  condicional a  $A$  e de  $A$  condicional a  $B$  respectivamente.

#### 4.4.1. ESTRUTURA DAS REDES BAYESIANAS

A porção qualitativa refere-se ao formato gráfico da rede, ou seja, define sua estrutura e as dependências entre as variáveis da distribuição através dos arcos que ligam os nós. Um arco que liga a variável **A** à variável **B** ( $A \rightarrow B$ ) indica que **B** é a variável consequência e **A** a variável causa. Nessa porção qualitativa, o grafo formado é dirigido e acíclico (DAG). A rede pode possuir múltiplos nós de entrada, mas sempre terá um nó fim. Esse grafo indica que há uma relação causal entre as variáveis e o relacionamento é indicado pela seta que parte da causa para os sintomas. Apesar do grafo indicar um relacionamento com um sentido, as Redes Bayesianas, utilizando o Teorema de Bayes, possuem a vantagem de se obter a consequência tanto através da alimentação das causas, como quanto obter as prováveis causas através da alimentação da consequência. A composição estrutural da rede pode ser inferida de maneira automática por meio da aquisição de um conjunto de dados representativo do problema a ser abordado. Ela também pode ser, e normalmente o é, definida explicitamente por especialistas no domínio da aplicação.

Uma vez identificadas todas as variáveis pertinentes ao domínio da aplicação, são definidos seus estados possíveis. Na sequência, deve-se estabelecer a relação causal entre as variáveis de entrada até a saída. Essa relação é definida através dos arcos.

Na Figura 19 é exibida uma Rede Bayesiana que possui 5 nós (variáveis aleatórias). As setas que ligam as variáveis representam as dependências causais.

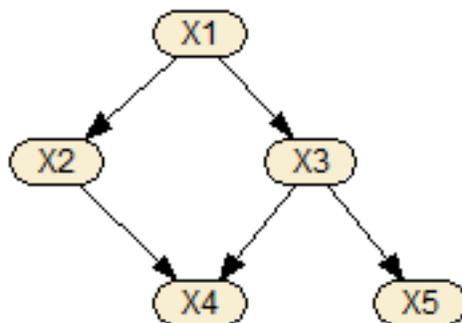


Figura 19 – Exemplo de uma Rede Bayesiana com 5 nós. Fonte: o próprio autor.

Quanto maior o número de variáveis na rede e maior o número de dependências, mais complexa é a sua estruturação. O número de possibilidades de ligação em uma distribuição conjunta de probabilidades é definido por:

$$2^n - 1 \quad (4.2)$$

Onde  $n$  é a quantidade de variáveis aleatórias (nós) definidos na rede (CHARNIAK, 1991). Nem todas essas relações precisam estar definidas. Isso se deve ao fato das Redes Bayesianas possuírem suposições de independência entre algumas variáveis. No entanto sempre deve haver uma ligação direta ou indireta com a variável de saída da rede.

Na rede exibida na Figura 19 existem cinco nós. A quantidade de ligações possíveis entre as variáveis é de 31 combinações. No entanto, se forem acrescentados apenas dois nós, o número de combinações possíveis cresce para 127. Se todas as ligações tivessem que ser feitas e o número de variáveis crescesse, em dado momento a definição e utilização desse sistema tornar-se-ia demasiadamente complexa. Dessa forma, não haveria viabilidade de construir sistemas com muitas variáveis, pois eles não seriam práticos e teriam um alto custo computacional. No entanto, devido à existência de suposições de independência entre as variáveis, nem todas as ligações precisam ser definidas, de tal maneira que o sistema limita-se a calcular as probabilidades entre as variáveis que possuem relação entre si.

A porção quantitativa refere-se ao conjunto de probabilidades condicionais associadas aos arcos do modelo gráfico, que identificam as dependências entre as variáveis aleatórias. As relações entre as variáveis possuem uma intensidade. Essa intensidade é armazenada na Tabela de Probabilidades Condicionais (TPC). A TPC lista a probabilidade de cada nó filho em relação à ocorrência de um evento no nó pai. Quando um evento é preenchido em algum nó, a rede propaga a atualização do grau de crença em determinado resultado por todos os outros nós relacionados com base na TPC.

A construção da TPC pode ser realizada de duas maneiras:

- Obtida dos especialistas e preenchidas diretamente nas Tabelas de Probabilidade Condicional (TPCs) ou;

- Apreendida de forma automática, através da apresentação de um arquivo de casos à Rede.

Neste trabalho os valores da TPC foram obtidos através do carregamento de um arquivo contendo as informações das embalagens de defensivos agrícolas. A Figura 20 apresenta a TPC do nó “HUE” da Rede Bayesiana utilizada neste trabalho. Pelo fato da restrição condicional ser relacionada apenas com o nó “Embalagem” a lista de probabilidades fica reduzida ao número de possibilidades pela quantidade de faixas de valores.

EMBALAGEM	0 to 76.3	76.3 to 96.75	96.75 to 167.5	167.5 to 360
1	99.997	1.14e-03	1.14e-03	1.14e-03
2	2.99e-03	2.99e-03	0.0299	99.964
3	38.178	55.736	6.084	1.17e-03
4	26.366	65.578	8.055	1.16e-03
5	13.556	55.026	31.4	0.0189
6	0.4	6.287	93.31	2.63e-03
7	3.804	15.592	72.226	8.378

Figura 20 - TPC do nó "HUE". Fonte: o próprio autor.

Em casos, como este trabalho, onde os dados das variáveis são contínuos há a necessidade de discretizá-los em faixas. As faixas de valores possíveis para o nó “HUE” foram obtidas através do algoritmo K-Means, que analisa todos os dados presentes no domínio e define os melhores limiares de valores para separação em faixas.

O conhecimento fica armazenado na relação entre as variáveis, na porção qualitativa, e nas probabilidades da TPC, na porção quantitativa. Uma vantagem deste modelo em relação às Redes Neurais Artificiais (RNA) é que o conhecimento contido pela rede fica explícito e pode ser explicado. Enquanto que numa RNA o conhecimento fica armazenado implicitamente nos valores dos pesos, não informando através de uma simples observação o seu significado, nas

Redes Bayesianas o conhecimento é explícito. Portanto, a observação desses valores favorece a conclusão sobre a importância das variáveis que devem ser consideradas. Neste trabalho o tempo de treinamento de uma Rede Bayesiana mostrou-se significativamente menor em relação à RNA, facilitando a atualização dos dados e refinamento dos resultados do sistema quando foi necessário ajustar o conjunto de treinamento. Outra vantagem encontrada na utilização das Redes Bayesianas é a simplicidade na sua construção. A ausência de parâmetros que necessitam ser ajustados e que poderiam interferir no desempenho do sistema facilita a utilização, visto que não são necessários profundos conhecimentos em relação a como a rede processa os dados.

#### **4.4.2. CLASSIFICADORES BAYESIANOS**

Uma Rede Bayesiana pode ser utilizada na classificação de características dos pixels de uma imagem digital através da modelagem de sua estrutura gráfica. A modelagem da estrutura gráfica é a porção qualitativa da rede. Essa modelagem define quais são as variáveis de entrada do sistema, qual é a variável de saída e indicam como as variáveis relacionam-se entre si.

O modelo de Rede Bayesiana do tipo *Naive Bayes* é utilizado como uma ferramenta genérica para resolver problemas de classificação (MONTINI *et al.*, 2011; SILVA, 2006).

#### **4.4.3. CLASSIFICADOR NAIVE-BAYES**

O modelo *Naive Bayes* define um tipo de rede que considera que as variáveis do domínio são condicionalmente independentes, ou seja, não possuem relação uma com a outra, a não ser com a variável de saída. A vantagem desse modelo é a simplicidade de sua estrutura, e o processo de classificação é muito eficiente (SILVA, 2006). A única informação necessária além dos nós é saber qual é a variável de saída, o que torna a construção dessa rede bastante simples (Figura 21).

Neste trabalho o tipo de rede utilizado foi o *Naive Bayes*. O processo de aprendizagem foi realizado de forma indutiva, ou seja, através da apresentação de um conjunto de dados de treinamento foi realizado o cálculo da probabilidade condicional de cada atributo. Esse cálculo foi realizado diretamente pelo *software* Netica® da Norsys Software Corp. Esse processo é descrito com detalhes no capítulo 5.

A vantagem da utilização desta rede é a simplicidade de sua estrutura e treinamento, apresentando resultados confiáveis. Além disso, apenas os nós de entrada e saída precisam ser definidos, nenhum outro parâmetro precisa ser ajustado.

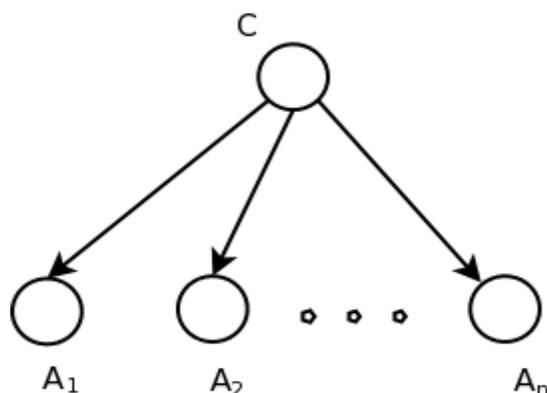


Figura 21 - Rede classificadora *Naive Bayes*. Fonte: o próprio autor.

#### 4.5. AVALIAÇÃO DO DESEMPENHO DOS TESTES

A avaliação dos resultados de um sistema de classificação, diagnóstico ou previsão é de importância fundamental para quantificar o poder discriminativo do sistema e identificar se o sistema realiza uma boa análise sobre o problema. No entanto, avaliar apenas a quantidade de acertos não indica necessariamente que o sistema é eficiente. Essa avaliação não indica falsos positivos (quando não há a presença da característica e o sistema detecta como existente) e falsos negativos (quando há presença da característica e o sistema não detecta) (DIAS, 2013).

Por exemplo, um sistema de detecção de diabetes é utilizado para diagnosticar a doença em um grupo de 100 pessoas, e dentre as quais já é sabido quais possuem ou não a doença. Se o sistema apresentar um acerto de 90% parecerá que o resultado foi muito positivo. No entanto, se a lista das pessoas for

analisada e detectar-se que 90% das pessoas realmente possuíam a doença, poder-se-ia afirmar que o sistema poderia ter devolvido o resultado como verdadeiro para todas elas e ainda assim o resultado seria o mesmo.

Para resolver problemas como este existe a Tabela de Contingência, também conhecida como matriz de confusão ou Tabela 2x2. Essa tabela serve de base para medidas de avaliação de desempenho que tratam eventuais desbalanceamentos nos grupos de teste. Para realizar o preenchimento desta tabela, os resultados obtidos no sistema proposto são comparados com o padrão-ouro. O padrão ouro é o conjunto de resultados obtidos através da execução de um método preciso consolidado.

#### 4.5.1. TABELA DE CONTINGÊNCIA

A Tabela de Contingência é uma matriz 2x2. Essa matriz é preenchida com os resultados obtidos do sistema em relação ao resultado do padrão-ouro, onde são carregados os resultados do sistema:

- **Verdadeiro Positivo (VP):** é o resultado onde o sistema detectou como positivo e a característica está presente.
- **Verdadeiro Negativo (VN):** é o resultado onde o sistema detectou como negativo e a característica está ausente.
- **Falso Negativo (FN):** é o resultado onde o sistema detectou como negativo e a característica está presente.
- **Falso Positivo (FP):** é o resultado onde o sistema detectou como positivo e a característica está ausente.

Tabela II - Tabela de contingência

		Característica		Total
		PRESENTE	AUSENTE	
Resultado do sistema	POSITIVO	VP	FP	VP + FP
	NEGATIVO	FN	VN	FN + VN
Total		VP + FN	FP + VN	

Fonte: Adaptado de DIAS (2013).

A partir dos dados preenchidos na Tabela de Contingência, é possível calcular outros índices de desempenho:

O **Valor Preditivo Positivo** (VPP) é a probabilidade que o sistema detecte a característica quando ela está realmente presente (SHORTLIFFE & PERREAULT, 2006). A probabilidade de que a característica seja detectada quando existe é dada pela razão das amostras que contém a característica e que foram detectadas pelo sistema por todas as amostras que contém a característica (4.3).

$$VPP = \frac{VP}{VP+FP} \quad (4.3)$$

A **Sensibilidade** é a proporção de verdadeiros positivos que são corretamente identificados pelo resultado do teste. Ela indica a capacidade do sistema em prever o resultado para casos onde a característica está presente (4.4) (DIAS, 2013).

$$SENSIBILIDADE = \frac{VP}{VP+FN} \quad (4.4)$$

O **Valor Preditivo Negativo** (VPN) é a probabilidade que quando a característica não está presente o resultado do sistema seja que a característica não foi detectada. A probabilidade de que da característica não ser detectada é dada pela razão das amostras que não contém a característica por todas as amostras que não contém a característica (4.5).

$$VPN = \frac{VN}{VN+FN} \quad (4.5)$$

A **Especificidade** é a proporção de verdadeiros negativos corretamente identificados pelo sistema. Essa medida mostra a capacidade do sistema em apontar a ausência da característica quando ela não está presente (DIAS, 2013). A especificidade é dada por 4.6:

$$ESPECIFICIDADE = \frac{VN}{VN+FP} \quad (4.6)$$

A **Probabilidade de Falso Positivo** (PFP) é a probabilidade do resultado do sistema ser positivo e a característica não esteja presente (4.7).

$$PFP = \frac{FP}{FP+VN} \quad (4.7)$$

A **Probabilidade de Falso Negativo** (PFN) é a probabilidade do resultado do teste ser negativo quando a característica não esteja presente (4.8).

$$PFN = \frac{FN}{FN+VP} \quad (4.8)$$

#### 4.5.2. CURVA ROC

Os resultados dos sistemas de classificação são, geralmente, contínuos, possuindo um valor entre 0 e 1, portanto é necessário definir um ponto de corte para classificar e contabilizar o número de predições negativas e positivas. Porém definir o ponto de corte de maneira arbitrária pode não gerar o melhor resultado, portanto faz-se necessário realizar uma análise de vários pontos de corte sobre as estatísticas de desempenho.

A curva ROC (*Receiver Operating Characteristic*) ilustra o desempenho de um sistema classificador com base em diversos pontos de corte (Figura 22). A curva é representada pelos vários valores de sensibilidade e especificidade que são calculados com base em pontos de corte.

Um classificador perfeito corresponde a uma linha horizontal no topo do gráfico, porém dificilmente é alcançada. Um bom classificador fica entre a linha diagonal e a linha perfeita. A linha diagonal indica que o resultado é totalmente aleatório.

A definição do ponto de corte pode ser realizada manualmente ou através do cálculo de uma medida chamada eficiência. A eficiência é dada pela média aritmética da sensibilidade e especificidade (4.9). Através do uso deste ponto de corte é possível realizar ajustes finos no sistema, de forma que a taxa de acerto

seja melhorada. Ao modificar o valor deste ponto de corte, aumenta-se a sensibilidade ou a especificidade do sistema em relação a alguma característica. A sensibilidade refere-se à capacidade do sistema identificar a presença da característica. Aumentando o valor da sensibilidade a característica será identificada de maneira mais fácil, no entanto, em contrapartida o número de falsos positivos pode aumentar. A especificidade por sua vez, indica a capacidade de detectar a ausência da característica.

O ajuste deste ponto de corte na curva ROC está intrinsecamente ligado ao domínio do problema abordado. Neste trabalho, a curva ROC é utilizada para determinar o ponto de corte e desta forma permitir a criação da Tabela de Contingência para determinar os níveis mínimos de crença em determinada característica encontrada na embalagem.

$$EFF = \frac{SENSIBILIDADE+ESPECIFICIDADE}{2} \quad (4.9)$$

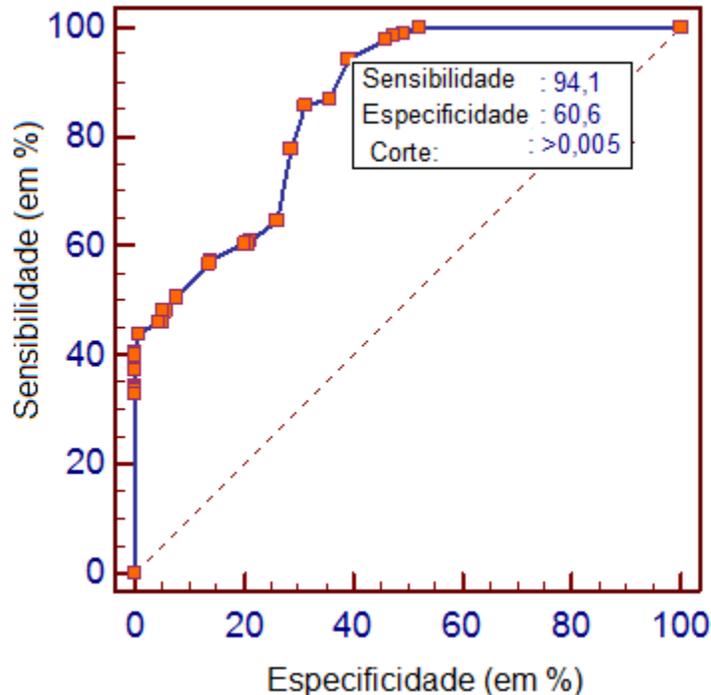


Figura 22 – Curvas ROC de uma embalagem Branco Leitoso. Fonte: o próprio autor.

## 5. METODOLOGIA

Ao observar uma cena, é possível destacar todos os objetos e avaliar além da cor, a forma, a textura, o tamanho entre outras características de um objeto em foco. As faculdades físicas e cognitivas, quando na sua perfeita harmonia e funcionamento, possibilitam o reconhecimento quase que imediato das características presentes. Os estímulos sensoriais recebidos pelo cérebro através do nervo óptico permitem a formação da imagem na mente e ao focalizar-se determinado ponto ou objeto torna-se possível identificar a cor predominante de maneira automática (LAMB, 2011). Isso ocorre porque já existe o conhecimento em relação à classificação das cores e esses estímulos estão ligados diretamente a adjetivos que são armazenados na memória que informam qual é a cor percebida. No entanto a classificação da cor predominante em um objeto de uma imagem digital é do ponto de vista computacional uma tarefa bastante complexa. Essa complexidade dá-se inicialmente em definir a forma como a imagem será adquirida pelo sistema, posteriormente pela necessidade de isolar o objeto na imagem, extrair as informações relevantes em quantidade suficiente e finalmente identificar a cor em tempo aceitável para o domínio do problema.

A classificação de uma embalagem de defensivo agrícola proposta neste trabalho segue os seguintes passos: *i)* aquisição, pré-processamento, segmentação e amostragem dos pixels da imagem digital, *ii)* conversão do formato RGB para HSL, *iii)* classificação da cor dos pixels através de uma rede bayesiana, *iv)* classificação da cor predominante da embalagem através da análise da saída da rede utilizando um cálculo de aproximação de vetores (Figura 23).

O presente trabalho utiliza a divisão proposta na Figura 14 do capítulo 3 para o processamento de imagens digitais. Essa visão modular do sistema facilita o entendimento de cada componente e como eles se relacionam para gerar o resultado final. Em cada etapa do processo ferramentas computacionais distintas são acionadas. Dentre as ferramentas computacionais utilizadas neste trabalho destacam-se:

- **Matlab®**: Software distribuído pela The Mathworks Inc., utilizado para desenvolver os algoritmos que realizam a aquisição, pré-

processamento, segmentação, extração de características e integração com a Rede Bayesiana.

- **Netica®**: Software distribuído pela Norsys Software Corp., utilizado para criar e treinar a Rede Bayesiana utilizada neste trabalho.

Dentre os equipamentos de *hardware* utilizados destacam-se:

- **Câmera webcam** Microsoft® *LifeCam* VX-800, utilizada para adquirir as imagens das embalagens.
- **2 lâmpadas fluorescentes de 25W 6400K**, utilizadas na iluminação do ambiente.

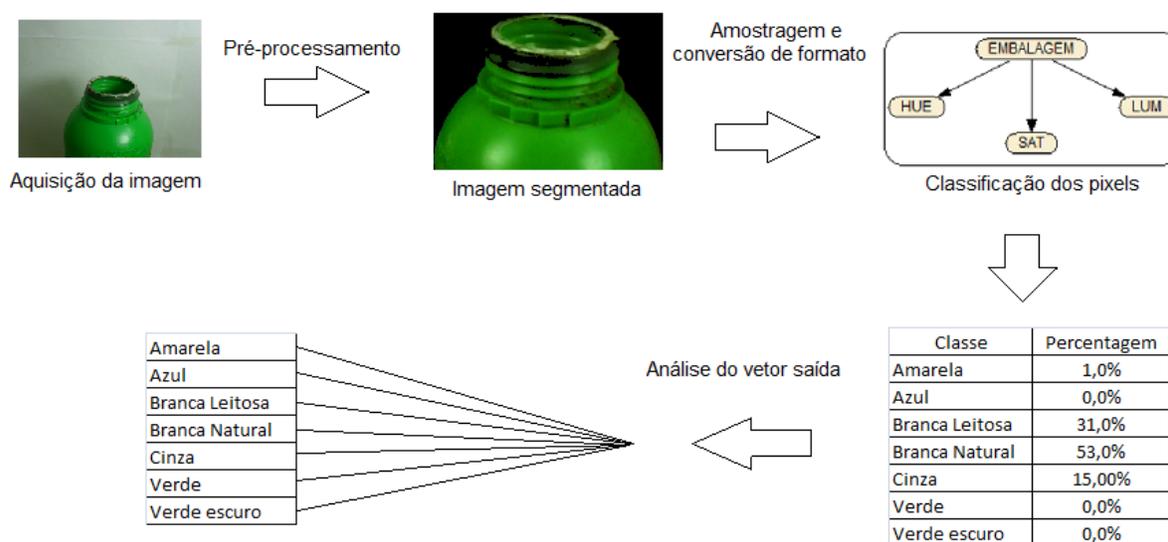


Figura 23 – Processos executados pelo sistema. Fonte: o próprio autor.

Neste capítulo são abordados cada um dos passos que tornam possível realizar a classificação da cor predominante de uma embalagem de defensivo agrícola, descrevendo a técnica e a ferramenta utilizada. Ao final são descritos os processos de treinamento e testes de desempenho do sistema.

Todos os algoritmos desenvolvidos para a resolução do problema (testes, aquisição de imagem, processamento de imagem e avaliação de desempenho) foram escritos no programa Matlab®. A integração com a Rede Bayesiana foi escrita também no Matlab®, e foi possível através da utilização de uma *Application*

*Programming Interface* (API) disponibilizada pela Norsys Software Corp.. A aplicabilidade do sistema não fica restrita apenas a microprocessadores x86, porque embora os programas tenham sido escritos na ferramenta Matlab®, elas podem ser traduzidas para a linguagem C e compiladas para outros processadores, como por exemplo, processadores ARM.

### **5.1. AQUISIÇÃO DE IMAGENS**

As técnicas utilizadas no processamento de uma imagem digital estão intrinsecamente ligadas à forma como a imagem é adquirida pelo sistema. Quando a aquisição das imagens favorece os métodos de extração de características, menor é o custo computacional do pré-processamento e segmentação. Cor da iluminação, intensidade luminosa, objetos de fundo e etc. são características que devem ser levadas em consideração no momento da aquisição da imagem.

Neste trabalho a aquisição das imagens é realizada através de uma câmera *webcam* Microsoft® *LifeCam* VX-800. A opção de utilizar uma câmera de propósitos genéricos dá-se pelo fato dessa ferramenta ser bastante difundida no mercado e apresentar um custo consideravelmente baixo, favorecendo a aplicabilidade do sistema proposto. A resolução definida para obter as imagens foi de 320x240 pixels, no formato RGB. As embalagens são posicionadas em frente a um fundo negro em condições de luminosidade de aproximadamente 800 lux. Um algoritmo desenvolvido para o programa Matlab® é o responsável pela aquisição da imagem. Um dos intuitos deste trabalho é minimizar o contato do operador com a embalagem de defensivo agrícola, outro é utilizar as ferramentas computacionais de maneira inteligente favorecendo a automatização completa do sistema. Portanto, o algoritmo realiza a captura da imagem embalagem de maneira automática, ou seja, através deste algoritmo o operador não necessita realizar intervenções no sistema para indicar que a embalagem já está posicionada em frente à câmera, nem o sistema precisa de sensores auxiliares para indicar a posição da embalagem. Outra vantagem de realizar a verificação por imagem é que isso traz a redução de custos extras com sensores e minimiza a

complexidade em relação aos equipamentos e regulagens técnicas necessárias. Esse algoritmo é apresentado com mais detalhes na próxima seção.

Conforme mostrado no capítulo 2, as embalagens de defensivos agrícolas possuem rótulos de papel que normalmente estão colados ou impressos na sua porção externa. Como essa informação não contribui para o objetivo do trabalho, e poderia inclusive atrapalhar o processo de classificação, optou-se por eliminar a sua influência no momento da aquisição da imagem. Portanto optou-se por obter uma imagem do gargalo da embalagem.

## 5.2. PRÉ-PROCESSAMENTO E SEGMENTAÇÃO

A imagem digital da embalagem analisada (Figura 24) é obtida através de uma câmera *webcam* conectada ao computador através de um barramento USB. Antes, porém, de iniciar o processo de validação de cada pixel da imagem, é necessário realizar a extração das informações da porção relevante da imagem, ou seja, apenas os pixels que representam o objeto entendido como embalagem contido na imagem digital.



Figura 24 - Imagem original adquirida através da *webcam*. Fonte: o próprio autor.

A exclusão da região entendida como o fundo da imagem permite que o sistema trabalhe apenas com dados relevantes para a resolução do problema. Segmentar a imagem e definir a embalagem num espaço bidimensional é possível através da técnica de subtração de fundo. Tendo como base a imagem de fundo, adquirida durante um processo de calibragem do sistema, a segmentação é

realizada, e a partir deste processo a porção entendida como o fundo da imagem é eliminada.

Para realizar esse processo de segmentação, outro algoritmo foi desenvolvido também no ambiente Matlab®. A captura da primeira imagem é definida como fundo. Para facilitar o entendimento do processo ela será tratada a partir de agora como *ImFundo*. Após a sua aquisição novas capturas são realizadas. A cada nova captura é realizada uma subtração entre a imagem adquirida e *ImFundo*. Quando a diferença entre elas atinge um determinado limiar o sistema identifica uma alteração no cenário. Essa alteração caracteriza a inserção de uma embalagem em frente à câmera. Conforme a embalagem é posicionada, o limiar de diferença vai variando, e nesse momento o sistema aguarda que esse limiar estabilize-se. Quando estabilizado, indica que a embalagem está parada em frente à câmera, e o processo de identificação pode começar. Nesse momento é realizada a subtração do fundo, conforme técnica de subtração de fundo apresentada no capítulo 3.

Durante a extração do fundo alguns ruídos podem ser capturados. Esses ruídos são provenientes de pequenas alterações no ponto da imagem referente ao fundo. Essas modificações tênues devem-se ao fato das condições de iluminação sofrerem pequenas variações quando a embalagem é posicionada no campo de alcance da câmera. No intuito de reduzir essa influência, a máscara utilizada para a subtração da imagem é processada por um algoritmo de erosão, descrito no capítulo 3.

A câmera utilizada pelo sistema possui um ângulo de captura maior do que o necessário para realizar o tratamento dos dados pelo sistema. Portanto, após separar o fundo do objeto a imagem passa por um processo de extração de margens, conforme linhas mostradas na Figura 25. A porção lateral e superior não contém informações relevantes para o sistema, portanto elas são removidas. Esse processamento é realizado através de um algoritmo que realiza três varreduras na imagem. Na primeira varredura são avaliadas as linhas horizontais da imagem. Se nenhum pixel contiver informação relevante ela deve ser eliminada. Em seguida são realizadas as varreduras verticais, sendo avaliadas as colunas do lado esquerdo para o direito e em seguida do direito para o esquerdo da imagem. Após

esse processo o resultado final é o visto na Figura 26. A utilização desse método favorece o algoritmo responsável por realizar a amostragem dos pixels, pois quanto menos área sem características relevantes na imagem, maior será a chance de amostrar dados relevantes. O sistema de amostragem é detalhado na próxima seção.



Figura 25 - Imagem após subtração do fundo. Fonte: o próprio autor.



Figura 26 - Imagem final que será avaliada pelo sistema. Fonte: o próprio autor.

### 5.3. AMOSTRAGEM DOS PIXELS

A imagem digital adquirida é composta por milhares de pixels, que combinados num vetor bidimensional representam a imagem. Avaliar a totalidade dos pixels da imagem torna-se uma tarefa lenta, mesmo com as ferramentas computacionais existentes. Para realizar a avaliação de 100% dos pixels de uma imagem de 170x120 pixels o sistema leva 2 minutos e 20 segundos, resultando em aproximadamente 145 pixels por segundo. Isso se deve ao fato de que o pixel precisa ser convertido de RGB para HSL, posteriormente adicionado na Rede Bayesiana e somente aí se obtêm o resultado. Para estar de acordo com os

propósitos deste trabalho, o sistema precisa ser rápido. Portanto, foi desenvolvido um algoritmo de amostragem que realiza uma varredura na imagem e carrega apenas algumas amostras do total da imagem.

A coleta da porcentagem de amostras do total de imagens é definida através de parâmetro, e a partir dele o algoritmo de amostragem carrega apenas alguns pixels da imagem. Essa amostragem é realizada de maneira sequencial de acordo com a porcentagem de amostras definida. Se um pixel de fundo for obtido, ele é ignorado e a próxima amostra é obtida. No entanto, poderia ocorrer de apenas os pixels amostrados não representarem a região de onde foram amostrados. Por isso cada amostra coletada é composta pelo cálculo da média dos pixels de uma região amostrada. Essa região também é conhecida como vizinhança do pixel (MARQUES FILHO & VIEIRA NETO, 1999). O limiar de tamanho dessa região foi definido através de testes de desempenho versus custo computacional. Os resultados mostrados no capítulo 6 mostram que esse limiar mostrou-se suficiente para realizar a classificação corretamente. A amostragem por região diminui a possibilidade de coletar ruído durante a amostragem, e que poderiam impactar negativamente na classificação da embalagem. Esse ruído é composto principalmente por pontos de reflexão da luz na embalagem, dados impressos na embalagem, sombras dos frisos do gargalo e porção de lacre não removido do gargalo da embalagem. Durante a amostragem e a média os pixels estão ainda no formato RGB. Após esta etapa, eles são convertidos e posteriormente podem ser inseridos na ferramenta de classificação.

#### **5.4. CONVERSÃO RGB PARA HSL**

Para realizar a classificação da cor dos pixels da imagem, há a necessidade de realizar a conversão do formato da imagem. Para isso cada pixel selecionado pelo algoritmo de amostragem é convertido do formato RGB para o formato HSL. O cálculo de conversão utilizado neste trabalho é o descrito no capítulo 3.

## 5.5. CLASSIFICAÇÃO DOS PIXELS

A quantidade de cores que podem ser representadas numa imagem digital colorida é bastante grande (16.581.375 valores possíveis). Não existem valores específicos que determinem cada uma das cores conhecidas, e nem limites específicos que definam quando há a transição de uma cor para outra. Essa transição dá-se de maneira sutil, dessa forma, o sistema empregado na classificação de cor predominante de uma imagem digital deve ter a capacidade de lidar com informações imprecisas. A Rede Bayesiana é uma ferramenta capaz de lidar com esse tipo de informação.

Tanto a porção qualitativa quanto a quantitativa podem ser aprendidas pela Rede Bayesiana. Neste trabalho a parte qualitativa já era conhecida, e na criação da rede foram definidos os seguintes nós: Embalagem (nó de saída), *Hue*, *Sat*, *Lum* (Figura 27).

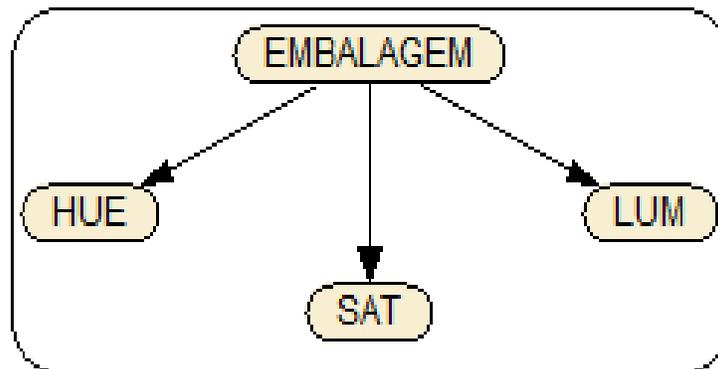


Figura 27 - Rede classificadora de cores. Fonte: o próprio autor.

Uma vez realizado o pré-processamento, segmentação e a conversão de formato, descritos na seção anterior, os pixels selecionados são apresentados a Rede Bayesiana. Cada pixel, agora no formato HSL, possui as informações: tonalidade (*hue*), saturação e luminosidade. As informações são inseridas nos nós pertinentes: *HUE* recebe o valor da tonalidade, *SAT* recebe o valor da saturação e *LUM* recebe o valor da luminosidade.

A rede processa os dados de entrada e devolve como resultado, o grau de crença em cada uma das classes (tipo de embalagem) no nó Embalagem (nó de saída). O grau de crença é definido com base na Tabela de Probabilidades

Condicionais (TPC) adquiridas pela rede no momento do treinamento desta (Figura 28).

EMBALAGEM	
Amarela	0 +
Azul	0 +
Branca Leitosa	59.0
Branca Natural	36.0
Cinza	4.96
Verde	.008
Verde escuro	0 +
$3.46 \pm 0.59$	

Figura 28 – Estados do nó *EMBALAGEM*, após alimentação dos nós de entrada (*HUE*, *SAT*, *LUM*) com as informações de um pixel obtido da imagem de uma embalagem Branca Leitosa. Fonte: o próprio autor.

A classe que obtiver o maior grau de crença é considerada como resultado. Esse processo é executado para cada pixel amostrado, e os resultados vão sendo armazenados num vetor acumulador.

Dentre as sete classes de embalagens que o sistema proposto irá classificar, três apresentam as características de cor muito próximas, dificultando a sua caracterização quando é realizada a amostragem. Elas são: Branca Leitosa, Branca Natural e Cinza. Dessa forma, após realizar a construção da Rede Bayesiana, foram realizados alguns testes para medir o desempenho da rede, a avaliação foi realizada através da Tabela de Contingência, descrita no capítulo 4. À partir dela foi obtida a curva ROC. A curva ROC apresenta o melhor ponto de corte para definir o resultado. Esse índice é chamado de Eficiência ou índice Younden (YOUNDEN, 1950). No entanto esse índice pode ser modificado para aumentar a especificidade ou sensibilidade do diagnóstico. Uma alta especificidade determina que o sistema só considere o resultado como positivo, quando as chances de ser positivo são mais altas que o índice definido. A sensibilidade por sua vez, determina o quão sensível o sistema é a determinado diagnóstico, ou seja, mesmo com uma probabilidade não tão elevada, ele irá considerar o resultado como positivo. No intuito de melhorar os resultados obtidos com a classificação das cores dos pixels, e reduzir erros na classificação dessas

três classes, a especificidade das embalagens Branca Leitosa e Cinza foram aumentadas, de forma que o sistema só classifique essas duas classes quando o grau de crença ultrapasse esse limiar.

O vetor acumulador de resultados, descrito anteriormente, é composto por sete posições que representam cada uma das classes, e armazena a percentagem de pixels encontrados para cada classe numa mesma imagem, conforme Tabela III.

Esse vetor acumulador é armazenado até que todos os pixels amostrados sejam avaliados, e ao final da avaliação eles são comparados aos vetores médios de cada classe. Esse processo é detalhado na próxima seção.

Tabela III - Representatividade da classe na imagem de uma embalagem Branca Natural.

Classe	Percentagem
Amarela	1,0%
Azul	0,0%
Branca Leitosa	31,0%
Branca Natural	53,0%
Cinza	15,0%
Verde	0,0%
Verde escuro	0,0%

Fonte: o próprio autor.

## 5.6. CLASSIFICADOR DE CORES

É nesta etapa que o sistema realiza o processo de identificação da cor predominante na embalagem de defensivo agrícola. Na mesma imagem digital podem ser encontrados pixels de diversas classes. Por exemplo, numa imagem de uma embalagem cinza, alguns pontos da imagem podem ficar mais iluminados do que outros, dessa forma poderão ser identificados como Branco Natural no lugar de Cinza.

Para cada imagem, um vetor acumulador descrito anteriormente é a resposta da etapa de classificação das cores dos pixels (Tabela III). Esse vetor é comparado com vetores médios de cada classe. Esses vetores médios são obtidos na fase de treinamento. Essa comparação é realizada através de um

processo de aproximação de vetores, utilizando o cálculo de distância euclidiana (5.1):

$$\sqrt{(p_1 - q_1)^2 + (p_2 - q_2)^2 + \dots + (p_n - q_n)^2} = \sqrt{\sum_{i=1}^n (p_i - q_i)^2} \quad (5.1)$$

Sendo  $P = (p_1, p_2, \dots, p_n)$  o vetor contendo as porcentagens encontradas em uma determinada imagem e  $Q = (q_1, q_2, \dots, q_n)$  o vetor médio contendo as porcentagens de quantidade de pixels para uma determinada classe

Após comparar o vetor da imagem com os vetores de cada classe obtêm-se as distâncias. O que for menos distante do vetor da imagem define o resultado, ou seja, a classe que ele representa. Dessa forma obtêm-se a cor predominante na embalagem. Os resultados obtidos com o emprego da metodologia apresentada neste capítulo são apresentados e detalhados no próximo capítulo.

## 6. RESULTADOS E DISCUSSÕES

A utilização do espaço de cores HSL possibilitou a caracterização da cor da embalagem de defensivo agrícola. Através dos valores armazenados em suas variáveis, o conhecimento em relação à distribuição dos grupos de cores pode ser armazenado na Rede Bayesiana através do sistema de aprendizagem. Utilizando-se do ambiente Matlab® foi possível desenvolver as ferramentas computacionais necessárias para realizar a aquisição, segmentação, extração de características e reconhecimento de cor predominante de um objeto. Os resultados apresentados neste capítulo são provenientes dos testes realizados utilizando essas ferramentas.

Os testes foram realizados em duas etapas. Num primeiro momento 22 imagens separadas para o processo de validação foram avaliadas. Em seguida outras 55 imagens de embalagens, obtidas sob diferentes graus de luminosidade, foram avaliadas. Neste capítulo serão descritos os procedimentos de treinamento da Rede Bayesiana e os resultados dos testes realizados.

### 6.1. TREINAMENTO DO SISTEMA

No treinamento do sistema foram utilizadas 33 imagens de embalagens, sendo estas distribuídas entre as classes de embalagens existentes, conforme Tabela IV.

Tabela IV - Quantidades de imagens utilizadas no treinamento

Classe	AM	AZ	BL	BN	CZ	VR	VE
Quantidade	6	3	6	6	6	3	3

Fonte: o próprio autor.

Para realizar o treinamento do sistema os mesmos algoritmos de aquisição de imagem descritos anteriormente foram utilizados. Após o processo de segmentação as imagens capturadas ficaram com uma resolução média de 170x110 pixels. De cada uma destas imagens digitais obteve-se aproximadamente 70% de pixels que contém informações pertinentes ao processo de classificação. A informação dita pertinente refere-se aos pixels que representam o objeto embalagem na imagem. O restante representa o fundo e esta porção é eliminada

do processo de treinamento através da segmentação. O número de pixels utilizado no treinamento foi de 211.626 amostras. Essas informações foram armazenadas em um arquivo texto. Após a obtenção desses dados foi possível iniciar a construção da Rede Bayesiana.

A Rede Bayesiana foi criada através do software Netica®, da Norsys Software Corp. Através da interface computacional gráfica existente nesse programa a parte qualitativa da rede foi criada, ou seja, foram definidos os nós de entrada e saída e também o seu relacionamento, identificado através dos arcos. Posteriormente, nessa mesma interface, foram realizados os procedimentos de treinamento da rede. O treinamento foi realizado através da leitura do arquivo texto contendo as amostras dos pixels das imagens de treinamento.

Através da interface gráfica do software Netica®, é possível verificar os níveis de sensibilidade das variáveis do sistema, ou seja, o software indica qual é a variável com maior influência na definição do resultado (Tabela V).

Tabela V – Sensibilidade do sistema.

Nó	Redução de variância	Percentual	Informação mútua	Percentual	Varição da crença
EMBALAGEM	3,054	100,0	264,034	100	0,6878404
HUE	1,692	55,4	0,979	37,1	0,1019684
INT	1,253	41,0	130,139	49,3	0,1794571
SAT	0,973	31,9	138,041	52,3	0,1534951

Fonte: o próprio autor.

Através da análise da Tabela V é possível observar que o nó que apresenta maior influência na identificação do resultado é o nó *HUE*, com 55% de sensibilidade. Essa sensibilidade da variável *HUE* deve-se em grande parte ao fato das cores ficarem discretizadas de forma bem distinta na variável *Hue* no plano *HSL*. No entanto, as embalagens Branco Leitoso, Branco Natural e Cinza, não possuem a característica tonalidade como relevante, apenas a intensidade e saturação. Dessa forma a sua classificação mostrou-se complexa, exigindo do sistema um segundo classificador que realizasse a determinação da cor da embalagem através da comparação do vetor saída com os vetores típicos de cada classe.

Após realizar o treinamento da rede, o mesmo arquivo contendo as informações de treinamento foi utilizado para gerar o arquivo contendo os vetores típicos de cada classe, conforme mostra a Tabela VI. Nessa tabela está a média da percentagem de pixels de classes distintas encontrados numa mesma imagem. Essas informações foram obtidas diretamente da saída da Rede Bayesiana, e representam a média para cada classe. Ela é utilizada pelo sistema como base de comparação ao vetor de saída obtido após a classificação de cada pixel pela Rede Bayesiana na fase de teste.

Tabela VI - Vetores de classificação médios de cada classe.

		Resultado obtido da Rede Bayesiana						
		AM	AZ	BL	BN	CZ	VR	VE
Embalagem Avaliada	Amarela	100,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%
	Azul	0,00%	100%	0,00%	0,00%	0,00%	0,00%	0,00%
	Branca L.	0,00%	0,00%	64,41%	16,40%	19,40%	0,00%	0,00%
	Branca N.	0,00%	0,00%	5,30%	58,50%	36,10%	0,00%	0,00%
	Cinza	0,00%	0,00%	4,02%	9,08%	86,01%	0,00%	0,00%
	Verde	0,00%	0,00%	1,47%	0,15%	0,00%	96,45%	1,93%
	Verde E.	0,04%	1,99%	0,00%	0,90%	0,80%	2,86%	93,51%

Fonte: o próprio autor.

Nem sempre a maior quantidade de pixels em uma determinada cor representa a cor predominante na embalagem. Na embalagem Amarela, por exemplo, encontrou-se 100% dos pixels classificados na classe Amarela (AM). Contudo, numa embalagem Branca Natural existem mais pixels classificados como Cinza (CZ) do que Branco Natural (BN) (Tabela VI). Isso ocorre pelo fato das classes Branco Leitoso (BL), Branco Natural (BN) e Cinza (CZ) possuírem as suas características acromáticas muito próximas uma das outras. Na prática, o que diferencia uma da outra é a quantidade de pixels da classe distribuída pela embalagem, e por isso o segundo classificador faz-se necessário.

## 6.2. TESTES

Após o treinamento foi realizado o processo de avaliação de desempenho do sistema. Para analisar esse desempenho optou-se dividir os testes em 2 etapas. Na primeira etapa as imagens adquiridas foram obtidas nas mesmas condições de iluminação. Numa segunda etapa, as imagens foram obtidas sob condições de iluminação propositalmente modificadas. A variação na luminosidade foi realizada com a intenção de analisar a robustez do sistema em relação à condições adversas que podem surgir num ambiente produtivo. Dessa forma é possível saber até que ponto o sistema suportaria quando instalado em condições inadequadas.

A quantidade de imagens de embalagens utilizadas na fase de teste e suas respectivas classes estão detalhadas na Tabela VII.

Tabela VII - Quantidades de imagens utilizadas na fase de teste

Classe	AM	AZ	BL	BN	CZ	VR	VE
Quantidade	10	5	10	10	10	5	5

Fonte: o próprio autor.

### 6.2.1. PRIMEIRA AVALIAÇÃO

Quando as condições de luminosidade foram mantidas no padrão utilizado no treinamento, o acerto do sistema foi, utilizando Rede Bayesiana, de 100% para todas as classes de embalagens, conforme mostrado na Tabela VIII.

Tabela VIII - Taxa de acerto do sistema em condições ideais de iluminação.

Técnica	Dist. Euclidiana	Dist. Mahalanobis	Rede Neural Artificial	Rede Bayesiana
Acerto	57,58%	78,79%	100%	100%

Fonte: o próprio autor.

No intuito de comparar os resultados do trabalho proposto com um método já consolidado, foi desenvolvido um algoritmo que utilizava, no lugar da Rede Bayesiana, uma Rede Neural Artificial para identificar a cor dos pixels. O classificador de cores utilizando distância euclidiana foi mantido, apenas a técnica para classificar a cor do pixel avaliado é que foi modificada.

O treinamento da rede neural foi realizado através da *toolbox* de RNA do programa Matlab®, utilizando os parâmetros de treinamento padrão e parâmetros descritos na Tabela IX.

Tabela IX - Parâmetros da RNA

Parâmetro	Neurônios na camada Intermediária	Percentagem treinamento	Percentagem validação	Percentagem teste	Épocas
Valor	7	70%	15%	15%	100

Fonte: o próprio autor.

Utilizando a RNA o acerto também foi de 100%. A Rede Neural Artificial foi treinada e avaliada com as mesmas imagens utilizadas na Rede Bayesiana. O formato de representação da imagem utilizado também foi o HSL, necessitando de 3 entradas na RNA, 7 neurônios na camada intermediária e 1 na saída. Buscando verificar a viabilidade de utilizar um método mais simples de avaliação, um algoritmo que utilizava distância Euclidiana para classificar a cor do pixel também foi utilizado. O resultado obtido utilizando este método foi de 57,58%. Também foram realizados testes utilizando o algoritmo de distância Mahalanobis (MAHALANOBIS, 1936) e o resultado obtido foi de 78,79% de acerto. Os baixos índices de acerto nos dois últimos métodos descritos ocorrem fundamentalmente pela incapacidade de classificar as embalagens das cores Branco Leitoso, Branco Natural e Cinza, visto que essas classes possuem as informações distribuídas de maneira não tão distintas no espaço HSL.

### 6.2.2. SEGUNDA AVALIAÇÃO

Buscando avaliar a capacidade do sistema em lidar com diferentes graus de luminosidade, foram realizados testes com 5 diferentes condições de iluminação. Sob essas novas condições o sistema apresentou uma sensível redução na capacidade de classificar corretamente as embalagens, conforme resultados apresentados na

Tabela X.

Tabela X - Taxa de acerto para cada classe, na avaliação sem variação nas condições de iluminação.

Técnica	Dist. Euclidiana	Dist. Mahalanobis	Rede Neural Artificial	Rede Bayesiana
Acerto	60,00%	76,36%	89,09%	90,91%

Fonte: o próprio autor.

Após obter esses resultados, uma análise mais profunda foi realizada com o objetivo de verificar quais embalagens o sistema estava classificando de maneira incorreta. Para tanto, os resultados individuais de cada classe foram obtidos, conforme Tabela XI.

Tabela XI – Resultados individuais de cada classe.

AM	AZ	BL	BN	CZ	VR	VE
100,00%	100,00%	100,00%	90,00%	60,00%	100,00%	100,00%

Fonte: o próprio autor.

Através da análise da Tabela XI, observa-se que as embalagens que contém informações cromáticas (AM, AZ, VR e VE) continuam sendo corretamente classificadas. No entanto, as embalagens que não possuem a informação de tonalidade (BN e CZ) apresentaram dificuldade para serem classificadas. Algumas embalagens BN foram classificadas como CZ quando a intensidade luminosa foi reduzida, e as embalagens CZ foram classificadas como BN quando a intensidade luminosa foi aumentada. As embalagens da classe BL tiveram uma variação no vetor de saída da rede, no entanto ainda foi possível classificá-la corretamente.

Para analisar a intensidade da variação de luminosidade sobre o resultado final, foram selecionadas duas embalagens. Uma conteria informações de tonalidade, e a outra não. Assim sendo, optou-se por comparar a saída da Rede Bayesiana para uma embalagem Azul e uma embalagem Branca Natural, em relação à variação das condições de iluminação. O resultado da saída da rede em relação a cada condição luminosa é apresentado a seguir.

Através da análise da Figura 29, observa-se que os valores de saída da etapa de classificação de pixels mantêm-se estáveis, para uma embalagem da classe Azul (AZ). Em todas as condições a quantidade de pixels avaliados como

azul ficou superior a 95%. Dessa forma o sistema conseguiu realizar o reconhecimento do vetor de saída. Isso ocorre porque a embalagem azul possui a componente Tonalidade bastante representativa, e que não é tão afetada pela redução da luminosidade.

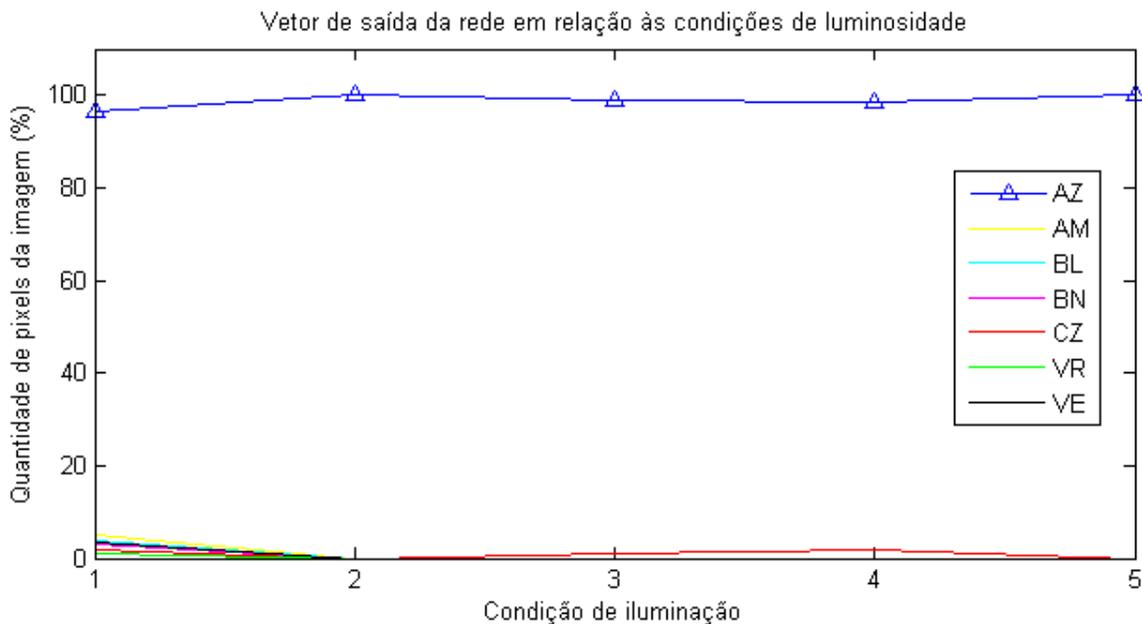


Figura 29 - Estabilidade na porcentagem de pixels classificados como Azuis com base na variação das condições de iluminação de uma embalagem da classe Azul. Fonte: o próprio autor.

No entanto, na Figura 30, percebe-se que os valores dos vetores de saída de uma embalagem Branca Natural (BN) não ficam estáveis, interferindo no processo de classificação de cores por aproximação de vetores. Os vetores de saída da etapa de classificação de pixels ficam demasiadamente distantes do resultado médio. Dessa forma, na etapa de classificação de cores, o sistema não consegue classificar corretamente a cor predominante.

Ainda analisando a Figura 30, percebe-se que quando o nível de iluminação é reduzido, os pixels que eram classificados como BN (mais clara) começam a ser identificados como CZ (mais escura). Isso se deve a dois fatores que estão intrinsecamente interligados. O primeiro é em relação ao fato das embalagens das classes Branca Leitosa, Branca Natural e Cinza possuírem apenas representação significativa nas componentes Saturação e Luminosidade. O segundo fato é que a componente Luminosidade está diretamente ligada com a quantidade de luz

emitida ou refletida por um objeto, e a Saturação é calculada com base na Luminosidade. Dessa forma as características fogem demasiadamente do padrão. Portanto ao diminuir ou aumentar a intensidade luminosa, os valores de Luminosidade e Saturação são reduzidos e o sistema não possui mecanismos para compensação.

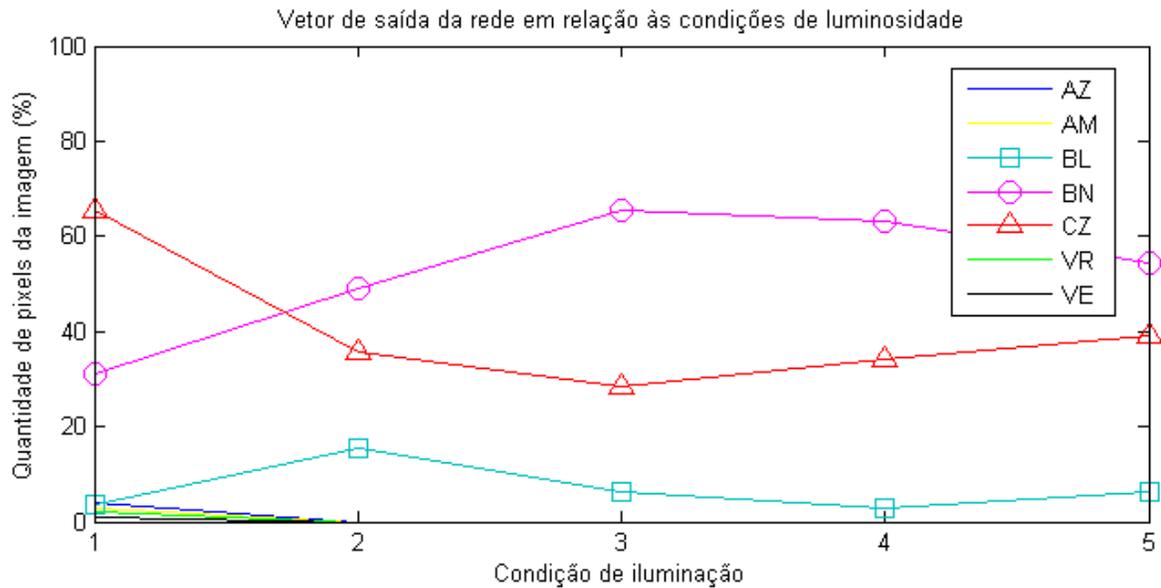


Figura 30 - Falta de estabilidade na porcentagem de pixels classificados como BN e CZ com base na variação das condições de iluminação de uma embalagem da classe Branca Leitosa. Fonte: o próprio autor.

## 7. CONCLUSÃO

Nas condições ideais de luminosidade o sistema apresenta resultados positivos e demonstram que a ferramenta possui a capacidade de realizar a classificação desejada. O sistema proposto apresenta as seguintes vantagens: *i)* modelagem do sistema simplificada, não sendo necessário definir muitos parâmetros ou regras; *ii)* rapidez no treinamento, em média 2 minutos para treinar a rede; *iii)* facilidade no treinamento e adição de novas classes; e *iv)* classificação realizada em média em 0,6 segundos para cada embalagem.

A caracterização da cor através do modelo HSL permitiu que as informações das cores presentes na imagem digital fossem representadas no meio computacional, viabilizando o processo de identificação da cor. Através da utilização do *software* Netica® permitiu a construção e treinamento da Rede Bayesiana utilizada neste trabalho. Através dos algoritmos escritos no programa Matlab® foi possível integrar as ferramentas de hardware e software necessárias para a execução do processo de classificação da cor predominante na embalagem.

Nos testes realizados, observou-se que o resultado final é semelhante ao resultado obtido com um modelo por Redes Neurais Artificiais, no entanto o diferencial deste método é a velocidade do treinamento da rede. Enquanto que para realizar o treinamento da Rede Neural Artificial o tempo médio gasto foi de 50 minutos, a Rede Bayesiana é treinada em aproximadamente 2 minutos, proporcionando um ganho computacional bastante elevado. Isso possibilitaria treinamentos para atualização em tempo real, durante a utilização do sistema em campo. A parametrização no treinamento e avaliação da Rede Bayesiana também é mais simples do que a Rede Neural Artificial, uma vez que necessita menos parâmetros para ser definida.

Apesar do resultado positivo na primeira avaliação, o sistema apresentou uma queda de desempenho na segunda. Detectou-se que as embalagens que não possuem a característica tonalidade relevante (Branca Leitosa, Branca Natural e Cinza) mostraram-se bastante sensíveis às variações das condições de luminosidade. Isso se deve ao fato da cor dessas embalagens possuírem apenas representação significativa através das componentes Saturação e Luminosidade.

A luminosidade é diretamente ligada com as condições de iluminação, pois define a quantidade de luz refletida ou emitida pelo objeto. Portanto, torna-se dependente dessas condições para manter a sua característica. Essa dependência fica evidenciada nos testes apresentados na Figura 29 e Figura 30. Para a embalagem Azul (Figura 29), a diminuição da intensidade luminosa não afetou a avaliação de forma significativa, pois a componente tonalidade manteve-se íntegra. Já a embalagem Branca Natural (Figura 30), que possui a sua cor (branca) representada pela saturação e luminosidade, e não possui valor de tonalidade relevante, acabou sendo interpretada como embalagem Cinza quando as condições de iluminação encontravam-se mais baixas.

Comparando os resultados da primeira avaliação com os resultados da segunda avaliação observou-se que o sistema é sensível a mudanças de luminosidade. Dessa forma o sistema apresenta as seguintes desvantagens: *i)* a aplicabilidade fica restrita a níveis mínimos de luminosidade para poder operar na sua capacidade ótima; e *ii)* dependência de um fundo contrastante para obter a imagem da embalagem.

Apesar das restrições o sistema apresenta resultados que motivam a aplicabilidade de um sistema completamente automatizado no segmento de classificação de embalagens de defensivos agrícolas, de forma que o contato dos operadores com a embalagem seja minimizado, sendo necessário apenas parametrizar as condições de iluminação durante a aplicação do sistema.

## **7.1. TRABALHOS FUTUROS**

O uso das Redes Bayesianas como agentes classificadores mostrou-se eficiente na área de classificação de cores. No entanto, o sistema ainda pode ser melhorado através de novas modelagens de sua estrutura gráfica. Uma técnica possível seria alimentar a Rede Bayesiana com todas as amostras de uma vez só, de forma que a inferência seja realizada com base no grupo de pixels informados e dessa forma se eliminaria a necessidade de verificar o vetor de saída e compará-lo a um vetor médio.

A principal dificuldade encontrada durante o desenvolvimento do sistema foi em relação às variações de luminosidade. Esse item pode ser corrigido através de um algoritmo de correção automático de luminosidade, utilizando para isso, uma imagem de referência obtida no treinamento. Dessa forma o sistema pode readequar via *software* às condições de iluminação da imagem. Para esse mesmo problema, também poderia ser implementado um sistema de controle automático de luminosidade do ambiente.

Também existem outros modelos de representação de imagens digitais. Esses modelos poderiam ser utilizados para verificar se é possível obter uma melhora no desempenho através da sua alteração, de forma que as informações sobre as cores das embalagens fiquem distribuídas de maneira que o processo de classificação seja beneficiado (MARTINKAUPPI *et al.*, 2001).

Outra modificação que poderia melhorar o desempenho do sistema é utilizar o cálculo de Distância Mahalanobis no sistema de classificação da cor da embalagem no lugar da Distância Euclidiana, de forma que a saída da rede seja comparada com vetores típicos de cada classe, levando em consideração a variância dos dados.

Em relação à Rede Bayesiana desenvolvida, ela pode ter sua capacidade de classificação de cores expandida ou alterada, de forma que verificações na resolução de problemas como: identificação da cor da pele na imagem (MASUTANI, 2013); identificação de cores em pixels de imagens digitais (BONVENTI & COSTA, 2000), no intuito de melhorar os resultados.

As dificuldades encontradas durante a classificação das embalagens do tipo Branco Leitoso, Branco Natural e Cinza, demonstram que a padronização de cores das embalagens dentro um padrão que favoreçam a sua discriminação, poderia facilitar o trabalho de classificação posterior, o que acabaria por beneficiar a própria indústria.

## REFERÊNCIAS

ADDCS. **Demonstrativo do material recolhido em 2012**. No prelo.

APPLE INC. **SIRI**. Disponível em: <<http://www.apple.com/ios/siri/>>. Acesso em: 01 jul. 2013

ALVES FILHO, J. P. **Uso de agrotóxicos no Brasil: controle social e interesses corporativos**. Annablume, Fapesp: São Paulo, 2002.

BAKSHI, A. P. G. U. A. Electron Devices. **Technical Publications**, 2008.

BAYER, B. **Color imaging array**. United States Patent. PN: 3.971.065, 20 jul. 1976.

BENGTSSON, E. **Digital cameras, CMOS and CCD sensors, Digital Imaging Systems**. Uppsala Universitet, 2008. Disponível em: <[http://www.cb.uu.se/~ewert/DIS\\_2008\\_CCD\\_CMOS.pdf](http://www.cb.uu.se/~ewert/DIS_2008_CCD_CMOS.pdf)>. Acesso em: 01 jul. 2013.

BIGATÃO, D. A. R. **Cuidados e Destinação Final de Embalagens, na Utilização de Agrotóxicos por Produtores Rurais no Município de Itaiporã – MS**. 85 f. Dissertação de mestrado em Ciência da Saúde, Universidade de Brasília, Brasília, 2009.

BONVENTI, W.; COSTA, A. H. R., Classificação de pixels de imagens coloridas digitais por lógica nebulosa. **Workshop de Computação – WORKCOMP'2000**. p. 67-72. ITA. 2000.

BRASIL. Decreto-lei n. 12.305, de 02 de agosto de 2010. **Diário Oficial [da República Federativa do Brasil]**, Brasília, DF, p. 2, 03 ago. 2010.

BSI BRASIL. **GHGEV – Verificação de Emissões de Gases de Efeito Estufa**. Disponível em: <[http://www.bsibrasil.com.br/certificacao/sistemas\\_gestao/normas/ghgev/](http://www.bsibrasil.com.br/certificacao/sistemas_gestao/normas/ghgev/)>. Acesso em: 01 jul. 2013.

BUTZKE, M.; SILVA, A. G.; HOUNSELL, M.; PILLON, M. Automatic Recognition of Vehicle Attributes - Color Classification and Logo Segmentation. **Hífen**, Uruguiana, v. 32, n.62, p. 293-300, 2008.

CASTLEMAN, K. R. **Digital image processing**. New Jersey: Prentice Hall, 1996.

CAMPOS, V. de O.; PACHECO, M. A. C.; FEITOSA, R. Q. Otimização de Classificador Fuzzy para Imagens de Sensoriamento remoto utilizando Algoritmos Genéticos. **ICA** – vol. 3, 2010.

CHARNIAK, E. Bayesian Networks without Tears. **AI Magazine**, v. 12, n. 4, p. 50-63, 1991.

COMMETI, J. L. S.; ALVES, I. T. G. Responsabilização Pós-Consumo e Logística Reversa: O Caso das Embalagens de Agrotóxico no Brasil. **Sustentabilidade em debate**. p. 13 - 24, 2010.

CONNOLY, J. W. **Color detection and separation method**. United States Patent. PN: 5.432.545, 11 jul. 1995.

DIAS, J. da S. **Raciocínio Médico e a Abordagem Bayesiana: um estudo de caso**. Tese de concurso de professor titular. Pontifícia Universidade Católica do Paraná, Curitiba, 2013.

FARIA, D. **Análise e Processamento de Imagens**. Trabalho prático do mestrado integrado em Engenharia Biomédica. Faculdade de Engenharia da Universidade do Porto, 44 f., Porto – Portugal, 2010.

FORLIN, F. J.; FARIA, J. A. F. Considerações Sobre a Reciclagem de Embalagens Plásticas. **Polímeros: Ciência e Tecnologia**, v. 12, n. 1, p. 1-10, 2002.

GONZALEZ R.C.; WOODS R.E., **Digital Image Processing**, Addison-Wesley Publishing Co., 1992.

HOLST, G. C.; LOMHEIM, T. S. **CMOS/CCD Sensors and Camera Systems, Second Edition**. J C D Publishing. 408 p, 2011.

INPEV. **Estatísticas**. Disponível em:  
<[http://www.inpev.org.br/destino\\_embalagens/estatisticas/br/teEstatisticas.asp](http://www.inpev.org.br/destino_embalagens/estatisticas/br/teEstatisticas.asp)>.  
Acesso em: 24 mar. 2013.

JAMES, C. **Global Status of Commercialized Biotech/GM Crops: 2010**. ISAAA Brief, n. 42. ISAAA: Ithaca, NY. 2011. Disponível em:  
<<http://www.isaaa.org/resources/publications/briefs/42/executivesummary/default.asp>>. Acesso em: 19 de out. 2011.

LAMB, T. D. Evolution of the Eye. **Scientific American**, v. 305, n. 1, p. 64-69, 2011.

LEITE, P. R. **Logística reversa: meio ambiente e competitividade**. São Paulo: Prentice Hall, 2003.

LIMA, D. L.; GALO, M. L. B. T.; IMAI, N. N. Aplicação do modelo de cores IHS na detecção de plantas aquáticas imersas. **Anais XII Simpósio Brasileiro de Sensoriamento Remoto**, Goiânia, Brasil, p. 4115–4122, 2005.

MAHALANOBIS, P. C. On the generalised distance in statistics. **Proceedings of the National Institute of Sciences of India** 2, p. 49–55, 1936.

MARTINKAUPPI, J. B.; SORIANO, M. N.; LAAKSONEN, M. H. **Behavior of Skin Color Under Varying Illumination Seen by Different Cameras at Different Color Spaces**. University of Oulu. Finland. 2001.

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

MASUTANI, V. H.; ARTERO, A. O.; ALMEIDA, L. L. de, ASSIS da SILVA, F. Reconhecimento de Objetos Coloridos e Mãos Usando Cores e Formas. **Colloquium Exactarum**, v. 5, n.1, p. 1–11, 2013.

MAX AMBIENTAL. **Carbono Neutro**. Disponível em: <<http://www.maxambiental.com.br/carbono.php>>. Acesso em: 01 jul. 2013.

MCCULLOCH, W.; PITTS, W. A Logical Calculus of Ideas Immanent in Nervous Activity. **Bulletin of Mathematical Biophysic**, v. 5, p.115-133, 1943.

MONTINI, D. A.; OLIVEIRA, M. A. de; MONTINI, A. A. Aplicação de Teste de Hipótese de Inferência de Redes Bayesianas pela Utilização da GQM em Sistemas de Informação. Franca: **FACEF PESQUISA**, v. 14, n. 3, p. 326-340, 2011.

MOURA, R. A.; BANZATO, J. M. **Embalagem, Unitização e Containerização**. 2 ed., Vol 3. São Paulo: IMAM, Séria Manual de Logística, 1997.

MURARO, C.; OLIVEIRA, F.; JUNIOR, J.; ROBERTO, M.; KONISI, P. A Tendência de Utilização de Embalagens Retornáveis em Indústrias – Um estudo exploratório no Brasil. **Jovens Pesquisadores**, v. 3, n. 5, p. 39-54, 2006.

NASCIMENTO JR., C. L.; YONEYAMA, T. **Inteligência Artificial em Controle e Automação**. São Paulo: Editora Edgard Blücher LTDA, FAPESP, 2004.

NAVEGA, S. C. Inteligência Artificial: Presente, Passado e Futuro. **INFOIMAGEM 2001**, Cenadem, 2001.

NILSSON, N. J. **Principles of Artificial Intelligence**. Morgan Kaufmann, 1986.

RABUSKE, R. A. **Inteligência Artificial**. Florianópolis: Editora da UFSC, 1995.

REZENDE, S. O.; PRATI, R. C. **Sistemas Inteligentes - Fundamentos e Aplicações**, Manole, 2003.

RICH, E. **Artificial Intelligence**. McGraw-Hill, 1983.

RUDEK, M.; COELHO, L. dos S.; JUNIOR, O. C. Visão Computacional Aplicada a Sistemas Produtivos: Fundamentos e Estudo de Caso. **Engep XXI**. 2001.

RUSSELL, S. J.; NORVIG, P. **Artificial Intelligence: A Modern Approach**. 2.ed. Upper Saddle River, New Jersey: **Prentice Hall**, 2003

SANTANA, A. L. de. **Projeto e implementação de um sistema de suporte à decisão para o observatório de saúde da Amazônia**. 62 f. Dissertação de mestrado em Engenharia Elétrica – Centro Tecnológico - Universidade Federal do Pará, Belém, 2005

SCHUBERT, E. F. **Light Emitting Diodes**. 2.ed. Cambridge University Press, 2006.

SHORTLIFFE, E.; PERREAULT, L. E. **Medical Informatics: Computer Applications in Health Care and Biomedicine**. 3.ed. New York: Springer, 2006.

SILVA, M. F. de O.; COSTA, L. M. A indústria de defensivos agrícolas. **BNDES Setorial**, v. 35, p. 233-276, 2012.

SILVA, R. L. de S. da. **Um modelo de redes bayesianas aplicado a sistema de realidade aumentada**. 117 f. Tese de doutorado (Engenharia Civil) – Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2006.

SIMÕES, P. W. T. de A. **SACI – Sistema de Apoio na Avaliação de Distúrbios do Crescimento Infantil**. 103 f. Dissertação de mestrado em Ciência da Computação – Universidade Federal de Santa Catarina, Florianópolis, 2001.

SIMÕES, A. da S.; COSTA, A. H. R. Classificação de laranjas baseada em padrões visuais. **VI SBAI**, p. 77-81, 2003.

TURING. A.M. Computing machinery and intelligence. **Mind**, v. 59, p. 433-460, 1950.

UMBAUGH, S. E. **Digital Imaging Processing and Analysis: Human and Computer Vision Applications With CVIPtools**. New York: CRC Press, 957p., 2010.

VASCONSELOS, V. V.; MARTINS JUNIOR, P. P. Protótipo de Sistema Especialista em Direito Ambiental para Auxílio à decisão em Situações de Desmatamento Rural. Belo Horizonte, **Fundação CETEC**, UFOP-EM-DEGEO, Nota Técnica NT-CRHA-27/2004.

WEEKS, A. JR. Fundamentals of Electronic Image Processing, SPIE/IEEE. Series on Imaging Science & Engineering, **IEEE PRESS**, 1996.

WILD, R.; MAURENTE, V.; MARASCHIN, C.; BIAZUS, M. C. "Coisas que as pessoas sabem": computação e territórios do senso comum. **Sci. stud.** [online]. 2011, vol.9, n.1, pp. 149-166. Disponível em: <[http://www.scielo.br/scielo.php?script=sci\\_arttext&pid=S1678-31662011000100008&lng=en&nrm=iso](http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1678-31662011000100008&lng=en&nrm=iso)>. ISSN 1678-3166. Acesso em 08/07/2013.

YOUNES, A.; TRUCK, I.; AKDAG, H. Color Image Profiling Using Fuzzy Sets. **Turkish Journal of Electric Engineering & Computer Sciences** – vol. 13, n. 3, p. 343-359, 2005.

YOUNDEN, W. J. Index for rating diagnostic tests. **Cancer**, vol. 3, p. 32-35, 1950.