Universidade de São Paulo
Instituto de Ciências Matemáticas e de Computação

Identificação dos sintomas de
ferrugem em áreas cultivadas com
cana-de-açúcar.

Desirée Nagliati Dias

Dissertação apresentada ao Instituto de Ciências Matemáticas e de Computação - ICMC-USP, como parte dos requisitos para a obtenção do título de Mestre em Ciências - Área de Ciências de Computação e Matemática Computacional.

USP - São Carlos
Janeiro/2004

Data de Depósito: 14.01.2004

Assinatura: _____

Universidade de São Paulo
Instituto de Ciências Matemáticas e de Computação

**Identificação dos sintomas de
ferrugem em áreas cultivadas com
cana-de-açúcar.**

Desirée Nagliati Dias

Orientador: Prof. Dr. João do Espírito Santo Batista Neto

Dissertação apresentada ao Instituto de Ciências Matemáticas e de Computação - ICMC-USP, como parte dos requisitos para a obtenção do título de Mestre em Ciências - Área de Ciências de Computação e Matemática Computacional.

USP - São Carlos
Janeiro/2004

AGRADECIMENTOS

A **DEUS** pela força nos momentos mais difíceis.

À **Minha Família**, pelo apoio e dedicação.

Ao meu orientador, **Prof. Dr. João Batista**, pela confiança depositada no meu trabalho.

Ao **Dr. Marcos Landell** e ao **Prof. Dr. Onofre**, por não medir esforços em ajudar. Ajuda indispensável sem a qual não seria possível o desenvolvimento deste trabalho.

Ao **Prof. Dr. André** e **Profa. Dra. Solange** pela ajuda no esclarecimento das dúvidas.

As secretárias da seção da pós, pela disposição e pela atenção sempre dedicadas.

As **amigas conquistadas Maria e Daniela**, que sempre tinham uma palavra de ânimo.

A **Usina Dedini** por disponibilizar as áreas para a coleta de dados.

À **CAPES** por financiar parte deste trabalho de mestrado.

E a todos os **colegas** que fiz durante estes dois anos, que me ajudaram tanto nas horas de dúvidas quanto com idéias para enriquecer o trabalho.

Certeza

De tudo, ficam três coisas:

- *A certeza de que estamos sempre começando...*
 - *A certeza de que precisamos continuar...*
- *A certeza de que quase sempre seremos interrompidos antes de terminar...*

Por tanto, devemos:

- *Fazer da interrupção um caminho novo...*
 - *Da queda, um passo de dança...*
 - *Do medo, uma escada...*
 - *Do sonho, uma ponte...*
 - *Da procura, um encontro...*

Anônimo

RESUMO

DIAS, D. N. (2004) **Identificação dos sintomas de ferrugem em áreas cultivadas com cana-de-açúcar**. São Carlos, 2004. 110p. Dissertação (Mestrado) – Instituto de Ciências Matemáticas e Computacional, Universidade de São Paulo.

Áreas cultivadas com cana-de-açúcar podem sofrer o ataque do fungo *Puccinia melanocephala* e variedades suscetíveis desenvolvem uma doença conhecida por ferrugem da cana-de-açúcar. Por afetar, geralmente, áreas imensas, os prejuízos são grandes. Atualmente, a avaliação da doença é feita por especialistas que percorrem as áreas plantadas analisando visualmente as folhas e atribuindo à região um determinado grau de infecção. Esse modelo pode ser considerado subjetivo pois, dependendo da experiência e acuidade visual do especialista, a avaliação de uma mesma área pode apresentar resultados divergentes. Diante desta situação, este trabalho apresenta uma abordagem para automatizar o processo de identificação e avaliação, criando alternativas para minimizar os prejuízos. Este trabalho apresenta um método para classificação dos níveis de infecção da ferrugem por meio da análise de imagens aéreas de canaviais, adquiridas por um aeromodelo. Dessas fotos são extraídas características baseadas nas cores, as quais são classificadas por meio de uma rede neural *backpropagation*. Além disso, foi implementado um método para segmentação de imagens digitais de folhas de cana-de-açúcar infectadas com o intuito de corroborar a avaliação manual feita por especialistas. Os resultados mostram que o método é eficaz na discriminação dos três níveis de infecção disponíveis, além disso, indicam que este pode ser igualmente eficiente na discriminação dos nove níveis de infecção da escala adotada.

Palavras-chave: extração de característica, cores, classificação por redes neurais, segmentação.

ABSTRACT

DIAS, D. N. (2004) **Identification of symptoms of rust in sugar cane plantations.** São Carlos, 2004. 110p. MSc Dissertation – Instituto de Ciências Matemáticas e Computacional, Universidade de São Paulo.

Cultivated areas of sugar cane may be targeted by the fungus *Puccinia melanocephala* and susceptible varieties may develop a disease known as sugar cane rust. Because the disease affects, in general, very large areas, the losses are very considerable. Currently, the evaluation of the disease is carried out by experts who must walk through the plantations analysing the leaves visually and assigning a certain degree of infection to the area. This model is somehow subjective because, due to experts' experience and visual acuity, the evaluation for a specific area may present divergent results. In face of this problem, this work presents an approach to automate the process of identification and evaluation of the disease, as a new means to minimise the losses. This work shows a method to classify the infection levels of sugar cane rust through the analysis of aerial images of sugar cane plantations, acquired by an aeromodel. From these pictures, some characteristics are based on colours are extracted and further classified by a Backpropagation Neural Network. Furthermore, it has been implemented a method for the segmentation of digital images of sugar cane leaves infected by rust. This is done to corroborate the manual evaluation done by experts. The results have shown that the method is capable of discriminating the three levels of infection available and they also indicate that it can also be equally efficient in the discrimination of the nine distinct infection levels of the adopted scale.

Key-words: feature extraction, colours, neural network classification, segmentation.

ÍNDICE

LISTA DE FIGURAS	III
LISTA DE TABELAS.....	VI
INTRODUÇÃO.....	1
CARACTERIZAÇÃO DO PROBLEMA	1
OBJETIVOS.....	2
ORGANIZAÇÃO DO TRABALHO.....	2
CAPÍTULO 01 – A FERRUGEM.....	4
1.1. INTRODUÇÃO	4
1.2. CARACTERIZAÇÃO DA DOENÇA	5
1.3. CONSIDERAÇÕES FINAIS.....	11
CAPÍTULO 02 – CORES E CARACTERÍSTICAS.....	12
2.1. CONSIDERAÇÕES INICIAIS.....	12
2.2. MODELOS DE CORES	14
2.2.1. Sistema RGB	14
2.2.2. Sistema CMYK	15
2.2.3. Sistema YIQ.....	17
2.2.4. Sistema HSV.....	18
2.2.5. Sistema L1L2L3 (Cor Invariante).....	20
2.3. CARACTERÍSTICAS DAS CORES.....	21
2.3.1. Histograma de Cores.....	22
2.3.2. Momentos das Cores	24
2.3.3. Cor Dominante.....	25
2.3.4. Histogramas Combinados.....	27
2.3.5. Vetor de Coerência de Cor.....	28
2.3.6. Correlogramas de Cores	31
2.4. CONSIDERAÇÕES FINAIS.....	33
CAPÍTULO 03 – TÉCNICAS PARA CLASSIFICAÇÃO E SEGMENTAÇÃO DA INFECÇÃO NA CANA	34
3.1. NOMENCLATURA	35
3.2. TIPOS DE APRENDIZADO.....	38
3.2.1. Metodologia de Avaliação dos Algoritmos de Aprendizado	39
3.3. REDES NEURAIS ARTIFICIAIS.....	42
3.4. SVM (SUPPORT VECTOR MACHINE).....	46
3.4.1. SVM's para conjuntos linearmente separáveis (margens rígidas).....	47
3.4.2. SVM's para conjuntos linearmente separáveis (margens suaves).....	48
3.4.3. SVM's não lineares.....	49
3.4.4. SVM's para várias classes.....	49
3.5. ÁRVORE DE DECISÃO	50
3.6. CLUSTERING.....	53

3.7.	SEGMENTAÇÃO	56
3.7.1.	<i>Métodos de Limiarização Desenvolvidos.....</i>	<i>61</i>
3.8.	CONSIDERAÇÕES FINAIS.....	61
CAPÍTULO 04 – METODOLOGIA DO EXPERIMENTO		63
4.1.	AQUISIÇÃO DAS IMAGENS.....	64
4.2.	MÉTODO MANUAL.....	67
4.3.	SEGMENTAÇÃO POR THRESHOLD (LIMARIZAÇÃO).....	69
4.4.	EXTRAÇÃO DE CARACTERÍSTICAS.....	69
4.5.	TREINAMENTO DA REDE NEURAL.....	71
CAPÍTULO 05 – RESULTADOS.....		74
5.1.	RESULTADOS DO MÉTODO MANUAL.....	74
5.2.	RESULTADOS DA SEGMENTAÇÃO POR LIMARIZAÇÃO	75
5.3.	RESULTADOS DA CLASSIFICAÇÃO POR REDE NEURAL.....	81
5.3.1.	<i>Classificação da foto inteira.....</i>	<i>83</i>
5.3.2.	<i>Classificação da foto com 1 região de interesse.....</i>	<i>85</i>
5.3.3.	<i>Classificação da foto com 10 regiões de interesse.....</i>	<i>88</i>
CAPÍTULO 06 – CONCLUSÕES E TRABALHOS FUTUROS.....		103
6.1.	CONCLUSÕES.....	103
6.2.	TRABALHOS FUTUROS.....	105
REFERÊNCIAS BIBLIOGRÁFICAS		107

LISTA DE FIGURAS

<i>Figura 1 – Visão lateral das fileiras de cana-de-açúcar, mostrando a formação da planta bem prejudicada (no centro) por causa da ferrugem.</i>	1
<i>Figura 2 – Origem e dispersão da ferrugem da cana-de-açúcar pelo mundo.</i>	5
<i>Figura 3 – Fotos aérea que mostram uma faixa do canavial afetada severamente pela ferrugem (variedade RB725828) em Capivari – 28/11/1986.</i>	5
<i>Figura 4 – À esquerda, sintomas da doença mostrando pústulas isoladas. À direita, detalhes das pústulas na face interior da folha (Copersucar, 1986).</i>	6
<i>Figura 5 – Dois exemplos de seções ampliadas com ataque da ferrugem nas folhas (Sanguino & Toledo, 1983).</i>	6
<i>Figura 6 – Evolução da ferrugem desde uma folha sadia (esquerda) até a necrosada (direita)(Copersucar, 1986).</i>	7
<i>Figura 7 – Folhas infectadas pela ferrugem.</i>	7
<i>Figura 8 – Aparência da cana no campo (Copersucar, 1986).</i>	9
<i>Figura 9 – Representação esquemática das notas de infecção de folhas da cana (Masuda et al., 1986).</i>	10
<i>Figura 10 – Escala de notas desenvolvida pela Copersucar(Amorim et al., 1987).</i>	10
<i>Figura 11 – Representação esquemática do sistema RGB (Foley & Dan, 1994).</i>	15
<i>Figura 12 – Relação entre as cores primárias e os pigmentos primários.</i>	16
<i>Figura 13 – Subtração das primárias (cyan, magenta e amarelo) e suas misturas(Foley & Dan, 1994).</i>	16
<i>Figura 14 – Esquema do sistema HSI.(Foley & Dan, 1994).</i>	18
<i>Figura 15 – Cubo RGB visto ao longo da diagonal principal, forma o espaço HSV (Foley & Dan, 1994).</i>	19
<i>Figura 16 – Aproximação geral da extração de características da cor da imagem, cada fase trás exemplos de métodos que podem ser utilizados (Smith & Chang, 1996).</i>	21
<i>Figura 17 – Histograma de Cores.</i>	22
<i>Figura 18 – Resultado de uma imagem depois da suavização pela média.</i>	29
<i>Figura 19 – Imagem depois de discretizadas as cores.</i>	29
<i>Figura 20 – Imagem depois de identificados seus componentes conectados.</i>	30
<i>Figura 21 – Temperatura de cores de diferentes fontes de luz (Yang, 2000).</i>	33
<i>Figura 22 – Principais passos para o reconhecimento de um padrão.</i>	35
<i>Figura 23 – Espaço de Características com suas funções discriminantes, cada espaço representa uma classes (cluster) diferente.</i>	36

<i>Figura 24 – Classificador estatístico.....</i>	<i>36</i>
<i>Figura 25 – Ilustração de classificação por distância mínima, onde um padrão apresentado é classificado de acordo com a menor distância entre ele e os pontos exemplos de cada classe.</i>	<i>37</i>
<i>Figura 26 – Hierarquia do aprendizado.....</i>	<i>38</i>
<i>Figura 27 – Deslocamento do hiperplano pelo Bias.....</i>	<i>43</i>
<i>Figura 28 – Ilustração de uma rede neural com 03 camadas.....</i>	<i>44</i>
<i>Figura 29 – Fases do BackPropagation.....</i>	<i>45</i>
<i>Figura 30 – Exemplo de conjunto de treinamento: (a) o caso mais simples; (c) caso mais complexo; (b) um caso intermediário (Lorena & Carvalho, 2002).</i>	<i>47</i>
<i>Figura 31 – Exemplo de uma separação de classes com margens rígidas.....</i>	<i>48</i>
<i>Figura 32 – A imagem ilustra uma classificação de uma SVM de margens suaves considerada em (a) correta, e em (b) uma classificação incorreta (padrões diferentes de um mesmo lado da margem)</i>	<i>48</i>
<i>Figura 33 – Transformação de um (a) conjunto de dados não linearmente separáveis para um (b) espaço de características.....</i>	<i>49</i>
<i>Figura 34 – Plotagem dos dados supostamente contidos no BD dos clientes da Instituição Bancária.....</i>	<i>50</i>
<i>Figura 35 – Árvore de Decisão depois de adicionado um nó de decisão.....</i>	<i>51</i>
<i>Figura 36 – Árvore de Decisão depois de adicionado dois nós de decisão.....</i>	<i>51</i>
<i>Figura 37 – Árvore com três nós de decisão.....</i>	<i>52</i>
<i>Figura 38 – Árvore de Decisão completa para o problema de classificação de clientes bons e clientes ruins.....</i>	<i>52</i>
<i>Figura 39 – (a) Tabela com a amostragem de 07 tipos de alimentos com suas quantidades de proteínas e gorduras; (b) A distribuição dos dados graficamente (Rao et al., 1996).....</i>	<i>54</i>
<i>Figura 40 – Resultado final do algoritmo k-means.....</i>	<i>55</i>
<i>Figura 41 – Exemplo de histograma bimodal.....</i>	<i>57</i>
<i>Figura 42 – Exemplo de Limiarização Adaptativa.....</i>	<i>57</i>
<i>Figura 43 – Comparação entre a escolha de um limiar de maneira supervisionada e não supervisionada, em (a) temos a distribuição de probabilidade dos objetos e do fundo; em (b) os histogramas correspondentes.....</i>	<i>58</i>
<i>Figura 44 – Ilustração do método P-Tile.....</i>	<i>59</i>
<i>Figura 45 – Esquema do projeto desenvolvido. À esquerda, das imagens aéreas do canalial foram extraídas as características das cores que foram classificadas pela rede neural. Ao centro, ilustra a avaliação feita in loco pelos especialistas. À direita, foto digitalizada das folhas avaliadas, que foram segmentadas.....</i>	<i>63</i>
<i>Figura 46 – Fotos de uma mesma região em momentos distintos. A foto da esquerda contém sombra enquanto a da direita está sob ação solar direta.....</i>	<i>64</i>

<i>Figura 47 – Este croqui ilustra o que seria a porção da plantação de cana rastreada, organizada em quadrantes. Os pontos indicam as áreas de sobrevôo do helicóptero para a captura das imagens e o número da foto feita naquela área.</i>	<i>65</i>
<i>Figura 48 – Mesma imagem mostrando a diferença entre os dados dos dois experimentos. À esquerda, a foto que foi digitalizada depois de ter sido revelada. À direita, a foto conseguida com a digitalização do negativo.</i>	<i>66</i>
<i>Figura 49 – Plotagem das notas de infecção de ferrugem nas folhas da cana-de-açúcar comparadas a uma função polinomial.</i>	<i>68</i>
<i>Figura 50 – Exemplo de seleção de 07 regiões de interesse (ROI's) de 16 x 16, a partir das quais foram extraídas as características.....</i>	<i>70</i>
<i>Figura 51 – Esquema de plotagem de histogramas, o histograma (a) representa uma região com nível de infecção 1, em (b) temos uma região de nível de infecção 2 e em (c) um região nível de infecção 7.</i>	<i>72</i>
<i>Figura 52 – Níveis de infecção atribuídos in loco pelos engenheiros do IAC aos diferentes quadrantes.....</i>	<i>74</i>
<i>Figura 53 – Imagem com baixa infecção, segundo o especialista (nível entre 1 e 2).</i>	<i>76</i>
<i>Figura 54 – Imagem com baixa infecção, segundo o especialista (nível 2).</i>	<i>76</i>
<i>Figura 55 – Imagem com média infecção, segundo o especialista (nível entre 4 e 5).</i>	<i>77</i>
<i>Figura 56 – Imagem com alta infecção, segundo o especialista (nível 7).</i>	<i>77</i>
<i>Figura 57 – Imagem com alta infecção, segundo o especialista (nível entre 7,5 e 8).</i>	<i>78</i>
<i>Figura 58 – Imagem com alta infecção, segundo o especialista (nível 8).</i>	<i>78</i>
<i>Figura 59 – Imagem com alta infecção, segundo o especialista (nível entre 8,5 e 8).</i>	<i>79</i>
<i>Figura 60 – Imagem com alta infecção, segundo o especialista (nível entre 8,5 e 9).</i>	<i>79</i>
<i>Figura 61 – Gráfico com a comparação entre as avaliações do especialista (linha escura) e as melhores conseguidas por meio da segmentação pelo desvio padrão e pelo método de Otsu (linha clara).</i>	<i>80</i>

LISTA DE TABELAS

<i>TABELA 1 – Tabela internacional para avaliação do grau de infecção de folhas de cana-de-açúcar por ferrugem(Copersucar, 1986; Masuda et al., 1986).</i>	9
<i>TABELA 2 – Tabela de componentes conectados.</i>	30
<i>TABELA 3 – Vetor de Coerência de Cor da imagem, onde a representa os pixels coerentes e b os pixels incoerentes. Assim, cada cor tem um par a e b.</i>	31
<i>TABELA 4 – Alguns parâmetros de estimadores segundo Monard (Monard & Baranauskas, 2003a).</i>	41
<i>TABELA 5 – Funções de ativação de uma rede neural.</i>	43
<i>TABELA 6 – Pontos escolhidos pelo algoritmo k-means.</i>	55
<i>TABELA 7 – Exemplos de arquivos e explicação de sua nomenclatura.</i>	66
<i>TABELA 8 – Exemplo de como é feita a avaliação de uma plantação de cana para se detectar o nível de infecção por ferrugem.</i>	67
<i>TABELA 9 – Comparação entre métodos de classificação.</i>	70
<i>TABELA 10 – Análise feita em diferentes intensidades de cores nos histogramas das imagens das folhas.</i>	81
<i>TABELA 11 – Resultados da média dos erros MSE, no experimento 01.</i>	82
<i>TABELA 12 – Resultados da média dos erros MSE, no experimento 02.</i>	82
<i>TABELA 13 – Teste com a imagem inteira no experimento 01 (digitalização das fotos).</i>	83
<i>TABELA 14 – Teste com a imagem inteira no experimento 02 (digitalização dos negativos).</i>	84
<i>TABELA 15 – Análise resultados da classificação da imagem inteira.</i>	84
<i>TABELA 16 – Resultado dos testes com somente uma região de interesse selecionada por foto. Experimento 01.</i>	85
<i>TABELA 17 – Resultado dos testes com somente uma região de interesse selecionada por foto. Experimento 02.</i>	86
<i>TABELA 18 – Análise dos resultados para a classificação de uma ROI por foto para os dois experimentos realizados.</i>	87
<i>TABELA 19 – Resultados conseguidos pela classificação do histograma no experimento 01 nível 7.</i>	89
<i>TABELA 20 – Resultados conseguidos pela classificação do histograma no experimento 01 nível 2.</i>	90
<i>TABELA 21 – Resultados conseguidos pela classificação do histograma no experimento 01 nível 1.</i>	91

<i>TABELA 22 – Resultados conseguidos pela classificação do histograma no experimento 02 nível 7.....</i>	<i>92</i>
<i>TABELA 23 – Resultados conseguidos pela classificação do histograma no experimento 02 nível 2.....</i>	<i>93</i>
<i>TABELA 24 – Resultados conseguidos pela classificação do histograma no experimento 02 nível 1.....</i>	<i>94</i>
<i>TABELA 25 – Resultados conseguidos pela classificação da cor invariante no experimento 01 nível 7.....</i>	<i>95</i>
<i>TABELA 26 – Resultados conseguidos pela classificação da cor invariante no experimento 01 nível 2.....</i>	<i>96</i>
<i>TABELA 27 – Resultados conseguidos pela classificação da cor invariante no experimento 01 nível 1.....</i>	<i>97</i>
<i>TABELA 28 – Resultados conseguidos pela classificação da cor invariante no experimento 02 nível 7.....</i>	<i>98</i>
<i>TABELA 29 – Resultados conseguidos pela classificação da cor invariante no experimento 02 nível 2.....</i>	<i>99</i>
<i>TABELA 30 – Resultados conseguidos pela classificação da cor invariante no experimento 02 nível 1.....</i>	<i>100</i>
<i>TABELA 31 – Análise dos resultados da classificação das dez ROI's nos dois experimentos.</i>	<i>101</i>

INTRODUÇÃO

CARACTERIZAÇÃO DO PROBLEMA

Um problema comum em plantações de cana-de-açúcar é a ferrugem, causada por um fungo conhecido como *Puccinia melanocephala*. Esta infecção acarreta prejuízos à cultura da cana-de-açúcar, podendo ser agrupados em dois fatores:

- Econômico: por se tratar de imensas áreas de plantações, a pulverização de fungicidas torna-se inviável. Assim, para a resolução do problema há a necessidade do uso de cultivares (variedades) mais resistente, pois a cultivar atacada tem sua produção muito prejudicada (*Figura 1*);
- Logístico: é necessário o deslocamento de técnicos ao campo para fazer o diagnóstico “*in loco*”, trabalho este muito cansativo e demorado. Por se tratar de um processo manual, pode trazer transtornos aos técnicos. Estes fatores impedem uma rápida identificação de áreas infectadas, prejudicando a adoção de estratégias de manejo que possam reduzir os níveis de infecção em tempo hábil.

Figura 1 – Visão lateral das fileiras de cana-de-açúcar, mostrando a formação da planta bem prejudicada (no centro) por causa da ferrugem.

OBJETIVOS

O objetivo desse trabalho é utilizar técnicas de análise de imagens, para extrair informações quantitativas de fotos aéreas coloridas de canaviais com presença de ferrugem em diferentes graus de infecção. Em posse desses valores, comparar com os dados obtidos de uma avaliação tradicional baseada na escala desenvolvida pela Copersucar (Amorim et al., 1987) (veja *Figura 10*) e identificar se há ou não correlação entre as medidas.

Para averiguar esta possível correlação o trabalho foi dividido em três partes. A primeira consiste em uma avaliação “*in loco*” feita por especialistas. A segunda consiste em extrair características das cores de fotos aéreas, por meio de algumas técnicas apresentadas no Capítulo 02 – Cores e Características, estas características alimentarão um rede neural *Back-Propagation* que será a responsável por fazer as classificações.

A terceira parte consiste em um processo de segmentação. Como a avaliação dos especialistas é por meio da análise visual das folhas, este é um método subjetivo, por isso as folhas analisadas foram fotografadas digitalmente e passaram por um processo de segmentação com o objetivo de confirmar a avaliação feita.

Havendo correlação, tal instrumento será (segundo os pesquisadores do Centro Avançado de Pesquisa Tecnológica do Agronegócio de Cana-de-Açúcar de Ribeirão Preto, ligado ao Instituto Agrônomo de Campinas da Secretaria da Agricultura e do Abastecimento do Estado de São Paulo) de grande valia no processo de diagnóstico uma vez que dispensaria a necessidade de um técnico *in loco*, além de permitir o monitoramento de áreas de plantio bastante amplas, contribuindo para diminuir os custos e o tempo na identificação da doença.

ORGANIZAÇÃO DO TRABALHO

Este trabalho está organizado da seguinte maneira:

No *Capítulo 01 (A Ferrugem)* são apresentados: a origem da doença e sua propagação ao redor do mundo. Seus sintomas e métodos de avaliação da doença no campo, e os prejuízos causados pela ferrugem na cana-de-açúcar.

No *Capítulo 02 (Cores e Características)* são definidos os sistemas de cores mais usados e alguns métodos de extração de características baseadas em cor, entre eles: Histograma de Cor, Momentos de Cores, Correlogramas de Cores.

No *Capítulo 03 (Técnicas para Classificação e Segmentação da Infecção na Cana)* são apresentados os tópicos relacionados à etapa de classificação, além de alguns tipos de aprendizado de máquina como: redes neurais (topologia *Back-Propagation*), SVM's, Árvores de Decisão, método de Clusterização *k-means*, e métodos de Segmentação (Limiarização).

No *Capítulo 04 (Metodologia do Experimento)* é apresentada toda a metodologia da pesquisa, o método usado para a aquisição das imagens aéreas, os usados para a extração das características bem como o processo desenvolvido para a obtenção dos resultados.

No *Capítulo 05 (Resultados)* são apresentados os resultados obtidos com os diferentes testes de classificação das imagens empregados na pesquisa. Para os testes foram empregadas diferentes abordagens.

Finalmente, o *Capítulo 06 (Conclusões e Trabalhos Futuros)* traz as conclusões e as diretrizes para o aprimoramento e expansão das técnicas empregadas na identificação da ferrugem.

CAPÍTULO 01 – A FERRUGEM

1.1. INTRODUÇÃO

A ferrugem da cana-de-açúcar é causada por fungo da classe dos Basidiomicetos, ordem Uredinales, gênero *Puccinia*. O primeiro registro da doença foi em 1890. Descoberta na ilha de Java, por Krüger, ocorrendo sobre espécies selvagens de *Saccharum*. Krüger classificou o agente causal como *Uromyces kuehnii*.

Em 1898, Walker & Went o reclassificaram como *Uredo kuehnii*, mas foi somente em 1918 que Butler, encontrando os teliosporos, o denominou *Puccinia kuehnii* (Masuda et al., 1986; Copersucar, 1986) até hoje não conhecida no continente Americano. Mas há também outro tipo de ferrugem a classificada como *Puccinia melanocephala*, que é uma das principais doenças da cana-de-açúcar (Asnaghi et al., 2000).

Na década de 40, a ferrugem foi constatada em quase todos os países produtores de cana-de-açúcar do continente asiático e africano, como a Índia, China e da África do Sul, sendo considerados os responsáveis pela disseminação do fungo para outras regiões da Ásia e África (Sanguino & Toledo, 1983). Na segunda metade da década de 70 a ferrugem da cana-de-açúcar causou epidemias em diversos países, como o Japão, Taiwan, Austrália e outros países da África (Masuda et al., 1986).

Nas Américas foi descoberta em 1978 na República Dominicana, espalhando-se rapidamente para a América do Norte e Central, Caribe e norte da América do Sul (Copersucar, 1986). A ferrugem foi relatada na Venezuela, Colômbia e Equador em 1979/1980 (Masuda et al., 1986). A Figura 2 ilustra a disseminação da ferrugem ao redor do globo ao longo dos anos.

Seu primeiro relato no Brasil foi em 26 de novembro de 1986, numa lavoura do Município de Capivari (SP), área canavieira tradicional, pelo técnico agrícola José Deodato Pereira de Campos, do Centro de Tecnologia da Cooperativa Central dos Produtores de Açúcar e Alcool do Estado de São Paulo (Copersucar), registrado no dia 28 como ilustram as

fotos na Figura 3. Em dezembro de 1986, foi constatada com menor intensidade em outra plantação próxima a Itapira (SP), a 15 km da fronteira com Minas Gerais (Blecher, 1986). O Planalsucar constatou a ferrugem em Porto Feliz, Santa Bárbara, Charqueada, Cosmópolis e Araras (SP) e outros focos no Estado do Paraná e em Itajaí (SC) (Masuda et al., 1986).

Figura 2 – Origem e dispersão da ferrugem da cana-de-açúcar pelo mundo (Masuda et al., 1986; Sanguino & Toledo, 1983).

*Figura 3 – Fotos aérea que mostram uma faixa do canavial afetada severamente pela ferrugem (variedade RB725828) em Capivari – 28/11/1986.
(Copersucar, 1986)*

1.2. CARACTERIZAÇÃO DA DOENÇA

Os sintomas se limitam às partes foliares da planta (Masuda et al., 1986; Silva et al., 2001). Inicialmente, são pequenas pontuações cloróticas, visíveis principalmente contra o sol.

Tais pontuações evoluem na forma de manchas alongadas de cor amarelo-pálida, visíveis em ambas as partes da folha. Medem de 2 a 10 mm de comprimento e 1 a 3 mm de largura. As lesões, ligeiramente em alto relevo (veja *Figura 4 e Figura 5*), aumentam rapidamente de tamanho adquirindo coloração avermelhada, podendo chegar a vermelho-parda e preta nos estágios finais (Copersucar, 1986; Masuda et al., 1986).

Figura 4 – À esquerda, sintomas da doença mostrando pústulas is oladas. À direita, detalhes das pústulas na face interior da folha (Copersucar, 1986).

Figura 5 – Dois exemplos de seções ampliadas com ataque da ferrugem nas folhas (Sanguino & Toledo, 1983).

A Figura 6 mostra a evolução da doença desde as folhas saudáveis até a necrosada. Normalmente as manchas são rodeadas por estreito halo de cor amarela. As pústulas, que são os uredosporos subepidérmicos, se rompem no centro das lesões, principalmente na fase inferior das folhas, deixando escapar os uredosporos de cor marrom, marrom-alaranjada ou marrom-avermelhada (Copersucar, 1986; Masuda et al., 1986) (*Figura 7*).

Figura 6 – Evolução da ferrugem desde uma folha sadia (esquerda) até a necrosada (direita)(Copersucar, 1986).

Figura 7 – Folhas infectadas pela ferrugem.

Em variedades bem suscetíveis estas pústulas reduzem a vida da folha que perdem a função fotossintética. A presença das pústulas resulta no crescimento reduzido da cana e perda de produção (Asnaghi et al., 2000; Masuda et al., 1986).

Disseminação e Controle

A disseminação se dá principalmente por meio do vento (Blecher, 1986), e em menor escala pela água (Copersucar, 1986; Masuda et al., 1986). O agente causal da ferrugem apresenta um desenvolvimento rápido em condições favoráveis de umidade (70%), temperatura (de 17-25°C) e variedades suscetíveis. A presença de água na superfície foliar (chuva, orvalho, etc) tem sido relatada como o fator ambiental primordial para a ocorrência de infecção, sendo a progressão da doença significativamente influenciada pelas condições ambientais. Sob condições ideais, a evolução das pústulas e produção de nova massa de inoculo completa-se dentro do curto período de 7 a 14 dias (Copersucar, 1986).

O controle químico é aplicado em países onde o clima não é tão propício à doença e as áreas de cultivo não são tão extensas, pois é altamente dispendioso e custoso. O principal meio de controle da doença é a substituição da variedade suscetível por uma variedade resistente.

Importância Econômica

A importância da ferrugem é tanto maior quanto maior for a suscetibilidade das variedades comerciais (Masuda et al., 1986). Os prejuízos causados pela doença se mostraram consideráveis em todos os países onde a ferrugem foi constatada (Ásia, África e América), determinando sempre a erradicação de variedade de alto valor comercial (Copersucar, 1986).

Os prejuízos são causados pela redução do desenvolvimento dos colmos (*veja Figura 1*), em consequência da alta infestação da doença nos primeiros meses de desenvolvimento da cultura (Copersucar, 1986). Na África do Sul, por exemplo, o prejuízo variou entre 20% (em solos férteis) a 50% (em solos marginais).

A doença afeta indistintamente a cana-planta (aquela que sofrerá o 1º corte) e a soca (aquela que sofrerá o 2º corte ou mais), que com a emissão de perfilhos tardios nas touceiras, afeta a qualidade da matéria prima.

Há recentes estudos sobre o prejuízo causado pela ferrugem na cana, como o do Dr. Marcelo Silva (Silva et al., 2001), pesquisador científico do Centro de Cana-de-Açúcar do Instituto Agrônomo. Seus estudos realizados em Jaú mostram que certas variedades podem chegar a ter uma quebra de 29,5% na produção.

Diagnóstico Tradicional

O diagnóstico da doença no campo, como visto na Figura 8, pode ser realizado por meio da observação de pústulas na página inferior da folha. Há testes que podem ser feitos para reconhecer a presença da doença. Um bem simples seria o de sentir a aspereza da página inferior da lâmina foliar. Outro é chamado “Teste do Lenço Branco”, que detecta a presença dos esporos liberados das pústulas, ao se passar um lenço branco na página inferior. Caso existam os esporos estes deixam manchas escuras (coloração marrom) no tecido. Este teste deve se feito com folhas de idade intermediária e evitando-se “folhas sujas” com terra (Copersucar, 1986).

Figura 8 – Aparência da cana no campo (Copersucar, 1986).

O canavial contaminado é avaliado *in loco* por técnicos, que dão uma “nota” segundo uma escala como a da TABELA 1. A tabela em questão corresponde à Escala Internacional utilizada para avaliação do nível de resistência da cana-de-açúcar à ferrugem (Masuda et al., 1986; Copersucar, 1986). Esta nota indica quão suscetível é a variedade à ferrugem de acordo com a percentagem da concentração das pústulas (Figura 9).

TABELA 1 – Tabela internacional para avaliação do grau de infecção de folhas de cana-de-açúcar por ferrugem (Copersucar, 1986; Masuda et al., 1986).

Nota	Características
(0)	Ausência completa de sintomas em qualquer estágio da cultura.
(1)	Até 5% da área foliar afetada. Ocorrência de manchas cloróticas, durante os primeiros quatro meses de desenvolvimento da cana-planta ou soca. Eventualmente, pode se associar ao sintoma acima, a ocorrência de pequeno número de manchas necróticas, localizadas principalmente no ápice das folhas.
(2)	Até 15% da área foliar afetada. Ocorrência de abundantes manchas cloróticas e poucas manchas nos primeiros quatro meses de desenvolvimento da cultura. As manchas necróticas e pústulas aparecem nas folhas mais velhas.
(3)	Até 30% da área foliar afetada. Ocorrência de abundantes manchas cloróticas, muitas das quais se necrosam nos primeiros quatro a cinco meses de idade. Presença de grandes manchas necróticas localizadas no ápice do limbo foliar. Afetam também as folhas médias e inferiores.
(4)	Mais de 30% da área foliar. Ocorrência de grande número de manchas necróticas que se unem formando amplas zonas de tecidos necrosado nas folhas médias e jovens. Amarelamento generalizado.

Figura 9 – Representação esquemática das notas de infecção de folhas da cana (Masuda et al., 1986).

Em 1981, outras propostas de avaliação da ferrugem por meio de escala diagramática foram feitas. Uma delas foi por Purdy e Dean (Amorim et al., 1987), com seis níveis de doenças distintos (1, 5, 10, 15, 25 e 50 % de área foliar atacada). Cujas avaliações são feitas no terço apical da folha, não distinguindo os tipos de lesões diferentes nem considerando necroses foliares. Outra avaliação foi a proposta por Tai e colaboradores (Amorim et al., 1987), que sugerem outros critérios de avaliação da ferrugem com uma escala maior de notas. Já a escala ilustrada na Figura 10, foi desenvolvida na Coordenadoria de Fitopatologia do Centro de Tecnologia Copersucar e leva em conta a concentração de manchas necróticas e pústulas na região foliar da planta (Amorim et al., 1987).

Figura 10 – Escala de notas desenvolvida pela Copersucar (Amorim et al., 1987).

1.3. CONSIDERAÇÕES FINAIS

A ferrugem da cana-de-açúcar é uma doença relativamente recente no Brasil, relatada pela primeira vez em 1986. Mesmo assim já tem causado inúmeros prejuízos, incentivando diversos estudos sobre o assunto e mecanismos de diagnóstico.

Em função de sua importância econômica, foram propostas algumas escalas de avaliação do nível de infecção. Neste trabalho foi adotada a proposta de diagnóstico baseada na Escala desenvolvida pela Coopersucar (*Figura 10*), que considera um número maior de níveis de infecção (9) que as demais escalas. Todos os resultados apresentados neste trabalho pelo método de identificação de ferrugem baseado em características de cores a partir de imagens digitais de plantações infectadas, utilizam a escala da Copersucar para fins de comparação.

O próximo capítulo descreve a importância da cor e algumas técnicas para a extração de características de cores que serão utilizados pelo processo de classificação de infecção de ferrugem.

CAPÍTULO 02 – CORES E CARACTERÍSTICAS

2.1. CONSIDERAÇÕES INICIAIS

A extração de características é um subsistema importante em muitos sistemas de visão (Sonka et al., 1999). Num sentido mais amplo, características podem ser aquelas baseadas na visão (cor, textura, forma, etc).

A abordagem para o problema de identificação do grau de ferrugem na cana-de-açúcar nos leva a crer que a característica predominante é a cor. A análise visual *in loco*, por exemplo, procura quantificar o percentual de infecção pela observação da presença de áreas avermelhadas ou mais escuras na superfície foliar verde (*Figura 3*). Assim, a identificação de ferrugem por imagens aéreas explorará a característica da cor.

O estudo das cores apresenta aplicações em inúmeras áreas, como, por exemplo, em reconhecimento facial (Sobottka & Pitas, 1996), recuperação de imagens em banco de dados de imagens (Yong et al., 1999) e aplicações em segmentação de imagens coloridas (Comaniciu & Meer, 1997).

Cor é uma das qualidades mais óbvias e penetrantes da percepção, que é um processo neural que depende do sistema visual e mudanças no sistema fisiológico afetam este processo (Goldstein, 1989). Cor não é uma coisa simples que pode ser facilmente descrita por alguém que nunca a tenha experimentado, por exemplo, uma pessoa cega. A cor não pode ser definida sem ser acompanhada por um exemplo, ela é um atributo de sensação visual que só existe devido a interação de três componentes: fonte de luz, objeto e o sistema de visão (Faiechild, 1998).

O primeiro componente é uma fonte de energia eletromagnética visível necessária para iniciar o processo sensorial de visão. A fonte de luz influencia na aparência da cor, pois a cor é a reflexão da luz sob a superfície do objeto. O segundo componente é um objeto, cuja propriedade é modular a energia eletromagnética. O terceiro componente é o sistema de visão

(humano). A energia modularizada é captada pelo olho, detectada por fotoreceptores, e processada pelo mecanismo neural do sistema visual produzindo a percepção da cor.

Uma aproximação para definir cor está no termo composição espectral, ondas contidas na luz. O que percebemos por diferenças de cores são bandas de frequência dentro de um espectro eletromagnético, e cada um desses diferentes valores de frequência corresponde a uma cor distinta (Hearn & Baker, 1994). A cor pode ser uma das características mais utilizadas pelas pessoas para o reconhecimento visual e descritivo. As pessoas têm a habilidade de usar diferentes níveis de cor em diferentes contextos. Por exemplo, uma maçã é sempre vermelha independentemente da matiz da cor, pois associar a maçã ao vermelho é um conceito pré-definido; já um carro pode ser vermelho, vermelho escuro ou até mesmo marrom, dependendo da pessoa que está extraindo a cor, pois o reconhecimento da cor depende da estrutura fisiológica do aparelho visual e depende também da interpretação da cor em questão (Goldstein, 1989). Já a extração da cor por computador independe do contexto (Smith & Chang, 1995).

A cor só existe na luz que é incolor aos olhos humanos. O que vemos colorido são superfícies que refletem uma quantidade específica de luz que incide nelas. As superfícies podem refletir cores diferentes se expostas a fontes de luz diferentes da branca. Sem a luz não pode haver cor (Rudolph et al., 1968).

Em segmentação, os mesmos paradigmas aplicados às imagens de tons de cinza (baseado em pixel/região ou contornos) são normalmente empregados em imagens coloridas. No entanto, é preciso considerar que imagens coloridas contêm informações da cena que técnicas exclusivamente voltadas para imagens monocromáticas não consideram. A diferenciação de uma região colorida sobre outra deve satisfazer um critério de uniformidade (homogeneidade) baseado em características derivadas de componentes espectrais. Estes componentes são definidos a partir de um modelo de cores pré-estabelecido. No caso de segmentação, esse processo pode ser refinado se considerarmos propriedades geométricas, por exemplo.

O enfoque deste trabalho não é a segmentação, mas sim a extração de características de cor e classificação das características entre uma das nove classes (1 a 9) ilustradas na Figura 10, apresentada no capítulo anterior. Com isso, poderemos estabelecer se há ou não uma correlação entre o processo manual e o desenvolvido.

As seções subseqüentes conterão tópicos como teoria de modelos de cores, métodos para medir a similaridade de imagens e características extraídas de cores que serão usadas na classificação.

2.2. MODELOS DE CORES

Um modelo de cor é uma especificação de um sistema de coordenadas de cores em 3D, onde é determinada uma gama de cores baseada em um pequeno conjunto de cores primárias. Há vários sistemas de cores. Três deles (RGB, YIQ, CMYK) são orientados por hardware, e não são muito intuitivos. Já o sistema HSV é um sistema intuitivo, orientado a usuário (Foley & Dan, 1994). A definição destes modelos é apresentada nas seções subseqüentes.

2.2.1. Sistema RBG

O sistema RBG é um dos mais conhecidos e é, principalmente, usado em monitores de vídeo do tipo CRT (Foley & Dan, 1994). É composto por três cores primárias *Red* (vermelho), *Green* (verde) e *Blue* (azul) que são misturadas para produzir uma cor resultante. É um modelo de cores aditivo, isto é, as cores são formadas pela adição das cores primárias e a soma das três cores resulta no branco.

É um sistema quantizado por números discretos e podem ser representado por um cubo (*Figura 11*), onde o R, G, B são os eixos do sistema de coordenadas cartesiano normalizado. Por exemplo, a cor amarela é representada por uma tripla (1,1,0). A diagonal do cubo, que possui igual quantidade de cada cor primária, representa os níveis de cinza, do preto (0,0,0) ao branco (1,1,1) (Gonzalez & Woods, 1992).

Figura 11 – Representação esquemática do sistema RGB (Foley & Van Dam, 1994).

2.2.2. Sistema CMYK

O modelo CMYK (*Cyan – Magenta – Yellow – Black*) é importante em dispositivos *hardcopy*, aqueles que depositam pigmentos coloridos sobre o papel, tal como um plotter eletroestático ou uma impressora a jato de tinta. É um esquema que combina pigmentos primários. O esquema de RGB é principalmente usado para exibições de computador, enquanto o modelo de CMYK é usado para imprimir ilustrações coloridas (*hardcopy*) (Techtarget, 2002).

Há uma diferença fundamental entre cor e pigmento. A cor representa energia radiada por um objeto luminoso como um tubo de raio de cátodo (CRT). Quando se vê uma área vermelha em um CRT, é porque ocorre a radiação de uma grande quantidade de luz na porção vermelha do espectro de radiação eletromagnético, ao redor 750 nanômetros, e muito menos de outros comprimentos de onda. Pigmentos, ao invés de cores, representam energia que não é absorvida por uma substância como tinta ou pintura. Às vezes o preto (K) também é considerado um pigmento primário, embora o preto pode ser obtido misturando-se em porções iguais o puro cyan, magenta, e amarelo. Quando se vê tinta amarela em uma página, é porque ocorre a absorção da maior parte da energia de todos os outros comprimentos de onda visíveis menos o da porção amarela do espectro (ao redor 600 nanômetros) que é refletida.

Os pigmentos primários e as cores primárias estão matematicamente relacionados. Qualquer combinação de duas cores primárias puras brilhantes (R, G, ou B), produz um pigmento primário puro não preto (C, M, ou Y). E quaisquer dois pigmentos primários puros e não pretos, quando misturados, produza uma cor primária pura. Estas relações são representados na Figura 12.

Figura 12 – Relação entre as cores primárias e os pigmentos primários.

Cyan (Cyan), *Magenta* (Magenta), *Yellow* (Amarelo) são os complementares de vermelho, verde e azul, respectivamente (Foley & Dan, 1994). Neste sistema, as cores são especificadas pelo que é subtraído ou removido de cor da luz branca como ilustrado na Figura 13.

Figura 13 – Subtração das primárias (cyan, magenta e amarelo) e suas misturas (Foley & Dan, 1994).

A cor cyan subtrai o vermelho da luz branca refletida e é, por sua vez, a soma de verde e azul. O mangenta subtrai o verde e é a mistura de vermelho e azul. O amarelo subtrai o azul e é a soma de vermelho e verde. A soma das cores resulta no preto. Assim, podemos definir este sistema como:

$$\begin{bmatrix} C \\ M \\ Y \end{bmatrix} = \begin{bmatrix} 1 \\ 1 \\ 1 \end{bmatrix} - \begin{bmatrix} R \\ G \\ B \end{bmatrix}$$

(1)

E a conversão de CMY para RGB é então:

$$\begin{bmatrix} R \\ G \\ B \end{bmatrix} = \begin{bmatrix} 1 \\ 1 \\ 1 \end{bmatrix} - \begin{bmatrix} C \\ M \\ Y \end{bmatrix} \quad (2)$$

2.2.3. Sistema YIQ

O sistema YIQ é usado nos EUA em comerciais de TV a cabo coloridas e há relação com o raster gráfico colorido (Foley & Dan, 1994). O sistema YIQ é usado para transmissões eficientes e para garantir a compatibilidade das TV's a cabo preto e branco com as coloridas. Nessa situação o sinal é transmitido usando o padrão *National Television System Committee (NTSC)* (Foley & Dan, 1994). O Y não significa amarelo, mas luminosidade. Somente a componente Y do sinal de TV colorida é mostrado nas TV preto e branco. A cromaticidade é encontrada em I e Q.

O sistema YIQ usa um sistema de Coordenadas Cartesiano, com o subconjunto visível sendo um poliedro convexo que mapeia o cubo RGB. O mapeamento de RGB para YIQ é (Foley & Dan, 1994; Skarbek & Koschan, 1994; Hearn & Baker, 1994):

$$\begin{bmatrix} Y \\ I \\ Q \end{bmatrix} = \begin{bmatrix} 0,299 & 0,587 & 0,114 \\ 0,596 & -0,275 & -0,321 \\ 0,212 & -0,528 & 0,311 \end{bmatrix} \cdot \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad (3)$$

A transformação do modelo YIQ para o modelo RGB é feita pelo inverso da matriz.

Especificações de cores no modelo YIQ resolve um problema: duas cores diferentes mostradas lado a lado em um monitor colorido podem parecer diferentes; mas, quando são convertidas para o sistema YIQ e visualizadas em um monitor monocromático, estas cores podem parecer a mesma. Para se evitar este problema, as cores devem ter diferentes valores de Y no modelo YIQ.

Este modelo tem duas propriedades importantes para o nosso sistema de visão (Foley & Dan, 1994):

– Este sistema é mais sensível às mudanças de luminosidade do que a matiz e saturação. Nossa habilidade de discriminar informações de cores espacialmente é melhor do que nossa habilidade de discriminar uma informação monocromática.

– Objetos que cobrem partes extremamente pequenas no nosso campo de visão produzem uma sensação limitada de cor que podem ser mais bem especificados em duas dimensões de cores.

2.2.4. Sistema HSV

No sistema HSV uma cor é representada por meio de sua matiz (*Hue*), saturação (*Saturation*) e brilho (*Value*), este sistema também é conhecido por HSI (*Intensity*). É um sistema intuitivo baseado na atração do artista pela tinta, sombra e tom (Foley & Dan, 1994). Este sistema é muito útil, pois a matiz e a saturação são intimamente relacionados à maneira pela qual o ser humano percebe a cor.

O sistema de coordenadas é cilíndrico, e o subconjunto dentro do qual o modelo é definido é um hexacone (Figura 14). O topo do hexacone corresponde a $V=1$, que contém o brilho relativo das cores. A matiz descreve a cor pura, a frequência dominante e é medida pelo ângulo ao redor do eixo vertical com o vermelho em 0° e o verde em 120° . As cores complementares do HSV são as que se encontram no lado oposto a 180° (Foley & Dan, 1994). A saturação dá a medida do grau que a pureza da cor é diluída na luz branca (Gonzalez & Woods, 1992), e corresponde ao raio que começa em 0 (sobre o eixo vertical) e se estende até 1 nos lados dos triângulos do hexacone. O brilho (*value*) é a intensidade da luz.

Figura 14 – Esquema do sistema HSI.(Foley & Dan, 1994)

O ponto ápice é o preto e tem uma coordenada $V=0$. Nessa situação, os valores de H e S são irrelevantes. O ponto $V=1$ e $S=0$ é o branco, variando o valor de V mantendo $S=0$, dá os tons de cinza. Quando $S=0$, o valor de H se torna irrelevante.

O topo do hexacone HSV corresponde à projeção que pode ser vista ao longo da diagonal principal do cubo RGB. A diagonal principal do espaço RGB, do preto ao branco, torna-se o eixo V no espaço HSV (*Figura 15*) (Foley & Dan, 1994).

Figura 15 – Cubo RGB visto ao longo da diagonal principal, forma o espaço HSV (Foley & Dan, 1994).

As transformações entre o sistema RGB e o sistema HSV são dadas, segundo Gonzalez (Gonzalez & Woods, 1992) por:

$$I = \frac{1}{3} (R + G + B) \quad (4)$$

$$S = 1 - \frac{3}{(R + G + B)} [\min(R, G, B)] \quad (5)$$

$$\Theta = \cos^{-1} \left\{ \frac{\frac{1}{2} [(R - G) + (R - B)]}{\left[(R - G)^2 + (R - B)(G - B) \right]^{\frac{1}{2}}} \right\}$$

$$H = \begin{cases} \Theta & , se G \geq B \\ 2\pi - \Theta & , caso contrário \end{cases} \quad (6)$$

Já segundo Sharbek (Skarbek & Koschan, 1994), as equações são:

$$I = \frac{(R + G + B)}{3} \quad (7)$$

$$S = 1 - \frac{\min(R, G, B)}{I} \quad (8)$$

$$H = \arctan'(\sqrt{3}(G - B), 2R - G - B) \quad (9)$$

onde o $\arctan'$ (x,y), dá o ângulo entre o eixo horizontal e a linha (0,0)-(x,y).

2.2.5. Sistema L1L2L3 (Cor Invariante)

Os espaços de cores podem ser divididos entre dois grupos: a) os que são uma transformação linear do espaço RGB, como o CMYK e o YIQ; b) os que não são uma transformação linear de RGB, como o HSV e o L1L2L3 (Martinkauppi et al., 2001).

Segundo o estudo proposto por Martinkauppi, a aparência da cor em uma imagem depende, entre outras coisas, da câmera, de sua calibração, e da iluminação sobre a qual a imagem foi obtida. L1L2L3 é um modelo de cores invariante a uma mudança substancial do ponto de vista, da geometria do objeto e da iluminação (Gevers & Smeulders, 1999).

Este espaço é representado por (Martinkauppi et al., 2001; Gevers & Smeulders, 1999):

$$l_1 = \frac{(R - G)^2}{(R - G)^2 + (R - B)^2 + (G - B)^2} \quad (10)$$

$$l_2 = \frac{(R - B)^2}{(R - G)^2 + (R - B)^2 + (G - B)^2} \quad (11)$$

$$l_3 = \frac{(G - B)^2}{(R - G)^2 + (R - B)^2 + (G - B)^2} \quad (12)$$

Este sistema de cores é importante no contexto deste trabalho, pois pode contribuir para minimizar a influência da iluminação do sol no processo de aquisição de fotos em ambientes externos.

2.3. CARACTERÍSTICAS DAS CORES

A extração de características de uma imagem pode ser vista como uma tarefa que envolve dois estágios (Smith & Chang, 1996) (*Figura 16*):

- 1 – Extração da região;
- 2 – Extração de propriedades da região.

Figura 16 – Aproximação geral da extração de características da cor da imagem, cada fase trás exemplos de métodos que podem ser utilizados (Smith & Chang, 1996).

Identificando-se as regiões da imagem, cada região pode ser caracterizada e representada por um conjunto de características.

Este trabalho concentra-se no segundo estágio. Como o enfoque não é o da segmentação, serão selecionadas, manualmente, regiões de interesses (ROI's) para posterior extração das características. A seguir, são apresentados vários métodos para a extração das propriedades da imagem ou de regiões baseados em cores.

2.3.1. Histograma de Cores

Histograma de cores é o método muito usado para medir a similaridade entre imagens. O histograma captura a distribuição global das cores na imagem, mas a informação espacial não é preservada, pois ele meramente descreve quais as cores presentes na imagem e sua frequência (Pass et al., 1996; Deng & Moore, 2001), por exemplo, uma grande bolha de cor vermelha em um fundo verde irá ter o mesmo histograma de cores de uma imagem que tenha o mesmo número de pixels distribuídos aleatoriamente (Deng & Moore, 2001), causando assim histogramas similares para imagem muito diferentes (Pass et al., 1996).

O histograma de cores é muito popular porque são trivialmente computados e invariantes a pequenos movimentos do objeto na imagem ou pequenas mudanças no ponto de vista (Pass & Zabih, 1999).

Mapeando-se as cores de uma imagem N para um espaço de cores discreto, têm-se n cores, então o histograma $H(N)$ é um vetor $(h_{c1}, h_{c2}, \dots, h_{cn})$, onde cada h_{ci} representa o número de pixels da cor ci na imagem N (Mahlmeister et al., 1996).

Genericamente, em uma imagem com N pixels tem-se:

$$\sum_{i=1}^n h_{ci} = N \quad (13)$$

Um histograma consiste de dois eixos de coordenadas particionados uniformemente com intervalos fixos. No eixo x são dispostas as cores e no eixo y a sua frequência (quantidade de pixels de cada uma das cores) (Figura 17).

Figura 17 – Histograma de Cores.

Histograma de cores é uma das formas bastante utilizadas na caracterização de cores. Ele esquematiza a frequência de cada cor na imagem (quantidade de pixels de cada cor). Estatisticamente, ele representa a probabilidade conjunta das intensidades dos três canais de cores. A diferenciação entre uma cor e outra via histograma de cor pode ser obtida por meio de medidas de similaridade. Algumas dessas são (Stricker & Orengo, 1995): métrica L_1 ; métrica L_2 que levam em consideração as similaridades entre cores parecidas, mas não necessariamente iguais.

A métrica L_1 , baseada na soma dos valores absolutos das diferenças entre dois histogramas H e I , é definida por:

$$d_{L_1}(H, I) = \sum_{j=1}^n |h_{cj} - i_{cj}| \quad (14)$$

A métrica L_2 , baseada na soma quadrática das diferenças entre dois histogramas H e I , é definida por:

$$d_{L_2}(H, I) = \sqrt{\sum_{j=1}^n |h_{cj} - i_{cj}|^2} \quad (15)$$

Uma variação vantajosa da abordagem de histogramas de cores tradicional é o cálculo do histograma acumulado (Stricker & Orengo, 1995), uma vez que os primeiros podem ser esparsos e sensíveis a ruídos.

Um histograma acumulado $\tilde{H}(N) = (\tilde{h}_{c1}, \tilde{h}_{c2}, \dots, \tilde{h}_{cn})$ de uma imagem N é definido nos termos da cor do histograma $H(N)$:

$$\tilde{h}_{cj} = \sum_{cl \leq cj} h_{cl} \quad (16)$$

onde $c_l < c_j$ se $r_l < r_j$, $g_l < g_j$, $b_l < b_j$.

Para determinar a similaridade entre histogramas acumulados usam-se as métricas L_1 (14), L_2 (15) ou L_∞ . A métrica L_∞ entre dois histogramas acumulados $\tilde{H}$ e $\tilde{I}$ com n pixels é dado por:

$$L_{\infty}(\tilde{H}, \tilde{I}) = \max_{i \leq j \leq n} \left| \tilde{h}_{cj} - \tilde{i}_{cj} \right| \quad (17)$$

A constância das cores é um fenômeno tipicamente definido como a aparente invariância na aparência da cor do objeto com mudanças na iluminação (Faiechild, 1998). A aparência da cor da superfície do objeto é fortemente afetada pela luminosidade, mas em um ambiente natural não é possível controlar a luz. Assim, uma pequena alteração na luminosidade afeta o histograma de cores (Mahlmeister et al., 1996). Essa variação na constância das cores deve-se às diferentes fontes de iluminação e apresenta-se como um problema considerável na restauração de imagens (Gevers & Smeulders, 1999).

2.3.2. Momentos das Cores

Os momentos das cores (Stricker & Orengo, 1995) são especialmente utilizados em recuperação de imagens em banco de dados, e minimizam os efeitos de quantização presente nos histogramas. A base matemática dessa abordagem é que qualquer distribuição de cor pode ser caracterizada pelo seu momento.

O momento da cor tem uma representação compacta, onde somente as características dominantes são armazenadas ao invés das distribuições completas da cor. Recentes estudos mostram que o momento da cor tem um desempenho pouco pior do que o histograma de cores de alta dimensionalidade. Uma desvantagem é que a média de todas as cores pode ser bastante diferente de algumas das imagens originais (Deng & Moore, 2001).

Os três Momentos da Cor são (Stricker & Orengo, 1995):

- média (*average*), que é definida por:

$$E_i = \frac{1}{N} \sum_{j=1}^N p_{ij} \quad (18)$$

onde N é o número de pixels da imagem, p_{ij} é o valor da i^{th} cor no j^{th} pixel.

- variância (*variance*), definida por:

$$s_i = \left(\frac{1}{N} \sum_{j=1}^N (p_{ij} - E_i)^2 \right)^{\frac{1}{2}} \quad (19)$$

- inclinação (*skewness*), definida por:

$$s_i = \left(\frac{1}{N} \sum_{j=1}^N (p_{ij} - E_i)^3 \right)^{\frac{1}{3}} \quad (20)$$

Sejam H e I as distribuições das cores de duas imagens com n cores. Se o índice entre estas imagens são E_i para a média de H e F_i para a média de I, s_i para a variância de H e V_i para a variância de I, s_i para a inclinação de H e t_i para a inclinação de I, então se defini a similaridade entre H e I como:

$$d_{mom}(H, I) = \sum_{i=1}^n w_{i1} |E_i - F_i| + w_{i2} |s_i - V_i| + w_{i3} |s_i - t_i| \quad (21)$$

onde $w_{ij} \geq 0$ são pesos definidos pelo usuário.

Os pesos podem ser usados como uma função de similaridade em uma dada aplicação. Por exemplo, se as imagens foram obtidas nas mesmas condições de luminosidade, então os pesos podem ser $w_1 > w_2$ e $w_1 > w_3$ de maneira a valorizar as mudanças na média da cor (Stricker & Orengo, 1995). Se as condições de iluminação forem diferentes para todas as imagens então, w_1 deve ter valores pequenos.

2.3.3. Cor Dominante

Cor dominante é uma característica proposta por Deng (Deng & Moore, 2001), baseada na observação de que um pequeno número de cores é geralmente suficiente para caracterizar a informação da cor em uma região da imagem, e que registra a cor e sua relativa distribuição na região.

A extração das características começa primeiramente com a segmentação. A clusterização por cores é aplicada sobre cada região segmentada para obter a cor

representativa (Deng & Moore, 2001). Depois, somente um pequeno número das principais cores tem suas porcentagens calculadas, formando assim um par de atributos que descreve as características da cor em uma dada região da imagem. A cor dominante $\mathbf{F}$ é definida por (Deng & Moore, 2001):

$$F = \{\{c_i, p_i\} \mid i = 1 \dots N\} \quad (22)$$

onde N é o número total de clusters de cores na região da imagem, c_i é um vetor de cor em 3D (R, G, B), p_i é a sua porcentagem, onde $\sum p_i = 1$.

A medida de similaridade é feita por meio da métrica L_2 (15). A diferença entre a cor dominante e o histograma de cores é que as cores representativas são computadas para cada imagem em vez de ser fixo no espaço de cor. A representação de cor dominante permite a visualização simples das distribuições de cor na imagem.

A similaridade de $F_1 = \{\{c_i, p_i\} \mid i = 1 \dots N_1\}$ e $F_2 = \{\{b_j, q_j\} \mid j = 1 \dots N_2\}$, que são duas discriminações de características de cor, é dada pelo cálculo da distância entre F_1 e F_2 (Deng & Moore, 2001):

$$D^2(F_1, F_2) = \sum_{i=1}^{N_1} p_i^2 + \sum_{j=1}^{N_2} q_j^2 + \sum_{i=1}^{N_1} \sum_{j=1}^{N_2} 2a_{i,j} p_i q_j \quad (23)$$

onde $a_{i,j}$ é o coeficiente de similaridade entre c_i e b_j ,

$$a_{i,j} = \begin{cases} 1 - \frac{d_{i,j}}{d_{\max}} & , \quad d_{i,j} \leq Td \\ 0 & , \quad d_{i,j} > Td \end{cases} \quad (24)$$

onde $d_{i,j}$ é a distância Euclidiana (25) entre c_i e b_j ; e Td é a distância máxima entre duas cores a serem consideradas similarmente. $d_{\max} = \alpha Td$.

A distância euclidiana entre dois pontos $p(x,y)$ e $q(s,t)$ é:

$$D_e(p, q) = \sqrt{(x-s)^2 + (y-t)^2} \quad (25)$$

O método de cor dominante foi testado por Deng (Deng & Moore, 2001) em um banco de dados de 2.500 imagens coloridas. Depois da segmentação, mais de 26.000 regiões foram obtidas. Os resultados foram comparados com o histograma de cores e se mostrou mais eficiente, recuperando um número bem maior de imagens.

2.3.4. Histogramas Combinados

Um histograma combinado, seleciona um conjunto de características locais dos pixels e constrói um histograma multidimensional. Cada entrada contém o número de pixels da imagem que são descritos por uma combinação particular de valores de características (Pass & Zabih, 1999).

Segundo Pass (Pass & Zabih, 1999) podemos descrever formalmente um histograma combinado como: dado um conjunto de k características, onde a l^{th} característica tem n_l possíveis valores, um histograma combinado é um vetor de k dimensões, tal que cada entrada contém o número de pixels na imagem que são descritos por uma k tupla de valores das características locais. O tamanho da combinação é

$$n = \prod_{l=1}^k n_l \quad (26)$$

possíveis combinações de valores para cada características.

As características locais podem ser (Pass & Zabih, 1999):

- *cor*: espaço RGB;
- *densidade das extremidades*: a densidade da extremidade de um pixel (j,k) é a razão das extremidades do pixels em uma pequena vizinhança ao redor do pixel;
- *texturização*: a texturização de um pixels (j,k) é o número de pixels vizinhos cuja intensidade difere mais do que um valor fixo;
- *magnitude do gradiente*: é uma medida de quão rapidamente a intensidade é mudada na direção da maior mudança;

- *rank*: o rank de um pixel (j,k) é definido como o número de pixels na vizinhança local cuja intensidade é menor do que a intensidade (j,k).

As combinações destas características podem produzir muitos histogramas combinados distintos. Como por exemplo:

Hist. Comb. 01- cor, densidade das extremidades

Hist. Comb. 02- cor, densidade das extremidades, texturização

Hist. Comb. 03- cor, densidade das extremidades, texturização, magnitude do gradiente

Hist. Comb. 04- cor, densidade das extremidades, texturização, magnitude do gradiente, rank

Os experimentos de Pass (Pass & Zabih, 1999), que comparavam histogramas de cores com histogramas combinados, foram feitos em um banco de dados com 210.000 imagens de vários formatos, das quais foram selecionados 52 pares de imagens que continham diferentes visões de uma mesma cena ou diferentes arranjos de uma mesma cena. Uma das imagens para a pesquisa e a outra para a resposta correta.

Para as 52 pesquisas realizadas, a porcentagem das respostas corretas achadas em um determinado escopo foi de 94% de acerto para os histogramas combinados e de 40% para os histogramas de cores. Um histograma combinado incorpora informações espaciais e suas medidas de similaridade são as mesmas do histograma de cores.

2.3.5. Vetor de Coerência de Cor

Pelo fato do histograma de cores não manter a informação espacial, Greg Pass (Pass et al., 1996), propôs o método do vetor de coerência de cor (CCV). Enquanto o histograma de cores contém o número de pixels de uma dada cor na imagem, um CCV mede a coerência espacial dos pixels com uma dada cor, isto é, se uma cor está presente em uma grande região da imagem, esta cor terá alta coerência, se sua frequência for baixa ela terá baixa coerência. Os pixels serão coerentes se fizerem parte de regiões coerentes, isto é, contíguas.

Segundo Pass demonstrou, o CCV pode ser usado para distinguir objetos que com o histograma de cores são indistinguíveis e que podem ter resultados superior ao histograma de cores em recuperação de imagens.

Os passos para se ter um CCV (Pass et al., 1996) são:

1º – Suavize ligeiramente a imagem, substituindo o valor do pixel pela média de uma pequena vizinhança local (08 pixel adjacentes), como ilustrado na Figura 18.

22	10	21	22	15	16
24	21	13	20	14	17
23	17	38	23	17	16
25	25	22	14	15	14
27	22	12	11	17	18
24	21	10	12	15	19

Figura 18 – Resultado de uma imagem depois da suavização pela média.

Discretize o espaço de cores de maneira a obter somente n cores distintas na imagem armazenadas em faixas (*buckets*). Cada faixa representa um intervalo de cores, por exemplo, a faixa 01 contém as intensidades de 10 a 19, a 2 de 20 a 29 e assim por diante. Este processo produz a imagem ilustrada na Figura 19.

2	1	2	2	1	1
2	2	1	2	1	1
2	1	3	2	1	1
2	2	2	1	1	1
2	2	1	1	1	1
2	2	1	1	1	1

Figura 19 – Imagem depois de discretizadas as cores.

2º – Classifique os pixels dentro de uma dada cor como coerente ou incoerente, determinando se o grupo ao qual o pixel pertence é um componente conectado. Um componente conectado $\mathbf{C}$ é um conjunto máximo de pixels tal que para quaisquer dois pixels, $p, p' \in \mathbf{C}$ há um caminho em $\mathbf{C}$ entre p e p' . Um caminho é uma seqüência de pixels $p=p_1, p_2, \dots, p_n=p'$, onde p_i e p_{i+1} são adjacentes.

Depois disto, cada pixel pertencerá a exatamente um dos componentes conectados e será coerente ou não dependendo do tamanho do componente. Estes componentes serão rotuladas por letras (A, B, ...). Este tamanho deve exceder a um valor τ , por exemplo, $\tau = 4$, gerando componentes conectados como visto na Figura 20.

```

B C B B A A
B B C B A A
B C D B A A
B B B A A A
B B A A A A
B B A A A A

```

Figura 20 – Imagem depois de identificados seus componentes conectados.

O número de pixels coerentes da j^{th} cor discretizada determina o a_j e o número de pixels incoerentes o b_j . Para cada cor tem-se um par (a_j, b_j) e o número total de pixels da cor j é $a_j + b_j$. O CCV de uma imagem é (Pass et al., 1996):

$$\langle (a_1, b_1), (a_2, b_2), \dots, (a_n, b_{n_l}) \rangle \quad (27)$$

onde n é o número de cores depois da discretização.

Para o exemplo acima, guarda-se em uma tabela (TABELA 2) a cor discretizada de cada letra e sua frequência. Das Figura 19 e Figura 20 temos:

TABELA 2 – Tabela de componentes conectados.

Letra	A	B	C	D
Cor	1	2	1	3
Frequência	17	15	3	1

As componentes A e B são maiores do que τ ($\tau = 4$ pixels) sendo então coerentes; e C e D são menores, portanto incoerentes.

Uma faixa pode conter somente pixels coerentes, por exemplo, a 02, ou somente incoerentes, a 03, ou uma mistura de ambos como a 01. O CCV para esta imagem seria:

TABELA 3 – Vetor de Coerência de Cor da imagem, onde α representa os pixels coerentes e β os pixels incoerentes. Assim, cada cor tem um par α e β .

Ccr	1	2	3
α	17	15	0
β	3	0	1

Se assumirmos que há três possíveis cores discretizadas (TABELA 3) o CCV pode ser escrito como:

$$< (17,3) , (15,0) , (0,1) >$$

Para a comparação de imagens, considere duas imagens I e I' . Seus CCV são G e G' , o número de pixels coerentes na faixa da cor j é a_j para I e a'_j para I' . Analogamente, a incoerência dos pixels é b_j e b'_j . A diferença entre I e I' é definida por:

$$\Delta_G = \sum_{j=1}^n \left| (a_j - a'_j) \right| + \left| (b_j - b'_j) \right| \quad (28)$$

cuja normalização é:

$$\Delta = \sum_{j=1}^n \left| \frac{a_j - a'_j}{a_j + a'_j + 1} \right| + \left| \frac{b_j - b'_j}{b_j + b'_j + 1} \right| \quad (29)$$

2.3.6. Correlogramas de Cores

O método de correlograma de cor foi proposto por Huang (Huang et al., 1997) e seu uso é voltado principalmente para a indexação e comparação de imagens. Ele guarda a correlação espacial da cor, é eficiente na recuperação e tolera grandes mudanças na aparência

e forma causadas pela mudança do ponto de visão. Suas propriedades são (Huang et al., 1997):

1 – inclui a correlação espacial das cores;

2 – pode ser usado para descrever a distribuição global com a correlação espacial local das cores;

3 – é fácil de processar;

4 – produz característica de tamanho razoavelmente pequeno.

Informalmente, um correbgrama de cores de uma imagem é uma tabela indexada por pares de cores, onde a k^{th} entrada para $\langle i, j \rangle$ especifica a probabilidade de achar o pixel de cor j a uma distância k de um pixel de cor i na imagem.

Dada uma imagem I de $n \times n$, o conjunto $\{1, 2, \dots, n\}$ é denotado por $[n]$, em m cores $c_1, c_2, \dots, c_m$, onde m é uma constante. Para o pixel $p = (x, y)$ $\hat{I} I, I(p)$ denota sua cor. Por conveniência usa-se a métrica L_∞ (17) para medir a distância entre pixels (Huang et al., 1997).

Para se definir um correlograma de cores, primeiro devemos definir uma distância $d \in [n]$. Assim, o correlograma de uma imagem I é definido por $i, j \in [m]$, $k \in [d]$, $[d]$ é o intervalo de distâncias possíveis, como:

$$g_{c_i, c_j}^{(k)}(I) \triangleq \Pr_{p_1 \in I_{c_i}, p_2 \in I} [p_2 \in I_{c_j} \mid |p_1 - p_2| = k] \quad (30)$$

Dado qualquer pixel de cor c_i na imagem, $g_{c_i, c_j}^{(k)}$ dá a probabilidade de encontrar um pixel de cor c_j , a uma distância k deste pixel de cor c_i . O tamanho do correlograma de cores é da ordem de $m^2 d$. O autocorrelograma (subconjunto do correlograma de cores e que requer espaço somente da ordem de md) de I captura a correlação espacial entre cores idênticas somente e é definido por:

$$a_c^{(k)}(I) \triangleq g_{c, c}^{(k)}(I) \quad (31)$$

A medida de similaridade usada pelo correlograma de cores é a métrica L_1 (14).

2.4. CONSIDERAÇÕES FINAIS

Como mostrado neste capítulo, a característica da cor, em qualquer dos métodos apresentados, é bastante suscetível a luminosidade no momento da aquisição. Essa variação da luminosidade no momento da aquisição está relacionada ao aspecto conhecido como temperatura da cor.

A temperatura da cor é uma das características da luz. A temperatura é medida em graus Kelvin, e descreve a relação entre o grau de calor aplicado sobre uma fonte luminosa e a cor especificada de luz gerada (Yang, 2000). A Figura 21 mostra a medida da temperatura de diferentes fontes de luz.

Figura 21 – Temperatura de cores de diferentes fontes de luz (Yang, 2000).

A temperatura da cor altera a cor da superfície do objeto. Um dos fatores dessa variação é a dificuldade em controlar a luminosidade no momento da aquisição das fotos, principalmente em cenas externas e aéreas, como é o caso deste projeto. Para minimizar este problema a aquisição deverá ser feita nos mesmos horários e com as mesmas condições de iluminação, tentando assim manter uma uniformidade da cor das imagens.

Adicionalmente, o Sistema L1L2L3 (Cor Invariante) (seção 2.2.5), poderá ser utilizado a fim de minimizar as distorções das características extraídas nos resultados dos classificadores apresentados no próximo capítulo.

CAPÍTULO 03 – TÉCNICAS PARA CLASSIFICAÇÃO E SEGMENTAÇÃO DA INFECÇÃO NA CANA

A classificação consiste em dividir, por meio de uma regra de decisão, um conjunto de objetos em grupos que possuam características comuns ou padrões (Gonzalez & Woods, 1992).

Uma forma de classificação é aquela baseada no princípio da distância mínima, onde são definidos M pontos no espaço de características $p_1, p_2, \dots, p_m$, que são representantes das classes $c_1, c_2, \dots, c_m$. Dado um padrão x ele pertencerá à classe que possuir a menor distância, de x ao ponto p_i (veja Figura 25).

Uma das propostas deste trabalho é a classificação de características extraídas a partir de imagens aéreas de canaviais em uma das 9 classes definidas na escala de ferrugem (Capítulo 01 - Figura 10).

Há duas abordagens para o aprendizado: não supervisionada, via algoritmos de *clustering* (Scheering, 1997; Medeiros & Carvalho, 2001), por exemplo, e supervisionada, tal como redes neurais (Haykin, 2001). Devido a sutil variação dos níveis de cores percebidos nas imagens aéreas, a autora acredita que tal sutileza poderia ser mais bem discriminada nos 9 níveis de infecção por um sistema supervisionado, como o de redes neurais.

As seções subseqüentes descrevem: a nomenclatura usada para classificações, tipos de aprendizado induzido, algumas técnicas de classificação, tais como Redes Neurais Artificiais, Clusterização, Máquinas de Vetor Suporte – SVM (*Support Vector Machine*) e Árvore de Decisão, bem como técnicas de segmentação baseadas em limiarização, e os métodos desenvolvidos para quantificar a área infectada por ferrugem nas folhas de cana-de-açúcar.

3.1. NOMENCLATURA

Classes (clusters) são conjuntos de objetos que foram divididos em subconjuntos distintos, mas que mantêm alguma característica em comum. A classificação é a atribuição, a partir do reconhecimento desta característica do objeto, a uma destas classes (Sonka et al., 1999).

No reconhecimento de padrões, dado um conjunto de propriedades elementares escolhidas de um objeto, estas propriedades são medidas baseadas na experiência e intuição, formando assim a descrição formal do padrão do objeto. Este padrão é detectado pelo classificador que o classifica em uma das classes possíveis, mas não o reconhece como objeto (Figura 22) (Sonka et al., 1999).

Figura 22 – Principais passos para o reconhecimento de um padrão.

As características de um objeto são compostas pelo conjunto de suas propriedades elementares. Um padrão é um conjunto (vetor) de n características que descrevem um objeto:

$$\mathbf{x} = (x_1, x_2, \dots, x_n) \quad (32)$$

O conjunto de todos os possíveis padrões é chamado de espaço de características. Uma ilustração de um conjunto de características e sua respectiva função discriminante é dada pela Figura 23.

Figura 23 – Espaço de Características com suas funções discriminantes, cada espaço representa uma classes (cluster) diferente. As classes formam clusters no espaço de características.

A Figura 23 mostra um espaço de características com classes linearmente separáveis, embora, no mundo real, isso raramente aconteça o que se torna um problema, pois as classes podem não ser classificadas corretamente (Sonka et al., 1999).

Há diferentes tipos de classificação como a classificação estatística e a por distância mínima. As classificações estatísticas normalmente utilizam n entradas (que são as quantidades de características do objeto a ser classificado) e produzem uma saída, como ilustra a Figura 24.

Figura 24 – Classificador estatístico.

O R-class é um classificador que generaliza as entradas em uma das possíveis saídas. A saída é interpretada como uma decisão de pertinência do objeto à classe. Estas classes são denotadas por w_r .

A regra de decisão divide o espaço de características em R subconjuntos distintos como ilustrado na Figura 23, e cada um destes subconjuntos inclui todas as características representadas no vetor x do objeto. As hiper superfícies são discriminadas por funções escalares, que são as funções de discriminação.

Na classificação por distância mínima, em cada classe é assumido um ponto exemplo que representa a classe. Esse ponto pode ser, por exemplo, a média dos padrões da classe. Um padrão é classificado como sendo pertencente a uma determinada classe, se a distância entre ele e o ponto exemplo for a menor de todas as outras classes (Sonka et al., 1999). A medida de distância pode ser, por exemplo, a euclidiana (25).

Figura 25 – Ilustração de classificação por distância mínima, onde um padrão apresentado é classificado de acordo com a menor distância entre ele e os pontos exemplos de cada classe.

A Figura 25 ilustra as distâncias $d1$, $d2$ e $d3$ entre o padrão apresentado (quadrado) e os pontos exemplos escolhidos para as classes 1, 2 e 3 respectivamente. No exemplo, o padrão apresentado será classificado no padrão 2, pois $d2$ é a menor distância dentre todas as outras.

3.2. TIPOS DE APRENDIZADO

O aprendizado indutivo é conseguido a partir do raciocínio sobre exemplos externos ao sistema de aprendizado. Há dois tipos de aprendizado indutivo (Monard & Baranauskas, 2003a): supervisionado e não-supervisionado (*Figura 26*).

O aprendizado supervisionado é um aprendizado por exemplos, onde cada exemplo é descrito por um vetor de características (ou atributos) e por um rótulo da classe associada. O aprendizado não-supervisionado é um aprendizado por observação e descoberta, com o objetivo de descobrir padrões significativos ou características nos dados de entrada sem o auxílio de um “professor” (Haykin, 2001).

Figura 26 – Hierarquia do aprendizado (Monard & Baranauskas, 2003a).

No aprendizado supervisionado, se o rótulo da classe possuir um valor contínuo, este é um problema de regressão, caso contrário se o rótulo for discreto, o problema é de classificação (Monard & Baranauskas, 2003a). Existem vários paradigmas que podem ser utilizados para resolver problemas de classificação, entre eles:

¹ PCA – (*Principal Components Analysis*) é um tipo de aprendizagem auto-organizada ou não supervisionada baseada no postulado de Hebb, por isso também é conhecida como aprendizagem hebbiana (Haykin, 2001).

- Redes Neurais: tipo de aprendizado estatístico ou conexionista;
- SVM's: tipo de aprendizado estatístico;
- Árvores de Decisão: tipo de aprendizado simbólico;
- Clustering: tipo de aprendizado hierárquico e não hierárquico (Sonka et al., 1999).

3.2.1. Metodologia de Avaliação dos Algoritmos de Aprendizado

Para um algoritmo de aprendizado (redes neurais, SVM's, árvore de decisão, etc) possuir uma boa generalização ele precisa ter um bom desempenho na classificação de dados que não foram utilizados durante o seu treinamento. Caso o algoritmo não apresente esse bom desempenho diante de novos dados, pode ter ocorrido uma situação chamada de *overfitting*. Esta situação ocorre quando a hipótese induzida pelo algoritmo de aprendizado se torna especializado nos dados de treinamento e não consegue ter bom desempenho quando são apresentados novos dados (Lorena & Carvalho, 2002). Para uma melhor generalização, o conjunto de dados deve ser dividido em três outros conjuntos:

- *Conjunto de treinamento*: usado para construir um modelo de hipótese induzida. O erro deste conjunto de dados é minimizado durante o treinamento;
- *Conjunto de validação*: para uma boa generalização do algoritmo de aprendizado, este conjunto é usado como um pseudo teste para melhorar a qualidade da rede durante o treinamento (Prechelt, 1994).
- *Conjunto de teste*: usado para avaliar o desempenho da hipótese induzida pelo algoritmo de aprendizado. Este conjunto é aplicado depois do treinamento.

Quando não se dispõe de uma partição exclusiva para teste, é necessário utilizar os próprios dados usados no treinamento para o teste. Neste caso, o erro é conhecido como erro de resubstituição (Monard & Baranauskas, 2003a).

É importante compreender o poder e as limitações dos diferentes algoritmos de aprendizado. Para isso existem algumas metodologias de avaliação, que permitem compará-

los. Alguns métodos capazes de testar o desempenho destes algoritmos são (Pereira, 2002; Monard & Baranauskas, 2003a):

k-Fold-Cross-Validation: o conjunto de dados com n exemplos é dividido aleatoriamente em k partições (*folds*) mutuamente exclusivas, de tamanho aproximadamente igual a n/k exemplos. Um exemplo quando selecionado não pode ser selecionado novamente (sem substituição). Os exemplos das $k-1$ partições são utilizados no treinamento de um algoritmo de aprendizado, o qual é testado pela partição restante. Este processo é repetido k vezes, utilizando em cada ciclo uma partição de teste diferente.

Stratified Cross-Validation: este é similar ao *k-fold-cross-validation*, mas ao gerar as partições mutuamente exclusivas, a distribuição das classes, que é a proporção de exemplos em cada uma delas, é considerada durante a coleta dos dados (Monard & Baranauskas, 2003a).

Leave-one-out: é uma forma particular do *k-fold-cross-validation*. O número de partições é fixado com o número de exemplos de treinamento. O processo é repetido n vezes, no qual n é o número de exemplos de treinamento (número de ciclos igual ao número de exemplos). Este método faz uso máximo dos dados, por isso é computacionalmente caro e frequentemente usado em amostras pequenas.

Holdout: é um método de estimativa que divide os exemplos em uma porcentagem fixa de exemplos p para o treinamento e $(1 - p)$ para o teste. Normalmente $p > 1/2$ e valores típicos são $p = 2/3$ dos exemplos para o conjunto de treinamento e $1/3$ para o conjunto de teste.

Para se estimar uma medida verdadeira destes métodos citados, pode-se utilizar as seguintes regras mostradas na TABELA 4, onde n representa o número de exemplos e k o

número de partições (*folds*) e p uma porcentagem de exemplos, tal que $0 < p < 1$ (Monard & Baranauskas, 2003a).

TABELA 4 – Alguns parâmetros de estimadores segundo Monard (Monard & Baranauskas, 2003a).

	<i>Leave-one-cut</i>	<i>k-fold-CV</i>	<i>k-fold-strat-CV</i>	<i>Holdout</i>
Treinamento	$n - 1$	$n(k-1)/k$	$n(n-1)/k$	pn
Teste	1	n/k	n/k	$(1 - p) n$
Iterações	n	k	k	1

A comparação do desempenho de cada tipo de algoritmo é feita por meio da medida do erro. Essa medida pode ser, por exemplo, o *Sum of Square Errors* - SSE (33), o *Mean Square Errors* - MSE (34) ou *Root Mean Square Error* - RMSE (35). Essas medidas se baseiam no cálculo do erro, dado pela diferença entre o resultado conseguido pelo algoritmo de aprendizado e o resultado esperado.

$$SSE = \sum_{p \in \text{padroes}} \sum_{j \in \text{saida}} (t_{pj} - o_{pj})^2 \quad (33)$$

onde t_{pj} é o resultado desejado e o_{pj} é o resultado obtido. O MSE é dado por:

$$MSE = \frac{SSE}{n - p} \quad (34)$$

onde SSE é a soma dos erros quadrados (33), n é o número de observações e p é o número de parâmetros a serem estimados. Já o RMSE é dado por:

$$RMSE = \sqrt{MSE} \quad (35)$$

Em problemas de classificação, para se estimar a taxa de erro pode-se usar, por exemplo, o método *k-Fold-Cross-Validation*. Suponha um $k = 10$, o conjunto de dados deve ser dividido em 10 partições de mesmo tamanho aproximadamente. A taxa de erro é calculada da seguinte maneira: separa-se uma das partições para teste e treina-se o algoritmo com as 9 restantes. A seguir, usa-se a partição isolada para a classificação e calcula-se a quantidade de exemplos classificados incorretamente. Esse valor é uma das medidas de erro. Repete-se este processo para as partições restantes. A taxa de erro final é a média e desvio padrão dos erros obtidos em cada uma das 10 partições. Assim o erro para uma nova classificação será o erro médio estimado mais ou menos o desvio padrão.

3.3. REDES NEURAIS ARTIFICIAIS

Redes Neurais Artificiais são sistemas inspirados nos neurônios biológicos e na estrutura massivamente paralela do cérebro, com capacidade de adquirir, armazenar e utilizar conhecimento experimental.

Uma importante característica de redes neurais é a habilidade de “aprender”, e a partir do seu ambiente e por meio de aprendizagem melhorar seu desempenho (Haykin, 2001), isto é, quanto melhor sua capacidade de generalização melhor terá sido seu aprendizado. Os elementos para uma rede neural artificial são:

Entradas – exemplos apresentados à rede para o treinamento, teste e uso;

Pesos Sinápticos – tem o efeito de inibição ou de excitação sobre a ativação dos sinais de entrada. Todo o “conhecimento” da rede se encontra nos pesos;

Função de Soma (net_j) – é o estado interno do neurônio j . Somatório das entradas pelos pesos associados mais o *bias*:

$$net_j = \sum_{i=1}^n x_i w_{ij} + bias \quad (36)$$

onde n é a quantidade de entradas da rede. Geometricamente as n entradas estabelecem a orientação do hiperplano (Gonzalez & Woods, 1992);

Bias - seu valor é sempre 01 (um). Ele representa o deslocamento do hiperplano com relação à origem (Gonzalez & Woods, 1992), como ilustrado na Figura 27. Com o *bias*, a rede sempre retorna uma solução e é um parâmetro externo ao neurônio (Haykin, 2001);

Figura 27 – Deslocamento do hiperplano pelo Bias.

Função de Ativação $F(net_j)$ – função que mapeia a saída da rede para um intervalo $[0,+1]$ ou $[-1,+1]$. Alguns destas funções são descritas na TABELA 5 (Haykin, 2001):

TABELA 5 – Funções de ativação de uma rede neural.

Limiar (ou Hard Limit) r	Pseudo-Linear	Sigmóide (logistic ou tanh)
$F(net)_j = \begin{cases} 1, & net_j \geq 0 \\ 0, & net_j < 0 \end{cases}$	$F(net)_j = \begin{cases} 1, & net_j \geq \frac{1}{2} \\ net_j, & -\frac{1}{2} < net_j < \frac{1}{2} \\ 0, & net_j \leq -\frac{1}{2} \end{cases}$	$F(net)_j = \frac{1}{1 + e^{-net_j}}$

A resposta do neurônio quando usada a função de ativação limiar é somente 0 ou 1, por isso esta função também é conhecida como função degrau, sendo usada para problemas

mais simples como a implementação da porta lógica AND. Já a função pseudo-limiar apresenta uma suavização, mas ainda é limitada. A função sigmóide tanh, cujo intervalo varia do $[-1, +1]$ é uma função de ativação simétrica e converge mais rápido do que a sigmóide logistic acelerando o treinamento, sendo assim uma das mais usadas.

O comportamento da rede dependerá da escolha da estrutura dos neurônios (topologia e valores das conexões). A Figura 28 ilustra um exemplo de rede *Multi Layer Perceptron BackPropagation* – MLP, que consiste de pelo menos 03 camadas: uma de entrada, uma ou mais intermediárias (ou escondidas) e uma de saída. É uma rede totalmente conectada (Haykin, 2001), isto é, todos os neurônios da camada anterior são conectados com todos os neurônios da próxima camada e não há ligação entre neurônios em uma mesma camada. Ela é usada geralmente para problemas não linearmente separáveis e não há realimentação. Esta rede é uma evolução da rede *Perceptron* que só resolvia problemas linearmente separáveis.

Figura 28 – Ilustração de uma rede neural com 03 camadas.

A rede MLP - *BackPropagation* foi proposta por Paul Werbos nos anos 70, mas só foi realmente explorada e utilizada em 1986 por Rumelhart e McClelland (Haykin, 2001; Allemang et al., 1990). É um método supervisionado e o aprendizado é por correção e propagação de erro. O erro é a diferença entre a saída esperada e a conseguida.

O algoritmo *BackPropagation* tem duas fases para cada exemplo (entrada) apresentado (Haykin, 2001) (Figura 29).

Figura 29 – Fases do BackPropagation.

Na fase de propagação (*FeedForward*): os sinais de entradas se propagam pela rede, da camada de entrada para a camada de saída. Cada neurônio apresenta um estado interno (*net*) calculado por meio da função de soma (*Figura 28*), que é o somatório de todas as entradas multiplicadas por seus respectivos pesos. Assim, o estado interno do neurônio *j* pode ser dado por:

$$net_j = \sum w_{ij} x_i \quad (37)$$

Calculado o estado interno do neurônio, aplica-se a função de ativação:

$$F(net_j) = \frac{1}{1 + e^{-net_j}} \quad F'(net_j) = \frac{e^{-net_j}}{[1 + e^{-net_j}]^2} \quad (38)$$

Na fase de retropropagação (*FeedBack*): os erros se propagam na direção contrária ao fluxo dos dados, indo da camada de saída até a primeira camada escondida.

Depois de conhecida a saída e calculado o erro, este é propagado no sentido contrário do fluxo dos dados. Quando o neurônio se encontra na camada de saída, aplicam-se as equações (39) e (40):

$$e_j = (t_j - s_j) F'(net_j) \quad (39)$$

onde e_j é o erro da rede, t_j é a saída esperada e s_j é a saída conseguida.

$$\Delta w_{ij} = \eta s_i e_j \quad (40)$$

onde Δ é a variação do peso, h e a taxa de aprendizado, s_j é a saída conseguida e e_j é o erro.

Se o neurônio se encontra nas camadas intermediárias (ou escondidas), usam-se as equações (41) e (42):

$$e_i = \left(\sum e_j w_{ij} \right) F'(net_j) \quad (41)$$

onde e_i é o erro da camada i, e_j é o erro da camada j (próxima) e w_{ij} é o peso de i para j.

$$\Delta w_{ij} = h s_i e_j \quad (42)$$

onde Δ é a variação do peso, h e a taxa de aprendizado, s_j é a saída conseguida e e_j é o erro.

3.4. SVM (SUPPORT VECTOR MACHINE)

As Máquinas de Vetores Suporte (*Support Vector Machines – SVM's*), foram propostas por Vapnik (Haykin, 2001) e constituem uma família de algoritmo de aprendizado bem eficientes em algumas tarefas como o reconhecimento de caracteres, detecção de faces em imagens e categorização de textos. As SVM's fundamentam-se em teorias estatísticas e possuem as seguintes características (Lorena & Carvalho, 2002):

- Boa capacidade de generalização: capacidade de ser eficiente na classificação de dados que não pertençam ao conjunto de treinamento;
- Robustez em grandes dimensões: comumente há ocorrência de *overfitting* em classificação de dados de grandes dimensões, como imagens;
- Convexidade da função objetivo: a aplicação das SVM's implica na otimização de uma função quadrática, que possui apenas um mínimo global, o que não ocorre nas redes neurais, em que há a presença de mínimos locais na função objetivo;
- Teoria matematicamente bem definida.

Seja o exemplo da Figura 30, onde há a necessidade de se encontrar um bom classificador que separe as classes. Para isso é natural a escolha da função que produza o menor erro durante o treinamento. Essa escolha se torna mais difícil à medida que se aumenta a dimensão da função escolhida. Quanto menor a dimensão, maior é sua capacidade de generalização.

Figura 30 – Exemplo de conjunto de treinamento: (a) o caso mais simples; (c) caso mais complexo; (b) um caso intermediário (Lorena & Carvalho, 2002).

A dimensão tem o papel de controlar a complexidade das funções (ou fronteiras de decisão) induzidas pelo algoritmo de aprendizado. Originalmente as SVM's são utilizadas para a classificação de dados em duas classes, mas podem ser utilizadas também em aplicações de mais classes. As SVM's podem ser: a) linearmente separáveis com margens rígidas; b) linearmente separáveis com margens suaves; c) não lineares e d) para várias classes. Estas 4 categorias serão descritas sucintamente a seguir.

3.4.1. SVM's para conjuntos linearmente separáveis (margens rígidas)

Para um conjunto de dados ser linearmente separável é necessário que exista um hiperplano que separe as diferentes classes. O responsável pela construção do melhor hiperplano para um problema, são as SVM's (Cavalheiro & Gomes, 2003). A menor distância entre este hiperplano e qualquer ponto do conjunto de treinamento chama-se margem de separação (γ). As SVM's lineares buscam construir um hiperplano que seja ótimo, isto é, cuja margens de separação seja máxima segundo as leis da estatística (Figura 31).

Figura 31 – Exemplo de uma separação de classes com margens rígidas (Haykin, 2001).

3.4.2. SVM's para conjuntos linearmente separáveis (margens suaves)

SVM's com margens suaves são separadores lineares de um conjunto não linearmente separável, que admitem a ocorrência de alguns erros de classificação por meio da introdução de variáveis de relaxamento. Isso é chamado de “suavização de margens”. Esse erro permitido está associado às margens que são controladas por parâmetros adicionais de treinamento (Braga et al., 2003). A margem de separação é dita suave se algum ponto dos dados violar a margem imposta pela SVM. Assim, ocorrem duas situações distintas: o ponto se encontra dentro da margem de separação e do lado correto da superfície de decisão, então a classificação é considerada correta; ou o ponto se encontra dentro da margem de separação mas do lado incorreto da superfície de decisão, e a classificação é considerada incorreta (Cavalheiro & Gomes, 2003) (Figura 32).

Figura 32 – A imagem ilustra uma classificação de uma SVM de margens suaves considerada em (a) correta, e em (b) uma classificação incorreta (padrões diferentes de um mesmo lado da margem) (Cavalheiro & Gomes, 2003; Haykin, 2001).

3.4.3. SVM's não lineares.

Existem conjuntos de dados que não podem ser separados por um hiperplano, como ilustra o exemplo da Figura 33. Neste caso, seria correto o uso de uma fronteira curva para a separação. Como isso não é possível, para as SVM's lineares, é necessário fazer um mapeamento do conjunto de treinamento para um novo espaço de maneira que se torne linearmente separável. Este novo espaço é denominado *espaço de características*.

As funções Φ que transformam os dados de entrada em um espaço de características devem pertencer a um domínio em que seja possível o cálculo e são usualmente denominados de *Kernels*. Os mais conhecidos são os polinomiais, os gaussianos ou RBF (*Radial-Basis Function*) e os sigmóides.

Figura 33 – Transformação de um (a) conjunto de dados não linearmente separáveis para um (b) espaço de características.

3.4.4. SVM's para várias classes

Embora as SVM's sejam a princípio empregadas para a classificação binária, há duas abordagens que podem ser usadas para a classificação de multi classes: a “um-contra-todos” e a “todos-contra-um”. Sendo k o número de classes, em “um-contra-todos” produz-se k classificadores, cada um separando uma classe i das $k-1$ restantes. No “todos-contra-um” são produzidos classificadores para a separação de cada classe i de outra j , onde i e $j = 1, 2, \dots, n$ e $i \neq j$.

3.5. ÁRVORE DE DECISÃO

As Árvores de Decisão são algoritmos pertencentes à família de algoritmos *Top Down Induction of Decision Trees – TDIDT*. Possuem estrutura de dados recursiva, onde os nós folhas (quadrados) correspondem a uma classe e os nós de decisão (elipses) contêm testes sobre algum atributo. A avaliação do teste produz uma classe ou uma sub-árvore (Monard & Baranauskas, 2003b). As árvores podem ter nós de incerteza, que são aqueles que dependem de fatores externos, como a probabilidade da ocorrência de uma determinada situação.

Árvore de Decisão é um tipo de aprendizado simbólico. Isto indica que os classificadores são legíveis e interpretáveis por humanos. É uma maneira gráfica de visualizar as consequências de decisões atuais e futuras bem como os eventos aleatórios relacionados e são normalmente construídas a partir da descrição de um problema.

No aprendizado simbólico são usadas linguagens de representação, que pode descrever exemplos, hipótese e conhecimento do domínio. Por generalidade, estes termos são referenciados como (Monard & Baranauskas, 2003b): Lógica de Ordem 0 ou Proposicional, Lógica de Atributos, Lógica de 1ª Ordem ou Lógica de 2ª Ordem.

Para ilustrar a construção de uma Árvore de Decisão e de suas regras considere o seguinte problema: Uma instituição bancária possui um Banco de Dados (BD) que contém as idades, renda mensal e uma classificação para o cliente (bom ou ruim) (Lopes, 2003). O problema consiste em como, baseado nos dados do BD, definir um perfil da qualidade de seus futuros clientes. Seja a Figura 34, onde tais informações são ilustradas graficamente.

Figura 34 – Plotagem dos dados supostamente contidos no BD dos clientes da Instituição Bancária.

Como o objetivo é determinar regras para a classificação de futuros clientes, há a necessidade de se separar os bons clientes dos clientes ruins. Assim, uma das separações seria a representada na Figura 35.

Figura 35 – Árvore de Decisão depois de adicionado um nó de decisão.

A separação (linha cinza) dos clientes com menos de 25 anos e com mais de 25 anos, possibilitou terminar uma regra de decisão (cliente com menos de 25 anos são clientes ruins), mas ainda não há uma separação efetiva dos clientes. O erro de classificação é alto, com 30 clientes ruins para 18 clientes bons. Por isso uma outra separação (nó de decisão) é necessária. A Figura 36 ilustra a Árvore com dois nós de decisão.

Figura 36 – Árvore de Decisão depois de adicionado dois nós de decisão.

Duas regras de decisão (linhas cinzas) que classificam clientes ruins já foram definidas: são clientes ruins os clientes com menos de 25 anos e os clientes com mais de 25

anos e com renda inferior a 2.000. Mas o erro ainda é alto, com 21 clientes ruins para 18 clientes bons. Um novo nó de decisão é então adicionado (*Figura 37*).

Figura 37 – Árvore com três nós de decisão.

O erro de classificação foi menor e foi possível definir mais uma regra de decisão (clientes com mais de 45 anos com renda superior a 2.000 são clientes ruins). No entanto, ainda é possível adicionar mais um nó de decisão para que com isso haja separação quase que completa entre os clientes bons e os ruins. Depois da inclusão deste quarto nó de decisão Árvore de Decisão fica completa (*Figura 38*).

Figura 38 – Árvore de Decisão completa para o problema de classificação de clientes bons e clientes ruins.

Como ilustrado na Figura 38, existem cinco nós folha, isto é, cinco possíveis classes. Portanto, existem cinco regras de decisão exclusivas e independentes umas das outras. Estas regras na Lógica de Atributos seriam:

1. **SE** Idade < 25 = Sim **ENTÃO** Cliente = Ruim.
2. **SE** Idade < 25 = Não **E** Renda > 2.000 = Não **ENTÃO** Cliente = Ruim.
3. **SE** Idade < 25 = Não **E** Renda > 2.000 = Sim **E** Idade > 45 = Sim **ENTÃO** Cliente = Ruim.
4. **SE** Idade < 25 = Não **E** Renda > 2.000 = Sim **E** Idade > 45 = Não **E** Renda > 5.000 = Sim **ENTÃO** Cliente = Ruim.
5. **SE** Idade < 25 = Não **E** Renda > 2.000 = Sim **E** Idade > 45 = Não **E** Renda > 5.000 = Não **ENTÃO** Cliente = Bom.

O sucesso para a construção de uma Árvore de Decisão depende do critério utilizado para a escolha o atributo que irá fazer a separação do conjunto de dados (linhas cinzas). Para esta escolha há algumas possibilidades (Monard & Baranauskas, 2003b), tais como: escolha aleatória, escolha do atributo de menor quantidade, escolha do atributo de maior quantidade e ganho máximo.

3.6. CLUSTERING

A clusterização é um dos possíveis métodos utilizados na segmentação de imagens coloridas (Scheering, 1997). Cada pixel (ou regiões de pixels) é representado por um vetor no espaço de cores. Os vetores formam clusters neste espaço segundo um critério de similaridade.

A análise dos clusters é uma técnica exploratória usada para descobrir a classificação natural da estrutura dos dados (Medeiros & Carvalho, 2001). Os métodos de clustering são divididos em duas categorias: hierárquica (aglomerativa baseada na ligação média) e não hierárquica (*k-means*).

O algoritmo *k-means* minimiza a medida de dispersão dentro dos conjuntos (Rao et al., 1996), como ilustra o exemplo da Figura 39, em que são amostrados 07 tipos de alimentos com suas respectivas proteínas (eixo x) e gorduras (eixo y) e sua disposição geométrica (Rao et al., 1996).

Figura 39 – (a) Tabela com a amostragem de 07 tipos de alimentos com suas quantidades de proteínas e gorduras; (b) A distribuição dos dados graficamente (Rao et al., 1996).

O algoritmo *k-means*:

1º – Seleciona os pontos mais distantes do gráfico. Estes pontos selecionados determinarão a quantidade de clusters deste conjunto. Neste exemplo entre os pontos dos alimentos 1 e 2, 1 e 3, 1 e 4, 1 e 5, 2 e 3, 2 e 4, 3 e 4 estão as maiores distâncias. Assim, os 04 pontos escolhidos (TABELA 6) resultam em 04 conjuntos que são:

TABELA 6 – Pontos escolhidos pelo algoritmo k-means.

Conjuntos	Qt. Proteínas (P)	Qt. Gorduras (G)
C ₁	1,1	60
C ₂	8,2	20
C ₃	4,2	35
C ₄	1,5	21

2º – Pegam-se os outros pontos que não foram escolhidos e fundem-nos com o conjunto mais próximo.

Assim o ponto 06 está mais próximo do ponto 01, então se pode fundi-los a um só conjunto dando origem ao conjunto C₁₆, onde a cenóide (centro) do conjunto é $P = (1,1 + 2,0)/2 = 1,55$ e $G = (60 + 55) / 2 = 57,50$. E assim sucessivamente com todos os pontos.

Ao final tem-se 04 conjuntos com 03 cenóides (Figura 40).

Figura 40 – Resultado final do algoritmo k-means.

3.7. SEGMENTAÇÃO

Segmentação de imagens é um processo que subdivide a imagem em regiões disjuntas, isto é, não há intersecção entre as regiões (Gonzalez & Woods, 1992; Marques & Vieira, 1999). A segmentação, que é um dos primeiros estágios na análise ou interpretação de uma imagem de maneira automática, é baseada em duas propriedades dos valores de níveis de cinza: descontinuidade e similaridade.

A técnica de segmentação pode ser classificada em dois grupos (Guelph, 2002):

- Não contextual: ignora a relação existente entre características da imagem, como por exemplo, o valor de intensidade do pixel;
- Contextual: explora a relação entre as características da imagem, como por exemplo o valor de intensidade do pixel e aproximação espacial dos pixels vizinhos.

Uma técnica de segmentação muito simples e muito usada por ter um custo computacional muito baixo é a Limiarização (*Thresholding*) (Guelph, 2002; Sonka et al., 1999). A limiarização é uma técnica simples e não contextual (Guelph, 2002) na qual uma imagem $f(x,y)$ tem seus pixels classificados em n regiões cuja soma resulta na imagem original, não havendo áreas de intersecção entre nenhuma região (Sonka et al., 1999). A limiarização pode ser visto como a transformação de uma imagem $f(x,y)$ em duas categorias de acordo com um limiar T , que gera uma imagem binária $g(x,y)$. Por isso este processo também é conhecido por binarização (Marques & Vieira, 1999).

$$\begin{aligned} g(x, y) &= 1 && \text{; se } f(x, y) \geq T \\ g(x, y) &= 0 && \text{; se } f(x, y) < T \end{aligned}$$

(43)

A limiarização pode ser supervisionada e não supervisionada. Algumas abordagens supervisionadas são:

Convencional: um limiar T é escolhido baseado na análise do histograma da imagem. Se uma imagem for bimodal, um excelente limiar é o que se encontra no “vale” formado (Marques & Vieira, 1999), como ilustra a Figura 41.

Figura 41 – Exemplo de histograma bimodal

Adaptativa: a imagem é dividida em n subimagens, de maneira que cada uma destas subimagens sejam bimodais. A seguir um limiar é escolhido para cada uma delas (veja Figura 42).

Figura 42 – Exemplo de Limiarização Adaptativa.

Por Banda: a limiarização por banda utiliza um intervalo D ao invés de um valor fixo de limiar, como observado na equação abaixo:

$$\begin{aligned} g(x, y) &= 1 && \text{; se } f(x, y) \in D \\ g(x, y) &= 0 && \text{; caso contrário} \end{aligned}$$

(44)

Multi-limiar: são usados limiares múltiplos (T_1 , T_2 , etc.), produzindo uma imagem com várias regiões ao invés de duas, por exemplo (Guelph, 2002):

$$\begin{aligned} \text{se } f(x, y) \geq T_2 & \quad \text{então } g(x, y) = 255 \quad \text{else} \\ \text{se } T_1 \leq f(x, y) < T_2 & \quad \text{então } g(x, y) = 128 \quad \text{else} \\ \text{se } f(x, y) < T_1 & \quad \text{então } g(x, y) = 0 \end{aligned}$$

(45)

Em muitas situações reais os histogramas não são perfeitamente bimodais, como ilustrado na Figura 43. Por isso, muitas vezes somente a análise do histograma da imagem não é suficiente para escolher um bom limiar, o que torna inviável o uso de um dos métodos supervisionados. Para esses casos, existem vários métodos automáticos ou não supervisionados para a escolha do limiar. A seguir serão apresentadas algumas destas abordagens.

Ótimo: o ponto escolhido é o que tem a mínima probabilidade entre dois máximos, resultando em erro mínimo na segmentação.

Figura 43 – Comparação entre a escolha de um limiar de maneira supervisionada e não supervisionada, em (a) temos a distribuição de probabilidade dos objetos e do fundo; em (b) os histogramas correspondentes.

P-Tile: este método requer que se conheça a área ou o tamanho do objeto presente na imagem, assim sabe-se que o objeto ocupa uma porcentagem p da imagem, e o limiar deve ser escolhido acima desta porcentagem (Figura 44);

Figura 44 – Ilustração do método P-Tile.

Otsu (Liao et al., 2001; Sonka et al., 1999): uma possível medida de homogeneidade entre regiões é a variância. Quanto menor a variância mais homogênea é a região. O melhor limiar será aquele, em que a variância for máxima. Para isto, deve-se calcular a probabilidade de um pixel ter intensidade i :

$$P(i) = \frac{n_i}{N} \quad (46)$$

onde, n_i é o número de pixels com intensidade i e N é o número total de pixels.

Depois de calculada a probabilidade de cada intensidade de cinza que varia de 1 a L , dividimos os pixels em duas classes: uma classe C_1 com a intensidade de nível de cinza variando de $[1, \dots, t]$; e uma classe C_2 variando de $[t + 1, \dots, L]$. Então, a probabilidade das distribuições do nível de cinza para duas classes é:

$$\begin{aligned} C_1 : & \frac{p_1}{w_1}, \dots, \frac{p_t}{w_1}; \\ C_2 : & \frac{p_{t+1}}{w_2}, \frac{p_{t+2}}{w_2}, \dots, \frac{p_L}{w_2}. \end{aligned} \quad (47)$$

onde,

$$w_1 = \sum_{i=1}^t p_i \quad \text{e} \quad w_2 = \sum_{i=t+1}^L p_i \quad (48)$$

A média das classes C_1 e C_2 é dada por:

$$m_1 = \sum_{i=1}^t i \frac{p_i}{w_1} \quad \text{e} \quad m_2 = \sum_{i=t+1}^L i \frac{p_i}{w_2} \quad (49)$$

A média da intensidade de toda a imagem m_T é dada por:

$$m_T = w_1 m_1 + w_2 m_2, \text{ com } w_1 + w_2 = 1 \quad (50)$$

O método Otsu define a variância entre duas classes como:

$$s^2 = w_1 (m_1 - m_T)^2 + w_2 (m_2 - m_T)^2 \quad (51)$$

Depois de calculada a variância de todas as possíveis divisões de classes da imagem, analisa-se as classes que apresentaram a maior variância, possivelmente, é onde se encontra o melhor limiar.

Iterativo: o limiar ótimo será baseado na intensidade média da imagem, assim um algoritmo para seleccionar um limiar iterativamente é (Guelph, 2002):

1. seleccionar um limiar inicial T_0 ;
2. particionar a imagem em duas classes C_1 e C_2 usando T_0 ;
3. calcular o valor médio da intensidade μ_1 e μ_2 das classes C_1 e C_2 como na equação 49;
4. seleccionar um novo limiar:

$$T_i = \frac{(m_1 + m_2)}{2} \quad (52)$$

5. repetir os passos 2-4 até que : $T_i = T_{i-1}$;

3.7.1. Métodos de Limiarização Desenvolvidos

Das técnicas apresentadas na seção anterior, a limiarização pelo método de Otsu apresentou bons resultados para imagens em que o nível de infecção é alto (nível 4 ou maior). No entanto, para baixos níveis de infecção (áreas reduzidas de ferrugem) fez-se necessário a implementação de outros métodos de limiarização.

Para este trabalho foram desenvolvidos dois métodos de limiarização. Um é baseado na medida da vizinhança e outro no desvio padrão dos canais de cores.

- *Método baseado na média da vizinhança* – Método semi-automático, onde o usuário seleciona na imagem (com o auxílio do mouse) cinco pontos infectados. Para cada ponto escolhido calcula-se a média dos 08 pixels vizinhos ao ponto. O limiar final corresponde ao valor médio das cinco medidas obtidas em cada um dos cinco pontos selecionados. As imagens usadas para este método são as obtidas separando-se somente o canal verde;

- *Método baseado no desvio padrão* – Método automático, onde se calcula, para cada pixel a média (53) e o desvio padrão (54) dos três canais de cores. A segmentação final é obtida comparando-se o desvio padrão com um limiar pré-estabelecido (55);

$$Média = (R + G + B)/3 \quad (53)$$

$$s = \sqrt{((R - média)^2 + (G - média)^2 + (B - média)^2)/3} \quad (54)$$

$$\begin{aligned} g(x, y) &= 1 \quad ; \text{ se } s(R, G, B) \geq 10 \\ g(x, y) &= 0 \quad ; \text{ se } s(R, G, B) < T \end{aligned} \quad (55)$$

3.8. CONSIDERAÇÕES FINAIS

O projeto consiste em analisar fotos aéreas de canaviais e tentar, por meio de processamento de imagem, identificar os diferentes níveis de infecção da ferrugem nas plantações, observando-se as diferenças da tonalidade de cores.

Como o grau de infecção corresponde a uma sutil diferença na tonalidade de cores, a autora optou pela implementação de uma rede neural *backpropagation* por acreditar que, sendo um método supervisionado, traria melhores resultados se comparados a métodos não supervisionados como, por exemplo, clustering. Esse fato foi posteriormente comprovado como ilustra a TABELA 8 do Capítulo 04 (Metodologia do Experimento).

Embora tenha sido cogitada a necessidade de se usar um método para a redução das características, como a PCA, isso não se mostrou necessário, já que foram extraídos muitos exemplos de poucas características de cada foto.

A metodologia empregada em todo o experimento será apresentada no próximo capítulo.

CAPÍTULO 04 – METODOLOGIA DO EXPERIMENTO

A proposta desta pesquisa é a identificação do grau de ferrugem da cana-de-açúcar por meio de imagens aéreas dos canaviais. Uma identificação rápida das áreas com ferrugem possibilita a adoção de estratégias de manejo capazes de reduzir os níveis de infecção.

Numa primeira etapa foi feita a aquisição de imagens, por um helicóptero (aeromodelo) do projeto ARARA do ICMC, sob orientação de pesquisadores do Centro Avançado de Cana de Ribeirão Preto.

Na segunda etapa deste projeto, foram implementados procedimentos de geração das características baseadas em cores, seguindo o modelo de cor RGB (seção 2.2.1). De posse destas características, realizou-se a classificação por uma rede neural *backpropagation* (seção 3.2). Os resultados obtidos neste processo foram comparados com a avaliação *in loco* feita pelo pesquisador Marcos Landell.

O trabalho desenvolvido pode ser resumido no esquema ilustrado na Figura 45.

Figura 45 – Esquema do projeto desenvolvido. À esquerda, das imagens aéreas do canavial foram extraídas as características das cores que foram classificadas pela rede neural. Ao centro, ilustra a avaliação feita *in loco* pelos especialistas. À direita, foto digitalizada das folhas avaliadas, que foram segmentadas.

Para o processamento e manipulação das imagens RGB, foi utilizado o programa LIZA (projeto Fapesp - Proc. N° 01/09807-7), cuja interface contém uma série de rotinas que proporcionam uma rápida implementação de técnicas em processamento de imagens e rotinas gráficas para manipulação de imagens RGB, indexadas e em tons de cinza.

4.1. AQUISIÇÃO DAS IMAGENS

As imagens foram coletadas pelo helicóptero do projeto ARARA (em desenvolvimento no ICMC – USP – São Carlos) sob supervisão do Prof. Onofre, que consiste de um aeromodelo guiado por controle remoto, no qual está embutido, dentre outros dispositivos eletrônicos, uma câmera fotográfica química e uma câmera de vídeo. Esta segunda permite, inclusive, vôos sem contato visual com o aeromodelo, pois as imagens são transmitidas em tempo real para um monitor junto ao piloto da aeronave. Isso garante o rastreamento de plantações vastas de cana ou que estejam em terreno muito irregular.

As fotos foram adquiridas na Usina Denini Açúcar e Alcool, na Fazenda São João, município de Vargem Grande do Sul/SP, em 13/06/2003. O responsável pela fazenda, o Eng. Agr. João Celso F. Nogueira, foi quem selecionou a área juntamente com o Dr. Marcos Landell e o Eng. Agr. Antonio Carlos Vasconcelos, especialistas em cana-de-açúcar do Centro Avançado de Cana de Ribeirão Preto. Desse canavial foram diagnosticados três níveis de infecção.

Figura 46 – Fotos de uma mesma região em momentos distintos. A foto da esquerda contém sombra enquanto a da direita está sob ação solar direta.

Um aspecto que certamente influenciou a interpretação dos resultados é a temperatura da cor (veja Capítulo 2 - Figura 21). Variações na luz solar incidente geram imagens com diferentes graduações na cor, isto é, cores com maiores ou menores intensidades. A presença de nuvens gerou imagens com tonalidades de cores diferenciadas se comparadas com a mesma cena fotografada sem a presença das mesmas (Figura 46).

No entanto, o problema da normalização ou correção da cor é ainda um dos tópicos sem definição clara em sistemas de visão, não havendo métodos suficientemente sólidos para aplicarmos. Não obstante, uma das características implementadas (*Sistema L1L2L3 – seção 2.2.5*) tenta minimizar este efeito e foi utilizada nos experimentos. Para minimizar grandes distorções na interpretação dos dados em função das condições de luz no momento da aquisição, tivemos o cuidado de realizar a sessão de fotos no mesmo horário, por volta das 14h50. Além disto, as fotos que por ventura continham sombreamento (Figura 46) não foram consideradas nos experimentos. Foram adquiridas 49 fotos aéreas, sendo 25 do lado direito e 24 do lado esquerdo. A coleta das imagens obedeceu ao croqui da Figura 47. Cada ponto corresponde às áreas capturadas em imagem e a seqüência de números acima de cada ponto é o número da foto feita naquela área.

Figura 47 – Este croqui ilustra o que seria a porção da plantação de cana rastreada, organizada em quadrantes. Os pontos indicam as áreas de sobrevôo do helicóptero para a captura das imagens e o número da foto feita naquela área.

Das 49 fotos reveladas, foram utilizadas 36, pois 13 foram afetadas pelas condições ambientais de iluminação. As 36 fotos restantes foram digitalizadas, formando assim os dados que compõem o Experimento 01. Como houve, aparentemente uma normalização das cores no processo de revelação das fotos, os negativos também foram digitalizados compondo assim os dados que formam o Experimento 02. Essa separação entre experimentos 01 e 02 foi feita pela visível diferença perceptível das imagens como pode ser observado na Figura 48.

Figura 48 – Mesma imagem mostrando a diferença entre os dados dos dois experimentos. À esquerda, a foto que foi digitalizada depois de ter sido revelada. À direita, a foto conseguida com a digitalização do negativo.

Os arquivos (imagens), correspondentes às fotos digitalizadas, utilizados neste trabalho obedecem à seguinte notação: **Nr_TIPOS_NivNNLD.jpg**. Onde, Nr é o número da foto que varia de 1 a 25 no lado direito e de 1 a 24 no lado esquerdo; TIPOS representa a variedade de cana; NN é o grau de infecção; e LD o lado: direita (dr) ou esquerda(es). A TABELA 7 descreve 3 possíveis nomes de arquivos.

TABELA 7 – Exemplos de arquivos e explicação de sua nomenclatura.

Nome do arquivo	Descrição
24_RB486_Niv07dr.jpg	Este arquivo representa a foto número 24 da variedade RB835486, de nível de infecção 7, tirada do lado direito do campo (<i>Figura 47</i>).
10_RB6-5Niv2_5es.jpg	Este arquivo representa a foto número 10, tirada da parte intermediária entre as variedades RB835486 e RB867515, avaliada em nível 2 a 2,5 do lado esquerdo do campo.
19_RB515Niv1_5es.jpg	Este arquivo representa a foto número 19 da variedade RB867515, avaliada de nível 1 a 1,5 do lado esquerdo.

4.2. MÉTODO MANUAL

Junto com a aquisição das fotos foi feita uma análise *in loco*. Foram selecionadas várias folhas aleatoriamente, as quais foram fotografadas digitalmente e avaliadas pelos pesquisadores do IAC por meio do método tradicional seguindo a escala da Copersucar (veja Capítulo 01 - Figura 10).

Esta avaliação se dá da seguinte forma: cada engenheiro avalia áreas distintas de uma região da plantação, atribuindo notas. Depois disto, é feita uma média aritmética das notas atribuídas por todos os avaliadores, obtendo-se a nota geral da plantação. Um exemplo hipotético deste tipo de avaliação é apresentado na TABELA 8, onde 08 avaliadores (A, B, ..., H) avaliam 02 variedades.

TABELA 8 – Exemplo hipotético de como é feita a avaliação de uma plantação de cana para se detectar o nível de infecção por ferrugem.

Variedade	Notas dos Avaliadores								Média de oito avaliadores
	A	B	C	D	E	F	G	H	Nota da Plantação
Variedade 01	2	2	2	2	3	2	3	2	2,25
Variedade 02	5	4	4	5	5	4	5	5	4,62

Diante da plotagem das notas e suas respectivas porcentagens de infecção da escala da Copersucar, foi desenvolvido um método de aproximação para se estimar a porcentagem de área afetada.

A curva de infecção da ferrugem, segundo a classificação da Copersucar (Figura 10), é apresentada na Figura 49 (curva mais clara, pontuada). A curva mais escura (sem pontos) é uma aproximação com erro pequeno e aceitável, e corresponde à função polinomial $y = 1.3839x^2 - 5.3185x + 4.4554$.

Figura 49 – Plotagem das notas de infecção de ferrugem nas folhas da cana-de-açúcar comparadas a uma função polinomial.

A função polinomial aproximada da curva de infecção contém uma parte, que se a nota obtida pela avaliação (TABELA 8) estivesse entre suas raízes $x'=1,23$ e $x''=2,61$, retornaria uma porcentagem de infecção negativa. Por este motivo, para se saber o percentual de área foliar afetada baseado no gráfico acima, foi por nós especificado um novo método pela função $f: \hat{A} @ \hat{A}$, tal que:

$$\begin{cases} 0\% & , \text{ se } x \leq 1,23 \\ 0,5\% & , \text{ se } 1,23 < x \leq 2,61 \\ \text{equação} & , \text{ se } 2,61 < x \leq 8 \\ \text{mais de 50\%} & , \text{ se } x > 8 \end{cases}$$

(56)

Assim pode-se substituir a nota média x dada à plantação, e tem-se o percentual de área foliar afetada. Por exemplo, para um valor médio $x = 4,62$ (TABELA 8) tem-se $y = 9,42\%$ de infecção.

4.3. SEGMENTAÇÃO POR THRESHOLD (LIMIAÇÃO)

A segmentação por limiarização foi aplicada sobre as fotos digitais tiradas das folhas da cana *in loco*. Apenas a área foliar da planta (com ou sem ferrugem) foi considerada, eliminando-se, portanto, todo o *background* antes da limiarização.

Estas imagens foram segmentadas para isolar as áreas infeccionadas e calcular assim o percentual da área realmente afetada. Este processo tem como objetivo corroborar a avaliação do especialista. Para a segmentação foi implementado um método automático de limiarização baseado no método de Otsu (seção 3.7), um semi automático baseado na média da vizinhança dos pixels que forem selecionados das áreas afetadas e um automático baseado no desvio padrão dos três canais de cores (R, G, B) de cada pixels (seção 3.7.1).

Como após a limiarização, tem-se o percentual de área foliar afetada é necessário fazer o caminho inverso ao descrito pela função 56. Para se contornar o problema com as notas contidas entre as raízes da equação, determinamos um limitante que é $x = 3$ e $y = 0,95\%$. Assim, deduzimos a função $f: \hat{A} @ \hat{A}$ para se obter as notas a partir da porcentagem conseguida com a segmentação das folhas:

$$\left\{ \begin{array}{ll} 1 & , \text{ se } y = 0\% \\ 2 & , \text{ se } 0\% < y \leq 0,95\% \\ \text{equação} & , \text{ se } 0,95\% < y \leq 50\% \\ 9 & , \text{ se } y > 50\% \end{array} \right.$$

(57)

4.4. EXTRAÇÃO DE CARACTERÍSTICAS

Das fotos adquiridas, foram selecionadas manualmente pequenas regiões de interesse (Figura 50), de tamanho 16 x 16 pixels, a partir das quais foram extraídas as características das cores, obedecendo aos métodos de extração de características de cores apresentados no Capítulo 2. Estes métodos foram implementados e adicionados ao programa LIZA, como o histograma (seção 2.3.1), momento de cores (seção 2.3.2), o vetor de coerência (seção 2.3.5) e cor invariante (seção 2.2.5).

Das 36 fotos, foram selecionadas 150 regiões de interesse, sendo 50 regiões de cada nível de infecção (apenas os três níveis conseguidos durante a avaliação foram considerados), resultando em conjuntos de dados contendo: 450 exemplos do histograma; 1.350 exemplos do momento da cor; 900 exemplos do vetor de coerência e 450 exemplos da cor invariante. O conjunto para treinamento que continha todas as características juntas possui 3.150 exemplos.

Figura 50 – Exemplo de seleção de 07 regiões de interesse (ROI's) de 16 x 16, a partir das quais foram extraídas as características.

A Figura 50 exemplifica o processo de seleção de regiões de 16 x 16 pixels na imagem. Destas regiões extraíam-se as características, histograma (*seção 2.3.1*), momento da cor (*seção 2.3.2*), vetor de coerência (*seção 2.3.5*) e cor invariante (*seção 2.2.5*). As características extraídas eram associadas ao nível de infecção da imagem avaliado pelos engenheiros. No exemplo da Figura 50 a infecção presente é a de nível 7. Assim foram gerados dez arquivos para cada uma das características e dez contendo todas as características juntas. Estes arquivos foram gerados obedecendo as restrições do método de análise de desempenho de redes neurais *10-Fold-Stratified-Cross-Validation* (*seção 3.2.1*).

Foram realizados treinamentos tanto com os dados intactos quanto com os dados normalizados, mas os resultados não apresentaram diferença significativa. As redes neurais foram escolhidas, pois nos testes iniciais realizados, apresentaram desempenho superior aos outros métodos (TABELA 9).

TABELA 9 – Comparação entre métodos de classificação.

Método	Redes Neurais	Clusterização	SVM's	Árvore de Decisão
Média de erro (MSE)	0,5135	0,5766	0,7760	1,813

4.5. TREINAMENTO DA REDE NEURAL

É importante salientar que além das Redes Neurais, foram conduzidos testes de classificação com Clustering, SVM, Árvores de Decisão. No entanto, a técnica adotada foi a de Redes Neurais, pois esta apresentou desempenho superior aos outros. Para os treinamentos foram utilizados simuladores como:

- SNNS 4.2: desenvolvido pela Universidade de Stuttgart e pela Universidade de Tübingen, este software é de domínio público e se encontra disponível em <<http://www-ra.informatik.uni-tuebingen.de/SNNS/>>.
- Weka: Universidade de Waikato, também de domínio público e disponível em <<http://www.cs.waikato.ac.nz/ml/weka/>>.
- BPNN: Universidade de São Paulo- ICMC, desenvolvido por Rosely Romero.

Nos testes realizados, o SNNS mostrou resultados mais consistentes que os demais (ver TABELA 11 e TABELA 12 no Capítulo 05 – Resultados). Por esta razão, além do fato de ser um software de domínio público e possuir ótimo manual de instruções, foi o escolhido para o trabalho de classificação.

Foram feitos testes em redes *backpropagation* com várias topologias. Como o conjunto de dados obtido da extração de características resulta em 256 cores, a topologia da rede apresenta uma camada de entrada com 256 neurônios e uma de saída com 03 neurônios que correspondem aos três tipos de níveis de infecções disponíveis. Assim, alguns exemplos de topologias testadas foram: 256x256x3, 256x128x3, 256x50x3. Como já foi dito, o primeiro e terceiro representam, respectivamente, aos números de neurônio das camadas de entrada e saída. O valor central é o número de neurônios da camada intermediária. A topologia de 256x128x3 foi a escolhida, pois produziu os melhores resultados.

Com o objetivo de reduzir o conjunto de dados de entrada, cogitou-se eliminar os valores das extremidades dos histogramas. Mas como mostrado na Figura 51, essa redução não foi possível, pois a distribuição da frequência dos três canais de cores nos diferentes níveis se mostrou significativa em pontos distintos, inclusive nos extremos. O canal azul é mais frequente nas intensidades de cores inferiores, já o canal vermelho é mais frequente nas intensidades de cores superiores e o verde é uniforme em toda a extensão das intensidades.

(a)

(b)

(c)

Figura 51 – Esquema de plotagem de histogramas, o histograma (a) representa uma região com nível de infecção 1, em (b) temos uma região de nível de infecção 2 e em (c) um região nível de infecção 7.

Para a avaliação dos resultados da classificação o método escolhido foi o *Stratified-fold-cross-validation* (seção 3.2.1) de 10 partições, pois houve a preocupação de que cada conjunto de dados possuisse a mesma porcentagem de exemplos para cada um dos níveis de infecção. Das 10 partições, oito foram usadas para o treinamento, uma partição para a validação e uma partição para o teste.

O treinamento consistia de 1.000 ciclos, fazendo-se uma validação a cada 100 ciclos. Ao final de cada 1.000 ciclos do treinamento era apresentado o conjunto de teste para a rede e calculado o erro deste conjunto usando-se a medida MSE (34). Depois disto, os conjuntos de testes e validação eram trocados e não mais utilizados.

Depois de terminados os diferentes treinamentos de todas as características extraídas e de feita a avaliação de seus desempenhos (ver TABELA 11 e TABELA 12 no Capítulo 05 – Resultados), as duas características que obtiveram melhor desempenho foram escolhidas, e uma rede contendo todos os exemplos foi treinada. A rede resultante deste treinamento foi utilizada para as classificações das fotos, cujos resultados são apresentados no próximo capítulo.

CAPÍTULO 05 – RESULTADOS

Neste capítulo serão apresentados os resultados obtidos pelo método manual (*seção 4.2*), pela segmentação das folhas (*seção 4.3*) e pelas redes neurais (*seção 4.5*). Também são mostrados os resultados de todos os testes de classificação realizados.

5.1. RESULTADOS DO MÉTODO MANUAL

Os engenheiros agrônomos analisaram a plantação *in loco* e identificaram duas variedades plantadas: a RB835486 e a RB867515, com datas de cortes diferentes. Esta avaliação pôde ser esquematicamente representada pelo croqui da Figura 52.

Figura 52 – Níveis de infecção atribuídos *in loco* pelos engenheiros do IAC aos diferentes quadrantes.

O campo avaliado pôde ser dividido em 04 regiões: no lado direito havia dois tipos de variedades de cana (RB835486 e RB867515), ambas com corte em 28/02/2003. A data de corte é um dado importante, pois indica a “idade” da plantação. Há maior suscetibilidade da planta quando esta apresenta idade entre 90 e 200 dias. O quadrante superior, com a variedade RB835486, foi avaliado como nível 7. Já o quadrante inferior, com a variedade RB867515, foi avaliado com níveis entre 2 e 2,5. A região intermediária aos quadrantes superior e inferior (região entre as linhas tracejadas), foi também avaliada pelos técnicos como sendo uma infecção entre níveis 2 e 2,5.

No lado esquerdo, foram também identificadas as mesmas variedades presentes à direita. No quadrante superior a variedade RB835486, com corte em 22/01/2003 avaliada em nível 7. No quadrante inferior a variedade RB867515, com corte em 03/01/2003, foi avaliada com níveis entre 1 e 1,5.

Como houve uma variação com as notas na avaliação da infecção das regiões pelos especialistas, optou-se por uma padronização. Todas as regiões avaliadas entre os níveis 2 e 2,5 foram interpretadas como sendo de nível 2 e as regiões avaliadas entre os níveis 1 e 1,5 foram interpretadas como sendo de nível 1.

5.2. RESULTADOS DA SEGMENTAÇÃO POR LIMARIZAÇÃO

Esta seção ilustra vários resultados obtidos na segmentação das folhas de cana-de-açúcar infectadas, pelos métodos de segmentação desenvolvidos (Otsu, Semi-Automático e Desvio Padrão). O percentual e o nível de infecção foram estimados segundo a função (57) (seção 4.3). Esse valor foi, então, confrontado com a “nota” atribuída pelo especialista. Os resultados nas figuras, que obedecem ao seguinte formato:

- Parte superior: à esquerda está a foto digital original da folha infectada; à direita está imagem recortada (sem o fundo) juntamente com a nota avaliada pelo especialista;
- Parte inferior: à esquerda a imagem do resultado da segmentação usando o método de Otsu, o limiar escolhido pelo método, o percentual de infecção da imagem e a nota dada baseada nesta porcentagem. Ao centro, a imagem resultante do método por seleção de pontos

infectados, o limiar escolhido, o percentual de infecção e a nota. À direita a imagem resultante do método baseado no desvio padrão dos canais de cores. Para este último teste foi preestabelecido o limiar 10 para a comparação com o desvio padrão obtido em cada pixel e a porcentagem resultante.

Figura 53 – Imagem com baixa infecção, segundo o especialista (nível entre 1 e 2).

Figura 54 – Imagem com baixa infecção, segundo o especialista (nível 2).

Figura 55 – Imagem com média infecção, segundo o especialista (nível entre 4 e 5).

Figura 56 – Imagem com alta infecção, segundo o especialista (nível 7).

Figura 57 – Imagem com alta infecção, segundo o especialista (nível entre 7,5 e 8).

Figura 58 – Imagem com alta infecção, segundo o especialista (nível 8).

Figura 59 – Imagem com alta infecção, segundo o especialista (nível entre 8,5 e 8).

Figura 60 – Imagem com alta infecção, segundo o especialista (nível entre 8,5 e 9).

A análise dos resultados permite-nos concluir que o método de segmentação automático de Otsu se mostrou eficiente para as folhas com grau de infecção acima de 2. Já o método automático do desvio padrão mostrou-se eficiente para as folhas com grau de infecção inferior a 2 (estas avaliações estão representadas na Figura 61). O método semi-automático, no entanto, produziu resultados semelhantes ao de Otsu (para imagens com médio/alto nível de infecção), com exceção do resultado apresentado na Figura 55, e não se revelou apropriado nos casos de folhas pouco infectadas. A Figura 61 mostra um gráfico de comparação entre as avaliações do especialista (linha escura) e as melhores avaliações conseguidas pela segmentação (linha clara). O erro nas avaliações é muito baixo e aceitável.

Figura 61 – Gráfico com a comparação entre as avaliações do especialista (linha escura) e as melhores conseguidas por meio da segmentação pelo desvio padrão e pelo método de Otsu (linha clara).

Foi possível identificar o percentual e o nível de infecção com sucesso, por meio do método de Otsu ou da limiarização por desvio padrão, ambos automáticos. E assim, nós desenvolvemos um método totalmente automático para o processo da segmentação das folhas, descrito nos parágrafos seguintes.

Foi feita uma análise no histograma das folhas, da intensidade dos canais vermelho e verde e constatou-se que na intensidade de cor 120 há um padrão, onde o canal verde é mais intenso do que o vermelho nas folhas menos infectadas, e o vermelho é mais intenso do que o verde nas folhas mais infectadas. Veja a TABELA 10.

Assim, dada uma imagem de uma folha infectada, analisa-se o histograma desta imagem na frequência 120 e comparam-se os canais, se o canal vermelho for maior que o verde a folha estará pouco infectada e para a segmentação usa-se o método baseado no desvio padrão, senão a folha estará mais infectada e usa-se o método de segmentação baseado em Otsu.

TABELA 10 – Análise feita em diferentes intensidades de cores nos histogramas das imagens das folhas.

	Intensidades Avaliadas															
	20		50		80		100		120		150		180		200	
Nível	R	G	R	G	R	G	R	G	R	G	R	G	R	G	R	G
1 a 2	0	0	2	0	7111	0	94	153	1	1462	0	150	0	0	0	0
2	0	0	54	2	3563	11	131	608	5	4052	0	4	0	5	0	0
4 a 4,5	0	0	0	0	1	33	832	71	3457	127	250	1120	1	1290	0	182
7	0	0	2	16	46	170	859	192	1824	297	200	1498	0	167	0	72
7,5 a 8	0	0	3	35	11	454	200	607	898	735	1293	766	13	169	0	0
8	0	3	203	95	345	307	829	512	1326	551	818	860	117	904	26	90
8 a 8,5	0	0	10	138	545	275	793	491	1673	802	486	927	41	494	32	23
8,5 a 9	0	18	241	227	595	671	861	834	1212	829	982	719	172	332	20	236

5.3. RESULTADOS DA CLASSIFICAÇÃO POR REDE NEURAL

Os dados obtidos com a extração de características das imagens (seção 4.4) foram usados para o treinamento e teste das redes nos três diferentes simuladores.

Foi feito um treinamento para cada uma das características extraídas e os resultados da média dos erros MSE (34) são apresentados na TABELA 11 e TABELA 12, que ilustram os resultados obtidos com imagens digitalizadas das fotos (experimento 01) e as imagens digitalizadas dos negativos (experimento 02), respectivamente. Os valores das TABELA 11 e TABELA 12 mostram que para a característica histograma o SNNS foi superior aos demais. Para as outras características, o simulador BPNN produziu erros mais baixos. No entanto, foi uma surpresa constatar que a média de erros para os dois experimentos no BPNN foi exatamente igual, sendo que os conjuntos de dados são completamente diferentes. Além disso, o SNNS provê um ferramental, para testes e classificações, mais versátil que os seus

congêneres. Por essas razões o simulador SNNS foi adotado para o processo de classificação das imagens.

TABELA 11 – Resultados da média dos erros MSE, no experimento 01.

	Experimento 01		
	BPNN	WEKA	SNNS
Histograma	0,2244	0,52072	0,209957
Momento da Cor	0,2620	0,69574	0,670783
Vetor Coerência	0,2210	0,75576	0,765307
Cor Invariante	0,2244	0,31241	0,277844
Conj. com todas	0,2441	1,26080	0,643700

TABELA 12 – Resultados da média dos erros MSE, no experimento 02.

	Experimento 02		
	BPNN	WEKA	SNNS
Histograma	0,2244	0,23869	0,177628
Momento da Cor	0,2620	0,72958	0,644966
Vetor Coerência	0,2210	0,79277	0,837329
Cor Invariante	0,2244	0,32862	0,518361
Conj. com todas	0,2441	1,36871	0,847866

Além disso, diante dos resultados obtidos com o treinamento das redes, pode-se observar que as características histograma da cor (*seção 2.3.1*) e cor invariante (*seção 2.2.5*) apresentaram desempenho um pouco superior às outras características. Portanto, todos os testes de classificações foram feitos baseados nestas duas características. Os resultados obtidos são apresentados a seguir.

CLASSIFICAÇÕES

Os teste de classificações obedeceram ao seguinte esquema: 1) Classificação da foto inteira; 2) Classificação de somente uma região de interesse (ROI) de 16 x 16 por foto; 3) Classificação de dez ROI's de 16 x 16, escolhidas aleatoriamente de uma foto.

5.3.1. Classificação da foto inteira

Neste experimento a ROI é única e corresponde à imagem inteira. Apenas o histograma de cores foi utilizado como característica, já que a cor invariante resultaria em um conjunto de dados extremamente grande (igual ao número de pixels da imagem), ao contrário dos 256 valores gerados no cálculo do histograma.

Os resultados foram adquiridos baseados nos três canais de cores (R, G, B). Isto é, cada um deles resulta, após a extração de características, em um exemplo que foi apresentado à rede neural, e esta o classificou em um dos níveis de infecção.

Os resultados desta classificação para o experimento 01 (digitalização das fotos reveladas) são apresentados na TABELA 13, e os resultados para o experimento 02 (digitalização dos negativos das fotos) estão na TABELA 14.

TABELA 13 – Teste com a imagem inteira no experimento 01 (digitalização das fotos).

FOTO				HISTOGRAMA				FOTO			
Foto	R	G	B	Foto	R	G	B	Foto	R	G	B
01_RB486_Niv07es.jpg	1	7	7	09_RB6-5_Niv2_5e.jpg	7	1	7	14_RB515_Niv1_5e.jpg	7	1	1
02_RB486_Niv07es.jpg	1	7	7	10_RB6-5_Niv2_5e.jpg	1	1	7	15_RB515_Niv1_5e.jpg	7	1	7
03_RB486_Niv07es.jpg	1	1	7	11_RB6-5_Niv2_5e.jpg	1	1	1	16_RB515_Niv1_5e.jpg	7	1	7
04_RB486_Niv07es.jpg	1	7	7	12_RB6-5_Niv2_5e.jpg	1	1	1	17_RB515_Niv1_5e.jpg	7	1	1
05_RB486_Niv07es.jpg	7	7	7	13_RB6-5_Niv2_5e.jpg	1	1	7	18_RB515_Niv1_5e.jpg	7	1	7
06_RB486_Niv07es.jpg	1	1	7	14_RB515_Niv2_5d.jpg	7	7	7	19_RB515_Niv1_5e.jpg	7	1	7
07_RB486_Niv07es.jpg	1	1	1	15_RB515_Niv2_5d.jpg	1	1	7	20_RB515_Niv1_5e.jpg	7	1	7
08_RB486_Niv07es.jpg	7	1	1	16_RB515_Niv2_5d.jpg	7	1	7	21_RB515_Niv1_5e.jpg	7	1	7
22_RB486_Niv07dr.jpg	1	1	7	17_RB515_Niv2_5d.jpg	1	1	7	22_RB515_Niv1_5e.jpg	7	1	2
23_RB486_Niv07dr.jpg	1	1	7	18_RB515_Niv2_5d.jpg	7	1	7				
23_RB486_Niv07es.jpg	1	7	7	19_RB515_Niv2_5d.jpg	7	1	7				
24_RB486_Niv07dr.jpg	1	1	7	20_RB515_Niv2_5d.jpg	1	1	7				
24_RB486_Niv07es.jpg	1	7	7	21_RB515_Niv2_5d.jpg	7	1	7				
25_RB486_Niv07dr.jpg	1	1	7								

Nas TABELA 13 e TABELA 14, a coluna da esquerda representa todos os resultados obtidos da classificação das imagens de nível 7. Na coluna do meio estão os resultados das imagens de nível 2 e a coluna da direita estão os resultados das imagens de nível 1. O número

abaixo dos canais R, G e B são as classificações obtidas como resultado da classificação pela rede neural.

TABELA 14 – Teste com a imagem inteira no experimento 02 (digitalização dos negativos).

FOTO				HISTOGRAMA				FOTO				FOTO			
Foto	R	G	B	Foto	R	G	B	Foto	R	G	B	Foto	R	G	B
01_RB486_Niv07es.jpg	7	7	1	09_RB6-5_Niv2_5e.jpg	2	7	7	14_RB515_Niv1_5e.jpg	7	7	7	15_RB515_Niv1_5e.jpg	7	7	2
02_RB486_Niv07es.jpg	7	7	1	10_RB6-5_Niv2_5e.jpg	7	7	1	16_RB515_Niv1_5e.jpg	7	7	2	17_RB515_Niv1_5e.jpg	7	7	1
03_RB486_Niv07es.jpg	7	7	1	11_RB6-5_Niv2_5e.jpg	7	7	7	18_RB515_Niv1_5e.jpg	7	7	1	19_RB515_Niv1_5e.jpg	7	7	1
04_RB486_Niv07es.jpg	7	7	1	12_RB6-5_Niv2_5e.jpg	7	7	1	20_RB515_Niv1_5e.jpg	2	7	2	21_RB515_Niv1_5e.jpg	7	7	1
05_RB486_Niv07es.jpg	2	2	1	13_RB6-5_Niv2_5e.jpg	7	7	1	22_RB515_Niv1_5e.jpg	7	7	2				
06_RB486_Niv07es.jpg	7	7	1	14_RB515_Niv2_5d.jpg	7	7	2								
07_RB486_Niv07es.jpg	7	2	1	15_RB515_Niv2_5d.jpg	7	7	2								
08_RB486_Niv07es.jpg	7	2	1	16_RB515_Niv2_5d.jpg	7	7	2								
22_RB486_Niv07dr.jpg	7	7	2	17_RB515_Niv2_5d.jpg	7	7	2								
23_RB486_Niv07dr.jpg	7	2	2	18_RB515_Niv2_5d.jpg	7	7	2								
23_RB486_Niv07es.jpg	7	7	2	19_RB515_Niv2_5d.jpg	2	2	2								
24_RB486_Niv07dr.jpg	7	2	2	20_RB515_Niv2_5d.jpg	2	2	2								
24_RB486_Niv07es.jpg	7	7	1	21_RB515_Niv2_5d.jpg	2	2	2								
25_RB486_Niv07dr.jpg	7	7	2												

Os resultados obtidos com a classificação do histograma da imagem inteira em ambos experimentos, podem ser resumidos na TABELA 15 da seguinte forma: são representadas a quantidade de classificações corretas pelo número de imagens de cada um dos níveis de infecção, para cada um dos diferentes canais de cores. O total leva em consideração todas as 36 imagens que foram trabalhadas, representando assim a quantidade de imagens classificadas corretamente (contando os três níveis de infecção e seu percentual).

TABELA 15 – Análise resultados da classificação da imagem inteira.

Experimento 01				Experimento 02			
	R	G	B		R	G	B
Nível 7	2 / 14	6 / 14	12 / 14	Nível 7	13 / 14	9 / 14	0 / 14
Nível 2	0 / 13	0 / 13	0 / 13	Nível 2	4 / 13	3 / 13	8 / 13
Nível 1	0 / 9	9 / 9	2 / 9	Nível 1	0 / 9	0 / 9	4 / 9
Total	2 / 36	15 / 36	14 / 36	Total	17 / 36	12 / 36	12 / 36
Percentual	5,55%	41,66%	38,88%	Percentual	47,22%	33,33%	33,33%

Este baixo desempenho constatado era de se esperar, pois a imagem inteira apresenta ruídos como áreas compostas por terra e sombra, as quais não foram consideradas durante a

seleção das ROI para o treinamento. Deve-se notar, enquanto os resultados para os canais verde e azul não apresentaram grandes variações em ambos os experimentos, a resposta para o canal vermelho no experimento 02 foi bem superior ao experimento 01 e que 13 das 14 imagens de nível 7 foram corretamente classificadas.

5.3.2. Classificação da foto com 1 região de interesse

Para este teste foi selecionada aleatoriamente somente uma região de interesse (ROI) por foto. Desta ROI foram extraídas as características histograma e cor invariante. Os resultados para o experimento 01 e 02 são mostrados na TABELA 16 e na TABELA 17, respectivamente.

TABELA 16 – Resultado dos testes com somente uma região de interesse selecionada por foto. Experimento 01.

HISTOGRAMA			
Foto	R	G	B
01 RB486 Niv07es.jpg	7	7	1
02 RB486 Niv07es.jpg	1	7	1
03 RB486 Niv07es.jpg	2	2	7
04 RB486 Niv07es.jpg	1	2	2
05 RB486 Niv07es.jpg	7	7	2
06 RB486 Niv07es.jpg	1	1	7
07 RB486 Niv07es.jpg	1	7	7
08 RB486 Niv07es.jpg	2	1	7
22 RB486 Niv07dr.jpg	2	2	2
23 RB486 Niv07dr.jpg	2	2	7
23 RB486 Niv07es.jpg	7	7	7
24 RB486 Niv07dr.jpg	2	2	7
24 RB486 Niv07es.jpg	7	7	7
25 RB486 Niv07dr.jpg	7	2	7

Foto	R	G	B
09 RB6-5 Niv2 5e.jpg	7	1	1
10 RB6-5 Niv2 5e.jpg	2	2	2
11 RB6-5 Niv2 5e.jpg	2	7	2
12 RB6-5 Niv2 5e.jpg	1	7	1
13 RB6-5 Niv2 5e.jpg	2	2	2
14 RB515 Niv2 5d.jpg	7	2	1
15 RB515 Niv2 5d.jpg	2	1	2
16 RB515 Niv2 5d.jpg	2	2	2
17 RB515 Niv2 5d.jpg	1	7	2
18 RB515 Niv2 5d.jpg	2	2	1
19 RB515 Niv2 5d.jpg	2	2	7
20 RB515 Niv2 5d.jpg	7	2	1
21 RB515 Niv2 5d.jpg	1	1	2

Foto	R	G	B
14 RB515 Niv1 5e.jpg	7	2	7
15 RB515 Niv1 5e.jpg	2	2	2
16 RB515 Niv1 5e.jpg	7	7	1
17 RB515 Niv1 5e.jpg	1	1	2
18 RB515 Niv1 5e.jpg	2	2	2
19 RB515 Niv1 5e.jpg	7	2	7
20 RB515 Niv1 5e.jpg	1	7	1
21 RB515 Niv1 5e.jpg	1	2	7
22 RB515 Niv1 5e.jpg	2	2	1

COR INVARIANTE			
Foto	L1	L2	L3
01 RB486 Niv07es.jpg	7	7	2
02 RB486 Niv07es.jpg	7	7	2
03 RB486 Niv07es.jpg	7	7	7
04 RB486 Niv07es.jpg	2	7	7
05 RB486 Niv07es.jpg	7	7	7
06 RB486 Niv07es.jpg	1	1	7
07 RB486 Niv07es.jpg	7	7	2
08 RB486 Niv07es.jpg	7	7	7
22 RB486 Niv07dr.jpg	7	7	7
23 RB486 Niv07dr.jpg	7	2	7
23 RB486 Niv07es.jpg	2	7	7
24 RB486 Niv07dr.jpg	1	7	7
24 RB486 Niv07es.jpg	2	7	2
25 RB486 Niv07dr.jpg	7	2	2

Foto	L1	L2	L3
09 RB6-5 Niv2 5e.jpg	2	1	2
10 RB6-5 Niv2 5e.jpg	2	2	2
11 RB6-5 Niv2 5e.jpg	1	1	2
12 RB6-5 Niv2 5e.jpg	7	7	7
13 RB6-5 Niv2 5e.jpg	2	2	2
14 RB515 Niv2 5d.jpg	2	2	2
15 RB515 Niv2 5d.jpg	1	2	2
16 RB515 Niv2 5d.jpg	2	2	2
17 RB515 Niv2 5d.jpg	1	2	2
18 RB515 Niv2 5d.jpg	1	2	2
19 RB515 Niv2 5d.jpg	2	2	2
20 RB515 Niv2 5d.jpg	2	7	2
21 RB515 Niv2 5d.jpg	7	2	2

Foto	L1	L2	L3
14 RB515 Niv1 5e.jpg	2	2	1
15 RB515 Niv1 5e.jpg	7	2	1
16 RB515 Niv1 5e.jpg	7	1	1
17 RB515 Niv1 5e.jpg	1	2	2
18 RB515 Niv1 5e.jpg	2	2	2
19 RB515 Niv1 5e.jpg	1	2	1
20 RB515 Niv1 5e.jpg	1	2	2
21 RB515 Niv1 5e.jpg	7	1	1
22 RB515 Niv1 5e.jpg	1	1	1

Nas TABELA 16 e TABELA 17, o quadro à esquerda representa os resultados obtidos com a classificação das imagens nível 7. No quadro central estão os resultados das imagens de nível 2 e no quadro à direita estão os resultados das imagens de nível 1. O número abaixo dos canais R, G, B ou L1, L2, L3 são as classificações obtidas pela da rede neural.

TABELA 17 – Resultado dos testes com somente uma região de interesse selecionada por foto. Experimento 02.

HISTOGRAMA

Foto	R	G	B
01 RB486 Niv07es.jpg	1	7	7
02 RB486 Niv07es.jpg	2	2	2
03 RB486 Niv07es.jpg	7	2	1
04 RB486 Niv07es.jpg	7	2	7
05 RB486 Niv07es.jpg	7	7	7
06 RB486 Niv07es.jpg	2	7	7
07 RB486 Niv07es.jpg	2	2	1
08 RB486 Niv07es.jpg	1	7	7
22 RB486 Niv07dr.jpg	2	7	2
23 RB486 Niv07dr.jpg	7	2	2
23 RB486 Niv07es.jpg	1	1	7
24 RB486 Niv07dr.jpg	2	2	7
24 RB486 Niv07es.jpg	2	1	7
25 RB486 Niv07dr.jpg	1	7	7

Foto	R	G	B
09 RB6-5 Niv2 5e.jpg	2	1	7
10 RB6-5 Niv2 5e.jpg	2	1	7
11 RB6-5 Niv2 5e.jpg	1	7	7
12 RB6-5 Niv2 5e.jpg	2	1	1
13 RB6-5 Niv2 5e.jpg	1	2	7
14 RB515 Niv2 5d.jpg	7	1	7
15 RB515 Niv2 5d.jpg	2	2	2
16 RB515 Niv2 5d.jpg	2	2	2
17 RB515 Niv2 5d.jpg	7	1	1
18 RB515 Niv2 5d.jpg	2	7	2
19 RB515 Niv2 5d.jpg	2	2	2
20 RB515 Niv2 5d.jpg	2	2	2
21 RB515 Niv2 5d.jpg	2	1	2

Foto	R	G	B
14 RB515 Niv1 5e.jpg	1	2	1
15 RB515 Niv1 5e.jpg	2	7	2
16 RB515 Niv1 5e.jpg	1	1	1
17 RB515 Niv1 5e.jpg	1	1	2
18 RB515 Niv1 5e.jpg	1	2	1
19 RB515 Niv1 5e.jpg	7	7	7
20 RB515 Niv1 5e.jpg	2	2	1
21 RB515 Niv1 5e.jpg	1	2	2
22 RB515 Niv1 5e.jpg	1	1	1

COR INVARIANTE

Foto	L1	L2	L3
01 RB486 Niv07es.jpg	2	7	7
02 RB486 Niv07es.jpg	2	7	2
03 RB486 Niv07es.jpg	1	7	7
04 RB486 Niv07es.jpg	2	2	7
05 RB486 Niv07es.jpg	7	7	7
06 RB486 Niv07es.jpg	7	7	2
07 RB486 Niv07es.jpg	7	7	7
08 RB486 Niv07es.jpg	7	7	7
22 RB486 Niv07dr.jpg	1	1	2
23 RB486 Niv07dr.jpg	2	7	1
23 RB486 Niv07es.jpg	7	7	7
24 RB486 Niv07dr.jpg	2	1	1
24 RB486 Niv07es.jpg	2	7	7
25 RB486 Niv07dr.jpg	2	2	7

Foto	L1	L2	L3
09 RB6-5 Niv2 5e.jpg	1	1	2
10 RB6-5 Niv2 5e.jpg	7	7	2
11 RB6-5 Niv2 5e.jpg	7	1	7
12 RB6-5 Niv2 5e.jpg	7	1	7
13 RB6-5 Niv2 5e.jpg	7	7	7
14 RB515 Niv2 5d.jpg	2	1	1
15 RB515 Niv2 5d.jpg	1	1	2
16 RB515 Niv2 5d.jpg	2	2	2
17 RB515 Niv2 5d.jpg	2	2	1
18 RB515 Niv2 5d.jpg	2	2	1
19 RB515 Niv2 5d.jpg	2	1	2
20 RB515 Niv2 5d.jpg	2	2	2
21 RB515 Niv2 5d.jpg	2	1	1

Foto	L1	L2	L3
14 RB515 Niv1 5e.jpg	2	1	1
15 RB515 Niv1 5e.jpg	2	1	1
16 RB515 Niv1 5e.jpg	2	2	2
17 RB515 Niv1 5e.jpg	7	7	7
18 RB515 Niv1 5e.jpg	7	2	2
19 RB515 Niv1 5e.jpg	1	2	7
20 RB515 Niv1 5e.jpg	1	2	1
21 RB515 Niv1 5e.jpg	1	1	2
22 RB515 Niv1 5e.jpg	2	2	1

Os resultados obtidos com a classificação do histograma e da cor invariante para ROI selecionada nos dois experimentos, são sumarizados na TABELA 18 da seguinte forma: são representadas as quantidade de classificações corretas pelo número de imagens de cada um dos níveis de infecção, em cada um dos diferentes canais de cores. O total leva em consideração todas as 36 imagens trabalhadas, representando assim, a quantidade de imagens classificadas corretamente (contando os três níveis de infecção e seu percentual).

TABELA 18 – Análise dos resultados para a classificação de uma ROI por foto para os dois experimentos realizados.

Experimento 01

Histograma			
	R	G	B
Nível 7	5 / 14	6 / 14	9 / 14
Nível 2	7 / 13	7 / 13	7 / 13
Nível 1	3 / 9	1 / 9	3 / 9
Total	15 / 36	14 / 36	19 / 36
Percentual	41,66%	38,88%	52,77%

Cor Invariante			
	L1	L2	L3
Nível 7	9 / 14	11 / 14	9 / 14
Nível 2	7 / 13	9 / 13	12 / 13
Nível 1	4 / 9	3 / 9	5 / 9
Total	20 / 36	23 / 36	26 / 36
Percentual	55,55%	63,88%	72,22%

Experimento 02

Histograma			
	R	G	B
Nível 7	4 / 14	6 / 14	9 / 14
Nível 2	9 / 13	5 / 13	6 / 13
Nível 1	6 / 9	3 / 9	5 / 9
Total	19 / 36	14 / 36	20 / 36
Percentual	52,77%	38,88%	55,55%

Cor Invariante			
	L1	L2	L3
Nível 7	5 / 14	10 / 14	9 / 14
Nível 2	7 / 13	4 / 13	6 / 13
Nível 1	3 / 9	3 / 9	4 / 9
Total	15 / 36	17 / 36	19 / 36
Percentual	41,66%	47,22%	52,77%

Diante dos resultados podemos tecer algumas observações:

- Os resultados com a característica de Cor Invariante foram superiores aos com o Histograma de Cor no experimento 01. No experimento 02 elas foram praticamente equivalentes;
- O canal azul e a L3 tiveram desempenho superior aos outros nos dois experimentos, mas não se mostrou eficiente nos testes com a foto inteira (*seção 5.3.1*);
- Nos testes de classificação com a foto inteira, o melhor desempenho foi no experimento 02 com as classificações pelo canal vermelho (acerto de 17 fotos em 36); já neste teste o melhor desempenho foi obtido no experimento 01 pela cor invariante L3 (acerto de 26 fotos em 36).

5.3.3. Classificação da foto com 10 regiões de interesse

Os resultados da classificação para 10 regiões de interesse (ROI's) selecionadas aleatoriamente (não são as mesmas das usadas para o treinamento) por foto são apresentados segundo o formato abaixo:

ROI's ^(a)		1	2	3	4	5	6	7	8	9	10	Freq.Canal ^(e)
02_RB486_Niv07es.jpg ^(b)	^(c) R	2 ^(d)	1	2	7	7	2	2	7	7	1	4
	G	7	7	1	1	2	2	1	7	7	7	5
	B	7	7	7	7	2	1	2	7	7	7	7

Frequência Total	7 ^(g)	2	1
por níveis ^(f)	16 ^(h)	8	6

(a) – Regiões de interesse selecionadas aleatoriamente (1...10);

(b) – Imagem a ser classificada, para a qual já se sabe o nível de infecção (neste exemplo, nível 7);

(c) – Classificação obtida em cada um dos três canais de cores;

(d) – Saída obtida em um dos três níveis de infecção (7, 2 ou 1), por meio da classificação pela rede neural;

(e) – Frequência de classificações corretas para o nível esperado em cada um dos canais. Neste exemplo foram contadas quantas vezes a rede classificou corretamente o nível 7 em cada canal separadamente;

(f) – Quadro da frequência total dos três níveis de infecção para todas as 10 ROI's;

(g) – Níveis de infecção possíveis (7, 2 ou 1);

(h) – Quantidade total de classificações corretas para cada um dos níveis desta imagem.

TABELA 19 – Resultados conseguidos pela classificação do histograma no experimento 01 nível 7.

01 RB486 Niv07es.png	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	R	1	2	2	1	1	7	2	1	1	7	2
	G	2	7	1	7	1	7	2	2	7	2	4
	B	7	2	7	7	2	7	2	2	7	7	9
Frequência Total por níveis							7	2	1			
							11	12	7			
02 RB486 Niv07es.png	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	R	2	1	7	1	7	2	2	7	7	1	4
	G	7	7	1	1	2	1	1	7	2	7	4
	B	2	7	7	7	1	1	2	7	1	7	5
Frequência Total por níveis							7	2	1			
							13	8	9			
03 RB486 Niv07es.png	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	R	7	7	2	7	2	2	2	1	7	2	4
	G	2	2	1	2	2	1	2	2	1	1	0
	B	7	7	7	7	2	7	1	7	2	7	7
Frequência Total por níveis							7	2	1			
							11	13	6			
04 RB486 Niv07es.png	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	R	2	2	1	2	1	7	1	1	1	1	1
	G	1	7	1	7	1	2	1	2	2	1	2
	B	7	2	2	2	7	1	7	2	7	7	5
Frequência Total por níveis							7	2	1			
							8	10	12			
05 RB486 Niv07es.png	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	R	1	1	7	7	1	1	7	1	7	2	4
	G	7	7	7	7	7	2	7	1	1	1	6
	B	7	7	2	7	1	1	7	7	7	1	6
Frequência Total por níveis							7	2	1			
							16	3	11			
06 RB486 Niv07es.png	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	R	2	7	2	7	1	1	1	2	1	2	2
	G	1	1	1	2	2	7	1	7	1	7	3
	B	1	1	1	7	7	2	7	1	1	1	3
Frequência Total por níveis							7	2	1			
							8	7	15			
07 RB486 Niv07es.png	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	R	7	7	1	7	2	1	2	7	1	2	4
	G	7	1	2	7	2	7	1	2	7	2	4
	B	7	7	7	1	7	7	7	7	1	7	8
Frequência Total por níveis							7	2	1			
							16	7	7			
08 RB486 Niv07es.png	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	R	2	7	7	2	2	1	1	7	7	7	5
	G	2	7	7	2	1	2	1	1	7	2	3
	B	7	7	7	2	7	2	7	7	1	7	7
Frequência Total por níveis							7	2	1			
							15	9	6			
22 RB486 Niv07dr.png	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	R	7	7	2	7	2	2	7	1	7	1	5
	G	2	2	2	7	7	2	2	1	7	1	3
	B	1	7	7	7	2	1	2	7	7	7	6
Frequência Total por níveis							7	2	1			
							14	10	6			
23 RB486 Niv07dr.png	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	R	1	2	7	7	2	2	2	2	2	2	2
	G	2	7	7	7	2	2	7	2	2	1	4
	B	2	1	7	2	2	2	2	2	7	7	3
Frequência Total por níveis							7	2	1			
							9	18	3			
23 RB486 Niv07es.png	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	R	1	7	7	2	1	7	2	7	1	1	4
	G	7	7	7	1	7	7	2	7	2	7	7
	B	7	2	7	7	2	1	2	7	7	7	6
Frequência Total por níveis							7	2	1			
							17	7	6			
24 RB486 Niv07dr.png	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	R	2	7	2	2	1	1	2	7	2	7	3
	G	1	7	1	7	2	7	7	2	1	1	4
	B	7	7	7	1	7	7	2	2	7	1	6
Frequência Total por níveis							7	2	1			
							13	9	8			
24 RB486 Niv07es.png	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	R	7	7	7	1	7	2	1	7	2	7	6
	G	7	7	7	1	2	7	2	7	2	7	6
	B	7	1	7	2	7	1	2	7	2	1	5
Frequência Total por níveis							7	2	1			
							17	8	5			
25 RB486 Niv07dr.png	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	R	1	2	7	1	1	2	2	7	1	1	2
	G	7	1	1	1	7	7	1	7	1	2	4
	B	7	7	7	7	1	2	2	7	1	2	6
Frequência Total por níveis							7	2	1			
							12	6	12			

TABELA 20 – Resultados conseguidos pela classificação do histograma no experimento 01 nível 2.

09 RB6-5 Niv2 5e.img	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	R	2	2	1	2	2	7	2	1	1	1	5
	G	2	2	7	1	2	7	1	1	7	2	4
	B	7	2	7	7	2	1	7	2	1	7	3
Frequência total por níveis							7	2	1			
							9	12	9			
10 RB6-5 Niv2 5e.img	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	R	1	2	2	2	1	1	2	2	2	1	6
	G	7	2	2	7	2	2	7	1	1	1	4
	B	2	1	2	2	7	2	7	2	7	1	5
Frequência total por níveis							7	2	1			
							6	15	9			
11 RB6-5 Niv2 5e.img	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	R	7	7	7	2	2	1	1	2	2	1	4
	G	2	7	7	2	1	1	2	7	1	1	3
	B	1	2	2	2	1	7	7	7	2	1	4
Frequência total por níveis							7	2	1			
							9	11	10			
12 RB6-5 Niv2 5e.img	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	R	1	7	7	1	2	2	7	1	2	2	4
	G	1	1	2	1	2	2	7	2	1	2	5
	B	1	7	7	2	2	1	1	1	7	2	3
Frequência total por níveis							7	2	1			
							7	12	11			
13 RB6-5 Niv2 5e.img	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	R	7	2	2	7	1	2	1	2	1	1	4
	G	2	1	1	1	2	2	1	2	1	7	4
	B	2	1	7	7	2	2	1	2	1	1	4
Frequência total por níveis							7	2	1			
							5	12	13			
14 RB515 Niv2 5d.img	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	R	7	7	7	7	2	7	1	7	2	2	3
	G	2	7	2	7	2	2	7	1	2	7	5
	B	7	7	2	1	7	7	7	2	1	7	2
Frequência total por níveis							7	2	1			
							16	10	4			
15 RB515 Niv2 5d.img	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	R	1	1	7	7	2	1	2	1	1	7	2
	G	1	2	2	1	2	2	2	1	1	1	4
	B	2	7	2	1	2	2	2	7	1	2	6
Frequência total por níveis							7	2	1			
							5	12	13			
16 RB515 Niv2 5d.img	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	R	7	1	7	1	2	7	7	1	2	2	3
	G	7	1	1	2	7	2	7	2	7	7	3
	B	7	2	1	2	2	1	7	7	7	2	4
Frequência total por níveis							7	2	1			
							13	10	7			
17 RB515 Niv2 5d.img	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	R	7	7	1	7	1	2	2	7	1	7	2
	G	1	1	2	7	2	2	2	1	1	1	4
	B	7	7	7	2	1	7	7	1	7	1	1
Frequência total por níveis							7	2	1			
							12	7	11			
18 RB515 Niv2 5d.img	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	R	7	7	2	2	7	7	2	2	1	1	4
	G	7	1	2	2	1	1	1	1	7	1	2
	B	7	7	7	7	1	7	2	2	7	7	2
Frequência total por níveis							7	2	1			
							13	8	9			
19 RB515 Niv2 5d.img	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	R	2	7	1	2	2	2	2	2	2	7	7
	G	7	1	1	7	2	7	2	7	2	1	3
	B	7	1	7	1	2	7	7	7	7	2	2
Frequência total por níveis							7	2	1			
							12	12	6			
20 RB515 Niv2 5d.img	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	R	2	2	7	2	2	7	7	7	1	2	5
	G	7	2	7	1	1	2	1	7	1	7	2
	B	2	2	7	1	7	7	2	2	7	1	3
Frequência total por níveis							7	2	1			
							12	10	8			
21 RB515 Niv2 5d.img	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	R	2	7	7	7	2	7	1	7	7	1	2
	G	7	7	7	2	2	2	2	2	7	7	5
	B	1	7	7	1	2	7	1	2	7	2	3
Frequência total por níveis							7	2	1			
							15	10	5			

TABELA 21 – Resultados conseguidos pela classificação do histograma no experimento 01 nível 1.

14_RB515_Niv1_5e.jpg											
ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
R	1	7	1	7	1	1	7	1	2	2	5
G	1	7	2	2	7	1	2	7	1	7	3
B	1	7	1	7	1	7	7	1	1	7	6
Frequência Total por níveis						7	2	1			
						11	5	14			

15_RB515_Niv1_5e.jpg											
ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
R	2	7	1	2	7	1	2	1	2	2	3
G	2	7	1	1	1	7	7	1	1	2	5
B	7	2	1	1	7	1	7	2	2	2	3
Frequência Total por níveis						7	2	1			
						8	11	11			

16_RB515_Niv1_5e.jpg											
ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
R	7	7	1	7	2	7	2	1	1	7	3
G	7	7	7	2	1	7	2	1	1	7	3
B	2	7	7	7	2	1	1	1	7	1	4
Frequência Total por níveis						7	2	1			
						14	6	10			

17_RB515_Niv1_5e.jpg											
ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
R	2	2	1	7	1	1	1	7	7	1	5
G	1	7	2	1	2	7	7	1	1	2	4
B	1	7	1	1	1	1	1	7	1	2	7
Frequência Total por níveis						7	2	1			
						8	6	16			

18_RB515_Niv1_5e.jpg											
ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
R	1	2	7	2	7	7	1	2	2	2	2
G	7	1	7	1	1	2	7	2	7	7	3
B	7	1	7	1	7	2	1	1	1	1	6
Frequência Total por níveis						7	2	1			
						11	9	10			

19_RB515_Niv1_5e.jpg											
ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
R	7	2	2	7	1	1	2	1	2	7	4
G	2	2	2	2	7	2	1	1	1	7	3
B	2	7	1	1	1	7	7	1	7	2	5
Frequência Total por níveis						7	2	1			
						8	10	12			

20_RB515_Niv1_5e.jpg											
ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
R	1	1	1	1	7	7	1	1	1	1	8
G	1	7	1	1	1	1	1	7	1	1	8
B	1	1	1	1	7	2	2	7	1	1	6
Frequência Total por níveis						7	2	1			
						6	2	22			

21_RB515_Niv1_5e.jpg											
ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
R	2	1	2	2	7	1	1	2	1	1	5
G	1	2	1	1	2	1	7	1	7	2	5
B	7	1	7	1	2	1	1	1	1	7	6
Frequência Total por níveis						7	2	1			
						6	8	16			

22_RB515_Niv1_5e.jpg											
ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
R	7	7	2	2	2	7	1	2	1	7	2
G	1	2	1	1	1	1	1	1	2	7	7
B	7	1	1	1	7	1	7	7	7	1	5
Frequência Total por níveis						7	2	1			
						10	8	12			

TABELA 22 – Resultados conseguidos pela classificação do histograma no experimento 02 nível 7.

01 RB486 Niv07en.jpg	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	R	7	7	1	2	2	7	2	7	2	2	4
	G	1	7	2	2	2	1	1	1	7	7	3
	B	7	7	7	1	2	1	7	7	7	1	6
Frequência Total por níveis							7	2	1			
							13	10	7			
02 RB486 Niv07en.jpg	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	R	2	1	2	7	1	1	1	2	7	1	2
	G	1	7	7	7	1	7	2	2	1	7	5
	B	1	7	7	7	7	7	1	1	1	7	7
Frequência Total por níveis							7	2	1			
							14	5	11			
03 RB486 Niv07en.jpg	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	R	2	2	7	2	7	1	7	7	7	2	5
	G	2	1	2	2	2	2	1	2	2	1	0
	B	7	7	7	7	7	7	7	2	7	7	9
Frequência Total por níveis							7	2	1			
							14	12	4			
04 RB486 Niv07en.jpg	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	R	7	1	1	2	7	7	7	1	1	1	4
	G	7	1	1	1	1	1	7	1	1	7	3
	B	7	7	1	1	7	7	7	7	2	1	6
Frequência Total por níveis							7	2	1			
							13	2	15			
05 RB486 Niv07en.jpg	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	R	7	7	2	2	7	1	1	7	7	2	5
	G	2	2	2	2	7	2	7	7	7	2	4
	B	7	1	7	1	1	7	7	7	7	7	7
Frequência Total por níveis							7	2	1			
							16	9	5			
06 RB486 Niv07en.jpg	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	R	7	7	1	1	2	2	2	1	1	7	3
	G	2	2	2	7	7	2	1	1	2	1	3
	B	7	2	7	7	2	7	7	2	7	1	5
Frequência Total por níveis							7	2	1			
							11	11	8			
07 RB486 Niv07en.jpg	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	R	7	2	7	1	7	7	2	1	7	2	6
	G	1	2	1	7	7	7	1	1	7	7	5
	B	7	2	7	7	1	7	2	1	7	7	7
Frequência Total por níveis							7	2	1			
							18	4	8			
08 RB486 Niv07en.jpg	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	R	2	1	7	7	2	1	7	2	7	1	4
	G	1	2	1	2	1	1	7	1	1	2	1
	B	7	7	1	7	2	7	7	2	7	7	7
Frequência Total por níveis							7	2	1			
							12	8	10			
22 RB486 Niv07dn.jpg	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	R	7	7	2	1	2	2	1	1	2	7	3
	G	7	2	2	1	7	7	7	1	1	7	5
	B	1	1	2	2	2	2	2	2	2	2	0
Frequência Total por níveis							7	2	1			
							8	14	8			
23 RB486 Niv07dn.jpg	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	R	2	1	7	1	1	2	2	1	1	2	1
	G	7	2	2	2	2	7	2	7	2	2	3
	B	7	7	2	7	7	7	1	7	2	2	6
Frequência Total por níveis							7	2	1			
							10	14	6			
23 RB486 Niv07en.jpg	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	R	2	7	1	1	1	1	1	2	1	7	2
	G	7	7	7	1	1	1	1	1	7	7	5
	B	1	1	7	2	7	1	1	1	1	7	3
Frequência Total por níveis							7	2	1			
							10	3	17			
24 RB486 Niv07dn.jpg	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	R	7	7	7	7	2	2	1	1	1	1	4
	G	7	1	2	7	2	7	7	2	2	7	5
	B	7	2	7	2	2	2	1	2	7	7	4
Frequência Total por níveis							7	2	1			
							13	11	6			
24 RB486 Niv07en.jpg	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	R	1	2	7	1	7	2	7	7	2	1	4
	G	7	7	1	7	1	1	2	7	1	7	5
	B	7	7	1	7	7	2	1	7	7	7	7
Frequência Total por níveis							7	2	1			
							16	5	9			
25 RB486 Niv07dn.jpg	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	R	7	7	7	1	1	2	1	2	7	2	4
	G	2	2	1	1	2	1	7	1	1	1	1
	B	7	2	2	2	7	7	7	7	7	1	7
Frequência Total por níveis							7	2	1			
							11	9	10			

TABELA 23 – Resultados conseguidos pela classificação do histograma no experimento 02 nível 2.

09 RB6-5 Niv2 5en.ing	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	R	2	2	7	7	2	2	7	2	7	7	5
	G	7	2	7	2	7	2	2	7	7	7	4
	B	7	2	7	2	7	7	2	2	7	7	4
Frequência Total por níveis							7	2	1			
							17	13	0			
10 RB6-5 Niv2 5en.ing	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	R	1	7	2	7	2	2	2	1	2	7	5
	G	7	2	7	2	7	2	2	1	2	7	5
	B	1	1	7	1	1	1	7	1	7	1	0
Frequência Total por níveis							7	2	1			
							10	10	10			
11 RB6-5 Niv2 5en.ing	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	R	2	2	7	7	2	7	1	7	2	1	3
	G	2	2	1	7	1	1	1	7	2	1	3
	B	7	7	7	7	2	7	7	1	7	7	1
Frequência Total por níveis							7	2	1			
							15	7	8			
12 RB6-5 Niv2 5en.ing	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	R	1	1	2	1	2	2	2	1	1	7	4
	G	2	2	2	7	2	1	2	2	7	2	7
	B	1	2	7	1	1	7	1	1	1	1	1
Frequência Total por níveis							7	2	1			
							5	12	13			
13 RB6-5 Niv2 5e.ing	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	R	2	7	7	2	2	2	2	2	1	2	7
	G	2	1	2	1	2	7	7	7	7	7	3
	B	7	1	7	2	2	7	7	2	7	1	3
Frequência Total por níveis							7	2	1			
							12	13	5			
14 RB515 Niv2 5d.ing	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	R	7	1	1	2	1	1	7	2	2	7	3
	G	7	2	2	2	2	7	7	1	2	7	5
	B	2	2	7	2	1	1	7	7	7	1	3
Frequência Total por níveis							7	2	1			
							11	11	8			
15 RB515 Niv2 5d.ing	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	R	2	1	7	1	2	1	1	1	7	7	2
	G	7	2	7	1	7	1	2	1	2	1	3
	B	1	1	2	2	7	7	1	7	1	1	2
Frequência Total por níveis							7	2	1			
							9	7	14			
16 RB515 Niv2 5dn.ing	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	R	7	1	7	2	2	1	7	1	1	2	3
	G	7	7	7	7	2	2	2	2	1	2	5
	B	7	7	2	2	2	2	7	1	2	1	5
Frequência Total por níveis							7	2	1			
							10	13	7			
17 RB515 Niv2 5dn.ing	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	R	7	2	2	2	7	2	2	1	2	7	6
	G	7	2	2	1	1	2	7	1	7	7	3
	B	1	2	1	1	2	7	7	7	7	7	2
Frequência Total por níveis							7	2	1			
							12	11	7			
18 RB515 Niv2 5d.ing	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	R	2	1	7	7	1	1	7	7	2	7	2
	G	7	7	7	2	2	2	2	1	2	2	6
	B	2	2	2	2	2	2	2	7	2	7	8
Frequência Total por níveis							7	2	1			
							10	16	4			
19 RB515 Niv2 5d.ing	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	R	2	7	2	1	7	2	7	2	7	2	5
	G	2	2	7	2	2	2	2	2	7	2	8
	B	2	7	1	1	1	2	2	7	2	7	4
Frequência Total por níveis							7	2	1			
							9	17	4			
20 RB515 Niv2 5d.ing	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	R	2	7	2	2	2	2	1	1	1	7	5
	G	2	1	7	1	7	2	2	2	1	2	5
	B	2	2	2	2	2	2	2	2	7	2	9
Frequência Total por níveis							7	2	1			
							5	19	6			
21 RB515 Niv2 5dn.ing	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	R	1	7	2	1	7	7	2	7	2	1	3
	G	1	2	2	7	2	2	2	7	7	1	5
	B	2	2	7	2	2	2	2	2	2	7	8
Frequência Total por níveis							7	2	1			
							9	16	5			

TABELA 24 – Resultados conseguidos pela classificação do histograma no experimento 02 nível 1.

14 RB515 Niv1 5en.jpg												19 RB515 Niv1 5en.jpg											
ROI's												ROI's											
R												R											
G												G											
B												B											
Freq.Canal												Freq.Canal											
7												7											
6												7											
8												7											
16												18											
15 RB515 Niv1 5en.jpg												20 RB515 Niv1 5en.jpg											
ROI's												ROI's											
R												R											
G												G											
B												B											
Freq.Canal												Freq.Canal											
7												7											
7												15											
11												11											
16 RB515 Niv1 5en.jpg												21 RB515 Niv1 5en.jpg											
ROI's												ROI's											
R												R											
G												G											
B												B											
Freq.Canal												Freq.Canal											
7												7											
7												9											
13												14											
17 RB515 Niv1 5en.jpg												22 RB515 Niv1 5en.jpg											
ROI's												ROI's											
R												R											
G												G											
B												B											
Freq.Canal												Freq.Canal											
7												7											
9												8											
15												15											
18 RB515 Niv1 5en.jpg																							
ROI's																							
R																							
G																							
B																							
Freq.Canal																							
7																							
9																							
10																							

TABELA 25 – Resultados conseguidos pela classificação da cor invariante no experimento 01 nível 7.

01 RB486 Niv07es.ing	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	L1	1	7	2	2	7	2	1	1	1	2	2
	L2	7	7	2	7	7	1	7	7	7	2	7
	L3	7	7	7	1	2	2	1	7	7	7	6
Frequência Total por nível							7	2	1			
							15	8	7			
02 RB486 Niv07es.ing	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	L1	7	7	1	7	7	2	7	7	2	2	6
	L2	2	7	7	7	7	7	7	2	2	7	7
	L3	1	7	2	7	1	7	7	2	2	2	4
Frequência Total por nível							7	2	1			
							17	10	3			
03 RB486 Niv07es.ing	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	L1	2	7	2	7	7	2	7	7	2	7	6
	L2	2	7	2	2	7	2	2	2	2	2	2
	L3	7	7	7	7	7	1	7	7	7	1	8
Frequência Total por nível							7	2	1			
							16	12	2			
04 RB486 Niv07es.ing	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	L1	2	7	2	2	1	7	7	7	2	7	5
	L2	7	7	7	2	1	7	2	7	1	2	5
	L3	7	7	7	7	7	7	2	7	7	2	8
Frequência Total por nível							7	2	1			
							18	9	3			
05 RB486 Niv07es.ing	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	L1	7	1	7	1	7	7	7	7	2	2	6
	L2	7	2	2	7	7	1	7	1	2	7	5
	L3	7	7	7	7	7	1	7	1	2	7	7
Frequência Total por nível							7	2	1			
							18	6	6			
06 RB486 Niv07es.ing	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	L1	1	2	2	2	7	7	7	2	7	2	4
	L2	7	1	2	7	2	7	2	7	7	2	5
	L3	7	2	2	7	7	7	1	2	2	2	4
Frequência Total por nível							7	2	1			
							13	14	3			
07 RB486 Niv07es.ing	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	L1	2	2	7	1	2	7	7	2	1	7	4
	L2	2	2	7	7	7	7	7	7	1	2	6
	L3	2	2	7	2	7	7	7	7	2	7	6
Frequência Total por nível							7	2	1			
							16	11	3			
08 RB486 Niv07es.ing	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	L1	7	2	1	7	7	2	7	2	2	2	4
	L2	2	7	2	7	7	2	7	2	7	7	6
	L3	7	7	7	7	7	7	7	2	7	7	9
Frequência Total por nível							7	2	1			
							19	10	1			
22 RB486 Niv07dr.ing	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	L1	2	2	7	2	1	7	7	2	2	2	3
	L2	2	7	7	2	7	7	7	2	7	7	7
	L3	7	7	7	7	7	7	1	7	7	7	9
Frequência Total por nível							7	2	1			
							19	9	2			
23 RB486 Niv07dr.ing	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	L1	7	1	7	1	1	1	1	2	2	7	3
	L2	7	7	7	7	7	7	7	7	2	2	8
	L3	7	2	7	7	1	7	2	7	7	7	7
Frequência Total por nível							7	2	1			
							18	6	6			
23 RB486 Niv07es.ing	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	L1	2	2	7	7	2	2	7	7	2	1	4
	L2	2	2	1	7	7	2	7	7	7	7	6
	L3	1	7	1	1	7	2	7	7	2	7	6
Frequência Total por nível							7	2	1			
							16	10	4			
24 RB486 Niv07dr.ing	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	L1	7	1	1	7	1	7	7	2	2	1	4
	L2	7	7	7	7	2	7	7	2	2	2	6
	L3	1	7	7	7	2	7	2	7	1	1	5
Frequência Total por nível							7	2	1			
							15	8	7			
24 RB486 Niv07es.ing	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	L1	1	1	1	1	7	2	2	2	2	2	1
	L2	7	1	7	1	7	1	7	7	1	2	5
	L3	2	2	7	1	2	7	7	7	2	2	4
Frequência Total por nível							7	2	1			
							10	11	9			
25 RB486 Niv07dr.ing	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	L1	2	2	1	7	1	7	7	7	7	1	5
	L2	2	2	1	7	7	7	7	7	7	7	7
	L3	1	2	1	2	2	7	7	2	7	2	3
Frequência Total por nível							7	2	1			
							12	12	6			

TABELA 26 – Resultados conseguidos pela classificação da cor invariante no experimento 01 nível 2.

ROI's													1	2	3	4	5	6	7	8	9	10	Freq.Canal
09 RB6-5 Niv2 5e.jpg	L1	1	2	2	1	7	7	2	1	2	1	4											
	L2	2	7	2	2	2	7	2	1	7	2	6											
	L3	2	7	2	2	2	2	2	7	7	1	6											
Frequência Total por níveis						7	2	1															
						8	16	6															

ROI's													1	2	3	4	5	6	7	8	9	10	Freq.Canal
16 RB515 Niv2 5d.jpg	L1	1	2	1	2	2	2	1	1	1	2	5											
	L2	2	1	2	7	2	2	7	7	2	2	6											
	L3	2	7	2	7	2	7	7	1	7	1	3											
Frequência Total por níveis						7	2	1															
						8	14	8															

ROI's													1	2	3	4	5	6	7	8	9	10	Freq.Canal
10 RB6-5 Niv2 5e.jpg	L1	1	2	2	2	2	7	2	1	1	1	5											
	L2	2	2	2	7	2	7	1	2	2	2	7											
	L3	2	7	2	2	2	2	1	2	1	2	7											
Frequência Total por níveis						7	2	1															
						4	19	7															

ROI's													1	2	3	4	5	6	7	8	9	10	Freq.Canal
11 RB6-5 Niv2 5e.jpg	L1	2	1	7	1	2	2	2	2	2	2	7											
	L2	2	1	2	1	1	7	1	2	1	7	3											
	L3	7	1	2	7	2	1	2	2	1	2	5											
Frequência Total por níveis						7	2	1															
						5	15	10															

ROI's													1	2	3	4	5	6	7	8	9	10	Freq.Canal
12 RB6-5 Niv2 5e.jpg	L1	2	2	2	1	2	7	1	1	1	2	5											
	L2	2	2	2	2	7	7	2	1	2	2	7											
	L3	2	7	7	1	7	2	1	2	1	2	4											
Frequência Total por níveis						7	2	1															
						6	16	8															

ROI's													1	2	3	4	5	6	7	8	9	10	Freq.Canal
13 RB6-5 Niv2 5e.jpg	L1	2	2	2	7	2	2	7	7	7	2	6											
	L2	2	2	2	2	2	2	2	7	7	7	8											
	L3	2	2	2	1	2	7	2	2	2	7	7											
Frequência Total por níveis						7	2	1															
						8	21	1															

ROI's													1	2	3	4	5	6	7	8	9	10	Freq.Canal
14 RB515 Niv2 5d.jpg	L1	2	2	1	2	2	1	1	1	1	2	6											
	L2	2	1	2	7	7	2	2	1	2	2	6											
	L3	7	7	2	1	2	7	2	2	2	1	5											
Frequência Total por níveis						7	2	1															
						5	17	8															

ROI's													1	2	3	4	5	6	7	8	9	10	Freq.Canal
15 RB515 Niv2 5d.jpg	L1	1	1	2	1	1	7	2	2	2	1	4											
	L2	2	1	2	2	2	2	2	2	1	2	8											
	L3	2	7	7	2	2	1	2	1	1	2	5											
Frequência Total por níveis						7	2	1															
						3	17	10															

ROI's													1	2	3	4	5	6	7	8	9	10	Freq.Canal
17 RB515 Niv2 5d.jpg	L1	2	1	7	2	2	2	7	2	2	2	7											
	L2	2	2	2	2	2	2	2	2	7	2	9											
	L3	2	2	2	2	2	2	2	2	7	2	9											
Frequência Total por níveis						7	2	1															
						4	25	1															

ROI's													1	2	3	4	5	6	7	8	9	10	Freq.Canal
18 RB515 Niv2 5d.jpg	L1	2	7	2	1	2	2	2	7	2	2	7											
	L2	2	7	2	1	2	2	2	2	2	2	8											
	L3	2	1	2	2	2	1	2	2	2	1	7											
Frequência Total por níveis						7	2	1															
						3	22	5															

ROI's													1	2	3	4	5	6	7	8	9	10	Freq.Canal
19 RB515 Niv2 5d.jpg	L1	2	1	7	2	2	2	2	2	1	7	6											
	L2	7	1	7	2	2	2	2	2	1	2	6											
	L3	7	2	7	2	1	7	2	2	7	2	5											
Frequência Total por níveis						7	2	1															
						8	17	5															

ROI's													1	2	3	4	5	6	7	8	9	10	Freq.Canal
20 RB515 Niv2 5d.jpg	L1	1	2	2	2	1	1	1	7	7	7	3											
	L2	2	2	2	7	2	2	1	2	7	2	7											
	L3	7	2	2	2	2	7	2	2	2	2	8											
Frequência Total por níveis						7	2	1															
						7	18	5															

ROI's													1	2	3	4	5	6	7	8	9	10	Freq.Canal
21 RB515 Niv2 5d.jpg	L1	2	2	1	2	1	7	1	2	7	1	4											
	L2	2	7	2	2	7	7	7	2	2	2	6											
	L3	2	7	2	1	2	1	2	2	2	2	7											
Frequência Total por níveis						7	2	1															
						7	17	6															

TABELA 27 – Resultados conseguidos pela classificação da cor invariante no experimento 01 nível 1.

14 RB515 Niv1 5e.jpg												19 RB515 Niv1 5e.jpg											
ROI's												ROI's											
L1												L1											
L2												L2											
L3												L3											
Freq. Canal												Freq. Canal											
7 2 1												7 2 1											
2 13 15												1 21 8											
15 RB515 Niv1 5e.jpg												20 RB515 Niv1 5e.jpg											
ROI's												ROI's											
L1												L1											
L2												L2											
L3												L3											
Freq. Canal												Freq. Canal											
7 2 1												7 2 1											
5 10 15												6 12 12											
16 RB515 Niv1 5e.jpg												21 RB515 Niv1 5e.jpg											
ROI's												ROI's											
L1												L1											
L2												L2											
L3												L3											
Freq. Canal												Freq. Canal											
7 2 1												7 2 1											
8 5 17												7 12 11											
17 RB515 Niv1 5e.jpg												22 RB515 Niv1 5e.jpg											
ROI's												ROI's											
L1												L1											
L2												L2											
L3												L3											
Freq. Canal												Freq. Canal											
7 2 1												7 2 1											
2 8 20												5 6 19											
18 RB515 Niv1 5e.jpg																							
ROI's												ROI's											
L1												L1											
L2												L2											
L3												L3											
Freq. Canal												Freq. Canal											
7 2 1												7 2 1											
2 15 13																							

TABELA 28 – Resultados conseguidos pela classificação da cor invariante no experimento 02 nível 7.

01 RB486 Niv07en.ing	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	L1	2	2	7	2	7	7	2	7	7	7	6
	L2	7	1	7	7	7	7	1	1	7	7	7
	L3	2	7	7	2	2	7	7	7	7	2	6
Frequência Total por nível							7	2	1			
							19	8	3			
02 RB486 Niv07en.ing	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	L1	7	2	2	1	7	7	7	7	7	7	7
	L2	7	1	7	7	1	7	7	7	2	7	7
	L3	7	7	7	7	7	2	2	7	7	7	8
Frequência Total por nível							7	2	1			
							22	5	3			
03 RB486 Niv07en.ing	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	L1	7	2	7	7	2	7	7	7	1	1	6
	L2	7	7	7	7	7	7	7	7	7	1	9
	L3	2	2	7	7	7	2	7	2	7	7	8
Frequência Total por nível							7	2	1			
							21	6	3			
04 RB486 Niv07en.ing	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	L1	7	1	2	7	7	7	7	7	7	7	8
	L2	7	2	1	7	7	7	7	7	7	7	8
	L3	7	7	7	7	7	2	7	2	2	7	7
Frequência Total por nível							7	2	1			
							23	5	2			
05 RB486 Niv07en.ing	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	L1	1	7	1	7	1	7	7	1	7	7	6
	L2	7	2	1	1	2	7	1	2	2	7	4
	L3	2	7	7	7	7	7	7	7	2	7	8
Frequência Total por nível							7	2	1			
							18	5	7			
06 RB486 Niv07en.ing	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	L1	7	7	7	7	7	7	7	7	2	7	9
	L2	7	7	7	2	7	7	7	7	7	7	9
	L3	7	7	7	2	2	2	2	7	2	7	5
Frequência Total por nível							7	2	1			
							23	7	0			
07 RB486 Niv07en.ing	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	L1	2	1	1	7	1	7	7	7	7	7	6
	L2	1	1	2	7	7	1	7	7	7	7	6
	L3	7	7	7	7	7	7	2	7	7	2	8
Frequência Total por nível							7	2	1			
							21	3	6			
08 RB486 Niv07en.ing	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	L1	2	2	7	7	2	1	1	7	7	1	4
	L2	7	7	7	7	1	1	7	7	7	1	7
	L3	1	7	7	7	2	7	7	7	7	1	7
Frequência Total por nível							7	2	1			
							18	4	8			
22 RB486 Niv07dn.ing	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	L1	1	2	7	1	1	1	7	1	7	1	3
	L2	1	1	1	2	1	1	1	1	7	1	1
	L3	7	7	7	2	2	1	2	7	7	1	5
Frequência Total por nível							7	2	1			
							9	5	16			
23 RB486 Niv07dn.ing	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	L1	2	7	7	2	1	7	2	7	7	7	6
	L2	1	7	7	1	1	7	7	1	7	1	5
	L3	2	2	7	7	7	7	7	1	2	2	5
Frequência Total por nível							7	2	1			
							16	7	7			
23 RB486 Niv07en.ing	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	L1	1	7	7	7	7	7	7	7	7	7	9
	L2	1	1	7	7	7	7	7	2	7	2	6
	L3	1	7	7	7	7	7	2	7	7	7	8
Frequência Total por nível							7	2	1			
							23	3	4			
24 RB486 Niv07dn.ing	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	L1	1	7	7	7	7	2	7	1	7	7	7
	L2	1	1	7	7	7	2	1	1	1	7	4
	L3	7	1	2	7	2	2	7	7	2	2	4
Frequência Total por nível							7	2	1			
							15	7	8			
24 RB486 Niv07en.ing	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	L1	2	1	7	7	1	1	7	2	7	7	5
	L2	1	7	7	7	1	7	7	7	1	7	7
	L3	7	7	7	1	7	7	2	7	7	7	8
Frequência Total por nível							7	2	1			
							20	3	7			
25 RB486 Niv07dn.ing	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	L1	7	1	1	7	7	2	7	7	7	7	7
	L2	7	7	1	7	7	7	1	7	7	7	8
	L3	7	7	2	7	7	7	7	2	7	2	7
Frequência Total por nível							7	2	1			
							22	4	4			

TABELA 29 – Resultados conseguidos pela classificação da cor invariante no experimento 02 nível 2.

09 RB6-5 Niv2 5en.jpg	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	L1	2	2	2	1	2	1	2	2	2	2	8
	L2	1	1	2	7	1	2	1	2	2	2	6
	L3	1	2	2	7	2	7	7	1	2	2	5
Frequência Total por nível		7 2 1 4 19 7										

10 RB6-5 Niv2 5en.jpg	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	L1	7	1	7	1	7	7	2	2	1	2	3
	L2	7	2	7	1	1	7	7	2	1	1	2
	L3	7	7	7	7	7	7	7	7	7	1	1
Frequência Total por nível		7 2 1 17 6 7										

11 RB6-5 Niv2 5en.jpg	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	L1	2	2	7	7	7	7	7	1	7	2	3
	L2	7	2	7	7	1	7	1	1	7	1	1
	L3	2	2	2	2	2	2	7	2	2	7	8
Frequência Total por nível		7 2 1 13 12 5										

12 RB6-5 Niv2 5en.jpg	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	L1	7	7	2	7	7	7	7	1	7	1	1
	L2	7	7	1	7	7	7	7	2	7	1	1
	L3	7	7	7	2	7	7	2	7	7	7	2
Frequência Total por nível		7 2 1 22 4 4										

13 RB6-5 Niv2 5e.jpg	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	L1	7	1	7	7	7	7	7	7	7	7	0
	L2	2	1	7	7	7	7	7	7	7	7	1
	L3	1	7	2	7	7	7	2	2	2	7	4
Frequência Total por nível		7 2 1 22 5 3										

14 RB515 Niv2 5d.jpg	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	L1	2	2	2	2	2	2	2	2	2	2	10
	L2	1	1	1	2	1	2	1	2	2	1	4
	L3	1	1	2	1	2	2	1	2	1	2	5
Frequência Total por nível		7 2 1 0 19 11										

15 RB515 Niv2 5d.jpg	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	L1	1	1	2	2	1	1	2	2	2	2	6
	L2	1	1	2	2	1	2	1	1	1	2	4
	L3	1	2	2	7	1	2	1	1	1	1	3
Frequência Total por nível		7 2 1 1 13 16										

16 RB515 Niv2 5dn.jpg	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	L1	2	1	1	2	2	2	2	1	2	2	7
	L2	2	1	2	2	2	2	2	2	2	1	8
	L3	1	1	1	2	2	2	2	2	2	2	7
Frequência Total por nível		7 2 1 0 22 8										

17 RB515 Niv2 5dn.jpg	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	L1	2	2	1	7	2	2	2	1	2	7	6
	L2	1	2	2	1	2	1	1	1	1	2	4
	L3	2	2	2	7	2	2	2	2	1	1	7
Frequência Total por nível		7 2 1 3 17 10										

18 RB515 Niv2 5d.jpg	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	L1	2	2	2	1	2	2	2	2	1	2	8
	L2	2	2	1	1	1	1	2	2	1	2	5
	L3	1	2	2	2	1	2	2	2	2	2	8
Frequência Total por nível		7 2 1 0 21 9										

19 RB515 Niv2 5d.jpg	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	L1	1	2	2	1	2	2	2	2	2	1	7
	L2	2	1	2	1	2	1	1	1	1	2	4
	L3	2	1	1	7	2	1	2	7	2	1	4
Frequência Total por nível		7 2 1 2 15 13										

20 RB515 Niv2 5d.jpg	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	L1	2	2	2	2	2	2	2	2	2	2	10
	L2	1	1	2	1	2	2	2	1	2	2	6
	L3	2	1	1	2	2	7	2	1	1	2	5
Frequência Total por nível		7 2 1 1 21 8										

R21 RB515 Niv2 5dn.jpg	ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
	L1	1	2	2	2	2	2	2	2	2	2	9
	L2	7	2	1	2	2	1	2	2	1	2	7
	L3	2	1	1	2	7	7	2	2	2	2	7
Frequência Total por nível		7 2 1 1 23 6										

TABELA 30 – Resultados conseguidos pela classificação da cor invariante no experimento 02 nível 1.

14 RB515 Niv1 5en.jpg													ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
													L1	2	1	1	2	2	2	2	2	1	2	3
													L2	1	1	2	1	2	2	2	1	1	2	5
													L3	2	1	2	2	2	2	1	1	2	2	3
													Frequência Total por nível						7	2	1			
																			0	19	11			
15 RB515 Niv1 5en.jpg													ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
													L1	1	2	2	2	1	2	2	1	1	2	4
													L2	1	2	2	1	2	2	2	1	7	2	3
													L3	2	1	2	2	2	1	2	2	2	2	2
													Frequência Total por nível						7	2	1			
																			1	20	9			
16 RB515 Niv1 5en.jpg													ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
													L1	1	2	2	2	2	2	2	2	2	1	2
													L2	7	1	2	2	2	2	2	1	1	1	4
													L3	7	1	2	2	7	1	2	2	1	2	3
													Frequência Total por nível						7	2	1			
																			3	18	9			
17 RB515 Niv1 5en.jpg													ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
													L1	2	2	2	1	2	2	1	2	2	1	3
													L2	2	2	2	2	1	2	2	7	2	2	1
													L3	7	2	2	2	2	2	2	2	2	2	0
													Frequência Total por nível						7	2	1			
																			2	24	4			
18 RB515 Niv1 5en.jpg													ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
													L1	2	1	2	1	2	1	2	1	2	2	4
													L2	7	2	1	2	2	2	2	2	2	2	1
													L3	7	1	1	7	2	2	2	1	2	1	4
													Frequência Total por nível						7	2	1			
																			3	18	9			
19 RB515 Niv1 5en.jpg													ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
													L1	1	2	1	2	1	2	2	1	2	1	5
													L2	1	7	1	7	1	1	1	7	1	7	6
													L3	2	2	2	7	7	2	1	7	2	7	1
													Frequência Total por nível						7	2	1			
																			8	10	12			
20 RB515 Niv1 5en.jpg													ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
													L1	1	2	2	1	2	2	2	2	2	2	2
													L2	7	2	2	2	1	2	1	1	1	2	4
													L3	1	1	2	2	1	2	2	2	2	2	3
													Frequência Total por nível						7	2	1			
																			1	20	9			
21 RB515 Niv1 5en.jpg													ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
													L1	2	1	1	2	1	2	2	2	1	2	4
													L2	2	7	1	7	2	1	7	2	7	2	2
													L3	2	7	2	7	1	1	7	1	2	2	3
													Frequência Total por nível						7	2	1			
																			7	14	9			
22 RB515 Niv1 5en.jpg													ROI's	1	2	3	4	5	6	7	8	9	10	Freq.Canal
													L1	2	2	2	2	2	2	1	2	2	2	1
													L2	2	2	2	2	2	2	1	2	2	2	1
													L3	1	1	2	2	2	2	1	2	2	2	3
													Frequência Total por nível						7	2	1			
																			0	25	5			

Os resultados obtidos com a classificação do histograma e da cor invariante para dez ROI's selecionadas nos dois experimentos, são apresentados na TABELA 31 da seguinte forma: foram contadas as classificações corretas para os três níveis de infecção em relação ao número de fotos disponíveis de cada um dos níveis. Foram levadas em considerações as classificações baseadas na frequência total (nível mais frequente contando-se todos as regiões e todos os canais de cores) e as classificações baseadas nos três canais de cores separadamente. O total leva em consideração a soma das classificações corretas para os três níveis de infecção e seu percentual leva em consideração as 36 imagens trabalhadas.

TABELA 31 – Análise dos resultados da classificação das dez ROI's nos dois experimentos.

Experimento 01		Histograma			Cor Invariante			
	Frequência Total	R	G	B	Frequência Total	L	L _a	L _b
Nível 7	8 / 14	6 / 14	4 / 14	12 / 14	11 / 14	5 / 14	13 / 14	10 / 14
Nível 2	5 / 13	7 / 13	4 / 13	4 / 13	13 / 13	9 / 13	12 / 13	12 / 13
Nível 1	7 / 9	5 / 9	5 / 9	8 / 9	6 / 9	7 / 9	5 / 9	7 / 9
Total	20 / 36	18 / 36	13 / 36	24 / 36	30 / 36	21 / 36	30 / 36	29 / 36
Percentual	55,55%	50%	36,11%	66,66%	83,33%	58,33%	83,33%	80,55%

Experimento 02		Histograma			Cor Invariante			
	Frequência Total	R	G	B	Frequência Total	L	L _a	L _b
Nível 7	9 / 14	6 / 14	5 / 14	11 / 14	13 / 14	13 / 14	11 / 14	12 / 14
Nível 2	7 / 13	6 / 13	7 / 13	5 / 13	8 / 13	9 / 13	4 / 13	7 / 13
Nível 1	6 / 9	8 / 9	5 / 9	6 / 9	1 / 9	1 / 9	6 / 9	1 / 9
Total	22 / 36	20 / 36	17 / 36	22 / 36	22 / 36	23 / 36	21 / 36	20 / 36
Percentual	61,11%	55,55%	47,22%	61,11%	61,11%	63,88%	58,33%	55,55%

Diante dos resultados podemos tecer algumas observações:

- O melhor desempenho foi obtido no experimento 01 com a característica cor invariante, revelando na classificação pela frequência total um desempenho de 30 acertos em 36 imagens (83,33%). Porcentagem igual a L2 no mesmo experimento.
- Embora a cor invariante tenha tido bom desempenho na classificação do experimento 01, o mesmo não ocorreu no experimento 02 para a identificação do nível 01.
- Dos canais de cores, o azul produziu o melhor resultado nas classificações com histograma da cor (66,6% no experimento 01 e 61,1% no experimento 02).
- A classificação, levando-se em consideração os níveis de infecção separadamente, é consideravelmente alta em alguns casos, como o da cor invariante no experimento 01. Com 13 acertos de 14 fotos (92,8%) pela L2 no nível 7; 12 acertos de 13 fotos (92,3%) pela L2 e pela L3 no nível 2 ou o acerto de 7 em 9 fotos (77,7%) pela L1 e pela L3 no nível 1.

CAPÍTULO 06 – CONCLUSÕES E TRABALHOS FUTUROS

6.1. CONCLUSÕES

Este trabalho relacionou três áreas distintas de pesquisas: fitopatologia em cana-de-açúcar, processamento de imagens e inteligência artificial (aprendizado de máquina).

O objetivo deste trabalho era, a partir de fotos aéreas identificar os níveis de infecção nas áreas plantadas com cana-de-açúcar. Os primeiros resultados se mostraram bem promissores e o aprofundamento da técnica seria de grande valia ao setor sucro-alcooleiro, pois reduziria significativamente os custos e o tempo de diagnóstico, reduzindo assim os prejuízos.

A abordagem adotada para este trabalho foi a de dividi-lo em dois experimentos diferentes. No experimento 01 foram trabalhados os dados extraídos de fotos digitalizadas, que aparentemente sofreram uma normalização das cores na revelação. No experimento 02, trabalhou-se os dados extraídos da digitalização dos negativos destas fotos, imunes da normalização de cores efetuada pelo equipamento de revelação. Esta divisão foi feita, pois havia uma perceptível diferença visual entre as imagens adquiridas pelos dois métodos. Esta diferença mostrou-se significativa com resultados bem distintos em todos os testes feitos.

Foram adotadas três metodologias de classificação diferentes em todos os testes aplicados nos dois experimentos. E das duas características mais significativas que foram testadas a cor invariante mostrou resultados superiores ao histograma da cor em todos os testes feitos no experimento 01 e foram praticamente equivalentes no experimento 02.

Como os dados do experimento 01 foram alterados pela normalização na revelação, o sistema de cor invariante foi mais eficiente do que o histograma. O sistema L1L2L3 (cor invariante) conseguiu suavizar as distorções na iluminação corrigindo o problema da normalização, já o histograma manteve os dados modificados.

Desta maneira, o sistema de cor invariante se mostrou o mais eficiente e adequado para ser usado, provendo uma boa taxa de classificação com 30 acertos em 36 imagens (83,3%) no experimento 01. Isto nos permite sinalizar a existência de uma correlação entre a avaliação feita *in loco* pelo especialista e o método proposto nesta pesquisa.

Já os dados do experimento 02, aqueles adquiridos da digitalização dos negativos das fotos, não passaram por nenhuma modificação, por isso a característica do histograma se mostrou equivalente à cor invariante.

Embora nesta pesquisa tenham sido avaliados somente três níveis de infecção, a rede neural se mostrou eficiente na distinção entre os níveis 01 e 02 cuja diferença visual observada nas imagens aéreas é praticamente imperceptível. Por exemplo, na classificação no experimento 1 da cor invariante baseada na frequência total a rede classificou corretamente todas as fotos disponíveis do nível 2 (100%) e acertou seis das nove fotos do nível 1 (66,6%). Já na classificação da cor invariante baseada na L1, L2 e L3, separadamente, em destaque a L3, o acerto da rede foi de doze em treze fotos disponíveis para o nível 2 (92,3%) e sete fotos das nove disponíveis para o nível 1 (77,7%).

Por isso, se for possível adquirir amostras de todos os 09 níveis, a autora acredita ser possível uma classificação efetiva usando as fotos aéreas de regiões contaminadas, podendo contribuir com a redução do deslocamento do especialista ao campo.

Esta avaliação do especialista, que é feita visualmente, é um método subjetivo. Para corroborar tal avaliação foi desenvolvido um método totalmente automático envolvendo segmentação híbrida. Por meio destes processos foi possível fazer uma boa avaliação de maneira eficiente. Tal correlação entre os métodos possibilita uma avaliação sem a necessidade do deslocamento do especialista ao campo, pois com apenas algumas fotos digitais de folhas infeccionadas é possível fazer uma avaliação tão boa quanto a feita *in loco*.

Como a característica trabalhada é a cor, e não a textura, as oscilações de altitude do aeromodelo durante o processo de captura não interferiu na qualidade da classificação, pois todas as fotos que apresentaram uma altitude mais elevada foram classificadas corretamente.

Uma das dificuldades encontradas para o desenvolvimento desta pesquisa foi o de selecionar boas áreas cultivadas com cana-de-açúcar (aquelas que apresentassem o maior número possível de diferentes níveis de infecção) para a aquisição das imagens. A ferrugem

se manifesta quando o clima apresenta umidade do ar alta (70%), mas sem chuvas. As chuvas “lavam” as folhas eliminando os esporos, prejudicando consideravelmente a avaliação, mas ajudam na proliferação da doença.

Outra dificuldade encontrada foi a falta de conhecimento mais preciso do posicionamento geográfico de cada foto com relação à sua área ocupada no canavial. Como o canavial não apresenta uma homogeneidade na infecção, isto é, diferentes níveis de infecção em pequenas áreas, e como não havia mecanismos para uma melhor associação entre a área da avaliação com a imagem capturada, isto pode ter interferido em alguns dos resultados. Em outras palavras, é possível que algumas das imagens adquiridas e rotuladas com um determinado nível de infecção, na realidade não correspondam exatamente àquele nível ou, então, apresentem uma combinação de mais de um nível. Das seis imagens classificadas incorretamente (na melhor classificação conseguida), três se encontravam em áreas de transição entre níveis.

6.2. TRABALHOS FUTUROS

A autora acredita que uma considerável porção do erro de classificação deve-se à falta de melhor conhecimento da área capturada nas imagens com os reais níveis de infecção observados em solo. Isso poderia ser corrigido com um sistema de geo-referência, baseado em GPS. Com um GPS embarcado na aeronave e outro em solo, poder-se-ia ter um grau de precisão melhor sobre posicionamento da aeronave e a real área captura em solo. Dessa maneira seria possível aferir com mais precisão a eficiência do método.

Com relação ao melhoramento da técnica de identificação dos níveis de ferrugem, pode-se citar o cálculo da área capturada em foto em função da altitude do aeromodelo no momento da aquisição da foto (com um altímetro embarcado no aeromodelo). Essa informação, aliada ao conhecimento das coordenadas geo-referenciadas, daria aos especialistas uma certeza maior do local real em que o problema ocorre, permitindo assim que as medidas de tratamento sejam tomadas. É preciso salientar que tanto o GPS quanto o altímetro são equipamentos projetados e previstos para serem em breve embarcados nos aeromodelos do projeto ARARA, o que torna a realização dessa atividade um processo factível.

Como no experimento 01, para o qual se obteve a melhor classificação, o canal azul foi de maior destaque (66,6% para o histograma), uma tentativa de melhoramento do método seria o de realizar o treinamento da rede neural com os canais de cores separadamente, eliminado assim o ruído das outras cores. Ou treinar somente com a L2 do sistema de cor invariante, o qual obteve 80,5% de acerto.

Desenvolver um método baseado na combinação do histograma com a cor invariante, para treinamento da rede, é uma alternativa interessante levando em consideração que estas foram as características de melhor desempenho entre todas as extraídas e usadas para treinamento da rede neural.

Outra tentativa de melhoramento do método seria o de alterar a topologia da rede para 768 (256r + 256g + 256b) neurônios na camada de entrada, assim os três canais de cores seriam apresentados juntos à rede.

REFERÊNCIAS BIBLIOGRÁFICAS

- ALLEMANG, D., ALMASSY, N., SCHRETER, Z. (1990) **Module Description: Machine Learning**. 26/nov/1990. Disponível em: <<http://cbl.leeds.ac.uk/nikos/pail/intml/subsection3.11.4.html>>. Acesso em: 02/01/2003.
- AMORIM, L. et al. (1987) **Metodologia de Avaliação da Ferrugem da Cana-de-Açúcar (*Puccinia melanocephala*)**. Boletim Técnico Copersucar. pág.13-16.
- ASNAGHI, C., D'HONT, A., GLASZMANN, J. C., ROTT, P. (2000) **Resistance of Sugarcane Cultivar R570 to *Puccinia melanocephala* Isolates from Different Geographic Locations**. Centre de coopération internationale en recherche agronomique pour le développement, Cirad. Aceito para publicação em 12/11/2000. Disponível em: <<http://www.apsnet.org/pd/summaries/dma01sum.asp>>. Acesso em: 23/09/2002.
- BLECHER, B. (1986) **A Ferrugem Chegou. E a Cana Ganha Mais um Inimigo**. Jornal O Estado de São Paulo, 24/12/1986.
- BRAGA, A.P. et al. (2003) **Redes Neurais Artificiais**. In: REZENDE, S. O. (2003) **Sistemas Inteligentes – Fundamentos e Aplicações**. 1ª Edição. Editora Manole Ltda. Cap.06. p. 141-168.
- CAVALHEIRO, A. P., & COMES, E. R. (2003) **Máquinas de Vetor de Suporte**. Instituto de Informática, Universidade Federal do Rio Grande do SUL (UFRGS), Porto Alegre.
- COMANICIU, D., & MEER, P. (1997) **Robust Analysis of Feature Spaces: Color Image Segmentation**. Proceedings of IEEE Conference on Computer Vision and Pattern Recognition, San Juan, Puerto Rico. p 750-755.
- COPERSUCAR. (1986) **Ferrugem da Cana-de-Açúcar e sua Constatação no Município de Capivari**. Edição Especial. Boletim Técnico Copersucar; dezembro de 1986. p. 3-8.
- DENG, Y., & MOORE, M. S. (2001) **An Efficient Color Representation for Image Retrieval**. IEEE Transactions on Image Processing; Vol. 10, no 01, Janeiro de 2001. p.140-147.
- FAIECHILD, M. D. (1998) **Color Appearance Models**. Ed. Addison-Wesley Longman. 417p.
- FOLEY, J. D., & DAN, A. V. (1994) **Introduction to Computer Graphics**. Ed. Addison-Wesley. p. 410-421.

- GEVERS T., & SMEULDERS, A. W. M. (1999) **Color Based Object Recognition**. In A. Del Bimbo, editor, Lecture Notes in Computer Science, volume 1310, pages 319–327. Springer Verlag, 1997.
- GOLDSTEIN, E. B. (1989) **Sensation and Perception**. 3ª edição. University of Pittsburgh. California: Editora Wadsworth Publishing Company. 598p.
- GONZALEZ, R. C., & WOODS, R. E. (1992) **Digital Image Processing**. Addison-Wesley Publishing Company. 703 p.
- GUELPH. (2002) **Image Processing Algorithms and Applications**. University of Guelph. Janeiro 2002. Disponível em: <<http://www.uoguelph.ca/~mwirth/CIS6320/lecture4.pdf>>. Acesso em: 18/08/2003.
- HAYKIN, S. (2001) **Neural Networks – A Comprehensive Foundation**. 2a Edição. Editora Prentice Hall. 900p.
- HEARN, D., & BAKER, M. P. (1994) **Computer Graphics**. Editora Prentice-Hall International, INC. Capítulo 15. 651p.
- HUANG, J., KUMAR, S. M., MITRA, M., ZHU, W. J., ZABIH, R. (1997) **Image Indexing Using Color Correlograms**. In Proc. IEEE Comp. Soc. Conf. Comp. Vis. and Patt. Rec., pages 762-768, 1997.
- LIAO, P., CHEN, T., CHUNG, P. (2001) **A Fast Algorithm for Multilevel Thresholding**. Journal of Information Science and Engineering 17, p.713-727. Disponível em: <www.iis.sinica.edu.tw/JISE/2001/200109_01.pdf>. Acesso em: 19/08/03.
- LOPES, A.A. (2003) **Inteligência Artificial – Uma Visão Geral**. ICMC – USP, São Carlos/SP. Disponível em: <<http://coweb.icmc.sc.usp.br/coweb/mostra.php?ident=134.2>>. Acesso em: 01/12/03.
- LORENA, A. C., & CARVALHO, A. C. P. (2002) **As Máquinas de Vetores Suporte – Support Vector Machines**. Relatório Técnico no. 192, ICMC – USP, São Carlos/SP, Junho 2002.
- MARTINKAUPPI, J. B., SORIANO, M. N., LAAKSONEN, M. H. (2001) **Behavior of Skin Color Under Varying Illumination Seen by Different Cameras at Different Color Spaces**. University of Oulu. Finland.
- MARQUES, O. F., & VIEIRA, H.N. (1999) **Processamento Digital de Imagens**. Série Acadêmica. Rio de Janeiro: Editora Brasport.
- MASUDA, Y., et al. (1986) **A Ferrugem da Cana-de-Açúcar no Brasil**. Brasil Açucareiro – Planalsucar, Ano LIV – vol.104, n^{os} 5 e 6. p. 6-13.
- MAHLMEISTER, U., PAHL, H., SOMMER, G. (1996) **Color – Orientation Indexing**. Universität zu Kiel. Alemanha.
- MEDEIROS, A. S., & CARVALHO, P. C. P. (2001) **Color Quantization by Pairwise Clustering Using a Reduced Graph**. Instituto de Matemática Pura e aplicada. Rio de Janeiro.

- MONARD, M.C. & BARANAUSKAS, J.A. (2003a) **Conceitos sobre Aprendizado de Máquina.** In: REZENDE, S. O. (2003) *Sistemas Inteligentes – Fundamentos e Aplicações*. 1ª Edição. Editora Manole Ltda. Cap.04. p. 89-114.
- MONARD, M.C. & BARANAUSKAS, J.A. (2003b) **Indução de Regras e Árvore de Decisão** In: REZENDE, S. O. (2003) *Sistemas Inteligentes – Fundamentos e Aplicações*. 1ª Edição. Editora Manole Ltda. Cap.05. p.115-139.
- PASS, G., ZABIH, R., MILLER, J. (1996) **Comparing Image Using Color Coherence Vectors**. Computer Science Department. Cornell University. Ithaca.
- PASS, G., & ZABIH, R. (1999) **Comparing Images Using Joint Histograms**. Computer Science Department. Cornell University. Ithaca.
- PEREIRA, F. M. (2002) **Avaliação do Conhecimento Descoberto**. Disponível em: <<http://www.ppgia.pucpr.br/~picolotto/Weka/Evaluation.ppt>>. Acesso em: 11/07/2003.
- PRECHELT, L. (1994) **Proben1 – A set of Neural Network Benchmark Problems and Benchmarking Rules**. University Karlsruhe. Alemanha.
- RAO, A. B., et al. (1996) **K-Means Clustering Algorithm**. Defense Acquisition University; 10/10/1996. Disponível em: <http://cne.gmu.edu/modules/dau/stat/clustgalgs/clust5_bdy.html>. Acesso em: 10/01/2003.
- RUDOLPH, A., et al. (1968) **Luz e Visão**. Biblioteca Científica LIFE. Rio de Janeiro: Livraria José Olímpio Editora. 204 p.
- SANGUINO, A., & TOLEDO, A. C. D. (1983) **Considerações Sobre a Ferrugem da Cana-de-Açúcar**. Divisão de Melhoramento. Boletim Técnico Copersucar. p.25-28.
- SCHEERING, C. (1997) **Domain-Knowledge Incorporation for Fast Color Image Segmentation Using a Pre-Clustered Chromaticity-Plane**. University of Bielefeld.
- SILVA, M.A., et al. (2001) **Perdas Causadas pela Ferrugem, Puccinia melanocephala, à Variedades de Cana-de-Açúcar com Diferentes Níveis de Resistência**. Summa Phytopatologica, v.27, n.1. p.39-43.
- SKARBEEK, W., & KOSCHAN, A. (1994) **Colour Image Segmentation - A Survey**. Technical report, Technical University Berlin.
- SMITH, J. R., & CHANG, S. (1995) **Single color extraction and Image Query**. Columbia University Department of Electrical Engineering and Center for Telecommunications Research, New York.
- SMITH, J. R., & CHANG, S. (1996) **Tools and Techniques for color Image Retrieval**. Columbia University Department of Electrical Engineering and Center for Telecommunications Research, New York.

- SOBOTTKA, K., & PITAS, I. (1996) **Extraction of Facial Regions and Features Using Color and Shape Information**. Proc. 13th International Conference on Pattern Recognition, Vienna, Austria. August 1996. p421-425.
- SONKA, M.; VACLAN, H.; BOYLE, R.. (1999) **Image Processing Analysis, and Machine Vision**. PWS Publishing: Editora Chapman & Hall , 2ª edição. 555 p.
- STRICKER, M., & ORENGO, M. (1995) **Similarity of Color Images**. Proceeding of SPIE Storage and Retrieval for Image and Video Databases III. Vol. 2420. p. 381-392.
- TECHTARGET. (2002) **CMYK**. 16/10/2002. Disponível em: <[http:// http://whatis.techtarget.com/definition/0,,sid9_gci211805,00.html](http://http://whatis.techtarget.com/definition/0,,sid9_gci211805,00.html)>. Acesso em: 11/07/2003.
- YANG, J. C. (2000) **A Light Field Camera for Image Based Rendering**. Massachusetts Institute of Technology.
- YONG, R., HUANG, T., CHANG, S. (1999) **Image Retrieval: Current Techniques, Promising Directions and Open Issues**. Journal of Visual Communication and Image Representation, vol. 10. p. 1-23.