

UNIVERSIDADE DE SÃO PAULO
Instituto de Ciências Matemáticas e de Computação
ISSN 0103-2569

**Identificação dos Sintomas de Ferrugem em Áreas
Cultivadas com Cana-de-Açúcar**

**Desirée Nagliati Dias
João do Espírito Santo Batista Neto**

Nº 232

RELATÓRIOS TÉCNICOS



**São Carlos – SP
Mai./2004**

| | |
|-------------|----------------|
| SYSNO | <u>1388201</u> |
| DATA | <u> / /</u> |
| ICMC - SBAB | |

Universidade de São Paulo
Instituto de Ciências Matemáticas e de Computação
Departamento de Ciência da Computação e Estatística

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

Desirée Nagliati Dias

Prof. Dr. João do Espírito Santo Batista Neto

USP - São Carlos
Maio/2004

ÍNDICE

| | |
|---|------------|
| LISTA DE FIGURAS..... | III |
| LISTA DE TABELAS..... | IV |
| INTRODUÇÃO | 1 |
| CARACTERIZAÇÃO DO PROBLEMA | 1 |
| OBJETIVOS | 1 |
| ORGANIZAÇÃO DO RELATÓRIO | 2 |
| CAPÍTULO 01 – A FERRUGEM..... | 3 |
| 1.1. INTRODUÇÃO | 3 |
| 1.2. CARACTERIZAÇÃO DA DOENÇA | 3 |
| 1.3. CONSIDERAÇÕES FINAIS | 5 |
| CAPÍTULO 02 – CORES E CARACTERÍSTICAS..... | 6 |
| 2.1. CONSIDERAÇÕES INICIAIS | 6 |
| 2.2. MODELOS DE CORES | 6 |
| 2.2.1. Sistema RBG..... | 6 |
| 2.2.2. Sistema CMYK..... | 7 |
| 2.2.3. Sistema YIQ..... | 7 |
| 2.2.4. Sistema HSV..... | 7 |
| 2.2.5. Sistema L1L2L3 (Cor Invariante) | 8 |
| 2.3. CARACTERÍSTICAS DAS CORES | 8 |
| 2.3.1. Histograma de Cores..... | 9 |
| 2.3.2. Momentos das Cores | 9 |
| 2.3.3. Cor Dominante..... | 10 |
| 2.3.4. Histogramas Combinados | 11 |
| 2.3.5. Vetor de Coerência de Cor..... | 11 |
| 2.3.6. Correlogramas de Cores..... | 11 |
| 2.4. CONSIDERAÇÕES FINAIS | 12 |
| CAPÍTULO 03 – TÉCNICAS PARA CLASSIFICAÇÃO E SEGMENTAÇÃO DA INFECÇÃO NA CANA..... | 13 |
| 3.1. TIPOS DE APRENDIZADO | 13 |
| 3.1.1. Metodologia de Avaliação dos Algoritmos de Aprendizado | 14 |
| 3.2. REDES NEURAIAS ARTIFICIAIS | 16 |
| 3.3. SVM (SUPPORT VECTOR MACHINE) | 18 |
| 3.3.1. SVM's para conjuntos linearmente separáveis (margens rígidas) | 18 |
| 3.4.2. SVM's para conjuntos linearmente separáveis (margens suaves) | 19 |
| 3.4.3. SVM's não lineares..... | 19 |
| 3.4.4. SVM's para várias classes..... | 19 |
| 3.5. ÁRVORE DE DECISÃO..... | 19 |
| 3.6. CLUSTERING | 20 |
| 3.7. SEGMENTAÇÃO | 21 |
| 3.7.1. Métodos de Limiarização Desenvolvidos..... | 21 |

| | | |
|---|---|-----------|
| 3.8. | CONSIDERAÇÕES FINAIS | 22 |
| CAPÍTULO 04 – METODOLOGIA DO EXPERIMENTO | | 23 |
| 4.1. | AQUISIÇÃO DAS IMAGENS | 24 |
| 4.2. | MÉTODO MANUAL..... | 25 |
| 4.3. | SEGMENTAÇÃO POR THRESHOLD (LIMARIZAÇÃO)..... | 26 |
| 4.4. | EXTRAÇÃO DE CARACTERÍSTICAS | 27 |
| 4.5. | TREINAMENTO DA REDE NEURAL..... | 28 |
| CAPÍTULO 05 – RESULTADOS..... | | 30 |
| 5.1. | RESULTADOS DO MÉTODO MANUAL | 30 |
| 5.2. | RESULTADOS DA SEGMENTAÇÃO POR LIMARIZAÇÃO | 31 |
| 5.3. | RESULTADOS DA CLASSIFICAÇÃO POR REDE NEURAL | 37 |
| 5.3.1. | <i>Classificação da foto inteira</i> | <i>38</i> |
| 5.3.2. | <i>Classificação da foto com 1 região de interesse</i> | <i>39</i> |
| 5.3.3. | <i>Classificação da foto com 10 regiões de interesse.....</i> | <i>41</i> |
| CAPÍTULO 06 – CONCLUSÕES E TRABALHOS FUTUROS | | 44 |
| 6.1. | CONCLUSÕES | 44 |
| 6.2. | TRABALHOS FUTUROS | 46 |
| REFERÊNCIAS BIBLIOGRÁFICAS | | 48 |

LISTA DE FIGURAS

| | |
|--|----|
| FIGURA 1 – VISÃO LATERAL DAS FILEIRAS DE CANA-DE-AÇÚCAR, MOSTRANDO A FORMAÇÃO DA PLANTA BEM PREJUDICADA (NO CENTRO) POR CAUSA DA FERRUGEM. | 1 |
| FIGURA 2 – ESCALA DE NOTAS DESENVOLVIDA PELA COPERSUCAR(AMORIM ET AL., 1987)..... | 5 |
| FIGURA 3 – APROXIMAÇÃO GERAL DA EXTRAÇÃO DE CARACTERÍSTICAS DA COR DA IMAGEM, CADA FASE TRÁS EXEMPLOS DE MÉTODOS QUE PODEM SER UTILIZADOS (SMITH & CHANG, 1996). | 9 |
| FIGURA 4 – HIERARQUIA DO APRENDIZADO | 14 |
| FIGURA 5 – ILUSTRAÇÃO DE UMA REDE NEURAL COM 03 CAMADAS. | 18 |
| FIGURA 6 – EXEMPLO DE ÁRVORE DE DECISÃO. | 20 |
| FIGURA 7 – 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. | 23 |
| FIGURA 8 – 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. | 25 |
| FIGURA 9 – PLOTAGEM DAS NOTAS DE INFECÇÃO DE FERRUGEM NAS FOLHAS DA CANA-DE-AÇÚCAR COMPARADAS A UMA FUNÇÃO POLINOMIAL. | 26 |
| FIGURA 10 – NÍVEIS DE INFECÇÃO ATRIBUÍDOS IN LOCO PELOS ENGENHEIROS DO IAC AOS DIFERENTES QUADRANTES..... | 30 |
| FIGURA 11 – IMAGEM COM BAIXA INFECÇÃO, SEGUNDO O ESPECIALISTA (NÍVEL ENTRE 1 E 2). 32 | |
| FIGURA 12 – IMAGEM COM BAIXA INFECÇÃO, SEGUNDO O ESPECIALISTA (NÍVEL 2)..... | 32 |
| FIGURA 13 – IMAGEM COM MÉDIA INFECÇÃO, SEGUNDO O ESPECIALISTA (NÍVEL ENTRE 4 E 5). 33 | |
| FIGURA 14 – IMAGEM COM ALTA INFECÇÃO, SEGUNDO O ESPECIALISTA (NÍVEL 7). | 33 |
| FIGURA 15 – IMAGEM COM ALTA INFECÇÃO, SEGUNDO O ESPECIALISTA (NÍVEL ENTRE 7,5 E 8). | 34 |
| FIGURA 16 – IMAGEM COM ALTA INFECÇÃO, SEGUNDO O ESPECIALISTA (NÍVEL 8). | 34 |
| FIGURA 17 – IMAGEM COM ALTA INFECÇÃO, SEGUNDO O ESPECIALISTA (NÍVEL ENTRE 8,5 E 8). | 35 |
| FIGURA 18 – IMAGEM COM ALTA INFECÇÃO, SEGUNDO O ESPECIALISTA (NÍVEL ENTRE 8,5 E 9). | 35 |
| FIGURA 19 – 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). | 36 |

LISTA DE TABELAS

| | |
|--|----|
| TABELA 1 – EXEMPLO DE UM 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 | 11 |
| TABELA 2 – ALGUNS PARÂMETROS DE ESTIMADORES SEGUNDO MONARD (MONARD & BARANAUSKAS, 2003A). | 16 |
| TABELA 3 – EXEMPLO HIPOTÉTICO DE COMO É FEITA A AVALIAÇÃO DE UMA PLANTAÇÃO DE CANA PARA SE DETECTAR O NÍVEL DE INFECÇÃO POR FERRUGEM. | 25 |
| TABELA 4 – COMPARAÇÃO ENTRE MÉTODOS DE CLASSIFICAÇÃO. | 28 |
| TABELA 5 – ANÁLISE FEITA EM DIFERENTES INTENSIDADES DE CORES NOS HISTOGRAMAS DAS IMAGENS DAS FOLHAS. | 37 |
| TABELA 6 – RESULTADOS DA MÉDIA DOS ERROS MSE, NO EXPERIMENTO 01. | 37 |
| TABELA 7 – RESULTADOS DA MÉDIA DOS ERROS MSE, NO EXPERIMENTO 02. | 38 |
| TABELA 10 – ANÁLISE RESULTADOS DA CLASSIFICAÇÃO DA IMAGEM INTEIRA. | 39 |
| TABELA 13 – ANÁLISE DOS RESULTADOS PARA A CLASSIFICAÇÃO DE UMA ROI POR FOTO PARA OS DOIS EXPERIMENTOS REALIZADOS. | 40 |
| TABELA 14 – EXEMPLO DE ALGUNS RESULTADOS CONSEGUIDOS PELA CLASSIFICAÇÃO DO HISTOGRAMA NO EXPERIMENTO 01 NÍVEL 7. | 42 |
| TABELA 26 – ANÁLISE DOS RESULTADOS DA CLASSIFICAÇÃO DAS DEZ ROI'S NOS DOIS EXPERIMENTOS. | 43 |

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 mais resistente, pois a 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 2*) 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, 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.

ORGANIZAÇÃO DO RELATÓRIO

Este relatório está organizado da seguinte maneira:

No *Capítulo 01 (A Ferrugem)* são apresentados: a origem da doença e sua propagação. Sintomas, métodos de avaliação da doença e os prejuízos causados pela ferrugem na cana.

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 utilizadas na pesquisa, desde 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

Finalmente, o *Capítulo 06 (Conclusões e Trabalhos Futuros)* traz as conclusões e as diretrizes para o aprimoramento e expansão das técnicas empregadas neste trabalho.

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. Em 1918, 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). Desde sua descoberta esta doença tem-se disseminado ao redor do globo ao longo dos anos, causando prejuízos em todos os lugares em que foi constatada.

Seu primeiro relato no Brasil foi em 26 de novembro de 1986, numa lavoura do Município de Capivari (SP), pelo técnico agrícola José Deodato, do Centro de Tecnologia da Cooperativa Central dos Produtores de Açúcar e Álcool do Estado de São Paulo (Copersucar), (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 de tamanho rapidamente. (Copersucar, 1986; Masuda et al., 1986).

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. 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, 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). 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 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).

O canavial contaminado é avaliado *in loco* por técnicos, que dão uma “nota” segundo uma escala. Esta nota indica quão suscetível é a variedade à ferrugem de acordo com a percentagem da concentração das pústulas (*Figura 2*). Existem várias escala para a classificação da doença, a ilustrada na *Figura 2*, 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). Esta foi a escala adotada para este trabalho.




Figura 2 – 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 Copersucar (*Figura 2*), 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 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. Assim, a identificação de ferrugem por imagens aéreas explorará a característica da cor.

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). A cor é um atributo de sensação visual que só existe devido à interação de três componentes: fonte de luz (fonte de energia eletromagnética visível que influencia na aparência da cor), objeto e o sistema de visão humano (Faiechild, 1998).

As seções subseqüentes conterão tópicos como teoria de modelos de cores 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. Estes modelos 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). 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

sistema quantizado por uma tripla de números discretos e o sistema pode ser representado geometricamente por um cubo (Gonzalez & Woods, 1992).

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 uma impressora a jato de tinta.

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). Pigmentos, ao invés de cores, representam energia que não é absorvida por uma substância como tinta ou pintura. Às vezes o preto também é considerado um pigmento primário, embora o preto pode ser obtido misturando-se em porções iguais o puro cyan, magenta, e amarelo (Foley & Dan, 1994).

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. O Y significa luminosidade e a cromaticidade é encontrada em I e Q. O mapeamento de RGB para YIQ é (Foley & Dan, 1994; Skarbek & Koschan, 1994; Hearn & Baker, 1994):

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

(1)

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

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).

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

$$I = \frac{1}{3}(R + G + B) \quad (2)$$

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

$$\Theta = \cos^{-1} \left\{ \frac{\frac{1}{2}[(R - G) + (R - B)]}{\left[(R - G)^2 + (R - B)(G - B) \right]^{\frac{1}{2}}} \right\} \quad H = \begin{cases} \Theta & , \text{se } G \geq B \\ 2\pi - \Theta & , \text{caso contrário} \end{cases} \quad (4)$$

2.2.5. Sistema L1L2L3 (Cor Invariante)

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):

$$l_1 = \frac{(R - G)^2}{(R - G)^2 + (R - B)^2 + (G - B)^2} \quad (5)$$

$$l_2 = \frac{(R - B)^2}{(R - G)^2 + (R - B)^2 + (G - B)^2} \quad (6)$$

$$l_3 = \frac{(G - B)^2}{(R - G)^2 + (R - B)^2 + (G - B)^2} \quad (7)$$

Este sistema de cores 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 3*): 1) Extração da região; 2) Extração de propriedades da região.

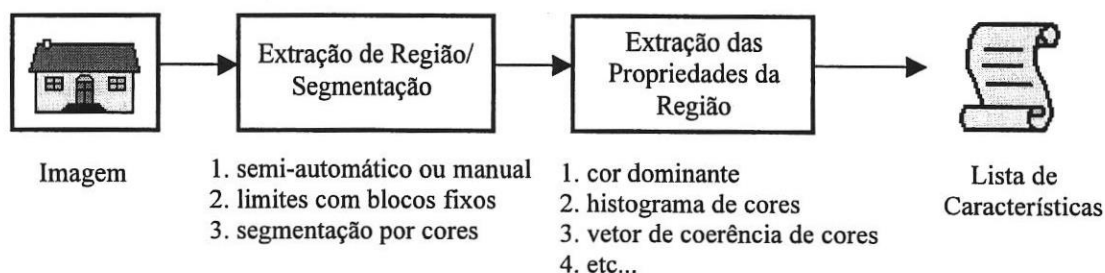


Figura 3 – Aproximação geral da extração de características da cor da imagem, cada fase trás exemplos de métodos que podem ser utilizados (Smith & Chang, 1996).

Este trabalho concentra-se na extração das características. 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 não preserva a informação espacial, pois ele meramente descreve quais as cores presentes na imagem e sua frequência (Pass et al., 1996; Deng & Moore, 2001). Genericamente, em uma imagem com N pixels tem-se:

$$\sum_{i=1}^n h_{ci} = N \quad (8)$$

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. A base matemática dessa abordagem é que qualquer distribuição de cor pode ser caracterizada pelo seu momento, por isso é uma

representação compacta, onde somente as características dominantes são armazenadas ao invés das distribuições completas da cor. 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:
$$E_i = \frac{1}{N} \sum_{j=1}^N p_{ij}$$
 (9)

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:
$$\sigma_i = \left(\frac{1}{N} \sum_{j=1}^N (p_{ij} - E_i)^2 \right)^{\frac{1}{2}}$$
 (10)

- inclinação (*skewness*), definida por:
$$s_i = \left(\frac{1}{N} \sum_{j=1}^N (p_{ij} - E_i)^3 \right)^{\frac{1}{3}}$$
 (11)

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 F é definida por (Deng & Moore, 2001):

$$F = \{ \{c_i, p_i\} \mid i = 1 \dots N \}$$
 (12)

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 $\sum p_i = 1$.

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^{a} 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.

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.

Os passos para se ter um CCV (Pass et al., 1996) são: 1) Suavizar a imagem pela média da vizinhança e discretize em n faixas de cores, cada faixa representa um intervalo de cores; 2) Rotule o pixels pela faixa de cor e pela conectividade com os vizinhos. Classifique os pixels como coerentes ou incoerentes, um pixels é considerado coerente se pertencer a uma região rotulada com mais de τ pixels;

TABELA 1 – Exemplo de um 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 .

| Cor | 1 | 2 | 3 |
|----------|----|----|---|
| α | 17 | 15 | 0 |
| β | 3 | 0 | 1 |

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.

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 $p=(x,y) \in I$, $I(p)$ denota sua cor. Para se definir um correlograma de uma imagem I , primeiro devemos definir uma distância $d \in [n]$. Assim, o correlograma é definido por $i, j \in [m]$, $k \in [d]$, $[d]$ é o intervalo de distâncias possíveis, como:

$$\gamma_{c_i, c_j}^{(k)}(I) \triangleq \Pr_{p_1 \in I_{c_i}, p_2 \in I} [p_2 \in I_{c_j} \mid |p_1 - p_2| = k] \quad (13)$$

Dado qualquer pixel de cor c_i na imagem, $\gamma_{c_i, c_j}^{(k)}$ dá a probabilidade de encontrar um pixel de cor c_j , a uma distância k deste pixel de cor c_i .

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; medida em graus Kelvin descreve a relação entre o grau de calor aplicado sobre uma fonte luminosa e a cor especificada de luz gerada (Yang, 2000).

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 condições de iluminação semelhantes, 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 INFECCÃO 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 .

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 2*). Devido a sutil diferença entre os níveis de infecção, acreditamos que uma boa classificação poderá ser obtida por meio de um método de aprendizado. Há duas abordagens para o aprendizado: não supervisionada, via algoritmos de *clustering* (Scheering, 1997), por exemplo, e supervisionada, tal como redes neurais (Haykin, 2001).

As seções subseqüentes descrevem: 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. 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 4*). 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).

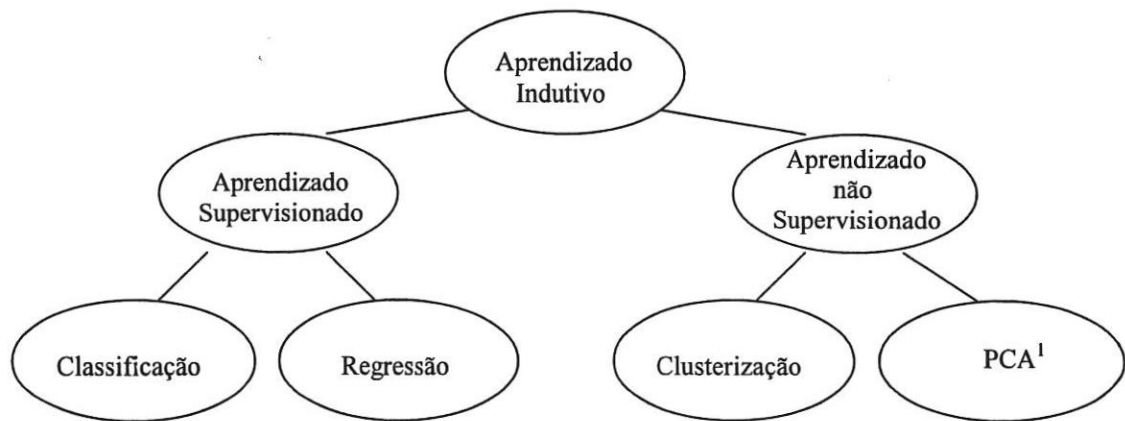


Figura 4 – Hierarquia do aprendizado (Monard & Baranauskas, 2003a).

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:

- 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).

3.1.1. 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:

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).

- *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.

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. 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, mas durante a coleta dos dados a proporção de exemplos de cada uma das classes é considerada (Monard & Baranauskas, 2003a).

Leave-one-out: é uma forma particular do *k-fold-cross-validation*. Onde, se há n exemplos, há n partições de treinamento e o processo é repetido n vezes. Este método faz uso máximo dos dados, por isso é computacionalmente caro e freqüentemente 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.

Para se estimar uma medida verdadeira destes métodos citados, pode-se utilizar as seguintes regras mostradas na TABELA 2, 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 2 – Alguns parâmetros de estimadores segundo Monard (Monard & Baranauskas, 2003a).

| | <i>Leave-one-out</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 (diferença entre o resultado conseguido pelo algoritmo de aprendizado e o resultado esperado) que pode ser, por exemplo, o *Sum of Square Errors* - SSE (14), o *Mean Square Errors* - MSE (15) ou *Root Mean Square Error* – RMSE.

$$SSE = \sum_{p \in \text{padroes}} \sum_{j \in \text{saida}} (t_{pj} - o_{pj})^2 \quad (14)$$

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

$$MSE = \frac{SSE}{n - p} \quad (15)$$

onde SSE é a soma dos erros quadrados (14), n é o número de observações e p é o número de parâmetros a serem estimados. Já o RMSE é dado por:

$$RMSE = \sqrt{MSE} \quad (16)$$

3.2. REDES NEURAIAS ARTIFICIAIS

Redes Neurais Artificiais são sistemas inspirados nos neurônios biológicos 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;

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

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

$$net_j = \sum_{i=1}^n x_i w_{ij} + bias \quad (17)$$

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

Função de Ativação $F(net_j)$ – função que mapeia a saída da rede para um intervalo $[0,+1]$ ou $[-1,+1]$. Um exemplo de função de ativação sigmóide:

$$F(net_j) = \frac{1}{1 + e^{-net_j}} \quad F'(net_j) = \frac{e^{-net_j}}{[1 + e^{-net_j}]^2} \quad (18)$$

O comportamento da rede dependerá da topologia da rede e dos valores das conexões. A Figura 5 ilustra uma 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. É usada geralmente para problemas não linearmente separáveis e não há realimentação.

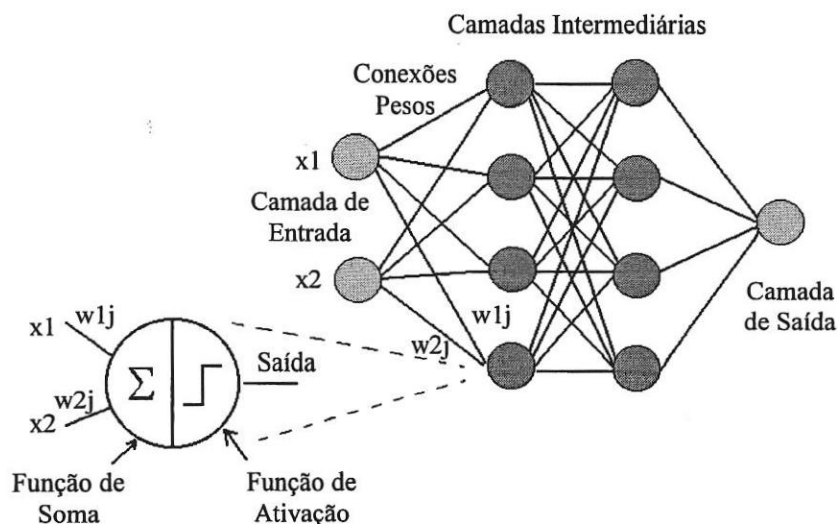


Figura 5 – Ilustração de uma rede neural com 03 camadas.

Uma *MLP – BackPropagation* é um método supervisionado e o algoritmo tem duas fases (Haykin, 2001): 1) propagação dos dados (*FeedForWard*): onde 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 (Σ) (Figura 5). 2) retropropagação do erro (*FeedBack*): os erros se propagam na direção contrária ao fluxo dos dados, indo da camada de saída até a primeira camada escondida.

3.3. SVM (*SUPPORT VECTOR MACHINE*)

As Máquinas de Vetores Suporte (*Support Vector Machines – SVM's*), foram propostas por Vapnik (Haykin, 2001) e originalmente as SVM's eram 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.

3.3.1. 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 chama-se margem de separação.

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. Isso é chamado de “suavização de margens”. A margem de separação é dita suave se algum ponto dos dados violar a margem imposta pela SVM (Cavalheiro & Gomes, 2003).

3.4.3. SVM's não lineares.

Existem conjuntos de dados que não podem ser separados por um hiperplano, 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 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.

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 um 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 depende de fatores externos, como a probabilidade da ocorrência de uma determinada situação. Árvore de

Decisão é um tipo de aprendizado simbólico e 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 (Figura 6).

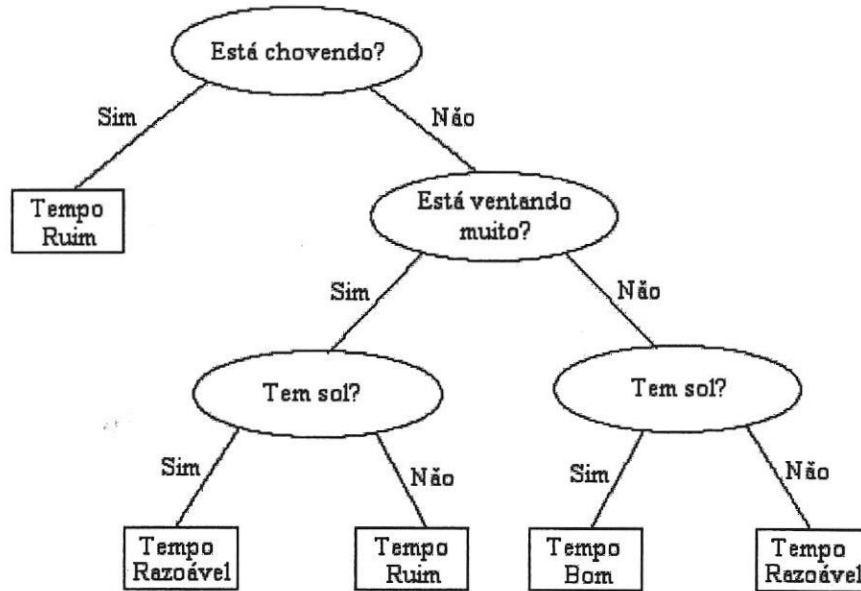


Figura 6 – Exemplo de Árvore de Decisão.

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. 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*).

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): a) Não contextual, onde se ignora a relação existente entre características da imagem, como por exemplo, o valor de intensidade do pixel; b) Contextual, onde se 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).

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

(19)

A limiarização pode ser supervisionada e não supervisionada. Algumas abordagens supervisionadas são: convencional, adaptativa, por banda, multi-limiar, ótimo, p-tile, Otsu (Liao et al., 2001; Sonka et al., 1999), iterativo.

3.7.1. Métodos de Limiarização Desenvolvidos

Das técnicas apresentadas na seção anterior, a limiarização pelo método de Otsu (este método mede a variância entre classes) 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 (20) e o desvio padrão (21) dos três canais de cores. A segmentação final é obtida comparando-se o desvio padrão com um limiar pré-estabelecido (22);

$$Média = (R + G + B) / 3$$

(20)

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

(21)

$$g(x, y) = 1 \quad ; \text{ se } \sigma (R, G, B) \geq 10$$

$$g(x, y) = 0 \quad ; \text{ se } \sigma (R, G, B) < T$$

(22)

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 3 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) e L1L2L3 (seção 2.2.5). De posse destas características, realizou-se a classificação por uma rede neural *backpropagation* (seção 3.1).

O trabalho desenvolvido pode ser resumido no esquema ilustrado na Figura 7.

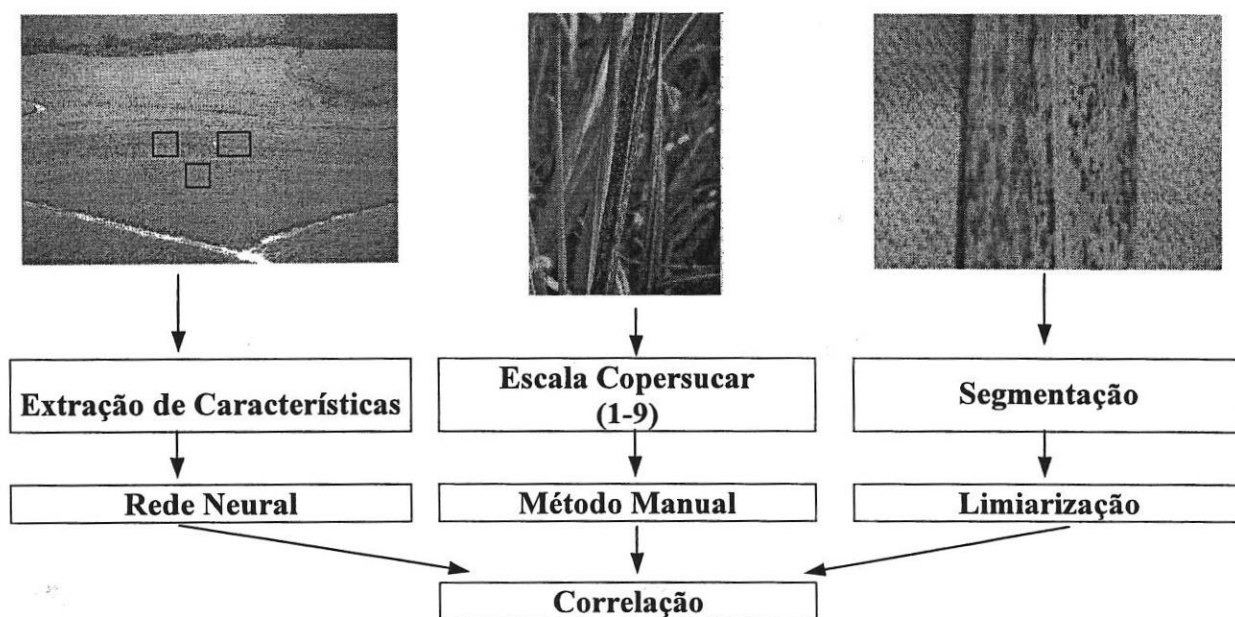


Figura 7 – Esquema do projeto desenvolvido. À esquerda, das imagens aéreas do canavial foram extraídas as características das cores que foram classificadas pela rede neural. Ao centro, ilustra a avaliação feita in loco pelos especialistas. À direita, foto digitalizada das folhas avaliadas, que foram segmentadas.

Para o processamento e manipulação das imagens RGB, foi utilizado o programa LIZA (projeto Fapesp - Proc. Nº 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 (desenvolvido no ICMC – USP – São Carlos) sob supervisão do Prof. Onofre, que consiste de um aeromodelo guiado por controle remoto, no qual está embutido uma câmera fotográfica química e uma câmera de vídeo.

As fotos foram adquiridas na Usina Denini Açúcar e Álcool, na Fazenda São João, em 13/06/2003, município de Vargem Grande do Sul/SP. A área foi selecionada por engenheiros agrônomos especialistas em cana-de-açúcar do Centro Avançado de Cana de Ribeirão Preto. Foram diagnosticados três níveis de infecção.

Um aspecto que certamente influenciou a interpretação dos resultados é a temperatura da cor. 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. Para minimizar grandes distorções na interpretação dos dados, tivemos a preocupação de utilizar um sistema de cor invariante e o cuidado de realizar a sessão de fotos no mesmo horário, por volta das 14h50. Além disto, as fotos que por ventura continham sombreamento 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 8. Cada ponto corresponde às áreas capturadas em imagem e a seqüência de números acima de cada ponto é o número da foto. Os arquivos, 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).

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 perceptível diferença das imagens.

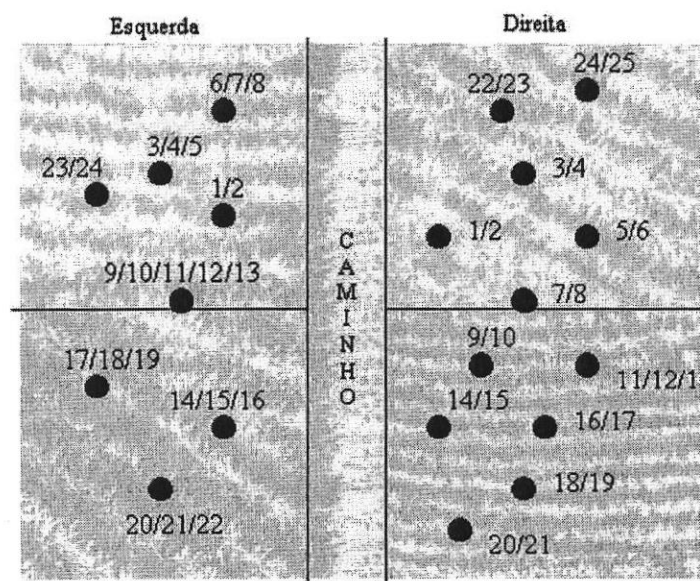


Figura 8 – Este croqui ilustra o que seria a porção da plantação de cana rastreada, organizada em quadrantes. Os pontos indicam as áreas de sobrevôo do helicóptero para a captura das imagens e o número da foto feita naquela área.

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 2).

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 3.

TABELA 3 – 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 Nota da Plantação |
|--------------|-----------------------|---|---|---|---|---|---|---|--|
| | A | B | C | D | E | F | G | H | |
| 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 da curva de infecção da ferrugem dada pelas notas e suas respectivas porcentagens segundo a escala da Copersucar (curva mais clara, pontuada), foi desenvolvido um método de aproximação para se estimar a porcentagem de área afetada (Figura 9). A curva mais escura (sem pontos) é uma aproximação com erro pequeno e aceitável, e corresponde à função polinomial $y = 1.3839x^2 - 5.3185x + 4.4554$.

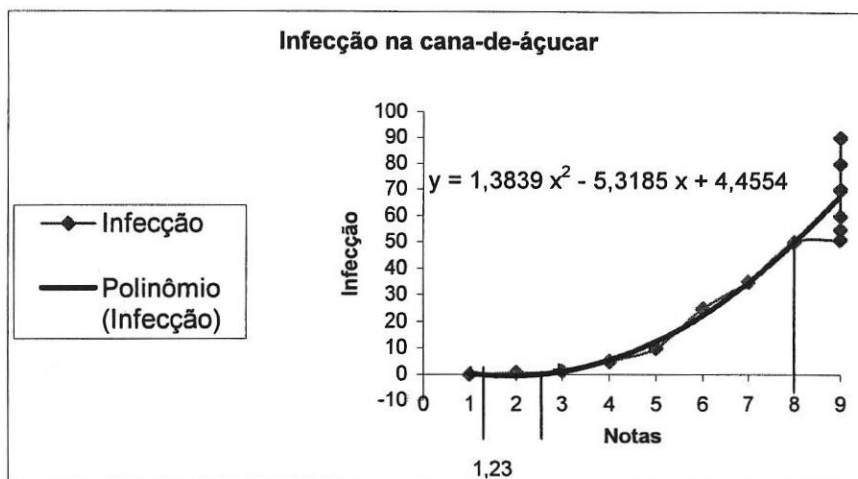


Figura 9 – Plotagem das notas de infecção de ferrugem nas folhas da cana-de-áçúcar comparadas a uma função polinomial.

A função polinomial aproximada da curva de infecção contém uma parte, que se a nota obtida pela avaliação 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 $f: \mathcal{N} \rightarrow \mathcal{N}$, tal que:

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

(23)

4.3. SEGMENTAÇÃO POR THRESHOLD (LIMIARIZAÇÃO)

A segmentação por limiarização foi aplicada sobre as fotos digitais tiradas das folhas da cana avaliadas *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 23. 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 $f: \mathcal{H} \rightarrow \mathcal{H}$ para se obter as notas a partir da porcentagem conseguida com a segmentação das folhas:

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

(24)

4.4. EXTRAÇÃO DE CARACTERÍSTICAS

Das fotos digitalizadas, foram selecionadas manualmente pequenas regiões de interesse de 16×16 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.

Destas regiões extraíram-se as características, as quais eram associadas ao nível de infecção avaliado pelos engenheiros. 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 3.1.1).

Foram realizados treinamentos tanto com os dados intactos quanto com os dados normalizados, mas os resultados não apresentaram diferença significativa. 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 métodos (TABELA 4).

TABELA 4 – 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

Para os treinamentos foram utilizados simuladores como:

- SNNS 4.2: desenvolvido pela Universidade de Stuttgart e pela Universidade de Tübingen, disponível em <<http://www-ra.informatik.uni-tuebingen.de/SNNS/>>.
- Weka: Universidade de Waikato, 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. 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.

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 (15). 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 6 e TABELA 7 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 3.2). 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 10.




Figura 10 – 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 LIMIAÇÃO

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 (24) (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.

Imagem Original





Imagem recortada




Nível avaliado pelo especialista – 1 a 2


Método Otsu

Método Semi-Automático


Método do Desvio Padrão



Nível avaliado em 6,4
Limiar de 129
Porcentagem afetada em 27,4%



Nível avaliado em 4,4
Limiar de 115
Porcentagem afetada em 7,8%



Nível avaliado em 2,0
Limiar de 10
Porcentagem afetada em 0,1%

Figura 11 – Imagem com baixa infecção, segundo o especialista (nível entre 1 e 2).

Imagem Original





Imagem recortada



Nível avaliado pelo especialista – 2


Método Otsu

Método Semi-Automático

Método do Desvio Padrão



Nível avaliado em 9,0
Limiar de 120
Porcentagem afetada em 62,6%



Nível avaliado em 2,0
Limiar de 97
Porcentagem afetada em 0,6%



Nível avaliado em 2,0
Limiar de 10
Porcentagem afetada em 0,6%

Figura 12 – Imagem com baixa infecção, segundo o especialista (nível 2).

Imagem Original





Imagem recortada


Nível avaliado pelo especialista – 4 a 5




Método Otsu

Método Semi-Automático


Método do Desvio Padrão



Nível avaliado em 4,5
Limiar de 145
Porcentagem afetada em 8,6%



Nível avaliado em 4,0
Limiar de 132
Porcentagem afetada em 5,4%



Nível avaliado em 1,0
Limiar de 10
Porcentagem afetada em 0%

Figura 13 – Imagem com média infecção, segundo o especialista (nível entre 4 e 5).

Imagem Original





Imagem recortada


Nível avaliado pelo especialista – 7



Método Otsu

Método Semi-Automático


Método do Desvio Padrão



Nível avaliado em 5,8
Limiar de 130
Porcentagem afetada em 20,0%



Nível avaliado em 6,1
Limiar de 135
Porcentagem afetada em 23,6%



Nível avaliado em 5,8
Limiar de 10
Porcentagem afetada em 20,1%

Figura 14 – Imagem com alta infecção, segundo o especialista (nível 7).

Imagem Original





Imagem recortada


Nível avaliado pelo especialista – 7,5 a 8



Método Otsu

Método Semi-Automático

Método do Desvio Padrão



Nível avaliado em 7,7
Limiar de 124
Porcentagem afetada em 45,8%



Nível avaliado em 6,6
Limiar de 106
Porcentagem afetada em 29,9%



Nível avaliado em 2,0
Limiar de 10
Porcentagem afetada em 0,3%

Figura 15 – Imagem com alta infecção, segundo o especialista (nível entre 7,5 e 8).

Imagem Original





Imagem recortada


Nível avaliado pelo especialista – 8




Método Otsu

Método Semi-Automático

Método do Desvio Padrão



Nível avaliado em 7,1
Limiar de 131
Porcentagem afetada em 35,9%



Nível avaliado em 7,2
Limiar de 133
Porcentagem afetada em 38,5%



Nível avaliado em 6,3
Limiar de 10
Porcentagem afetada em 25,7%

Figura 16 – Imagem com alta infecção, segundo o especialista (nível 8).

Imagem Original





Imagem recortada


Nível avaliado pelo especialista – 8 a 8,5




Método Otsu

Método Semi-Automático


Método do Desvio Padrão



Nível avaliado em 7,3
Limiar de 131
Porcentagem afetada em 39,3%



Nível avaliado em 7,4
Limiar de 132
Porcentagem afetada em 41,3%



Nível avaliado em 6,5
Limiar de 10
Porcentagem afetada em 27,9%

Figura 17 – Imagem com alta infecção, segundo o especialista (nível entre 8,5 e 8).

Imagem Original




Imagem recortada


Nível avaliado pelo especialista – 8,5 a 9




Método Otsu

Método Semi-Automático


Método do Desvio Padrão



Nível avaliado em 9,0
Limiar de 128
Porcentagem afetada em 53,6%



Nível avaliado em 9,0
Limiar de 140
Porcentagem afetada em 63,6%



Nível avaliado em 8,0
Limiar de 10
Porcentagem afetada em 49,7%

Figura 18 – 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 19). 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 13, e não se revelou apropriado nos casos de folhas pouco infectadas. A Figura 19 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 19 – 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 5). 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 5 – Análise feita em diferentes intensidades de cores nos histogramas das imagens das folhas.

| Nível | Intensidades Avaliadas | | | | | | | | | | | | | | | |
|---------|------------------------|----|-----|-----|------|-----|-----|-----|------|------|------|------|-----|------|-----|-----|
| | 20 | | 50 | | 80 | | 100 | | 120 | | 150 | | 180 | | 200 | |
| | 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 (15) são apresentados na TABELA 6 e TABELA 7, 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 6 e TABELA 7 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 6 – 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 7 – 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 obtidos com a classificação do histograma da imagem inteira em ambos experimentos, podem ser resumidos na TABELA 8 da seguinte forma: são representas as 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 8 – 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 obtidos com a classificação do histograma e da cor invariante para ROI selecionada nos dois experimentos, são sumarizados na TABELA 9 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 9 – 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).

TABELA 9 – 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.Canál ^(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 10 – Exemplo de alguns resultados conseguidos pela classificação do histograma no experimento 01 nível 7.

| | | | | | | | | | | | | | | | | |
|----------------------|---|---|---|---|---|---|---|---|---|--------------------------------|---|---|---|----|----|----|
| 01_RB486_Niv07es.jpg | | | | | | | | | | Frequência Total por níveis | | | | | | |
| ROI's | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 7 | 2 | 1 | 11 | 12 | 7 |
| R | 1 | 2 | 2 | 1 | 1 | 1 | 7 | 2 | 1 | 1 | 7 | 2 | 1 | 1 | 7 | 2 |
| G | 2 | 7 | 1 | 7 | 1 | 7 | 2 | 2 | 7 | 2 | 4 | 2 | 7 | 2 | 4 | 4 |
| B | 7 | 2 | 7 | 7 | 2 | 7 | 2 | 2 | 7 | 7 | 9 | 7 | 7 | 2 | 7 | 7 |
| 08_RB486_Niv07es.jpg | | | | | | | | | | Frequência Total por níveis | | | | | | |
| ROI's | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 7 | 2 | 1 | 15 | 9 | 6 |
| R | 2 | 7 | 7 | 2 | 2 | 2 | 1 | 1 | 7 | 7 | 5 | 7 | 7 | 1 | 7 | 7 |
| G | 2 | 7 | 7 | 2 | 1 | 2 | 1 | 2 | 1 | 1 | 7 | 2 | 3 | 2 | 3 | 3 |
| B | 7 | 7 | 7 | 2 | 7 | 2 | 7 | 2 | 7 | 7 | 7 | 7 | 7 | 1 | 7 | 7 |
| 22_RB486_Niv07dt.jpg | | | | | | | | | | Frequência Total por níveis | | | | | | |
| ROI's | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 7 | 2 | 1 | 14 | 10 | 6 |
| R | 7 | 7 | 2 | 7 | 2 | 2 | 2 | 7 | 1 | 7 | 5 | 7 | 7 | 1 | 7 | 1 |
| G | 2 | 2 | 2 | 7 | 7 | 2 | 2 | 1 | 7 | 1 | 3 | 2 | 2 | 1 | 7 | 1 |
| B | 1 | 7 | 7 | 7 | 2 | 1 | 2 | 7 | 7 | 7 | 6 | 7 | 7 | 7 | 7 | 7 |
| 23_RB486_Niv07dt.jpg | | | | | | | | | | Frequência Total por níveis | | | | | | |
| ROI's | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 7 | 2 | 1 | 9 | 18 | 3 |
| R | 1 | 2 | 7 | 7 | 2 | 2 | 2 | 2 | 2 | 2 | 2 | 2 | 2 | 2 | 2 | 2 |
| G | 2 | 7 | 7 | 7 | 2 | 2 | 7 | 2 | 2 | 2 | 4 | 2 | 7 | 2 | 2 | 1 |
| B | 2 | 1 | 7 | 2 | 2 | 2 | 2 | 2 | 2 | 7 | 3 | 7 | 7 | 7 | 7 | 7 |
| 23_RB486_Niv07es.jpg | | | | | | | | | | Frequência Total por níveis | | | | | | |
| ROI's | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 7 | 2 | 1 | 17 | 7 | 6 |
| R | 1 | 7 | 7 | 2 | 1 | 7 | 2 | 7 | 8 | 9 | 4 | 7 | 7 | 1 | 1 | 1 |
| G | 7 | 7 | 7 | 1 | 7 | 2 | 7 | 2 | 7 | 2 | 7 | 2 | 7 | 2 | 7 | 7 |
| B | 7 | 2 | 7 | 7 | 2 | 1 | 2 | 7 | 7 | 7 | 6 | 7 | 7 | 7 | 7 | 7 |
| 24_RB486_Niv07dt.jpg | | | | | | | | | | Frequência Total por níveis | | | | | | |
| ROI's | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 7 | 2 | 1 | 13 | 9 | 8 |
| R | 2 | 7 | 2 | 2 | 1 | 1 | 2 | 7 | 8 | 9 | 3 | 7 | 7 | 2 | 7 | 7 |
| G | 1 | 7 | 1 | 7 | 2 | 7 | 2 | 7 | 2 | 1 | 4 | 7 | 7 | 2 | 1 | 1 |
| B | 7 | 7 | 7 | 1 | 7 | 1 | 7 | 7 | 2 | 2 | 6 | 7 | 7 | 2 | 7 | 1 |
| 24_RB486_Niv07es.jpg | | | | | | | | | | Frequência Total por níveis | | | | | | |
| ROI's | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 7 | 2 | 1 | 17 | 8 | 5 |
| R | 7 | 7 | 7 | 1 | 7 | 2 | 1 | 7 | 2 | 7 | 6 | 7 | 7 | 2 | 7 | 6 |
| G | 7 | 7 | 7 | 1 | 2 | 7 | 2 | 7 | 2 | 1 | 7 | 7 | 7 | 2 | 7 | 6 |
| B | 7 | 1 | 7 | 2 | 7 | 1 | 2 | 7 | 2 | 1 | 5 | 7 | 7 | 2 | 1 | 5 |
| 25_RB486_Niv07dt.jpg | | | | | | | | | | Frequência Total por níveis | | | | | | |
| ROI's | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 7 | 2 | 1 | 12 | 6 | 12 |
| R | 1 | 2 | 7 | 1 | 1 | 2 | 2 | 7 | 1 | 1 | 2 | 7 | 7 | 1 | 1 | 2 |
| G | 7 | 1 | 1 | 1 | 1 | 7 | 7 | 1 | 7 | 1 | 4 | 7 | 7 | 1 | 7 | 1 |
| B | 7 | 7 | 7 | 1 | 7 | 7 | 1 | 2 | 7 | 7 | 8 | 7 | 7 | 1 | 2 | 6 |

Os resultados obtidos são apresentados na TABELA 11 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. O total leva em consideração a soma das classificações corretas para os três níveis de infecção.

TABELA 11 – Análise dos resultados da classificação das dez ROI's nos dois experimentos.

| Experimento 01 | | Histograma | | | Cor Invariante | | | |
|----------------|------------------|------------|---------|---------|------------------|---------|---------|---------|
| | Frequência Total | R | G | B | Frequência Total | L1 | L2 | L3 |
| 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 | L1 | L2 | L3 |
| 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

Para o desenvolvimento deste trabalho foram exploradas 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 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 01 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

- 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.
- CAVALHEIRO, A. P., & GOMES, E. R. (2003) **Máquinas de Vetor de Suporte**. Instituto de Informática, Universidade Federal do Rio Grande do SUL (UFRGS), Porto Alegre.
- 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 Intenational, 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.
- 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*. 1^a 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*. 1^a 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.
- 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. (1996) **Tools and Techniques for color Image Retrieval**. Columbia University Department of Electrical Engineering and Center for Telecommunications Research, New York.
- SONKA, M.; VACLAN, H.; BOYLE, R.. (1999) **Image Processing Analysis, and Machine Vision**. PWS Publishing: Editora Chapman & Hall , 2^a 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.
- YANG, J. C. (2000) **A Light Field Camera for Image Based Rendering**. Massachusetts Institute of Technology.