“Identificação de Plantas Invasoras em Tempo Real”

Viviane Araujo Pernomian

Orientador: *Prof. Dr. Onofre Trindade Júnior*

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

São Carlos - SP

Outubro - 2002

*A Deus, pela vida e oportunidades
aos meus pais Luiz Carlos e Nair
pelo amor, carinho e apoio em minhas decisões
aos meus irmãos por eles existirem*

Agradecimentos

Gostaria de agradecer duas pessoas em especial: ao Silvio (antes professor, hoje um grande amigo) por me apoiar, incentivar na realização do mestrado, e ao meu orientador Onofre, por me possibilitar a realização deste mestrado e por todo apoio e ensinamentos que até hoje me é transmitido. Quero ressaltar o carinho e respeito que tenho por eles.

Aos meus pais, Luis Carlos e Nair, aos meus irmãos, Gustavo e Jaqueline, porque acredito que sem o incentivo deles, amor, e muitas vezes compreensão, não seria possível a realização desta nova etapa da minha vida. Reconheço também o apoio indireto que recebi do meu sobrinho Gustavinho durante os momentos de descontração.

Ao meu namorado, Alysso, pela compreensão e carinho, tentando me entender em momentos que até então, não podia lhe dar muita atenção.

Ao apoio financeiro dado pelo CNPq, que foi realmente muito importante para a realização deste trabalho.

Ao meus amigos do Lcad, Luciano, Lúcio, Rodrigo, Fernando (Chavier), Kleber, Valério pelo companheirismo, momentos de descontração e apoio.

Aos meus amigos de Lucélia, Cheibe, Tiago, até hoje pelo grande incentivo e amizade.

Às minhas companheiras de Rep atual e antiga, Lilian, Andréia, Ana Cláudia, Helen, Vivian e Anali, pelos grandes momentos de descontração e ensinamentos de vida... além dos meus amigos Rogério, Cássio, Almir por participarem desses grandes momentos, principalmente das festas que fizemos na minha antiga casa. Aos meus novos companheiros incentivadores (de festa, claro!), Ceará e Mineiro.

Aos funcionários pela colaboração de diversas maneiras, e alguns professores pelo incentivo e colaboração no meu trabalho.

Sumário

Agradecimentos	2
Resumo	ix
Abstract	x
1 Introdução	1
1.1 Organização do Texto	3
2 Técnicas para Processamento de Imagens e Reconhecimento de Padrões	4
2.1 Processamento Digital de Imagens	4
2.2 Técnicas de Pré-processamento	9
2.2.1 Suavização	10
2.3 Técnicas de Segmentação de Imagens	12
2.3.1 Técnica de Limiarização - <i>Threshold</i>	13
2.3.2 Técnicas para Detecção de Bordas	15
2.3.3 Segmentação por Região	19
2.3.4 Segmentação por Cor	22
2.4 Técnicas de Reconhecimento de Padrões	24
2.4.1 Descritores Simples	26
2.4.2 Descritores de Fourier	26
2.4.3 Descritores Baseados em Momentos	28
2.4.4 Descritores Baseados em Contorno	29
2.4.5 Esqueletização	30
2.4.6 Classificação por <i>Template Matching</i> - Casamento	33

2.4.7	Lógica Nebulosa - Fuzzy	33
2.4.8	Classificação por Redes Neurais	35
2.4.9	Análise de Componentes Principais (PCA)	38
2.5	Sumário	41
3	Situação do Problema	42
3.1	Plantas Invasoras e sua Importância Econômica na Região do Cerrado Brasileiro	42
3.1.1	A Fazenda Campo Bom	42
3.1.2	Fator Econômico	43
3.1.3	Resistência das Plantas Invasoras	44
3.1.4	Plantas Invasoras da região	45
3.2	Agricultura de Precisão no Controle de Plantas Invasoras	46
3.3	Técnicas Utilizadas para o Controle das Plantas Invasoras	47
3.3.1	Plantio Direto	48
3.3.2	Outras Práticas Convencionais	48
3.3.3	Técnicas Apoiadas por Sensoriamento Remoto	49
3.4	<i>Bidens Pilosa</i> - Picão-Preto	51
3.4.1	Estudo do Reconhecimento da Planta Invasora Picão Preto	53
3.4.2	O reconhecimento da Planta Picão Preto na Agricultura	56
3.5	Metodologia Adotada	57
3.6	Sumário	58
4	Arquitetura do Sistema de Identificação	59
4.1	Projeto Modular	60
4.2	Módulo de Extração das Informações para Processamento	61
4.2.1	Técnica de Hotteling	61
4.3	Módulo de Redes Neurais	62
4.3.1	Redes Neurais Artificiais	62
4.3.2	Algoritmo <i>Backpropagation</i>	65
4.4	Ambiente de Desenvolvimento SNNS	67
4.5	Sumário	71

5	Módulo de Geração de Imagens para Teste	72
5.1	Necessidades e Requisitos	72
5.2	Projeto e Implementação	74
5.2.1	Operação do Sistema	76
5.3	Sumário	82
6	Resultados Obtidos	83
6.1	Treinamento da rede	83
6.1.1	Caso 1 - Treinamento com 70 Padrões de Folha e 10 % de Erro	84
6.1.2	Caso 2 - Treinamento com 100 Padrões de Folha e 10 % de Erro . . .	85
6.1.3	Caso 3 - Treinamento com 100 Padrões de Folha e 1 % de Erro	86
6.1.4	Caso 4 - Treinamento com 150 Padrões de Folha e 10 % de Erro . . .	86
6.1.5	Caso 5 - Treinamento com 150 Padrões de Folha e 1 % de Erro	87
6.1.6	Caso 6 - Treinamento com 100 Padrões de Flor e Semente e 10 % de Erro	87
6.1.7	Caso 7 - Treinamento com 200 Padrões de Folha, Flor e Semente e 10% de Erro	88
6.2	Testes Realizados	89
6.2.1	Teste da Rede do Caso 1	89
6.2.2	Teste da Rede do Caso 2	89
6.2.3	Teste da Rede do Caso 3	90
6.2.4	Teste da Rede do Caso 4	90
6.2.5	Teste da Rede do Caso 5	90
6.2.6	Teste da Rede do Caso 6	91
6.2.7	Teste da Rede do Caso 7	91
6.3	Análise dos Resultados	92
7	Conclusões	93
7.1	Contribuições do Trabalho	94
7.2	Trabalhos Futuros	94
	Referências Bibliográficas	103

A Principais Plantas Invasoras	104
Glossário das Plantas Invasoras	113

Lista de Figuras

2.1	Conectividade dos pixels vizinhos em uma imagem	5
2.2	Sistema de visão computacional	6
2.3	CCD de uma câmera fotográfica digital	6
2.4	Reconhecimento de padrões	9
2.5	Máscara passa-baixas	10
2.6	Processo de filtragem passa-baixas	11
2.7	Aplicação do filtro da mediana	11
2.8	Processo de filtragem pela mediana	12
2.9	Processo de binarização por <i>threshold</i>	13
2.10	Processo de equalização da imagem	15
2.11	Máscara de Sobel	16
2.12	Determinação da magnitude e da direção da borda	16
2.13	Aplicação dos operadores de Sobel sobre uma imagem	17
2.14	Máscara de Laplace	17
2.15	Aplicação do operador laplaciano	18
2.16	Processo de busca do contorno de uma imagem	19
2.17	Processo de crescimento de região	21
2.18	Processo de divisão e fusão de uma imagem	22
2.19	Cubo de cores do modelo RGB	23
2.20	Exemplos de reconstrução com descritores de Fourier	28
2.21	Representação do segmento de uma fronteira por momentos	29
2.22	Extração do contorno de uma região para parametrização	30
2.23	Esqueletização de uma imagem	32
2.24	Gráfico da função de associação pela lógica fuzzy	35

2.25	Rede neural artificial	36
3.1	Agricultura de precisão	51
3.2	Picão adulto.	52
3.3	Picão pequeno.	53
3.4	Semente de picão.	53
3.5	Planta com 3 a 5 dias.	54
3.6	Planta com 10 a 15 dias	54
3.7	Planta com 17 a 20 dias	54
3.8	Planta com 22 a 25 dias	54
3.9	Planta com 27 a 30 dias	55
3.10	Planta com 35 a 38 dias.	55
3.11	Planta com 40 a 50 dias	55
3.12	Planta com 50 a 60 dias	55
3.13	Planta com 60 a 70 dias	56
3.14	Plantas invasoras em culturas de soja e milho.	57
4.1	Arquitetura proposta para identificação de plantas invasoras	60
4.2	Neurônio artificial.	64
4.3	Rede perceptron multicamadas - MLP	65
4.4	<i>Backpropagation</i>	66
4.5	Tela inicial do SNNS	68
4.6	Definição da rede neural	68
4.7	Representação gráfica da rede neural	69
4.8	Definição dos arquivos	69
4.9	Parâmetros do treinamento	70
4.10	Simulação do treinamento	70
4.11	Simulação do teste	71
5.1	Plantas invasoras em culturas de soja e milho.	73
5.2	Módulo de geração de imagens para teste	74
5.3	Diagrama de fluxo de dados - nível 1	75
5.4	Tela inicial	77

5.5	Opção para inserção da tomada	77
5.6	Opção para inserção de imagens	78
5.7	Opção para escolha da dimensão das subimagens	78
5.8	Inserção de uma imagem	79
5.9	Inserção de várias imagens	79
5.10	Subdivisão da imagem inserida	80
5.11	Cadastro das subimagens	80
5.12	Inserção de novas características	81
5.13	Inserção de novas plantas	81
6.1	Exemplo de um arquivo Hotteling	83
6.2	Padrão utilizado pelo SNNS	84
6.3	Treinamento do Caso 1.	85
6.4	Treinamento do Caso 2.	85
6.5	Treinamento do Caso 3.	86
6.6	Treinamento do Caso 4.	86
6.7	Treinamento do Caso 5.	87
6.8	Treinamento do Caso 6.	87
6.9	Treinamento do Caso 7.	88

Lista de Tabelas

2.1	Atribuição do grau de pertinência	34
3.1	Planilha de custo de herbicidas por área de aplicação	44
6.1	Tabela Comparativa de Treinamento	88
6.2	Tabela Comparativa dos Testes	91

Resumo

A identificação de plantas invasoras é de extrema importância em diversos procedimentos utilizados na agricultura. Apesar de ser uma tarefa computacionalmente difícil, esta identificação tem se tornado muito importante no contexto da agricultura de precisão.

A agricultura de precisão substitui os tratamentos culturais de grandes áreas da cultura, feitos pela média do nível dos problemas encontrados nessas áreas, por tratamentos específicos e pontuais. As principais vantagens são o aumento de produtividade, relacionado com a diminuição da variabilidade na produção, a economia de insumos e a preservação do meio ambiente.

Este trabalho enfoca o reconhecimento de plantas invasoras em tempo real. Para manter o requisito de tempo real, são utilizadas redes neurais artificiais como meio para o reconhecimento de padrões.

Entre as diversas plantas invasoras de ocorrência frequente no cerrado brasileiro, foi selecionado o picão preto para a avaliação das técnicas adotadas. Uma arquitetura modular de reconhecimento é proposta, com o uso de processamento paralelo, facilitando a inclusão de módulos de reconhecimento de outras plantas invasoras sem a deterioração do desempenho do sistema.

Os resultados obtidos são amplamente satisfatórios, demonstrando a possibilidade do desenvolvimento de um sistema embarcado completo de identificação de plantas invasoras em tempo real. Este sistema, apoiado pelo sistema de posicionamento global GPS, pode servir de base para uma série de máquinas agrícolas inteligentes, como pulverizadores de herbicidas e outros defensivos utilizados na agricultura.

Abstract

Weed identification is an important task in many agricultural procedures. In spite of being a computation intensive task, this identification is very important in the role of precision agriculture.

Conventional procedures in agriculture are based on the average level of the problems found in large areas. Precision agriculture introduces new punctual management procedures, dealing with very small areas. The main advantages are: productivity increase, related with the decrease in production unevenness, economy and environment preservation.

This work focuses on the real time recognition of weeds. To maintain the real time requirement, neural networks are used to carry out the recognition of image patterns.

Among the several weeds frequently found in the Brazilian savannah, the "picão preto" was selected for the evaluation of the adopted techniques. A modular architecture is proposed, using parallel processing, making easier the use of new recognition modules (for other weeds), still preserving the real time capabilities of the system.

Results obtained are thoroughly adequate, demonstrating the possibility of the development of embedded systems for the identification of several weeds in real time. These systems, jointly with the global positioning system (GPS), can be used in a family of intelligent equipment, such as spraying machines for herbicides and other agricultural products.

Capítulo 1

Introdução

Na agricultura, a identificação de plantas invasoras constitui uma tarefa bastante difícil, porém, de grande importância. Essa importância está relacionada com a prática convencional agrícola, onde são aplicadas grandes quantidades de herbicidas sem dosagem muito correta, podendo comprometer não só o desenvolvimento da cultura, como também resultar em um aumento do custo. Na prática convencional agrícola, a análise da infestação de plantas invasoras é realizada visualmente através de uma observação em grande escala.

O conceito de agricultura de precisão (AP) envolve um conjunto de tecnologias como, por exemplo, o sensoriamento remoto, manipulação e controle de dados, informações geográficas e o processamento digital de imagens, para um melhor gerenciamento na detecção de plantas invasoras [MOR 97, SON 98, PAC 01, MOL 97].

Baseadas em um melhor conhecimento do campo, as técnicas de agricultura de precisão permitem tomadas de decisão mais eficientes. Ao contrário da prática convencional agrícola, as técnicas utilizadas na agricultura de precisão utilizam pequenas amostragens para a análise, observando a variabilidade espacial e temporal. Essas técnicas possibilitam uma melhor distribuição de insumos e herbicidas no tempo e na quantidade certa, minimizando o custo de produção [NIS 98, PIE 99] e possibilitando maior produtividade. Os insumos e herbicidas com melhor dosagem também favorecem a preservação contínua do meio ambiente.

As técnicas de processamento digital de imagens auxiliam na extração de informações para posterior interpretação, como por exemplo, para a análise inteligente em uma rede neural artificial [MOR 97].

Na obtenção das imagens são utilizadas técnicas de sensoriamento remoto, feitas por sensores em aeronaves ou satélites [PHO 83, NIS 98]. O sensoriamento remoto por aeronaves tem sido de grande importância para a agricultura de precisão [MOR 97, FRA 98], pois além de permitir a detecção de vários problemas ambientais possibilita o monitoramento da cultura sem comprometer o seu desenvolvimento [TEO 90, ULB 95, SUD 97].

Câmeras fotográficas digitais ou de vídeo também são bastante utilizadas na aquisição das imagens. Dentre algumas vantagens quanto a sua utilização, destaca-se o seu baixo custo [MOR 97, PAC 98, BRA 95].

Inúmeras aplicações estão diretamente relacionadas ao gerenciamento de recursos terrestres, mapeamento e monitoramento de coberturas vegetais [MOR 97, SUD 97, PIE 99]. Entre elas destacam-se:

- Monitoramento do Solo - consiste na aquisição de informações do solo, como presença de nutrientes, seus componentes e vegetação existente;
- Monitoramento do Crescimento da Cultura - consiste em monitorar os elementos da cultura e também a quantidade de plantas invasoras na cultura;
- Identificação e Controle de doenças - consiste na identificação de doenças nas culturas, como por exemplo, problemas genéticos ou má formação durante o período de desenvolvimento; infestação de insetos na cultura e posterior controle por meio de inseticidas ou outro meio.

A necessidade de identificar plantas invasoras em uma cultura é quase tão antiga quanto a própria agricultura. Sua prática é de suma importância para a obtenção de altos rendimentos em qualquer tipo de exploração agrícola [GAZ 01, PIE 99].

Plantas invasoras ou daninhas, como são conhecidas por muitos, podem ser vistas de formas diferentes, dependendo das conseqüências de sua existência no local. Uma mesma planta pode ser vista como daninha quando sua existência prejudica a cultura em atividade, ou benéfica, quando ela atua na proteção do solo, como por exemplo, controlando erosão e desequilíbrio de nutrientes. As plantas invasoras podem ser espécies nativas ou introduzidas a partir de outro habitat [CAP 97a, RIS 96, PIE 99]. Existe uma grande variedade dessas plantas e inúmeras delas estão associadas à cultura em atividade.

A permanência ou persistência das plantas invasoras de uma cultura a outra é causada pela existência de sementes deixadas e germinadas das plantas invasoras da cultura anterior. Durante a colheita as sementes das plantas invasoras caem permanecendo nos locais aproximados do seu desenvolvimento anterior [CAP 97a].

A partir da identificação das plantas invasoras, pode-se estabelecer o grau de invasão através de mapas digitais que podem ser utilizados no planejamento da compra dos herbicidas necessários e também na dosagem da quantidade necessária para o controle dessas plantas, de acordo com o grau de invasão e a época de aplicação [MOR 97, GAZ 01].

Embora a utilização de fotos aéreas seja importante no mapeamento da infestação de plantas invasoras, para a identificação das espécies existentes, as fotos devem ser, geralmente, obtidas com mais proximidade.

Neste trabalho, o sistema de identificação de plantas invasoras é feito a partir de fotos obtidas por câmeras digitais (Kodak e Mavica) embarcadas nos tratores que realizam a pulverização de herbicidas. A identificação das plantas invasoras é feita automaticamente, com a aplicação de técnicas de processamento digital de imagens.

1.1 Organização do Texto

Este trabalho está dividido em sete capítulos. No capítulo 2 são apresentados alguns conceitos de processamento digital de imagens, abrangendo filtros de suavização de imagens, tais como filtro passa-baixas, mediana; técnicas de reconhecimento de padrões, apresentando redes neurais e análise de componentes principais (PCA). O capítulo 3 apresenta a situação do problema, a fazenda Campo Bom, as plantas encontradas durante a pesquisa e sua resitência e fator econômico, bem como as técnicas utilizadas para o controle de plantas invasoras e a planta picão preto, escolhida para a realização dos testes. A arquitetura do sistema de identificação de plantas invasoras em tempo real é apresentada no capítulo 4, bem como os módulos de extração de informações para o processamento com a técnica de análise de componentes principais, Hotteling, redes neurais e o ambiente de simulação de redes neurais SNNS. No capítulo 5 é apresentado o módulo de geração de imagens para testes, a necessidade e requisitos, projeto e a implementação. O capítulo 6 apresenta os resultados obtidos, bem como a fase de treinamento e teste das informações em uma rede neural. Finalmente, no capítulo 7 são apresentadas as conclusões deste trabalho.

Capítulo 2

Técnicas para Processamento de Imagens e Reconhecimento de Padrões

Este capítulo tem por objetivo apresentar o conceito de Processamento Digital de Imagens e as técnicas utilizadas no tratamento da imagem desde o pré-processamento, extração de características, definição de padrões, classificação e identificação até o reconhecimento de padrões. A seção 3.1 introduz o conceito de processamento digital de imagens e as etapas fundamentais no processamento dessas imagens. Na seção 3.2 são apresentadas algumas técnicas utilizadas durante o pré-processamento das imagens digitais, como técnicas de realce, suavização e detecção de bordas. As técnicas de segmentação de imagens são apresentadas na seção 3.3. Na seção 3.4, são apresentadas as técnicas de reconhecimento de padrões, como os descritores e as técnicas de classificação.

Finalmente, é apresentado um sumário dos diversos tópicos revistos neste capítulo.

2.1 Processamento Digital de Imagens

O Processamento digital de imagens consiste na extração e transformação de uma imagem de tal forma que as informações dessa imagem se apresentem de maneira mais facilmente discernível para a análise de suas características.

Esse processamento é utilizado para melhorar o aspecto visual de certas características

da imagem com o objetivo de fornecer subsídios para a sua interpretação e geração de dados que possam ser submetidos a outros processamentos [FRI 98].

O termo imagem está associado a um conjunto de pixels ¹ dispostos em uma matriz (vetor bi-dimensional), onde o índice i aponta as linhas e o índice j , as colunas [JAI 95].

Um pixel $p_1(x, y)$, é vizinho de um outro $p_2(m, n)$ se e somente se $|x-m|$ ou $|y-n| = 1$.

Exemplo de vizinhança em uma matriz:

0	0	0	0	0
1	v	v	v	0
1	v	a	v	1
0	v	v	v	1
0	0	0	1	0

onde, **v** são os vizinhos de **a**.

A figura 2.1(a) representa vizinhança 4 e a 2.1(b), vizinhança 8.

Figura 2.1: Conectividade dos pixels vizinhos em uma imagem

Uma imagem pode possuir vários objetos. Para que esses objetos possam ser identificados, classificados e separados, utiliza-se o processamento digital de imagens digitais juntamente com técnicas de análise e reconhecimento de padrões.

Todas estas técnicas compõem um sistema de visão computacional conforme apresenta a figura 2.2 [JAI 95].

¹Pixels ou Pel (Picture Elements), são os elementos componentes da imagem [GON 92].

Figura 2.2: Sistema de visão computacional

A primeira etapa do processo é denominada **aquisição de imagens** e consiste na obtenção da imagem digital. Para isso são necessários sensores, podendo ser de raio-X, ultravioleta, infravermelho, entre outros, e um dispositivo digitalizador do sinal elétrico produzido pelo sensor [GON 92].

Os *scanners* também são mecanismos bastante usados na aquisição de imagens, principalmente em aplicações que requerem o congelamento de imagens [GON 92].

No caso de fotografia digital, há um dispositivo eletrônico conhecido como CCD (*Charge Coupled Device*), que converte as intensidades de luz que incidem sobre ele em valores digitais armazenáveis na forma de bits [CAP 97b]. Esse dispositivo pode ser visto na figura 2.3.

Figura 2.3: CCD de uma câmera fotográfica digital

Existem dois tipos básicos de CCD que podem ser utilizados em câmeras fotográficas digitais:

- **CCD linear**- nada mais é que uma fileira com milhares de elementos fotossensíveis que varrem a área onde a imagem se forma na câmera, capturando uma coleção de linhas que formam a fotografia. Esse dispositivo pode fornecer uma resolução bem alta

e gerar arquivos bem grandes. A geração de uma imagem leva um bom tempo para ser completada. As câmeras que usam este tipo de CCD são geralmente utilizadas, em estúdios para fotografias estáticas de alta definição. Não são câmeras indicadas para objetos em movimento e podem apresentar resultados ruins quando utilizadas em iluminação piscante, como lâmpadas fluorescentes.

- **CCD do tipo Array** - é uma matriz com milhares, ou até milhões, de elementos fotossensíveis que capturam os pixels da imagem simultaneamente. Esse dispositivo produz resultados equivalentes ao de uma imagem fotográfica comum, com relação ao tempo de captura, mas normalmente produz imagens com qualidade inferior às conseguidas com o CCD linear. O CCD linear permite capturar uma quantidade maior de pixels que o CCD tipo Array. As câmeras que utilizam este tipo de CCD (retangular) são as mais populares do mercado e apresentam não somente preços mais acessíveis, como também facilidade de uso e portabilidade.

Outra tecnologia similar ao CCD é o CMOS (*Complementary Metal - Oxide Semiconductor*). A principal vantagem que os sensores CMOS apresentam é o baixo custo. Além disso, consome menos energia que os dispositivos CCD, embora a qualidade da imagem seja inferior podendo apresentar mais ruído [CHI 01].

Após a aquisição das imagens, é necessário realizar o **pré-processamento**. Nesta etapa, o objetivo é modificar a imagem evidenciando as características utilizadas nas próximas fases do processamento. É realizada a calibração radiométrica na imagem para corrigir as distorções de cor encontradas. Técnicas adicionais, como realce e remoção de ruídos, são utilizadas para tornar a imagem mais adequada que a imagem original para uma aplicação específica ² [GON 92, JUN 96]. Várias técnicas podem ser utilizadas durante o pré-processamento e algumas são apresentadas na seção 3.2.

A próxima etapa do processo é a **segmentação da imagem**, que consiste na divisão da imagem em partes ou objetos constituintes. Esses objetos são posteriormente analisados por algoritmos específicos na busca de informações ditas de alto nível [GON 92, ALB 00].

A imagem binária é bastante utilizada no processamento de imagens por apresentar um número reduzido de dados, facilitando consideravelmente sua manipulação [ALB 00].

²Dizer apropriada para uma aplicação específica, significa que um método de realce pode ser vantajoso para um tipo de aplicação, mas pode não ser melhor para outra [GON 92].

Uma operação de segmentação pode por exemplo, identificar os pixels que correspondem à fronteira de uma região ou à sua parte interna. A representação por fronteira é importante nas aplicações que se concentram nas características externas, como cantos ou contornos. A representação por regiões é adequada nas aplicações que se concentram nas características internas, como textura ou forma do esqueleto [GON 92].

Existem várias técnicas de segmentação. Nenhuma delas segmenta todos os tipos de imagem [ALB 00]. Na seção 3.3 são apresentadas algumas técnicas de segmentação de imagens.

A etapa seguinte do processo constitui a **representação e descrição**. O processo de representação consiste na transformação dos dados iniciais em uma forma adequada para a próxima etapa do processamento. As características principais devem ser enfatizadas e extraídas [GON 92]. O processo de descrição, também conhecido como seleção de características, extrai as características principais que resultam em informação quantitativa, capaz de discriminar as classes de objetos importantes para o reconhecimento dos padrões [GON 92, DOR 00].

Não existe uma regra geral para saber quais características são relevantes para a solução de um problema. A escolha é influenciada pela natureza dos dados, aplicação em questão e a tecnologia disponível [DOR 00]. Por exemplo, no reconhecimento de folhas vegetais, descritores de contornos e esqueletos são importantes na sua diferenciação [GON 92]. Algumas técnicas discriminantes, ou descritores e extratores de características como também são conhecidas, são apresentadas na seção 3.4 deste capítulo.

A última etapa do processamento de imagens, o **reconhecimento e interpretação**, consiste em atribuir rótulos aos objetos, classificando-os a partir de informações encontradas na imagem pelo descritor. Existe uma base de conhecimento de apoio que age de forma interativa com os módulos de reconhecimento [GON 92, ALB 00].

É importante ressaltar que, para cada problema de reconhecimento de padrões, técnicas variadas podem ser utilizadas, desde métodos clássicos até métodos baseados em redes neurais [DOR 00, ALB 00]. Alguns métodos mais utilizados são:

- **Reconhecimento Estatístico** - as características estão na forma de n-tuplas de vetores, sendo utilizadas regras de decisão e teoria da probabilidade, entre outras;
- **Reconhecimento Lingüístico/Estrutural** - as características têm a forma de sen-

tenças de uma linguagem reconhecida por uma gramática.

A figura 2.4 representa o processo de reconhecimento de padrões; em 2.4(a) é mostrada uma imagem com classes identificadas; em 2.4(b), uma atribuição de identificadores (rótulos) a cada objeto.

Figura 2.4: Reconhecimento de padrões

Neste trabalho foram revistas vistas várias técnicas para o pré-processamento da imagem. Poucos artigos se preocupam com o tempo de processamento. Na próxima seção, são apresentadas algumas técnicas de pré-processamento bastante utilizadas.

2.2 Técnicas de Pré-processamento

Existem vários filtros e outras técnicas que podem ser utilizados para o pré-processamento da imagem. Entre as técnicas mais comuns pode-se citar:

- Suavização;
- Técnica de Fourier;
- Função gaussiana;
- Histogramas
- Detecção de bordas.

A técnica de suavização é descrita no item seguinte.

2.2.1 Suavização

Pode-se provocar um borramento na imagem diminuindo o ruído (altas-freqüências), como por exemplo, pelo uso de filtros passa-baixas e filtragem pela média. Quando se tem por objetivo preservar as bordas em uma imagem é importante o uso de filtros que suavizam, mantendo as informações das bordas, como por exemplo, o filtro da mediana [ART 99, GON 92].

Filtragem Passa-Baixas

Esse tipo de filtro é normalmente utilizado na suavização da imagem para eliminação de ruídos ³ [ART 99, GON 92].

O termo domínio do espaço ou espacial refere-se ao agregado de pixels que compõem uma imagem. Métodos no domínio espacial, como o filtro passa-baixas, são procedimentos que operam diretamente sobre os pixels [GON 92].

Para esse tipo de filtragem, são utilizadas máscaras, ou seja, matrizes quadradas com valores(coeficientes), para a filtragem. Um filtro passa-baixas no domínio do espaço possui todos os coeficientes com o mesmo sinal. As máscaras são utilizadas em toda a imagem, realizando-se a somatória do produto entre os valores da máscara e os pixels da região na imagem seguida de uma divisão pelos coeficientes da máscara.

A figura 2.5(a) mostra uma máscara com vizinhança 4 e 8.

0	1	0
1	1	1
0	1	0

(a)

1	1	1
1	1	1
1	1	1

(b)

Figura 2.5: Máscara passa-baixas

Um filtro espacial 3 x 3 simples, com coeficientes todos iguais a 1, pode ser aplicado na imagem utilizando-se a equação: $R = (Z_1 + Z_2 + ...Z_9)/9$, onde R é o valor do pixel resultante e $Z_1...Z_9$, os valores dos pixels da imagem sobre os quais é aplicada a máscara.

³Considerando a imagem como um sinal periódico, os ruídos estão associados com as oscilações de alta freqüência do sinal [VEL 00].

A filtragem utilizando a matriz acima é conhecida como filtragem pela Média. Máscaras maiores seguem o mesmo conceito [GON 92].

A figura 2.6(a) mostra a imagem original com ruídos e a figura 2.6(b) mostra o resultado obtido por este tipo de filtragem.

Figura 2.6: Processo de filtragem passa-baixas

Filtragem pela Mediana

Um dos problemas decorrentes da aplicação de filtros passa-baixas é a perda de informações nas bordas. Como alternativa para eliminar ruídos, pode-se utilizar um filtro da mediana. Este tipo de filtro preserva as informações das bordas em uma imagem [GON 92, ART 99, JAI 95].

Utilizando-se uma máscara 3 x 3, para o cálculo da mediana, deve-se ordenar o vetor para encontrar o valor mediano que divide o vetor em duas partes iguais. Encontrado o valor mediano, este irá substituir o pixel central [COS 01]. Este procedimento pode ser observado na figura 2.7.

Figura 2.7: Aplicação do filtro da mediana

A imagem resultante de uma filtragem pela mediana pode ser vista na figura 2.8, sendo a figura (a) a imagem original e a (b) o resultado da filtragem.

Figura 2.8: Processo de filtragem pela mediana

2.3 Técnicas de Segmentação de Imagens

A segmentação é um dos passos mais importantes para o reconhecimento de objetos em imagens [JAI 95, MEN 00]. Segmentar é particionar uma imagem em regiões. As partições podem representar um objeto ou parte dele.

Existem muitas técnicas para a segmentação de imagens. Entre as principais pode-se citar:

- Limiarização (*threshold*);
- Segmentação por região;
- Segmentação por bordas
- Segmentação por contorno;
- Segmentação por cor;
- Watershed;

Nos itens seguintes são descritas algumas das técnicas de uso mais comum.

2.3.1 Técnica de Limiarização - *Threshold*

Threshold é uma operação que tem por objetivo classificar os pixels de uma imagem em duas classes distintas, normalmente, objetos e o fundo [GON 92, JAI 95, SCH 89].

Esse método é bastante utilizado na segmentação de imagens. O processamento é feito da seguinte maneira: um valor (limiar) é determinado após alguma análise dos valores dos níveis de cinza da imagem. Pixels com valores de brilho inferiores a esse limiar são colocados em uma classe enquanto pixels com valores superiores ou iguais são colocados em outra classe [ART 99, JAI 95].

A determinação de um limiar ótimo não é uma tarefa simples. Existem vários métodos propostos para a obtenção do valor limiar adequado, entre eles destacam-se: P-Tile, Método de Pun, Método de Kapur, Método de Sahoo e Wong, Método de Johannsen e Bille e Método do Triângulo [SAH 88].

Como ferramenta auxiliar para várias operações, é comum a utilização de histogramas que permitem uma visualização da distribuição dos níveis de cinza das imagens. Vários dos métodos citados utilizam a informação da distribuição dos níveis de cinza para determinar o limiar [COS 01, BEE 97, PAR 99].

Em alguns casos é mais conveniente trabalhar com uma imagem que contenha apenas dois níveis de cinza (imagem binária). Neste caso, pixels com valores de brilho inferiores ao limiar recebem valor 0 (zero) e pixels com valores superiores ou iguais recebem o valor 1 (um).

As figuras 2.9(a) e 2.9(b) ilustram o processo de binarização de uma imagem.

(a)

(b)

Figura 2.9: Processo de binarização por *threshold*

Para o cálculo da imagem resultante $f_t(x, y)$ utiliza-se a regra:

$$f_t(x, y) = \begin{cases} 1 & \text{se } f(x, y) \geq T; \\ 0 & \text{se } f(x, y) < T. \end{cases} \quad (2.1)$$

Sendo T, o valor limiar dos pixels da imagem utilizado para determinação dos valores (1 e 0).

Histograma

Em processamento de imagens, a utilização de histogramas não se resume apenas em operações de limiarização/ binarização. É comum a utilização de histogramas em várias outras operações com objetivo de melhorar a imagem sob algum aspecto [SON 99]. Algumas operações são realizadas através de uma manipulação direta do histograma. Uma dessas operações é a equalização, que altera a distribuição dos níveis de cinza [JAI 95, SON 99, INP 01]. Esta distribuição dos níveis de cinza é utilizada para obter um histograma uniforme, melhorar o aspecto da imagem possibilitando uma melhor e mais fácil interpretação.

O histograma de uma imagem $f(x,y)$, com N níveis de cinza, é representado por um vetor unidimensional de N elementos. Inicialmente, todos os elementos deste vetor recebem o valor 0 (zero). O elemento N desse vetor é incrementado de 1 sempre que um nível de cinza igual a N é encontrado na imagem [SON 99, GON 92].

A equalização do histograma pode ser obtida por [GON 00]:

$$S = \left(\sum_{i=0}^k m_i / I \right) - 1 \quad (2.2)$$

onde S, corresponde ao nível de cinza do pixel que está sendo equalizado. Para todo $0 \leq k \leq NC$, onde NE corresponde aos níveis de cinza da imagem equalizada; NC são os níveis de cinza da imagem original; m_i é a freqüência do nível de cinza i ; I está definido no exemplo abaixo.

Para o cálculo da equalização de uma imagem contendo 30 pixels (n x m), com 9 níveis de cinza (NC), e I é dado por:

$$I = \frac{nm}{NC} = \frac{30}{9} = 3,33...(\text{arrend}) = 3 \quad (2.3)$$

O processo de equalização de uma imagem original é apresentado na figura 2.10.

Figura 2.10: Processo de equalização da imagem

2.3.2 Técnicas para Detecção de Bordas

As bordas de uma imagem definem o limite entre duas regiões distintas com referência a propriedades de cor ou nível de cinza, definindo o contorno dos objetos presentes na imagem. Quando ocorre uma mudança bastante brusca de um valor de nível de cinza para outro (alta frequência), entende-se que há presença de borda. Isso contribui para a detecção de formas e para a análise de objetos [GON 92, GON 96].

Técnica de Sobel

A técnica de Sobel utiliza duas máscaras distintas, uma para o eixo X e outra para o eixo Y, para a detecção das bordas de uma imagem. Ela considera a somatória dos pixels da imagem multiplicados pelos coeficientes da máscara. Esta somatória é utilizada para os cálculos da magnitude, gradiente e direção da borda [GON 92, ART 99].

As máscaras utilizadas no operador de Sobel podem ser vistas na figura 2.11 [JAI 95, ART 99].

-1	0	1
-2	0	2
-1	0	1

S(x)

1	2	1
0	0	0
-1	-2	-1

S(y)

Figura 2.11: Máscara de Sobel

A aplicação dos dois operadores S_x e S_y (primeira derivada), resulta nos gradientes da borda na direção x e y , e por meio destes, é possível obter a magnitude e a direção (ângulo) da borda em cada pixel por [ART 99, GON 92]:

$$Magnitude = \sqrt{S_x^2 + S_y^2} \quad (2.4)$$

$$\alpha = \arctan \frac{S_y}{S_x} \quad (2.5)$$

A determinação da magnitude e da direção das bordas pode ser vista graficamente na figura 2.12.

Figura 2.12: Determinação da magnitude e da direção da borda

Deve-se ressaltar que as máscaras são baseadas no operador diferencial. Elas podem resultar em valores nulos em regiões que sejam homogêneas, indicando que o pixel em estudo não pertence a uma borda [ART 99, JAI 95].

Os operadores diferenciais ressaltam os contornos das bordas, porém amplificam o ruído da cena. Grande parte dos operadores de borda utiliza algum tipo de suavização da imagem antes da operação diferencial, com o uso de algum filtro apropriado [ART 99, SCH 89, MEN 00].

O resultado da aplicação dos operadores de Sobel sobre uma imagem pode ser visto na figura 2.13. A figura 2.13(b) é a imagem binarizada da imagem original 2.13(a). A detecção de bordas na imagem binarizada é apresentada na figura 2.13(c).

Figura 2.13: Aplicação dos operadores de Sobel sobre uma imagem

Técnica de Laplace

Enquanto a técnica de Sobel emprega derivadas de primeira ordem, ou seja, gera dois gradientes da imagem (S_x e S_y), o laplaciano de uma função bidimensional $f(x,y)$ é formado por derivadas de segunda ordem, sendo definido por [GON 92, JAI 95, SCH 89]:

$$\nabla^2 f(x, y) = \frac{\partial^2 f(x, y)}{\partial x^2} + \frac{\partial^2 f(x, y)}{\partial y^2}, \quad (2.6)$$

Da mesma forma que a técnica de Sobel utiliza máscaras para o cálculo dos gradientes, o laplaciano utiliza a máscara apresentada na figura 2.14 [GON 92, JAI 95, SCH 89, BRI 98].

0	-1	0
-1	4	-1
0	-1	0

Figura 2.14: Máscara de Laplace

O laplaciano $R(x,y)$ (imagem resultante), é nulo se $f(x,y)$ for constante ou variar linearmente em amplitude. Se a taxa de variação de $f(x,y)$ for maior que a de uma função

linear, então $R(x,y)$ exibe uma mudança de sinal, indicando que pixels vizinhos têm o mesmo valor. Dessa forma a derivada passa por zero, detectando a presença de uma borda [BRI 98, GON 92].

A aproximação mais simples para o laplaciano consiste no cálculo das diferenças das derivadas em cada posição da imagem de acordo com a expressão abaixo [BRI 98]:

$$R(x,y)=[f(x,y)-f(x,y-1)]-[f(x,y+1)-f(x,y)]+[f(x,y)-f(x+1,y)]-[f(x-1,y)-f(x,y)]$$

Por ser uma derivada de segunda ordem, o laplaciano é bastante sensível a ruídos, o que representa uma desvantagem. Mesmo assim, ele pode auxiliar na determinação precisa da borda (claro ou escuro) que se encontra um pixel [GON 92, JAI 95, MEN 00].

O resultado da aplicação do operador laplaciano sobre uma imagem, pode ser visualizado na figura 2.15. A figura 2.15 (b) é uma imagem binarizada da imagem original 2.15 (a). A detecção de bordas na imagem original é apresentada na figura 2.15 (c).

Figura 2.15: Aplicação do operador laplaciano

Formação de Contornos

Um contorno é definido como o caminho obtido através da conexão dos pixels de borda encontrados em uma dada região da imagem [JAI 95]. Para a representação de um contorno, são armazenados os valores das coordenadas x e y de cada pixel do caminho percorrido. É possível definir se o contorno é aberto ou fechado. No caso do pixel inicial ser igual ao final, tem-se um contorno fechado; caso contrário, tem-se um contorno aberto [SCH 89, COS 01]. Descontinuidades podem ocorrer na fronteira de uma região devido a problemas de contraste,

tornando difícil a detecção do contorno completo [JAI 95].

Como a segmentação por contorno baseia-se exclusivamente nas bordas da imagem, para que o contorno seja realmente encontrado é necessário que as bordas estejam bem definidas [SCH 89, JAI 95]. Quando isso não ocorre, podem ser utilizadas operações como a de equalização do histograma da imagem.

Vários algoritmos podem ser utilizados para determinar o caminho do contorno. O mais conhecido é o algoritmo de perseguição de contorno (*Contour Following Algorithm*). Este algoritmo inicia uma varredura na primeira linha da imagem e segue até encontrar o primeiro pixel da borda. Em seguida procura na vizinhança o próximo pixel do contorno, repetindo este passo até encontrar o pixel inicial (contorno fechado) ou até não ser possível continuar (contorno aberto) [JAI 95, GON 00].

A figura 2.16 mostra uma representação esquemática do processo de busca do contorno sobre uma determinada imagem [GON 00]:

Figura 2.16: Processo de busca do contorno de uma imagem

2.3.3 Segmentação por Região

Uma região da imagem é um conjunto de pixels conectados que apresentam uma certa homogeneidade⁴. A definição da região depende do tipo de vizinhança utilizada (vizinhança 4 ou vizinhança 8) [JAI 95, BRI 99].

A segmentação de uma imagem por região consiste na sua divisão e subdivisão (particionamento) em outras regiões menores, levando-se em consideração a homogeneidade desejada. Desta forma, a imagem original está relacionada com suas partes através da seguinte

⁴Por homogeneidade entende-se um conjunto de pixels com propriedades (valores) similares, quanto aos níveis de cinza ou cor [BRI 99].

expressão:

$$\cup_{i=1}^n R_i = f(x, y) \quad (2.7)$$

onde, $\cup_{i=1}^n R_i$ corresponde a união de todas as regiões e $f(x,y)$ a imagem total.

Nesse tipo de segmentação encontram-se alguns problemas, por exemplo, dado um conjunto de pixels da imagem $f(x,y)$ e uma homogeneidade $H(R_i)$, encontrar uma partição S da imagem $f(x,y)$ dentro do conjunto de n regiões R [JAI 95, GON 92]:

A homogeneidade H das partições R_i da imagem têm a seguinte propriedade:

$$H(R_i) = Verdadeiro \quad (2.8)$$

$$H(R_i \cup R_j) = Falso, \quad (2.9)$$

com i diferente de j .

A homogeneidade $H(R_i)$ define a conformidade de todos os pixels da Região R_i para com o modelo de região [JAI 95, BRI 99].

Vários métodos podem ser utilizados para segmentar uma imagem por região. Alguns são apresentados nesta seção, como o de crescimento de região e o de divisão e fusão.

Crescimento de Região

O crescimento de região consiste em agrupar pixels ou sub-regiões em regiões maiores. Essa agregação inicia com um pixel (semente), e a partir dele, são anexados pixels vizinhos que possuem propriedades similares, como por exemplo, nível de cinza, cor e pixels pertencentes a um mesmo padrão de textura [BRI 99]. O processo se repete também para os pixels anexados. Quando um pixel não apresenta propriedades similares, define-se uma nova região [BRI 99, GON 92].

É possível fazer o crescimento de regiões por varredura ou por busca em todas as direções. Cada pixel é comparado com seus vizinhos anteriores (já rotulados) e adicionado (ou não) à região de um dos vizinhos.

Partição de Região

Essa técnica consiste na partição da imagem em N blocos ($N = 2^i$), levando em consideração propriedades, como por exemplo, nível de cinza, cor e padrão de textura.

Para o início da partição normalmente utilizam-se dois pixels, que resultam em duas regiões R_1 e R_2 . Para continuar o processo de partição é verificado a propriedade de homogeneidade. Caso o pixel não pertença a uma região já particionada, o processo de partição é novamente realizado [GON 92, JAI 95, BRI 99].

A técnica de quadtree é bastante utilizada na representação da estrutura de particionamento de uma região. A figura 2.17 mostra a técnica de quadtree.

Figura 2.17: Processo de crescimento de região

A imagem original R constitui a raiz da árvore. Após verificar a homogeneidade de R , realiza-se a partição da imagem em quatro regiões (R_1, R_2, R_3 e R_4). Tais regiões constituem o primeiro nível da árvore. Em seguida são verificadas as homogeneidades de cada uma das regiões menores. Na figura 2.17, R_1, R_2 e R_3 contêm a homogeneidade desejada, enquanto que R_4 precisa ser novamente dividida em quatro regiões, gerando mais um nível na árvore [GON 92, JAI 95].

Divisão e fusão de regiões

Este método complementa o anterior, realizando a fusão de regiões adjacentes que apresentam características similares (podem constituir uma única região homogênea). Novamente a estrutura quadtree pode ser utilizada para representar o processo de segmentação [GON 92].

A figura 2.18(a), representa a imagem a ser dividida; na figura 2.18 (b), várias regiões podem ser fundidas; a figura 2.18(c), mostra o resultado dessas operações de difusão e fusão; a figura 2.18(d), mostra o resultado segmentado final, onde todas as regiões satisfazem a homogeneidade desejada, a partir da última operação de divisão e fusão.

Figura 2.18: Processo de divisão e fusão de uma imagem

2.3.4 Segmentação por Cor

A capacidade da percepção de cores possibilita ao ser humano um melhor entendimento do mundo que o cerca, proporcionando maior capacidade de autoproteção, localização e compreensão do ambiente [LEV 85].

A percepção de várias faixas do espectro de luz no sistema visual humano é baseada em sensores que apresentam diferentes respostas ao estímulo luminoso. Na retina do olho humano existem três tipos de sensores (cones), que respondem de maneira distinta ao estímulo luminoso (maior resposta nas cores azul, vermelho ou verde). A interação entre as respostas destes sensores dá origem à sensação de cor [LEV 85, JOR 01].

A luminosidade é uma propriedade particular de um objeto associada à quantidade de luz refletida por ele. O brilho é uma propriedade que depende da iluminação sobre o objeto [JOR 01, LEV 85, JAI 95]. Se o objeto reflete mais luz, ele pode parecer mais claro, ou se absorve quase toda luz, pode parecer mais escuro. Em certas condições, a luminosidade (preto ou branco) e o brilho (escuro ou claro) são difíceis de serem distinguidos visualmente.

A visão de cores do ser humano permite uma grande capacidade de percepção e discriminação de objetos. A percepção e a separação dessas cores requerem um estágio de aprendizagem. O convívio social do ser humano influi na formação de vários conceitos e, um deles, é a interpretação das cores [LEV 85]. A percepção da cor resulta da combinação de alguns fatores: as características físicas do próprio objeto, a parte do espectro luminoso refletida ou absorvida, as propriedades espectrais da fonte de luz que ilumina o objeto, as propriedades do sistema visual e a experiência prévia com o objeto e a sensação de cor [JOR 01].

A tonalidade de uma cor pode ser alterada com a mistura da cor branca, alterando a propriedade de saturação. Quanto menos branco mais saturada é a cor. Essa percepção de

saturação corresponde ao conceito de pureza de uma cor [JAI 95, JOR 01].

Conforme mencionado anteriormente, a cor é um atributo bastante importante e discriminatório na identificação e extração de características no processo de análise de imagens. Porém, como todas as técnicas anteriormente apresentadas, também há particularidades que não se ajustam a todos os tipos de aplicação.

Para a representação de cor, há modelos que fornecem padrões de cores permitindo sua quantificação, independentemente das condições psicofísicas dos observadores. Os dois principais modelos são [JAI 95, JOR 01, LEV 85, MEN 00] :

- RGB - define um espaço tridimensional onde cada cor é obtida a partir das cores primárias: vermelho - **R**ed, verde - **G**reen e azul - **B**lue;
- HSI - define as cores a partir de três propriedades: **H**, é o matiz, descreve a cor pura; **S**, é a saturação da cor, o grau de pureza da cor; **I** representa a intensidade de luz (brilho) da cor. O sistema HSI mostra-se mais eficaz que o sistema RGB na interação com operadores humanos.

A figura 2.19 representa o cubo de cores do modelo RGB.

Figura 2.19: Cubo de cores do modelo RGB

Como os equipamentos utilizados para a visualização de imagens, (monitores de vídeo), operam no sistema RGB, a implementação de equipamentos que operam utilizando o sistema HSI exige a realização de operações de conversão entre os sistemas [JAI 95, LEV 85, GON 92]. Em seguida são apresentadas as fórmulas de conversão entre os sistemas RGB e HSI:

$$H = \cos H = \frac{2R - G - B}{2\sqrt{(R - G)^2 + (R - B)(G - B)}} \quad (2.10)$$

$$S = 1 - \frac{3}{R + G + B} \min(R, G, B) \quad (2.11)$$

$$I = \frac{1}{3}(R + G + B) \quad (2.12)$$

O uso de histogramas no processo de segmentação pode ser feito nas diversas aplicações que utilizam imagens coloridas [HAF 95, HEA 92]. Para cada componente (R, G e B) é construído um histograma.

Com base em alguns artigos e trabalhos anteriores, este trabalho utilizou das informações de cor e forma para a extração das informações da imagem envolvida no processo de reconhecimento da planta invasora [SHE 90, GUY 93, MAR 98, EF 00a, EF 00b, PER 00].

Durante o estudo, observou-se que a cor das folhas, assim como a cor da flor das plantas invasoras em estudo, são importantes para o seu reconhecimento. Este porém, não representa o único meio discriminante, sendo normalmente necessários outros meios, como por exemplo, a forma da folha.

Na próxima seção são apresentadas algumas técnicas de reconhecimento de padrões, dentre elas, a técnica utilizada neste trabalho.

2.4 Técnicas de Reconhecimento de Padrões

O reconhecimento de padrões é uma área de pesquisa que tem por objetivo a classificação de objetos (padrões) em um número de categorias ou classes. Embora tenham ocorrido grandes avanços nos últimos anos, o problema de reconhecimento de padrões complexos continua sem uma solução definitiva [JAI 95, CAM 00].

Diversos trabalhos e estudos em diferentes áreas estão utilizando as técnicas de reconhecimento de padrões para resolver diversos problemas. Entre elas figuram:

- Bio-informática, análise de seqüências de proteínas ou DNA;
- Mineração de dados (*data mining*), procura por padrões significativos em espaços multidimensionais;
- Classificação de documentos de Internet;
- Análise de imagens de documentos para reconhecimento de caracteres (*Optical Character Recognition - OCR*);

- Inspeção visual para automação industrial;
- Busca e classificação em bases de dados multimídia;
- Reconhecimento biométrico, incluindo face, íris ou impressão digital;
- Sensoriamento remoto por imagens multiespectrais;
- Reconhecimento de fala.

Em todas essas aplicações, as características disponíveis nos padrões de entrada normalmente não são diretamente utilizadas, sendo necessário um pré-processamento para a sua extração [CAM 00].

Existem muitos descritores e classificadores de características de imagens. Entre os principais pode-se citar:

- Descritores simples (área, perímetro);
- Descritores de Fourier;
- Descritores baseados em contorno;
- Descritores baseados em momentos;
- Esqueletização;
- Descritores baseados na vizinhança;
- Classificação por *template matching*;
- Classificação por lógica nebulosa(fuzzy);
- Classificação por redes neurais;
- Classificação sintática;
- Análise de Componentes Principais (PCA)

Algumas dessas técnicas são descritas nos itens seguintes.

2.4.1 Descritores Simples

Descritores ou extratores de características, como são conhecidos, tem por finalidade a extração das características principais da imagem, os quais são de suma importância para o reconhecimento de padrões [GON 92, SCH 89, FRA 91].

Os descritores simples podem ser definidos como aqueles que extraem algumas características triviais do padrão, como por exemplo, o cálculo da área e perímetro. Por exemplo, segundo Jain [JAI 89], a área pode ser calculada por:

$$\text{Área} = \sum_x^{n-1} \sum_y^{n-1} x.y f(x, y) \quad (2.13)$$

onde, x_i e y_i correspondem aos pixels da imagem.

Existem várias formas para se calcular o perímetro. Uma das formas mais simples, consiste em um algoritmo que percorre os pixels da borda, calculando a distância entre esses pixels de borda, somando e totalizando ao fechamento do contorno. O perímetro pode ser determinado por [RUS 95]:

$$\text{Perímetro} = \sum_i \sqrt{(x_i - x_{i-1})^2 + (y_i - y_{i-1})^2} \quad (2.14)$$

onde, x_i e y_i correspondem aos pixels da borda da imagem.

2.4.2 Descritores de Fourier

Os descritores de Fourier podem ser utilizados para capturar a aspecto geral de uma fronteira. Seus coeficientes carregam informações sobre forma e podem ser usados para diferenciar formatos distintos de fronteiras [GON 92, SON 99].

A definição das bordas pode não ser completa. Bordas descritas por apenas alguns pixels ainda podem ser detectadas pelos descritores de Fourier. As coordenadas são representadas por $x(k) = x_k$ e $y(k) = y_k$, sendo o eixo x real e o eixo y, imaginário. As coordenadas tomam a forma de um número complexo $s(k) = x(k) + jy(k)$, para $k=0,1,2,\dots,N-1$, denominadas representação no domínio espacial [GON 92].

A transformada discreta de Fourier é definida por:

$$a(u) = \frac{1}{N} \sum_{k=0}^{N-1} s(k) \exp[-j2\pi uk/N] \quad (2.15)$$

Onde N é o número total de pixels da imagem, $a(u)$ são os coeficientes complexos, denominados descritores de Fourier e u o índice dos coeficientes.

A inversa da transformada também pode ser definida:

$$s(k) = \sum_{u=0}^{N-1} a(u) \exp[j2\pi uk/N] \quad (2.16)$$

Supondo que somente os M primeiros coeficientes sejam utilizados, a equação aproximada de $s(k)$ é definida por $\hat{S}$ [GON 92]:

$$\hat{S}(K) = \sum_{u=0}^{M-1} a(u) \exp[j2\pi uk/N] \quad (2.17)$$

De uma maneira geral, os descritores de Fourier são invariantes quanto à translação ou rotação, apresentando algumas propriedades básicas como [GON 92, SON 99]:

Identidade

$$a(u) \quad (2.18)$$

Rotação

$$a_r(u) = a(u) e^{j\theta} \quad (2.19)$$

Translação

$$a_t(u) = a(u) + \Delta_{xy} \delta(u) \quad (2.20)$$

Essas propriedades básicas podem ser importantes na identificação de folhas de plantas. As folhas podem se apresentar em posições variadas, sendo normalmente necessárias operações de rotação e translação para a obtenção de fatores discriminantes mais adequados. Com os M primeiros coeficientes, já é possível definir uma aproximação da forma a ser identificada, mesmo que se perca detalhes. Para cada aplicação, esses descritores podem ser utilizados de forma diferente e com diferentes resultados. A figura 2.20 mostra exemplos de reconstrução com descritores de Fourier para vários valores de M [GON 92].

Figura 2.20: Exemplos de reconstrução com descritores de Fourier

2.4.3 Descritores Baseados em Momentos

O momento de uma região interpreta uma imagem (uma função normalizada de tons de cinza) como uma densidade de probabilidade de uma função aleatória bidimensional. Assim, propriedades desta variável podem ser descritas por métodos estatísticos [SON 99, JAH 97, BAN 90].

Assumindo que os valores dos pixels da imagem são sempre diferentes de zero, os momentos podem ser usados para a descrição de imagens.

Um momento de ordem $p + q$ dependente de escala, translação, rotação e transformações regulares, é dado por:

$$m_{pq} = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} x^p y^q f(x, y) dx dy \quad (2.21)$$

No caso discreto (processamento de imagens digitais) define-se m_{pq} como:

$$m_{pq} = \sum_{i=-\infty}^{\infty} \sum_{j=-\infty}^{\infty} i^p j^q f(i, j) \quad (2.22)$$

Onde x, y, i, j são as coordenadas dos pixels na imagem.

Invariância à translação pode ser obtida se forem usados os momentos centrais. No caso discreto tem-se:

$$\mu_{pq} = \sum_{i=-\infty}^{\infty} \sum_{j=-\infty}^{\infty} (i - x_c)^p (j - y_c)^q f(i, j) \quad (2.23)$$

onde x_c e y_c são as coordenadas do centro de gravidade da região (centróide) e podem ser calculadas por:

$$x_c = \frac{m_{10}}{m_{00}} \quad (2.24)$$

$$y_c = \frac{m_{01}}{m_{00}} \quad (2.25)$$

Onde m_{00} corresponde a área da região e m_{10} o coeficiente do momento sobre a linha e m_{01} o coeficiente do momento sobre a coluna.

Segundo Sonka [SON 99], há possibilidade de se obter atributos invariantes quanto a escala. Muitos aspectos das propriedades do momento variam normalmente quanto a rotação e translação. Ainda, segundo o mesmo autor, menores probabilidades de erro de classificação foram obtidas utilizando seqüências de contornos do que usando momentos baseados em áreas.

A figura 2.21(a) mostra o segmento de uma fronteira, e a figura 2.21(b), mostra o segmento representado pela função de momentos [GON 92].

Figura 2.21: Representação do segmento de uma fronteira por momentos

2.4.4 Descritores Baseados em Contorno

Descritores de contorno baseiam-se nas medidas das formas dos objetos [SCH 89]. A representação das formas pode ser feita pela extração das informações das fronteiras dos objetos [SCH 89, GON 92].

O comprimento de um contorno, por exemplo, é um bom descritor do objeto, sendo definido por uma contagem simples dos pixels do contorno. Além do comprimento, mostra-se bastante eficiente o cálculo da curvatura ao longo do contorno [SCH 89]. Essa representação considera o tamanho e o ângulo da curva.

A figura 2.22 mostra a representação dos parâmetros do contorno de uma certa região.

Figura 2.22: Extração do contorno de uma região para parametrização

A curvatura k de uma curva, em um pixel P , é determinada pela taxa de mudança do ângulo formado pelo conjunto de coordenadas ao longo da curva:

$$k(s) = d\phi(s)/ds \quad (2.26)$$

onde, ds pode ser aproximado por:

$$ds = \sqrt{dx^2 + dy^2} \quad (2.27)$$

Para que a escala seja invariante em determinadas rotações e translações, é importante realizar a normalização dos parâmetros da curva.

O valor k pode ser obtido dos valores $x(s)$ e $y(s)$, utilizando as derivadas:

$$y' = dy/dx \quad (2.28)$$

$$y'' = d^2y/dx^2 \quad (2.29)$$

O valor de k é obtido por:

$$k(s) = y''/(1 + y')^2)^{\frac{3}{2}} \quad (2.30)$$

Técnicas de extração de características baseadas em contornos podem utilizar dados obtidos na segmentação por contorno, como conceituado anteriormente.

2.4.5 Esqueletização

O objetivo da esqueletização é reduzir a representação da imagem, ou parte dela, em uma cadeia simples com largura de um pixel, preservando todas as demais características relevantes [FRI 98, GON 92].

Uma análise da forma do esqueleto pode produzir algumas informações úteis para o reconhecimento de padrões. Deve haver um bom entendimento do processo de esqueletização, para que, durante sua utilização, as informações importantes não sejam removidas desnecessariamente [FRI 98].

Um método para fazer a esqueletização consiste na eliminação dos pixels nos contornos ou fronteiras até permanecer somente o esqueleto do objeto [GON 92, GON 00, FRI 98]. Para a realização do método de esqueletização é necessário conhecer a vizinhança dos pixels e a conectividade entre eles.

Existem vários algoritmos para o afinamento de regiões binárias, como por exemplo, o algoritmo Zhang Suen. Este algoritmo assume que tais regiões possuem pixels de valor 1, enquanto que os do fundo, possuem valor 0 [GON 92]. O método consiste na aplicação sucessiva de um algoritmo com dois passos nos pixels do contorno da região. Um pixel de contorno é definido como um pixel de valor 1 que possui pelo menos um vizinho (de vizinhança 8) com valor 0 [LIM 01, GON 92].

O passo 1 determina que um pixel de contorno p deve ser eliminado se as seguintes condições forem satisfeitas:

$$a) 1 \leq N(p_1) \leq 6;$$

onde, $N(p_1)$ é o número de vizinhos diferentes de zero sendo $N(p_1) = p_2 + p_3 + \dots, p_9$.

$$b) S(p_1) = 1;$$

onde, $S(p_1)$ é o número de transições de 0 até 1 da seqüência ordenada, $p_2, p_3, p_4, \dots, p_9$.

$$c) p_2 \cdot p_4 \cdot p_6 = 0;$$

$$d) p_4 \cdot p_6 \cdot p_8 = 0;$$

p_9	p_2	p_3
p_8	p_1	p_4
p_7	p_6	p_5

No passo 2, as condições (a) e (b) são as mesmas. Porém, as condições C e D mudam para:

$$c') p_2 \cdot p_4 \cdot p_8 = 0;$$

$$d')p_2 \cdot p_6 \cdot p_8 = 0;$$

O passo 1 é aplicado a todos os pixels que ficam na fronteira da região em consideração. Se alguma das considerações não for cumprida, o valor do pixel não é alterado. Se todas condições forem satisfeitas, o pixel marcado é eliminado. A estrutura de vizinhança utilizada pelo algoritmo de afinamento, é apresentada abaixo [GON 92, LIM 01].

0	0	1
1	p_1	0
1	0	1

É importante observar que um pixel não é apagado até que todos os outros pixels da fronteira tenham sido processados. Isto evita que a estrutura dos dados seja alterada durante a execução do algoritmo [GON 92, LIM 01]. Após a realização do passo 1, todos os pixels que foram marcados são apagados e é aplicado o passo 2. Este procedimento é aplicado iterativamente até que não haja mais pixels para serem apagados. O resultado é o esqueleto da região. A figura 2.23 apresenta o processo de esqueletização de uma imagem. A figura 2.23(a) mostra a imagem original e a figura 2.23(b), o resultado obtido pelo processo.

Figura 2.23: Esqueletização de uma imagem

Vários métodos e técnicas podem ser aplicados para classificar as características obtidas pelos descritores. A seguir são apresentadas algumas técnicas de classificação como *template matching* (casamento), lógica nebulosa (fuzzy) e classificação por redes neurais.

2.4.6 Classificação por *Template Matching* - Casamento

Trata-se da abordagem mais antiga e mais simples. De uma maneira geral, dispõe-se de um modelo (*template*) que é o protótipo do objeto a ser reconhecido [CAM 00]. No caso de imagens, o modelo é representado em 2D. Para a classificação, é realizado o casamento direto do modelo com os segmentos da imagem. O sucesso da operação depende da robustez da biblioteca de padrões, ou seja, quanto mais modelos houver do padrão a ser reconhecido, com poucas variações de posição e tamanho, maior será a taxa de acerto [CAM 00].

No caso de modelos rígidos, podem ocorrer falhas no reconhecimento de padrões distorcidos. Os modelos deformáveis podem transladar e rotacionar para melhor enquadramento na representação procurada [BAN 97].

O algoritmo de *template matching* é utilizado freqüentemente em aplicações de sensoriamento remoto quando a imagem de uma determinada cena é capturada em tempos diferentes ou por sensores diferentes [BAN 97].

Os modelos são utilizados em toda a imagem verificando-se a similaridade entre os valores dos pixels do modelo com os pixels dos segmentos da imagem. A maior desvantagem de se utilizar esse tipo de casamento está no seu custo operacional

Os casamentos por correlação de uma subimagem $w(x,y)$ de tamanho $j \times k$ dentro de uma imagem $f(x,y)$ de tamanho $M \times N$, é definido por $j \leq M$ e $k \leq N$:

$$c(s, t) = \sum_x \sum_y f(x, y) w(x - s, y - t) \quad (2.31)$$

onde s varia de 0,1,2... M e t de 0,1,2,... $N-1$; a soma é realizada sobre a região da imagem em que f e w se sobrepõem.

2.4.7 Lógica Nebulosa - Fuzzy

A lógica nebulosa foi criada com inspiração no comportamento humano, que se baseia na interpretação do mundo sem precisão e na descrição por atributos lingüísticos [CAM 00].

A partir de conjuntos de dados não nebulosos, a criação de seus respectivos conjuntos nebulosos (fuzzificação) é feita através da determinação do grau de pertinência de cada um dos elementos aos conjuntos [CAM 00].

A classificação com lógica nebulosa, normalmente é feita através de regras nebulosas e métodos de defuzzificação ⁵ . As regras nebulosas normalmente utilizam delimitadores de

valores de pertinência de cada padrão aos conjuntos.

A lógica fuzzy pode ser vista como uma generalização da lógica booleana convencional. A grande diferença entre as duas está no fato da lógica fuzzy permitir um certo grau de incerteza, isto é, ela aceita a noção de parcialmente verdade ou parcialmente falso [GAM 00]. A lógica tradicional trabalha com os dois extremos 1 e 0, ou o elemento está no conjunto ou não está. Esta definição faz os conjuntos fuzzy contínuos enquanto os conjuntos da lógica tradicional são discretos. Os valores intermediários no intervalo $[0,1]$ são os graus de pertinência dos elementos ao conjunto. O mapeamento destes valores é freqüentemente descrito como uma função de associação [GAM 00, SCI 97].

A possibilidade de existir valores intermediários representa um certo grau de incerteza, tornando a teoria fuzzy mais apropriada para aplicações mais complexas.

A lógica fuzzy pode utilizar variáveis lingüísticas, ao invés de variáveis numéricas, que admitem expressões como *alto*, *muito alto*, *pouco gordo*, *mais ou menos gordo*, *largo*, *mais largo* [GAM 00, SCI 97, GON 92]. Por exemplo, tem-se um conjunto de pessoas definidas como o conjunto universo. Define-se um subconjunto das pessoas altas como ALTO. ALTO é uma variável lingüística que descreve a altura da pessoa.

É necessário associar um grau de pertinência para cada pessoa do conjunto. Um exemplo pode ser visto na tabela 2.1:

Tabela 2.1: Atribuição do grau de pertinência

Pessoa	Altura	Grau
Mônica	1.4	0.0
Eduardo	1.7	0.4
Carlos	1.9	0.8
João	2.1	1.0

Para estabelecer o grau de pertinência é utilizada uma função de associação baseada

⁵Defuzzificação consiste na utilização dos resultados das regras para criação de conjuntos que têm informações sobre a classificação dos elementos [CAM 00].

na altura da pessoa:

$$ALTO(x) = \begin{cases} 0 & \text{se } altura(x) < 1.5m; \\ 2.altura(x) - 1.5m/0.5m & \text{se } 1.5m < altura(x) < 2.0m; \\ 1 & \text{se } altura(x) > 2.0m. \end{cases} \quad (2.32)$$

Essa função pode ser vista na figura 2.24.

As funções de associação nem sempre têm a mesma forma descrita acima e geralmente utilizam outras notações.

Figura 2.24: Gráfico da função de associação pela lógica fuzzy

2.4.8 Classificação por Redes Neurais

Uma rede neural artificial consiste em um modelo de grafo orientado disposto em uma rede onde os nós representam neurônios artificiais e as arestas orientadas são as conexões entre as entradas e saídas dos neurônios [CAM 00, BAR 97].

Essas redes podem ser vistas como máquinas maciçamente paralelas, com muitos processadores simples e muitas interconexões. Elas são hábeis em aprender relações entre entradas e saídas complexas e não lineares. Dentre suas características, inclui-se a possibilidade de utilizar procedimentos sequenciais de treinamento e o poder de adaptação aos dados.

Existem várias famílias de redes neurais como: a *feed-forward network*, que inclui as redes perceptron multicamadas (*Multilayer Perceptron* - *MLP*); redes de funções de bases radiais (*radial-basis function* - *RBF*); *backpropagation*, que se baseia realimentação do erro para os níveis anteriores da rede [CAM 00, MIC 01, BAR 97].

Essas redes são organizadas em camadas possuindo conexões unidirecionais entre uma camada e outra. Outra classe popular de redes é a dos mapas auto-organizáveis (*self-*

organizing maps - SOM), e redes de *Kohonen*, as quais são utilizadas principalmente para agrupamento de dados (*clustering*) e no mapeamento de características [CAM 00].

A figura 2.25 representa o modelo de uma rede neural artificial.

Figura 2.25: Rede neural artificial

O processo de aprendizado envolve a atualização da arquitetura da rede e dos pesos das conexões, de forma que a rede possa efetuar tarefas específicas de classificação e análise de agrupamentos.

O grande crescimento no uso de redes neurais se deve ao fato das redes poderem ser aplicadas em vários problemas, o que não ocorre com as abordagens baseadas em modelos ou em regras. Outro fator importante é a existência de muitos algoritmos eficientes de aprendizado para redes neurais. Os sistemas de computação baseados em redes neurais têm a capacidade de receber ao mesmo tempo várias entradas e distribuí-las de maneira organizada [CAM 00, JUN 01, MIC 01]. Outra vantagem é que em um sistema de rede neural, a informação possui representação redundante, porém, ela se encontra distribuída por todos os elementos da rede. Isso significa que, mesmo que parte da rede seja destruída, normalmente a informação contida nessa parte ainda poderá estar presente na rede e poderá ser recuperada [JUN 01, MIC 01]. Uma rede neural, diferente de outros sistemas, é um sistema inerentemente tolerante à falhas. A falha de um dos neurônios não causa efeito significativo no desempenho da rede.

Os atributos de uma rede neural, tais como aprender através de exemplos, generalizações redundantes e tolerância à falhas, proporcionam fortes incentivos para a escolha de redes neurais como técnica para modelagem de sistemas de diversas áreas [JUN 01, MIC 01].

Algoritmos de extração de características podem ser mapeados em arquiteturas de redes neurais para implementação eficiente em hardware [CAM 00].

Apesar de possuírem aparentemente princípios diferentes, a maioria dos modelos de redes neurais populares é implicitamente equivalente ou similar aos métodos clássicos de reconhecimento estatístico de padrões. Oferecem porém, várias vantagens como abordagens para extração, classificação e procedimentos flexíveis para encontrar boas soluções não lineares.

Modelos de Redes Neurais

As redes neurais podem ser classificadas segundo diversos modelos, de acordo com suas características e propriedades. Os mais utilizados são os aprendizados supervisionados e não supervisionados [MED 99].

No aprendizado supervisionado são apresentados sucessivamente à rede conjuntos de padrões de entrada e seus correspondentes padrões de saída. Durante este processo, a rede realiza um ajustamento dos pesos das conexões entre os elementos de processamento. Esse ajustamento baseia-se em uma determinada lei de aprendizagem, até que o erro entre os padrões de saída gerados pela rede alcancem um valor mínimo desejado [MED 99, BER 99]. Existem vários tipos de redes de aprendizado supervisionado, como por exemplo, *a adaline e madaline, perceptron e backpropagation*.

Um outro método semelhante ao de aprendizado supervisionado é o de reforço. Consiste em fornecer somente um valor que diz se a saída está correta ou não, ao invés de fornecer saídas corretas à rede em cada etapa de treinamento [MED 99, BAR 97].

No aprendizado não-supervisionado a rede analisa os conjuntos de dados apresentados a ela e determina algumas propriedades dos conjuntos de dados, refletindo essas propriedades na sua saída [MED 99, BER 99, BAR 97, BEC 96].

As propriedades que a rede vai aprender sobre os dados podem variar em função do tipo de arquitetura utilizada e do tipo de aprendizagem. Como exemplo de aprendizado não supervisionado, tem-se como os mais conhecidos, o Mapa Auto-Organizável de Kohonen, Redes de Hopfield, Memória Associativa Bidirecional, *Binary Adaptive Resonance Theory* (ART1), *Analog Adaptive Resonance Theory* (ART2).

2.4.9 Análise de Componentes Principais (PCA)

Análise de Componentes Principais, também conhecida como Transformada de *Karhunen-Loève* é um dos métodos estatísticos multivariados mais simples, sendo constituído de p variáveis $x_1, x_2, \dots, x_p$ nas quais se deseja encontrar combinações lineares para produzir índices $z_1, z_2, \dots, z_n$ tal que sejam não correlacionados [MOR 67, HER 96].

Essa falta de correlação significa que os índices estão medindo diferentes dimensões dos dados. Estes índices são ordenados de forma que z_1 representa a maior quantidade de variação, z_2 a segunda maior quantidade e assim sucessivamente;

Tem-se $\text{var}(z_1) \geq \text{var}(z_2) \geq \dots \geq \text{var}(z_p)$, onde $\text{var}(z_i)$ corresponde a variância de z_i no conjunto de dados em questão; esses índices z_i são chamados de componentes principais.

Em uma análise de componentes principais, espera-se que as variâncias da maioria dos índices sejam muito pequenas de forma que possam ser desprezadas. Assim, podendo descrever a variação do conjunto de dados com as poucas variáveis consideradas não desprezíveis.

A PCA nem sempre reduz um grande número de variáveis originais a um pequeno número de variáveis transformadas. Caso as variáveis originais sejam não correlacionadas, a análise não produzirá efeito algum [OLI 97].

Alguns métodos seguem o princípio de análise de componentes principais, como por exemplo, o método de Hotteling.

Procedimento de uma Análise de Componentes Principais

Para utilizar os resultados de uma análise de componentes principais, não é necessário entender as derivações das equações, mas a natureza dessas equações, ou seja, uma PCA resume-se em encontrar os autovalores da matriz de covariância dos dados [MOR 67, OLI 97].

Uma matriz de covariância simétrica é representada como:

$$C = \begin{bmatrix} c_{11} & c_{12} & \dots & c_{1p} \\ c_{21} & c_{22} & \dots & c_{2p} \\ \dots & \dots & \dots & \dots \\ c_{p1} & c_{p2} & \dots & c_{pp} \end{bmatrix}$$

Onde o elemento da diagonal principal c_{ii} é a variância de x_i e $c_{ij} (i \neq j)$ é a covariância das variáveis x_i e x_j .

Para se calcular a matriz de covariância, é necessário que primeiramente se realize a padronização das variáveis $x_1, x_2, \dots, x_p$, ou seja, calcular o vetor médio do conjunto de vetores. Essa média corresponde a soma dos x_i dividido pelo número total de vetores existentes.

O problema que se encontra em álgebra linear [GRA 83], corresponde na resolução da equação:

$$Ca = \lambda a \quad (2.33)$$

Onde $a \neq 0$ para valores de λ , ou seja, os chamados autovalores da matriz de covariância C . Os valores de a associados aos autovalores são chamados de autovetores. A matriz de covariância é caracterizada por autovalores reais não negativos.

Se os autovalores são distintos, os autovetores associados são únicos. Assim a matriz de covariância pode ser descrita:

$$Ca = \lambda_j a_j \quad (2.34)$$

Onde, $\lambda_1, \lambda_2, \dots, \lambda_p$ correspondem ao autovalores da matriz de covariância C , $a_1, a_2, \dots, a_p$ os autovetores associados e j o índice que varia de 1,2,...,p.

Supondo que os autovalores correspondentes sejam arranjados em ordem decrescente, $\lambda_1 \geq \lambda_2 \dots \geq \lambda_p$ de modo que $\lambda_1 = \lambda_{max}$ e que os autovetores associados sejam usados para construir uma matriz de dimensão (p x p): $A = [a_1, a_2, \dots, a_p]$.

Pode-se combinar o conjunto das p equações em uma única equação:

$$CA = A\Lambda \quad (2.35)$$

Onde Λ corresponde a uma matriz diagonal definida pelos autovalores da matriz C :

$$\Lambda = diag[\lambda_1, \lambda_2, \dots, \lambda_p] \quad (2.36)$$

A matriz A obtida pela técnica de PCA, corresponde a uma matriz ortogonal, no sentido em que suas colunas, ou seja, os autovetores de C , satisfazem as condições:

$$a_i^T a_j = \begin{cases} 1 & \text{se } i = j \\ 0 & \text{se } i \neq j \end{cases} \quad (2.37)$$

Essas condições significam que as colunas da matriz A representam vetores linearmente independentes; assim:

$$A^T A = I \quad (2.38)$$

Onde I é a matriz identidade. A partir disso, geralmente deduz-se que a inversa da matriz A é igual a sua transposta; assim:

$$A^T = A^{-1} \quad (2.39)$$

Desta forma, tem-se uma nova equação:

$$A^T C A = \Lambda \quad (2.40)$$

Obtendo a matriz de covariância $n \times n$, a partir de um vetor n -dimensional. Também se diz que, os autovalores somados, correspondem à soma dos elementos da diagonal principal de C . Desta forma, pode-se reduzir normalmente o número de características necessárias para representação efetiva dos dados descartando-se as combinações lineares que apresentam baixa variância e restando-se as demais.

A análise de componentes principais segue as seguintes etapas:

1. Padronizar os dados correspondentes às variáveis x_i , ou seja, calcular a média dos elementos dos vetores n -dimensionais;
2. Calcular a matriz de covariância C .
3. Encontrar os autovalores $\lambda_1, \lambda_2, \dots, \lambda_p$ da matriz C e seus correspondentes autovetores $a_1, a_2, \dots, a_p$. Os coeficientes da i -ésima componente principal são dados por a_i , enquanto λ_i é sua variância.
4. Descartar as componentes que acumulem pequena proporção da variação dos dados, por exemplo, entre 10 variáveis, se as 3 primeiras forem responsáveis por 90 % da variância, então as 7 demais serão descartadas.

Transformada de Hotteling

A transformada de Hotteling utiliza todos os procedimentos da análise de componentes principais. Essa análise pode ser aplicada para casos particulares, como por exemplo, para a extração de dados da forma e cor em uma imagem. Neste trabalho, a transformada de Hotteling é utilizada para extração dos dados de cor (RGB), permanecendo informações geométricas, ou seja, forma [HOT 33, JOR 01].

A partir dos conceitos apresentados anteriormente, a transformada de Hotteling pode ser descrita:

$$y = A(x - m_x) \quad (2.41)$$

Onde A é a matriz de autovetores, x as variáveis dos vetores n -dimensionais, m_x a média dos vetores envolvidos.

A transformada de Hotteling, seguindo os conceitos da análise de componentes principais e aplicada à extração dos dados RGB, pode ser descrita [JOR 01]:

$$\begin{bmatrix} H \\ O \\ T \end{bmatrix} = \begin{bmatrix} E_{11} & E_{12} & E_{13} \\ E_{21} & E_{22} & E_{23} \\ E_{31} & E_{32} & E_{33} \end{bmatrix} \cdot \begin{bmatrix} R - m_R \\ G - m_G \\ B - m_B \end{bmatrix} \quad (2.42)$$

Onde $[E_{11}, E_{12}, E_{13}]$, $[E_{21}, E_{22}, E_{23}]$ e $[E_{31}, E_{32}, E_{33}]$ são os autovetores da matriz de covariância.

Esta técnica, foi utilizada neste trabalho com finalidade de extrair informações da imagem, de forma a minimizar a quantidade de informações para classificação em rede neural [TIP 99].

A aplicação da transformada de Hotteling, bem como a forma de implementação, é detalhada no capítulo 5 deste trabalho.

2.5 Sumário

Neste capítulo foram apresentados alguns conceitos de processamento digital de imagens, incluindo: filtros de suavização de imagens, tais como filtro passa-baixas, mediana; técnicas de segmentação utilizando operadores para detecção de bordas, como Sobel e Laplace, além da formação de contornos, limiarização, por região e cor; técnicas de reconhecimento de padrões, apresentando alguns descritores (simples, Fourier, momentos, contornos e esqueletos); análise de componentes principais (PCA), técnica de Hotteling; técnicas de classificação, empregando casamento (*matching*), lógica nebulosa (fuzzy) e redes neurais.

Destas técnicas, foram analisadas as mais utilizadas e as que melhor se adequam para a resolução do problema de identificação de plantas invasoras. Deve-se observar que foram encontrados poucos artigos técnicos sobre o tema central do trabalho, considerando-se principalmente, os tipos de plantas invasoras típicas da região sob estudo.

O capítulo 4 apresenta a situação do problema, conceituando o problema das plantas invasoras, bem como sua importância econômica na região do cerrado brasileiro.

Capítulo 3

Situação do Problema

As plantas invasoras, daninhas ou mato como são conhecidas, podem prejudicar o desenvolvimento das culturas caso sua presença não seja controlada.

A identificação e a classificação das plantas invasoras apresentam grande complexidade, existindo diversas espécies de plantas em um pequeno espaço territorial, muitas vezes agrupadas umas sobre as outras. A identificação da presença das plantas invasoras mais resistentes têm uma grande importância, sendo determinante na dosagem adequada de herbicidas. Estudos de conhecimento multidisciplinar como agricultura e administração devem ser considerados.

3.1 Plantas Invasoras e sua Importância Econômica na Região do Cerrado Brasileiro

Como visto anteriormente, o controle de plantas invasoras evita a diminuição da produtividade associada ao aumento dos custos, causado pelo aumento da quantidade de herbicidas aplicada. Além da produtividade ser afetada, o meio ambiente também sofre consequências, acrescentando novos custos.

3.1.1 A Fazenda Campo Bom

Este trabalho tem a colaboração da Fazenda Campo Bom, situada na cidade de Chapadão do Sul em Mato Grosso do Sul. Esta cidade foi fundada em 1989, possuindo em média, 9.800 habitantes, 2,56 hab/ km^2 , em uma área total de 3.860 km^2 .

A fazenda Campo Bom, com razão social Reichert Agropecuária Ltda, controlada por Cia. Reny Participações, foi fundada em 1978 por um grupo de associados. Esta fazenda fica aproximadamente a 300 km de Campo Grande, 500 km de Goiânia e a 1000 km de São Paulo. Possui aproximadamente 120 funcionários. Apesar de apresentar poucos funcionários, ela conta com um conjunto de máquinas com tecnologia de última geração, o que facilita o manuseio do cultivo. A fazenda é composta pelas áreas administrativa, de cultivo, de pastagem, além de possuir uma usina de geração de energia e uma área reservada para moradia dos funcionários e associados. Possui uma área total de 45 mil hectares (ha), sendo 30 mil ha utilizados pela lavoura e 5 mil ha para a pastagem.

As culturas principais são a soja, o milho e o girassol, sendo a soja a cultura predominante e, o milho e o girassol, utilizados na rotação de cultura.

Além do cultivo de milho, soja e girassol, há também investimento na pecuária, com aproximadamente 3.500 cabeças de gado.

3.1.2 Fator Econômico

Estudos realizados na fazenda Campo Bom comprovam o custo relativamente alto associado com a aquisição e aplicação de herbicidas. O processamento de imagens para identificação de plantas invasoras, é considerado muito importante, pois um melhor planejamento pode ser realizado a partir da descrição e análise das imagens.

O reconhecimento prévio das plantas a serem controladas é condição básica para um resultado positivo na escolha eficiente do herbicida. As denominações folha larga e folha estreita diferenciam o tipo básico de herbicida utilizado.

O responsável em dosar os herbicidas a serem usados deve identificar em que classe as plantas se encontram, larga ou estreita, e a partir dessa análise, identificar as plantas mais resistentes.

A tabela 3.1 apresenta uma planilha de custos aproximados de herbicidas correspondente a lavoura de soja em uma área de aplicação de aproximadamente 20.000 ha. Nesta tabela são apresentados os herbicidas utilizados para o controle das plantas mais resistentes, pois sabe-se que as menos resistentes são combatidas com a dosagem especificada para as mais resistentes.

Tabela 3.1: Planilha de custo de herbicidas por área de aplicação

Dessecante	Dose/Ha.	Custo R\$	Época
Round-up WG	1.5 kg	230.000,00	set a dez
Folha Larga			
Classic	50 g	135.000,00	set a fev
Pivot	600 ml	115.000,00	set a fev
Cobra	400 ml	86.000,00	set a fev
Double	1200 ml	13.000,00	set a fev
Folha Estreita			
Podium S	800 ml	120.000,00	set a fev
Verdict	400 ml	40.000,00	set a fev

3.1.3 Resistência das Plantas Invasoras

A resistência é a habilidade da população de plantas invasoras resistir a doses significativamente maiores de herbicida do que a população pode normalmente suportar. Tolerância está relacionada com a dose do herbicida que a planta é capaz de suportar antes mesmo de haver seleção pelo uso contínuo de herbicidas [JOS 99].

Tem sido constatada uma maior resistência de certas plantas daninhas à herbicidas, tais como a *brachiaria plantaginea*, a *bidens pilosa* (picão preto) e a *euphorbia heterophylla* entre outras que são apresentadas como as principais plantas invasoras no apêndice A deste trabalho.

A maioria dos casos de seleção e de resistência das plantas pode ocorrer quando se utiliza sempre o mesmo herbicida ou quando se utiliza o herbicida da mesma forma. Errar na dose e na aplicação, em muitas vezes pode prejudicar a cultura em atividade [GAZ 01, JOS 99].

Outros fatores também estão relacionados com o desenvolvimento da resistência, tais como: pressão de seleção exercida pelo herbicida; esquema de rotação de herbicidas; ciclo da planta daninha; condições ambientais; práticas culturais como a monocultura; dinâmica de germinação de sementes; frequência inicial de indivíduos resistentes que ocorrem naturalmente na população de plantas daninhas e adaptação ecológica dos biótipos resistentes e suscetíveis [JOS 99].

Estes fatores determinam modelos que tentam prever quanto tempo leva para o desenvolvimento da resistência em uma população de plantas daninhas. Porém, devido ao grande número de fatores envolvidos e do conhecimento limitado em alguns aspectos, é praticamente impossível prever exatamente quando a resistência se desenvolverá [JOS 99].

3.1.4 Plantas Invasoras da região

Foram relacionadas várias espécies de plantas invasoras predominantes na região do cerrado.

A seguir são apresentadas as plantas invasoras e o grau de infestação correspondente.

NOME POPULAR	GRAU DE INFESTAÇÃO
Timbete/Carrapicho	Alta
Falsa Serralha	Média-alta
Cheirosa/Salva Limão	Alta
Capim Amargoso	Alta
Mentrasito/Picão Roxo	Alta
Picão Preto	Alta
Cordão de Frade	Baixa
Sorgo Selvagem	Alta
Custódio	Média-baixa
Guaxuma	Alta
Capim Favorito/Favorito	Alta
Joá de Capote	Alta
Capim Colônia	Alta
Fedegoso	Média-alta
Capim Marmelada	Alta
Capim Braquiária	Alta
Capim Pé-de-Galinha	Média-alta
Capim Colchão	Alta
Trapoeira	Alta
Carrapicho Carneiro	Média-alta

Carrapichinho	Média-alta
Caruru-Gigante/Caruru	Baixa
Crista de Galo	Média-alta
Corda de Viola	Alta
Tiririca	Baixa
Erva Quente	Alta
Leiteira	Alta
Beldroega	Baixa
Fedegoso Branco/Fedegoso	Média-alta
Guanxuma Branca/Guanxuma	Média-alta

3.2 Agricultura de Precisão no Controle de Plantas Invasoras

A busca por técnicas capazes de aumentar a produtividade é muito antiga e tem levado à mecanização e à agricultura em grande escala [SON 98, SCH 01].

Entretanto, a solução ainda utilizada é a de focar grandes áreas e entendê-las como homogêneas, levando ao conceito da necessidade média para a aplicação dos insumos - herbicidas, o que faz com que, a mesma formulação ou quantidade do herbicida seja utilizada em toda a área. Essa solução atende apenas as necessidades médias e não considera as carências específicas de cada parte da área de cultivo. O mesmo acontece para os demais insumos, resultando em uma lavoura com produtividade não uniforme.

A proposta da agricultura de precisão é focar a variabilidade espacial e temporal dos requisitos da área de plantio permitindo uma aplicação diferenciada. Porém, para que ela tenha sucesso é necessário a utilização de tecnologias avançadas (imageamento e posicionamento) e interpretação das informações obtidas [SCH 01].

O aumento da produtividade está relacionado com a tecnologia utilizada, porém, um melhor aproveitamento depende da quantidade de informação disponível para guiar e sincronizar a aplicação de cada um dos recursos existentes.

Destacam-se duas motivações principais que induzem à agricultura de precisão. Uma diz respeito à preservação do meio ambiente, com objetivos de reduzir cada vez mais as

quantidades aplicadas de herbicidas. A outra diz respeito ao aumento dos lucros obtidos com a diminuição de insumos e com um aumento na produtividade [SCH 01, SON 98].

A agricultura de precisão é, antes de mais nada, uma questão de gestão, ou seja, está apoiada no planejamento e no acompanhamento contínuo do processo produtivo, principalmente, na disponibilidade de informação para a tomada de decisão.

Ainda não há uma solução única que possa ser aplicada a todos os casos. Soluções particulares são necessárias para cada cultura e isto abre espaço para serviços de consultoria, que utilizam informações acumuladas sobre as condições locais para tomadas de decisões mais corretas [SCH 01].

O fator mais importante na decisão na adoção da agricultura de precisão, é o econômico, ou seja, analisar se a redução dos insumos, acompanhada do aumento de produtividade compensam os investimentos tecnológicos que acompanham sua implantação.

Estudos que demonstram a viabilidade destas técnicas em diferentes culturas são realizados por pesquisadores de universidades e instituições que compõem o Sistema Nacional de Pesquisa Agropecuária.

3.3 Técnicas Utilizadas para o Controle das Plantas Invasoras

Várias técnicas podem ser adotadas para o controle de plantas invasoras, entre elas: o preparo do solo, predadores biológicos, controle mecânico, controle químico, alelopatia e pelo fogo [SIL 97].

No caso de grandes áreas de cultivo, estas técnicas podem ser apoiadas com recurso de sensoriamento remoto. As informações obtidas com imagens podem ser utilizadas para auxiliar o planejamento do cultivo. Nota-se neste caso, a necessidade de se referenciar as imagens com os pontos no terreno, o que é realizado com a utilização do Sistema Global de Posicionamento (GPS). Isto permite que diferentes procedimentos sejam utilizados em cada área de plantio, caracterizando a agricultura de precisão.

3.3.1 Plantio Direto

Segundo o órgão governamental CATI (Coordenadoria de Assistência Técnica Integral), o uso do plantio direto, ou seja, plantio sobre palha, apresenta várias vantagens, entre elas:

- Aumenta a disponibilidade de água para as plantas;
- Reduz a oscilação térmica, a erosão do solo e o uso de máquinas e equipamentos;
- Aumenta os teores de matéria orgânica e a disponibilidade de nutrientes;
- Melhora a estrutura, a fertilidade e a atividade biológica do solo;
- Melhora a produtividade;
- Promove uma diminuição significativa dos custos e o aumento da vida útil das máquinas.

O plantio direto consiste na aplicação de dessecantes antes da semeadura, levando à morte as plantas restantes da cultura anterior e as plantas invasoras, dando início à formação da palha, utilizada como cobertura para a próxima cultura.

3.3.2 Outras Práticas Convencionais

O controle de plantas invasoras pode ser feito por competição e rotação de culturas [SIL 97], sendo que a competição baseia-se no princípio da sobrevivência do mais forte. Neste caso, as medidas empregadas são o controle da data de plantio, a técnica de semeadura, as culturas que fazem competição e a cobertura morta. O controle por meio de rotação de cultura baseia-se no fato de que certas plantas invasoras são mais comuns em determinadas culturas, e a troca da cultura causa a extinção de certas pragas.

O controle mecânico consiste na utilização de instrumentos ou implementos (arados, grades e cultivadores), tracionados por máquinas, animais ou mesmo pelo homem (através da capina) com o objetivo de reduzir a população de plantas no solo ou na lavoura antes do plantio. O método manual é o mais simples, demanda grande quantidade de mão-de-obra e pode ser utilizado como complemento a outros métodos.

Uma outra técnica importante é a Alelopatia, que utiliza o princípio do controle por competição por algumas plantas que liberam substâncias químicas afetando a germinação e o desenvolvimento de plantas invasoras indesejáveis. Permite o controle natural da área

infestada [GAZ 01, SIL 97]. Esta alternativa se mostra interessante porque reduz a utilização de herbicidas.

A utilização de qualquer técnica de controle deve ser feita antes da floração da planta (cultura principal), evitando danos devido ao contato com equipamentos.

A quantidade de vezes que se utiliza um método de controle depende exclusivamente, da presença de plantas daninhas na lavoura. Como regra geral, duas a três vezes antes do florescimento são suficientes para manter a lavoura em boas condições. Após o florescimento, normalmente não haverá mais problemas com invasoras, desde que a lavoura tenha sido mantida limpa [GAZ 01].

O método químico de controle (uso de herbicidas) é utilizado em grande escala. Após a colheita são aplicados produtos químicos com o objetivo de realizar a limpeza do terreno (dessecação). Em estudo na Fazenda Campo Bom, a prática de plantio direto utiliza o método químico para o processo de dessecação e preparo do solo para plantio. As grandes vantagens deste controle são a economia de mão-de-obra e a rapidez na aplicação [GAZ 01, JOS 99].

3.3.3 Técnicas Apoiadas por Sensoriamento Remoto

O sensoriamento remoto e a interpretação de imagens são técnicas que podem auxiliar na identificação dos fatores que afetam a variação da produtividade em áreas distintas do campo [MOR 97, SUD 97, PIE 99]. As informações obtidas com as imagens de sensoriamento remoto, podem gerar mapas de aplicação localizada de insumos. Estes mapas são utilizados pelas máquinas e equipamentos de aplicação para identificar as áreas de interesse no campo, no caso, fazendo uso de equipamento de posicionamento global (GPS). [MOR 97, SUD 97, SON 98, SCH 01].

O acompanhamento do desenvolvimento da cultura em tempo real e a correção dos fatores deficientes e a identificação de pragas é uma das atividades mais importantes na agricultura [SUD 97, SON 98].

A identificação de áreas com infestação de plantas invasoras, através de imagens obtidas com sensoriamento remoto, pode possibilitar, após verificação no local, um controle em tempo para que a queda de produtividade seja minimizada.

Embora o sensoriamento remoto apresente precisão razoável para uma parte das

necessidades da agricultura de precisão, ainda é deficiente com respeito ao tempo transcorrido entre a passagem do satélite e o resultado interpretado na imagem.

Para áreas muito grandes, as técnicas de sensoriamento remoto podem ser mais apropriadas do que as de sensoriamento local, em termos de custos, facilidade e rapidez na obtenção dos dados. Porém, para a identificação de plantas invasoras, se faz necessário a utilização de sensores em tratores ou outros maquinários agrícolas para obtenção de imagens mais próximas.

As relações entre produtividade e informações do meio físico precisam ser bem entendidas e gerenciadas. Para isso, há necessidade de desenvolvimento de softwares que auxiliem o agricultor com respeito a manipulação do grande volume de informação que normalmente estão disponíveis para o processo de tomada de decisão.

Os mapas de aplicação localizada de insumos precisam ter rigoroso fundamento técnico porque a aplicação localizada e precisa desses herbicidas, não terá sucesso sem uma prescrição correta de sua utilização. Os diferentes procedimentos realizados a partir das informações contidas nos mapas, caracterizam a agricultura de precisão. O sistema de agricultura de precisão é ilustrado na figura 3.1.

Figura 3.1: Agricultura de precisão

3.4 Bidens Pilosa - Picão-Preto

O gênero *Bidens* abriga cerca de 200 espécies de plantas herbáceas e sub-arbustivas, anuais ou perenes, que ocorrem no mundo inteiro. *Bidens pilosa* ou picão preto como é conhecida, é

uma planta herbácea, originária da América tropical, com maior presença na América do Sul [ACC 02]. No Brasil está presente em quase todo o território, com maior concentração nas áreas agrícolas do centro-oeste-sul, onde constitui uma das espécies mais resistentes quanto à infestação. A planta pode ser encontrada durante todo o ano, mas a maior ocorrência é na primavera e no verão, recebendo os seguintes nomes populares: picão, picão-preto, picão-campo, pico-pico, erva-picão, fura-capá, carrapicho-de-duas-pontas, goambu, coambi, dependendo da região. A origem do nome vem do latim "Bidens", dois dentes, em alusão às duas projeções agudas sobre os aquênios (sementes), e "pilosa" pela ocorrência de pêlos esparsos sobre as brácteas (folhas). Um exemplar de picão adulto pode ser visto na figura 3.2.

Figura 3.2: Picão adulto.

O picão preto é uma planta anual, reproduzida por semente. Segundo a Enciclopédia das Plantas [ACC 02], uma única planta pode produzir até 3.000 sementes, o que demonstra o potencial reprodutivo e infestante. É uma planta polimorfa, de aspectos bastante variáveis: plantas provindas de uma mesma planta-mãe podem apresentar flores (amarelas) com diversos tipos de lígulas (pequenas pétalas), desde quase imperceptíveis até muito desenvolvidas.

O amadurecimento dessas flores dão origem às sementes, que com suas farpas, prendem-se facilmente em tecidos e pêlos, facilitando sua dispersão. A figura 3.3 mostra o picão quando

pequeno e a figura 3.4 mostra a semente fornecida.

Figura 3.3: Picão pequeno.

Figura 3.4: Semente de picão.

Em estudos químicos e farmacológicos foram isolados hidrocarbonetos e fitosteróis, poliacetilenos com ação cercaricida e um poliacetileno, fenilheptatriino, com ação tóxica para bactérias, fungos e fibroblastos humanos, na presença da luz solar. Desta forma, a planta invasora picão-preto, pode também ser considerada uma planta medicinal [ACC 02, HOF 02].

Todas as partes da planta podem ser utilizadas, sendo indicada pela farmacopéia como planta medicinal, de propriedades estimulantes, desobstruentes e vermífugas, sendo ainda recomendada contra icterícia, hepatite e diabetes.

A planta, também é utilizada pelos nativos da África negra como verdura. Nas Filipinas entra na fabricação de uma bebida chamada "sinitsit"; também consumida no México e Peru. Antes da floração pode ser usada como forrageira, sendo freqüentemente dada a coelhos.

3.4.1 Estudo do Reconhecimento da Planta Invasora Picão Preto

Foi realizado um estudo baseado na observação da planta picão para determinação das características importantes para o seu reconhecimento. Foram plantadas sementes e durante aproximadamente dois meses e meio, foi acompanhado o desenvolvimento da planta invasora picão-preto.

As primeiras características apareceram dentro de 3 a 5 dias após a germinação, seguidas de outras, como apresentada a seguir.

1) 3 a 5 dias após a germinação, apareceram duas primeiras folhas, conforme a figura 3.5.

Figura 3.5: Planta com 3 a 5 dias.

2) 10 a 15 dias, o picão desenvolveu um pouco mais suas folhas, alongando mais, mantendo o aspecto estreito e dando surgimento a outras duas folhas ao centro, sendo estas de forma mais larga. Esta etapa pode ser vista na figura 3.6.

Figura 3.6: Planta com 10 a 15 dias

3) 17 a 20 dias, as 4 folhas continuaram se desenvolvendo como na figura 3.7.

Figura 3.7: Planta com 17 a 20 dias

4) 22 a 25 dias, apareceram mais duas folhas, porém com aspecto mais largo, como na figura 3.8

Figura 3.8: Planta com 22 a 25 dias

5) 27 a 30 dias, outras duas folhas do mesmo aspecto surgiram, como mostra a figura 3.9.

Figura 3.9: Planta com 27 a 30 dias

6) 35 a 38 dias, aproximadamente, o caule começou a se alongar, surgindo novas folhas mais espaçadas, alternando as formas. A figura 3.10 mostra a planta nesta etapa.

Figura 3.10: Planta com 35 a 38 dias.

7) 40 a 50 dias, as flores começaram a surgir, como mostra a figura 3.11.

Figura 3.11: Planta com 40 a 50 dias

8) 50 a 60 dias, a planta já se encontrava totalmente adulta, como na figura 3.12.

Figura 3.12: Planta com 50 a 60 dias

9) 60 a 70 dias, as sementes amadureceram, surgindo os picãos-secos (sementes), conforme as figuras 3.13.

Figura 3.13: Planta com 60 a 70 dias

Após o alongamento do caule da planta, as folhas se desenvolveram no tamanho médio de 5 a 10 cm de comprimento. Algumas folhas morreram, secaram e caíram.

Algumas plantas desenvolveram suas flores amarelas com aproximadamente 40 a 45 dias, em número de 2 ou 3. O tamanho final, quando adultas, pode atingir até 50 cm de altura.

Algumas plantas adquiriram um aspecto mais alongado que outras. Segundo os agrônomos, isso corresponde a competição do local com relação aos fatores: luz, água e calor.

Plantas mais espaçadas demoraram um pouco mais a se alongar, pois não entraram em competição forte. Assim mesmo, se alongaram e forneceram flores amarelas (sementes) como as demais.

3.4.2 O reconhecimento da Planta Picão Preto na Agricultura

Os herbicidas podem ser classificados em relação ao estágio de desenvolvimento da planta invasora, da cultura ou de ambos, quanto a aplicação em: pré-emergentes (PRE) e pós-emergentes (POS).

A aplicação do herbicida POS, para o picão preto, durante sua fase inicial de vida, é feita pelo reconhecimento da forma da folha quando adulta, sendo importante reconhecer as flores amarelas e suas sementes pretas, que juntamente com a forma das folhas leva à uma identificação da planta.

Os herbicidas PRE são aplicados no solo antes da germinação das sementes dessa planta invasora. Muitos herbicidas PRE necessitam ser incorporados ao solo para maior eficiência, sendo aplicados antes do plantio da cultura. Esses herbicidas são também conhecidos como herbicidas residuais, porque deixam no solo resíduos ativos que continuarão por algum tempo matando as plantas que por ventura entrarem em germinação, como por

exemplo, o *Round-up*.

Os herbicidas POS são aplicados na folhagem das plantas daninhas. Alguns, entretanto, podem ser absorvidos pelas raízes após sua queda no solo. A maioria dos herbicidas POS também possuem ação residual ou de pré-emergência.

Além de observar o estágio de desenvolvimento da planta invasora para aplicação do herbicida ou conjunto de herbicidas, segundo os administradores da fazenda Campo Bom, é analisado também o tipo de folhagem da planta, ou seja, se folha estreita ou folha larga. Para cada tipo de folhagem há um tipo de herbicida a ser utilizado.

3.5 Metodologia Adotada

Este trabalho trata da identificação em tempo real de plantas invasoras. Para a realização deste trabalho, foi escolhida a planta invasora Picão Preto, que durante a pesquisa feita na fazenda Campo Bom apresentou grande infestação em boa parte das áreas estudadas.

Com câmeras fixadas em máquinas agrícolas, foi possível obter algumas centenas de fotos da lavoura. Parte dessas fotografias foi submetida ao processamento proposto neste trabalho.

Para se ter uma idéia da complexidade do problema de identificação do picão preto na lavoura, são apresentadas na figura 3.14 algumas dessas imagens. Entre outras plantas invasoras, aparece nessas imagens o picão preto em seus diversos estágios de desenvolvimento.

Figura 3.14: Plantas invasoras em culturas de soja e milho.

3.6 Sumário

Neste capítulo foi apresentado o problema das plantas invasoras na agricultura. Também foi feita uma breve apresentação da fazenda Campo Bom, situada no cerrado brasileiro, onde se realizou a coleta de dados para este trabalho. Foram relacionadas as plantas invasoras predominantes no local, sua importância econômica, sua resistência a herbicidas e o grau de infestação. Foi também apresentada a planta escolhida para os testes, o picão preto. Sementes de picão foram cultivadas para o acompanhamento dos estágios de desenvolvimento da planta e a identificação das características marcantes de cada estágio que pudessem permitir o seu reconhecimento.

O capítulo 4 apresenta a arquitetura do sistema utilizado para a identificação de plantas invasoras em tempo real. Também são apresentadas as técnicas utilizadas para esse reconhecimento.

Capítulo 4

Arquitetura do Sistema de Identificação

Este capítulo apresenta a arquitetura proposta para o sistema de identificação de plantas invasoras em tempo real. A arquitetura apresentada neste capítulo tem potencial para tratar a complexidade do problema proposto, conforme visto no capítulo anterior.

Durante a pesquisa foram encontrados alguns artigos e relatórios que tratam da identificação de plantas invasoras, porém poucos se preocupam com a identificação em tempo real. A maioria é de artigos estrangeiros, pois na data de escrita dessa dissertação está se iniciando o estudo desse assunto no Brasil.

Métodos clássicos de processamento de imagens apresentam, nos artigos revistos, resultados satisfatórios. A classificação dos padrões por casamento de *templates* é um exemplo, embora esta técnica demanda bastante tempo, não sendo recomendada para processamento em tempo real. Para análise em tempo real, alguns trabalhos propõem a utilização de redes neurais artificiais [YAN 00, DRU 00, TAN 99], e essa linha de pesquisa foi adotada neste trabalho.

A implementação de redes neurais pode ser feita tanto em hardware quanto em software. Em qualquer um dos casos, o sistema pode ser instalado com sucesso em muitos veículos agrícolas, como tratores, pulverizadores, colheitadeiras, entre outros [PAR 99, YAN 00].

4.1 Projeto Modular

O sistema de identificação de plantas invasoras inicia com a aquisição das imagens e sua subdivisão em subimagens, reduzindo-se a complexidade de tratamento dessas imagens. A técnica de componentes principais é utilizada, através da transformada de Hotteling, para reduzir ainda mais a complexidade do problema, uma vez que somente a primeira componente é utilizada.

Para que o processamento seja realizado em tempo real, propõe-se neste trabalho a utilização de redes neurais. Para acelerar ainda mais o processamento, também é proposta a utilização de vários processadores formando uma arquitetura de processamento paralelo do tipo multicomputador. Cada processador da arquitetura pode ser responsável pelo reconhecimento de uma ou mais plantas invasoras ou de uma ou mais características de uma mesma planta invasora. O que define a estratégia a ser utilizada é a limitação no tempo de processamento imposta pelo requisito de processamento em tempo real.

Neste trabalho, os testes foram realizados para uma única planta invasora, o picão. Para essa planta três características foram consideradas: forma das folhas, flor e picão-seco (semente), conforme discutido no capítulo anterior.

A arquitetura paralela proposta para a identificação de plantas invasoras, pode ser vista na figura 4.1.

Figura 4.1: Arquitetura proposta para identificação de plantas invasoras

4.2 Módulo de Extração das Informações para Processamento

As informações para processamento da imagem são obtidas pela transformada de Hotteling, apresentada no capítulo 2. Na seção seguinte é apresentado o procedimento utilizado para efetuar essa transformação.

4.2.1 Técnica de Hotteling

Para calcular a primeira componente de Hotteling, seguindo a descrição apresentada no capítulo 2, é necessário inicialmente calcular a matriz de covariância:

$$C_{RGB} = \begin{bmatrix} C_{RR} & C_{RG} & C_{RB} \\ C_{GR} & C_{GG} & C_{GB} \\ C_{BR} & C_{BG} & C_{BB} \end{bmatrix} \quad (4.1)$$

Onde C_{RR} representa a auto-covariância calculada a partir da componente R de cada pixel da imagem, conforme a expressão:

$$C_{RR} = \frac{1}{N} \sum_{i=1}^N R_i^2 - \mu_R^2 \quad (4.2)$$

Onde N, é o número de pixels da imagem, R_i é o valor R de cada pixel e μ_R é o valor médio de todas componentes R da imagem. O valor C_{GG} , é a auto-covariância para a componente G, substituindo R por G na equação anterior; De forma similar, calcula-se C_{BB} para a componente B.

As covariâncias entre R e G (C_{RG}, C_{GR}), entre R e B (C_{RB}, C_{BR}) e entre G e B (C_{GB}, C_{BG}), podem ser calculadas da seguinte forma:

$$C_{XY} = \frac{1}{N} \sum_{i=1}^N X_i Y_i - \mu_X \mu_Y \quad (4.3)$$

Onde X e Y representam R,G,B e os valores μ_X e μ_Y , os valores médios de X e Y.

Após calcular a matriz de covariância, calcula-se os auto-vetores através do método de rotações sucessivas de Jacobi para matrizes simétricas, conforme visto em [PRE 92]. Tendo os auto-vetores, as componentes HOT são encontradas conforme a equação 2.42.

4.3 Módulo de Redes Neurais

O modelo de rede neural adotado para testes neste trabalho foi escolhido segundo a complexidade das características a serem identificadas. Adotou-se inicialmente uma rede neural supervisionada. Em [JOR 01], mostra-se que redes neurais supervisionadas utilizando o algoritmo *backpropagation*, apresentam resultados satisfatórios na análise de imagens.

Outras redes neurais são propostas na literatura, como por exemplo RBF (*Radial Basic Funtion*). Entretanto, para o tipo de análise feita neste trabalho, não foram obtidas informações suficientes para motivar a sua utilização. Trabalhos futuros devem considerar a investigação do comportamento das redes RBF na análise de plantas invasoras, principalmente plantas de identificação mais difícil que o picão preto. A rede supervisionada MLP, com o algoritmo de aprendizado *backpropagation*, apresentaram resultados suficientemente satisfatórios para o caso estudado neste trabalho.

4.3.1 Redes Neurais Artificiais

A rede neural artificial é uma técnica utilizada na solução de problemas de inteligência artificial, utilizando modelos que simulam o cérebro humano [BER 99, JUN 01]. As redes neurais podem adquirir conhecimento através da experiência. Uma grande rede neural artificial pode ter centenas ou milhares de elementos de processamento enquanto o cérebro biológico pode ter bilhões de neurônios.

Duas características importantes em uma rede neural artificial são:

- Grande número de elementos simples de processamento, inspirados no funcionamento de um neurônio;
- Grande número de conexões entre esses elementos de processamento, cada uma com um peso associado. Este peso representa a força de interação ou acoplamento entre os elementos de processamento e a sua natureza: de ativação ou inibição.

Alguns modelos de redes neurais possuem características apropriadas para o reconhecimento de padrões, podendo simular aprendizado, modificando seu comportamento frente a um conjunto de estímulos de entrada (padrão de entrada) [BER 99, MED 99, BAR 97]. As redes aprendem a dar uma resposta específica segundo um determinado conjunto de estímulos fornecidos.

Uma rede neural é uma estrutura de processamento de informação distribuída paralelamente na forma de um grafo direcionado ¹ com algumas restrições e definições próprias [BER 99, JUN 01, MIC 01]. Os nós deste grafo são os **elementos de processamento**. Suas arestas são **conexões**, que funcionam como caminhos de condução instantânea de sinais em uma única direção. Os elementos de processamento podem receber qualquer número de conexões de entrada.

Estas estruturas podem possuir memória local e qualquer número de conexões de saída desde que o tipo de sinais nessas conexões seja o mesmo. Na verdade existe apenas uma única conexão de saída, que pode dividir-se em cópias para formar múltiplas conexões, todas com o mesmo sinal.

Cada elemento de processamento possui uma função de transferência, cujas entradas são os valores armazenados na memória local.

Os valores de saída da função de transferência são valores armazenados na memória local do elemento de processamento.

A função de transferência pode operar continuamente ou periodicamente. No primeiro caso, os elementos estão sempre ativados e a entrada *activate* chega através de uma conexão de um elemento de processamento. No segundo caso, deve existir uma entrada de ativação da função de transferência com o sinal de entrada corrente e com valores da memória local. O sinal de saída é atualizado alterando os valores da memória [JUN 01].

A operação de um elemento de processamento da rede se resume em:

- Sinais são apresentados à entrada;
- Cada sinal é multiplicado por um peso que indica sua influência na saída do elemento de processamento;
- É feita a soma ponderada dos sinais, produzindo um nível de atividade;
- Se este nível excede um limite *threshold*, o elemento de processamento produz uma saída.

A falta de embasamento teórico sobre o processo de aprendizagem de uma rede neural ainda é uma séria desvantagem, gerando desconfiança por parte dos especialistas quanto a

¹Um grafo direcionado é um objeto geométrico que consiste em um conjunto de pontos, chamados nós, e um conjunto de segmentos de linhas direcionadas entre eles.

sua confiabilidade. Outra desvantagem das redes neurais, é o tempo necessário para a fase de aprendizado da rede. Em algumas aplicações críticas a fase de treinamento pode durar horas e até dias para ser realizada [JUN 01]. No entanto, existem arquiteturas que dispensam a fase de aprendizado. Entre essas estão as redes que têm capacidade auto-adaptativa para perceber novos padrões.

Neurônio Artificial

Neurônio artificial, elemento de processamento ou ainda, unidade de processamento, consiste em um dispositivo simples capaz de calcular a somatória ponderada de N entradas. A saída Y do dispositivo é a somatória das entradas $X_0, X_1, \dots, X_{n-1}$, ponderadas pelos pesos $W_0, W_1, W_2, \dots, W_{n-1}$ [MED 99, BER 99, BAR 97].

De acordo com os sinais de entrada, o neurônio pode ser ativado enviando um sinal de saída, que será propagado de acordo com a topologia de interconexão da rede [BER 99].

Na figura 4.2 pode ser observado o modelo de um neurônio artificial.

Figura 4.2: Neurônio artificial.

Existem vários tipos ou modelos de RNA (Redes Neurais Artificiais) e vários algoritmos para realizar o aprendizado ou treinamento dos neurônios. Uma das redes mais utilizadas é a rede MLP (*Multilayer Perceptron*) que utiliza o algoritmo *backpropagation*.

Perceptron Multicamadas - (Multi Layers Perceptron-MLP)

Redes MLP são bastante utilizadas para resolver problemas mais complexos, os quais não poderiam ser resolvidos pelo modelo de neurônio básico [JUN 01, VEI 99]. A estrutura da rede MLP pode ser vista na figura 4.3.

Figura 4.3: Rede perceptron multicamadas - MLP

A **camada de entrada** recebe os padrões apresentados à rede. A **camada intermediária** corresponde ao local onde a maior parte processamento é realizado através das conexões, sendo também denominada extratora de características. A **camada de saída** é responsável pela apresentação do resultado. Os neurônios internos são de grande importância na rede neural, pois sem estes, fica impossível a resolução de diversos problemas [JUN 01, VEI 99].

Uma função de ativação típica para o j -ésimo neurônio da segunda camada da rede é determinada por:

$$Y_j = f(S_j) = \frac{1}{1 + e^{-S_j/Q}} \quad (4.4)$$

onde S_j é a saída do j -ésimo neurônio.

Se mais de uma camada for usada, o processo se repete a cada camada que servirá de entrada para a seguinte. Ao iniciar o treinamento de uma rede, valores randômicos iniciais devem ser atribuídos, geralmente limitados entre -1 e +1 [VEI 99].

4.3.2 Algoritmo *Backpropagation*

O algoritmo *backpropagation*, também denominado regra delta generalizada, consiste em um método de aprendizado por minimização de erros [BER 99, BAR 97].

Este algoritmo é usado em redes com realimentação denominadas *feedforward*. Além das camadas de neurônios de entrada e saída, as redes podem ter uma ou mais camadas intermediárias denominadas *camadas escondidas*, conforme visto anteriormente na figura 2.25 do capítulo 2. Este tipo de rede utiliza N valores contínuos como as suas entradas,

M valores como suas saídas e normalmente duas camadas de elementos de processamento ocultas.

O conjunto de padrões para treinamento deve conter amostras representativas de do que se deseja que a rede aprenda. Durante o treinamento com o algoritmo *backpropagation*, a rede opera em uma sequência de dois passos, como mostra a figura 4.4 [MED 99, BAR 97].

Figura 4.4: *Backpropagation*

No primeiro passo, um padrão é apresentado à camada de entrada da rede. A atividade resultante flui através da rede, camada por camada, até que a resposta seja produzida pela camada de saída. No segundo passo, a saída obtida é comparada à saída desejada para esse padrão particular. Caso as saídas obtidas e desejadas não sejam iguais, o erro é calculado. O erro é então propagado a partir da camada de saída até a camada de entrada e os pesos das conexões dos elementos de processamento da camada de saída e das camadas intermediárias vão sendo modificados conforme o erro é retropropagado [MED 99].

A possibilidade de reajustar os pesos, corresponde a parte mais importante desse algoritmo.

Assim as etapas do treinamento são [BER 99, BAR 97, MED 99]:

- Iniciação dos pesos com valores dentro de determinado intervalo;
- Apresentação do vetor de entradas com as respectivas saídas desejadas:

$$xp = (x_0, x_1, \dots, x_n) \Rightarrow t_p$$

Onde $x_0, x_1, x_2 \dots x_n$ correspondem as entradas do vetor x_p e t_p , a saída desejada.

- Cálculo da saída:

$$Y_{p,j} = \sum_{i=0}^{i=0} W_{ij} \Theta_{pi} \quad (4.5)$$

onde:

W_{ij} - Peso do elemento de processamento i para o elemento de processamento j.

Θ_{pi} - Saída produzida pela rede para o padrão p na conexão i .

Na camada inicial Θ_{pi} , é igual a X_i .

- A adaptação dos Pesos, começando pela camada de saída, é definida pela seguinte regra:

$$W_{ij}(t+1) = W_{ij}(t) + \alpha \cdot \delta_{pj} \cdot \Theta_{pi} \quad (4.6)$$

onde: $W_{ij}(t)$ - Peso da elemento de processamento i para elemento de processamento j no tempo t.

α - Taxa de aprendizado.

δ_{pj} - Erro para o padrão p no elemento de processamento j.

No elemento de processamento de saída o erro é calculado por:

$$\delta_{pj} = (t_{pj} - \Theta_{pj}) \Theta_{pj} \cdot (1 - \Theta_{pj}) \quad (4.7)$$

Nos elementos de processamentos da camada escondida, o erro é calculado por:

$$\delta_{pj} = \Theta_{pj} \cdot (1 - \Theta_{pj}) \sum_k \delta_{pk} \cdot W_{kj}$$

4.4 Ambiente de Desenvolvimento SNNS

SNNS (Stuttgart Neural Network Simulator), é um ambiente de simulação de redes neurais desenvolvido pela Universidade de Stuttgart, no departamento de Sistemas Distribuídos e de Alto Desempenho. O objetivo do SNNS é criar um ambiente de simulação em ambiente Linux/ Unix, proporcionando flexibilidade para a pesquisa de aplicação de vários tipos de redes neurais com diversos algoritmos de aprendizagem.

Inicialmente o ambiente SNNS apresenta uma tela com opções para o usuário definir a rede neural, conforme mostra a figura 4.5

Figura 4.5: Tela inicial do SNNS

O usuário deverá clicar sobre a tela de apresentação para iniciar o ambiente. Após iniciado, o usuário deve escolher a opção BIGNET para definir a rede neural. Uma nova tela é apresentada para que o usuário possa definir a quantidade de camadas, o número neurônios de entrada, as saídas e as camadas intermediárias. Essa opção é apresentada na figura 4.6.

Figura 4.6: Definição da rede neural

Após definir a rede neural, o usuário pode visualizá-la na opção DISPLAY, conforme

The screenshot displays the SHNS Manager application interface, which is divided into three main sections:

- Left Pane (Terminal):** Shows the execution of the 'xgsl' command. The output includes network statistics (negative/zero values), file loading information, and color information for the network nodes.
- Right Pane (3D Visualization):** Displays a 3D visualization of the network structure. Nodes are represented by colored spheres, and edges are shown as lines connecting them. The colors likely correspond to the 'color' information output by the 'xgsl' command.
- Bottom Pane (Control Panel):** Contains a series of buttons for managing the network visualization and data. The buttons are: FILE, CONTROL, INFO, DISPLAY, 3D DISPLAY, GRAPH, SIGNET, PRUNING, CASCADE, KOHONEN, WEIGHTS, PROTECTION, ANALYZER, INVERSION, PRINT, HELP, CLASSES, and QUIT.

Para treinar a rede, se faz necessário definir um arquivo do tipo .pat para treinamento, sendo optativo um outro arquivo para validação. O arquivo do tipo .pat corresponde ao arquivo texto criado com as informações das características a serem identificadas. Para iniciar a tela de treinamento, o usuário deve clicar sobre a opção CONTROL da tela principal. Essa opção pode ser vista na figura 4.8.

Após definir os arquivos, é necessário informar o número de passos, ciclos, taxa de aprendizagem e algoritmo de treinamento. Esses dados são importantes para que o treinamento aconteça. A figura 4.9 apresenta essa opção.

Figura 4.9: Parâmetros do treinamento

Clicando na opção SHUFFLE, o usuário força o treinamento de forma randômica, não obedecendo a ordem do arquivo, para que a rede não fique "viciada" durante o treinamento. Finalmente, a opção INIT inicia a rede, e a opção ALL inicia o treinamento, conforme a figura 4.10.

Figura 4.10: Simulação do treinamento

Ao finalizar um treinamento, o usuário troca o arquivo de treinamento pelo arquivo de teste. Clicando no botão TEST da tela CONTROL, pode-se realizar os testes. Caso o usuário queira visualizar a porcentagem de erros e o tempo de teste, tem-se a opção ANALYSER da tela principal, que pode ser vista na figura 4.11.

Figura 4.11: Simulação do teste

4.5 Sumário

Neste capítulo foi apresentada a arquitetura utilizada para o sistema de identificação de plantas invasoras, bem como os procedimentos utilizados no processamento das imagens coletadas da cultura agrícola.

Foi enfatizada a motivação do uso de Redes Neurais Artificiais na identificação de plantas invasoras em tempo real, bem como os conceitos de Redes Neurais Artificiais, seu mecanismo de funcionamento, processamento e o algoritmo de aprendizado *backpropagation*.

O capítulo 5 apresenta o desenvolvimento do módulo de geração das subimagens utilizadas nos testes da rede neural MLP utilizada no reconhecimento da planta invasora selecionada, o picão preto.

Capítulo 5

Módulo de Geração de Imagens para Teste

Este capítulo tem por objetivo apresentar o sistema de geração de imagens para a realização de testes de reconhecimento de plantas invasoras com a utilização de redes neurais. Compreende o levantamento dos requisitos, a especificação, o projeto e a implementação do sistema.

O módulo de geração das imagens para teste divide cada imagem em subimagens, gerando as componentes da transformada de Hotteling. É possível associar a cada subimagem as características nela contidas que podem ser posteriormente identificadas, facilitando desta forma o treinamento, validação e testes das redes neurais.

5.1 Necessidades e Requisitos

A necessidade do módulo de geração de imagens para teste surgiu no processo de seleção e preparação das imagens para o treinamento, validação e testes das redes neurais utilizadas. Neste processo, algumas operações tomam um tempo significativo se executadas manualmente em cada uma das imagens utilizadas. Dentre essas operações, as mais significativas são a divisão da imagem original em subimagens e a geração das componentes de Hotteling dessas subimagens. A organização das imagens para facilidade de localização e acesso é outro problema quando se trabalha com um grande número de imagens.

Foram obtidas algumas centenas de imagens (fotografias) e informações para o reco-

nhecimento das plantas invasoras em estudo. Além das informações fornecidas pelo agrônomo da Fazenda Campo Bom, foi realizado o cultivo da planta picão preto selecionada para estudo, e feita a observação da sua aparência durante as diversas fases do seu desenvolvimento, conforme relatado no capítulo 3.

Para o picão preto, foram selecionadas as características mais marcantes no seu reconhecimento: a forma das folhas, a flor e as sementes (picão seco). Como a fazenda realiza o plantio direto, ou seja, plantio sobre palha, houve a necessidade de estudar características que também distinguíssem a planta da terra e da palha.

No seu primeiro estágio de desenvolvimento, o picão pode ser visualmente reconhecido pela aparência da folha, quanto à forma e a cor. Após aproximadamente dois meses de desenvolvimento, quando os agricultores se preocupam em aplicar herbicidas para o controle, esta planta já se encontra no estágio adulto, apresentando flores e em alguns casos até o picão seco (semente). Nesta fase a planta pode ser reconhecida pelas flores e sementes.

As imagens abaixo são exemplos de padrões utilizados para a extração das características no reconhecimento do picão. As figuras 5.1 (a) e (b), correspondem ao padrão de folhas em um picão jovem; a figura 5.1 (c), o padrão de flor e a figura 5.1 (d) o padrão de um picão-seco.

Figura 5.1: Plantas invasoras em culturas de soja e milho.

Os requisitos funcionais do sistema de geração de imagens para teste são:

- 1. O sistema deve permitir o armazenamento de imagens organizadas de acordo com a sua finalidade ou missão em que foram tomadas;
- 2. O sistema deve possibilitar que o usuário defina as dimensões das subimagens geradas a partir da divisão das imagens originais;
- 3. O sistema deve armazenar as imagens e permitir que o usuário associe informações às subimagens;

- 4. O usuário deve poder inserir novas plantas e características.
- 5. O sistema deve fornecer o arquivo de Hotteling para análise em uma rede neural.

5.2 Projeto e Implementação

O Diagramas de Fluxo de Dados (DFD) de nível 0 do sistema de geração de imagens para teste é apresentado na figura 5.2. Deste diagrama, foi derivado o DFD de nível 1, apresentado na figura 5.3.

Figura 5.2: Módulo de geração de imagens para teste

Figura 5.3: Diagrama de fluxo de dados - nível 1

A descrição dos módulos constantes no DFD da figura 5.3 é apresentada a seguir.

- **Cadastrar Tomada:** este processo é responsável pelo cadastro da tomada (missão), que será utilizada para referenciar o armazenamento das imagens.
- **Armazena Imagem:** este processo é responsável pelo armazenamento das imagens.
- **Gera Subimagens:** este processo realiza a subdivisão da imagem em outras menores

conforme a dimensão indicada pelo usuário.

- **Gera Arquivo Hotteling:** este processo realiza a geração do arquivo Hotteling, pela transformada de Hotteling através das informações extraídas das subimagens.
- **Inserir Característica Subimagem:** neste processo o usuário registra na base de dados da subimagem, as características como: o tipo de planta invasora, folha, semente, flor e grau de infestação.
- **Cadastrar Planta:** este processo é responsável pelo cadastro da planta, com seu nome científico e popular.
- **Cadastrar Característica:** este processo é responsável pelo cadastro de características, como folha, semente, flor entre outras.

O sistema de geração de imagens para teste foi implementado na linguagem de programação C++ Builder para o sistema operacional Microsoft Windows. A escolha do C++ Builder é justificada pela facilidade de desenvolvimento de aplicações gráficas. Essa linguagem de programação apresenta um ótimo ambiente para o paradigma de programação orientada a objetos.

Foi utilizado também o banco de dados do C++ Builder, Paradox 7, pois o mesmo permite a inclusão de imagens em suas tabelas. Essa linguagem não possui acesso direto a bancos de dados, sendo necessário fazer uma interface com um gerenciador de dados, o Borland Database Engine (BDE). O BDE utiliza um driver específico para cada tipo de banco de dados. Todas as versões do C++ Builder possuem um driver Standard para ser utilizado com o Paradox.

5.2.1 Operação do Sistema

Inicialmente, o usuário deve registrar uma tomada (missão) para o armazenamento da imagem ou imagens. Caso já exista a tomada que irá referenciar a imagem, o usuário deve clicar sobre essa tomada para ativar a opção de inserção de imagem. As figuras 5.4 e 5.5 apresentam essa opção.

Figura 5.4: Tela inicial

Figura 5.5: Opção para inserção da tomada

A opção de inserção de imagens pode ser vista na figura 5.6.

Figura 5.6: Opção para inserção de imagens

Após selecionar a imagem ou o diretório onde se encontram as imagens para o armazenamento, o usuário define a dimensão das subimagens que serão geradas, conforme a figura 5.7.

Figura 5.7: Opção para escolha da dimensão das subimagens

A figura 5.8 representa a inserção uma imagem e a figura 5.9, de várias imagens.

Figura 5.8: Inserção de uma imagem

Figura 5.9: Inserção de várias imagens

A figura 5.10 mostra o processo de geração de subimagens após sua inserção no banco de imagens.

Figura 5.10: Subdivisão da imagem inserida

O usuário tem a opção de registrar as características encontradas nas subimagens. Caso ele defina como um possível padrão para treinamento da rede, também pode gerar o arquivo Hotteling da determinada subimagem, como é apresentado na figura 5.11.

Figura 5.11: Cadastro das subimagens

Novas características e plantas podem ser inseridas quando necessário. Essas opções

podem ser vistas nas figuras 5.12 e 5.13.

Figura 5.12: Inserção de novas características

Figura 5.13: Inserção de novas plantas

5.3 Sumário

Neste capítulo foi apresentado o módulo de geração de imagens para teste iniciando com o estudo dos requisitos. Após esta análise, o sistema de geração de subimagens foi modelado, utilizando-se DFDs e implementado. Foi definido o ambiente de execução, bem como a linguagem e o banco de dados utilizados na sua implementação. A operação do sistema foi apresentada através das diversas telas que compõem sua interface com o usuário. Os resultados práticos de utilização do sistema de geração de imagens para teste demonstraram sua grande utilidade na preparação das imagens utilizadas nos testes realizados. Boa parte dos módulos desenvolvidos para o sistema descrito neste capítulo pode ser utilizada diretamente na implementação do sistema de reconhecimento de plantas invasoras.

O capítulo 6 apresenta os treinamentos e os testes realizados no simulador de redes neurais SNNS, bem como os resultados obtidos.

Capítulo 6

Resultados Obtidos

Neste capítulo são apresentados os resultados obtidos com o treinamento das redes neurais adotadas, cada qual com diferentes conjuntos de imagens e parâmetros de treinamento.

A partir dos treinamentos efetuados, foram realizados testes com conjuntos de imagens diferentes dos utilizados no treinamento e validação das redes neurais. Os arquivos de imagens utilizados, do tipo texto, correspondem a primeira componente da transformada de Hotteling gerada pelo software de geração de subimagens.

6.1 Treinamento da rede

Para o treinamento foram utilizados arquivos Hotteling no formato mostrado no exemplo dado na figura 6.1. Estes arquivos foram colocados no padrão utilizado pelo simulador SNNS para o treinamento e teste, como mostra a figura 6.2.

Figura 6.1: Exemplo de um arquivo Hotteling

SNNS pattern definition file V3.2
generated at Fri Jun 22 15:24:52 2002

No. of patterns : 1
No. of input units : 625
No. of output units : 2

```
# Input pattern 1:
0.008 0.011 0.012 0.014 0.014 0.011 0.009 0.011 0.038 0.117 0.128 0.131 0.131 0.134 0.136 0.135 0.129 0.120 0.111 0.114 0.119 0.114 0.109 0.110
0.012 0.015 0.012 0.010 0.015 0.011 0.010 0.011 0.048 0.126 0.134 0.134 0.137 0.135 0.138 0.137 0.131 0.124 0.114 0.101 0.101 0.106 0.106 0.104
0.008 0.014 0.024 0.010 0.011 0.011 0.011 0.031 0.084 0.116 0.129 0.134 0.134 0.130 0.132 0.131 0.129 0.124 0.124 0.114 0.097 0.089 0.089 0.082
0.006 0.015 0.022 0.006 0.005 0.023 0.088 0.121 0.132 0.131 0.134 0.136 0.134 0.133 0.132 0.128 0.125 0.122 0.124 0.118 0.115 0.115 0.110 0.106
0.017 0.019 0.010 0.010 0.067 0.120 0.136 0.138 0.141 0.138 0.134 0.136 0.134 0.131 0.128 0.131 0.124 0.118 0.120 0.113 0.114 0.116 0.112 0.115
0.014 0.009 0.011 0.086 0.136 0.142 0.138 0.137 0.139 0.135 0.133 0.135 0.135 0.129 0.124 0.125 0.122 0.118 0.117 0.117 0.119 0.113 0.111 0.117
0.011 0.007 0.026 0.126 0.140 0.140 0.139 0.138 0.136 0.132 0.131 0.132 0.131 0.129 0.125 0.123 0.124 0.123 0.116 0.116 0.120 0.114 0.117 0.116
0.012 0.012 0.016 0.060 0.119 0.137 0.141 0.141 0.135 0.132 0.132 0.134 0.133 0.131 0.129 0.128 0.124 0.124 0.110 0.101 0.105 0.112 0.116 0.114
0.010 0.011 0.014 0.016 0.039 0.097 0.132 0.133 0.130 0.129 0.130 0.134 0.132 0.131 0.129 0.130 0.122 0.106 0.077 0.069 0.103 0.118 0.118 0.117
0.016 0.015 0.013 0.014 0.015 0.022 0.060 0.098 0.103 0.113 0.126 0.133 0.129 0.126 0.124 0.126 0.106 0.082 0.086 0.106 0.119 0.117 0.116 0.121
0.013 0.015 0.013 0.010 0.012 0.014 0.017 0.023 0.023 0.069 0.126 0.134 0.127 0.123 0.109 0.095 0.093 0.108 0.116 0.121 0.122 0.126 0.118 0.119
0.015 0.017 0.015 0.005 0.011 0.019 0.016 0.010 0.008 0.049 0.112 0.112 0.099 0.085 0.063 0.080 0.110 0.121 0.125 0.127 0.125 0.125 0.120 0.111
0.013 0.016 0.012 0.009 0.014 0.018 0.015 0.007 0.004 0.020 0.035 0.036 0.026 0.020 0.053 0.118 0.128 0.123 0.122 0.126 0.129 0.123 0.121 0.097
0.011 0.015 0.012 0.008 0.017 0.020 0.014 0.011 0.012 0.015 0.013 0.015 0.007 0.020 0.105 0.130 0.132 0.123 0.118 0.119 0.119 0.122 0.100 0.037
0.012 0.012 0.011 0.009 0.009 0.010 0.012 0.016 0.014 0.014 0.016 0.015 0.008 0.042 0.127 0.133 0.125 0.114 0.103 0.107 0.117 0.103 0.052 0.023
0.014 0.014 0.014 0.009 0.012 0.005 0.011 0.015 0.014 0.014 0.013 0.013 0.011 0.034 0.105 0.108 0.090 0.071 0.036 0.061 0.091 0.053 0.017 0.059
0.015 0.013 0.014 0.014 0.009 0.007 0.010 0.012 0.012 0.014 0.015 0.015 0.012 0.017 0.030 0.031 0.027 0.022 0.015 0.018 0.024 0.014 0.015 0.068
0.016 0.014 0.011 0.013 0.010 0.010 0.017 0.016 0.011 0.012 0.015 0.014 0.015 0.013 0.016 0.016 0.018 0.016 0.016 0.013 0.012 0.012 0.013 0.038
0.014 0.012 0.008 0.015 0.010 0.009 0.017 0.017 0.013 0.013 0.012 0.013 0.012 0.014 0.017 0.013 0.010 0.014 0.016 0.014 0.015 0.013 0.045
0.010 0.011 0.013 0.014 0.015 0.010 0.011 0.012 0.014 0.015 0.016 0.013 0.013 0.017 0.013 0.018 0.010 0.014 0.014 0.016 0.012 0.015 0.055
0.012 0.012 0.012 0.013 0.013 0.013 0.014 0.014 0.013 0.012 0.014 0.014 0.014 0.014 0.015 0.014 0.012 0.012 0.013 0.014 0.014 0.014 0.011 0.057
0.015 0.014 0.014 0.014 0.015 0.015 0.014 0.014 0.018 0.016 0.010 0.018 0.016 0.015 0.019 0.011 0.006 0.012 0.014 0.012 0.016 0.010 0.002 0.042
0.014 0.014 0.014 0.011 0.010 0.015 0.018 0.015 0.015 0.020 0.009 0.011 0.014 0.013 0.014 0.013 0.013 0.012 0.012 0.012 0.014 0.012 0.014 0.016
0.014 0.011 0.014 0.014 0.013 0.017 0.019 0.020 0.018 0.014 0.016 0.013 0.016 0.016 0.007 0.006 0.012 0.009 0.011 0.011 0.011 0.012 0.015 0.014
0.016 0.014 0.013 0.013 0.013 0.014 0.010 0.014 0.017 0.015 0.016 0.013 0.015 0.015 0.012 0.012 0.013 0.013 0.014 0.014 0.014 0.014 0.017
```

#Output pattern 1:
1 0

Figura 6.2: Padrão utilizado pelo SNNS

O exemplo da figura 6.2 representa a forma com que os arquivos de treinamento e testes foram disponibilizados para que o SNNS pudesse simular a rede especificada. Neste trabalho, a rede especificada é uma MLP (Multi Layer Perceptron) com o algoritmo de treinamento *backpropagation*.

Foram treinadas sete redes neurais, cada qual possuindo três camadas: a primeira, de entrada n de 2500 neurônios, correspondendo à dimensão do padrão extraído (subimagem de dimensão 50x50); a camada intermediária, possuindo $2n$ neurônios, ou seja, duas vezes o número de neurônios de entrada; a terceira, possuindo duas saídas (0 e 1). Cada rede neural foi analisada como sendo um caso particular.

6.1.1 Caso 1 - Treinamento com 70 Padrões de Folha e 10 % de Erro

O treinamento foi realizado utilizando 70 imagens para treinamento, 50 imagens para validação durante o treinamento, sendo utilizado somente padrões de folhas tanto da planta picão, quanto de outras plantas, com margem de erro de 10 %. A taxa de aprendizagem (α) foi variada entre 0.2 e 0.9, tendo sido variada também a taxa momentum (μ) conforme convergia à taxa de erro. Foram necessários 800 ciclos para esse treinamento. O gráfico deste treinamento pode ser visto na figura 6.3.

Figura 6.3: Treinamento do Caso 1.

6.1.2 Caso 2 - Treinamento com 100 Padrões de Folha e 10 % de Erro

O treinamento foi realizado utilizando 100 imagens para treinamento, 70 imagens para validação durante o treinamento, com 10 % de tolerância ao erro. Assim como no primeiro treinamento, o α e o μ variaram entre 0.2 e 0.9, alternando os valores conforme a taxa convergência do erro. Foram utilizados padrões de folhas para treinamento. Com o aumento das imagens para treinamento, foram necessários 1000 ciclos para o treinamento. A figura 6.4 apresenta o gráfico deste treinamento.

Figura 6.4: Treinamento do Caso 2.

6.1.3 Caso 3 - Treinamento com 100 Padrões de Folha e 1 % de Erro

Este treinamento utilizou as mesmas condições do caso anterior, porém alterando a margem de erro de 10 % para 1 %. Na figura 6.5 é apresentado o gráfico deste treinamento.

Figura 6.5: Treinamento do Caso 3.

6.1.4 Caso 4 - Treinamento com 150 Padrões de Folha e 10 % de Erro

Neste treinamento foram utilizadas 150 imagens para treinamento, sendo 100 (cem) imagens para validação durante o treinamento, com apenas padrões de folhas, com margem de 10 % de erro. Assim como nos demais treinamentos, variaram o α e o μ entre 0.2 e 0.9, de acordo sempre com a convergência do erro. Para este treinamento, foram necessários 1500 ciclos para que a rede fosse treinada. O gráfico deste treinamento pode ser observado na figura 6.6.

Figura 6.6: Treinamento do Caso 4.

6.1.5 Caso 5 - Treinamento com 150 Padrões de Folha e 1 % de Erro

Este treinamento utilizou as mesmas imagens do treinamento anterior, alterando apenas a margem de erro de 10 % para 1 %. Este treinamento pode ser visualizado através do gráfico da figura 6.7.

Figura 6.7: Treinamento do Caso 5.

6.1.6 Caso 6 - Treinamento com 100 Padrões de Flor e Semente e 10 % de Erro

Neste treinamento foram utilizadas 100 imagens para treinamento e 70 imagens para validação durante o treinamento. Ao contrário dos demais treinamentos, foram utilizados padrões de flor e semente de picão, considerando uma margem de 10 % ao erro. Os valores de α e μ foram atribuídos conforme a convergência do erro, variando como nos demais casos. Foram necessários 1000 ciclos para o treinamento, podendo ser visto na figura 6.8.

Figura 6.8: Treinamento do Caso 6.

6.1.7 Caso 7 - Treinamento com 200 Padrões de Folha, Flor e Semente e 10% de Erro

Este treinamento reuniu vários tipos de padrões, ou seja, padrões de folhas, flor e picão seco, ou seja, todos os padrões que até então foram utilizados de forma isolada para treinamento. Foram utilizadas 200 imagens para treinamento, 120 imagens para validação, considerando uma margem de erro de 10 %. Pelo aumento da complexidade dos padrões e aumento do número de imagens para o treinamento, foram necessários 2000 ciclos para que a rede fosse treinada. O gráfico deste treinamento pode ser visualizado na figura 6.9.

Figura 6.9: Treinamento do Caso 7.

A tabela 6.1 apresenta um resumo comparativo entre os treinamentos dos 7 casos apresentados anteriormente.

Tabela 6.1: Tabela Comparativa de Treinamento

Casos	NPT	TP	NPV	PTE	NC	TT
Caso1	70	1	50	10	800	16
Caso2	100	1	70	10	1000	22
Caso3	100	1	70	1	1000	23
Caso4	150	1	100	10	1500	48
Caso5	150	1	100	1	1500	49
Caso6	100	2	70	10	1000	22
Caso7	200	3	120	10	2000	72

NPT: número de padrões utilizados para treinamento.

TP: tipo de padrão.

NPV: número de padrões utilizados para validação.

PTE: porcentagem de erro (tolerância).

NC: número de ciclos.

TT: média de tempo de treinamento em horas.

Tipos de Padrões:

1: Folha.

2: Flor e semente (picão seco).

3: Folha, flor e semente.

O treinamento foi realizado remotamente em máquinas Pentium III Dual, com 1 GHZ cada processador. O tempo de treinamento foi considerado com relação a disponibilidade da máquina para processar e o número de padrões de treinamento.

6.2 Testes Realizados

Nesta seção são apresentados os resultados obtidos nos testes realizados com as redes neurais treinadas e descritos anteriormente. Para os testes, foram utilizadas 250 novas imagens.

6.2.1 Teste da Rede do Caso 1

Das 250 imagens houve um acerto de 78 %, correspondente a 195 imagens. Das 55 imagens restantes, 22 % foram classificadas erroneamente, 18 correspondendo a imagens da planta picão e 37 de outras plantas.

Das 18 imagens da planta picão classificadas erroneamente, em 3 houve indecisão. Das 37 imagens de outras plantas, em 6 houve indecisão.

6.2.2 Teste da Rede do Caso 2

Das 250 imagens testadas, o acerto foi de 84 %, correspondentes a 210 imagens e 16 %, 40 imagens, classificadas erroneamente. Destas 40 imagens, 4 representavam imagens da planta picão e 36 das demais plantas.

Das 4 imagens classificadas erroneamente da planta picão, 1 foi classificada com indecisão. Das 36 imagens de outras plantas classificadas erradamente, 3 foram classificadas com indecisão.

6.2.3 Teste da Rede do Caso 3

Das 250 imagens testadas, houve um acerto de 87 % correspondentes a 218 imagens; havendo um aumento de 3 % no acerto comparando ao teste do Caso 2, pela alteração da margem de erro no treinamento de 10 % para 1 %. Das 32 imagens classificadas erroneamente (13 %), 9 correspondem a planta picão e 23 a outras plantas.

Das 9 imagens classificadas erroneamente da planta picão, 2 foram classificadas com indecisão. Para as 23 imagens de outras plantas, 4 foram classificadas com indecisão.

6.2.4 Teste da Rede do Caso 4

Das 250 imagens testadas, houve um acerto de 90.4 %, correspondentes a 226 imagens, com erro de 9.6 %, correspondentes a 24 imagens. Dessas 24 imagens, 10 correspondem a planta picão e 14 a outras plantas.

Das 10 imagens classificadas erroneamente para a planta picão, 2 foram classificadas com indecisão. Para as 14 imagens de outras plantas, 5 foram classificadas com indecisão.

6.2.5 Teste da Rede do Caso 5

Das 250 imagens testadas, houve um acerto de 92 %, correspondendo a 230 imagens, representado um aumento de acerto de aproximadamente 2 % em relação ao caso 4, que utilizou as mesmas imagens de treinamento, com uma margem de erro reduzida 10 % para 1 %.

Das 20 imagens classificadas como erradas (8 %), 8 foram da planta picão e 12 de outras plantas. Das 8 imagens classificadas erroneamente para a planta picão, 2 foram classificadas com indecisão. Da mesma forma, entre as 12 imagens de outras plantas classificadas erroneamente, 3 foram classificadas com indecisão.

6.2.6 Teste da Rede do Caso 6

Das 250 imagens testadas, houve um acerto de 91 % correspondente a 227 imagens, com erro de 9 %, correspondente a 23 imagens.

Das 23 imagens classificadas erroneamente, 9 foram da planta picão e 14 de outras plantas. Das 9 imagens classificadas erroneamente da planta picão, 3 foram classificadas com indecisão. Da mesma forma, das 14 imagens classificadas erroneamente para as outras plantas, 4 foram classificadas com indecisão.

6.2.7 Teste da Rede do Caso 7

Das 250 imagens testadas, houve um acerto de 82.4 % correspondendo a 206 imagens e erro de 17.6 %, representando 44 imagens.

Das 44 imagens classificadas erroneamente, 5 foram da planta picão e 39 de outras plantas. Dessas 5, 1 foi classificada com indecisão. Das 39 imagens classificadas erroneamente das demais plantas, 5 foram classificadas com indecisão.

A tabela 6.2 apresenta um resumo comparativo entre os testes realizados nos 7 casos.

Tabela 6.2: Tabela Comparativa dos Testes

Casos	NPT	PA	NA	PTE	NTE	NEP	NIP	NEDP	NIDP
Caso1	250	78	195	22	55	15	3	31	6
Caso2	250	84	210	16	40	3	1	33	3
Caso3	250	87	218	13	23	7	2	19	4
Caso4	250	90.4	226	9.6	24	8	2	8	5
Caso5	250	92	230	8	20	6	2	9	3
Caso6	250	91	227	9	23	6	3	10	4
Caso7	250	82.4	206	17.6	44	4	1	34	5

NPT: número de padrões de teste.

PA : porcentagem de acertos.

NA : número total de acertos .

PTE: porcentagem total de erros.

NTE: número total de erros.

NEP: número de erros com padrão da planta picão.

NIP: número de indecisos com padrão da planta picão.

NEDP: número de erros com padrão das demais plantas.

NIDP: número de indecisos com padrão das demais plantas.

6.3 Análise dos Resultados

Dos resultados descritos, pode-se perceber que um aumento no número de padrões de teste utilizados para treinamento resultou um aumento na taxa de acerto. Pode existir, portanto, a possibilidade de treinamento mais intensivo com melhoria ainda maior da taxa de acerto. Também se pode perceber que, ao alterar a taxa de margem de erro no treinamento de 10% para 1 %, houve um aumento pequeno, porém significativo, da taxa de acerto. Margens de erro menores podem ser tentadas para aumentar a taxa de acerto. O longo tempo de treinamento das redes foi o principal fator limitante do número de tentativas de treinamento.

No caso 7 a rede foi treinada para reconhecer cada um dos padrões testados individualmente nos outros casos. O resultado demonstra a viabilidade dessa alternativa embora a taxa de acertos tenha sido reduzida de forma significativa.

Esse resultado é importante, pois permite a adoção dos dois procedimentos conforme a complexidade de reconhecimento de cada espécie de planta invasora no sistema final de reconhecimento. Espécies de reconhecimento mais simples que o picão podem ser tratadas por uma única rede neural, considerando todas as características da planta em seus diversos estágios de desenvolvimento. Espécies de reconhecimento mais complexo podem utilizar diversas redes neurais, cada uma treinada para reconhecer uma ou mais características dos estágios de desenvolvimento da planta.

De uma forma geral, os testes demonstram a viabilidade da utilização de redes neurais para o reconhecimento de plantas invasoras em tempo real, embora testes para avaliar o tempo de processamento não tenham sido realizados. Os índices de acerto obtidos permitem a montagem de mapas de infestação baseados na presença das invasoras nas subimagens. O grau de infestação pode estar relacionado com o nível de agrupamento das subimagens com detecção positiva.

Capítulo 7

Conclusões

A identificação de plantas invasoras vem ganhando importância no contexto da agricultura de precisão, possibilitando a aplicação seletiva de defensivos e permitindo a obtenção de produtos agrícolas mais baratos com menor impacto ao meio ambiente.

Neste trabalho foi apresentado um sistema de identificação de plantas invasoras em tempo real. O sistema foi parcialmente implementado, para identificar uma única planta invasora, para validar o desenvolvimento de um sistema de identificação de plantas invasoras de diversos tipos. Foram utilizadas técnicas de processamento digital de imagens, particularmente técnicas baseadas em redes neurais artificiais.

Para o desenvolvimento do sistema de identificação de plantas invasoras em tempo real, foram revistos conceitos básicos relacionados à agricultura de precisão, técnicas e equipamentos utilizados para o controle de plantas invasoras. Foram revistos também, conceitos importantes no desenvolvimento de um sistema de identificação, como técnicas de processamento digital de imagens para classificação dos padrões de imagens em tempo real.

A tarefa de identificar plantas invasoras constitui uma operação complexa, considerando os diversos estágios de desenvolvimento das plantas com aparências bastante diferentes. Devido a esta complexidade, foram encontradas muitas dificuldades na escolha das técnicas para o sistema de identificação, exigindo um grande esforço e tempo de aprendizagem.

O projeto do desenvolvimento do sistema de identificação de plantas invasoras em tempo real utilizou um simulador de redes neurais, SNNS, no qual possibilitou que os testes fossem realizados. Este sistema de identificação consiste basicamente no armazenamento das imagens adquiridas, gerando subimagens para análise pela rede neural. Essas subimagens são

representadas por arquivos texto através da utilização da técnica de análise de componentes principais, PCA, Hotteling.

A utilização do sistema de identificação com o auxílio do simulador SNNS, juntamente com a utilização do software de geração automática de subimagens para análise, mostrou-se muito eficiente, além demonstrando a possibilidade de expansão deste sistema para as demais plantas de ocorrência comum no Brasil.

7.1 Contribuições do Trabalho

A principal contribuição deste trabalho foi demonstrar a possibilidade prática do desenvolvimento de um sistema de identificação de plantas invasoras em tempo real com a utilização de redes neurais artificiais. Além dessas contribuições, outras também foram importantes:

- Estudo dos sistemas de identificação propostos por outros pesquisadores. Este estudo auxiliou na decisão da melhor técnica para utilização neste trabalho;
- Desenvolvimento de um gerador de subimagens para treinamento e testes de identificação utilizando o SNNS;
- Estudo e determinação das plantas invasoras de maior ocorrência no cerrado do centro oeste brasileiro em culturas de milho e soja;
- Obtenção de algumas centenas de imagens das plantas invasoras em campo, em diferentes estágios de desenvolvimento, formando uma base de imagens importante para a continuidade do trabalho.

7.2 Trabalhos Futuros

Devido a complexidade do projeto, a gama de tarefas restantes a serem realizadas e o curto tempo disponível para o seu desenvolvimento dentro de um programa de mestrado, torna-se importante a execução de vários outros trabalhos correlatos:

- Implementação das redes neurais utilizadas no desenvolvimento deste trabalho e determinação do tempo necessário para o processamento das várias subimagens compo-

nentes de cada foto, verificando a potência computacional do hardware necessário para operação em tempo real;

- Teste de outros tipos de rede neural, inclusive redes neurais não supervisionadas, para acompanhar o comportamento na classificação dos tipos de padrões das plantas invasoras utilizadas neste trabalho;
- Geração automática de mapas de plantas invasoras considerando a sua identificação e heurísticas para determinação da sua densidade populacional;
- Desenvolvimento de um sistema que não apenas identifique a planta invasora, mas classifique-a de acordo com o herbicida necessário para a sua eliminação.
- Implementação em hardware da rede neural para o sistema de identificação em tempo real.

Referências Bibliográficas

- [ACC 02] ACCORSI, W. **Enciclopédia das Plantas**, 2002.
<http://www.ervasdositio.com.br>.
- [ALB 00] ALBUQUERQUE, M. P. **Processamento de imagens: Métodos e Análises**. Centro Brasileiro de Pesquisas Físicas-CBPF/MCT, Outubro, 2000.
<http://152.84.50.20/curso2.htm>.
- [ART 99] ARTERO, A. O. **Técnicas para extração automática de feições retas em imagens digitais**. Dezembro, 1999. Presidente Prudente: Universidade Estadual Paulista.
- [BAN 90] BANKS, S. **Signal processing, image processing and pattern recognition**. Prentice Hall, 1990.
- [BAN 97] BANON, G. J. F. Morphological approach for template matching. In: X SIMPOSIO BRASILEIRO DE COMPUTAÇÃO GRÁFICA E PROCESSAMENTO DE IMAGENS - SIBGRAPI'97, 1997. **Proceedings...** Campos do Jordão, São Paulo:[s.n.], 1997.
- [BAR 97] BARATTO, G. **Classificador de Aromas com Redes Neurais Artificiais para um Nariz Eletrônico**. 1997. Universidade de São Paulo - Departamento de Engenharia Elétrica.
- [BEC 96] BECKER, S. Unsupervised neural network learning procedures for feature extraction and classification. **Applied Intelligence, Special Issue on Applications of Neural Networks**, [S.l.], v.6, n.3, p.1–25, 1996.

- [BEE 97] BEER, R. **Histogram-Based Methods.** Instituto Nacional de Pesquisas Espaciais-INPE, Março, 1997. <http://dutnsic.tn.tudelft.nl:8080/main/node50.html>.
- [BER 99] BERTASI, D. **Reconhecimento de caracteres utilizando Redes Neurais Artificiais.** Universidade Federal do Rio Grande do Sul-UFRGS, 1999. <http://www.inf.ufrgs.br/procpar/disc/cmp135/trabs/992/Recon/trab2.html>.
- [BRA 95] BRAGA, H. J. **Previsão Agrícola: Uma Nova Abordagem.** Março, 1995. Universidade Federal de Santa Catarina - UFSC.
- [BRI 98] BRITO, S. F. **Estudo, Seleção e Implementação de Algoritmos de Segmentação.** Universidade Federal da Paraíba-UFPB, Agosto, 1998. <http://www.dee.ufpb.br/acsi/relsergio/fonte.html>.
- [BRI 99] BRITO, S. F. **Detecção de Regiões.** Universidade Federal da Paraíba-UFPB, Janeiro, 1999. <http://www.dee.ufpb.br/acsi/>.
- [CAM 00] CAMPOS, T. E. Reconhecimento de padrões. Monografia para o exame de qualificação, Setembro, 2000.
- [CAP 97a] CAPELLI, N. L. **Agricultura de Precisão, Novas Tecnologias para o Processo Produtivo.** Embrapa, 1997. <http://wwwbases.cnptia.embrapa.br/cria/gip/gipap/capelli.htm>.
- [CAP 97b] CAPPELARO, E. A.; MENDONÇA, F. C. **Câmeras Digitais,** 1997. <http://www.educar.sc.usp.br/licenciatura/trabalhos/camera.htm>.
- [CHI 01] CHIP, Z. S. O. A. **Megapixel CMOS Image Sensors,** 2001. <http://www.zoran.com/products/camera/arquity.asp>.
- [COS 01] COSTA, L. D. F. **Shape Analysis and Classification.** CRC Press, 2001.
- [DOR 00] DORIA, V. C. **Reconhecimento de Padrões.** Universidade Federal de Pernambuco, Junho, 2000. <http://www.cin.ufpe.br/if114/Monografias/Reconhecimento/>.

- [DRU 00] DRUMMOND, S. T.; SUDDUTH, K. A. Predictive ability of neural networks for site specific yield estimation. In: SECOND INTERNATIONAL GEOSPATIAL INFORMATION IN AGRICULTURE AND FORESTRY CONFERENCE, 2000. **Proceedings...** Lake Buena, Florida:[s.n.], 2000. p.1–8.
- [EF 00a] EL-FAKI, M. S.; ZHANG, N. Factors affecting color-based weed detection. **Transactions of the ASAE**, [S.l.], v.43, n.4, p.1001–1009, Maio, 2000.
- [EF 00b] EL-FAKI, M. S.; ZHANG, N. Weed detection using color machine vision. **Transactions of the ASAE**, [S.l.], v.43, n.6, p.1969–1978, Agosto, 2000.
- [FRA 91] FRANZ, E.; GEBHARDT, M. R. The use of local spectral properties of leaves as an aid for identifying weed seedling in digital images. **Transactions of the ASAE**, [S.l.], v.34, n.2, p.682–687, 1991.
- [FRA 98] FRANZONI, A. M. B.; ÉDIS MAFRA LAPOLLI. O uso de sensoriamento remoto na caracterização do meio físico visando o estudo do sistema viário. In: III ENCONTRO IBERO-AMERICANO DE UNIDADES AMBIENTAIS DO SETOR DE TRANSPORTES, 1998. **Proceedings...** Santa Catarina:[s.n.], 1998.
- [FRI 98] FRIEDLAENDER, G. M. S. **Verificação de Assinaturas Manuscritas OFF-LINE: Uma abordagem utilizando modelos estatísticos**. Setembro, 1998. Florianópolis/SC: Universidade Federal de Santa Catarina.
- [GAM 00] GAMA, A.; IGOR, A. **Lógica Fuzzy**. Universidade Federal da Bahia - UFBA, Laboratório de Ensino a Distância, Junho, 2000. <http://led.ufba.br/algebra1a/trab6/>.
- [GAZ 01] GAZZIERO, D. L. P. **Plantas Daninhas**. Embrapa, 2001. <http://www.cnpso.embrapa.br/plantdan.htm>.
- [GON 92] GONZALEZ, R. C. **Processamento Digital de Imagens**. Addison-Wesley Publishing Company, Inc., 1992.
- [GON 96] GONZAGA, A. **Algoritmos de Detecção de Bordas em Imagens Digitais**. Escola de Engenharia de São Carlos - EESC-USP, outubro, 1996. <http://www.sel.eesc.sc.usp.br/sel/lavi/tecreport/TR-SEL-LAVI-00296/>.

- [GON 00] GONZAGA, A. **Manual de Visão Computacional**. Escola de Engenharia de São Carlos - EESC-USP, 2000.
- [GRA 83] GRAYBILL, F. A. **Matrices with Applications in Statistics**. 2nd Edition, Ed.Belmont, 1983.
- [GUY 93] GUYER, D. E. et al. Application of machine vision to shape analysis in leaf and plant identification. **Transactions of the ASAE**, [S.l.], v.36, n.1, p.163–171, Janeiro-Fevereiro, 1993.
- [HAF 95] HAFNER, J. et al. Efficient color histogram indexing for quadratic form distance functions. **IEEE Transaction on Pattern Analysis and Machine Intelligence**, [S.l.], v.17, n.7, p.729–736, Julho, 1995.
- [HEA 92] HEALEY, G. Segmentation images using normalized color. **IEEE Transation on Systems man and Cybernetics**, [S.l.], v.22, n.1, p.64–73, Janeiro, 1992.
- [HER 96] HERAS, D. B. et al. Principal component analysis on vector computers. In: VECPAR, 1996. **Proceedings...** Porto, Portugal:[s.n.], 1996. p.416–428.
- [HOF 02] HOFFMANN, R. A.; WOZNIACK, R. **Homeopharma**, 2002. <http://www.homeopharma.com.br>.
- [HOT 33] HOTTELING, H. Analysis of a complex of statistical variables into principal components. **Education Psychology**, [S.l.], v.24, p.417–441, 498–520, 1933.
- [INP 01] INPE. **Processamento de Imagem**. Instituto Nacional de Pesquisas Espaciais-INPE, Março, 2001. <http://www.dpi.inpe.br/spring/CURSO/>.
- [JAH 97] JAHNE, B. **Digital Image Processing**, v.4. Springer, 1997.
- [JAI 89] JAIN, A. K. **Fundamentals of Digital Image Processing**. Prentice Hall, 1989.
- [JAI 95] JAIN, R.; KASTURI, R. **Machine Vision**, v.15. Mc Graw Hill, 1995.
- [JOR 01] JORGE, L. A. C. **Reconhecimento Automático da Cobertura do Solo em Fotografias Aéreas obtidas no Projeto ARARA**. Dezembro, 2001. São Carlos: Universidade de São Paulo.

- [JOS 99] JOSE, P. S. **Resistência das Plantas Daninhas aos Herbicidas.** Universidade Federal de Lavras - Núcleo de Estudo de Genética, Janeiro, 1999. <http://www.nucleoestudo.ufla.br/gen/publicacoes/revista/semi00s/paulosergio.htm>.
- [JUN 96] JUNIOR, J. Z. et al. Pré-processamento das imagens de satélite. **Caderno de Informações Georeferenciadas - CIG**, [S.l.], v.1, n.7, 1996.
- [JUN 01] JUNIOR, W. L. **Redes Neurais**, 2001. <http://williamlauer.hpg.com.br/neurais.htm>.
- [LEV 85] LEVINE, M. D. **Vision in Man and Machine.** MacGraw-Hill Series in Electrical Engineering, 1985.
- [LIM 01] LIMA, I. **Aplicações de processamento de sinal e imagem.** Faculdade de Engenharia da Universidade do Porto -FEUP (Portugal), 2001. <http://www.fe.up.pt/ee94010/>.
- [MAR 98] MARCHANT, J. A.; TILLET, R. D. Real-time segmentation of plants and weed. **Real-Tie Imaging**, [S.l.], v.4, n.ri970086, p.243–253, 1998.
- [MED 99] MEDEIROS, J. S. **Banco de Dados Geográficos e Redes Neurais Artificiais: tecnologia de apoio à gestão do território.** julho, 1999. Universidade de São Paulo - Departamento de Geografia da Faculdade de Filosofia, Letras e Ciências Humanas.
- [MEN 00] MENDES, J. M. **Aplicação de algoritmos no reconhecimento de padrões gerados por sensores ópticos.** 2000. São Paulo: Universidade de São Paulo-Engenharia Elétrica.
- [MIC 01] MICROSSISTEMAS, S. I. E. **Classificador com Redes Neurais.** Escola Politécnica da Universidade de São Paulo, 2001. <http://sim.lme.usp.br/linhas/iinteligente/rneurais/rneu.html>.
- [MOL 97] MOLIN, J. P. Agricultura de precisão, parte i: O que é e estado da arte em sensoriamento. **Engenharia Agrícola**, [S.l.], v.17, n.2, p.97–107, Dezembro, 1997.

- [MOR 67] MORRISON, F. D. **Multivariate Statistical Methods**. 2nd Edition, McGraw-Hill Book Company, 1967.
- [MOR 97] MORAN, M. S.; INOUE, Y. Opportunities and limitations for image-based remote sensing in precision crop management. **USDA-ARS U.S. Water Conservation Laboratory**, United States, v.61, p.319–46, Janeiro, 1997.
- [NIS 98] NISHIDA, W. **Uma Rede Neural Artificial para Classificação de Imagens Multiespectrais de Sensoriamento Remoto**. Fevereiro, 1998. UFSC - Universidade Federal de Santa Catarina.
- [OLI 97] OLIVEIRA, P. R. **Redes Neurais Artificiais para Extração de Características**. Outubro, 1997. São Carlos: Universidade de São Paulo.
- [PAC 98] PACHECO, A. P. **Sensoriamento Remoto Aplicado ao Uso da Terra**. Universidade Federal de Pernambuco, UFPE Recife, Abril, 1998. <http://geodesia.ufsc.br/Geodesia-online/ARQUIVO/2001/xx/PACHECO.HTM>.
- [PAC 01] PACHECO, A. P. **Sensoriamento Remoto Multitemporal aplicado à Cobertura Vegetal da Mata Atlântica**. Universidade Federal de Pernambuco- UFPE Recife, Janeiro, 2001. <http://geodesia.ufsc.br/Geodesia-online/ARQUIVO/2001/01>.
- [PAR 99] PARVIS, M. A measurement system for on-line estimation of weed coverage. **IEEE Transactions on Instrumentations and Measurement**, [S.l.], v.48, n.5, p.990–994, Outubro, 1999.
- [PER 00] PEREZ, A. J. et al. Colour and shape analysis techniques for weed detection in cereal fields. **Computers and Electronics in Agriculture**, [S.l.], v.25, p.197–212, 2000.
- [PHO 83] PHOTOGRAMMETRY, A. S. **Manual of Remote Sensing**, 1983.
- [PIE 99] PIERRE, F. J. Aspects of precision agriculture. **Advances in Agronomy**, [S.l.], v.67, p.1–67, 1999.

- [PRE 92] PRESS, W. H. et al. **Numerical Recipes in C**. Cambridge University Press, 1992. The Art of Scientific Computing, Second Edition.
- [RIS 96] RISSLER, J. The ecological risks of engineered crops, 1996.
- [RUS 95] RUSS, J. C. **The Image Proccesing - Handbook**. CRC Press, 1995.
- [SAH 88] SAHOO, P. K.; SOLTANI, S. An survey of thresholding techniques. **Graphics and Image Processing**, United States, v.41, p.233–260, 1988.
- [SCH 89] SCHALKOFF, R. J. **Digital Image Processing and Computer Vision**. Addison-Wesley Publishing Company,Inc., 1989.
- [SCH 01] SCHMOLDT, D. L. Precision agriculture and information technology. **Computers and Electronics in Agriculture - ELSEVIER**, [S.l.], v.1, n.30, p.5–7, 2001.
- [SCI 97] SCIENCE, S. C. **Fuzzy**. Carnegie Mellon University, Agosto, 1997. <http://www.cs.cmu.edu/Groups/AI/html/faqs/ai/fuzzy/>.
- [SHE 90] SHEARER, S. A. Plant identification using color co-occurrence matrices. **Transactions of the ASAE**, [S.l.], v.33, n.6, p.2037–2044, Novembro-Dezembro, 1990.
- [SIL 97] SILVEIRA, G. M. Ervas daninhas devem ser controladas, Novembro, 1997.
- [SON 98] SONKA, S. T.; BAUER, M. E. **Public Policy and Precision Agriculture**. National Academy Press, 1998. 90-119p.
- [SON 99] SONKA, M.; HLAVAC, V. **Image Processing, Analysis, and Machine Vision**. PWS Publishing, 1999.
- [SUD 97] SUDDUTH, K. A.; HUMMEL, S. W. Sensor for site-specific management. **The Site-Specific Management for Agriculture Systems**, United States, v.1, p.183–210, 1997.
- [TAN 99] TANG, L. et al. Texture-based weed classification using gabor wavellet and neural network for real-time selective herbicide applications. In: ASAE, 1999. **Proceedings...** St. Joseph, MI:[s.n.], 1999. 991151, p.1–14.

- [TEO 90] TEOTIA, H. et al. Digital image processing and gis applications for natural resources monitoring and evaluation in northeastern brazil. In: VII SYMPOSIUM ON GLOBAL AND ENVIRONMENTAL MONITORING, 1990. **Proceedings...** Canadá:[s.n.], 1990. p.347–357.
- [TIP 99] TIPPING, M. E. Probabilistic principal component analysis. **Royal Statistical Society**, [S.l.], v.serie B, n.61 - par 3, p.611–622, Setembro, 1999.
- [ULB 95] ULBRICHT, K. et al. Photogrammetry and remote sensing. **ISPRS**, [S.l.], v.5, n.50, p.31–32, 1995.
- [VEI 99] VEIRA, Z. P. Implementação do servocontrole auto-sintonizado em tempo real utilizando rede perceptron multicamadas. In: IV CONGRESSO BRASILEIRO DE REDES NEURAIS, 1999. **Proceedings...** Rio de Janeiro, RJ:[s.n.], 1999. p.308–313.
- [VEL 00] VELHO, L. **Image Processing for Vision and Graphics**, 2000. <http://www.visgraf.impa.br/Courses/ip00/proj/Deconv/ruido.htm>.
- [YAN 00] YANG, C. C. et al. Application of artificial neural networks in image recognition and classifications of crop and weeds. **Canadian Agricultural Engineering**, [S.l.], v.42, n.3, p.147–152, Julho-Agosto-Setembro, 2000.

Apêndice A

Principais Plantas Invasoras

Em visita à Fazenda Campo Bom, na cidade de Chapadão do Sul, Mato Grosso do Sul, foram feitas várias fotografias de plantas invasoras predominantes em culturas de milho e soja. Algumas dessas plantas não só aparecem nessas culturas, mas também em vários outros locais, incluindo jardins. A seguir são apresentadas algumas plantas invasoras relacionadas nessa pesquisa, suas características e o grau de infestação, segundo a simbologia abaixo:

- +++ para muita infestação;
- ++ - para uma média-alta infestação;
- + - - para uma média-baixa infestação;
- - - - para uma baixíssima infestação.

Nome popular: Timbete/Carrapicho

Nome científico: Cenchrus Echinatus

Características: Folhas espinhentas de 10 a 30 cm de comprimento

Infestação: +++

Nome popular: Falsa Serralha

Nome científico: Emilia Sonchifolia

Características: Folhas pecioladas, flor de cor vermelha

Infestação: ++-

Nome popular: Cheirosa/ Salva Limão

Nome científico: Hyptis Suaveolens

Características: Planta aromática, folhas pubescentes de 4 a 10 cm de comprimento, caule quadrangulado

Infestação: +++

Nome popular: Capim Amargoso

Nome científico: Digitaria Insularis

Características: Planta ereta, folhas ligeiramente ásperas de 15 a 25 cm de comprimento

Infestação: +++

Nome popular: Mentrasto/ picão roxo
Nome científico: *Ageratum Conyzoides*
Características: Planta ereta, folhas denso-pubescentes de 4 a 9 cm de comprimento, flor roxeada
Infestação: +++

Nome popular: Picão preto
Nome científico: *Bidens Pilosa*
Características: Planta ereta, folhas superiores eventualmente de 5 a 10 cm de comprimento, flor amarelada
Infestação: +++

Nome popular: Cordão de Frade
Nome científico: *Leonotis Nepetaefolia* L.
Características: Planta ereta, folhas de 5 a 10 cm de comprimento, flor com algumas pétalas alaranjadas
Infestação: - - -

Nome popular: Sorgo Selvagem
Nome científico: *Sorghum Arundinaceum*
Características: Planta ereta, Colmos com nós pubescentes, folhas áspero-pubescentes de 30 a 60 cm de comprimento
Infestação: +++

Nome popular: Custódio

Nome científico: Pennisetum Setosum

Características: Planta entoucerada, ereta, Colmos levemente pigmentados (roxeadas)

Infestação: + - -

Nome popular: Guanxuma

Nome científico: Sida Santaremnensis

Características: Planta fibrosa, ereta, caule com duas protuberâncias, flor branca com o centro amarelado

Infestação: +++

Nome popular: Capim favorito/ Favorito

Nome científico: Rhynchelytrum Repens

Características: Planta ereta e ornamental quando flor (avermelhada); colmos glabros de 30 a 60 cm de altura

Infestação: +++

Nome popular: Joá de Capote

Nome científico: Nicandra Physaloides

Características: Planta ereta, robusta, caule glabro, folhas glabras de 7 a 14 cm de comprimento, flor roxeada

Infestação: +++

Nome popular: Capim colonião

Nome científico: Panicum Maximum

Características: Planta robusta; colmos com densa pilosidade nos nós, folhas glabras de 20 a 70 cm de comprimento

Infestação: +++

Nome popular: Fedegoso

Nome científico: Senna Occidentalis

Características: Planta lenhosa, ereta; folhas compostas, com 4 a 6 pares de folíolos de 6 a 7 cm de comprimento

Infestação: ++-

Nome popular: Campim Marmelada

Nome científico: Brachiaria Plantaginea

Características: Planta ereta; colmos com enraizamento nos nós; folhas glabras de 10 a 25 cm

Infestação: +++

Nome popular: Campim Braquiária

Nome científico: Brachiaria Decumbens

Características: Planta ereta; folhas densamente pubescentes de 10 a 20 cm de comprimento

Infestação: +++

Nome popular: Campim pé-de-galinha

Nome científico: Eleusine Indica

Características: Planta fortemente enraizada ereta; folhas de 7 a 30 cm de comprimento

Infestação: ++-

Nome popular: Capim Colchão

Nome científico: Digitaria Horizontalis

Características: Planta ereta; colmo com enraizamento no nós; folhas de 6 a 12 cm de comprimento

Infestação: +++

Nome popular: Trapoeraba

Nome científico: Commelina
Benghalensis

Características: Planta tenra; folhas pubescentes de 6 a 12 cm de comprimento

Infestação: +++

Nome popular: Carrapicho carneiro

Nome científico: Acanthospermum
Hispidum

Características: Planta espinhenta; folhas pubescentes de 4 a 12 cm de comprimento

Infestação: ++-

Nome popular: Carrapichinho

Nome científico: Acanthospermum
Australe

Características: Planta herbácea; folhas
de 1 a 4 cm de comprimento

Infestação: ++-

Nome popular: Caruru-gigante/ caruru

Nome científico: Amaranthus retroflexus

Características: Planta ereta; caule
geralmente de coloração avermelhada na
parte inferior

Infestação: - - -

Nome popular: Crista de Galo

Nome científico: Amaranthus Hybridus

Características: Planta ereta; caule
pigmentado; inflorescência pigmentada
(roxeada), ou sem pigmentação

Infestação: ++-

Nome popular: Corda de viola

Nome científico: Ipomoea Acuminata

Características: Planta trepadeira; folhas
pubescentes de 7 a 14 cm de comprimento;
flores roxeadas

Infestação: +++

Nome popular: Corda de viola

Nome científico: Ipomoea Grandifolia

Características: Planta trepadeira; folhas de forma irregular (inteiras e trilobadas) de 4 a 8 cm de comprimento; flores rosadas com centro de pigmentação mais forte

Infestação: +++

Nome popular: Corda de viola

Nome científico: Ipomoea Hederifolia

Características: Planta trepadeira, esparsamente pubescente; folhas de forma bastante irregular (inteira e trilobada) de 6 a 12 cm de comprimento; flores vermelhas

Infestação: +++

Nome popular: Tiririca

Nome científico: Cyperus Iria

Características: Planta medianamente entouceirada; folhas em número de 2 a 3, mais curtas que o caule

Infestação: - - -

Nome popular: Erva Quente

Nome científico: Spermacoce Latifolia

Características: Planta prostrada; caule tetragonal pubescentes; folhas de 3 a 8 cm de comprimento

Infestação: +++

Nome popular: Leiteira

Nome científico: Euphorbia Heterophylla

Características: Planta lactescente, ereta; folhas pubescentes, quando adulta, há presença de "sementes-gomos" ao centro

Infestação: +++

Nome popular: Beldroega

Nome científico: Portulaca Oleracea

Características: Planta succulenta, glabra, prostrada; folhas carnosas de 1 a 3 cm de comprimento

Infestação: - - -

Nome popular: Fedegoso Branco/
Fedegoso

Nome científico: Senna Obtusifolia

Características: Planta ereta; folhas compostas, com 3 pares de folíolos de 3 a 5 cm de comprimento

Infestação: ++-

Nome popular: Guanxuma Branca/
guanxuma

Nome científico: Sida Glaziovii

Características: Planta ereta, fibrosa; folhas lanuginosas; flores brancas de centro amarelado

Infestação: ++-

Glossário das Plantas Invasoras

Colmo - o caule especializado das gramíneas e ciperáceos.

Denso - que tem muita massa.

Entoucerado - robusto; forte; espesso; grosso.

Ereto - erguido; levantado.

Folíolos - as menores divisões de uma folha composta.

Glabro - que não tem pêlos; liso.

Herbácea - planta desprovida de caule lenhoso e persistente.

Inflorescência - agrupamento de flores.

Lactescente - que contém latex.

Lanuginoso - pubescência com textura de lã.

Lenho - principal tecido de sustentação e condução da seiva bruta nos caules e raízes.

Lenhoso - que tem aspecto, consistência do lenho.

Lobada - que contém lobos.

Lobo - qualquer segmento de um órgão, especialmente se arredondado.

Ornamental - relativo a ornamento; aquilo que enfeita; adorno.

Peciolado - que contém pecíolos.

Pecíolo - ramo que sustenta uma folha.

Pigmentado - de coloração aroxeadada ou avermelhada.

Pilosidade - planta pilosa, que contém pêlos longos, retos e macios.

Prostrado - deitado sobre o chão.

Protuberância - saliência.

Pubescente - revestido com qualquer tipo de pêlo.

Robusto - forte; resistente.

Suculento - carnosos; cheio de suco.

Tenro - macio; novo; pouco crescido.

Tetragonal - quadrângulo; quadrilátero.