

UNIVERSIDADE FEDERAL DE SÃO CARLOS
CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

Desenvolvimento de Descritores de Imagens para
Reconhecimento de Padrões de Plantas Invasoras
(Folhas Largas e Folhas Estreitas)

ANA PAULA DE OLIVEIRA SANTOS

São Carlos
Junho/2009

**Ficha catalográfica elaborada pelo DePT da
Biblioteca Comunitária da UFSCar**

S237dd

Santos, Ana Paula de Oliveira.

Desenvolvimento de descritores de imagens para reconhecimento de padrões de plantas invasoras (folhas largas e folhas estreitas) / Ana Paula de Oliveira Santos. -- São Carlos : UFSCar, 2009.
185 f.

Dissertação (Mestrado) -- Universidade Federal de São Carlos, 2009.

1. Processamento de imagens. 2. Reconhecimento de padrões. 3. Erva daninha. 4. Agricultura de precisão. I. Título.

CDD: 006.42 (20^a)

Universidade Federal de São Carlos
Centro de Ciências Exatas e de Tecnologia
Programa de Pós-Graduação em Ciência da Computação

“Desenvolvimento de Descritores de Imagens para
Reconhecimento de Padrões de Plantas Invasoras
(Folhas Largas e Folhas Estreitas) ”

ANA PAULA DE OLIVEIRA SANTOS

Dissertação de Mestrado apresentada ao
Programa de Pós-Graduação em Ciência da
Computação da Universidade Federal de São
Carlos, como parte dos requisitos para a
obtenção do título de Mestre em Ciência da
Computação

Membros da Banca:



Prof. Dr. Paulo Estevão Cruvinel
(Orientador – EMBRAPA/Instrumentação
Agropecuária)



Prof. Dr. Ednaldo Brigante Pizzolato
(DC/UFSCar)



Prof. Dr. Joaquim Teixeira de Assis
(UERJ)

São Carlos
Junho/2009

À Deus, em primeiro lugar,
pela força, oportunidade e capacitação para chegar até aqui, e à minha família pelo amor e compreensão incondicional.

Agradecimentos

Em primeiro lugar à Deus pela oportunidade de realização deste trabalho, ajudando no meu crescimento de desenvolvimento pessoal.

À minha família, pelo apoio incondicional e coragem que me deram todos os dias.

Ao meu orientador, Prof. Dr. Paulo E. Cruvinel, por acreditar em mim, e me ajudar a cumprir essa importante etapa da minha vida.

Aos meus amigos de coração, Elis Hernandez, Kamila Rios, Mariana Feres, Filipe Ribeiro, Flávio Montoro, Matheus Viana, Ivan Zanon, Daniel Porto, Adriano Lucas, Claudio Oliveira e Thiago Medeiros, da turma de 2007 do mestrado em Ciência da Computação da UFSCar, pelo incentivo durante a jornada e momentos de muita alegria e descontração.

À minha companheira de mestrado, Érika Tezuka, pelas discussões e convivência que me ajudaram tanto a chegar ao fim do trabalho.

À Johana Rosas, pelo tempo de ótima convivência na república, que me proporcionou condições favoráveis para o cumprimento deste objetivo.

Aos colegas Leonardo Botega e Marcos Laia, pelo apoio e incentivo.

Ao programa de pós-graduação do departamento de computação da Universidade Federal de São Carlos (PPG-CC/UFSCar), à Embrapa Instrumentação Agropecuária (São Carlos/SP) e Embrapa Milho e Sorgo (Sete Lagoas/MG), na pessoa do Dr. Décio Karam, pela oportunidade e apoio concedidos.

À Profa. Dra. Vilma Alves de Oliveira (USP-EESC / Departamento de Engenharia Elétrica) e ao Prof. Dr. Nelson d'Ávila Mascarenhas (UFSCar / Departamento de Computação), pelas críticas e sugestões apresentadas durante o exame de qualificação.

Ao CNPq - Conselho Nacional de Desenvolvimento Científico e Tecnológico, processos 306988/2007-0 e 134550/2008-0, pelo apoio concedido.

“Fazer ou não fazer algo só depende de nossa vontade e perseverança”

Albert Einstein

Resumo

No Brasil é ainda embrionário o desenvolvimento de ferramentas de reconhecimento de plantas invasoras, capazes de auxiliar a tomada de decisão e indicar o seu risco no sistema de produção. Este trabalho apresenta o desenvolvimento de um sistema de reconhecimento de padrões de plantas invasoras e percentuais de ocupação de folhas largas e folhas estreitas, em sistemas de produção agrícola, utilizando técnicas de processamento digital de imagens. Para o desenvolvimento houve a consideração das etapas de aquisição das imagens, pré-processamento, segmentação baseada em textura, descritores para o reconhecimento das plantas invasoras e percentual de ocupação de cada tipo de planta. A validação foi desenvolvida considerando padrões geométricos gerados em laboratório, bem como o próprio ambiente de produção agrícola de milho (*Zea mays*), tomando por base duas espécies de plantas invasoras, sendo uma de folha larga (*Euphorbia heterophylla* L.), e outra de folha estreita (*Digitaria sanguinalis* Scop.). Resultados indicam uma taxa de acerto no reconhecimento em ambiente de campo da ordem de 84,24% para folhas largas e da ordem de 80,17% para folhas estreitas, além da capacidade de identificar plantas invasoras em locais restritos a visão natural. Adicionalmente, o resultado obtido apresenta potencial para a aplicação no manejo baseado em agricultura de precisão, o que auxilia na tomada de decisão em pulverização agrícola.

Palavras-chave: Reconhecimento de padrões, Segmentação em textura, Processamento digital de imagens, Planta invasora, Agricultura de precisão.

Abstract

In Brazil, the development of tools for weeds recognition, capable of aiding risk detection and decision making on the fieldwork is still embryonic. This master's thesis presents the development of a pattern recognition system that recognizes weeds and gives the occupation percentage of wide and narrow leaves in an agricultural production system, with digital image processing techniques. The development was based on considerations about image acquisition, pre-processing, texture based segmentation, descriptors for weeds recognition and occupation percentage of each kind of leaf. The validation has been developed considering geometric patterns generated in laboratory, as well as others obtained of a maize (*Zea mays*) production agricultural environment, i. e. two species of weeds, one with wide leaves (*Euphorbia heterophylla* L.) and other with narrow leaves (*Digitaria sanguinalis* Scop.). The results show recognition of about 84.24 percent for wide leaves and 80.17 percent for narrow leaves in agricultural environment and also the capability to spot weed on unreachable locations by natural vision. Besides, the method presents application in precision agriculture to improve the decision making in pulverization processes.

Keywords: Pattern recognition, Texture segmentation, Digital image processing, Weed, Precision agriculture.

Lista de Abreviaturas

ASM: *Active Shape Models* - Modelos de forma ativos

AP: Agricultura de Precisão - *Precision Agriculture, Precision Farming* ou ainda *Site-Specific Crop Management*

CSS: *Curvature Scale Space*

DGPS: *Differential Global Positioning System* - Sistema de posicionamento global diferencial

GIS: *Geographic Information System* - Sistema de informação geográfica

GLCM: *Grey Level Cooccurrence Matrix* - Matriz de co-ocorrência dos níveis de cinza

GPS: *Global Positioning System* - Sistema de posicionamento global

HSI: modelo de cores que utiliza *Hue, Saturation* e *Intensity* - Matiz, saturação e intensidade

LDA: *Linear Discriminant Analysis* - Análise dos discriminantes lineares

MAP: Máxima probabilidade *a posteriori*

MCI: Momentos centrais invariantes

MDS: *Multidimensional Scaling* - Escalonamento multidimensional

MFD: *Modified Fourier Descriptor* - Descritor de Fourier modificado

OEG: *Offset Excessive Green* - Compensação de verde excessivo

PCA: *Principal Component Analysis* - Análise dos componentes principais

RGB: modelo de cores que utiliza *Red, Green* e *Blue* - vermelho, verde e azul

SMA: Segundo momento angular

SOM: *Self-Organizing Map* - Mapas auto-organizáveis

SVM: *Support Vector Machine* - Máquina de vetores de suporte

Lista de Figuras

1	Etapas envolvidas no manejo baseado em técnicas de agricultura de precisão.	7
2	Representação de vizinhança	20
3	Vizinhança 3×3 ao redor de um <i>pixel</i> de coordenadas (x, y) em uma imagem.	23
4	Exemplo de crescimento de região usando duas sementes.	29
5	Divisão e Fusão de Regiões	30
6	Filtros de <i>Prewitt</i> nas oito direções possíveis.	32
7	Métodos de Análise de Texturas	38
8	Diagrama de blocos de um sistema de reconhecimento de padrões	46
9	Ciclo de projeto de um sistema de reconhecimento de padrões	47
10	Modelo para reconhecimento de padrões estatístico	49
11	Divisões do reconhecimento de padrões estatístico	50
12	Interações básicas em reconhecimento de padrões	56
13	Diagrama de blocos do sistema de reconhecimento	63
14	Tela inicial do sistema de reconhecimento	73
15	Tela do sistema de reconhecimento: abrir imagem.	74
16	Tela do sistema de reconhecimento: imagem de entrada.	75
17	Tela do sistema de reconhecimento: pré-processamento.	76

18	Tela do sistema de reconhecimento: mapa de textura das folhas	77
19	Tela do sistema de reconhecimento: mapas das folhas largas e estreitas. . . .	78
20	Tela do sistema de reconhecimento: percentuais de ocupação.	79
21	Imagens da forma círculo geradas para a validação da textura	82
22	Imagens da forma quadrado geradas para a validação da textura	83
23	Imagens da forma retângulo geradas para a validação da textura	84
24	Imagens da forma triângulo geradas para a validação da textura	85
25	Imagens da forma círculo2 geradas para a validação da textura	86
26	Imagens da forma quadr2 geradas para a validação da textura	87
27	Imagens da forma retâng2 geradas para a validação da textura	88
28	Imagens da forma triâng2 geradas para a validação da textura	89
29	Exemplos de folhas largas obtidas para a validação dos algoritmos	90
30	Exemplos de folhas estreitas obtidas para a validação dos algoritmos	91
31	Exemplos de imagens com formas compostas e sobreposição.	92
32	Exemplos de agrupamentos de folhas largas e estreitas.	93
33	Uma folha larga na primeira fase do pré-processamento.	95
34	Uma folha estreita na primeira fase do pré-processamento.	96
35	Um agrupamento de folhas na primeira fase do pré-processamento.	97
36	Uma folha larga nas últimas fases do pré-processamento.	98
37	Uma folha estreita nas últimas fases do pré-processamento.	99
38	Um agrupamento de folhas nas últimas fases do pré-processamento.	100
39	Comparação dos valores de contraste	101
40	Comparação dos valores de SMA	102
41	Comparação dos valores de entropia	102
42	Imagens do processo de formação das regiões de interesse	104
43	Processo de segmentação por textura de uma forma geométrica	105
44	Processo de segmentação por textura de duas formas geométricas	106
45	Processo de segmentação por textura de formas geométricas sobrepostas . .	107
46	Processo de segmentação por textura de uma folha larga	108
47	Processo de segmentação por textura de um agrupamento de folhas largas .	109
48	Comparação dos descritores em cada tipo de folha	111

49	Comparação dos valores dos descritores	112
50	Comparação dos descritores em cada tipo de agrupamento	113
51	Sobreposição do retângulo sobre quadrado (33%)	114
52	Sobreposição do retângulo sobre quadrado (66%)	114
53	Sobreposição do retângulo sobre quadrado (99%)	115
54	Sobreposição do quadrado sobre retângulo (33%)	115
55	Sobreposição do quadrado sobre retângulo (66%)	116
56	Sobreposição do quadrado sobre retângulo (99%)	116
57	Sobreposição de quadrados (33%)	117
58	Sobreposição de quadrados (66%)	117
59	Sobreposição de quadrados (99%)	118
60	Sobreposição de retângulos (33%)	118
61	Sobreposição de retângulos (66%)	119
62	Sobreposição de retângulos (99%)	119
63	Regressões lineares para análise do descritor de redondez.	122
64	Regressões lineares para análise do descritor de redondez.	123
65	Regressões lineares para análise do descritor de alongação.	124
66	Regressões lineares para análise do descritor de alongação.	125
67	Regressões lineares para análise do descritor de solidez.	126
68	Regressões lineares para análise do descritor de solidez.	127
69	Imagem da planta de folha larga a ser reconhecida pelo sistema.	130
70	Imagem da planta de folha larga a ser reconhecida pelo sistema.	130
71	Exemplos da aplicação do pré-processamento em imagens de campo	131
72	Imagens da segmentação de textura nas imagens de campo	132
73	Imagens do processo de formação das regiões das folhas	133
74	Imagens do processo de formação das regiões das folhas	134
75	Regressão linear para os descritores em folhas largas	137
76	Regressão linear para os descritores em folhas estreitas	138
77	Ficha de análise de campo preenchida para IMG_6562	141
78	Ficha de análise de campo preenchida para IMG_6564	142
79	Ficha de análise de campo preenchida para IMG_6573	143

80	Ficha de análise de campo preenchida para IMG_6585	144
81	Ficha de análise de campo preenchida para IMG_6592	145
82	Ficha de análise de campo preenchida para IMG_6595	146
83	Ficha de análise de campo preenchida para IMG_6596	147
84	Ficha de análise de campo preenchida para IMG_6597	148
85	Ficha de análise de campo preenchida para IMG_6609	149
86	Ficha de análise de campo preenchida para IMG_6610	150
87	Ficha de análise de campo preenchida para IMG_6615	151
88	Ficha de análise de campo preenchida para IMG_6616	152
89	Ficha de análise de campo preenchida para IMG_6617	153
90	Ficha de análise de campo preenchida para IMG_6618	154
91	Ficha de análise de campo preenchida para IMG_6619	155
92	Ficha de análise de campo preenchida para IMG_6620	156
93	Ficha de análise de campo preenchida para IMG_6621	157
94	Ficha de análise de campo preenchida para IMG_6622	158
95	Ficha de análise de campo preenchida para IMG_6628	159
96	Ficha de análise de campo preenchida para IMG_6629	160
97	Ficha de análise de campo preenchida para IMG_6630	161
98	Ficha de análise de campo preenchida para IMG_6631	162
99	Ficha de análise de campo preenchida para IMG_6632	163
100	Ficha de análise de campo preenchida para IMG_6633	164
101	Ficha de análise de campo preenchida para IMG_6634	165
102	Ficha de análise de campo preenchida para IMG_6635	166
103	Ficha de análise de campo preenchida para IMG_6640	167
104	Ficha de análise de campo preenchida para IMG_6641	168
105	Ficha de análise de campo preenchida para IMG_6642	169
106	Ficha de análise de campo preenchida para IMG_6643	170
107	Ficha de análise de campo preenchida para IMG_6644	171
108	Ficha de análise de campo preenchida para IMG_6645	172

Lista de Algoritmos

1	Algoritmo para o agrupamento de primitivas de textura	43
2	Algoritmo para o pré-processamento	64
3	Algoritmo para a segmentação baseada em textura	67
4	Algoritmo para o reconhecimento das folhas	70

Lista de Tabelas

1	Métodos de Estimação de Erro	60
2	Valores de desvio padrão das medidas de textura.	103
3	Tabela de reconhecimento para o descritor de redondez	120
4	Tabela de reconhecimento para o descritor de alongação	121
5	Tabela de reconhecimento para o descritor de solidez	121
6	Percentuais de ocupação de folhas largas	136
7	Percentuais de ocupação de folhas estreitas	136
8	Informações do observador de campo e síntese da avaliação de campo	173

Sumário

Introdução	1
1 Visão Computacional no Controle de Plantas Invasoras	3
1.1 Controle de Plantas Invasoras	3
1.1.1 Formas de Controle	5
1.1.2 Agricultura de Precisão	6
1.2 Visão Computacional aplicada no Controle de Plantas Invasoras	7
2 Análise de Imagens Digitais	19
2.1 Aquisição de imagens	19
2.2 Pré-Processamento	21
2.2.1 Filtragem	21
2.2.2 Modificação do Histograma	26
2.3 Segmentação	27
2.3.1 Segmentação por Regiões	28
2.3.2 Detecção de Bordas	31
2.4 Descritores de Forma	32
2.4.1 Descritores Geométricos	33
2.4.2 Descritores Baseados em Momentos	35
2.5 Análise de Textura	37

2.5.1	Abordagem Estatística	40
2.5.2	Abordagem Estrutural	41
3	Reconhecimento de Padrões	44
3.1	Sistemas de Reconhecimento de Padrões	46
3.1.1	Ciclo de um Projeto em Reconhecimento de Padrões	47
3.1.2	Aprendizado e Adaptação	47
3.2	Reconhecimento de Padrões Estatístico	48
3.2.1	Aprendizado Supervisionado Paramétrico	51
3.2.2	Aprendizado Supervisionado Não Paramétrico	51
3.2.3	Aprendizado Não Supervisionado	52
3.3	O Problema da Dimensionalidade	52
3.4	Redução da Dimensionalidade	53
3.4.1	Extração de Características	54
3.4.2	Seleção de Características	54
3.5	Classificação de Padrões	55
3.5.1	Regra de Decisão Bayesiana	57
3.5.2	Avaliação de Desempenho de um Classificador	59
4	Sistema de Reconhecimento de Plantas Invasoras e Percentual de Ocupação	61
4.1	Modelagem do Sistema	62
4.2	Aquisição das Imagens	62
4.3	Pré-Processamento	62
4.4	Segmentação Baseada em Textura	66
4.5	Descritores e Reconhecimento das Plantas Invasoras	69
4.6	Modelagem da interface com o usuário	71
5	Resultados e Discussões	81
5.1	Validação dos Algoritmos	81
5.1.1	Imagens Geradas para Validação do Método	81
5.1.2	Pré-Processamento	94
5.1.3	Segmentação Baseada em Textura	101
5.1.4	Descritores e Reconhecimento de Plantas Invasoras	110

5.2	Aplicação em Ambiente de Campo de Produção Agrícola	128
5.2.1	Aquisição das Imagens	128
5.2.2	Validação do Método em Nível de Campo	131
5.2.3	Aplicação do Método para Análise do Percentual de Ocupação	139
6	Conclusões	175
	Referências Bibliográficas	178

Introdução

A linha de estudos relacionada ao uso de visão computacional para o auxílio à tomada de decisão em ambiente agrícola para controle de plantas invasoras despertou a atenção de diversos pesquisadores por todo o mundo, preocupados com o grande número de trabalhos publicados em controle químico e poucos estudos relacionados à biologia de suas plantas.

O desequilíbrio ocasionado por variáveis ambientais torna propícia a explosão populacional de certas plantas no ambiente agrícola, podendo ocasionar infestação de plantas invasoras. A partir de informações ambientais, pode-se inferir qual o nível de risco de uma cultura ser atacada por alguma praga. A partir da praga já instalada, pode-se inferir a capacidade de dispersão da mesma pela cultura. A previsão das pragas, com base em protocolos que viabilizem o seu reconhecimento com taxa mínima de erro, auxiliará em modelos que viabilizem o combate das mesmas, avisando o agricultor quanto à ocorrência para que medidas necessárias de prevenção, como a dispersão de defensivos agrícolas¹ em regiões precisas, sejam executadas.

Esta dissertação apresenta o desenvolvimento de um sistema para o reconhecimento de plantas invasoras e percentual de ocupação de folhas largas e folhas estreitas usando técnicas de processamento digital de imagens e reconhecimento de padrões. Sendo assim, o texto está organizado em seis capítulos, conforme descrição a seguir, incluindo a

¹Defensivos agrícolas: são produtos químicos de utilidade contra as doenças e pragas que além de atacarem as lavouras, criam grandes problemas para o agricultor, afetando tanto sua economia como sua saúde.

bibliografia consultada.

Capítulo 1 - Visão computacional no controle de plantas invasoras: apresenta uma contextualização sobre o problema das plantas invasoras em ambiente agrícola, bem como uma introdução e alguns exemplos de sistemas de visão computacional para esta aplicação encontrados na literatura.

Capítulo 2 - Análise de imagens digitais: relata as técnicas de processamento digital de imagens para a análise das mesmas, abordando a aquisição de imagens, técnicas de pré-processamento, de segmentação, alguns descritores e análise de textura.

Capítulo 3 - Reconhecimento de padrões: descreve o que é reconhecimento de padrões, as etapas de sistemas para esse fim, os tipos existentes, pontos importantes quanto a dimensionalidade e um classificador.

Capítulo 4 - Desenvolvimento do sistema de reconhecimento de padrões de plantas invasoras e percentual de ocupação de folhas largas e folhas estreitas: apresenta a modelagem do sistema desenvolvido, detalhando todas as etapas do mesmo.

Capítulo 5 - Resultados e discussões: relata e discute os resultados apresentados pelo sistema durante a validação dos algoritmos, bem como sua aplicação em um ambiente de campo de produção agrícola.

Capítulo 6 - Conclusões: descreve as conclusões obtidas pela análise dos resultados apresentados pelo sistema, assim como sugestões de trabalhos futuros.

Visão Computacional no Controle de Plantas Invasoras

Neste capítulo são apresentadas as potencialidades da visão computacional para o controle de plantas invasoras. As plantas invasoras têm grande impacto nos processos de produção agrícola sendo sua minimização ou mesmo erradicação desejável e necessária.

1.1 Controle de Plantas Invasoras

A competitividade e as exigências do mercado consumidor têm pressionado o setor agrícola a buscar maior eficiência na produção. Além disso, a busca pela conservação dos recursos naturais, diminuindo tanto quanto possível a poluição do meio ambiente, é outro fator que tem motivado a procura de melhor gerenciamento do processo produtivo agrícola. As aplicações convencionais de fertilizantes e defensivos vêm sendo objetos de pesquisa, que visam melhorar a sua eficiência com redução do impacto ambiental. Essas aplicações significam, muitas vezes, aplicações excessivas em algumas áreas do campo, podendo se tornar fontes de contaminação das águas subterrâneas e superficiais, e insuficientes em

outras.

A previsão da infestação de pragas² no ambiente agrícola é importante para a sua erradicação, implicando na redução do custo de aplicação de insumos e diminuição do impacto ambiental.

As plantas invasoras são pragas que ocorrem no ambiente agrícola e possuem grande impacto sobre o mesmo. O aspecto principal a ser considerado para diminuir o risco decorrente desse tipo de planta leva em consideração o reconhecimento das mesmas e um modelo de previsão da infestação anexado à variáveis agroclimáticas.

As plantas invasoras possuem as seguintes características:

- não são desejadas no meio;
- são de fácil sobrevivência;
- apresentam alto nível de propagação;
- podem causar danos à cultura;
- são de rápido crescimento;
- possuem rápida adaptação ao ambiente;
- apresentam germinação e crescimento em condições adversas;
- apresentam competição com a cultura por água, luz, nutrientes e dióxido de carbono.

Outros termos também são usados para identificar esse tipo de planta, como plantas ou ervas daninhas, inços, tigüera entre outros. Estas plantas crescem espontaneamente em todos os solos agrícolas.

A ocorrência de algumas espécies de plantas invasoras se dá em reboleiras³, devido à forma de propagação das mesmas. Entretanto, no manejo clássico, a aplicação de defensivos é feita em toda a área, não levando em consideração essa ocorrência desigual. Por outro lado, estudos fundamentados no manejo com técnicas de agricultura de precisão têm permitido o mapeamento da ocorrência de plantas invasoras (NORDMEYER et al., 1997; LAMB;BROWN, 2001), trazendo assim informações técnicas quanto às localizações em uma área considerada.

Pesquisas realizadas nos Estados Unidos mostraram que a percentagem de infesta-

²Pragas: erva ou outra planta daninha, ou qualquer forma de vida animal que possa destruir aquilo que o ser humano considera um bem seu (HOUAISS, 2001).

³Reboleiras: formação arbórea de pequena extensão; capão, moita, touça (HOUAISS, 2001).

ção por planta invasora pode variar entre 21 e 73% em relação ao total da área cultivada (TIAN et al., 1999). Nessas situações, o gerenciamento espacial e os sistemas de aplicações localizadas possuem grande potencial de diminuição do uso de defensivos agrícolas.

A capacidade de sobrevivência das plantas invasoras ocorre devido à sua grande agressividade competitiva, grande produção de sementes, facilidade de dispersão e longevidade das sementes, germinação escalonada e seus mecanismos diversos de reprodução (VOLL et al., 2005).

A presença desse tipo de planta no ambiente agrícola é um dos grandes problemas enfrentados pelos agricultores e pode ocasionar perdas de rendimento superiores a 80% quando nenhum método de controle é aplicado à cultura (KARAM, 2008).

1.1.1 Formas de Controle

A perda de rendimento em culturas agrícolas está relacionada à competição por insumos necessários para o desenvolvimento das plantas e pela ocorrência de pragas nesse ambiente.

Os métodos normalmente utilizados para o controle das plantas invasoras são o mecânico, o químico e o cultural. Quando possível, é aconselhável utilizar a combinação de dois ou mais destes métodos.

O controle cultural consiste na utilização de técnicas de manejo da cultura (época de semeadura, espaçamento, densidade, adubação, cultivo, etc.) que propiciem o desenvolvimento da cultura, e a extinção das plantas invasoras.

O método mais utilizado para controlar essas plantas é o químico, isto é, com uso de herbicidas⁴. A economia de mão de obra e a rapidez na aplicação podem ser destacadas como suas principais vantagens. É importante o uso de técnicas refinadas, para que a aplicação dos herbicidas seja segura, eficiente e econômica. O reconhecimento prévio das plantas invasoras predominantes no ambiente é condição básica para a escolha adequada do produto, que resultará em um controle mais eficiente.

O aumento substancial no uso de herbicidas para o controle de plantas invasoras tem sido uma tendência crescente para compensar as deficiências do controle mecânico tradicional (FELTON et al., 1991). Pesquisadores têm buscado meios para reduzir a quan-

⁴Herbicida: substância que mata ervas daninhas (HOUAISS, 2001).

tidade de defensivos e o impacto sobre o meio ambiente. A variabilidade espacial das plantas invasoras tem sido objeto de estudo com o objetivo de diminuir o volume de defensivos aplicados com base no uso de mapeamento das áreas infestadas (WILLIS;STOLLER, 1990; CHANCELLOR;GORONEA, 1994; TIAN et al., 1999).

No Brasil pode-se estimar que os herbicidas sejam usados em mais de 65% da área cultivada com culturas anuais. Os principais problemas que os agricultores enfrentam pela alta taxa de aplicação de herbicidas são aqueles relacionados à aplicação, ao meio ambiente, à saúde humana e ao surgimento de plantas resistentes (KARAM, 2008).

1.1.2 Agricultura de Precisão

Agricultura de Precisão (AP) é um sistema de gerenciamento que surgiu com o objetivo de fornecer informações sobre os fatores de produção que interagem na lavoura e sobre como eles podem ser maximizados. Reúne o uso de tecnologias para o manejo de solo, insumos e culturas, de modo adequado às variações espaciais e temporais em fatores que afetam a produtividade das mesmas, com o objetivo de aumentar a eficiência produtiva (TSCHIEDEL;FERREIRA, 2002; PIRES et al., 2004). O seu crescimento foi impulsionado por avanços tecnológicos que envolvem, entre outros, sistema de posicionamento global (GPS - *Global Positioning System*), sensoriamento remoto, aplicação de insumos em taxas variáveis e sistema de informação geográfica (GIS - *Geographic information system*).

As etapas da AP envolvem: coleta das informações, interpretação das mesmas e aplicação de insumos. A partir da coleta das informações, as mesmas passam para uma interpretação por modelo computacional, gerando mapas de aplicação com recomendações de intervenção, e por fim, através destes mapas essas recomendações são aplicadas nos locais de produção (MANTOVANI, 2002). Estas etapas estão ilustradas na Figura 1.

A idéia de AP meramente baseada em soluções tecnológicas vem aos poucos evoluindo para uma situação promissora que realmente demonstra potencialidade e resultados. O importante é associar as tecnologias, nas suas mais amplas possibilidades, a um acompanhamento técnico especializado baseado no conhecimento gerado pela pesquisa e em novas pesquisas que devem ser realizadas com perspectiva no manejo da variabilidade dos fatores de produção (PIRES et al., 2004).

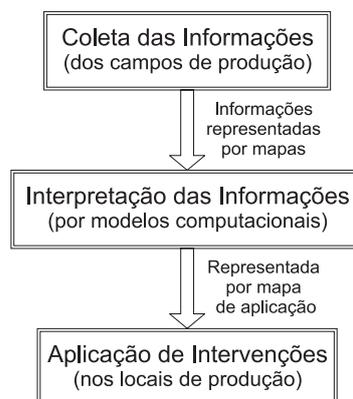


Figura 1: Etapas envolvidas no manejo baseado em técnicas de agricultura de precisão.

Dentre as ferramentas utilizadas na AP destaca-se o sensoriamento remoto, muito utilizado para o mapeamento de áreas de cultura e estimação do rendimento das mesmas. Entretanto, nos últimos anos a pesquisa tem sido direcionada para o monitoramento das condições da cultura como, por exemplo, a identificação das deficiências nutricionais de planta, a ocorrência de pragas e doenças, a classificação e quantificação de plantas invasoras dentre outros (GOEL et al., 2000).

A tecnologia de AP é utilizada para a identificação de áreas com diversos graus de infestação e estabelecimento de níveis de controle localizados, com a pretensão de atingir com maior eficiência as plantas invasoras, evitando atingir áreas livres e reduzir problemas de poluição ambiental (VOLL et al., 2005).

1.2 Visão Computacional aplicada no Controle de Plantas Invasoras

Uma economia de herbicida da ordem de 30 a 80% é possível de ser realizada quando se realiza o controle localizado de plantas invasoras em áreas mapeadas, comparada à aplicação em área total (NUSPL et al., 1996). A aplicação localizada de defensivos pode ser realizada por equipamentos capazes de identificar e controlar a planta invasora em tempo real ou por equipamentos que realizam a aplicação de acordo com um mapa de prescrição.

As técnicas de visão computacional têm sido utilizadas na área agrícola, princi-

palmente como mecanismo de inspeção da qualidade dos produtos (PARK et al., 1998; BASSET et al., 2000). Tais técnicas também são ferramentas potenciais para a identificação de plantas invasoras, com o principal objetivo de redução de custos em função da diminuição do volume de herbicida aplicado nas áreas de produção agrícola, devido à pressões sociais e leis que exigem a diminuição da aplicação desses defensivos.

A viabilidade do uso de imagens para a identificação de plantas invasoras e mapeamento das áreas infestadas é fortemente influenciada por fatores como: radiação incidente, espécie, densidade e estágio de crescimento das plantas (SU et al., 1999).

Os avanços em processamento digital de imagens, particularmente quando se faz uso de imagens digitais não orbitais, passou a ser uma importante estratégia a ser utilizada, as quais associadas ao estudo da variabilidade espacial das culturas e das plantas invasoras podem resultar em equipamentos para o manejo localizado de culturas em tempo real.

A detecção de plantas invasoras através do sensoriamento remoto orbital ainda possui limitações quanto a resolução espacial e temporal. Acredita-se que existe potencial para utilização de sistemas de visão computacional como sensores para coleta de dados em agricultura de precisão (PINTO et al., 1999). Tais sistemas são constituídos, basicamente, por uma câmera conectada a um computador por meio de uma placa de aquisição de vídeo, e por programas computacionais específicos de processamento de imagens para extração das informações desejadas.

Brown e Steckler (1995) trabalharam com imagens aéreas obtidas com altitude aproximada de 900 m e segmentação baseada na cor para identificar e mapear três diferentes espécies de plantas invasoras, com a finalidade de gerar mapas de aplicação diferenciada, objetivando a redução do uso de defensivos em uma lavoura de milho sob plantio direto⁵. Os estudos mostraram que a identificação de plantas invasoras via fotos aéreas é viável e que a redução na quantidade total de herbicidas foi da ordem de 40%.

Woebbecke e colaboradores (WOEBBECKE et al., 1995) fizeram uma investigação

⁵Plantio direto: O Sistema Plantio Direto (SPD) é um sistema de manejo do solo onde a palha e os restos vegetais são deixados na superfície do solo. O solo é revolvido apenas no sulco onde são depositadas sementes e fertilizantes. As plantas infestantes são controladas por herbicidas. Não existe preparo do solo além da mobilização no sulco de plantio (IAC, 2009).

completa de características de forma, em plantas monocotiledôneas⁶ e dicotiledôneas⁷ infestantes, para descrever mudanças no desenvolvimento de plantas com características de forma ao longo do tempo, bem como identificar quais seriam as melhores características para classificar nas duas categorias consideradas. As características estudadas foram redondeza, aspecto, perímetro/grossura, alongação e momentos centrais invariantes (MCI), características estas independentes do tamanho e da localização da planta e rotação da imagem. Segundo a investigação, a melhor característica para distinguir as plantas foi o MCI com taxa de classificação entre 60 e 90%.

Um estudo conduzido por Yonekawa e colaboradores (YONEKAWA et al., 1996) apresentou como resultado um software de aquisição e processamento de imagens para identificar tipos de folhas idealizados usando fatores de forma (compacidade, redondeza, alongação, lobosidade e rugosidade). Estes fatores de forma não requerem nem um grande esforço computacional, nem grande quantidade de memória. Os resultados indicaram que os fatores de forma são úteis para identificar plantas pela suas folhas, e para compor uma base de conhecimento para os sistemas de visão computacional.

Um sistema de identificação, em tempo real, de plantas invasoras na cultura da soja (*Glycine hispida*) foi desenvolvido por Steward e Tian (1998). O sistema utilizava câmeras de vídeo fixadas a uma estrutura metálica montada sobre um trator, sob condições variáveis de iluminação. Primeiramente os *pixels* foram classificados por análise de agrupamento, aprendizado não supervisionado. Depois, os dados classificados foram utilizados para treinar um classificador de Bayes, que foi base para criação de uma tabela de pesquisa para segmentação em tempo real. Os resultados obtidos mostram que o algoritmo utilizado apresentou alto índice de acerto e baixo tempo computacional.

Fan e colaboradores (FAN et al., 1998) afirmam que a identificação de plantas invasoras pela forma, principalmente da folha, apresenta problemas devido à sobreposição, diferentes orientações e movimentos provocados pelo vento. Por esse motivo, acreditam que a textura e as informações de cor merecem maior atenção no desenvolvimento de algoritmos para a segmentação das plantas, separando-as dos outros objetos na imagem.

⁶Monocotiledônea: plantas caracterizadas pelo embrião com apenas um cotilédone, folha que se forma no embrião, germinação sem crescimento secundário em espessura do caule e da raiz, folhas frequentemente estreitas e com nervação paralela (HOUAISS, 2001).

⁷Dicotiledônea: plantas caracterizadas pelo embrião germinado com dois, ou mais, cotilédones, cada uma das folhas que se formam no embrião, crescimento secundário em espessura do caule e da raiz, folhas frequentemente com nervação reticulada e flores pentâmeras ou tetrâmeras, raramente trímeras (HOUAISS, 2001).

Também, citaram que a classificação baseada em análise textural pode ser influenciada pelo mau ajuste do foco da câmera e pela movimentação da folha, onde, no caso do movimento foliar, o problema pode ser eliminado utilizando uma taxa de captura da câmera elevada.

Uma análise estatística discriminante tradicional na classificação de seis diferentes classes, utilizando os parâmetros texturais de imagens coloridas foi testada por Burks e colaboradores (BURKS et al., 1998). Os resultados mostraram que a técnica utilizada foi capaz de separar as classes com precisão de até 93% usando apenas a matiz e a saturação. De acordo com os autores, a principal contribuição do trabalho foi a retirada dos parâmetros texturais derivados da intensividade, sem que essa eliminação prejudicasse significativamente a classificação dos modelos, permitindo ainda, a redução em um terço do tempo computacional.

Cruvinel e colaboradores (CRUVINEL et al., 1999) apresentaram um método para ajuste e controle de qualidade de sistemas de pulverização de plantas invasoras baseado no uso de visão computacional para a avaliação do tamanho e distribuição de gotas de herbicidas. Tal sistema foi baseado em processamento de imagens com análise de correlação no domínio da frequência. As pequenas gotas estão sujeitas à deriva provocada pelo vento, que ilude a aplicação, as gotas grandes podem ser transferidas para a superfície do solo, resultando em crostas superficiais e enxurrada. Segundo os autores, o método possui a vantagem de ser de medição direta, que identifica e conta automaticamente as gotas de chuva, não apresentando erro maior do que 1,5%.

Lee e colaboradores (LEE, 1998; LEE;SLAUGHTER, 1998; LEE et al., 1999) desenvolveram um sistema de controle automático e inteligente de plantas invasoras para tomates (*Lycopersicon esculentum*), que foi testado para pulverização seletiva de plantas invasoras em linha que usam um sistema de visão de máquina e aplicação química com precisão. Para o sistema, utilizaram parâmetros de forma na identificação de quatro diferentes classes, três de tomate e uma de plantas invasoras. Para a identificação das plantas invasoras, foram extraídos dez descritores de formas, sendo eles: área, maior eixo, menor eixo, centro de massa, razão da área pelo comprimento, compactação, alongação, o logaritmo da altura pela largura, a razão do comprimento pelo perímetro e a razão do perímetro pela largura. Um classificador estatístico (Bayesiano) e outro neural (rede neural baseada no *hardware*)

foram implementados e apresentaram resultados pouco promissores em pelo menos duas das quatro classes analisadas. Esses autores mostraram também a possibilidade de usar uma rede neural baseada no *hardware* para melhorar a velocidade de processamento e a taxa de identificação de plantas. Segundo os autores, com a rede neural baseada em *hardware*, 38,9% dos cotilédones⁸, 37,5% das verdadeiras folhas de tomate e 85,7% das plantas invasoras foram corretamente identificados. A baixa precisão encontrada pelos classificadores utilizados foi atribuída à sobreposição das folhas das plantas.

A técnica de segmentação baseada na frequência espacial, utilizando transformada de Fourier, foi usada nos trabalhos desenvolvidos por Su e colaboradores (SU et al., 1999) e Tang e colaboradores (TANG et al., 1999) para o reconhecimento de plantas invasoras. Estes pesquisadores relataram que o baixo tempo computacional e a possibilidade de utilização de equipamentos mais baratos são as principais justificativas desse método que se baseia na discriminação textural entre as plantas.

O mapeamento de plantas invasoras na cultura do trigo (*Triticum aestivum*), em laboratório e no campo, utilizando sensores óticos, considerando as classes de solo descoberto, trigo e planta invasora, foi realizado por Wang e colaboradores (WANG et al., 2000). Para as condições de laboratório verificaram que durante o treinamento do classificador, 100% das amostras de solo e de trigo, em todas as suas densidades, foram classificadas corretamente. Já para a classe plantas invasoras apenas 58,7% foram classificadas corretamente. Nas condições de campo considerando apenas duas classes, plantas invasoras e trigo, os resultados obtidos variaram entre 87 e 98%, sendo que o menor valor ocorreu para a classe das plantas invasoras.

Pérez e colaboradores (PÉREZ et al., 2000) trataram do desenvolvimento da captura de imagens próximas ao solo e técnicas de processamento de imagens para detectar plantas invasoras em plantações de cereais sob efetivas condições de campo. Segundo os autores, a determinação da posição de fila na colheita ajudou a reduzir o número de objetos aos quais as técnicas de análise de imagens foram aplicadas. Eles propuseram um método para usar informações de cor para separar o fundo da vegetação, enquanto as técnicas de análise de forma são aplicadas para distinguir plantas invasoras da plantação. As técnicas de forma utilizadas foram: comprimento, razão de aspecto, área, razões do com-

⁸Cotilédone: folha ou cada uma das folhas que se forma no embrião das angiospermas e gimnospermas e que, em algumas espécies, pode ser um órgão de reserva para o desenvolvimento do embrião (HOUAISS, 2001).

primento maior/menor eixo, redondeza, invariantes geométricas baseadas nos momentos centrais normalizados e outra característica heurística baseada na própria experiência. Para a classificação utilizaram a regra de Bayes e o método dos k -vizinhos mais próximos⁹, que usaram todas as combinações possíveis de características para avaliar os algoritmos. O método dos k -vizinhos mais próximos apresentou melhor taxa de acerto na classificação de plantas invasoras. O desempenho dos algoritmos de detecção de plantas invasoras foi avaliado comparando com os resultados fornecidos pela pesquisa visual. Os resultados foram analisados por meio de gráficos de correlação, os quais mostraram inicialmente um índice de acerto de 75%, com aumento até 85% quando foi incluída análise de forma. Apesar da alta correlação obtida, aparece uma subestimação geral nos métodos automáticos, principalmente devido a fatores como: condições de iluminação natural (destaques e sombras), plantas invasoras incorporadas a cultura, falta de periodicidade na geometria das culturas, bem como a pequenez e da variabilidade de plantas invasoras.

El-Faki e colaboradores (EL-FAKI et al., 2000a,b) afirmaram que métodos baseados na cor são mais eficientes do que os que utilizam análises texturais ou forma, por serem pouco influenciados pela sobreposição e orientação das folhas, foco da câmera e efeito do vento. Entretanto, salientaram que a utilização direta dos níveis de cor é inadequada porque são fortemente influenciados pela iluminação, sendo necessária a criação de índices relativos adequados para cada uma das classes de interesse. Foram usados três classificadores, um estatístico, baseado em análise discriminante, e dois de redes neurais. Os índices de maior significância foram utilizados na função discriminante e também em um classificador com base em rede neural. Assim, concluíram que o estágio de desenvolvimento da cultura, deficiências nutricionais, coloração, textura, umidade e teor de matéria orgânica do solo, além da presença de outras plantas, podem degradar a eficiência dos classificadores em nível de campo, sendo necessário um novo treinamento dos algoritmos.

Manh e colaboradores (MANH et al., 2001) descreveram um método para segmentação de imagens de folhas de plantas invasoras por modelos deformáveis. Esta abordagem apresentou a vantagem de aplicar conhecimentos *a priori* ao objeto procurado, melhorando a robustez da fase de segmentação. Seu princípio consistiu em ajustar um modelo paramétrico ao contorno da folha na imagem, minimizando um termo de energia relacionado

⁹Método dos k -vizinhos mais próximos: classifica uma amostra, atribuindo-lhe a classe representada mais frequentemente entre as k amostras mais próximas (DUDA et al., 2000).

a limitação interna das características modeladas e salientes da imagem, como a cor da planta. Este método apresentou resultados promissores para uma das espécies de plantas invasoras, *Setaria viridis*, possibilitando caracterizar folhas parcialmente fechadas. Este trabalho foi um primeiro passo para se chegar a um sistema de reconhecimento, baseado nas características da folha e em sua relativa posição espacial.

Hemming e Rath (2001) desenvolveram um algoritmo de classificação baseado em lógica “Fuzzy” com oito diferentes características morfológicas e três características de cor de imagens de plantas invasoras, obtidas em condições de campo com iluminação controlada. Os descritores de forma usados foram a área, área/tamanho do contorno, alongação, circularidade, conectividades, diâmetro máximo, redondez e picos (este descritor se refere a estrutura do contorno da folha, se esta é suave ou serrilhada). Também, foram utilizados descritores baseados na cor, sendo eles, matiz, saturação e intensidade. O algoritmo de classificação apresentado foi significativamente influenciado pelo estágio de crescimento e densidade de plantas, variando de 51 a 95% a classificação correta.

Os parâmetros de textura para a classificação de plantas invasoras em imagens digitais foram avaliados por Alves e colaboradores (ALVES et al., 2002). Os parâmetros considerados foram: momento angular, valor médio, variância, correlação, momento do produto, momento da diferença inversa, entropia e duas medidas de correlação. Para os cálculos foram utilizadas imagens adquiridas sob um ambiente com iluminação controlada, onde as plantas invasoras foram plantadas em vasos, e as imagens obtidas 25 dias após a emergência e na altura de 10 cm. Destes parâmetros, cinco apresentaram resultados satisfatórios quanto a identificação para a separação das plantas, sendo eles momento angular, valor médio, momento da diferença inversa, entropia, e uma das medidas de correlação. Segundo os autores, os resultados indicaram a possibilidade de discriminação entre espécies de plantas invasoras de folhas largas e estreitas utilizando características texturais em imagens digitais.

Uma técnica para a classificação das folhas baseada na forma e tamanho foi também descrita por Andrade e Pinto (2002), onde foram utilizados descritores geométricos e análise dos componentes principais (PCA - *Principal Components Analysis*). Os descritores usados foram área, perímetro e redondez, chamada por eles de fator de forma, que serviram de entrada para o PCA. Com os resultados foi demonstrado ser possível diferenciar

folhas segundo o tamanho e a forma.

Baio e Balastreire (2003) mapearam as manchas de ocorrência das plantas invasoras com o auxílio de um DGPS¹⁰, anotando as espécies de plantas invasoras presentes e o seu estágio de desenvolvimento. Por meio desse mapeamento foi gerado um mapa de aplicação para uma área de 9,8 ha¹¹. A aplicação diferenciada representou uma economia de 31,6% de herbicida, quando comparado à aplicação em área total, controlando as plantas de maneira eficiente.

A facilidade de implementação de um sistema de identificação automática de sementes de plantas invasoras com imagens coloridas e em escalas de cinza foi explorada por Granitto e colaboradores (GRANITTO et al., 2003). Foram usadas técnicas padrões de processamento de imagens para obter as características de tamanho, forma, cor e textura, e avaliado o poder de classificação destas características. Os descritores de tamanho e forma utilizados foram raiz quadrada da área da semente, razão entre o semi-eixo e o eixo principal, razão entre a área da semente e a área da caixa de enquadramento (*bounding box*) e momentos de distribuição de massa plana. Os de cor foram variância e ubiquidade da intensidade do histograma, além das razões dos valores de *pixels* médios nos canais RGB. E por fim para identificar a textura foram utilizados os descritores de contraste ao longo da direção do maior eixo e a eminência de agrupamento ao longo da direção do menor eixo para a textura. Para a identificação das sementes os autores consideraram a abordagem de Bayes e redes neurais artificiais. De acordo com os resultados, em condições operacionais especiais, o trabalho apresentaria uma pequena perda de desempenho quando comparado com a implementação baseada em imagens coloridas.

Um sistema de recuperação de folhas baseado em forma, utilizando os descritores de curva de distância do centro de massa (centróide) ao contorno, excentricidade e um histograma do ângulo codificado foi descrito por Wang e colaboradores (WANG et al., 2003). Também foi proposto um método baseado em algoritmos de redução (usados para encontrar o esqueleto do objeto) para localizar os pontos iniciais do contorno da folha, o que tornou o sistema de identificação mais eficiente computacionalmente. Seus resultados experimentais apresentados mostram que a abordagem teve um desempenho de recupera-

¹⁰DGPS: Sistema de Posicionamento Global Diferencial - é uma técnica empregada em receptores de sistemas de posicionamento global para isto capacitados, que tem por finalidade obter precisões superiores as precisões obtidas com estes receptores em modo absoluto de posicionamento (SPG, 2009).

¹¹ha: símbolo de hectare, que significa, unidade de medida para superfícies agrárias corresponde a 10.000 m².

ção melhor que os métodos de curvatura (*Curvature Scale Space* - CSS) e do descritor de Fourier modificado (*Modified Fourier Descriptor* - MFD).

Sökefeld e Gerhards (2004) apresentaram um sistema de câmera móvel, o qual fotografava simultaneamente duas imagens geocodificadas (*geo-coded*) em duas bandas espectrais diferentes, com comparação entre elas. A técnica de pré-processamento utilizada reduzia as imagens aos contornos externos das plantas. Para a classificação baseada em conhecimento, programada com parâmetros multi-variáveis, procedimentos de identificação de amostra foram aplicados. Para a classificação das plantas foi usada a métrica Euclidiana. Os resultados de classificação foram usados para o mapeamento da distribuição das plantas invasoras. A taxa de identificação, em uma base de conhecimento com cinco classes, foi em torno de 80% (a abrangência da classificação ficou entre 67 e 93%).

Um outro método para a classificação de plantas invasoras usando modelos de formas ativas (*Active Shape Models* - ASM) foi apresentado por Søgaard (2005). O método consistiu em um modelo flexível, que viabilizou descrever como as formas do objeto (neste caso folhas) podem variar. Tratou-se de um algoritmo para a identificação de mudas jovens de plantas invasoras com até duas folhas verdadeiras e sem sobreposição mútua com outras folhas. Os resultados obtidos mostraram uma taxa de identificação correta variando entre 65 e 90% dependendo da espécie da planta avaliada.

Brown e Noble (2005) afirmaram que a detecção e identificação automática de plantas invasoras em uma plantação é um dos grandes desafios para o desenvolvimento de sistemas de gerenciamento desse tipo de plantas em um sítio específico. Os progressos nas pesquisas até aqui, podem ser resumidos em duas abordagens, uma com mapeamento de plantas invasoras por sensores remotos, e outra com detecção baseada em solo, usando câmeras digitais ou sensores sem imagens. O uso de sensores para imageamento multiespectral, como câmeras digitais coloridas, em plataformas móveis baseadas em solo mostrou mais possibilidade na identificação das plantas invasoras nas condições de campo. Características espectrais somadas às características espaciais, como forma e textura da folha e a organização da planta, podem ser extraídas destas imagens. Os autores também afirmam que para a identificação da forma das folhas podem ser usados descritores simples como comprimento e largura, área, perímetro, menor largura, espessura e momentos centrais invariantes baseados em inércia para a identificação das formas das folhas.

O método de elíptica de Fourier e análise discriminante através de descritores de forma para identificar soja (*Glycine max (L.) merrill*), foram utilizados por Camargo Neto e colaboradores (CAMARGO NETO et al., 2005). O método da elíptica de Fourier foi utilizado para gerar os descritores de forma a partir da codificação do contorno da folha e a análise discriminante *stepwise* foi utilizada para selecionar os descritores com máxima discriminação. Esta análise foi executada com os descritores de forma das folhas da segunda e terceira semana após a germinação da soja. Os resultados mostraram que a terceira semana após a germinação é a melhor semana para identificar a espécie de planta por meio da análise de forma com 89,4% de classificação correta.

Bressan e colaboradores (BRESSAN et al., 2006, 2008) trataram da classificação do risco de infestação por plantas invasoras usando técnicas geoestatísticas, análise de imagens e modelos de classificação fuzzy. A densidade das sementes (produção de sementes por área), a sua extensão (influência das sementes vizinhas), a cobertura foliar (extensão dos agrupamentos das plantas invasoras emergentes) e a agressividade (porcentagem de ocupação de espécies com alta capacidade de produção de sementes) foram os principais atributos utilizados para descrever a infestação das plantas invasoras em cada região. A partir de simulação com modelos matemáticos de populações foram obtidos os dados da densidade, da cobertura foliar e da agressividade para as diferentes regiões. Os autores propuseram um sistema de classificação fuzzy utilizando os atributos descritos para inferir os riscos de infestação de regiões da cultura por plantas invasoras.

Outro método foi desenvolvido para avaliar a qualidade da aplicação de herbicida em áreas de plantio, utilizando visão computacional e rede neural artificial (CRUVINEL et al., 2006). A técnica utilizava imagem digital e transformada de Hough para a contagem e distribuição das gotas, assim como um modelo para a tomada de decisão com rede neural, que recebia como entrada informações dos descritores da distribuição das classes de gotas para análise sítio-específico.

Outro estudo foi conduzido por Karimi e colaboradores (KARIMI et al., 2006) para avaliar a utilização de um método baseado em inteligência artificial (*Support Vector Machine* - SVM), como ferramenta para classificar imagens hiperespectrais obtidas sob uma plantação de cereais (*Zea mays L.*). A classificação foi executada com respeito à taxa de aplicação de nitrogênio e práticas de manejo de plantas invasoras. A precisão de classifica-

ção foi comparada com esses modelos obtidos por uma rede neural artificial nos mesmos dados. O experimento de campo consistiu em taxas de aplicação de nitrogênio e quatro estratégias de gerenciamento de plantas invasoras, sendo elas, nenhum gerenciamento, controle de gramíneas, controle de plantas invasoras de folhas largas e controle total de plantas invasoras. As taxas de aplicação de nitrogênio foram de 60, 120 e 250 kg N/ha. A precisão de classificação foi avaliada para três casos: combinações de taxas de aplicação de nitrogênio e níveis de infestações de plantas invasoras, apenas taxas de aplicação de nitrogênio e apenas controle de plantas invasoras. Segundo os autores, o método SVM resulta em uma pequena taxa de perda de classificação, se comparada com a abordagem da rede neural artificial para todos os três casos. Detecção de estresse em safras de estágio de crescimento precoce usando o método SVM pode auxiliar em aplicação precoce efetiva de tratamento em sítio-específico em intervenções sazonais.

Søgaard e Lund (2007) conduziram experimentos baseados no conceito da aplicação precisa de herbicida em linha de semente (*seed line*), que combina reconhecimento de plantas, micro-dosagem e robótica autônoma. Um sistema de visão de máquina reconhece objetos a serem pulverizados e um sistema de micro-dosagem lança doses muito pequenas de líquido nos objetos detectados, enquanto o veículo autônomo cuida da navegação. Para o reconhecimento dos objetos é feita uma limiarização nas imagens adquiridas pela intensidade dos níveis de cinza. Depois desses objetos serem reconhecidos, os mesmos têm sua caracterização feita por dois descritores, sendo eles, área e excentricidade. Estes experimentos foram executados sob condições internas controladas. Os resultados mostram que a pulverização líquida pode ser aplicada com precisão milimétrica e que a taxa de aplicação pode ser reduzida em duas ordens de grandeza comparada com as recomendações usadas na pulverização convencional.

Um sistema de visão de máquina para detectar e discriminar plantação das plantas invasoras foi desenvolvido e testado por ul Haq e colaboradores (UL HAQ et al., 2007). As imagens foram adquiridas em plantações sob iluminação natural e estudadas extensivamente. Os autores utilizaram uma segmentação de compensação de verde excessivo (OEG - *Offset Excessive Green*) e desenvolveram um classificador de plantas invasoras baseado na transformada de Radon, a qual classifica em folhas largas ou estreitas para aplicação seletiva de herbicida em tempo real. Os resultados dos testes, em laboratório, mostraram

que o sistema desenvolvido apresentou um desempenho confiável porém com significativo esforço computacional menor para imagens tomadas sob variadas condições. A precisão de classificação foi superior a 93,5% em um banco de dados de 200 amostras de imagens (100 amostras de plantas de folhas largas e 100 de folhas estreitas).

Slaughter e colaboradores (SLAUGHTER et al., 2008) apresentaram uma revisão de sistemas para controle mecânico automático de plantas invasoras. Em sua revisão, descrevem o estado atual das quatro tecnologias principais (*guidance*, detecção e identificação, precisão em linha de controle de plantas invasoras, e mapeamento) requeridas para o desenvolvimento bem-sucedido de sistemas robóticos de propósito geral para controle de plantas invasoras. Das quatro tecnologias, detecção e identificação das plantas invasoras sob a grande variedade de condições comuns aos campos de cultivo continuam a ser o maior desafio. Dentro deste maior desafio, mostraram que padrões de contorno de folha (como a curvatura) e a forma de plantas e folhas (como área, perímetro, comprimento, largura) geralmente alcançam altas taxas de reconhecimento.

Um sistema de visão de máquina em tempo real para o controle de plantas invasoras foi construído por Ahmed e colaboradores (AHMED et al., 2008). Tal sistema tinha como objetivo detectar a localização das plantas invasoras, e para isto foi utilizada uma plataforma robótica de tempo real, com tecnologia de visão de máquina e reconhecimento de padrões. O sistema baseou-se nas medidas de densidade das plantas invasoras para classificar em folhas largas ou folhas estreitas a fim de fazer a aplicação seletiva de herbicida em tempo real. Os resultados apresentaram mais de 95% de precisão sob 170 amostras de imagens (largas e estreitas) com 70 exemplos de cada categoria de plantas invasoras.

Dois métodos de linha de segmentação otimizada entre cultura e plantas invasoras foram apresentados por Mao e colaboradores (MAO et al., 2008). O primeiro método usava as componentes G (*green*) e R (*red*) do espaço de cores RGB (*Red Green Blue*), já o segundo usava as componentes H (*hue*) e S (*saturation*) do espaço HSI (*Hue Saturation Intensity*). O resultado da análise estatística desses dois métodos mostrou que ambos podem ser usados para diferenciar as plantas invasoras da cultura do trigo (*Triticum aestivum*), além disso, o método que utiliza as componentes H-S pôde evitar efeitos de iluminação, por usar a informação espectral da banda G onde a matiz foi considerada como comprimento de onda e a saturação foi representada como refletância.

Análise de Imagens Digitais

Este capítulo apresenta e discute técnicas de processamento digital de imagens para a análise das mesmas, abrangendo a aquisição de imagens, técnicas de pré-processamento, de segmentação, alguns descritores de forma e baseados em momentos, além da análise de textura.

2.1 Aquisição de imagens

A palavra imagem vem do latim *imago*, que significa representação visual de um objeto. As imagens podem ter diferentes origens, podendo ser captadas por comprimento de onda de radiação eletromagnética (como máquinas fotográficas), ou por ondas sonoras de alta frequência (como ultra-som). As imagens geradas por radiação podem ser obtidas de várias maneiras, como radiação refletida por objetos iluminados por fontes, radiação absorvida, objetos translúcidos ou diretamente do emissor da radiação (CONCI et al., 2008).

Uma imagem digital consiste na formatação de sua representação de modo que os computadores possam utilizá-las. A imagem digital é obtida pela conversão de uma representação contínua para discreta, ou representação real para digital. A partir de uma

iluminação, que pode ser natural ou artificial, que é refletida pelo objeto, tem-se a formação de uma imagem, que pode ser expressa por:

$$f(x, y) = i(x, y) \cdot r(x, y) \quad (1)$$

onde $i(x, y)$ representa a luz que incide sobre o objeto e $r(x, y)$ representa a luz que é refletida pelo mesmo.

A função f definida na equação 1 resulta na intensidade da luz no ponto (x, y) , formada por dois fatores, a quantidade de luz existente na cena onde o objeto foi capturado, representado por i , e pela reflexão desta luz pelo objeto, representado por r , ambos em um dado ponto (x, y) da imagem. Neste modelo a função f é dada como o produto de i , característica do ambiente e r , característica do objeto.

Uma imagem digital, $f(x, y)$, é representada e organizada em uma matriz cuja intersecção de uma linha e coluna forma um ponto na imagem, conhecido como *pixel*, que armazena o valor da intensidade de luz naquela coordenada, dito nível de cinza.

Uma propriedade importante a ser destacada sobre as imagens digitais é a vizinhança. Um *pixel* p , de coordenadas (x, y) , possui quatro vizinhos horizontais e verticais, de coordenadas $(x-1, y)$, $(x+1, y)$, $(x, y-1)$ e $(x, y+1)$, que formam a conhecida “4-vizinhança” de p . Os quatro vizinhos diagonais de p são aqueles de coordenadas $(x-1, y-1)$, $(x+1, y-1)$, $(x-1, y+1)$ e $(x+1, y+1)$. E por fim a “8-vizinhança” de p é definida como a união dos dois conjuntos apresentados anteriormente. Este conceito de vizinhança está ilustrado na Figura 2.

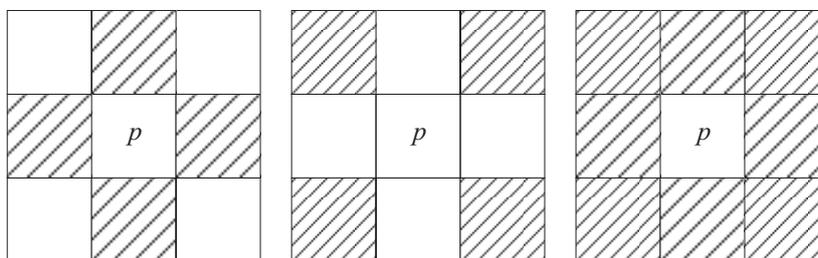


Figura 2: Representação de vizinhança, onde se tem x pixels conectados ao *pixel* p : (a) 4-vizinhança, (b) vizinhança diagonal e (c) 8-vizinhança.

2.2 Pré-Processamento

O pré-processamento de uma imagem é visto como a etapa anterior ao seu processamento efetivo, como o próprio nome sugere. Esta etapa é importante pois prepara a imagem para que a mesma possa ter um processamento satisfatório. Algumas técnicas podem ser utilizadas nesta etapa, entre elas filtragem e modificação de histograma.

2.2.1 Filtragem

A filtragem de uma imagem é utilizada para corrigir e realçar detalhes. Enquanto a correção é a remoção das características indesejáveis, a melhora/realce é a acentuação das características desejáveis. É importante destacar que não existe uma técnica melhor ou pior, toda aplicação de filtros depende de uma análise prévia do observador (MARQUES FILHO;VIEIRA NETO, 1999). Sendo assim, serão apresentadas nesta subseção algumas técnicas de filtragem, que futuramente serão discutidas no domínio da aplicação desta dissertação.

As técnicas de filtragem podem ser divididas em algumas categorias, como: filtragem espacial ou no domínio da frequência; filtragem passa-alta, passa-baixa ou passa-faixa; filtros lineares ou não lineares; ou ainda, filtros de suavização, de contraste, adaptativos, globais, janelados ou locais. Um detalhe importante a ser observado é que com a aplicação de filtros, alguns *pixels* da imagem podem ter valores inválidos (negativos, ou fora do limite) atribuídos, portanto é necessário fazer a verificação e correção destes possíveis casos (CONCI et al., 2008).

Filtragem no Domínio da Frequência

Para se realizar a filtragem no domínio da frequência é necessário primeiramente adequar a imagem para este domínio. A adequação ou conversão para o domínio da frequência pode ser feita, por exemplo, com o uso da transformada de Fourier.

A operação convolução, denotada pelo símbolo $*$, é a base matemática das técnicas de filtragem no domínio da frequência (GONZALEZ;WOODS, 1992), expresso por:

$$g(x, y) = f(x, y) * h(x, y) \quad (2)$$

onde $g(x, y)$ é a imagem formada pela convolução da imagem $f(x, y)$ com um operador linear $h(x, y)$.

Pelo teorema, no domínio da frequência a seguinte relação também é válida:

$$G(x, y) = F(x, y) \cdot H(x, y) \quad (3)$$

onde G , F e H são transformadas de Fourier de g , f e h , respectivamente, e \cdot representa o produto ponto a ponto das matrizes.

Filtragem no Domínio Espacial

As técnicas de filtragem no domínio espacial consistem na aplicação de filtros diretamente sobre os *pixels* da imagem, utilizando operações de convolução com máscaras. O uso destas máscaras no domínio espacial é chamado de filtragem espacial, e as máscaras são chamadas de filtros espaciais.

A função de filtragem de imagens no domínio espacial pode ser expressa por:

$$g(x, y) = T[f(x, y)] \quad (4)$$

onde $f(x, y)$ representa a imagem original, T um operador sobre f , definido com uma determinada vizinhança do *pixel* de posição (x, y) e $g(x, y)$ a imagem processada.

A vizinhança ao redor do *pixel* de posição (x, y) mais comum é a 8-vizinhança, que equivale a uma região 3×3 na qual o *pixel* central é o *pixel* de referência, formando uma máscara, que pode ser entendida também como uma subimagem, conforme ilustrado na Figura 3. Ainda pode-se considerar outros tamanhos de máscaras, 5×5 , 7×7 , 9×9 , entre outros, dependendo da aplicação.

A seguir, serão apresentados os filtros passa-baixas e passa-altas, onde os passa-baixas são os filtros responsáveis pela eliminação das componentes de alta frequência da imagem, e os passa-altas pela eliminação das componentes de baixa frequência.

Filtros Passa-Baixas

Os filtros passa-baixas são responsáveis pela suavização da imagem no domínio espacial. Esta suavização é obtida pela atenuação ou eliminação de componentes de alta

frequência presentes na imagem, que correspondem às regiões de bordas e/ou detalhes finos, portanto como resultado da aplicação deste tipo de filtro, temos uma imagem levemente borrada. O objetivo desta filtragem é a eliminação de ruídos, e como consequência temos a perda de nitidez. Dentre os vários tipos de filtros passa-baixas, a média, mediana e o gaussiano, se destacam e serão apresentados no decorrer desta subseção.

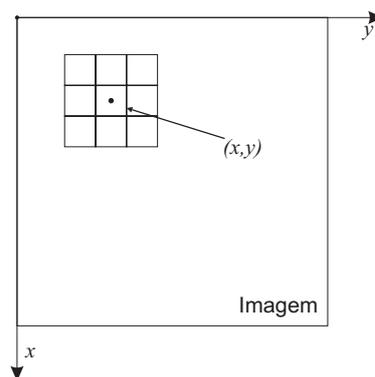


Figura 3: Vizinhança 3×3 ao redor de um *pixel* de coordenadas (x, y) em uma imagem.

Filtro de Média: O filtro da média se constitui em tirar a média das intensidades dentro de uma máscara de tamanho $n \times n$. Para se obter esta média basta utilizar o coeficiente igual a 1 em todas as posições da máscara e ao final dividir o valor obtido por n^2 , que é a quantidade de *pixels* da máscara. As máscaras de vizinhança 3×3 e 5×5 estão representadas na próxima equação (GONZALEZ;WOODS, 1992):

$$Z_{M1} = \frac{1}{9} \begin{bmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{bmatrix} \quad \text{e} \quad Z_{M2} = \frac{1}{25} \begin{bmatrix} 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 \end{bmatrix} \quad (5)$$

Filtro Gaussiano: Assim como o filtro da média, o filtro gaussiano também reduz o ruído da imagem, porém ele preserva os contornos da mesma, por não possuir todos os pesos iguais. Este filtro é baseado na aproximação digital da função gaussiana, cujas

máscaras 3×3 e 5×5 são representadas por (CONCI et al., 2008):

$$Z_{G1} = \frac{1}{16} \begin{bmatrix} 1 & 2 & 1 \\ 2 & 4 & 2 \\ 1 & 2 & 1 \end{bmatrix} \quad \text{e} \quad Z_{G2} = \frac{1}{273} \begin{bmatrix} 1 & 4 & 7 & 4 & 1 \\ 4 & 16 & 26 & 16 & 4 \\ 7 & 26 & 41 & 26 & 7 \\ 4 & 16 & 26 & 16 & 4 \\ 1 & 4 & 7 & 4 & 1 \end{bmatrix} \quad (6)$$

Filtro de Mediana: O filtro de mediana substitui o *pixel* central da máscara pela mediana de seus vizinhos, visando contornar a deficiência do filtro de média, que é a perda dos detalhes finos e bordas da imagem.

A mediana m de um conjunto com n elementos é o valor tal que metade dos n elementos se situem abaixo de m e a outra metade acima dele. Quando n for ímpar a mediana é o elemento central do conjunto ordenado, e quando for par corresponde a média dos dois elementos centrais do conjunto ordenado.

Filtros Passa-Altas

Os filtros passa-altas agem atenuando ou eliminando os componentes de baixa frequência, obtendo como resultado uma imagem com as bordas e regiões de alto contraste realçadas. Desta forma, eles destacam as características como bordas, linhas, curvas e manchas. Portanto, a maioria dos operadores de detecção de bordas baseiam-se em uma filtragem passa-alta.

Filtro Sobel: O filtro sobel faz ao mesmo tempo a suavização e diferenciação da imagem, onde o efeito de suavização é responsável pela atenuação do impacto dos ruídos e a diferenciação faz o realce de linhas horizontais e verticais sem realçar pontos isolados.

As duas máscaras de sobel são (GONZALEZ;WOODS, 1992):

$$Z_h = \begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix} \quad \text{e} \quad Z_v = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix} \quad (7)$$

Filtro Laplaciano: O filtro laplaciano tem como condição básica que o coeficiente asso-

ciado ao *pixel* central deve ser sempre positivo, e os demais negativos. A soma dos coeficientes do filtro laplaciano deve ser zero, porém o resultado na imagem só será zero quando o *pixel* central não apresentar variação com os seus vizinhos. Algumas máscaras laplacianas são representadas por (MARQUES FILHO;VIEIRA NETO, 1999):

$$Z_{L1} = \begin{bmatrix} 0 & -1 & 0 \\ -1 & 4 & -1 \\ 0 & -1 & 0 \end{bmatrix}, \quad Z_{L2} = \begin{bmatrix} -1 & -1 & -1 \\ -1 & 8 & -1 \\ -1 & -1 & -1 \end{bmatrix} \quad \text{e} \quad Z_{L3} = \begin{bmatrix} 1 & -2 & 1 \\ -2 & 4 & -2 \\ 1 & -2 & 1 \end{bmatrix} \quad (8)$$

Filtro Laplaciano do Gaussiano: O filtro laplaciano do gaussiano é uma junção de dois filtros lineares, o laplaciano e o gaussiano. Como o laplaciano é muito sensível a ruídos, ele é aplicado em conjunto com um filtro passa-baixa. O efeito do filtro é salientar os contornos dos objetos. A equação 9 expressa a representação digital do filtro para $\sigma = 1,4$, sendo que máscaras maiores ou menores também podem ser utilizadas, como pode ser visto na equação 10 (CONCI et al., 2008).

$$Z_{LG2} = \begin{bmatrix} 0 & 1 & 1 & 2 & 2 & 2 & 1 & 1 & 0 \\ 1 & 2 & 4 & 5 & 5 & 5 & 4 & 2 & 1 \\ 1 & 4 & 5 & 3 & 0 & 3 & 5 & 4 & 1 \\ 2 & 5 & 3 & -12 & -24 & -12 & 3 & 5 & 2 \\ 2 & 5 & 0 & -24 & -40 & -24 & 0 & 5 & 2 \\ 2 & 5 & 3 & -12 & -24 & -12 & 3 & 5 & 2 \\ 1 & 4 & 5 & 3 & 0 & 3 & 5 & 4 & 1 \\ 1 & 2 & 4 & 5 & 5 & 5 & 4 & 2 & 1 \\ 0 & 1 & 1 & 2 & 2 & 2 & 1 & 1 & 0 \end{bmatrix} \quad (9)$$

$$Z_{LG1} = \begin{bmatrix} 0 & 0 & -1 & 0 & 0 \\ 0 & -1 & -2 & -1 & 0 \\ -1 & -2 & 16 & -2 & -1 \\ 0 & -1 & -2 & -1 & 0 \\ 0 & 0 & -1 & 0 & 0 \end{bmatrix} \quad (10)$$

2.2.2 Modificação do Histograma

Uma das informações mais relevantes de uma imagem é referente ao tom de seus *pixels*. Para a análise de uma imagem podemos utilizar uma ferramenta chamada de histograma.

O histograma de uma imagem é um conjunto de números que indica o percentual de *pixels* de uma determinada intensidade (nível de cinza) na imagem. Este percentual geralmente é representado por um gráfico de barras. Sendo assim, um histograma é a representação gráfica da ocorrência de cada nível de cinza na imagem. Através do histograma é possível analisar algumas propriedades da imagem, como o nível de contraste e brilho médio da mesma.

Cada elemento do histograma é calculado por:

$$p_r(r_k) = \frac{n_k}{n} \quad (11)$$

onde, $0 \leq r_k \leq 1$; $k = 0, 1, \dots, L - 1$; L é o número de níveis de cinza da imagem digitalizada; n = número total de *pixels* na imagem e $n \neq 0$; $p_r(r_k)$ = probabilidade do k -ésimo nível de cinza; e n_k = número de *pixels* cujo nível de cinza corresponde a k .

Equalização do Histograma

A equalização do histograma procura redistribuir as intensidades do histograma original, de modo a obter um histograma uniforme, com praticamente todas as intensidades com o mesmo percentual. Para tal, pode ser utilizada uma função de distribuição acumulada da distribuição de probabilidade original, expressa por:

$$s_k = T(r_k) = \sum_{k=0}^{k=r_{\max}} p_r(r_k) = \sum_{k=0}^{k=r_{\max}} \frac{n_k}{n} \quad (12)$$

onde $0 \leq r_k \leq 1$ e $k = 0, 1, \dots, L - 1$.

A equalização do histograma, pode ser aplicada em partes da imagem, por exemplo, em uma janela $n \times m$. A aplicação local serve principalmente para realçar detalhes sutis de pequenas porções da imagem.

2.3 Segmentação

Segmentação de imagem é a decomposição da mesma em seus componentes (JAIN, 1989). Algumas técnicas de segmentação são fundamentadas em: amplitude de limiarização, rotulação de componente, abordagens baseadas em contorno, abordagens baseadas em regiões e agrupamento, casamento de modelo e segmentação de texturas.

Segmentação também pode ser definida como a simplificação da imagem, reduzindo-a em seus componentes básicos, ou objetos, sem descartar suas características relevantes (BAXES, 1994). A definição de “características relevantes” depende do requisito particular da imagem. Uma operação de segmentação é qualquer operação que destaca, ou de alguma forma isola, objetos individuais dentro de uma imagem considerada. A segmentação subdivide uma imagem em seus elementos ou objetos, especificando que o nível ao qual cada uma destas subdivisões é levada depende do problema que é resolvido, isto é, a segmentação deve parar quando os objetos de interesse em uma aplicação tiverem sido isolados (GONZALEZ;WOODS, 1992).

O processo de segmentação da imagem pode ser dividido em três estágios: pré-processamento, discriminação inicial do objeto e limpeza do contorno do objeto. No primeiro a imagem é melhorada visualmente, sem perder nenhuma informação. No segundo os objetos são claramente separados em grupos de atributos similares. No terceiro o contorno do objeto é reduzido à largura de um único *pixel* e também são removidos ruídos desordenados e outros artefatos.

Algoritmos de segmentação para imagens monocromáticas geralmente são baseados em uma ou duas propriedades básicas de nível de cinza: descontinuidade e similaridade. Na primeira categoria, a estratégia consiste em dividir uma imagem baseada nas grandes mudanças do nível de cinza, e as principais áreas de interesse desta categoria são descobertas de pontos isolados e descoberta de linhas e bordas em uma imagem. A principal estratégia na segunda categoria é baseada na limiarização, crescimento de região e divisão e fusão de regiões. O conceito de segmentação de imagem baseado na descontinuidade ou similaridade dos valores de nível de cinza dos *pixels* é aplicável tanto em imagens estáticas quanto dinâmicas (GONZALEZ;WOODS, 1992).

A limiarização é um dos métodos mais importantes em segmentação de imagens.

Os métodos mais simples e usados para segmentação de imagens são baseados na limiarização, também conhecida como *thresholding*. A idéia básica por trás deste método é simples (COSTA;CESAR, 2001). Geralmente é usada a limiarização quando se tem objetos com intensidades homogêneas e o fundo com um nível de intensidade diferente (PITAS, 1993). Uma imagem pode ser segmentada em duas regiões por limiarização simples, a qual é dada por:

$$g(x, y) = \begin{cases} 1, & \text{se } f(x, y) > L \\ 0, & \text{caso contrário} \end{cases} \quad (13)$$

A escolha do limiar L pode ser baseado no histograma da imagem sob análise.

2.3.1 Segmentação por Regiões

Proximidade geométrica desempenha um papel importante na segmentação de imagens. *Pixels* de mesma vizinhança tendem a ter propriedades estatísticas semelhantes e pertencer às mesmas regiões na imagem. Por isso algoritmos de segmentação devem incorporar, se possível, proximidade e homogeneidade para produzir regiões conectadas (PITAS, 1993).

Sendo R a representação da região de toda a imagem, a segmentação deve ser vista como o processo de divisão de R em n sub-regiões, R_1, R_2, \dots, R_n , tal que:

$$\left. \begin{array}{l} \text{(a) } \bigcup_{i=1}^n R_i = R, \\ \text{(b) } R_i \text{ é uma região conectada, } i = 1, 2, \dots, n, \\ \text{(c) } R_i \cap R_j = \phi \text{ para todo } i \text{ e } j, i \neq j, \\ \text{(d) } P(R_i) = V \text{ para } i = 1, 2, \dots, n, \text{ e} \\ \text{(e) } P(R_i \cup R_j) = F \text{ para } i \neq j \end{array} \right\} \quad (14)$$

onde $P(R_i)$ é um atributo lógico sobre os pontos no conjunto R_i e ϕ é o conjunto vazio.

As condições acima significam que: (a) a segmentação deve ser completa, ou seja, todo *pixel* deve pertencer a uma região; (b) os pontos em uma região devem estar conectados; (c) as regiões devem ser disjuntas; (d) a propriedade deve ser satisfeita pelos *pixels* em uma região segmentada - por exemplo $P(R_i) = V$ se todos os *pixels* de R_i têm

a mesma intensidade; e (e) as regiões R_i e R_j são diferentes em termos do atributo P (GONZALEZ;WOODS, 1992).

Crescimento de Região

O método de crescimento por região é iniciado com a seleção de um *pixel* individual, e vai agrupando a ele outros *pixels* que têm a mesma característica. Começa com algum *pixel* semente (geralmente providenciado pelo operador) e os *pixels* vizinhos são analisados um por vez e adicionados a região em crescimento, se forem suficientemente similares. Novamente, a comparação pode ser feita à região inteira ou apenas ao local do *pixel*, permitindo uma variação gradual no brilho. O procedimento continua até que nenhum outro *pixel* possa ser adicionado (RUSS, 2006).

Um exemplo de crescimento por região onde os números de cada célula representam seus valores de níveis de cinza, e as sementes são os *pixels* de coordenadas (3, 2) e (3, 4) é ilustrado na Figura 4.

0 0 5 6 7	a a b b b	a a a a a
1 1 5 8 7	a a b b b	a a a a a
0 1 6 7 7	a a b b b	a a a a a
2 0 7 6 6	a a b b b	a a a a a
0 1 5 6 5	a a b b b	a a a a a
(a)	(b)	(c)

Figura 4: Exemplo de crescimento de região usando duas sementes, identificadas pelos números 1 e 7 em negrito na primeira matriz: (a) matriz da imagem original; (b) resultado da segmentação usando um limiar 3; (c) resultado usando limiar 8.

Usando duas sementes (dois *pixels* de início) o resultado da segmentação consiste em no máximo duas regiões: R_1 associada ao *pixel* de coordenadas (3, 2) e R_2 associada à semente de coordenadas (3, 4). A propriedade P a ser usada para incluir um *pixel* a uma região é a diferença absoluta entre os níveis de cinza do *pixel* e o nível de cinza da semente, que deve ser menor que o limiar L . Qualquer *pixel* que satisfaça essa propriedade simultaneamente para ambas as sementes é, aleatoriamente, associado a região R_1 . A Figura 4(b) mostra o resultado obtido quando o valor de L era igual a 3, e a Figura 4(c) o resultado para um limiar igual a 8.

Divisão e Fusão de Regiões

A divisão e fusão de regiões é um método que começa a operação com a imagem inteira e termina quando é alcançado um *pixel* individual. Alguma propriedade da imagem é selecionada como critério para decidir o que é uniforme, critério este geralmente baseado em estatísticas do histograma de brilho. Se o histograma é multimodal ou tem uma derivação padrão alta, então a região é assumida como não uniforme e é derivada em quatro quadrantes. Cada quadrante é examinado da mesma forma e é subdividido se necessário. A relação entre a região pai e seus quatro quadrantes, ou filhos, é tipicamente codificada por uma estrutura *quadtree*, conforme ilustrada na Figura 5.

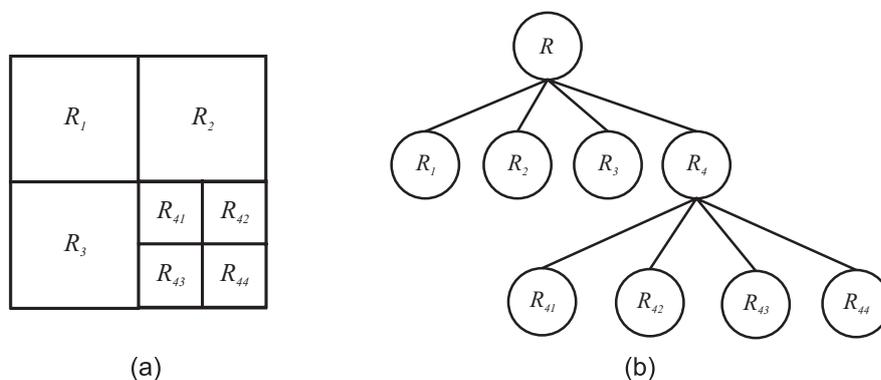


Figura 5: (a) Imagem dividida; (b) *quadtree* correspondente (GONZALEZ;WOODS, 1992). Uma região R foi dividida em 4 quadrantes, R_1 , R_2 , R_3 e R_4 , e a região R_4 foi subdividida em R_{41} , R_{42} , R_{43} e R_{44}

Subdividindo regiões sozinhas não se cria uma segmentação de imagem funcional. Para cada interação de subdivisão, cada região é comparada às adjacentes que se encontram em quadrantes diferentes até o nível mais alto de hierarquia. Se elas forem similares, serão mescladas, ou fundidas. A definição de similaridade pode usar os mesmos testes da operação de divisão, ou comparações que podem ser feitas apenas para *pixels* ao longo da borda comum. A última tem a vantagem de tolerância gradual ao caminho da imagem. O procedimento da divisão e fusão de regiões pode ser resumido nos passos:

- (a) Dividir em quatro quadrantes disjuntos qualquer região R_i onde $P(R_i) = F$;
- (b) Fundir qualquer região adjacente R_j e R_k para as quais $P(R_j \cup R_k) = V$; e
- (c) Parar quando não houver mais nenhuma possível divisão ou fusão.

2.3.2 Detecção de Bordas

Apesar da detecção de *pixels* e linhas serem certamente os elementos de qualquer discussão de segmentação, detecção de borda é certamente a abordagem mais comum para detecção significativa em níveis de cinza descontínuos. O motivo é que pontos e linhas isolados não são ocorrências frequentes na maioria das aplicações práticas (GONZALEZ;WOODS, 1992).

Vários detectores de bordas são encontrados na literatura, os quais podem ser agrupados em duas classes: *técnicas locais*: que usam operadores na vizinhança e *técnicas globais*: usam informações globais e métodos de filtragem para extrair informação da borda (PITAS, 1993).

A detecção de bordas é implementada por filtros espaciais (BAXES, 1994). Três filtros de bordas são mais comuns em muitas tarefas de processamento de imagens: deslocamento e diferença, gradiente de *Prewitt* e Laplaciano.

O mais simples dos filtros é o de deslocamento e diferença (*shift and difference*). Para realçar as informações horizontais e verticais das bordas, a imagem é deslocada em um *pixel* para a esquerda e então subtraído o resultado da imagem original, fazendo com que as bordas verticais apareçam. Analogamente, o filtro horizontal pode ser implementado deslocando a imagem um *pixel* para cima e executando a diferença. Esta operação pode ser executada usando as máscaras para filtragem vertical e horizontal, representadas na equação 15.

$$V = \begin{bmatrix} 0 & 0 & 0 \\ -1 & 1 & 0 \\ 0 & 0 & 0 \end{bmatrix} \quad \text{e} \quad H = \begin{bmatrix} 0 & -1 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 0 \end{bmatrix} \quad (15)$$

A operação de gradiente de *Prewitt* forma um realce de borda direcional. Usando uma máscara 3×3 , oito imagens gradientes podem ser geradas a partir da imagem original, uma em cada direção - Norte, Nordeste, Leste, Sudeste, Sul, Sudoeste, Oeste e Noroeste. A Figura 6 mostra as oito possíveis máscaras 3×3 do filtro de *Prewitt*, sendo uma em cada direção mencionada anteriormente (PRATT, 1991).

$$\begin{array}{cccc}
 \begin{bmatrix} -1 & -1 & -1 \\ 1 & -2 & 1 \\ 1 & 1 & 1 \end{bmatrix} & \begin{bmatrix} 1 & 1 & 1 \\ 1 & -2 & 1 \\ -1 & -1 & -1 \end{bmatrix} & \begin{bmatrix} 1 & 1 & -1 \\ 1 & -2 & -1 \\ 1 & 1 & -1 \end{bmatrix} & \begin{bmatrix} -1 & 1 & 1 \\ -1 & -2 & 1 \\ -1 & 1 & 1 \end{bmatrix} \\
 \text{(a)} & \text{(b)} & \text{(c)} & \text{(d)} \\
 \\
 \begin{bmatrix} -1 & -1 & 1 \\ -1 & -2 & 1 \\ 1 & 1 & 1 \end{bmatrix} & \begin{bmatrix} 1 & -1 & -1 \\ 1 & -2 & -1 \\ 1 & 1 & 1 \end{bmatrix} & \begin{bmatrix} 1 & 1 & 1 \\ -1 & -2 & 1 \\ -1 & -1 & 1 \end{bmatrix} & \begin{bmatrix} 1 & 1 & 1 \\ 1 & -2 & -1 \\ 1 & -1 & -1 \end{bmatrix} \\
 \text{(e)} & \text{(f)} & \text{(g)} & \text{(h)}
 \end{array}$$

Figura 6: Filtros de *Prewitt* nas oito direções possíveis: (a) Norte; (b) Sul; (c) Leste; (d) Oeste; (e) Noroeste; (f) Nordeste; (g) Sudoeste; (h) Sudeste.

O realce de bordas também pode ser feito pelo filtro laplaciano, que é uma operação onidirecional, evidenciando todas as bordas de uma imagem, independente de sua orientação.

2.4 Descritores de Forma

Uma vez que a imagem é segmentada, o próximo passo para a análise das características é buscar as informações individuais de cada objeto, que são obtidas com base no uso de descritores. Com estas medidas podemos comparar a informação dos objetos com medidas previamente conhecidas para enfim classificar o objeto em uma das várias categorias (BAXES, 1994). Existem vários tipos de descritores capazes de descrever as características de um objeto, como descritores de forma, textura ou cor.

Segundo Pitas (1993), descrição de forma é um problema importante tanto em análise quanto em síntese de imagens. A representação da forma obtida por técnicas de análise de imagens pode ser usada para aplicações de reconhecimento de objetos, em aplicações gráficas e representações de objetos bi e tridimensionais. Elas podem ser obtidas através de modelagem do objeto e são usadas para a síntese de imagens digitais. As representações devem descrever vários esquemas de forma bidimensional e suas aplicações se dão em análise de imagens, visão computacional e reconhecimento de padrões.

Formas bidimensionais podem ser descritas de duas maneiras diferentes. O primeiro método visa usar o contorno do objeto e suas características (como o tamanho do contorno, curvatura, assinatura, descritores de Fourier, etc.), e o segundo visa descrever a região ocupada pelo objeto no plano da imagem. O primeiro método está diretamente ligado à detecção de linhas e bordas e os esquemas descritores resultantes são chamados de representações externas. Estes gozam de certa popularidade, pois produzem uma compacta representação da forma. O segundo método é conectado às técnicas de segmentação de região. Os esquemas de segmentação conduzem diretamente para esquemas de representação do objeto. Descritores de região (como área, momentos e esqueletização) têm sido usados extensivamente em aplicações de reconhecimento de objetos.

Esquemas de representação de forma devem possuir algumas propriedades, como:

1. *Singularidade*: cada objeto deve ter uma representação única;
2. *Completude*: representação não ambígua;
3. *Invariância sob transformações geométricas*: invariância sob translações, rotações, escalonamento e reflexões;
4. *Sensitividade*: habilidade de refletir facilmente as diferenças entre objetos similares;
5. *Abstração de detalhes*: habilidade da representação das características básicas de uma forma e de abstração dos detalhes. Esta propriedade está diretamente relacionada à robustez do ruído da representação.

A representação da forma pode ser dividida em algumas categorias, como descritores de características regenerativas (contorno, regiões, momentos, bem como estrutural e sintática), medidas geométricas (perímetro, área, etc.) e medidas de momento (centro de massa, orientação, etc.).

2.4.1 Descritores Geométricos

Perímetro

O perímetro mede a quantidade de *pixels* em torno do contorno do objeto. Para computar precisamente o perímetro, a distância de *pixel* é uma unidade (1) quando o *pixel* do contorno é conectado com seu vizinho verticalmente ou horizontalmente, ou $\sqrt{2}$ (1,414)

quando o *pixel* é conectado com seu vizinho diagonalmente. A soma destas distâncias fornece o comprimento do contorno do objeto.

Área

Refere-se a área do interior do objeto, computada como o número total de *pixels* dentro do objeto, incluindo seu contorno. Pode-se interpretar a área como a medida do tamanho do objeto. Deve-se ter cuidado ao calcular a área de objetos com buracos, não incluindo o total da área dos buracos.

Eixos Principais

O maior eixo que atravessa o objeto, é a linha mais longa que pode ser traçada dentro do objeto (BAXES, 1994). Os pontos da extremidade da linha são determinados computando-se a maior distância de *pixel* entre toda combinação de *pixel* de borda no contorno do objeto, sendo que a linha formada pelos pontos se mantém sempre dentro do objeto. O menor eixo é a linha mais longa que pode ser traçada dentro do objeto, mantendo perpendicularidade com o maior eixo.

O eixo principal é a direção ao longo da qual a forma é mais alongada. Perpendicularmente ao maior eixo tem-se o menor eixo. Esses eixos são relacionados com o autovetor da matriz de covariância (GONZALEZ;WOODS, 1992; COSTA;CESAR, 2001).

Caixa de Enquadramento

Também conhecido como retângulo de enquadramento, ou mínimo retângulo circunscrito, refere ao menor retângulo que cerca o objeto, o qual é sempre alinhado com a sua orientação. Sendo conhecida a orientação, ângulo θ , usa-se as transformações:

$$\left. \begin{aligned} \alpha &= x \cos \theta + y \operatorname{sen} \theta \\ \beta &= -x \operatorname{sen} \theta + y \cos \theta \end{aligned} \right\} \quad (16)$$

nos pontos pertencentes a borda e encontra-se α_{\max} , α_{\min} , β_{\max} e β_{\min} . A partir destes pontos, a caixa de enquadramento é conhecida imediatamente com o comprimento $\text{comprimento} = \alpha_{\max} - \alpha_{\min}$ e a largura $\text{largura} = \beta_{\max} - \beta_{\min}$.

2.4.2 Descritores Baseados em Momentos

Características também podem ser representadas em termos de momentos. Os momentos espaciais de um objeto são medidas estatísticas de forma que não fazem de fato a caracterização específica do objeto, como as medidas de forma mencionadas. Particularmente, momentos espaciais fornecem medidas estatísticas relacionadas às caracterizações do objeto.

Orientação

Refere-se ao ângulo entre o maior eixo e o eixo x , também conhecido como eixo das abcissas. O resultado é a medida de orientação do objeto, e seu valor pode ser entre 0° e 360° .

$$\text{Orientacao} = \tan^{-1} \left(\frac{y_2 - y_1}{x_2 - x_1} \right) \quad (17)$$

onde (x_1, x_2) e (y_1, y_2) são dois pontos pertencentes ao maior eixo e $x_1 \neq x_2$.

Centro de Massa

O Centro de massa é o ponto de equilíbrio (x, y) do objeto, onde há a mesma massa em cima, abaixo, à direita e à esquerda. Objetos simétricos, como retângulos e elipses, têm seu centro de massa nos centros do maior e menor eixos, os quais são dados por:

$$\left. \begin{aligned} \text{Centro de Massa}_x &= \frac{\text{soma das coordenadas } x \text{ dos pixels do objeto}}{\text{Area}} \\ \text{Centro de Massa}_y &= \frac{\text{soma das coordenadas } y \text{ dos pixels do objeto}}{\text{Area}} \end{aligned} \right\} \quad (18)$$

onde $\text{Area} \neq 0$.

Momentos Invariantes

Esses momentos são invariantes sob transformações lineares, por isso são descritores úteis em problemas de reconhecimento de padrões, e para análise de formas. Usando N momentos, por exemplo, a imagem pode ser representada como um ponto em um espaço

de vetor N -dimensional. Suponha que $g(p, q)$ é a função que denota a imagem da forma. Os momentos 2D padrões são definidos como:

$$m_{r,s} = \sum_{p=0}^{P-1} \sum_{q=0}^{Q-1} p^r q^s g(p, q) \quad (19)$$

onde, r e s são índices utilizados na definição da ordem do momento calculado de forma tal que a ordem do mesmo é dada por $(r + s)$, onde $r, s = 0, 1, 2, \dots$

O momento central, denotado por $\mu_{r,s}$, pode ser definido como:

$$\mu_{r,s} = \sum_{p=0}^{P-1} \sum_{q=0}^{Q-1} (p - \bar{p})^r (q - \bar{q})^s g(p, q) \quad (20)$$

onde

$$\bar{p} = \frac{m_{1,0}}{m_{0,0}} \quad \text{e} \quad \bar{q} = \frac{m_{0,1}}{m_{0,0}} \quad (21)$$

Os momentos centrais até ordem 3 são:

$$\begin{aligned} \mu_{00} &= m_{00} \\ \mu_{10} &= \mu_{01} = 0 \\ \mu_{20} &= m_{20} - \bar{p}m_{10} \\ \mu_{02} &= m_{02} - \bar{q}m_{01} \\ \mu_{11} &= m_{11} - \bar{q}m_{10} \\ \mu_{30} &= m_{30} - 3\bar{p}m_{20} + 2m_{10}\bar{p}^2 \\ \mu_{12} &= m_{12} - 2\bar{q}m_{11} - \bar{p}m_{02} + 2\bar{q}^2m_{10} \\ \mu_{21} &= m_{21} - 2\bar{p}m_{11} - \bar{q}m_{20} + 2\bar{p}^2m_{01} \\ \mu_{03} &= m_{03} - 3\bar{q}m_{02} + 2\bar{q}^2m_{01} \end{aligned} \quad (22)$$

Os momentos centrais normalizados, denotados por $\eta_{r,s}$, de ordem $(r + s)$, são definidos como:

$$\eta_{r,s} = \frac{\mu_{r,s}}{\mu_{00}^\gamma}, \quad \text{onde } \gamma = \frac{r+s}{2} + 1, \quad \text{para } r+s = 2, 3, \dots \quad (23)$$

Finalmente, um conjunto de momentos invariantes pode ser derivado do segundo e terceiro momentos. Este conjunto de momentos é invariante à translação, rotação e mudança de escala (HU, 1962, citado por GONZALEZ;WOODS, 1992).

$$\begin{aligned}
\phi_1 &= \eta_{20} + \eta_{02} \\
\phi_2 &= (\eta_{20} + \eta_{02})^2 + 4\eta_{11}^2 \\
\phi_3 &= (\eta_{30} - 3\eta_{12})^2 + (3\eta_{21} - \eta_{03})^2 \\
\phi_4 &= (\eta_{30} + 3\eta_{12})^2 + (\eta_{21} + \eta_{03})^2 \\
\phi_5 &= (\eta_{30} - 3\eta_{12})(\eta_{30} + \eta_{12}) [(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2] + \\
&\quad (3\eta_{21} - \eta_{03})(\eta_{21} + \eta_{03}) [3(\eta_{30} + 3\eta_{12})^2 - (\eta_{21} + \eta_{03})^2] \\
\phi_6 &= (\eta_{20} - \eta_{02}) [(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2] + \\
&\quad 4\eta_{11}(\eta_{30} + \eta_{12})(\eta_{21} + \eta_{03}) \\
\phi_7 &= (3\eta_{21} - \eta_{03})(\eta_{30} + \eta_{12}) [(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2] + \\
&\quad (3\eta_{12} - \eta_{30})(\eta_{21} + \eta_{03}) [3(\eta_{30} + 3\eta_{12})^2 - (\eta_{21} + \eta_{03})^2]
\end{aligned} \tag{24}$$

2.5 Análise de Textura

A textura constitui uma característica diretamente relacionada com as propriedades físicas que a superfície de um objeto apresenta (lisa, rugosa, macia, áspera ou ondulada). Ela descreve o padrão de variação de tons de cinza ou cor numa determinada área. Trata-se de um termo intuitivo e de grandes utilidades, mas que, apesar de sua grande importância, não possui uma definição precisa.

Uma textura se caracteriza pela repetição de um modelo sobre uma região, sendo este modelo repetido em sua forma exata ou com pequenas variações. Através de sua análise é possível distinguir regiões que apresentem as mesmas características de refletância, e portanto, mesmas cores em determinada combinação de bandas. Isso torna a textura um excelente descritor regional, contribuindo para uma melhor precisão dos processos de reconhecimento, descrição e classificação de imagens (HARALICK et al., 1973; PRATT, 1991; RIBEIRO JR, 1995; TUCERYAN;JAIN, 1998; STEIN, 2005; DE-HUI et al., 2006; NUNES;CONCI, 2007).

As três principais abordagens usadas no processamento de imagens para descrever

a textura de uma região são (JAIN, 1989):

- *Estatística*: utiliza um conjunto de medidas estatísticas locais para representar uma imagem texturizada. Métodos estatísticos produzem melhores resultados quando aplicados sobre texturas naturais.
- *Estrutural*: as regiões da textura são consideradas como padrões bidimensionais compostos por primitivas que se relacionam. Métodos estruturais, por sua vez, apresentam melhores resultados quando aplicados sobre imagens texturais estruturais.
- *Espectral*: baseada em propriedades de espectros de frequência, obtidos através de transformadas tais como Fourier e Wavelets.

A Figura 7 ilustra em diagrama de blocos os principais métodos para medida de textura.

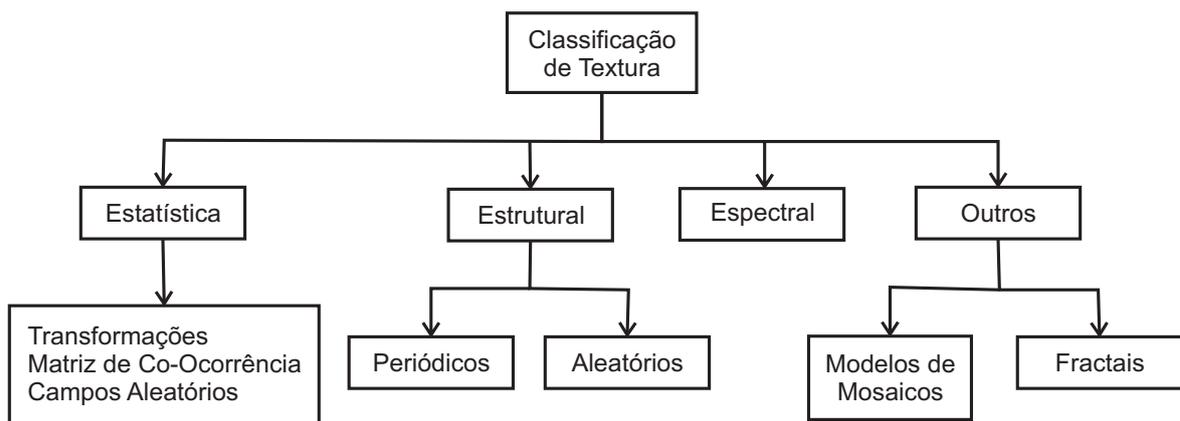


Figura 7: Métodos de Análise de Texturas (RIBEIRO JR, 1995), adaptado de (JAIN, 1989).

Segundo Haralick (HARALICK, 1979), quando uma imagem de textura é decomposta, ela tem duas dimensões básicas, sendo a primeira as primitivas das quais a imagem é composta e a segunda a descrição da dependência espacial ou interação entre as primitivas da imagem. A primeira dimensão preocupa-se com o tom ou propriedades locais das primitivas, enquanto a segunda preocupa-se com a organização espacial destes tons das primitivas.

Primitivas tonais são regiões com propriedades tonais, que incluem tanto tons de cinza como propriedades regionais destes tons. Elas podem ser descritas em termos de tom

médio, máximo ou mínimo de uma região. Uma região é um grupo de *pixels* conectados com uma determinada propriedade tonal. A região tonal pode ser avaliada em termos de sua área e forma.

A textura de uma imagem é descrita pelo número, tipos e a organização espacial ou *layout* de suas primitivas. A organização espacial pode ser aleatória, ter uma dependência em par de uma primitiva a vizinha, ou pode ter uma dependência de n primitivas ao mesmo tempo. Sendo que esta dependência pode ser estrutural, probabilística ou funcional (como uma dependência linear). Esta textura pode ser avaliada qualitativamente como tendo uma ou mais das seguintes propriedades: fineza, grossura, suavidade, granularidade, aleatoriedade, padronização, sendo irregular ou acidentado.

Para usar objetivamente o tom e os elementos padrões texturais, o conceito de características tonais e texturais devem estar explicitamente definidos. Com esta definição explícita, descobre-se que tom e textura não são conceitos independentes, então não foram apresentados dois conceitos, mas sim apenas um conceito de tom-textura.

Os inter-relacionamentos básicos no conceito tom-textura são: quando uma pequena área de uma imagem tem pequenas variações das primitivas tonais, a propriedade dominante desta área é o tom, assim como quando a pequena área tem grandes variações, a propriedade dominante é a textura. São cruciais nesta distinção o tamanho da pequena área, os tamanhos relativos e tipo das primitivas tonais, e o número e localização ou disposição das primitivas distinguíveis. Quando o número de primitivas tonais distinguíveis diminui, as propriedades tonais predominam. Na verdade, quando uma pequena área é apenas do tamanho de uma célula de resolução, então esta é apenas uma característica discreta, a única propriedade presente é o tom de cinza. Quando o número de primitivas tonais aumenta dentro da pequena área, textura é a propriedade dominante.

Resumindo, para caracterizar textura, devemos caracterizar as propriedades da primitiva tonal assim como a inter-relação entre elas. Isto implica que tom-textura é realmente uma estrutura de duas camadas, sendo a primeira ligada à especificação das primitivas locais, as quais se manifestam em primitivas tonais, e a segunda ligada à especificação da amostra através das primitivas tonais. Portanto, os métodos projetados para caracterizar textura devem ter partes dedicadas à análise de cada um destes aspectos de textura.

2.5.1 Abordagem Estatística

Na abordagem estatística a textura é descrita por um vetor de propriedades que representa um ponto em um espaço de característica multi-dimensional. O objetivo é encontrar uma regra de decisão determinística ou probabilística atribuindo a textura à alguma classe específica (SONKA et al., 1998).

Medidas obtidas através da Matriz de Co-Ocorrência

O método frequentemente citado para análise de textura estatística está baseado na extração de várias características texturais de uma matriz de co-ocorrência nivelada em cinza (*Grey Level Cooccurrence Matrix* - GLCM). Uma GLCM é uma matriz de tamanho $N_g \times N_g$, onde N_g é o número de níveis de cinzas, definida para um deslocamento de uma distância d junto com uma determinada direção θ . A entrada $p(i, j)$ desta matriz é o número de ocorrências de um par de níveis de cinza, i e j , para um deslocamento e ângulo especificado. Uma vez que a GLCM é definida, vários descritores texturais podem ser avaliados (BILLY et al., 2006). São considerados os mais usados: a entropia, a energia, o contraste, homogeneidade e a correlação, que são definidos a seguir:

Segundo Momento Angular (SMA) e Energia: avalia a uniformidade textural em uma imagem. Os valores elevados destas medidas ocorrem quando a imagem está muito ordenada.

$$SMA = \sum_i \sum_j p(i, j)^2 \quad (25)$$

$$Energia = \sqrt{SMA} \quad (26)$$

Entropia: mede a desordem em uma imagem, ou seja, o grau de dispersão de níveis de cinza.

$$Entropia = - \sum_i \sum_j p(i, j) \cdot \log(p(i, j)) \quad (27)$$

Contraste: mede a presença de transição abrupta de níveis de cinza (bordas) na imagem.

Pode-se dizer que é uma estimativa das variações locais dos níveis de cinza entre os *pixels*, também conhecida como soma do quadrado da variância.

$$\text{Contraste} = \sum_{n=0}^{N_g-1} n^2 \left\{ \sum_i \sum_j p(i, j), \text{ se } |i - j| = n \right\} \quad (28)$$

Homogeneidade: mede a homogeneidade da imagem, ou seja, a proximidade da distribuição dos elementos em relação à diagonal principal da GLCM.

$$\text{Homogeneidade} = \sum_i \sum_j \frac{p(i, j)}{1 + (i - j)^2} \quad (29)$$

Correlação: mede o grau de associação linear (negativa ou positiva) entre duas variáveis quantitativas. A correlação mede a dependência linear de um nível de cinza em relação aos vizinhos.

$$\text{Correlacao} = \frac{\sum_i \sum_j (ij) \cdot p(i, j) - \mu_x \mu_y}{\sigma_x \sigma_y} \quad (30)$$

onde μ_x e μ_y representam as médias nas direções x e y , respectivamente e σ_x e σ_y representam os desvios padrões, onde $\sigma_x \neq 0$ e $\sigma_y \neq 0$.

2.5.2 Abordagem Estrutural

Modelos estruturais são baseados na visão de que texturas são feitas de primitivas que aparecem em arranjos espaciais repetitivos, regulares e próximos. Para descrever textura devemos descrever as primitivas e as regras de localização (HARALICK, 1979).

Primitivas: Uma primitiva é um conjunto conectado de células de resolução, caracterizado por uma lista de atributos, sendo a mais simples um *pixel* com seu atributo de nível de cinza.

Tons de cinza e propriedades locais não são os únicos atributos possíveis das primitivas. Outros atributos, como medidas de forma de regiões conectadas e homogeneidade das propriedades locais também podem ser utilizados.

Muitos tipos de primitivas podem ser gerados ou construídos de dados de imagens por uma ou mais aplicações de operadores de vizinhança. Estão incluídas nestas classes de primitivas, componentes conectados, ascendentes ou descendentes, sobrecarregados, de ligação máxima ou mínima e de eixo central.

Relacionamentos Espaciais: Uma vez que as primitivas foram construídas, tem-se que avaliar a lista de primitivas, suas coordenadas centrais e seus atributos. Também é possível avaliar alguma informação topológica sobre as primitivas, como quais são adjacentes a quais. A partir destes dados, é possível selecionar um relacionamento espacial simples com adjacência das primitivas ou proximidade das primitivas e contar quantas primitivas de cada tipo ocorrem em um relacionamento espacial especificado.

A abordagem é estrutural no sentido de que primitivas são explicitamente definidas, e é estatística no sentido de que a interação espacial, ou a falta, é medida pelas probabilidades.

Texturas podem ser classificadas como fracas ou fortes. As fracas são aquelas que possuem fraca interação espacial entre as primitivas, e as fortes são aquelas que têm interações espaciais não aleatórias. Medidas de textura fracas geralmente consideram as características texturais estatísticas. Para distinguir entre as texturas fortes é suficiente determinar, para cada par de primitivas, a frequência com a qual as primitivas ocorrem em um relacionamento espacial especificado.

Agrupamento de Primitivas em Texturas Hierárquicas

Vários níveis de primitivas podem ser detectados em texturas hierárquicas - primitivas de mais baixo nível formam alguns padrões específicos os quais podem ser considerados com um nível de descrição maior. O agrupamento de primitivas é justamente o processo de detecção destes padrões de primitivas (unidades) em uma textura. Estas novas unidades podem formar novos padrões, e até mesmo um nível de descrição maior, por isso este processo de agrupamento deve ser repetido até que novas unidades não possam ser formadas (SONKA et al., 1998).

O agrupamento torna possível a segmentação de textura por abordagem estrutural. Ele utiliza as mesmas regras do cálculo local das características de textura em re-

conhecimento de textura estatístico. Primitivas diferentes e/ou relacionamentos espaciais diferentes representam texturas diferentes.

Sonka e colaboradores (SONKA et al., 1998) descrevem o algoritmo de agrupamento de primitivas como o Algoritmo 1.

Algoritmo 1 Algoritmo para o agrupamento de primitivas de textura

- 1: Determinar as propriedades da primitiva de textura e classificar estas primitivas em classes.
 - 2: Encontrar o primeiro e segundo vizinho mais próximo de cada primitiva de textura. Usando as classes das primitivas e as distâncias das duas primitivas vizinhas mais próximas d_1 e d_2 , classificar as primitivas de nível mais baixo em novas classes.
 - 3: Primitivas com a mesma nova classificação, que são conectadas (próximas umas as outras), são ligadas e formam primitivas de nível mais alto.
 - 4: Se qualquer duas regiões homogêneas resultarem em sobreposição de primitivas conectadas, sobreposição forma uma região separada.
-

Regiões formadas a partir de primitivas de baixo nível podem ser consideradas primitivas de nível mais alto e o processo de agrupamento pode ser repetido para estas novas primitivas. Todavia, o controle sofisticado do processo de agrupamento é necessário para arquivar os resultados significativos – isto deve ser controlado por um sub-sistema de entendimento de textura de visão de alto nível.

Reconhecimento de Padrões

Vistas as técnicas para a análise de imagens, este capítulo relata e discute sobre o que é reconhecimento de padrões, as etapas de sistemas para esse fim, os tipos existentes, pontos importantes quanto a dimensionalidade e o classificador Bayesiano.

Reconhecimento de padrões é o estudo de como máquinas podem observar o ambiente, aprender a distinguir padrões de interesse do seu fundo, e tomar decisões sólidas e razoáveis sobre suas categorias (JAIN et al., 2000).

Um padrão é um tipo de tema de eventos recorrentes de objetos, algumas vezes referidos como elementos de um conjunto. Estes elementos se repetem em um modo previsível. É um modelo que pode ser usado para gerar objetos ou partes de, especialmente se os objetos que são criados têm em comum o suficiente para o padrão subjacente ser inferido, em caso que os objetos expõem o único padrão. Como exemplo pode-se citar uma imagem de impressão digital, uma palavra escrita a mão, uma face humana, ou um sinal de voz.

Dado um padrão, o reconhecimento pode consistir em uma das seguintes tarefas: classificação supervisionada e classificação não supervisionada. Na classificação supervisionada o padrão de entrada é definido como membro de uma classe predefinida e na não

supervisionada o padrão é determinado como uma classe desconhecida. O problema de reconhecimento é apresentado como uma classificação ou tarefa de categorização onde a classe ou é definida pelo projetista do sistema, na classificação supervisionada, ou aprendida baseada na similaridade de padrões, como ocorre na classificação não supervisionada (DUDA et al., 2000).

As quatro abordagens mais conhecidas de reconhecimento de padrões são: casamento de modelo (*template matching*), classificação estatística, casamento sintático ou estrutural e redes neurais. Esses modelos não são necessariamente independentes e algumas vezes o mesmo método de reconhecimento de padrão existe com interpretações diferentes (FRIEDMAN;KANDEL, 1999).

A operação baseada no casamento de modelo, ou *template matching* é de caráter genérico sendo usada para determinar a similaridade entre duas entidades (pontos, curvas, ou formas) de mesmo tipo. Um modelo ou um protótipo do padrão a ser reconhecido está disponível, e a medida de similaridade, pode ser otimizada baseada na série de treinamento disponível.

Na abordagem estatística cada padrão é representado em termos de n características e é visto como um ponto em um espaço d -dimensional. A efetividade da representação (conjunto de características) é determinada pelo quão bem, os padrões de classes diferentes são separados. Dado um conjunto de treinamento, o objetivo é estabelecer limites de decisão no espaço de característica os quais separam padrões pertencentes a classes diferentes. Na abordagem teórica da decisão estatística, o limite de decisão é determinado pela distribuição de probabilidade dos padrões pertencentes a cada classe, que precisa ser especificado ou aprendido (FUKUNAGA, 1990).

Na terceira abordagem, reconhecimento sintático de padrões, uma analogia formal é desenhada entre a estrutura dos padrões e a sintaxe da linguagem. Os padrões são vistos como sentenças pertencentes à linguagem, e as sentenças são geradas de acordo com a gramática (BUNKE, 1993).

A última abordagem considera modelos de redes neurais, que usam princípios organizacionais (como aprendizado, generalização, adaptatividade, tolerância a falhas e representação distribuída) e computacionais em uma rede de grafos¹² dirigidos equilibrados nos

¹²Grafo: é representado como um conjunto de pontos, ou nodos, ligados por retas, as arestas. Dependendo da aplicação, as arestas podem ser direcionadas, podendo ter um peso associado a cada uma delas.

quais os nodos são neurônios artificiais e extremidades dirigidas (com pesos) são conexões entre neurônios de saída e neurônios de entrada. As principais características das redes neurais são a habilidade de aprender relações de entrada-saída não lineares complexas, usar procedimentos de treinamento sequencial, e adaptação ao tipo de dado.

3.1 Sistemas de Reconhecimento de Padrões

Os sistemas de reconhecimento de padrões podem ser divididos em algumas etapas, como mostradas na Figura 8. A partir das características extraídas pelos descritores, apresentados no capítulo anterior, o classificador usa essas características para atribuir o objeto a uma categoria. O pós-processador pode, além de usar a saída do classificador, levar em conta outras considerações, como os efeitos de contexto e os custos de erros, para decidir a ação apropriada. Apesar da descrição deste sistema ter um fluxo de dados linear, alguns sistemas utilizam *feedback* dos níveis mais altos para os mais baixos, representado pelas setas cinzas.

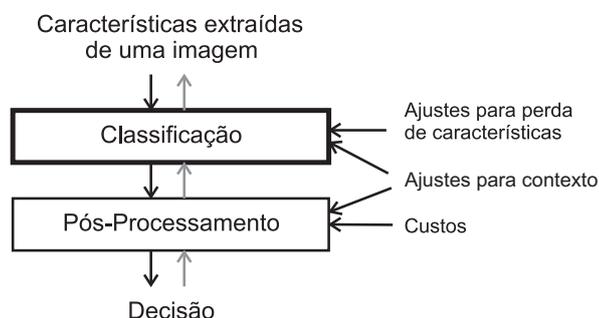


Figura 8: Diagrama de blocos de um sistema de reconhecimento de padrões, onde as setas escuras correspondem ao fluxo normal e as setas cinzas ao *feedback* para melhorar o sistema.

O limite conceitual entre extração de características e classificação é de algum modo arbitrário: Um extrator ideal deve produzir uma representação que torna o trabalho do classificador trivial. Inversamente, um classificador completo não precisa da ajuda de um extrator sofisticado (DUDA et al., 2000).

3.1.1 Ciclo de um Projeto em Reconhecimento de Padrões

O projeto de um sistema de reconhecimento de padrões demanda a repetição de um número de diferentes atividades: coleção de dados, escolha de descritores, modelo de escolha, treinamento e avaliação. Um diagrama esquemático do ciclo de um projeto desta natureza está ilustrado na Figura 9.

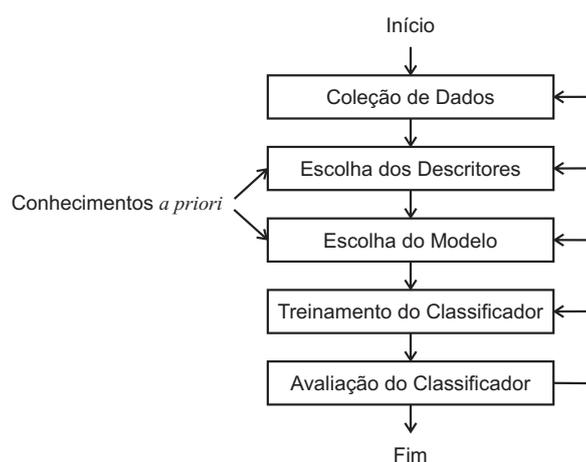


Figura 9: Ciclo de projeto de um sistema de reconhecimento de padrões, onde inicialmente os dados são agrupados, depois com a entrada de um conhecimento *a priori* são escolhidos os descritores e o modelo, logo após o classificador é treinado e por fim, é feita a análise do classificador, análise esta que fornece um *feedback* a todas as outras etapas do ciclo (DUDA et al., 2000).

Dados devem ser coletados para treinar e testar o sistema de reconhecimento de padrões. As características dos dados afetam a escolha de descritores discriminantes apropriados e a escolha de modelos para as diferentes categorias. O processo de treinamento utiliza alguns ou todos os dados para determinar os parâmetros do sistema. Os resultados da avaliação podem chamar repetições de vários passos neste processo para obter resultados satisfatórios (FUKUNAGA, 1990; DUDA et al., 2000).

3.1.2 Aprendizado e Adaptação

Qualquer método que incorpora informações de amostras de treinamento no projeto de um classificador emprega aprendizado. Esta etapa de aprendizado deve ser considerada pois quase todos os problemas práticos de reconhecimento de padrões são tão complexos

que não se pode prever a melhor decisão de classificação. Logo, criar classificadores envolve fixar algum modelo, ou classificador, e usar padrões de treinamento para aprender ou estimar os parâmetros desconhecidos do modelo. Aprendizado refere-se a algum algoritmo para a redução do erro em um conjunto de dados de treinamento (DUDA et al., 2000). Assim as seguintes formas para aprendizado podem ser estipuladas, como:

- *Método supervisionado*: quando um especialista atribui um rótulo ou custo a uma categoria para cada padrão em um conjunto de treinamento, e procura reduzir a soma dos custos destes padrões;
- *Método não supervisionado (agrupamento - clustering)*: não há um especialista, e o sistema forma agrupamentos (*clusters* ou agrupamentos naturais) dos padrões de entrada. Natural é sempre definido explicita ou implicitamente no próprio sistema de agrupamento; e dado um particular conjunto de padrões, ou função de custo, diferentes algoritmos de agrupamento levam a diferentes agrupamentos.
- *Método de reforço ou com crítica*: nenhum sinal de categoria desejada é fornecido e o único *feedback* do especialista é uma tentativa de categorização que pode estar certa ou errada. Pode ser feita uma analogia com um crítico, que simplesmente declara que alguma coisa é certa ou errada, mas não diz especificamente de que forma está errado.

3.2 Reconhecimento de Padrões Estatístico

No reconhecimento de padrões estatístico, um padrão é representado por um conjunto de d características (descritores ou atributos) visualizado como um vetor d -dimensional (JAIN et al., 2000). Os conceitos da teoria de decisão estatística são usados para estabelecer limites de decisão entre as classes (FRIEDMAN;KANDEL, 1999; YOUGUO et al., 2007). O sistema de reconhecimento opera em dois modos: treinamento (aprendizado) e classificação (teste), conforme mostrado na Figura 10.

No modo de treinamento, a extração/seleção de características encontra as características apropriadas para representar os padrões de entrada e o classificador é treinado para dividir o espaço de característica. O *feedback* permite ao projetista otimizar as estra-

tégias de pré-processamento e extração/seleção das características. No modo de classificação, o classificador treinado determina ao padrão de entrada uma das classes baseando-se nas características medidas.

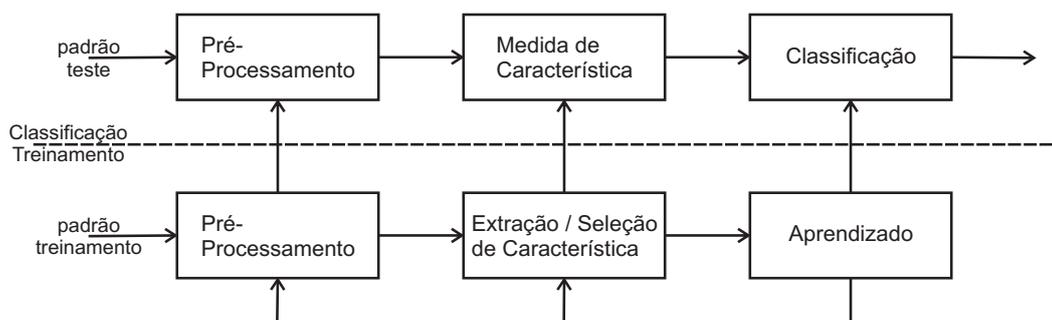


Figura 10: Modelo para reconhecimento de padrões estatístico operando em dois modos, treinamento e classificação, cujo *feedback* permite a otimização das etapas iniciais (JAIN et al., 2000).

O processo de tomada de decisão em reconhecimento de padrões pode ser resumido como: um dado padrão é determinado a uma das c categorias, $\omega_1, \omega_2, \dots, \omega_c$, baseado em um vetor de d valores de características $x = (x_1, x_2, \dots, x_d)$. As características são assumidas para ter uma densidade de probabilidade ou função de massa (dependendo se as características são contínuas ou discretas) condicionada na classe. Portanto, um vetor de padrões x pertencente a classe ω_i é visualizado como uma observação obtida randomicamente da função de probabilidade condicional¹³ da classe $p(x|\omega_i)$. Várias estratégias são utilizadas para projetar um classificador em reconhecimento de padrões estatístico, dependendo do tipo de informação disponível sobre a densidade condicional da classe.

O rótulo de um padrão de treinamento representa a categoria a qual o padrão pertence. Em um problema de treinamento não supervisionado, algumas vezes o número de classes deve ser aprendido junto com a estrutura de cada classe. As várias divisões que aparecem em reconhecimento de padrões estatístico são mostradas na estrutura de árvore da Figura 11. Conforme atravessamos a árvore de cima para baixo e da esquerda para direita, menos informação está disponível ao projetista do sistema e, como resultado, a dificuldade de problemas de classificação aumenta.

¹³Probabilidade condicional: é a probabilidade que depende de algum fator.

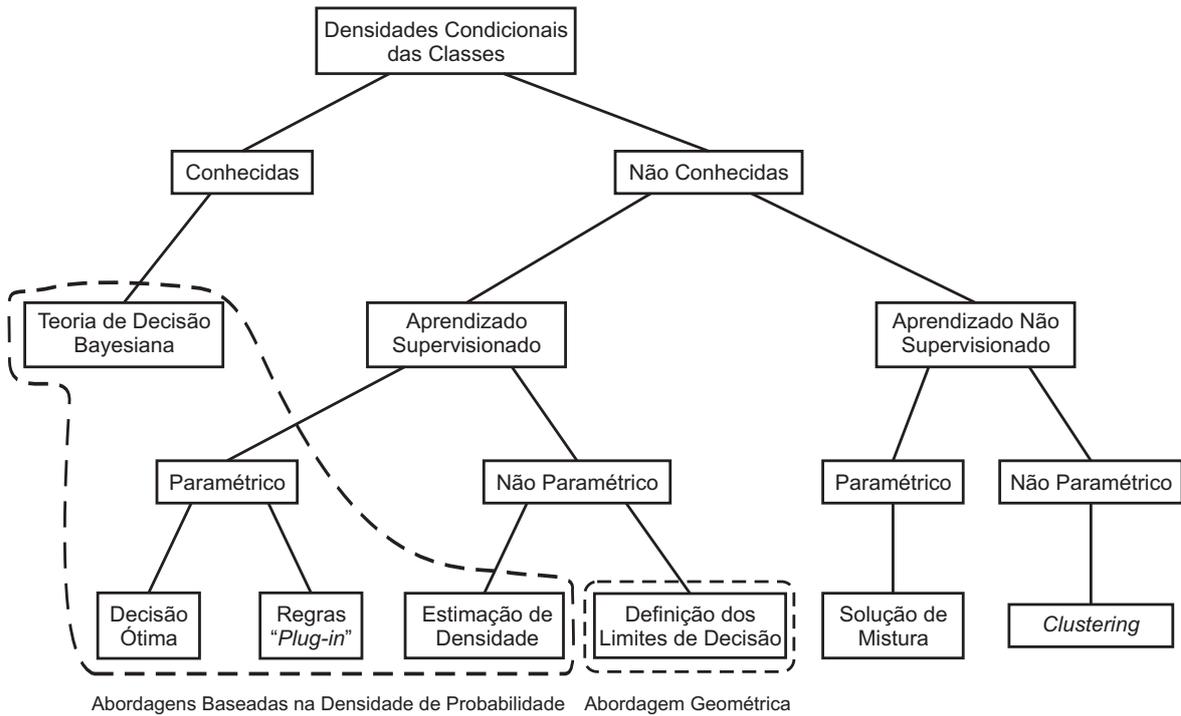


Figura 11: Divisões do reconhecimento de padrões estatístico representadas em árvore, onde quanto mais abaixo e a direita, menos informação está disponível dificultando o processo de reconhecimento (JAIN et al., 2000).

A abordagem probabilística requer primeiro a estimação de funções de densidade, e então construir as funções discriminantes as quais especificam os limites de decisão. Por outro lado, a abordagem geométrica geralmente constrói diretamente os limites de decisão para otimizar certas suposições nas funções de densidade. As duas abordagens são equivalentes sob algumas suposições nas funções de densidade.

Independente da abordagem utilizada, a mesma deve ser treinada com as amostras de treinamento disponíveis. Como resultado, o desempenho do classificador depende do número de amostras de treinamento disponíveis, assim como dos valores específicos das amostras. O objetivo de se projetar um sistema de reconhecimento é classificar futuras amostras de testes que provavelmente são diferentes das amostras de treinamento.

Para se projetar um classificador em reconhecimento de padrões estatístico podem ser utilizadas várias estratégias, dependendo do tipo de informação disponível sobre as densidades condicionais das classes. Usa-se, por exemplo, a teoria de decisão Bayesiana quando todas as densidades condicionais forem completamente especificadas. O problema

de decisão paramétrico é usado quando a forma das densidades condicionais é conhecida, porém alguns parâmetros destas densidades não são (FRIEDMAN;KANDEL, 1999). Dentre as técnicas paramétricas tem-se o classificador “*Plug-in*”, que é uma estratégia que substitui os parâmetros não conhecidos das funções de densidade por seus valores estimados e a estratégia ótima que requer uma informação adicional na forma de uma distribuição *a priori* nos parâmetros desconhecidos. O modo não paramétrico é usado quando a forma das densidades condicionais das classes não é conhecida, neste caso, é necessário estimar a função de densidade (abordagem das janelas de *Parzen*) ou construir diretamente o limite de decisão baseado nos dados de treinamento.

3.2.1 Aprendizado Supervisionado Paramétrico

Na realidade, em um problema de reconhecimento de padrões, raramente a estrutura probabilística é completamente conhecida, geralmente temos algum conhecimento vago sobre a situação, junto com um número de amostras de projeto ou dados de treinamento. O problema então é encontrar algum modo de usar esta informação para projetar e treinar o classificador. Uma abordagem é usar amostras para estimar as probabilidades e densidades de probabilidade, e usar os resultados estimados como se fossem os valores reais.

Os dois métodos mais comuns para se fazer esta estimação são: Estimação de Máxima Verossimilhança e Estimação de Bayes (FUKUNAGA, 1990). Apesar dos dois métodos resultarem em valores bem próximos, eles são conceitualmente diferentes. Enquanto a estimação de máxima verossimilhança vê os parâmetros como quantidades de valores fixos, porém desconhecidos, obtendo como melhor estimativa aquela que maximiza a probabilidade de obtenção das amostras, a estimação de Bayes vê os parâmetros como variáveis aleatórias com algumas distribuições *a priori* conhecidas, onde a observação das amostras converte para densidade *a posteriori*.

3.2.2 Aprendizado Supervisionado Não Paramétrico

Como nas aplicações de reconhecimento de padrões é suspeita a suposição de que a forma das funções de densidade são conhecidas, os métodos paramétricos raramente se ajustam às densidades de fato encontradas na prática.

Alguns dos métodos não paramétricos são a Estimação de Densidade, Janelas de Parzen e Estimação dos k -vizinhos mais próximos (DUDA et al., 2000).

3.2.3 Aprendizado Não Supervisionado

É aquele que tem um conjunto de amostras não rotuladas, ou seja, sem um conhecimento prévio das categorias de cada amostra. Os métodos para associar um dado agrupamento a cada padrão seguem algum critério de similaridade e são dependentes do algoritmo empregado, dos dados utilizados e da medida de similaridade adotada.

Existem duas abordagens para este tipo de aprendizado, a paramétrica e a não paramétrica. Na abordagem paramétrica, são definidos critérios de agrupamento e determinadas amostras são classificadas a um número de agrupamentos para otimizar os critérios. Os critérios mais comuns são as medidas de separabilidade de classe, onde a tarefa que maximiza a medida de separabilidade da classe é considerada como o melhor resultado de agrupamento. Nesta abordagem, a estrutura (forma paramétrica) do limite de classificação é determinada pelo critério. Um algoritmo iterativo determina eficientemente a melhor classificação a respeito do critério. Como outra abordagem paramétrica tem-se uma forma matemática assumida para a distribuição dos dados.

Agora as abordagens não paramétricas não assumem para a distribuição critérios de agrupamento ou formas matemáticas. Neste caso as amostras são separadas de acordo com o vale, que pode ser considerado como o limite natural que separa os modelos de distribuição, da função de densidade.

Como exemplos de algoritmos para aprendizado não supervisionado paramétrico têm-se *General Clustering Algorithm*, *Nearest Mean Reclassification Algorithm* e *Normal Decomposition*, e para os casos não paramétricos tem-se *Estimation of Density Gradient* e *Clustering Algorithm*.

3.3 O Problema da Dimensionalidade

O desempenho de um classificador depende do inter-relacionamento entre o tamanho das amostras, o número de características (descritores), e a complexidade do classificador. É conhecido que a probabilidade de errar a classificação de uma regra de decisão

não aumenta com o aumento do número de descritores, desde que as densidades condicionais da classe sejam completamente conhecidas. Porém, foi observado na prática que a adição de descritores pode degradar o desempenho do classificador se o número de amostras de treinamento que é usado para projetar o classificador for relativamente pequeno para o número de descritores (RAUDYS;PIKIALIS, 1980; RAUDYS;JAIN, 1991).

Todos os classificadores podem sofrer o problema da dimensionalidade. Enquanto um relacionamento exato entre a probabilidade de errar a classificação, o número de amostras de treinamento, o número de descritores e os verdadeiros parâmetros de densidade condicional da classe são muito difíceis de estabelecer, algumas linhas guia foram sugeridas relativas à razão do tamanho da amostra e a dimensionalidade. Em geral é aceito usar um número amostras de treinamento por classe pelo menos dez vezes o número de características. Quanto mais complexo o classificador, maior deve ser a relação entre o tamanho das amostras e a dimensionalidade para evitar o problema em questão.

3.4 Redução da Dimensionalidade

Há duas razões principais para manter a dimensionalidade da representação de um padrão o menor possível: custo da medição e precisão de classificação. Um limitado, porém saliente, descritor simplifica a representação do padrão e os classificadores que são construídos na representação selecionada. Consequentemente, o classificador resultante será mais rápido e usará menos memória. Além disso, como dito antes, um número menor de descritores pode suavizar o problema de dimensionalidade quando o número de amostras de treinamento é limitado. Por outro lado, esta redução pode levar a uma perda no poder de discriminação e assim diminui a precisão do sistema de reconhecimento resultante (WEBB, 2002).

É necessário diferenciar extração e seleção de características, já que na literatura estes termos têm sido usados indistintamente. Algoritmos de extração de características criam novos descritores baseados em transformações ou combinações do conjunto de descritores original, enquanto seleção de características refere-se a algoritmos que selecionam o melhor subconjunto dos descritores de entrada (FRIEDMAN;KANDEL, 1999).

3.4.1 Extração de Características

Métodos de extração de características determinam o subconjunto apropriado de dimensionalidade m (tanto de modo linear como não linear) no conjunto de características original de dimensionalidade d ($m < d$). Transformações lineares como, análise do componente principal (PCA - *Principal Component Analysis*), análise de discriminante linear (LDA - *Linear Discriminant Analysis*) e *Projection Pursuit* têm sido utilizadas em reconhecimento de padrões para a extração das características e redução de dimensionalidade (JAIN et al., 2000).

O melhor extrator de características linear conhecido é o PCA, ou expansão de Karhunen-Loève, que computa os m maiores autovalores da matriz de covariância $d \times d$ de n padrões d dimensionais (THEODORIDIS;KOUTROUMBAS, 2003).

Enquanto que o PCA usa as características mais expressivas (ou autovetores com os maiores autovalores), aproxima os dados por um subespaço linear usando o critério do erro médio quadrático. Outros métodos como *Projection Pursuit* e análise do componente independente (ICA - *Independent Component Analysis*), são mais apropriados para distribuições não gaussianas pois não são restritos a propriedade de segunda ordem dos dados (FRIEDMAN, 1987; LEE, 1998).

Existem algumas técnicas para a extração de características não linear como o escalonamento multidimensional (MDS - *Multidimensional Scaling*) e os mapas auto-organizáveis (SOM - *Self-Organizing Map*), ou mapa de Kohonen (BORG;GROENEN, 2003; KOHONEN, 2001).

3.4.2 Seleção de Características

Seleção de características é, dado um conjunto de d descritores, selecionar um subconjunto de tamanho m que conduza ao menor erro de classificação. O interesse na aplicação de métodos de seleção de características tem voltado devido ao grande número de características encontradas nas seguintes situações: i) fusão de multi-sensores: características computadas de diferentes modalidades de sensores são concatenadas para um vetor de características com um grande número de componentes; ii) integração de múltiplos modelos de dados: dados dos sensores podem ser modelados usando diferentes

abordagens, onde os parâmetros dos modelos servem como características.

Seja Y o conjunto de características com cardinalidade d , m o número desejado de características no subconjunto selecionado X , $X \subseteq Y$, e $J(X)$ a função de critério para seleção das características para o conjunto X . O maior valor de J indica o melhor subconjunto de características. A escolha natural para a função de critério é $J = (1 - P_e)$, onde P_e indica o erro de classificação. A abordagem mais simples para o problema de seleção característica exigiria 1) analisar todos os $\binom{m}{d}$ possíveis subconjuntos de tamanho m , e 2) selecionar o subconjunto com o maior valor de $J(\cdot)$. No entanto, o número de subconjuntos possíveis cresce de maneira combinatória, tornando esta busca exaustiva impraticável, mesmo para valores moderados de m e d . Para produzir o melhor subconjunto, pode-se utilizar procedimentos de seleção de características sequencial não exaustiva. Além disso, a ordenação dos erros de classificação de cada um dos 2^d subconjuntos de característica é possível. O método de seleção de característica que evita a busca exaustiva é baseado no algoritmo *branch and bound*, que utiliza os resultados intermédios para a obtenção de limites sobre o valor do critério definitivo. O ponto principal deste algoritmo é a propriedade de monotonicidade da função de critério $J(\cdot)$; dados dois subconjuntos de características X_1 e X_2 , se $X_1 \subset X_2$, então $J(X_1) < J(X_2)$. Em outras palavras, o desempenho de um subconjunto de características deve melhorar sempre que uma característica é adicionada a ele (JAIN et al., 2000).

3.5 Classificação de Padrões

Segundo Costa e Cesar Jr. (2001), uma idéia superficial de classificação de padrões pode ser feita com base no método ilustrado esquematicamente na Figura 12, a qual apresenta os principais elementos envolvidos em classificação de padrões. Este processo é influenciado por abstrações humanas como matemática e geometria. O processo de classificação de padrões feito automaticamente envolve o uso de computadores para processar a informação sobre os padrões, os quais são tipicamente feitos em termos de medidas de suas propriedades. Particularmente, no caso de classificação baseada em informação visual, uma imagem de um objeto a ser classificado é dada como entrada ao computador, que produz medidas satisfatórias (características, descritores) e então os métodos de clas-

sificação são aplicados para medir com o objetivo de determinar a classe correta a qual o padrão pertence. Também pode ser observado que o controle dos parâmetros pode ser acessado tanto por indivíduos quanto pelo computador (setas tracejadas) desde que sejam permitidas mais informações sobre o objeto, aumentando então as chances de uma classificação correta.

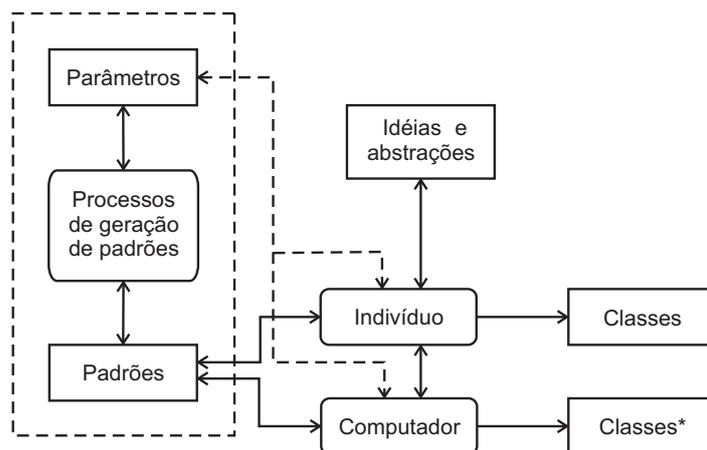


Figura 12: Interações básicas em reconhecimento de padrões. O retângulo tracejado representa a geração de padrões, que é controlada por um conjunto de parâmetros. Os homens interagem com a geração de padrões, medindo suas propriedades e identificando alguns dos parâmetros que possuem que são usados para organizar os padrões em classes. Adaptação de (COSTA;CESAR, 2001).

Foram identificadas três diferentes abordagens para se projetar classificadores:

- Abordagem baseada no conceito de similaridade: é a mais simples e mais intuitiva, onde os padrões similares devem ser atribuídos à mesma classe. Assim, uma vez que uma boa métrica tenha sido estabelecida para definir similaridade, padrões podem ser classificados pelo modelo de correspondência (*template matching*) ou classificador de mínima distância utilizando alguns protótipos por classe. A escolha da métrica e dos protótipos é crucial para o êxito desta abordagem.
- Abordagem probabilística: a regra de decisão de Bayes determina um padrão para a classe com a máxima probabilidade *a posteriori*¹⁴. Esta regra pode ser modificada para levar em consideração os custos associados a diferentes tipos de erros de classificação.

¹⁴Probabilidade *a posteriori*: é a probabilidade não conhecida, que será obtida através de cálculos.

- Construção de limites de decisão diretamente pela otimização de certos critérios de erro: enquanto esta abordagem depende da métrica escolhida, algumas vezes classificadores deste tipo podem se aproximar do classificador de Bayes assintoticamente.

3.5.1 Regra de Decisão Bayesiana

A teoria de decisão de Bayes é uma das teorias fundamentais para o problema de classificação de padrões, pois o assunto é posto em termos de suas probabilidades (DUDA et al., 2000). Cada classe de padrões tem sua probabilidade conhecida, porém seus padrões podem ser completamente conhecidos ou não, muitas vezes sendo necessário estimar os atributos dos padrões para análise.

Os estados da natureza possíveis são chamados de classes ω , sendo que $\omega = \omega_1$ para uma primeira classe, $\omega = \omega_2$ para uma segunda classe e $\omega = \omega_n$ para uma classe n . Devido ao fato das amostras serem imprevisíveis ao selecioná-las, as classes são consideradas variáveis aleatórias. O conhecimento da probabilidade *a priori*¹⁵ de uma classe ω_j , denotado por $P(\omega_j)$, é um conhecimento anterior do domínio do problema. Como este conhecimento não fornece argumentos suficientes para se decidir em favor de uma classe ou outra deve-se levar em conta os atributos das classes em questão.

Dado um vetor de atributos X cujo domínio é uma variável aleatória com d -componentes, e sua distribuição depende do estado da natureza, a função densidade de probabilidade condicional - $p(X|\omega_j)$ - é a probabilidade de ocorrer X sendo ω_j a classe verdadeira.

Conhecidas as probabilidades *a priori* $P(\omega_j)$ e as densidades condicionais $p(X|\omega_j)$, a probabilidade *a posteriori* - $P(\omega_j|X)$ - pode ser computada pela regra de Bayes, mostrada a seguir:

$$P(\omega_j|X) = \frac{p(X|\omega_j)P(\omega_j)}{p(X)} \quad (31)$$

onde

$$p(X) = \sum_{j=1}^N p(X|\omega_j)P(\omega_j) \quad (32)$$

onde N é o número de classes.

¹⁵Probabilidade *a priori*: é a probabilidade fornecida por um especialista.

A regra de decisão de Bayes ocorre pela máxima probabilidade *a posteriori*, ou critério MAP, onde a decisão será em favor da probabilidade que minimiza o erro. Sendo assim, a decisão é feita a favor do maior valor de $P(\omega_j|X)$. No caso de apenas duas classes, se $P(\omega_1|X) > P(\omega_2|X)$, decide-se a favor da classe ω_1 , caso contrário decidir por ω_2 .

Para que haja uma região de decisão adequada, deve-se escolher uma distância que separe corretamente o espaço de atributos. Uma distância que pode ser usada é a distância de Mahalanobis, que gera um hiperplano de decisão entre as distribuições dadas na forma de hiperelipsóides.

A distância quadrada de Mahalanobis, de X a μ , é dada pela fórmula:

$$r^2 = (X - \mu)^t \sum^{-1} (X - \mu) \quad (33)$$

onde \sum é a matriz de covariância e μ é o vetor médio.

Outra forma de representar um classificador de padrões é em termos de suas funções discriminantes $g_i(X)$, $i = 1, \dots, c$. O classificador atribui o vetor de atributos X à classe ω_j se:

$$g_i(X) > g_j(X) \text{ para todo } i \neq j \quad (34)$$

onde

$$g_i(X) = \ln p(X|\omega_i) + \ln P(\omega_i) \quad (35)$$

As funções discriminantes representam o decisor Bayesiano de maneira semelhante, somente colocando sob a forma canônica.

Basicamente, o decisor Bayesiano é uma máquina que computa c funções discriminantes e seleciona a categoria adequada ao maior valor discriminante, que corresponde à região onde o erro é mínimo e ótimo, denotando uma classificação em favor da máxima probabilidade *a posteriori*.

Desta maneira o classificador Bayesiano poderá classificar os padrões baseados em suas variâncias e covariâncias e distribuições probabilísticas a partir de um conhecimento prévio e aplicações de características dos padrões a uma função de decisão, para o caso

em que os padrões devem ser totalmente conhecidos.

Para o caso em que os padrões são totalmente conhecidos o aprendizado é supervisionado, sendo os valores incluídos pelo próprio usuário. Para o caso em que os padrões não são totalmente conhecidos deve-se utilizar o aprendizado não supervisionado.

3.5.2 Avaliação de Desempenho de um Classificador

A avaliação de desempenho deve ser parte de um classificador e não um aspecto a ser considerado separadamente. O critério utilizado para a concepção de um classificador pode ser diferente do utilizado para a avaliação do mesmo (WEBB, 2002).

O erro de classificação, ou simplesmente a taxa de erro, P_e , é a medida mais importante da avaliação de desempenho de um classificador. Outras medidas incluem o custo da medição das características e as exigências computacionais da regra de decisão. Embora seja fácil de definir a probabilidade de erro em termos de densidades condicionais da classe, é muito difícil obter uma expressão analítica para a expressão de P_e , portanto, ela deve ser estimada a partir dos dados disponíveis.

A taxa de erro de um sistema de reconhecimento deve ser estimada a partir de todas as amostras disponíveis, que são divididas em dois conjuntos: treinamento e teste. Sendo as amostras de treinamento utilizadas para se projetar o classificador e as de teste para a avaliação de desempenho do mesmo. A estimativa da taxa de erro é a percentagem de erro de classificação das amostras de teste. Para que essa estimativa seja confiável para prever o futuro desempenho de classificação, não só os dois conjuntos devem ser suficientemente grandes, mas as amostras de treinamento e de teste deverão ser independentes.

Dado um classificador, suponha que τ é o número de amostras de teste (de um total de n amostras) que são classificados incorretamente. Pode ser demonstrado que a função de densidade de probabilidade de τ tem uma distribuição binomial. A estimativa de máxima-verossimilhança, \hat{P}_e , de P_e , é dada por $\hat{P}_e = \tau/n$, com $E(\hat{P}_e) = P_e$ e $Var(\hat{P}_e) = P_e(1 - P_e)/n$. Assim, \hat{P}_e é um estimador imparcial e consistente. Porque \hat{P}_e é uma variável aleatória, um intervalo de confiança é associado a ela (THEODORIDIS;KOUTROUMBAS, 2003; WEBB, 2002).

Existem várias formas de se dividir as amostras. Quando o conjunto de treinamento é pequeno, o classificador não será muito robusto e terá uma baixa capacidade de gene-

realização. E quando o conjunto de teste é pequeno, a confiança na taxa de erro estimada é reduzida. Algumas formas de divisão estão apresentadas na Tabela 1, onde n representa o número de amostras disponíveis. É importante ressaltar que diferentes divisões das amostras resultarão em diferentes estimativas de erro.

Tabela 1: Métodos de Estimação de Erro (JAIN et al., 2000).

Método	Propriedade	Comentários
Método de Re-substituição	Todos os dados disponíveis são usados tanto para o treinamento como para o teste (os conjuntos de treinamento e teste são os mesmos).	Estimativa otimista, especialmente quando a razão do tamanho das amostras pela dimensionalidade é pequena.
Método <i>Holdout</i>	Metade dos dados são usados para o treinamento e o restante para o teste (os conjuntos de treinamento e teste são independentes).	Estimativa pessimista, diferentes particionamentos resultarão em estimativas diferentes.
Método <i>Leave-one-out</i>	Para o treinamento são usadas $(n - 1)$ amostras e para o teste a amostra que sobrou. Isto é repetido n vezes com diferentes conjuntos de treinamento de tamanho $(n - 1)$.	A estimativa é imparcial mas possui grande variância. Grande esforço computacional pois n diferentes classificadores devem ser projetados.
Método de Rotação, validação cruzada	Meio termo entre os métodos <i>holdout</i> e <i>leave-one-out</i> . Divide as amostras disponíveis em P subconjuntos disjuntos, $1 \leq P \leq n$. Usa $(P - 1)$ subconjuntos para o treinamento e o subconjunto restante para o teste.	Estimativa tem menor influência que o método <i>holdout</i> e possui um menor esforço computacional que o método <i>leave-one-out</i> .

O sistema de reconhecimento de plantas invasoras e percentual de ocupação das plantas de folhas largas e das plantas de folhas estreitas, utilizando como base as técnicas apresentadas até este capítulo, é apresentado no próximo capítulo.

Desenvolvimento do Sistema de Reconhecimento de Padrões de Plantas Invasoras e Percentual de Ocupação de Folhas Largas e Folhas Estreitas

Neste capítulo é apresentado o sistema de reconhecimento de plantas invasoras com especificidades para o reconhecimento de plantas de folhas largas e de folhas estreitas. São discutidas, além de sua modelagem, cada uma das etapas que o compõe, bem como é estabelecido o algoritmo para o cálculo dos percentuais de ocupação de cada tipo de planta invasora.

4.1 Modelagem do Sistema

O sistema de reconhecimento de plantas invasoras foi projetado com o objetivo de se aplicar técnicas de visão computacional e processamento de imagens para o reconhecimento dos padrões de folhas largas e estreitas de plantas invasoras da cultura do milho (*Zea mays*). A Figura 13 ilustra o diagrama de blocos do sistema de reconhecimento desenvolvido.

O sistema utiliza imagens georeferenciadas, adquiridas por câmera digital que são pré-processadas, visando uma adequação da mesma ao modelo de análise. Utilizando-se de uma técnica de segmentação baseada em textura apenas as plantas invasoras presentes na imagem são selecionadas. A partir da imagem com apenas plantas invasoras, são utilizados descritores baseados na forma das folhas para o reconhecimento das plantas de folhas largas e de folhas estreitas. A partir do reconhecimento dos padrões são criados dois mapas, um apenas com as plantas de folhas largas, e outro com as plantas de folhas estreitas. Por fim, são fornecidos os percentuais de identificação de cada um dos padrões conhecidos por meio de uma interface com o usuário. Também foi prevista a organização de um repositório das imagens adquiridas e processadas nas várias etapas do processo de análise.

4.2 Aquisição das Imagens

Para a aquisição das imagens é utilizada uma câmera digital da marca Canon, modelo PowerShot Pro1, com 180 *pixels*/polegadas de resolução a qual apresenta tamanho das imagens de 600×600 *pixels*.

4.3 Pré-Processamento

A etapa do pré-processamento possibilita a organização de uma nova imagem com apenas as folhas presentes na imagem original, com as folhas de cultura e de plantas invasoras, indiscriminadamente. Nessa nova imagem são eliminadas as informações de fundo, como palha e solo.

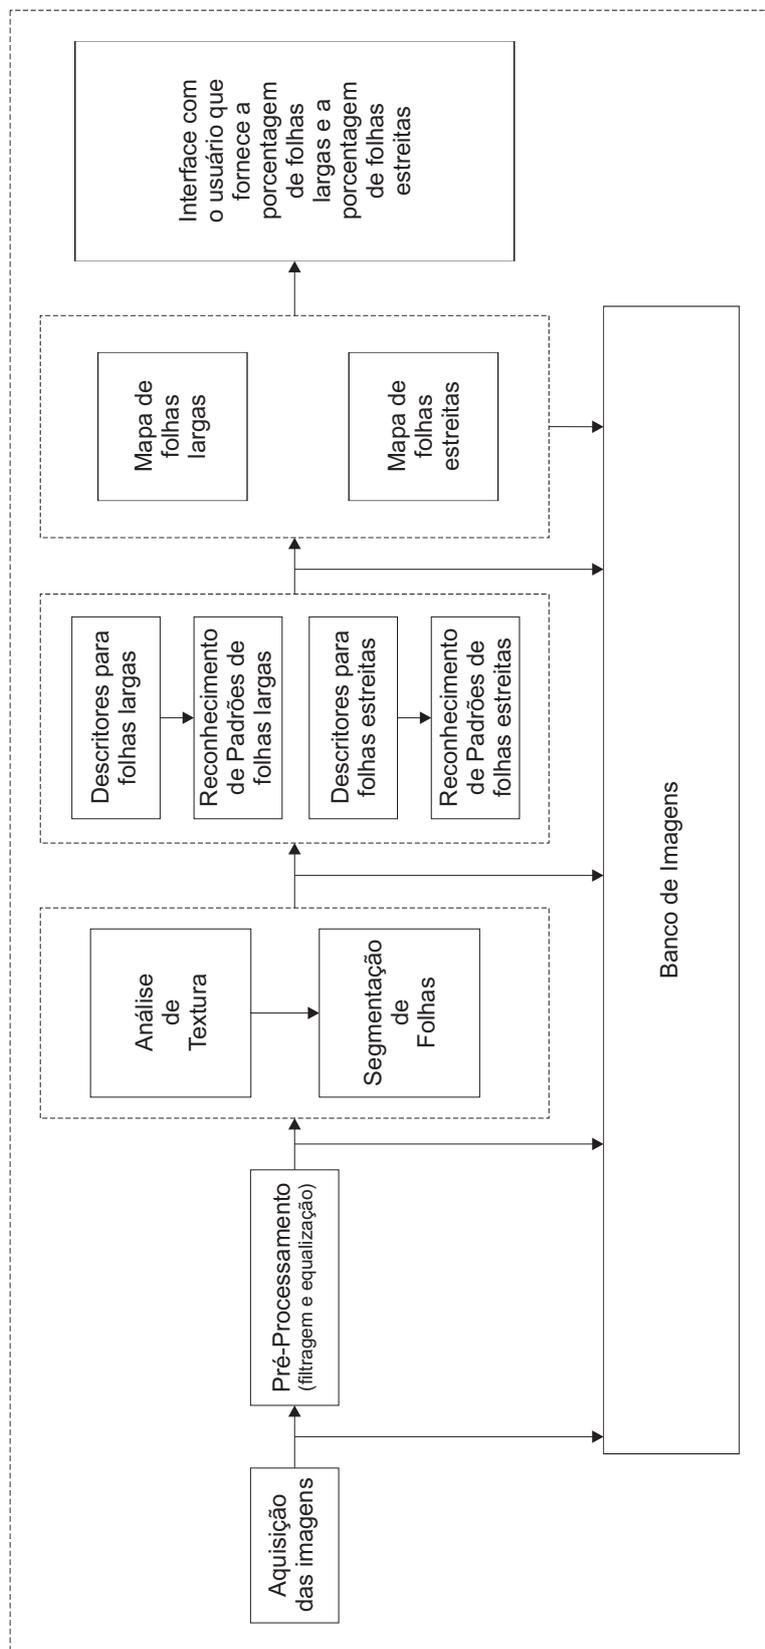


Figura 13: Diagrama de blocos do sistema de reconhecimento de plantas invasoras e indicativo de área de ocupação.

O Algoritmo 2 foi aplicado para se obter a imagem mencionada, sendo a primeira etapa a obtenção das áreas onde a componente verde prevalece na imagem, para em seguida eliminar o fundo, ficando apenas com as folhas, que são verdes. Para a primeira etapa, foram selecionadas as componentes R (*red*), G (*green*) e B (*blue*) da imagem, e então encontrada a informação da componente G menos a R. Para suavizar os ruídos da imagem resultante, foi aplicado o filtro de mediana. Depois essa imagem foi limiarizada, com limiar igual a média dos níveis de cinza presentes na imagem, obtendo em preto o fundo e em branco as folhas. A nova imagem foi obtida, de forma que o fundo (palha e solo) é preto, e as folhas continuaram com sua informação original, em tons de cinza.

Algoritmo 2 Algoritmo para o pré-processamento

- 1: Obter as componentes R, G e B da imagem.
 - 2: Formar uma nova imagem a partir da subtração da componente R da G.
 - 3: Aplicar o filtro de mediana, que uniformiza a região, sem perder detalhes de bordas.
 - 4: Limiarizar a imagem, do passo 3, com limiar igual ao valor médio dos níveis de cinza.
 - 5: Comparar o resultado da binarização com a imagem original, eliminando o fundo e mantendo as informações das folhas em tons de cinza.
-

Descrevendo com maior detalhe o Algoritmo 2, considera-se:

- Passo 1: A imagem de entrada possui três bandas, sendo que cada uma delas representa uma das componentes do seu modo de cor. No caso específico deste trabalho, a imagem era do modo RGB, e para a obtenção de uma componente isolada, foi necessário indicar a banda desejada através de uma passagem de parâmetros.
- Passo 2: A operação de subtração da componente R da G é feita através de uma subtração simples entre matrizes. Cada componente é representada por uma matriz cujos valores variam de 0 a 255. A subtração é feita para cada posição da matriz. Faz-se o elemento $(1, 1)$ da componente G menos o elemento $(1, 1)$ da componente R, e

assim até percorrer toda a matriz, ou seja

$$R = \begin{bmatrix} r_{11} & r_{12} & \dots & r_{1n} \\ r_{21} & r_{22} & \dots & r_{2n} \\ \vdots & \vdots & & \vdots \\ r_{m1} & r_{m2} & \dots & r_{mn} \end{bmatrix} \quad \text{e} \quad G = \begin{bmatrix} g_{11} & g_{12} & \dots & g_{1n} \\ g_{21} & g_{22} & \dots & g_{2n} \\ \vdots & \vdots & & \vdots \\ g_{m1} & g_{m2} & \dots & g_{mn} \end{bmatrix} \quad (36)$$

$$G - R = \begin{bmatrix} g_{11} - r_{11} & g_{12} - r_{12} & \dots & g_{1n} - r_{1n} \\ g_{21} - r_{21} & g_{22} - r_{22} & \dots & g_{2n} - r_{2n} \\ \vdots & \vdots & & \vdots \\ g_{m1} - r_{m1} & g_{m2} - r_{m2} & \dots & g_{mn} - r_{mn} \end{bmatrix} \quad (37)$$

É importante ressaltar que a imagem será escura, com o fundo em preto, pois ou os elementos serão iguais (no caso da palha), resultado em zero, ou o valor na componente R será maior (no caso do solo), que também resulta em zero, uma vez que valores negativos não são possíveis, e os mesmos devem ser interpretados como zero.

- Passo 3: Para a aplicação do filtro mediana foi considerada uma máscara 3×3 que percorre toda a imagem, substituindo o *pixel* central pela mediana *pixels* pertencentes à máscara. A mediana foi aplicada à imagem resultante do passo 2.
- Passo 4: Na limiarização a imagem é dividida em duas regiões, uma em branco e outra em preto. A decisão de qual *pixel* ficará branco ou preto depende da escolha do limiar. Neste caso, o limiar utilizado foi a média dos níveis de cinza da imagem do passo anterior. Sendo assim, os *pixels* que estiverem abaixo do limiar assumem o valor preto, e os que forem maiores ou iguais assumem o valor branco. Esta operação está demonstrada abaixo:

$$g(x, y) = \begin{cases} 1, & \text{se } f(x, y) \geq \text{média dos níveis de cinza de } f(x, y) \\ 0, & \text{caso contrário} \end{cases} \quad (38)$$

- Passo 5: Antes da comparação, foi obtida a imagem original em tons de cinza. A conversão é feita utilizando a fórmula seguinte:

$$I_{cinza} = \frac{1}{3}(R + G + B) \quad (39)$$

A imagem em tons de cinza, assim como a imagem resultante da limiarização, é representada em uma matriz. Para a obtenção da imagem final do pré-processamento foi feita a comparação de cada elemento da imagem limiarizada, se o elemento é igual a zero (preto, indicando o fundo), o seu correspondente na imagem em cinza assume o valor 0, caso o valor seja 255 (branco, indicado uma região de folha) seu elemento correspondente na imagem em cinza mantém o seu valor. Tal decisão é demonstrada pela equação abaixo:

$$g(x, y) = \begin{cases} 0, & \text{se } f(x, y) = 0 \\ f(x, y), & \text{caso contrário} \end{cases} \quad (40)$$

4.4 Segmentação Baseada em Textura

O método para a segmentação das plantas invasoras baseada em textura foi desenvolvido baseado no Algoritmo 1 apresentado na seção 2.5.2, o qual encontra em uma imagem a região de interesse, baseando-se no valor de textura que cada região apresenta.

Neste contexto, a primeira etapa da segmentação é dividir a imagem em sub-imagens, ou janelas, de tamanho $n \times n$ e calcular o valor de textura em cada uma dessas janelas. O valor de textura é encontrado a partir de medidas estatísticas de textura obtidas através da matriz de co-ocorrência. Esse valor é normalizado, ficando sempre entre 0 e 1. A partir das informações de textura em cada janela, pode-se obter um mapa de textura, cujos valores foram redistribuídos dentro da paleta de cinza da imagem (0-255) para que a sua visualização fosse possível. Depois de criado o mapa de textura foi necessário encontrar as janelas que podem ser conectadas, ou seja, aquelas que possuem vizinhos de valores iguais, ou com uma diferença dentro de um limite pré-estabelecido. Encontradas as regiões conectadas, as mesmas foram unidas, gerando uma nova classe de primitiva. Paralelamente, foram encontradas as regiões que cada objeto ocupa na imagem original.

Para isto foi necessário encontrar as informações das bordas das folhas e depois selecionar as regiões internas a essas bordas. A partir deste ponto foi organizada a união da imagem das regiões e do mapa de textura, obtendo como resultado o mapa de textura das folhas onde as regiões são representadas pelo valor de textura médio dentro de cada uma delas e o fundo preto. Finalmente, os objetos de interesse foram selecionados com base nos valores do mapa de textura das folhas. Este método está representado no Algoritmo 3.

Algoritmo 3 Algoritmo para a segmentação baseada em textura

- 1: Obter o mapa de textura:
 - a) Fazer um janelamento na imagem original;
 - b) Calcular o valor de textura de cada janela;
 - c) Normalizar os valores de textura;
 - d) Redistribuir os valores normalizados na paleta de cinza (0-255) para a visualização do mapa;
 - e) Conectar as classes iguais ou dentro de um limite;
 - 2: Encontrar na imagem vinda do pré-processamento apenas as regiões de interesse.
 - 3: Calcular o mapa de textura das folhas:
 - a) Unir o mapa de textura e a imagem das regiões;
 - b) Calcular para cada região o valor de textura médio.
 - 4: Selecionar no mapa de textura das folhas apenas as regiões de interesse.
-

Descrevendo com maior detalhe o Algoritmo 3, considera-se:

- Passo 1 a): Para o janelamento da imagem original, foram criadas pequenas imagens, com o tamanho especificado, no caso 10×10 , para que fossem feitos os cálculos de textura necessários. Para ilustrar o processo, suponha uma imagem de 30×30 . O primeiro janelamento é referente aos *pixels* cujas posições variam de $(0, 0)$ até $(9, 9)$, o segundo janelamento é referente às posições de $(0, 10)$ até $(9, 19)$, o terceiro refere-se às posições de $(0, 20)$ até $(9, 29)$, o quarto de $(10, 0)$ até $(19, 9)$ e assim por diante.
- Passo 1 b): Para cada janelamento foi calculada sua respectiva matriz de co-ocorrência e a partir dela, extraído o valor correspondente à medida de textura do contraste.
- Passo 1 c): Os valores de textura obtidos foram normalizados, para que ficassem na

faixa entre 0 e 1. Para a normalização, foi utilizada a seguinte expressão:

$$valor_{normalizado} = \frac{valor_{obtido} - menor_{valor}}{maior_{valor} - menor_{valor}} \quad (41)$$

- Passo 1 d): Para a visualização dos valores de textura, os mesmos foram redistribuídos na paleta de cinza (0-255), tendo seus valores normalizados multiplicados por 255.
- Passo 1 e): A conexão das classes foi feita através da comparação do valor de textura de uma janela com as suas vizinhas. Aquela janela que possuía uma vizinha com o mesmo valor, ou com valor dentro de um limite, era conectada com sua vizinha, passando a formar uma nova região, e nesta região, ambas as janelas, assumia um novo valor de textura, igual a média das duas regiões. Esta operação foi repetida até que novas regiões não pudessem ser formadas.
- Passo 2: Para encontrar as regiões de interesse, inicialmente foram encontradas as bordas aplicando um filtro laplaciano de tamanho 3×3 . Logo após foi feita uma dilatação, utilizando também uma máscara 3×3 , visando o fechamento das formas das folhas, e posteriormente foi feita uma erosão, cuja máscara era de 2×2 . Depois de identificadas as bordas na imagem, foi feita a subtração das mesmas na imagem binarizada, encontrada na etapa de pré-processamento, Algoritmo 2, passo 4. Como é possível que regiões muito pequenas tenham sido identificadas, é necessário excluir estas regiões, tornando-se este o encerramento deste passo.
- Passo 3 a): Para a união do mapa de textura e das regiões das folhas foi feita uma comparação entre as duas imagens, se o *pixel* da imagem das regiões fosse 0, a imagem resultante da união também teria seu valor igual a zero, mas caso fosse branco, o valor do *pixel* na imagem resultante será considerado igual ao valor correspondente na imagem do mapa de textura. Considerando a imagem do mapa de textura como $g(x, y)$, a imagem das regiões como $h(x, y)$ e a resultante como $s(x, y)$, o processo de união pode ser expresso pela equação seguinte:

$$s(x, y) = \begin{cases} 0, & \text{se } h(x, y) = 0 \\ g(x, y), & \text{caso contrário} \end{cases} \quad (42)$$

- Passo 3 b): O cálculo do valor médio de textura de cada região foi obtido através da divisão da soma dos valores de textura de cada *pixel* da região pela quantidade de *pixels* dentro da mesma. Após o cálculo, todos os *pixels* da região assumiram o valor da média.
- Passo 4: Para a seleção das regiões de interesse no mapa de textura das folhas, primeiramente foi identificado o intervalo de valores de textura que os padrões de interesse apresentaram. O intervalo não foi obtido por padrão pois nesta etapa não será feita a discriminação entre eles, apenas entre as folhas de plantas invasoras e as folhas da cultura, neste caso, o milho. Identificado o intervalo, foram selecionadas apenas as regiões que estavam na faixa de valores desejada.

4.5 Descritores e Reconhecimento das Plantas Invasoras

A partir da imagem das folhas de plantas invasoras, obtidas através do mapa de textura das folhas, podem ser calculados, para cada região, os descritores de área, perímetro, comprimento, largura e menor polígono convexo a fim de se distinguir entre folhas largas e estreitas.

No sistema desenvolvido foram considerados três descritores distintos para o reconhecimento dos dois tipos de plantas, sendo eles, redondez, alongação e solidez. A medida de redondez é uma razão baseada nos descritores de área e perímetro, ou seja:

$$Redondez = \frac{4\pi \times Area}{Perimetro} \quad (43)$$

onde, $Perimetro \neq 0$.

A medida de alongação é a razão computada pela largura do menor eixo dividida pelo comprimento do maior eixo. Quanto maior o resultado, significa que o objeto é aproximadamente de forma quadrada ou redonda e conforme a razão vai diminuindo, mais alongado é o objeto a ser reconhecido, isto é:

$$Elongacao = \frac{largura}{comprimento} \quad (44)$$

onde $comprimento \neq 0$.

Somou-se a este conjunto de descritores a solidez. Ela computa a razão entre a área do menor polígono convexo e a área do objeto. Quanto maior o valor, mais sólido é o objeto, ou seja:

$$\text{Solidez} = \frac{\text{Área do objeto}}{\text{Área do menor polígono convexo}} \quad (45)$$

onde $\text{Área do menor polígono convexo} \neq 0$.

Antes de se fazer o reconhecimento, é necessário escolher o descritor ou o conjunto de descritores que permite o melhor reconhecimento das folhas. O primeiro passo tomado para a escolha do descritor foi o cálculo dos mesmos para alguns exemplos de folhas largas e outros exemplos para folhas estreitas. A partir dos cálculos, foram obtidas as médias dos valores apresentados para cada um dos padrões requeridos.

Para o reconhecimento das regiões encontradas é feita uma comparação entre a distância do valor obtido para cada região e a média de cada um dos padrões. A região é atribuída a categoria de folhas largas, caso a distância do seu valor seja menor para a média de folhas largas, do que para a média de folhas estreitas. Este processo é demonstrado no Algoritmo 4.

Algoritmo 4 Algoritmo para o reconhecimento das folhas

- 1: Encontrar a média do descritor para cada um dos padrões (folhas largas e estreitas).
 - 2: Para cada região:
 - a) Calcular o valor do descritor;
 - b) Calcular a distância da região para a média de folhas largas;
 - c) Calcular a distância da região para a média de folhas estreitas;
 - d) Atribuir a região à classe que apresentar a menor distância.
-

Descrevendo com maior detalhe o Algoritmo 4, considera-se:

- Passo 1: Para encontrar a média do descritor para cada um dos padrões, foi necessário criar imagens de teste, nas quais havia apenas uma folha, ou larga, ou estreita. Para cada uma das imagens foram encontrados os seus respectivos valores de descritores, e então, para cada descritor, foi encontrada a média dos valores para folhas largas, e a média para folhas estreitas.

- Passo 2 a): O cálculo do valor do descritor foi feito criando uma nova imagem apenas com a região, e então obtidos os valores necessários para o cálculo, podendo ser área, perímetro, largura, comprimento e/ou área do menor polígono convexo. Com os valores necessários, o valor dos descritores foi obtido fazendo-se os cálculos apresentados nas equações 43, 44 e 45.
- Passo 2 b): A distância do valor obtido pela região para o valor das folhas largas foi obtida fazendo-se o cálculo do valor do descritor menos o valor da média das folhas largas. Computada a subtração, caso a mesma seja negativa, ela passa a perder o sinal, mantendo o seu valor absoluto.
- Passo 2 c): A distância do valor obtido pela região para o valor das folhas estreitas foi obtida fazendo o cálculo do valor do descritor menos o valor da média das folhas estreitas. Computada a subtração, caso a mesma seja negativa, ela passa a perder o sinal, mantendo o seu valor absoluto.
- Passo 2 d): Comparar as distâncias obtidas nos passos 2 b) e c) e atribuir a região ao padrão cuja distância foi menor.

4.6 Modelagem da interface com o usuário

O sistema foi desenvolvido utilizando o MATLAB¹⁶, e conta com uma interface com o usuário, que agrega todas as etapas do processo. A primeira etapa é a entrada da imagem adquirida, a segunda é o pré-processamento, eliminando-se o fundo, ficando apenas com as folhas da imagem. A terceira é a segmentação baseada em textura, selecionando apenas as plantas daninhas, a quarta é a aplicação dos descritores para obtenção dos mapas de plantas de folhas largas e outro de plantas de folhas estreitas. Por fim, a quinta e última etapa é o fornecimento dos percentuais de ocupação de cada tipo de planta na imagem.

A tela inicial da interface é exibida na Figura 14. Aberto o sistema, é necessário abrir a imagem da qual será feito o reconhecimento, para isso pressiona-se o botão <Abrir>. Quando este botão é pressionado, é aberta a caixa de diálogo *Open Image*, que está ilustrada na Figura 15. Nesta caixa de diálogo deve ser selecionada a imagem que se deseja

¹⁶MATLAB: linguagem de alto nível e ambiente interativo que permite executar tarefas computacionais intensivas de forma mais rápida do que com as linguagens tradicionais como C, C++, Java.

fazer o reconhecimento das plantas. Selecionada a imagem, clica-se no botão <Open> e a mesma é exibida no primeiro espaço da interface, como ilustra a Figura 16. Com a imagem de entrada, para se fazer o pré-processamento, clica-se no botão <Pré-Processamento>, e a imagem pré-processada será exibida no espaço acima do botão, como mostra a Figura 17. A partir da imagem pré-processada, é possível encontrar o seu respectivo mapa de textura das folhas, para isso, clica-se no botão <Textura>, e o mapa é exibido no espaço acima, como apresentado na Figura 18. O mapa de textura das folhas é obtido por meio do mapa de textura, que por sua vez é calculado através de um janelamento. O tamanho padrão deste janelamento é 10, mas o usuário pode mudá-lo a qualquer momento, digitando outro valor. É importante ressaltar que ao mudar o tamanho do janelamento, os valores do mapa de textura das folhas também muda. Calculado o mapa de textura das folhas, o mesmo pode ser dividido em dois mapas, um de folhas largas e outro de folhas estreitas, clicando-se no botão <Mapas>. Estes mapas estão ilustrados na Figura 19. O sistema também fornece a porcentagem de cada tipo de folha encontrada, para tal clica-se no botão <Percentuais> e as respectivas porcentagens são exibidas, como mostra a Figura 20.

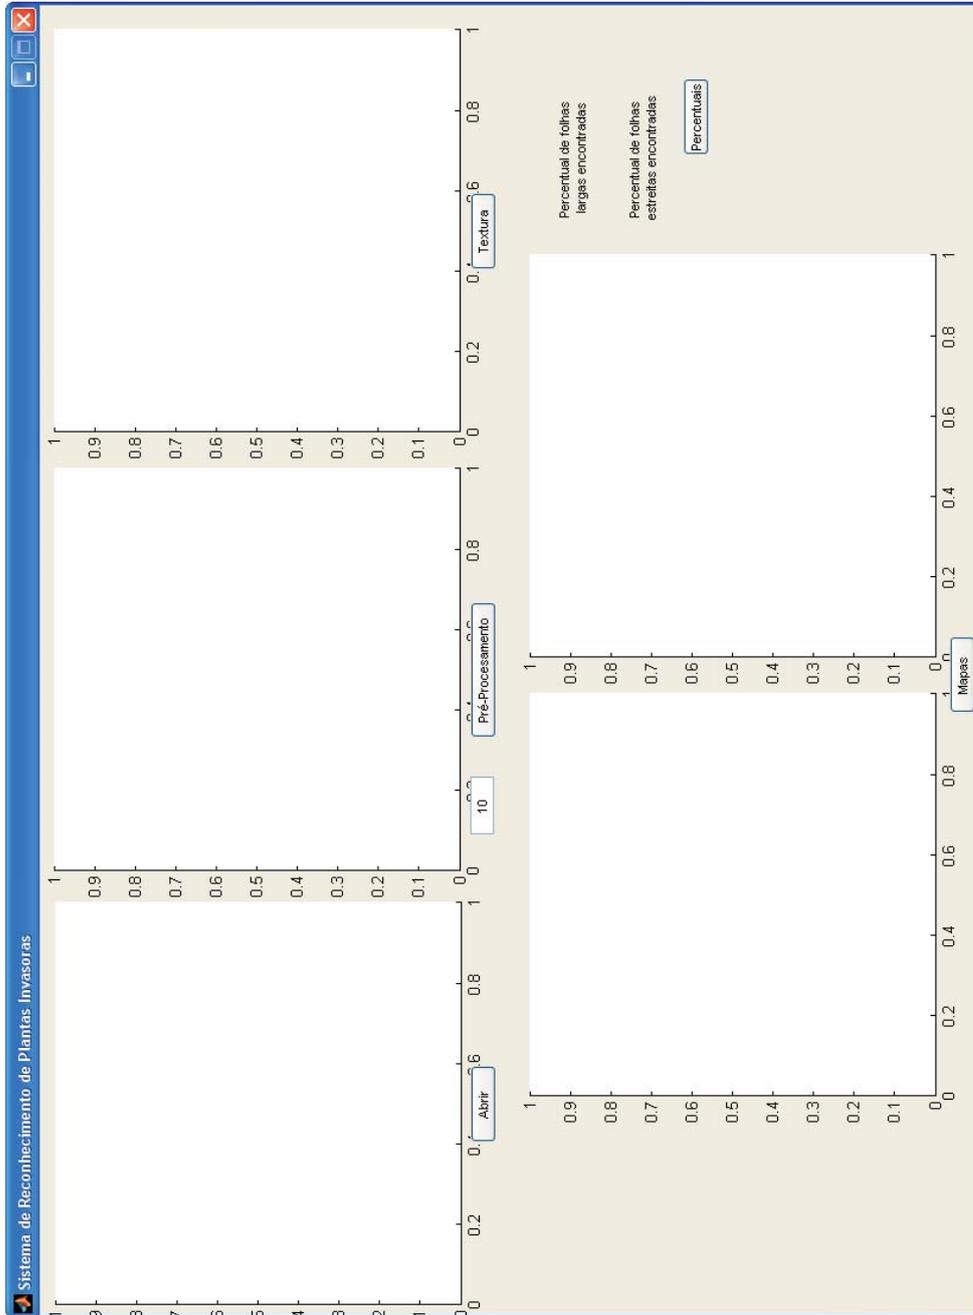


Figura 14: Tela inicial do sistema de reconhecimento, o qual fornecerá ao final o percentual de plantas invasoras de folhas largas e o percentual de plantas de folhas estreitas encontradas na imagem de entrada.

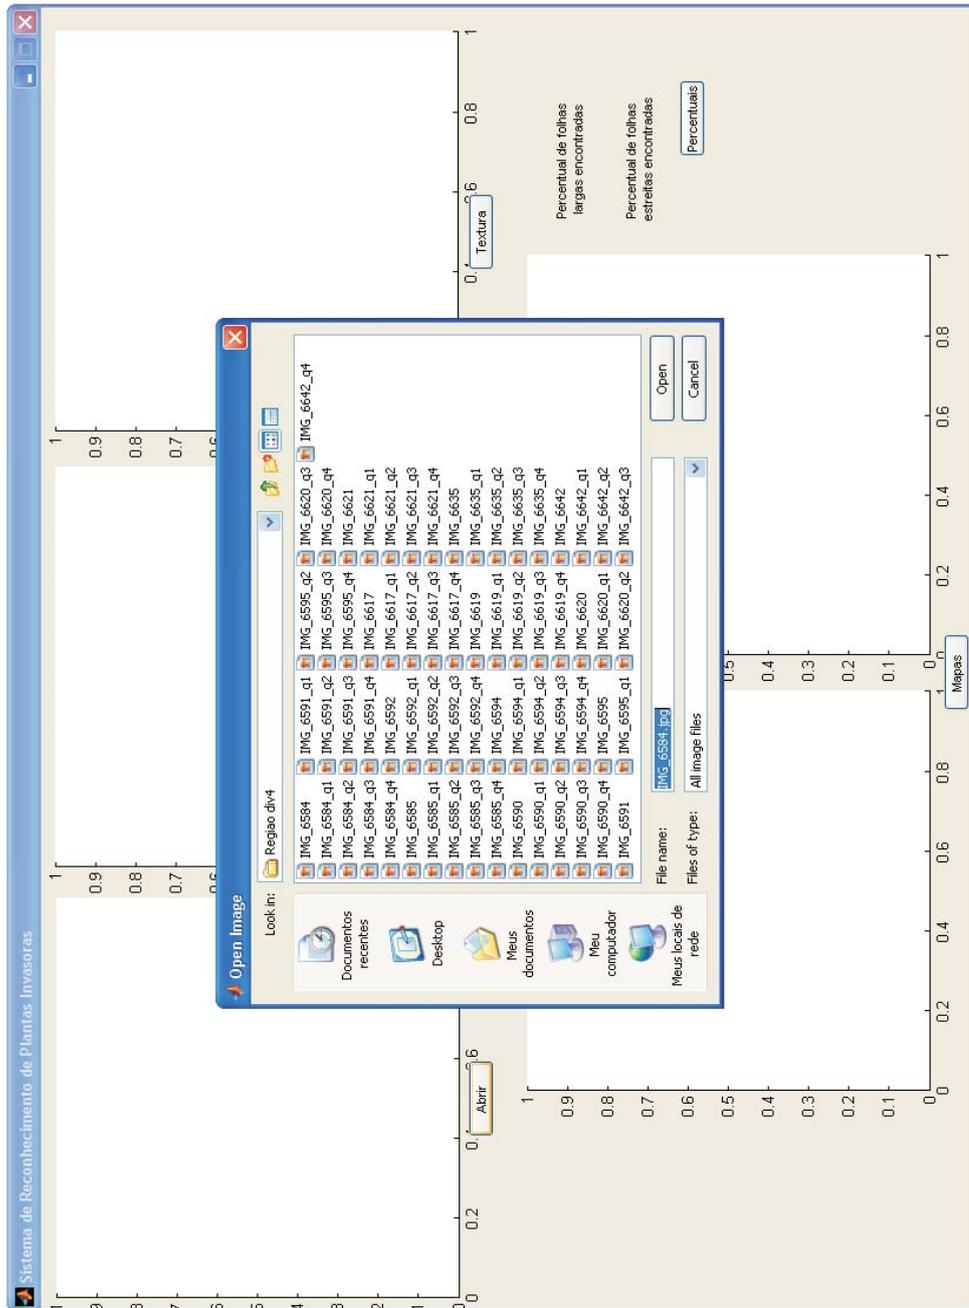


Figura 15: Tela do sistema de reconhecimento: caixa de diálogo Open Image, que é ativada ao se pressionar o botão <Abrir> para que a imagem de entrada seja selecionada.

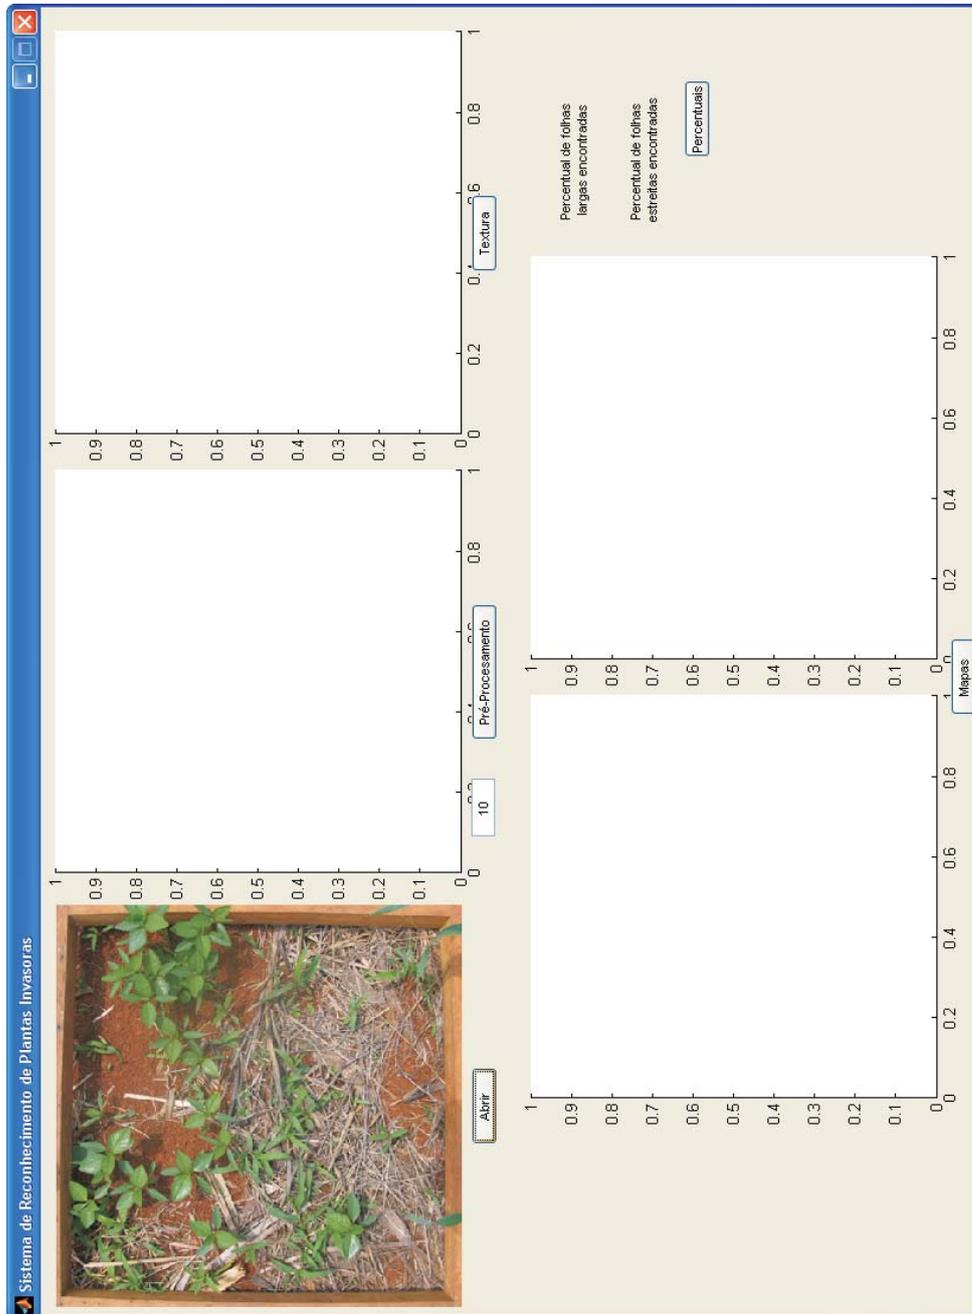


Figura 16: Tela do sistema de reconhecimento: imagem de entrada selecionada na caixa de diálogo Open Image.

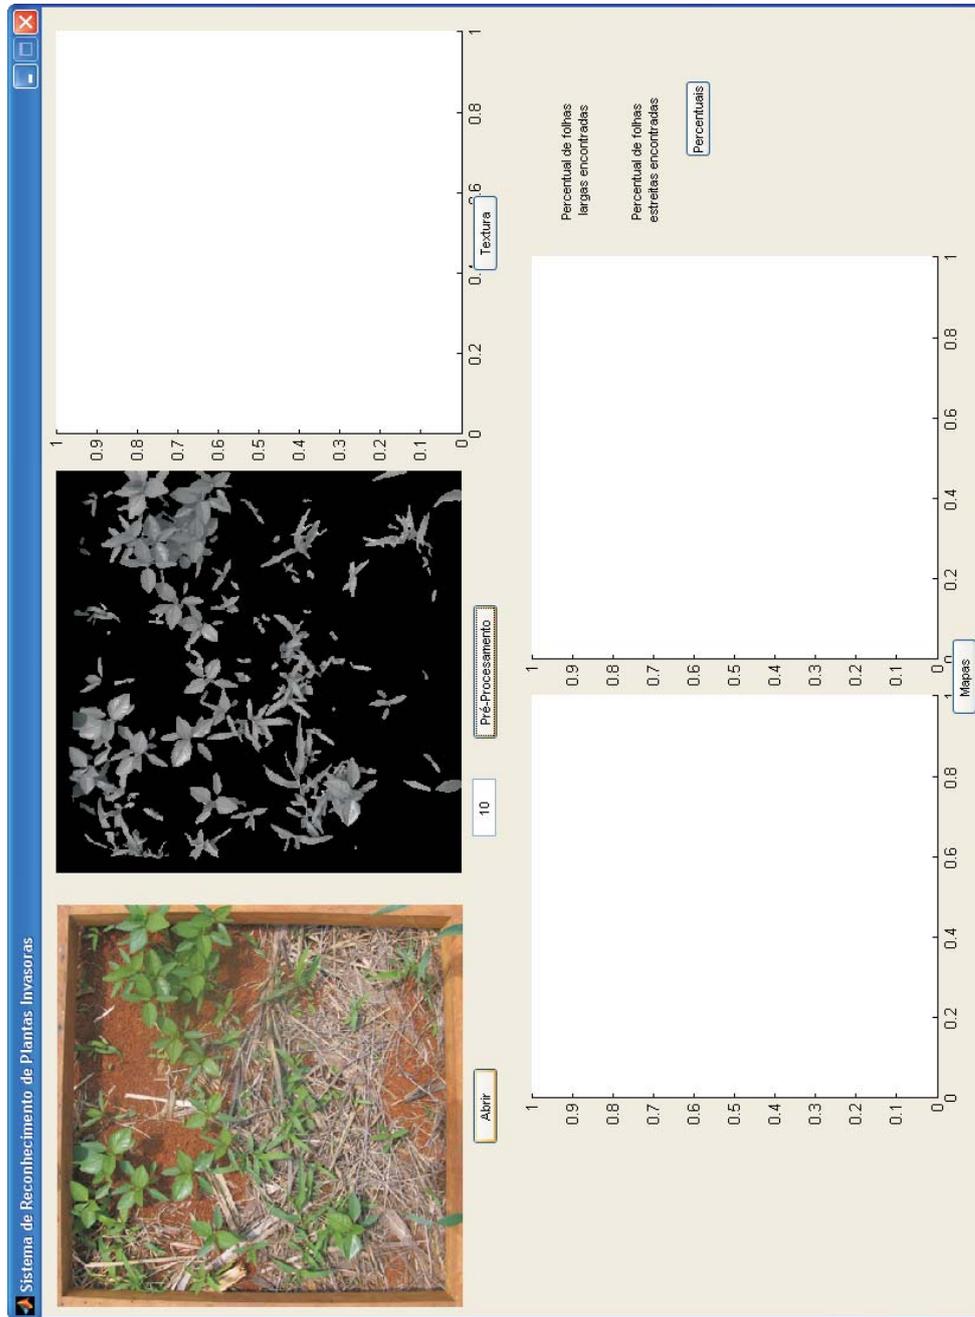


Figura 17: Tela do sistema de reconhecimento: imagem resultante do pré-processamento localizada ao lado da imagem de entrada. Para o cálculo da mesma, é necessário pressionar o botão <Pré-Processamento>.

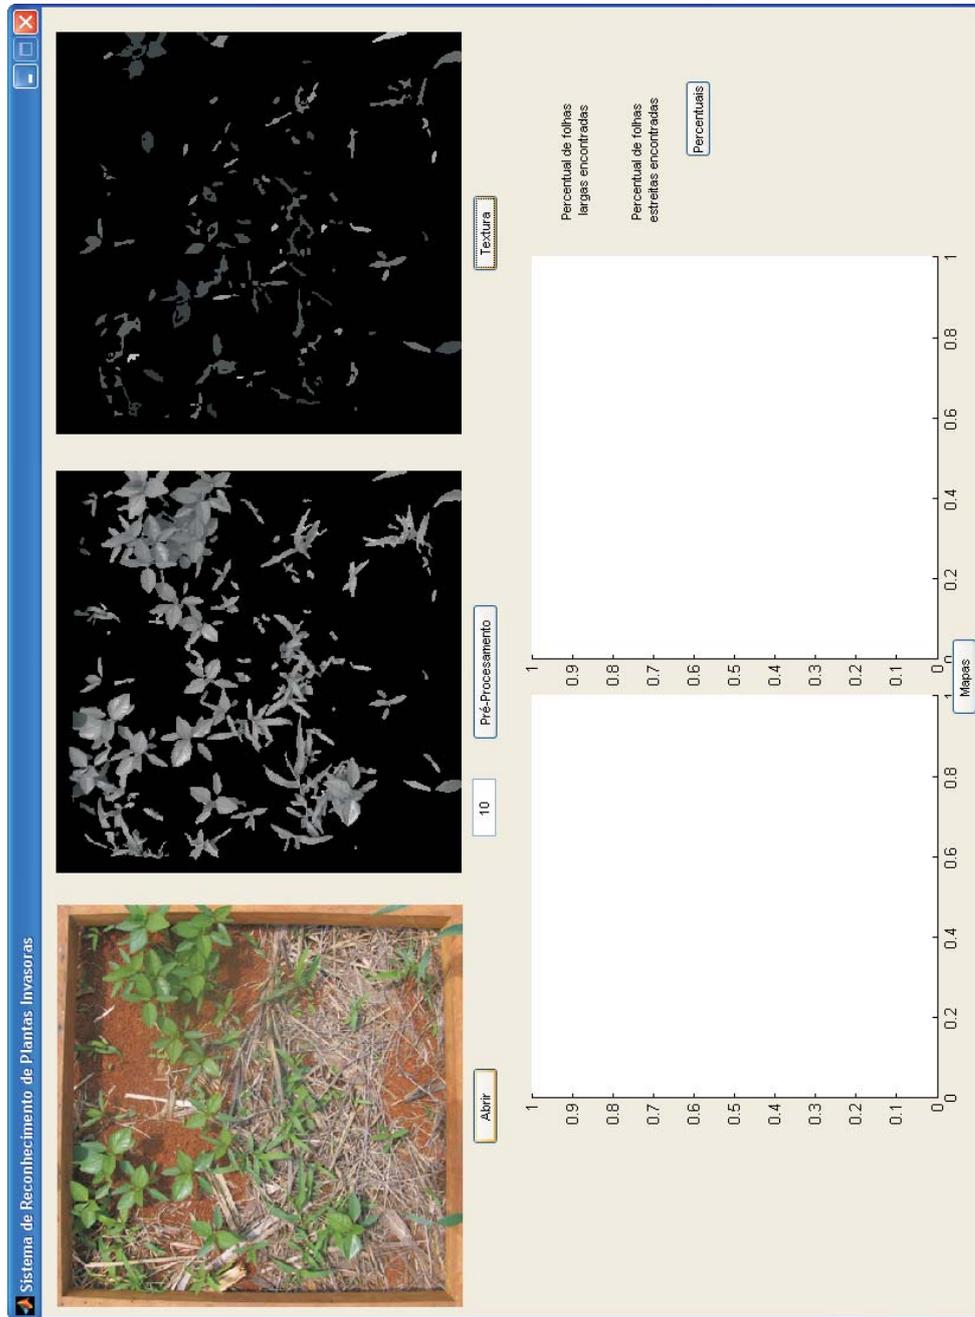


Figura 18: Tela do sistema de reconhecimento: mapa de textura das folhas de plantas invasoras, localizado ao lado da imagem do pré-processamento. O mapa é calculado quando o botão <Textura> é pressionado.

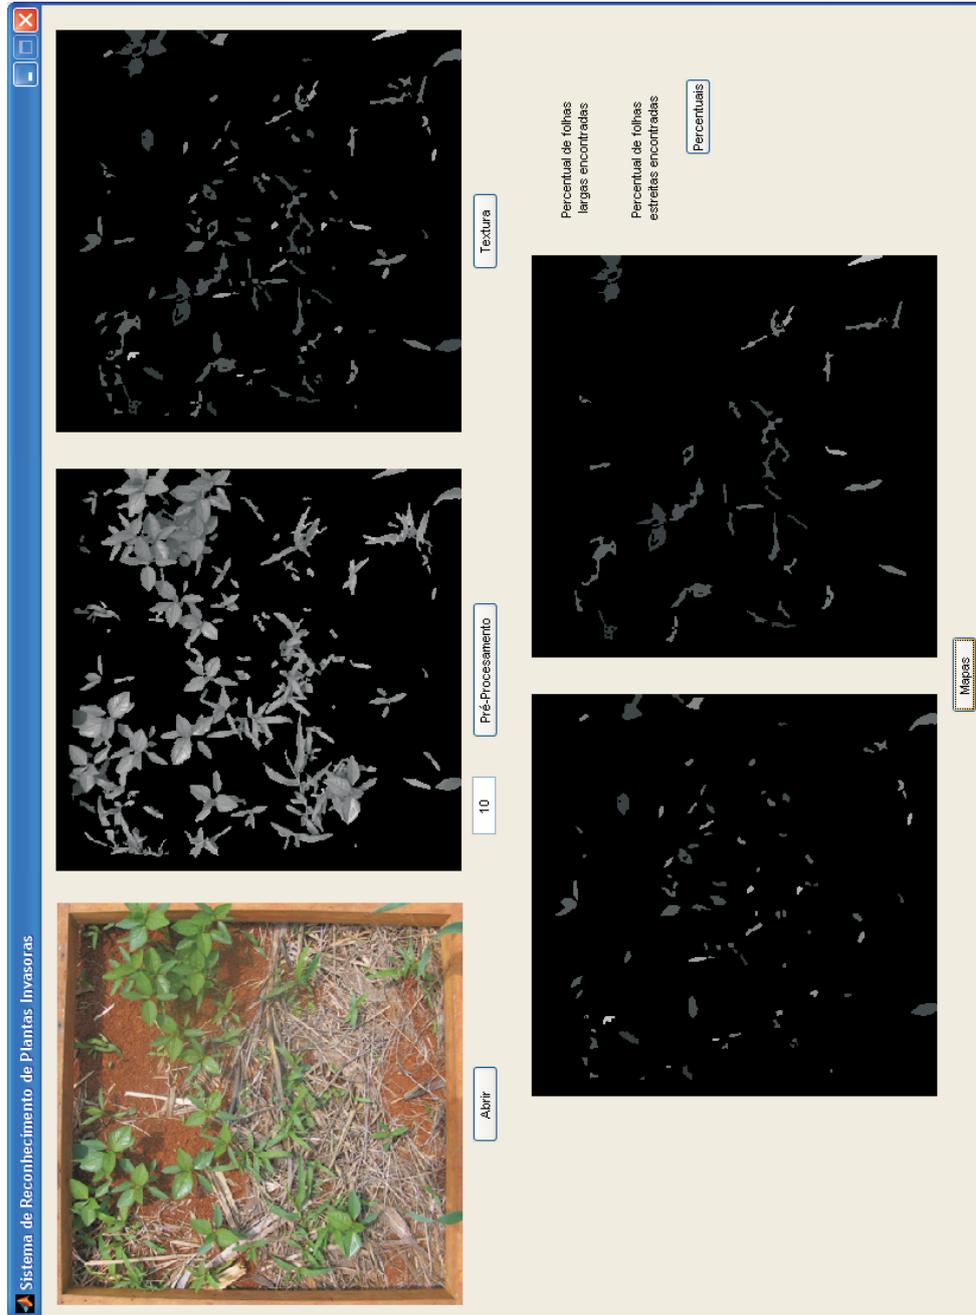


Figura 19: Tela do sistema de reconhecimento: mapa das folhas largas e estreitas, posicionadas na parte de baixo da imagem, sendo a esquerda o mapa das folhas largas e a direita o mapa das folhas estreitas. Para a obtenção dos mapas o botão <Mapas> foi pressionado.

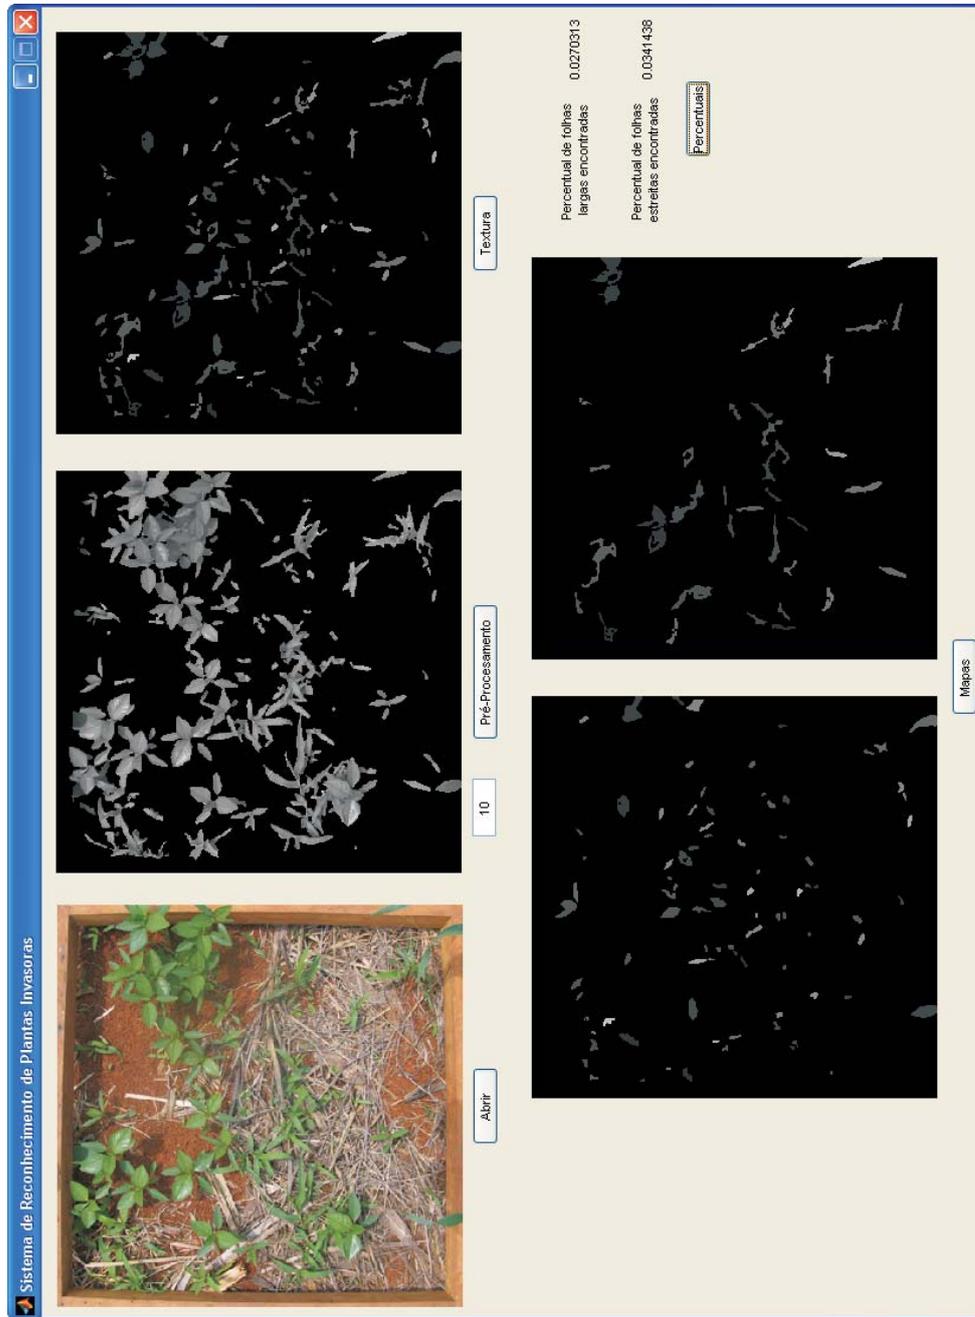


Figura 20: Tela final do sistema de reconhecimento, onde são obtidos os percentuais de ocupação das plantas de folhas largas, e os percentuais das plantas de folhas estreitas, após o clique no botão <Percentuais>.

Este capítulo apresentou as etapas consideradas para o entendimento e operação do sistema de reconhecimento dos padrões de plantas invasoras e percentuais de ocupação de plantas de folhas largas e folhas estreitas encontradas em ambiente de produção agrícola.

Resultados e Discussões

Neste capítulo são apresentados os resultados e as discussões que tratam da validação do método desenvolvido para o reconhecimento de padrões de plantas invasoras (folhas largas e folhas estreitas) e cálculo dos percentuais de ocupação dessas folhas em área de produção agrícola.

5.1 Validação dos Algoritmos

Nesta seção são apresentados e discutidos os métodos de validação dos algoritmos do sistema desenvolvido.

5.1.1 Imagens Geradas para Validação do Método

Para a validação dos algoritmos foram geradas imagens com dois tipos de padrões, sendo um utilizando padrões geométricos e outro padrões de folhas, onde ambos os tipos de imagens foram gerados com tamanho de 50×50 *pixels* e resolução de $28,346$ *pixels/cm*.

O primeiro tipo de imagem foi com uma forma geométrica ao centro, sendo elas círculo, quadrado, retângulo e triângulo. Para cada uma das formas foram geradas duas

imagens, e para cada uma delas 20 imagens, cada uma com um valor de intensidade diferente, variando entre a tonalidade 13 até 255, todas com o fundo preto. Foram utilizadas intensidades considerando uma distribuição igualmente espaçada na escala de níveis de cinza (13, 26, 38, 51, 64, 77, 89, 102, 115, 128, 140, 153, 166, 179, 191, 204, 217, 230, 242 e 255). As próximas figuras, de 21 a 28, exibem exemplos das imagens das figuras geométricas, criadas para os testes dos algoritmos. Ao total foram geradas 160 imagens, sendo 20 intensidades diferentes para cada forma geométrica considerada.

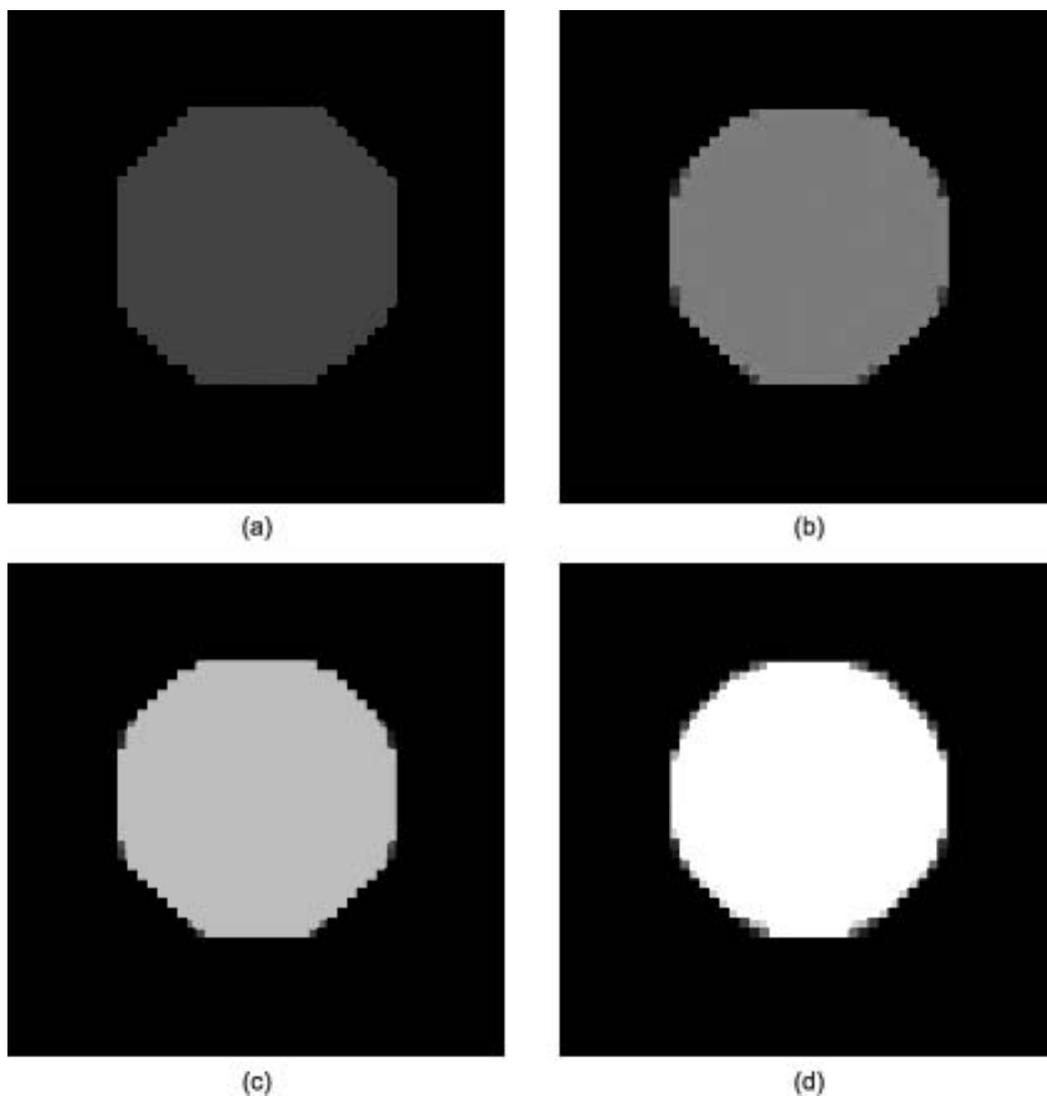


Figura 21: Imagens da forma círculo geradas para a validação da segmentação baseada em textura, onde as intensidades ilustradas são 13, 77, 191 e 255, respectivamente em (a), (b), (c) e (d).

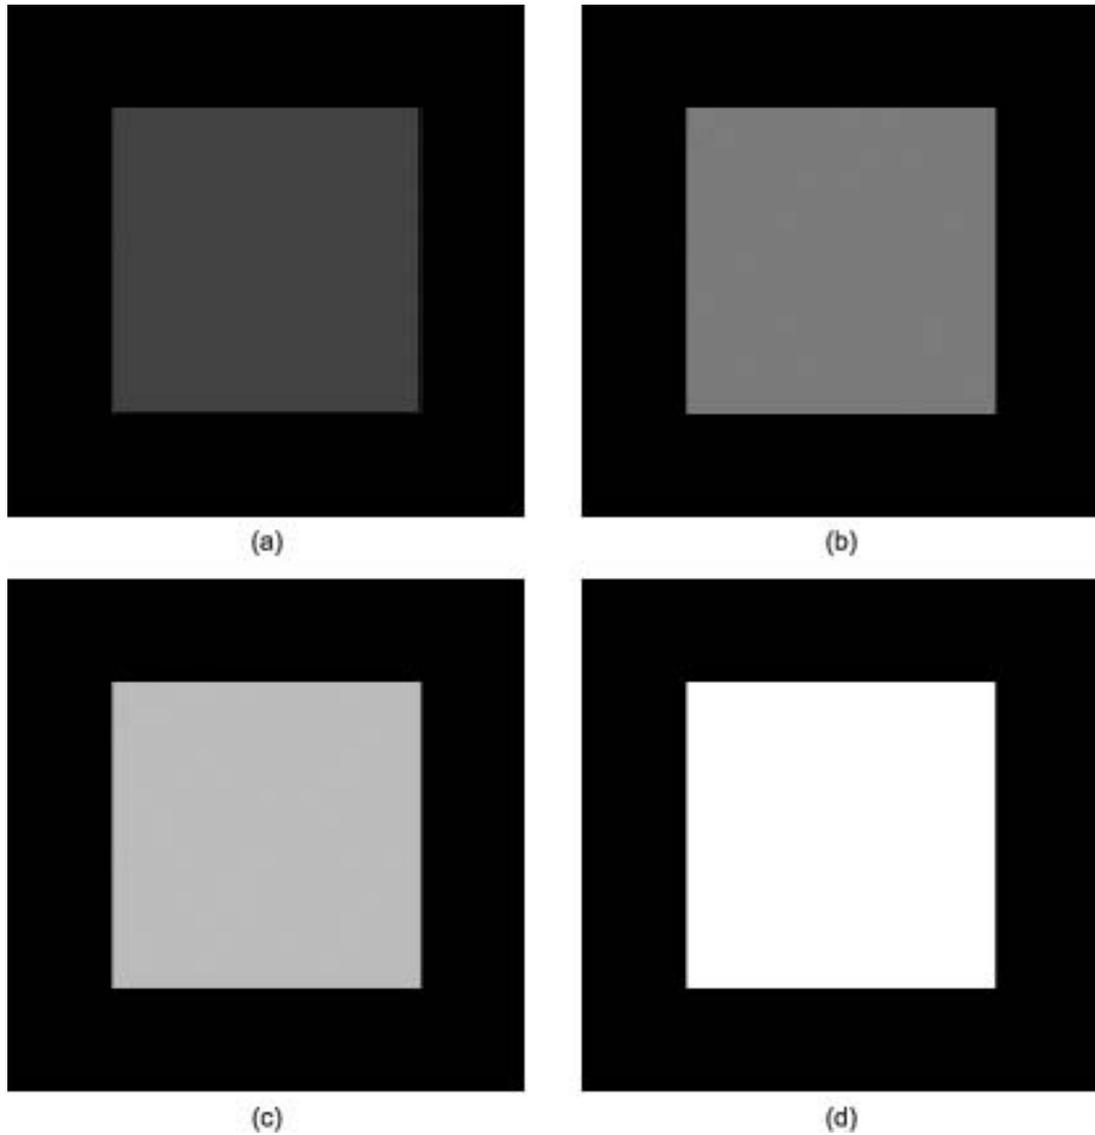


Figura 22: Imagens da forma quadrado geradas para a validação da segmentação baseada em textura, onde as intensidades ilustradas são 13, 77, 191 e 255, respectivamente em (a), (b), (c) e (d).

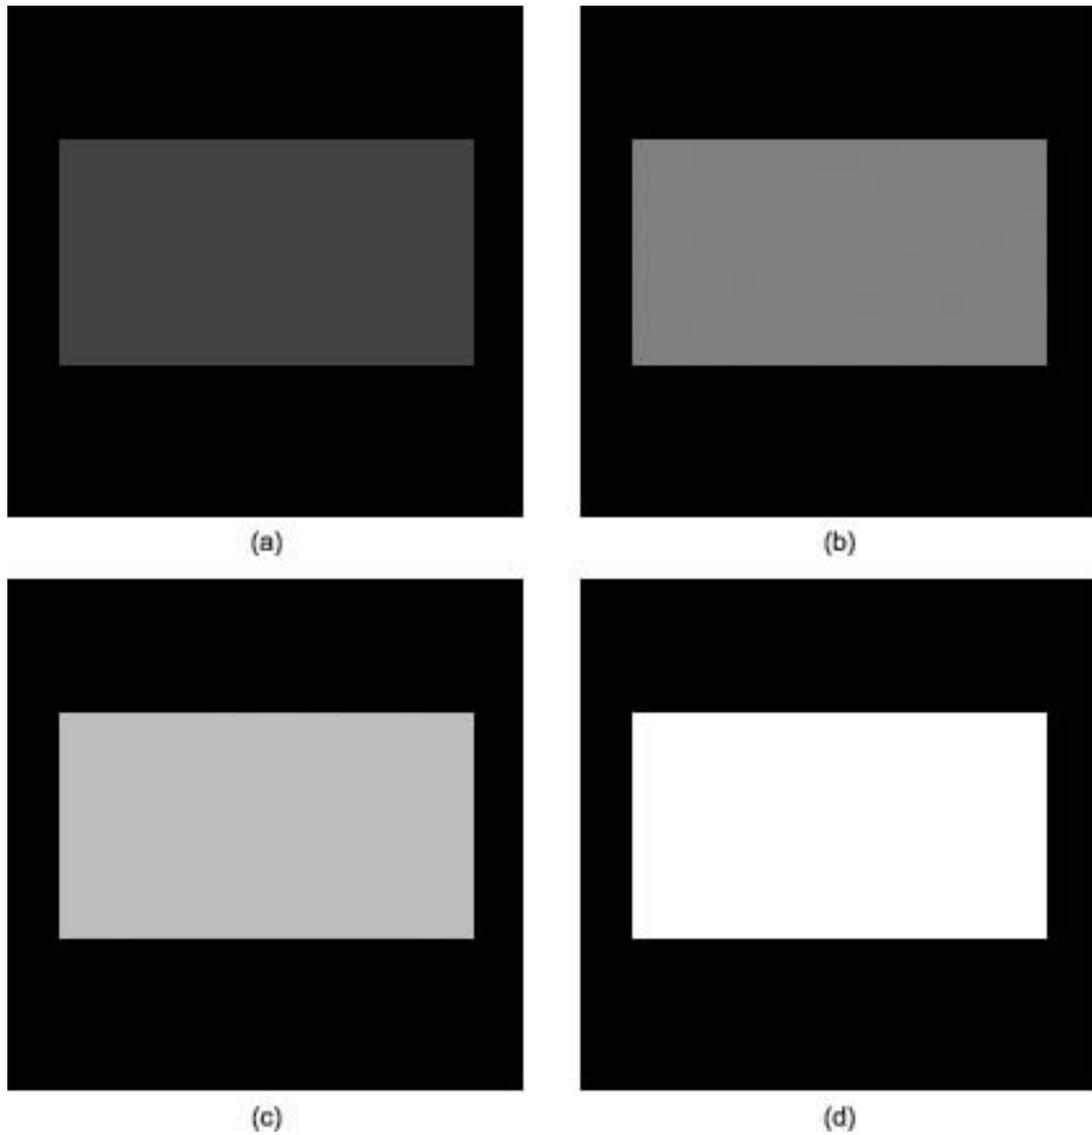


Figura 23: Imagens da forma retângulo geradas para a validação da segmentação baseada em textura, onde as intensidades ilustradas são 13, 77, 191 e 255, respectivamente em (a), (b), (c) e (d).

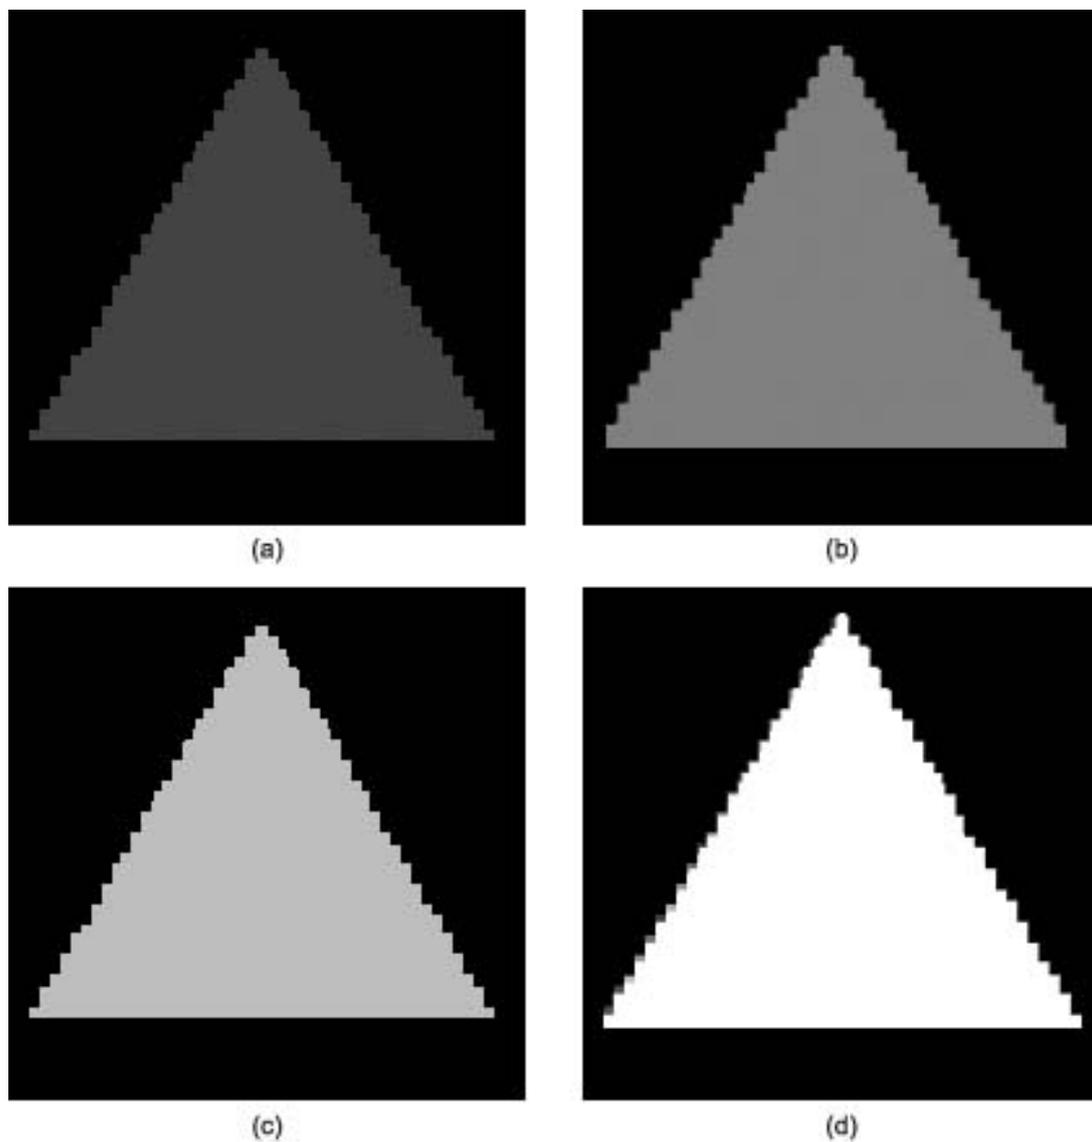


Figura 24: Imagens da forma triângulo geradas para a validação da segmentação baseada em textura, onde as intensidades ilustradas são 13, 77, 191 e 255, respectivamente em (a), (b), (c) e (d).

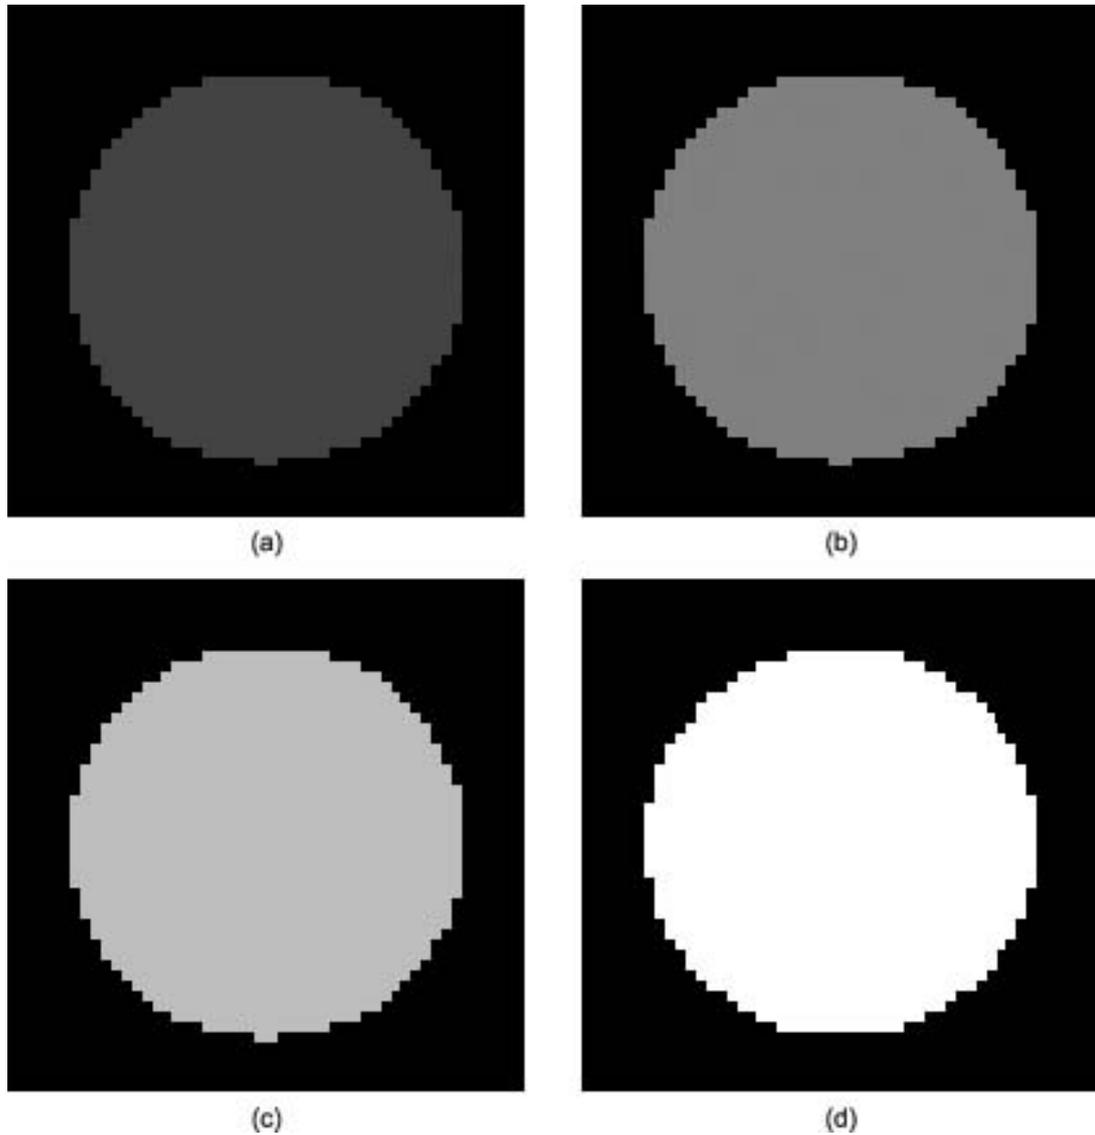


Figura 25: Imagens da forma círculo2 geradas para a validação da segmentação baseada em textura, onde as intensidades ilustradas são 13, 77, 191 e 255, respectivamente em (a), (b), (c) e (d).

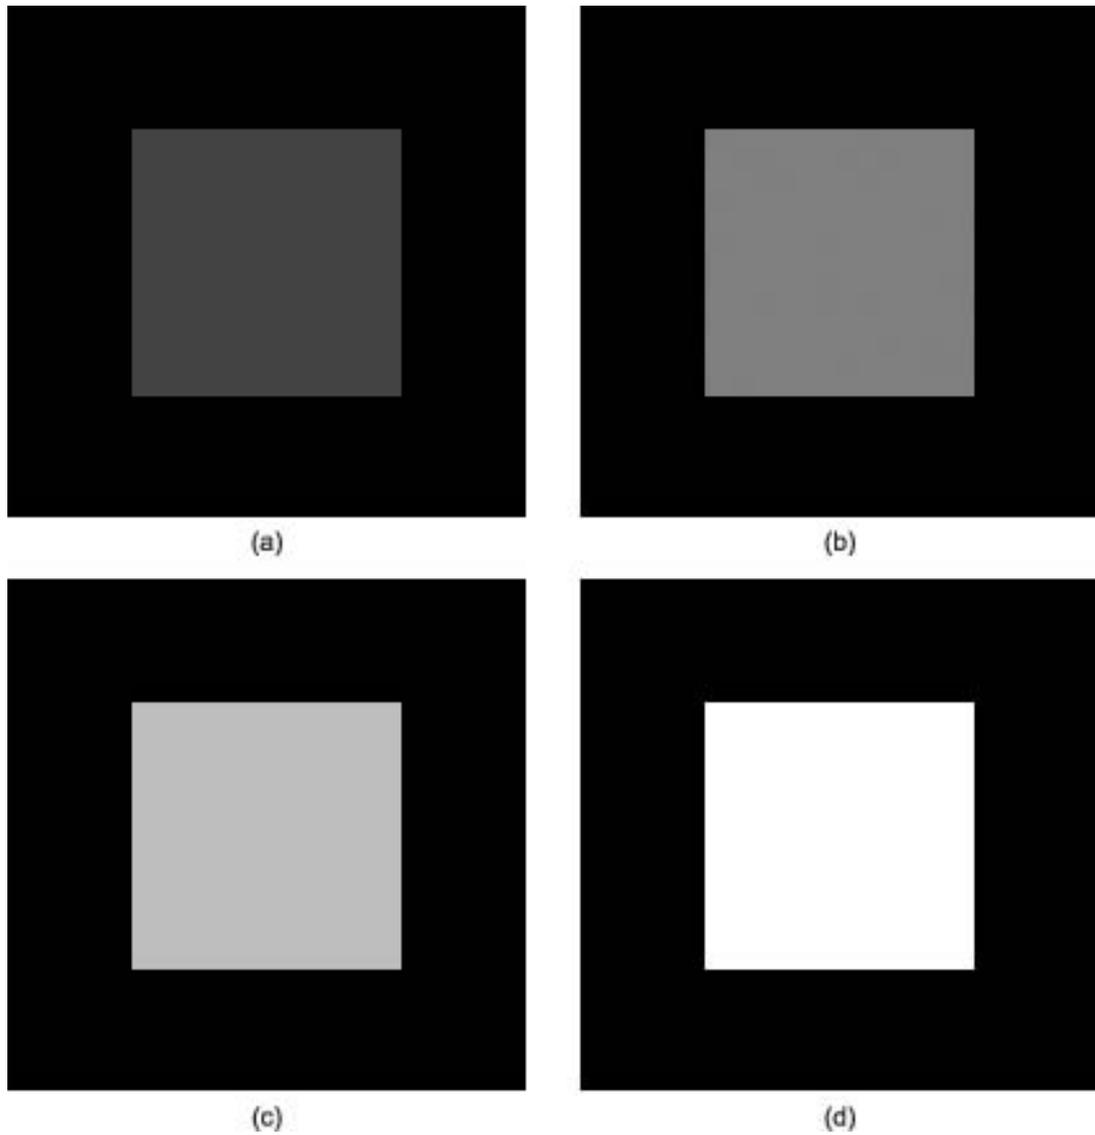


Figura 26: Imagens da forma `quadr2` geradas para a validação da segmentação baseada em textura, onde as intensidades ilustradas são 13, 77, 191 e 255, respectivamente em (a), (b), (c) e (d).

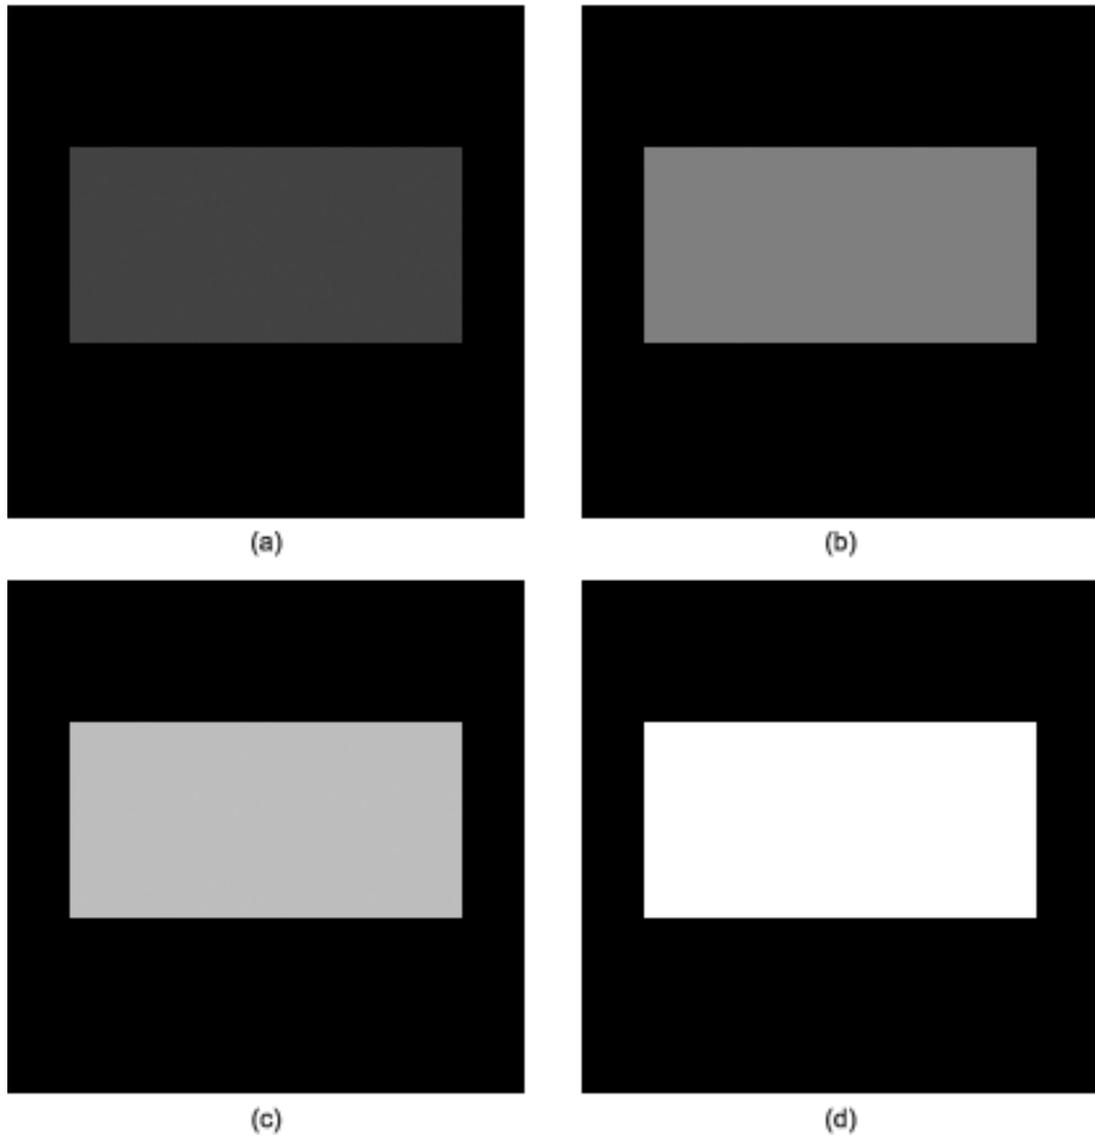


Figura 27: Imagens da forma retâng2 geradas para a validação da segmentação baseada em textura, onde as intensidades ilustradas são 13, 77, 191 e 255, respectivamente em (a), (b), (c) e (d).

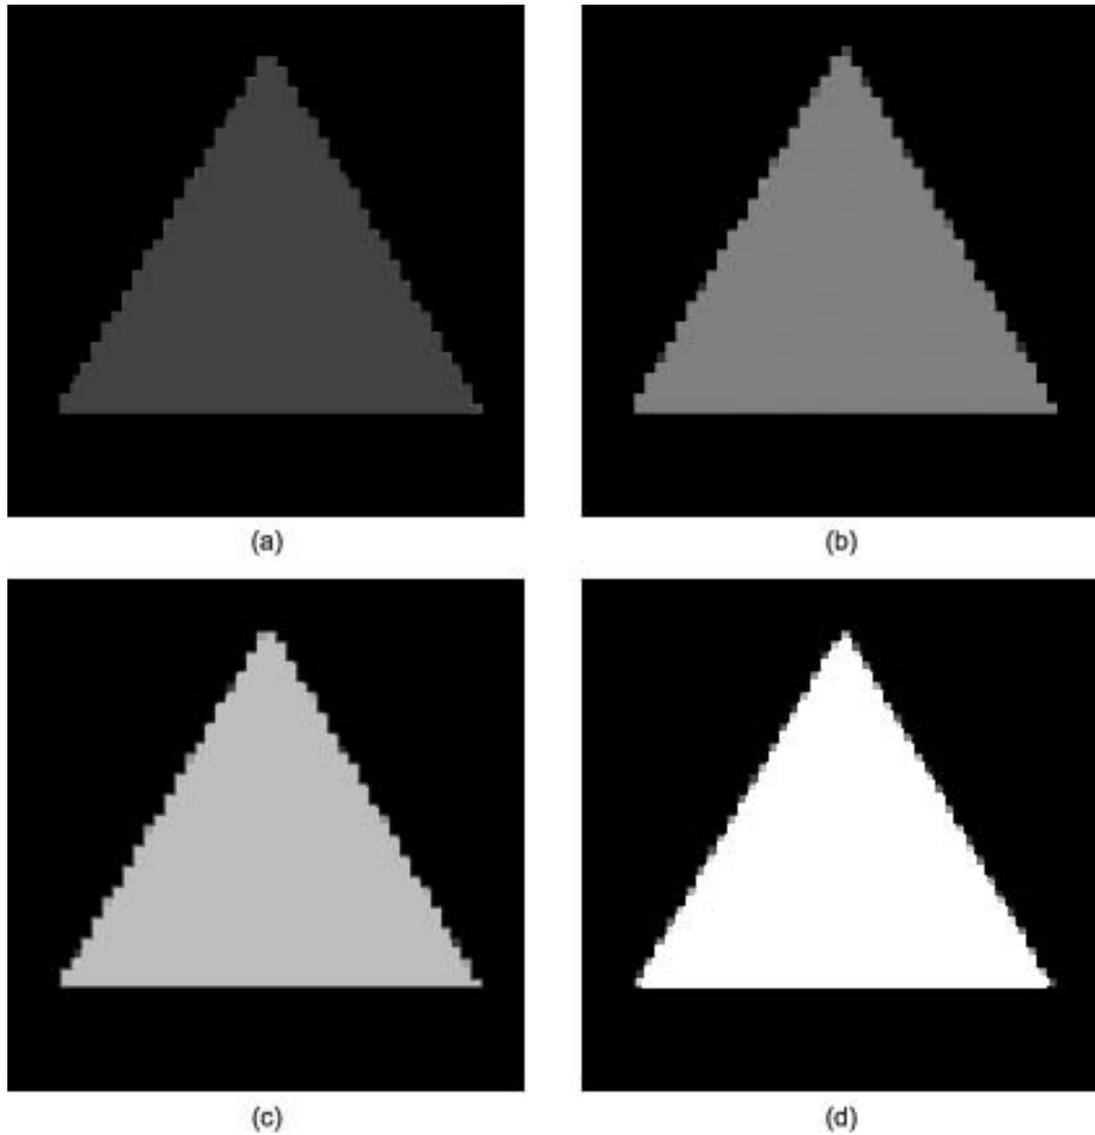


Figura 28: Imagens da forma triâng2 geradas para a validação da segmentação baseada em textura, onde as intensidades ilustradas são 13, 77, 191 e 255, respectivamente em (a), (b), (c) e (d).

O segundo tipo de imagem utilizada para a validação dos algoritmos foi com uma folha ao centro, sendo considerados os dois tipos de folhas, largas e estreitas, cujos dois exemplos de cada tipo são mostrados nas figuras 29 e 30, respectivamente. Estas imagens foram obtidas a partir de recortes nas imagens adquiridas em uma área de produção de milho (*Zea mays*). Ao todo foram geradas 54 imagens, sendo 26 de cada tipo de folha.



Figura 29: Exemplos de folhas largas obtidas para a validação dos algoritmos



Figura 30: Exemplos de folhas estreitas obtidas para a validação dos algoritmos

Além destas imagens, com padrões simples, também foram criadas imagens com padrões compostos, tanto com formas geométricas quanto com folhas. As imagens com formas geométricas compostas que foram criadas além de ter mistura de padrões, também possuíam, exemplos de sobreposição. E as imagens de folhas compostas foram criadas com agrupamentos de folhas, largas ou estreitas. A Figura 31 ilustra alguns exemplos de imagens com formas geométricas compostas criadas, e a Figura 32 ilustra exemplos de imagens de folhas compostas.

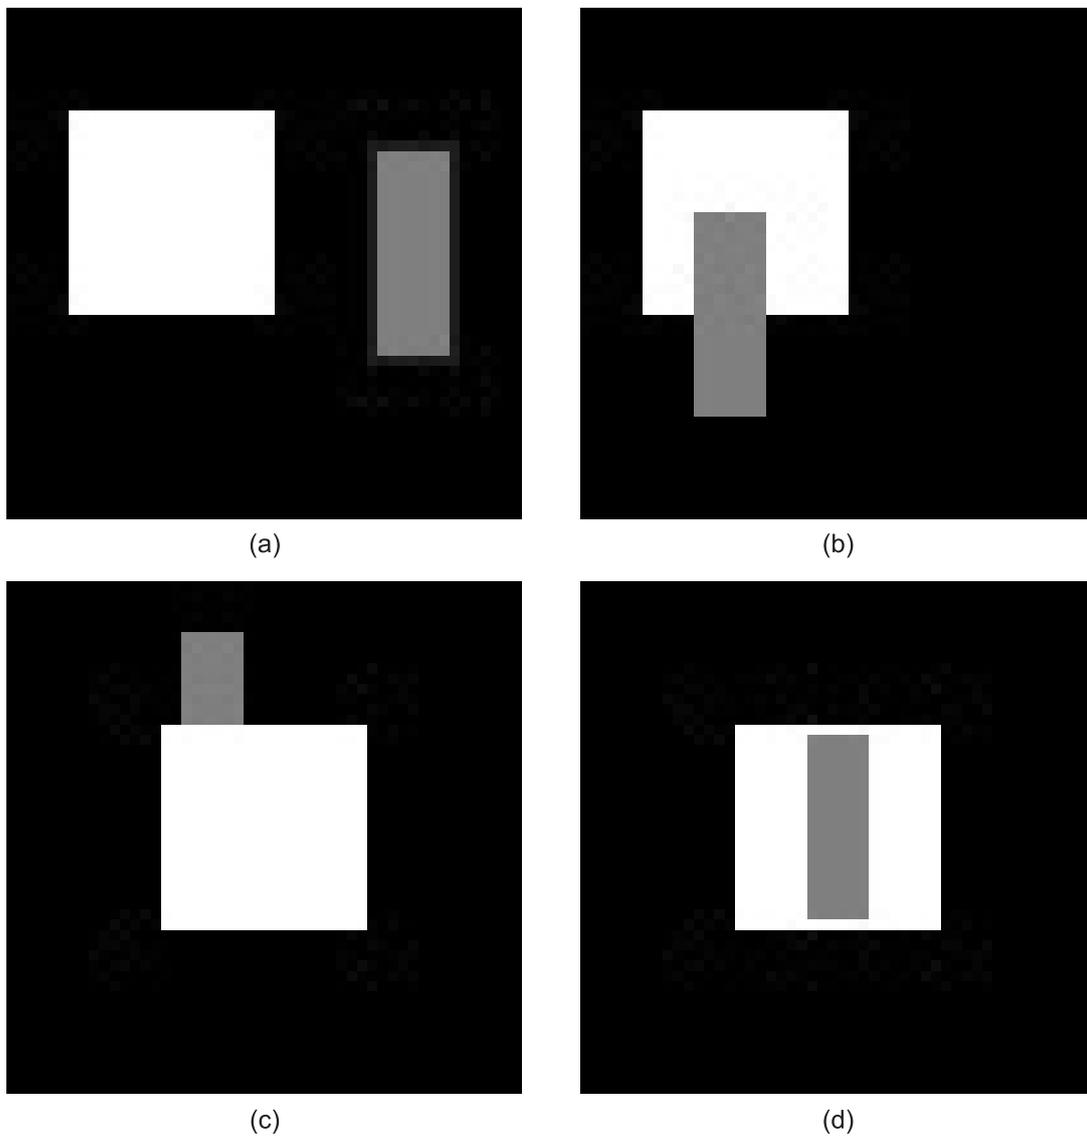


Figura 31: Exemplos de imagens com formas geométricas compostas: (a) imagem composta com um quadrado e um retângulo; (b) imagem composta com sobreposição de parte do retângulo sobre parte do quadrado; (c) imagem composta com sobreposição de parte do quadrado sobre parte do retângulo; (d) imagem composta com sobreposição total do retângulo sobre o quadrado.



(a)



(b)



(c)



(d)

Figura 32: Exemplos de agrupamentos de folhas, sendo (a) e (b) agrupamentos de folhas largas e (c) e (d) agrupamentos de folhas estreitas.

5.1.2 Pré-Processamento

O pré-processamento foi aplicado para eliminar as informações de fundo (palha e solo) das imagens de campo. Como o algoritmo manipula, entre outros as componentes R, G e B da imagem, sua validação foi feita utilizando apenas os padrões de folhas, desconsiderando, nesta etapa, os padrões geométricos.

O primeiro passo do Algoritmo 2 obtém as componentes R, G e B da imagem de entrada, que são ilustradas em escala de vermelho, verde e azul, respectivamente, juntamente com a imagem original nas figuras 33, 34 e 35.

Observando as imagens que representam a componente R, nota-se que a mesma representa as folhas com valores baixos, mais escuros, e a terra com valores mais altos, claros, exatamente o contrário da componente G, que representa as folhas com valores altos, e a terra com valores baixos. Pode-se dizer que a componente B é neutra, pois não apresenta nenhuma diferenciação expressiva nas regiões de folhas e de fundo (palha e solo). Por fim, foi observado que a palha é representada em cinza, o que significa que em todas as componentes o seu valor é o mesmo.

As figuras 36, 37 e 38 ilustram as imagens obtidas durante as outras fases do pré-processamento a partir das imagens 33(a), 34(a) e 35(a), respectivamente.

A partir da análise da primeira etapa, foi concluído que para encontrar apenas as folhas da imagem, era suficiente subtrair a imagem da componente R da imagem da componente G, como ilustram as figuras 36(a), 37(a) e 38(a). Encontradas as folhas, foi feita a aplicação do filtro da mediana com o objetivo de uniformizar os valores das folhas, conforme ilustram as figuras 36(b), 37(b) e 38(b). Assim, a partir da imagem com menor ruído, foi feita a limiarização da mesma, utilizando como limiar a média dos níveis de cinza, obtendo como resultado a imagem ilustrada nas figuras 36(c), 37(c) e 38(c). Em seguida, foi obtida a imagem com o fundo preto e as folhas com suas informações originais, em níveis de cinza, ilustradas nas figuras 36(d), 37(d) e 38(d).

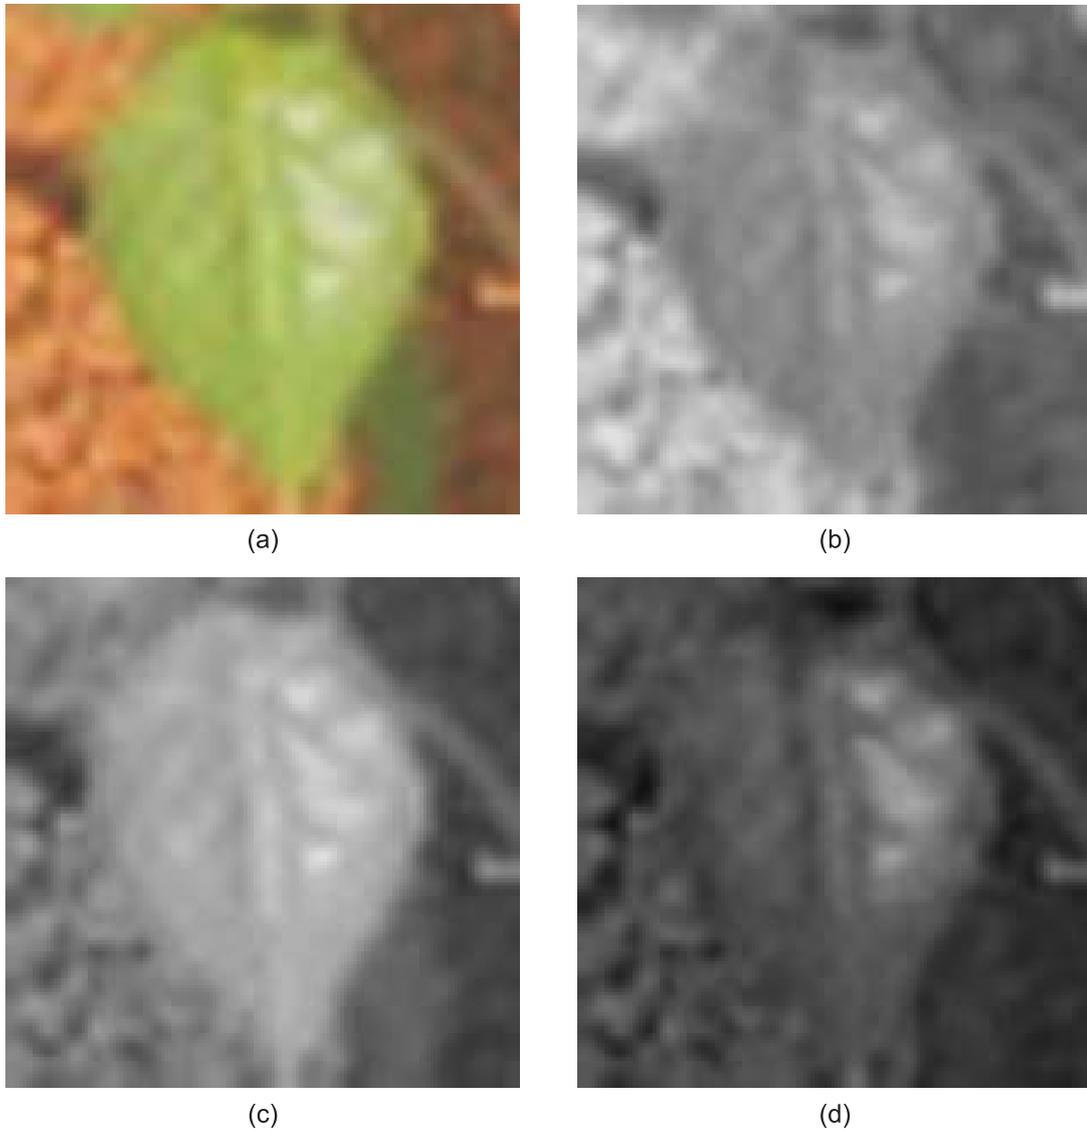


Figura 33: Exemplo de uma imagem de folha larga na primeira fase do pré-processamento: (a) imagem original; (b) representação da componente R da imagem original, em escala de vermelho; (c) representação da componente G da imagem original, em escala de verde; (d) representação da componente B da imagem original, em escala de azul. Nas representações das componentes, dadas as escalas, quanto mais claro, mais próximo da cor que a escala representa, e quanto mais escuro, mais próximo do preto, ausência da cor.

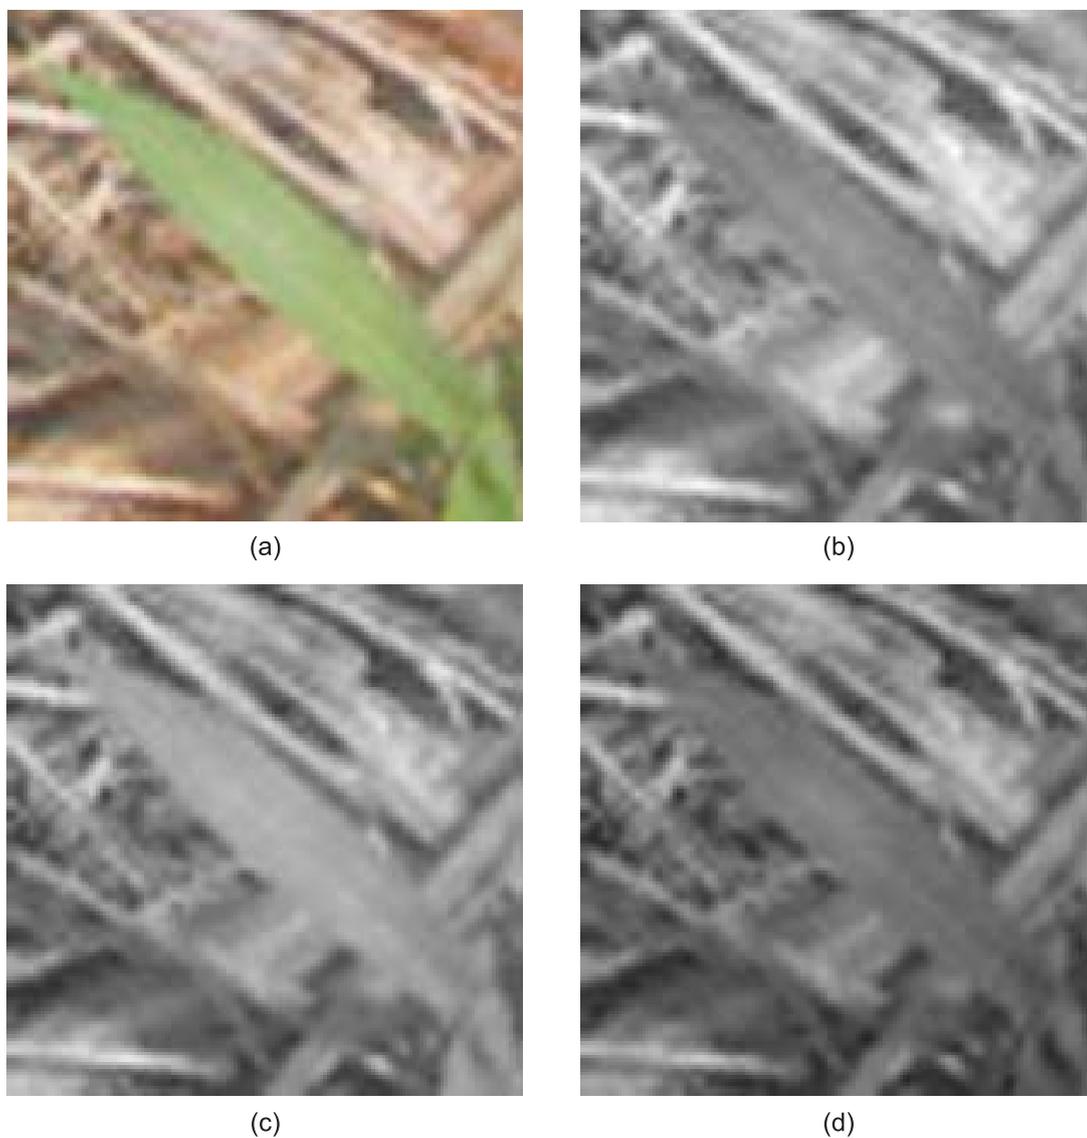


Figura 34: Exemplo de uma imagem de folha estreita na primeira fase do pré-processamento: (a) imagem original; (b) representação da componente R da imagem original, em escala de vermelho; (c) representação da componente G da imagem original, em escala de verde; (d) representação da componente B da imagem original, em escala de azul. Nas representações das componentes, dadas as escalas, quanto mais claro, mais próximo da cor que a escala representa, e quanto mais escuro, mais próximo do preto, ausência da cor.

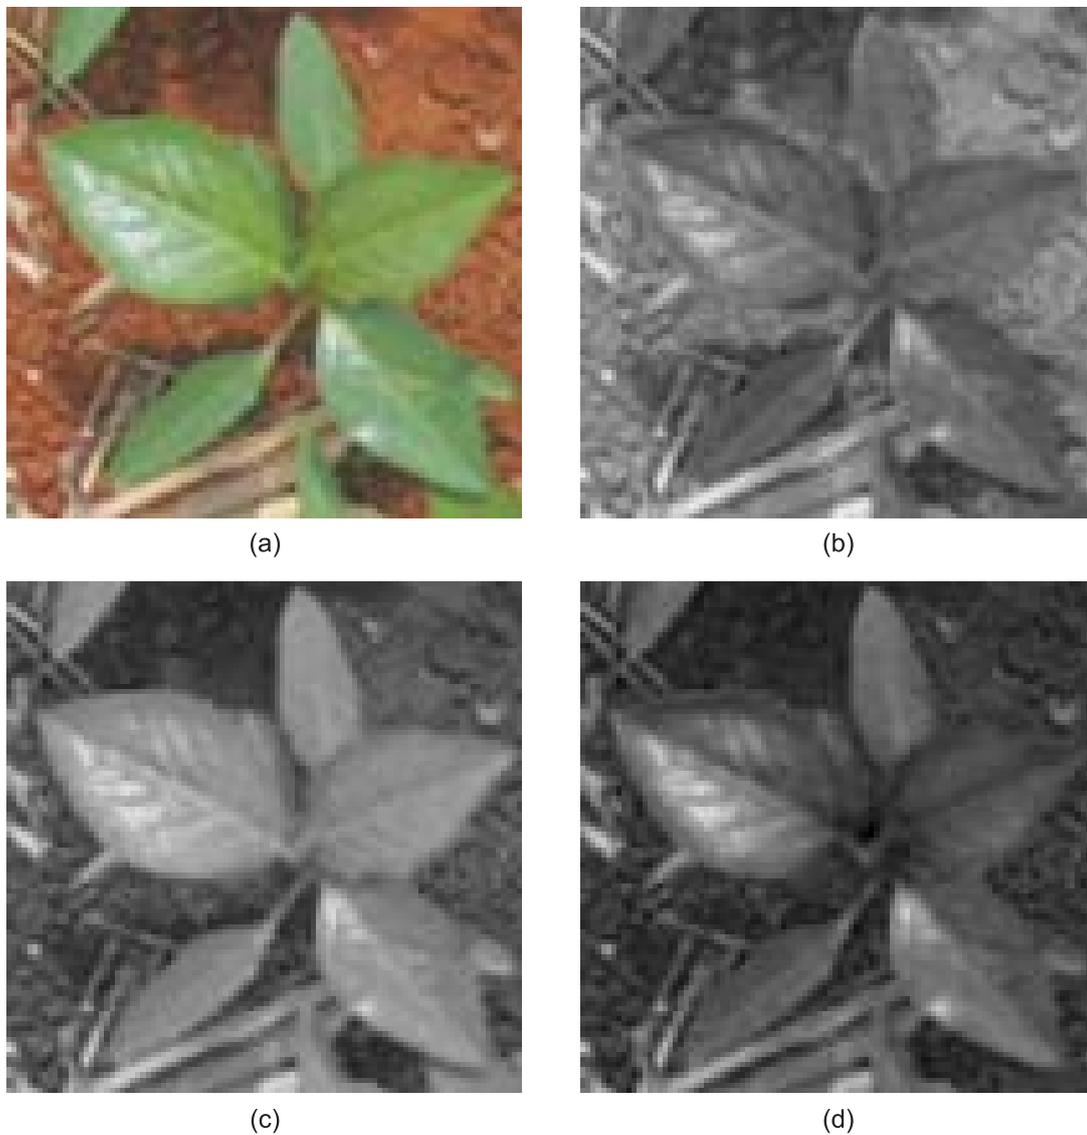


Figura 35: Exemplo de um agrupamento de folhas largas na primeira fase do pré-processamento: (a) imagem original; (b) representação da componente R da imagem original, em escala de vermelho; (c) representação da componente G da imagem original, em escala de verde; (d) representação da componente B da imagem original, em escala de azul. Nas representações das componentes, dadas as escalas, quanto mais claro, mais próximo da cor que a escala representa, e quanto mais escuro, mais próximo do preto, ausência da cor.

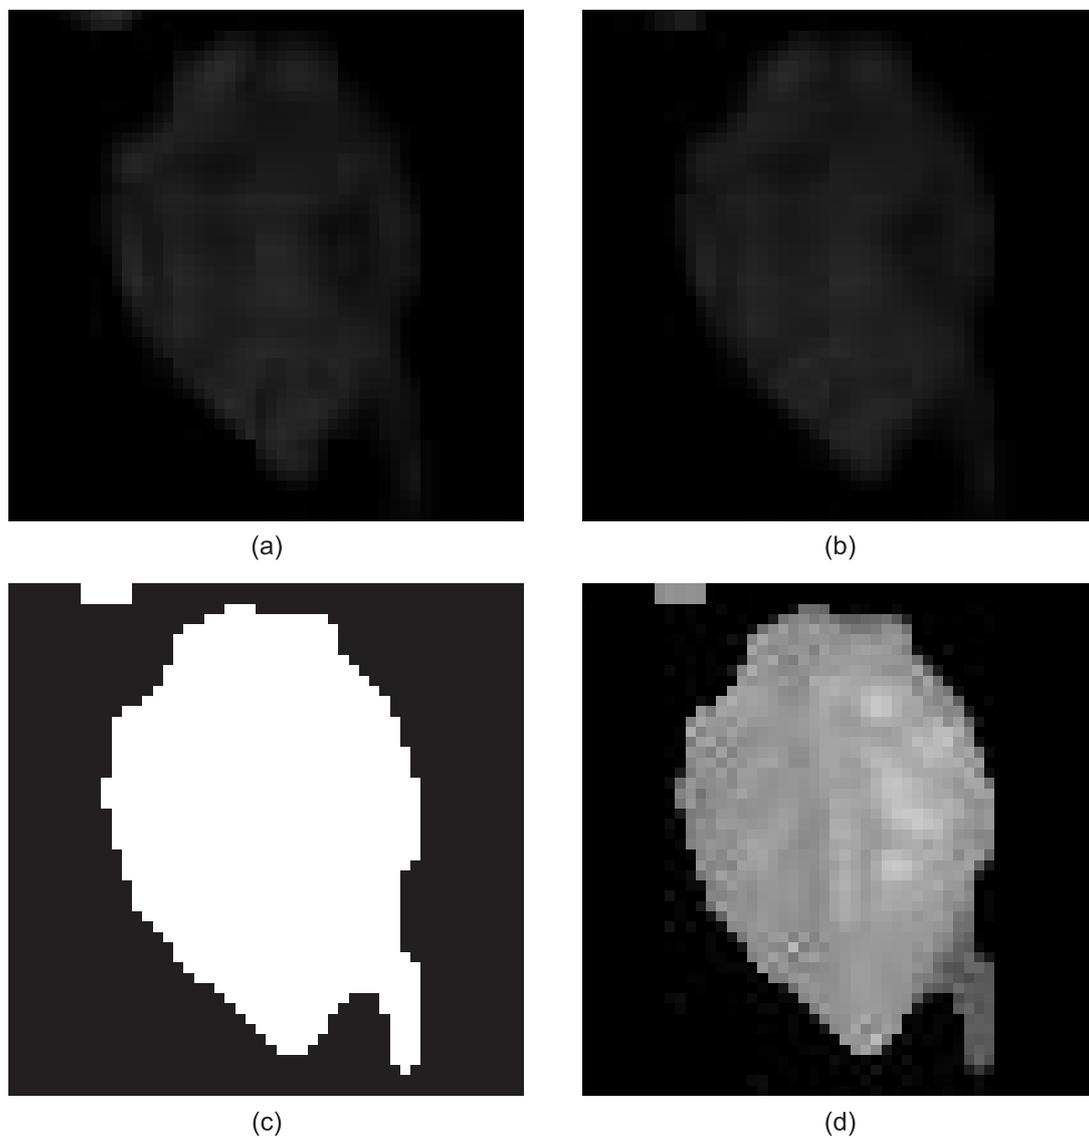


Figura 36: Exemplo de uma imagem de folha larga nas últimas fases do pré-processamento: (a) resultado da subtração da componente R da componente G; (b) resultado da aplicação do filtro de mediana na imagem a; (c) limiarização da imagem b com limiar igual a média dos níveis de cinza; (d) resultado do pré-processamento, onde o fundo é preto e a folha representada com sua informação original em tons de cinza.

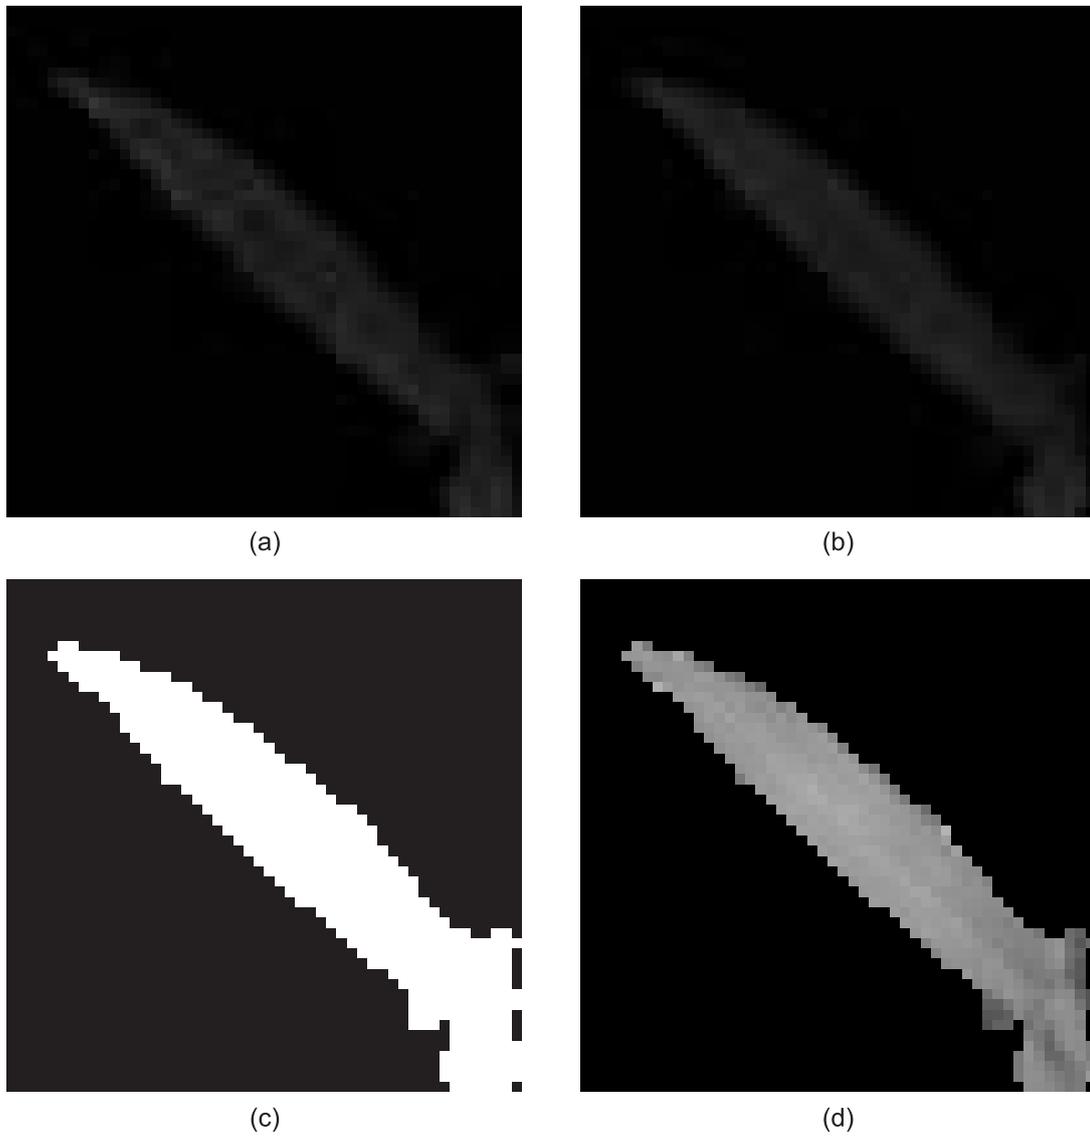


Figura 37: Exemplo de uma imagem de folha estreita nas últimas fases do pré-processamento: (a) resultado da subtração da componente R da componente G; (b) resultado da aplicação do filtro de mediana na imagem a; (c) limiarização da imagem b com limiar igual a média dos níveis de cinza; (d) resultado do pré-processamento, onde o fundo é preto e a folha representada com sua informação original em tons de cinza.

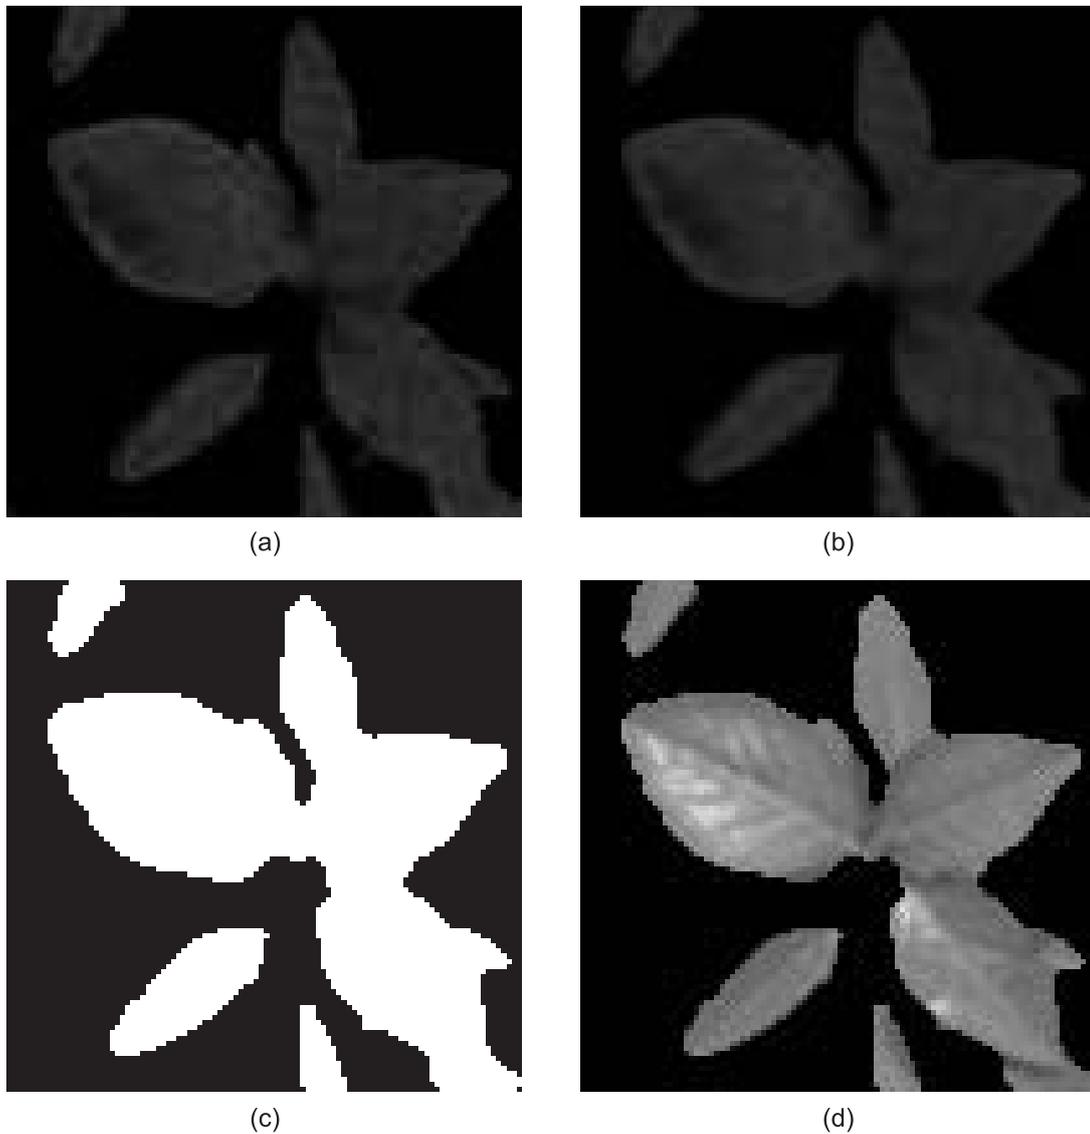


Figura 38: Exemplo de um agrupamento de folhas largas nas últimas fases do pré-processamento: (a) resultado da subtração da componente R da componente G; (b) resultado da aplicação do filtro de mediana na imagem a; (c) limiarização da imagem b com limiar igual a média dos níveis de cinza; (d) resultado do pré-processamento, onde o fundo é preto e a folha representada com sua informação original em tons de cinza.

5.1.3 Segmentação Baseada em Textura

O primeiro passo do Algoritmo 3 é a obtenção do mapa de textura, o qual calcula para cada janelamento, o seu respectivo valor de textura. Foram testadas diferentes medidas, buscando encontrar aquela que apresentasse o menor erro na identificação das formas. As medidas testadas foram o contraste, segundo momento angular (SMA) e entropia, sendo todas estatísticas e obtidas a partir da matriz de co-ocorrência. Para a avaliação do erro de identificação foi utilizado o desvio padrão dos valores de textura encontrados para cada imagem geométrica, considerando as 20 tonalidades diferentes.

As figuras 39, 40 e 41 apresentam os gráficos criados para a análise das três medidas de textura consideradas.

No teste do contraste houve uma medida constante, que não apresentou variação alguma nas diferentes intensidades utilizadas, esta ocorrência foi associada ao posicionamento do objeto e ao tamanho do janelamento, sendo o objeto um quadrado, cujo *pixel* inicial estava localizado no ponto (10,10) e seu tamanho era de 30×30 *pixels*.

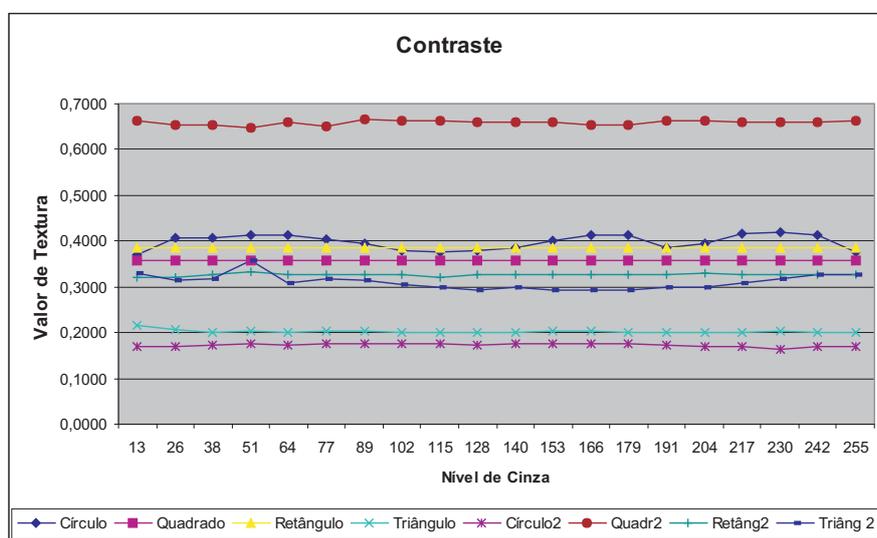


Figura 39: Comparação dos valores de textura utilizando a medida de contraste.

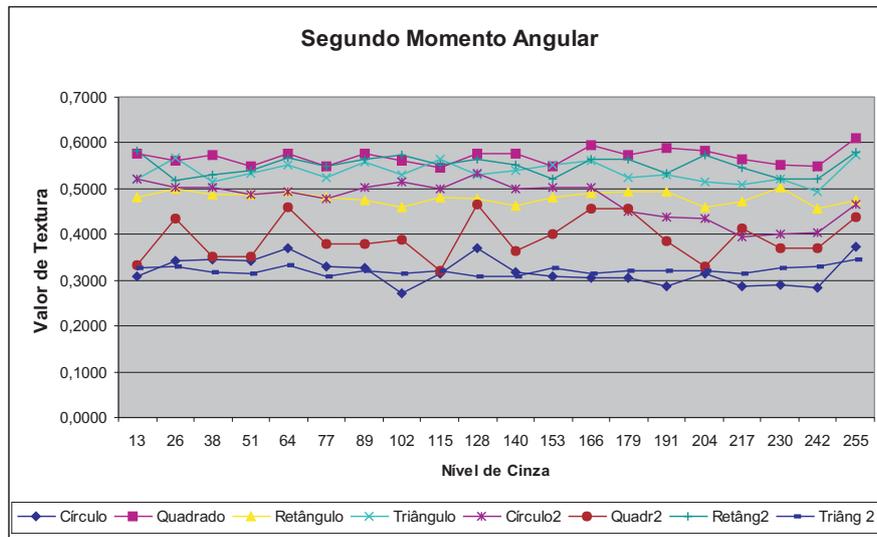


Figura 40: Comparação dos valores de textura utilizando a medida de SMA.

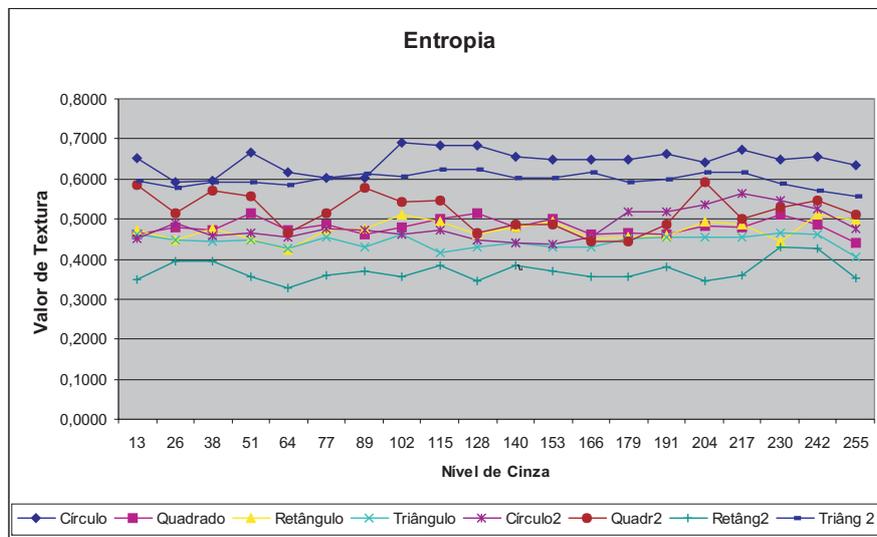


Figura 41: Comparação dos valores de textura utilizando a medida de entropia.

A Tabela 2 apresenta os valores de desvio padrão para cada uma das medidas de texturas consideradas. Analisando a tabela, percebe-se que as medidas de SMA e entropia não apresentaram grandes variações no desvio padrão, já a medida de contraste se diferenciou bem das demais. Em apenas um dos testes, Triâng2, o SMA se diferenciou

das demais, ficando com valor bem inferior enquanto o contraste e a entropia ficaram com valores mais próximos.

Tabela 2: Valores de desvio padrão das medidas de textura encontrados para cada uma das formas consideradas.

Forma	Desvio Padrão		
	Contraste	SMA	Entropia
Círculo	0,0154	0,0290	0,0285
Quadrado	$1,7 \cdot 10^{-16}$	0,0174	0,0193
Retângulo	$1,7 \cdot 10^{-16}$	0,0134	0,0229
Triângulo	0,0038	0,0213	0,0165
Círculo2	0,0038	0,0404	0,0371
Quadr2	0,0045	0,0448	0,0446
Retâng2	0,0025	0,0207	0,0259
Triâng2	0,0156	0,0088	0,0170

Com base nas análises feitas, observou-se que o contraste foi a medida de textura mais constante e discriminativa em cada uma das formas geométricas consideradas na análise dos gráficos, e também foi a medida que apresentou um valor de desvio padrão menor, na maioria dos casos. Sendo assim, o contraste foi selecionado para ser aplicado ao método desenvolvido.

O segundo passo do Algoritmo 3 é dedicado a se encontrar as regiões de interesse na imagem, cujas etapas estão ilustradas na Figura 42. A primeira etapa do algoritmo é a aplicação do operador Laplaciano para que sejam encontradas as bordas da imagem. Como pode ser observado na Figura 42(b), o operador Laplaciano frequentemente mantém o contorno aberto, não isolando corretamente as regiões. Para que as regiões fossem fechadas, após o laplaciano, foi feita uma dilatação nas bordas, utilizando uma máscara 3×3 e posteriormente aplicada uma erosão, com máscara 2×2 . A imagem resultante desta etapa para o exemplo da Figura 42 encontra-se na letra (c). Depois foi feita a subtração da imagem das bordas dilatadas na imagem limiarizada, encontrada no pré-processamento. O resultado dessa subtração é analisado para excluir as regiões muito pequenas, onde a área e o perímetro têm ou o mesmo valor ou valores muito próximos. A Figura 42(d) apresenta a imagem com as regiões encontradas pela subtração das bordas da imagem da limiarização da imagem original.

O terceiro passo do algoritmo é a união das imagens dos passos anteriores, mapa de textura e regiões de interesse, calculando para cada região seu respectivo valor médio

de textura. As figuras 43, 44, 45, 46 e 47 ilustram esse processo em uma imagem de forma geométrica simples, composta de dois objetos, com sobreposição, de uma folha e agrupamentos de folhas.

A última etapa do algoritmo de segmentação é obter os valores de textura da região de interesse para selecionar apenas ela, excluindo as outras regiões.

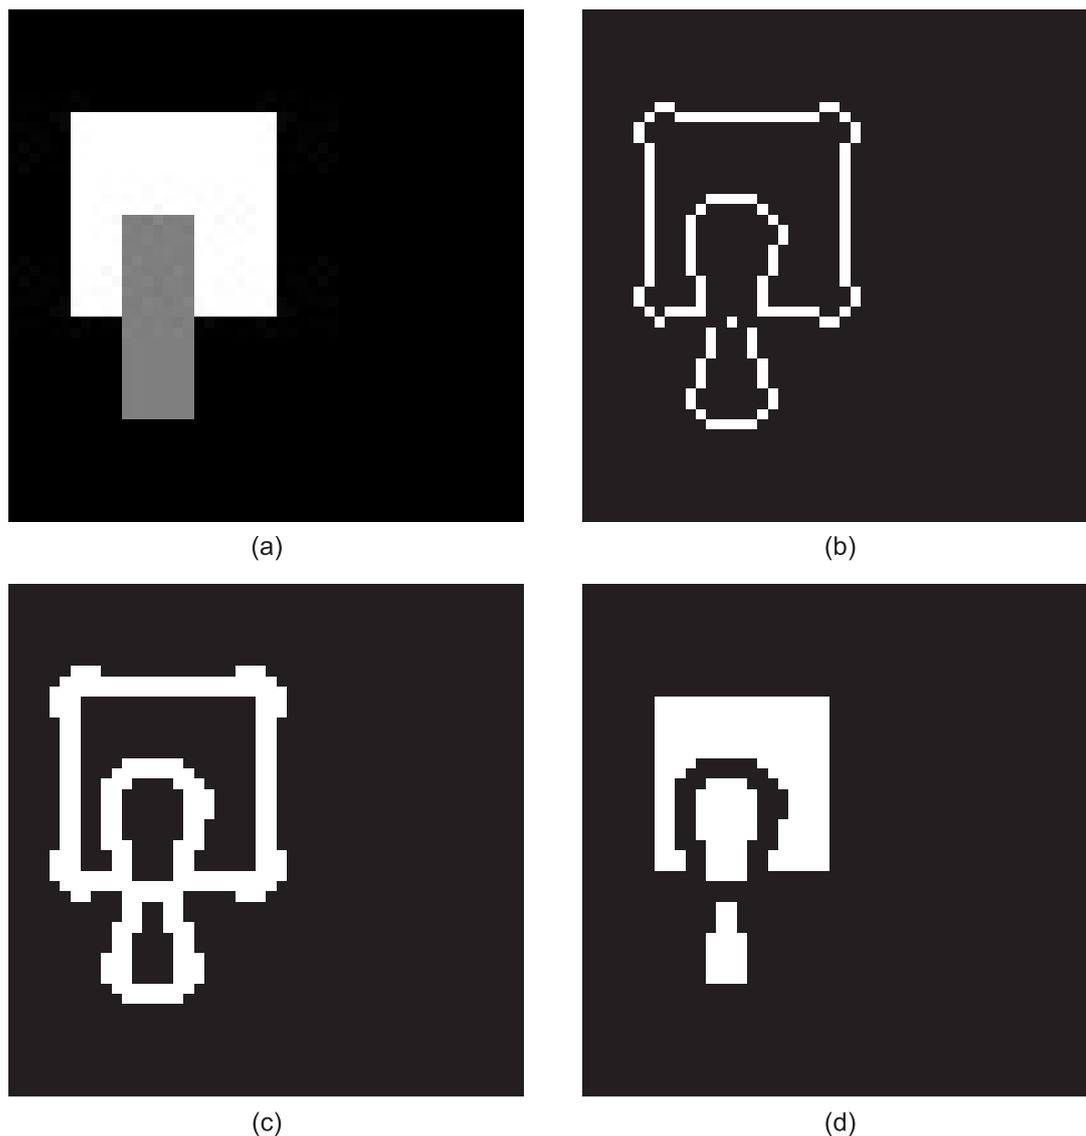


Figura 42: Imagens do processo de formação das regiões de interesse: (a) imagem original; (b) bordas da imagem original obtidas pelo operador laplaciano; (c) bordas dilatadas, com máscara 3×3 , e erodidas, com máscara 2×2 , em seguida; (d) imagem resultante da subtração das bordas, letra b, da imagem da limiarização da imagem original.

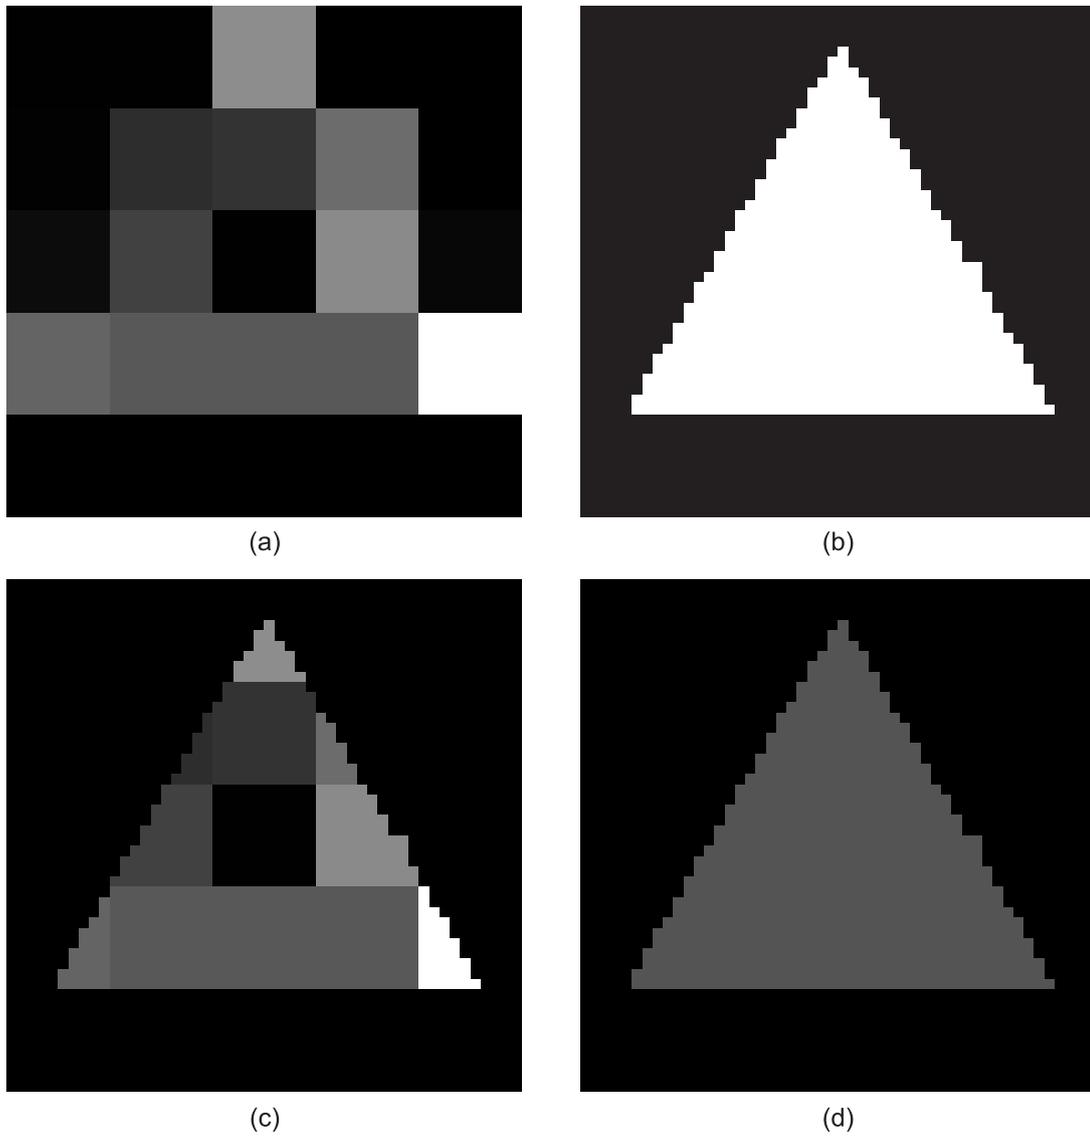


Figura 43: Processo de segmentação por textura de uma forma geométrica: (a) mapa de textura da imagem; (b) região encontrada na imagem; (c) união do mapa de textura com a região encontrada; (d) mapa de textura final, no qual a região é representada por seu valor de textura médio.

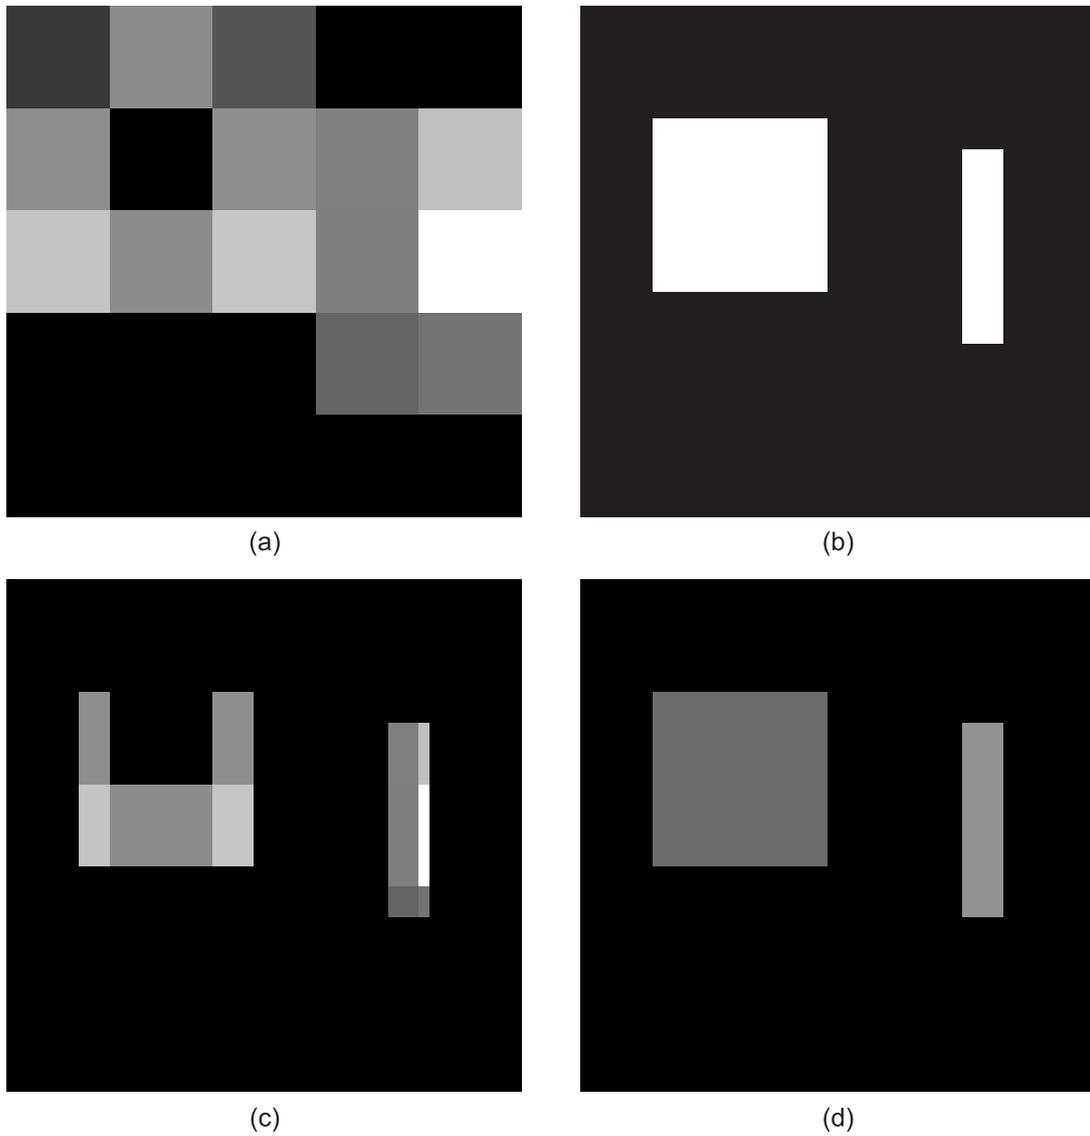


Figura 44: Processo de segmentação por textura de duas formas geométricas: (a) mapa de textura da imagem; (b) regiões encontradas na imagem; (c) união do mapa de textura com as regiões encontradas; (d) mapa de textura final, cujas regiões são representadas por seus valores de textura médio.

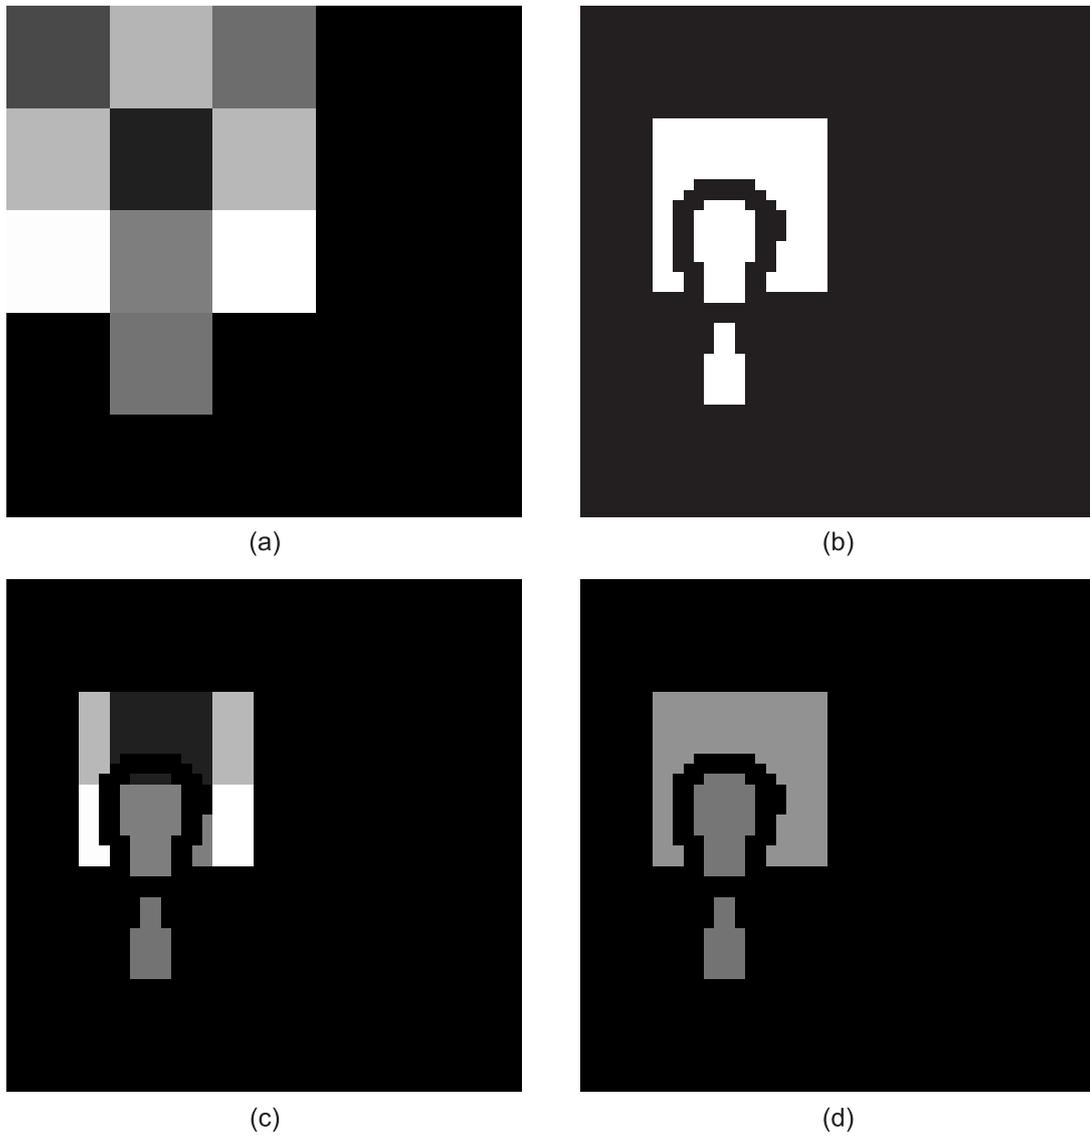


Figura 45: Processo de segmentação por textura de duas formas geométricas sobrepostas: (a) mapa de textura da imagem; (b) regiões encontradas na imagem; (c) união do mapa de textura com as regiões encontradas; (d) mapa de textura final, cujas regiões são representadas por seus valores de textura médio.

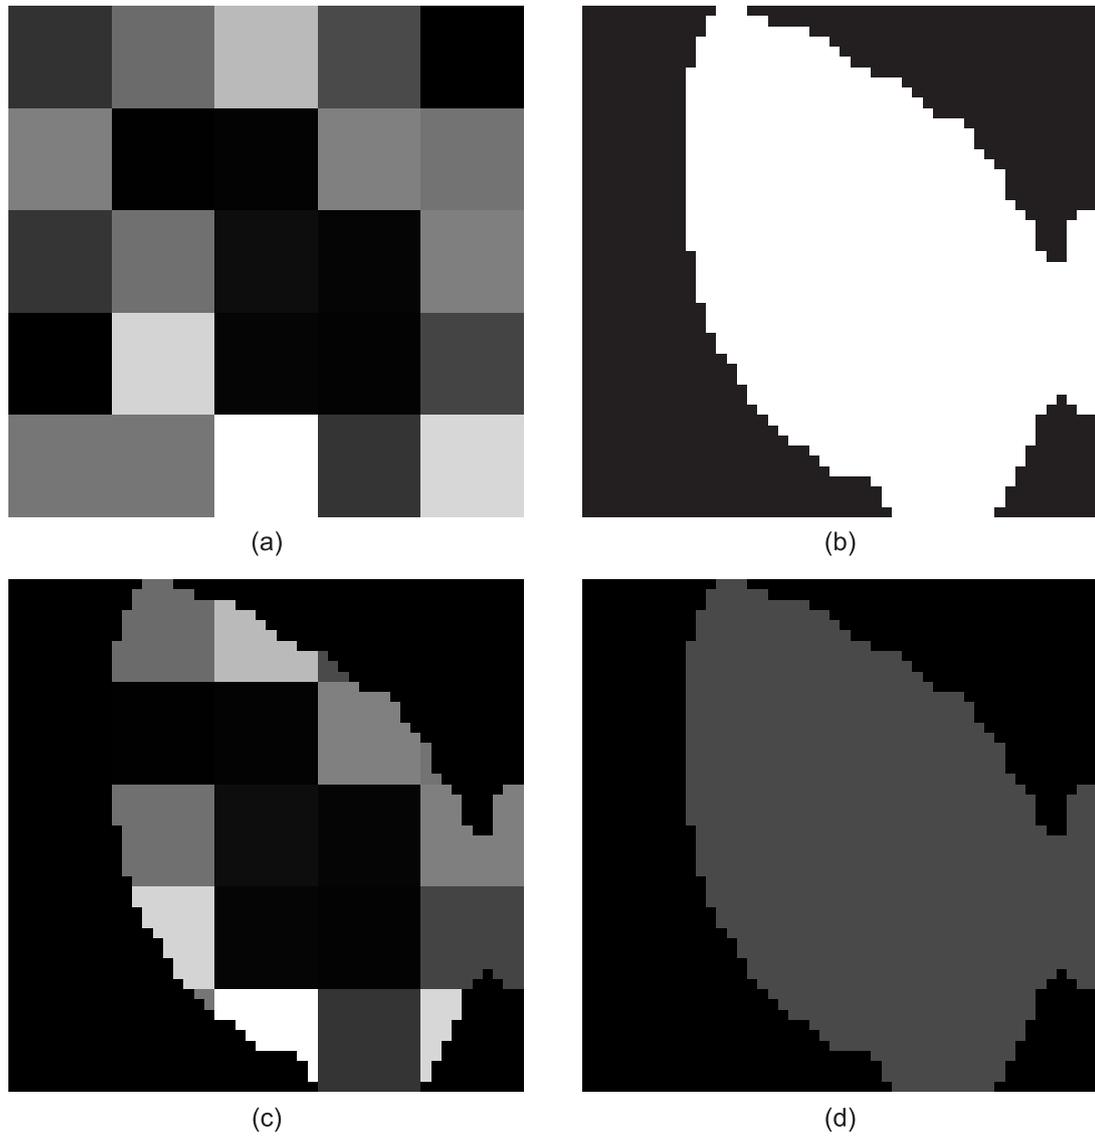


Figura 46: Processo de segmentação por textura de uma folha larga: (a) mapa de textura da imagem pré-processada; (b) região encontrada na imagem; (c) união do mapa de textura com a região encontrada; (d) mapa de textura final, cujas regiões são representadas por seus valores de textura médio.

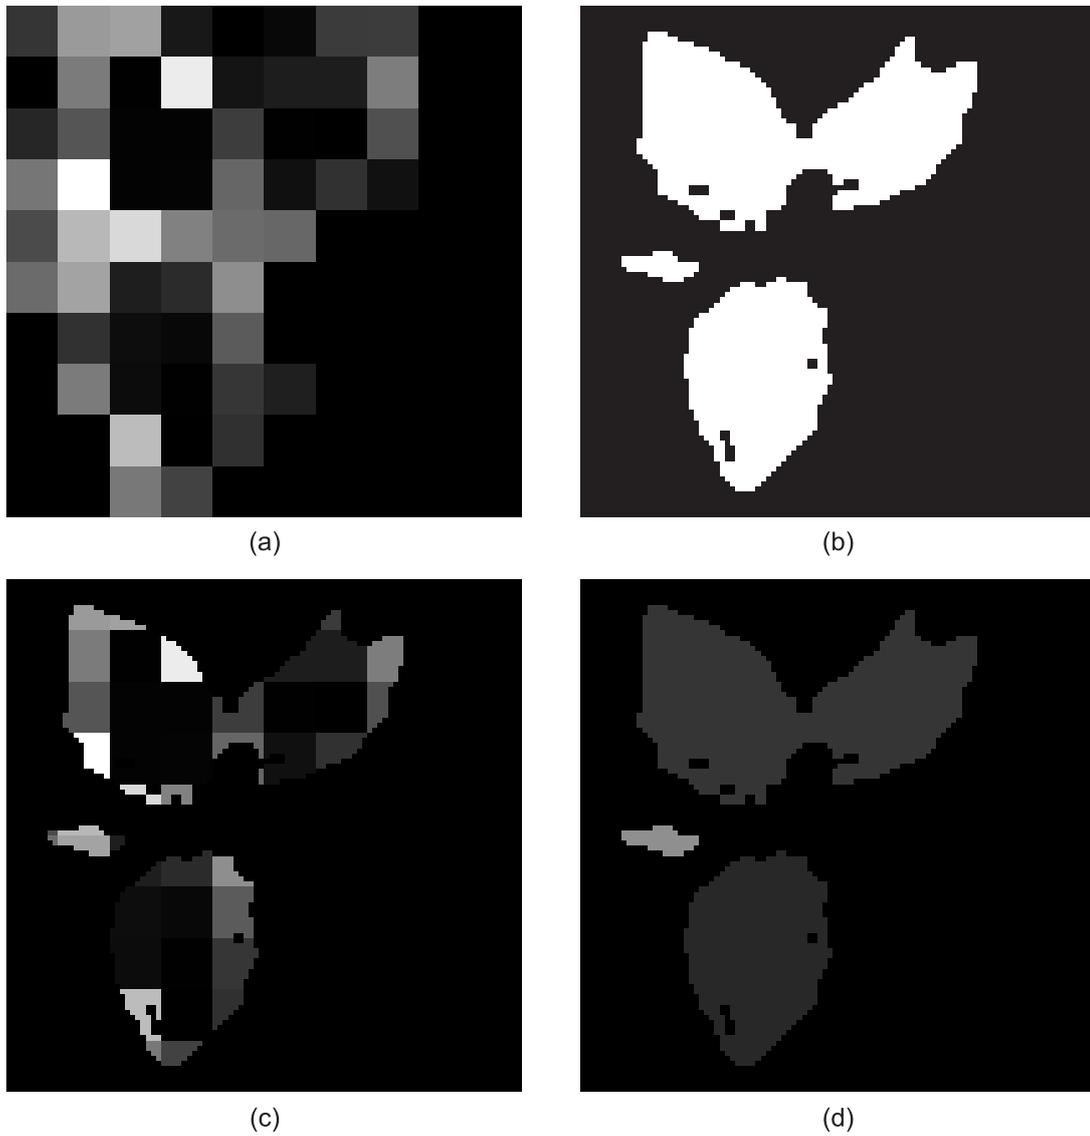


Figura 47: Processo de segmentação por textura de um agrupamento de folhas largas: (a) mapa de textura da imagem pré-processada; (b) regiões encontradas na imagem; (c) união do mapa de textura com as regiões encontradas; (d) mapa de textura final, cujas regiões são representadas por seus valores de textura médio.

Como pode ser observado no exemplo da Figura 42, a dilatação das bordas ocasiona uma perda de área da região de interesse. Esta perda foi estudada com maior atenção para que fosse encontrada uma forma de corrigir o valor da área das regiões a fim de obter uma identificação mais próxima do real. Como, com a dilatação das bordas, o contorno passa de um para, em média, três *pixels*, foi inferido que para se recuperar a área perdida deve-se dividir a área do contorno dilatado por três, ou seja:

$$Correcao_{bordas} \cong \frac{Area\ do\ contorno\ dilatado}{3} \quad (46)$$

Para se obter um valor normalizado desta correção deve-se dividir o valor encontrado pelo total de *pixels* na imagem.

5.1.4 Descritores e Reconhecimento de Plantas Invasoras

O passo mais importante para o reconhecimento das folhas é a escolha de descritores que permitam a correta descrição e diferenciação dos padrões que se deseja encontrar.

O primeiro passo é encontrar o descritor, ou conjunto de descritores, que melhor representa, ou descreve, cada um dos padrões. Para isto foram considerados alguns descritores, sendo eles, redondez, densidade, retangularidade e alongação. Para cada imagem de folhas individuais, foram extraídos os valores de cada um dos descritores e criados dois gráficos, um para comparar os resultados obtidos para folhas largas e outro para folhas estreitas. Os gráficos são ilustrados na Figura 48.

Pelos gráficos pode-se concluir que a retangularidade não é uma boa medida para o reconhecimento das formas das folhas, pois para ambos os tipos de folhas, seus respectivos valores dos descritores ficaram na mesma faixa de valores, entre 1,3 e 2,4, não permitindo desta forma a distinção entre os dois tipos de formas.

Para uma melhor análise dos demais descritores, foram criados mais três gráficos, ilustrados na Figura 49, sendo um para cada descritor, alongação, redondez e densidade, respectivamente. Pelos gráficos, observa-se que a redondez e densidade apresentam as mesmas curvas, isto acontece pois ambas as medidas são derivadas dos valores de área e perímetro do objeto. Analisando os descritores, nota-se que a alongação apresentou maior diferenciação entre as formas, pois em poucos casos os valores se cruzaram.

Além das imagens de folhas isoladas, também foi analisado o desempenho dos descritores nas imagens com agrupamentos de folhas, e para isto foram criados dois gráficos, sendo um para folhas largas e outro para folhas estreitas. Ambos os gráficos consideram os descritores de redondez, alongação e solidez. Pela análise dos mesmos, observou-se a relevância do descritor de solidez para estas situações, que ocorrem com certa frequência nas imagens adquiridas. A relevância foi observada pois os agrupamentos de folhas estreitas apresentaram valor mínimo próximo de 0,4, e a média deste conjunto foi de 0,66, enquanto os agrupamentos de folhas estreitas apresentaram valor mínimo próximo de 0,6 e média de 0,78. Os gráficos estão ilustrados na Figura 50.

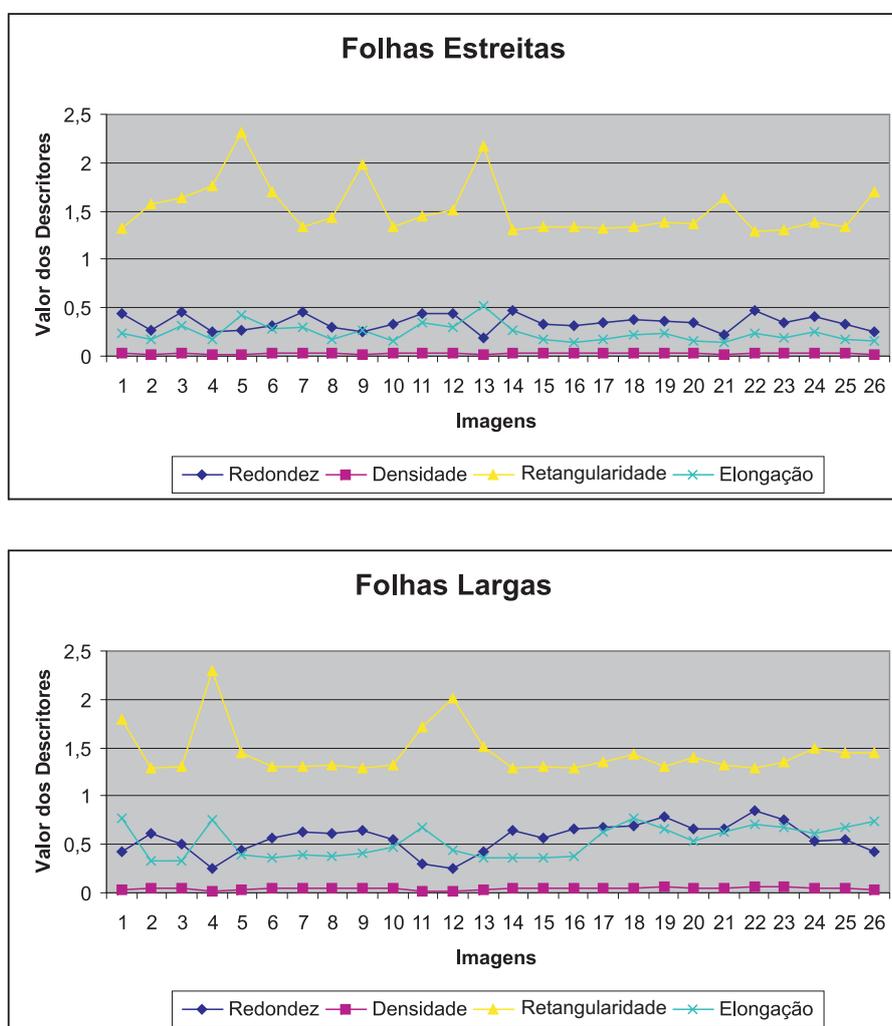


Figura 48: Comparação dos descritores nas folhas largas e estreitas.

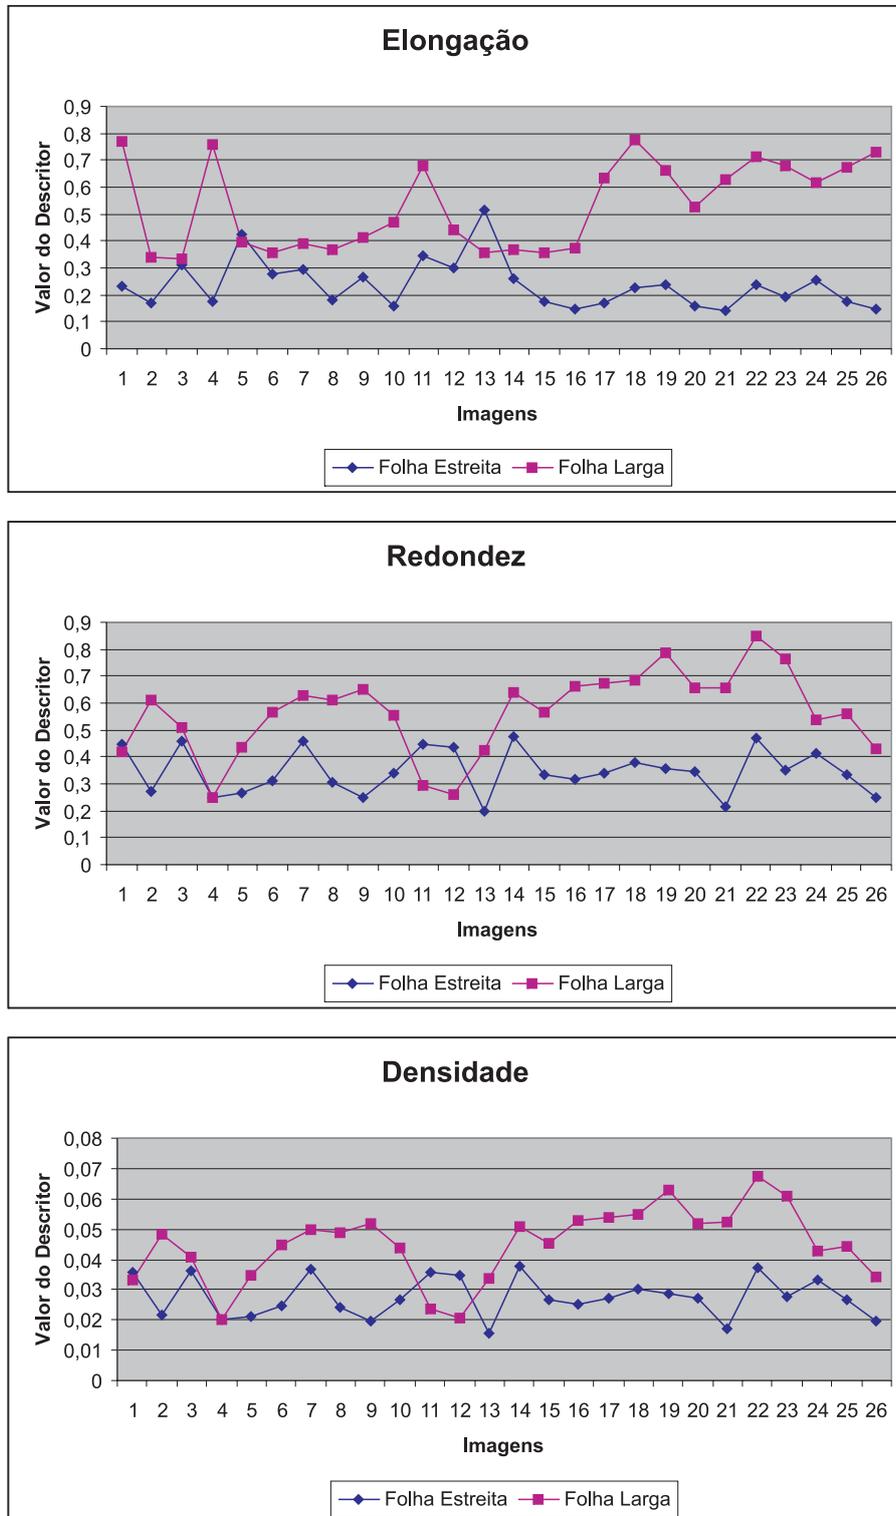


Figura 49: Comparação dos valores dos descritores de alongação, redondez e densidade.

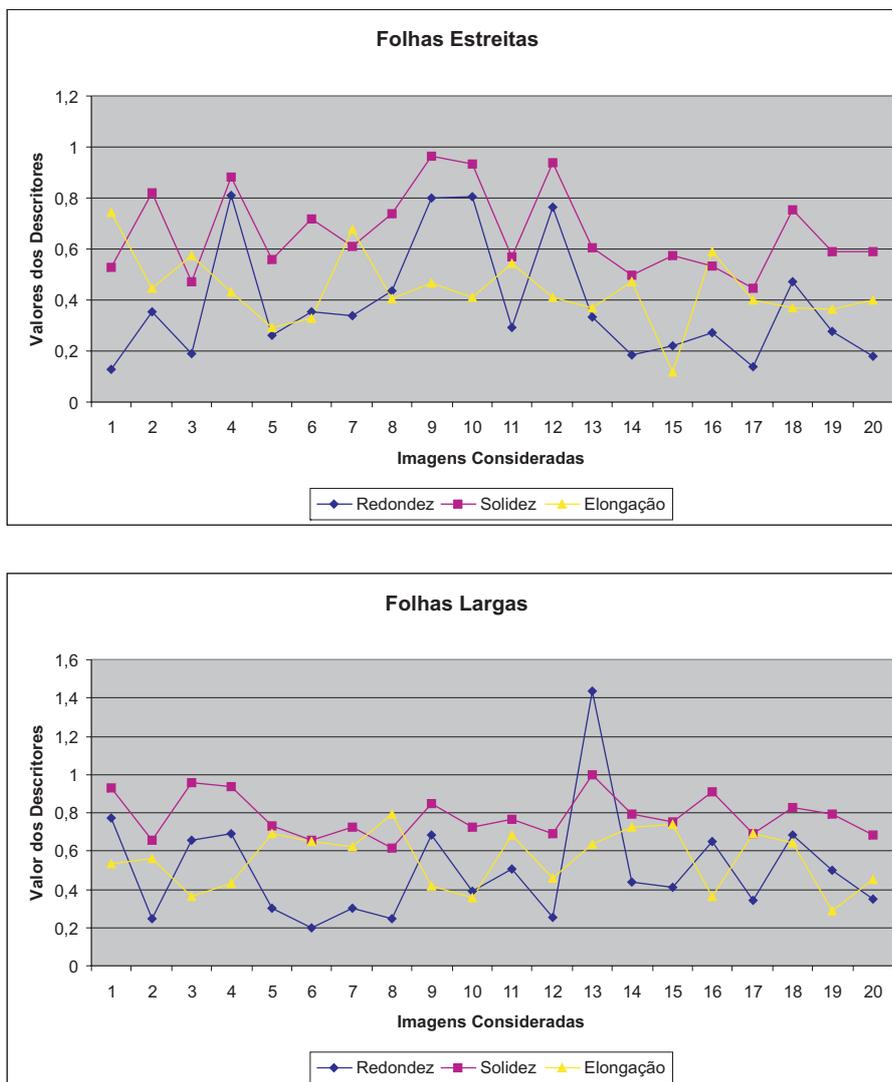


Figura 50: Comparação dos descritores nos agrupamentos de folhas largas e estreitas.

Análise do erro devido a sobreposição

Sabe-se que para o domínio do problema considerado, a sobreposição de regiões de interesse é um fator frequente e que se não for analisado, pode prejudicar o desempenho do sistema de reconhecimento. Existem quatro possíveis tipos de sobreposição para o problema em questão, sendo eles, sobreposição de folhas largas com folhas estreitas, folhas estreitas com folhas largas, folhas largas com folhas largas e folhas estreitas com folhas estreitas. Para a análise dessas situações foram geradas 12 imagens utilizando padrões

geométricos, onde a folha larga foi representada por um quadrado e a folha estreita representada por um retângulo. Para cada tipo, foram criadas as seguintes situações, 33% de sobreposição, 66% de sobreposição e 99% de sobreposição. As figuras de 51 a 62 ilustram as imagens criadas para o teste, com suas respectivas bordas.

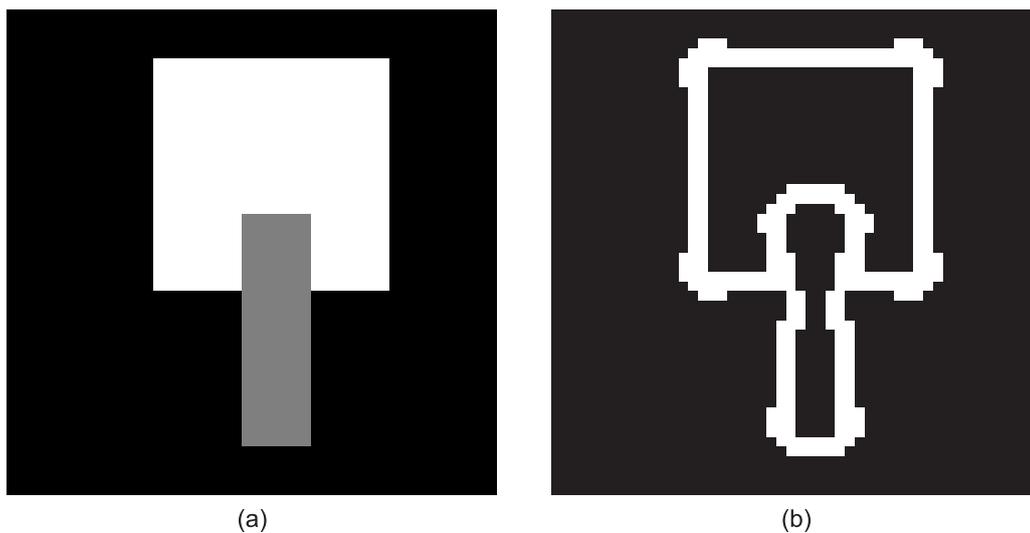


Figura 51: Sobreposição do retângulo sobre quadrado (33%): (a) imagem gerada; (b) bordas dilatadas da imagem.

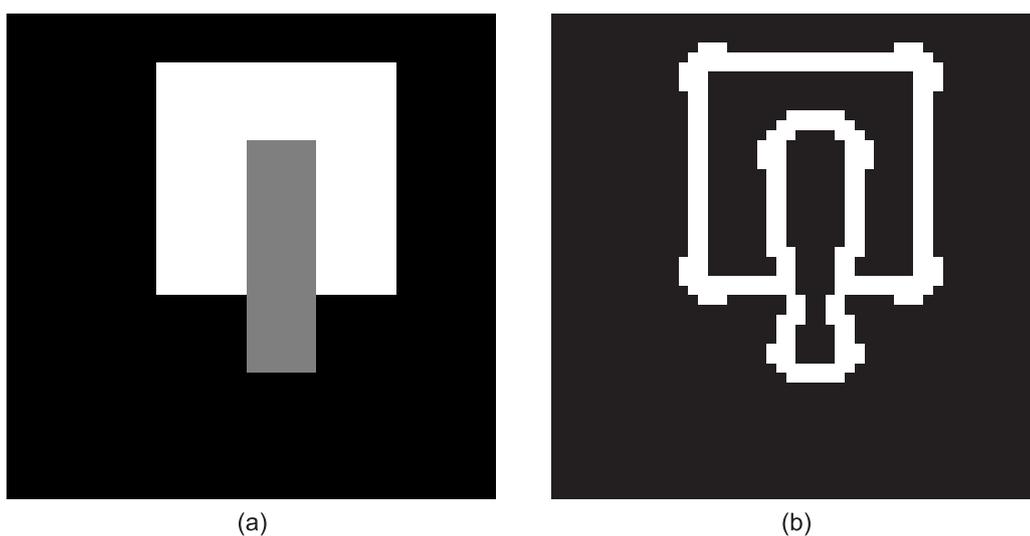


Figura 52: Sobreposição do retângulo sobre quadrado (66%): (a) imagem gerada; (b) bordas dilatadas da imagem.

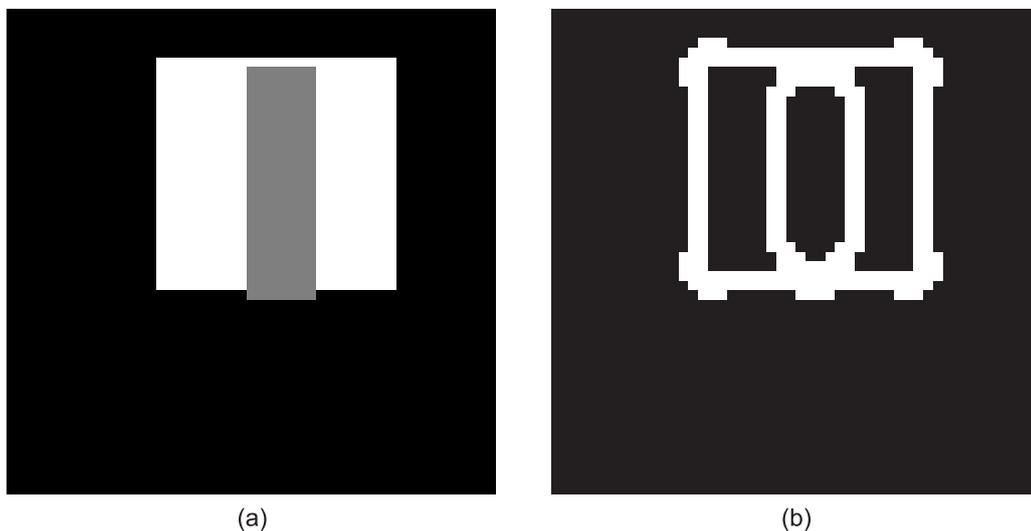


Figura 53: Sobreposição do retângulo sobre quadrado (99%): (a) imagem gerada; (b) bordas dilatadas da imagem.

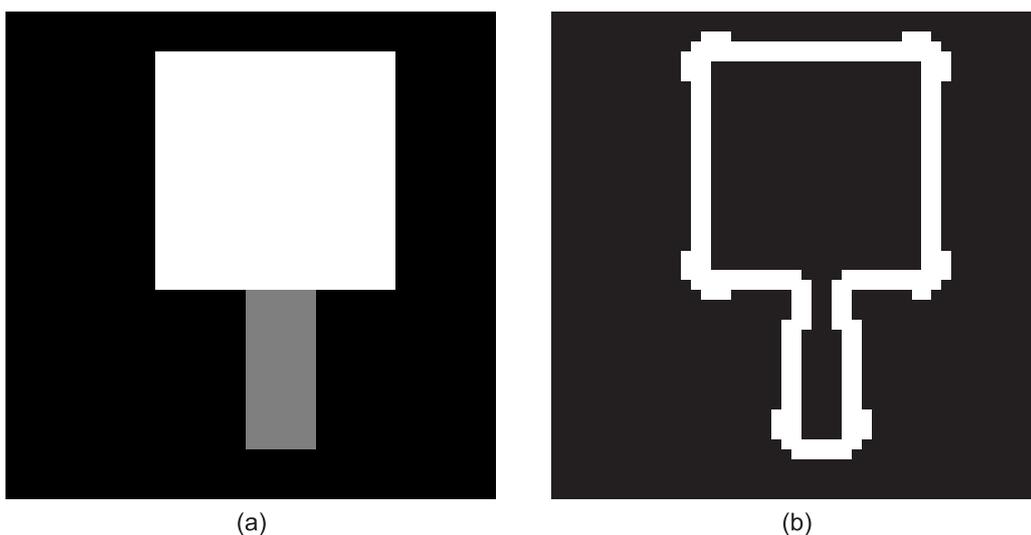


Figura 54: Sobreposição do quadrado sobre retângulo (33%): (a) imagem gerada; (b) bordas dilatadas da imagem.

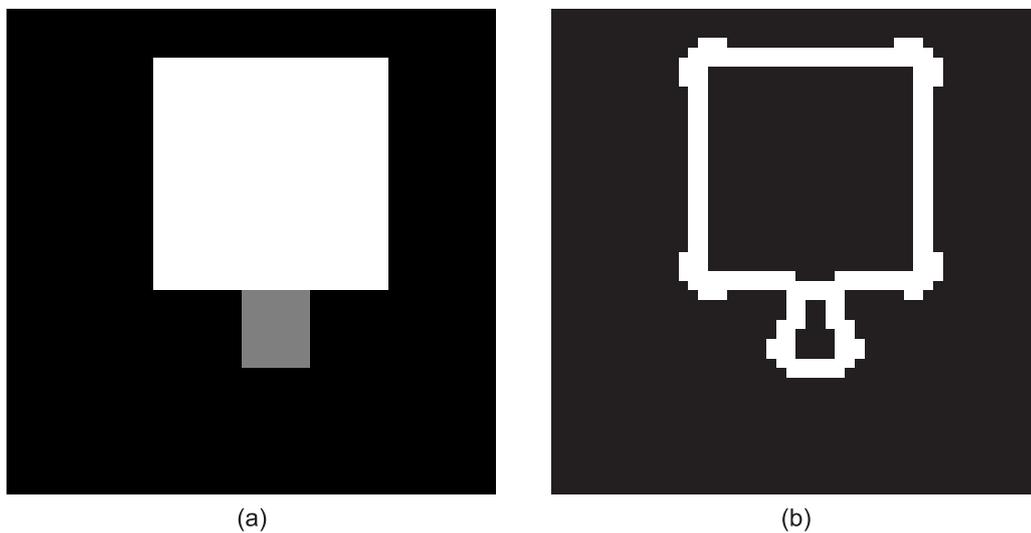


Figura 55: Sobreposição do quadrado sobre retângulo (66%): (a) imagem gerada; (b) bordas dilatadas da imagem.

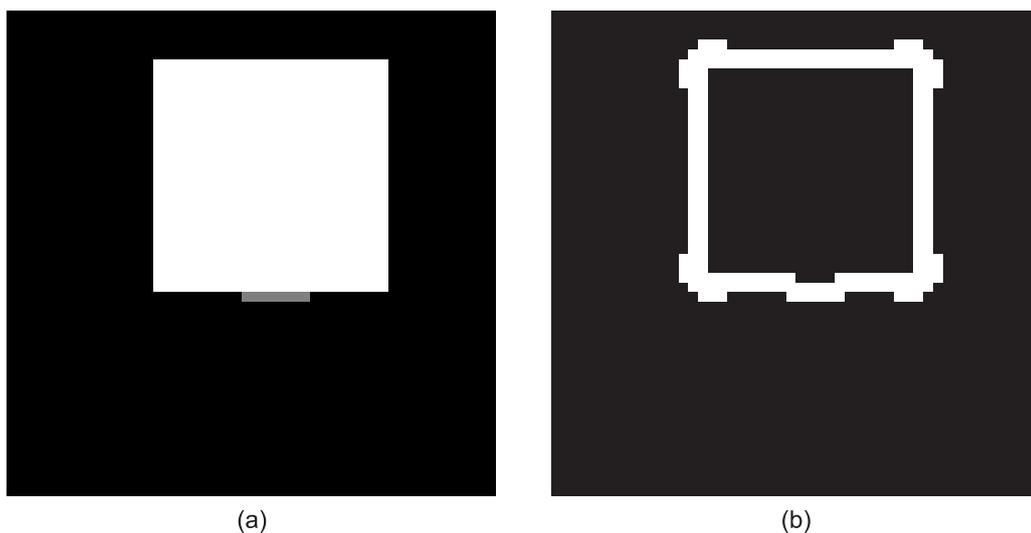


Figura 56: Sobreposição do quadrado sobre retângulo (99%): (a) imagem gerada; (b) bordas dilatadas da imagem.

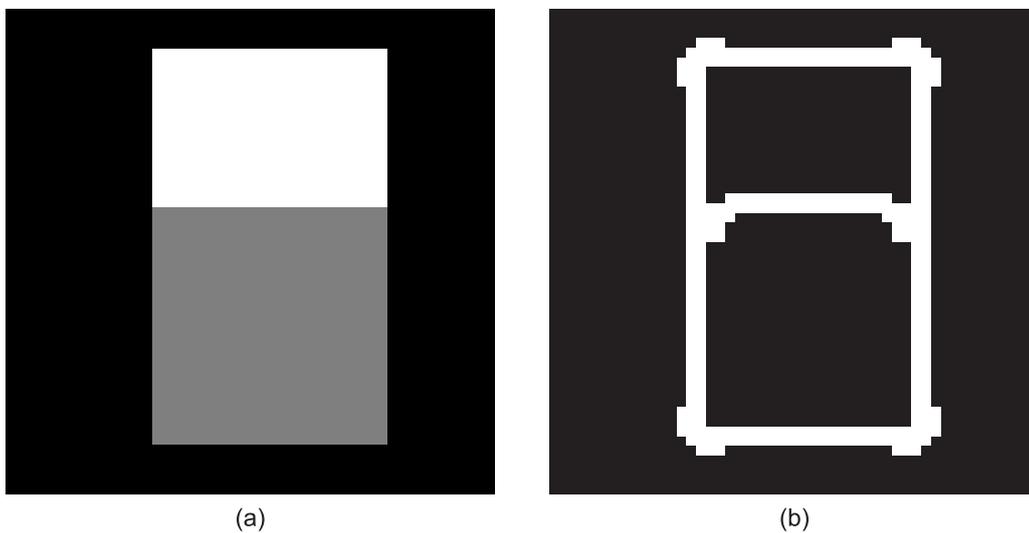


Figura 57: Sobreposição de quadrados (33%): (a) imagem gerada; (b) bordas dilatadas da imagem.

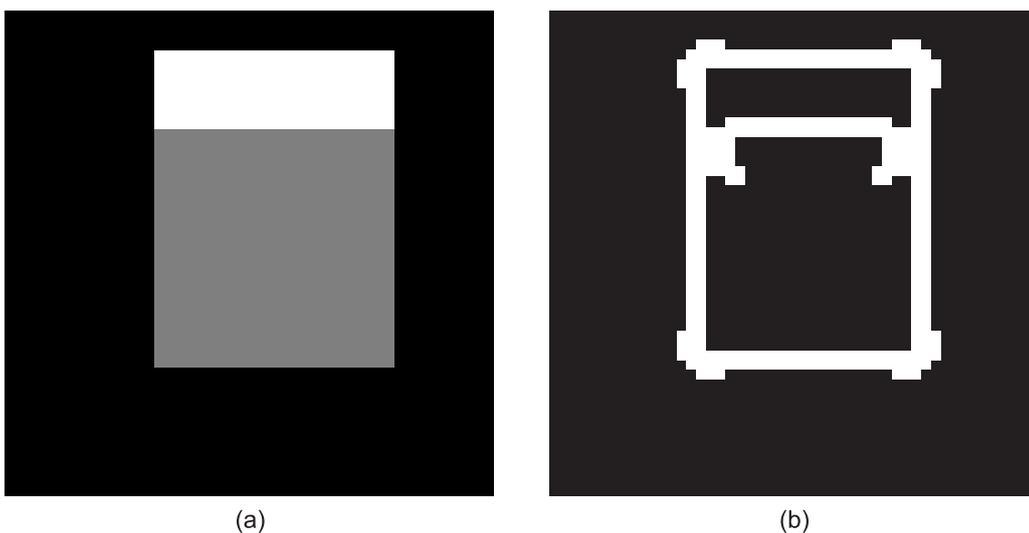


Figura 58: Sobreposição de quadrados (66%): (a) imagem gerada; (b) bordas dilatadas da imagem.

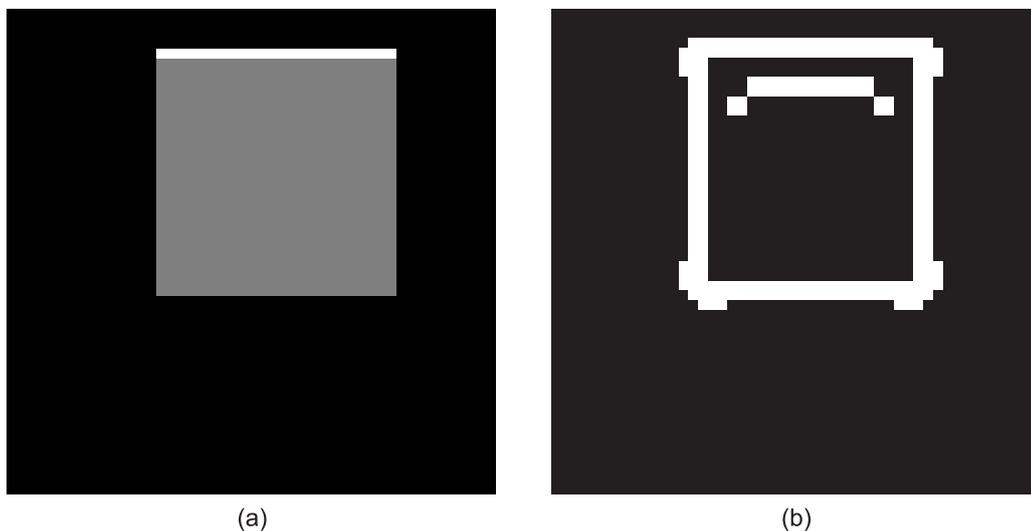


Figura 59: Sobreposição de quadrados (99%): (a) imagem gerada; (b) bordas dilatadas da imagem.

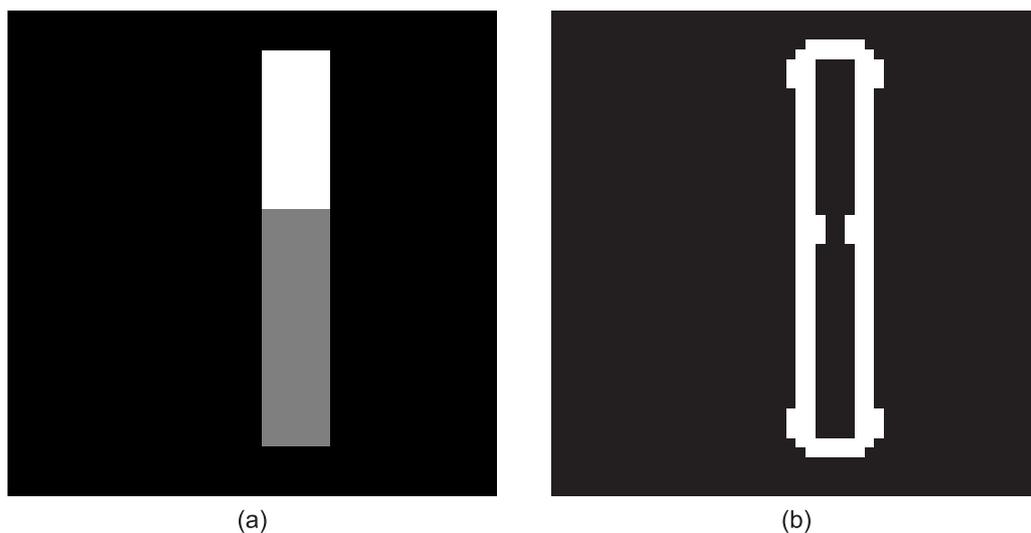


Figura 60: Sobreposição de retângulos (33%): (a) imagem gerada; (b) bordas dilatadas da imagem.

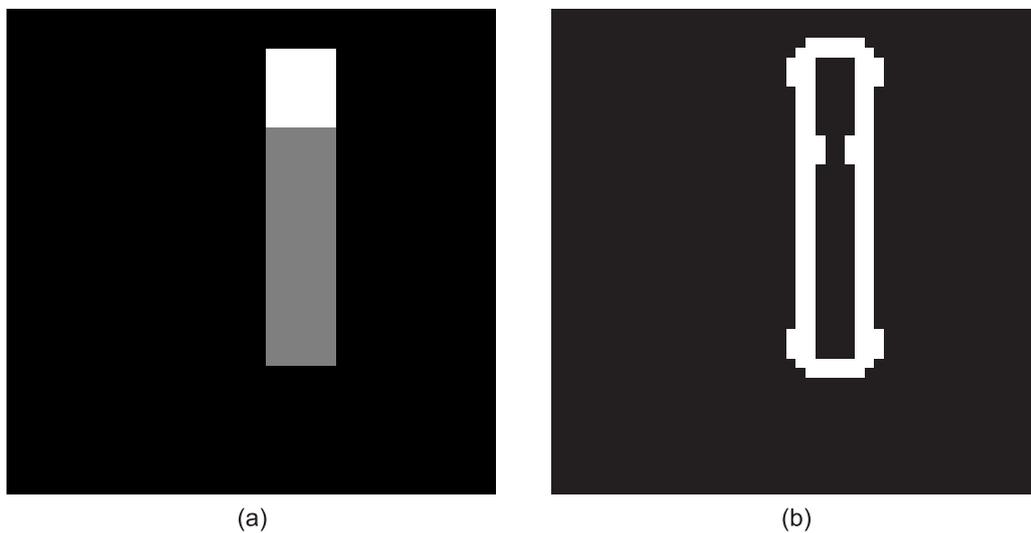


Figura 61: Sobreposição de retângulos (66%): (a) imagem gerada; (b) bordas dilatadas da imagem.

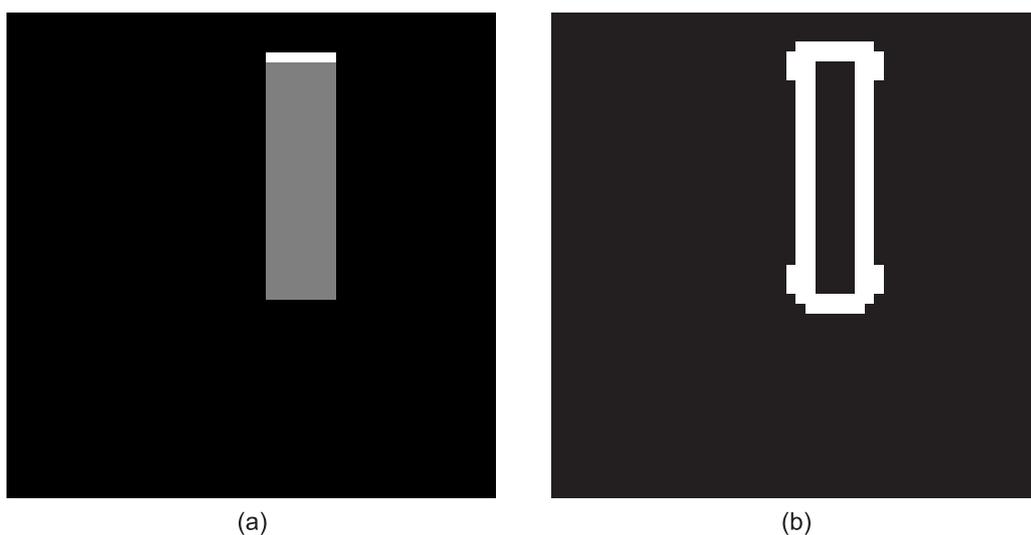


Figura 62: Sobreposição de retângulos (99%): (a) imagem gerada; (b) bordas dilatadas da imagem.

Para a correção do erro devido a sobreposição nas situações consideradas (1, 2, 3 e 4)¹⁷ foi inferida uma fórmula de correção, dada pela soma dos percentuais de erros médios de identificação de cada forma geométrica, sendo representada por:

$$Correcao_{sobreposicao} \cong \frac{(x_1\% + y_1\%) + (x_2\% + y_2\%) + x_3\% + y_4\%}{4} \quad (47)$$

onde $x_n\%$ representa o quadrado na situação de sobreposição n e $y_m\%$ representa o retângulo na situação de sobreposição m .

A análise do erro foi feita por meio do percentual de erro de indentificação de cada uma das formas nas dadas situações de sobreposição, considerando a visão natural e a visão computacional. As Tabelas 3, 4 e 5 apresentam os valores percentuais de área para os padrões pela visão natural, o percentual reconhecido pelo método computacional e os erros de identificação, considerando os descritores de redondez, alongação e solidez, respectivamente.

Tabela 3: Tabela de reconhecimento dos padrões, com os respectivos erros, para o descritor de redondez.

Imagem	% Área Q	% Área R	% Rec. Q	% Rec. R	Erro Q	Erro R
retQuad33	20,80	6,72	0,00	17,96	20,80	11,24
retQuad66	18,56	6,72	0,00	15,48	18,56	8,76
retQuad99	16,60	6,72	4,00	9,56	12,60	2,84
quadRet33	23,04	4,48	0,00	19,96	23,04	15,48
quadRet66	23,04	2,24	18,52	0,00	4,52	2,24
quadRet99	23,04	0,28	17,80	0,00	5,24	0,28
quad33	38,40	0,00	29,00	0,00	9,40	0,00
quad66	30,72	0,00	17,28	4,36	13,44	4,36
quad99	24,00	0,00	17,96	0,00	6,04	0,00
ret33	0,00	11,20	0,00	6,00	0,00	5,20
ret66	0,00	8,96	0,00	4,72	0,00	4,24
ret99	0,00	7,00	0,00	3,84	0,00	3,16

¹⁷Situações 1, 2, 3 e 4: Situações de sobreposição consideradas, onde a situação 1 representa a sobreposição do retângulo sobre o quadrado, a situação 2 o quadrado sobre o retângulo, a situação 3 o quadrado sobre o quadrado e a situação 4 o retângulo sobre o retângulo.

Tabela 4: Tabela de reconhecimento dos padrões, com os respectivos erros, para o descritor de alongação.

Imagem	% Área Q	% Área R	% Rec. Q	% Rec. R	Erro Q	Erro R
retQuad33	20,80	6,72	14,12	3,84	6,68	2,88
retQuad66	18,56	6,72	11,00	4,48	7,56	2,24
retQuad99	16,60	6,72	0,00	13,56	16,60	6,84
quadRet33	23,04	4,48	19,96	0,00	3,08	4,48
quadRet66	23,04	2,24	17,80	0,00	5,24	1,52
quadRet99	23,04	0,28	17,80	0,00	5,24	0,28
quad33	38,40	0,00	29,00	0,00	9,40	0,00
quad66	30,72	0,00	17,28	4,36	13,44	4,36
quad99	24,00	0,00	17,96	0,00	6,40	0,00
ret33	0,00	11,20	0,00	6,00	0,00	5,20
ret66	0,00	8,96	0,00	4,72	0,00	4,24
ret99	0,00	7,00	0,00	3,84	0,00	3,04

Tabela 5: Tabela de reconhecimento dos padrões, com os respectivos erros, para o descritor de solidez.

Imagem	% Área Q	% Área R	% Rec. Q	% Rec. R	Erro Q	Erro R
retQuad33	20,80	6,72	17,96	0,00	2,84	6,72
retQuad66	18,56	6,72	15,48	11,00	3,08	4,28
retQuad99	16,60	6,72	13,56	0,00	3,04	6,72
quadRet33	23,04	4,48	19,96	0,00	3,08	4,48
quadRet66	23,04	2,24	18,52	0,00	4,52	2,24
quadRet99	23,04	0,28	17,80	0,00	5,24	0,28
quad33	38,40	0,00	29,00	0,00	9,40	0,00
quad66	30,72	0,00	21,64	0,00	9,08	0,00
quad99	24,00	0,00	17,96	0,00	6,40	0,00
ret33	0,00	11,20	0,00	6,00	0,00	5,20
ret66	0,00	8,96	0,00	4,72	0,00	4,24
ret99	0,00	7,00	0,00	3,84	0,00	3,16

A partir das informações das tabelas, foram calculadas, para cada descritor, suas respectivas correções para as três situações de sobreposição, utilizando a equação 47.

As Figuras de 63 a 68 apresentam as regressões lineares dos descritores de redondez, alongação e solidez, respectivamente, com suas respectivas equações e coeficientes de correlação (R^2), obtidas a partir dos dados das tabelas, sendo uma para cada padrão (quadrado e retângulo) nas situações de sobreposição de quadrado com retângulo e retângulo com quadrado, uma para o padrão do quadrado para a sobreposição de quadrado com quadrado, e outra para o retângulo quando há sobreposição de retângulo com retângulo.

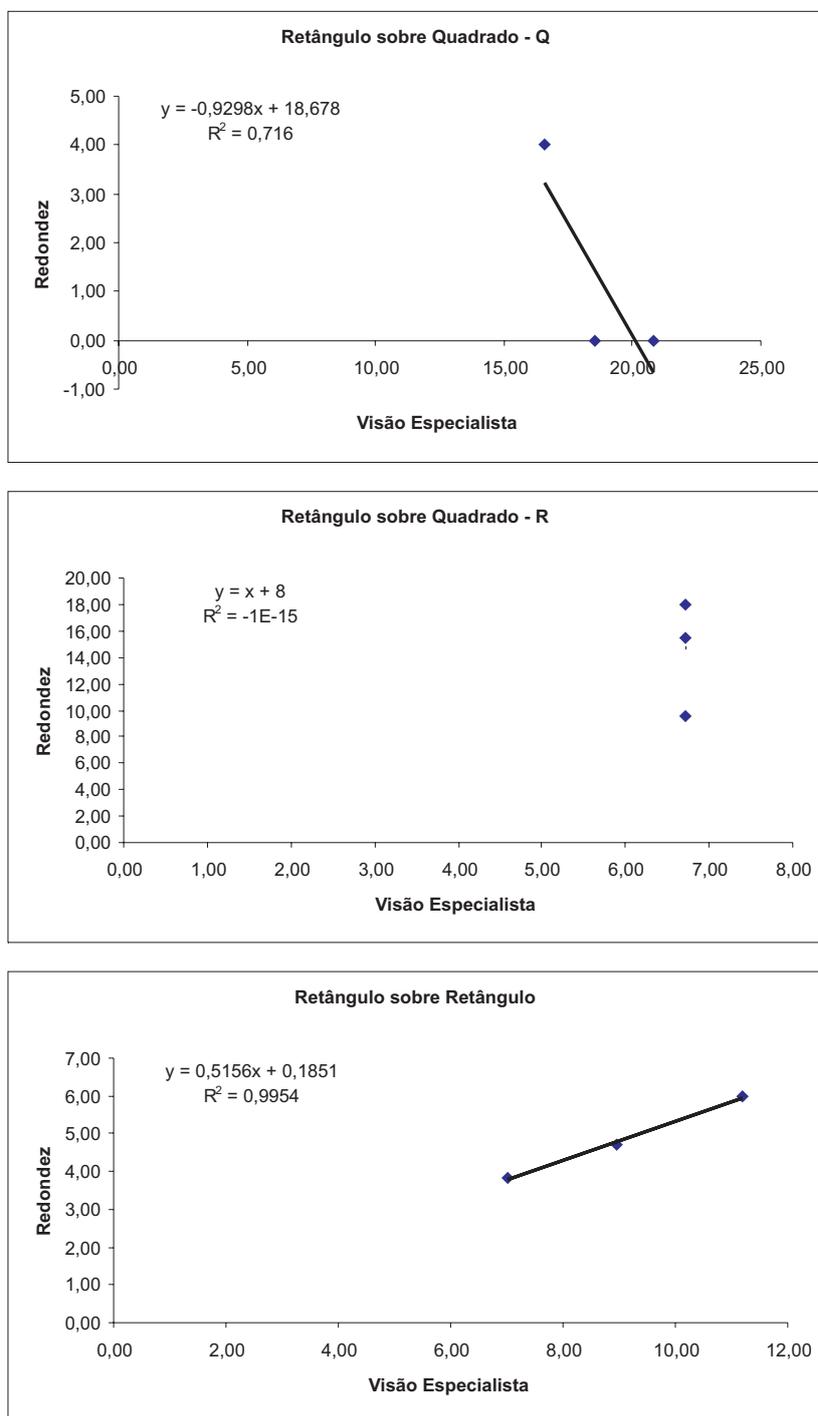


Figura 63: Regressões lineares para análise do desempenho do descritor de redondez para: (a) padrão quadrado na situação de sobreposição de quadrado com retângulo; (b) padrão retângulo na sobreposição de quadrado com retângulo; (c) quadrado na sobreposição de quadrado com quadrado; (d) retângulo na sobreposição de retângulo com retângulo.

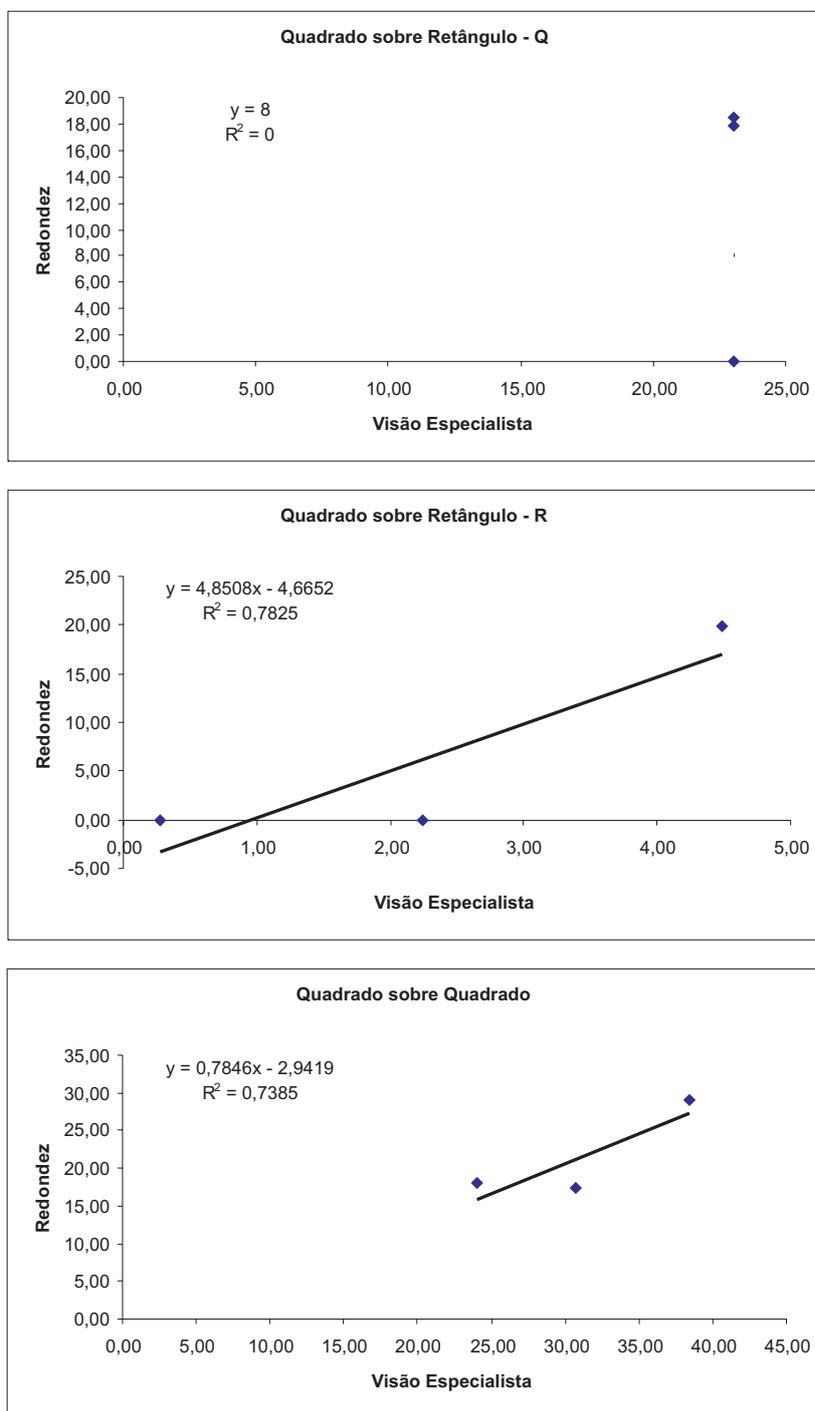


Figura 64: Regressões lineares para análise do desempenho do descritor de redondez para: (a) padrão quadrado na situação de sobreposição de quadrado com retângulo; (b) padrão retângulo na sobreposição de quadrado com retângulo; (c) quadrado na sobreposição de quadrado com quadrado; (d) retângulo na sobreposição de retângulo com retângulo.

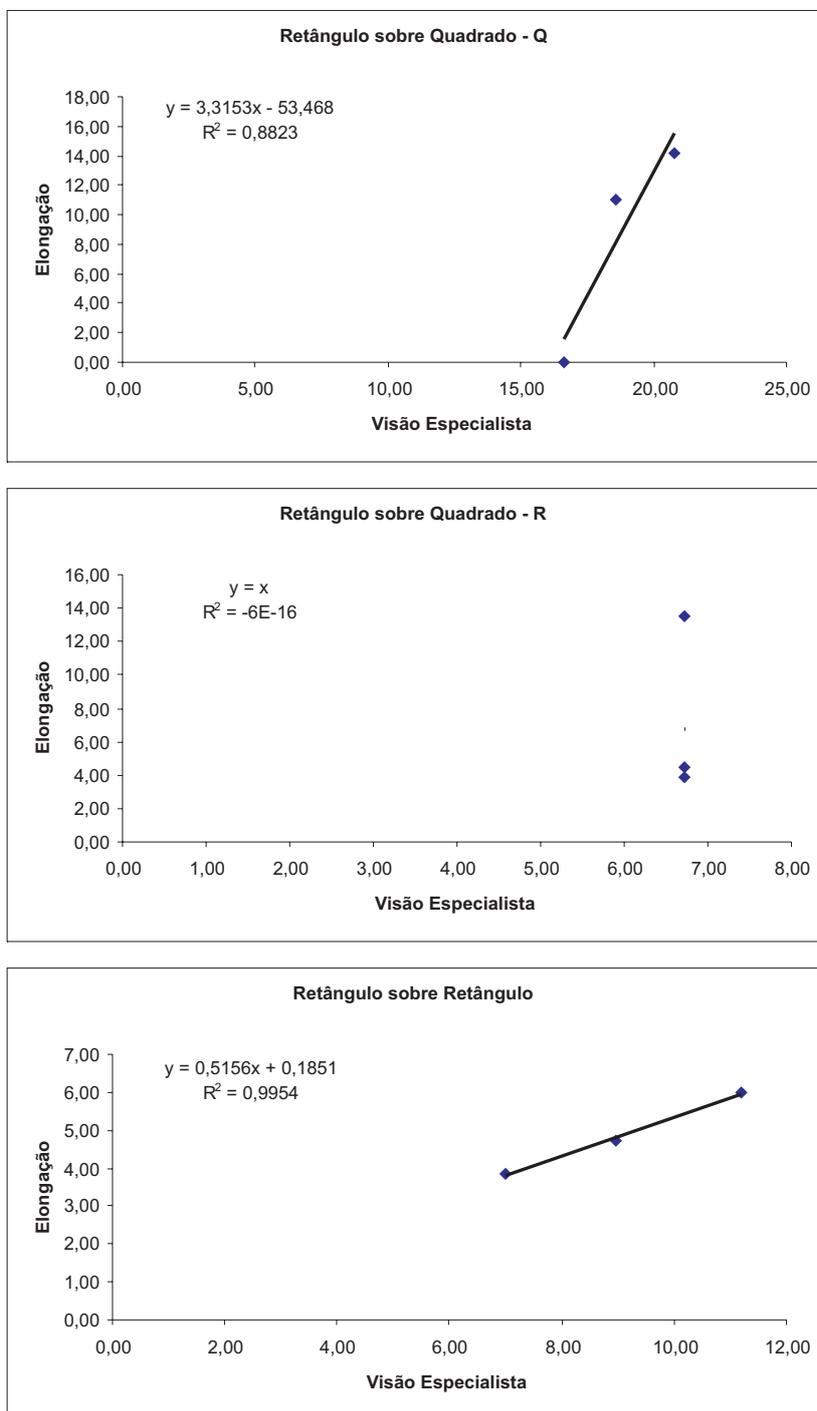


Figura 65: Regressões lineares para análise do desempenho do descritor de alongação para: (a) padrão quadrado na situação de sobreposição de quadrado com retângulo; (b) padrão retângulo na sobreposição de quadrado com retângulo; (c) quadrado na sobreposição de quadrado com quadrado; (d) retângulo na sobreposição de retângulo com retângulo.

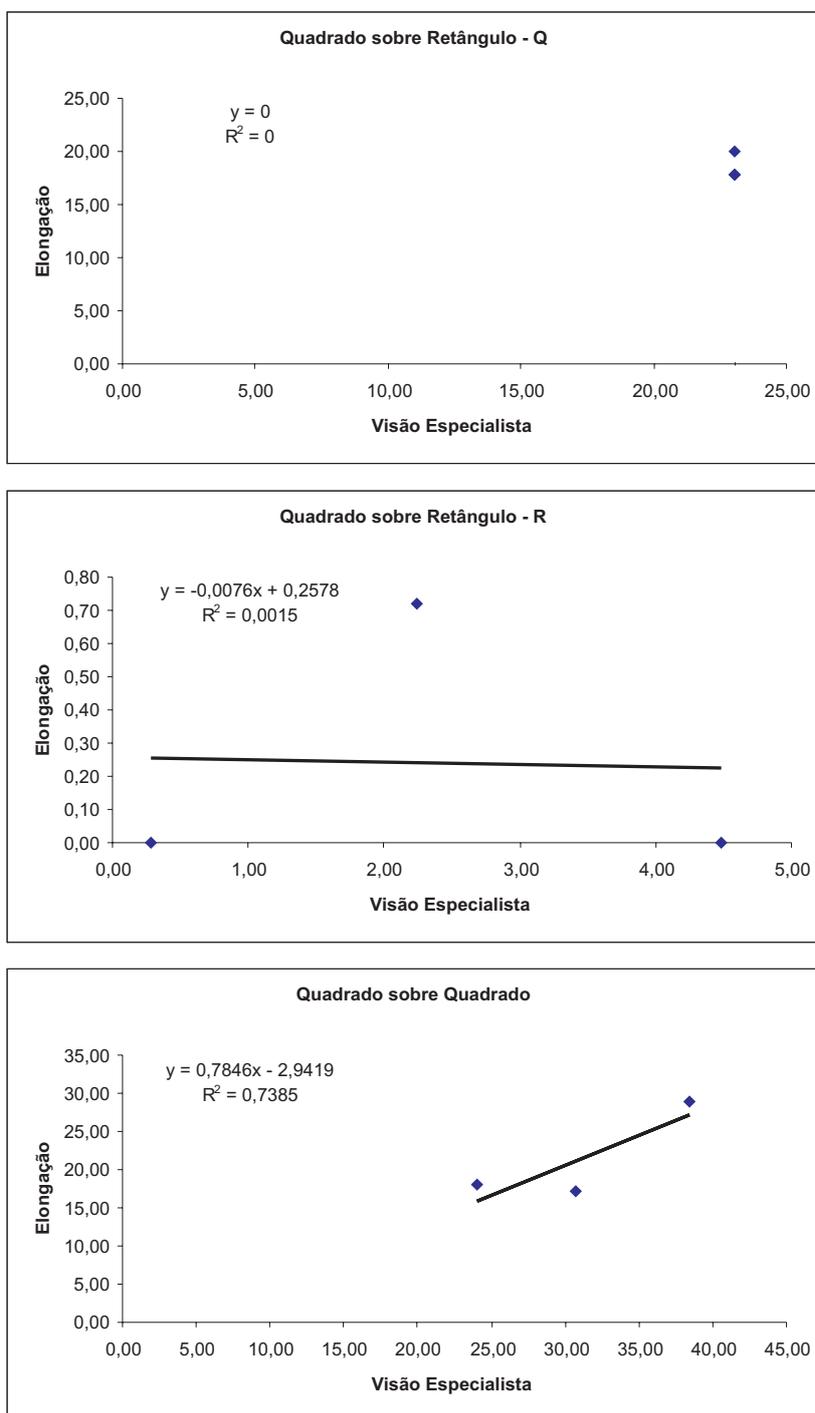


Figura 66: Regressões lineares para análise do desempenho do descritor de alongação para: (a) padrão quadrado na situação de sobreposição de quadrado com retângulo; (b) padrão retângulo na sobreposição de quadrado com retângulo; (c) quadrado na sobreposição de quadrado com quadrado; (d) retângulo na sobreposição de retângulo com retângulo.

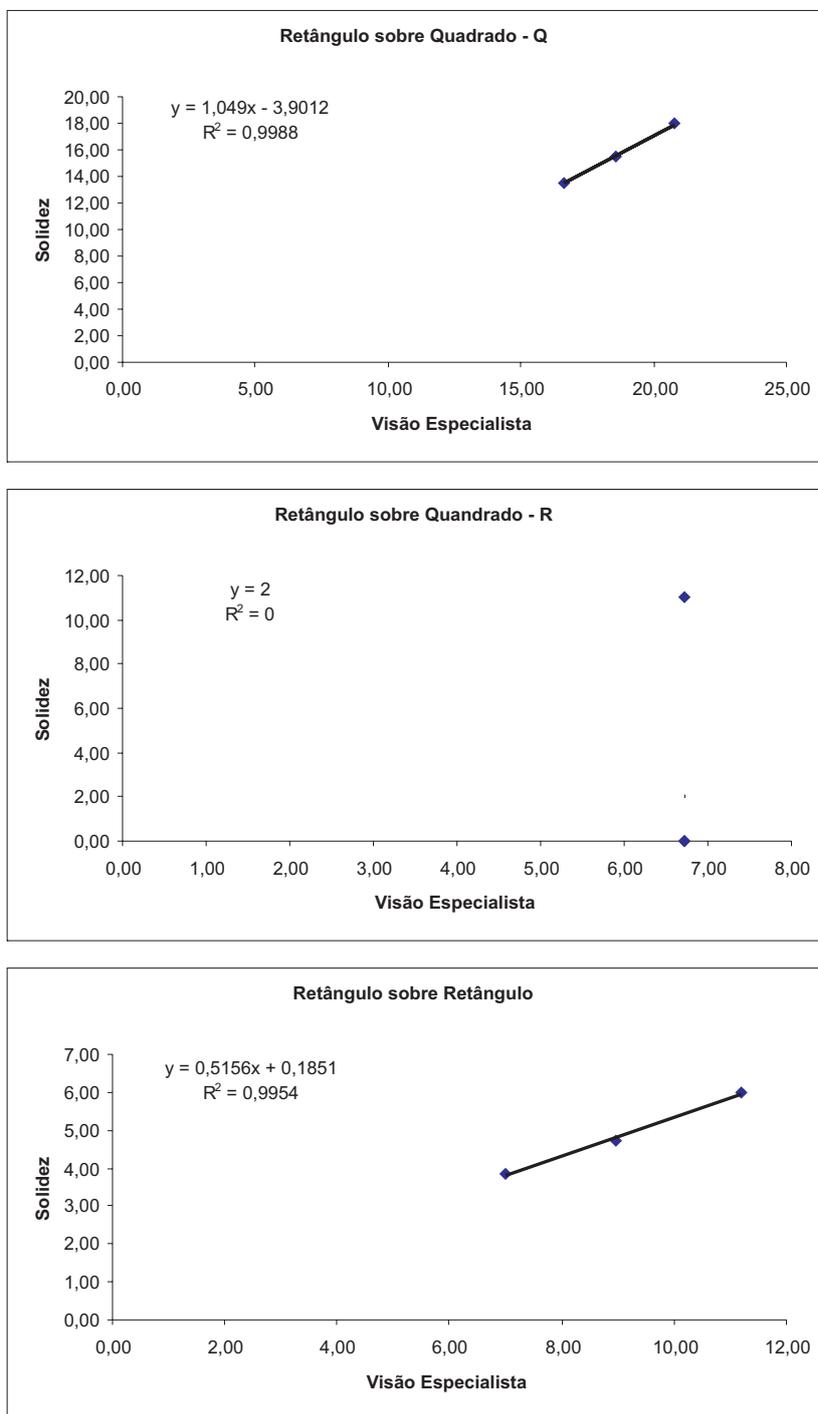


Figura 67: Regressões lineares para análise do desempenho do descritor de solidez para: (a) padrão quadrado na situação de sobreposição de quadrado com retângulo; (b) padrão retângulo na sobreposição de quadrado com retângulo; (c) quadrado na sobreposição de quadrado com quadrado; (d) retângulo na sobreposição de retângulo com retângulo.

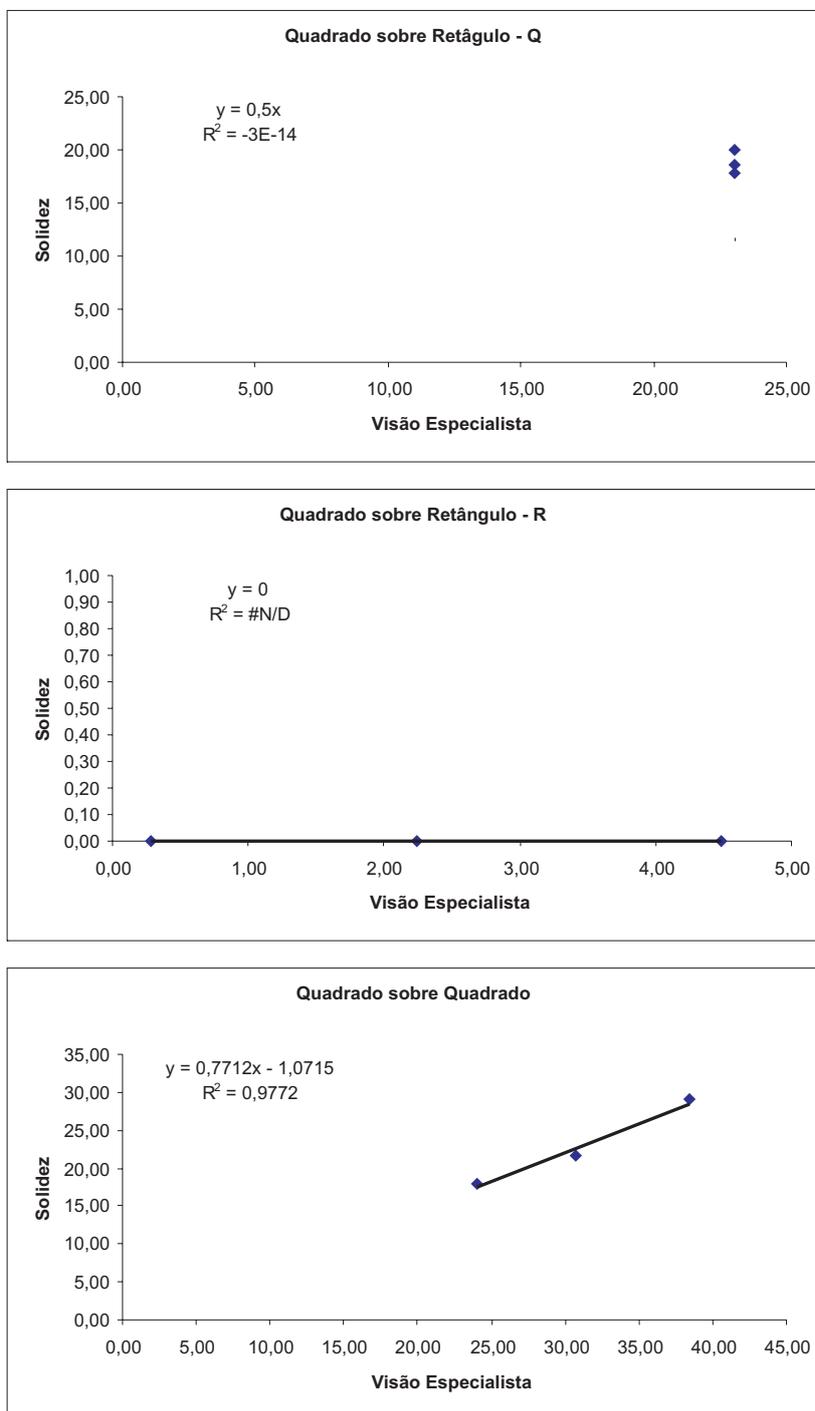


Figura 68: Regressões lineares para análise do desempenho do descritor de solidez para: (a) padrão quadrado na situação de sobreposição de quadrado com retângulo; (b) padrão retângulo na sobreposição de quadrado com retângulo; (c) quadrado na sobreposição de quadrado com quadrado; (d) retângulo na sobreposição de retângulo com retângulo.

Pela análise dos dados das tabelas e suas respectivas regressões lineares, observa-se que para a situação de sobreposição do retângulo sobre o quadrado, todos os descritores, através do método proposto, identificaram bem o quadrado, apresentando altos valores de correlação linear, porém erraram na identificação do retângulo, apresentando um R^2 quase nulo. Na situação de sobreposição do quadrado sobre o retângulo, o quadrado apresentou alto erro na identificação, com R^2 nulo em dois descritores, redondez e alongação, e quase nulo no descritor de solidez. Ainda nesta situação, o retângulo não foi identificado pelo descritor de solidez, apresentou baixa correlação pelo descritor de alongação e alta correlação pelo descritor de redondez. Analisando agora as situações de sobreposição com o mesmo padrão (quadrado com quadrado e retângulo com retângulo) os dados mostram que a identificação foi boa, não apresentando R^2 inferior a 0,7385.

5.2 Aplicação em Ambiente de Campo de Produção Agrícola

Nesta seção são apresentadas e discutidas as análises feitas para a validação do sistema de reconhecimento de padrões de plantas invasoras e percentual de ocupação de folhas largas e folhas estreitas através de um estudo de caso em um campo de produção agrícola com a cultura do milho (*Zea Mays*).

A aplicação do método em ambiente de campo foi feita considerando uma prática adotada atualmente para a prescrição de mapas de infestação para que uma estratégia de controle eficiente seja adotada. Nesta prática, o campo de produção é dividido em parcelas, onde de cada parcela são obtidas duas imagens as quais são utilizadas como amostras da parcela. Para cada imagem é feita a identificação visual das plantas invasoras presentes e depois esta informação é utilizada para inferir a ocupação das plantas invasoras na determinada parcela. Por fim, é criado um mapa de prescrição de herbicidas através das informações de todas as parcelas no campo de produção agrícola.

5.2.1 Aquisição das Imagens

Para a avaliação foram adquiridas imagens em um campo experimental da Embrapa Milho e Sorgo¹⁸. O campo tem a medida de 38 ha de área, e é dividido em 41 parcelas

¹⁸Embrapa Milho e Sorgo, Rod. MG 424 KM 45 - Sete Lagoas, Caixa Postal 285 - CEP 35701-970 Sete Lagoas - MG - Brasil

espaçadas de 100×100m e com área de 12m² (4×3m). Para a aquisição das imagens foi utilizado um quadro medindo 50×50cm visando o ajuste do *zoom* das mesmas. As imagens foram obtidas ao longo do campo. Foram abrangidas 26 das 41 parcelas, obtendo 2 imagens de cada parcela, formando um banco de 52 imagens.

Foram consideradas duas espécies de plantas invasoras presentes na cultura do milho, sendo uma de folha larga e outra de folha estreita, ilustradas nas figuras 69 e 70. A escolha das espécies foi feita considerando aquelas que possuíam um maior impacto sobre as plantações de milho, sendo as escolhidas a leiteira (*Euphorbia heterophylla* L.) e o capim-colchão (*Digitaria sanguinalis* Scop.), representando as folhas largas e estreitas, respectivamente. Cada uma das espécies apresentam características diferentes, tanto nas folhas quanto em sua importância agropecuária. Descrevendo com mais detalhes essas diferenças, tem-se:

Leiteira (*Euphorbia heterophylla* L.): nesta espécie as folhas ocorrem ao longo do caule, com gemas¹⁹ nas axilas²⁰. São glabras, medindo de 4 a 10 cm de comprimento. As folhas inferiores são alternadas e lanceoladas, enquanto as superiores são opostas ou verticiladas. Abaixo das inflorescências há maior concentração de folhas.

É uma das espécies mais importantes infestantes de lavouras, pois se desenvolvem e reproduzem rapidamente, apresentando alto grau de competitividade em relação à cultura, por nutrientes e água.

Capim-colchão (*Digitaria sanguinalis* Scop.): esta espécie apresenta folhas com até 15 cm de comprimento e 12 mm de largura, as lâminas são planas, com margens lisas; podem apresentar pêlos em sua extensão. A coloração é verde, podendo adquirir cor arroxeada quando em condições desfavoráveis.

Apesar de quando jovens ter qualidade forrageira²¹ durante um curto período, são infestantes agressivas e podem representar efeito alelopático²² negativo em relação às plantas cultivadas.

¹⁹Gema: mesmo que broto, ou seja, caule frequentemente herbáceo e cilíndrico, com nós bem demarcados, e entrenós ger. fistulosos, característico das gramíneas (HOUAISS, 2001).

²⁰Axila: região angular formada entre um órgão, ou parte vegetal, e o eixo em que se insere, esp. entre uma folha e o eixo caulinar, na qual germinam brotam gemas que dão origem a novos ramos, folhas ou flores (HOUAISS, 2001).

²¹Forrageira: planta que serve de forragem (HOUAISS, 2001).

²²Alelopático: que apresenta alelopatia, ou seja, dano provocado por uma planta em outro organismo, causado pela liberação no meio ambiente de metabólitos secundários tóxicos (HOUAISS, 2001).

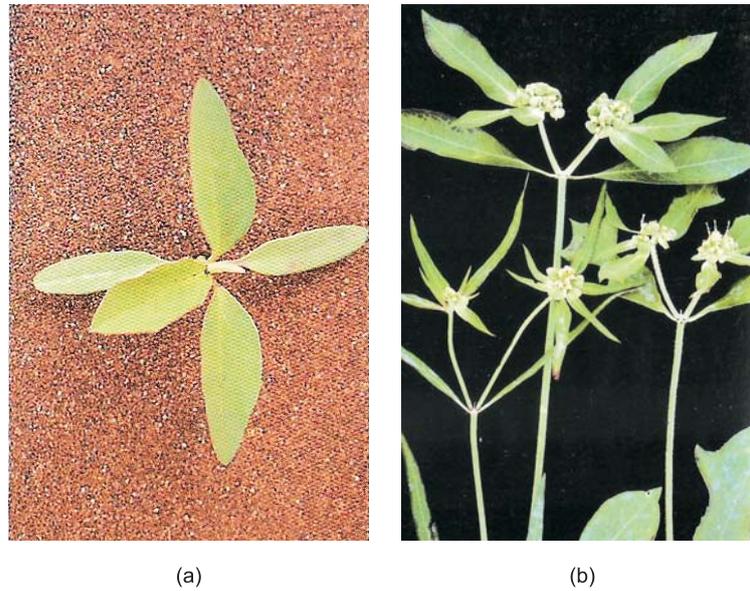


Figura 69: Imagem da leiteira (*Euphorbia heterophylla* L.), planta de folha larga a ser reconhecida pelo sistema: (a) planta com pouco tempo de desenvolvimento, que é alvo dos herbicidas; (b) planta madura, para a qual o controle químico não é mais indicado, pois o herbicida também prejudica a cultura.

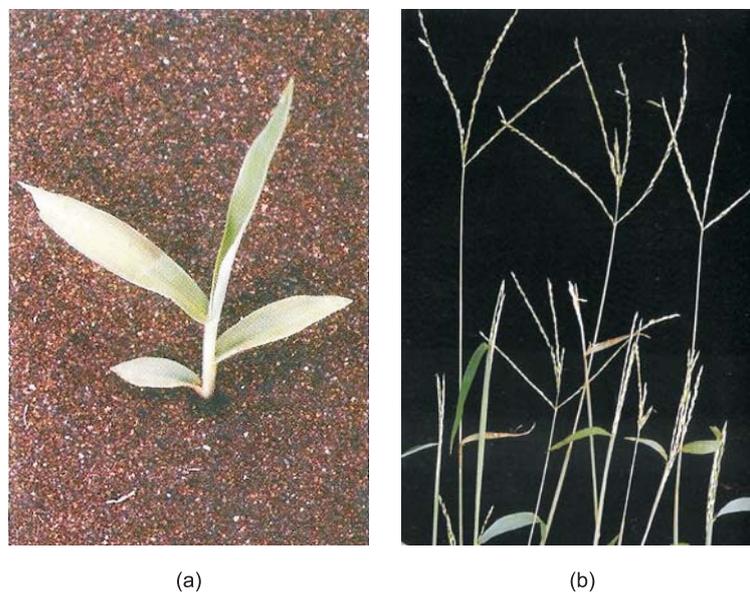


Figura 70: Imagem do capim-colchão (*Digitaria sanguinalis* Scop.), planta de folha estreita a ser reconhecida pelo sistema: (a) planta com pouco tempo de desenvolvimento, que é alvo dos herbicidas; (b) planta madura, para a qual o controle químico não é mais indicado, pois o herbicida também prejudica a cultura.

5.2.2 Validação do Método em Nível de Campo

A Figura 71 ilustra a aplicação do pré-processamento em duas das imagens de campo adquiridas. Nelas pode-se observar que o algoritmo é eficiente, e consegue eliminar de maneira satisfatória o fundo das imagens.

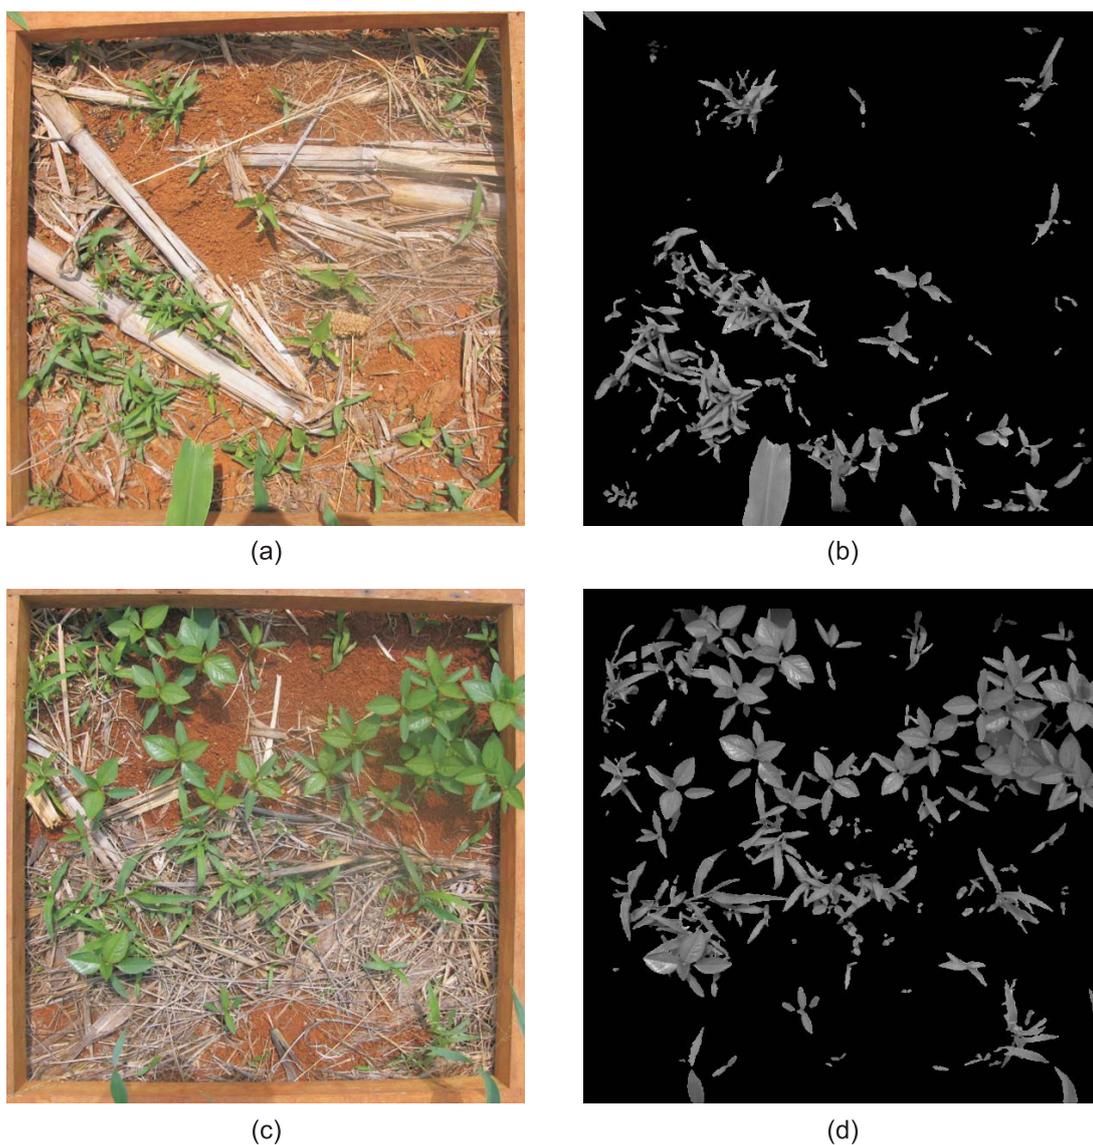


Figura 71: Exemplos da aplicação do pré-processamento em imagens de campo, onde (a) e (c) são as imagens originais, e (b) e (d) as respectivas imagens resultantes do pré-processamento, onde o fundo é preto e as folhas são representadas por sua informação original em tons de cinza.

A Figura 72 ilustra a aplicação da segmentação baseada em textura em duas das imagens de campo. Nelas é possível observar que o algoritmo é eficiente para o que se propôs, segmentar plantas invasoras, não selecionando portanto as plantas de cultura.

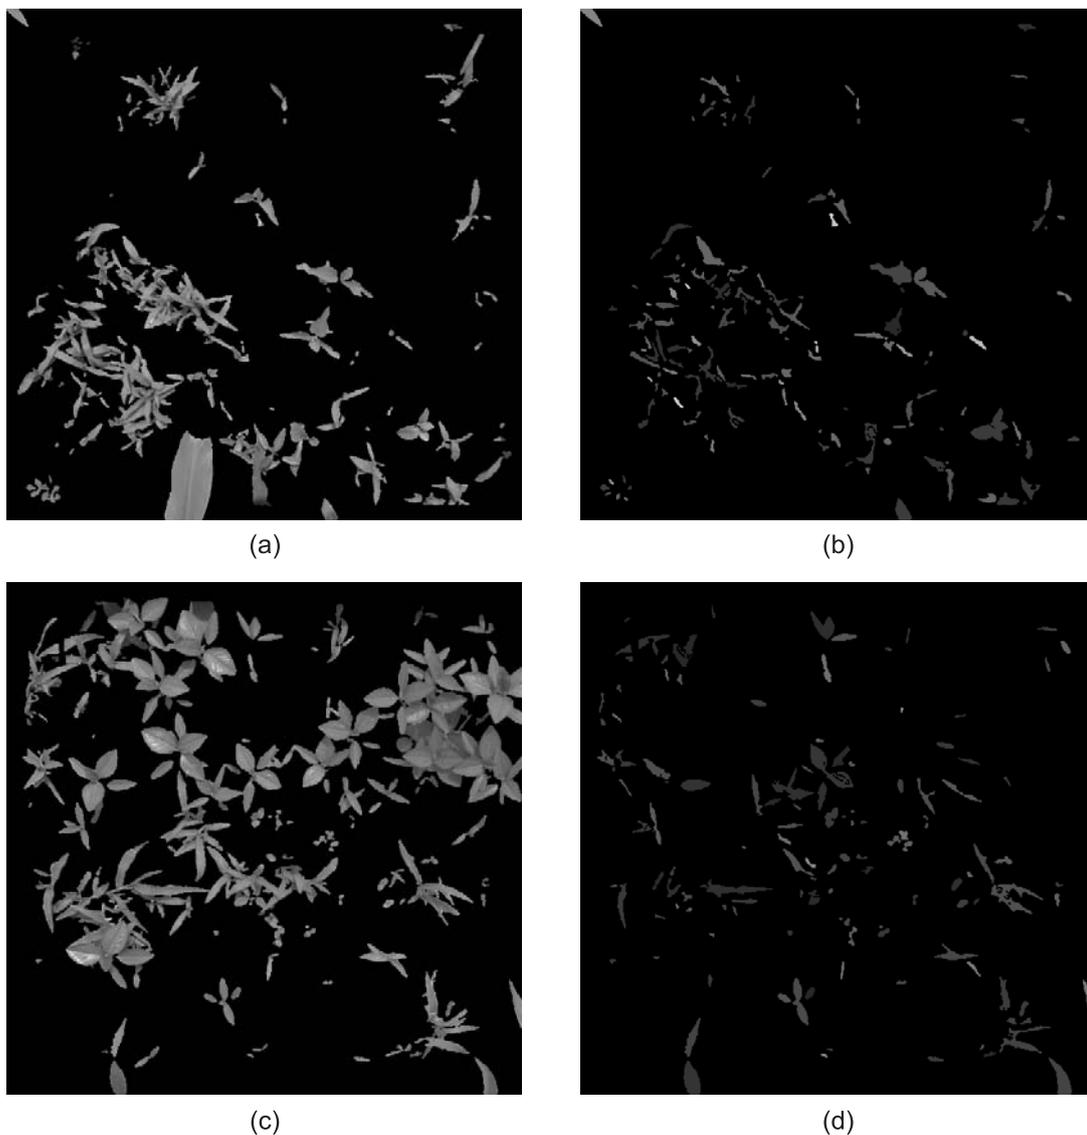


Figura 72: Imagens da segmentação de textura nas imagens de campo, onde (a) e (c) são as imagens resultantes do pré-processamento, e (b) e (d) as respectivas imagens resultantes da segmentação.

É possível observar na Figura 72 que o algoritmo apresenta uma deficiência, que é a perda da área de folhas da imagem, que é muito importante para a aplicação em questão, pois ao final do processo, é fornecido o percentual de ocupação das plantas de folhas largas

e estreitas na imagem. A perda de área ocorreu na fase onde são encontradas as regiões das folhas, conforme discutido na seção anterior. As figuras 73 e 74 apresentam a informação de borda utilizando o operador laplaciano, bordas dilatadas, a imagem limiarizada obtida no pré-processamento e a nova imagem limiarizada, retirando a informação das bordas dilatadas da imagem limiarizada original.

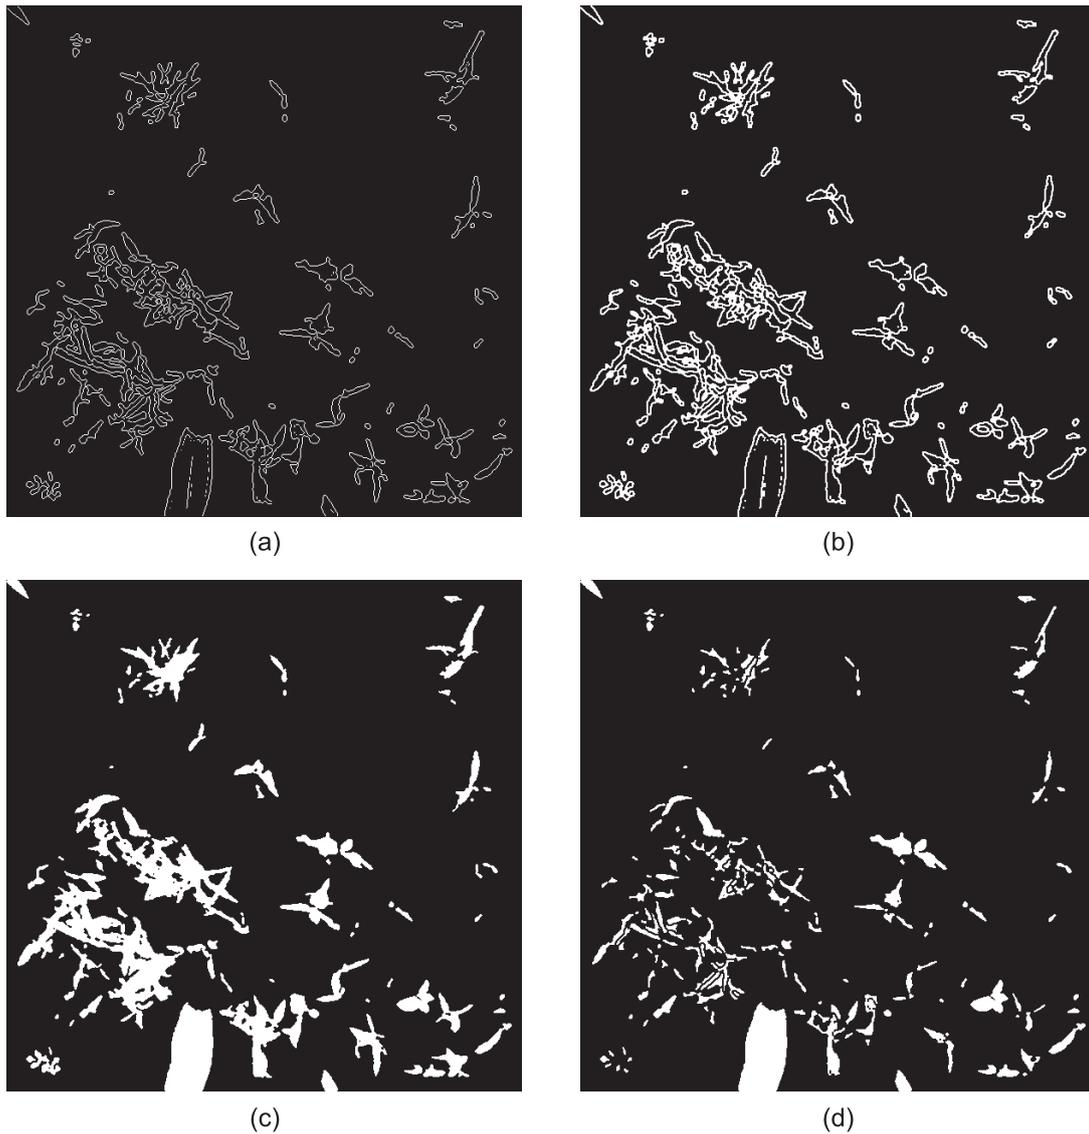


Figura 73: Imagens do processo de formação das regiões das folhas: (a) imagem das bordas das folhas; (b) imagem das bordas dilatadas, com máscara 3×3 , e erodidas, com máscara 2×2 , em seguida; (c) imagem limiarizada para ilustrar as regiões das folhas presentes na imagem; (d) imagem resultante da subtração das bordas, letra b, da imagem das regiões, letra c.

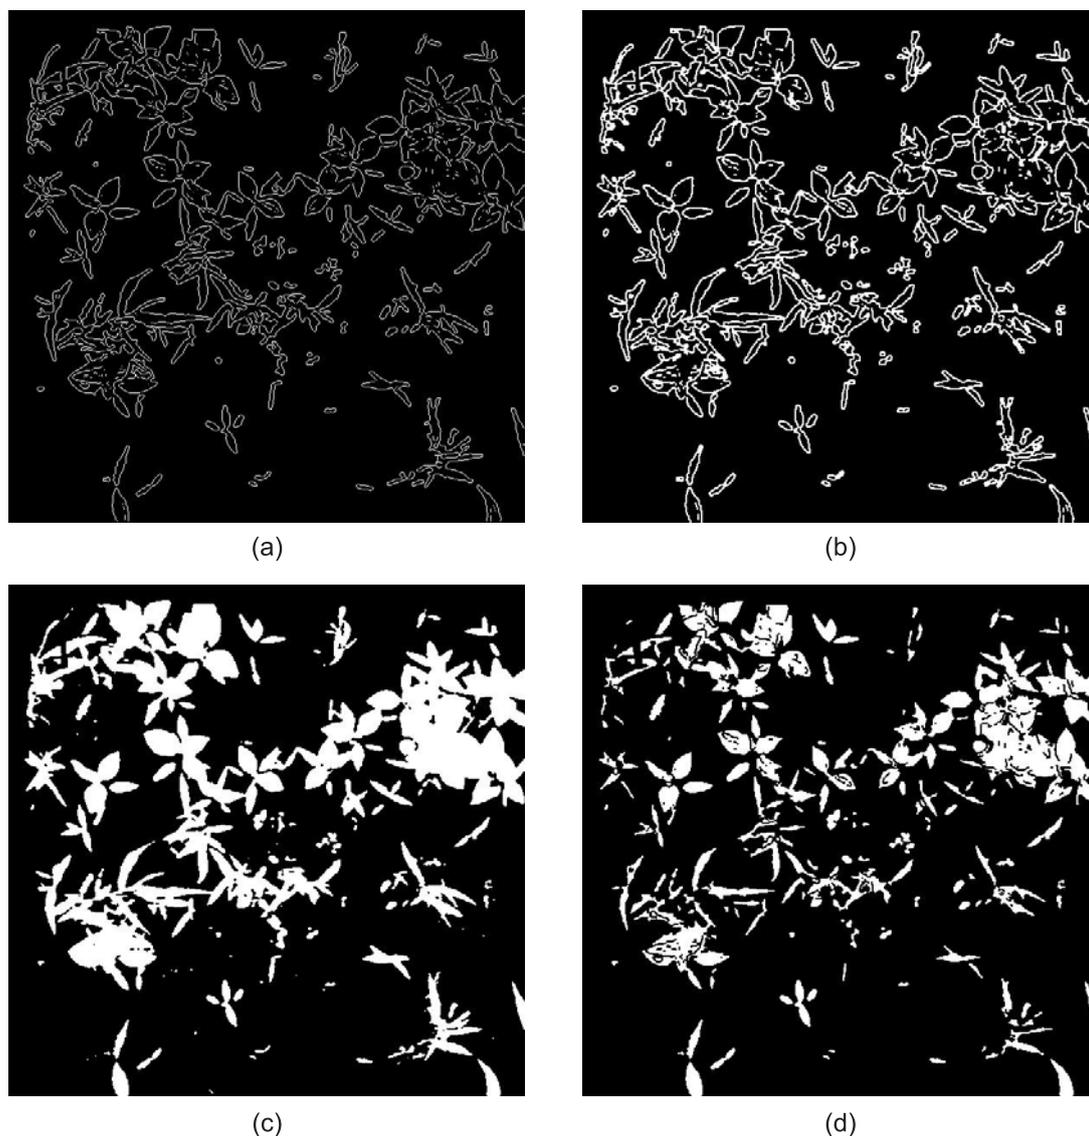


Figura 74: Imagens do processo de formação das regiões das folhas: (a) imagem das bordas das folhas; (b) imagem das bordas dilatadas, com máscara 3×3 , e erodidas, com máscara 2×2 , em seguida; (c) imagem limiarizada para ilustrar as regiões das folhas presentes na imagem; (d) imagem resultante da subtração das bordas, letra b, da imagem das regiões, letra c.

Para a separação das folhas de plantas invasoras das folhas do milho a textura se mostrou eficiente, pois os dois tipos de folhas apresentaram valores muito diferentes. No método de textura considerado foi utilizado um janelamento da imagem, obtendo a informação de contraste em cada janela. Como as folhas de milho são maiores que as de plantas invasoras, seu valor de textura foi mais baixo, pois o contraste apresenta valores

elevados apenas nas janelas onde há bordas (transições abruptas de cinza) e como as plantas de milho possuem mais janelas no seu interior do que nas bordas, onde a textura tende a ser mais constante, os valores de textura são mais baixos.

Na etapa dos descritores, o sistema encontra, a partir do mapa de textura de folhas, as regiões que representam as plantas de folhas largas, e as regiões que representam as plantas de folhas estreitas. Estas regiões são representadas em dois novos mapas, um de folhas largas, e outro de folhas estreitas. A partir desses novos mapas, são calculados os percentuais de ocupação de cada tipo de folha.

Os percentuais de ocupação são obtidos pela soma das áreas das folhas no mapa de folhas largas ou estreitas, seguida pela divisão do valor encontrado pela área total da imagem. Nesta etapa, foram consideradas as medidas de correção introduzidas nas equações 46 e 47, onde a primeira é a correção para o problema da perda de área devido a dilatação das bordas e a segunda se refere a correção da possível sobreposição.

Para este sistema foram avaliados três diferentes descritores, sendo eles, redondez, alongação e solidez. Para a avaliação de desempenho destes descritores, foram selecionadas 20 imagens do conjunto de 52 imagens de campo para as quais foram obtidos os percentuais de ocupação segundo cada descritor além da medida de visão natural, obtida com a ajuda de um especialista que identificou nas 20 imagens as plantas de folhas largas e plantas de folhas estreitas. A Tabela 6 apresenta a comparação dos percentuais de ocupação obtidos pela visão natural e pela visão computacional para as plantas de folhas largas, enquanto a Figura 75 apresenta a análise da tabela por meio das regressões lineares, entre a medida de visão natural e cada uma das medidas de visão computacional. A Tabela 7 e Figura 76 apresentam o dados para as plantas de folhas estreitas.

Analisando os resultados das figuras 75 e 76, observa-se que o descritor de solidez é o que apresenta melhor resultado, com R^2 médio de 0,7606, obtendo 0,8017 para as plantas de folhas estreitas e 0,7195 para as plantas de folhas largas. O descritor com pior desempenho é a redondez, apresentando R^2 médio de 0,5068. O descritor de alongação também apresentou bons resultados, ficando com a média de 0,7283, sendo 0,8424 para folhas largas e 0,6141 para folhas estreitas.

Para compor o sistema em questão, foram selecionados os descritores que apresentaram o melhor resultado para cada tipo de folha, sendo eles, a alongação para as plantas

de folhas largas que apresentou R^2 de 0,8424 e a solidez para as plantas de folhas estreitas com R^2 de 0,8017.

Tabela 6: Comparação dos percentuais de ocupação de folhas largas obtidos pela visão natural e pelo sistema utilizando os descritores de redondez, alongação e solidez.

	Imagem	Natural	Redondez	Elongação	Solidez
1	IMG_6563	0,25	0,97	0,57	1,47
2	IMG_6565	0,27	1,42	0,61	2,31
3	IMG_6568	0,00	0,66	0,42	0,83
4	IMG_6569	0,60	0,60	0,32	0,80
5	IMG_6570	0,37	1,07	0,69	1,12
6	IMG_6571	0,36	0,47	0,54	0,63
7	IMG_6572	2,04	1,60	1,73	2,46
8	IMG_6584	2,34	2,24	2,07	3,09
9	IMG_6589	1,85	1,74	1,73	2,91
10	IMG_6590	4,81	2,03	2,20	3,61
11	IMG_6591	3,60	1,22	2,33	3,71
12	IMG_6594	1,57	1,99	1,49	2,47
13	IMG_6598	1,54	1,32	0,84	1,77
14	IMG_6599	0,57	1,13	0,93	1,66
15	IMG_6600	0,16	1,39	0,76	1,72
16	IMG_6601	0,00	0,48	0,71	1,63
17	IMG_6604	0,47	0,88	0,84	2,62
18	IMG_6605	1,31	1,05	1,22	2,23
19	IMG_6608	0,17	0,92	0,62	1,27
20	IMG_6612	3,80	1,70	2,10	3,73

Tabela 7: Comparação dos percentuais de ocupação de folhas estreitas obtidos pela visão natural e pelo sistema utilizando os descritores de redondez, alongação e solidez.

	Imagem	Natural	Redondez	Elongação	Solidez
1	IMG_6563	0,91	0,73	0,95	0,13
2	IMG_6565	1,73	2,08	2,53	0,98
3	IMG_6568	0,73	0,22	0,47	0,05
4	IMG_6569	0,49	0,38	0,56	0,13
5	IMG_6570	0,26	0,22	0,47	0,10
6	IMG_6571	0,30	0,41	0,25	0,20
7	IMG_6572	2,73	2,95	2,37	1,84
8	IMG_6584	3,28	3,26	2,87	2,10
9	IMG_6589	1,37	2,07	1,68	0,68
10	IMG_6590	0,88	2,66	2,02	0,81
11	IMG_6591	2,83	4,46	2,76	1,65
12	IMG_6594	1,72	1,27	1,44	0,62
13	IMG_6598	0,42	1,03	1,25	0,44
14	IMG_6599	0,55	1,49	1,41	0,81
15	IMG_6600	0,83	0,78	1,18	0,34
16	IMG_6601	1,06	1,29	1,06	0,13
17	IMG_6604	0,81	2,38	2,09	0,46
18	IMG_6605	0,55	1,58	1,14	0,25
19	IMG_6608	0,40	0,70	0,84	0,28
20	IMG_6612	0,82	3,18	2,28	0,87

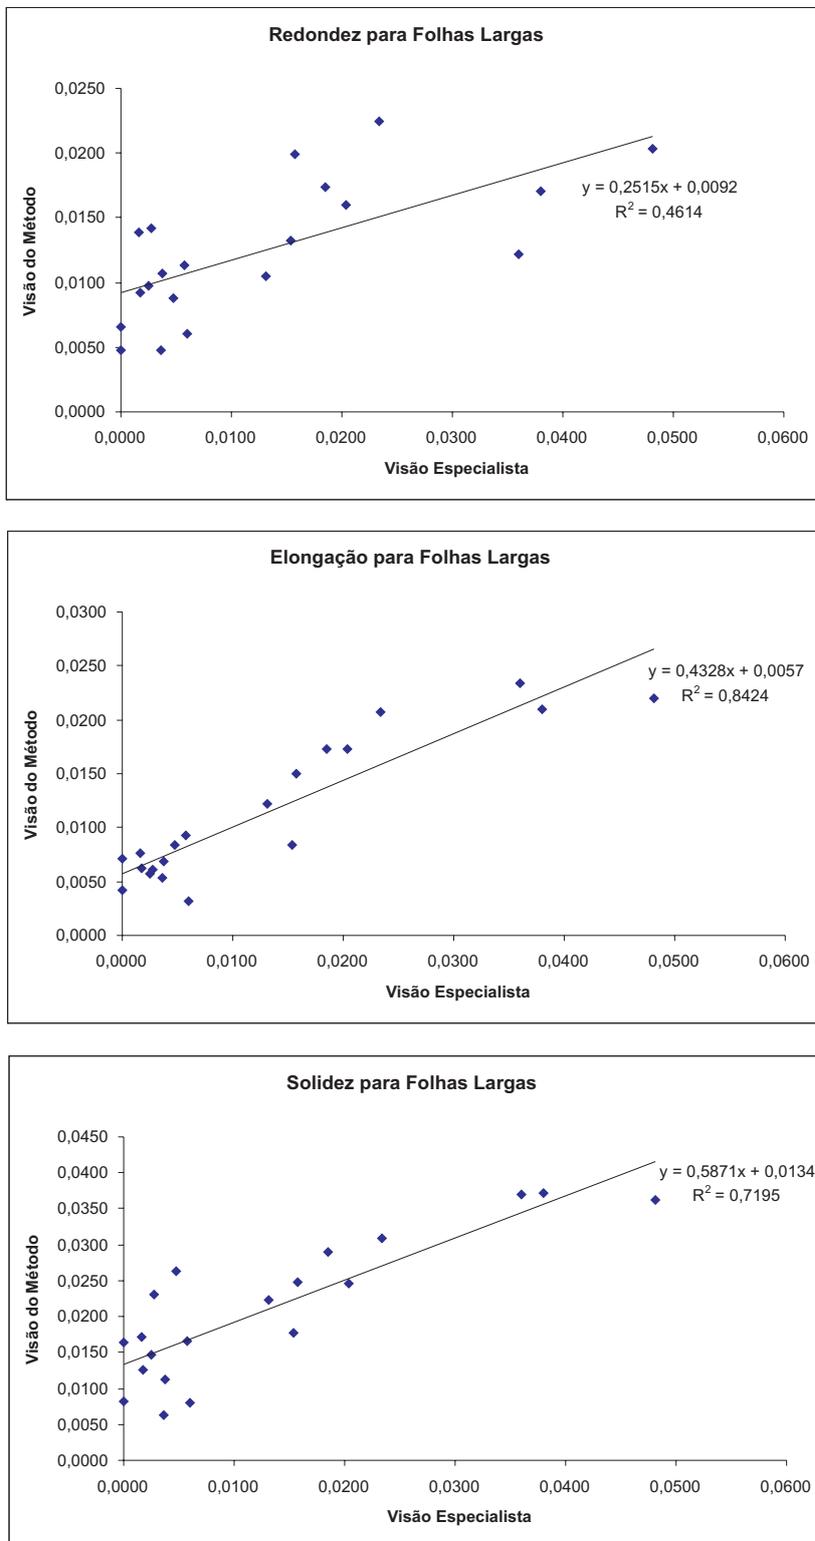


Figura 75: Regressão linear para os descritores no reconhecimento de folhas largas.

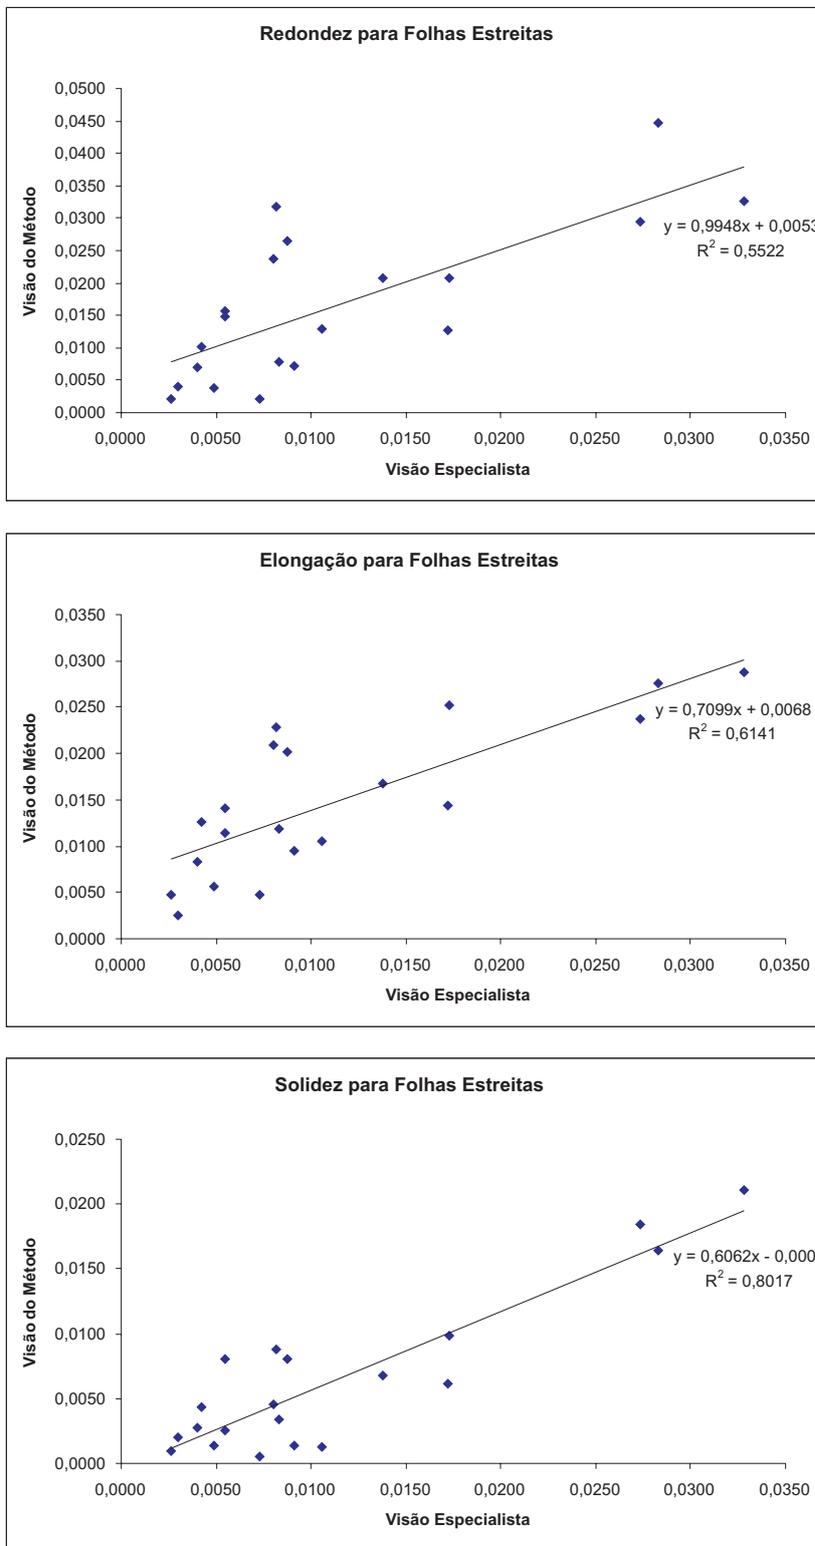


Figura 76: Regressão linear para os descritores no reconhecimento de folhas estreitas.

5.2.3 Aplicação do Método para Análise do Percentual de Ocupação

Esta subsecção trata da aplicação do método desenvolvido para a análise da percentagem de ocupação de plantas invasoras de folhas largas e estreitas em área de cultivo de milho.

A partir dos resultados apresentados anteriormente, foram formulados dois descritores para a análise das imagens de campo, sendo um para plantas de folhas largas e outro para folhas estreitas. Ambos os descritores formulados são invariantes quanto ao tamanho da forma, sendo assim, eles identificam as plantas invasoras em qualquer estágio de desenvolvimento.

O descritor de folhas largas conta com a subtração da componente R da componente G, seguida pela aplicação do filtro da mediana e limiarização para a separação correta das folhas do fundo (palha e solo). Adicionalmente são utilizadas a informação de textura, contraste, para a separação das folhas de plantas invasoras das folhas do milho, a medida de alongação, para identificação da forma de folhas largas, e finalmente as medidas de correção para recuperar a área perdida devido a dilatação das bordas e devido a sobreposição de folhas. Portanto, o descritor de folhas largas é definido como:

$$\text{Descritor}_{\text{folhas largas}} \equiv \left\{ \begin{array}{l} \left[\begin{array}{cccc} g_{11} - r_{11} & g_{12} - r_{12} & \dots & g_{1n} - r_{1n} \\ g_{21} - r_{21} & g_{22} - r_{22} & \dots & g_{2n} - r_{2n} \\ \vdots & \vdots & & \vdots \\ g_{m1} - r_{m1} & g_{m2} - r_{m2} & \dots & g_{mn} - r_{mn} \end{array} \right], \text{ filtro de mediana,} \\ \text{limiarizacao, mapa de textura} \left(\sum_{n=0}^{N_g-1} n^2 \left\{ \sum_i \sum_j p(i, j), \text{ se } |i - j| = n \right\} \right), \\ \text{alongacao} \left(\frac{\text{largura}}{\text{comprimento}} \right), \text{ correcao de bordas} \left(\frac{\text{Area do contorno dilatado}}{3} \right), \\ \text{correcao de sobreposicao} \left(\frac{(x_1\% + y_1\%) + (x_2\% + y_2\%) + x_3\% + y_4\%}{4} \right) \end{array} \right\} \quad (48)$$

Assim como o descritor anterior, o descritor de folhas estreitas conta com as mesmas medidas, diferenciando-se apenas na medida para a identificação da forma da folha, sendo utilizada a solidez. O descritor é representado como:

$$\begin{aligned}
 \text{Descritor}_{\text{folhas estreitas}} \equiv & \left\{ \begin{array}{l} \left[\begin{array}{cccc} g_{11} - r_{11} & g_{12} - r_{12} & \dots & g_{1n} - r_{1n} \\ g_{21} - r_{21} & g_{22} - r_{22} & \dots & g_{2n} - r_{2n} \\ \vdots & \vdots & & \vdots \\ g_{m1} - r_{m1} & g_{m2} - r_{m2} & \dots & g_{mn} - r_{mn} \end{array} \right], \text{ filtro de mediana,} \\ \text{limiarizacao, mapa de textura} \left(\sum_{n=0}^{N_g-1} n^2 \left\{ \sum_i \sum_j p(i, j), \text{ se } |i - j| = n \right\} \right), \\ \text{solidez} \left(\frac{\text{Area do objeto}}{\text{Area do menor poligono convexo}} \right), \text{ correcao de bordas} \left(\frac{\text{Area do contorno dilatado}}{3} \right), \\ \text{correcao de sobreposicao} \left(\frac{(x_1\% + y_1\%) + (x_2\% + y_2\%) + x_3\% + y_4\%}{4} \right) \end{array} \right\} \quad (49)
 \end{aligned}$$

Feitas as considerações sobre a composição do modelo computacional, foi desenvolvida uma ficha para a avaliação da aplicação do método em imagens de campo, onde em cada ficha consta a imagem em questão, com suas propriedades (nome, tamanho e resolução), localização (longitude e latitude), além da caracterização das espécies de plantas invasoras consideradas, uma avaliação de um especialista de campo, o qual indica a ocorrência ou não de plantas das espécies consideradas e as medidas de percentual de ocupação com o método de visão computacional desenvolvido. As figuras de 77 a 108 ilustram respectivamente essas fichas preenchidas para um conjunto de 32 imagens do banco de imagens adquirido em campo.

		Nome: IMG_6562.jpg Tamanho: 600x600 pixels Resolução do pixel: 0,1244mm ²
		Localização Longitude: Latitude:
Caracterização de espécies Planta Invasora de Folha Larga: Leiteira (<i>Euphorbia heterophylla</i> L.) Planta Invasora de Folha Estreita: Capim-Colchão (<i>Digitaria sanguinalis</i> Scop.)		
Avaliador de Campo (Ocorrência ou Não Ocorrência)		Medida de Percentual de Ocupação com Visão Computacional
Folhas Largas	Sim	1,64
Folhas Estreitas	Sim	0,63

Figura 77: Ficha de análise de campo preenchida para IMG_6562.

		Nome: IMG_6564.jpg Tamanho: 600x600 pixels Resolução do pixel: 0,1244mm ²
		Localização Longitude: Latitude:
Caracterização de espécies Planta Invasora de Folha Larga: Leiteira (<i>Euphorbia heterophylla</i> L.) Planta Invasora de Folha Estreita: Capim-Colchão (<i>Digitaria sanguinalis</i> Scop.)		
Avaliador de Campo (Ocorrência ou Não Ocorrência)		Medida de Percentual de Ocupação com Visão Computacional
Folhas Largas	Sim	1,93
Folhas Estreitas	Sim	1,26

Figura 78: Ficha de análise de campo preenchida para IMG_6564.

		Nome: IMG_6573.jpg Tamanho: 600x600 pixels Resolução do pixel: 0,1244mm ²
		Localização Longitude: Latitude:
Caracterização de espécies Planta Invasora de Folha Larga: Leiteira (<i>Euphorbia heterophylla</i> L.) Planta Invasora de Folha Estreita: Capim-Colchão (<i>Digitaria sanguinalis</i> Scop.)		
Avaliador de Campo (Ocorrência ou Não Ocorrência)		Medida de Percentual de Ocupação com Visão Computacional
Folhas Largas	Sim	0,41
Folhas Estreitas	Sim	0,56

Figura 79: Ficha de análise de campo preenchida para IMG_6573.

		Nome: IMG_6585.jpg Tamanho: 600x600 pixels Resolução do pixel: 0,1244mm ²
		Localização Longitude: Latitude:
Caracterização de espécies Planta Invasora de Folha Larga: Leiteira (<i>Euphorbia heterophylla</i> L.) Planta Invasora de Folha Estreita: Capim-Colchão (<i>Digitaria sanguinalis</i> Scop.)		
Avaliador de Campo (Ocorrência ou Não Ocorrência)		Medida de Percentual de Ocupação com Visão Computacional
Folhas Largas	Sim	3,88
Folhas Estreitas	Sim	4,44

Figura 80: Ficha de análise de campo preenchida para IMG_6585.

		Nome: IMG_6592.jpg Tamanho: 600x600 pixels Resolução do pixel: 0,1244mm ²
		Localização Longitude: Latitude:
Caracterização de espécies Planta Invasora de Folha Larga: Leiteira (<i>Euphorbia heterophylla</i> L.) Planta Invasora de Folha Estreita: Capim-Colchão (<i>Digitaria sanguinalis</i> Scop.)		
Avaliador de Campo (Ocorrência ou Não Ocorrência)		Medida de Percentual de Ocupação com Visão Computacional
Folhas Largas	Sim	2,14
Folhas Estreitas	Sim	1,05

Figura 81: Ficha de análise de campo preenchida para IMG_6592.

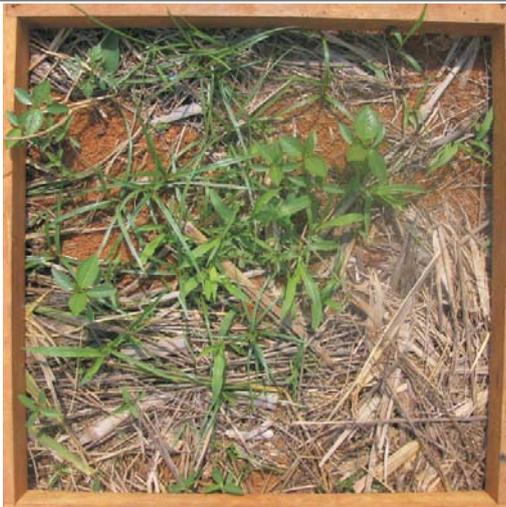
		Nome: IMG_6595.jpg Tamanho: 600x600 pixels Resolução do pixel: 0,1244mm ²
		Localização Longitude: Latitude:
Caracterização de espécies Planta Invasora de Folha Larga: Leiteira (<i>Euphorbia heterophylla</i> L.) Planta Invasora de Folha Estreita: Capim-Colchão (<i>Digitaria sanguinalis</i> Scop.)		
Avaliador de Campo (Ocorrência ou Não Ocorrência)		Medida de Percentual de Ocupação com Visão Computacional
Folhas Largas	Sim	0,92
Folhas Estreitas	Sim	1,05

Figura 82: Ficha de análise de campo preenchida para IMG_6595.

		Nome: IMG_6596.jpg Tamanho: 600x600 pixels Resolução do pixel: 0,1244mm ²
		Localização Longitude: Latitude:
Caracterização de espécies Planta Invasora de Folha Larga: Leiteira (<i>Euphorbia heterophylla</i> L.) Planta Invasora de Folha Estreita: Capim-Colchão (<i>Digitaria sanguinalis</i> Scop.)		
Avaliador de Campo (Ocorrência ou Não Ocorrência)		Medida de Percentual de Ocupação com Visão Computacional
Folhas Largas	Sim	1,50
Folhas Estreitas	Sim	0,91

Figura 83: Ficha de análise de campo preenchida para IMG_6596.

		Nome: IMG_6597.jpg Tamanho: 600x600 pixels Resolução do pixel: 0,1244mm ²
		Localização Longitude: Latitude:
Caracterização de espécies Planta Invasora de Folha Larga: Leiteira (<i>Euphorbia heterophylla</i> L.) Planta Invasora de Folha Estreita: Capim-Colchão (<i>Digitaria sanguinalis</i> Scop.)		
Avaliador de Campo (Ocorrência ou Não Ocorrência)		Medida de Percentual de Ocupação com Visão Computacional
Folhas Largas	Sim	2,49
Folhas Estreitas	Sim	0,30

Figura 84: Ficha de análise de campo preenchida para IMG_6597.

		Nome: IMG_6609.jpg Tamanho: 600x600 pixels Resolução do pixel: 0,1244mm ²
		Localização Longitude: Latitude:
Caracterização de espécies Planta Invasora de Folha Larga: Leiteira (<i>Euphorbia heterophylla</i> L.) Planta Invasora de Folha Estreita: Capim-Colchão (<i>Digitaria sanguinalis</i> Scop.)		
Avaliador de Campo (Ocorrência ou Não Ocorrência)		Medida de Percentual de Ocupação com Visão Computacional
Folhas Largas	Sim	0,12
Folhas Estreitas	Sim	0,10

Figura 85: Ficha de análise de campo preenchida para IMG_6609.

		Nome: IMG_6610.jpg Tamanho: 600x600 pixels Resolução do pixel: 0,1244mm ²
		Localização Longitude: Latitude:
Caracterização de espécies Planta Invasora de Folha Larga: Leiteira (<i>Euphorbia heterophylla</i> L.) Planta Invasora de Folha Estreita: Capim-Colchão (<i>Digitaria sanguinalis</i> Scop.)		
Avaliador de Campo (Ocorrência ou Não Ocorrência)		Medida de Percentual de Ocupação com Visão Computacional
Folhas Largas	Sim	0,47
Folhas Estreitas	Não	0,21

Figura 86: Ficha de análise de campo preenchida para IMG_6610.

		Nome: IMG_6615.jpg Tamanho: 600x600 pixels Resolução do pixel: 0,1244mm ²
		Localização Longitude: Latitude:
Caracterização de espécies Planta Invasora de Folha Larga: Leiteira (<i>Euphorbia heterophylla</i> L.) Planta Invasora de Folha Estreita: Capim-Colchão (<i>Digitaria sanguinalis</i> Scop.)		
Avaliador de Campo (Ocorrência ou Não Ocorrência)		Medida de Percentual de Ocupação com Visão Computacional
Folhas Largas	Sim	0,41
Folhas Estreitas	Não	0,35

Figura 87: Ficha de análise de campo preenchida para IMG_6615.

		Nome: IMG_6616.jpg Tamanho: 600x600 pixels Resolução do pixel: 0,1244mm ²
		Localização Longitude: Latitude:
Caracterização de espécies Planta Invasora de Folha Larga: Leiteira (<i>Euphorbia heterophylla</i> L.) Planta Invasora de Folha Estreita: Capim-Colchão (<i>Digitaria sanguinalis</i> Scop.)		
Avaliador de Campo (Ocorrência ou Não Ocorrência)		Medida de Percentual de Ocupação com Visão Computacional
Folhas Largas	Sim	1,00
Folhas Estreitas	Sim	0,11

Figura 88: Ficha de análise de campo preenchida para IMG_6616.

		Nome: IMG_6617.jpg Tamanho: 600x600 pixels Resolução do pixel: 0,1244mm ²
		Localização Longitude: Latitude:
Caracterização de espécies Planta Invasora de Folha Larga: Leiteira (<i>Euphorbia heterophylla</i> L.) Planta Invasora de Folha Estreita: Capim-Colchão (<i>Digitaria sanguinalis</i> Scop.)		
Avaliador de Campo (Ocorrência ou Não Ocorrência)		Medida de Percentual de Ocupação com Visão Computacional
Folhas Largas	Sim	1,91
Folhas Estreitas	Sim	0,76

Figura 89: Ficha de análise de campo preenchida para IMG_6617.

		Nome: IMG_6618.jpg Tamanho: 600x600 pixels Resolução do pixel: 0,1244mm ²
		Localização Longitude: Latitude:
Caracterização de espécies Planta Invasora de Folha Larga: Leiteira (<i>Euphorbia heterophylla</i> L.) Planta Invasora de Folha Estreita: Capim-Colchão (<i>Digitaria sanguinalis</i> Scop.)		
Avaliador de Campo (Ocorrência ou Não Ocorrência)		Medida de Percentual de Ocupação com Visão Computacional
Folhas Largas	Sim	0,75
Folhas Estreitas	Sim	0,29

Figura 90: Ficha de análise de campo preenchida para IMG_6618.

		Nome: IMG_6619.jpg Tamanho: 600x600 pixels Resolução do pixel: 0,1244mm ²
		Localização Longitude: Latitude:
Caracterização de espécies Planta Invasora de Folha Larga: Leiteira (<i>Euphorbia heterophylla</i> L.) Planta Invasora de Folha Estreita: Capim-Colchão (<i>Digitaria sanguinalis</i> Scop.)		
Avaliador de Campo (Ocorrência ou Não Ocorrência)		Medida de Percentual de Ocupação com Visão Computacional
Folhas Largas	Sim	0,85
Folhas Estreitas	Sim	0,51

Figura 91: Ficha de análise de campo preenchida para IMG_6619.

		Nome: IMG_6620.jpg Tamanho: 600x600 pixels Resolução do pixel: 0,1244mm ²
		Localização Longitude: Latitude:
Caracterização de espécies Planta Invasora de Folha Larga: Leiteira (<i>Euphorbia heterophylla</i> L.) Planta Invasora de Folha Estreita: Capim-Colchão (<i>Digitaria sanguinalis</i> Scop.)		
Avaliador de Campo (Ocorrência ou Não Ocorrência)		Medida de Percentual de Ocupação com Visão Computacional
Folhas Largas	Sim	1,51
Folhas Estreitas	Sim	0,39

Figura 92: Ficha de análise de campo preenchida para IMG_6620.

		Nome: IMG_6621.jpg Tamanho: 600x600 pixels Resolução do pixel: 0,1244mm ²
		Localização Longitude: Latitude:
Caracterização de espécies Planta Invasora de Folha Larga: Leiteira (<i>Euphorbia heterophylla</i> L.) Planta Invasora de Folha Estreita: Capim-Colchão (<i>Digitaria sanguinalis</i> Scop.)		
Avaliador de Campo (Ocorrência ou Não Ocorrência)		Medida de Percentual de Ocupação com Visão Computacional
Folhas Largas	Sim	2,40
Folhas Estreitas	Sim	0,74

Figura 93: Ficha de análise de campo preenchida para IMG_6621.

		Nome: IMG_6622.jpg Tamanho: 600x600 pixels Resolução do pixel: 0,1244mm ²
		Localização Longitude: Latitude:
Caracterização de espécies Planta Invasora de Folha Larga: Leiteira (<i>Euphorbia heterophylla</i> L.) Planta Invasora de Folha Estreita: Capim-Colchão (<i>Digitaria sanguinalis</i> Scop.)		
Avaliador de Campo (Ocorrência ou Não Ocorrência)		Medida de Percentual de Ocupação com Visão Computacional
Folhas Largas	Sim	3,13
Folhas Estreitas	Sim	3,10

Figura 94: Ficha de análise de campo preenchida para IMG_6622.

		Nome: IMG_6628.jpg Tamanho: 600x600 pixels Resolução do pixel: 0,1244mm ²
		Localização Longitude: Latitude:
Caracterização de espécies Planta Invasora de Folha Larga: Leiteira (<i>Euphorbia heterophylla</i> L.) Planta Invasora de Folha Estreita: Capim-Colchão (<i>Digitaria sanguinalis</i> Scop.)		
Avaliador de Campo (Ocorrência ou Não Ocorrência)		Medida de Percentual de Ocupação com Visão Computacional
Folhas Largas	Sim	1,71
Folhas Estreitas	Sim	2,50

Figura 95: Ficha de análise de campo preenchida para IMG_6628.

		Nome: IMG_6629.jpg Tamanho: 600x600 pixels Resolução do pixel: 0,1244mm ²
		Localização Longitude: Latitude:
Caracterização de espécies Planta Invasora de Folha Larga: Leiteira (<i>Euphorbia heterophylla</i> L.) Planta Invasora de Folha Estreita: Capim-Colchão (<i>Digitaria sanguinalis</i> Scop.)		
Avaliador de Campo (Ocorrência ou Não Ocorrência)		Medida de Percentual de Ocupação com Visão Computacional
Folhas Largas	Sim	2,78
Folhas Estreitas	Sim	0,92

Figura 96: Ficha de análise de campo preenchida para IMG_6629.

		Nome: IMG_6630.jpg Tamanho: 600x600 pixels Resolução do pixel: 0,1244mm ²
		Localização Longitude: Latitude:
Caracterização de espécies Planta Invasora de Folha Larga: Leiteira (<i>Euphorbia heterophylla</i> L.) Planta Invasora de Folha Estreita: Capim-Colchão (<i>Digitaria sanguinalis</i> Scop.)		
Avaliador de Campo (Ocorrência ou Não Ocorrência)		Medida de Percentual de Ocupação com Visão Computacional
Folhas Largas	Sim	0,92
Folhas Estreitas	Sim	0,22

Figura 97: Ficha de análise de campo preenchida para IMG_6630.

		Nome: IMG_6631.jpg Tamanho: 600x600 pixels Resolução do pixel: 0,1244mm ²
		Localização Longitude: Latitude:
Caracterização de espécies Planta Invasora de Folha Larga: Leiteira (<i>Euphorbia heterophylla</i> L.) Planta Invasora de Folha Estreita: Capim-Colchão (<i>Digitaria sanguinalis</i> Scop.)		
Avaliador de Campo (Ocorrência ou Não Ocorrência)		Medida de Percentual de Ocupação com Visão Computacional
Folhas Largas	Sim	2,96
Folhas Estreitas	Sim	1,40

Figura 98: Ficha de análise de campo preenchida para IMG_6631.

		Nome: IMG_6632.jpg Tamanho: 600x600 pixels Resolução do pixel: 0,1244mm ²
		Localização Longitude: Latitude:
Caracterização de espécies Planta Invasora de Folha Larga: Leiteira (<i>Euphorbia heterophylla</i> L.) Planta Invasora de Folha Estreita: Capim-Colchão (<i>Digitaria sanguinalis</i> Scop.)		
Avaliador de Campo (Ocorrência ou Não Ocorrência)		Medida de Percentual de Ocupação com Visão Computacional
Folhas Largas	Sim	1,16
Folhas Estreitas	Sim	0,28

Figura 99: Ficha de análise de campo preenchida para IMG_6632.

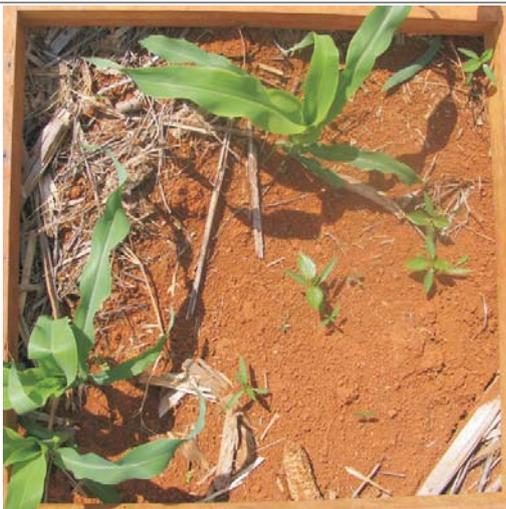
		Nome: IMG_6633.jpg Tamanho: 600x600 pixels Resolução do pixel: 0,1244mm ²
		Localização Longitude: Latitude:
Caracterização de espécies Planta Invasora de Folha Larga: Leiteira (<i>Euphorbia heterophylla</i> L.) Planta Invasora de Folha Estreita: Capim-Colchão (<i>Digitaria sanguinalis</i> Scop.)		
Avaliador de Campo (Ocorrência ou Não Ocorrência)		Medida de Percentual de Ocupação com Visão Computacional
Folhas Largas	Sim	0,46
Folhas Estreitas	Não	0,46

Figura 100: Ficha de análise de campo preenchida para IMG_6633.

		Nome: IMG_6634.jpg Tamanho: 600x600 pixels Resolução do pixel: 0,1244mm ²
		Localização Longitude: Latitude:
Caracterização de espécies Planta Invasora de Folha Larga: Leiteira (<i>Euphorbia heterophylla</i> L.) Planta Invasora de Folha Estreita: Capim-Colchão (<i>Digitaria sanguinalis</i> Scop.)		
Avaliador de Campo (Ocorrência ou Não Ocorrência)		Medida de Percentual de Ocupação com Visão Computacional
Folhas Largas	Sim	0,74
Folhas Estreitas	Sim	0,77

Figura 101: Ficha de análise de campo preenchida para IMG_6634.

		Nome: IMG_6635.jpg Tamanho: 600x600 pixels Resolução do pixel: 0,1244mm ²
		Localização Longitude: Latitude:
Caracterização de espécies Planta Invasora de Folha Larga: Leiteira (<i>Euphorbia heterophylla</i> L.) Planta Invasora de Folha Estreita: Capim-Colchão (<i>Digitaria sanguinalis</i> Scop.)		
Avaliador de Campo (Ocorrência ou Não Ocorrência)		Medida de Percentual de Ocupação com Visão Computacional
Folhas Largas	Sim	2,24
Folhas Estreitas	Sim	1,55

Figura 102: Ficha de análise de campo preenchida para IMG_6635.

	Nome: IMG_6640.jpg Tamanho: 600x600 pixels Resolução do pixel: 0,1244mm ²	
	Localização Longitude: Latitude:	
Caracterização de espécies Planta Invasora de Folha Larga: Leiteira (<i>Euphorbia heterophylla</i> L.) Planta Invasora de Folha Estreita: Capim-Colchão (<i>Digitaria sanguinalis</i> Scop.)		
Avaliador de Campo (Ocorrência ou Não Ocorrência)		Medida de Percentual de Ocupação com Visão Computacional
Folhas Largas	Sim	0,32
Folhas Estreitas	Sim	1,04

Figura 103: Ficha de análise de campo preenchida para IMG_6640.

		Nome: IMG_6641.jpg Tamanho: 600x600 pixels Resolução do pixel: 0,1244mm ²
		Localização Longitude: Latitude:
Caracterização de espécies Planta Invasora de Folha Larga: Leiteira (<i>Euphorbia heterophylla</i> L.) Planta Invasora de Folha Estreita: Capim-Colchão (<i>Digitaria sanguinalis</i> Scop.)		
Avaliador de Campo (Ocorrência ou Não Ocorrência)		Medida de Percentual de Ocupação com Visão Computacional
Folhas Largas	Sim	1,14
Folhas Estreitas	Não	0,30

Figura 104: Ficha de análise de campo preenchida para IMG_6641.

		Nome: IMG_6642.jpg Tamanho: 600x600 pixels Resolução do pixel: 0,1244mm ²
		Localização Longitude: Latitude:
Caracterização de espécies Planta Invasora de Folha Larga: Leiteira (<i>Euphorbia heterophylla</i> L.) Planta Invasora de Folha Estreita: Capim-Colchão (<i>Digitaria sanguinalis</i> Scop.)		
Avaliador de Campo (Ocorrência ou Não Ocorrência)		Medida de Percentual de Ocupação com Visão Computacional
Folhas Largas	Sim	3,40
Folhas Estreitas	Não	2,28

Figura 105: Ficha de análise de campo preenchida para IMG_6642.

		Nome: IMG_6643.jpg Tamanho: 600x600 pixels Resolução do pixel: 0,1244mm ²
		Localização Longitude: Latitude:
Caracterização de espécies Planta Invasora de Folha Larga: Leiteira (<i>Euphorbia heterophylla</i> L.) Planta Invasora de Folha Estreita: Capim-Colchão (<i>Digitaria sanguinalis</i> Scop.)		
Avaliador de Campo (Ocorrência ou Não Ocorrência)		Medida de Percentual de Ocupação com Visão Computacional
Folhas Largas	Sim	0,33
Folhas Estreitas	Sim	0,49

Figura 106: Ficha de análise de campo preenchida para IMG_6643.

		Nome: IMG_6644.jpg Tamanho: 600x600 pixels Resolução do pixel: 0,1244mm ²
		Localização Longitude: Latitude:
Caracterização de espécies Planta Invasora de Folha Larga: Leiteira (<i>Euphorbia heterophylla</i> L.) Planta Invasora de Folha Estreita: Capim-Colchão (<i>Digitaria sanguinalis</i> Scop.)		
Avaliador de Campo (Ocorrência ou Não Ocorrência)		Medida de Percentual de Ocupação com Visão Computacional
Folhas Largas	Sim	2,19
Folhas Estreitas	Sim	0,82

Figura 107: Ficha de análise de campo preenchida para IMG_6644.

		Nome: IMG_6645.jpg Tamanho: 600x600 pixels Resolução do pixel: 0,1244mm ²
		Localização Longitude: Latitude:
Caracterização de espécies Planta Invasora de Folha Larga: Leiteira (<i>Euphorbia heterophylla</i> L.) Planta Invasora de Folha Estreita: Capim-Colchão (<i>Digitaria sanguinalis</i> Scop.)		
Avaliador de Campo (Ocorrência ou Não Ocorrência)		Medida de Percentual de Ocupação com Visão Computacional
Folhas Largas	Sim	4,08
Folhas Estreitas	Sim	1,96

Figura 108: Ficha de análise de campo preenchida para IMG_6645.

A Tabela 8 apresenta uma síntese da análise dos resultados de campo, contendo o nome das imagens, as respectivas informações de ocorrência ou não de plantas de folhas largas e estreitas e os percentuais de ocupação utilizando o método de visão computacional desenvolvido.

Tabela 8: Informações do observador de campo sobre as imagens analisadas e síntese da avaliação das medidas de campo com visão computacional.

	Imagem	FL_{ocorre}	FE_{ocorre}	FL_{metodo}	FE_{metodo}
1	IMG_6562	Sim	Sim	1,64	0,63
2	IMG_6564	Sim	Sim	1,93	1,26
3	IMG_6573	Sim	Sim	0,41	0,56
4	IMG_6585	Sim	Sim	3,88	4,44
5	IMG_6592	Sim	Sim	2,14	1,05
6	IMG_6595	Sim	Sim	0,92	1,05
7	IMG_6596	Sim	Sim	1,50	0,91
8	IMG_6597	Sim	Sim	2,49	0,30
9	IMG_6609	Sim	Sim	0,12	0,10
10	IMG_6610	Sim	Não	0,47	0,21
11	IMG_6615	Sim	Não	0,41	0,35
12	IMG_6616	Sim	Sim	1,00	0,11
13	IMG_6617	Sim	Sim	1,91	0,76
14	IMG_6618	Sim	Sim	0,75	0,29
15	IMG_6619	Sim	Sim	0,85	0,51
16	IMG_6620	Sim	Sim	1,51	0,39
17	IMG_6621	Sim	Sim	2,40	0,74
18	IMG_6622	Sim	Sim	3,13	3,10
19	IMG_6628	Sim	Sim	1,71	2,50
20	IMG_6629	Sim	Sim	2,78	0,92
21	IMG_6630	Sim	Sim	0,92	0,22
22	IMG_6631	Sim	Sim	2,96	1,40
23	IMG_6632	Sim	Sim	1,16	0,28
24	IMG_6633	Sim	Não	0,46	0,46
25	IMG_6634	Sim	Sim	0,74	0,77
26	IMG_6635	Sim	Sim	2,24	1,55
27	IMG_6640	Sim	Sim	0,32	1,04
28	IMG_6641	Sim	Não	1,14	0,30
29	IMG_6642	Sim	Não	3,40	2,28
30	IMG_6643	Sim	Sim	0,33	0,49
31	IMG_6644	Sim	Sim	2,19	0,82
32	IMG_6645	Sim	Sim	4,08	1,96

Conforme observado, a visão natural do observador de campo apresentou 100% de ocorrência de folhas largas nas imagens analisadas e 84,36% para as plantas de folhas estreitas. Entretanto, o método desenvolvido encontrou medidas tanto de folhas largas como folhas estreitas para todas as imagens, o que indica um possível erro na identificação visual do observador de campo, uma vez que o método foi validado com padrões

pré-estabelecidos. O erro de identificação visual foi atribuído aos casos onde as plantas eram muito pequenas e não foi dada importância as mesmas por parte do observador de campo e também aos casos onde as folhas estavam no meio da palha, não permitindo sua identificação pela visão natural. Como o método proposto exclui a palha, juntamente com o solo, na etapa do pré-processamento, essas plantas não foram confundidas, sendo consideradas nos cálculos, o que é relevante para o processo de controle das plantas invasoras.

Outro aspecto a considerar é que o erro devido ao trabalho de bordas, somado ao erro de possíveis sobreposições, erro médio atribuído, poderia ser considerado a maior ou a menor junto aos resultados obtidos, uma vez que o mesmo foi diretamente somado a atribuição de área no ambiente de campo.

É importante ressaltar que as medidas de comparação são calculadas visando fornecer um auxílio ao agricultor para que o mesmo possa observar a ocorrência dos dois tipos de plantas invasoras, para que as medidas necessárias de controle sejam tomadas. Tais medidas envolvem a aplicação de herbicidas a taxa variável por meio do mapeamento da área de infestação no campo de produção, para melhorar a eficiência agrícola, reduzindo os custos e o impacto ambiental derivado da aplicação indiscriminada deste tipo de defensivo.

Conclusões

Foi apresentado neste trabalho o desenvolvimento de descritores de imagens para o reconhecimento de padrões de plantas invasoras e percentual de área de ocupação de folhas largas e folhas estreitas em área de produção agrícola. Assim, com base nos resultados apresentados e discutidos é possível concluir que:

1. Na etapa de pré-processamento, a utilização de um filtro da mediana viabilizou a uniformização dos valores de intensidade das folhas de plantas presentes na imagem, o que permitiu a limiarização das imagens, eliminando as informações de fundo, restando apenas as áreas pertencentes as folhas.
2. Na segmentação baseada em textura, o uso da informação de contraste foi adequado e discriminativo tanto em nível dos padrões geométricos, utilizados para a calibração, como para a atribuição e organização de mapas de textura das plantas presentes nas imagens adquiridas diretamente no campo agrícola. Adicionalmente, este método de segmentação se mostrou capaz de identificar corretamente as folhas das plantas invasoras, excluindo as folhas do milho, apesar de sua dependência ao tamanho do objeto, o que era esperado, uma vez que a área das regiões é considerada para o cál-

- culo do mapa de textura das folhas, o que pode necessitar uma normalização quando se buscar caracterizar um maior número de diferentes espécies de plantas em um ambiente de análise.
3. O uso da dilatação das bordas permitiu o fechamento das figuras geométricas de interesse, a exemplo das próprias folhas de plantas invasoras, quando sobrepostas com outros elementos do ambiente real, ou mesmo entre elas. Entretanto, se fez necessário atribuir correção nas medidas finais de forma a compensar o efeito não linear da operação de dilatação no processamento das imagens, o que ocasionou perda de área dos objetos de interesse, influenciando diretamente os resultados o que exigiu o estabelecimento de um fator de correção para ajuste no valor final do percentual de área de ocupação.
 4. Com base na análise feita com padrões geométricos, sobre o erro devido à sobreposição de padrões de folhas invasoras, o descritor geométrico de alongação foi o que apresentou melhor identificação para o padrão que representava as folhas largas na situação onde havia sobreposição de folhas largas e folhas estreitas. O descritor de redondez foi o que apresentou melhor identificação, para os padrões que representaram ambos os tipos de folhas em situações onde havia apenas sobreposição de folhas de mesmo tipo. Desta forma estabeleceu-se um fator de correção devido ao efeito de sobreposição de folhas o qual corrigiu satisfatoriamente as imagens analisadas.
 5. A validação do método de reconhecimento de plantas invasoras, que foi realizada, em um campo experimental da cultura do milho na unidade da Embrapa Milho e Sorgo (Sete Lagoas/MG), obteve um resultado significativo, visto que para folhas largas foi obtido um coeficiente de correção linear de 0,8424, representando assim uma taxa de acerto de 84,24% e para as folhas estreitas, foi obtido um coeficiente de correlação linear de 0,8017, representando assim uma taxa de acerto de 80,17%.
 6. Quanto a confirmação ou não com base em visão natural da ocorrência de plantas invasoras, o método baseado em visão computacional permitiu a identificação de plantas invasoras em locais restritos a visão natural de ocorrência de plantas invasoras em um campo de produção agrícola.

Desta forma, conclui-se que o método desenvolvido pode ser aplicado no âmbito da agricultura de precisão, podendo direccionar mapas para a aplicação de herbicidas a taxa variável, em função do percentual de ocupação de uma área considerada, adicionado ao aspecto de qualificar aplicações específicas para plantas invasoras de folhas largas e plantas invasoras de folhas estreitas.

Referências Bibliográficas

- AHMED, I.; ISLAM, M.; ADNAN, A. A real-time specific weed recognition system by measuring weeds density through mask operation. **Innovations and Advanced Techniques in Systems, Computing Sciences and Software Engineering**, p. 221, 2008.
- ALVES, E.; PINTO, F.; MANTOVANI, E.; SENA JÚNIOR, D. Avaliação de parâmetros de textura para classificação de plantas daninhas em imagens digitais. **XXXI Congresso Brasileiro de Engenharia Agrícola - CONBEA 2002**, 2002.
- ANDRADE, M.; PINTO, L. Classificação de folhas por tamanho e forma através de descritores geométricos e análise dos componentes principais. **IV Workshop em Tratamento de Imagens**, 2002.
- BAIO, F.; BALASTREIRE, L. Avaliação de um sistema para aplicação localizada de defensivos baseado na variabilidade espacial das plantas daninhas. **Engenharia Agrícola**. v. 23, n. 2, p. 316-325, 2003.
- BASSET, O.; BUQUET, B.; ABOUELKARAM, S.; DELACHARTRE, P.; CULIOLI, J. Application of texture image analysis for the classification of bovine meat. **Food Chemistry**. v. 69, n. 4, p. 437-445, 2000.
- BAXES, G. **Digital image processing: principles and applications**. John Wiley & Sons, Inc. New York, NY, USA, 1994.

- BILLY, L.; ARVISENET, G.; POINOT, P.; CHEVALLIER, S.; ROYER, G.; VIGNEAU, E.; PROST, C. Image texture analysis of apples broken down in a mastication simulator prototype. **IUFOST – 13th World Congress of Food Sciences Technology**, p. 775–782, 2006.
- BORG, I.; GROENEN, P. Modern multidimensional scaling: Theory and applications. **Journal of Educational Measurement**. v. 40, n. 3, p. 277–280, 2003.
- BRESSAN, G.; KOENIGKAN, L.; OLIVEIRA, V.; CRUVINEL, P. Sistema de classificação fuzzy para o risco de infestação por plantas daninhas considerando a sua variabilidade espacial. **Planta Daninha**. v. 24, p. 229–238, 2006.
- BRESSAN, G.; KOENIGKAN, L.; OLIVEIRA, V.; CRUVINEL, P.; KARAM, D. A classification methodology for the risk of weed infestation using fuzzy logic. **Weed Research**. v. 48, n. 5, p. 470–479, 2008.
- BROWN, R.; NOBLE, S. Site-specific weed management: sensing requirements—what do we need to see? **Weed Science**. v. 53, n. 2, p. 252–258, 2005.
- BROWN, R.; STECKLER, J. Prescriptions maps for spatially variable herbicide application in no-till corn. **Transactions of the ASAE**. v. 38, n. 6, p. 1659–1666, 1995.
- BURKS, T.; SHEARER, S.; PAYNE, F. **Evaluation of statistical discriminant analysis techniques for classification of weed species using machine vision**, 1998. Relatório técnico.
- CAMARGO NETO, J.; MEYER, G.; JONES, D. Identificação de espécies de plantas utilizando elíptica de fourier para aplicação localizada e a taxas variadas de herbicida. **3º Simpósio Internacional de Agricultura de precisão**, 2005.
- CHANCELLOR, W.; GORONEA, M. Effects of spatial variability of nitrogen, moisture and weeds on the advantages of site-specific applications for wheat. **Transactions of the ASAE**. v. 37, n. 3, p. 717–724, 1994.
- CONCI, A.; AZEVEDO, E.; LETA, F. **Computação Gráfica-Teoria e Prática, volume 2**. Elsevier Editora, 2008.

- COSTA, L.; CESAR, R. **Shape Analysis and Classification: Theory and Practice**. Boca Raton, FL: CRC Press, 2001.
- CRUVINEL, P.; SUZUMURA FILHO, Y.; MANTOVANI, E. Análise da qualidade da aplicação georeferenciada de chuva artificial em área de plantio com visão computacional e rede neural. **XXXV Congresso Brasileiro de Engenharia Agrícola - CONBEA 2006**, 2006.
- CRUVINEL, P.; VIEIRA, S.; CRESTANA, S.; MINATEL, E.; MUCHERONI, M.; NETO, A. Image processing in automated measurements of raindrop size and distribution. **Computers and Electronics in Agriculture**. v. 23, n. 3, p. 205–217, 1999.
- DE-HUI, K.; BAO-CAI, Y.; YAN, L.; YUN-HUI, S. A rapid texture synthesis algorithm based on clustering preprocessing. **IJCSNS – International Journal of Computer Science and Network Security**. v. 6, n. 6, p. 85, 2006.
- DUDA, R.; HART, P.; STORK, D. **Pattern Classification**. Wiley–Interscience, 2000.
- EL-FAKI, M.; ZHANG, N.; PETERSON, D. Factors affecting color-based weed detection. **Transactions of the ASAE**. v. 43, n. 4, p. 1001–1009, 2000a.
- EL-FAKI, M.; ZHANG, N.; PETERSON, D. Weed detection using color machine vision. **Transactions of the ASAE**. v. 43, n. 6, p. 1969–1978, 2000b.
- FAN, G.; ZHANG, N.; PETERSON, D.; LOUGHIN, T. Real-time weed detection using machine vision. **The 1998 ASAR Annual International Meeting**, n. 98032, 1998.
- FELTON, W.; DOSS, A.; NASH, P.; McCLOY, K. A microprocessor controlled technology to selectively spot spray weeds. **Proceedings of the Automated Agricultural for the 21st Century Symposium**, p. 427–432, 1991.
- FRIEDMAN, J. Exploratory projection pursuit. **Journal of the American Statistical Association**. v. 82, n. 397, p. 249–266, 1987.
- FRIEDMAN, M.; KANDEL, A. **Introduction to Pattern Recognition: Statistical, Structural, Neural and Fuzzy Logic Approaches**. World Scientific, 1999.
- FUKUNAGA, K. **Introduction to Statistical Pattern Recognition**. Academic Press, 1990.

- GOEL, P.; PRASHER, S.; PATEL, R.; DITOMMASO, A. and SMITH, D. Airborne optical remote sensing for detection of weed infestation in site specific management of field crops. **The 2000 ASAE Annual International Meeting**, n. paper nº 003056, p. 13, 2000.
- GONZALEZ, R.; WOODS, R. **Digital Image Processing**. Addison-Wesley Publishing Company, 1992.
- GRANITTO, P.; VERDES, P.; CECCATTO, H. Automatic identification of weed seeds. **JAIIO 2003, 32^o International Conference of the Argentine Computer Science and Operational Research Society**, 2003.
- HARALICK, R. Statistical and structural approaches to texture. **Proceedings of the IEEE**. v. 67, n. 5, p. 786-804, 1979.
- HARALICK, R.; SHANMUGAM, K.; DINSTEN, I. Textural features for image classification. **IEEE Transactions on Systems, Man and Cybernetics**. v. 3, n. 6, p. 610-621, 1973.
- HEMMING, J.; RATH, T. Pa - precision agriculture computer-vision-based weed identification under field conditions using controlled lighting. **Journal of Agricultural Engineering Research**. v. 78, n. 3, p. 233-243, 2001.
- HOUAISS. **Dicionário eletrônico Houaiss da língua portuguesa**. Editora Objetiva, 2001.
- HU, M. Visual pattern recognition by moment invariants. **IRE Transactions on Information Theory**. v. 8, n. 2, p. 179-187, 1962.
- IAC. **Plantio Direto - Caminho para a Agricultura Sustentável**.
<http://www.iac.sp.gov.br/Tecnologias/PlantioDireto/PlantioDireto.htm>
Último acesso: Março/2009.
- JAIN, A. **Fundamentals of Digital Image Processing**. Prentice-Hall, Inc. Upper Saddle River, NJ, USA, 1989.
- JAIN, A.; DUIN, R.; MAO, J. Statistical pattern recognition: A review. **IEEE Transactions on Pattern Analysis and Machine Intelligence**. v. 22, n. 1, p. 4-37, 2000.
- KARAM, D. Manejo de plantas daninhas na sustentabilidade agrícola. **Revista Campo & Negócios, Uberlândia**. v. 5, n. 63, p. 19, 2008.

- KARIMI, Y.; PRASHER, S.; PATEL, R.; KIM, S. Application of support vector machine technology for weed and nitrogen stress detection in corn. **Computers and Electronics in Agriculture**. v. 51, n. 1-2, p. 99-109, 2006.
- KOHONEN, T. **Self-Organizing Maps**. Springer, 2001.
- LAMB, D.; BROWN, R. Pa - precision agriculture remote-sensing and mapping of weeds in crops. **Journal of Agricultural Engineering Research**. v. 78, n. 2, p. 117-125, 2001.
- LEE, T. **Independent component analysis: theory and applications**. Kluwer Academic Publishers Hingham, MA, USA, 1998.
- LEE, W.; SLAUGHTER, D. Plant recognition using hardware-based neural network. **ASAE (American Society of Agricultural Engineers)**, p. 98-3040, 1998.
- LEE, W.; SLAUGHTER, D.; GILES, D. Robotic weed control system for tomatoes. **Precision Agriculture**. v. 1, n. 1, p. 95-113, 1999.
- MANH, A.; RABATEL, G.; ASSEMAT, L.; ALDON, M. Weed leaf image segmentation by deformable templates. **Journal of Agricultural Engineering Research**. v. 80, n. 2, p. 139-146, 2001.
- MANTOVANI, E. Avanços na pesquisa sobre agricultura de precisão no Brasil. **Congresso Nacional de Milho e Sorgo**, 2002.
- MAO, W.; HU, X.; ZHANG, X. Weed detection based on the optimized segmentation line of crop and weed. In: Computer and Computing Technologies in Agriculture: First IFIP WG 12.5 International Conference on Computer and Computing Technologies in Agriculture (CCTA2007) Wuyishan, China, August 18-20, 2007, 2008., 2008.
- MARQUES FILHO, O.; VIEIRA NETO, H. **Processamento Digital de Imagens**. Brasport, Rio de Janeiro, 1999.
- NORDMEYER, H.; HÄUSLER, A.; NIEMANN, P. Patchy weed control as an approach in precision farming. **Precision Agriculture**. v. 1, p. 307-314, 1997.
- NUNES, E.; CONCI, A. Segmentação por textura e localização do contorno de regiões em imagens multibandas. **IEEE Latin America Transactions**. v. 5, n. 3, p. 185-192, 2007.

- NUSPL, S.; RUDOLPH, W.; GUTHLAND, R. Use of injection for site-specific chemical application. In: Proceedings of the Third International Conference on Precision Agriculture, Minneapolis, 26.6, 1996., 1996.
- PARK, B.; CHEN, Y.; NGUYEN, M. Multi-spectral image analysis using neural network algorithm for inspection of poultry carcasses. **Journal of Agricultural Engineering Research**. v. 69, n. 4, p. 351-363, 1998.
- PÉREZ, A.; LÓPEZ, F.; BENLLOCH, J.; CHRISTENSEN, S. Colour and shape analysis techniques for weed detection in cereal fields. **Computers and Electronics in Agriculture**. v. 25, n. 3, p. 197-212, 2000.
- PINTO, F.; SENA JR, D.; QUEIROZ, D.; GOMIDE, R. Visão artificial na agricultura de precisão. **Avanços na Agricultura de Precisão no Brasil no período**. v. 2001, p. 309-316, 1999.
- PIRES, J.; CUNHA, G. d.; PASINATO, A.; FRANÇA, S.; RAMBO, L. Discutindo agricultura de precisão - aspectos gerais. (**Embrapa Trigo. Documentos Online, 42**), p. 18, 2004.
- PITAS, I. **Digital Image Processing Algorithms**. Prentice-Hall, Inc. Upper Saddle River, NJ, USA, 1993.
- PRATT, W. **Digital image processing**. Wiley, New York, 1991.
- RAUDYS, S.; JAIN, A. Small sample size effects in statistical pattern recognition: recommendations for practitioners. **IEEE Transactions on Pattern Analysis and Machine Intelligence**. v. 13, n. 3, p. 252-264, 1991.
- RAUDYS, S.; PIKIALIS, V. On dimensionality, sample size, classification error, and complexity of classification algorithm in pattern recognition. **IEEE Transactions on Pattern Analysis and Machine Intelligence**. v. 2, p. 242-252, 1980.
- RIBEIRO JR, E. **Análise de atributos visuais em imagens texturais utilizando técnicas espectrais**. Dissertação (Mestrado) - Universidade Federal de São Carlos, 1995.
- RUSS, J. **The Image Processing Handbook**. CRC Press, 2006.
- SLAUGHTER, D.; GILES, D.; DOWNEY, D. Autonomous robotic weed control systems: A review. **Computers and Electronics in Agriculture**. v. 61, n. 1, p. 63-78, 2008.

- SØGAARD, H. Weed classification by active shape models. **Biosystems Engineering**, v. 91, n. 3, p. 271-281, 2005.
- SØGAARD, H.; LUND, I. Application accuracy of a machine vision-controlled robotic micro-dosing system. **Biosystems Engineering**, v. 96, n. 3, p. 315-322, 2007.
- SÖKEFELD, M.; GERHARDS, R. Automatic weed mapping using digital image processing. **Landtechnik**, v. 59, n. 3, p. 156-157, 2004.
- SONKA, M.; HLAVAC, V.; BOYLE, R. **Image processing Analysis, and Machine Vision**. Brooks/Cole Publishing Company, 1998.
- SPG. **Soluções em Posicionamento Global - DGPS**.
http://www.spg.com.br/informacoes/artigos_gps/dgpsinfo.htm. Último acesso: Março/2009.
- STEIN, T. **Avaliação de descritores de textura para segmentação de imagens**. Dissertação (Mestrado) - Universidade Federal do Paraná, 2005.
- STEWART, B.; TIAN, L. Real-time machine vision weed-sensing. **ASAE Annual International Meeting**, 1998.
- SU, M.; TIAN, L.; REID, J. Spatial-frequency analysis for detection of weed-infestation areas with the wavelet decomposition. **Transactions of the ASAE**, 1999.
- TANG, L.; TIAN, L.; STEWARF, B.; REID, J. Texture-based weed classification using gabor wavelets and neural network for real-time selective herbicide applications. **Urbana**, v. 51, 1999.
- THEODORIDIS, S.; KOUTROUMBAS, K. **Pattern recognition**. Academic press, 2003.
- TIAN, L.; REID, J.; HUMMEL, J. Development of a precision sprayer for site-specific weed management. **Transactions-American Society of Agricultural Engineers**, v. 42, p. 893-902, 1999.
- TSCHIEDEL, M.; FERREIRA, M. Introdução à agricultura de precisão: conceitos e vantagens. **Ciência Rural**, v. 32, n. 1, 2002.

- TUCERYAN, M.; JAIN, A. Texture analysis. **Handbook of Pattern Recognition and Computer Vision (2nd Edition)**, p. 207-248, 1998.
- UL HAQ, M.; NAEEM, A.; AHMAD, I.; ISLAM, M. Radon transform based real-time weed classifier. **Proceedings of the Computer Graphics, Imaging and Visualisation (CGIV 2007)-Volume 00**, p. 245-249, 2007.
- VOLL, E.; GAZZIERO, D.; BRIGHENTI, A.; ADEGAS, F.; GAUDÊNCIO, C. d. A.; VOLL, C. **A dinâmica das plantas daninhas e práticas de manejo**, 2005. Relatório técnico.
- WANG, N.; DOWELL, F.; SUN, Y.; PETERSON, D. Testing of a spectral-based weed sensor. **American Society of Agricultural Engineers**, 2000.
- WANG, Z.; CHI, Z.; FENG, D. Shape based leaf image retrieval. **IEE Proceedings-Vision, Image and Signal Processing**. v. 150, n. 1, p. 34-43, 2003.
- WEBB, A. **Statistical pattern recognition**. John Willey & Sons, 2002.
- WILLIS, D.; STOLLER, E. Weed suppression for vegetation management in corn and soybeans. In: *Proceedings North Central Weed Science Society*, 9, 1990., 1990.
- WOEBBECKE, D.; MEYER, G.; VON BARGEN, K.; MORTENSEN, D. Shape features for identifying young weeds using image analysis. **Transactions of the ASAE**. v. 38, n. 1, p. 271-281, 1995.
- YONEKAWA, S.; SAKAI, N.; KITANI, O. Identification of idealized leaf types using simple dimensionless shape factors by image analysis. **Transactions of the ASAE**. v. 39, n. 4, p. 1525-1533, 1996.
- YOU GUO, P.; HUAILIN, S.; TIANCAI, L. The frame of cognitive pattern recognition. In: *Control Conference, 2007. CCC 2007. Chinese, 2007.*, 2007. p. 694-696.