

UNIVERSIDADE ESTADUAL DE PONTA GROSSA
MESTRADO EM COMPUTAÇÃO APLICADA

MARINALDO JOSÉ GASPARETO

SELEÇÃO DE ATRIBUTOS EM IMAGENS COLETADAS SOB CONDIÇÕES DE
ILUMINAÇÃO NÃO CONTROLADA E SUA INFLUÊNCIA NO DESEMPENHO DE
CLASSIFICADORES *NAIVE BAYES* PARA IDENTIFICAÇÃO DE OBJETOS EM
ESTUFAS AGRÍCOLAS

PONTA GROSSA
2013

MARINALDO JOSÉ GASPARETO

SELEÇÃO DE ATRIBUTOS EM IMAGENS COLETADAS SOB CONDIÇÕES DE
ILUMINAÇÃO NÃO CONTROLADA E SUA INFLUÊNCIA NO DESEMPENHO DE
CLASSIFICADORES *NAIVE BAYES* PARA IDENTIFICAÇÃO DE OBJETOS EM
ESTUFAS AGRÍCOLAS

Dissertação apresentada ao Programa de Pós-Graduação em Computação Aplicada – Área de concentração Computação para Tecnologias em Agricultura – Universidade Estadual de Ponta Grossa como requisito para obtenção do título de Mestre em Computação Aplicada.

Orientador: Prof. Dr. José Carlos Ferreira da Rocha.

Co-Orientador: Prof. Dr. Alceu Britto de Souza Júnior

PONTA GROSSA
2013

Ficha Catalográfica
Elaborada pelo Setor de Tratamento da Informação BICEN/UEPG

G249 Gaspareto, Marinaldo José
Seleção de atributos em imagens
coletadas sob condições de iluminação não
controlada e sua influência no desempenho
de Classificadores Naive Bayes para
identificação de objetos em estufas
agrícolas/ Marinaldo José Gaspareto. Ponta
Grossa, 2014.
57f.

Dissertação (Mestrado em Computação
Aplicada - Área de Concentração:
Computação para Tecnologias em
Agricultura), Universidade Estadual de
Ponta Grossa.

Orientador: Prof. Dr. José Carlos
Ferreira da Rocha.

Co-Orientador: Prof. Dr. Alceu Britto
de Souza Júnior.

1.Estufas agrícolas. 2.Navegação
autônoma. 3.Seleção de atributos.
4.Classificadores Naive Bayes. I.Rocha,
José Carlos Ferreira da. II. Souza
Júnior, Alceu Britto de. III. Universidade
Estadual de Ponta Grossa. Mestrado em
Computação Aplicada. IV. T.

CDD: 004

TERMO DE APROVAÇÃO

Marinaldo José Gaspareto

**“SELEÇÃO DE ATRIBUTOS EM IMAGENS COLETADAS SOB
CONDIÇÕES DE ILUMINAÇÃO NÃO CONTROLADA E SUA INFLUÊNCIA NO
DESEMPENHO DE CLASSIFICADORES NAIVE BAYES PARA IDENTIFICAÇÃO
DE OBJETOS EM ESTUFAS AGRÍCOLAS”.**

Dissertação aprovada como requisito parcial para obtenção do grau de Mestre no Programa de Pós-Graduação em Computação Aplicada da Universidade Estadual de Ponta Grossa, pela seguinte banca examinadora:

Orientador:


Dr. José Carlos Ferreira da Rocha
UEPG


Dr.ª Alaine Margarete Guimarães
UEPG

Dr. Daniel Poletto Tesser
UTFPR

Ponta Grossa, 10 de setembro de 2013.

Dedico à “baixinha” pelo esforço, dedicação e compreensão, em todos os momentos desta e de outras caminhadas.

AGRADECIMENTOS

A Deus, pelo dom da vida, sem a qual não estaria concluindo este curso.

A minha esposa, pelo apoio e carinho nas horas que mais precisei.

À minha família, pelo apoio irrestrito, mesmo nas horas mais difíceis, sempre me incentivando e apoiando de todas as formas possíveis.

Ao meu orientador e amigo Prof. Dr. José Carlos Ferreira da Rocha, pelas contribuições e orientações desta dissertação, mas acima de tudo pela oportunidade dada à minha pessoa.

Ao meu co-orientador Prof^o. Dr. Alceu de Brito Júnior, pela disposição e colaboração no desenvolvimento deste trabalho, em especial pela contribuição no Processamento Digital de Imagens.

A todos os professores e amigos da UEPG, os quais compartilharam as alegrias e tristezas durante esta caminhada, que de alguma forma contribuíram para minha formação acadêmica, em especial, Fabricio, Gustavo, Karine e Juscelino que me auxiliaram em muitos momentos no decorrer desses dois anos de estudo.

Por mais longa que seja a caminhada o mais importante é dar o
primeiro passo.
(Vinicius de Moraes)

RESUMO

Um problema relativo à implementação de sistemas de navegação para robôs autônomos móveis é a detecção dos objetos de interesse e dos obstáculos que estão no ambiente. Este trabalho considera a detecção das paredes/muretas de estufas agrícolas em imagens digitais adquiridas sem controle de iluminação. A abordagem proposta emprega técnicas de processamento digital de imagens e classificação digital para detectar o objeto de interesse. O classificador digital desenvolvido foi do tipo *Naive Bayes*. Duas questões importantes quando do emprego de métodos de classificação em visão computacional são a acurácia do classificador e a complexidade de tempo de computação. A seleção dos atributos descritores que compõem um classificador tem grande impacto sobre estes dois fatores, de um modo geral, quanto menos atributos forem necessários, menor o custo computacional. Considerando isso, este trabalho comparou o desempenho de dois métodos de seleção de atributos baseados na análise de componentes principais, chamados B2 e B4 em duas situações. Na primeira situação, a seleção de atributos foi realizada sobre o conjunto dos dados extraídos de todas as imagens. Na segunda, a seleção foi realizada para imagens agrupadas por similaridade. Após a seleção, os atributos selecionados em cada uma das abordagens foram usados para construir classificadores do tipo *Naive Bayes* com 12, 17, 22 e 27 variáveis de entrada. Os resultados indicam que o agrupamento de imagens é útil quando: (a) a distância do centro do grupo ao centro da base original ultrapassa um limiar e (b) a correlação entre as variáveis descritoras e a variável meta é maior no grupo do que no conjunto completo de dados.

Palavras Chave: Estufas agrícolas, Navegação autônoma, Seleção de atributos, Classificadores *Naive Bayes*.

ABSTRACT

A problem regarding the implementation of navigation systems for autonomous moving robots is to detect the objects of interest and obstacles which are in the environment. This study considers the detection of walls / low walls of agricultural greenhouses in digital images obtained without illumination control. The proposed approach employs techniques of digital image processing and digital classification to detect the object of interest. The classifier has been developed digital type Naive Bayes. Two important issues when employing classification methods in computer vision is the accuracy of the classifier and the complexity of computing time. The selection of attributes descriptors that comprise a classifier has great impact on these two factors, generally the fewer attributes are required, the lower the computational cost. Regarding it, this study compared the performance of two methods of feature selection based on principal component analysis, named B2 and B4 in two cases. In the first scenario the feature selection was conducted on all the data extracted from all images. The second selection was performed for images grouped by similarity. After selection, the selected attributes for each approach was used to construct the type Naive Bayes classifier with 12, 17, 22 and 27 input variables. The results indicate that the grouping of images is useful when: (a) the distance from the center of the group to the center of the original database exceeds a threshold and (b) a correlation among the descriptors variables and the target variable is greater than in the group as a whole complete data.

Keywords: Greenhouses, Autonomous navigation, Selection attributes, Naive Bayes classifiers.

LISTA DE ILUSTRAÇÕES

Figura 1- Imagem do interior de uma estufa agrícola.....	16
Figura 2- Estufa agrícola	19
Figura 3-Estrutura do sistema de visão baseada no conhecimento (SUCAR e GILIES, 1994).....	27
Figura 4- Um classificador <i>Naive Bayes</i> descrito como uma rede bayesiana na qual os atributos preditivos ($A_1, A_2, \dots, A_i$) são condicionalmente independentes dada classe (C) (JOHN e LANGLEY, 1995).....	29
Figura 5- Planta baixa da estufa.....	34
Figura 6- Imagens da estufa utilizada neste trabalho, sendo uma imagem externa e uma interna, respectivamente	34
Figura 7- Divisão da imagem em segmentos	35
Figura 8- Exemplo de imagem grupo 1, (a) Imagem mais próxima do centroide do grupo, (b) Imagem mais distante do centroide do grupo	36
Figura 9- Exemplo de imagem grupo 2, (a) Imagem mais próxima do centroide do grupo, (b) Imagem mais distante do centroide do grupo	36
Figura 10 - Exemplo de imagem grupo 2, (a) Imagem mais próxima do centroide do grupo, (b) Imagem mais distante do centroide do grupo	37
Figura 11- Exemplo de imagem grupo 4, (a) Imagem mais próxima do centroide do grupo, (b) Imagem mais distante do centroide do grupo	37
Figura 12 - Exemplo de imagem grupo 5, (a) Imagem mais próxima do centroide do grupo, (b) Imagem mais distante do centroide do grupo	37
.....	37
Figura 13- Exemplo de imagem grupo 6, (a) Imagem mais próxima do centroide do grupo, (b) Imagem mais distante do centroide do grupo	38
Gráfico 1: Acurácia, Acurácia Balanceada e <i>Informedness</i> usando todos os atributos	43
Gráfico 2- (a) Acurácia balanceada (b) <i>Informedness</i> , grupo 2, método B2.....	44
Gráfico 3- (a) Acurácia balanceada (b) <i>Informedness</i> , grupo 2, método B4.....	44
Gráfico 4- (a) Acurácia balanceada (b) <i>Informedness</i> , grupo 6, método B2.....	45
Gráfico 5- (a) Acurácia balanceada (b) <i>Informedness</i> , grupo 6, método B4.....	45
Gráfico 6- (a)Acurácia balanceada (b) <i>Informedness</i> , grupo 1, método B2.....	47

Gráfico 7- (a) Acurácia balanceada (b) <i>Informedness</i> , grupo 1, método B4.....	47
Gráfico 8- (a) Acurácia balanceada (b) <i>Informedness</i> , grupo 3, método B2.....	48
Gráfico 9- (a) Acurácia balanceada (b) <i>Informedness</i> , grupo 3, método B4.....	48
Gráfico 10- (a) Acurácia balanceada (b) <i>Informedness</i> , grupo 4, método B2.....	49
Gráfico 11- (a) Acurácia balanceada (b) <i>Informedness</i> , grupo 4, método B4.....	49
Gráfico 12- (a) Acurácia balanceada (b) <i>Informedness</i> , grupo 5, método B2.....	50
Gráfico 13- (a) Acurácia balanceada (b) <i>Informedness</i> , grupo 5, método B4.....	50

LISTA DE TABELAS

Tabela 1- Distribuição do conjunto de imagens em grupos de imagens similares	36
Tabela 2 - Distribuição das variáveis conforme a correlação das variáveis com a classe.	39
Tabela 3- Distribuição das variáveis pós corte por correlação abaixo de 0,02	40
Tabela 4- Índices de Acurácia Balanceada e <i>Informedness</i> grupos(1, 2, 3, 4, 5, 6).	42
Tabela 5- Resultados grupo 2	44
Tabela 6- Resultados grupo 6	45
Tabela 7 - Resultados grupo 1	47
Tabela 8- Resultados grupo 3	48
Tabela 9- Resultados grupo 4	49
Tabela 10- Resultados grupo 5	50

SUMÁRIO

1. INTRODUÇÃO	14
2. REVISÃO BIBLIOGRÁFICA	18
2.1. ESTUFAS AGRÍCOLAS E ROBÔS AGRÍCOLAS.....	18
2.2. VISÃO COMPUTACIONAL	20
2.2.1. EXTRAÇÃO DE CARACTERÍSTICAS	21
2.2.1.1. Cor	22
2.2.1.2. Textura	23
2.2.2. Interpretação de imagens e modelos baseados em conhecimento	26
2.2.2.1. Interpretação de imagens usando classificadores bayesianos.....	28
2.3. SELEÇÃO DE ATRIBUTOS.....	30
2.3.1. Análise de Componentes Principais e os métodos B2 e B4	30
2. 4. CONSIDERAÇÕES FINAIS	31
3. METODOLOGIA.....	33
3.1. AQUISIÇÃO DE IMAGENS E PRÉ-CLASSIFICAÇÃO	34
3.2. AGRUPAMENTO DAS IMAGENS	35
3.3. EXTRAÇÃO DE CARACTERÍSTICAS.....	38
3.4. SELEÇÃO DE ATRIBUTOS.....	39
3.5. TREINAMENTO DOS CLASSIFICADORES E AVALIAÇÃO DOS RESULTADOS.....	40
3. 6. CONSIDERAÇÕES FINAIS	41
4. RESULTADOS E DISCUSSÃO.....	42
4.1. DESEMPENHO DO CLASSIFICADOR COM TODOS OS ATRIBUTOS.....	42
4.2. RESULTADOS : GRUPOS G2 e G6.....	43
4.3. RESULTADOS: G1, G3, G4 e G5.....	46
4.4. CONSIDERAÇÕES FINAIS	51
5. CONCLUSÕES E TRABALHOS FUTUROS	52
REFERÊNCIAS.....	54
ANEXO A-	57

1. INTRODUÇÃO

Os resultados da pesquisa sobre robôs móveis, capazes de se locomover de maneira autônoma e segura em ambientes reais, têm motivado o desenvolvimento de dispositivos que executam tarefas complexas na indústria, no comércio e na agricultura. Os principais interesses no uso desse tipo de tecnologia têm origem em fatores que podem ter impacto econômico sobre a atividade produtiva. Por exemplo, robôs podem executar tarefas perigosas; estender a capacidade humana para realizar tarefas que exijam força ou velocidade; efetuar atividades quase ininterruptamente.

Além disso, o uso de robôs autônomos também é interessante do ponto de vista econômico e ambiental, haja vista que os robôs desenvolvidos para aplicação de pesticidas podem executar essa tarefa de forma precisa e de acordo com a necessidade da cultura em diferentes pontos da estufa. Isto é, o robô pode ser ajustado para economizar a quantidade aplicada do produto e, conseqüentemente, reduzir os custos e a agressão ao meio ambiente (WOLF et al., 2009).

A produção de alimentos é importante para a sobrevivência da população mundial, que cresce de forma exponencialmente. A fim de aumentar ou até mesmo de cultivar uma determinada planta em uma região à qual o clima não é favorável, são empregadas estufas agrícolas. As estufas agrícolas são estruturas (construções) que permitem o cultivo de plantas cujo crescimento demanda um controle mais preciso de variáveis como a umidade relativa do ar, a temperatura, a irrigação (VIDA et al., 2004). Estufas também são usadas para isolar a cultura do ambiente externo e assim reduzir a possibilidade de contágio e ocorrência de doenças, bem como facilitar seu monitoramento e tratamento.

As mesmas motivações econômicas que levaram à utilização de robôs na indústria têm contribuído para o seu emprego na agricultura (<http://www.economist.com/node/15048711>). Espera-se que o desenvolvimento de robôs agrícolas ou *agribots*, como são conhecidos, possibilite não apenas a automação de tarefas comumente realizadas por seres humanos, mas que também contribua para novos avanços da agricultura. Em específico, as estufas são um ambiente controlado que muitas vezes é inadequado à saúde humana. Com isso, na última década, além do desenvolvimento de robôs agrícolas para trabalhar no

campo, também tem havido interesse no desenvolvimento de robôs para atuar em estufas agrícolas.

Segundo Sales, Osório e Wolf (2011), uma das principais tarefas na implementação de robôs móveis autônomos é a navegação¹. Um sistema de navegação precisa obter informações sobre o ambiente de forma a localizar os objetos e obstáculos. Uma abordagem usual para isso envolve a coleta de dados por sensores que são inseridos como evidências em modelos (numéricos/lógicos/probabilísticos) que permitem a tomada de decisão com respeito da presença de objetos no ambiente.

Este trabalho considera que uma meta importante no desenvolvimento de sistemas de navegação em estufas agrícolas é a detecção de obstáculos no seu interior. Entre os obstáculos é possível citar as paredes, os corredores, as bandejas e as plantas. Uma abordagem para reconhecer objetos usando técnicas de visão computacional é o emprego de modelos baseados em conhecimento. Nessa abordagem, uma linguagem para representação de conhecimento é usada para codificar relacionamentos entre as evidências coletadas da cena e as hipóteses de reconhecimento. Nesse caso, a tomada de decisão envolve um passo de inferência que conclui pela viabilidade de uma hipótese que declara a presença de um objeto dadas as evidências coletadas de uma cena.

Este trabalho restringe-se à identificação de um obstáculo em particular, as paredes/muretas da estufa em imagens digitais (Figura 1). A detecção de objetos em imagens, usando modelos, pode ser vista como um problema de classificação que envolve a associação de um ou mais rótulos aos *pixels* da imagem indicando se aquele ponto da imagem pertence ao objeto alvo (parede) ou não. Um classificador é um algoritmo que implementa um modelo de decisão que tem como entrada um conjunto de informações (características) extraídas da imagem e como saída os rótulos de cada *pixel*.

Uma das dificuldades do uso de classificadores para detectar objetos em imagens digitais é a necessidade de se tratar incerteza (ZHANG *et al.*, 2006). Assim, a detecção automática da parede na estufa exige o uso de métodos automáticos para raciocínio evidencial que sejam capazes de associar o rótulo mais provável a

¹ Navegação é a capacidade de o robô movimentar-se de uma posição-origem até uma posição-alvo, desviando os obstáculos durante o percurso.

cada região da imagem dadas as características observadas. Em particular, o uso de métodos bayesianos para tomada de decisão nesse tipo de problema permite selecionar o rótulo que maximiza a probabilidade posterior da hipótese de classificação, dadas as evidências.

Figura 1- Imagem do interior de uma estufa agrícola



Diante do exposto, este trabalho tem por objetivo avaliar o uso de classificadores bayesianos do tipo *Naïve Bayes*, na detecção de estruturas em estufas agrícolas, em particular a parede/mureta da estufa. Esse classificador tem uma estrutura que assume que todas as evidências são independentes, o que o torna um procedimento rápido na execução de inferências. Foram avaliadas diferentes implementações de classificadores do tipo *Naïve Bayes* cuja estrutura incorpora atributos referentes à cor e textura dos objetos. O desempenho desses classificadores foi avaliado usando as medidas de acurácia balanceada e *informedness*.

Segundo Theodoridis e Koutroumbas (2009), uma etapa importante na construção de classificadores é a seleção de características. Considerando isso, este trabalho aplicou dois procedimentos para seleção de atributos que melhor descrevessem o conjunto de imagens, usando a análise de componentes principais, os métodos B2 e B4 (JOLIFFE, 1972). Nesse sentido, a utilização de um número limitado de atributos para descrever um objeto reduz o custo computacional para a detecção.

Adicionalmente, é relevante destacar que a aquisição de imagens nas estufas comumente não permite o controle das condições de iluminação. Com isso, os procedimentos de extração de características, seleção de atributos, treinamento de classificadores e classificação de dados são executados sobre conjuntos de

dados adquiridos sob condições não homogêneas. Em vista disso, este trabalho também teve o objetivo de avaliar se classificadores treinados sobre conjuntos de imagens similares apresentam diferença de desempenho quando comparado aos classificadores treinados sobre todo o conjunto de imagens.

Os resultados dos experimentos realizados na geração dos classificadores a partir de dados de imagens agrupadas permitiu avaliar como os métodos de seleção B2 e B4 afetavam o desempenho dos classificadores (acurácia balanceada e *informedness*) quando aplicados no conjunto com todas as imagens e nos conjuntos de imagens similares. Os resultados mostraram que a seleção de características sobre um conjunto de imagens similares treina classificadores com maior índice de acurácia balanceada e *informedness* quando a média da correlação dos atributos com a classe é maior que a média da correlação dos atributos com a classe do conjunto de imagens.

Este trabalho está organizado da seguinte forma: o Capítulo 2 apresenta uma revisão bibliográfica sobre trabalhos relacionados com a pesquisa; o Capítulo 3 descreve a metodologia que foi aplicada durante a execução do trabalho; o Capítulo 4 mostra os resultados obtidos e o Capítulo 5 traz as considerações finais do trabalho.

2. REVISÃO BIBLIOGRÁFICA

Este capítulo apresenta uma revisão sobre os principais fundamentos aplicados no desenvolvimento deste trabalho. Inicialmente, é realizada uma descrição sobre estufas agrícolas e a possibilidade do uso de robôs móveis nesse tipo de ambiente. Também é apresentado o problema da navegação autônoma de robôs e é relatada a contribuição da visão computacional na solução do problema. Nesse contexto, também são descritos os procedimentos de processamento de imagens digitais empregados na construção de classificadores elaborados durante o experimento.

Adicionalmente, este capítulo apresenta uma revisão sobre classificadores do tipo *Naive Bayes*. Finalmente, é abordada a questão da seleção dos atributos que compõem um classificador. Para tanto, são apresentados os dois métodos usados na seleção de variáveis, os métodos B2 e B4 propostos por Joliffe (1972).

2.1. ESTUFAS AGRÍCOLAS E ROBÔS AGRÍCOLAS

As estufas agrícolas são, usualmente, construções metálicas retangulares frequentemente cobertas com filme plástico de polietileno de baixa densidade, utilizadas para o cultivo de plantas que necessitam de: (a) controle mais rigoroso quanto: à umidade relativa do ar, à temperatura, à irrigação; (b) proteção contra: chuvas, granizo, geadas, insetos, animais; c) aplicação eficiente de produtos como: fertilizantes, fungicidas, herbicidas. A Figura 2 mostra um exemplo de estufa agrícola. As estufas agrícolas também permitem ampliar o período de safra e a redução do ciclo produtivo, (MANDOW *et al.*, 1996; VIDA *et al.*, 2004) e facilitam o controle de pragas e controle da qualidade da cultura.

Segundo Sanchez-Hermosilla *et al.* (2010), atualmente as estufas têm contribuído significativamente na produção agrícola. Contudo, deve ser notado que muitas das tarefas realizadas em estufas agrícolas são executadas manualmente - por exemplo, colheita, plantio, monitoramento e pulverização. Todavia, as condições do ambiente interno das estufas podem tornar o trabalho difícil ou mesmo perigoso e inadequado à saúde humana (MANDOW *et al.*, 1996; ACACCIA *et al.*, 2003; SAMMONS; FURUKAWA; BULGIN, 2005; MEHTA; BURKS; DIXON; 2008; GONZALES *et al.*, 2009).

Figura 2- Estufa agrícola



Fonte: O autor

Nesse contexto, Sammons; Furukawa e Bulgin (2005) destacam que a automação das tarefas em uma estufa pode reduzir os riscos aos envolvidos no trabalho. Tal possibilidade tem despertado o interesse no emprego de robôs agrícolas, os *agribots* (MANDOW *et al.*, 1996), em estufas. Dentre os *agribots*, uma classe de robôs cuja introdução na agricultura tem motivado o desenvolvimento de pesquisas é a dos robôs autônomos equipados com dispositivos para a operação agrícola: plantio, irrigação, polinização artificial, pulverização e colheita (ACACCIA *et al.*, 2003; SANCHEZ-HERMOSILLA *et al.*, 2010).

O desenvolvimento desses robôs envolve a elaboração de sistemas computacionais que permitam sua navegação autônoma no interior da estufa. Em particular, Metha; Burks e Dixon(2008); Sales; Osório e Wolf (2011) e Gonzales *et al.* (2009) afirmam que a navegação é a questão-chave em robôs móveis, e, portanto, selecionar o método de navegação mais adequado é a tarefa principal para construir um robô de sucesso.

Um problema importante para a criação de sistemas de navegação autônoma é a detecção/identificação de objetos no ambiente em que o robô irá atuar. No contexto de agribots para estufas agrícolas, alguns autores propuseram o uso de técnicas de visão computacional para reconhecer os elementos da cena (GONZALES *et. al.*, 2009; BUEMI *et. al.*, 1994; MANDOW *et al.*, 1996). Esses autores destacam que seus sistemas apresentavam um desempenho inadequado quanto à acurácia na classificação/identificação dos objetos na cena. Essas limitações afetaram diretamente a navegação do robô que, ao detectar um “falso

obstáculo²”, acionava o alerta de segurança e interrompia a execução das tarefas. Considerando o exposto, uma contribuição necessária para o desenvolvimento de sistemas de navegação autônomas de robôs é a implementação de sistemas eficazes para identificar/classificar objetos na cena (interior da estufa).

2.2. VISÃO COMPUTACIONAL

Conforme Gonzalez e Woods (2002), a visão computacional objetiva desenvolver procedimentos para a extração da informação contida na imagem a partir do emprego de métodos que procuram determinar alguns elementos relevantes para identificação de objetos na cena. Nesse sentido, Sucar e Gilies (1994) afirmam que, além de o processo da visão envolver a transformação dos dados fornecidos pela câmera em uma descrição simbólica e concisa dos elementos da imagem, é necessário integrar essas informações em um modelo que as explore de forma a resolver o problema do reconhecimento dos objetos da cena.

Segundo Marques Filho e Vieira Neto (1999), a solução de problemas de visão computacional pode ser abstraída nas seguintes etapas:

- a) aquisição de imagens;
- b) pré-processamento;
- c) segmentação;
- d) extração de características;
- e) reconhecimento e interpretação.

A aquisição de imagens é o processo de conversão de uma cena real tridimensional em uma imagem analógica por meio de um dispositivo (a câmera). Já a imagem digital, formato que permite processamento computacional, é o resultado da conversão da imagem analógica em uma matriz de $M \times N$ pontos, cada qual denominado *pixel*. O pixel é o menor elemento de uma imagem e armazena informações relativas à cor daquele ponto.

O pré-processamento corresponde a cada operação aplicada a uma imagem com objetivo de melhorar sua qualidade para as etapas futuras (GONZALES; WOODS, 2002). Tais operações visam: reduzir o ruído, realçar contraste e nitidez da

² Por exemplo: ao longo de um corredor, quando um galho solto ou pendurado de uma planta é detectado, o sistema não sabe ao certo o que foi detectado, afetando a navegação.

imagem. Observa-se que a etapa de pré-processamento, tanto a entrada quanto a saída, ainda é uma imagem. Nesse contexto, há uma grande variedade de técnicas a partir da qual se pode destacar conversão de uma imagem em níveis de cinza.

A segmentação de imagens é o processo de dividir a imagem em subconjuntos mutuamente exclusivos, chamados regiões, tal que os *pixels* de cada região compartilham uma determinada propriedade. Assim, propriedades derivadas de conceitos como cor, tonalidade ou textura podem ser aplicadas para decompor as imagens em regiões cujas características difiram das demais ou sejam relevantes para detecção de um determinado objeto (HARALICK; SHAPIRO, 1991; GONZALES; WOODS, 2002; RUSSEL e NORVIG, 2004).

Para Marques Filho e Vieira Neto (1999), a etapa de extração de características objetiva extrair informações das imagens resultantes da etapa anterior, gerando descritores³ que contribuam para a identificação do objeto de interesse na cena. Esses descritores são alocados em uma base de dados a fim de possibilitar o reconhecimento. Após essa etapa, a imagem passa ser um conjunto de dados (características) correspondentes. O reconhecimento é o procedimento de classificar um objeto com base nos seus descritores (RUSSEL; NORVIG, 2004; THEODORIDIS; KOUTROUMBAS, 2009). Já a interpretação, é processo de dar significado ao(s) objeto(s) reconhecido(s).

Diante do exposto, uma tarefa importante é a escolha do conjunto de atributos que melhor represente a cena, pois o desempenho do sistema de visão está diretamente relacionado ao poder de discriminação do conjunto de características escolhido (NAVA; CRISTÓBAL; ESCALANTE-RAMÍRES, 2011).

2.2.1. EXTRAÇÃO DE CARACTERÍSTICAS

A seguir são apresentadas as características que foram extraídas das imagens utilizadas nos experimentos realizados neste trabalho.

³ Descritores de uma imagem é um vetor onde são armazenadas as características da imagem. Exemplo: cor, textura, forma.

2.2.1.1. Cor

Em termos de processamento de imagem digital, a cor pode ser empregada como um descritor de imagem devido a cada objeto da cena a ser identificado/classificado possuir uma representação diferente no espaço de cor empregado. Os espaços de representação de cor usados neste trabalho são o RGB (red, green e blue - em português vermelho, verde, azul) e o HSI (hue, saturation e intensity - em português: matiz, saturação, intensidade).

No modelo RGB cada cor aparece em seus componentes espectrais primários: vermelho, verde e azul (MARQUES FILHO; VIEIRA NETO, 1999), (GONZALES; WOODS, 2002). A imagem representada no modelo de cores RGB consiste em três imagens, uma para cada cor primária, chamadas imagens monocromáticas. Assim como a imagem digital, as imagens formadas pelas cores primárias são matrizes $M \times N$. Cada pixel dessa matriz é representado por um valor entre 0 (zero) e 255(duzentos e cinquenta e cinco) conforme a intensidade. Para representar uma cena real, as três imagens são combinadas.

Segundo Gonzales e Woods (2002), o modelo HSI é um descritor importante porque separa a informação de cor em uma escala de níveis de cinza, tornando-a adequada para muitas das técnicas que façam uso de níveis de cinza para processamento. Os valores de HSI de um pixel podem ser calculados a partir do modelo RGB pelas equações (GONZALES; WOODS, 2002):

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

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

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

2.2.1.2. Textura

Conforme Russel e Norvig (2004), em visão computacional a textura se refere a um padrão tonal com repetição espacial que pode ser detectado visualmente sobre uma região da imagem⁴. A textura é uma propriedade comum a todas as superfícies. Propriedade que relaciona o arranjo estrutural da região da imagem com objetos da cena. Assim, o conceito de textura está relacionado com a distribuição espacial dos tons cinza de uma região e, portanto, cômputo de quantificadores para a textura só faz sentido para um grupo de *pixels*.

A textura e a tonalidade não são conceitos independentes, mas carregam uma relação indissociável entre si. No entanto, embora a textura e a tonalidade estejam sempre presentes na imagem, por vezes uma propriedade pode prevalecer à outra (HARALICK; SHANMUGAM; DINSTEIN, 1973). Isso faz com que o uso de métodos que permitam quantificar/qualificar a textura de regiões de uma imagem possibilite a extração de características úteis para a identificação de objetos (HARALICK; SHANMUGAM; DINSTEIN, 1973).

Existem vários métodos para quantificação/qualificação de texturas em imagens digitais. Este trabalho emprega os seguintes descritores de texturas:

- a) Filtro de Gabor;
- b) Filtro de Daubechies;
- c) Variância RGB;
- d) Variação Local;
- e) Desvio Padrão Local;
- f) Entropia Local;
- g) LBP⁵.

A transformada de Daubechies permite construção de estimativas de espectros espacialmente localizados e a autocovariância localizada que podem ser usadas para caracterizar textura de imagens (ECKLEY; NASON; TRELOAR, 2010), (ECKLEY; NASON, 2011). A transformada de Daubechies é dada em três direções:

⁴ Exemplos de textura incluem o padrão de janelas em um prédio, pontos em uma camisa, listras de um tigre e pessoas em um estádio.

⁵ Do inglês, local binary pattern (padrão binário local).

vertical, horizontal e diagonal. Eckley; Nason; Treloar (2010) definiram o cálculo da transformada de Daubechies, que é dado por:

$$\psi_j^l(\tau) = \sum_{v \in \mathbb{Z}^2} \psi_{j,v}^l(0) \psi_{j,v}^l(\tau)$$

onde $j \in \mathbb{N}$, $l \in \{v, h, d\}$, v é vertical, h é horizontal, d é diagonal, τ, ψ_j, ϕ_j são waveletes discretas 1D. A $\psi_j^l(\tau)$ para v, h e d é dada por:

$$\psi_j^l = \begin{bmatrix} \psi_j^l(0,0) & \cdots & \psi_j^l(0, L_j - 1) \\ \vdots & \ddots & \vdots \\ \psi_j^l(L_j - 1, 0) & \cdots & \psi_j^l(L_j - 1, L_j - 1) \end{bmatrix} \text{ para } l = h, v \text{ ou } d.$$

$$\left. \begin{aligned} \psi_j^h(\tau) &= \phi_{j,\tau_1} \psi_{j,\tau_2} \\ \psi_j^v(\tau) &= \psi_{j,\tau_1} \phi_{j,\tau_2} \\ \psi_j^d(\tau) &= \psi_{j,\tau_1} \psi_{j,\tau_2} \end{aligned} \right\} \text{ para } \tau_1, \tau_2 = 0, \dots, L_j - 1$$

O filtro de Gabor objetiva extrair características de textura presentes na imagem, de acordo com a frequência e a orientação e é dado por:

$$g(x, y) = s(x, y) wr(x, y) \text{ sendo:}$$

$$s(x, y) = \exp(j(2\pi F_0(x \cos \omega_0 + y \sin \omega_0) + P))$$

$$wr(x, y) = k \exp(-\pi(a^2(x - x_0)_r^2 + b^2(y - y_0)_r^2))$$

onde $s(x, y)$ é uma senoide complexa e $wr(x, y)$ é um função gaussiana 2-D, x, y são índices sobre os elementos de base da matriz (MOVELLAN, 2002).

Os descritores variância RGB, variação local, desvio padrão local e entropia local pretendem caracterizar a textura de uma imagem fornecendo informações sobre a variabilidade local dos valores da intensidade de pixels em uma imagem. O cálculo da variância nos canais R, G e B foi realizado separadamente para cada cor e é dado por:

$$\text{Var}(i, j) = \left(\frac{1}{n} \sum_{k=1}^n (x_k - \bar{x})^2 \right)$$

Nessa expressão, $\text{var}(i, j)$ indica a variância na intensidade associada a uma vizinhança de 3x3 do *pixel*(i,j), n é o número de *pixels* da vizinhança, o símbolo $\bar{x}$ indica a média do nível de cinza da cor analisada na vizinhança e x_k denota o nível de cinza da cor do k -ésimo *pixel* da vizinhança.

O cômputo das funções variação local, desvio padrão e entropia é semelhante. Define-se uma máscara $n \times n$, sendo o *pixel* de interesse o centro da máscara, calcula-se o valor estatístico para a vizinhança e utiliza-se esse valor como resultado do *pixel* de interesse em uma imagem de saída (GONZALES; WOODS; EDDINS, 2009). Assim, variação local é calculada com base na análise dos *pixels* em uma vizinhança de 3x3 do *pixel* (i,j), o valor do *pixel* (i,j) da imagem de saída é o resultado da subtração do *pixel* com valor máximo, com o *pixel* de valor mínimo. O cálculo da variação local é dado por:

$$\text{Variação Local}(i, j) = P_m - P_p$$

onde P_m é o *pixel* com maior valor na vizinhança e P_p é o *pixel* com menor valor na vizinhança.

O desvio padrão local para um *pixel* com n vizinhos é dado por:

$$\sigma(i, j) = \left(\frac{1}{n} \sum_{k=1}^n (x_k - \bar{x})^2 \right)^{\frac{1}{2}}$$

onde n é o número de *pixels* da vizinhança, o símbolo $\bar{x}$ indica a média do nível de cinza na vizinhança e x_k denota o nível de cinza do k -ésimo *pixel* da vizinhança.

A entropia de uma região da imagem é dada por:

$$\text{Entropia} = - \sum_{i=1}^n \sum_{j=1}^n P_{ij} \log_2 P_{ij}$$

onde n é o número de pixels analisados e P_{ij} é a probabilidade do ij -ésimo tom de cinza da imagem.

O descritor de textura por meio de um operador de LBP (NAVA; CRISTÓBAL; ESCALANTE-RAMÍRES, 2011) constitui um operador de imagem que transforma uma imagem em uma matriz de rótulos inteiros que codificam as informações de contexto local de cada pixel e também está associado à textura. Conforme Ojala (2002), o LBP é definido como um conjunto ordenado de comparações binárias de intensidades entre um *pixel* central e sua vizinhança, dado por:

$$LBP(gc) = \sum_{p=0}^{p-1} S(gp - gc)2^p$$


onde gc é o valor do nível de cinza do pixel central, gp é o valor do nível de cinza dos pixels vizinhos, p é o número de pixels analisados. LBP usa uma máscara $n \times n$ que representa a vizinhança em torno do pixel central.

2.2.2. Interpretação de imagens e modelos baseados em conhecimento

Como descrito anteriormente, a etapa de reconhecimento objetiva atribuir um rótulo a um objeto da imagem a partir da análise das características que foram extraídas nas etapas anteriores. Assim, a interpretação é a ação de atribuir significado a um conjunto de objetos reconhecidos. Uma abordagem para criar sistemas para o reconhecimento de objetos é o uso de modelos baseados em conhecimento (Figura 3). Essa abordagem define que um sistema de visão computacional tem três componentes principais (SUCAR; GILIES, 1994): processamento de imagem, inferência e base de conhecimento. A base de conhecimento armazena informações sobre o domínio da aplicação, isto é, ela descreve o relacionamento entre as características de cada região da imagem e os rótulos de identificação. O processamento de imagem extrai os descritores de características da imagem em análise. A inferência integra a informação produzida pelo processamento da imagem com o modelo armazenado na base de

conhecimento a fim de possibilitar a tomada de decisão (HARALICK ; SHAPIRO, 1991).

Figura 3-Estrutura do sistema de visão baseada no conhecimento (SUCAR e GILIES, 1994)



Mais detalhadamente, a base de conhecimento emprega modelos lógicos⁶ para representar o problema, e o procedimento de inferência explora o modelo durante a etapa de interpretação da imagem. O modelo codifica a estrutura dos objetos a serem reconhecidos por meio de asserções que explicitam as relações lógicas entre os atributos extraídos da imagem. Isto é, o modelo estabelece as hipóteses referentes aos rótulos de identificação, as variáveis que representam as características, as variáveis intermediárias que simbolizam conceitos e relacionamento entre esses componentes. O processo de interpretação consiste em inferir a identidade dos objetos na imagem, a partir dos dados e os fatos conhecidos sobre o domínio. O emprego de modelos baseados em conhecimento na confecção de sistemas de visão computacional permite que sejam utilizadas técnicas de inteligência artificial no seu desenvolvimento e aplicação (RUSSEL; NORVIG, 2004).

Uma questão importante, quanto ao uso de modelos baseados em conhecimento, é o tratamento de incerteza. Thrun; Burgard; Fox, (2005), citam que a

⁶ Aqui o termo modelo lógico se refere a qualquer tipo de lógica. A lógica proposicional, a lógica de primeira ordem, a lógica Fuzzy, a lógica probabilística e a lógica não monotônica são alguns tipos de lógica que podem ser explorados na construção de modelos para visão computacional.

incerteza pode ter origem em fatores como: (a) o ambiente⁷; (b) o fato de qualquer modelo poder apresentar incorreções, imperfeições ou ser incompleto; (c) as evidências podem ser permeadas por ruídos ou podem ser incompletas - no caso de imagens, o ruído/incompletude pode ser causado por reflexos, iluminação, sombras, oclusão.

Dada a incerteza implícita ao problema, é necessário empregar formalismos que permitam a representação dessa incerteza na elaboração do modelo. Também é necessário que os procedimentos de inferência sejam capazes de contabilizar a incerteza que permeará os resultados derivados do processo de tomada de decisão. A teoria de probabilidades tem sido largamente utilizada para tratar incerteza em inteligência artificial, em particular explorando-se classificadores bayesianos (RUSSEL; NORVIG, 2004; ZHANG et al., 2006).

2.2.2.1. Interpretação de imagens usando classificadores bayesianos

A classificação é uma tarefa importante do reconhecimento de padrões (FRIEDMAN; GOLDSZMIDT, 1996; FRIEDMAN, GEIZER; GOLDSZMIDT, 1997) e é empregada com objetivo de prever valores desconhecidos (variáveis de saída) com um número de valores conhecidos (variáveis de entrada). A fim de realizar a classificação, é necessário modelar a relação entre as variáveis de entrada e as variáveis de saída. Esse processo envolve a aprendizagem de dados usando um modelo no qual tanto as variáveis de entrada quanto as variáveis de saída estão presentes.

Segundo Marques (2011), os classificadores bayesianos realizam a classificação com base nas distribuições de probabilidade dos dados da base de treinamento para cada classe. Um objeto classificado/atribuído a uma classe para a qual é mais provável de acordo com características observadas. Os cálculos matemáticos realizados pelo classificador bayesiano fazem uso de três distribuições de probabilidade: (1) a priori: probabilidade para cada classe ω_k , denotada por $P(\omega_k)$; (2) a distribuição incondicional do vetor característica representando a medida padrão X , denotado por $p(x)$; (3) a distribuição condicional de classe, isto é, a probabilidade de x dada classe ω_k , denotado por $p(x|\omega_k)$. Essas três distribuições

⁷ Ambientes são imprecisos. Enquanto o grau de incerteza em ambientes estruturados é pequeno, como uma fábrica, ambientes desestruturados têm alto grau de incerteza, como rodovias.


são aplicadas, pela regra de Bayes (Pearl, 1988), para calcular a probabilidade a posteriori para classe ω_k dado x , representada como $p(\omega_k|x)$, como se segue:

$$p(\omega_k|X) = \frac{p(X|\omega_k)p(\omega_k)}{p(X)}$$

O classificador bayesiano *Naive Bayes* (MITCHELL, 1997) é método eficaz e tem sido empregado em várias tarefas devido a sua robustez à presença de ruído. Sua aplicabilidade abrange tarefas, em que cada instância C é descrita por um conjunto de valores de atributos e a função alvo $f(C)$ pode assumir qualquer valor de um conjunto finito V . Esse classificador pode ser visto como uma árvore de profundidade máxima igual a 1 tal que a raiz simboliza uma variável aleatória que indica a classe do objeto em análise. Os nós folhas simbolizam os atributos que permitem a identificação da classe. O classificador assume que todos os atributos são independentes uns dos outros, dado o rótulo da classe. O relacionamento entre o nó raiz e seus filhos é codificado pela tabela de probabilidade condicional.

A Figura 4 ilustra a estrutura de um classificador *Naive Bayes*. Nessa figura, o nó C simboliza a classe e os nós denotados por A_i representam os atributos descritores, para $i=1..n$. A ilustração assume que C é uma variável proposicional e A_i com probabilidades marginais $P(C=verdadeiro)$ e $P(C=falso)$. Os atributos X_i são variáveis contínuas associadas as distribuições condicionais $P(A_i|C=verdadeiro)$ e $P(A_i|C=falso)$, ambas gaussianas com médias $\mu_{i,v}$ e $\mu_{i,f}$ e variâncias $\sigma_{i,v}^2$ e $\sigma_{i,f}^2$, respectivamente.

Figura 4- Um classificador *Naive Bayes* descrito como uma rede bayesiana na qual os atributos preditivos ($A_1, A_2, \dots, A_i$) são condicionalmente independentes dada classe (C) (JOHN e LANGLEY, 1995)



Dada à estrutura de um classificador do tipo *Naive Bayes*, seu aprendizado supervisionado objetiva determinar as probabilidades *a priori* da variável classe (raiz da árvore) e as probabilidades condicionais que relacionam a classe a cada um dos atributos. Neste trabalho, o algoritmo chamado *Naive Bayes* Flexível foi empregado no treinamento dos classificadores (JOHN; LANGLEY, 1995).

2.3. SELEÇÃO DE ATRIBUTOS

Uma etapa importante no desenvolvimento de um classificador é a seleção dos atributos que sejam relevantes para descrever as classes de objetos que se pretende classificar (DASH; LIU, 1997). A escolha de um conjunto adequado de atributos pode afetar o desempenho do classificador, assim como interferir no tempo de processamento na classificação dos objetos. Segundo Joliffe (1972); John; Langley (1995); Guo *et al.*, (2002) e King; Jackson (1999) em muitos conjuntos de dados há variáveis redundantes que podem ser descartadas sem perdas no desempenho do classificador, seja porque elas não fornecem informações para a classificação, seja porque são combinações de outras variáveis.

A análise de componentes principais (ACP) é uma abordagem que aplica uma transformação linear sobre o conjunto de dados a fim de destacar a variação dos dados. Essa transformação permite a identificação de quais combinações lineares das variáveis originais contribuem para a variação. A seguir é descrita a ACP e são apresentados dois métodos para seleção de variáveis baseados em ACP propostos por Jolliffe (1972).

2.3.1. Análise de Componentes Principais e os métodos B2 e B4

Seja o vetor $\mathbf{X} = [X_1, \dots, X_p]^t$ de variáveis com médias $\mu_1, \dots, \mu_p$, e variâncias $\sigma_1, \dots, \sigma_p$. O *i*-ésimo componente principal amostral é definido como a combinação linear $Y_i = e_{i1} X_1 + \dots + e_{ip} X_p$ tal que os coeficientes estão sujeitos às seguintes restrições (FERREIRA, 2008):

- a) a soma dos coeficientes e_{ik} é igual a 1;
- b) $(\mathbf{S} - \lambda_i \mathbf{I}) \mathbf{e}_i = 0$, onde $\mathbf{S}$ é a matriz de covariância amostral, $\mathbf{I}_{p \times p}$ é a matriz identidade.

Dadas estas condições $\mathbf{e}_i = (e_{i1}, \dots, e_{ip})$ é um autovetor de $\mathbf{S}$ e λ_i o autovalor correspondente. Além disso, é importante observar que a solução $\mathbf{e}_i$ define o vetor que maximiza a variância dos dados após a transformação. O componente principal que responde pela maior parte das variações dos dados é aquele que possui o maior autovalor e assim sucessivamente. Assim, sem perda de generalidade, definindo $\lambda_1, \dots, \lambda_n$ tal que $\lambda_1 \geq \lambda_2 \geq \dots \lambda_{n-1} \geq \lambda_n$, temos Y_1 que codifica a maior parte da variação dos dados, a Y_2 segunda maior parte da variação até Y_n que representa a menor parte da variação.

Os métodos B2 e B4 exploram a propriedade de que cada componente principal representa uma parte da variância dos dados para selecionar as variáveis mais relevantes para descrever a variabilidade do conjunto original. O procedimento B2 pode ser descrito como:

- a) execute a ACP sobre o conjunto de dados definido sobre $\mathbf{X}$;
- b) defina o número p de variáveis para serem selecionadas;
- c) para cada um dos últimos $(n-p)$ componentes principais:
 - i) determine a variável com maior coeficiente;
 - ii) descarte a variável.

O procedimento B4 pode ser descrito como:

- a) execute a ACP sobre o conjunto de dados definido sobre $\mathbf{X}$;
- b) defina o número p de variáveis para serem selecionadas;
- c) para cada um dos p primeiros componentes principais:
 - i) determine a variável com maior coeficiente;
 - ii) selecione a variável.

2. 4. CONSIDERAÇÕES FINAIS

Este capítulo apresentou uma descrição dos elementos do problema, identificação/classificação de objetos em estufas agrícolas, e uma revisão sobre as técnicas propostas para abordar esse problema.

As estufas agrícolas contribuem para produção/cultivo de plantas. Com a introdução de robôs autônomos há possibilidade de otimizar a produção ou mesmo minimizar os danos a saúde dos trabalhadores, causados pelo uso de substâncias

tóxicas. Porém, os robôs autônomos não são capazes de identificar/classificar objetos. Uma abordagem para o problema é o emprego de técnicas de Visão Computacional e Classificadores Bayesianos.

No próximo capítulo, é apresentada a metodologia empregada no desenvolvimento deste trabalho.

3. METODOLOGIA

Este capítulo descreve os experimentos realizados no desenvolvimento deste trabalho. O objetivo das tarefas executadas foi avaliar o uso de classificadores bayesianos do tipo *Naive Bayes* na detecção da parede/mureta em uma estufa agrícola e o emprego dos métodos B2 e B4 na seleção dos atributos para sua composição. Adicionalmente, os experimentos avaliaram o desempenho dos classificadores quanto às condições de aquisição das imagens - não houve controle da iluminação. Mais detalhadamente, ao se comparar o desempenho de classificadores treinados a partir de atributos selecionados pelos métodos B2 e B4, a partir de características extraídas do conjunto de imagens agrupadas por similaridade, procurou-se verificar se difere do desempenho dos classificadores treinados sobre atributos selecionados a partir do conjunto total de imagens.

Para realização dos experimentos foram executados os seguintes procedimentos:


- a) Aquisição das imagens;
- b) Pré-classificação manual das imagens;
- c) Agrupamento das imagens por similaridade;
- d) Extração de características das imagens e construção da base treinamento;
- e) Seleção de atributos empregando correlação e B2, B4;
- f) Treinamento dos classificadores *Naive Bayes* usando os atributos selecionados por cada método;
- g) Avaliação do desempenho dos classificadores.

A seguir, a Seção 3.1 descreve os procedimentos empregados na aquisição e pré-classificação das imagens utilizadas neste trabalho. A Seção 3.2 apresenta o método para gerar os conjuntos de imagens similares. A Seção 3.3 descreve a extração de características das imagens. A Seção 3.4 detalha como foi efetuada a seleção de atributos. A Seção 3.5 enumera os procedimentos para o treinamento dos classificadores *Naive Bayes* usando os atributos selecionados por cada método. Na Seção 3.6 é descrito como foram avaliados os classificadores e a seção 3.7 traz as considerações finais do capítulo.

3.1. AQUISIÇÃO DE IMAGENS E PRÉ-CLASSIFICAÇÃO

A aquisição das imagens foi realizada na cidade de Guarapuava - PR, em uma estufa usada para cultivar mudas para reflorestamento. Situada na margem da BR-277, KM 340+500. A estufa possui 315 m², sendo 45 metros de comprimento e 7 metros de largura, com capacidade de 200 bandejas, dispostas em 5 fileiras com 40 bandejas cada, a uma distância de 28 centímetros uma fileira da outra, conforme a Figura 5.

Figura 5- Planta baixa da estufa



O piso é irregular, coberto por uma camada de brita e plantas daninhas. Existe uma mureta de alvenaria com altura variando de 25 cm a 35 cm circundando a estufa. O teto é em arco, coberto com filme plástico de polietileno de baixa densidade, assim como as paredes acima da mureta de alvenaria (Figura 6).

Figura 6- Imagens da estufa utilizada neste trabalho, sendo uma imagem externa e uma interna, respectivamente



A aquisição das imagens ocorreu em dias, horários e condições climáticas diferentes, implicando variação da iluminação do ambiente. Foram coletadas 83 imagens, com dimensão de 320x240 pixels, resolução 480X480 dpi, 8 bits e 3 canais (RGB). Para a coleta, foi utilizada uma câmera digital Kodak EasyShare M531 montada sobre um tripé a uma altura de 35 cm do piso. A baixa resolução adotada para a coleta das imagens se deve ao custo computacional.

Não foi mensurado o ângulo entre a posição da câmera e o piso. Após a aquisição, as regiões da imagem que estavam associadas à mureta foram rotuladas manualmente. Esse procedimento gerou um conjunto de dados com as coordenadas dos *pixels* rotulados.

3.2. AGRUPAMENTO DAS IMAGENS

O conjunto de imagens foi organizado em seis grupos com o objetivo de separá-las usando critério de similaridade. O critério utilizado foi a distribuição da média dos níveis de cinza em oito regiões da imagem. Isto é, todas as imagens foram transformadas para o formato não colorido em tons de cinza. Na sequência, cada imagem foi dividida em oito regiões. A média dessas regiões foi calculada e armazenada, produzindo um registro da forma (M1, M2 ..., M8) para cada imagem; aqui M_i representa a média do nível de cinza da i -ésima região. A Figura 7 descreve esse procedimento.

Figura 7- Divisão da imagem em segmentos



Em seguida o algoritmo K-médias (HORNIK; FEINERER; KOBERET, 2013) foi usado para agrupar as imagens de acordo com as médias das regiões. Dessa maneira cada imagem foi associada a um grupo quando a sua distância ao centroide deste grupo é mínima. A Tabela 1 apresenta a distribuição do número de imagens

entre os grupos, a proporção do número de pixels classificados como positivos (muretas) e negativos (demais regiões) em cada imagem. As Figuras 8, 9, 10, 11, 12 e 13 apresentam dois exemplos de imagens de cada grupo.

Tabela 1- Distribuição do conjunto de imagens em grupos de imagens similares

	Porcentagem de Mureta Rotulada	Demais Regiões	Número de Imagens
GRUPO 1	3	97	13
GRUPO 2	4	96	16
GRUPO 3	13	87	15
GRUPO 4	8	92	17
GRUPO 5	4	96	12
GRUPO 6	13	87	10

Figura 8- Exemplo de imagem grupo 1, (a) Imagem mais próxima do centroide do grupo, (b) Imagem mais distante do centroide do grupo



Figura 9- Exemplo de imagem grupo 2, (a) Imagem mais próxima do centroide do grupo, (b) Imagem mais distante do centroide do grupo




Figura 10 - Exemplo de imagem grupo 2, (a) Imagem mais próxima do centroide do grupo, (b) Imagem mais distante do centroide do grupo




Figura 11- Exemplo de imagem grupo 4, (a) Imagem mais próxima do centroide do grupo, (b) Imagem mais distante do centroide do grupo




Figura 12 - Exemplo de imagem grupo 5, (a) Imagem mais próxima do centroide do grupo, (b) Imagem mais distante do centroide do grupo





Figura 13- Exemplo de imagem grupo 6, (a) Imagem mais próxima do centroide do grupo, (b) Imagem mais distante do centroide do grupo



3.3. EXTRAÇÃO DE CARACTERÍSTICAS

Nesta etapa, foram extraídas as características das imagens. Primeiro foi extraída a média do RGB para cada pixel usando máscara 3x3 e na sequência foi calculado o valor de HSI. Em seguida, foram empregados filtros para extrair as informações de textura. O filtro de Gabor foi aplicado com os seguintes parâmetros: Variância = 0,05, frequência polar (0,0.25) e com cinco orientações ($0, \frac{\pi}{6}, \frac{\pi}{4}, \frac{\pi}{2}, \frac{3\pi}{4}$). Esse procedimento resultou em cinco atributos.

O filtro de Daubechies foi aplicado com uma submáscara de tamanho 64x64 que percorreu a imagem para extrair informações quanto às direções: vertical, horizontal e diagonal. Foram extraídos 18 descritores de acordo com (ECKLEY; NASON; TRELOAR, 2010). O filtro LBP foi aplicado sobre as imagens e determinou dois atributos, com e sem invariância rotacional (NAVA; CRISTÓBAL; ESCALANTE-RAMÍRES, 2011). A entropia, variação local, desvio padrão e variância RGB foram calculados para cada pixel da imagem segundo a descrição da seção 2.2.1.2. No total foram gerados 38 atributos para cada pixel de cada imagem.

O conjunto de dados original, formado com todos os atributos extraídos para cada pixel e a respectiva classificação, é denotado por (B). Da mesma forma, foram definidos seis conjuntos para treinamento e teste dos classificadores. Um para cada grupo de imagens obtido a partir do procedimento descrito na seção 3.2. Esses conjuntos de dados foram denominados G1, G2, G3, G4, G5 e G6.

3.4. SELEÇÃO DE ATRIBUTOS

A Tabela 2 mostra a distribuição do número de variáveis dada sua correlação com a variável meta (mureta) para cada grupo (B, G1, G2, G3, G4, G5, G6).

Tabela 2 - Distribuição das variáveis conforme a correlação das variáveis com a classe.

	B	G1	G2	G3	G4	G5	G6
Variáveis abaixo de 0,02	5	15	11	1	6	1	1
Correlação muito fraca (0,02 a 0,2)	30	23	27	32	32	36	22
Correlação fraca (0,2 a 0,4)	3	0	0	5	0	1	9
Correlação moderada (0,4 a 0,7)	0	0	0	0	0	0	6
Correlação forte (0,7 a 0,9)	0	0	0	0	0	0	0
TOTAL	38	38	38	38	38	38	38

Como pode ser observado nenhum atributo tem correlação forte com a variável indicadora da classe (mureta). O grupo G6 contém 6 variáveis com correlação moderada com a classe. Os grupos B, G3, G5 e G6 possuem variáveis fracamente correlacionadas com a classe e todos os grupos apresentaram mais de 20 variáveis que têm correlação muito fraca com a variável da classe. Além disso, todos os grupos apresentavam variáveis cuja correlação é inferior a 0,02 e portanto exercem pouca influência sobre a meta.

Considerando isso, estipulou-se que atributos com correlação inferior a 0,02 seriam removidos do conjunto de treinamento. Alguns desses atributos tinham alta variabilidade e afetavam o desempenho dos métodos B2 e B4 mesmo sem contribuir para melhora efetiva no desempenho dos classificadores. Deve ser observado que no grupo G1 foram mantidas quatro variáveis cuja correlação estava abaixo de 0,02. As quatro variáveis mantidas possuem maior correlação com a meta, entre as variáveis removidas. Esse procedimento foi aplicado para permitir que este grupo fosse submetido aos mesmos testes que os demais grupos. A Tabela 3 mostra a distribuição do número de variáveis dada sua correlação à variável meta para cada um dos grupos após este procedimento.

Tabela 3- Distribuição das variáveis pós corte por correlação abaixo de 0,02

	B	G1	G2	G3	G4	G5	G6
Variáveis abaixo de 0,02	0	4	0	0	0	0	0
Correlação muito fraca (0,02 a 0,2)	30	23	27	32	32	36	22
Correlação fraca (0,2 a 0,4)	3	0	0	5	0	1	9
Correlação moderada (0,4 a 0,7)	0	0	0	0	0	0	6
Correlação forte (0,7 a 0,9)	0	0	0	0	0	0	0
TOTAL	33	27	27	37	32	37	37

Em seguida, foram empregados os métodos B2 e B4 para seleção de atributos sobre os conjuntos de dados resultantes do corte por correlação. Esses procedimentos foram usados para gerar bases de treinamento com 27, 22, 17 e 12 atributos. Após a etapa de seleção de atributos, foram geradas 96 novas bases de treinamento/teste. Essas bases foram denominadas conforme Apêndice A.

3.5. TREINAMENTO DOS CLASSIFICADORES E AVALIAÇÃO DOS RESULTADOS

Geradas as bases de treinamento/teste, os dados foram discretizados com número máximo de *bins*=32, o algoritmo de John e Langley (1995) implementado na plataforma Weka⁸ foi usado para determinar os parâmetros numéricos de um classificador *Naive Bayes* para cada um dos conjuntos do Apêndice A.

Para avaliar o desempenho dos classificadores foi aplicada a validação cruzada⁹ estratificada com fator 10, no classificador treinado na etapa anterior. De posse dos resultados, foram realizadas análises dos índices de acurácia balanceada e *informedness*.

Brodersen *et al.* (2010) sugerem o cálculo da acurácia balanceada como índice para avaliar o desempenho de classificadores. Os autores argumentam que índices como acurácia convencional (número de previsões corretas dividido pelo número de casos) são tendenciosos quando aplicados em classificadores treinados com bases de dados desbalanceadas. Conforme foi observado na Tabela 1, a base de dados formada pelas características extraídas das imagens do interior de estufas

⁸ Endereço web: <http://www.cs.waikato.ac.nz/ml/weka/>.

⁹ Validação cruzada é o método estatístico de avaliar e comparar algoritmos de aprendizagem dividindo conjunto de dados em dois segmentos: um para aprender ou treinar o modelo e outro para validar o modelo (REFAEILZADEH; TANG; LIU, 2009).

é desbalanceada, pois o número de rótulos(muretas) é pequeno em relação às demais informações dos grupos(G1,G2,G3,G4,G5,G6).

A acurácia balanceada evita estimativas de desempenho tendenciosas em conjuntos de dados desbalanceados, tendo como parâmetros a sensibilidade e a especificidade. A sensibilidade é a proporção de verdadeiros positivos que foram corretamente classificados; por outro lado a especificidade é a proporção de verdadeiros negativos corretamente classificados (Powers, 2011). Dessa forma, o classificador que apresenta índice alto de acurácia balanceada é um bom classificador para ambas as classes. A acurácia balanceada é dada por:

$$\text{Acurácia balanceada} = \frac{\text{sensibilidade} + \text{especificidade}}{2}$$

Powers (2011) define *informedness* como valor de confiança do classificador. Quanto mais próximo de 1, maior é a chance de que a informação dada seja verdadeira, quanto mais próximo de 0, maior é a chance de que a informação dada não tenha relação com a pergunta realizada. O índice *informedness* é calculado pela expressão:

$$\text{Informedness} = \text{sensibilidade} + \text{especificidade} - 1$$

3. 6. CONSIDERAÇÕES FINAIS

Este capítulo apresentou a metodologia experimental deste trabalho. Metodologia essa que abrange desde a coleta das imagens até os testes que contribuíram para encontrar os resultados.

No próximo capítulo são apresentados os resultados desses experimentos. O próximo capítulo também traz uma discussão a respeito desses resultados.

4. RESULTADOS E DISCUSSÃO

Esta seção descreve os resultados obtidos pela aplicação dos procedimentos apresentados na seção de metodologia. Além disso, as principais evidências fornecidas pelos experimentos são discutidas. Inicialmente, na seção 4.1 são mostrados os resultados para cada grupo usando classificadores com todos os quarenta atributos. Na seção 4.2 são descritos resultados obtidos na seleção de atributos em conjunto de imagens G2 e G6. Na seção 4.3 são apresentados os resultados para classificadores treinados a partir de conjunto dos atributos selecionados nos grupos G1, G3, G4 e G5. A seção 4.4 traz as considerações finais do capítulo.

4.1. DESEMPENHO DO CLASSIFICADOR COM TODOS OS ATRIBUTOS

O desempenho dos classificadores treinados em cada grupo usando todos os atributos é mostrado na Tabela 4. Nessa tabela, a primeira coluna indica o conjunto de dados, a segunda a acurácia, a terceira a acurácia balanceada e a quarta o índice *informedness*. O Gráfico 1 ilustra esses mesmos resultados.


Tabela 4- Índices de Acurácia Balanceada e *Informedness* grupos(1, 2, 3, 4, 5, 6).

BASE	ACURÁCIA	ACURÁCIA BALANCEADA	INFORMEDNESS
G1	0,850	0,794	0,587
G2	0,920	0,770	0,539
G3	0,823	0,850	0,699
G4	0,803	0,820	0,640
G5	0,859	0,813	0,625
G6	0,890	0,892	0,784

Como pode ser observado na Tabela 4, o grupo G6 apresentou maior índice e o grupo G2 apresentou menor índice de acurácia balanceada e *informedness* entre os grupos. Como esperado, o desempenho dos classificadores, em termos desses dois índices, está relacionado com a correlação das variáveis descritoras em relação à variável meta. A média das correlações nos grupos G1 a G6 era 0,04; 0,037; 0,144; 0,074; 0,071; 0,185 respectivamente. Como pode ser notado, se ordenarmos

os grupos em relação a acurácia balanceada ou ao índice *informedness*, teremos a mesma ordem dada pela média das correlações.

Gráfico 1: Acurácia, Acurácia Balanceada e *Informedness* usando todos os atributos



O desempenho dos classificadores quanto à acurácia convencional foi maior no grupo G2. Contudo, deve ser observado que a acurácia é afetada pelo fato da base de dados ser desbalanceada. A proporção de casos positivos é 4% e de casos negativos 96%. Isso fez com que o classificador tendesse a rotular os casos como negativos, este fato que pode ser observado ao notarmos que os valores da sensibilidade e da especificidade dos classificadores para os grupos G1 a G6 foram (0,732;0,855), (0,607;0,932), (0,885;0,814), (0,841;0,799), (0,762;0,863) e (0,895;0,889). Como pode ser visto, o grupo G2 tem a menor sensibilidade indicando que o classificador entre os demais possui menor proporção em detectar a mureta (verdadeiro positivo), isto é, a proporção de erros do tipo falso negativo foi de 0,393. Considerando isto, a partir deste ponto apenas os índices de acurácia balanceada e *informedness* serão empregados.

4.2. RESULTADOS : GRUPOS G2 e G6

As Tabelas 5 e 6 mostram o desempenho dos classificadores gerados sobre as bases de treinamento/teste para os grupos G2 e G6, respectivamente. Nestas tabelas, a primeira e a quarta colunas indicam o conjunto de dados, a segunda e a quinta colunas a acurácia balanceada e a terceira e a sexta colunas o índice *informedness*. Os gráficos 2, 3, 4 e 5 ilustram os resultados para classificadores gerados pelos métodos de seleção B2 e B4.

Tabela 5- Resultados grupo 2

Base de Dados	Acurácia Balanceada	Informedness	Base de Dados	Acurácia Balanceada	Informedness
G2B2A12B	0,555	0,109	G2B4A12B	0,522	0,044
G2B2A12G2	0,580	0,160	G2B4A12G2	0,575	0,149
G2B2A17B	0,693	0,385	G2B4A17B	0,644	0,288
G2B2A17G2	0,693	0,385	G2B4A17G2	0,667	0,333
G2B2A22B	0,717	0,434	G2B4A22B	0,683	0,365
G2B2A22G2	0,719	0,437	G2B4A22G2	0,696	0,391
G2B2A27B	0,738	0,475	G2B4A27B	0,733	0,466
G2B2A27G2	0,735	0,470	G2B4A27G2	0,735	0,470





Gráfico 2- (a) Acurácia balanceada (b) *Informedness*, grupo 2, método B2Gráfico 3- (a) Acurácia balanceada (b) *Informedness*, grupo 2, método B4

Tabela 6- Resultados grupo 6

Base de Dados	Acurácia Balanceada	Informedness	Base de Dados	Acurácia Balanceada	Informedness
G6B2A12B	0,782	0,563	G6B4A12B	0,665	0,330
G6B2A12G6	0,854	0,707	G6B4A12G6	0,780	0,560
G6B2A17B	0,874	0,747	G6B4A17B	0,851	0,702
G6B2A17G6	0,855	0,710	G6B4A17G6	0,814	0,627
G6B2A22B	0,878	0,756	G6B4A22B	0,864	0,727
G6B2A22G6	0,878	0,755	G6B4A22G6	0,858	0,715
G6B2A27B	0,881	0,762	G6B4A27B	0,886	0,771
G6B2A27G6	0,882	0,764	G6B4A27G6	0,862	0,723

Gráfico 4- (a) Acurácia balanceada (b) *Informedness*, grupo 6, método B2Gráfico 5- (a) Acurácia balanceada (b) *Informedness*, grupo 6, método B4

Como pode ser observado, o método B2 obteve melhor desempenho na maioria das seleções. Além disso, percebe-se que nesses grupos o algoritmo B2 selecionou atributos que levaram à indução de classificadores cujo desempenho era maior ou igual ao desempenho dos classificadores gerados com atributos selecionados na base B em três das quatro seleções. Deve ser notado que a distância euclidiana D dos centroides desses grupos em relação ao centroide do grupo B, denotado por U , era maior do que a distância dos centroides dos demais grupos a U . Para G2 e G6 D era igual a 122,44 e 97,14 respectivamente.

Ao comparar-se os desempenhos dos classificadores gerados em G2 e G6 nota-se que os do segundo grupo obtiveram melhores índices de acurácia balanceada e *informedness* do que os classificadores induzidos no primeiro grupo. Esse resultado pode ser explicado pelo fato de que na média a correlação dos atributos em G6 é maior do que a média correlação dos atributos em G2.

4.3. RESULTADOS: G1, G3, G4 e G5

O desempenho dos classificadores gerados sobre as bases de treinamento/teste G1, G3, G4 e G5 são mostrados nas Tabelas 7, 8, 9 e 10, respectivamente, e ilustrados nos Gráficos 6 a 13.

Nos grupos G1, G3, G4 e G5 as distâncias dos respectivos centroides ao centroide de B eram de 71,46; 45,25; 72,16 e 55,5. Portanto, os centros desses grupos estão mais próximos do centro de B do que os centroides de G2 e G6. Nesses quatro casos as seleções realizadas em B geraram, na maioria das vezes, classificadores cujo desempenho era superior àqueles treinados em cada agrupamento. Além disso, a média da correlação dos atributos em B é maior que a média da correlação dos atributos nos G1, G4 e G5.

Tabela 7 - Resultados grupo 1

Base de Dados	Acurácia Balanceada	Informedness	Base de Dados	Acurácia Balanceada	Informedness
G1B2A12B	0,555	0,109	G1B4A12B	0,529	0,058
G1B2A12G1	0,537	0,074	G1B4A12G1	0,550	0,099
G1B2A17B	0,645	0,290	G1B4A17B	0,607	0,213
G1B2A17G1	0,545	0,089	G1B4A17G1	0,563	0,126
G1B2A22B	0,653	0,306	G1B4A22B	0,630	0,259
G1B2A22G1	0,637	0,274	G1B4A22G1	0,637	0,274
G1B2A27B	0,693	0,385	G1B4A27AB	0,685	0,369
G1B2A27G1	0,781	0,562	G1B4A27G1	0,781	0,562



Gráfico 6- (a)Acurácia balanceada (b) *Informedness*, grupo 1, método B2Gráfico 7- (a) Acurácia balanceada (b) *Informedness*, grupo 1, método B4

Tabela 8- Resultados grupo 3

Base de Dados	Acurácia Balanceada	Informedness	Base de Dados	Acurácia Balanceada	Informedness
G3B2A12B	0,792	0,583	G3B4A12B	0,748	0,496
G3B2A12G3	0,788	0,575	G3B4A12G3	0,706	0,411
G3B2A17B	0,840	0,679	G3B4A17B	0,834	0,668
G3B2A17G3	0,812	0,623	G3B4A17G3	0,773	0,545
G3B2A22B	0,848	0,696	G3B4A22B	0,849	0,698
G3B2A22G3	0,847	0,694	G3B4A22G3	0,839	0,677
G3B2A27B	0,850	0,699	G3B4A27B	0,849	0,697
G3B2A27G3	0,855	0,709	G3B4A27G3	0,847	0,694



Gráfico 8- (a) Acurácia balanceada (b) *Informedness*, grupo 3, método B2Gráfico 9- (a) Acurácia balanceada (b) *Informedness*, grupo 3, método B4

Tabela 9- Resultados grupo 4

Base de Dados	Acurácia Balanceada	Informedness	Base de Dados	Acurácia Balanceada	Informedness
G4B2A12B	0,677	0,353	G4B4A12B	0,631	0,261
G4B2A12G4	0,716	0,432	G4B4A12G4	0,651	0,301
G4B2A17B	0,774	0,547	G4B4A17B	0,754	0,508
G4B2A17G4	0,765	0,529	G4B4A17G4	0,752	0,504
G4B2A22B	0,781	0,562	G4B4A22B	0,771	0,542
G4B2A22G4	0,776	0,552	G4B4A22G4	0,765	0,530
G4B2A27B	0,791	0,582	G4B4A27B	0,791	0,581
G4B2A27G4	0,788	0,575	G4B4A27G4	0,793	0,586

Gráfico 10- (a) Acurácia balanceada (b) Informedness, grupo 4, método B2




Gráfico 11- (a) Acurácia balanceada (b) Informedness, grupo 4, método B4






Tabela 10- Resultados grupo 5

Base de Dados	Acurácia Balanceada	Informedness	Base de Dados	Acurácia Balanceada	Informedness
G5B2A12B	0,606	0,211	G5B4A12B	0,615	0,230
G5B2A12G5	0,589	0,177	G5B4A12G5	0,587	0,174
G5B2A17B	0,675	0,350	G5B4A17B	0,693	0,386
G5B2A17G5	0,644	0,287	G5B4A17G5	0,648	0,296
G5B2A22B	0,717	0,434	G5B4A22B	0,734	0,468
G5B2A22G5	0,671	0,342	G5B4A22G5	0,689	0,377
G5B2A27B	0,766	0,531	G5B4A27B	0,764	0,527
G5B2A27G5	0,738	0,475	G5B4A27G5	0,751	0,501

Gráfico 12- (a) Acurácia balanceada (b) *Informedness*, grupo 5, método B2Gráfico 13- (a) Acurácia balanceada (b) *Informedness*, grupo 5, método B4

4.4. CONSIDERAÇÕES FINAIS

Este capítulo apresentou os resultados obtidos nos experimentos realizados neste trabalho. Os resultados indicam que a seleção de atributos e o treinamento de classificadores sobre partições de um conjunto de dados é interessante quando atende às seguintes condições: (a) a distância do centro do grupo ao centro da base original ultrapassa um limiar e (b) a correlação entre as variáveis descritoras e a variável meta é maior no grupo do que no conjunto completo de dados. A próxima seção apresenta as conclusões deste trabalho.

5. CONCLUSÕES E TRABALHOS FUTUROS

Há um crescente interesse no uso de robôs móveis e autônomos na agricultura, seja no campo, seja em estufas agrícolas. O uso desses equipamentos tem o objetivo de reduzir a exposição do ser humano a toxinas e aumentar a produtividade. Todavia um dos principais problemas na construção de robôs móveis e autônomos para trabalhar em estufas agrícolas é o desenvolvimento de sistemas de navegação que permitam que o robô detecte objetos e obstáculos em um ambiente em que geralmente não há controle de iluminação.

Neste trabalho o problema da detecção da mureta em uma estufa foi abordado com o uso de técnicas de visão computacional e classificação bayesiana. As técnicas de Visão Computacional foram aplicadas a fim de extrair características de cor e textura das imagens. As características foram usadas para elaboração de uma base de dados, a qual foi empregada na indução de classificadores do tipo Naive Bayes.

Como a eficiência computacional é um aspecto importante no desenvolvimento de sistemas de navegação para robôs móveis e como classificadores mais simples demandam menos tempo de processamento, este trabalho avaliou o uso dos métodos B2 e B4 para selecionar as características empregadas na composição dos classificadores, dessa forma foi possível reduzir o número de características. O trabalho também avaliou o efeito da seleção de variáveis e o treinamento de classificadores sobre bases de dados com imagens coletadas em diferentes condições de iluminação. A solução proposta para a questão referente às diferentes condições de iluminação foi o agrupamento de imagens em seis grupos por similaridade em termos da distribuição da média dos níveis de cinza em oito regiões da imagem usando o algoritmo médias-k. Para cada grupo foram gerados vários classificadores do tipo Naive Bayes, a estrutura de cada classificador dependia da estratégia de seleção escolhida. Em seguida, o desempenho dos classificadores gerados a partir de cada grupo foi comparado com o desempenho dos classificadores gerados a partir da base de dados composta por todas as imagens - independente da condição de iluminação.

O desempenho dos classificadores foi avaliado com os índices de acurácia balanceada e informedness. Esses índices procuram evitar avaliação tendenciosa em situações em que a distribuição das classes no conjunto de imagens utilizado

nos testes é desbalanceada. Particularmente, este é o caso das imagens tratadas neste trabalho. Em particular, o uso de índices que não observam essa característica do problema poderia gerar modelos com baixa sensibilidade.

Na análise dos classificadores gerados, foram identificados como: G1, G2, G3, G4, G5 e G6, de acordo com o grupo de imagens. Os grupos G2 e G6 se destacaram em relação aos demais grupos porque apresentaram uma maior diferença na média de tons de cinza do grupo em relação ao conjunto de todas as imagens. O resultado referente ao desempenho dos classificadores, mostrou que o ganho de desempenho em relação aos índices de acurácia balanceada e informedness, obtido com o uso da estratégia de gerar classificadores para imagens similares, cresce quando as imagens do grupo se destacam em relação as imagens do conjunto completo. Aqui, a expressão se destacam refere-se ao fato de que a diferença entre as médias dos valores dos níveis de cinza das imagens desses grupos e a média dos níveis de cinza do conjunto total de imagens é maior do que a diferença observada nos demais grupos. Também foi observado que, quando a média da correlação dos atributos descritores com a variável meta do grupo de imagens similares é maior que a média da correlação do conjunto de todas as imagens, os resultados são melhores. Esse fato também foi observado no grupo G6.

Com o objetivo de melhorar os resultados dos classificadores gerados e se obter maiores informações sobre a indução de classificadores especializados para diferentes condições de iluminação, pretende-se estender este trabalho. Inicialmente, pretende-se aplicar técnicas para conjunto de dados desbalanceados. Em seguida, pretende-se avaliar o uso de outros extratores de características para textura e filtros para detecção de elementos geométricos como linhas paralelas e regiões homogêneas. Também se objetiva testar outras métricas para a definição das distâncias entre os grupos além da distância euclidiana; entre elas, a distância de Komolgorov-Smirnov, a distância χ quadrado.

REFERÊNCIAS

- ACACCIA, G.M.; MICHELINI R.C.; MOLFINO, R.M.; RAZZOLI, R.P. Mobile robots in greenhouse cultivation: inspection and treatment of plants. International Workshop on Advances in Service Robotics, pp. 1-6, ISBN 3-8167-6268-9, Bardolino, Italia. 2003.
- BUEMI F.; MAGRASSI M.; MANNUCCI A.; MASSA M.; SANDINI G. The vision system for the agrobot project, Proc. *5th ASAE International Conference on Computers in Agriculture*, Orlando, 1994.
- BRODERSEN, K. H.; ONG, C. S.; STEPHAN, K. E.; BUHMANN, J. M. The balanced accuracy and its posterior distribution. In *Pattern Recognition (ICPR), 20th International Conference on* (pp. 3121-3124). IEEE. 2010
- DASH, M.; LIU, H. Feature selection for classification. *Intelligent data analysis* 1.3: 131-156. 1997.
- ECKLEY, I. A.; NASON, G. P.; TRELOAR, R. L. Locally stationary wavelet fields with application to the modelling and analysis of image texture. *Journal of the Royal Statistical Society: Series C (Applied Statistics)* 59.4: 595-616. 2010.
- ECKLEY, I. A.; NASON, G. P. Ls2w: implementing the locally stationary 2d wavelet process approach in R. *Journal of Statistical Software* 43.3 1-23. 2011.
- FERREIRA, D. F. Estatística Multivariada. 1. ed. Lavras: UFLA, 2008.
- FRIEDMAN, N.; GOLDSZMIDT, M. Building classifiers using Bayesian networks. In: *Proceedings of the national conference on artificial intelligence*. p. 1277-1284. 1996.
- FRIEDMAN, N.; GEIGER, D.; GOLDSZMIDT, M. Bayesian network classifiers. *Machine learning* 29.2-3: 131-163, 1997.
- GONZALES, R. C.; WOODS, R. E. Processamento de imagens digitais. São Paulo, Editora Blucher, 2002.
- GONZALES, R. C.; WOODS, R. E.; EDDINS, L. S. *Digital image processing using MATLAB*. Vol. 2. Knoxville: Gatesmark Publishing, 2009.
- GONZALEZ, R.; RODRIGUEZ F.; SANCHEZ-HERMOSILLA J.; DONAIRE J.G. Navigation Techniques for Mobile Robots in Greenhouses. *Applied Engineering in Agriculture*, vol.25, 2009, pp 153-165.
- GUO, Q.; WU, W.; MASSART, D.L.; BOUCON, C.; JONG, S. de. Feature selection in principal component analysis of analytical data. *Chemometrics and Intelligent Laboratory Systems* 61.1: 123-132. 2002.
- HARALICK, R. M.; SHANMUGAM, K.; DINSTEN I. H. Textural features for image classification. *Systems, Man and Cybernetics, IEEE Transactions on* 6: 610-621, 1973.

HARALICK, R. M.; SHAPIRO, L. G. Glossary of computer vision terms. *Pattern recognition* 24.1: 69-93, 1991.

HORNIK, K. FEINERER, I. KOBERET, M. Package 'skmeans', 2013.

JOHN, G. H.; LANGLEY, P. Estimating continuous distributions in Bayesian classifiers. Proceedings of the Eleventh conference on Uncertainty in artificial intelligence. Morgan Kaufmann Publishers Inc, 1995.

JOLLIFFE, I. T. Discarding Variables in a Principal Component Analysis. I: Artificial Data. *Journal of the Royal Statistical Society. Series C (Applied Statistics)*, Blackwell Publishing for the Royal Statistical Society, v. 21, n. 2, p. 160-173, 1972.

KING, J. R.; JACKSON A. D. Variable selection in large environmental data sets using principal components analysis. *Environmetrics* 10.1: 67-77. 1999.

MANDOW, A.; GOMEZ-DE-GABRIEL, J.M.; MARTÍNEZ, J.L.; MUNÓZ, V.F.; OLLERO, A.; GARCÍA-CEREZO, A. The autonomous mobile robot AURORA for greenhouse operation. *Robotics e Automation. IEEE*, 3 (4) pp. 18-28, 1996.

MARQUES FILHO, O.; VIEIRA NETO, H. *Processamento Digital de Imagens*, Rio de Janeiro: Brasport, 1999. ISBN 8574520098.

MARQUES, O. *Practical image and video processing using MATLAB*. Wiley. com, 2011.

MEHTA, S. S.; BURKS, T. F.; DIXON, W. E. Vision-based localization of a wheeled mobile robot for greenhouse applications: A daisy-chaining approach. *Computers and electronics in agriculture*, v. 63, n. 1, p. 28-37, 2008.

MITCHELL, T. *Machine learning*. New York: McGraw-Hill, 1997.

MOVELLAN, Javier R. Tutorial on Gabor filters. Open Source Document, 2002.

NAVA, R.; CRISTÓBAL, G.; ESCALANTE-RAMÍREZ, B. Invariant texture analysis through Local Binary Patterns. arXiv preprint arXiv:1111.7271, 2011.

OJALA, T.; PIETIKAINEN, M.; MAENPAA, T. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, v. 24, n. 7, p. 971-987, 2002.

PEARL, J. *Probabilistic Reasoning in Intelligent Systems: Networks of plausible inference*. Morgan Kaufmann Publishers, 2nd edition, 1988.

POWERS, D. M. W. Evaluation: From precision, recall and f-measure to roc., informedness, markedness & correlation. *Journal of Machine Learning Technologies*, v. 2, n. 1, p. 37-63, 2011.

PURQUERIO, L.F.V.; TIVELLI, S.W. Manejo do ambiente em cultivo protegido. Manual técnico de orientação: projeto hortalimento. São Paulo: Codeagro, p. 15-29. 2006.

REFAELZADEH, P.; TANG, L.; LIU, H. Cross-validation. In: Encyclopedia of Database Systems. Springer US, p. 532-538. 2009.

RUSSELL, S.; NORVIG, P. Artificial Intelligence: A Modern Approach. Prentice-Hall, Second Edition, 2004.

SALES, D.; OSÓRIO, F.; WOLF, D. Topological autonomous navigation for mobile robots in indoor environments using ann and fsm. In: Proceedings of the I Brazilian Conference on Critical Embedded Systems (CBSEC), São Carlos, Brazil. 2011.

SAMMONS, P. J.; FURUKAWA, T.; BULGIN, A. Autonomous pesticide spraying robot for use in a greenhouse. In: Australian Conference on Robotics and Automation. p. 1-9. 2005.

SANCHEZ-HERMOSILLA, J.; RODRÍGUEZ, F.; GONZÁLEZ, R.; GUZMÁN, J.L.; BERENGUEL, M. A mechatronic description of an autonomous mobile robot for agricultural tasks in green-houses. Mobile Robots Navigation, p 583-608, 2010.

SUCAR, L. E.; GILLIES, D. F. Probabilistic reasoning in high-level vision. Image and vision computing, v. 12, n. 1, p. 42-60, 1994.

THRUN, S.; BURGARD, W.; FOX, D. *Probabilistic robotics*. Vol. 1. Cambridge: MIT press, 2005.

THEODORIDIS, S.; KOUTROUMBAS K. *Pattern Recognition*. Elsevier. 4 ed. 2009. ISBN 978-159749-272-0

VIDA, J. B.; ZAMBOLIM, L.; TESSMANN, D. J.; BRANDÃO FILHO, J. U. T.; VERZIGNASSI, J. R.; Caixeta, M. P. Manejo de doenças de plantas em cultivo protegido. Fitopatologia Brasileira, 29(4), 355-372. 2004.

ZHANG, H.; GAO, W.; CHEN, X.; ZHAO, D. Object detection using spatial histogram features. Image and Vision Computing 24.4: 327-341. 2006.

WOLF, D. F.; OSÓRIO, F. S.; SIMÕES, E.; TRINDADE JR, O. Robótica Inteligente: Da Simulação às Aplicações no Mundo Real.[Tutorial] In: André Ponce de Leon F. de Carvalho; Tomasz Kowaltowski.(Org.). JAI: Jornada de Atualização em Informática da SBC. Rio de Janeiro: SBC-Editora da PUC. RJ, 1, 279-330. 2009.

ANEXO LISTA DE NOMES DAS BASES GERADAS DE ACORDO COM:
A- GRUPO, MÉTODO DE SELEÇÃO DE ATRIBUTOS, NÚMERO DE
ATRIBUTOS, BASE DE ORIGEM.

(continua)				
Rótulo da Base	Grupo de imagens	Método de Seleção	Número de Atributos	Conjunto de atributos
G1B2A27B	1	B2	27	B
G1B2A22B	1	B2	22	B
G1B2A17B	1	B2	17	B
G1B2A12B	1	B2	12	B
G1B2A27B	1	B2	27	B
G1B2A22B	1	B2	22	B
G1B2A17B	1	B2	17	B
G1B2A12B	1	B2	12	B
G1B4A27G1	1	B4	27	G1
G1B4A22G1	1	B4	22	G1
G1B4A17G1	1	B4	17	G1
G1B4A12G1	1	B4	12	G1
G1B4A27G1	1	B4	27	G1
G1B4A22G1	1	B4	22	G1
G1B4A17G1	1	B4	17	G1
G1B4A12G1	1	B4	12	G1
G2B2A27B	2	B2	27	B
G2B2A22B	2	B2	22	B
G2B2A17B	2	B2	17	B
G2B2A12B	2	B2	12	B
G2B2A27B	2	B2	27	B
G2B2A22B	2	B2	22	B
G2B2A17B	2	B2	17	B
G2B2A12B	2	B2	12	B
G2B4A27G2	2	B4	27	G2
G2B4A22G2	2	B4	22	G2
G2B4A17G2	2	B4	17	G2
G2B4A12G2	2	B4	12	G2
G2B4A27G2	2	B4	27	G2
G2B4A22G2	2	B4	22	G2
G2B4A17G2	2	B4	17	G2
G2B4A12G2	2	B4	12	G2
G3B2A27B	3	B2	27	B
G3B2A22B	3	B2	22	B
G3B2A17B	3	B2	17	B
G3B2A12B	3	B2	12	B
G3B2A27B	3	B2	27	B
G3B2A22B	3	B2	22	B
G3B2A17B	3	B2	17	B
G3B2A12B	3	B2	12	B
G3B4A27G3	3	B4	27	G3
G3B4A22G3	3	B4	22	G3
G3B4A17G3	3	B4	17	G3
G3B4A12G3	3	B4	12	G3
G3B4A27G3	3	B4	27	G3
G3B4A22G3	3	B4	22	G3
G3B4A17G3	3	B4	17	G3
G3B4A12G3	3	B4	12	G3
G4B2A27B	4	B2	27	B
G4B2A22B	4	B2	22	B
G4B2A17B	4	B2	17	B

Rótulo da Base	Grupo de imagens	Método de Seleção	Número de Atributos	(conclusão) Conjunto de atributos
G4B2A12B	4	B2	12	B
G4B2A27B	4	B2	27	B
G4B2A22B	4	B2	22	B
G4B2A17B	4	B2	17	B
G4B2A12B	4	B2	12	B
G4B4A27G4	4	B4	27	G4
G4B4A22G4	4	B4	22	G4
G4B4A17G4	4	B4	17	G4
G4B4A12G4	4	B4	12	G4
G4B4A27G4	4	B4	27	G4
G4B4A22G4	4	B4	22	G4
G4B4A17G4	4	B4	17	G4
G4B4A12G4	4	B4	12	G4
G5B2A27B	5	B2	27	B
G5B2A22B	5	B2	22	B
G5B2A17B	5	B2	17	B
G5B2A12B	5	B2	12	B
G5B2A27B	5	B2	27	B
G5B2A22B	5	B2	22	B
G5B2A17B	5	B2	17	B
G5B2A12B	5	B2	12	B
G5B4A27G5	5	B4	27	G5
G5B4A22G5	5	B4	22	G5
G5B4A17G5	5	B4	17	G5
G5B4A12G5	5	B4	12	G5
G5B4A27G5	5	B4	27	G5
G5B4A22G5	5	B4	22	G5
G5B4A17G5	5	B4	17	G5
G5B4A12G5	5	B4	12	G5
G6B2A27B	6	B2	27	B
G6B2A22B	6	B2	22	B
G6B2A17B	6	B2	17	B
G6B2A12B	6	B2	12	B
G6B2A27B	6	B2	27	B
G6B2A22B	6	B2	22	B
G6B2A17B	6	B2	17	B
G6B2A12B	6	B2	12	B
G6B4A27G6	6	B4	27	G6
G6B4A22G6	6	B4	22	G6
G6B4A17G6	6	B4	17	G6
G6B4A12G6	6	B4	12	G6
G6B4A27G6	6	B4	27	G6
G6B4A22G6	6	B4	22	G6
G6B4A17G6	6	B4	17	G6
G6B4A12G6	6	B4	12	G6