

PAULO RICARDO LISBOA DE ALMEIDA

**COMBINAÇÃO DE CARACTERÍSTICAS TEXTURAIS PARA A
CLASSIFICAÇÃO AUTOMÁTICA DE VAGAS DE
ESTACIONAMENTO**

CURITIBA

2014

PAULO RICARDO LISBOA DE ALMEIDA

**COMBINAÇÃO DE CARACTERÍSTICAS TEXTURAIS PARA A
CLASSIFICAÇÃO AUTOMÁTICA DE VAGAS DE
ESTACIONAMENTO**

Dissertação apresentada como requisito parcial para obtenção do grau de Mestre. Programa de Pós-Graduação em Informática, Setor de Ciências Exatas, Universidade Federal do Paraná.

Orientador: Prof. Dr. Luiz Eduardo S. Oliveira

Co-Orientador: Prof. Dr. Alceu de S. Britto Jr.

CURITIBA

2014



Ministério da Educação
Universidade Federal do Paraná
Programa de Pós-Graduação em Informática

PARECER

Nós, abaixo assinados, membros da Banca Examinadora da defesa de Dissertação de Mestrado em Informática, do aluno Paulo Ricardo Lisboa de Almeida, avaliamos o trabalho intitulado, “*Combinação de Características Texturais para a Classificação Automática de Vagas de Estacionamento*”, cuja defesa foi realizada no dia 17 de dezembro de 2013, às 09:00 horas, no Departamento de Informática do Setor de Ciências Exatas da Universidade Federal do Paraná. Após a avaliação, decidimos pela:
aprovação do candidato. ()reprovação do candidato.

Curitiba, 17 de dezembro de 2013.

Prof. Dr. Luiz Eduardo Soares de Oliveira
DINF/UFPR – Orientador

Prof. Dr. Alessandro Lameiras Koerich
PUC/PR – Membro Externo

Prof. Dr. Alceu de Souza Britto Jr
PUC/PR – Membro Externo



Agradecimentos

Agradeço aos meus pais Maria e Paulo Almeida pelo apoio incondicional e por todos seus ensinamentos.

À minha irmã Natali Almeida, pelo apoio e por ser uma pessoa com quem sempre posso contar e confiar.

Agradeço à minha namorada Camila Oliveira pelos bons momentos proporcionados e pela compreensão à minha ausência quando precisei me dedicar à este trabalho.

Ao meu amigo Eunelson Silva, que além de ser um grande amigo me ajudou na engenharia de diversos componentes necessários para a confecção deste trabalho.

Aos professores Luiz Oliveira (orientador) e Alceu Britto (co-orientador) pela amizade, pelo incentivo e por suas valorosas contribuições neste trabalho.

Ao membro da banca professor Alessandro Koerich por suas sugestões e contribuições que ajudaram a enriquecer o trabalho.

Também agradeço a todos meus demais amigos e familiares, pelo incentivo e apoio.

Resumo

A crescente frota de veículos nas cidades aliada à falta de planejamento urbano têm tornado cada vez mais difícil a tarefa de se encontrar vagas de estacionamento, forçando os motoristas a procurarem alternativas como os pátios de estacionamentos públicos ou privados, que são dedicados exclusivamente a acomodar um grande número de veículos. Uma metodologia viável para a gerência das vagas individuais desses estabelecimentos, ou das vagas laterais presentes em vias públicas, apesar de ser um grande desafio, pode prover informações importantes para a engenharia de tráfego, como o índice de ocupação das vagas, as áreas mais utilizadas e a detecção de superlotações, além de poder servir como base para sistemas que executem tarefas como a detecção de veículos estacionados irregularmente ou que guiem o motorista até a vaga livre mais próxima. Neste trabalho é proposta uma metodologia para classificação de vagas de estacionamento baseada em imagens coletadas de câmeras fixas, capaz de lidar com as complexidades impostas a sistemas que capturam imagens em ambientes abertos, como as variações de luminosidade, a presença de sombras e os ruídos causados pelas variações climáticas. Para cumprir essa tarefa são utilizados descritores de textura baseados nos Padrões Locais Binários e na Quantização de Fase Local, que têm mostrado excelentes resultados em diversos trabalhos. Para possibilitar os testes deste e de outros trabalhos relacionados à detecção de veículos em áreas de estacionamentos, foi criada uma base de imagens que atualmente contém cerca de 1.300.000 amostras de vagas individuais coletadas de dois estacionamentos distintos, de diferentes ângulos e em diversas condições climáticas, a qual está disponível para trabalhos de pesquisa. Os resultados dos experimentos mostram que os classificadores treinados com os descritores de textura são capazes de atingir excelentes taxas de acertos, próximas aos 100%. Testes com amostras coletadas de estacionamentos ou de ângulos que não participaram dos treinamentos dos classificadores também foram executados, e mostraram que os classificadores ainda são capazes de atingir boas taxas de acertos, geralmente próximas aos 85%. Métodos de combinação de classificadores também foram utilizados e se mostraram capazes de melhorar os desempenhos dos classificadores, principalmente nos testes com amostras coletadas de estacionamentos ou ângulos diferentes dos utilizados nos treinamentos dos classificadores.

Palavras-chave: Transporte inteligente. Veículos. Processamento de imagens. Detecção de vagas. Textura. LBP. LPQ.

Abstract

The growing fleet of vehicles in the cities allied with the lack of urban planning has made increasingly difficult the task of finding parking spaces, leading drivers to seek for alternatives like public or private parking lots, which are designed exclusively to accommodate a large number of vehicles. A feasible methodology for managing individual parking spaces in a parking lot, or the parking spaces present on public roads, despite being a big challenge, can provide important information for traffic engineering such as the occupancy rate of parking spaces, the most used areas and detection of overcrowding, and can also serve as the basis for systems that perform tasks such as detecting illegally parked vehicles or to guide the driver to the nearest free vacant lot. This work proposes a methodology for classification of parking spaces based on images collected from fixed cameras, capable of handling the complexities imposed on systems that capture images in outdoor environments, such as light variations, the presence of shadows and noises caused by weather variations. To accomplish this task texture descriptors based on Local Binary Patterns and Local Phase Quantization were employed, since these descriptors have shown excellent results in several studies. To allow the tests of this and other works related to the detection of vehicles in parking areas, we have built an image database that currently contains about 1,300,000 individual parking spaces samples collected from two separate parking lots from distinct angles and under different weather conditions, which is available for research purposes. The experimental results show that the classifiers trained with texture descriptors are able to achieve excellent accuracies, close to 100%. Tests on samples collected from parking lots or angles that have not participated in the training of the classifiers were also performed and showed that the classifiers are still able to achieve good accuracies, generally close to 85%. Classifiers combining methods were also tested and were able to improve the performance of classifiers, especially in the experiments that the samples were collected from parking lots or angles different from those used for training the classifiers.

Key-words: Intelligent transportation. Vehicles. Image processing. Parking detection. Texture. LBP. LPQ.

Lista de Figuras

Figura 1.1	Exemplos de variação de luminosidade	16
Figura 2.1	Estágios envolvidos na construção de um classificador	21
Figura 2.2	Exemplo de cálculo do LBP	23
Figura 2.3	Padrões Uniformes e não Uniformes	24
Figura 2.4	Exemplos de hiperplanos para separação entre duas classes	27
Figura 2.5	Razões para utilização da combinação de classificadores	29
Figura 2.6	Fusão das respostas de diversos classificadores	30
Figura 2.7	Exemplo de Curva ROC	34
Figura 3.1	Exemplo de pacote com 3 vagas	38
Figura 3.2	Modelo Bayesiano Hierárquico	40
Figura 4.1	Fluxograma para classificação das vagas	55
Figura 4.2	Estacionamento UFPR04 com dia ensolarado	58
Figura 4.3	Estacionamento UFPR05 com dia ensolarado	58
Figura 4.4	Estacionamento UFPR04 com dia chuvoso	59
Figura 4.5	Estacionamento PUCPR com dia ensolarado	60
Figura 4.6	Estacionamento PUCPR com dia chuvoso	60

Figura 4.7	Exemplo de Descritor XML de um estacionamento	61
Figura 4.8	Exemplo de segmentação de uma imagem de estacionamento	62
Figura 4.9	Esquemas de rotação das amostras	63
Figura 4.10	Imagens Segmentadas	63
Figura 4.11	Exemplo de veículos estacionados irregularmente	64
Figura 4.12	Vagas Segmentadas no estacionamento PUCPR	65
Figura 5.1	O mesmo veículo capturado respectivamente às 8:48, 9:18 e 9:43 de um mesmo dia	69
Figura 5.2	Esquema de treinamento de classificadores por estacionamento	72
Figura 5.3	Curvas ROC dos testes UFPR04/UFPR04	73
Figura 5.4	Imagens classificadas incorretamente para o teste UFPR04/UFPR04	73
Figura 5.5	Curvas ROC dos testes UFPR04/UFPR05	74
Figura 5.6	Curvas ROC dos testes UFPR04/PUCPR	75
Figura 5.7	Curvas ROC dos testes UFPR05/UFPR05	77
Figura 5.8	Imagens classificadas incorretamente para o teste UFPR05/UFPR05	77
Figura 5.9	Curvas ROC dos testes UFPR05/UFPR04	78
Figura 5.10	Curvas ROC dos testes UFPR05/PUCPR	79
Figura 5.11	Curvas ROC dos testes PUCPR/PUCPR	81
Figura 5.12	Imagens classificadas incorretamente para o teste PUCPR/PUCPR	81

Figura 5.13 Curvas ROC dos testes PUCPR/UFPR04	82
Figura 5.14 Curvas ROC dos testes PUCPR/UFPR05	83
Figura 5.15 Curvas ROC dos testes TODOS/UFPR04	85
Figura 5.16 Curvas ROC dos testes TODOS/UFPR05	87
Figura 5.17 Curvas ROC dos testes TODOS/PUCPR	87
Figura 5.18 Exemplos de imagens da base de Huang e Wang (2010)	89
Figura 5.19 Curvas ROC para os testes na base de Huang e Wang (2010) com dia ensolarado normal	91
Figura 5.20 Curvas ROC para os testes na base de Huang e Wang (2010) com dia de muita incidência de luz solar	91
Figura 5.21 Curvas ROC para os testes na base de Huang e Wang (2010) com dia com luminosidade variável	92

Lista de Tabelas

Tabela 2.1	Matriz de Confusão para problemas binários	33
Tabela 3.1	Sumarização das Metodologias	45
Tabela 4.1	Base de Imagens	57
Tabela 4.2	Quantidade de amostras vazias/ocupadas presentes na base	65
Tabela 4.3	Extrações de características	66
Tabela 5.1	Separação entre a base de treinamento e testes	70
Tabela 5.2	Melhores classificadores para o teste UFPR04/UFPR04	72
Tabela 5.3	Melhores classificadores para o teste UFPR04/UFPR05	74
Tabela 5.4	Melhores classificadores para o teste UFPR04/PUCPR	75
Tabela 5.5	Resultados obtidos nas bases de teste utilizando os classificadores treinados com amostras do estacionamento UFPR04	76
Tabela 5.6	Melhores classificadores para o teste UFPR05/UFPR05	76
Tabela 5.7	Melhores classificadores para o teste UFPR05/UFPR04	78
Tabela 5.8	Melhores classificadores para o teste UFPR05/PUCPR	79
Tabela 5.9	Resultados obtidos nas bases de teste utilizando os classificadores treinados com amostras do estacionamento UFPR05	80
Tabela 5.10	Melhores classificadores para o teste PUCPR/PUCPR	80
Tabela 5.11	Melhores classificadores para o teste PUCPR/UFPR04	80

Tabela 5.12 Melhores classificadores para o teste PUCPR/UFPR05	82
Tabela 5.13 Resultados obtidos nas bases de teste utilizando os classificadores treinados com amostras do estacionamento PUCPR	84
Tabela 5.14 Comparativo dos resultados na base UFPR04	86
Tabela 5.15 Comparativo dos resultados na base UFPR05	88
Tabela 5.16 Comparativo dos resultados na base PUCPR	88
Tabela 5.17 Quantidades de amostras segmentadas na base de Huang e Wang (2010) .	90
Tabela 5.18 Resultados na base de Huang e Wang (2010)	93

Lista de Siglas

AUC	<i>Area Under ROC Curve</i>
DFT	<i>Discrete Fourier Transform</i>
EER	<i>Equal Error Rate</i>
GMM	<i>Gaussian Mixture Model</i>
HSI	<i>Hue, Saturation, and Intensity</i>
HSV	<i>Hue, Saturation, and Value</i>
JPEG	<i>Joint Photographic Experts Group</i>
LBP	<i>Local Binary Pattern</i>
LPQ	<i>Local Phase Quantization</i>
FN	Falso Negativo
FP	Falso Positivo
FPGA	<i>Field Programmable Gate Array</i>
FNR	<i>False Negative Rate</i>
FPR	<i>False Positive Rate</i>
PCA	<i>Principal Component Analysis</i>
PSF	<i>Point Spread Function</i>
PSO	<i>Particle Swarm Optimization</i>
RBF	<i>Radial Basis Function</i>
RGB	<i>Red, Green and Blue</i>
ROC	<i>Receiver Operating Characteristic</i>
STFT	<i>Short-Term Fourier Transform</i>
SVM	<i>Support Vector Machine</i>
TA	Taxa de acertos
TNR	<i>True Negative Rate</i>
TPR	<i>True Positive Rate</i>

VN Verdadeiro Negativo

VP Verdadeiro Positivo

XML *Extensible Markup Language*

Sumário

1	Introdução	14
1.1	Definição do Problema	14
1.2	Objetivos	16
1.3	Desafios	17
1.4	Hipóteses	18
1.5	Contribuições do Trabalho	18
1.6	Estrutura do Documento	19
2	Fundamentação Teórica	20
2.1	Reconhecimento de Padrões	20
2.2	Características Relacionadas à Textura	21
2.2.1	Padrões Locais Binários	22
2.2.2	Quantização de Fase Local	24
2.3	Máquinas de Vetor de Suporte	26
2.4	Combinação de Classificadores	28
2.4.1	Métodos de Fusão	30
2.5	Métricas de Avaliação de Classificadores	32
2.5.1	Taxas de acertos e matrizes de confusão	32
2.5.2	Curvas ROC e Área Sob a Curva ROC	33
3	Estado da Arte	36
3.1	Detecção de Veículos Baseada na Cor dos Objetos	36
3.2	Detecção de Veículos Sem Utilização da Cor como Critério de Classificação	41

3.3	Sumário do Estado da Arte	44
3.4	Discussão Crítica Sobre os Métodos Apresentados	51
4	Método Proposto	53
4.1	Modelagem do Problema	53
4.2	Criação da Base de Imagens	54
4.2.1	Protocolo de Captura	54
4.2.2	Características da Base de Imagens	56
4.2.3	Descritores das Imagens	61
4.3	Segmentação e Preparação das Imagens	62
4.4	Criação dos Classificadores	64
4.4.1	Extração de Características	66
4.4.2	Classificação e Fusão dos Resultados	66
5	Avaliação do Método Proposto	68
5.1	Separação das Bases de Treinamento e Testes	69
5.2	Classificadores treinados com características de cor	70
5.3	Classificadores Treinados com amostras de um único estacionamento	71
5.3.1	Classificadores treinados com amostras do estacionamento UFPR04	72
5.3.2	Classificadores treinados com amostras do estacionamento UFPR05	76
5.3.3	Classificadores treinados com amostras do estacionamento PUCPR	79
5.3.4	Discussão dos resultados obtidos com os classificadores treinados com amostras de um estacionamento	82
5.4	Classificadores Treinados com amostras de múltiplos estacionamentos	85
5.5	Testes em Outras Bases	89
6	Conclusão	94
	Referências	96

1 Introdução

Nos últimos anos, com a crescente frota de veículos nas cidades, a tarefa de encontrar vagas de estacionamento tem se tornado cada vez mais difícil. Uma saída encontrada pelos motoristas que procuram um local para deixar seus automóveis são os estacionamentos públicos e privados, que são muito comuns principalmente nos grandes centros. Esses estacionamentos podem conter centenas de vagas e a tarefa de administrá-las pode ser difícil, principalmente se o gerenciamento das vagas for realizado de forma manual.

Uma das formas de se gerenciar um pátio de estacionamento consiste em coletar informações sobre o estado de cada uma de suas vagas. Essa solução pode prover não só informações sobre a quantidade de veículos estacionados, mas também suas localizações, as áreas mais utilizadas do estacionamento, os horários em que determinadas áreas estão mais ocupadas, etc..

A gerência individual de vagas de estacionamento em áreas abertas pode ir além dos pátios de estacionamento, pois informações quanto ao índice de ocupação das vagas públicas presentes nas laterais das vias também podem ser de grande importância para a engenharia de tráfego. Contudo, nesses casos torna-se inviável a coleta de dados utilizando-se a percepção humana devido à grande quantidade de pessoas necessárias para se cumprir essa tarefa.

Além da gerência de estacionamentos, uma metodologia de detecção de veículos estacionados podem servir como base para outros sistemas como, sistemas de detecção de superlotações de estacionamentos, detecção de veículos estacionados em locais proibidos, ou para sistemas que guiem o motorista diretamente até a vaga desocupada mais próxima, poupando assim tempo dos motoristas e ajudando no descongestionamento do trânsito.

1.1 Definição do Problema

Informações sobre a lotação de determinado pátio de estacionamento, bem como a localização exata das vagas ocupadas e vazias, podem poupar muito tempo dos motoristas,

além de possibilitar um melhor gerenciamento desses estabelecimentos.

Apesar de sistemas simples, como os baseados em cancelas, exibirem bons resultados quanto à manutenção da quantidade de veículos em um estacionamento e oferecerem formas de controle de entrada e saída destes, o estado de cada uma das vagas individuais não pode ser definido desta forma. Além disso, esse tipo de sistema se limita a estacionamentos fechados, impossibilitando sua utilização em locais públicos e de livre acesso.

Uma alternativa para prover uma visão global do atual estado de um estacionamento com detalhes sobre cada uma de suas vagas é a instalação de sensores em suas vagas individuais (CHUNHE; JILIN, 2004; WOLFF et al., 2006), porém esta solução apresenta um alto custo, além de poder ser de difícil manutenção, principalmente em estacionamentos grandes e em áreas abertas (BIN et al., 2009; BONG; TING; LAI, 2008).

Uma abordagem mais simples que a instalação de sensores individuais pode ser a classificação de múltiplas vagas simultaneamente através de um sistema de processamento de imagens, que pode indicar se cada uma das vagas presentes na imagem em processamento está livre ou não. Esses sistemas, que podem utilizar como fonte de imagens câmeras de vigilância já instaladas nos estacionamentos, são potencialmente mais baratos e de manutenção mais simples quando comparados aos sistemas baseados em sensores individuais (ICHIHASHI et al., 2009; BIN et al., 2009), porém apresentam algumas complexidades inerentes às suas construções.

Dentre essas complexidades, estão os fatos de que imagens coletadas ao longo de um dia em ambientes abertos podem sofrer grandes variações de luminosidade, conter sombras que se projetam em diferentes pontos dependendo do período do dia, e conter ruídos introduzidos por mudanças climáticas como pela chuva ou neblina, por exemplo. Essas complexidades ainda podem se acentuar quando são comparadas imagens capturadas em estacionamentos distintos. A Figura 1.1 exemplifica algumas dessas problemáticas, mostrando as variações que podem ocorrer ao se capturar a imagem de um mesmo local em diferentes condições climáticas e em diferentes horários do dia.

As imagens da Figura 1.1 também mostram a dificuldade de se obter uma representação (modelo) de vaga ocupada, já que podem existir inúmeras combinações de cores e modelos de veículos estacionados em uma vaga, além de que estes veículos podem estar dispostos de diversas maneiras.

Um sistema de classificação de vagas baseado em imagens que anule ou minimize os efeitos causados por essas complexidades poderia baratear, e portanto tornar mais viável, a



Figura 1.1: Exemplos de variação de luminosidade

implantação sistemas de gerência de vagas individuais em estacionamentos.

1.2 Objetivos

Este trabalho tem como objetivo principal propor um método de classificação de vagas de estacionamentos abertos a partir de imagens de câmeras fixas, considerando a combinação de classificadores treinados com características texturais. Entenda-se por classificação de uma vaga, a tarefa de definir sua condição como livre ou ocupada.

As características texturais foram escolhidas para este trabalho por acreditar-se que esse tipo de característica pode absorver o efeito das variações de luminosidade, que ocorrem devido às variações climáticas ou do decorrer do dia, sem grandes impactos nas taxas de acertos dos sistema de classificação.

Além do objetivo principal, esse trabalho visa cumprir os seguintes objetivos secundários:

- Avaliar métodos de combinação de classificadores com o intuito de maximizar a taxa de acertos do sistema. Para isso serão treinados classificadores com conjuntos de características específicos, e a resposta final do estado de uma vaga será dada através de um esquema de combinação das respostas desses classificadores.
- Verificar o quão genéricos serão os modelos dos estacionamentos criados, colocando-os à prova utilizando-se imagens de ângulos ou de estacionamentos que não participaram

de seus treinamentos. Com isso será possível avaliar se um classificador criado a partir de amostras de determinado estacionamento pode servir para classificar uma área de estacionamentos totalmente nova, que não contribuiu com nenhuma amostra de treinamento.

- Criar uma base de imagens de estacionamentos que possibilite a execução dos testes necessários neste trabalho. Esta base será disponibilizada publicamente, possibilitando assim que outros autores a utilizem, facilitando a comparação dos resultados obtidos com diferentes metodologias.
- Comparar o método proposto com classificadores treinados com características de cor, as quais são utilizadas em diversos outros trabalhos (LIN; CHEN; LIU, 2006; BONG; TING; LAI, 2008; HUANG et al., 2008).
- Utilizar bases propostas por outros autores para colocar em teste a metodologia deste trabalho, com o objetivo de prover um comparativo entre os resultados obtidos por esses autores e os obtidos com a metodologia proposta.

1.3 Desafios

O principal desafio a ser superado neste trabalho é a criação de uma metodologia para classificação de imagens de vagas de estacionamento, capaz de lidar com as complexidades impostas pelas variações de luminosidade no ambiente, e a variação dos padrões das vagas ocupadas. Para que esse desafio seja superado, primeiramente será necessária a superação de cada um dos seguintes itens:

- A criação de uma base de imagens de diferentes estacionamentos e coletadas de diversos ângulos. Na base de imagens também devem constar amostras coletadas em diferentes condições climáticas e com diversos níveis de lotação dos estacionamentos, desde quase vazios até próximos de suas capacidades totais.
- A definição de um protocolo de captura de imagens, no qual devem constar parâmetros como o formato e padrão de cores das imagens que farão parte da base, e o espaçamento de tempo entre as capturas. Esse protocolo terá como objetivo facilitar a manutenção da base de imagens, bem como garantir sua extensibilidade.
- O treinamento e teste de diversos classificadores baseados em textura, com e sem combinação, para imagens de diferentes estacionamentos. Os resultados dos testes deverão

ser avaliados e comparados a fim de se verificar a eficiência dos classificadores.

1.4 Hipóteses

A execução do trabalho tem por objetivo verificar a validade das seguintes hipóteses:

1. Características texturais são representativas para o problema de classificação de vagas de estacionamento, atenuando os efeitos causados pelas mudanças de luminosidade, a presença de sombras e a variação dos padrões de vaga ocupada.
2. Um único classificador pode representar um modelo suficientemente genérico, sendo capaz de classificar vagas com as imagens capturadas de ângulos diferentes, ou até mesmo de estacionamentos que não contribuíram com nenhuma amostra para o seu treinamento. Imagens de diferentes estacionamentos ou ângulos podem diferir em diversas propriedades como: luminosidade, disposição dos veículos, área em pixels ocupada por cada uma das vagas, etc.. Espera-se que as características de textura sejam capazes de lidar com essas problemáticas.
3. Ao se combinar as respostas de diversos classificadores, treinados com diferentes conjuntos de características texturais para resolver o problema do generalismo descrito no item 2, serão obtidas taxas de acertos superiores às dos classificadores individuais. Essa hipótese parte da premissa de que a taxa de acertos do sistema pode ser melhorada através da diversidade de classificadores incumbidos dessa tarefa.

1.5 Contribuições do Trabalho

As contribuições deste trabalho podem ser separadas basicamente entre as de cunho científico e as de cunho social. As principais contribuições científicas esperadas para este trabalho são:

- A avaliação do desempenho de descritores baseados em textura para a distinção entre veículos e terreno.
- A avaliação de métodos de combinação de classificadores especialistas para classificação de imagens utilizando-se características baseadas em textura.

- A avaliação da capacidade de generalização dos classificadores baseados em textura através de testes envolvendo imagens coletadas de áreas de estacionamento ou de ângulos que não participaram de seus treinamentos.
- A criação de uma base de imagens de estacionamentos e um protocolo de captura de imagens que garanta a extensibilidade e usabilidade da base para diversas tarefas relacionadas a Sistemas Inteligentes de Transporte - *Intelligent Transportation Systems* (CHOWDHURY; SADEK, 2003).

Já as contribuições sociais esperadas para este trabalho são as seguintes:

- A criação de um método para classificação de vagas de estacionamento que pode servir como base para outros sistemas como, por exemplo, sistemas capazes de indicar a vaga mais próxima ao motorista, poupando assim tempo de viagem e diminuindo congestionamentos, além de auxiliar na redução da poluição causada pelos veículos, que precisarão circular por um tempo menor até encontrarem uma vaga.
- Possibilitar a gerência dos pátios de estacionamento de uma forma mais eficaz, provendo informações sobre cada uma de suas vagas.
- Prover um método de classificação de vagas que pode ser utilizado pela engenharia de tráfego para detectar locais com superlotação de veículos estacionados.

Além destas contribuições, os resultados preliminares obtidos com este trabalho foram publicados na *IEEE International Conference on Systems, Man, and Cybernetics 2013* (ALMEIDA et al., 2013).

1.6 Estrutura do Documento

Este trabalho está organizado em seis capítulos. O capítulo 2 trata dos principais conceitos de reconhecimento de padrões utilizados na metodologia proposta. No capítulo 3 é discutido o estado da arte do reconhecimento automático de vagas de estacionamento utilizando imagens. No capítulo 4 é descrita a abordagem proposta para a detecção automática de vagas de estacionamento utilizando-se imagens e combinação de classificadores de textura. Já no capítulo 5 é apresentada a abordagem para a avaliação dos métodos propostos, bem como os resultados obtidos. Finalmente, no capítulo 6, são apresentadas as conclusões e os direcionamentos para trabalhos futuros.

2 Fundamentação Teórica

Neste capítulo são apresentados os principais conceitos envolvidos no desenvolvimento da metodologia proposta. No item 2.1 é dada a definição de um sistema de reconhecimento de padrões. O item 2.2 trata da extração de características de textura de imagens. Já no item 2.3 são apresentados os classificadores do tipo Máquina de Vetor de Suporte, enquanto no item 2.5 são descritas algumas métricas de avaliação de classificadores.

2.1 Reconhecimento de Padrões

O reconhecimento de padrões refere-se à área de estudos que tem por objetivo construir sistemas capazes de categorizar objetos em classes conhecidas. Esses objetos (muitas vezes denominados padrões), dependendo do escopo da aplicação, podem ser das mais variadas formas como imagens ou espectros sonoros. O reconhecimento de padrões é de fundamental importância em diversos sistemas como os que envolvem visão computacional, reconhecimento de caracteres, reconhecimento de voz e mineração de dados.

Nos sistemas de reconhecimento de padrões, geralmente um padrão é composto por diversas características que o descrevem como, por exemplo, suas medidas, coloração, textura, etc.. Essas características são agrupadas para então formarem vetores de características na forma $X = [x_1, x_2, \dots, x_L]$, contendo L valores. Esses vetores de características são utilizados pelo sistema de reconhecimento tanto na criação do método quanto na etapa de classificação dos objetos (THEODORIDIS; KOUTROUMBAS, 2008; ROKACH, 2009).

Após a definição de quais características serão utilizadas para descrever os padrões, o problema pode ser modelado basicamente como um sistema não-supervisionado ou supervisionado de classificação. Em sistemas não-supervisionados, não se sabe de antemão quais as possíveis classes de objetos existentes, e o objetivo do sistema é encontrar possíveis agrupamentos desses objetos, e quais características podem ser utilizadas para definir esses agrupamentos.

Já em sistemas de classificação supervisionada, que são o foco deste trabalho, um

conjunto de treinamento com objetos de classes conhecidas é utilizado na construção de um modelo de classificação, que após seu treinamento deve ser capaz de categorizar objetos de classes desconhecidas. Nesses sistemas os algoritmos de classificação geralmente são chamados de indutores, enquanto uma instância de um indutor construído através de um conjunto específico de treinamento é denominado classificador (ROKACH, 2009; DUDA; HART; STORK, 2012).

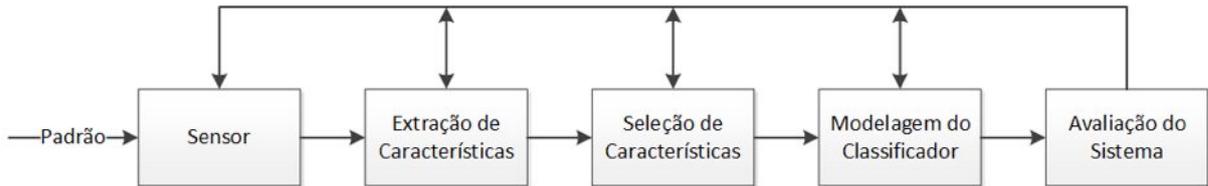


Figura 2.1: Estágios envolvidos na construção de um classificador (THEODORIDIS; KOUTROUMBAS, 2008)

A Figura 2.1 exhibe os principais estágios envolvidos na construção de um sistema de classificação. No primeiro estágio é utilizado um sensor para coletar os objetos que serão analisados. No segundo estágio são extraídas as características dos objetos, enquanto no terceiro o número de características pode ser reduzido através de algum método de seleção. No quarto estágio é realizada a modelagem do classificador através da definição de aspectos como o indutor a ser utilizado, a forma em que será realizado o treinamento e as possíveis estratégias de combinação dos classificadores. Já no quinto estágio é realizada a avaliação do desempenho do sistema como um todo. As setas de retorno na figura indicam que os estágios são inter-relacionados. Sendo assim, determinado estágio pode ser remodelado dependendo dos resultados obtidos nos demais, com o intuito de maximizar o desempenho geral do sistema (THEODORIDIS; KOUTROUMBAS, 2008; DUDA; HART; STORK, 2012).

Como este trabalho trata da classificação de vagas de estacionamento através de imagens, uma câmera foi escolhida como sensor. Texturas foram selecionadas como características a serem extraídas dos objetos (item 2.2), e indutores do tipo SVM juntamente com estratégias de combinação de classificadores foram escolhidos para a modelagem do sistema de classificação (itens 2.3 e 2.4, respectivamente). A avaliação do sistema é realizada através de métricas como as curvas ROC, taxas de acertos e matrizes de confusão (item 2.5).

2.2 Características Relacionadas à Textura

Como citado no item 2.1, a modelagem de um problema de reconhecimento de padrões envolve a extração dos vetores de características referentes aos objetos, os quais são utilizados

para o treinamento dos indutores e para a classificação dos objetos.

Os vetores de características utilizados exercem grande impacto no desempenho de um sistema de reconhecimento de padrões, e a escolha de um conjunto adequado para a distinção entre as classes dos objetos que se deseja classificar está fundamentalmente conectada ao domínio da aplicação e às métricas (características) disponíveis (GUYON, 2006; THEODORIDIS; KOUTROUMBAS, 2008).

Alguns descritores de características muito utilizados são os baseados em textura. A textura é um conceito geralmente atribuído à percepção humana, e apesar de não apresentar uma definição matemática, este pode ser descrito como os padrões nos arranjos de partículas que formam um objeto como um todo.

As características baseadas em textura podem apresentar bons resultados quando utilizadas em sistemas de classificação, pois podem dar informações quanto ao material do qual o objeto é feito, além de que em muitos casos é mais simples se computar as informações sobre a textura de um objeto do que as informações sobre seu formato e dimensões. Alguns exemplos de descritores de texturas são os Fractais, as Matrizes de Co-ocorrência, Funções de Gabor e, mais recentemente, os Padrões Locais Binários e a Quantização de Fase Local (NIXON; AGUADO, 2012; PETROU; SEVILLA, 2006).

Por se tratarem de metodologias relativamente recentes e por terem apresentados bons resultados em diversos trabalhos (OJALA; PIETIKAINEN; MAENPAA, 2002; AHONEN; HADID; PIETIKAINEN, 2006; OJANSIVU; HEIKKILÄ, 2008), a metodologia proposta neste documento utiliza como características de textura os Padrões Locais Binários (2.2.1) e a Quantização de Fase Local (2.2.2).

2.2.1 Padrões Locais Binários

Uma das representações de texturas mais conhecidas da atualidade é baseada na extração dos Padrões Locais Binários - *Local Binary Pattern* (LBP) - já que essa é uma metodologia de implementação relativamente simples e com um baixo tempo de cálculo.

O cálculo básico do LBP em uma imagem em escala de cinza considera os 3×3 vizinhos de um pixel central C . É atribuído o valor 1 aos vizinhos que possuem valoração maior que a de C , enquanto aos demais vizinhos é atribuído o valor 0. Realizando-se uma leitura sequencial no sentido horário que parte de um vizinho qualquer de C é obtido um valor binário, que pode então ser atribuído ao pixel central C para caracterizar sua textura. Como a leitura pode iniciar em qualquer um dos oito vizinhos para esse caso, podem existir oito valores

diferentes de textura para um mesmo pixel, tornando essa abordagem sensível à rotação. A Figura 2.2a mostra os oito vizinhos de um pixel C enquanto a Figura 2.2b mostra os valores atribuídos aos vizinhos de C após a aplicação das limiarizações.

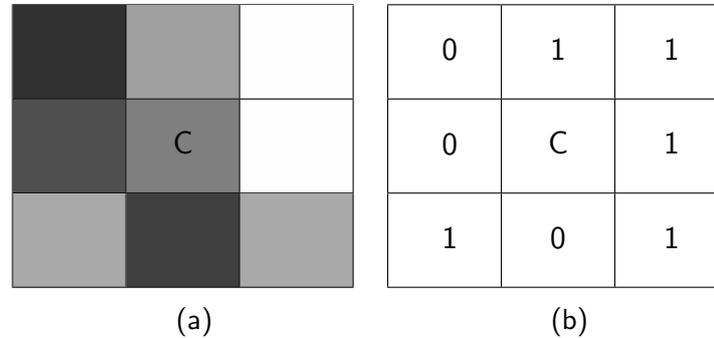


Figura 2.2: Um pixel central e seus 8 vizinhos (a). Valores atribuídos aos vizinhos de C , onde os vizinhos de maior valor que C recebem 1, enquanto os demais recebem 0 (b)

Uma representação invariante à rotação pode ser construída ao se gerar todos os P valores de textura para C , e então selecionar o menor destes valores para representar a textura centrada em C . Com isso, por exemplo, para $P = 8$ vizinhos de C , existem 36 padrões de textura que são únicos e independentes de rotação (PETROU; SEVILLA, 2006).

Uma das propriedades mais interessantes do LBP é o fato deste método utilizar o valor do pixel central como limiar para seus pixels vizinhos, tornando-o invariante a modificações monotônicas na escala de cinza como, por exemplo, as diferenças causadas por variações na luminosidade (OJALA; PIETIKÄINEN, 1999). Além disso, a metodologia descrita pode ser estendida para uma vizinhança contendo P pixels, em um raio de tamanho R que parte do pixel central C . Para tal, as coordenadas de um pixel $p(0 \leq p \leq P - 1)$ presente nessa vizinhança são dadas pela equação 2.1 (OJALA; PIETIKÄINEN; MAENPAA, 2002).

$$p(x,y) = p\left(-R\sin\left(\frac{2\pi p}{P}\right), R\cos\left(\frac{2\pi p}{P}\right)\right) \quad (2.1)$$

Para os casos em que o cálculo das coordenadas não resulte no centro exato de um pixel qualquer, o seu valor pode ser calculado via interpolação.

No trabalho de Ojala, Pietikainen e Maenpaa (2002) foi observado que determinados padrões de LBP invariantes à rotação ocorrem com uma maior frequência nas imagens, chegando a 90% dos padrões de textura de um imagem considerando-se os oito vizinhos de seus pixels. Esses padrões, denominados “uniformes” possuem um valor de transições entre zeros e uns de seus valores binários menores ou iguais a 2, onde essas transições são calculadas por uma métrica U . Sendo assim, o padrão 00100000_2 possui o valor de U igual a 2 e é

considerado uniforme (Figura 2.3a), enquanto o padrão 00100010_2 não é uniforme por ter o valor de U igual a 4 (Figura 2.3b).

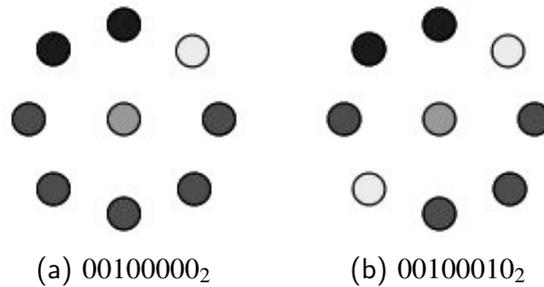


Figura 2.3: Padrões Uniformes e não Uniformes.(a) $U = 2$ indicando um padrão uniforme.(b) $U = 4$, indicando um padrão não uniforme

Utilizando essa métrica é possível a construção de um histograma no qual os padrões uniformes são totalizados de forma separada, enquanto os demais padrões são agrupados em uma classe única, gerando um vetor de características de tamanho consideravelmente menor que o gerado pela implementação padrão do LBP. Por exemplo, para uma vizinhança de 8 pixels, a implementação padrão do LBP irá gerar um vetor de tamanho 256, enquanto o LBP com Padrões Uniformes produzirá um vetor de tamanho 59. Já quando é aplicada a invariância à rotação, o histograma formado pelos padrões uniformes contém por definição $P + 2$ padrões totalizados, onde P é o número de vizinhos considerados para o cálculo do LBP.

2.2.2 Quantização de Fase Local

Movimento, turbulência atmosférica e falta de foco na câmera são fatores comuns que degradam as imagens tornando-as borradas e interferindo na capacidade dos sistemas de classificação de extrair suas informações. A Quantização de Fase Local - *Local Phase Quantization* (LPQ) - é um método para representação de texturas em imagens que se caracteriza por sua insensibilidade a esse tipo de interferência, podendo assim ser utilizado em imagens com ou sem perda de foco (OJANSIVU; RAHTU; HEIKKILA, 2008).

O método proposto por Ojansivu e Heikkilä (2008) baseia-se no fato de que a fase da Transformada Discreta de Fourier - *Discrete Fourier Transform* (DFT)- é invariante ao borrimento simétrico das imagens.

No domínio da frequência uma imagem desfocada pode ser representada por $G = F \cdot H$, onde G é a DFT da imagem desfocada, F é a imagem original e H é a função de espalhamento de ponto - *Point Spread Function* (PSF). Ao se considerar somente a fase do espectro temos que $\angle G = \angle F + \angle H$. Assumindo-se que o borrimento é simétrico ao centro,

os valores de H são reais e positivos ao menos para baixas frequências. Nessas frequências $\angle F$ é uma característica invariante ao borramento, pois $\angle H = 0$.

Como as imagens capturadas possuem um tamanho finito, parte da informação sobre o borramento é perdida, porém a invariância de $\angle F$ a esse fenômeno ainda pode ser considerada.

O cálculo do LPQ para um pixel na posição x é realizado utilizando-se suas informações de fase, que são extraídas através da *Short-Term Fourier Transform* (STFT) para sua vizinhança N_x quadrada de tamanho $M \times M$, definida pela equação 2.2.

$$F(\mathbf{u}, x) = \sum_{y \in N_x} f(x-y) e^{-j2\pi \mathbf{u}^T y} \quad (2.2)$$

em que $j = \sqrt{-1}$ e $f(x)$ é uma função de janela que define a vizinhança N_x . Algumas das funções de janela aplicáveis ao método LPQ são as do tipo Gaussianas, uniformes e com filtros de banda de quadraturas Gaussianas Derivativas. Mais informações sobre as funções de janela podem ser encontradas no trabalho de Rahtu et al. (2012).

A metodologia utiliza quatro coeficientes complexos u para o cálculo do LPQ, sendo eles $\mathbf{u}_1 = [a, 0]^T$, $\mathbf{u}_2 = [0, a]^T$, $\mathbf{u}_3 = [a, a]^T$ e $\mathbf{u}_4 = [a, -a]^T$, onde a é um escalar suficientemente pequeno tal que $H(\mathbf{u}_i) > 0$.

Com isso, para cada pixel x tem-se o seguinte vetor

$$\mathbf{F}(\mathbf{x}) = [F(u_1, x), F(u_2, x), F(u_3, x), F(u_4, x)] \quad (2.3)$$

Tomando-se as partes reais e imaginárias de $F(x)$ separadamente, é possível definir o vetor

$$G(x) = [Re\{F(x)\}, Im\{F(x)\}] \quad (2.4)$$

em que $Re\cdot$ é uma função que retorna a parte real de um número complexo, enquanto $Im\cdot$ retorna sua parte imaginária.

Um vetor Q então pode ser definido de acordo com a seguinte regra:

$$q_i = \begin{cases} 1 & \text{se } g_i \geq 0 \\ 0 & \text{se } g_i < 0 \end{cases} \quad (2.5)$$

Em que q_i é a i -ésima posição do vetor Q , e g_i representa o i -ésimo componente do

vetor G .

Realizando-se uma leitura linear em Q , este pode então ser interpretado como um valor em binário, que é então atribuído como sendo o valor da textura para a janela. Esse método, assim como o LBP, é sensível à rotação das imagens. Uma versão do LPQ invariante à rotação pode ser encontrada no trabalho de Ojansivu, Rahtu e Heikkila (2008).

A última etapa do processo consiste na construção de um histograma de 256 dimensões composto pelos valores de textura computados para cada um dos pixels da imagem. Esse vetor pode então ser utilizado como um vetor de características em métodos de reconhecimento de padrões.

2.3 Máquinas de Vetor de Suporte

Em um problema binário (de duas classes) linearmente separável podem existir infinitos hiperplanos que dividem os dados entre as classes corretamente. Enquanto muitos classificadores, como os perceptrons, param seus treinamentos assim que encontram a primeira fronteira que separa corretamente os dados, uma máquina de vetor de suporte - *Support Vector Machine* (SVM) - irá encontrar o hiperplano com a maior distância possível dos pontos de exemplo, ou seja, encontrará a margem máxima de separação dos dados (THEODORIDIS; KOUTROUMBAS, 2008).

A Figura 2.4 exemplifica o conceito de margem máxima para um problema binário com duas características extraídas dos objetos. Na figura, os pontos destacados com um círculo são os exemplos de treinamento mais próximos à margem máxima de separação. Esses pontos são denominados vetores de suporte, e são responsáveis por moldar a fronteira de decisão. Há uma distância Z de cada uma das retas pontilhadas definidas pelos vetores de suporte, encontra-se o hiperplano A , que é o separador de margem máxima dos dados.

Diferentemente do exemplo da Figura 2.4, na vasta maioria dos casos os dados não podem ser linearmente separáveis. Nessas situações os dados podem ser elevados para dimensões mais altas, nas quais eles tendem a ser separados linearmente por um hiperplano. Para elevar os dados a essas dimensões mais altas utilizam-se funções denominadas funções de *kernel*, que tomam um par de vetores, \mathbf{x}_j e \mathbf{x}_k , para computar o produto escalar em algum espaço de características (RUSSELL; NORVIG, 2010; THEODORIDIS; KOUTROUMBAS, 2008). Algumas funções de *kernel* comuns são:

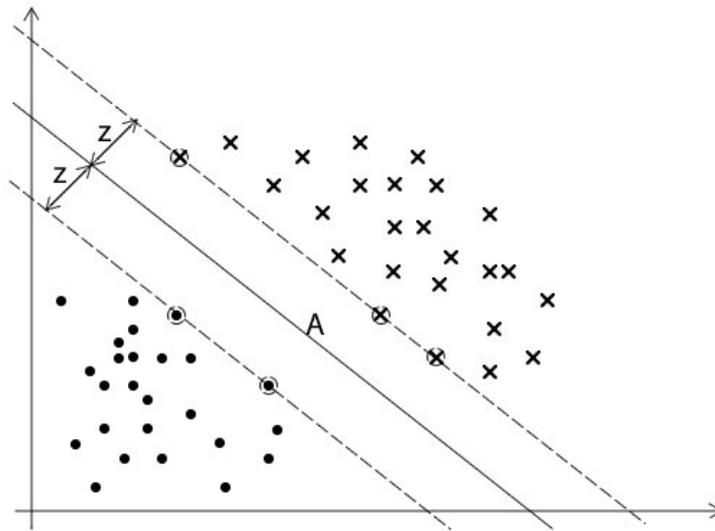


Figura 2.4: Exemplos de hiperplanos para separação entre duas classes

- Polinomial de grau d

$$K(\mathbf{x}_j, \mathbf{x}_k) = (1 + \mathbf{x}_j \cdot \mathbf{x}_k)^d \quad (2.6)$$

- *Radial Basis Function* (RBF) com o comportamento da exponencial definido por γ

$$K(\mathbf{x}_j, \mathbf{x}_k) = \exp(-\gamma \|\mathbf{x}_j - \mathbf{x}_k\|^2) \quad (2.7)$$

- Tangente hiperbólica

$$K(\mathbf{x}_j, \mathbf{x}_k) = \tanh(\beta \mathbf{x}_j \cdot \mathbf{x}_k + \alpha) \quad (2.8)$$

Para algum $\beta > 0$ e $\alpha > 0$ que satisfaçam as condições do teorema de Mercer (MERCER, 1909)

Por padrão, as saídas dos SVMs são descalibradas, não representando probabilidades à posteriori. No entanto, no trabalho de Platt (1999) foi proposta uma forma de se converter essas saídas em probabilidades. O método consiste basicamente em estimar uma função sigmóide e utilizá-la para converter as saídas dos SVMs em *scores* variando entre 0 e 1, que representam a probabilidade dos objetos pertencerem a cada uma das classes.

Apesar dos SVMs realizarem a distinção somente entre duas classes, estes classificadores podem ser adaptados para problemas multiclasse. Uma das soluções é treinar um SVM para cada classe do problema, onde cada um dos SVMs distinguem se o objeto sendo classificado pertence a determinada classe, ou se ele pertence a qualquer uma das demais (um-contra-todos).

Outra abordagem possível é treinar um SVM para cada par de classes existentes no

problema (um-contra-um), totalizando $M(M - 1)/2$ classificadores para um problema de M classes. No método um-contra-um a decisão final quanto à classe do objeto pode ser dada através de um método de combinação, como o da votação majoritária das respostas de todos classificadores treinados (THEODORIDIS; KOUTROUMBAS, 2008).

2.4 Combinação de Classificadores

A combinação de classificadores consiste na utilização de algum método de fusão das respostas de um conjunto de classificadores, almejando um desempenho melhor que o obtido ao se considerar as respostas destes classificadores de maneira separada.

Agregar as informações de diversos tomadores de decisão frequentemente resulta em decisões melhores do que as tomadas por qualquer um dos indivíduos isoladamente, mesmo que este indivíduo seja um especialista. Porém, para que o conjunto de tomadores de decisão seja realmente eficaz, alguns critérios devem ser seguidos (SUROWIECKI, 2005):

- Diversidade de opiniões - cada tomador de decisão deve ter pelo menos um trecho da informação, mesmo que esta seja uma interpretação excêntrica dos fatos.
- Independência - um membro não pode ter sua resposta afetada pela opinião dos demais.
- Descentralização - Cada tomador de decisão deve ser capaz de se especializar e extrair informações do conhecimento local.
- Agregação - deve haver algum mecanismo que possibilite tornar os julgamentos individuais em uma decisão coletiva.

São três os principais motivos que tornam a combinação de classificadores uma boa alternativa para melhorar os resultados de sistemas classificação de padrões. Tomando-se o motivo estatístico, quando temos uma grande quantidade de classificadores com diferentes capacidades de generalização, utilizar somente um dentre eles implica no risco de se escolher um mau classificador. Combinar as respostas desses classificadores pode ser uma boa alternativa para reduzir o risco de se escolher um classificador com desempenho ruim (DIETTERICH, 2000; POLIKAR, 2006).

Na Figura 2.5a a área externa representa o espaço de todos os classificadores, enquanto a área sombreada interna representa os classificadores com os melhores desempenhos nos dados de treinamento. Uma técnica de combinação pode ser utilizada para se tentar

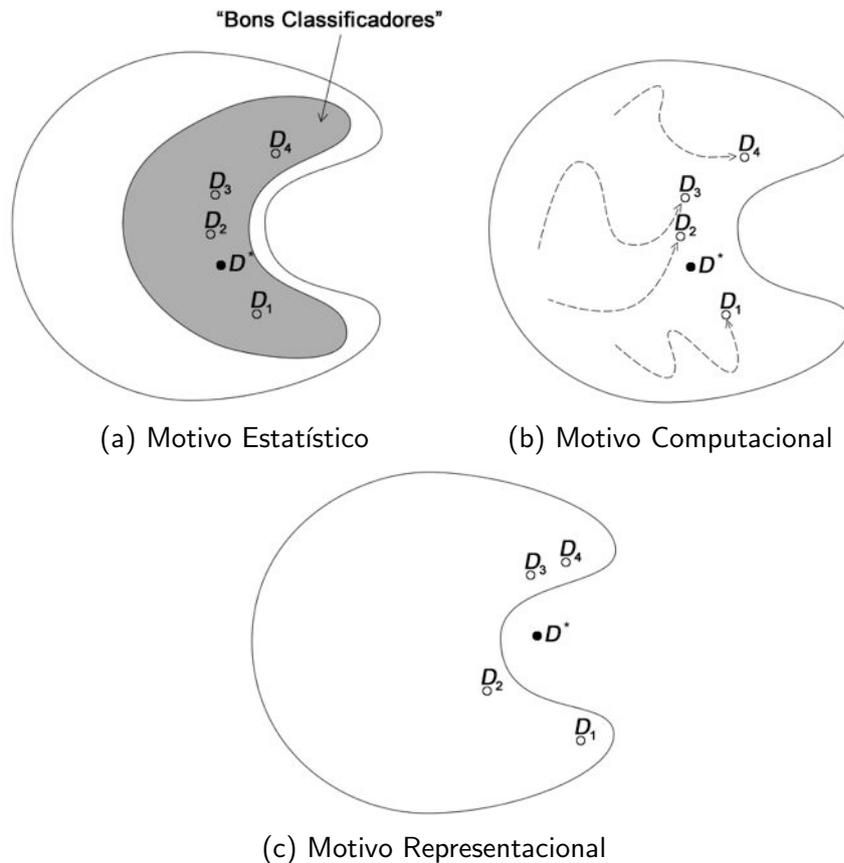


Figura 2.5: Razões para utilização da combinação de classificadores - Adaptado de Kuncheva (2004)

chegar o mais próximo possível do classificador D^* , que representa o classificador ideal para o problema.

Um dos aspectos computacionais do treinamento dos algoritmos é que muitos deles podem ficar presos em máximos locais, e mesmo em casos onde é possível encontrar o classificador ótimo, o treinamento pode se tornar computacionalmente inviável devido ao tempo de processamento necessário. Combinar múltiplos classificadores que iniciam seus aprendizados em diferentes locais do espaço de possíveis classificadores, e terminam em algum ponto próximo do classificador ótimo, pode levar a um classificador melhor do que qualquer um dos tomadores de decisão individuais (KUNCHEVA, 2004; DIETTERICH, 2000). Esse conceito, que representa o motivo computacional de se combinar classificadores, é exemplificado na Figura 2.5b.

Existem também casos onde a fronteira de decisão é muito complexa, ou então devido a limitações dos indutores, como os que são capazes de aprender somente funções lineares, o classificador ideal não existe no espaço de possíveis classificadores (Figura 2.5c). Combinar as respostas dos classificadores pode gerar um classificador mais próximo ao ideal, sendo este o

motivo representacional de se combinar classificadores (POLIKAR, 2006; KUNCHEVA, 2004).

2.4.1 Métodos de Fusão

Os métodos de fusão classificam os objetos através da combinação das respostas de diversos classificadores, aplicando uma função de fusão em suas respostas, como ilustrado na Figura 2.6. Nesta seção são apresentadas algumas das regras de fusão mais comuns, presentes no trabalho de Kittler et al. (1998).

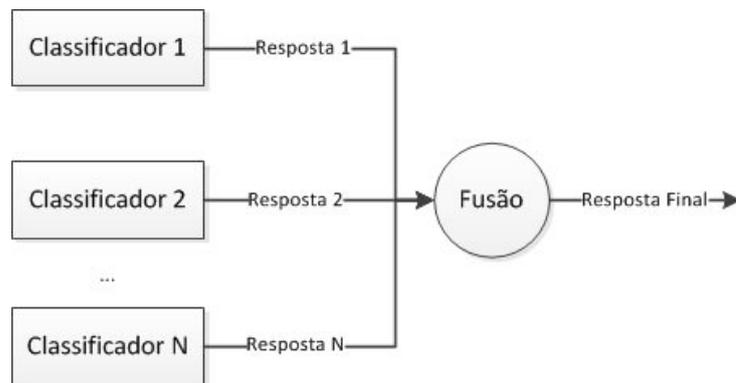


Figura 2.6: Fusão das respostas de diversos classificadores

Voto Majoritário

Uma das formas mais simples de se fundir as respostas dos classificadores é através do voto majoritário de suas respostas. Esta regra basicamente define que a classe de determinado objeto é a classe que mais recebeu votos dentre todos os classificadores.

Em um problema contendo c classes possíveis e n classificadores, a classe de um objeto x dada pela votação majoritária pode ser definida como:

$$classe(x) = \arg \max_{k=1}^c \sum_{i=1}^n g(y_i, k) \quad (2.9)$$

em que y_i é o rótulo dado ao objeto pelo i -ésimo classificador, e $g(y, k)$ é uma função indicativa definida como:

$$g(y, k) = \begin{cases} 1 & \text{se } y = k \\ 0 & \text{se } y \neq k \end{cases} \quad (2.10)$$

Caso haja empates no método de votação majoritária, a classe final pode ser dada através de uma seleção aleatória entre as classes empatadas (KUNCHEVA, 2004).

Muitos classificadores tem como resposta um número contínuo que representa a probabilidade (*score*) *a posteriori* de um objeto x pertencer a classe k . Considere $d_{y,k}$ o *score* dado pelo classificador y de que x pertence a classe k , em um problema contendo n classificadores e c classes. Os próximos métodos de fusão baseiam-se nesse *score* para definir a classe de um objeto.

Regra do Produto

A regra do produto consiste em multiplicar os *scores* gerados pelos classificadores, tornando esse método altamente sensível à baixos *scores*, pois um *score* próximo a 0 dado por um classificador para determinada classe pode anular a chance dela ser selecionada como a classe do objeto. A regra do produto é definida pela equação 2.11.

$$classe(x) = \arg \max_{k=1}^c \prod_{i=1}^n d_{yi,k} \quad (2.11)$$

Regra da Soma

Na regra da soma é realizado o somatório dos *scores* gerados pelos classificadores, e é definida pela equação 2.12.

$$classe(x) = \arg \max_{k=1}^c \sum_{i=1}^n d_{yi,k} \quad (2.12)$$

Regra da Média

A regra da média consiste basicamente em se realizar uma média dos *scores* atribuídos pelos classificadores, como definido pela equação 2.13

$$classe(x) = \arg \max_{k=1}^c \frac{1}{n} \sum_{i=1}^n d_{yi,k} \quad (2.13)$$

Regra da Mediana

Toma-se a mediana dos *scores* gerados pelos classificadores como resultado da classificação combinada. A regra da mediana é definida pela equação 2.14.

$$classe(x) = \arg \max_{k=1}^c \text{mediana}_{i=1}^n d_{yi,k} \quad (2.14)$$

Regra do Máximo (Max)

A regra do máximo toma como resultado da combinação o maior *score* dado pelos classificadores, como definido na equação 2.15

$$classe(x) = \arg \max_{k=1}^c \max_{i=1}^n d_{yi,k} \quad (2.15)$$

Regra do Mínimo (Min)

Na regra do mínimo é considerado como resultado combinado o valor mínimo de *score* atribuído pelos classificadores às classes. Assim como a regra do produto, esta regra é considerada conservadora por ser sensível à baixos *scores*. A regra do mínimo é definida pela equação 2.16.

$$classe(x) = \arg \max_{k=1}^c \min_{i=1}^n d_{yi,k} \quad (2.16)$$

2.5 Métricas de Avaliação de Classificadores

Ao se treinar um modelo de classificação, este é posto a prova a fim de se verificar o seu desempenho em uma base de dados de testes, porém a taxa de acertos desse classificador sozinha pode não representar precisamente o quão eficiente este é. O problema se torna ainda maior quando é necessário comparar os resultados obtidos utilizando classificadores diferentes.

Nas próximas subseções são descritas algumas métricas comuns empregadas para a verificação do desempenho e comparação de classificadores.

2.5.1 Taxas de acertos e matrizes de confusão

Uma matriz de confusão é uma matriz $n \times n$ utilizada para medir a eficiência de um classificador para cada uma das n classes de objetos possíveis. Os elementos $A(i, j)$ da matriz representam o número de objetos da classe i que foram classificados como sendo da classe j . Na diagonal principal da matriz, em que $i = j$, são encontrados os acertos do classificador, enquanto os elementos fora dessa diagonal representam as confusões geradas por ele (THEODORIDIS; KOUTROUMBAS, 2008).

Muitos problemas de classificação são binários e seus objetos podem ser mapeados como pertencentes à classe positiva (classe P) ou negativa (Classe N). A matriz de confusão para estes problemas exhibe as informações sobre os verdadeiros e falsos positivos, bem como os

verdadeiros e falsos negativos gerados pelo classificador. Um exemplo de Matriz de Confusão para problemas binários pode ser visualizado na Tabela 2.1.

Tabela 2.1: Matriz de Confusão para problemas binários

	P	N
P	Verdadeiro Positivo (VP)	Falso Negativo (FN)
N	Falso Positivo (FP)	Verdadeiro Negativo (VN)

As seguintes informações podem ser extraídas de uma matriz de confusão de um problema binário (FAWCETT, 2006):

- Taxa de acertos (TA)

$$TA = \frac{VP + VN}{P + N} \quad (2.17)$$

- Taxa de Verdadeiro Positivo - *True Positive Rate* (TPR)

$$TPR = \frac{VP}{P} \quad (2.18)$$

- Taxa Verdadeiro Negativo - *True Negative Rate* (TNR)

$$TNR = \frac{VN}{N} \quad (2.19)$$

- Taxa de Falso Positivo - *False Positive Rate* (FPR)

$$FPR = \frac{FP}{N} = 1 - TNR \quad (2.20)$$

- Taxa de Falso Negativo - *False Negative Rate* (FNR)

$$FNR = \frac{FN}{P} = 1 - TPR \quad (2.21)$$

2.5.2 Curvas ROC e Área Sob a Curva ROC

Muitos classificadores, como as Redes Neurais e os SVMs, podem estimar a probabilidade *a posteriori* de determinado objeto pertencer a uma classe. Para determinar se um objeto classificado pertence a classe A ou B, aplica-se um limiar nessas probabilidades, onde os objetos com pontuação abaixo do limiar pertencem, por exemplo, a classe A, enquanto os acima do limiar pertencem à classe B.

Variando-se o valor deste limiar e plotando-se um gráfico contendo as taxas de verdadeiro positivo no eixo Y e as taxas de falso positivo no eixo X para cada um destes limiares, obtemos uma curva denominada Característica de Operação do Receptor - *Receiver Operating Characteristic* (ROC). Por exibirem de forma visual a quantidade de erros (falsos positivos) do classificador para determinada quantidade de acertos (verdadeiros positivos) em diversos pontos de operação, as curvas ROC são uma importante ferramenta para análise de custo/-benefício dos classificadores (FAWCETT, 2006).

A Figura 2.7 exhibe um exemplo de curva ROC. No ponto A o sistema não acusa nenhum falso positivo, porém nenhum verdadeiro positivo é classificado. Já o ponto F classifica corretamente todos os verdadeiros positivos, porém ao custo de acusar todos os falsos positivos possíveis. Tanto o ponto A quanto o ponto F coincidem com a reta tracejada na diagonal do gráfico, na qual constam os classificadores que realizam uma categorização desinformada, ou seja, os classificadores que se encontram nesta reta basicamente sorteiam de forma aleatória as classes dos objetos por não conterem informações relevantes para efetuar suas tomadas de decisão.

Os classificadores com pontos acima desta reta, como os representados por B , C , D e E , possuem informações suficientes para classificar os objetos de maneira melhor que uma simples adivinhação.

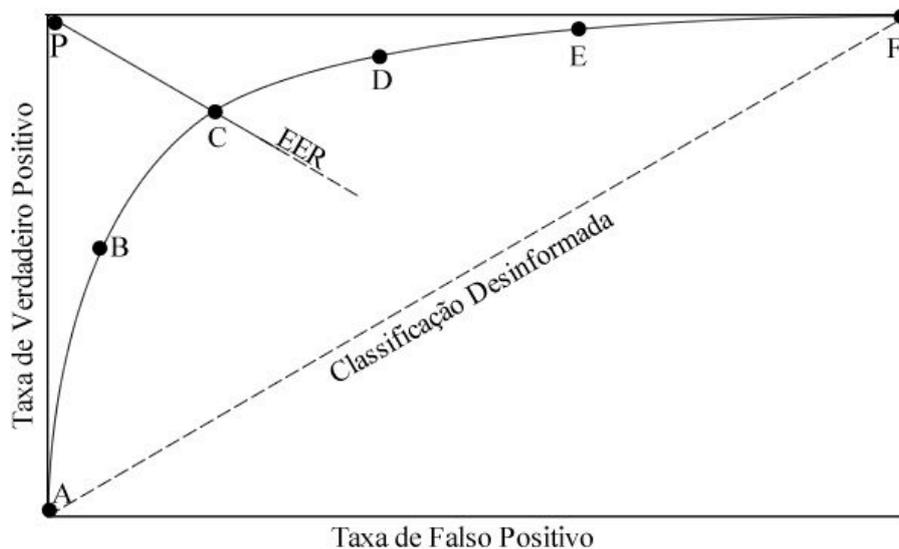


Figura 2.7: Exemplo de Curva ROC

Já os classificadores abaixo da reta de classificação desinformada possuem resultados piores do que um classificador escolhe aleatoriamente a classe de um objeto. Apesar disso, ao se inverter as respostas geradas por esses classificadores, estes passarão a operar acima da

diagonal da classificação desinformada, tornando-se classificadores que possuem algum poder discriminativo entre as classes dos objetos.

A reta que inicia na no canto superior esquerdo do gráfico, e termina no canto inferior direito, define os classificadores que distribuem igualmente as taxas de falsos positivos e negativos, sendo que os classificadores que coincidem com essa reta, como o classificador C , possuem taxas de erros iguais - *Equal Error Rate* (EER), definidas na equação 2.22.

$$EER = \frac{FP + FN}{TP + TN + FP + FN} \quad (2.22)$$

Um classificador ideal teria uma taxa de verdadeiro positivo de 100%, sem a acusação de nenhum falso positivo. Esse classificador estaria situado no ponto P da figura 2.7.

Uma métrica derivada da curva ROC frequentemente utilizada para analisar o poder discriminativo das características utilizadas é a Área Sob a Curva ROC - *Area Under ROC Curve* (AUC). Um classificador perfeito teria uma AUC igual a 1, enquanto um classificador desinformado, que tem todos seus pontos na diagonal principal do gráfico, teria uma AUC = 0,5 (BROWN; DAVIS, 2006).

3 Estado da Arte

Neste capítulo são apresentadas as abordagens e ferramentas utilizadas por diversos autores para atacar o problema da classificação automática de vagas de estacionamento. Os trabalhos foram divididos em duas seções, sendo que na seção 3.1 são descritos os métodos que se baseiam na cor dos pixels para classificar as vagas, enquanto a seção 3.2 contém informações sobre os métodos que não utilizam a cor dos pixels de forma direta para a classificação.

3.1 Detecção de Veículos Baseada na Cor dos Objetos

Muitas vezes a decisão final sobre a categoria dos pixels de uma imagem pode ser realizada aplicando-se um limiar sobre estes, onde esse limiar serve como uma fronteira de decisão para classificar os pixels de acordo com seus valores (BRADSKI; KAEHLER, 2008). Os trabalhos apresentados nesta seção utilizam basicamente a cor dos pixels para determinar o status das vagas. Para classificar os pixels como pertencentes a uma vaga ocupada ou não, esses métodos necessitam de algum modelo do plano de fundo das áreas de estacionamento para realizar a distinção entre a cor dos veículos e a do pátio do estacionamento.

No processamento de imagens, os objetos pertencentes à determinada cena que permanecem estáticos ao longo do tempo são considerados plano de fundo. Uma modelagem desse plano pode permitir que os novos objetos que entram em cena (objetos de primeiro plano) possam ser diferenciados dos objetos que pertencem ao plano de fundo, possibilitando assim detectar as mudanças que ocorreram na cena. (ACHARYA; RAY, 2005; GONZALEZ; WOODS, 2008)

Apesar de se tratar de um conceito relativamente simples, a modelagem do plano de fundo apresenta diversos desafios que, se não tratados corretamente, podem levar à queda na qualidade dos resultados dos métodos que o utilizam. No trabalho de Toyama et al. (1999) muitos desses desafios estão descritos, dentre eles: a mudança de luminosidade com o decorrer do dia, objetos em constante movimento como árvores agitadas pelo vento, dificuldade em

se obter uma imagem de fundo sem objetos em primeiro plano, sombreamentos e mudanças súbitas de luminosidade.

No trabalho de Lin, Chen e Liu (2006) foi proposta uma metodologia para classificação de vagas de estacionamento *outdoor* utilizando um modelo do plano de fundo e a paleta de cores RGB. O método consiste em verificar se a cor de cada pixel da vaga sendo processada pertence ao chão ou a um objeto de primeiro plano através de um modelo do plano de fundo que contém informações sobre a cor do terreno. Os efeitos causados pelas sombras são atenuados realizando um descarte dos pixels que possuem intensidade que se assemelha a uma sombra, e uma vaga de estacionamento é classificada como ocupada se a proporção de pixels considerados como não sendo sombra nem parte do terreno é maior que determinado limiar. Foram realizados testes com imagens com profundidade de cores de 24-bits e tamanho de 352×288 pixels, porém maiores detalhes como a quantidade de amostras utilizadas ou a taxa de acertos do sistema não foram descritos no trabalho.

Um sistema para procura de veículos em grandes estacionamentos foi proposto por Tan et al. (2009). Para o funcionamento do sistema devem ser instaladas câmeras em cada uma das interseções do estacionamento. Como a localização das câmeras é fixa, primeiramente é criado um modelo do plano de fundo para possibilitar a detecção de objetos em movimento, que são processados por um método baseado em Adaboost (ROKACH, 2009) a fim de verificar se o objeto se trata de um veículo.

Um classificador Bayesiano é aplicado nas imagens que contém veículos com o intuito de detectar a cor dos mesmos e armazená-las em um banco de dados. Além disso, as placas dos veículos são identificadas utilizando um método de casamento de padrões (*pattern-match*), sendo que todas as possibilidades de placa encontradas pelo método são armazenadas no banco de dados. Quando é necessária a busca de algum veículo no sistema, o usuário pode entrar com a placa e a cor do automóvel, e o sistema realizará uma busca de todos os veículos que contém essas características em ordem de relevância.

Para realizar os testes foram utilizadas três sequências de vídeo, nas quais o sistema detectou cerca de 200 veículos. Ao se realizar as buscas pelos mesmos através de suas placas e cores no sistema, todos foram encontrados nos TOP 10 resultados. Informações sobre a base utilizada e a taxa de reconhecimento de veículos pelo sistema não são citadas no trabalho.

Uma forma para classificar vagas de estacionamento baseada em suas correlações espaciais foi proposta por Wu et al. (2007). Para efetuar a classificação, primeiramente as imagens são divididas em pequenos pacotes contendo três vagas cada um (Figura 3.1). Utilizando uma modelagem Gaussiana da cor do terreno, três linhas de pixels de cada um dos

pacotes são processadas a fim de se calcular a probabilidade de cada um dos pixels dessas linhas pertencer ao chão. O autor considera que uma linha começa na esquerda da imagem e termina na sua direita. Como os pacotes possuem 75 pixels de largura, para as três linhas são extraídas então 215 características, que são reduzidas a 50 utilizando o método de Análise de Componentes Principais - *Principal Component Analysis* (PCA) (JOLLIFFE, 2002).



Figura 3.1: Exemplo de pacote com 3 vagas

Apesar de ser um problema binário (vaga ocupada ou não), o autor modelou-o como um problema multiclasse, partindo do princípio que cada pacote contém três vagas, ou seja, podem ser atribuídos $2^3 = 8$ estados para cada pacote. A classificação se dá através das 50 características extraídas utilizando um SVM adaptado para problemas multiclasse utilizando o método um-contra-um. Como cada pacote pode compartilhar as vagas presentes em seus extremos com até outros dois pacotes, podem ocorrer conflitos na classificação. A fim de resolver esses conflitos um Campo Aleatório de Markov (*Markov Random Field*) é aplicado no sistema. Para os testes foram utilizadas trezentas amostras para criar o modelo Gaussiano do terreno, então o sistema foi treinado com quinhentas imagens e testado com outras trezentas. Os resultados mostraram que o método proposto atingiu uma taxa de acertos de 93,52%.

Um sistema para detecção de vagas de estacionamento baseado em imagens que utiliza a cor dos pixels como característica foi proposto por Bong, Ting e Lai (2008). O sistema, denominado COINS, toma como entrada imagens de uma câmera que monitora o estacionamento, a qual deve ser fixada em um ponto alto e sem obstruções onde seja possível visualizar a parte frontal ou traseira do estacionamento.

Durante sua inicialização, o sistema deve ser alimentado manualmente com uma imagem do estacionamento completamente vazio e com um ponto amarelo em cada uma das vagas para marcá-las. As linhas que separam as vagas devem ser brancas e claras nas imagens. Através dessa imagem inicial o sistema encontra as coordenadas de retângulos que delimitam as vagas existentes no estacionamento. Em casos onde não é possível encontrar as coordenadas de uma vaga através desse método, uma seleção manual das vagas deve ser realizada. Já na etapa de classificação, as imagens do estacionamento são convertidas para escala de cinza, e então os pixels das vagas são analisados. Para determinar se cada um dos pixels pertence ao chão do estacionamento ou a um veículo, um limiar é utilizado. A quantidade de pixels de uma vaga que foram classificados como pertencentes a um veículo é então contabilizada, e se

esta quantidade ultrapassar um valor pré-estabelecido, a vaga é considerada como ocupada.

Para reduzir os efeitos das sombras nas vagas o algoritmo de Sobel para detecção de bordas, juntamente com a utilização do filtro da mediana são utilizados. Quando o sistema detecta um veículo em determinado local, porém a quantidade de bordas detectada pelo algoritmo de Sobel é menor que 5% do total de pixels da imagem, o sistema considera que a vaga contém uma sombra e não um veículo, classificando assim a vaga como desocupada. Testes realizados em um estacionamento com veículos padrão mostrou uma taxa de acerto de 100% para as condições de iluminação de manhãs, tardes e noites, e uma taxa de acerto de 93,8% para dias nublados. Quando posto à prova em dias chuvosos, o sistema mostrou uma taxa de acerto de 100% para imagens com garoa ou pós-chuva, 95,8% para imagens com chuva e 93,8% para imagens capturadas com chuva forte.

Huang et al. (2008) propuseram uma forma de se detectar vagas de estacionamento utilizando um framework Bayesiano Hierárquico de três camadas com capacidade de lidar com mudanças de iluminação, oclusão de veículos e oclusão de ambiente. O framework possui as seguintes camadas: camada de observação que lida com as características que podem ser baseadas tanto em pixels quanto em texturas, camada de rotulação que categoriza um pixel ou região e a camada semântica, que inclui hipóteses semânticas a respeito das vagas.

Para o trabalho a representação da cor dos pixels no formato RGB na forma de um conjunto $D = \{d_1, \dots, d_m\}$ foi escolhido como característica a ser utilizada na camada de observação. Já para a camada de rotulação foi determinado que um pixel poderia ser categorizado como um dos itens do conjunto $H = \{\text{"carro"}, \text{"chão"}, \text{"qualquer outro"}\}$. A camada semântica representa as vagas $S = \{s_1, s_2, \dots, s_n\}$ e seus estados, que podem ser considerados como ocupadas (1) ou vazias (0). Os nodos da camada semântica se conectam tanto aos nodos da camada de rotulação pertencentes a ela, quanto aos nodos de rotulação pertencentes às suas vagas vizinhas laterais, possibilitando assim a modelagem do sistema considerando-se as possíveis oclusões causadas pelos veículos nas vagas adjacentes. Uma ilustração do modelo pode ser observada na Figura 3.2.

Através das informações das três camadas do método hierárquico é então treinado um modelo para encontrar o estado mais adequado para H e S dado um conjunto D , ou seja:

$$H, S = \operatorname{argmax} P(H, S | D) \quad (3.1)$$

Os testes foram realizados com imagens que incluíam 1.300 vagas de estacionamento vazias e 1.500 ocupadas. Os resultados mostraram uma FPR de 0,032, FNR de 0,02 e uma

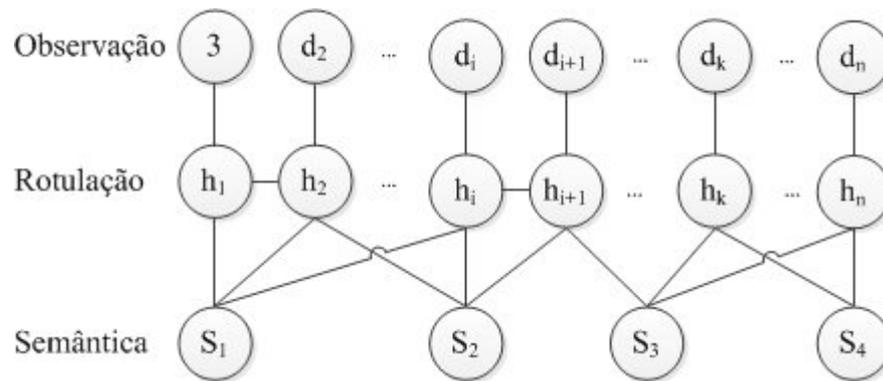


Figura 3.2: Modelo Bayesiano Hierárquico - Figura Adaptada de Huang et al. (2008)

taxa de acertos de 97,44%.

Um Framework Bayesiano para detecção de vagas com as mesmas características do trabalho de Huang et al. (2008) foi proposto por Huang e Wang (2010), porém este trabalho adicionou algumas particularidades no sistema, como a utilização dos parâmetros da câmera para modelar os veículos em um espaço tridimensional. Essas informações possibilitam ao sistema prever as oclusões causadas pelos veículos nas vagas adjacentes a eles, bem como a distorção causada pela perspectiva da câmera. Através de informações sobre o posicionamento do sol a cada instante do dia, as quais devem ser dadas de antemão ao software, e da modelagem em três dimensões dos veículos, um mapeamento das possíveis regiões sombreadas também foi criado no trabalho.

Como em um ambiente aberto o sol pode ser ocluído em algum instante, a hipótese da presença de uma sombra em determinado local é aceita somente quando a diferença do valor da cor média da área supostamente sombreada pela cor média da área não sombreada ultrapassa um limiar pré-estabelecido.

Devido ao grande número de parâmetros a serem definidos e informações que devem ser angariadas para a instalação do sistema, a configuração do mesmo nos estacionamentos utilizados nos testes do trabalho levou aproximadamente cinco dias.

Para avaliar os resultados foram utilizadas AUCs das curvas ROC obtidas dos conjuntos de teste. Um desses testes foi realizado com imagens de um estacionamento com 46 vagas visíveis, onde essas imagens foram separadas de acordo com as condições climáticas do dia que pode ser ensolarado normal, luz solar intensa ou com luminosidade variável, sendo que as AUCs obtidas foram 0,9749, 0,9626 e 0,9802, respectivamente. Para esse teste foi considerado um total de 14.766 vagas de estacionamento.

Outro teste realizado em um estacionamento com 64 vagas visíveis mostrou uma

taxa de acertos, FNR e FPR de 98,8%, 0,0198 e 0,0097, respectivamente. Neste teste foi considerado um total de 6.912 vagas de estacionamento.

3.2 Detecção de Veículos Sem Utilização da Cor como Critério de Classificação

Os trabalhos descritos nesta seção não utilizam diretamente a cor dos pixels como critério de classificação das vagas, mas sim informações coletadas através de métodos de extração de características mais sofisticadas das amostras. Apesar de geralmente possuírem um nível de complexidade mais alto, esses métodos podem atenuar os problemas causados pela oscilação da luminosidade e presença de sombras, que são dois grandes desafios encontrados ao se utilizar somente a cor dos pixels como critério de classificação.

Uma abordagem para detecção de vagas de estacionamento baseada na modelagem do plano de fundo foi utilizada no trabalho de Bin et al. (2009), no qual foi proposto um sistema baseado em software e hardware organizado em três módulos independentes. O primeiro módulo contém o sensor responsável pela captura das imagens com uma resolução de no mínimo 640×480 pixels. O segundo, implementado em hardware do tipo *Field Programmable Gate Array* (FPGA), tem o objetivo de filtrar os ruídos presentes nas imagens, enquanto o terceiro módulo realiza a classificação das vagas. Para definir se uma vaga está livre ou não, o método se baseia na correlação, na variância e na quantidade de pontos de borda detectados pelo método de Canny (CANNY, 1986) entre a imagem sendo processada e a imagem de fundo. Os testes foram realizados com imagens de um estacionamento contendo seis vagas visíveis, do qual foram extraídas 7.020 amostras de teste. Os resultados mostraram uma FPR de 0,0908 e uma FNR de 0,002.

Ping e Yu (2009) propuseram uma metodologia para detectar veículos estacionados de forma irregular utilizando uma câmera omnidirecional, que é capaz de capturar imagens em um ângulo de 360° . Para realizar a tarefa, os autores primeiramente assumiram que um veículo estacionado se trata de um objeto temporariamente estático, já que este entra em cena em um determinado instante e fica parado durante certo tempo antes de sair.

Para detectar os objetos temporariamente estáticos foram criados dois Modelos de Mistura Gaussiana - *Gaussian Mixture Model* (GMM) - do plano de fundo com diferentes taxas de aprendizagem. Um modelo com aprendizagem de longo termo M_L é utilizado para detectar objetos em movimento, objetos temporariamente estáticos, sombras, mudanças de iluminação e ruídos, enquanto um modelo com aprendizagem de termo curto M_C é utilizado para detectar

objetos em movimento e ruídos.

O princípio do sistema é de que um objeto temporariamente estático será detectado como primeiro plano pelo M_L , já que este modelo possui uma taxa de aprendizado mais baixa e demora mais para assimilar o objeto na sua modelagem de plano de fundo. Porém este mesmo objeto será detectado como plano de fundo pelo M_C , pois sua taxa de aprendizagem é maior e um objeto estático passa rapidamente a ser interpretado como plano de fundo. Como as sombras podem ser confundidas com objetos em movimento, interferindo assim no processo de classificação, um algoritmo de remoção de sombras baseado no modelo de cores HSV foi utilizado no método. A classificação final se dá através da análise dos objetos temporariamente estáticos presentes em uma área pré-definida como sendo de estacionamento proibido, e que não foram detectados como sombra no modelo HSV. Apesar de ser mencionado no trabalho que foram realizados testes com imagens de uma câmera omnidirecional com resolução de 320×240 , não é citada a taxa de acertos do sistema.

Uma forma de se classificar vagas de pátios de estacionamento utilizando informações epipolares de imagens aéreas foi proposto por Wang e Hanson (1998). O método baseia-se no princípio de que os veículos estacionados estão necessariamente mais altos que o chão, e utiliza duas imagens de uma área de estacionamento com os parâmetros da câmera conhecidos, as quais servem de entrada em um algoritmo estéreo de reconstrução de terreno para a extração de oito características relacionadas à elevação dos objetos. Como veículos adjacentes podem ser reconhecidos como um objeto único, as linhas que delimitam as vagas são utilizadas de forma a distinguir quantos veículos estão presentes em um desses objetos.

O método tende a atingir melhores resultados em áreas de estacionamento esparsas e com poucos veículos, pois áreas com grande lotação podem levar o algoritmo estéreo de reconstrução a conectar os veículos adjacentes, e por conta do maior número de oclusões devido à grande quantidade de veículos, muitas das linhas delimitadoras das vagas podem se tornar invisíveis. Resultados contendo as taxas de reconhecimento do método não foram citados no trabalho.

Fabiàn (2008) propôs um método para detectar vagas de estacionamento baseado em três estágios principais. No primeiro estágio é feito um pré-processamento, onde são removidas as distorções causadas pelas lentes e as sombras. Nesse estágio também é criado um modelo 3D da imagem baseando-se nos parâmetros de posição da câmera.

O segundo estágio é o de preparação, cujo qual é o responsável por extrair as áreas de interesse e definir um mapa de oclusões das vagas presentes na imagem, pois assume-se que certas partes da imagem de uma vaga podem ser cobertas por carros que estão ao

seu entorno, e que portanto não são confiáveis. No terceiro estágio é realizada a avaliação da imagem utilizando o método *Quad Tree*, que é uma técnica que subdivide a imagem em quatro blocos. Caso um bloco não cumpra um critério de homogeneidade, ele então é subdividido novamente em quatro outros blocos. O processo se repete até que o critério de homogeneidade seja atingido ou até que o tamanho do bloco seja igual a 1.

No trabalho assume-se que as vagas vazias tendem a ter uma superfície mais homogênea em comparação às vagas ocupadas. Tomando essa premissa a vaga é classificada então de acordo com a quantidade de blocos gerados na *Quad Tree*. O estado de uma vaga também pode ser considerado como desconhecido caso o número de pixels que possuem oclusão for suficientemente grande. O trabalho não apresenta resultados estatísticos de testes com o método proposto.

No trabalho de Sastre et al. (2007) foi proposta uma metodologia para se resolver um sistema de equações que possibilita o cálculo de uma matriz de transformação que traduz coordenadas de pontos para diferentes planos. Essa metodologia foi utilizada como parte de um sistema de classificação de vagas em áreas de estacionamento.

Para o seu funcionamento, o sistema proposto primeiramente utiliza a metodologia de transformação de coordenadas para criar uma pseudo-imagem aérea do estacionamento a partir de uma imagem do mesmo. Características baseadas nos Filtros de Gabor são então extraídas dessa pseudo-imagem e, finalmente, um classificador do tipo SVM utiliza essas características para classificar as vagas.

Para realização dos testes, um SVM com função de Kernel linear foi treinado utilizando-se 12.150 vetores de características extraídos das vagas de um estacionamento que continha 21 vagas visíveis. Esse SVM então foi posto à prova para classificar outras 12.150 imagens desse mesmo estacionamento. A maior taxa de acertos atingida nos testes foi de 97,73% quando foram utilizados vetores contendo 38 características extraídas com os Filtros de Gabor.

Um método para classificação de vagas de estacionamento baseado num classificador Fuzzy C-Means com Otimização por Enxame de Partículas - *Particle Swarm Optimization* (PSO) (ICHIHASHI et al., 2008) foi proposto por Ichihashi et al. (2009). Nesse sistema as vagas são segmentadas em blocos quadrados de 32 x 32 pixels, das quais são extraídos os vetores base utilizando-se a Análise de Componentes Principais. O treinamento do classificador se dá através da interação com o usuário, que primeiramente seleciona cerca de 500 amostras do estacionamento para a aprendizagem do sistema. Após a aprendizagem, o sistema passa a classificar as vagas automaticamente. Quando uma vaga não é classificada corretamente, o usuário pode informar ao sistema o correto estado da mesma, e então adicioná-la ao conjunto

de treinamento.

Testes foram realizados utilizando-se 2.000 imagens coletadas durante duas semanas de um estacionamento contendo 27 vagas visíveis. O sistema foi treinado com 27.000 amostras extraídas de 1.000 imagens coletadas na primeira semana, e então foi posto à prova utilizando-se outras 27.000 amostras retiradas das demais 1.000 imagens coletadas na segunda semana. A melhor taxa de acertos obtida foi de 97,24%. Outro teste foi feito adicionando-se 1.056 amostras coletadas em uma terceira semana no treinamento do classificador, o que resultou em uma taxa de acertos de 97,96%.

O trabalho de Zhu, Hirahara e Ikeuchi (2003) propõe um método para detectar carros estacionados utilizando imagens epipolares, que contém informações tridimensionais da imagem. Essas informações são obtidas de uma cena estática através de uma densa coleção de imagens coletadas com uma câmera em movimento. Para capturar as imagens, é instalada uma câmera do tipo *line-scan* em um veículo que faz o rastreamento das vagas. Com a câmera virada para a lateral, é possível a captura das imagens das vagas e a obtenção de suas informações em três dimensões, para que então as informações sobre suas profundidades sejam utilizadas para detectar se existe um veículo estacionado em determinado local ou não. Foram feitos 15 testes em uma rua durante um dia chuvoso. Na lateral da via haviam 81 carros estacionados e o sistema com a metodologia proposta atingiu uma taxa de acertos de 96,4%.

3.3 Sumário do Estado da Arte

Nesta seção é apresentada uma breve descrição sobre as metodologias aplicadas para a classificação automática de vagas de estacionamento utilizadas pelos autores citados nas seções 3.1 e 3.2, além de apresentar os resultados obtidos pelos mesmos ao testarem suas metodologias.

Na Tabela 3.1 é apresentado um resumo das metodologias empregadas, o tipo de característica utilizada (baseado na coloração dos pixels ou não), as bases de dados utilizadas para os testes e os resultados obtidos pelos autores ao testarem suas metodologias. Os resultados podem ser exibidos como taxas de falso positivo (FPR), taxas de falso negativo (FNR), taxas de acertos ou então áreas sobre a curva ROC (AUC), dependendo da forma com que os autores disponibilizaram seus resultados. Maiores informações sobre estas métricas podem ser encontradas na seção 2.5.

Muitos dos campos de resultados da tabela foram deixados em branco devido ao fato de que em alguns dos trabalhos não constam resultados estatísticos dos testes realizados.

Tabela 3.1: Sumarização das Metodologias

Autores	Metodologia Empregada	Baseado na Cor dos Pixels	Base de Testes	FPR	FNR	TA(%)	AUC
(LIN; CHEN; LIU, 2006)	Detecção de objetos comparando a cor dos pixels da imagem capturada com a cor dos pixels de um modelo do plano de fundo.	Sim	-	-	-	-	-
(TAN et al., 2009)	Detecção por coloração e Pattern Match.	Sim	-	-	-	-	-
(WU et al., 2007)	215 características relacionadas à cor são extraídas de uma imagem contendo três vagas. Utilizando PCA essas características são então reduzidas a 50 para a classificação.	Sim	Base contendo 1.100 amostras das quais 800 foram utilizadas para o treinamento e 300 para os testes.	-	-	93,52%	-
(BONG; TING; LAI, 2008)	Detecção de objetos baseado em um limiar de cor.	Sim	Estacionamento com veículos padrão e condições de iluminação de manhãs, tardes e noites em dias sem chuva.	-	-	100 %	-

(Continua)

Tabela 3.1: Sumarização das Metodologias

(continuação)

Autores	Metodologia Empregada	Baseado na Cor dos Pixels	Base de Testes	FPR	FNR	TA(%)	AUC
			Estacionamento com veículos padrão e condições de iluminação de dias nublados.	-	-	93,80 %	-
			Estacionamento com veículos padrão e condições de dias chuvosos com garoa ou pós-chuva.	-	-	100 %	-
			Estacionamento com veículos padrão e imagens capturadas durante a chuva.	-	-	95,80 %	-
			Estacionamento com veículos padrão e imagens capturadas durante chuva forte.	-	-	93,80 %	-
(HUANG et al., 2008)	Framework Bayesiano de três camadas com características baseadas na cor.	Sim	Base contendo 1.300 amostras de vagas vazias e 1.500 amostras de vagas ocupadas.	0,032	0,02	97,44%	-

(Continua)

Tabela 3.1: Sumarização das Metodologias

(continuação)

Autores	Metodologia Empregada	Baseado na Cor dos Pixels	Base de Testes	FPR	FNR	TA(%)	AUC
(HUANG; WANG, 2010)	Framework Bayesiano de três camadas com características baseadas na cor e uma metodologia para previsão de oclusões e posicionamento de sombras baseada nos parâmetros da câmera.	Sim	Imagens de Estacionamento com 46 vagas visíveis com luz solar normal.	0,0004	0,0081	99,88%	0,9749
			Imagens de Estacionamento com 46 vagas visíveis com luz solar intensa.	0,0024	0,0324	99,59%	0,9626
			Imagens de Estacionamento com 46 vagas visíveis capturadas em dias com luminosidade variável.	0,0040	0,0437	99,43%	0,9802
			6.912 amostras de vagas de um estacionamento com 64 vagas visíveis.	0,0097	0,0198	98,80 %	-

(Continua)

Tabela 3.1: Sumarização das Metodologias

(continuação)

Autores	Metodologia Empregada	Baseado na Cor dos Pixels	Base de Testes	FPR	FNR	TA(%)	AUC
(BIN et al., 2009)	Objetos identificados através da quantidade de bordas reconhecidas pelo algoritmo de Canny.	Não	Base contendo 7.020 amostras de vagas de um estacionamento contendo 6 vagas visíveis	0,0908	0,002	-	-
(PING; YU, 2009)	Dois Modelos de Mistura Gaussiana (GMM) do plano de fundo dos estacionamentos com diferentes taxas de aprendizagem detectam objetos temporariamente estacionários.	Não	-	-	-	-	-
(WANG; HANSON, 1998)	Deteccção da elevação dos objetos feita através de imagens extraídas de duas câmeras diferentes de parâmetros conhecidos.	Não	-	-	-	-	-

(Continua)

Tabela 3.1: Sumarização das Metodologias

(continuação)

Autores	Metodologia Empregada	Baseado na Cor dos Pixels	Base de Testes	FPR	FNR	TA(%)	AUC
(FABIÀN, 2008)	Detecção de objetos utilizando subdivisão das amostras de vagas por Quad Tree	Não	-	-	-	-	-
(SASTRE et al., 2007)	Transformação de Coordenadas para obtenção de uma pseudo-imagem aérea. Classificação baseada em características extraídas com Filtros de Gabor.	Não	12.150 mostras de um estacionamento com 21 vagas visíveis.	-	-	97,73%	-
(ICHIHASHI et al., 2009)	Vetores base de amostras de 32x32 pixels extraídos através da análise de Componentes Principais (PCA).	Não	Treinamento com 27.000 amostras e teste com 27.000 amostras de um estacionamento com 27 vagas visíveis.	-	-	97,24%	-

(Continua)

Tabela 3.1: Sumarização das Metodologias

(continuação)

Autores	Metodologia Empregada	Baseado na Cor dos Pixels	Base de Testes	FPR	FNR	TA(%)	AUC
			Treinamento com 28.056 amostras e teste 27.000 amostras de um estacionamento com 27 vagas visíveis.	-	-	97,96 %	-
(ZHU; HIRAHARA; IKEUCHI, 2003)	Informações tridimensionais de imagens epipolares capturadas com uma câmera do tipo line-scan em movimento.	Não	Escaneamento com uma câmera do tipo line-scan da lateral de uma via contendo 81 veículos estacionados.	-	-	96,40%	-

3.4 Discussão Crítica Sobre os Métodos Apresentados

Boa parte dos trabalhos encontrados na literatura baseia-se na detecção dos veículos estacionados através da cor, ou então necessitam de um sistema intrincado para detecção dos veículos, contendo mais de uma câmera ou equipamentos capazes de coletar informações tridimensionais da cena. Quanto aos sistemas baseados na cor dos pixels, embora computacionalmente simples, podem ser vulneráveis às mudanças de luminosidade não só da cena como um todo, mas também às mudanças de coloração que ocorrem nos objetos após uma chuva ou quando existem sombras projetadas sobre estes, por exemplo.

Já os sistemas que envolvem equipamentos sofisticados ou então necessitam que muitos parâmetros sejam conhecidos de antemão, como o posicionamento exato das câmeras ou o posicionamento global do estacionamento, apesar de possuírem um potencial maior de apresentarem bons resultados, podem ser inviáveis devido à complexidade de instalação e alto custo dos equipamentos. Devido a isso, soluções que envolvem características mais sofisticadas que consideram não só os pixels, mas também suas vizinhanças, podem ser uma boa alternativa para a construção de sistemas de reconhecimento automático de vagas. Um exemplo de trabalho baseado nesse tipo de característica é o de Sastre et al. (2007). Outra possível solução é utilização de modelagens de plano de fundo utilizando técnicas menos suscetíveis aos efeitos descritos no trabalho de Toyama et al. (1999). Uma abordagem com essas características foi descrita no trabalho de Ping e Yu (2009).

Durante a análise da literatura foi verificado que somente o trabalho de Huang e Wang (2010) foi posto à prova em duas áreas de estacionamento distintas. Os testes em áreas de estacionamento diferentes são de suma importância para a realização de uma análise da capacidade de generalização dos métodos propostos. Testes em uma mesma área de estacionamento, mas com posicionamento diferente da câmera também podem contribuir para verificar a capacidade de generalização dos métodos.

A única base pública com uma quantidade razoável de amostras encontrada para realização de testes está disponível em Huang (2013) e foi utilizada no trabalho de Huang e Wang (2010). Essa base contém imagens capturadas durante três dias de um estacionamento que possui cerca de 45 vagas visíveis.

Apesar de possuir uma quantidade razoável de vagas visíveis e de imagens (325 capturas), essa base apresenta limitações como falta de imagens capturadas em dias chuvosos, além do fato de que imagens capturadas em apenas três dias podem não conter amostras o suficiente para representar as possíveis variações de luminosidade, que podem ocorrer ao se

capturar as imagens de um estacionamento.

Desta maneira, uma base pública com um número grande de amostras disponíveis, coletadas em diferentes condições climáticas e ao longo de um período razoável de tempo, poderia padronizar os testes neste tipo de sistema, possibilitando uma melhor comparação entre as metodologias propostas.

4 Método Proposto

A seguir é descrita uma metodologia para classificação de vagas de estacionamento baseada em técnicas clássicas de reconhecimento de padrões com aprendizagem supervisionada e combinação de classificadores. O reconhecimento é feito a partir de imagens capturadas dos estacionamentos, das quais são extraídas características baseadas em textura para o treinamento dos classificadores.

O objetivo do trabalho é prover uma metodologia capaz de classificar vagas de estacionamento em diferentes condições climáticas utilizando imagens predominantemente aéreas, coletadas a partir de diferentes ângulos do estacionamento. O trabalho também é focado na criação de um sistema genérico o suficiente para ser utilizado em áreas de estacionamento que não contribuíram com nenhuma amostra de treinamento para os modelos de classificação, além de propor uma nova base de imagens para testes com um protocolo que garanta sua extensibilidade.

4.1 Modelagem do Problema

Em um problema clássico de reconhecimento de padrões desejamos atribuir classes pré-definidas a objetos. No reconhecimento de padrões com treinamento supervisionado, primeiramente são extraídas características de objetos com classes conhecidas, que serão utilizados para o treinamento de um modelo. Depois de treinado, esse modelo então pode ser utilizado para classificar novos objetos dos quais não se sabe de antemão a qual classe pertencem.

A classificação de vagas de estacionamento utilizando suas imagens pode então ser modelada como um problema de reconhecimento de padrões com treinamento supervisionado. Para isso serão extraídos vetores de características baseadas em textura das vagas de estacionamento individuais cujos estados são conhecidos com antecedência. Essas características serão utilizadas para o treinamento do modelo, e então novas vagas de estacionamento pode-

rão ser classificadas, bastando para isso a extração de suas características e que estas sejam submetidas a teste no modelo treinado.

A Figura 4.1 mostra o fluxo seguido para a classificação de uma vaga de estacionamento. Na fase de captura as imagens são adquiridas para que, na fase de preparação as vagas individuais sejam segmentadas e suas imagens sejam convertidas para escala de cinza. Na fase de classificação é realizada a extração das características da amostra, onde cada vetor gerado é enviado para categorização em um classificador especialista para que, finalmente, os resultados sejam combinados e a vaga seja classificada.

A fonte das imagens de estacionamento utilizadas na fase de captura é detalhada na seção 4.2, a fase de preparação das imagens é descrita na seção 4.3, enquanto a seção 4.4 detalha a fase de classificação das amostras.

4.2 Criação da Base de Imagens

Uma base de imagens de estacionamentos foi criada a fim de que esta pudesse prover os dados necessários para os treinamentos e testes não só deste trabalho, mas de qualquer outro que envolva a detecção de veículos em áreas de estacionamento. A base foi denominada PKLot, e teve como premissa possuir imagens de mais de um estacionamento, coletadas em diversas condições climáticas e a partir de diferentes ângulos.

A criação da base envolveu a definição de um protocolo de aquisição e a criação de descritores para as imagens, os quais foram desenvolvidos de forma a padronizar e simplificar suas categorizações, facilitando assim o processamento das amostras, além de garantir a extensibilidade e a manutenção da base.

As informações sobre o protocolo de captura são descritas no tópico 4.2.1, os descritores das imagens são detalhados no item 4.2.3, enquanto no tópico 4.2.2 são descritas as características atuais da base.

4.2.1 Protocolo de Captura

Antes de se realizar qualquer captura de imagens, foi definido um protocolo a fim de se padronizar as coletas para a base de imagens. As coletas foram realizadas tomando como base as seguintes orientações:

- A câmera deve ser posicionada em uma altura suficiente para evitar, ou pelo menos

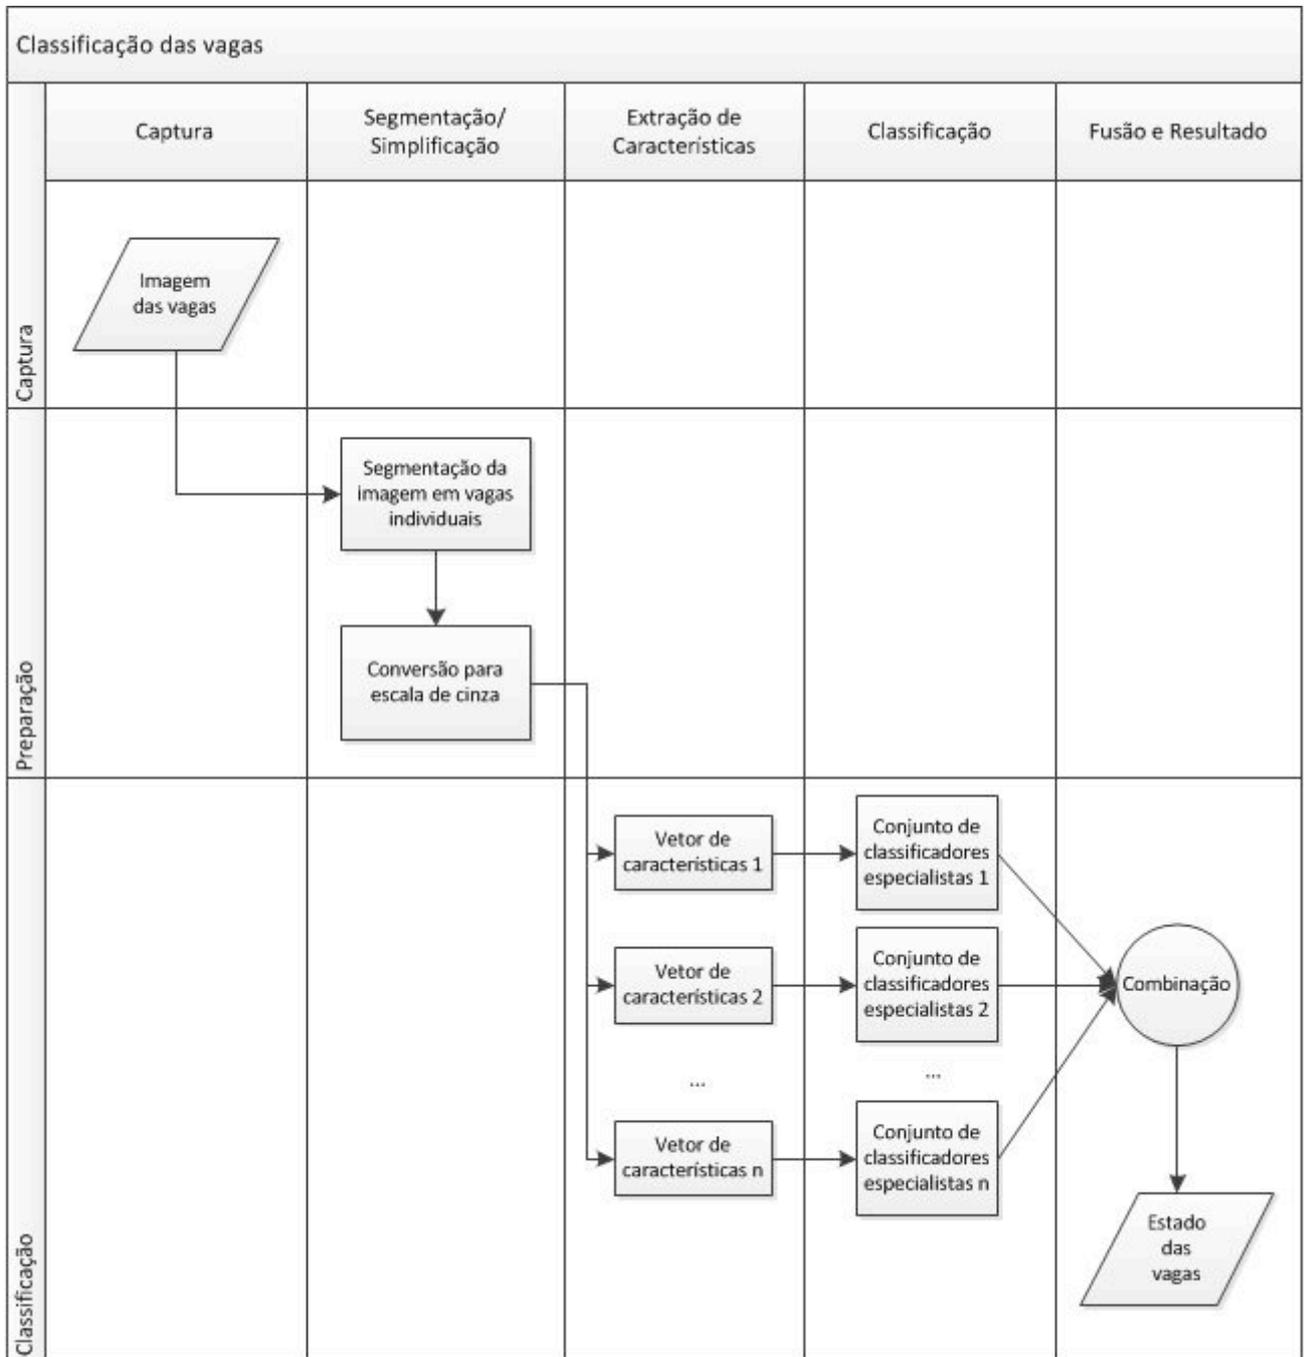


Figura 4.1: Fluxograma para classificação das vagas

minimizar, as oclusões geradas por veículos em suas vagas adjacentes, gerando assim imagens predominantemente aéreas. Essa restrição no posicionamento almeja um menor índice de oclusão e uma maior quantia de vagas capturadas em cada uma das imagens.

- Em cada uma das imagens coletadas da área de estacionamento devem estar presentes no mínimo 15 vagas individuais, ocupadas ou não. Com esse número de vagas em cada uma das imagens é possível realizar testes mais próximos de situações reais de operação, onde câmeras podem capturar dezenas de vagas simultaneamente.
- A câmera deve capturar pelo menos uma imagem a cada 5 minutos. Esse espaçamento foi definido empiricamente como sendo um tempo razoável no qual algum evento pode acontecer, como a chegada ou saída de veículos, ou até mesmo mudanças climáticas e de iluminação.
- A base deve conter imagens capturadas em diversos níveis de lotação dos estacionamentos, desde quase vazios até totalmente ocupados.
- As imagens coletadas devem estar no padrão RGB de cores, e salvas no formato JPEG sem compressão, já que este formato é amplamente difundido e utilizado.

4.2.2 Características da Base de Imagens

A base de imagens foi criada inicialmente a partir de capturas de dois pátios de estacionamento distintos utilizando-se o protocolo descrito no item 4.2.1. Imagens de um dos estacionamentos também foram coletadas de dois ângulos diferentes, possibilitando a verificação da robustez dos sistemas de classificação quando estes se deparam com mudanças no posicionamento da câmera.

Depois de coletadas, as imagens foram separadas em uma estrutura de diretórios de acordo com seus respectivos estacionamentos e condições climáticas seguindo a hierarquia:

nome_estacionamento /clima/data_coleta/ano-mês-dia_hora_minuto_segundo.jpg

Onde *clima* refere-se à condição climática das capturas, e pode conter os valores *ensolarado*, *nublado* ou *chuvoso*, enquanto as informações contidas em *ano-mês-dia_hora_minuto_segundo* referem-se ao exato momento em que a imagem foi capturada. Sendo assim, o caminho completo de uma imagem na base de dados poderia, por exemplo, ser da seguinte forma:

estacionamento1/Ensolarado/2012-08-06/2012-08-06_08_50_30.jpg

Essa estrutura foi montada com o intuito de prover uma forma simples de separar as

imagens, onde fosse possível encontrar todas as informações sobre determinada captura no seu próprio caminho na estrutura de diretórios, além de facilitar a busca por imagens capturadas em determinada data ou ainda com determinada característica climática.

Como citado anteriormente, a base de dados conta atualmente com imagens de dois pátios de estacionamentos. As amostras do pátio UFPR foram coletadas de um dos estacionamentos do Centro Politécnico da Universidade Federal do Paraná, sendo que as amostras desse estacionamento foram coletadas de dois ângulos diferentes. A fim de simplificar a catalogação dessas imagens, cada um dos ângulos de coleta desse estacionamentos foram considerados como uma base de estacionamentos nova.

Sendo assim, as imagens coletadas do estacionamento da UFPR estão separadas em duas bases, denominadas UFPR04 e UFPR05, as quais receberam estes nomes por terem sido capturadas, respectivamente, a partir do 4º e 5º andares de um prédio adjacente ao estacionamento. O segundo pátio de estacionamentos presente na base contém imagens coletadas de um dos estacionamentos da Pontifícia Universidade Católica do Paraná (PUCPR), sendo que para este estacionamento foram coletadas imagens de somente um ângulo.

Todas as vagas presentes base PKLot foram rotuladas de forma manual como ocupadas ou vazias, e essas informações foram salvas nos descritores XML de suas respectivas imagens (item 4.2.3). Atualmente a base conta com um total de 12.417 imagens capturadas. A Tabela 4.1 contém as informações sobre o estado atual da base de imagens.

Tabela 4.1: Base de Imagens

Estacionamento	Quantidade Aproximada de vagas visíveis	Clima	Número de dias em que a coleta foi realizada	Imagens
Estacionamento UFPR04 (Ângulo 1)	28	Ensolarado	20	2.098
		Nublado	15	1.408
		Chuvoso	14	285
Estacionamento UFPR05 (Ângulo 2)	45	Ensolarado	25	2.500
		Nublado	19	1.426
		Chuvoso	8	226
Estacionamento PUCPR	225	Ensolarado	24	2.315
		Nublado	11	1.328
		Chuvoso	8	831
Total de imagens				12.417

Amostras das imagens do estacionamento da UFPR podem ser visualizadas nas Figuras 4.2, 4.3 e 4.4, onde as figuras 4.2 e 4.3 foram capturadas em dias ensolarados com a câmera em posicionamentos distintos, enquanto a figura 4.4 é uma amostra de um dia chuvoso.



Figura 4.2: Estacionamento UFPR04 com dia ensolarado



Figura 4.3: Estacionamento UFPR05 com dia ensolarado



Figura 4.4: Estacionamento UFPR04 com dia chuvoso

Observando-se as imagens pode-se concluir que um grande desafio para a classificação das amostras deste estacionamento é a disposição dos veículos, que pode variar de acordo com o local do estacionamento em que estes se encontram. Outros desafios do estacionamento UFPR que podem ser observados nas imagens é a presença de muitas sombras projetadas por árvores e veículos, e a grande variação de luminosidade que ocorre em condições de chuva quando as imagens são comparadas com as capturadas em dias de sol.

Amostras das imagens do estacionamento PUCPR podem ser visualizadas nas figuras 4.5 e 4.6, onde a imagem da figura 4.5 foi capturada em um dia ensolarado enquanto a imagem da figura 4.6 foi capturada em um dia chuvoso. As principais características deste estacionamento são a disposição uniforme da maioria dos veículos, a grande quantidade de vagas visíveis e a presença de dois tipos de terreno diferentes na mesma imagem.

Bem como nas imagens dos estacionamentos UFPR, as imagens do estacionamento PUCPR apresentam muitas sombras, em especial sombras grandes projetadas por edifícios ao redor do estacionamento. Além disso, devido ao fato da câmera capturar imagens de uma distância razoavelmente grande, as vagas ocupam poucos pixels nas imagens, dificultando a classificação das amostras principalmente na presença de ruídos introduzidos pela chuva, como se pode observar na figura 4.6.



Figura 4.5: Estacionamento PUCPR com dia ensolarado

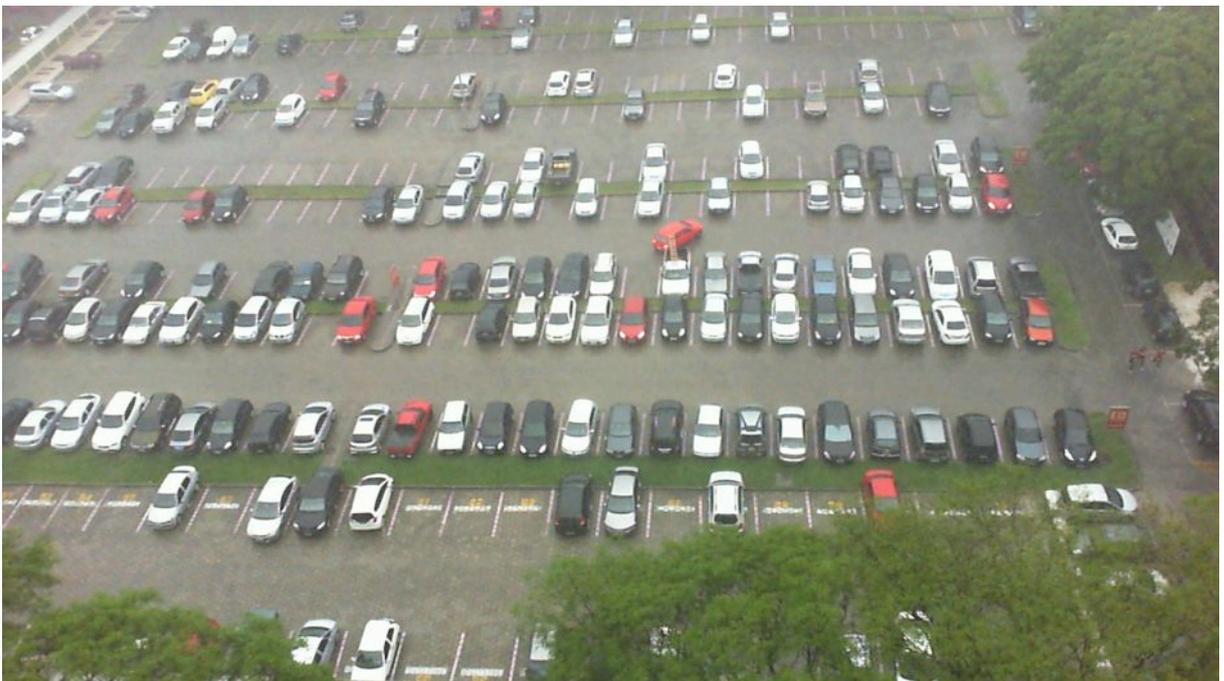


Figura 4.6: Estacionamento PUCPR com dia chuvoso

4.2.3 Descritores das Imagens

Para cada uma das imagens presentes existe um descritor no formato *Extensible Markup Language* (XML)(DEITEL, 2001). Esses descritores contém informações sobre o estado e o posicionamento de cada uma das vagas, como o exibido na figura 4.7, que exemplifica o descritor XML de uma das imagens de estacionamento.

```
<?xml version="1.0"?>
<parking id="ufpr04">
  <space id="1" occupied="1">
    <contour>
      <point x="720" y="549" />
      <point x="805" y="665" />
      <point x="715" y="698" />
      <point x="644" y="582" />
    </contour>
  </space>
  <space id="2" occupied="0">
    <contour>
      <point x="769" y="451" />
      <point x="849" y="534" />
      <point x="789" y="586" />
      <point x="701" y="489" />
    </contour>
  </space>
  ...
</parking>
```

Figura 4.7: Exemplo de Descritor XML de um estacionamento

Os arquivos XML são estruturados da seguinte forma: o elemento raiz, denominado *parking*, define o identificador do estacionamento. Dentro do nodo raiz encontram-se os elementos *space*, que definem as vagas individuais do estacionamento, contendo um atributo denominado *id* que define um identificador único para a vaga, e um atributo denominado *occupied* que define se a vaga está vazia(0) ou ocupada(1).

Elementos denominados *contour*, que se encontram dentro dos nodos *space*, tem a função de definir $n \geq 4$ pontos de um polígono que delimita a vaga. Esses pontos são definidos nos elementos *point*, que possuem os atributos de coordenadas *X* e *Y* em pixels.

Os nomes dos arquivos XML e a estrutura de diretórios seguida para armazená-los seguem o mesmo padrão das imagens da base, porém os arquivos possuem a extensão xml.

Sendo assim, uma imagem cujo caminho é

estacionamento1/Ensolarado/2012-08-06/2012-08-06_08_50_30.jpg

terá seu descritor no caminho

estacionamento1/Ensolarado/2012-08-06/2012-08-06_08_50_30.xml

4.3 Segmentação e Preparação das Imagens

Para realização dos experimentos, as imagens das áreas dos estacionamentos primeiramente foram segmentadas a fim de se obter as imagens de suas vagas isoladas. Para isso foi desenvolvido um software que, através das informações contidas nos descritores XML das imagens, realiza a segmentação das vagas individuais.

O software de segmentação primeiramente carrega uma imagem e seu descritor XML, e para cada vaga presente no descritor é calculado o menor retângulo rotacionado que contém todos os pontos do polígono que delimita a vaga (figura 4.8). O trecho da imagem contida nesse retângulo é então recortada e rotacionada até 0° se o ângulo α de rotação do retângulo for menor que 45° (figura 4.9a), ou então é rotacionada até 90° se o ângulo α for maior ou igual a 45° (figura 4.9b).



Figura 4.8: Exemplo de segmentação de uma imagem de estacionamento

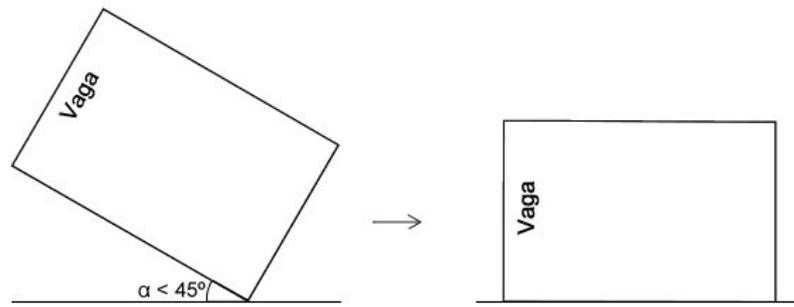
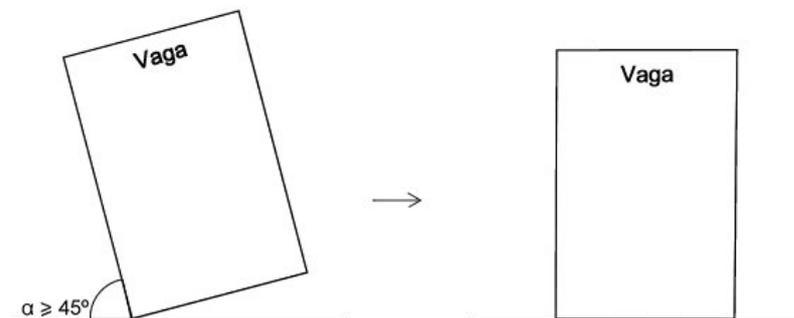
(a) Rotação de vagas com ângulo menor que 45° (b) Rotação de vagas com ângulo maior ou igual a 45°

Figura 4.9: Esquemas de rotação das amostras

As amostras resultantes que possuem seus comprimentos maiores que suas alturas, como é o caso da amostra resultante da rotação da figura 4.9a, são então rotacionadas novamente, porém em um ângulo de 90° .

Finalmente as amostras são salvas em diretórios separados, dependendo de seus estados (ocupada/vazia), onde elas podem ser utilizadas para os testes. As amostras resultantes da segmentação das cinco primeiras vagas da figura 4.8 podem ser visualizadas na figura 4.10.



Figura 4.10: Imagens Segmentadas

É importante salientar que os pátios de estacionamento presentes na base de imagens sofrem com problemas de superlotação em horários de pico, fazendo com que muitos motoristas estacionem seus veículos de maneira irregular, como no trecho em destaque da figura 4.11. Neste trabalho somente as amostras de vagas regulamentadas são consideradas, sendo que as

amostras de veículos estacionados irregularmente não são segmentadas.



Figura 4.11: Exemplo de veículos estacionados irregularmente

Todas as vagas visíveis nas imagens dos estacionamentos UFPR04 e UFPR05 foram segmentadas. Já para o estacionamento PUCPR foi segmentado um trecho que contém 100 vagas visíveis. Essa limitação na quantidade de vagas foi feita para diminuir o total de amostras deste estacionamento, que chegaria próximo a 1 milhão se todas as vagas fossem consideradas, tornando os testes com esse estacionamento muito custosos.

A figura 4.12 destaca as vagas selecionadas para segmentação no estacionamento PUCPR. Essas vagas foram escolhidas por não sofrerem com oclusões de ambiente, por possuírem diferentes tipos de terreno e por apresentarem grande variação de luminosidade ao longo do dia.

As quantidades de amostras vazias e ocupadas segmentadas para cada uma das possíveis condições climáticas da base PKLot podem ser visualizadas na Tabela 4.2.

4.4 Criação dos Classificadores

Nas próximas subseções são definidos os vetores de características extraídos das amostras, o processo de treinamento dos indutores e o esquema de fusão dos resultados, que compreendem a fase de “Classificação” da Figura 4.1.



Figura 4.12: Vagas Segmentadas no estacionamento PUCPR

Tabela 4.2: Quantidade de amostras vazias/ocupadas presentes na base

		Ocupadas	Vazias	Total
UFPR04	Ensolarado	32.166 (54,98%)	26.334 (45,02%)	58.500
	Nublado	11.608 (29,47%)	27.779 (70,53%)	39.387
	Chuvoso	2.351 (29,54%)	5.607 (70,46%)	7.958
	Total	46.125 (43,58%)	59.720 (56,42%)	105.845
UFPR05	Ensolarado	57.584 (57,65%)	42.306 (42,35%)	99.890
	Nublado	33.764 (59,27%)	23.202 (40,73%)	56.966
	Chuvoso	6.078 (68,07%)	2.851 (31,93%)	8.929
	Total	97.426 (58,77%)	68.359 (41,23%)	165.785
PUCPR	Ensolarado	96.761 (46,42%)	111.672 (53,58%)	208.433
	Nublado	42.363 (31,90%)	90.417 (68,10%)	132.780
	Chuvoso	55.105 (66,35%)	27.951 (33,65%)	83.056
	Total	194.229 (45,78%)	230.040 (54,22%)	424.269
Total de amostras		337.780 (48,54%)	358.119 (51,46%)	695.899

4.4.1 Extração de Características

Após a segmentação das imagens são extraídas características baseadas em textura das mesmas, sendo que para isso são utilizados extratores do tipo LBP (seção 2.2.1) e LPQ (seção 2.2.2).

As características baseadas em LBP são extraídas com invariância à rotação, com padrões uniformes e com padrões uniformes invariantes à rotação (Seção 2.2.1). Já as características baseadas em LPQ são extraídas utilizando funções de janela do tipo Gaussianas, uniformes e com filtros de banda de quadraturas Gaussianas Derivativas (Seção 2.2.2).

Para todas as extrações de características são utilizadas janelas de análise que consideram os oito vizinhos dos pixels em um raio de tamanho um, e as características extraídas são normalizadas por linha durante a extração e, posteriormente, por coluna através do método Min-Max. A tabela 4.3 sumariza as extrações e o tamanho dos vetores de características gerados.

Tabela 4.3: Extrações de características

Característica	Nome	Tipo da Extração	Tamanho do Vetor
LBP	LBP ^{ri}	Invariante à rotação	36
	LBP ^u	Padrões uniformes	59
	LBP ^{riu2}	Padrões uniformes invariantes à rotação	10
LPQ	LPQ ^u	Filtro Uniforme	256
	LPQ ^g	Filtro Gaussiano	256
	LPQ ^{gd}	Filtro de Quadratura Gaussiana Derivativa	256

4.4.2 Classificação e Fusão dos Resultados

O método de classificação proposto neste trabalho consiste em, utilizando um mesmo indutor, treinar um classificador para cada um dos tipos de extração de características descritos no item 4.4.1, totalizando 6 classificadores distintos. O resultado da classificação de determinada amostra é dado através da combinação das respostas de todos os classificadores.

As estratégias de combinação de classificadores utilizadas neste trabalho são a combinação pela maior confiança e a combinação pela média das respostas dos classificadores, já que esses métodos são pouco sensíveis à baixos scores (Seção 2.4). Por ser capaz de gerar probabilidades *a posteriori* e por ter apresentado bons resultados em diversos outros trabalhos (JEE; LEE; PAN, 2004; SANTANA et al., 2010; SILLA; KAESTNER; KOERICH, 2007), o SVM foi selecionado como indutor para a criação dos classificadores propostos (Seção 2.3).

A função RBF foi escolhida como *Kernel* para os SVMs treinados, já que diversos outros *kernels* foram testados e este foi o que apresentou os melhores resultados. Os parâmetros dos SVMs foram selecionados através de buscas em grid e validação cruzada de 5-*folds* (CHEN, 2012; HSU; CHANG; LIN, 2010). Devido ao alto custo computacional, para cada um dos classificadores são utilizadas cerca de 15.000 amostras selecionadas aleatoriamente das bases de treinamento para a realização das buscas dos parâmetros.

5 Avaliação do Método Proposto

Nesta seção é descrita a metodologia de avaliação do método proposto, bem como os resultados obtidos com os testes. Os principais testes executados e suas finalidades são os seguintes:

- Testes com classificadores treinados com amostras de um único estacionamento (Seção 5.3): este teste visa verificar a eficácia das características texturais na classificação de vagas de estacionamentos, além de testar o generalismo dos modelos criados colocando-os à prova em estacionamentos/ângulos de coleta que não contribuíram com amostras de treinamento. Neste teste também constam comparativos de resultados obtidos com classificadores treinados com características baseadas em cor.
- Testes com classificadores treinados com amostras de múltiplos estacionamentos (Seção 5.4): este teste tem por objetivo verificar o desempenho das características de textura, e o impacto causado pela adição de imagens de vários estacionamentos e ângulos nos conjuntos de treinamento dos classificadores.
- Testes em Outras Bases (Seção 5.5): o objetivo deste teste é o de prover um comparativo entre os resultados obtidos por outros autores em suas bases com a metodologia proposta.

Em todos os testes os métodos de combinação de classificadores também são postos à prova. Os resultados obtidos são exibidos na forma de curvas ROC, AUCs e de matrizes de confusão. Com o objetivo de simplificar a visualização, somente as curvas ROC com a maior AUC para cada um dos grupos de classificadores (classificadores LPQ, LBP e esquemas de combinação) serão exibidas nos gráficos. As curvas ROC que tiveram suas AUCs muito próximas a 1 possuem seus gráficos exibidos de maneira ampliada, não contendo a curva completa e facilitando a visualização.

As classes dos objetos computados nas matrizes de confusão são definidas como a classe com maior *score* gerado pelos classificadores. Sendo assim, se um objeto receber um

score de 51 para a classe ocupada e 49 para vazia, ele será classificado como sendo da classe ocupada. Empates são resolvidos de forma aleatória. Nas matrizes de confusão apresentadas, as linhas da matriz representam a classe real dos objetos, enquanto as colunas apresentam as classes resultantes do processo de classificação.

Visando simplificar a leitura do documento, a nomenclatura dos itens que possuem os resultados destes testes (curvas ROC, matrizes de confusão,...) seguem o padrão *base_treinamento/base_teste*. Sendo assim, por exemplo, a curva ROC do teste UFPR04/PUCPR é a curva referente ao teste realizado com as amostras de teste do estacionamento PUCPR, utilizando classificadores treinados com as amostras de treinamento do estacionamento UFPR04.

5.1 Separação das Bases de Treinamento e Testes

Para realizar os experimentos, primeiramente foi necessária a criação de bases de imagens separadas para o treinamento e testes dos modelos. Essas bases foram criadas utilizando-se as amostras das imagens de estacionamento já segmentadas, as quais foram distribuídas igualmente entre a base de treinamento e testes, tomando-se o cuidado de manter as proporções de amostras de dias chuvosos, nublados e ensolarados iguais entre as bases.

Como para a criação da base de imagens foi realizada uma captura a cada 5 minutos, e um veículo pode permanecer estacionado em um mesmo lugar por várias horas, após a segmentação notou-se que existiam muitas amostras semelhantes, as quais diferiam somente pelo horário de captura e por pequenas mudanças de luminosidade.

A figura 5.1 exemplifica o caso onde um veículo permanece estacionado em uma mesma vaga gerando diversas amostras similares. Como se pode observar, essa característica da base de imagens permite que a imagem de um mesmo veículo seja analisada em diferentes condições de luminosidade, possibilitando a criação de métodos mais robustos às variações de luz.



Figura 5.1: O mesmo veículo capturado respectivamente às 8:48, 9:18 e 9:43 de um mesmo dia

Apesar de possibilitar a construção de métodos menos sensíveis às mudanças de

luminosidade, a presença dessas amostras similares inspira cuidados na separação entre as bases de treinamento e testes. Caso as amostras sejam escolhidas aleatoriamente, existe a possibilidade de que algumas das amostras similares sejam escolhidas para o treinamento, e outras para testes, tornando o resultado do teste tendencioso. Esse problema pode se agravar caso seja utilizado um método de classificação baseado em instância, como é o exemplo do algoritmo dos K-Vizinhos Mais Próximos (HAN; KAMBER, 2001).

Para evitar a existência de amostras similares entre as bases de treinamento e testes, utilizou-se um método onde os dias das coletas das imagens são selecionados aleatoriamente para compor as bases. Sendo assim, todas as amostras de determinado dia só podem pertencer a somente uma das bases. Esse método de seleção dificulta a distribuição proporcional de imagens entre as bases (pode haver um número ímpar de dias, por exemplo), porém evita que imagens similares sejam compartilhadas entre as bases, pois é pouco provável que um veículo permaneça em uma mesma vaga por mais de um dia.

A tabela 5.1 exibe as informações das bases de dados de treinamento e testes geradas através desta metodologia de separação de amostras. Estas duas bases foram as utilizadas para os treinamento e testes dos classificadores deste trabalho.

Tabela 5.1: Separação entre a base de treinamento e testes

		Base de Treinamento			Base de Testes		
		Ocup.	Vazias	Total	Ocup.	Vazias	Total
UFPR04	Ensolarado	16.524	14.327	30.851	15.642	12.007	27.649
	Nublado	6.989	15.076	22.065	4.619	12.703	17.322
	Chuvoso	1.041	2.553	3.594	1.310	3.054	4.364
	Total	24.554	31.956	56.510	21.571	27.764	49.335
UFPR05	Ensolarado	28.822	21.657	50.479	28.762	20.649	49.411
	Nublado	15.421	12.985	28.406	18.343	10.217	28.560
	Chuvoso	2.751	1.633	4.384	3.327	1.218	4.545
	Total	46.994	36.275	83.269	50.432	32.084	82.516
PUCPR	Ensolarado	47.490	59.731	107.221	49.271	51.941	101.212
	Nublado	26.774	42.933	69.707	15.589	47.484	63.073
	Chuvoso	19.540	16.025	35.565	35.565	11.926	47.491
	Total	93.804	118.689	212.493	100.425	111.351	211.776
Total de amostras		165.352	186.920	352.272	172.428	171.199	343.627

5.2 Classificadores treinados com características de cor

Classificadores treinados com características de cor foram criados a fim de prover um comparativo entre os classificadores treinados com essas características e os classificadores

treinados com textura.

Para a extração das características as imagens, que estavam no espaço RGB, foram primeiramente convertidas para o espaço HSI - Matiz, Saturação e Intensidade, onde as cores são representadas de forma mais conveniente no canal H (GONZALEZ; WOODS, 2008).

Para cada uma das amostras, foi então computado o histograma da matiz, o qual foi agrupado em 30 subdivisões (*bins*). O histograma resultante dessa operação é um vetor $X = [b_1, b_2, \dots, b_{30}]$, onde b_n contém a quantidade de pixels na matiz da imagem com o valor n , após a operação de agrupamento (BRADSKI; KAEHLER, 2008).

Os histogramas gerados foram então utilizados como vetores de características para o treinamento/teste dos indutores utilizados nos testes.

5.3 Classificadores Treinados com amostras de um único estacionamento

Nesta seção são descritos os testes realizados com classificadores que possuem amostras de somente um estacionamento em seus conjuntos de treinamento. Os testes consistiram em, para cada um dos estacionamentos presentes na base de treinamento (seção 5.1), extrair as características LBP e LPQ das amostras e treinar um classificador para cada um dos conjuntos de características. O processo de criação dos classificadores é detalhado na figura 5.2.

Cada um dos classificadores treinados foi posto à prova com as bases de testes de todos os estacionamentos, ou seja, os classificadores foram testados com amostras de estacionamentos/ângulos que não contribuíram com imagens para seus treinamentos, possibilitando assim verificar suas capacidades de generalização.

Como grande parte das metodologias propostas por outros autores utiliza características baseadas na cor das imagens, as bases também foram postas à prova com um classificador treinado com características dessa natureza. Os resultados obtidos com esses classificadores podem ser encontrados nas tabelas comparativas de cada um dos testes desta subseção.

É importante salientar que os classificadores com características baseadas em cor não participaram de nenhum dos esquemas de combinação presentes nos resultados, já que o foco do trabalho é o de avaliar o desempenho das características texturais. A metodologia empregada para criação desses classificadores encontra-se no item 5.2.

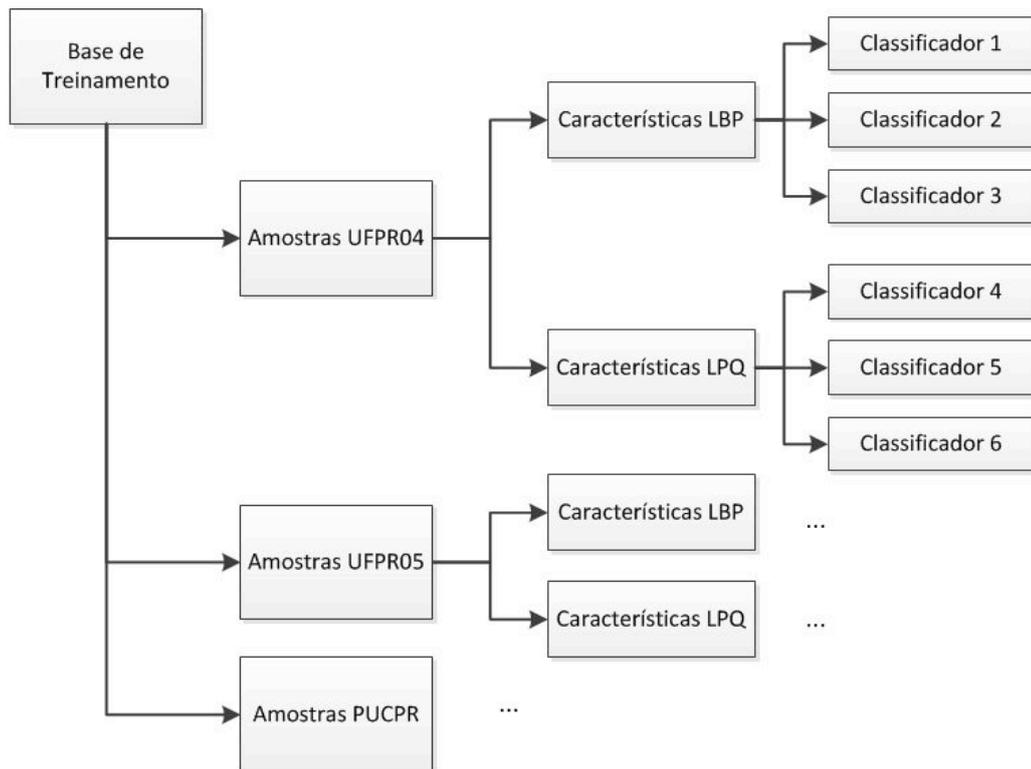


Figura 5.2: Esquema de treinamento de classificadores por estacionamento

Os resultados dos testes para os classificadores treinados com as amostras UFPR04, UFPR05 e PUCPR são detalhados nos itens 5.3.1, 5.3.2 e 5.3.3, respectivamente. No item 5.3.4 são discutidos os resultados obtidos com estes testes.

5.3.1 Classificadores treinados com amostras do estacionamento UFPR04

Nesta seção são apresentados os resultados obtidos com os classificadores treinados com amostras do estacionamento UFPR04. Na figura 5.3 é exibida a curva ROC obtida ao colocar os classificadores à prova utilizando as amostras de teste desse mesmo estacionamento, enquanto a tabela 5.2 exhibe as matrizes de confusão do classificador individual e do esquema de combinação com as maiores taxas de acertos obtidas neste teste.

Tabela 5.2: Melhor classificador e melhor esquema de combinação para os testes UFPR04/UFPR04

LPQ^u

	Ocupada	Vazia
Ocupada	21.491	80
Vazia	140	27.624
Acertos	99,55%	

Combinação pela Média

	Ocupada	Vazia
Ocupada	21.477	94
Vazia	84	27.680
Acertos	99,64%	

Como se pode observar, o classificador LPQ^{gd} obteve a maior AUC, atingindo o valor

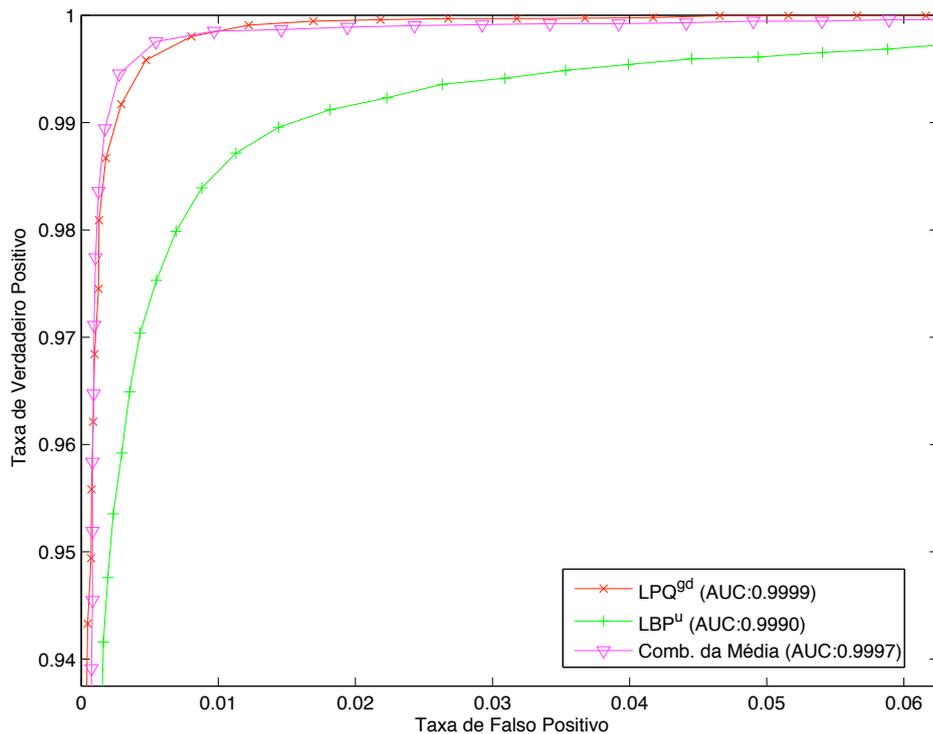


Figura 5.3: Curvas ROC dos testes UFPR04/UFPR04

de 0,9999. Já analisando-se as taxas de acertos, o melhor classificador encontrado foi o gerado pela combinação das médias das respostas de todos classificadores, com uma taxa de 99,64%. Na figura 5.4 encontram-se alguns exemplos de amostras classificadas incorretamente pelo classificador criado pela combinação da média das respostas.



Figura 5.4: Exemplos de imagens classificadas incorretamente para o teste UFPR04/UFPR04

Na figura 5.5 constam as curvas ROC dos testes realizados com as amostras da base UFPR05. Como as imagens da base UFPR04 e UFPR05 foram capturadas no mesmo estacionamento, porém em ângulos e dias diferentes, este teste tem por objetivo verificar a robustez dos modelos quanto às mudanças de ângulo de câmera. Na tabela 5.3 encontram-se as matrizes de confusão do classificador individual e do esquema de combinação que obtiveram os melhores resultados para este teste.

Os resultados deste teste mostram que a mudança no ângulo de captura das imagens

gera um grande impacto no desempenho dos classificadores, e que esse impacto pode ser atenuado utilizando-se as estratégias de combinação de classificadores propostas.

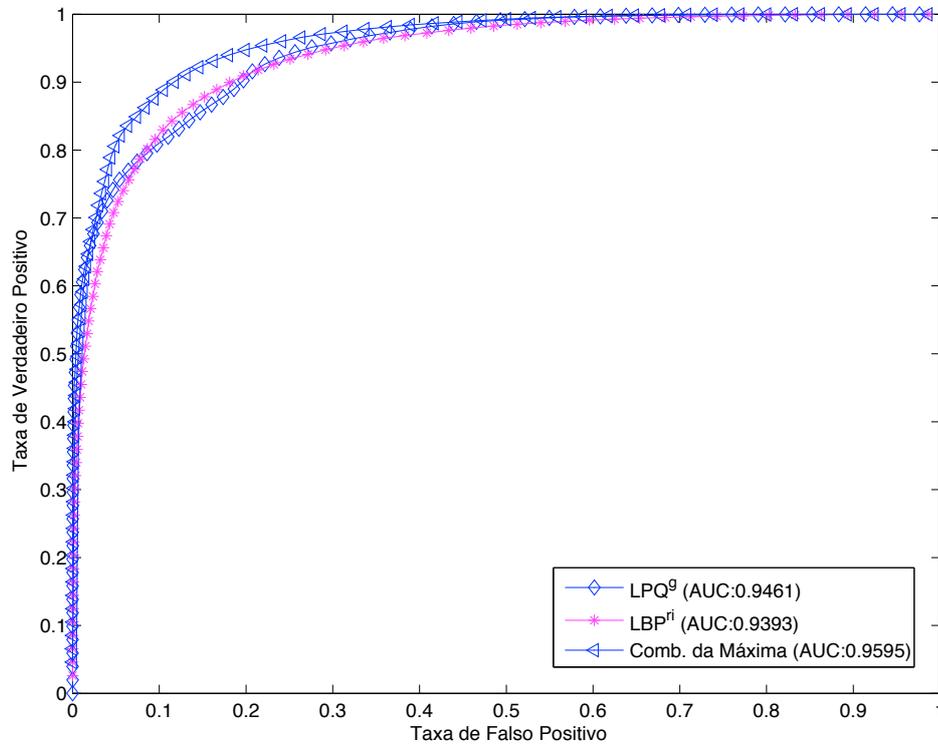


Figura 5.5: Curvas ROC dos testes UFPR04/UFPR05

Tabela 5.3: Melhor classificador e melhor esquema de combinação para os testes UFPR04/UFPR05

LPQ^g	Ocupada	Vazia	Combinação Max	Ocupada	Vazia
	Ocupada	41.919		8.513	Ocupada
Vazia	3.928	28.156	Vazia	2.273	29.811
Acertos	84,92%		Acertos	88,33%	

Para testar a performance dos classificadores em um ambiente totalmente novo, o qual não contribuiu com amostras de treinamento, os classificadores foram postos à prova com as amostras da base de testes do estacionamento PUCPR. As curvas ROC referentes a este teste podem ser observadas na figura 5.6.

As matrizes de confusão do classificador individual e do esquema de combinação que obtiveram as maiores taxas de acertos durante os testes no estacionamento PUCPR podem ser observadas na tabela 5.4.

Os resultados obtidos nos testes com as imagens do estacionamento PUCPR mostram que ocorre uma queda significativa nas taxas de acertos e nas AUCs dos classificadores quando

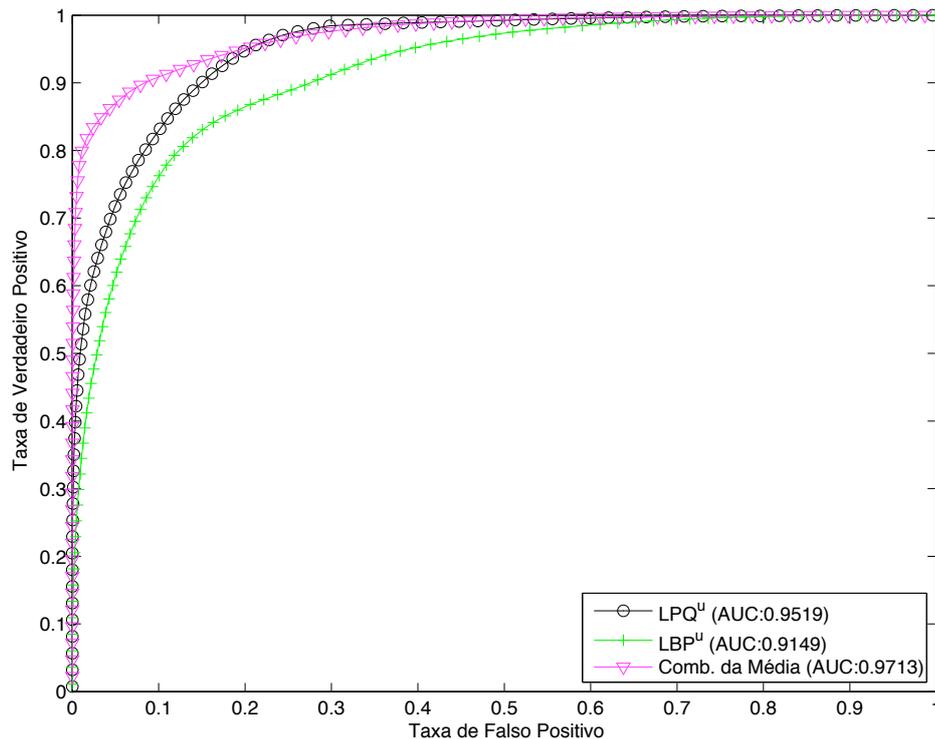


Figura 5.6: Curvas ROC dos testes UFPR04/PUCPR

Tabela 5.4: Melhor classificador e melhor esquema de combinação para os testes UFPR04/PUCPR

LPQ ^g	Ocupada	Vazia	Combinação Max	Ocupada	Vazia
	Ocupada	72.898		27.527	Ocupada
Vazia	5.819	105.532	Vazia	5.204	10.6147
Acertos	84,25%		Acertos	88,40%	

estes são postos à prova com amostras de uma área que não contribuiu em seus treinamentos, apesar dos classificadores ainda apresentarem bons desempenhos. Os resultados também mostram que essa queda de desempenho é muito semelhante à que ocorre quando o ângulo de captura das imagens é modificado.

Na tabela 5.5 encontra-se um resumo dos resultados obtidos com os testes dos classificadores treinados com as amostras do estacionamento UFPR04. Na tabela também encontram-se os resultados de um classificador treinado com características de cor que, quando comparado com os classificadores individuais, apresenta uma melhor capacidade de generalização. No entanto, o classificador treinado com características de cor obteve resultados inferiores à grande parte dos de textura quando o teste é realizado no mesmo estacionamento de treinamento.

Tabela 5.5: Resultados obtidos nas bases de teste utilizando os classificadores treinados com amostras do estacionamento UFPR04

	UFPR04			UFPR05			PUCPR		
	AUC	FPR	FNR	AUC	FPR	FNR	AUC	FPR	FNR
LPQ ^g	0,9997	0,0062	0,0060	0,9461	0,1688	0,1224	0,9423	0,2741	0,0523
LPQ ^{gd}	0,9999	0,0040	0,0048	0,9368	0,2094	0,1031	0,9498	0,5468	0,0050
LPQ ^u	0,9998	0,0037	0,0050	0,9393	0,2090	0,1004	0,9519	0,5198	0,0077
LBP ^u	0,9990	0,0164	0,0086	0,9329	0,1701	0,1368	0,9149	0,1345	0,2015
LBP ^{ri}	0,9685	0,1242	0,0707	0,9393	0,2662	0,0549	0,8953	0,3630	0,1144
LBP ^{riu2}	0,9380	0,1834	0,0915	0,8954	0,2972	0,0721	0,8324	0,3315	0,1097
Comb. Média	0,9997	0,0044	0,0030	0,9582	0,1765	0,0625	0,9713	0,2630	0,0052
Comb. Max	0,9994	0,0050	0,0040	0,9595	0,1458	0,0708	0,9522	0,1928	0,0467
Cor	0,9960	0,0338	0,0206	0,9508	0,2458	0,0321	0,9740	0,1102	0,0319

5.3.2 Classificadores treinados com amostras do estacionamento UFPR05

Os resultados obtidos com o classificadores treinados com as amostras do estacionamento UFPR05 são descritos neste item. Na Figura 5.7 encontra-se a curva ROC do teste realizado com as amostras de testes desse mesmo estacionamento. As matrizes de confusão do melhor classificador individual e do melhor esquema de combinação deste mesmo teste podem ser visualizadas na Tabela 5.6.

Tabela 5.6: Melhor classificador e melhor esquema de combinação para os testes UFPR05/UFPR05

LPQ ^u	Ocupada		Vazia		Combinação pela Média	Ocupada		Vazia	
Ocupada	49.847		585		Ocupada	50.041		391	
Vazia		320		31.764	Vazia		188		31.896
Acertos	98,90%				Acertos	99,30%			

Os resultados mostram AUCs muito próximas a 1, indicando um alto poder discriminativo dos classificadores para este teste. As matrizes de confusão também exibem baixos índices de erros, sendo que somente 0,70% das amostras foram classificadas incorretamente quando foi utilizado o método de combinação de classificadores pela média. A figura 5.8 exibe alguns exemplos de amostras classificadas incorretamente utilizando este método.

A curva ROC dos testes realizados no estacionamento UFPR04, que possui imagens do mesmo estacionamento coletadas de um ângulo diferentes, podem ser visualizada na Figura 5.9. As matrizes de confusão do classificador individual e do esquema de confusão que atingiram as maiores taxas de acertos encontram-se na Tabela 5.7.

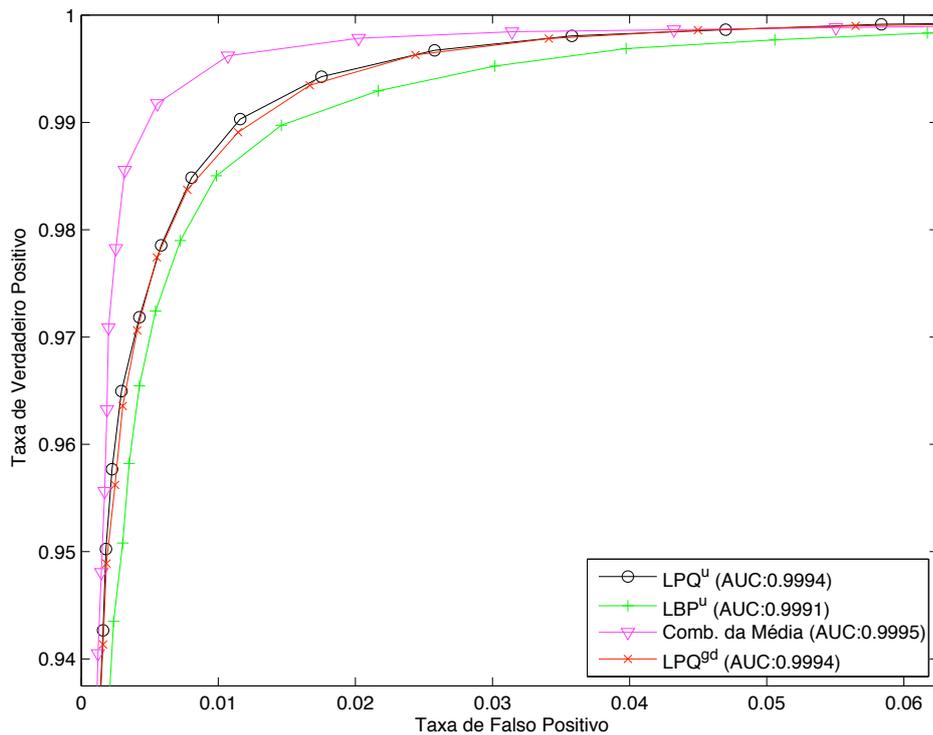


Figura 5.7: Curvas ROC dos testes UFPR05/UFPR05



Figura 5.8: Exemplos de imagens classificadas incorretamente para o teste UFPR05/UFPR05

A análise do resultados deste teste mostra que mesmo com a mudança de ângulo, os classificadores conseguem tomar decisões com um índice de acertos razoavelmente alto. Porém esses índices são muito inferiores quando comparados aos alcançados com o teste realizado utilizando imagens do mesmo estacionamento de treinamento, mostrando que essa mudança no ângulo resultou em um grande impacto nas taxas de acertos dos classificadores.

Neste teste a combinação pela média se mostrou o método com a melhor AUC dentre os modelos testados, porém ao se considerar a taxa de acertos como métrica de comparação dos classificados, este método é superado pelo classificador individual treinado com as características LPQ^u .

Da mesma forma que para os testes realizados com o estacionamento UFPR04, os classificadores treinados foram postos à prova com as amostras do estacionamento PUCPR, que possui amostras coletadas de uma área e ângulo que não participaram do treinamento dos

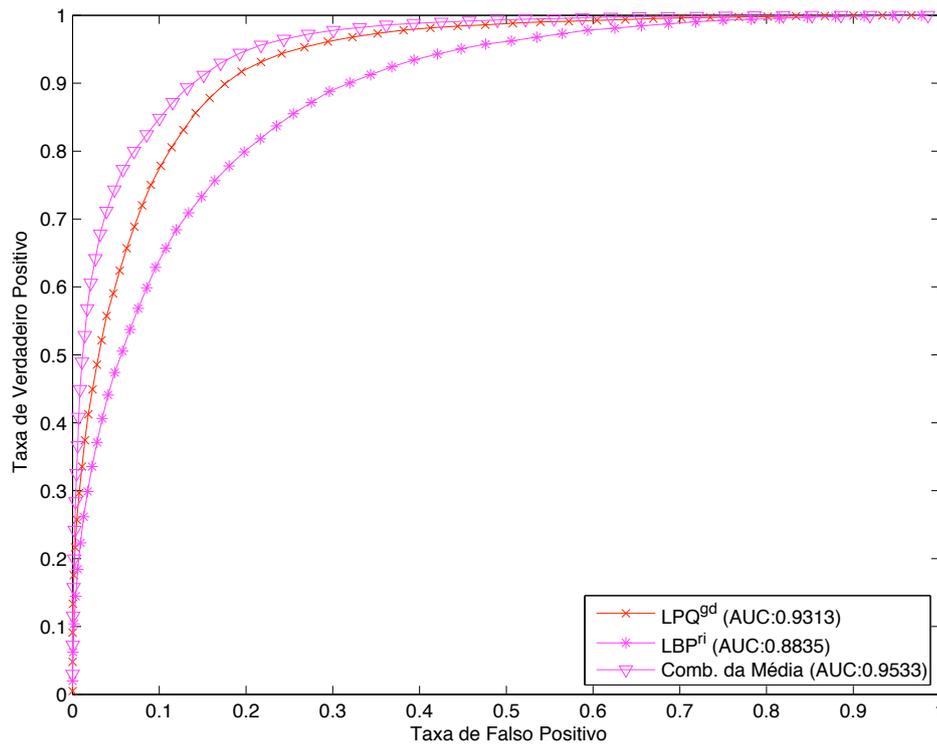


Figura 5.9: Curvas ROC dos testes UFPR05/UFPR04

Tabela 5.7: Melhor classificador e melhor esquema de combinação para os testes UFPR05/UFPR04

LPQ^{gd}	Ocupada	Vazia	Combinação pela Média	Ocupada	Vazia
	Ocupada	19.251		2.320	Ocupada
Vazia	4.703	23.061	Vazia	6.255	21.509
Acertos	85,76%		Acertos	85,53%	

classificadores.

A curva ROC resultante deste teste pode ser visualizada na figura 5.10, enquanto as matrizes de confusão dos dois classificadores com as maiores taxas de acertos encontram-se na Tabela 5.8.

O resumo dos resultados obtidos com os testes dos classificadores treinados com as amostras do estacionamento UFPR05 são sumarizados na Tabela 5.9. No resumo pode-se observar que, quando comparadas as AUCs, os classificadores de cor foram superiores somente ao classificador LBP^{riu2} no teste UFPR05/PUCPR, e aos classificadores LBP invariantes à rotação no teste UFPR05/UFPR05. Já no teste UFPR05/UFPR04 os classificadores de cor se mostraram superiores à todos os demais.

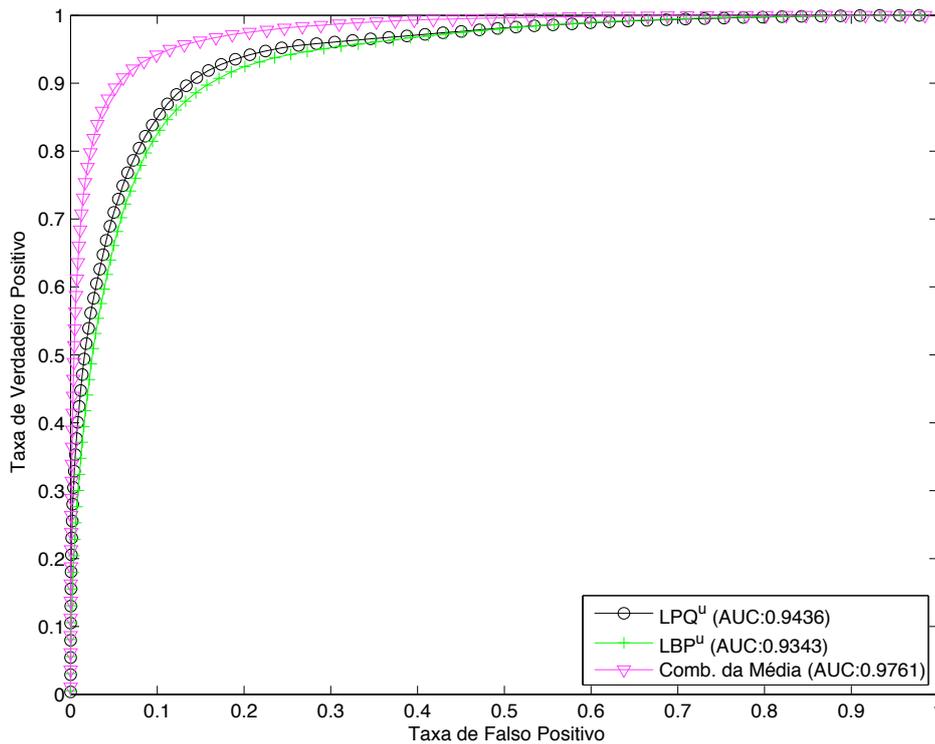


Figura 5.10: Curvas ROC dos testes UFPR05/PUCPR

Tabela 5.8: Melhor classificador e melhor esquema de combinação para os testes UFPR05/PUCPR

LPQ^u	Ocupada	Vazia	Combinação pela Média	Ocupada	Vazia
	Ocupada	92.365		8.060	Ocupada
Vazia	17.912	93.439	Vazia	18.133	93.218
Acertos	87,74%		Acertos	89,83%	

5.3.3 Classificadores treinados com amostras do estacionamento PUCPR

Nesta seção são descritos os testes realizados com classificadores treinados com imagens de uma segunda área de estacionamentos, denominada PUCPR. O primeiro teste consistiu colocar os classificadores à prova utilizando as amostras de teste desse mesmo estacionamento. As curvas ROC obtidas com este teste encontram-se na Figura 5.11, enquanto as matrizes de confusão do melhor classificador individual e do melhor esquema de combinação podem ser visualizadas na Tabela 5.10.

Os resultados mostram que, apesar das amostras do estacionamento PUCPR ocuparem uma quantidade muito menor de pixels nas imagens quando comparadas às dos outros dois estacionamentos testados, além de possuírem dois tipos de terreno, os classificadores obtiveram AUCs muito próximas a 1. Uma análise nas matrizes de confusão também mostra

Tabela 5.9: Resultados obtidos nas bases de teste utilizando os classificadores treinados com amostras do estacionamento UFPR05

	UFPR04			UFPR05			PUCPR		
	AUC	FPR	FNR	AUC	FPR	FNR	AUC	FPR	FNR
LPQ ^g	0,9091	0,0848	0,2475	0,9992	0,0140	0,0115	0,9310	0,0637	0,2416
LPQ ^{gd}	0,9313	0,1076	0,1694	0,9994	0,0120	0,0106	0,9384	0,1032	0,1495
LPQ ^u	0,9307	0,1128	0,1669	0,9994	0,0116	0,0100	0,9436	0,0803	0,1609
LBP ^u	0,8689	0,1763	0,2458	0,9991	0,0164	0,0090	0,9343	0,0441	0,3212
LBP ^{ri}	0,8835	0,0617	0,4052	0,9801	0,0707	0,0705	0,9082	0,0920	0,2366
LBP ^{riu2}	0,8047	0,0638	0,4600	0,9546	0,1004	0,0944	0,8842	0,1089	0,2190
Comb. Média	0,9533	0,0411	0,2253	0,9995	0,0078	0,0059	0,9761	0,0340	0,1628
Comb. Max	0,9298	0,0449	0,2920	0,9991	0,0083	0,0061	0,9520	0,0339	0,1826
Cor	0,9793	0,1015	0,0395	0,9921	0,0421	0,0364	0,9093	0,1087	0,1792

Tabela 5.10: Melhor classificador e melhor esquema de combinação para os testes PUCPR/-PUCPR

LPQ ^u	Ocupada		Vazia		Acertos	%
Ocupada	99.911	514			99,58%	
Vazia	374	110.977				
Combinação pela Média						
	Ocupada		Vazia		Acertos	%
Ocupada	99.944	481			99,61%	
Vazia	351	111.000				

taxas de erros baixas, sendo que utilizando-se a combinação pela média, somente 0,39% das amostras foram classificadas incorretamente. Alguns exemplos dessas amostras podem ser visualizados na Figura 5.12.

Além dos testes com as imagens do estacionamento PUCPR, os classificadores foram postos à prova com as amostras de teste coletadas com ambos os ângulos de captura do estacionamento UFPR, que não contribuiu com nenhuma amostra para seus treinamentos.

A Figura 5.13 e a Tabela 5.11 exibem, respectivamente, a curva ROC e as matrizes de confusão com as maiores taxas de acertos referentes ao teste com as amostras UFPR04.

Tabela 5.11: Melhor classificador e melhor esquema de combinação para os testes PUCPR/UFPR04

LPQ ^g	Ocupada		Vazia		Acertos	%
Ocupada	20.310	1.261			87,15%	
Vazia	5.077	22.687				
Combinação pela Média						
	Ocupada		Vazia		Acertos	%
Ocupada	20.650	921			88,88%	
Vazia	4.563	23.201				

As curvas ROC e as matrizes de confusão referentes ao teste com as amostras do estacionamento UFPR05 encontram-se na Figura 5.14 e na Tabela 5.12, respectivamente.

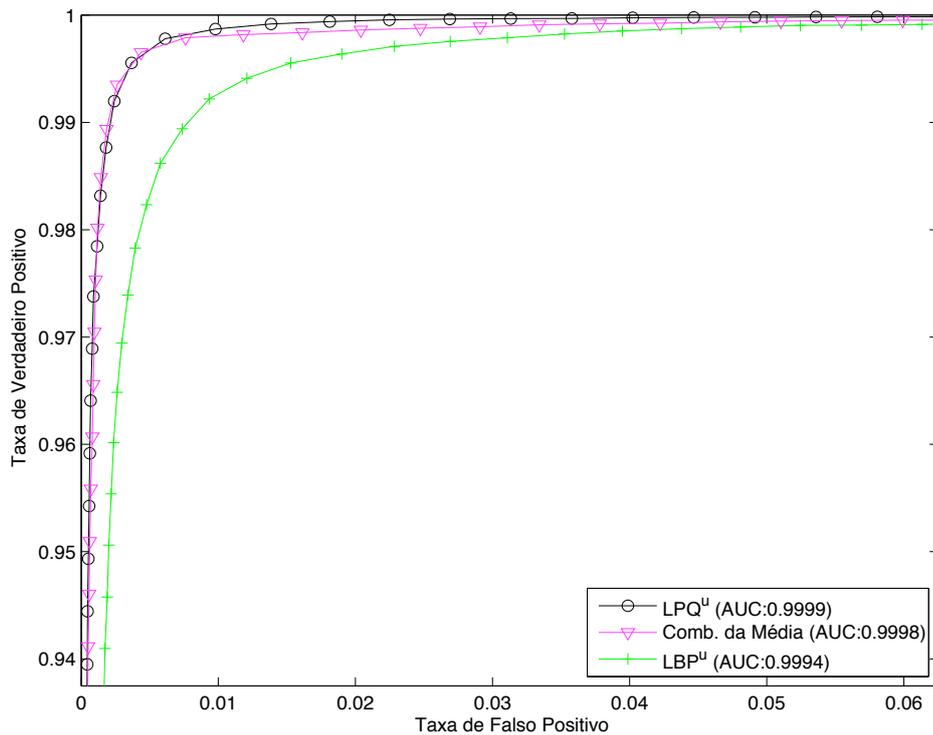


Figura 5.11: Curvas ROC dos testes PUCPR/PUCPR



Figura 5.12: Exemplos de imagens classificadas incorretamente para o teste PUCPR/PUCPR

Os testes nos estacionamentos UFPR reforçam os resultados obtidos nos itens anteriores, mostrando uma queda nos índices de acertos e nas AUCs dos classificadores quando estes são postos à prova em áreas que não contribuíram com amostras de treinamento. Apesar disso, os classificadores continuam a rotular corretamente mais de 80% das amostras, chegando à 88,88% de acertos para o teste com a base UFPR04 utilizando-se a combinação dos classificadores pela média.

Os testes em outra área de estacionamentos também mostram que o classificador treinado com as características LPQ^u , que obteve os melhores resultados quando posto à prova com as imagens da base PUCPR, degenerou sua taxa de acertos e AUC quando testado com imagens de estacionamentos diferentes.

Os resultados obtidos durante os testes com os classificadores treinados com o estacionamento PUCPR são resumidos na Tabela 5.13. O comparativo mostra que, quando comparadas as AUCs, os classificadores baseados em cor foram superiores somente aos classi-

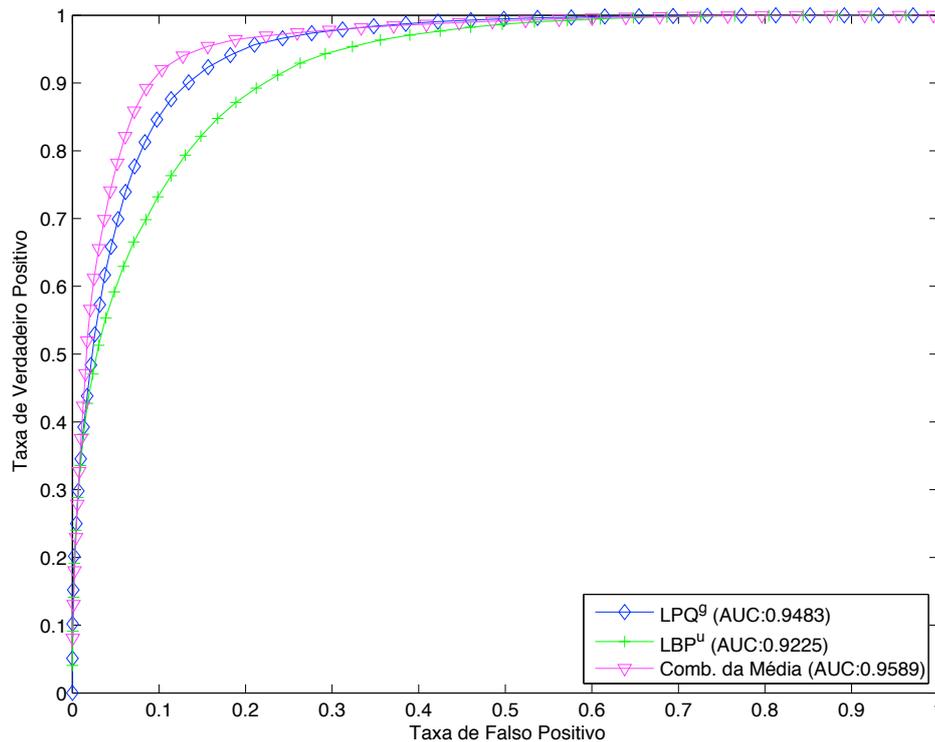


Figura 5.13: Curvas ROC dos testes PUCPR/UFPR04

Tabela 5.12: Melhor classificador e melhor esquema de combinação para os testes PUCPR/UFPR05

LBI ^{ri}	Ocupada		Vazia	
	Ocupada	42.088	8.344	
Vazia	5.862	26.222		
Acertos	82,78%			

	Combinação pela Média	
	Ocupada	Vazia
Ocupada	42.496	7.936
Vazia	5.102	26.982
Acertos	84,20%	

ficadores LBP invariantes à rotação no teste PUCPR/PUCPR e ao classificador LPQ^u no teste PUCPR/UFPR04. Todos os demais classificadores obtiveram resultados superiores aos de cor nestes testes.

5.3.4 Discussão dos resultados obtidos com os classificadores treinados com amostras de um estacionamento

Os testes com classificadores treinados com amostras de uma única área de estacionamento mostraram que as características do tipo LPQ geram melhores resultados quando comparadas às características LBP para a tarefa da classificação de vagas de estacionamento. Dentre os testes realizados somente para o teste PUCPR/UFPR05 um classificador treinado com características do tipo LBP obteve a maior taxa de acertos quando considerandos somente

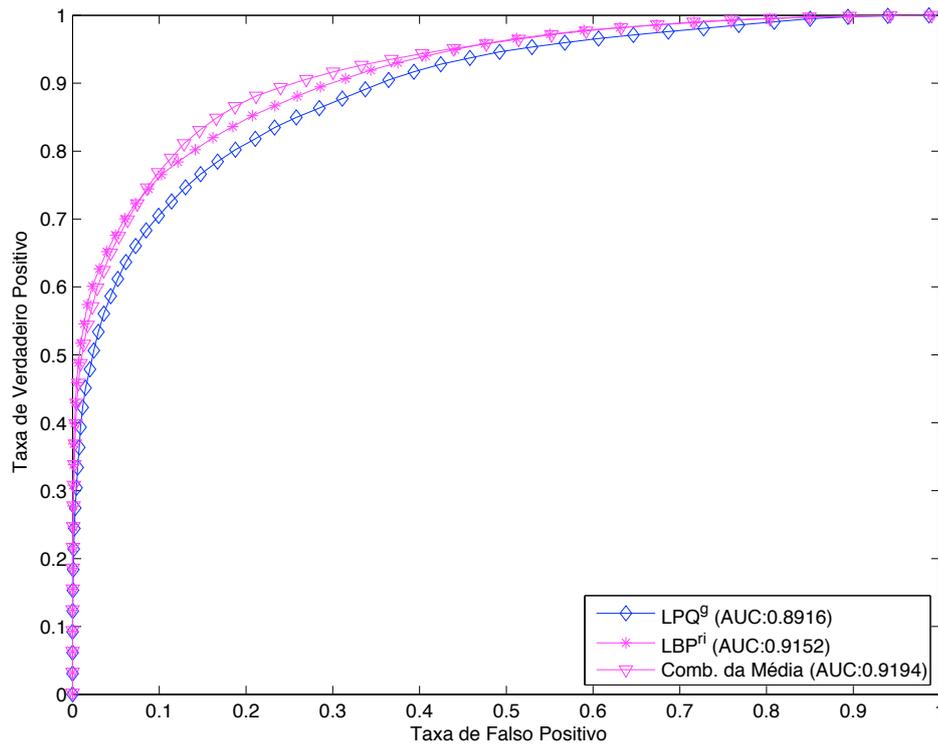


Figura 5.14: Curvas ROC dos testes PUCPR/UFPR05

os classificadores individuais.

Testes com um pátio de estacionamento para o qual foram capturadas imagens com diferentes tipos de terreno (base PUCPR) também foram realizados e mostraram que, desde que os classificadores sejam treinados com ambos os terrenos, não há efeitos negativos perceptíveis em suas taxas de acertos.

Quando postos à prova com amostras de estacionamentos/ângulos que não contribuíram para seus treinamentos, os classificadores ainda apresentaram bons desempenhos, apesar de haver uma queda significativa nas taxas de acertos e AUCs, quando esses testes são comparados aos realizados com o mesmo estacionamento e ângulo utilizados no treinamento.

Foi constatado também é possível que um classificador torne-se tendencioso quando colocado à prova com imagens de estacionamentos/ângulos que não participaram de seus treinamentos. Um exemplo desse fenômeno pode ser observado no classificador LPQ^u, que apresentou bons resultados para o teste PUCPR/PUCPR, mas obteve um desempenho ruim para os testes PUCPR/UFPR04 e PUCPR/UFPR05, apresentando altas taxas de falso positivo.

Os testes também mostram que o impacto no desempenhos dos classificadores quando ocorre uma mudança no ângulo de captura das imagens é equiparável ao da mudança de área de estacionamentos.

Tabela 5.13: Resultados obtidos nas bases de teste utilizando os classificadores treinados com amostras do estacionamento PUCPR

	UFPR04			UFPR05			PUCPR		
	AUC	FPR	FNR	AUC	FPR	FNR	AUC	FPR	FNR
LPQ ^g	0,9483	0,0585	0,1829	0,8916	0,1335	0,2904	0,9998	0,0068	0,0043
LPQ ^{gd}	0,9479	0,0502	0,2545	0,8792	0,1313	0,3072	0,9998	0,0052	0,0034
LPQ ^u	0,7777	0,9090	0,0006	0,7675	0,9243	0,0006	0,9999	0,0051	0,0034
LBP ^u	0,9225	0,1131	0,2055	0,8697	0,1611	0,2890	0,9994	0,0127	0,0063
LBP ^{ri}	0,9006	0,0563	0,3879	0,9152	0,1655	0,1827	0,9912	0,0559	0,0377
LBP ^{riu2}	0,8577	0,0804	0,3410	0,891	0,2009	0,1435	0,9794	0,0726	0,0415
Comb. Média	0,9589	0,0427	0,1643	0,9194	0,1574	0,1590	0,9998	0,0048	0,0032
Comb. Max	0,8826	0,0537	0,2065	0,8363	0,2186	0,1114	0,9997	0,0053	0,0037
Cor	0,8169	0,4195	0,0535	0,7605	0,4565	0,1436	0,9965	0,0205	0,0183

Quando comparados com o classificador treinado com características de cor, os classificadores LPQ e o classificador LBP^u obtiveram resultados levemente superiores em todos os testes em que as amostras de teste pertenciam ao mesmo estacionamento de treinamento. Já para os testes com mudança de ângulo/estacionamento, os classificadores de cor variaram seus resultados entre uma maior robustez que os classificadores de textura, como nos testes com os classificadores treinados com amostras UFPR04, e quedas significativas em seus desempenhos, como nos testes com os classificadores PUCPR. Esse resultado pode indicar que mudanças na área de estacionamento em testes pode resultar em alterações nas cores que definem as imagens ocupadas e vazias, prejudicando os classificadores de cor.

A análise das amostras classificadas incorretamente pelos classificadores de textura mostra que os erros mais comuns dos classificadores ocorrem quando há a presença de sombras ou objetos projetando padrões de textura complexos nas imagens. Vagas parcialmente ocluídas por veículos adjacentes também possuem uma maior probabilidade de serem classificadas de maneira incorreta.

Nos testes realizados, as técnicas de combinação de classificadores geraram modelos com taxas de acertos superiores ou próximas ao melhor classificador individual. Esse resultado mostra que as técnicas de combinação podem melhorar os resultados ou então diminuir a probabilidade de se escolher um modelo ineficaz para classificar as amostras das vagas (DIETTERICH, 2000; POLIKAR, 2006).

As técnicas de combinação também se mostraram importantes ferramentas para atenuar os efeitos das mudanças de ângulo de captura ou área de estacionamento nas taxas de acertos dos classificadores individuais, criando modelos significativamente mais robustos.

5.4 Classificadores Treinados com amostras de múltiplos estacionamentos

A fim de verificar o desempenho dos classificadores treinados com múltiplos estacionamentos, foram realizados testes que consistiram em treinar os classificadores amostras das três áreas de estacionamentos presentes na base PKLot.

As bases de treinamento e teste utilizadas foram as mesmas definidas para os testes com os classificadores treinados com somente uma área de estacionamentos (seção 5.3). A metodologia empregada para a separação das bases é descrita na seção 5.1.

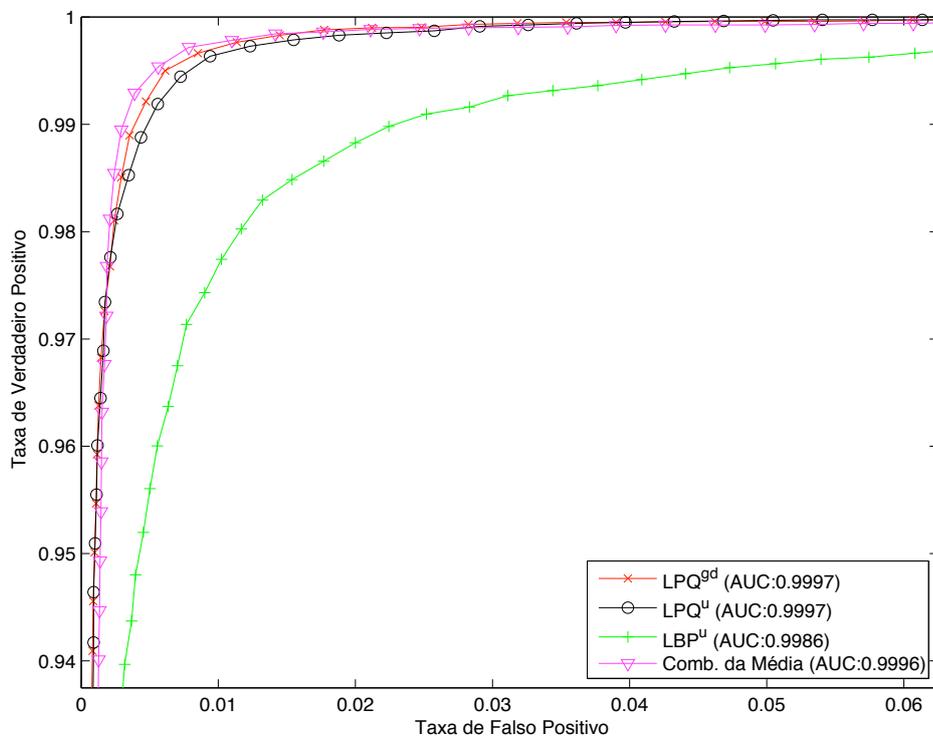


Figura 5.15: Curvas ROC dos testes TODOS/UFPR04

Antes de sua utilização, a base de treinamento necessitou passar por um processo de normalização, o qual teve como objetivo igualar as quantidades de amostras de treinamento entre as três áreas de estacionamentos. Para isso, foram descartadas imagens aleatoriamente dos estacionamentos UFPR05 e PUCPR, até que as bases de treinamentos desses estacionamentos ficassem com o mesmo tamanho da base UFPR04, que possui a menor quantidade de imagens capturadas.

As bases de testes não sofreram alterações. As figuras e tabelas referentes à esse experimento seguem a nomenclatura *TODOS/base_testes*, indicando que os classificadores

foram treinados com imagens de todos estacionamentos.

Na Figura 5.15 encontram-se as curvas ROC referentes ao experimento realizado com a base de testes do estacionamento UFPR04.

A Tabela 5.14 exibe um comparativo entre os resultados obtidos com os classificadores treinados com o estacionamento UFPR04 e os treinados com todos estacionamentos, quando postos à prova com amostras de testes do estacionamento UFPR04.

O comparativo mostra que os classificadores treinados com todos os estacionamentos, mesmo não sendo especializados no estacionamento em teste, obtiveram resultados muito próximos aos classificadores especialistas.

Tabela 5.14: Comparativo dos resultados na base de testes do estacionamento UFPR04

	UFPR04/UFPR04			TODOS/UFPR04		
	AUC	FPR	FNR	AUC	FPR	FNR
LPQ ^g	0,9997	0,0062	0,0060	0,9995	0,0088	0,0087
LPQ ^{gd}	0,9999	0,0040	0,0048	0,9997	0,0045	0,0069
LPQ ^u	0,9998	0,0037	0,0050	0,9997	0,0051	0,0075
LBP ^u	0,9990	0,0164	0,0086	0,9986	0,0167	0,0138
LBP ^{ri}	0,9685	0,1242	0,0707	0,9596	0,0945	0,1175
LBP ^{riu2}	0,9380	0,1834	0,0915	0,9525	0,1094	0,1761
Comb. Média	0,9997	0,0044	0,0030	0,9996	0,0046	0,0057
Comb. Max	0,9994	0,0050	0,0040	0,9993	0,0039	0,0062

As curvas ROC para o estacionamento UFPR05, que representa um novo ângulo de captura para o estacionamento UFPR04, encontram-se na Figura 5.16. A Tabela 5.15 exibe os demais resultados obtidos com este teste, bem como uma comparação com os classificadores treinados exclusivamente com o estacionamento UFPR05.

A análise da Tabela 5.15 mostra que, de maneira similar aos testes com o estacionamento UFPR04 (Tabela 5.14), os classificadores treinados com todos os estacionamentos obtém resultados muito próximos aos classificadores especialistas.

Finalmente, na Figura 5.17 são exibidas as curvas ROC referentes aos testes realizados com as amostras do estacionamento PUCPR. Os resultados deste teste e o comparativo com o teste realizado com os classificadores treinados somente com o estacionamento PUCPR encontram-se na Tabela 5.16.

Os resultados do teste com a base PUCPR mostraram que a maioria dos classificadores treinados com todos estacionamentos obtiveram desempenhos um pouco superiores aos

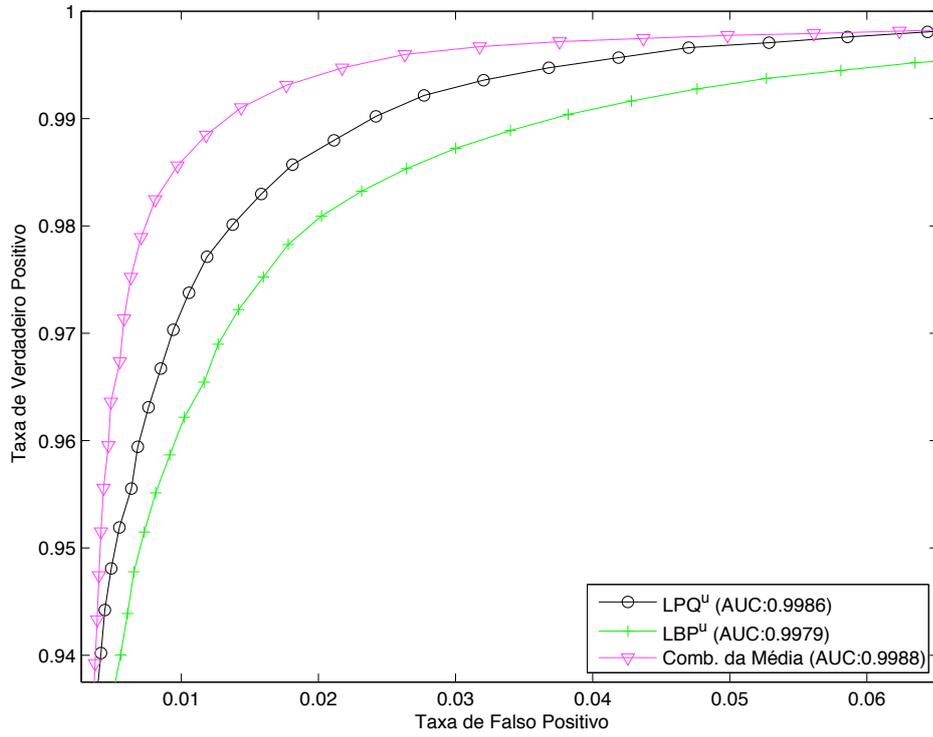


Figura 5.16: Curvas ROC dos testes TODOS/UFPR05

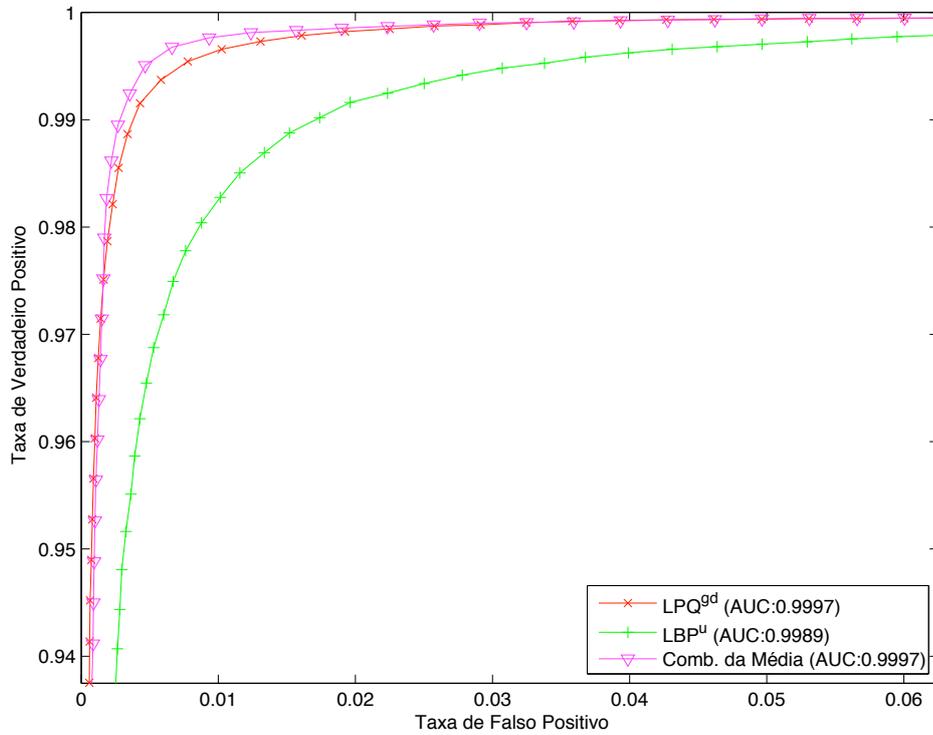


Figura 5.17: Curvas ROC dos testes TODOS/PUCPR

Tabela 5.15: Comparativo dos resultados na base de testes do estacionamento UFPR05

	UFPR05/UFPR05			TODOS/UFPR05		
	AUC	FPR	FNR	AUC	FPR	FNR
LPQ ^g	0,9992	0,0140	0,0115	0,9982	0,0152	0,0209
LPQ ^{gd}	0,9994	0,0120	0,0106	0,9984	0,0132	0,0208
LPQ ^u	0,9994	0,0116	0,0100	0,9986	0,0138	0,0189
LBP ^u	0,9991	0,0164	0,0090	0,9979	0,0200	0,0194
LBP ^{ri}	0,9801	0,0707	0,0705	0,9745	0,1030	0,0618
LBP ^{riu2}	0,9546	0,1004	0,0944	0,9467	0,1485	0,0780
Comb. Média	0,9995	0,0078	0,0059	0,9988	0,0116	0,0118
Comb. Max	0,9991	0,0083	0,0061	0,9980	0,0102	0,0125

treinados exclusivamente com o estacionamento PUCPR. Esse resultado difere dos obtidos com os estacionamentos UFPR04 e UFPR05, já que nesses testes os desempenhos dos classificadores treinados com todos estacionamentos ficaram próximos, porém abaixo dos classificadores especialistas.

Tabela 5.16: Comparativo dos resultados na base de testes do estacionamento PUCPR

	PUCPR/PUCPR			TODOS/PUCPR		
	AUC	FPR	FNR	AUC	FPR	FNR
LPQ ^g	0,9992	0,0140	0,0115	0,9994	0,0080	0,0097
LPQ ^{gd}	0,9994	0,0120	0,0106	0,9997	0,0058	0,0063
LPQ ^u	0,9994	0,0116	0,0100	0,9996	0,0072	0,0073
LBP ^u	0,9991	0,0164	0,0090	0,9989	0,0107	0,0159
LBP ^{ri}	0,9801	0,0707	0,0705	0,9755	0,0827	0,0577
LBP ^{riu2}	0,9546	0,1004	0,0944	0,9643	0,0942	0,0552
Comb. Média	0,9995	0,0078	0,0059	0,9997	0,0048	0,0048
Comb. Max	0,9991	0,0083	0,0061	0,9993	0,0046	0,0060

Os resultados obtidos nos testes realizados com os classificadores treinados com todos os estacionamentos mostram que, os indutores treinados com diferentes áreas de estacionamentos e características de textura possuem desempenhos muito próximos aos treinados exclusivamente com o estacionamento em teste. No entanto, é importante ressaltar que os conjuntos de treinamentos dos classificadores continham amostras de treinamento capturadas dos estacionamentos sendo postos à prova.

Para os estacionamentos UFPR04 e UFPR05 houve um pequeno decréscimo nas AUCs dos classificadores, porém ainda assim essas AUCs ficaram muito próximas à 1. Já para

o estacionamento PUCPR houve um ganho na capacidade discriminativa dos classificadores treinados com todos os estacionamentos, o qual pode ser observado em suas AUCs. Esse ganho no desempenho dos classificadores possivelmente está relacionado ao aumento da diversidade das amostras de treinamento.

5.5 Testes em Outras Bases

A fim de prover uma análise comparativa do método proposto com trabalhos de outros autores, o método foi posto à prova com as amostras da base utilizada no trabalho de Huang e Wang (2010). Vale salientar que essa foi a única base pública com uma quantidade razoável de amostras encontrada para realização de testes.

A base contém imagens coletadas em três dias distintos, sendo eles um dia ensolarado normal (figura 5.18a), um dia com alta incidência de luz solar (figura 5.18b) e um dia com luminosidade instável, variando entre luz solar forte e luminosidade normal. As coletas de imagens foram realizadas entre as 8:00 às 17:00 horas de cada dia, sendo que uma imagem foi coletada a cada 5 minutos.



(a) Imagem com luz solar normal

(b) Imagem com alta incidência de luz solar

Figura 5.18: Exemplos de imagens da base de Huang e Wang (2010)

Ao todo a base possui 322 imagens, as quais estão armazenadas no formato JPEG e possuem dimensões de 352x240 pixels. Todas as 46 vagas visíveis de cada uma das imagens foram segmentadas através do método descrito no item 4.3. O resultado da segmentação pode ser visualizado na tabela 5.17.

Esta base apresenta alguns desafios como a presença de imagens com regiões apresentando superexposição, como na imagem 5.18b, e a grande desproporção entre as quantidades de amostras de vagas ocupadas e vazias. Além disso, devido à perspectiva das imagens, algumas amostras de vagas são muito pequenas, sendo que as vagas presentes no canto superior

Tabela 5.17: Quantidades de amostras segmentadas na base de Huang e Wang (2010)

Amostras Segmentadas	
Ocupadas	13.834 (93,4 %)
Vazias	978 (6,6 %)
Total	14.812

esquerdo das imagens chegam a ocupar uma área de somente 17x17 pixels, o que pode causar muitas perdas de informações na etapa de extração de características dessas vagas.

Para a realização dos testes, 50% das amostras foram selecionadas para o treinamento dos classificadores, e os 50% restantes foram utilizados nos testes. Devido ao fato de que as amostras foram coletadas ao longo de somente três dias, o método descrito no item 5.1 não pode ser utilizado. Sendo assim, as imagens foram selecionadas de forma aleatória para participar da base de treinamento ou de testes.

Apesar dos classificadores potencialmente serem treinados com amostras dos três dias, já que as amostras são selecionadas aleatoriamente, os resultados dos testes foram separados por dia. Essa abordagem foi adotada para facilitar a comparação dos resultados, já que esse método foi adotado no trabalho de Huang e Wang (2010).

Para a realização dos testes não foram utilizados classificadores com características invariantes à rotação. Os métodos de combinação testados foram a combinação pela maior confiança e a combinação pela média das respostas dos classificadores.

A métrica selecionada para a avaliação dos resultados desse experimento é a curva ROC dos classificadores, pois existe uma grande desproporção entre as quantidades de amostras vazias e ocupadas na base.

As curvas ROC para os testes com as amostras do dia ensolarado normal, com muita incidência de luz solar e com luminosidade instável encontram-se nas figuras 5.19, 5.20 e 5.21, respectivamente.

Como se pode observar, as curvas AUCs de todos classificadores ficaram muito próximas a 1, sendo que para o dia com luminosidade variável as AUCs dos esquemas de combinação atingiram esse valor, indicando uma classificação perfeita.

O trabalho de Huang e Wang (2010) incluiu testes de métodos propostos por outros autores. As AUCs resultantes dos testes para os métodos desses autores, bem como os as AUCs obtidas pelo método proposto por Huang e Wang (2010) e pelos classificadores propostos neste trabalho encontram-se na tabela 5.18.

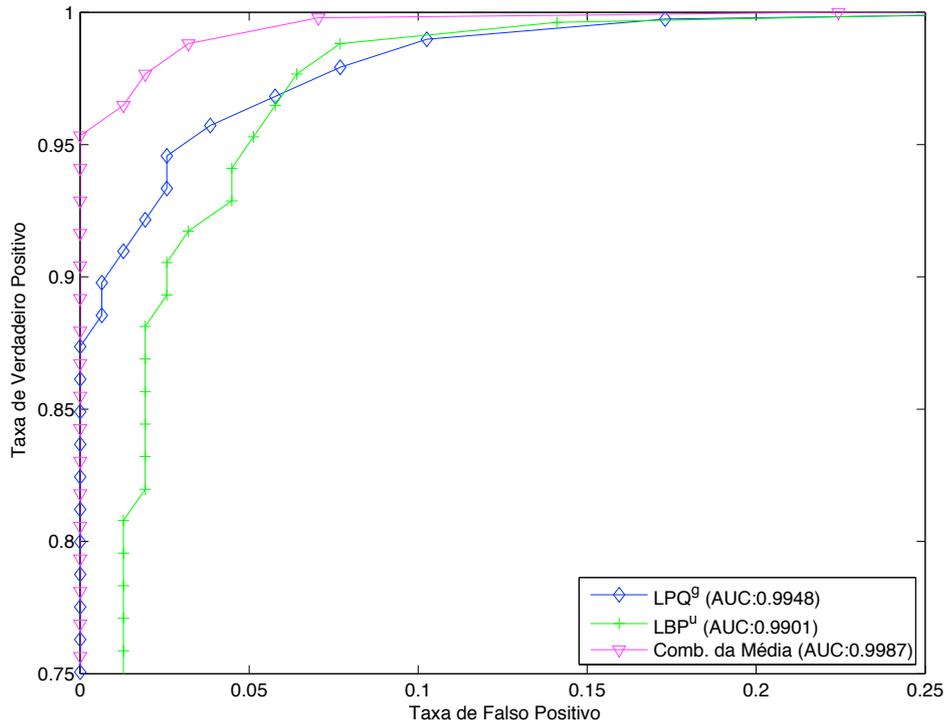


Figura 5.19: Curvas ROC para os testes na base de Huang e Wang (2010) com dia ensolarado normal

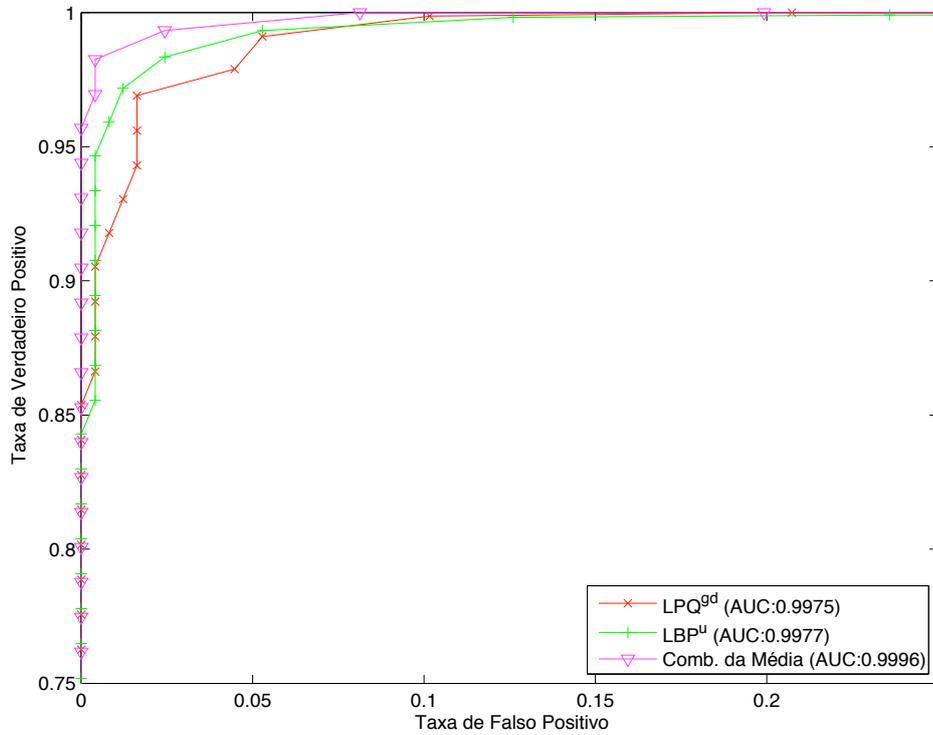


Figura 5.20: Curvas ROC para os testes na base de Huang e Wang (2010) com dia de muita incidência de luz solar

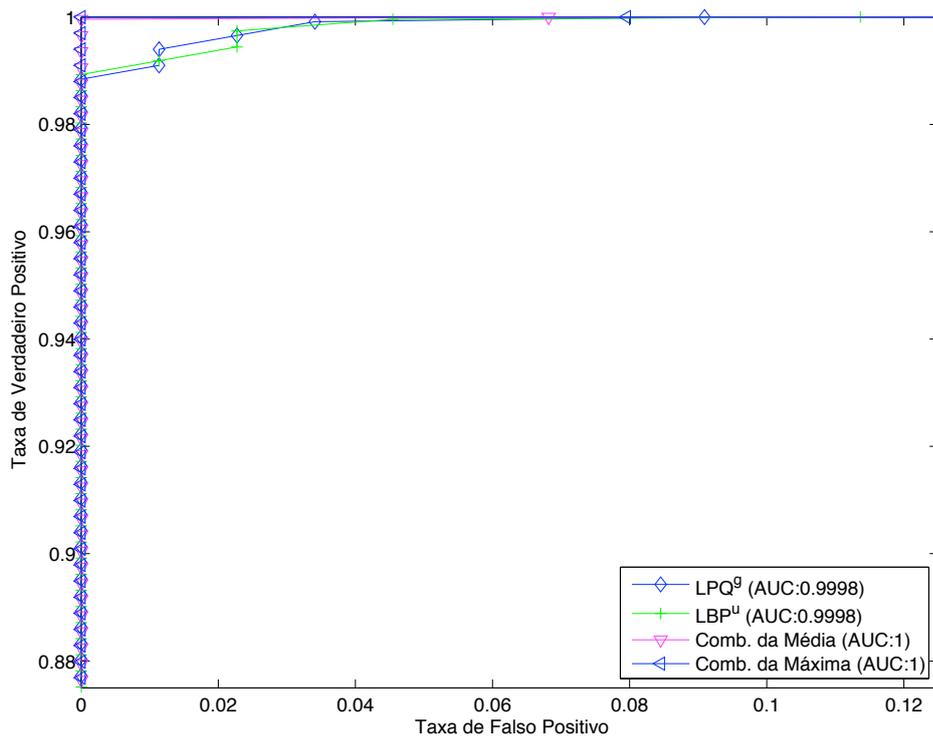


Figura 5.21: Curvas ROC para os testes na base de Huang e Wang (2010) com dia com luminosidade variável

Na tabela 5.18 é possível observar que os classificadores baseados em textura propostos neste trabalho obtiveram AUCs superiores as dos métodos propostos pelos demais autores. Pode-se observar também que os esquemas de combinação do classificadores de textura melhoraram os resultados, e que a combinação pela média dos classificadores obteve a melhor AUC para os três conjuntos de testes, sendo que para o conjunto de testes com luminosidade variável esse esquema obteve uma AUC perfeita, juntamente com o a combinação pela máxima.

É importante frisar que as AUCs presentes na tabela 5.18 para os métodos propostos neste trabalho foram calculadas utilizando-se 50% da base, pois os outros 50% foram utilizados no treinamento dos classificadores. Já os métodos propostos pelos demais autores, os quais foram testados por Huang e Wang (2010), foram testados utilizando-se 100% da base, pois esses métodos foram treinados com outras 5.000 amostras de estacionamento, as quais não puderam ser encontradas para download.

Tabela 5.18: Resultados na base de Huang e Wang (2010)

Método	AUC - Dia ensolarado normal	AUC - Dia com muita incidência de luz	AUC - Dia com luminosidade variável
Huang e Wang (2010)	0,9749	0,9626	0,9802
Huang et al. (2008)	0,9420	0,8972	0,9651
Wu et al. (2007)	0,7935	0,8342	0,6122
Dan (2003)	0,8135	0,8470	0,6294
LPQ ^g	0,9948	0,9955	0,9998
LPQ ^{gd}	0,9944	0,9975	0,9996
LPQ ^u	0,9933	0,9962	0,9997
LBP ^u	0,9901	0,9977	0,9998
Comb. da Média (LPQ, LBP)	0,9987	0,9996	1
Comb. da Máxima (LPQ, LBP)	0,9984	0,9992	1

6 Conclusão

Neste trabalho foi apresentada uma metodologia para classificação de vagas de estacionamentos abertos utilizando características de textura, extraídas de imagens coletadas de câmeras fixas. As características de textura utilizadas no trabalho são do tipo LBP e LPQ, as quais foram utilizadas para treinar indutores do tipo SVM com funções de kernel RBF.

Para execução dos experimentos foi criada uma base de imagens de estacionamentos, denominada PKLot, a qual atualmente contém cerca de 12.400 imagens capturadas de dois estacionamentos distintos e em diferentes condições climáticas e de iluminação, totalizando aproximadamente 1.300.000 amostras de vagas individuais. A base também conta com amostras capturadas a partir de dois ângulos distintos de câmera para um dos estacionamentos. A extensibilidade da base é garantida através de um protocolo de captura, o qual contém informações sobre como as imagens devem ser coletadas, e as definições de arquivos xml, que contém metadados a cerca de cada uma das imagens presentes na base.

Os experimentos mostram que, quando os estacionamentos em testes contribuem com amostras para o treinamento dos classificadores, as características de textura geram excelentes resultados, com AUCs muito próximas à 1. Os testes também mostram que, quando desconsiderados os classificadores com características invariantes à rotação, os classificadores treinados com textura apresentam resultados muito semelhantes, porém levemente superiores, aos treinados com características de cor.

Os classificadores também foram postos à prova com amostras coletadas de estacionamentos ou de ângulos diferentes das amostras utilizadas em seus treinamentos. Esses testes mostraram que os classificadores ainda são capazes de atingir boas taxas de acertos, geralmente acima dos 85 %, porém seus desempenhos são muito inferiores aos obtidos com os classificadores treinados e testados com o mesmo estacionamento e ângulo. Nestes mesmos testes os classificadores baseados em cor obtiveram variações em seus resultados, sendo algumas vezes superiores, e outras inferiores aos classificadores de textura, indicando que mudanças nas áreas de estacionamento podem causar flutuações nos desempenhos dos classificadores

treinados com características de cor.

Nos testes realizados, quase sempre as características LPQ obtiveram resultados superiores às características LBP, porém essa superioridade geralmente foi suportada por uma margem relativamente pequena quando são desconsiderados os classificadores LBP invariantes à rotação. Os testes com características LBP com invariância à rotação apresentaram resultados muito inferiores aos demais, mostrando que a rotação das texturas pode ser uma informação importante para o treinamento dos classificadores.

As técnicas de combinação geraram classificadores com desempenhos superiores que o melhor classificador individual na grande maioria dos testes. A combinação de classificadores se mostrou de fundamental importância, principalmente para atenuar as quedas de desempenho dos classificadores, quando os testes são realizados com amostras coletadas de ângulos ou estacionamentos diferentes das utilizadas em seus treinamentos.

Trabalhos futuros podem combinar classificadores treinados com características de outras naturezas com os classificadores de textura, para tentar amenizar ainda mais o efeito da mudança de ângulo ou estacionamento de testes no sistema de classificação. Futuramente pretende-se também implementar técnicas que reconheçam automaticamente a posição das vagas de estacionamentos em determinada imagem, já que atualmente a delimitação das vagas nas imagens é realizada de forma manual.

Referências

- ACHARYA, T.; RAY, A. *Image Processing: Principles and Applications*. [S.l.]: Wiley, 2005. ISBN 9780471745785.
- AHONEN, T.; HADID, A.; PIETIKAINEN, M. Face description with local binary patterns: Application to face recognition. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, v. 28, n. 12, p. 2037–2041, 2006. ISSN 0162-8828.
- ALMEIDA, P. et al. Parking space detection using textural descriptors. In: *Systems, Man and Cybernetics, 2013. ISIC. IEEE International Conference on*. [S.l.: s.n.], 2013. p. 67–74.
- BIN, Z. et al. A design of parking space detector based on video image. In: *Electronic Measurement Instruments, 2009. ICEMI '09. 9th International Conference on*. [S.l.: s.n.], 2009. p. 2–253–2–256.
- BONG, D. B. L.; TING, K. C.; LAI, K. C. Integrated approach in the design of car park (coins). v. 35, n. 1, p. 7–14, 2008.
- BRADSKI, G.; KAEHLER, A. *Learning OpenCV: Computer Vision with the OpenCV Library*. [S.l.]: O'Reilly Media, 2008. ISBN 9780596554040.
- BROWN, C. D.; DAVIS, H. T. Receiver operating characteristics curves and related decision measures: A tutorial. *Chemometrics and Intelligent Laboratory Systems*, v. 80, n. 1, p. 24 – 38, 2006. ISSN 0169-7439.
- CANNY, J. A computational approach to edge detection. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, PAMI-8, n. 6, p. 679–698, 1986. ISSN 0162-8828.
- CHEN, C. *Signal and Image Processing for Remote Sensing, Second Edition*. [S.l.]: Taylor & Francis, 2012. (Signal and Image Processing for Remote Sensing). ISBN 9781439855966.
- CHOWDHURY, M.; SADEK, A. *Fundamentals of intelligent transportation systems planning*. [S.l.]: Artech House, Incorporated, 2003. (The Artech House ITS Library). ISBN 9781580531603.
- CHUNHE, Y.; JILIN, L. A type of sensor to detect occupancy of vehicle berth in carpark. In: *Signal Processing, 2004. Proceedings. ICSP '04. 2004 7th International Conference on*. [S.l.: s.n.], 2004. v. 3, p. 2708–2711 vol.3.
- DAN, N. Parking management system and method. n. U.S. Patent 20030144890A1, 07 2003.
- DEITEL, H. *Xml Como Programar*. [S.l.]: BOOKMAN COMPANHIA ED, 2001. ISBN 9788536301471.
- DIETTERICH, T. G. Ensemble methods in machine learning. In: *MULTIPLE CLASSIFIER SYSTEMS, LBCS-1857*. [S.l.]: Springer, 2000. p. 1–15.

DUDA, R.; HART, P.; STORK, D. *Pattern Classification*. [S.l.]: Wiley, 2012. ISBN 9781118586006.

FABIÀN, T. An algorithm for parking lot occupation detection. In: *Computer Information Systems and Industrial Management Applications, 2008. CISIM '08. 7th*. [S.l.: s.n.], 2008. p. 165–170.

FAWCETT, T. An introduction to ROC analysis. *Pattern Recognition Letters*, Elsevier Science Inc., New York, NY, USA, v. 27, n. 8, p. 861–874, jun. 2006. ISSN 01678655.

GONZALEZ, R. C.; WOODS, R. E. *Digital Image Processing (3rd Edition)*. Upper Saddle River, NJ, USA: Prentice-Hall, Inc., 2008. ISBN 013168728X.

GUYON, I. *Feature Extraction: Foundations and Applications*. [S.l.]: Springer, 2006. (Studies in Fuzziness and Soft Computing). ISBN 9783540354871.

HAN, J.; KAMBER, M. *Data Mining: Concepts and Techniques*. [S.l.]: Elsevier Books, Oxford, 2001. (The Morgan Kaufmann Series In Data Management Systems). ISBN 9781558604896.

HSU, C. wei; CHANG, C. chung; LIN, C. jen. *A practical guide to support vector classification*. 2010.

HUANG, C.-C. *Huang's Projects*. 2013. Disponível em: <<http://140.113.238.220/~chingchun/projects.html>>. Acesso em: 14 jul 2013.

HUANG, C.-C.; WANG, S.-J. A hierarchical bayesian generation framework for vacant parking space detection. *Circuits and Systems for Video Technology, IEEE Transactions on*, v. 20, n. 12, p. 1770–1785, 2010. ISSN 1051-8215.

HUANG, C.-C. et al. A bayesian hierarchical detection framework for parking space detection. In: *Acoustics, Speech and Signal Processing, 2008. ICASSP 2008. IEEE International Conference on*. [S.l.: s.n.], 2008. p. 2097–2100. ISSN 1520-6149.

ICHIHASHI, H. et al. Fuzzy c-means classifier with particle swarm optimization. In: *Fuzzy Systems, 2008. FUZZ-IEEE 2008. (IEEE World Congress on Computational Intelligence). IEEE International Conference on*. [S.l.: s.n.], 2008. p. 207–215. ISSN 1098-7584.

ICHIHASHI, H. et al. Vacant parking space detector for outdoor parking lot by using surveillance camera and fcm classifier. In: *Fuzzy Systems, 2009. FUZZ-IEEE 2009. IEEE International Conference on*. [S.l.: s.n.], 2009. p. 127–134. ISSN 1098-7584.

JEE, H.; LEE, K.; PAN, S. Eye and face detection using svm. In: *Intelligent Sensors, Sensor Networks and Information Processing Conference, 2004. Proceedings of the 2004*. [S.l.: s.n.], 2004. p. 577–580.

JOLLIFFE, I. *Principal Component Analysis*. [S.l.]: Springer, 2002. (Springer Series in Statistics). ISBN 9780387954424.

KITTLER, J. et al. On combining classifiers. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, v. 20, n. 3, p. 226–239, 1998. ISSN 0162-8828.

- KUNCHEVA, L. *Combining Pattern Classifiers: Methods and Algorithms*. [S.l.]: Wiley, 2004. ISBN 9780471660255.
- LIN, S.-F.; CHEN, Y.-Y.; LIU, S.-C. A vision-based parking lot management system. In: *Systems, Man and Cybernetics, 2006. SMC '06. IEEE International Conference on*. [S.l.: s.n.], 2006. v. 4, p. 2897–2902.
- MERCER, J. Functions of positive and negative type, and their connection with the theory of integral equations. *Philosophical Transactions of the Royal Society, London*, v. 209, p. 415–446, 1909.
- NIXON, M.; AGUADO, A. *Feature Extraction and Image Processing for Computer Vision*. [S.l.]: Academic Press, 2012. ISBN 9780123965493.
- OJALA, T.; PIETIKÄINEN, M. Unsupervised texture segmentation using feature distributions. *Pattern Recognition*, v. 32, n. 3, p. 477 – 486, 1999. ISSN 0031-3203.
- 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. ISSN 0162-8828.
- OJANSIVU, V.; HEIKKILÄ, J. Blur insensitive texture classification using local phase quantization. In: *Proceedings of the 3rd international conference on Image and Signal Processing*. Berlin, Heidelberg: Springer-Verlag, 2008. (ICISP '08), p. 236–243. ISBN 978-3-540-69904-0.
- OJANSIVU, V.; RAHTU, E.; HEIKKILA, J. Rotation invariant local phase quantization for blur insensitive texture analysis. In: *Pattern Recognition, 2008. ICPR 2008. 19th International Conference on*. [S.l.: s.n.], 2008. p. 1–4. ISSN 1051-4651.
- PETROU, M.; SEVILLA, P. *Image processing: dealing with texture*. [S.l.]: John Wiley & Sons Inc., 2006. ISBN 9780470026281.
- PING, T. Y.; YU, C. Y. Illegally parked vehicles detection based on omnidirectional computer vision. In: *Image and Signal Processing, 2009. CISP '09. 2nd International Congress on*. [S.l.: s.n.], 2009. p. 1–5.
- PLATT, J. C. Probabilistic outputs for support vector machines and comparisons to regularized likelihood methods. In: *ADVANCES IN LARGE MARGIN CLASSIFIERS*. [S.l.]: MIT Press, 1999. p. 61–74.
- POLIKAR, R. Ensemble based systems in decision making. *Circuits and Systems Magazine, IEEE*, v. 6, n. 3, p. 21–45, 2006. ISSN 1531-636X.
- RAHTU, E. et al. Local phase quantization for blur-insensitive image analysis. *Image and Vision Computing*, v. 30, n. 8, p. 501 – 512, 2012. ISSN 0262-8856. <ce:title>Special Section: Opinion Papers</ce:title>.
- ROKACH, L. *Pattern Classification Using Ensemble Methods*. [S.l.]: World Scientific Publishing Company, Incorporated, 2009. (Series in machine perception and artificial intelligence). ISBN 9789814271073.

RUSSELL, S.; NORVIG, P. *Artificial intelligence: a modern approach*. [S.l.]: Pearson Education/Prentice Hall, 2010. (Prentice Hall series in artificial intelligence). ISBN 9780136042594.

SANTANA, O. et al. Writer identification based on graphology techniques. *Aerospace and Electronic Systems Magazine, IEEE*, v. 25, n. 6, p. 35–42, 2010. ISSN 0885-8985.

SASTRE, R. et al. Computer algebra algorithms applied to computer vision in a parking management system. In: *Industrial Electronics, 2007. ISIE 2007. IEEE International Symposium on*. [S.l.: s.n.], 2007. p. 1675–1680.

SILLA, C.; KAESTNER, C.; KOERICH, A. Automatic music genre classification using ensemble of classifiers. In: *Systems, Man and Cybernetics, 2007. ISIC. IEEE International Conference on*. [S.l.: s.n.], 2007. p. 1687–1692.

SUROWIECKI, J. *The Wisdom of Crowds*. [S.l.]: Knopf Doubleday Publishing Group, 2005. ISBN 9780307275059.

TAN, H.-C. et al. Intelligent car-searching system for large park. In: *Machine Learning and Cybernetics, 2009 International Conference on*. [S.l.: s.n.], 2009. v. 6, p. 3134–3138.

THEODORIDIS, S.; KOUTROUMBAS, K. *Pattern Recognition*. [S.l.]: Elsevier Science, 2008. ISBN 9780080949123.

TOYAMA, K. et al. Wallflower: Principles and practice of background maintenance. In: *ICCV'99*. [S.l.: s.n.], 1999. p. 255–261.

WANG, X.; HANSON, A. Parking lot analysis and visualization from aerial images. In: *Applications of Computer Vision, 1998. WACV '98. Proceedings., Fourth IEEE Workshop on*. [S.l.: s.n.], 1998. p. 36–41.

WOLFF, J. et al. Parking monitor system based on magnetic field senso. In: *Intelligent Transportation Systems Conference, 2006. ITSC '06. IEEE*. [S.l.: s.n.], 2006. p. 1275–1279.

WU, Q. et al. Robust parking space detection considering inter-space correlation. In: *Multimedia and Expo, 2007 IEEE International Conference on*. [S.l.: s.n.], 2007. p. 659–662.

ZHU, C.; HIRAHARA, K.; IKEUCHI, K. Street-parking vehicle detection using line scan camera. In: *Intelligent Vehicles Symposium, 2003. Proceedings. IEEE*. [S.l.: s.n.], 2003. p. 575–580.