

ALEXANDRE WAGNER CHAGAS FARIA

Orientador: Arnaldo de Albuquerque Araújo

Co-orientador: David Menotti Gomes

**UMA METODOLOGIA PARA VALIDAÇÃO
FOTOMÉTRICA EM SISTEMAS INTERATIVOS
VEICULARES BASEADA EM INTELIGÊNCIA
COMPUTACIONAL**

Belo Horizonte
Dezembro de 2009

UNIVERSIDADE FEDERAL DE MINAS GERAIS
INSTITUTO DE CIÊNCIAS EXATAS
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

**UMA METODOLOGIA PARA VALIDAÇÃO
FOTOMÉTRICA EM SISTEMAS INTERATIVOS
VEICULARES BASEADA EM INTELIGÊNCIA
COMPUTACIONAL**

Dissertação apresentada ao Curso de Pós-Graduação em Ciência da Computação da Universidade Federal de Minas Gerais como requisito parcial para a obtenção do grau de Mestre em Ciência da Computação.

ALEXANDRE WAGNER CHAGAS FARIA

Belo Horizonte
Dezembro de 2009



UNIVERSIDADE FEDERAL DE MINAS GERAIS

FOLHA DE APROVAÇÃO

Uma Metodologia para Validação Fotométrica em Sistemas Interativos
Veiculares Baseada em Inteligência Computacional

ALEXANDRE WAGNER CHAGAS FARIA

Dissertação defendida e aprovada pela banca examinadora constituída por:

Dr. ARNALDO DE ALBUQUERQUE ARAÚJO – Orientador
Universidade Federal de Minas Gerais

Dr. DAVID MENOTTI GOMES – Co-orientador
Universidade Federal de Ouro Preto

Dr. CLODOVEU AUGUSTO DAVIS JÚNIOR
Universidade Federal de Minas Gerais

Dr. HANI CAMILLE YEHA
Universidade Federal de Minas Gerais

Belo Horizonte, Dezembro de 2009

Resumo

O presente trabalho propõe uma metodologia para validação automática do sistema de iluminação interna de um veículo, avaliando a qualidade visual de um painel de instrumentos veicular, baseada na percepção de seres humanos.

Embora a avaliação da qualidade visual seja uma questão subjetiva, ela é influenciada por algumas características fotométricas da iluminação do instrumento, como por exemplo, a distribuição da intensidade luminosa. Neste trabalho é desenvolvida uma metodologia visando identificar e quantificar regiões não homogêneas na distribuição da iluminação de um instrumento, a partir de uma imagem digital.

A fim de realizar tal tarefa, foram capturadas 107 imagens de instrumentos (velocímetros, indicação de rotações por minuto do motor (RPM), indicadores de velocidade e temperatura). Estes instrumentos foram avaliados por seres humanos a fim de identificar as regiões que eram homogêneas e não homogêneas. Então, para cada região encontrada no instrumento, foram extraídos um conjunto de descritores de homogeneidade. É proposto também neste trabalho, um descritor relacional com objetivo de entender a influência da homogeneidade de uma região em relação às outras regiões que compõem instrumento. Estes descritores foram associados às rotulações efetuadas pelos seres humanos, e assim fornecidas a dois algoritmos de Aprendizado de Máquina (Redes Neurais Artificiais - RNA e Máquinas Vetores de Suporte - SVM). Estes algoritmos foram treinados para classificar as regiões como homogêneas ou não. O trabalho apresenta também uma análise criteriosa sobre as avaliações subjetivas realizadas pelos usuários e especialista.

Após análise dos resultados a metodologia apresentou uma precisão superior a 94%, tanto para classificação das regiões quanto para a classificação final do instrumento.

Abstract

This work proposes a methodology for automatically validating the internal lighting system of an automobile, by assessing the visual quality of an instrument cluster (IC) based on the user's perceptions.

Although the visual quality assessment of an instrument is a subjective matter, it is influenced by some photometric features of the instrument, such as the light intensity distribution. In this work a methodology aiming to identify and quantify non homogeneous regions in the lighting distribution of these instruments, starting from a digital image, is presented.

In order to accomplish this task, a set of 107 digital images of some gauges (speedometer, tachometer, temperature and fuel) was acquired and preprocessed. The same instruments were evaluated by users to identify their non-homogenous regions. Then, for each instrument region, we extracted a set of homogeneity descriptors. It is also proposed in this work, a relational descriptor to study the homogeneity influence of a region in relation with the others regions in the gauges. These descriptors were associated with the results of the user labeling, and given to two machine learning algorithms (Artificial Neural Network - ANN and Support Vector Machine - SVM). These algorithms were trained to identify a region as being homogeneous or not. The work also accomplished a meticulous analysis of the user and the specialist evaluation.

After the analysis of the results, the proposed methodology obtained a precision above 94%, for both regions and final classifications.

Dedico esse trabalho aos meus Avós e minha Mãe.

Agradecimentos

Como começar esta seção, sem agradecer primeiramente a DEUS? Impossível. A ele agradeço por TUDO: pela minha vida; por minhas maiores virtudes: determinação e perseverança, que me trouxeram até aqui; por ter sido criado pelas melhores pessoas do mundo: meus AVÓS, que me ensinaram meus bens mais preciosos: caráter e honestidade; pelos amigos sinceros que foram colocados em minha vida e por iluminar meu caminho;

Agradeço aos meus Avós: Vovó Maria e Vovô Bené e minha Mãe Silézia, a vocês agradeço pela minha vida, agradeço por tudo que fizeram por mim, por tudo que me ensinaram, agradeço por ser quem sou. Este é mais um daqueles momentos que tanto gostaria de compartilhar com a presença de vocês ao meu lado, espero que se sintam orgulhosos de mais uma vitória nossa.

A minha querida esposa Keila Janine, obrigado por estar ao meu lado, acreditando e sempre me incentivando a superar meus desafios.

A minha irmã Jaqueline Andrea, por sempre confiar em mim e sempre me demonstrar que me ama incondicionalmente.

Aos amigos Emerson da Silva Almeida e Wiliam Apolinário Moreira, vocês são meus grandes amigos de fé, meus irmãos camaradas.

Aos amigos Giovanni Carvalho, Mary Pinheiro, Ronaldo Marinho, Ronaldo Pires e Sidney Melo pelo constante incentivo e torcida.

Aos meus amigos da FIAT Automóveis, em especial à: Claudio Parreiras; Cecília Sereno; Edimar Cunha; Giorgio Felix; Giovanni Bellis; Gilmar Laignier; Kenedy Marconi; Leandro Figueiredo; Samanta Teixeira; Viviane Marinho e Wander Cezar obrigado pelo apoio, pelas palavras de incentivos e por serem tão generosos.

Ao amigo Fernando Akira, pelos livros e incentivo.

Aos amigos: Daniel Lara, Leandro Aguiar e Sandra Eliza, obrigado pelas palavras de apoio e pela ajuda nos estudos.

Ao professor Alexandre Leão pelo apoio e pelas dicas de fotografia.

A professora Gisele Lobo Pappa pelas dicas e revisões do texto.

Aos professores de altíssimo nível que tive durante essa jornada: Arnaldo de Albuquerque Araujo; Antônio Alfredo Loureiro; Mario Fernando Montenegro e Peterson Resende. A vocês eu agradeço a oportunidade de ser vosso aluno e por tudo que aprendi nessa etapa de tantos estudos.

Ao meu orientador professor Arnaldo de Albuquerque Araujo, obrigado por me acolher como seu orientando, por seu voto de confiança, pelas oportunidades e pela orientação.

Ao meu Co-orientador professor David Menotti, muito obrigado pela orientação precisa e inspiradora, pelas diversas ajudas nos momentos difíceis, por sempre a me encorajar a cumprir minha meta e descobrir meu próprio caminho.

Aos membros da banca: Clodoveu Augusto Davis Júnior e Hani Camille Yehia, pela honra de aceitarem a fazer parte da banca, pelas revisões realizadas e excelentes sugestões fornecidas.

E por fim a todos que de alguma maneira contribuíram, incentivaram ou acreditaram neste trabalho.

Sumário

1	Introdução	1
1.1	Definição do Problema	3
1.2	Motivação	4
1.3	Objetivos	4
1.3.1	Objetivos Gerais	5
1.3.2	Objetivos Específicos	5
1.4	Materiais	5
1.5	Contribuições	6
1.6	Trabalhos Relacionados	6
1.7	Organização deste Trabalho	7
2	Ergonomia Visual e Sistemas de interação	8
2.1	Ergonomia Visual	8
2.2	Análise Visual Por Cores Falsas	9
2.3	Sistemas de Interação	10
3	Fundamentação Teórica	14
3.1	Exposição em Fotografias	14
3.2	Espaço de Cores	17
3.2.1	Espaço RGB	18
3.2.2	Espaço HSV	18
3.2.3	Conversão RGB para HSV	20
3.3	Limiarização	20
3.4	Operação Morfológica de Erosão	21
3.5	Rotulação de Componentes Conexos	22
3.6	Descritores de Homogeneidade	22
3.7	Aprendizado de Máquina	25
3.7.1	Redes Neurais Artificiais	27
3.7.2	Máquina de Vetores de Suporte	32
3.8	Considerações	36

4	Metodologia	37
4.1	Descrição Geral da Metodologia	37
4.2	Extração de Características	37
4.2.1	Calibração Radiométrica e Aquisição de Imagem	38
4.2.2	Pré-processamento da Imagem	39
4.2.3	Extração dos Descritores de Homogeneidade	41
4.3	Aprendizado	44
4.4	Classificação	44
4.5	Seleção de Características	45
4.6	Avaliações Subjetivas	45
4.7	Considerações	46
5	Resultados Experimentais	47
5.1	Descrição da Base	47
5.2	Descrição do Método de Avaliação dos Classificadores	48
5.3	Definição de Parâmetros	50
5.3.1	Definição dos Parâmetros de Câmera	50
5.3.2	Definição dos Parâmetros da ANN	55
5.3.3	Definição dos Parâmetros da SVM	56
5.4	Avaliação Subjetiva	56
5.4.1	Avaliação com Usuário	57
5.4.2	Avaliação com o Especialista	57
5.4.3	Análise das Avaliações Subjetivas	57
5.5	Experimentos Computacionais	62
5.5.1	Resultados obtidos para Classificação das Regiões	63
5.5.2	Resultados Obtidos para Classificação do Instrumento	64
5.5.3	Análise dos Resultados	64
5.5.4	Visualização das Classificações	67
5.5.5	Análise dos Descritores	67
5.6	Conclusões sobre os Experimentos Computacionais e Avaliação Subjetiva	69
5.7	Considerações	71
6	Conclusões e Trabalhos Futuros	72
6.1	Trabalhos Futuros	73
6.2	Publicações Oriundas deste Trabalho	73
A	Instrumentos Utilizados	74
	Referências Bibliográficas	77

Lista de Figuras

1.1	(a) Iluminação mais intensa (b) Iluminação menos intensa.	2
1.2	(a) Iluminação vermelha, (b) Iluminação verde, (c) Iluminação ambar.	2
1.3	Problemas típicos de falta de homogeneidade em instrumentos: (a,d) Iluminação mais escura nas bordas do símbolo; (b,e) Falta de homogeneidade em vários pontos, alguns números mais intenso que outros; (c,f) Iluminação com intensidade mais forte do centro para as bordas.	3
2.1	Efeito das bandas de Mach: (a) Níveis crescente de intensidade; (b) Intensidade real; (c) Intensidade percebida.	10
2.2	Exemplo de contraste simultâneo.	10
2.3	Análise de imagens em cores-falsas: a)Imagem original; b)Imagem em tons de cinza; c)Imagem cores-falsas.	11
2.4	Evolução dos painéis automotivos: a) Velocímetro típico utilizado nos anos 50's; b) Painel de instrumento do Koenigsegg CCX 2007; c) Painel de instrumentos de um Porsche Carrera 2005.	12
2.5	Vista explodida das partes principais de um painel de instrumento (<i>Imagem gentilmente cedida pela Magneti Marelli - Divisão Eletrônica</i>).	13
2.6	Um exemplo de difusor aplicado sob a serigrafia.	13
3.1	Variação dos Parâmetros: Abertura de diafragma (<i>f-stop</i>) e tempo de exposição (<i>S</i>).	15
3.2	Valores Usuais de <i>f-stop</i>	16
3.3	(a) <i>f stop</i> = 2.8 e Velocidade = 1/8"; (b) <i>f stop</i> = 4.0 e Velocidade = 1/4"; (c) <i>f stop</i> = 5.6 e Velocidade = 1/2"; (d) <i>f stop</i> = 8.0 e Velocidade = 1".	17
3.4	Espaço de cores RGB.	18
3.5	Espaço de cores HSV.	19
3.6	Tipos de vizinhança para componentes conexos: (a) Vizinhança-4; (b) Vizinhança-8.	22
3.7	Exemplo de texturas para cálculo dos descritores.	25
3.8	Histogramas para cada região destacada na Figura 3.7.	26
3.9	Neurônio Biológico.	29
3.10	Neurônio Artificial.	30

3.11	(a)Função linear; (b)Função rampa; (c) Função degrau; (d)Função tangente hiperbólica; (e)Função sigmoidal.	31
3.12	Exemplo de um hiperplano ótimo para padrões separáveis linearmente.	33
3.13	Interpretação geométrica da distância algébrica de um ponto para o hiperplano ótimo.	34
3.14	SVM não linear:(a) Conjunto de dados (não lineares); (b) Fronteira não linear do espaço de entrada; (c) Fronteira linear no espaço de características.	35
4.1	Diagrama da Metodologia Proposta.	38
4.2	Diagrama do método para extração de características.	38
4.3	Leitura dos valores no canal V nos pontos medidos: (a) Seleção da região para leitura; (b) Valores dos <i>pixels</i> indicados pelo círculo em (a).	39
4.4	Conversão do espaço de cores: (a) Figura original; (b) Canal V, do espaço HSV, correspondente à imagem de (a).	40
4.5	Limiarização: (a) Canal V, do espaço HSV; (b) Após algoritmo de limiarização de Otsu.	40
4.6	Erosão: (a) Imagem binarizada; (b) Imagem de (a) erodida; (c) Detalhe da região erodida (ressaltada em verde) de (b).	41
4.7	Rotulação: (a) Imagem após binarização + erosão; (b) Componentes conexos.	41
4.8	Figura sintética exemplo.	43
4.9	<i>Setup</i> de avaliação: (a) Instrumento montado sobre a bancada (b) <i>Croqui</i> do instrumento para avaliação do ser humano.	46
4.10	Condutor × Automóvel: (a) Posicionamento médio de um condutor em relação ao Painel de instrumentos, (b) Simulação da visão do condutor em relação ao painel de instrumentos.	46
5.1	Matriz de Confusão.	48
5.2	Matriz de Confusão Adaptada.	49
5.3	Matriz de Confusão Para Classificação Final do Instrumento.	50
5.4	Câmera fotográfica Canon S3 IS.	51
5.5	Medições realizada com o espectrofotômetro.	52
5.6	Instrumento Âmbar - Análise gráfica entre as medidas sobre a imagem (diferentes tempos de exposição) X espectrofotômetro.	53
5.7	Instrumento Verde - Análise gráfica entre as medidas sobre a imagem (diferentes tempos de exposição) X espectrofotômetro.	53
5.8	Instrumento Vermelho - Análise gráfica entre as medidas sobre a imagem (diferentes tempos de exposição) X espectrofotômetro.	54
5.9	Instrumento Azul - Análise gráfica entre as medidas sobre a imagem (diferentes tempos de exposição) X espectrofotômetro.	54

5.10	Análise da Percepção do Usuário: a) Instrumento original; b) Detalhe da região ressaltada em amarelo; c) Análise por cores falsas - imagem original; d) Análise de superfície - imagem original; e) Detalhe da região ressaltada - corrigida; f) Análise por cores falsas - imagem corrigida; g) Análise de superfície - imagem corrigida.	60
5.11	Gráfico resumo da avaliação do usuário sobre o especialista.	61
5.12	Estratificação da avaliação.	62
5.13	Imagens de instrumentos e suas respectivas classificações: as imagens a, b, c e d representam as imagens originais; as imagens e, f, g e h representam a classificação com base na rotulação do especialista; as imagens i, j, k e l representam a classificação com base na rotulação do Grupo 1 e as imagens m, n, o e p representam a classificação com base na rotulação do Grupo 5. As regiões homogêneas e não homogêneas classificadas corretamente são representadas pelas cores branca e amarela, respectivamente. Já as regiões não homogêneas, classificadas como homogêneas, são representadas pela cor vermelha, e as regiões homogêneas classificadas como não homogêneas, são representadas pela cor verde.	68
5.14	Um exemplo ilustrativo de instrumentos e sua respectiva classificação realizada pela metodologia: (a) Imagem original; (b) Imagem classificada. A cor branca representa as regiões que eram homogêneas e foram classificadas corretamente como homogêneas e a cor verde representa a região que era homogênea e foi classificada erradamente como não homogênea.	69
5.15	Análise da ocorrência dos descritores, nas 50 melhores execuções.	70

Lista de Tabelas

3.1	Valores de exposição para diferentes velocidades do obturador e aberturas do diafragma.	17
3.2	Análise dos descritores para cada região apresentada na Figura 3.7.	27
3.3	Principais <i>kernels</i> utilizados para SVM não lineares.	35
5.1	Cálculo do erro entre medida do espectrofotômetro e fotografia.	55
5.2	Avaliação do número de neurônios na camada oculta.	56
5.3	Avaliação do <i>kernel</i>	56
5.4	Distribuição das classes Não Homogêneas/Homogêneas.	58
5.5	Distribuição de regiões não homogêneas por avaliação.	58
5.6	Matriz de concordância para regiões não homogêneas.	59
5.7	Matriz de concordância para regiões homogêneas.	59
5.8	Matriz de confusão para ANN.	63
5.9	Matriz de confusão para SVM.	63
5.10	Matriz de confusão: Classificação final dos instrumentos para ANN.	64
5.11	Matriz de confusão: Classificação final dos instrumentos para SVM.	65
5.12	Resumo da Precisão Global dos Classificadores.	65
5.13	Resumo da Precisão Por Classe.	66
5.14	Resumo da Precisão da Classificação do Instrumento.	66
A.1	Instrumentos avaliados	74
A.2	Instrumentos avaliados (Continuação)	75
A.3	Instrumentos avaliados (Continuação b)	76

Capítulo 1

Introdução

Uma das formas mais utilizadas de comunicação entre um veículo e o ser humano é por meio de informações visuais, seja por painel de instrumentos, mensagens escritas ou gráficas em *displays*, indicações luminosas, *etc.* Em um ambiente embarcado, esta comunicação é imprescindível para uma correta interação entre veículo e homem (Bosch, 2007), seja em ambiente diurno ou noturno.

Em um automóvel, essa comunicação é percebida desde o primeiro contato interno com o veículo, como por exemplo: a operabilidade de um rádio; sistema de climatização digital; comandos agregados ao volante; botões para a personalização de funções; painel de instrumentos; *etc.* Esse último é o principal meio de comunicação do veículo com o motorista (Guimarães, 2007). É no painel de instrumentos que são apresentadas ao condutor as informações vitais do veículo: indicação de velocidade; RPM (indicação de rotações por minuto do motor); indicação do nível de combustível; temperatura do líquido de arrefecimento; ideogramas indicadores de funções e respostas de sensores; *etc.*

Com o crescimento acentuado da *infotainment*¹ nos veículos, tais como sistemas de navegação, serviços de entretenimento, adoção de novos *displays*, ideogramas, *etc.*, os sistemas automotivos desenvolvidos para interagir com o usuário tendem a crescer cada vez mais (Guimarães, 2007). Assim, o cuidado com a qualidade de visualização desses dispositivos é ponto de destaque quando se trata de conforto visual² interno de um veículo em um ambiente noturno. Portanto, torna-se de extrema importância um estudo baseado em metodologia científica capaz de determinar o nível de qualidade destas iluminações, conforme percebidas pelos usuários.

É de grande importância que o painel de instrumentos apresente uma grande harmonia para seu usuário. Para buscar essa harmonia, características fotométricas são estudadas, medidas e trabalhadas de forma a se obter, no final, produtos que transmitam qualidade visual ao cliente. As características fotométricas estudadas nesses instrumentos são:

¹Sistemas que integram funções de informação e entretenimento, do inglês: *Information e Entertainment*.

²Grau subjetivo da satisfação visual, produzida pelas estimulações visuais em um ambiente (Sagawa, 1999).

1. Intensidade luminosa: visa obter um nível de intensidade de iluminação adequado ao usuário de modo que seja fácil a visualização e interpretação dos instrumentos e ainda que seja confortável e agradável ao usuário do veículo mesmo em viagens mais longas. As imagens da Figura 1.1 ilustram instrumentos iluminados com mais (Figura 1.1(a)) e menos (Figura 1.1(b)) intensidade.




Figura 1.1: (a) Iluminação mais intensa (b) Iluminação menos intensa.

O nível de intensidade em um instrumento não é considerado um ponto crítico, pois além desses valores já serem conhecidos pelos fabricantes devido à experiência de anos de produção, muitos veículos hoje em dia contêm dispositivos para ajustar o valor de intensidade de acordo com o gosto do usuário, *e.g.*, *dimmers*.

2. Cromaticidade: a escolha da cor em uma iluminação reflete muito a imagem que o *designer* deseja passar de seu produto ao usuário: uma aparência mais esportiva, clássica, jovem, *etc.* Como os diversos instrumentos de iluminação são desenvolvidos em locais diferentes no mundo, é importante para a harmonia da iluminação que os instrumentos de um projeto apresentem a mesma percepção de cor, independente do fabricante. As imagens da Figura 1.2 apresentam exemplos de instrumentos em diferentes cores.




Figura 1.2: (a) Iluminação vermelha, (b) Iluminação verde, (c) Iluminação ambar.

3. Homogeneidade: o estudo da homogeneidade tem um papel muito importante nessa

harmonia, pois é por meio desse estudo que se garante a uniformidade da intensidade distribuída na iluminação. Esse é um grande desafio, pois desenvolver uma metodologia capaz de definir o nível adequado de homogeneidade em que o sistema visual humano é capaz de perceber como bom ou ruim, é uma tarefa complexa, dependendo de estudos dos limites de percepção do usuário para definir uma região como homogênea ou não. As imagens da Figura 1.3 apresentam exemplos de problemas causados pela falta de homogeneidade nos instrumentos.

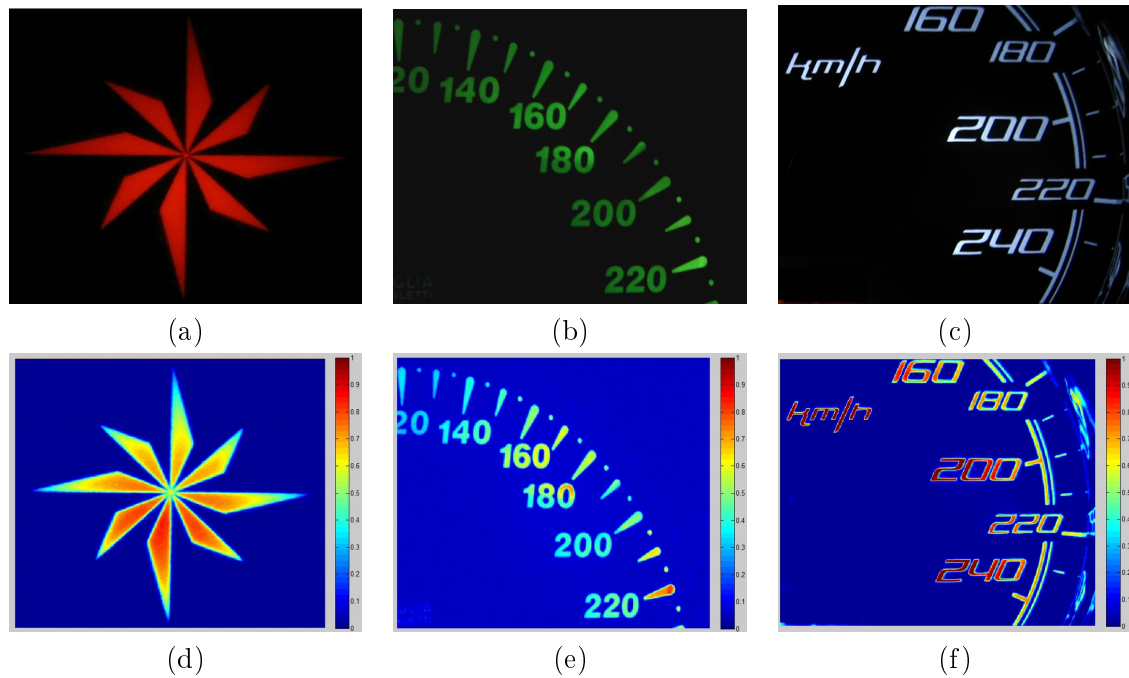


Figura 1.3: Problemas típicos de falta de homogeneidade em instrumentos: (a,d) Iluminação mais escura nas bordas do símbolo; (b,e) Falta de homogeneidade em vários pontos, alguns números mais intenso que outros; (c,f) Iluminação com intensidade mais forte do centro para as bordas.

1.1 Definição do Problema

Com base no exposto na seção anterior, a elaboração de uma metodologia capaz de realizar de forma automática a análise da homogeneidade na iluminação de instrumentos, baseada na percepção visual humana, se caracteriza como uma ferramenta poderosa para o processo de desenvolvimento de sistemas de iluminação de novos produtos.

Entre os pontos ressaltados anteriormente para caracterização da iluminação, a homogeneidade se destaca como o parâmetro mais complexo de ser mensurado. Ela demanda uma pesquisa aprofundada, visando determinar se regiões são ou não homogêneas baseado nos limites percebidos pelo usuário. Para tal tarefa é necessário o desenvolvimento de uma metodologia

confiável, robusta e unida com a percepção visual humana.

O foco desta pesquisa é determinar uma metodologia, baseada na percepção visual humana, para identificar e quantificar regiões não homogêneas na distribuição da iluminação de um instrumento (*e.g.*, velocímetro, RPM, indicadores de temperatura e combustível), a partir de uma imagem digital.

1.2 Motivação

A maioria dos sistemas atuais de validação de iluminação interna é realizada através de inspeção visual, sistemas semi-automáticos com intervenção humana ou através de medições pontuais utilizando-se algum equipamento (*e.g.*, espectrofotômetro³). Para a implementação desse último método, são realizadas inúmeras medições (pontuais) no objeto de prova para depois realizar um estudo dos dados coletados. Ao fim desses estudos, são calculadas manualmente as características de iluminação do instrumento: intensidade, cor e homogeneidade.

Os métodos citados acima trazem consigo algumas desvantagens: a) Tempo de análise; b) Falta de repetibilidade; c) Subjetividade do resultado; d) Uso de um equipamento relativamente caro; e) As medidas pontuais não contemplam toda a área de iluminação do instrumento; f) Falta de um critério científico, para determinar homogeneidade baseado na percepção humana.

Um exemplo de um método semi-automático é a utilização de um espectrofotômetro (Oleari, 1998), que é um instrumento de alto custo especializado em medições de intensidade e análise de cor. O principal problema no uso de um espectrofotômetro é o tempo de medição para cada ponto. Por exemplo, um painel de instrumentos completo contemplaria a medição de aproximadamente 400 pontos possíveis. Cada medição realizada pelo espectrofotômetro leva em média 20 segundos, mais 10 segundos para reposicionamento do equipamento, levando um total de aproximadamente 3 horas de trabalho somente para as medições. Além do tempo de medição, este tipo de análise não contempla um critério científico baseado na percepção humana para questões de falta de homogeneidade.

Juntamente com o exposto acima, o trabalho proposto visa auxiliar de forma ativa os fabricantes de painéis automotivos. Com os dados gerados pela metodologia, é possível fornecer ao fabricante informações de onde ele deverá atuar no seu projeto, de forma a melhorar a homogeneidade do instrumento. Esta metodologia visa a redução do tempo de análise do instrumento em fase de prototipação e aumentar sua qualidade visual.

1.3 Objetivos

Os objetivos gerais e específicos deste trabalho são apresentados a seguir.

³ Aparelho que mede com precisão o brilho da luz emitida/refletida (intensidade) por um “ponto” na unidade cd/m^2 , ou seja, candela por metro quadrado.

1.3.1 Objetivos Gerais

O objetivo geral deste trabalho é desenvolver uma metodologia eficaz para validação automática das características de homogeneidade da iluminação em um instrumento veicular, utilizando percepções humanas, por meio de avaliação subjetiva, e algoritmos de aprendizado de máquina.

1.3.2 Objetivos Específicos

A seguir, são listados os objetivos específicos que se espera obter neste trabalho:

1. Definir um procedimento para calibração dos parâmetros da câmera fotográfica (*i.e.*, tempo de exposição e abertura de diafragma), de modo que a câmera reproduza, de forma confiável, a distribuição da intensidade do instrumento a ser fotografado;
2. Definir o espaço de cores apropriado para a extração das características de intensidade;
3. Identificar os descritores, existentes na literatura, mais adequados para caracterizar a homogeneidade em uma imagem de intensidade;
4. Definir um método de avaliação confiável e robusto relacionado ao ser humano, com o propósito de estudar sua percepção em relação à homogeneidade de um instrumento;
5. Identificar algoritmos de aprendizado de máquina capazes de “aprender”, a partir das avaliações com os seres humanos, a tarefa de classificar uma região como homogênea ou não;
6. Definir um método de avaliação que permita quantificar a qualidade das classificações realizadas pelo sistema proposto.

1.4 Materiais

São utilizados neste projeto diversos instrumentos de diferentes veículos para avaliação. Os instrumentos utilizados neste trabalho são: velocímetros, indicadores de temperatura, indicadores de combustível e indicador de rotações por minuto do motor (RPM). Foram usados instrumentos de cores diversas para testar a robustez da metodologia proposta. É utilizado, também, um espectrofotômetro para calibragem do sistema proposto e, para alguns testes específicos, são utilizadas as instalações do laboratório de Fotometria e Colorimetria da Fiat Automóveis S/A, para aquisição das imagens e avaliações com os usuários.

1.5 Contribuições

Uma vez alcançados os objetivos propostos neste trabalho, as principais contribuições deste são:

- Desenvolvimento de uma metodologia para validação automática de instrumentos automotivos, com base em homogeneidade, utilizando análise de imagens, inteligência computacional e avaliações com o ser humano (Faria et al., 2009, 2010);
- Um método de calibração para uma câmera digital, visando análise de intensidade;
- Proposta de um descritor relacional, para abordar o efeito que uma região (menor parte iluminada do instrumento) possui na homogeneidade global de um instrumento;
- Um método de avaliação com usuários para percepção visual, com potencial a ser estendido, para outras sensações humanas: audição, olfato, *etc*;
- Um estudo sobre a percepção humana, por meio de aprendizado de algoritmos de máquina.
- Um método capaz de acompanhar a evolução do projeto de iluminação, desde a fase de prototipagem até a peça industrializada.

1.6 Trabalhos Relacionados

Na literatura, são abordados vários métodos para cálculo de homogeneidade em imagens de intensidade (Cheng et al., 2003; Cheng e Sun, 2000; Wang e Suter, 2003; Martinez et al., 2005; Kebin et al., 2005; Singh e Singh, 2004; Suarez et al., 2007; Kim et al., 2004), principalmente visando a segmentação de regiões. Existem, também, na literatura inúmeras pesquisas relacionadas com a detecção automática de MURA⁴, (Lee e Yoo, 2004; Ahengyao e Ling, 2006; Choi et al., 2004; Taniguchi et al., 2006; Oh et al., 2007), por meio de técnicas de análise de imagens. O termo MURA é usado, principalmente, por engenheiros da indústria de *display* para denotar falhas de homogeneidade (Cheng et al., 2003) em dispositivos como: LCD (*Liquid Cristal Display*), TFT (*Thin Film Transistor*), FPD (*Flat Panel Display*), *etc*.

Contudo, tais metodologias são mais adequadas quando aplicadas em uma única imagem de superfície. Quando se trabalha com iluminação de instrumentos veiculares, é bem usual que um instrumento seja composto por várias e pequenas regiões iluminadas. Então, para esta aplicação, propõe-se uma metodologia que atue não somente sobre uma avaliação local em uma pequena área, mas uma análise do impacto que a iluminação local de uma área tem sobre a visualização global do instrumento.

⁴ MURA é uma palavra japonesa utilizada para descrever uma variação não uniforme da intensidade local em uma região, que não apresenta um contorno definido e geralmente de baixo contraste, sobre uma superfície, que é percebida como uma sensação visual não agradável.

1.7 Organização deste Trabalho

O restante deste trabalho está organizado da seguinte forma: No Capítulo 2, são descritos aspectos sobre ergonomia visual e sistemas de interação, objeto deste trabalho. No Capítulo 3, são descritos alguns conceitos teóricos, necessários para o embasamento deste trabalho. A metodologia proposta juntamente com a descrição dos métodos para certificação da eficácia da metodologia serão tratados no Capítulo 4. Toda a etapa de experimentos dos métodos propostos e eficiência da metodologia está descrita no Capítulo 5. Para finalizar o trabalho, são relatadas no Capítulo 6 as conclusões finais e trabalhos futuros a serem desenvolvidos.

Capítulo 2

Ergonomia Visual e Sistemas de interação

Neste capítulo, são descritos conceitos relativos à ergonomia visual, abordando suas definições e implicações, e também são abordados conceitos e características de sistemas de interação veicular.

2.1 Ergonomia Visual

Segundo a IEA (Associação Internacional de Ergonomia - International Ergonomics Association) ergonomia é a disciplina científica que tem por objetivo os estudos das interações entre o homem e o meio no qual ele está incluso, visando aperfeiçoar seu bem estar e a sua interação com este ambiente.

Pode-se, também, definir ergonomia como sendo o conforto, a forma, a interação entre homens e sistemas, de modo que um objeto ou sistema é considerado ergonômico quando o usuário se sente confortável usando-o ou manipulando-o. Aplicando ergonomia ao âmbito visual pode-se descrever que ergonomia visual é o estudo das cores, formatos, diagramação, disposição de componentes e sistemas que permitam a seus usuários, o maior conforto possível em sua percepção pelo sistema visual humano.

No âmbito automotivo, a ergonomia visual preocupa-se com a harmonia da iluminação de cada componente dentro de um contexto pré-estabelecido: cores, contraste, reflexos, luzes fantasmas, homogeneidade da distribuição da iluminação, ofuscamento, alta ou baixa intensidade, *etc.* Um dos principais objetivos de um estudo de ergonomia visual é melhorar a segurança e conforto do sistema visual humano, evitando sua fadiga.

Segundo Walraven e Alferdinck (2001), para sistemas de interação aplicados em aeronaves, o que também é extensível a área automotiva, a ergonomia visual pode ser dividida em dois aspectos:

- Cognitivo: O estudo da eficiência da transmissão da informação por meio da leitura dos instrumentos, que deve ser de fácil e rápida interpretação e não deve dar margens a duplos significados;
- Qualidade visual do instrumento: O estudo da cor, intensidade e homogeneidade da distribuição luminosa do componente.

Neste trabalho, foca-se sobre este último, ou seja, estuda-se a percepção que os usuários têm sobre a homogeneidade da iluminação.

Percepção visual

Gonzalez e Woods (2007) ressaltam dois efeitos interessantes sobre a percepção da intensidade luminosa de um objeto em relação ao seu contexto.

O primeiro efeito, exemplificado pelas bandas de Mach¹, mostra que a percepção da intensidade luminosa não é uma função simplesmente do objeto por si só. O sistema visual humano tende a exceder ou diminuir a percepção da intensidade à medida que essa se aproxima ou se afasta de outro nível. Na Figura 2.1, pode-se perceber que, embora, a intensidade de cada coluna seja constante, tende-se a perceber o final de cada coluna em tom mais escuro quando se aproxima de uma nova coluna (mais clara) e essa se inicia, aparentemente, mais clara.

O segundo efeito, chamado de contraste simultâneo, também mostra que a percepção da intensidade tem uma forte influência do fundo no qual o objeto está inserido. Por exemplo, na Figura 2.2, embora o quadrado central (objeto) tenha a mesma intensidade nas três imagens, a medida que o fundo se torna mais escuro, tende-se a perceber o objeto mais claro em cada imagem.

Esses efeitos serão úteis para avaliação dos resultados com os usuários sobre a homogeneidade.

2.2 Análise Visual Por Cores Falsas

Uma técnica bem utilizada para inspeção visual de iluminação em imagens, é chamada de cores falsas ou pseudocoloração. Essa técnica consiste em associar cores para imagens em tons de cinza. A principal vantagem dessa técnica está baseada na característica do próprio sistema visual humano, cuja habilidade em discernir valores entre cores é muitas vezes maior que a capacidade em discernir valores em tons de cinza (Gonzalez e Woods, 2007) e (Jinxiu et al., 2007). A Figura 2.3 apresenta um exemplo dessa característica.

Zhou et al. (2007) descrevem que o sistema visual humano consegue perceber aproximadamente entre 60 e 90 JND's (*Just Notice Difference* ou Diferenças Mínimas Evidentes) para níveis de cinza e acima de 500 JND's para níveis de cores.

Observe que essa técnica é utilizada em algumas imagens ilustradas deste trabalho.

¹Ernst Mach 1838-1916, físico e filósofo austríaco.




Figura 2.1: Efeito das bandas de Mach: (a) Níveis crescente de intensidade; (b) Intensidade real; (c) Intensidade percebida.




Figura 2.2: Exemplo de contraste simultâneo.

2.3 Sistemas de Interação

No último século, o desenvolvimento tecnológico tem conduzido o homem a conviver e interagir com sistemas cada vez mais complexos. A respeito de interação entre homem e máquina, um crescimento considerável de instrumentos para os meios de transporte se deu na Segunda Guerra Mundial, com a inserção de inúmeros instrumentos aplicados nas *cockpits* de aeronaves.

No início, grande parte desses equipamentos, destinados a dar informações aos pilotos, não

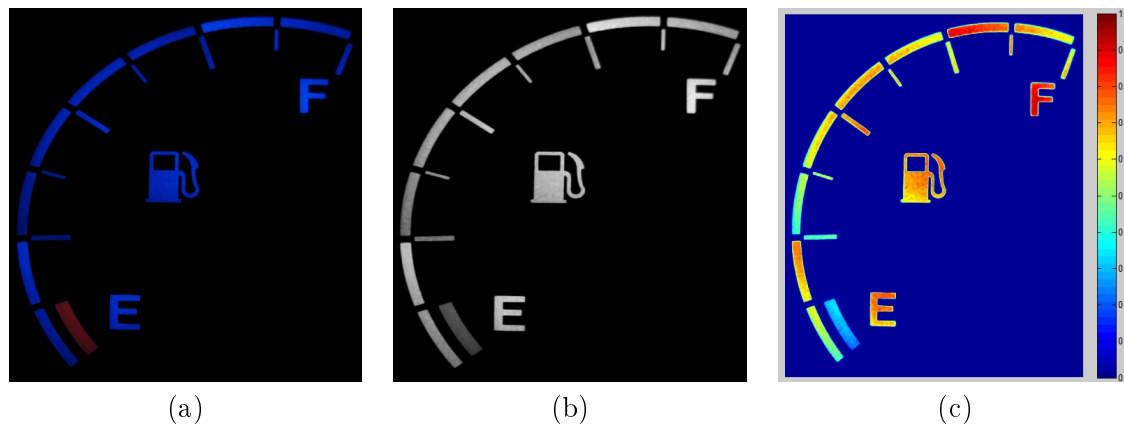


Figura 2.3: Análise de imagens em cores-falsas: a)Imagem original; b)Imagem em tons de cinza; c)Imagem cores-falsas.

estavam adaptados para uma correta e rápida interpretação dos operadores. Entre os principais aspectos destacavam-se, a pouca visibilidade de alguns instrumentos, falta de padronização da disposição dos instrumentos, dentre outros pontos. Como consequência, inúmeros acidentes e imprecisão de missões ocorreram. Em função deste cenário, grupos de pesquisadores começaram a estudar e modificar os projetos de posicionamento de instrumentos nas aeronaves, melhorando os mesmos na ótica de operabilidade e visualização por parte do piloto.

Segundo Kroemer et al. (1994), a Segunda Guerra Mundial de certa maneira contribuiu para o desenvolvimento da ergonomia, aumentando o estudo entre a relação homem-máquina. Por exemplo, Heskett (1998) resalta em seu trabalho que a necessidade de reações quase instantâneas por parte dos pilotos de caças estimulou e ajudou a contribuir para o aperfeiçoamento dos estudos de ergonomia para os controles e instrumentos aplicados em aeronaves.

Sistemas de interação automotivos

Contemporaneamente aos estudos da ergonomia aplicados à aviação, os mesmos se estenderam ao setor automotivo, visando fornecer ao condutor um ambiente confortável e de fácil interação.

Neste cenário, o painel de instrumento se destaca como o principal meio de interação entre o carro e o seu condutor. É através dele que informações primordiais do veículo são transmitidas, permitindo ao condutor tomar ações baseadas nessas informações.

O painel de instrumentos tem se tornado um dos mais complexos sistemas eletrônicos embarcados nos veículos modernos (Huang et al., 2008), fornecendo para o usuário um variado universo de informações, desde condições de direção, mensagens e pré-diagnósticos até sistemas de multimídia (Castineira et al., 2009). A fim de fornecer esse conjunto de informações, a quantidade de instrumentos e dispositivos incluídos em um simples painel tem aumentado consideravelmente nos últimos anos.

Os modernos painéis de instrumentos, além de serem uma interface essencial com o usuário,

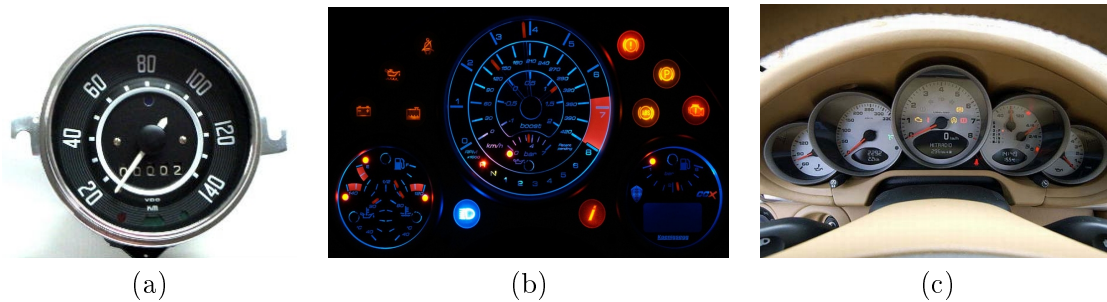


Figura 2.4: Evolução dos painéis automotivos: a) Velocímetro típico utilizado nos anos 50's; b) Painel de instrumento do Koenigsegg CCX 2007; c) Painel de instrumentos de um Porsche Carrera 2005.

também representam um importante elemento estilístico para o condutor (Wei et al., 2006). O painel tem grande influência no aspecto interno do veículo, e transmitem diferentes tipos de sensações ao usuário, tais como: modernidade, esportividade, aspecto futurístico, clássico, *etc.* Por exemplo, veja os painéis na Figura 2.4. No entanto, além do *design* gráfico, é essencial que o painel de instrumento apresente uma qualidade visual adequada.

A Figura 2.5 apresenta uma visualização dos vários componentes que fazem parte de um painel de instrumentos. Dentre elas, destaca-se a serigrafia, onde é trabalhada a homogeneidade de um instrumento. Para a fabricação da mesma, são necessárias, em média, mais de 10 etapas de passagem de tinta: desenhos; bordas; cores; escalas; fundo; difusores de luz, dentre outras.

Os difusores², Figura 2.6, são aplicados sobre a parte iluminada dos instrumentos. É através do controle da densidade desses difusores que se permite passar mais ou menos intensidade emitida pela fonte de luz, geralmente diodos emissores de luz (LEDs, *Lighting Emitting Diodes*), controlando desta forma a homogeneidade do instrumento.

O desenvolvimento dos difusores é uma etapa complexa que demanda experiência e análises precisas da iluminação final do instrumento. O desenvolvimento da metodologia proposta neste trabalho, visa-se a retroalimentação do fabricante de painéis com importantes informações, de modo que o fabricante possa realizar um estudo mais preciso sobre a aplicação dos difusores. Será possível indicar com maior eficiência os locais precisos que precisam ser retrabalhados na fase de projeto. Com isso será reduzido tempo de desenvolvimento e aumentada a qualidade do sistema de iluminação.

²Elementos ópticos capazes de gerar uma distribuição luminosa com um formato específico, deixando passar mais ou menos luz em uma dada região.

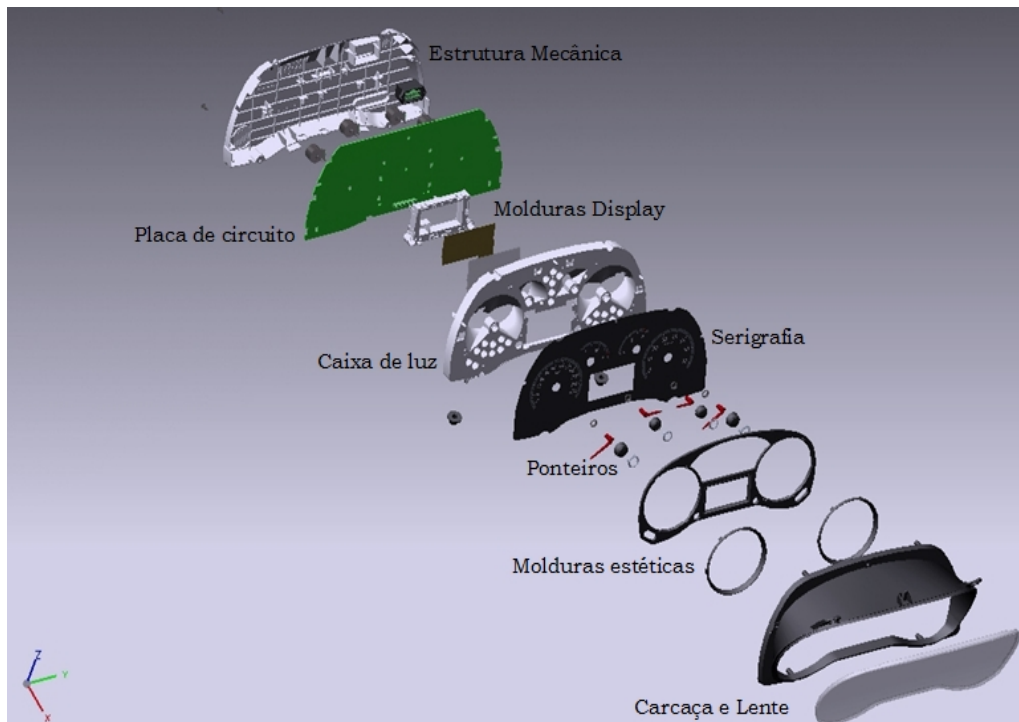


Figura 2.5: Vista explodida das partes principais de um painel de instrumento (*Imagem gentilmente cedida pela Magneti Marelli - Divisão Eletrônica*).



Figura 2.6: Um exemplo de difusor aplicado sob a serigrafia.

Capítulo 3

Fundamentação Teórica

Neste capítulo, são apresentados os aspectos teóricos necessários para o embasamento desta dissertação. O presente capítulo está organizado da seguinte forma. A Seção 3.1, é apresentada uma discussão sobre os parâmetros de fotografia que influenciam a exposição da imagem. A Seção 3.2 descreve os modelos de espaço de cores envolvidos no trabalho. Nas Seções 3.3, 3.4 e 3.5 são descritos os algoritmos utilizados para a etapa de pré-processamento. A Seção 3.6 discute os descritores utilizados para caracterizar homogeneidade e, finalmente, na Seção 3.7, são descritos os algoritmos de aprendizado de máquina utilizados para classificação dos instrumentos.

3.1 Exposição em Fotografias

Em fotografia, os parâmetros velocidade do obturador, abertura de diafragma e sensibilidade ISO são as variáveis fundamentais para a exposição do material fotossensível à luz. Tais parâmetros influenciam diretamente os padrões de iluminação, ou exposição, na captura de uma imagem (*e.g.*, veja imagens na Figura 3.1).

Pode-se definir exposição como sendo a quantidade de luz necessária para sensibilizar um filme ou um sensor em uma câmera digital (Hedgecoe, 2006). Algumas cenas são mais luminosas que outras, portanto, a quantidade de luz que atinge o elemento sensível precisa ser controlado. Tecnicamente, a exposição leva em conta os seguintes fatores:

1. Sensibilidade ISO

A sensibilidade ISO, sigla de *International Standards Organization*, antes conhecido como a “velocidade ASA” (*American Standard Association*) dos filmes de celulose, determina a sensibilidade do sensor da câmera em relação à luz. Seus valores usuais são: 80, 100, 200, 400, 800, *etc.*

Para aumentar a sensibilidade nos sensores, a câmera amplia o sinal de tensão recebido por cada elemento sensor (*e.g.*, CCD, CMOS), antes de converter o sinal em um valor

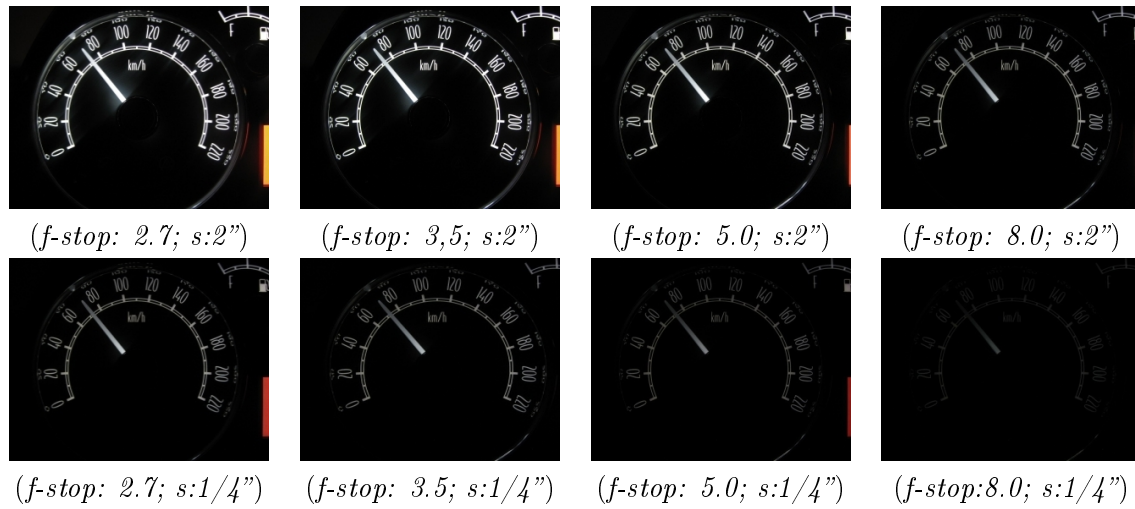


Figura 3.1: Variação dos Parâmetros: Abertura de diafragma ($f\text{-stop}$) e tempo de exposição (S).

digital. No entanto, como cada elemento sensor tem seu sinal amplificado, dependendo do aumento desta sensibilidade, anomalias podem acontecer. O resultado é que alguns *pixels* esporádicos podem apresentar valores de intensidade incorretos. Tal anomalia é conhecida como ruído. Para este trabalho a sensibilidade ISO foi ajustada em 80, a menor da câmera utilizada.

2. A **abertura do diafragma** em $f\text{-stop}$ é realizada por meio do ajuste das aletas internas que compõem o diafragma. Com maior abertura, permite-se que mais luz passe através das lentes e assim uma maior quantidade de luz irá chegar ao sensor. O tamanho da abertura do diafragma é medida em $f\text{-stop}$. O $f\text{-stop}$ é baseado na razão entre a distância focal das lentes dividido pelo diâmetro efetivo da abertura do diafragma. Por exemplo, uma lente de 50 mm com abertura de diafragma de diâmetro de 12,5 mm resulta em um $f\text{-stop}$ de $f4$ ($50/12,5=4$). O maior valor numérico de $f\text{-stop}$ indica uma menor abertura do diafragma. Os valores típicos de $f\text{-stop}$ são: $f 1; f 1.4; f 2; f 2.8; f 4; f 5.6; f 8$ e assim por diante, veja a ilustração na Figura 3.2. Observe que os números são múltiplos da raiz quadrada de dois, o que significa que entre dois passos consecutivos a relação é duplicada ou reduzida pela metade. Então, a mudança em um passo significa que a abertura é diminuída ou aumentada pelo fator de 2.

A abertura do diafragma também tem grande influência sobre a profundidade de campo (Hedgecoe, 2006). Profundidade de campo é um termo técnico de fotografia que define até que ponto os objetos situados na frente e atrás do ponto focalizado estarão em foco. Em caso de diafragmas mais fechados (números de f maiores), a profundidade de campo é grande, ao passo que em diafragmas mais abertos (números f menores) a profundidade de campo é pequena.




Figura 3.2: Valores Usuais de *f-stop*.

3. **Tempo de exposição ou velocidade do obturador** O obturador é um mecanismo complexo que controla precisamente o tempo em que a luz passa através da lente e permanece em contato com o sensor ou o filme. Velocidade de obturador se refere à quantidade de tempo que o obturador é aberto deixando passar a luz. A exposição da imagem é determinada pela combinação da velocidade do obturador, abertura do diafragma e a sensibilidade do filme/sensor. A velocidade do obturador é apresentada em segundos ou frações de segundo, por exemplo: $1''$; $1/8''$ ou $1/250''$. Os incrementos da velocidade do obturador são similares aos ajustes da abertura do diafragma, onde cada incremento ajusta para a metade ou o dobro da exposição anterior. Por exemplo, $1/60$ de segundos é a metade da exposição em relação a $1/30$ de segundos (Gimena, 2004).

Em Gimena (2004), é introduzida a seguinte fórmula para o cálculo do valor de exposição, *i.e.*:

$$VE = \log_2 \left(\frac{\text{Abertura}^2}{\text{Velocidade do Obturador}} \right) \quad (3.1)$$

Os controles de abertura e velocidade possuem uma relação conhecida como relação de reciprocidade. Quando se aumenta em um ponto um destes parâmetros, pode-se obter a mesma exposição diminuindo também em um ponto o outro parâmetro. A Tabela 3.1 apresenta os valores de exposição para parâmetros de velocidade e tempo de abertura mais comuns utilizadas em câmeras fotográficas.

A Figura 3.3 apresenta quatro fotografias, cada uma capturada com diferentes valores de abertura de diafragma e tempo de exposição, mas que representam os mesmos valores

Tabela 3.1: Valores de exposição para diferentes velocidades do obturador e aberturas do diafragma.

Abertura do Diafragma ($f - stop$)	Velocidade do Obturador (segundos)									
	1	1/2	1/4	1/8	1/16	1/30	1/60	1/125	1/250	1/500
1	0	1	2	3	4	5	6	7	8	9
1.4	1	2	3	4	5	6	7	8	9	10
2	2	3	4	5	6	7	8	9	10	11
2.8	3	4	5	6	7	8	9	10	11	12
4	4	5	6	7	8	9	10	11	12	13
5.6	5	6	7	8	9	10	11	12	13	14
8	6	7	8	9	10	11	12	13	14	15
11	7	8	9	10	11	12	13	14	15	16
16	8	9	10	11	12	13	14	15	16	17
22	9	10	11	12	13	14	15	16	17	18
32	10	11	12	13	14	15	16	17	18	19

de exposição. A Tabela 3.1 ressalta esses cálculos de exposição. Essa semelhança pode ser notada nas imagens da Figura 3.3, onde as diferenças na distribuição de iluminação são quase imperceptíveis.




Figura 3.3: (a) $f stop = 2.8$ e Velocidade = $1/8''$; (b) $f stop = 4.0$ e Velocidade = $1/4''$; (c) $f stop = 5.6$ e Velocidade = $1/2''$; (d) $f stop = 8.0$ e Velocidade = $1''$.

3.2 Espaço de Cores

Espaço de cores, também conhecido como espaço de cor ou ainda sistemas de coordenadas de cor, é uma especificação de um sistema de coordenadas tridimensionais e um subespaço dentro deste sistema onde cada cor é representada por um único ponto. Diversos modelos de cores podem ser encontrados na literatura (Gonzalez e Woods, 2007), entretanto os modelos frequentemente utilizados para o processamento de imagens são o RGB (*Red, Green, Blue*), usado por monitores coloridos e câmeras de vídeo em cores, e o modelo HSV (*Hue, Saturation, Value*), usado para manipulação de imagens coloridas (Gonzalez e Woods, 2007). Esses dois modelos são abordados a seguir.

3.2.1 Espaço RGB

O modelo RGB trata a imagem colorida como um conjunto de três canais independentes: vermelho (R), verde (G) e azul (B). O modelo RGB é representado por um cubo no plano de coordenadas cartesianas, no qual os valores de vermelho, verde e azul estão localizados nos três cantos; o ciano, magenta e amarelo estão nos outros três cantos; o preto está na origem e branco está no canto mais distante da origem. Nesse modelo, a escala de cinza estende-se do preto ao branco ao longo da linha diagonal que conecta estes dois pontos, e as cores são pontos sobre ou dentro do cubo, definidas por vetores estendendo-se a partir da origem. Por conveniência, assume-se que todos os valores de cor foram normalizados, de modo que o cubo é unitário, isto é, todos os valores de R, G e B são assumidos estar no intervalo $[0,1]$ (Gonzalez e Woods, 2007).




Figura 3.4: Espaço de cores RGB.

O modelo RGB não é capaz de representar todas as cores perceptíveis pelo sistema visual humano, mas é uma boa aproximação. Na prática, esse modelo permite que cada cor primária varie entre 0 e 255 (um *byte*), sendo portanto possível a formação de 256 valores diferentes para cada cor primária. Como existem três cores primárias, há então a possibilidade de $256 \times 256 \times 256$ combinações, resultando em um total de 16.777.216 valores possíveis. Uma variação de luminosidade ou saturação no modelo RGB varia de forma irregular dentro do espaço de cor, sendo necessárias outras formas de representação para capturar as informações de cor mais de acordo com o sistema visual humano.

3.2.2 Espaço HSV

Acharya e Ray (2005) descrevem que o espaço HSV representa as cores de uma forma mais próxima de como os seres humanos as percebem, representando-as de uma forma mais intuitiva que o modelo RGB (Foley et al., 1990). Os parâmetros utilizados nesse modelo são a matiz

(*hue*), a saturação (*saturation*) e a luminância (*value*). Matiz é um atributo que descreve uma cor pura (*e.g.*, azul, amarelo, laranja ou vermelho), enquanto saturação representa uma medida do grau de diluição de uma cor pura por uma luz branca. Cores tais como rosa (vermelho e branco) e lilás (violeta e branco) são menos saturadas, com o grau de saturação inversamente proporcional à quantidade de luz branca adicionada. A luminância, ou valor, é a intensidade de luz refletida (claro/escuro) (Gonzalez e Woods, 2007).

A representação geométrica do modelo HSV possui uma forma cônica, como ilustra a Figura 3.5. A matiz varia ao longo do perímetro do círculo do cone e é representada como um ângulo sobre o eixo vertical. Seu valor passa por vermelho (0°), amarelo (60°), verde (120°), ciano (180°), azul (240°) e magenta (300°), onde o ângulo entre os vértices é de 60° . A saturação varia ao longo da distância radial, tendo seus valores compreendidos entre 0 a 1. Uma determinada matiz possui $\frac{1}{4}$ de pureza em $S = 0,25$. Quando $S = 0$ tem-se a escala de cinza. A luminância é representada ao longo do eixo vertical do cone, variando de 0 (no vértice do cone, representa a cor preta) e 1 (na base, representando as intensidades das cores máximas).

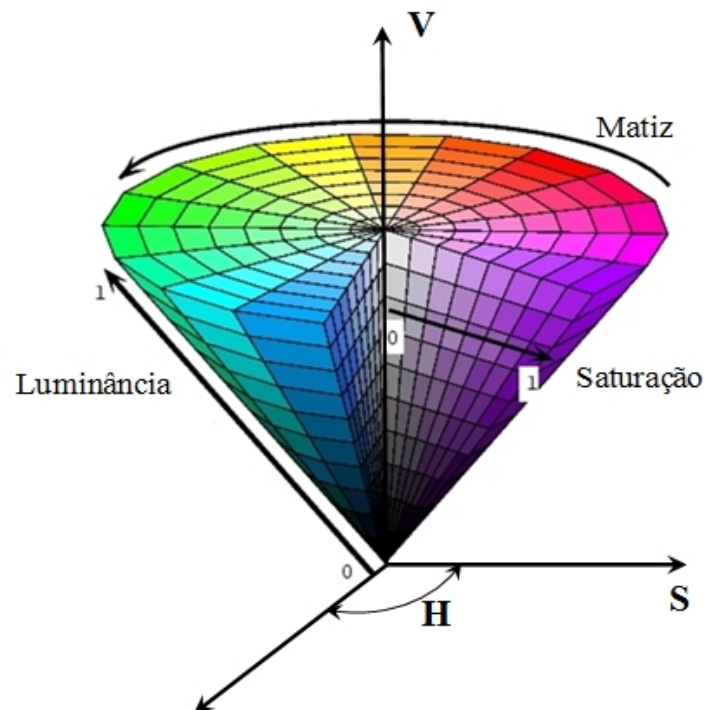


Figura 3.5: Espaço de cores HSV.

De acordo com Gonzalez e Woods (2007), esse modelo deve sua utilidade a dois fatos principais. Primeiramente, o componente de intensidade V é desacoplado de informação de cor na imagem. A importância desse desacoplamento é que o componente da intensidade pode

ser processado sem afetar o seu conteúdo de cor. Em segundo lugar, os componentes de matiz e saturação são intimamente relacionados à percepção humana de cores. Essas características tornam o modelo adequado para o desenvolvimento de algoritmos de processamento de imagens baseados em propriedades do sistema visual humano.

Nesta dissertação, em particular, trabalha-se exclusivamente sobre o canal V do modelo HSV.

3.2.3 Conversão RGB para HSV

A conversão das cores no modelo RGB para o modelo HSV é dada pelas seguintes equações (Foley et al (1990)).

$$H = \begin{cases} \frac{G-B}{max-min} * 60 & \text{se } max = R \\ 2 + \frac{G-B}{max-min} * 60 & \text{se } max = G \\ 4 + \frac{G-B}{max-min} * 60 & \text{se } max = B \end{cases} \quad (3.2)$$

$$S = \frac{max - min}{max} \quad (3.3)$$

$$V = max \quad (3.4)$$

onde max e min representam o valor máximo e mínimo entre os valores de R, G e B, respectivamente.

3.3 Limiarização

Na literatura existem diversas técnicas de limiarização, *e.g.* Niblack, Otsu, Savoula, *etc* (Sezgin, 2004). Essa técnica busca separar determinadas regiões na imagem e classificá-las em duas classes. Matematicamente, pode-se definir limiarização usando uma função que recebe uma imagem de entrada $f(x, y)$ (em níveis de cinza), e produz como saída uma imagem $g(x, y)$, denominada imagem limiarizada ou binarizada. A imagem de saída $g(x, y)$ apresenta dois valores, que obedecem a seguinte equação:

$$g(x, y) = \begin{cases} 1 & \text{se } f(x, y) > T \\ 0 & \text{se } f(x, y) \leq T \end{cases} \quad (3.5)$$

A escolha da técnica de limiarização a empregar é uma tarefa delicada, e deve ser baseada no estudo da aplicação a ser utilizada, havendo vantagens e desvantagens em cada caso.

Algoritmo de limiarização de Otsu

A limiarização de Otsu é um método de limiarização global. Este método busca um limiar ótimo que maximize a variância entre classes em um conjunto de *pixels* de uma determinada intensidade, *i.e.*, o método define automaticamente um limiar global para a imagem, de modo que separe em dois grupos de *pixels* com níveis de intensidade semelhantes entre si.

Objetivando aplicar o método, o primeiro passo é normalizar o histograma, *i.e.*,

$$p_r(r_k) = \frac{n_k}{n} \quad (3.6)$$

onde $p_r(r_k)$ é o percentual do k -ésimo nível de cinza e n_k representa o número de *pixels* cujo nível de cinza corresponde a K .

Para um determinado limiar T , há dois grupos de *pixels*; um grupo C_0 , composto pelos valores $(0, 1, 2, \dots, T - 1)$ e outro grupo C_1 , composto pelos valores $(T, T + 1, T + 2, \dots, L - 1)$.

É possível calcular a variância entre classes para um limiar T da seguinte forma:

$$\sigma^2(T) = \omega_0(T)(\mu_0(T) - \mu_{Tot})^2 + \omega_1(T)(\mu_1(T) - \mu_{Tot})^2, \quad (3.7)$$

onde: ω_0 é a probabilidade do conjunto C_0 ; ω_1 representa a probabilidade do grupo C_1 ; μ_0 é a média do grupo C_0 ; μ_1 a média do grupo C_1 e μ_{Tot} é a média total do histograma.

O valor T , que maximiza a Equação 3.7, é então tomado como o limiar para a binarização da imagem.

3.4 Operação Morfológica de Erosão

A erosão é uma operação morfológica básica em processamento de imagens (Schmitt e Mattioli, 1994; Facon, 1996) e, juntamente com a dilatação, formam a base de várias outras operações morfológicas, *e.g.*, abertura e fechamento. A operação de erosão binária tem a função de remover *pixels* das regiões que se localizam nas bordas dos objetos. Dessa forma, os objetos principais têm sua área diminuída, e os furos dentro dos objetos têm sua área aumentada.

A erosão necessita de uma máscara para ser realizada, chamada de elemento estruturante. Com essa máscara, cada *pixel* da imagem e seus vizinhos são comparados com o elemento estruturante. A erosão de uma imagem A por um elemento estruturante B , descrito como $A \ominus B$, é definida como,

$$A \ominus B = \{Z | (B)_z \cap A^c = \emptyset\}. \quad (3.8)$$

onde: A^c representa o complemento de A .

3.5 Rotulação de Componentes Conexos

Rotulação de componentes conexos pode ser definida como a tarefa de se encontrar e rotular todos os componentes conexos de uma dada imagem, de modo que exista para todo *pixel*, pertencente a um mesmo componente, um caminho conexo para todos os outros pertencentes ao mesmo componente (Jain, 1989). De acordo com Gonzalez e Woods (2007), o termo componentes conectados ou conexos é definido em termos de um caminho, e a definição de um caminho depende de sua adjacência. Observando esta afirmação, tem-se que o conceito de componente conexo depende de qual forma de adjacência escolhe-se para aplicação do algoritmo. As formas mais usuais de adjacência são a Vizinhança-4 (4 elementos adjacentes) e a Vizinhança-8 (8 elementos adjacentes). Um *pixel* p localizado à coordenada (x, y) possui dois vizinhos horizontais e verticais, cujas coordenadas são: $(x+1, y)$, $(x-1, y)$, $(x, y+1)$ e $(x, y-1)$. Este conjunto de vizinhos é chamado Vizinhança-4 (Figura 3.6 (a)). Os quatro outros vizinhos diagonais: $(x+1, y+1)$, $(x+1, y-1)$, $(x-1, y+1)$ e $(x-1, y-1)$ em conjunto com a Vizinhança-4, formam a outra forma de adjacência conhecida Vizinhança-8, como apresentado na Figura 3.6 (b).




Figura 3.6: Tipos de vizinhança para componentes conexos: (a) Vizinhança-4; (b) Vizinhança-8.

3.6 Descritores de Homogeneidade

Para descrever uma região com relação a sua homogeneidade, é necessário extrair características que possam representar o comportamento da iluminação naquela região. Na literatura, são abordados diversos métodos para caracterizar uma região quanto à sua distribuição de iluminação. Alguns destes métodos são também conhecidos como descritores de textura.

Textura é uma característica muito importante que tem sido usada para caracterização de imagens. Uma definição para textura é descrita em Archarya e Ray (2005) como sendo a repetição de padrão ou padrões sobre uma região em uma imagem.

O tamanho, forma, cor e orientação do tipo de textura podem variar em uma dada região. Essas variações podem ser devidas ao grau de intensidade desses padrões e também devida à

distribuição estatística espacial da textura sobre a imagem. Análise de texturas tem sido alvo de pesquisas em reconhecimento de padrões desde os anos 70 (Archarya e Ray, 2005). Neste trabalho, são utilizados alguns descritores de textura para determinar níveis de homogeneidade nas regiões em análise.

Cheng e Sun (2000) apresentam um método utilizando uma função com quatro parâmetros: a) Valor de borda, usando um operador de Sobel (Jain, 1989); b) Entropia, descrevendo a variação da intensidade em uma região; c) Gama para descrever a impulsividade da distribuição; e d) Desvio padrão, para calcular a dispersão da intensidade.

Oh et al. (2007) definem uniformidade de iluminação como sendo a razão entre as intensidades mínima e máxima, *i.e.*,

$$UL(I) = \left(\frac{Lmin}{Lmax} \right) \times 100, \quad (3.9)$$

onde $Lmin$ e $Lmax$ representam a intensidade mínima e máxima em uma região, respectivamente.

Lee e Yoo (2004) propõem um método automático para detecção de MURA. Este método é dividido em duas fases distintas: a primeira utilizando uma adaptação do método *Regression Diagnostics* e limiarização de Niblack (Niblack, 1986) para segmentar regiões candidatas a MURA. Na segunda fase é quantificado o nível de MURA para cada candidata. A medição do nível de MURA é definida pela equação

$$QI = (|Io - Ib|)/(1,97/A^{0,33}) + 0,72 \quad (3.10)$$

onde Io , Ib e A representam a intensidade do objeto, a intensidade do *background* e a área do objeto, respectivamente.

Gonzalez e Woods (2007) e Pratt (1991) abordam a distribuição de intensidade em uma imagem utilizando momentos estatísticos do histograma referentes aos níveis de intensidade em uma dada região. Seja z uma variável randômica para descrever intensidade e seja $p(z_i)$, $i = 0, 1, 2, \dots, L - 1$, a função de probabilidade do histograma correspondente, onde L é o número de níveis de intensidade distintos. O n -ésimo momento de z sobre a média é descrito como:

$$\mu_n(z) = \sum_{i=0}^{L-1} (z_i - m)^n p(z_i), \quad (3.11)$$

onde m é a média dos valores de z (a intensidade média), *i.e.*,

$$m = \sum_{i=0}^{L-1} (z_i \times p(z_i)). \quad (3.12)$$

Logo, definem-se os seguintes descritores de homogeneidade para uma dada região em função de $p(z_i)$:

$$\sigma = \sqrt{\mu_2(z)} = \sqrt{\sigma^2}, \quad (3.13)$$

$$\mu_3(I) = \sum_{i=0}^{L-1} (z_i - m)^3 p(z_i), \quad (3.14)$$

$$R(I) = 1 - 1/(1 + \sigma^2), \quad (3.15)$$

$$U(I) = \sum_{i=0}^{L-1} p^2(z_i), \quad (3.16)$$

$$e = - \sum_{i=0}^{L-1} p(z_i) \times \log_2 p(z_i), \quad (3.17)$$

onde σ representa o desvio padrão, $\mu_3(I)$ representa o *skewness*, $R(I)$ representa a suavidade, $U(I)$ representa a uniformidade e e a entropia. Ressalta-se que o segundo momento (μ_2) representa a variância.

Discussão sobre os descritores

A Figura 3.7 apresenta imagens com diversos tipos de texturas. Da imagem central, foram selecionadas 11 diferentes regiões. Essas regiões estão ampliadas ao redor da imagem central. Para cada região, foram calculados alguns dos descritores relacionados anteriormente. A Tabela 3.2 apresenta os valores dos descritores para as 11 regiões selecionadas. Foram extraídos também os respectivos histogramas apresentados na Figura 3.8.

Observando as regiões selecionadas e seus respectivos histogramas e descritores, é possível realizar importantes análises. O objetivo dessas análises é compreender melhor as características dos descritores e a relação existente entre eles. Essas análises são reportadas a seguir:

- Observa-se que a região 11 (Figura 3.7) possui a maior entropia calculada dentre as regiões. Isto é devido à distribuição dos *pixels* nesta região possuir maior variabilidade de valor que os *pixels* de outras regiões, característica observada pelo seu histograma;
- O Desvio Padrão descreve a variação de níveis de intensidade em uma região, porém nem sempre este valor sozinho pode definir bem uma região em questão de homogeneidade percebida, *e.g.*, as regiões 4 e 5 possuem praticamente valores iguais de Desvio Padrão, porém visualmente percebe-se que a região 5 possui uma distribuição mais suave, não apresentando mudanças tão bruscas de intensidade como a região 4;
- Outro detalhe interessante é observado em relação aos descritores Desvio Padrão e Suavidade. Embora os dois possuam quase a mesma ordem crescente para classificar as regiões, a escala entre os valores de Suavidade (variando entre 0,0006 e 0,0201) é cerca

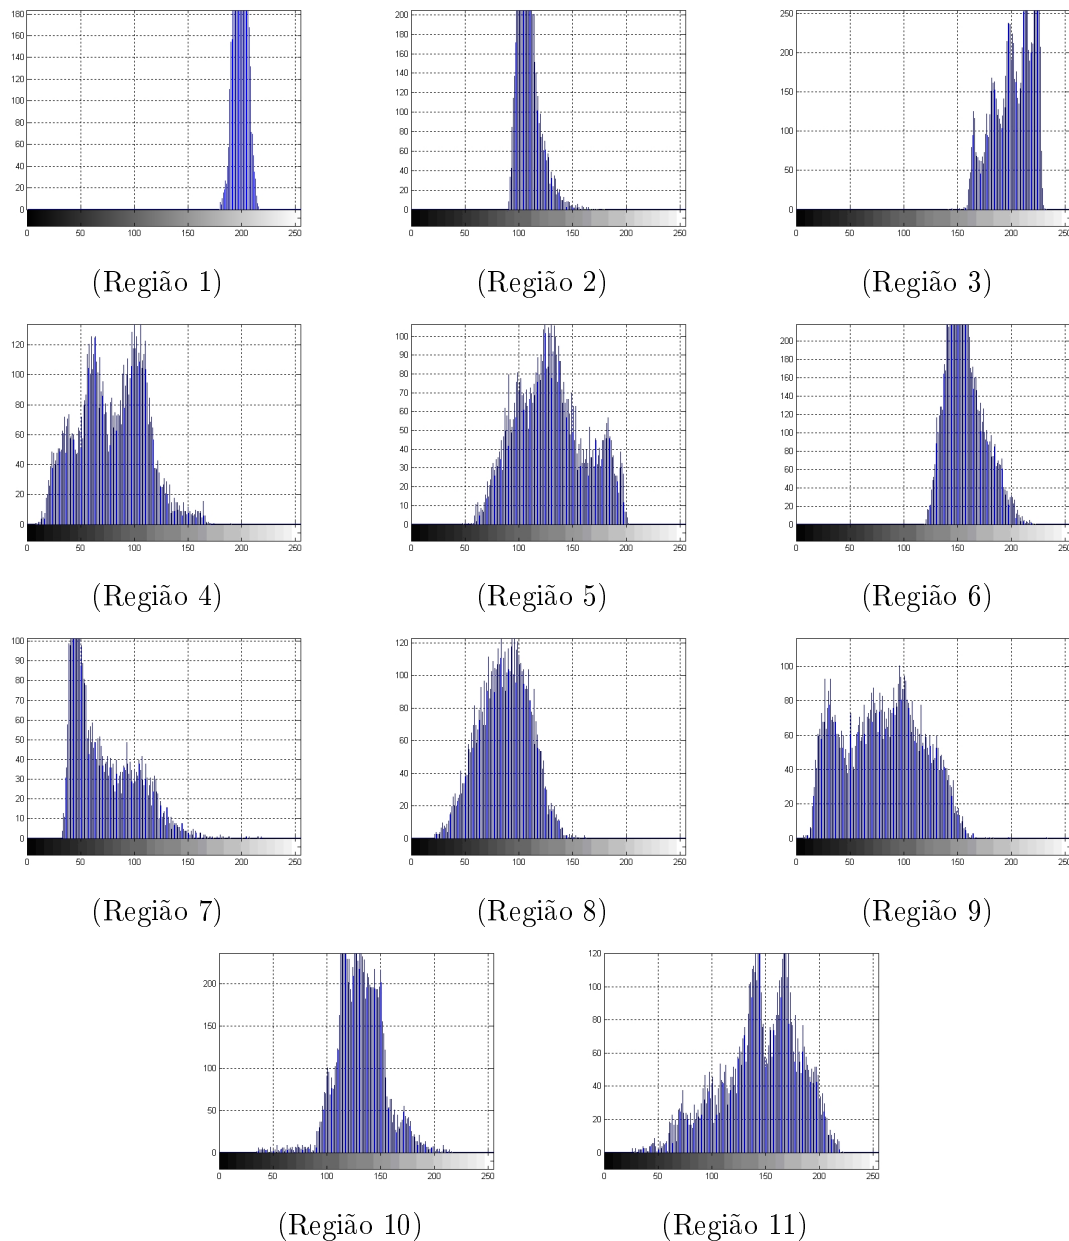


Figura 3.8: Histogramas para cada região destacada na Figura 3.7.

supervisionada. No aprendizado supervisionado, o sistema precisa conhecer o ambiente. Tem-se o papel de um “professor externo” o qual fornece exemplos contendo: entrada e saída desejada (Haykin, 1997). Então, a partir desses exemplos, o algoritmo começa a “aprender”. Já no aprendizado não supervisionado, não há exemplos de valores de saída desejados, ou seja, não existe um professor. O algoritmo, nesse último tipo, procura, a partir dos dados de entrada, criar uma certa compreensão dos dados e fornecer uma representação interna capaz de codificar as características de entrada em novas classes e agrupá-las corretamente.

Tabela 3.2: Análise dos descritores para cada região apresentada na Figura 3.7.

Região	D.Padrão 1	Unif.(Oh) 2	Suavidade 3	Skewness 4	Unif. 5	Entropia 6
1	6,09	82,87	0,0006	-0,0004	0,0460	4,63
2	10,63	50,84	0,0017	0,0273	0,0330	5,23
3	18,44	60,34	0,0052	-0,0525	0,0192	5,91
4	31,32	4,21	0,0149	0,0463	0,0094	6,91
5	32,19	23,76	0,0157	0,1027	0,0089	6,95
6	17,84	52,23	0,0049	0,0538	0,0168	6,12
7	29,75	15,14	0,0134	0,4104	0,0163	6,42
8	23,29	13,58	0,0083	-0,0210	0,0119	6,56
9	36,51	3,00	0,0201	0,0337	0,0078	7,09
10	22,39	16,06	0,0076	-0,0005	0,0145	6,42
11	36,34	11,71	0,0199	-0,3947	0,0086	7,10

Um aspecto muito importante quando se fala de aprendizado de máquina é o aspecto de generalização do classificador, que significa a capacidade de prever corretamente dados que não foram apresentados na fase de treinamento. Quando um classificador se especializa muito nos dados que foram apresentados em seu treinamento, corre-se o risco de haver uma taxa de acerto muito baixa quando se apresenta novos dados. Tal fenômeno chama-se sobre-ajuste ou *overfitting*. Também, pode ocorrer o sub-ajuste ou *underfitting*, que é consequência de um mau treinamento. Neste caso, o conjunto de dados apresentado para treinamento, é pouco representativo com relação ao universo de dados ao qual se deseja trabalhar.

Na execução deste trabalho, é utilizado o aprendizado supervisionado, pois os rótulos das regiões para o treinamento são conhecidos, devido à etapa de avaliação subjetiva. Foram utilizados dois algoritmos de aprendizado de máquina: Redes Neurais Artificiais (Artificial Neural Networks - ANN) e Máquina de Vetores de Suporte (Support Vector Machine - SVM).

3.7.1 Redes Neurais Artificiais

Na literatura, encontram-se várias definições de Redes Neurais Artificiais (ANN). Sivanandam et al. (2006) definem ANN como sendo sistemas computacionais inspirados em neurônios biológicos humanos e na estrutura paralela do cérebro, com capacidade de adquirir, armazenar e utilizar conhecimento experimental. Em Haykin (1997), são apresentadas as seguintes definições para ANN: ANN é um processamento paralelo massivo feito por unidades simples de processamento, o qual possui uma propensão natural para armazenar conhecimento experimental e o disponibilizar para aplicação; ANN é um circuito composto de um grande número de elementos simples de processamento; ANN é a disciplina tecnológica interessada no processamento de informação paralela, distribuída e adaptativa.

A aprendizagem das redes neurais é realizada quando modificações ocorrem nas sinapses,

essas mudanças ocorrem de acordo com o processo de ativação dos neurônios.

Um breve histórico sobre Redes Neurais Artificiais

Fruto dos primeiros estudos sobre ANN, em 1943, foi publicado o artigo “*A logical calculus of the ideas Immanent in nervous activity*”, escrito pelo biólogo McCulloch e o matemático Pitts (McCulloch e Pitts, 1943). No artigo são estabelecidas algumas das principais bases da neurocomputação.

Já em Hebb (1949), propõe-se a regra de modificação dos pesos sinápticos, criando assim um modelo de aprendizado das redes baseadas em neuroprocessamento. Logo mais, Rosenblatt (1958) desenvolveu o *Perceptron*, utilizado na primeira aplicação de uma ANN para reconhecimento de padrões. Logo em seguida, Widrow e Hoff (1960) desenvolvem a chamada *Adaline* (*Adaptive Linear Element*), e junto com ela uma eficiente lei de aprendizado chamada algoritmo da média dos mínimos quadrados (*LMS - Least Mean Square*). Porém tanto a *Adaline* quanto o *Perceptron*, com uma única camada de neurônios, apresentavam limitações.

Mais tarde Rosenblatt e Widrow apresentaram trabalhos com ANN de múltiplas camadas a fim de superar algumas das limitações dos modelos iniciais. Devido a limitações tecnológicas, o fim dos anos 60 e anos 70 foram marcados por pouco progresso no campo das ANN. Nos anos 80, os estudos ressurgem com grande força impulsionados por trabalho de Hopfield (1982), neste trabalho foram apresentadas as bases do algoritmo de retropropagação (*Back-propagation*) utilizado para treinar perceptrons conectados.

Hoje impulsionadas não somente pelo avanço da tecnologia disponível e grandes grupos de pesquisas dedicados aos estudos da ANN, as aplicações para este ramo estendem-se por quase toda cadeia tecnológica de diversas áreas, indo além de onde seus primeiros idealizadores poderiam imaginar.

O neurônio biológico

O cérebro humano é responsável pela tomada de inúmeras decisões e adaptação ao meio onde está contido, por meio de um aprendizado contínuo e acumulativo. O neurônio biológico é a unidade básica da complexa estrutura do cérebro. A Figura 3.9 apresenta um esquema de um neurônio biológico. Ele é dividido em partes conectadas e com funções bem específicas. Os dendritos têm como sua função principal receber os impulsos nervosos de origem de outros neurônios e canalizá-los até o corpo celular. O corpo celular e o núcleo são onde os impulsos são recebidos e processados. Como resultado deste processamento, novos impulsos são gerados e transmitidos através do axônio para as extremidades do neurônio. Esses, por sua vez, são transmitidos para outros neurônios através das sinapses. Dependendo dos sinais enviados pelos axônios, as sinapses possuem função excitatória ou inibitória, contribuindo ou não para formação do impulso nervoso de saída.

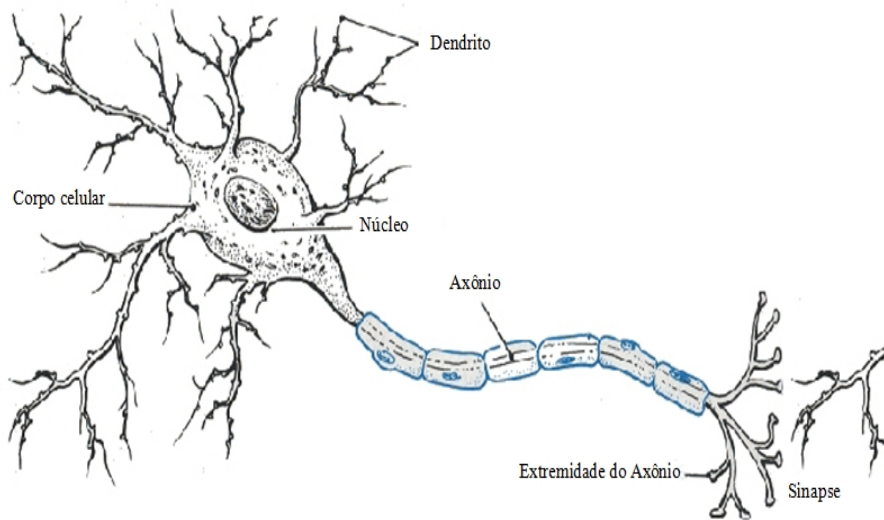


Figura 3.9: Neurônio Biológico.

Resumidamente pode-se dizer que um neurônio biológico é uma célula que, ao sofrer um estímulo em sua entrada, gera uma saída que é enviada para outros neurônios. Tal saída dependerá da força de cada uma das entradas e suas conexões associadas, ou seja, as sinapses. Então a sinapse pode excitar ou inibir um neurônio, aumentando ou diminuindo sua saída.

Neurônio artificial

O neurônio artificial é o elemento básico de uma ANN.

Como dito no início dessa seção, sua forma básica foi proposta por McCulloch e Pitts (1943). Uma representação de neurônio artificial é apresentada na Figura 3.10. Sua estrutura é composta por:

- Um conjunto de n entradas $x_1, x_2, x_3, \dots, x_n$, emulando os dendritos em um neurônio biológico,
- Cada entrada é ponderada por um peso sináptico acoplado, *i.e.*, $p_1, p_2, p_3, \dots, p_n$;
- O resultado das entradas ponderado pelos pesos sinápticos chega até um somador ou junção aditiva, gerando uma saída v , *i.e.*,

$$v = \sum_{j=0}^n p_j \cdot x_j, \quad (3.18)$$

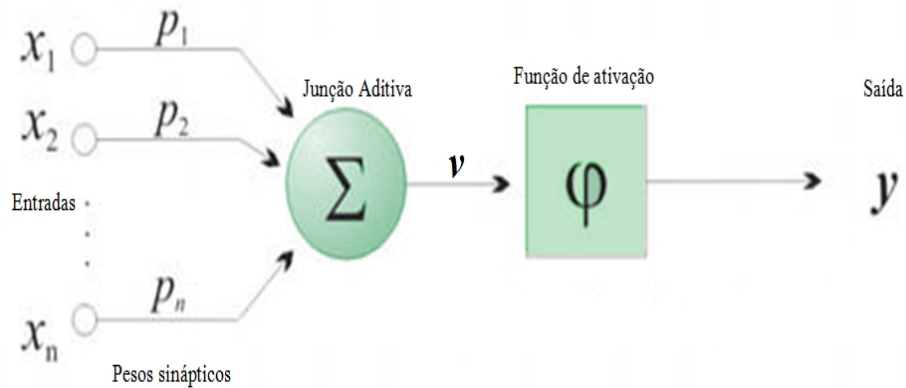


Figura 3.10: Neurônio Artificial.

A saída y do neurônio artificial é obtida pela aplicação de uma função f à saída v , indicada por:

$$y = f(v) \quad (3.19)$$

onde f é uma função de ativação, para restringir a amplitude de saída de um neurônio.

Funções de ativação

As funções de ativação são usadas para calcular a resposta (saída) de um neurônio. A soma dos sinais de entrada, após passar pelos seus respectivos pesos sinápticos, chega até uma função de ativação a fim de se obter uma resposta. A função de ativação possui também o objetivo de restringir a amplitude de saída de um neurônio, por exemplo, ao intervalo $[0,1]$ ou $[-1,1]$.

As funções de ativação podem ser lineares ou não-lineares, essas últimas são mais usadas nas redes *perceptrons*, definidas na próxima seção. As funções mais utilizadas são:

1. Função linear;
2. Função rampa;
3. Função degrau;
4. Função hiperbólica;
5. Função sigmoide.

A Figura 3.11 apresenta um esboço dos gráficos destas funções.




Figura 3.11: (a) Função linear; (b) Função rampa; (c) Função degrau; (d) Função tangente hiperbólica; (e) Função sigmoideal.

Redes *Perceptron* de múltiplas camadas

Uma rede *Perceptron* de Múltiplas Camadas (*Multilayer Perceptron - MLP*) é um conjunto de neurônios artificiais ligados por conexões sinápticas e divididas em camadas: camadas de entrada; camadas intermediárias ou ocultas e camada de saída (Haykin, 1997). Nesse trabalho, é descrito que uma MLP possui três características distintas:

1. O modelo de cada neurônio inclui uma função de ativação não linear suave. A função comumente utilizada é a sigmoideal;
2. As redes contêm uma ou mais camadas ocultas que não são parte da entrada ou da saída da rede. A grande importância dessas camadas ocultas é a capacidade que elas trazem à rede de aprender tarefas complexas, extraindo progressivamente características mais significativas dos dados de entrada;
3. A rede possui um alto grau de conectividade, determinada pelas sinapses. Uma mudança da conectividade na rede requer uma mudança na população das conexões sinápticas ou pesos.

Método de treinamento Levenberg-Marquardt

O algoritmo de *Levenberg-Marquardt* é uma técnica iterativa para encontrar o mínimo de uma dada função. Este algoritmo é considerado um dos métodos mais rápidos para treinamento de redes *Feedforward Backpropagation*. A restrição deste algoritmo é que a rede possua uma quantidade não muito extensa de neurônios na camada de entrada. Para acelerar o treinamento da rede, esse algoritmo baseia-se na determinação de derivadas de segunda ordem do erro quadrático em relação os pesos, diferindo do algoritmo *backpropagation* tradicional que utiliza

derivadas de primeira ordem. Esse algoritmo apresenta convergência em menos iterações, mas em contrapartida requer mais cálculos por iteração. Mesmo devido ao grande esforço computacional, o algoritmo de *Levenberg-Marquardt* ainda é mais rápido para treinamento de redes neurais em relação a outros algoritmos (Santos, 2008), levando em conta sua restrição: quantidade não muito grande de neurônios na camada de entrada.

3.7.2 Máquina de Vetores de Suporte

A máquina de vetores de suporte ou *support vector machine (SVM)* é um algoritmo relativamente recente de aprendizado de máquina. Essa teoria foi originalmente proposta no início dos anos 90 por Boser et al. (1992), e é considerada o estado da arte em técnicas de reconhecimento de padrões (Sivanandam et al., 2006).

A máquinas de vetores de suporte vêm recebendo crescente atenção nos últimos anos, sendo utilizadas em diversas tarefas e em diversas esferas de aplicação com resultados promissores (Lorena e Carvalho, 2007).

De acordo com Haykin (1997), a ideia principal da SVM é construir um hiperplano no espaço de característica, de modo que a margem de separação entre os padrões positivos e negativos seja maximizada. O algoritmo SVM atinge essa propriedade seguindo a abordagem baseada na teoria do aprendizado estatístico. Mais precisamente a SVM é uma aproximação da implementação do método de minimização do risco estrutural (*structural risk minimization - SRM*). Este princípio indutivo é baseado no fato que a razão do erro em um aprendizado de máquina, nos dados de teste, é limitado pela soma do erro de teste e um termo que depende da dimensão VC (originada em homenagem aos seus criadores *i.e.*, Vapnik e Chervonenkis).

Uma noção central do problema de construção do algoritmo SVM é o produto interno “*kernel*” entre os vetores de suporte x_i e o vetor x tirado do espaço de entrada. Os vetores de suporte consistem em um pequeno subconjunto dos dados de treinamento extraídos pelo algoritmo. Dependendo de como o produto interno é gerado, pode-se construir diferentes máquinas de aprendizado. Essas máquinas ficam caracterizadas pela superfície de decisão não linear.

SVM linear

Considere uma amostra de treinamento $\mathfrak{S} = (x_i, d_i)_{i=1}^N$ onde x_i representa os padrões de entrada e d_i a resposta desejada correspondente (*target*). Inicialmente, é assumido que os padrões representados pelo subconjunto $d_i = +1$ e os padrões representados pelo subconjunto $d_i = -1$ são linearmente separáveis. A superfície de decisão será representada por um hiperplano, definido da seguinte forma:

$$w \cdot x + b = 0 \tag{3.20}$$

onde x é um vetor de entrada, w é um vetor peso ajustável normal ao hiperplano e b é um *bias*.

Para um dado vetor peso w e um *bias* b , a separação entre o hiperplano definida pela Equação 3.20 e o ponto mais próximo deste hiperplano é chamado *margem de separação*, denotado por ρ . O objetivo da SVM é encontrar um hiperplano particular para o qual a *margem de separação* ρ é maximizada. Sobre estas condições, o plano de decisão é dito como hiperplano ótimo (H_0). A Figura 3.12 ilustra a construção geométrica de um hiperplano ótimo para uma entrada bi-dimensional linearmente separável.

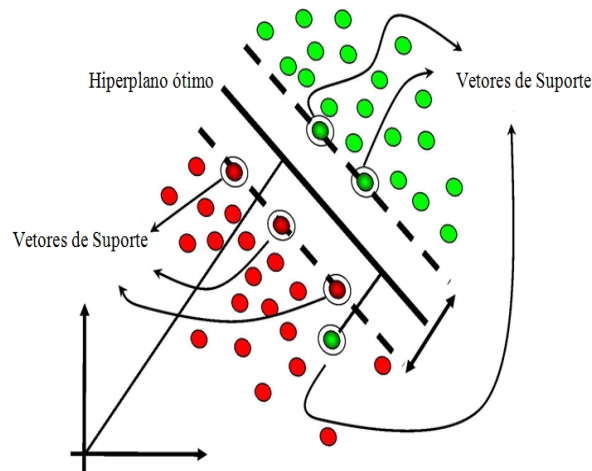


Figura 3.12: Exemplo de um hiperplano ótimo para padrões separáveis linearmente.

Sejam os pontos (x_i, d_i) para a qual a primeira ou a segunda inequações da Equação 3.21 são satisfeitas com o sinal de igualdade. Tais pontos são chamados *vetores de suporte*. Daí o nome “*Máquina de Vetores de Suporte*”.

Considere os sub-espacos definidos pelas seguintes inequações:

$$\begin{cases} w^T x_i + b \geq 1, & \text{para } d_i = +1 \\ w^T x_i + b \leq -1, & \text{para } d_i = -1 \end{cases} \quad (3.21)$$

As inequações descritas na primeira e segunda linha da Equação 3.21 são representadas pelos planos: $H_1 = w \cdot x + b = 1$, com normal w e distância perpendicular a origem de $|1 - b|/||w||$ e $H_{-1} = w \cdot x + b = -1$, com normal w e distância perpendicular a origem de $|-1 - b|/||w||$, ambos ilustrados na Figura 3.13.

Dessa forma, $r^+ = r^- = 1/||w||$ representam a largura da *margem* (ρ). Tem-se então que ρ descreve o valor ótimo da *margem de separação* entre as duas classes que constituem o conjunto de treinamento \mathfrak{S} , portanto,




Figura 3.13: Interpretação geométrica da distância algébrica de um ponto para o hiperplano ótimo.

$$\begin{cases} \rho = 2.r \\ = \frac{2}{\|w_0\|} \end{cases} \quad (3.22)$$

A Equação 3.22 informa que a margem de maximização entre as classes é equivalente a minimização da normal euclidiana do vetor peso w . Resumindo, o hiperplano ótimo (H_0) definido pela Equação 3.20, é único no sentido que o vetor peso w_0 ótimo contém a separação máxima possível entre os exemplos positivos e negativos. Esta condição ótima é atingida pela minimização euclidiana normal ao vetor de peso w .

Pelo exposto anteriormente podemos definir o problema a ser resolvido pelo SVM linear como: “*Dado um conjunto de treinamento \mathfrak{S} , encontrar os valores ótimos do vetor de pesos w e o bias b , que satisfaçam a restrição: $d_i(w^T x_i + b) \geq 1$ para $i = 1, 2, \dots, N.$, e o vetor de pesos w que minimize a função de custo definido pela seguinte equação:*”.

$$\Phi(w) = \frac{1}{2}(w^T \cdot w) \quad (3.23)$$

SVMs não lineares

A SVM apresentado na seção anterior é eficaz para classificação de conjuntos de dados linearmente separáveis, ou ainda mesmo quando possuem uma distribuição quase linear, com alguns ruídos e discrepâncias (*outliers*). Neste último caso, fazendo-se uso da SVM linear com margens suaves (Lorena e Carvalho, 2007; Haykin, 1997).

Contudo, em aplicações reais, dados com distribuições lineares são difíceis de se encontrar.

Em tais casos não é possível dividir, de forma eficaz, os dados de treinamento por um hiperplano. Dessa forma, se faz necessária a mudança dimensional do espaço onde o conjunto de treinamento é mapeado. Um exemplo é apresentado pela Figura 3.14.




Figura 3.14: SVM não linear:(a) Conjunto de dados (não lineares); (b) Fronteira não linear do espaço de entrada; (c) Fronteira linear no espaço de características.

Para dados que não são linearmente separáveis, a solução é uma extensão das técnicas apresentadas anteriormente. Para os casos não lineares, o conjunto de treinamento é mapeado em um espaço de maior dimensão, conhecido como espaço de características (Cortes e Vapnik, 1995). Seja $\Phi : X \rightarrow \psi$ um mapeamento, onde X é o espaço original dos dados de entrada e seja ψ o espaço de característica. De modo que ao encontrarmos um mapeamento Φ adequado aos dados que se está trabalhando, é possível que o conjunto de treinamento, agora mapeado em ψ , possa ter uma separação realizada por uma SVM linear. Desta forma é possível encontrar um hiperplano com maior margem de separação.

Para o mapeamento, é necessário realizar o cálculo de produtos escalares entre os dados no espaço de características ψ , pois sempre existe $\Phi(x_i) \cdot \Phi(x_j)$ para os dados de entrada x_i, x_j . Esse produto é obtido através de funções chamadas “*Kernels*”. Então, um *Kernel* K é uma função que recebe dois pontos do espaço de entradas e realiza o produto escalar desses dados no espaço de característica.

$$K(x_i, x_j) = \Phi(x_i) \cdot \Phi(x_j) \quad (3.24)$$

Os *kernels* mais aplicados em problemas práticos (Lorena e Carvalho, 2007; Haykin, 1997), são apresentados na Tabela 3.3.

Tabela 3.3: Principais *kernels* utilizados para SVM não lineares.

Tipo de Kernel	Função	Observações
Polinomial	$(x_i^T \cdot x_j + 1)^p$	A potência p é definida pelo usuário
Gaussiano (RBF)	$e^{(-\frac{1}{2\sigma^2} \ x_i - x_j\ ^2)}$	A amplitude σ é definida pelo usuário
Sigmoidal	$\tanh(\beta_0 x_i \cdot x_j + \beta_1)$	Utilizado somente para alguns valores de β_0 e β_1

3.8 Considerações

Neste capítulo, foram descritos conceitos teóricos fundamentais que serão aplicados ao longo deste trabalho. A Seção 3.1 é utilizada para a decisão do método de captura das imagens dos instrumentos. As Seções 3.2, 3.3, 3.4 e 3.5 são utilizadas para o pré-processamento da imagem, enquanto que as Seções 3.6 e 3.7 são a base para a extração de características e classificação das regiões presentes nos instrumentos.

Capítulo 4

Metodologia

Neste capítulo, é apresentada a metodologia aplicada no presente trabalho para identificar, de forma automática, regiões de iluminação não homogêneas através de análise de imagens.

Na próxima seção, é apresentada de forma sucinta a metodologia proposta e nas demais seções um aprofundamento em cada passo.

4.1 Descrição Geral da Metodologia

Na Figura 4.1, é apresentado um esquema geral da metodologia proposta para validação automática do sistema de iluminação interna de um automóvel.

Inicialmente é realizado o processo de extração de características das regiões de cada instrumento. Essas características, ou descritores, juntamente com a rotulação realizada pelo avaliador servirão de base para a fase de aprendizado supervisionado dos algoritmos de classificação. Com a fase de treinamento realizada, é o momento de efetuar a classificação automática das regiões entre homogêneas e não homogêneas. A validação da classificação é realizada efetuando uma comparação entre as avaliações realizadas pelos usuários e a classificação realizada pela RNA e pela SVM. A seguir, é detalhada cada etapa do processo da metodologia.

4.2 Extração de Características

Esta etapa é iniciada com uma calibração da câmera digital, visando identificar os parâmetros de abertura e tempo de exposição, para a correta captura das imagens.

Uma vez capturada, a imagem é pré-processada, a fim de extrair seus componentes conexos, que são as regiões a serem analisadas. A partir da imagem processada, descritores de homogeneidade são extraídos de cada região.

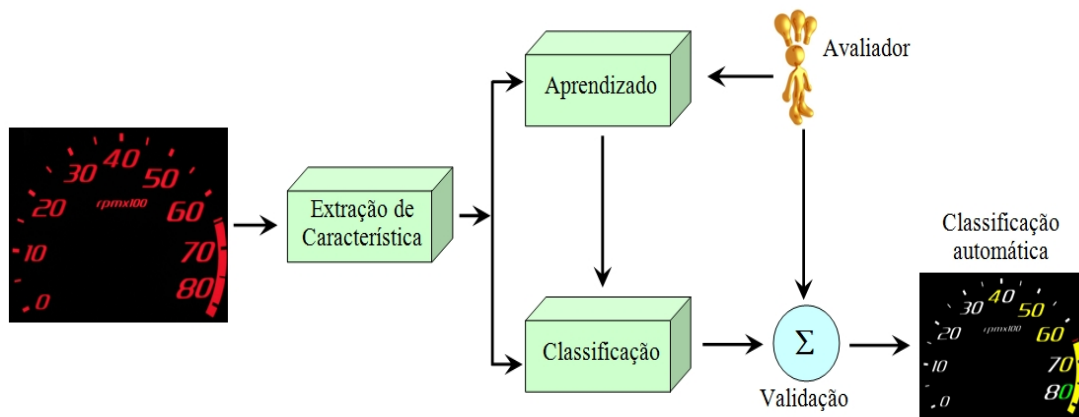


Figura 4.1: Diagrama da Metodologia Proposta.



Figura 4.2: Diagrama do método para extração de características.

4.2.1 Calibração Radiométrica e Aquisição de Imagem

A metodologia proposta neste trabalho é altamente dependente da distribuição luminosa das imagens adquiridas. Desta forma, é fundamental que as imagens, que serão trabalhadas reproduzam da forma mais consistente possível os padrões de iluminação do instrumento em análise.

Para conseguir tal reprodução, é feito um confronto entre medidas efetuadas com o espectrofotômetro e imagens adquiridas através de câmera digital. Essas são tiradas com diferentes

tempos de exposição. O objetivo é identificar os parâmetros de câmera conseguem reproduzir de forma adequada a distribuição de iluminação encontrada pelas leituras efetuadas com o espectrofotômetro.

Com base na relação de reciprocidade que o tempo de exposição e abertura do diafragma possuem entre si, foi estabelecido fixar o valor de abertura de diafragma em 2.7. Dessa forma, somente o tempo de exposição é variado. O valor de 2.7 é o maior da câmera em utilização. A escolha deste valor se deve a dois motivos:

- Com o maior valor de abertura do diafragma é possível obter tempos de exposição menores, dessa forma diminui-se a possibilidade de ocorrência de ruído;
- Como o objeto a ser fotografado está em um plano paralelo ao sensor da câmera utilizada, não há necessidade de uma profundidade de campo grande, uma vez que todo o objeto a ser fotografado está em um único plano.

Com as imagens capturadas, deve-se comparar as medidas realizadas com o espectrofotômetro e os valores de *pixel* correspondentes (Figura 4.3). Para cada região onde serão feitas as medições com o espectrofotômetro, deve-se realizar uma média dos valores dos *pixels* daquela região. Uma medida para análise da comparação é definida e a escolha do tempo de exposição é estabelecida pelo menor erro.




Figura 4.3: Leitura dos valores no canal V nos pontos medidos: (a) Seleção da região para leitura; (b) Valores dos *pixels* indicados pelo círculo em (a).

4.2.2 Pré-processamento da Imagem

A fim de identificar as várias regiões existentes em cada imagem de instrumento para posteriormente realizar a extração dos descritores de homogeneidade em cada região encontrada, é realizado um pré-processamento nas imagens capturadas. A imagem original é submetida aos seguintes passos:

Conversão do espaço de cores

Nesta etapa, é realizada a conversão do espaço de cores, transformando a imagem original em RGB para o espaço de cores HSV. Escolheu-se o modelo HSV pois o mesmo é capaz de descrever a cor e a intensidade em canais distintos, desta forma é possível trabalhar com uma variável livre da influência da outra. O canal V (valor/intensidade/brilho/luminância) é levado em conta como sendo o representante da intensidade da luz. A Figura 4.4 apresenta um exemplo desta etapa.



Figura 4.4: Conversão do espaço de cores: (a) Figura original; (b) Canal V, do espaço HSV, correspondente à imagem de (a).

Limiarização

Para realização da limiarização, sobre a imagem de entrada, é aplicado o algoritmo de OTSU (Otsu, 1979).




Figura 4.5: Limiarização: (a) Canal V, do espaço HSV; (b) Após algoritmo de limiarização de Otsu.

O objetivo desta etapa é separar na imagem o objeto do fundo (Figura 4.5), simplificando a análise da próxima etapa.

Erosão

A erosão tem como propósito, neste trabalho, eliminar os *pixels* indesejados de borda devido ao processo de amostragem/digitalização. Para este trabalho foi utilizado um elemento estru-

turante circular (totalmente preenchido) com diâmetro de 5 *pixels*. A Figura 4.6 apresenta a etapa de erosão sobre uma imagem e o detalhe da região erodida.




Figura 4.6: Erosão: (a) Imagem binarizada; (b) Imagem de (a) erodida; (c) Detalhe da região erodida (ressaltada em verde) de (b).

Rotulação dos Componentes Conexos

Esse algoritmo é utilizado para identificar as várias regiões conexas presentes na imagem do instrumento em análise, para que posteriormente seja feita a avaliação em cada região encontrada (Shapiro e Stockman, 2002). Na Figura 4.7, é apresentada uma imagem e sua respectiva rotulação.




Figura 4.7: Rotulação: (a) Imagem após binarização + erosão; (b) Componentes conexas.

4.2.3 Extração dos Descritores de Homogeneidade

Após a etapa de pré-processamento da imagem, tendo encontrado as regiões de interesse do instrumento, são extraídos os descritores que descrevem a homogeneidade da iluminação em cada região.

Descritores utilizados

Existem na literatura diversos métodos propostos para calcular a homogeneidade em uma região na imagem, como apresentado no Capítulo 3. Para a execução deste trabalho, foram

selecionados os seguintes descritores para caracterizar as regiões quanto a sua homogeneidade:

1. Desvio padrão: Descreve a dispersão dos valores de intensidade z_i de um conjunto. Dessa forma, define-se o desvio padrão como sendo a raiz quadrada do erro quadrático médio em relação a média:

$$\sigma(I) = \sqrt{\frac{1}{N} \sum_{i=1}^N (z_i - m)^2}. \quad (4.1)$$

onde m é a média dos níveis de intensidade, conforme definido no Capítulo 3;

2. Uniformidade:

$$U(I) = \sum_{i=0}^{L-1} p^2(z_i). \quad (4.2)$$

Seu valor é máximo quando todos os níveis de intensidade são iguais e seu valor decresce com o aumento das diferenças entre os níveis;

3. 3º Momento ou *Skewness*: O terceiro momento central é geralmente chamado de medida da assimetria ou *skewness* da distribuição e descreve a inclinação do histograma da região em análise, *i.e.*,

$$\mu_3(I) = \sum_{i=0}^{L-1} (z_i - m)^3 p(z_i). \quad (4.3)$$

A distribuição uniforme e normal são exemplos de distribuições simétricas e as distribuições gama e exponencial são exemplos de distribuições assimétricas (Martinez e Martinez, 2005). Distribuições que são inclinadas para a esquerda irão possuir um coeficiente negativo de *skewness* e distribuições que são inclinadas para a direita irão receber coeficientes positivo de *skewness*. *Skewness* é um número puro que representa somente a forma da distribuição;

4. Entropia: Este descritor é usado para caracterizar a diversidade da distribuição em uma região, também conhecido como medida de aleatoriedade (Gonzalez e Woods, 2007).

$$e(I) = - \sum_{i=0}^{L-1} p(z_i) \times \log_2 p(z_i). \quad (4.4)$$

A entropia tem valor máximo quando todos os níveis de intensidade ocorrem com igual frequência, correspondendo a um histograma uniforme. Ela possui um valor mínimo de zero quando todos os *pixels* tiverem a mesma intensidade;

5. Suavidade: Descreve a medida da suavidade relativa da distribuição das intensidades em uma região (Gonzalez e Woods, 2007), *i.e.*,

$$R(I) = 1 - 1/(1 + \sigma^2). \quad (4.5)$$

A suavidade é zero para uma região de intensidade constante e se aproxima de um para regiões com grandes excursões nos valores de intensidade;

6. Uniformidade proposta por Oh et al. (2007), *i.e.*,

$$UL(I) = \left(\frac{Lmin}{Lmax} \right) \times 100. \quad (4.6)$$

onde *Lmin* e *Lmax* representam a intensidade mínima e máxima em uma região, respectivamente.

Descritor relacional

Todos os descritores apresentados na seção anterior, calculam o grau de homogeneidade considerando uma única região. Considerando-se por exemplo uma imagem como a da Figura 4.8, observa-se que todas as cinco regiões apresentam boa homogeneidade individualmente. Porém, quando se analisa as regiões com relação a um referencial, verifica-se que o número 4 apresenta iluminação menor em relação à média global, fazendo com que a percepção de homogeneidade global da imagem mude.




Figura 4.8: Figura sintética exemplo.

Com base no exposto, é necessário também o cálculo do impacto que uma dada região tem em relação à homogeneidade global do objeto em análise. Dessa forma, um descritor relacional é proposto, *i.e.*,

$$DR(I) = \left(\frac{ml}{mg}\right) \times 100, \quad (4.7)$$

onde ml representa a intensidade média de uma dada região e mg representa a intensidade média geral do instrumento.

4.3 Aprendizado

A habilidade de aprendizagem que uma RNA ou uma SVM possuem é considerada sua característica primordial. Este aprendizado ocorre através de um processo iterativo de ajustes dos seus parâmetros, sempre buscando minimizar alguma medida de erro. Baseado no exposto pode-se definir a etapa de aprendizado supervisionado como: “Um processo pelo qual os parâmetros de uma RNA ou SVM, são adaptados através de um processo de estimulação pelo ambiente de dados no qual ambos estão inserido. O tipo de aprendizado é determinado pela maneira pela qual as modificações destes parâmetros ocorrem” (Haykin, 1997).

Para a realização dessa etapa, são fornecidos os descritores extraídos de cada região e a rotulação das mesmas realizadas pelos seres humanos, como descrito na Seção 4.6.

4.4 Classificação

Classificação é um método utilizado para separar um grupo de dados em classes. Esta classificação é baseada em alguma(s) característica(s) ou característica(s), que faça(m) que dados associados a uma mesma classe possuam alguma similaridade. Os métodos de classificação são divididos em: supervisionado, semi-supervisionado e não-supervisionado (Lorena e Carvalho, 2007). O modelo adotado neste trabalho é o supervisionado.

Após realizada a etapa de avaliação com os usuários, rotulando cada região como homogênea ou não homogênea, estes dados rotulados são utilizados na fase de aprendizado, tanto da RNA quanto da SVM.

Estas duas últimas seções são curtas, pois foram abordadas de forma abrangente no Capítulo 3, e seus conteúdos serão complementados no Capítulo 5, onde a arquitetura dos algoritmos utilizados será apresentada.

4.5 Seleção de Características

Para ambos os classificadores, foi realizado uma seleção de características por força bruta¹, uma vez que a dimensionalidade do vetor de características utilizado neste trabalho é relativamente baixa, *i.e.*, 7. Todas as possíveis combinações de descritores foram testadas, já que o número de possibilidades ($2^7 - 1 = 127$) é computável em tempo hábil.

Existem outros métodos para escolha de características, *e.g.*, Análise de Componente Principal (*Principal Component Analysis* - PCA) (C.M.Bishop, 2006), porém a escolha por se fazer seleção de características por força bruta deve-se não só à baixa dimensionalidade do vetor de entrada, mas também à possibilidade de avaliar o impacto de cada descritor no resultado.

Estas duas últimas seções são curtas, pois foram abordadas de forma mais abrangente no Capítulo 3. Seus conteúdos são finalizados no Capítulo 5, quando será apresentada a arquitetura dos algoritmos utilizados.

4.6 Avaliações Subjetivas

A avaliação subjetiva para este trabalho tem como propósito avaliar a percepção de homogeneidade que o usuário tem do instrumento analisado. Esta percepção, descrita como homogênea e não homogênea, é utilizada para a etapa de rotulação das regiões do instrumento. A rotulação das regiões (homogênea e não homogênea), por sua vez é utilizada na fase de aprendizado dos classificadores, *i.e.*, RNA e SVM.

A avaliação subjetiva é realizada de três formas: usuário, especialista e avaliação do usuário sobre a avaliação do especialista. Salienta-se que esta última forma de avaliação não é utilizada para o treinamento dos classificadores.

Fase de aprendizado

Antes do início das avaliações são apresentados para o avaliador alguns instrumentos, de cores e formas diferentes, para que o mesmo assimile bem o conceito de não homogeneidade de iluminação.

Protocolo de avaliação

A avaliação é realizada em uma câmara escura, com todas as luzes apagadas, visando emular uma situação real de uso noturno dos usuários em um veículo.

O instrumento em teste é montado sobre um suporte em uma bancada (Figura 4.9 (a)), respeitando a mesma inclinação em relação aos olhos do usuário, e simulando o posicionamento médio de um usuário em relação a um painel de instrumento montado sobre um veículo

¹Força bruta ou busca exaustiva, é um algoritmo que consiste em enumerar todos os possíveis candidatos para uma determinada solução e posteriormente verificar quais destes candidatos satisfazem o problema.

(Figura 4.10). O instrumento é montado a uma distância média de 650 mm entre o instrumento e os olhos do avaliador - distância média obtida em medições (Figura 4.10).




Figura 4.9: *Setup* de avaliação: (a) Instrumento montado sobre a bancada (b) *Croqui* do instrumento para avaliação do ser humano.

A instrução declarada para o avaliador é: “Identificar regiões que apresentem falta de homogeneidade na iluminação do instrumento”. Cada avaliador recebe um desenho esquemático do instrumento avaliado (Figura 4.9 (b)) para marcar as regiões que julgue estar com falta de homogeneidade, assinalando as mesmas.




Figura 4.10: Condutor \times Automóvel: (a) Posicionamento médio de um condutor em relação ao Painel de instrumentos, (b) Simulação da visão do condutor em relação ao painel de instrumentos.

4.7 Considerações

Neste capítulo, foram apresentadas as etapas da metodologia proposta para classificação automática das regiões de iluminação presente em um instrumento. No próximo capítulo, são apresentados os resultados experimentais para validação da metodologia.

Capítulo 5

Resultados Experimentais

Neste capítulo, são apresentados e discutidos os experimentos realizados para validar a metodologia proposta.

A Seção 5.1 descreve os instrumentos contidos na base de imagens de testes. Na Seção 5.2, são descritos os métodos para avaliação dos classificadores. A Seção 5.3 define os parâmetros utilizados nos experimentos pela câmera fotográfica, pela ANN e pela SVM. A descrição do método da avaliação subjetiva e uma análise sobre a mesma é relatada na Seção 5.4. Os experimentos computacionais são apresentados e discutidos na Seção 5.5 e finalmente na Seção 5.6 são relatadas as conclusões sobre os experimentos computacionais e as avaliações subjetivas.

Os experimentos aqui descritos foram realizados em uma máquina HP Pavilion dv2880BR, com processador Intel®Core™2 Duo, 2,10 GHz, 3072 MB de memória RAM, disco rígido de 250 GB interface SATA com rotação de 5400 RPM, Sistema Operacional Windows Vista Business. A metodologia computacional descrita nas seções anteriores foi integralmente implementada em MatLab (Sivanandam et al., 2006).

5.1 Descrição da Base

Para validar a metodologia, foi construída uma base de imagens de instrumentos com cores e formatos diferentes. Esta base é composta de:

- 23 velocímetros;
- 18 indicadores de rotação por minuto do motor(RPM);
- 35 indicadores de temperatura;
- 31 indicadores de nível combustível.

As cores dos instrumentos são âmbar, vermelho, branco, verde e azul, que são as cores mais usuais aplicadas aos instrumentos de veículos da atualidade. Foram escolhidas cores diferentes

com o intuito de comprovar que a metodologia não sofre influência da cor. Dos 107 instrumentos, foram extraídas mais de 3000 regiões (menor parte iluminada de um instrumento). Para cada região foram calculados sete descritores, como apresentado no Capítulo 4.

5.2 Descrição do Método de Avaliação dos Classificadores

Os experimentos foram realizados utilizando uma validação *leave-N-out* (Fukunaga e Hummels, 1989), ou seja, para cada execução de teste é separada uma amostra (imagem) contendo N regiões. O treinamento é então realizado com as amostras/regiões das $K - 1$ imagens restantes. Tanto para a ANN quanto para a SVM, 100% dos dados foram utilizados para treinamento.

A imagem retirada é então testada com o modelo treinado. É importante ressaltar que o número N de regiões de teste muda em cada execução, porque esse número depende de cada imagem, *i.e.*, a quantidade de regiões varia de instrumento para instrumento.

Esse processo é realizado para cada uma das imagens, de forma que todas sejam testadas. Então, o desempenho do modelo é verificado fazendo uma média sobre a validação de todos os K testes.

Esse tipo de validação (*leave-N-out*) possui a característica de ser a menos tendenciosa na avaliação, uma vez que cada imagem (N regiões) será testada usando como treinamento a base de imagens completa, exceto a imagem avaliada. Porém, é o tipo que exige mais recursos computacionais.

Para avaliação do desempenho dos classificadores (ANN e SVM), é usual analisar a relação entre taxa de erros e sucessos na etapa de classificação. Esses resultados geralmente são apresentados em forma de uma matriz bidimensional chamada “matriz de Confusão” (Provost et al., 1998). A Figura 5.1 ilustra tal matriz.

		Observada (Predit)	
		+	-
Esperada (Real)	+	VP (verdadeiro positivo)	FN (falso negativo)
	-	FP (falso positivo)	VN (verdadeiro negativo)

Figura 5.1: Matriz de Confusão.

Cada elemento dessa matriz apresenta o número de casos avaliados. Nas linhas, são apre-

sentadas as classes esperadas e nas colunas, as classes observadas pelo experimento. A partir da matriz de confusão, podem ser realizados cálculos de índices de desempenho do classificador. Para este trabalho, é usado o índice de precisão, *i.e.*,

$$\text{Precisão} = \frac{VP + VN}{Tot.}, \quad (5.1)$$

onde VP é o número de verdadeiros positivos, VN o número de verdadeiros negativos e $Tot.$ representa o valor total de casos avaliados, *i.e.*, $VP + VN + FN + FP$.

Também, é utilizado o índice de precisão da classe positiva e negativa, *i.e.*,

$$\text{Precisão da Classe Positiva} = \frac{VP}{VP + FN}, \quad (5.2)$$

$$\text{Precisão da Classe Negativa} = \frac{FP}{FP + VN}. \quad (5.3)$$

Para a avaliação da metodologia proposta, a matriz de confusão é representada como mostra a Figura 5.2, ou seja, a classe positiva representa as regiões não homogêneas (NH), e a classe negativa as regiões homogêneas (H).

		Observada (Predit)	
		NH	H
Esperada (Real)	NH	VP (verdadeiro positivo)	FN (falso negativo)
	H	FP (falso positivo)	VN (verdadeiro negativo)

Figura 5.2: Matriz de Confusão Adaptada.

Nessa matriz, VP representa as regiões não homogêneas classificadas corretamente, FN regiões não homogêneas classificadas erroneamente como homogêneas, FP representa regiões Homogêneas classificadas erroneamente como não homogêneas e finalmente VN regiões homogêneas classificadas corretamente.

Por meio da matriz de confusão apresentada anteriormente, pode-se realizar uma análise sobre as regiões do instrumento. No entanto, em situação de uso na fase de desenvolvimento (prototipagem), não basta analisar somente a classificação das regiões, é necessário analisar todas as regiões que constituem o instrumento.

Para a classificação final do instrumento, são propostas três categorias: aprovado; atenção e reprovado. A partir dessas categorias, pode-se obter outra matriz de confusão, conforme

apresenta a Figura 5.3. Cada categoria é descrita a seguir:

- **Aprovado:** O instrumento apresenta todas as regiões homogêneas (**OK**);
- **Atenção:** O instrumento apresenta menos que 5% de suas regiões classificadas como não homogêneas. Este caso informa que o fabricante deve ter atenção em seu projeto (!);
- **Reprovado:** O instrumento apresenta mais que 5% de suas regiões classificadas como não homogêneas. Esta categoria informa que o fabricante deve modificar o projeto de seus difusores de luz (**KO**).

O percentual definido em 5% é baseado em experiências práticas, portanto, não é um valor encontrado em norma de avaliação.

		Observada (Pedita)		
		OK	!	KO
Esperada (Real)	OK	(Ap/Ap) Aprovado/Aprovado	(Ap/At) Aprovado/Atenção	(Ap/Re) Aprovado/Reprovado
	!	(At/Ap) Atenção/Aprovado	(At/At) Atenção/Atenção	(At/Re) Atenção/Reprovado
	KO	(Re/Ap) Reprovado/Aprovado	(Re/At) Reprovado/Atenção	(Re/Re) Reprovado/Reprovado

Figura 5.3: Matriz de Confusão Para Classificação Final do Instrumento.

5.3 Definição de Parâmetros

Nesta seção, são definidos os parâmetros de câmera e as arquiteturas da ANN e SVM.

5.3.1 Definição dos Parâmetros de Câmera

Nesta seção, apresenta-se a câmera fotográfica usada para captura das imagens utilizadas nos experimentos, assim como, o ajuste de seus parâmetros.

Câmera fotográfica

A câmera utilizada para esse trabalho possui as seguintes características:

- Fabricante: *Canon*;

- Modelo: *PowerShot S3 IS*;
- Sensor: *CCD de 1/2.5"*;
- Resolução efetiva: *6.0 milhões de pixels*;
- Tamanho de imagem máxima: *2816 × 2112 pixels*;
- Lentes: *36 - 432 mm equiv. (12 × zoom óptico)*;
- Abertura de diafragma: *f2.7 → f3.5*;
- Sensibilidade ISO: High ISO; Automático; ISO 80; ISO 100; ISO 200; ISO 400; ISO 800;
- Tempo de exposição: 15 - 1/3200 segundos;
- Controle de branco: Automático; Luz do dia; Nublado; Tungstênio; Fluorescente.



Figura 5.4: Câmera fotográfica Canon S3 IS.

Para ajustar os parâmetros da câmera, um experimento foi realizado fixando-se dois parâmetros: a sensibilidade ISO da câmera, fixada em 80 (a menor da câmera utilizada) para evitar ao máximo o ruído e a abertura de diafragma fixada em 2.7. Assim, somente o tempo de exposição é variado, de forma a identificar qual valor de tempo de exposição captura a imagem mais próxima dos valores encontrados com o espectrofotômetro.


Foram também pré-ajustados na câmera:

- Tamanho da imagem: 2816×2112 *pixels* (o maior da câmera utilizada), visando capturar a maior quantidade de informação possível;
- Controle de branco: Luz do dia - para não sofrer influência da variação da intensidade entre os instrumentos.

Para esse experimento, foram capturadas imagens de quatro instrumentos diferentes, com tempo de exposição de $1/5''$, $1/8''$, $1/10''$, $1/13''$, $1/15''$ e $1/20''$. Essas imagens foram capturadas em formato JPEG, que utiliza o espaço de cores RGB. Posteriormente, elas foram convertidas para o espaço de cor HSV, onde foi analisado o canal V (intensidade).




(Instrumento Ambar)



(Instrumento Verde)



(Instrumento Vermelho)



(Instrumento Azul)

Figura 5.5: Medições realizada com o espectrofotômetro.

Com o objetivo de comparar os valores de intensidade obtidos pela câmera fotográfica e com o espectrofotômetro, foram realizadas medições em 52 posições diferentes, em cada um dos quatro instrumentos (Figura 5.5).

Análise dos resultados

Para efeito comparativo, os valores medidos pelo Espectrofotômetro (unidade de medida em cd/m^2 , ou seja, candela por metro quadrado) e a leitura dos *pixels* nas imagens foram normalizados. Para realizar a normalização, foi utilizada a regra *max-min* de acordo com Martinez e Martinez (2005), *i.e.*,




Figura 5.6: Instrumento Âmbar - Análise gráfica entre as medidas sobre a imagem (diferentes tempos de exposição) X espectrofotômetro.




Figura 5.7: Instrumento Verde - Análise gráfica entre as medidas sobre a imagem (diferentes tempos de exposição) X espectrofotômetro.

$$z = \frac{x - \min(x)}{\max(x) - \min(x)}. \quad (5.4)$$

Para avaliação dos resultados, foi calculada a Raiz do Erro Quadrático Médio (REQM), *i.e.*,

$$REQM = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2}. \quad (5.5)$$

Os cálculos foram realizados entre as leituras tomadas das imagens, com diferentes tempos de exposição, em relação aos valores medidos com o espectrofotômetro (Referência/*Ground Truth*).




Figura 5.8: Instrumento Vermelho - Análise gráfica entre as medidas sobre a imagem (diferentes tempos de exposição) X espectrofotômetro.




Figura 5.9: Instrumento Azul - Análise gráfica entre as medidas sobre a imagem (diferentes tempos de exposição) X espectrofotômetro.

Pelas análises dos gráficos apresentados nas Figuras 5.6, 5.7, 5.8 e 5.9 e resultados apresentados na Tabela 5.1, percebe-se que para os instrumentos âmbar, verde e azul, o tempo de exposição que mais se aproxima das medidas realizadas com o espectrofotômetro foi de $1/15''$ e para o instrumento vermelho $1/13''$. Para padronização deste parâmetro, foi escolhida a velocidade $1/15''$ para captura de todas as imagens utilizadas nos experimentos.

Com esses resultados, foram estabelecidos os seguintes parâmetros para captura da imagem:

- Sensibilidade: ISO 80;
- Abertura do diafragma: 2.7;
- Velocidade do obturador: $1/15''$;

- Tamanho da imagem: 2816×2112 pixels;
- Controle de branco: Luz do dia.

Tabela 5.1: Cálculo do erro entre medida do espectrofotômetro e fotografia.

Tempo	REQM			
	Ambar	Verde	Azul	Vermelho
1/5"	0,139	0,188	0,312	0,261
1/8"	0,106	0,126	0,134	0,147
1/10"	0,088	0,135	0,205	0,133
1/13"	0,073	0,112	0,143	0,120
1/15"	0,065	0,093	0,098	0,162
1/20"	0,077	0,098	0,216	0,163

5.3.2 Definição dos Parâmetros da ANN

Nesta seção, são definidos o número de camadas ocultas e o número de neurônio em cada camada.

Foi utilizada uma rede neural *Multi-Layer-Perceptron* (MLP) *Feedforward Backpropagation*, como um dos classificadores. O treinamento foi realizado pela função de Levenberg-Marquardt, devido à sua velocidade. Todas as funções de transferência dos neurônios foram ajustadas por uma função tangente inversa e o critério de parada foi ajustado para 500 épocas ou um Erro Quadrático Médio (EQM) de treinamento menor que 10^{-2} . Também, levou-se em consideração, como critério de parada, um conjunto de validação para evitar especialização e garantir a generalização da rede.

Visando definir o número de camadas ocultas e a quantidade de neurônios em cada uma destas, avaliando tempo e precisão, foram realizados experimentos preliminares com 25% do total da base de instrumentos, usando a técnica de validação citada anteriormente.

Os valores testados foram:

- Número de camadas ocultas: uma, duas e três camadas;
- Número de neurônios em cada camada: $1/3$; $2/3$; 1 ; 2 e 5 vezes o número de neurônios de entrada (n).

Analisando os dados apresentados na Tabela 5.2, observa-se que os valores de precisão encontrados são muito próximos um dos outros, seja com uma, duas ou três camadas ocultas. Porém o tempo de processamento cresce consideravelmente à medida que o número de camadas aumenta.

Para o número de neurônios na camada oculta, também é observado que a precisão é bem próxima para os valores testados, se diferenciando pelo tempo de processamento.

Tabela 5.2: Avaliação do número de neurônios na camada oculta.

Neurônios	1 Camada		2 Camadas		3 Camadas	
	Tempo	Precisão	Tempo	Precisão	Tempo	Precisao
1/3 n	66'	88,4% \pm 8,5%	72'	91,4% \pm 8,4%	89'	91,2% \pm 7,1%
2/3 n	75'	91,0% \pm 6,4%	80'	91,3% \pm 6,8%	101'	90,5% \pm 8,3%
1 n	80'	90,9% \pm 8,3%	88'	91,4% \pm 8,1%	105'	91,2% \pm 8,2%
2 n	87'	91,3% \pm 6,3%	105'	90,1% \pm 8,5%	125'	90,7% \pm 8,2%
5 n	95'	90,4% \pm 8,4%	430'	92,1% \pm 4,5%	15h 14'	90,7% \pm 6,4%

Com base na Tabela 5.2, optou-se por uma camada oculta contendo duas vezes o número de neurônios da camada de entrada. Esse valor foi escolhido por apresentar uma alta precisão, baixo valor de desvio padrão e tempo de processamento factível.

5.3.3 Definição dos Parâmetros da SVM

Nesta seção, é definido o tipo de “*kernel*” para a SVM.

Para definir qual *kernel* teria o melhor resultado para a SVM, foram realizados experimentos preliminares com 25% da base total de instrumentos, usando a mesma técnica de validação da seção anterior. Os *kernels* testados foram: Polinomial, Gaussiano ou RBF (*Radial Basis Function*) e Sigmoidal, uma vez que são considerados os mais utilizados na prática (Lorena e Carvalho, 2007; Haykin, 1997).

Tabela 5.3: Avaliação do *kernel*.

<i>Kernel</i>	Tempo de execução	Precisão da SVM
Polinomial	*	*
RBF	13'	94,92% \pm 5,56%
Sigmoidal	11'	73,8% \pm 15,20%

Analisando os dados apresentados na Tabela 5.3, conclui-se que o *kernel* RBF apresentou a melhor precisão para a base testada, portanto, foi o *kernel* escolhido. Ressalta-se também que, utilizando o *kernel* Polinomial com diferentes graus (2, 3, 4 e 5), após 60 minutos de execução, o algoritmo não conseguiu convergir.

Para a utilização da SVM, foi utilizada a biblioteca SVMLIB desenvolvida por Chang e Lin (2001).

5.4 Avaliação Subjetiva

Nesta seção, são descritos os experimentos realizados com os usuários e o especialista, visando rotular as regiões dos instrumentos (como homogêneo ou não) para o aprendizado (treinamento

dos classificadores). O procedimento de teste foi realizado como descrito na Seção 4.6.

5.4.1 Avaliação com Usuário

O experimento foi realizado por 48 pessoas: 35 homens e 13 mulheres com idades entre 20 e 50 anos, diferentes atividades profissionais, variação de altura entre 1,55m a 1,90m, com e sem sistemas corretivos de visão (lentes e óculos). Este conjunto de avaliadores visa contemplar uma amostra média proporcional dos usuários comuns, *i.e.*, motoristas de veículos.

Cada um dos 107 instrumentos foi avaliado por cinco diferentes usuários, distribuindo-se os instrumentos aos avaliadores de forma que dois usuários não avaliaram mais de um instrumento em comum.

Uma vez que existe grande variação entre as opiniões dos usuários (ver análise na Seção 5.4.3), decidiu-se sumarizar/agrupar as cinco classificações de cada instrumento segundo as seguintes restrições:

- Grupo 01: Regiões classificadas como não homogêneas, por pelo menos 1 usuário.
- Grupo 02: Regiões classificadas como não homogêneas, por pelo menos 2 usuários.
- Grupo 03: Regiões classificadas como não homogêneas, por pelo menos 3 usuários.
- Grupo 04: Regiões classificadas como não homogêneas, por pelo menos 4 usuários.
- Grupo 05: Regiões classificadas como não homogêneas, por todos os usuários.

Assim, para cada instrumento, as regiões que atenderam as restrições foram rotuladas como “não homogêneas”, e as que não atenderam as restrições foram rotuladas como “homogêneas”.

Salienta-se que o Grupo 01, formado por avaliações de instrumentos cujas regiões não homogêneas foram apontadas como não homogêneas por pelo menos um usuário, é considerado o grupo menos tolerante com relação à não homogeneidade. Já o Grupo 05, no outro extremo, é considerado o mais tolerante, pois nele, as regiões são tidas como não homogêneas somente quando elas são julgadas como não homogêneas por todos os cinco usuários.

Estes cinco diferentes grupos foram utilizadas para treinar e validar os classificadores.

5.4.2 Avaliação com o Especialista

A fim de realizar uma avaliação mais consistente e criteriosa, um especialista em iluminação da área automotiva avaliou todos os instrumentos envolvidos no trabalho. O procedimento adotado na avaliação de cada instrumento foi o mesmo descrito na Seção 4.6.

5.4.3 Análise das Avaliações Subjetivas

Nesta seção, são apresentados estudos sobre as avaliações de regiões entre os grupos de usuários e o especialista.

Tabela 5.4: Distribuição das classes Não Homogêneas/Homogêneas.

Avaliador	(%)		(#)		
	NH	H	NH	H	Total
Grupo 01	41.32	58.68	1409	2001	3410
Grupo 02	20.56	79.44	701	2709	3410
Grupo 03	8.83	91.17	301	3109	3410
Grupo 04	3.43	96.57	117	3293	3410
Grupo 05	0.65	99.35	22	3388	3410
Especialista	20.59	79.41	702	2708	3410

Tabela 5.5: Distribuição de regiões não homogêneas por avaliação.

N° Regiões	Avaliadores					
	G1	G2	G3	G4	G5	Esp.
0	14	39	53	70	93	42
1-3	24	15	21	23	13	15
4-5	7	10	13	9	1	9
6-10	18	17	11	4	0	19
11-	44	26	9	1	0	22

5.4.3.1 Análise entre as Avaliações

A Tabela 5.4 apresenta a distribuição das classes (Não Homogênea / Homogênea) para cada avaliação. Os dados estão expressos em valores absolutos e em percentual.

Observa-se que à medida que a tolerância dos grupos aumenta, o número de regiões rotuladas como não homogêneas diminui consideravelmente. O Grupo 02 teve sua distribuição próxima da avaliação do especialista. Porém, esta semelhança, não se mostrou presente na análise da precisão das classificações.

A seguir, é apresentada a Tabela 5.5 contendo a distribuição de regiões Não Homogêneas em cada grupo.

As Tabelas 5.6 e 5.7 apresentam o grau de concordância entre cada rotulação. A concordância é definida da seguinte forma:

$$Concordância(X, AV_1, AV_2) = \frac{\#(AV_1(X) \cap AV_2(X))}{\#(AV_1(X) \cup AV_2(X))}, \quad (5.6)$$

onde $AV_y(X)$ representa o conjunto de regiões do tipo X (não homogênea e homogênea) rotulada pelo avaliador y (Grupo 01, Grupo 02, Grupo 03, Grupo 04, Grupo 05 e Especialista) e $\#(\bullet)$ representa a cardinalidade do conjunto \bullet . A concordância será máxima, *i.e.*, 1, quando todas as rotulações recebidas por um grupo forem iguais ao outro grupo.

Avaliando as Tabelas 5.6 e 5.7, percebe-se que o grau de concordância entre os grupos é bem maior para as rotulações homogêneas, o que é natural devido à forma que as avaliações

Tabela 5.6: Matriz de concordância para regiões não homogêneas.

Avaliadores	G1	G2	G3	G4	G5	Esp.
G1	1.00	0.50	0.21	0.08	0.02	0.32
G2	0.50	1.00	0.43	0.17	0.03	0.33
G3	0.21	0.43	1.00	0.39	0.07	0.22
G4	0.08	0.17	0.39	1.00	0.19	0.12
G5	0.02	0.03	0.07	0.19	1.00	0.02
Esp.	0.32	0.33	0.22	0.12	0.02	1.00

Tabela 5.7: Matriz de concordância para regiões homogêneas.

Avaliadores	G1	G2	G3	G4	G5	Esp.
G1	1.00	0.74	0.64	0.61	0.59	0.63
G2	0.74	1.00	0.87	0.82	0.80	0.77
G3	0.64	0.87	1.00	0.94	0.92	0.80
G4	0.61	0.82	0.94	1.00	0.97	0.81
G5	0.59	0.80	0.92	0.97	1.00	0.80
Esp.	0.63	0.77	0.80	0.81	0.80	1.00

foram geradas. Nas rotulações não homogêneas, existe uma grande variação de concordâncias entre os grupos. Durante a realização da avaliação com os usuários, essa característica foi observada.

O usuário possui uma facilidade maior para rotular regiões homogêneas, quando estas apresentam uma homogeneidade mais evidente. Para as regiões não homogêneas, as opiniões variam muito entre os usuários, dependendo se um usuário é mais crítico ou mais tolerante. As maiores discordâncias estão em regiões mais próximas do limiar entre homogêneas e não.

Devido à experiência e ao método de análise mais técnico realizado pelo especialista, a rotulação feita por ele é mais consistente. Analisando as tabelas de concordância, observa-se que para as regiões homogêneas os índices de concordância com os demais grupos são relativamente altos. Entretanto a concordância para as regiões não homogêneas, onde há uma maior dificuldade de rotulação para o usuário, é muito baixa.

Análise da percepção do usuário

Por meio das imagens da Figura 5.10, é possível fazer uma análise sobre a percepção visual do usuário.

Durante as avaliações com os usuários, o instrumento apresentado na Figura 5.10 (a) obteve os números “4” (do “40”) e o “6” do (“60”), rotulados como “não homogêneos”. Segundo os próprios usuários, tal rotulação se deu por estes estarem mais escuros que a intensidade média do instrumento.

Entretanto, em uma análise mais técnica, Figura 5.10 (c),(d), é possível perceber que

ambos os números citados estão mais próximos da média geral do instrumento, e na verdade são os números “0” (do “40”) e o “0” (do “60”) que estão mais intensos que a média geral.

A imagem da Figura 5.10 (e) apresenta uma correção sobre os números “0” (do “40”) e o “0” (do “60”), na qual pode-se perceber (5.10 (f),(g)) uma melhora da homogeneidade.

Este fato pode ter explicações nos efeitos descritos no Capítulo 2, onde o contexto no qual o objeto está inserido afeta diretamente sua percepção. Este efeito ocorreu em avaliações de vários instrumentos. E o interessante dessa análise é que alguns usuários perceberam esta diferença e outros não.

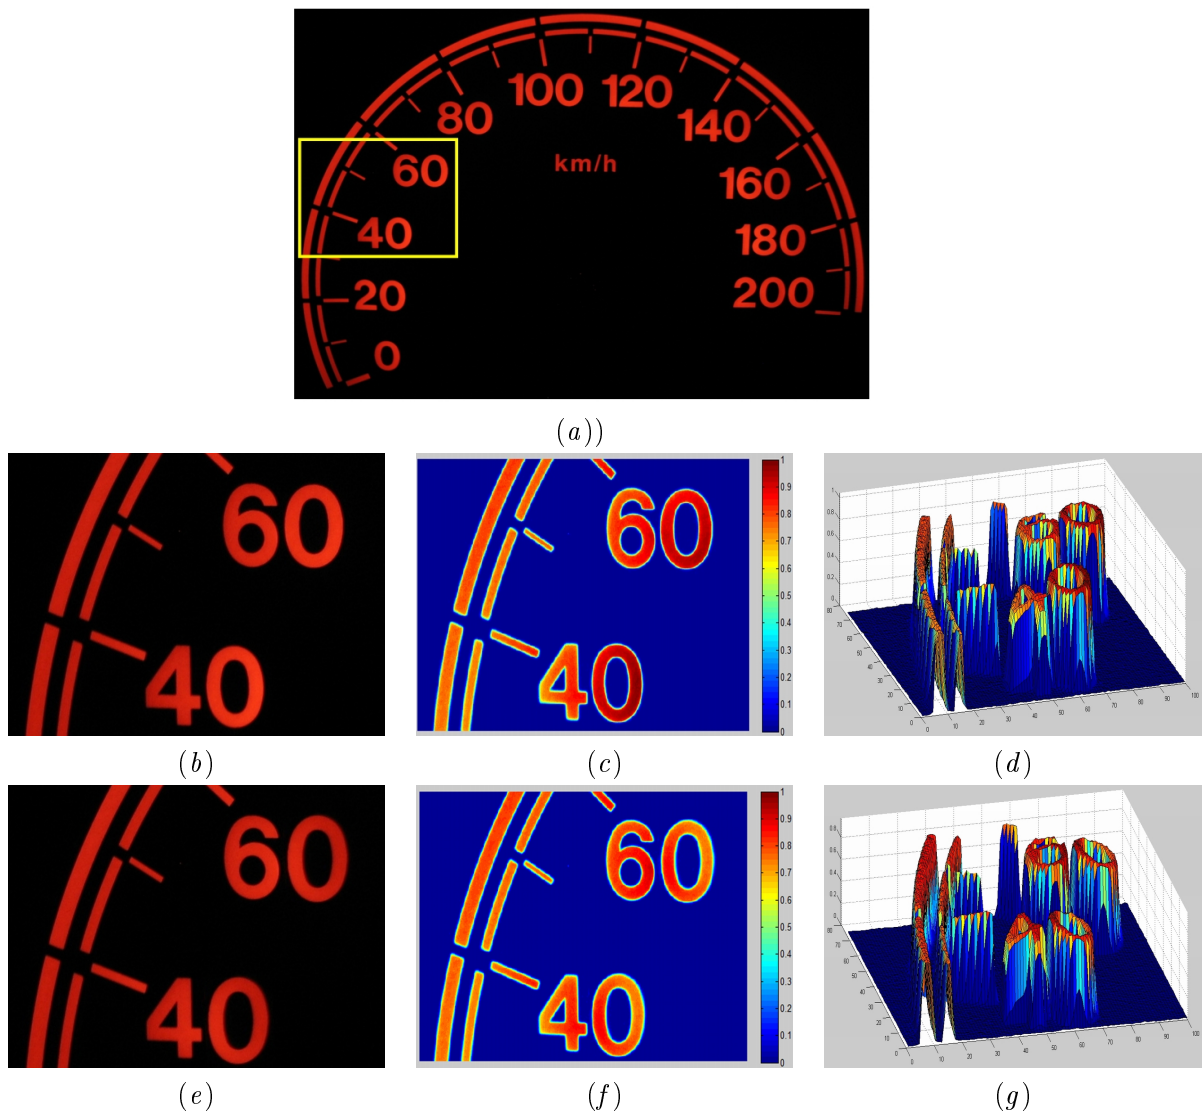


Figura 5.10: Análise da Percepção do Usuário: a) Instrumento original; b) Detalhe da região ressaltada em amarelo; c) Análise por cores falsas - imagem original; d) Análise de superfície - imagem original; e) Detalhe da região ressaltada - corrigida; f) Análise por cores falsas - imagem corrigida; g) Análise de superfície - imagem corrigida.

5.4.3.2 Avaliação dos Usuários sobre a Avaliação do Especialista

Com o intuito de avaliar se a rotulação realizada pelo especialista representa de forma adequada a percepção geral dos usuários, foi realizada uma nova avaliação.

Nesse modelo, o usuário avalia a classificação realizada pelo especialista. As correções do instrumento sugeridas pelo especialista (*i.e.*, regiões rotuladas como não homogêneas) são apresentadas para o usuário por meio de um desenho esquemático do instrumento. Juntamente com este esquema, são apresentados para os usuários os respectivos instrumentos, iluminados sobre uma bancada em câmara escura.

A instrução declarada para cada usuário é: “Como você avalia as correções sugeridas (avaliação do especialista)?”. A resposta é dada através de uma escala de 1 a 3, sendo:

1. *Insuficiente*: Corrigindo-se as regiões sugeridas, ainda assim o instrumento não apresentaria uma iluminação homogênea;
2. *Adequada*: Corrigindo-se as regiões sugeridas, o instrumento irá apresentar uma iluminação adequada;
3. *Excessiva*: Não é necessária a correção de todas as regiões sugeridas para que o instrumento apresente uma boa iluminação.

Resultados

Cada instrumento foi avaliado por 5 usuários diferentes e cada usuário avaliando em média 10 instrumentos. Ao todo foram realizadas 535 avaliações (5 usuários \times 107 Instrumentos). O objetivo é avaliar a classificação realizada pelo especialista, levando-se em conta a percepção do usuário. O gráfico apresentado pela Figura 5.11 resume os resultados obtidos após a avaliação.




Figura 5.11: Gráfico resumo da avaliação do usuário sobre o especialista.

Pela análise do gráfico, observa-se que 72% das rotulações do especialista obtiveram as 5 avaliações (dentre as 5 possíveis) como adequadas, 17 % das classificações do especialista foram consideradas adequadas por 4 dentre 5 avaliadores, 5% foram avaliadas como adequadas por 3 avaliadores dentre 5 avaliadores, 4% foram avaliadas como adequadas por 2 avaliadores dentre 5 e somente 2% foram avaliadas como adequadas por só 1 avaliador. Ressalta-se que nenhuma classificação realizada pelo especialista obteve as 5 avaliações como não adequadas.

Observa-se que das 535 avaliações realizadas, somente 48 foram consideradas não adequadas pelos usuários, perfazendo um índice de aceitação de 91,0% da rotulação do especialista. Do total de 48 avaliações rotuladas como não adequadas, 73% foram classificadas como excessivas, e apenas 27% como insuficientes. A Figura 5.12 apresenta essa última análise.




Figura 5.12: Estratificação da avaliação.

Realizando um análise sobre o gráfico apresentado na Figura 5.12, é possível determinar que as discordâncias que houve sobre a análise do especialista indicam que o especialista tende a ser mais exigente na correção do painel de instrumentos. Essa maior exigência, apesar de ter a possibilidade de trazer mais custo para a indústria, beneficia o consumidor final.

5.5 Experimentos Computacionais

Nas próximas seções, são apresentados os resultados, por meio de matrizes de confusão, obtidos pelos algoritmos de aprendizado de máquina na classificação das regiões e dos instrumentos. Os valores apresentados estão em percentual (%) e valores absolutos (#). Esses expressam a média e o desvio padrão ($\mu(\sigma)$) dos 107 testes realizados através do “*Leave-N-Out*”. Salienta-se que os altos valores de desvio padrão, na matriz de confusão, são devidos à grande variação no número de regiões de cada instrumento. Por exemplo, o indicador de combustível (F35) possui 7 regiões e o velocímetro (V30) tem 80 regiões.

5.5.1 Resultados obtidos para Classificação das Regiões

A seguir, são apresentadas as matrizes de confusão obtidas pelos algoritmos de aprendizado de máquina para classificação das regiões, baseadas na rotulação realizada pelo especialista e usuários. Os resultados dos usuários estão divididos de acordo com os grupos pré-definidos na Seção 5.4.1. As Tabelas 5.8 e 5.9 apresentam os resultados obtidos com a ANN e a SVM, respectivamente.

As 12 possíveis matrizes de confusão, para os dois classificadores (ANN e SVM), foram condensadas em duas, para permitir a visualização completa dos dados.

Tabela 5.8: Matriz de confusão para ANN.

$\mu\%(\sigma\%)/(\mu\#(\sigma\#))$			Observado	
			NH	H
Esperado	NH	G1	19,02%(18,55%) / 7.86(10.72)	16,41%(14,58%) / 5.31(6.91)
		G2	6,05%(7,89%) / 2.51(3.78)	11,41%(13,13%) / 4.04(5.17)
		G3	0,74%(2,24%) / 0.42(1.43)	7,15%(9,44%) / 2.39(3.32)
		G4	0,07%(0,49%) / 0.03(0.17)	2,86%(4,66%) / 1.07(2.07)
		G5	0,00%(0,00%) / 0.00(0.00)	0,58%(1,71%) / 0.21(0.63)
		Esp.	15,47%(15,89%) / 6.30(8.59)	0,85%(1,87%) / 0.26(0.48)
	H	G1	11,37%(11,37%) / 3.68(4.46)	53,20%(27,58%) / 15.02(13.98)
		G2	4,75%(7,82%) / 1.71(2.81)	77,79%(19,71%) / 23.61(19.07)
		G3	1,65%(5,30%) / 0.53(1.38)	90,47%(11,50%) / 28.52(23.12)
		G4	0,56%(2,71%) / 0.14(0.57)	96,50%(5,52%) / 30.64(24.66)
		G5	1,41%(7,45%) / 0.26(1.82)	98,01%(7,54%) / 31.40(25.48)
		Esp.	1,88%(5,54%) / 0.38(1.05)	81,81%(17,44%) / 24.93(19.79)

Tabela 5.9: Matriz de confusão para SVM.

$\mu\%(\sigma\%)/(\mu\#(\sigma\#))$			Observado	
			NH	H
Esperado	NH	G1	14,24%(15,27%) / 5,93±(8,44)	21,19%(16,68%) / 7,23±(8,92)
		G2	3,86%(5,86%) / 1,73±(2,91)	13,59%(14,44%) / 4,82±(6,03)
		G3	0,41%(1,18%) / 0,20±(0,56)	7,47%(9,41%) / 2,62±(3,69)
		G4	0,00%(0,00%) / 0,00±(0,00)	2,94%(4,79%) / 1,09±(2,13)
		G5	0,00%(0,00%) / 0,00±(0,00)	0,58%(1,71%) / 0,21±(0,63)
		Esp.	15,17%(15,58%) / 6,11±(8,26)	1,14%(2,37%) / 0,45±(0,83)
	H	G1	8,41%(10,48%) / 2,79 (3,47)	56,16%(27,49%) / 15,92 (14,55)
		G2	2,78%(5,18%) / 1,05 (1,98)	79,76%(18,73%) / 24,27 (19,61)
		G3	0,71%(1,83%) / 0,25 (0,55)	91,41%(10,29%) / 28,80 (23,34)
		G4	0,06%(0,60%) / 0,01 (0,10)	97,00%(4,79%) / 30,77 (24,65)
		G5	0,00%(0,00%) / 0,00 (0,00)	99,42%(1,71%) / 31,66 (25,34)
		Esp.	2,22%(5,81%) / 0,46 (1,08)	81,47%(17,67%) / 34,85 (19,75)

5.5.2 Resultados Obtidos para Classificação do Instrumento

Nesta seção, são reportados os resultados obtidos para a classificação dos instrumentos, baseada na rotulação realizada pelo especialista e usuários. As Tabelas 5.10 e 5.11 apresentam os resultados obtidos com a ANN e a SVM, respectivamente. Da mesma forma que foi realizado na seção anterior, as tabelas foram condensadas em duas, para permitir a visualização completa dos dados.

Tabela 5.10: Matriz de confusão: Classificação final dos instrumentos para ANN.

			Observado		
			Aprovado	Atenção	Reprovado
Esperado	Aprovado	G1	06	02	06
		G2	36	02	03
		G3	57	00	01
		G4	77	01	02
		G5	97	01	04
		Esp.	42	01	04
	Atenção	G1	04	00	02
		G2	02	00	03
		G3	03	03	02
		G4	15	00	00
		G5	05	00	00
		Esp.	00	02	01
	Reprovado	G1	18	02	67
		G2	12	07	42
		G3	30	08	05
		G4	11	00	01
		G5	01	00	00
		Esp.	00	00	57

5.5.3 Análise dos Resultados

Análise da precisão da metodologia para classificação das regiões

A Tabela 5.12 apresenta um resumo da precisão geral do modelo testado tanto para a ANN quanto para a SVM, segundo as Tabelas 5.8 e 5.9. Pela Tabela 5.12, observa-se que as avaliações realizadas pelo especialista e os usuários representados pelos Grupos 04 e 05 obtiveram os melhores resultados para a classificação geral das regiões. Porém os Grupos 04 e 05 contêm um baixo índice de acerto para a classe de regiões não homogêneas, como é visto a seguir.

Observando-se os dados das Tabelas 5.8 e 5.9, nota-se que, à medida que a tolerância dos grupos dos usuários aumenta (do Grupo 01 para o Grupo 05), o número de regiões não homogêneas diminui consideravelmente. Esse fato fica mais evidente quando se observa a distribuição das regiões rotuladas como não homogêneas pelos avaliadores, conforme apresentado

Tabela 5.11: Matriz de confusão: Classificação final dos instrumentos para SVM.

			Observado		
			Aprovado	Atenção	Reprovado
Esperado	Aprovado	G1	07	03	04
		G2	39	01	01
		G3	58	00	00
		G4	79	01	00
		G5	101	00	00
		Esp.	41	02	04
	Atenção	G1	04	01	01
		G2	02	01	02
		G3	04	02	00
		G4	15	00	00
		G5	05	00	00
		Esp.	00	02	01
	Reprovado	G1	22	06	59
		G2	18	10	33
		G3	38	04	01
		G4	12	00	00
		G5	01	00	00
		Esp.	00	00	56

Tabela 5.12: Resumo da Precisão Global dos Classificadores.

Avaliação	Classificador	
	ANN	SVM
Especialista	97.28% (6.16%)	96.64% (6.65%)
Usuário (Grupo 01)	72.22% (14.84%)	70.39% (17.78%)
Usuário (Grupo 02)	83.84% (15.02%)	83.63% (15.67%)
Usuário (Grupo 03)	91.20% (10.68%)	91.82% (9.88%)
Usuário (Grupo 04)	96.57% (5.34%)	97.00% (4.79%)
Usuário (Grupo 05)	98.01% (7.54%)	99.42% (1.71%)

na Tabela 5.5. Enquanto no primeiro grupo, para uma região ser rotulada como não homogênea, bastava um dentre os cinco usuários ter classificado a região como não homogênea, no quinto grupo é necessário que a região tenha sido rotulada como não homogênea por todos os cinco usuários. Com isso, tem-se que o número de regiões não homogêneas do quinto grupo é muito inferior ao do primeiro grupo.

Tal característica faz com que os classificadores se especializem cada vez mais em identificar regiões homogêneas em detrimento da classificação das não homogêneas. A Tabela 5.13, que reporta a precisão por classe, confirma esta característica. Entre as classificações, a que obteve resultados mais equilibrados, para regiões homogêneas e não homogêneas, foi a realizada pelo especialista, obtendo elevadas taxas de precisão para ambas as classes.

Tabela 5.13: Resumo da Precisão Por Classe.

Avaliação	Não Homogêneas		Homogêneas	
	ANN	SVM	ANN	SVM
Especialista	94,79%	93,01%	97,75%	97,34%
Usuário (Grupo 01)	53,68%	40,19%	82,39%	86,97%
Usuário (Grupo 02)	34,65%	22,12%	94,42%	96,63%
Usuário (Grupo 03)	9,37%	5,20%	98,20%	99,23%
Usuário (Grupo 04)	2,38%	0,00%	99,42%	99,93%
Usuário (Grupo 05)	0,00%	0,00%	98,58%	99,42%

Análise da precisão da metodologia para classificação do instrumento

Nesta seção, são analisadas as matrizes de confusão para classificação dos instrumentos. A Tabela 5.14 reporta a precisão para classificação dos instrumentos segundo as Tabelas 5.10 e 5.11. Também é reportado o número de erros críticos, ou seja, aprovar um instrumento ruim. Esse tipo de erro é muito grave, pois se o instrumento for aprovado na fase de projeto, ele servirá de base para todo o processo produtivo.

Analisando os resultados gerados pela rotulação do especialista, percebe-se que houve somente seis classificações erradas, das 107 possíveis, nenhuma considerada crítica.

Avaliando os resultados gerados pelas avaliações dos usuários, observa-se que além da precisão ser menor, o número de classificações críticas é bem expressivo para os quatro primeiros grupos.

Os resultados gerados pelo quinto grupo de rotulação dos usuários possuem apenas uma classificação crítica, contudo esse grupo é composto das avaliações mais tolerantes de todas, ou seja, quase 100 % dos instrumentos são considerados adequados, fato que é pouco provável na prática como pode ser evidenciado na Seção 5.5.4.

Tabela 5.14: Resumo da Precisão da Classificação do Instrumento.

Avaliação	ANN		SVM	
	Precisão	NºErros	Precisão	NºErros
Especialista	94,39%	0	92,52%	0
Usuário (Grupo 01)	71,96%	18	62,62%	22
Usuário (Grupo 02)	72,89%	12	68,22%	18
Usuário (Grupo 03)	60,75%	30	57,00%	38
Usuário (Grupo 04)	72,90%	11	73,82%	12
Usuário (Grupo 05)	90,65%	1	94,39%	1

5.5.4 Visualização das Classificações

A Figura 5.13 apresenta a classificação de alguns instrumentos. As imagens dispostas na primeira linha da Figura 5.13 representam as imagens originais, seguidas pelas imagens resultantes do aprendizado baseado na rotulação do especialista, do Grupo 01 e do Grupo 05, na segunda, terceira e quarta linhas, respectivamente.

Para as imagens da segunda à quarta linha, foi gerado uma representação por meio de cores. As regiões homogêneas e não homogêneas classificadas corretamente são representadas pelas cores branca e amarela, respectivamente. Já as regiões não homogêneas, classificadas como homogêneas, são representadas pela cor vermelha, e as opostas, ou seja, regiões homogêneas classificadas como não homogêneas, são representadas pela cor verde.

Analisando as imagens da Figura 5.13, constata-se que o Grupo 01 realmente é o mais intolerante das avaliações, onde grande parte das regiões são consideradas como não homogêneas. No outro extremo, o Grupo 05 é o mais tolerante de todos aceitando quase 100 % das regiões como homogêneas.

A partir da análise dessas imagens, pode-se confirmar alguns fatos constatados pelos experimentos computacionais reportados anteriormente. Os resultados obtidos pela rotulação do especialista (segunda linha), mostram que houve poucas regiões classificadas erradamente, e estas não comprometeram a classificação final do instrumento (aprovado ou reprovado).

Os resultados obtidos pelo Grupo 01 (terceira linha) apresentam muitas regiões classificadas erroneamente, contribuindo diretamente para a classificação final errada do instrumento.

Já na quarta linha, que apresenta a avaliação do Grupo 05 (o grupo mais tolerante), observa-se que quase 100% das regiões são classificadas como homogêneas. Além deste fato ser pouco provável na prática, os classificadores não conseguiram determinar as poucas regiões não homogêneas existentes.

A Figura 5.14 apresenta a imagem de um instrumento e sua respectiva imagem resultante do aprendizado baseado na rotulação do especialista 5.14(b), que teve sua classificação final errada.

A imagem originalmente foi rotulada como sendo toda homogênea. Porém, na classificação realizada pela metodologia, a região superior da imagem foi classificada como não homogênea (por isso marcada em verde).

Devido a este fato, como o número de regiões não homogêneas no instrumento ultrapassou 5% do número total de regiões, sua classificação final foi considerada como reprovada. Nessa situação, houve um erro de classificação final do instrumento, que deveria ser aprovado, porém não é considerado um erro crítico (aprovar um instrumento ruim).

5.5.5 Análise dos Descritores

Com o intuito de realizar um estudo sobre os descritores utilizados pelos algoritmos de classificação/aprendizado de máquina, foram estudados as ocorrências desses para cada classificação

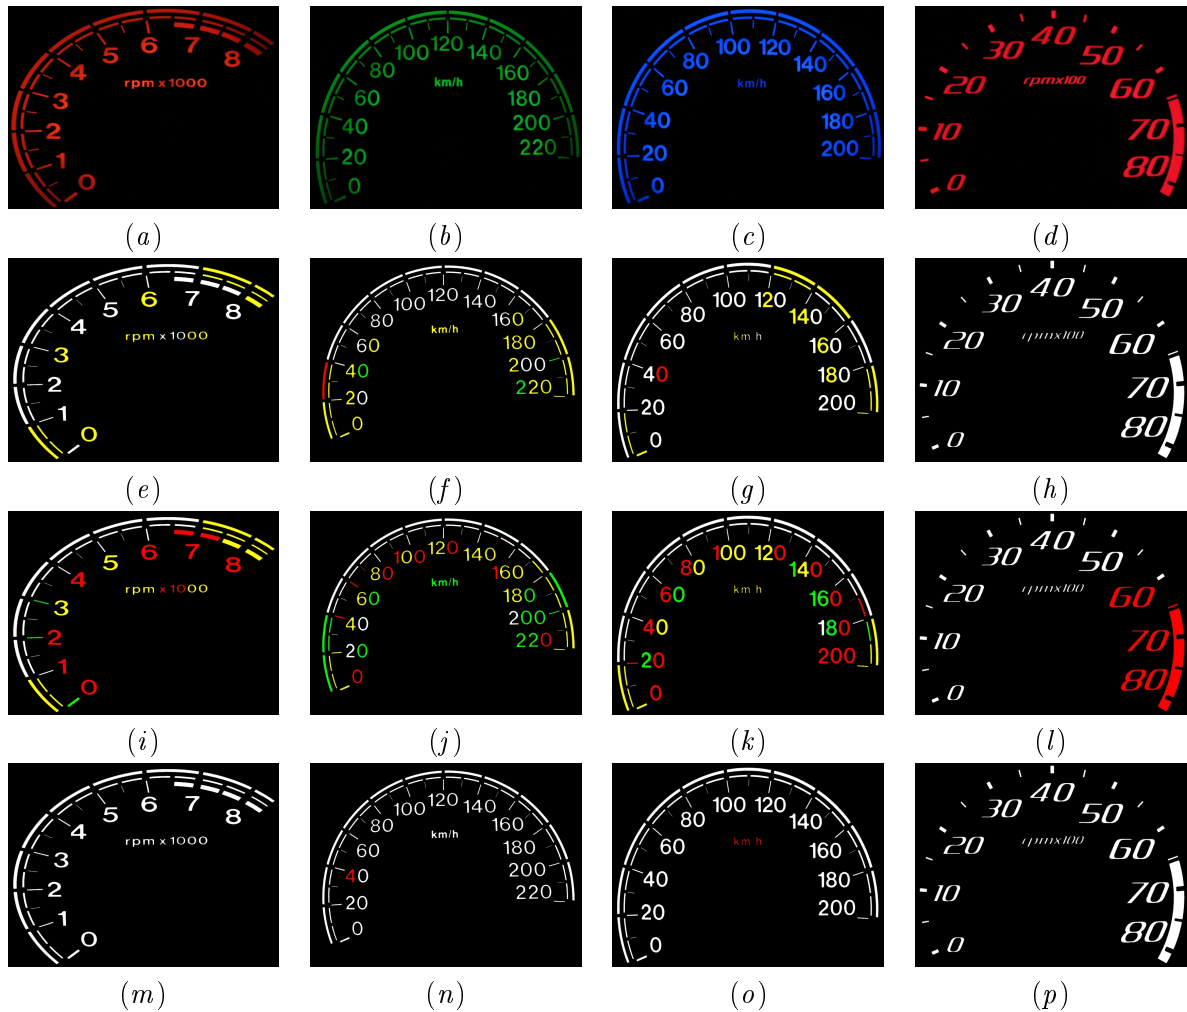


Figura 5.13: Imagens de instrumentos e suas respectivas classificações: as imagens a, b, c e d representam as imagens originais; as imagens e, f, g e h representam a classificação com base na rotulação do especialista; as imagens i, j, k e l representam a classificação com base na rotulação do Grupo 1 e as imagens m, n, o e p representam a classificação com base na rotulação do Grupo 5. As regiões homogêneas e não homogêneas classificadas corretamente são representadas pelas cores branca e amarela, respectivamente. Já as regiões não homogêneas, classificadas como homogêneas, são representadas pela cor vermelha, e as regiões homogêneas classificadas como não homogêneas, são representadas pela cor verde.

(especialista e usuários).

Os gráficos apresentados na Figura 5.15 mostram as ocorrências dos descritores (1-Desvio Padrão, 2-Uniformidade (Oh), 3-Suavidade, 4- Assimetria ou *Skewness*, 5-Uniformidade, 6-Entropia, 7-Descritor Relacional) entre as 50 melhores execuções (das 107 possíveis) do *Leave-N-Out*, em termos de precisão. Observa-se que a SVM utiliza menos descritores para reportar resultados semelhantes à ANN.

Observa-se que para a avaliação do especialista, os descritores 2 (Uniformidade) e 7 (Des-




Figura 5.14: Um exemplo ilustrativo de instrumentos e sua respectiva classificação realizada pela metodologia: (a) Imagem original; (b) Imagem classificada. A cor branca representa as regiões que eram homogêneas e foram classificadas corretamente como homogêneas e a cor verde representa a região que era homogênea e foi classificada erradamente como não homogênea.

critor Relacional) foram os mais presentes, dentre as 50 melhores execuções, considerando-se a precisão.

Para a classificação realizada pelo usuário (Grupo 01), a qual contém o maior número de regiões não homogêneas, houve uma exigência maior dos classificadores, necessitando um maior número de descritores para encontrar uma solução. Já a rotulação realizada pelo usuário (Grupo 05), onde quase 100 % dos instrumentos são homogêneos, precisam apenas um descritor para classificar os instrumentos. Este fato é devido ao grande desbalanceamento da classe, onde 99,35% das regiões são consideradas como homogêneas (vide Tabela 5.4) e também devido às características dos classificadores empregados neste trabalho, que envolvem treinamento.

5.6 Conclusões sobre os Experimentos Computacionais e Avaliação Subjetiva

A metodologia proposta neste trabalho se mostrou eficaz em sua tarefa de identificar automaticamente regiões não homogêneas em um instrumento, e assim classificar este como aprovado ou não.

Observou-se que os dois classificadores utilizados neste trabalho (ANN e SVM) obtiveram resultados muito próximos, tanto para avaliação dos usuários quanto a avaliação do especialista. Ressalta-se que para o classificador SVM foram necessários menos descritores para reportar resultados similares.

As avaliações foram divididas em dois grupos:

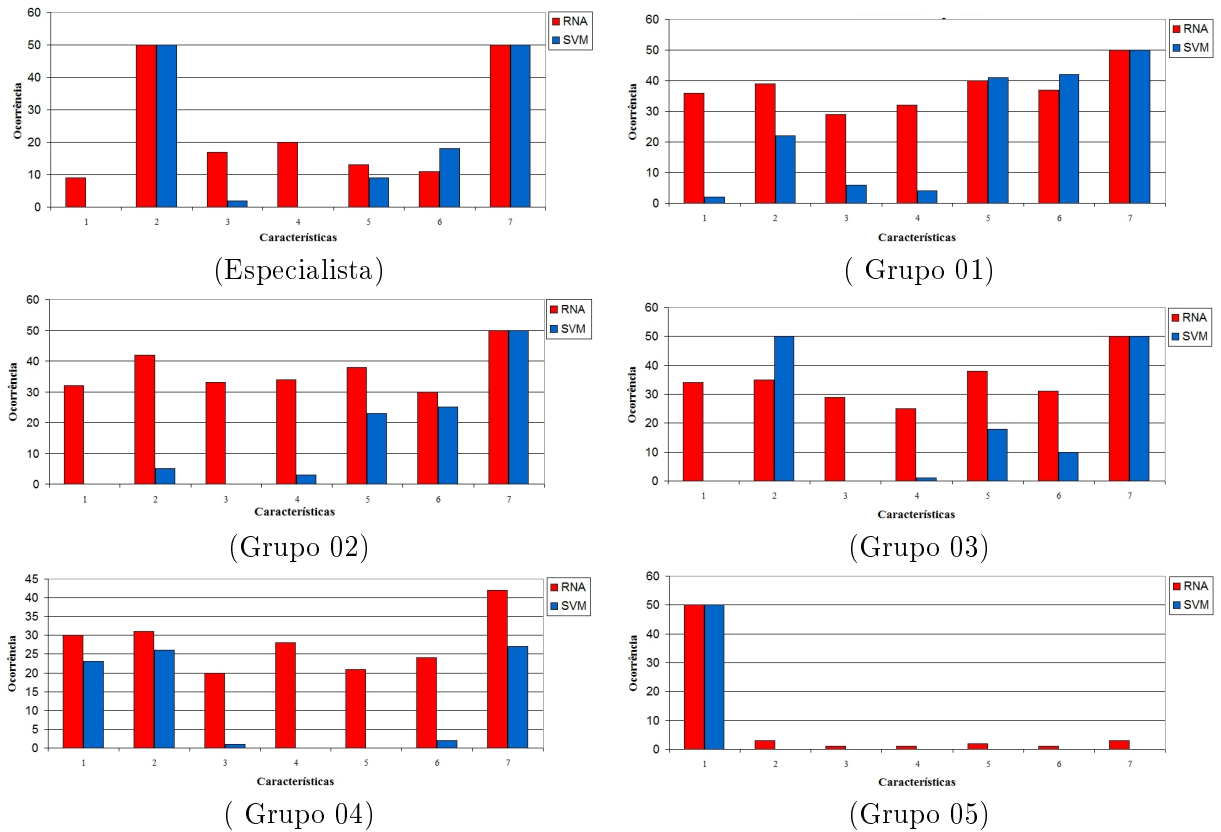


Figura 5.15: Análise da ocorrência dos descritores, nas 50 melhores execuções.

1. Rotulação com o especialista: Aprendizado adequado dos algoritmos; classificação entre as classes (Homogêneas e Não Homogêneas) bem equilibrada e alta precisão na classificação final do instrumento (aprovado *versus* reprovado);
2. Rotulação com os usuários: Aprendizado deficiente dos algoritmos; desequilíbrio na classificação das classes (maior aprendizado na classe homogênea) e classificação final do instrumento com erros críticos (aprovação de instrumentos ruins).

Em relação às avaliações com o ser humano, as avaliações realizadas com os usuários demonstraram que ocorre uma grande dispersão dos resultados durante a avaliação. Ao deixar o usuário livre para realizar as rotulações, sem nenhuma indicação, a percepção do mesmo muda consideravelmente, conforme a característica do usuário, *e.g.*, mais crítico, mais complacente, relapso, *etc.*

A avaliação técnica do especialista proporcionou melhor aprendizado pelos classificadores. Por meio das avaliações dos usuários sobre a avaliação do especialista, foi possível perceber que o especialista representa bem a percepção média dos usuários, obtendo um índice de aceitação superior a 90%.

5.7 Considerações

Neste capítulo, foram apresentados a base de imagens utilizadas no trabalho e os seguintes experimentos: configuração dos parâmetros de câmera; definição da arquitetura dos classificadores (ANN e SVM); avaliação com usuários e especialista; e validação geral da metodologia proposta. Tais experimentos apresentaram resultados satisfatórios, validando a eficácia da metodologia proposta.

A metodologia proposta apresenta duas vantagens principais sobre o método que utiliza o espectrofotômetro: baixo custo e velocidade. Essas características permitem ao fabricante de painéis de instrumentos automotivos a possibilidade de aplicar a metodologia em vários pontos de sua linha de produção, aumentando o controle. Com isso, o número de reprovações que ocorrem na montadora, devido a instrumentos com má iluminação, poderá diminuir consideravelmente.

Capítulo 6

Conclusões e Trabalhos Futuros

Estudos que buscam mapear, caracterizar e compreender as percepções humanas são tanto atraentes quanto complexos. As sensações humanas são fruto da trajetória de vida de cada indivíduo, do caminho percorrido, dos conhecimentos adquiridos, *etc.* A percepção do mundo, através dos sentidos, é algo baseado em experiências pessoais e daí a sua complexidade.

Neste trabalho foi apresentada uma metodologia para validação automática de instrumentos de painéis automotivos com base em homogeneidade, utilizando análise de imagens, inteligência computacional e avaliações com o ser humano. Para alimentar os algoritmos de aprendizado de máquina utilizados (ANN e SVM), objetivando a classificação das regiões como homogêneas ou não, foram realizados experimentos com especialista e usuários.

Os dois classificadores utilizados neste trabalho (ANN e SVM) obtiveram resultados muito próximos, tanto para avaliação dos usuários quanto a avaliação do especialista, porém a SVM utilizou menos descritores para reportar estes resultados.

As avaliações com os usuários apresentaram grande dispersão entre os resultados, prejudicando desta forma o treinamento dos classificadores. Por outro lado, as avaliações realizadas pelo especialista apresentaram boa consistência e obtiveram índices de aceitação maiores que 90% pelos usuários.

Como apresentado na introdução, a aplicação desta metodologia na indústria ajudará a ganhar qualidade e tempo precioso na fase de desenvolvimento de novos instrumentos, auxiliando tanto a fase de testes experimentais na montadora como indicando ao fabricante os pontos que devem ser melhorados em seu projeto.

Os resultados experimentais indicam que a metodologia proposta se mostra eficiente, obtendo índices de precisão, na classificação tanto das regiões quanto dos instrumentos, acima de 94%.

6.1 Trabalhos Futuros

O trabalho apresentado nesta dissertação pode ser estendido de forma a gerar novos estudos, explorando os seguintes pontos:

- Visando obter uma metodologia mais robusta, estudos sobre parâmetros adaptativos de pré-processamento da imagem podem ser realizados, *e.g.*, nível de limiarização e erosão. Com esses parâmetros adaptativos, poderá ser realizada captura de imagens com diferentes câmeras fotográficas e resoluções de imagem;
- Estudos com outros algoritmos de classificação, *e.g.*, Lógica Fuzzy (Sivanandam et al., 2007), Árvore de decisão (Duda et al., 2000), *etc.* E também abordagens não supervisionadas, na qual o classificador determinará, sem intervenção externa, qual classe a região pertence;
- Implementação de um “orientador”, de forma que seja possível indicar qual a solução para a região identificada como não homogênea. Com essa extensão, seria possível dizer que tipo de correção será necessário: aumento ou diminuição da intensidade;
- Estender este trabalho, com o intuito de mapear outras percepções dos sentidos humanos. Uma extensão poderia ser a aplicação da metodologia para validação de sistemas de áudio, com relação à qualidade auditiva percebida pelo usuário.

6.2 Publicações Oriundas deste Trabalho

- Faria, A.; Menotti, D.; Lara, D.; Pappa, G. e Araújo, A. de A. (2010). A New Methodology for Photometric Validation in Vehicles Visual Interactive Systems. *In: Association for Computing Machinery - XXIV Symposium On Applied Computing, Track: Computational Intelligence and Image Analysis; Switzerland. XXIV ACM SAC 2010. p. 1-6. <http://www.acm.org/conferences/sac/sac2010/>; (Aceito para publicação)*
- Faria, A.; Menotti, D.; Lara, D. e Araújo, A. de A. (2009). Uma Metodologia para Validação Fotométrica em Sistemas Interativos Visuais Baseada em Inteligência Computacional. *In: IX Congresso Brasileiro de Redes Neurais/Inteligência Computacional, 2009, Ouro Preto. IX CBRN 2009. p. 1-5. <http://www.cbrn2009.lps.ufrj.br>*

Apêndice A

Instrumentos Utilizados

As Tabelas A.1, A.2 e A.3 apresentam as informações dos instrumentos utilizados nos experimentos. Nas tabelas são descritos: O número; o código; tipo de instrumento; sua cor e o número de regiões que cada instrumento possui.

Tabela A.1: Instrumentos avaliados

<i>N</i> ^o	Código	Instrumento	Cor	<i>N</i> ^o Regiões
1	F20	Indicador de Combustível	Vermelho	5
2	F35	Indicador de Combustível	Vermelho	5
3	F36	Indicador de Combustível	Vermelho	5
4	F6	Indicador de Combustível	Ambar	5
5	F17	Indicador de Combustível	Amarelo	6
6	F26	Indicador de Combustível	Ambar	6
7	T17	Indicador de Temperatura	Amarelo	6
8	T20	Indicador de Temperatura	Vermelho	8
9	T41	Indicador de Temperatura	Vermelho	8
10	T42	Indicador de Temperatura	Vermelho	8
11	T6	Indicador de Temperatura	Vermelho	8
12	F21	Indicador de Combustível	Ambar	9
13	F22	Indicador de Combustível	Ambar	9
14	F23	Indicador de Combustível	Ambar	9
15	F24	Indicador de Combustível	Ambar	9
16	F25	Indicador de Combustível	Ambar	9
17	F28	Indicador de Combustível	Ambar	9
18	F30	Indicador de Combustível	Ambar	9
19	F31	Indicador de Combustível	Branca	9
20	F33	Indicador de Combustível	Ambar	9
21	T32	Indicador de Temperatura	Ambar	9
22	T38	Indicador de Temperatura	Branca	9
23	T21	Indicador de Temperatura	Ambar	10
24	T22	Indicador de Temperatura	Ambar	10
25	T25	Indicador de Temperatura	Ambar	10
26	T36	Indicador de Temperatura	Ambar	10
27	T26	Indicador de Temperatura	Ambar	12
28	T29	Indicador de Temperatura	Ambar	12
29	T30	Indicador de Temperatura	Ambar	12
30	T31	Indicador de Temperatura	Ambar	12

Tabela A.2: Instrumentos avaliados (Continuação)

N°	Código	Instrumento	Cor	N° Regiões
31	T34	Indicador de Temperatura	Ambar	12
32	T35	Indicador de Temperatura	Ambar	12
33	T37	Indicador de Temperatura	Ambar	12
34	T39	Indicador de Temperatura	Ambar	12
35	F18	Indicador de Combustível	Ambar	16
36	F12	Indicador de Combustível	Azul	17
37	F1	Indicador de Combustível	Ambar	19
38	F10	Indicador de Combustível	Verde	19
39	F11	Indicador de Combustível	Ambar	19
40	F13	Indicador de Combustível	Azul	19
41	F14	Indicador de Combustível	Ambar	19
42	F15	Indicador de Combustível	Ambar	19
43	F3	Indicador de Combustível	Ambar	19
44	F37	Indicador de Combustível	Ambar	19
45	F38	Indicador de Combustível	Ambar	19
46	F39	Indicador de Combustível	Ambar	19
47	F4	Indicador de Combustível	Azul	19
48	F40	Indicador de Combustível	Ambar	19
49	F5	Indicador de Combustível	Verde	19
50	T18	Indicador de Temperatura	Ambar	19
51	T1	Indicador de Temperatura	Ambar	22
52	T10	Indicador de Temperatura	Verde	22
53	T11	Indicador de Temperatura	Ambar	22
54	T12	Indicador de Temperatura	Azul	22
55	T13	Indicador de Temperatura	Azul	22
56	T14	Indicador de Temperatura	Ambar	22
57	T15	Indicador de Temperatura	Ambar	22
58	T3	Indicador de Temperatura	Ambar	22
59	T4	Indicador de Temperatura	Azul	22
60	T43	Indicador de Temperatura	Ambar	22
61	T44	Indicador de Temperatura	Ambar	22
62	T45	Indicador de Temperatura	Ambar	22
63	T46	Indicador de Temperatura	Ambar	22
64	T5	Indicador de Temperatura	Verde	22
65	C10	Conta Giros - RPM	Amarelo	25
66	C18	Conta Giros - RPM	Ambar	28
67	C15	Conta Giros - RPM	Ambar	30
68	F16	Indicador de Combustível	Ambar	30
69	C14	Conta Giros - RPM	Vermelho	31
70	T16	Indicador de Temperatura	Ambar	33
71	V38	Velocímetro	Branca	33
72	V17	Velocímetro	Amarelo	34
73	V21	Velocímetro	Ambar	36
74	V25	Velocímetro	Ambar	36
75	V28	Velocímetro	Ambar	36

Tabela A.3: Instrumentos avaliados (Continuação b)

<i>N</i> ^o	Código	Instrumento	Cor	<i>N</i> ^o Regiões
76	C4	Conta Giros - RPM	Vermelho	40
77	C34	Conta Giros - RPM	Ambar	43
78	C35	Conta Giros - RPM	Vermelho	44
79	C22	Conta Giros - RPM	Ambar	45
80	C23	Conta Giros - RPM	Ambar	48
81	C7	Conta Giros - RPM	Verde	49
82	C9	Conta Giros - RPM	Ambar	49
83	C1	Conta Giros - RPM	Ambar	59
84	C37	Conta Giros - RPM	Ambar	59
85	V42	Velocímetro	Vermelho	59
86	C3	Conta Giros - RPM	Verde	60
87	C36	Conta Giros - RPM	Ambar	60
88	C38	Conta Giros - RPM	Ambar	60
89	C39	Conta Giros - RPM	Ambar	60
90	C8	Conta Giros - RPM	Ambar	60
91	V41	Velocímetro	Vermelho	60
92	V45	Velocímetro	Ambar	74
93	V1	Velocímetro	Ambar	76
94	V34	Velocímetro	Ambar	76
95	V43	Velocímetro	Ambar	77
96	V10	Velocímetro	Verde	78
97	V30	Velocímetro	Ambar	80
98	V4	Velocímetro	Azul	80
99	V11	Velocímetro	Ambar	81
100	V12	Velocímetro	Azul	81
101	V3	Velocímetro	Ambar	81
102	V46	Velocímetro	Ambar	81
103	V14	Velocímetro	Ambar	82
104	V44	Velocímetro	Ambar	82
105	V13	Velocímetro	Azul	83
106	V5	Velocímetro	Verde	89
107	V15	Velocímetro	Ambar	90

Referências Bibliográficas

- Acharya, T. e Ray, A. K. (2005). *Image Processing; Principles and Applications*. John Wiley & Sons, 3a. edição.
- Ahengyao, W. e Ling, M. (2006). Implementation of region-mura detection based on recursive polynomial-surface fitting algorithm. In *2nd Asia International Symposium on Mechatronics (AISM)*, volume 6, pp. 1–6.
- Archarya, T. e Ray, A. (2005). *Image processing, Principles and Applications*. John Wiley & Sons, 1a. edição.
- Bosch, R. (2007). *Automotive Handbook*. John Wiley & Sons, England.
- Boser, B. E.; Guyon, I. L. e Vapnik, V. N. (1992). A training algorithm for optimal margin classifiers. In *5th Annual Workshop on Computational Learning Theory*, volume 8, pp. 144–152.
- Castineira, F.; Dieguez, D. e Castano, F. (2009). Integration of nomadic devices with automotive user interfaces. *IEEE Transactions on Consumer Electronics*, 55(1):31–34.
- Chang, C.-C. e Lin, C.-J. (2001). *LIBSVM: a library for support vector machines*. software disponível em <http://www.csie.ntu.edu.tw/~cjlin/libsvm>.
- Cheng, H. e Sun, Y. (2000). A hierarchical approach to color image segmentation using homogeneity. *IEEE Transactions on Image Processing*, 9(12):2071–2082.
- Cheng, H. D.; Xue, M. e Shi, X. J. (2003). Contrast enhancement based on a novel homogeneity measurement. *Pattern Recognition*, 36(11):2687–2697.
- Choi, K. N.; Lee, J. Y. e S.I.Yoo (2004). Area mura detection in TFT-LCD panel. *SPIE Society of Photographic Instrumentation Engineers*, 530(8):1–8.
- C.M.Bishop (2006). *Pattern Recognition and Machine Learning*. Springer Science.
- Cortes, C. e Vapnik, V. (1995). Support-vector networks. In *Machine Learning*, pp. 273–297. Springer.

- Duda, R.; Hart, P. e Stork, D. (2000). *Pattern Classification*. Wiley-Interscience, 2a. edição.
- Facon, J. (1996). *Morfologia Matemática: Teoria e Exemplos*. Jacques Facon.
- Faria, A.; Menotti, D.; Lara, D. e Araújo, A. (2009). Uma metodologia para validação fotométrica em sistemas interativos visuais baseada em inteligência computacional. In *IX Congresso Brasileiro de Redes Neurais/Inteligência Computacional*, pp. 1–5.
- Faria, A.; Menotti, D.; Lara, D.; Pappa, G. e Araújo, A. (2010). A new methodology for photometric validation in vehicles visual interactive systems. In *XXIV ACM Symposium On Applied Computing, Track: Computational Intelligence and Image Analysis*, pp. 1–6.
- Fukunaga, K. e Hummels, D. (1989). A leave-one-out procedures for nonparametric error estimates. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 11(4):421–423.
- Gimena, L. (2004). Exposure value in photography: A graphics concept map proposal. In *First International Conference on Concept Mapping*, pp. 256–259, Pamplona, Spain.
- Gonzalez, R. e Woods, R. (2007). *Digital Image Processing*. Prentice Hall, New Jersey, EUA, 3a. edição.
- Guimarães, A. (2007). *Eletrônica Embarcada Automotiva*. Editora Érica.
- Haykin, S. (1997). *Neural Networks, A comprehensive Foundation*. Prentice-Hall, New Jersey-EUA, 2a. edição.
- Hebb, D. O. (1949). *The Organization of Behavior*. Jonh Wiley & Sons.
- Hedgecoe, J. (2006). *O Novo Manual de Fotografia: Guia Completo para Todos os Formatos*. SENAC, São Paulo, 3a. edição.
- Heskett, J. (1998). *Desenho Industrial*. José Olympio, 2a. edição.
- Hopfield, J. (1982). Neural networks and physical systems with emergent collective computational abilities. *The National Academy of Sciences*, 79(4):2554–2558.
- Huang, Y.; Mouzakitis, A.; McMurrin, R.; Dhadyalla, G. e Jontes, P. (2008). Design validation testing of vehicle instrument cluster using machine vision and hardware in the loop. In *IEEE International Conference on Vehicular Electronics and Safety*, pp. 22–24.
- Jain, A. (1989). *Fundamentals of Digital Image processing*. Prentice Hall, California, EUA.
- Jinxiu, L.; Junli, L. e Ping, W. (2007). Pseudocolor coding of medical images based on gradient. In *1st International Conference on Bioinformatics and Biomedical Engineering (ICBBE)*, volume 4, pp. 932–935.

- Kebin, A.; Jun, S. e Weina, D. (2005). Homogeneity based image objective quality metric. In *International Symposium on Intelligent Signal Processing and Communication System*, volume 4, pp. 649–652.
- Kim, J.; Cho, M. e Choi, B. (2004). Study on the methods of digital image quality evaluation. In *IEEE Region 10 Conference TENCN*, volume 1, pp. 359–362.
- Kroemer, K.; Kroemer, H. e Kroemer-Elbert, K. (1994). *Ergonomics: How to Design for Ease and Efficiency*. Prentice Hall, 1a. edição.
- Lee, J. e Yoo, S. (2004). Automatic detection of region-mura defect in tft-lcd. *IEICE Transactions on Information and Systems*, E87-D(10):2371–2378.
- Lorena, A. C. e Carvalho, A. C. P. L. F. (2007). Introdução às máquinas de vetores suporte (support vector machines). *Revista de Informática Teórica e Aplicada*, XIV(2):65–86.
- Martinez, J.; Sanches, D.; Prados, B. e Pereles, F. (2005). Fuzzy homogeneity measures for path-based colour image segmentation. In *14th IEEE International Conference on Fuzzy Systems*, volume 5, pp. 218–223.
- Martinez, W. e Martinez, A. (2005). *Exploratory Data Analysis with MATLAB - Computer Science and Data Analysis Series*. Chapman & Hall/CRC.
- McCulloch, K. e Pitts, W. (1943). Va logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, 24(18):115–133.
- Niblack, W. (1986). *An Introduction to Image Processing*. Prentice-Hall.
- Oh, J.; Yun, B. e Park, K. (2007). The defect detection using human visual system and wavelet transform in tft-lcd image. In *Frontiers in the Convergence of Bioscience and Information Technologies (FIBIT)*, pp. 498–503.
- Oleari, C. (1998). *Misurare Il colore, Spettrofotometria, fotometria e colorimetria: Fisiologia e percezione*. JHo-epli, 1a. edição.
- Otsu, N. (1979). A threshold selection method from gray level histograms. *IEEE Transactions on Systems, Man and Cybernetics*, 9(5):62–66.
- Pratt, W. (1991). *Digital Image Processing*. John Wiley & Sons, 2a. edição.
- Provost, F.; Fawcett, T. e Kohavi, R. (1998). The case against accuracy estimation for comparing induction algorithms. In *15th International Conference on Machine Learning*, pp. 445–553.
- Rosenblatt, F. (1958). The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, 32(18):386–408.

- Sagawa, K. (1999). Visual comfort to colored images evaluated by saturation distribution. *Color Research and Application*, 24(5):313–321.
- Santos, G. (2008). Aplicação de redes neurais para diagnóstico de poluição em isoladores de alata tensão. Dissertação de mestrado, UFPE.
- Schmitt, M. e Mattioli, J. (1994). *Morphologie Mathématique*. Masson Editeur.
- Segaran, T. (2007). *MProgramming Collective Intelligence: Building Smart Web 2.0 Applications*. O Reilly Media Inc., 1a. edição.
- Sezgin, M. (2004). Survey over image thresholding techniques and quantitative performance evaluation. *Journal of Electronic Imaging*, pp. 146–165.
- Shapiro, L. e Stockman, G. (2002). *Computer Vision*. Prentice Hall, Seattle, EUA.
- Singh, S. e Singh, M. (2004). A novel measure of estimation color purity of image regions. In *International Conference on Computational Intelligence for Homeland and Personal Safety*, volume 4, pp. 5–9.
- Sivanandam, S.; Sumathi, S. e Deppa, S. (2006). *Introduction to Neural Networks using Matlab 6.0*. McGraw-Hill Publishing Company Limited, New Delhi, India.
- Sivanandam, S.; Sumathi, S. e Deppa, S. (2007). *Introduction to Fuzzy Logic using Matlab*. Springer, Berlin, Alemanha.
- Suarez, B.; Martinez, J. e Sanches, D. (2007). Region based fit of color homogeneity measures for fuzzy image segmentation. *Fuzzy Sets and Systems*, 158(14):215–229.
- Taniguchi, K.; Ueta, K. e Tatsumi, S. (2006). A mura detection method. *Pattern Recognition*, 39(8):1044–1052.
- Walraven, J. e Alferdinck, J. (2001). *Visual Ergonomics of Colour-Coded Cockpit Displays: A Generic Approach*. The Research And Technology Organization (RTO), 2a. edição.
- Wang, H. e Suter, D. (2003). Color image segmentation using global information and local homogeneity. In *VII Digital Image Computing: Techniques and Applications (DICTA)*, volume 9, pp. 89–98.
- Wei, Z.; Xian-Kui, Z.; Lei, Z.; Rui, Z. e C.Z.Bin (2006). Study on the evaluation system of instrument cluster. In *Computer Aided Industrial Design and Conceptual Design*, pp. 1–5.
- Widrow, W. e Hoff, M. (1960). Adaptive switching circuits. *WESCON Convention Record*, 8:96–104.

Zhou, X.; Zhang, C. e Li, S. (2007). A perceptive uniform pseudo color coding method of sar images. In *CIE International Conference on Radar*, volume 4, pp. 16–19.