

# Uma Metodologia para Validação Fotométrica em Sistemas Interativos Visuais Baseada em Inteligência Computacional

Alexandre W.C. Faria, Daniel S.D. Lara, Arnaldo de A. Araújo

Departamento de Ciência da Computação  
Universidade Federal de Minas Gerais  
Belo Horizonte, Minas Gerais, Brasil  
{awcfaria,daniels,arnaldo}@email.com

David Menotti

Departamento de Computação  
Universidade Federal de Ouro Preto  
Ouro Preto, Minas Gerais, Brasil  
{menottid}@gmail.com

**Resumo** – Neste artigo, é apresentada uma metodologia automática para a validação fotométrica em sistemas de iluminação interna veicular. Nessa metodologia, propõe-se um método para extração de descritores de homogeneidade de cada região de avaliação. A percepção visual humana, representada pela avaliação do usuário, é usada para classificar as regiões em homogêneas e não-homogêneas. Dois algoritmos de aprendizado de máquina (Redes neurais e *Support Vector Machine*) são usados para a classificação de regiões visando identificar quais as melhores configurações de descritores irá representar a percepção do usuário em relação à homogeneidade da iluminação dos sistemas de interação com o motorista. Resultados experimentais mostram que a metodologia proposta consegue diferenciar regiões homogêneas de não-homogêneas com precisão superior à 90%.

**Palavras-chave** – Homogeneidade, segmentação, classificação de padrões, avaliação com usuário, aprendizado de máquina.

**Abstract** – This paper presents an automatic methodology for the photometric validation of an automotive internal illumination system. In the methodology, we propose a method for homogeneity descriptors extraction from each region of evaluation. The human visual perception, represented by the user evaluation, is used to classify the regions as non- and homogeneous. Two machine learning algorithms (Artificial Neural Network and Support Vector Machine) are used for region classification based on the classical extracted homogeneity descriptors guided (*i.e.*, supervised) by the user's perception. Experimental results show that the proposed methodology reach precision above 90% on the classification of non- and homogeneous regions.

**Keywords** – Homogeneity, segmentation, pattern classification, user interaction and evaluation.

## 1. INTRODUÇÃO

Informações visuais representam uma das maneiras mais comuns de interação entre o ser humano e as máquinas [1]. Em veículos, esta interação com o condutor é realizada através da leitura do painel de instrumentos (velocímetro, conta-giros, nível de combustível e temperatura, *etc.*), a operabilidade do rádio, comandos e outros componentes. Neste sentido, é de extrema importância que a iluminação interna de um veículo apresente boa harmonia com o condutor, seja durante o dia ou durante a noite. Para alcançar esta harmonia, o desenvolvimento industrial leva em conta características fotométricas dos componentes, tais como: intensidade, cor e homogeneidade, são estudadas e medidas. A maioria das metodologias atuais para validação do sistema de iluminação interna veicular é baseada em inspeção visual ou é semi-automática.

As metodologias mencionadas anteriormente trazem consigo algumas desvantagens: falta de repetibilidade na inspeção visual; uso de equipamento específico e de alto custo; grande tempo de medição, *etc.* Em relação ao último, a simples análise de um painel de instrumentos pode consumir horas para medição. Por exemplo, um painel veicular contém em média 400 pontos possíveis de medição. Em geral, com o uso de um espectrofotômetro<sup>1</sup> leva-se aproximadamente 15 segundos para cada medição, adicionando aproximadamente mais 10 segundos para reposicionamento do instrumento, atinge-se um tempo aproximado de 3 horas. Além do grande tempo para coletar as medições, a análise dos dados não possui um critério científico para determinar o nível de homogeneidade baseado na percepção humana.

Na literatura, existem diversos esforços para identificação automática de MURA<sup>2</sup> em monitores e *displays*, utilizando análise de imagens [2, 3]. Contudo, tais metodologias são mais adequadas quando aplicadas em uma única imagem de superfície. Quando se trabalha com iluminação de componentes veiculares, é bem usual que um instrumento seja composto por várias e

<sup>1</sup>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.

<sup>2</sup>MURA é uma palavra japonesa utilizada para descrever uma variação não uniforme da intensidade local em uma região, que não apresenta um contorno definido, a qual é percebida como uma sensação visual não agradável.

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 componente.




Figura 1: Problemas típicos envolvendo homogeneidade: (a) Maior concentração de intensidade no meio do componente; (b) Dígitos mais intensos que outros, e regiões bem escuras que outras; (c) Maior intensidade no lado esquerdo que no lado direito.

O objetivo principal deste trabalho é desenvolver uma metodologia, baseada na percepção visual humana (avaliação de usuários), para automaticamente identificar e quantificar regiões com distribuição de iluminação não homogênea (Figura 1) sobre os componentes de iluminação veicular, contribuindo de maneira efetiva, para o processo industrial de desenvolvimento do sistema de iluminação interna veicular.

As demais seções deste trabalho são organizadas da seguinte forma: A Seção 2 descreve o procedimento de calibração e aquisição da imagem para uso neste trabalho. A metodologia proposta é apresentada na Seção 3. Na Seção 4, são abordados os algoritmos usados para classificação das regiões, enquanto que na Seção 5 são apresentados os experimentos para validação da proposta. Finalmente, conclusões e trabalhos futuros são apresentadas na Seção 6.

## 2. CALIBRAÇÃO RADIOMÉTRICA E AQUISIÇÃO DE IMAGEM

O processo de aquisição da imagem é um passo muito importante para o sucesso da metodologia proposta. É necessário que a imagem adquirida dos instrumentos em análise reproduza fielmente o padrão da distribuição da iluminação sobre o componente.

Em fotografia, parâmetros como a velocidade do obturador ( $s$ ) e abertura do diafragma ( $f - stop$ ) tem grande influência [4] na exposição da imagem (Figura 2).




Figura 2: Influência dos parâmetros de câmera na distribuição da iluminação.

A fim de obter fotografias/imagens confiáveis, que representem bem a distribuição da iluminação, dois painéis de instrumentos, de cores diferentes, foram medidos com um espectrofotômetro.

Para os dois painéis, 52 medidas foram realizadas em cada um deles medindo os principais pontos em cada instrumento (Figura 3). Seis imagens foram adquiridas através de câmeras digitais profissionais com variações de  $s$  ( $1/5''$ ;  $1/8''$ ;  $1/10''$ ;  $1/13''$ ;  $1/15''$  e  $1/20''$ ) e tendo  $f - stop$  fixo em 2,7.

Para cada imagem adquirida foram lidos os valores dos *pixels* da imagem nos mesmos pontos onde foram realizadas as medidas com o espectrofotômetro. Os valores dos *pixels* da imagem foram tomados como sendo o canal  $V$  (valor/intensidade)



Figura 3: Pontos de medição com o espectrofotômetro.

do sistema de cores *HSV*, ou seja a intensidade/brilho dos *pixels*. Os valores medidos pelo espectrofotômetro e os valores lidos pelos *pixels* na imagem, foram então normalizados ( $x - \min / (\max - \min)$ ) para realizar uma comparação com objetivo de determinar a configuração de câmera (*s* e *f-stop*) que melhor irá representar as medidas obtidas pelo espectrofotômetro. O resultado dessa comparação foi feito através do erro médio quadrático entre o valor lido pelo espectrofotômetro e o valor do *pixel* no ponto na imagem e pode ser observado na Tabela 1.

Tabela 1: Erro médio quadrático (*EMQ*) entre o valor lido pelo espectrofotômetro e o valor do *pixel* no ponto na imagem.

<i>s</i>	<i>EMQ</i>	<i>s</i>	<i>EMQ</i>
1/5"	0,182	1/8"	0,108
1/10"	0,099	1/13"	0,055
<b>1/15"</b>	<b>0,036</b>	1/20"	0,069

Analisando esses dados, fica evidente que a configuração de câmera que melhor representa a medição do espectrofotômetro é a configuração com velocidade de obturador (*s*) igual a 1/15". Portanto, ficou configurado *f-stop* como 2,7 e *s* como 1/15" para aquisição de todas as imagens usadas neste trabalho.

### 3. METODOLOGIA

Nesta seção, são descritos os procedimentos para identificar de forma automática regiões não homogêneas em imagens digitais de sistemas de iluminação interna.

#### 3.1. AVALIAÇÃO SUBJETIVA COM USUÁRIOS

O objetivo da realização de avaliação de componentes luminosos por usuários é permitir que um algoritmo de aprendizado de máquina possa caracterizar as regiões que não apresentam homogeneidade perceptíveis pelo ser humano. Essa caracterização irá permitir que a metodologia proposta possa classificar automaticamente regiões com falta de homogeneidade nos componentes em análise, levando em conta a percepção humana.

Todas as avaliações foram conduzidas em uma câmera escura, com todas as luzes apagadas, emulando uma condição real de noite. O componente foi montado em uma bancada de teste, respeitando a posição e inclinação média que este componente iria ter em um veículo, em relação ao motorista.

#### 3.2. PRÉ-PROCESSAMENTO DA IMAGEM

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


a) Conversão da imagem, de *RGB* (*Red*, *Green* e *Blue*) para o espaço de cores *HSV* (*Hue*, *Saturation* e *Value*). A escolha do modelo *HSV* é devido o mesmo descrever as cores de forma mais intuitiva que o modelo *RGB*. O canal *V* (valor/intensidade/brilho/luminância) é levado em conta como sendo o representante da intensidade da luz [5].

b) Binarização da imagem. Binarização é um processo de limiarização [5], onde níveis acima de um dado valor (*Threshold*) da imagem são considerados como objeto (1) e inferior (ou igual) são considerados como fundo (0).

c) Erosão. O objetivo da erosão neste trabalho, foi eliminar os *pixels* indesejados de borda, devido a resolução da câmera utilizada. A erosão é uma operação morfológica [5] e sua utilização visa eliminar detalhes irrelevantes de um objeto a partir da redução dos *pixels* das bordas que compõem uma imagem.



(a)



(b)

Figura 4: O ambiente de avaliação.

d) Rotulação dos componentes conexos [6]. Esse algoritmo será 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.

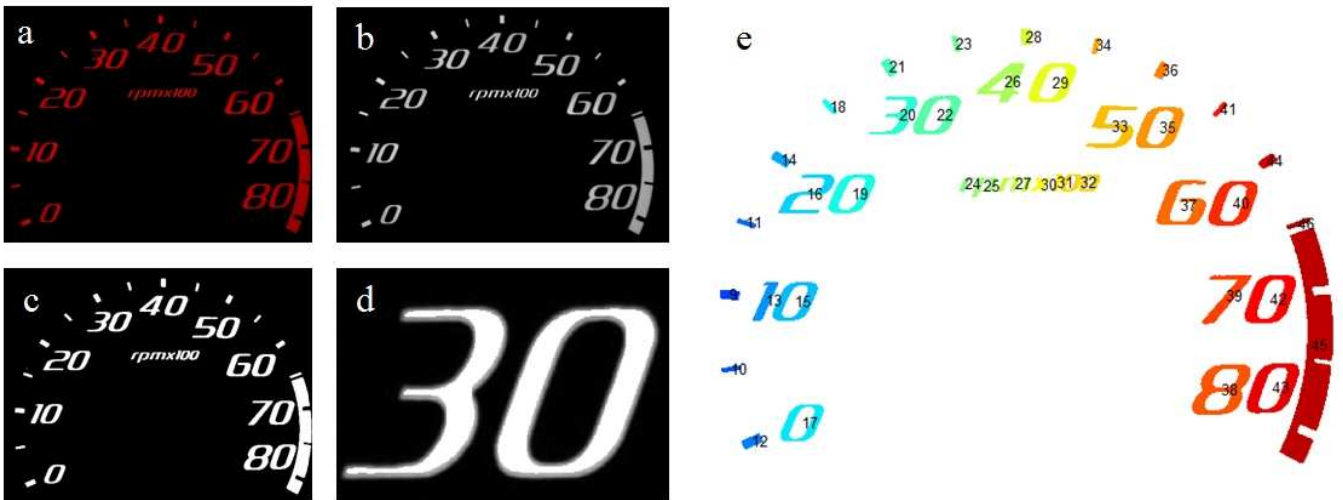


Figura 5: Fases do Pré-Processamento: (a) Imagem original; (b) Canal  $V$  do espaço  $HSV$ ; (c) Imagem binarizada; (d) Aplicação da erosão; (e) Rotulação das regiões conexas.

### 3.3. EXTRAÇÃO DE DESCRITORES DE HOMOGENEIDADE

Após ter encontrado as regiões na imagem, realiza-se a extração de descritores para representar a homogeneidade da iluminação em cada região. Existem na literatura diversos métodos para computar a homogeneidade em uma região na imagem [2, 5, 7].

Neste trabalho adotam-se descritores clássicos. Seja  $r$  uma variável aleatória denotando o nível de intensidade  $r$  em uma imagem  $I$ . Seja  $P_I(r_i)$ , com  $i = 0, 1, 2, \dots, L - 1$  a probabilidade do nível de intensidade  $r_i$  na imagem  $I$ , onde  $L$  representa o número de níveis distintos de intensidade. Seja ainda o  $n$ -ésimo momento estatístico do histograma (função de distribuição de probabilidade) da imagem, *i.e.*

$$\mu_n(I) = \sum_{i=0}^{L-1} (r_i - m(I))^n P_I(r_i), \quad (1)$$

onde

$$m(I) = \sum_{i=0}^{L-1} (r_i \times P_I(r_i)). \quad (2)$$

Logo, definem-se os descritores de homogeneidade de cada região em função de  $P_I(r_i)$ , *i.e.*,

$$\sigma(I) = \sqrt{\mu_2(I)} = \sqrt{\sigma^2(I)}, \quad (3)$$

$$\mu_3(I) = \sum_{i=0}^{L-1} (r_i - m(I))^3 P_I(r_i), \quad (4)$$

$$R(I) = 1 - 1/(1 + \sigma^2(I)), \quad (5)$$

$$U(I) = \sum_{i=0}^{L-1} P_I^3(r_i), \quad (6)$$

$$e(I) = - \sum_{i=0}^{L-1} P_I(r_i) \times \log_2 P_I(r_i), \quad (7)$$

e um descritor proposto por [2], *i.e.*,

$$GUL(I) = (I(\min)/I(\max)) * 100, \quad (8)$$

onde  $I(\min)$  e  $I(\max)$  representam a intensidade mínima e a máxima em uma região (imagem  $I$ ), respectivamente.

Todos os descritores apresentados acima: desvio padrão; terceiro momento; uniformidade; entropia; suavidade; mais o descrito por [2] (representados respectivamente pelas Equações de 3 a 8), serão aplicados sobre as regiões encontradas na seção anterior. A função dessas características é descrever o grau da sensação de homogeneidade percebida pelo especialista nas avaliações apresentadas na Seção 3.1.

#### 4. APRENDIZADO DE MÁQUINA

Nesta seção, apresentam-se brevemente conceitos sobre algoritmos de aprendizado de máquina. O aprendizado de máquina, uma subárea de Inteligência Artificial, dedica-se ao desenvolvimento de algoritmos que melhoram automaticamente seus resultados através de experiências ou treinamento [8]. A etapa de aprendizado pode ser dividida em dois tipos principais: supervisionada e não-supervisionada. Na execução deste trabalho, é utilizado o aprendizado supervisionado, pois são conhecidos os rótulos das regiões para o treinamento. Foram utilizados nesse trabalho dois algoritmos: Máquina de Vetores de Suporte (SVM) e Redes Neurais Artificiais (RNA).

Máquinas de Vetores de Suporte (SVM) vêm recebendo crescente atenção nos últimos anos, sendo utilizadas em diversas tarefas em diversas esferas de aplicação [9]. SVM é um algoritmo de aprendizado de máquina, baseado na construção de hiperplanos que possibilitem a maximização da margem de separação entre grupos de análise e ao mesmo tempo minimização do erro de treinamento.

Redes Neurais Artificiais são sistemas computacionais inspirados em neurônios biológicos humanos e na estrutura paralela do cérebro, com capacidade de adquirir, armazenar e utilizar conhecimento experimental [10]. A aprendizagem das redes neurais é realizada quando modificações ocorrem nas sinapses, essas mudanças ocorrem de acordo com o processo de ativação dos neurônios.

#### 5. EXPERIMENTOS E RESULTADOS

Nesta seção, são apresentados e discutidos experimentos realizados para validar a metodologia proposta. A metodologia computacional descrita nas seções anteriores foram integralmente implementada em MatLab. Foram utilizadas 16 imagens de diferentes instrumentos, 4 velocímetros, 4 marcadores de combustível, 4 marcadores de temperatura e 4 conta giros. Destas imagens foram extraídas mais de 600 regiões. Para cada região foram calculados 6 descritores, como apresentado na Seção 3.3. Foi utilizado uma validação cruzada com seis partições, sendo quatro utilizadas para treinamento, uma validação e uma última para teste.

Para a avaliação com RNA, foi utilizada uma *Multi-Layer-Perceptron (MLP) Feedforward Backpropagation*. O treinamento foi realizado pela função Levenberg-Marquardt, devido à velocidade. Foi utilizada uma única camada escondida com 2/3 de neurônios dos usados na camada de entrada. Todos as funções de transferência dos neurônios foram ajustadas por uma função tangente inversa e o critério de parada de treinamento foi 500 épocas ou um *EMQ* menor que  $10^{-2}$ , levando em conta também um conjunto de validação. Para a avaliação com o SVM, foi utilizado o algoritmo com função *kernel* polinomial (o que permite separar classes não lineares).

Para ambos os classificadores, foi realizada seleção de características por força bruta, *i.e.*, todas as possíveis combinações de descritores foram testadas, já que o número de possibilidades  $2^6 - 1 = 63$  é factível. Tanto a melhor rede quanto o melhor grupo (SVM) das cinco execuções foram armazenados para reportar a precisão da metodologia proposta, e aplicados sobre uma mesma partição desconhecida - a partição de teste.

Foram realizadas cinco execuções para cada classificador, e as matrizes de confusões são reportadas nas Tabelas 2 e 3.

Comparando os resultados, observa-se que o SVM tem uma taxa de acerto maior sobre ambas regiões não- e homogêneas, obtendo uma média geral de acerto de 98, 77%  $\pm$  0, 72%. Já a RNA possui taxas de acertos mais baixas obtendo uma média geral de acerto de 92, 47%  $\pm$  3, 83%. Os descritores de uniformidade e terceiro momento foram os que melhor representaram a percepção do usuário para este problema.

Tabela 2: Matriz de confusão de 5 execuções para a RNA de regiões não-(NH) e homogêneas (H).

		Esperado			
		NH		H	
O	NH	6,6	± 0,5	1,4	± 0,5
b.	H	4,4	± 2,2	64,6	± 2,5

Tabela 3: Matriz de confusão de 5 execuções para o SVM de regiões não-(NH) e homogêneas (H).

		Esperado			
		NH		H	
O	NH	5,0	± 2,8	0,2	± 0,4
b.	H	0,6	± 0,5	60,8	± 7,8




Figura 6: Um grupo de componentes (painel): (a) imagem original; (b) imagem classificada/segmentada.

Na Figura 6, apresenta-se o resultado da aplicação da metodologia proposta sobre uma imagem de conta-giros. As regiões homogêneas e não-homogêneas classificadas corretamente, são representadas pela cor branca e verde, respectivamente. Já as não-homogêneas classificadas como homogêneas são representadas pela cor vermelha, e a oposta (ou seja, regiões homogêneas classificadas como não-homogêneas) são representadas pelas cor verde. Como pode-se observar, nesta imagem houve três regiões não homogêneas classificadas corretamente (representada pela cor amarela), e duas regiões classificadas erradas (regiões verdes e vermelha). Neste exemplo, o painel seria rejeitado pela área de teste da indústria, pois houve regiões classificadas como não homogêneas

## 6. CONCLUSÕES E TRABALHOS FUTUROS

Neste trabalho, foi proposta uma metodologia automática para definir regiões não homogêneas em sistemas visuais interativos veiculares, a partir de avaliações com usuários. Com objetivo de representar o grau de homogeneidade percebida pelos usuários em painéis de instrumentos automotivos, características clássicas de homogeneidade [6] foram utilizadas. Através de aprendizado de máquina, utilizando SVM e RNA, foram encontradas taxas de acerto satisfatórias pela metodologia proposta.

Trabalhos futuros incluem realizar testes com um número maior de componentes (painéis) com cores e formas geométricas variadas, bem como implementar mais descritores para avaliar a homogeneidade global do instrumento. Observe que essas avaliações serão feitas por usuários comuns. Também, deve ser realizada uma análise estatística mais criteriosa dos resultados. Ainda, é interessante analisar os conjuntos de regiões coesos (painéis) que seriam aprovados e reprovados na indústria, visto que a presença de uma única região não homogênea em um painel protótipo é suficiente para reprová-lo.

## AGRADECIMENTOS

Os autores gostariam de agradecer a Engenharia de Experimentação Eletro-Eletrônica da FIAT Automóveis S.A., Betim, Minas Gerais, Brasil, pelo apoio neste trabalho. Também agradecem à CNPq/MCT e CAPES/MEC.

## REFERÊNCIAS

- [1] R. Bosch. *Automotive Handbook*. John Wiley & Sons, England, 7th edition, 2007.

- [2] J. Oh, B. Yun and K. Park. “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, 2007.
- [3] J. Lee and S. Yoo. “Automatic Detection of Region-Mura Defect in TFT-LCD”. *IEICE Transactions on Information and Systems*, vol. E87-D, no. 10, pp. 2371–2378, 2004.
- [4] L. Gimena. “Exposure Value In Photography: A Graphics Concept Map Proposal”. In *Proceedings of the First International Conference on Concept Mapping*, pp. 256–259, Pamplona, Spain, 2004.
- [5] R. Gonzalez and R. Woods. *Digital Image Processing*. Prentice Hall, New Jersey, USA, third edition, 2007.
- [6] A. Jain. *Fundamentals of digital Image processing*. Prentice Hall, California, USA, 1989.
- [7] H. Cheng and Y. Sun. “A Hierarchical Approach to Color Image Segmentation Using Homogeneity”. *IEEE Transactions on Image Processing*, vol. 9, no. 12, pp. 2071–2082, 2000.
- [8] R. Duda, P. Hart and D. Stork. *Pattern Classification*. Wiley-Interscience, second edition, 2000.
- [9] A. C. Lorena and A. C. P. L. F. Carvalho. “Introdução às máquinas de vetores suporte (Support Vector Machines)”. *Revista de Informática Teórica e Aplicada*, vol. XIV, no. 2, pp. 65–86, 2007.
- [10] S. Sivanandam, S. Sumathi and S. Deppa. *Introduction do Neural Networks using Matlab 6.0*. McGraw-Hill Publishing Company Limited, New Delhi, India, 2006.