**UNIVERSIDADE DE SÃO PAULO
ESCOLA DE ENGENHARIA DE SÃO CARLOS**

Tamiris Trevisan Negri

**Descritores locais de textura para classificação de
imagens coloridas sob variação de iluminação**

São Carlos

2017

Tamiris Trevisan Negri

**Descritores locais de textura para classificação de
imagens coloridas sob variação de iluminação**

Tese apresentada à Escola de Engenharia de
São Carlos da Universidade de São Paulo,
para obtenção do título de Doutor em Ciên-
cias - Programa de Pós-Graduação em Enge-
nharia Elétrica.

Área de concentração: Processamento de Si-
nais e Instrumentação

Orientador: Prof. Dr. Adilson Gonzaga

**Trata-se da versão corrigida da tese. A versão original se encontra
disponível na EESC/USP que aloja o Programa de Pós-Graduação
de Engenharia Elétrica.**

**São Carlos
2017**

AUTORIZO A REPRODUÇÃO TOTAL OU PARCIAL DESTE TRABALHO,
POR QUALQUER MEIO CONVENCIONAL OU ELETRÔNICO, PARA FINS
DE ESTUDO E PESQUISA, DESDE QUE CITADA A FONTE.

N386d Negri, Tamiris Trevisan
 Descritores locais de textura para classificação de
 imagens coloridas sob variação de iluminação / Tamiris
 Trevisan Negri; orientador Adilson Gonzaga. São
 Carlos, 2017.

 Tese (Doutorado) - Programa de Pós-Graduação em
Engenharia Elétrica e Área de Concentração em
Processamento de Sinais e Instrumentação -- Escola de
Engenharia de São Carlos da Universidade de São Paulo,
2017.

 1. Classificação de texturas coloridas. 2.
Descritores locais de textura. 3. Variação de
iluminação. I. Título.

FOLHA DE JULGAMENTO

Candidata: Licenciada **TAMIRIS TREVISAN NEGRI**.

Título da tese: "Descritores locais de textura para classificação de imagens coloridas sob variação de iluminação".

Data da defesa: 15/12/2017.

Comissão Julgadora:

Resultado:

Prof. Associado **Adilson Gonzaga**

(Orientador)

(Escola de Engenharia de São Carlos/EESC)

APROVADA

Prof. Associado **Evandro Luis Linhari Rodrigues**

(Escola de Engenharia de São Carlos/EESC)

APROVADA

Prof. Dr. **Marcelo Andrade da Costa Vieira**

(Escola de Engenharia de São Carlos/EESC)

APROVADA

Prof. Dr. **Marco Antônio Piteri**

(Universidade Estadual Paulista "Júlio de Mesquita Filho"/UNESP-Presidente Prudente)

APROVADA

Profa. Titular **Agma Juci Machado Traina**

(Instituto de Ciências Matemáticas e de Computação/ICMC)

APROVADA

Coordenador do Programa de Pós-Graduação em Engenharia Elétrica:

Prof. Associado **Luís Fernando Costa Alberto**

Presidente da Comissão de Pós-Graduação:

Prof. Associado **Luís Fernando Costa Alberto**

*Dedico este trabalho aos meus pais, Odete e João,
à minha irmã, Bruna,
e ao meu noivo, Lucas.*

AGRADECIMENTOS

Aos meus pais João e Odete, e à minha irmã Bruna, por todo o apoio nesta jornada. Sem o incentivo de vocês nada disso teria sido possível.

Ao meu futuro esposo Lucas, por todo amor, carinho, dedicação, apoio e paciência em todos os momentos compartilhados.

Ao meu orientador, Prof. Dr. Adilson Gonzaga, por todo o conhecimento compartilhado durante este período de doutoramento e pelos ensinamentos de vida partilhados durante os momentos de descontração.

Ao meu supervisor durante o período de intercâmbio, Zoran Obradovic, e aos colegas do Centro de Análise de Dados e Informática Biomédica, por todos os momentos de grande aprendizado durante minha visita à Universidade *Temple* na Filadélfia (EUA). Em especial gostaria de agradecer a Dra. Fang Zhou por todo o apoio e valiosas contribuições nesta pesquisa.

Aos amigos do Laboratório de Visão Computacional, pela troca de conhecimento e momentos de descontração dentro e fora do laboratório.

Aos amigos que fiz em São Carlos e aos que estão comigo desde a época em que morávamos na região de Presidente Prudente. Obrigada por fazerem essa caminhada mais leve.

Aos amigos do IFSP, por todo o incentivo e disponibilidade sempre que precisei de ajuda.

Ao Departamento de Engenharia Elétrica e de Computação da Escola de Engenharia de São Carlos. Em especial aos funcionários, sempre muito atenciosos e eficientes.

Ao IFSP, pelo incentivo concedido em forma de afastamento para que eu pudesse dedicar mais tempo a esta pesquisa.

A todos que de forma direta ou indireta colaboraram para que esse trabalho fosse realizado.

*“One's mind, once stretched by a new idea,
never regains its original dimensions.”*

Oliver Wendell Holmes

RESUMO

NEGRI, T.T. **Descritores locais de textura para classificação de imagens coloridas sob variação de iluminação**. 2017. 98p. Tese (Doutorado) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2017.

A classificação de texturas coloridas sob diferentes condições de iluminação é um desafio na área de visão computacional, e depende da eficiência dos descritores de textura em capturar características que sejam discriminantes independentemente das propriedades da fonte de luz incidente sobre o objeto. Visando melhorar o processo de classificação de texturas coloridas iluminadas com diferentes fontes de luz, este trabalho propõe três novos descritores, nomeados *Opponent Color Local Mapped Pattern* (OCLMP), que combina o descritor de texturas por padrões locais mapeados (Local Mapped Pattern - LMP) com a teoria de cores oponentes; *Color Intensity Local Mapped Pattern* (CILMP), que extrai as informações de cor e textura de maneira integrada, levando em consideração a textura da cor, combinando estas informações com características da luminância da textura em uma análise multiresolução; e *Extended Color Local Mapped Pattern* (ECLMP), que utiliza dois operadores para extrair informações de cor e textura de forma integrada (textura da cor) combinadas com informações apenas de textura (sem cor) de uma imagem. Todos esses novos descritores propostos são paramétricos e, sendo o ajuste ótimo de seus parâmetros não trivial, o processo exige um tempo excessivo de computação. Portanto, foi proposto nesta tese a utilização de algoritmos genéticos para o ajuste automático dos parâmetros. A avaliação dos descritores propostos foi realizada em duas bases de dados de texturas coloridas com variação de iluminação: RawFooT (*Raw Food Texture Database*) e KTH-TIPS-2b (*Textures under varying Illumination, Pose and Scale Database*), utilizando-se um classificador Os resultados experimentais mostraram que os descritores propostos são mais robustos à variação de iluminação do que outros decritores de textura comumente utilizados na literatura. Os descritores propostos apresentaram um desempenho superior aos descritores comparados em 15% na base de dados RawFooT e 4% na base de dados KTH-TIPS-2b.

Palavras-chave: Classificação de texturas coloridas. Descritores locais de textura. Variação de iluminação.

ABSTRACT

NEGRI, T.T. **Local texture descriptors for color texture classification under varying illumination.** 2017. 98p. Tese (Doutorado) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2017.

Color texture classification under varying illumination remains a challenge in the computer vision field, and it greatly relies on the efficiency at which the texture descriptors capture discriminant features, independent of the illumination condition. The aim of this thesis is to improve the classification of color texture acquired with varying illumination sources. We propose three new color texture descriptors, namely: the Opponent Color Local Mapped Pattern (OCLMP), which combines a local methodology (LMP) with the opponent colors theory, the Color Intensity Local Mapped Pattern (CILMP), which extracts color and texture information jointly, in a multi-resolution fashion, and the Extended Color Local Mapped Pattern (ECLMP), which applies two operators to extract color and texture information jointly as well. As the proposed methods are based on the LMP algorithm, they are parametric functions. Finding the optimal set of parameters for the descriptor can be a cumbersome task. Therefore, this work proposes the use of genetic algorithms to automatically adjust the parameters. The methods were assessed using two data sets of textures acquired using varying illumination sources: the RawFooT (Raw Food Texture Database), and the KTH-TIPS-2b (Textures under varying Illumination, Pose and Scale Database). The experimental results show that the proposed descriptors are more robust to variations to the illumination source than other methods found in the literature. The improvement on the accuracy was higher than 15% on the RawFoot data set, and higher than 4% on the KTH-TIPS-2b data set.

Keywords: Color texture classification. Local texture descriptors. Varying illumination.

LISTA DE FIGURAS

Figura 1 – Mesma textura sob três fontes de iluminação diferentes.	23
Figura 2 – Comprimento de onda englobando a faixa visível do espectro eletromagnético.	27
Figura 3 – Histograma de cor 3D da imagem de <i>Crunchberries</i> com o fundo preto subtraído.	28
Figura 4 – Vizinhança 3×3	30
Figura 5 – Cálculo do LBP a) Imagem em nível de cinza b) Vizinhança limiarizada c) Matriz de pesos d) Padrão gerado LBP=169.	30
Figura 6 – Vizinhanças circulares simétricas para diferentes configurações de (P, r)	31
Figura 7 – Os 36 padrões do $LBP_{8,1}^{ri}$. Os círculos pretos e brancos correspondem aos valores 0 e 1, respectivamente. A primeira linha contém os nove padrões uniformes do $LBP_{8,1}^{riu2}$	33
Figura 8 – Histograma concatenado a partir dos histogramas LBP de cada canal de cor do espaço de cores RGB.	34
Figura 9 – Diagrama representando o cálculo do LCC correspondente à vizinhança circular com 16 pontos amostrados e raio igual a 2.	39
Figura 10 – Exemplo de vizinhança $v = W \times W$, $W = 3$ e $g_c = g_5$	42
Figura 11 – Comparação entre os códigos LBP e LMP.	43
Figura 12 – Diferença do mapeamento dos níveis de cinza utilizando as funções (a) sigmoidal (b) degrau.	44
Figura 13 – Ordem de disposição da vizinhança circular para $(P,r)=(8,1)$	45
Figura 14 – Padrão Local 3×3 de uma textura em um espaço de cores RGB.	46
Figura 15 – Canais de cores oponentes G-R, B-R, B-G.	46
Figura 16 – Processo de geração do vetor de características do descritor OCLMP.	47
Figura 17 – Dois pixels (vetores) g_p e g_c em um espaço de cores RGB.	49
Figura 18 – Exemplo de uma textura RGB e sua imagem resultante após o mapeamento realizado pelo CILMP utilizando a Eq. (3.10).	49
Figura 19 – Exemplo de uma análise multiresolução realizada pelo CILMP utilizando cinco configurações de vizinhança: $(8, 1) + (16, 3) + (24, 5)$ para a imagem de luminância e $(8, 2) + (16, 3)$ para a imagem RGB.	50
Figura 20 – Padrão local 5×5	51
Figura 21 – Vizinhanças circulares concêntricas.	51
Figura 22 – Geração do vetor de características ECLMP de uma imagem de luminância, considerando $P = 8$, $r_{out} = 2$, $r_{in} = 1$, $Q = 16$ e $\beta_{c1} = \beta_{r1} = 0, 1$	53
Figura 23 – Geração do vetor de características ECLMP de uma imagem RGB, considerando $P = 8$, $r_{out} = 2$, $r_{in} = 1$, $Q = 16$ e $\beta = 0, 1$	54

Figura 24 – Vetor de características multiresolução ECLMP.	55
Figura 25 – As 68 classes da base de dados RawFooT.	58
Figura 26 – Exemplo de uma das texturas (lentilha) da base de dados RawFooT adquirida sob as 46 condições de iluminação.	59
Figura 27 – Quatro amostras de cada uma das onze categorias da base de dados KTH- TIPS-2b (amostras adquiridas na escala 4, pose frontal e iluminação frontal).	60
Figura 28 – Processo de classificação.	62
Figura 29 – Subconjuntos que compõem o experimento 2 da base de dados RawFooT.	63
Figura 30 – Experimentos realizados na base de dados KTH-TIPS-2b.	64
Figura 31 – Comportamento da curva sigmóide para um intervalo de valores de β	65
Figura 32 – Comparação das acurácias gerais obtidas pelos descritores OCLMP e OCLBP na base de dados RawFooT.	72
Figura 33 – Avaliação dos descritores no experimento 1 da base de dados RawFooT.	74
Figura 34 – Avaliação dos descritores no experimento 2 da base de dados RawFooT.	75
Figura 35 – Avaliação dos descritores no experimento 3 da base de dados RawFooT.	75
Figura 36 – Avaliação dos descritores no experimento 4 da base de dados RawFooT.	76
Figura 37 – Avaliação dos descritores no experimento 5 da base de dados RawFooT.	76
Figura 38 – Avaliação dos descritores no experimento 6 da base de dados RawFooT.	76
Figura 39 – Avaliação dos descritores no experimento 7 da base de dados RawFooT.	77
Figura 40 – Avaliação dos descritores no experimento 8 da base de dados RawFooT.	77
Figura 41 – Avaliação dos descritores no experimento 9 da base de dados RawFooT.	78
Figura 42 – Comparação das acurácias gerais obtidas pelos descritores OCLMP e OCLBP com a base de dados KTH-TIPS-2b.	82
Figura 43 – Tempo de processamento para a geração do vetor de características de uma amostra, considerando-se as diferentes resoluções do descritor OCLMP.	85
Figura 44 – Tempo de processamento para a geração do vetor de características de uma amostra, considerando-se as diferentes resoluções do descritor CILMP.	86
Figura 45 – Tempo de processamento para a geração do vetor de características de uma amostra, considerando-se as diferentes resoluções do descritor ECLMP.	87
Figura 46 – Tempo de processamento para a geração do vetor de características de uma amostra, considerando-se as diferentes resoluções do descritor OCLBP.	88
Figura 47 – Tempo de processamento para a geração do vetor de características de uma amostra pelo descritor LCC.	88

LISTA DE TABELAS

Tabela 1	– Experimentos realizados na base de dados KTH-TIPS-2b	61
Tabela 2	– Parâmetros ajustados para as diferentes configurações (P,r) do descritor OCLMP para a base de dados RawFooT.	68
Tabela 3	– Acurácias médias (%) obtidas pelas diferentes configurações do descritor OCLMP nos nove experimentos da base de dados RawFooT.	68
Tabela 4	– Parâmetros ajustados para as diferentes configurações (P,r) do descritor CILMP para a base de dados RawFooT.	69
Tabela 5	– Acurácias médias (%) obtidas pelas diferentes configurações do descritor CILMP nos nove experimentos da base de dados RawFooT.	70
Tabela 6	– Parâmetros ajustados para as diferentes configurações (P, r_{out}, r_{in}) do descritor ECLMP para a base de dados RawFooT.	71
Tabela 7	– Acurácias médias (%) obtidas pelas diferentes configurações do descritor ECLMP nos nove experimentos da base de dados RawFooT.	71
Tabela 8	– Acurácias gerais (%) obtidas pelos descritores em comparação, considerando- se os nove experimentos da base de dados RawFooT, em ordem decrescente.	73
Tabela 9	– Parâmetros ajustados para as diferentes configurações (P,r) do descritor OCLMP para a base de dados KTH-TIPS-2b.	79
Tabela 10	– Acurácias (%) obtidas pelas diferentes configurações do descritor OCLMP nos três experimentos com a base de dados KTH-TIPS-2b.	79
Tabela 11	– Parâmetros ajustados para as diferentes configurações (P,r) do descritor CILMP para a base de dados KTH-TIPS-2b.	80
Tabela 12	– Acurácias (%) obtidas pelas diferentes configurações do descritor CILMP nos três experimentos com a base de dados KTH-TIPS-2b.	80
Tabela 13	– Parâmetros ajustados para as diferentes configurações do descritor ECLMP para a base de dados KTH-TIPS-2b.	81
Tabela 14	– Acurácias (%) obtidas pelas diferentes configurações do descritor ECLMP nos três experimentos com a base de dados KTH-TIPS-2b.	82
Tabela 15	– Acurácias gerais (%) obtidos pelos descritores em comparação, considerando- se os três experimentos com a base de dados KTH-TIPS-2b.	83
Tabela 16	– Descritores indicados para cada tipo de variação na iluminação.	93

SUMÁRIO

1	INTRODUÇÃO	21
1.1	Texturas coloridas	21
1.2	Motivação	24
1.3	Objetivos	25
1.4	Contribuições desta Tese	25
1.5	Estrutura do Trabalho	25
2	MÉTODOS PARA CLASSIFICAÇÃO DE TEXTURAS COLORIDAS COM VARIAÇÃO DE ILUMINAÇÃO	27
2.1	Considerações Iniciais	27
2.2	<i>Color Indexing</i>	28
2.3	<i>Color Constant Color Indexing</i>	29
2.4	LBP para descrição de texturas coloridas	30
2.4.1	<i>Local Binary Pattern (LBP)</i>	30
2.4.2	LBP invariante à rotação (LBP^{ri})	31
2.4.3	LBP uniforme invariante à rotação (LBP^{riu2})	32
2.4.4	LBP aplicado a imagens coloridas	33
2.4.5	Opponent Color Local Binary Pattern (OCLBP)	35
2.4.6	LBP 3D	35
2.5	Filtros de Gabor aplicados a Texturas Coloridas	36
2.5.1	Filtros de Gabor e Cores Oponentes	36
2.6	<i>Intensity Color Contrast Descriptor (ICCD)</i>	37
2.7	<i>Local Color Contrast (LCC)</i>	38
2.8	Considerações Finais	40
3	DESCRITORES PROPOSTOS	41
3.1	Considerações Iniciais	41
3.1.1	A abordagem <i>Local Mapped Pattern</i>	41
3.2	<i>Opponent Color Local Mapped Pattern (OCLMP)</i>	45
3.3	<i>Color Intensity Local Mapped Pattern (CILMP)</i>	47
3.4	<i>Extended Color Local Mapped Pattern (ECLMP)</i>	50
3.4.1	Extração da informação de textura	51
3.4.2	Extração da informação de textura da cor	52
3.4.3	Combinação das informações de textura e textura da cor	54
3.5	Considerações Finais	55

4	MATERIAL E MÉTODOS	57
4.1	Considerações Iniciais	57
4.2	Bases de Dados	57
4.2.1	Base de dados RawFooT	57
4.2.2	Base de dados KTH-TIPS-2b	60
4.3	Classificação e Avaliação	61
4.4	Sintonização dos Parâmetros	64
4.5	Considerações Finais	66
5	RESULTADOS E DISCUSSÃO	67
5.1	Considerações Iniciais	67
5.2	Resultados Experimentais para a base de dados RawFooT	67
5.2.1	OCLMP	67
5.2.2	CILMP	69
5.2.3	ECLMP	70
5.2.4	OCLMP x OCLBP	72
5.2.5	Comparação com outros descritores da literatura	72
5.3	Resultados Experimentais para a base de dados KTH-TIPS-2b	78
5.3.1	OCLMP	78
5.3.2	CILMP	79
5.3.3	ECLMP	81
5.3.4	OCLMP x OCLBP	82
5.3.5	Comparação com outros descritores da literatura	83
5.4	Análise do tempo de processamento	84
5.5	Considerações Finais	86
6	CONCLUSÃO	91
	REFERÊNCIAS	95

1 INTRODUÇÃO

1.1 Texturas coloridas

As técnicas de processamento de imagens, visando a segmentação e extração de características para Visão Computacional, são baseadas em três propriedades de arranjos dos pixels: forma, cor e textura. Em geral estas três propriedades são tratadas independentemente para geração do vetor de características que represente um objeto da cena ou a cena como um todo. A forma define padrões de contornos e regiões da imagem e a cor refere-se aos valores dos pixels. A textura talvez seja uma das propriedades mais complexas de se definir em uma imagem, pois representa a estrutura de arranjos de pixels que envolve intrinsecamente tanto o conceito de forma como o de cor.

A análise de texturas em imagens digitais desempenha um papel importante em muitas aplicações como robótica (BLAS et al., 2008), biometria (HUANG et al., 2011), processamento de documentos (BUSCH; BOLES; SRIDHARAN, 2005), medicina (CHANG; ZHANG; LIU, 2011), sensoriamento remoto (PLA et al., 2009) e inspeção visual (XIE, 2008).

A textura é um termo intuitivo mas não possui uma definição precisa na literatura. Tuceryan e Jain (1993) definem a textura de uma imagem como sendo uma função da variação espacial nas intensidades dos pixels (TUCERYAN; JAIN, 1993). Para Coggins (1983), uma textura é compreendida como uma primitiva que é repetida sobre uma região que é maior em comparação ao tamanho da primitiva (COGGINS, 1983). Haralick, Shanmugan e Dinstein (1973) relacionam a definição de textura com o uso de coeficientes de uniformidade, densidade, aspereza, regularidade, intensidade, dentre outras características da imagem (HARALICK; SHANMUGAM; DINSTEIN, 1973).

A partir da textura é possível extrair características relevantes sobre o relacionamento dos pixels em uma determinada região, o que a torna muito útil no processo de reconhecimento, descrição e classificação de imagens.

Em imagens digitais, as características de uma textura podem ser detectadas por meio de variações nas intensidades (luminância) ou cores (crominância) capturadas (MAENPAA, 2003). Os descritores de textura já estabelecidos na literatura utilizam, em sua maioria, imagens em níveis de cinza para a extração de características, ou seja, apenas a luminância da textura. Quando o método de análise da textura de uma imagem leva em conta, além das características obtidas pelos arranjos espaciais dos pixels, também a informação da crominância dos mesmos, diz-se que trata-se de uma Textura Colorida ou da Textura da Cor (em inglês, *Color Texture*). Esta abordagem tem obtido bons resultados na classificação de texturas e tem sido alvo de investigação de diversos autores

([MAENPAA; PIETIKAINEN, 2004](#)), ([PALM, 2004](#)), ([DRIMBAREAN; WHELAN, 2001](#)), ([CHINDARO; SIRLANTZIS; DERAVID, 2005](#)), ([CUSANO; NAPOLETANO; SCHETTINI, 2013](#)) e ([CUSANO; NAPOLETANO; SCHETTINI, 2014](#)).

As informações de cor e textura podem ser extraídas de uma imagem e combinadas de diferentes maneiras. Palm (2004) agrupa os diferentes métodos de combinar cor e textura em três abordagens: paralela, sequencial e integrativa ([PALM, 2004](#)). A abordagem paralela descreve a textura de uma imagem considerando a relação entre as intensidades de pixels vizinhos, ignorando sua informação de crominância, enquanto a cor (crominância) é descrita globalmente, ignorando a informação local de pixels vizinhos. Na abordagem sequencial, a imagem colorida é quantizada de forma a gerar uma imagem de apenas um canal de “cor”, e esta é então processada como uma textura em nível de cinza. Os métodos integrativos processam cor e textura de forma conjunta, considerando os canais de cor de forma separada ou combinando mais de um canal de cor.

Alguns métodos já existentes utilizados em análises de texturas em escala de cinza, como o *Local Binary Pattern* (LBP) e suas variações ([OJALA; PIETIKAINEN; HARWOOD, 1996](#)), ([OJALA; PIETIKAINEN; MAENPAA, 2002](#)), e os filtros de Gabor ([MANJUNATH; MA, 1996](#)) podem ser aplicados em texturas coloridas. O descritor é aplicado a cada canal de cor separadamente, e os vetores de características obtidos a partir dos diferentes canais são concatenados, formando um descritor de textura colorida ([MAENPAA; PIETIKAINEN, 2004](#)). Outros métodos, no entanto, foram criados especificamente para texturas coloridas ([SWAIN; BALLARD, 1991](#)) ([FUNT; FINLAYSON, 1995](#)) ([CUSANO; NAPOLETANO; SCHETTINI, 2013](#)) ([CUSANO; NAPOLETANO; SCHETTINI, 2014](#)).

Maenpaa e Pietikainen (2004) compararam o desempenho de vários métodos aplicados na classificação de texturas coloridas e em níveis de cinza. Três bancos de dados foram considerados com a finalidade de avaliar o desempenho dos descritores em diferentes situações. Além disso, diferentes espaços de cores foram considerados. Eles concluíram que quando a iluminação é constante, todos os métodos trabalham bem, embora aqueles que consideram informações de crominância tenham um melhor desempenho. No entanto, quando há mudanças de iluminação, os descritores aplicados nas imagens em níveis de cinza obtiveram melhores resultados ([MAENPAA; PIETIKAINEN, 2004](#)).

A importância da cor na classificação de texturas foi também minuciosamente explorada por Bianconi et al. (2011). Eles propuseram uma taxonomia para classificar os descritores de texturas coloridas existentes, e avaliaram o desempenho destes descritores em um conjunto de dados bastante utilizado nesta linha de pesquisa, o Outex 13 ([OJALA et al., 2002](#)), que possui também texturas com variação na orientação. Os resultados mostraram que a cor é realmente uma característica muito importante na classificação de texturas, obtendo bons resultados simplesmente utilizando histogramas marginais no

espaço de cores sRGB (*Standard RGB*). No entanto, não houve avaliação com texturas sob diferentes fontes de iluminação (BIANCONI et al., 2011).

A maior parte dos problemas relacionados à classificação de texturas é resultado da não-uniformidade das texturas naturais, provenientes de cenas do mundo real, que pode ser causada por mudanças na orientação, iluminação, escala, etc. Um bom descritor de texturas deve ser robusto a estas não-uniformidades.

O fato da textura ter várias definições e interpretações conduz a diferentes maneiras de análises. Assim, várias abordagens podem ser consideradas na construção de um descritor de texturas, como a abordagem estatística (HARALICK; SHANMUGAM; DINSTEN, 1973), a abordagem estrutural (JULESZ, 1981), (XIANGHUA; MIRMEHDI, 2007), (BACKES; CASANOVA; BRUNO, 2009), (BACKES; CASANOVA; BRUNO, 2013), a abordagem espectral (GABOR, 1946), (ARIVAZHAGAN; GANESAN, 2003), e a abordagem por micropadrões locais (VIEIRA, 2013) (HE; WANG, 1990), (OJALA; PIETIKAINEN; HARWOOD, 1996) (OJALA; PIETIKAINEN; MAENPAA, 2002).

Um dos descritores mais utilizados na atualidade é o LBP (OJALA; PIETIKAINEN; HARWOOD, 1996), baseado em uma abordagem por micropadrões locais. Ele se tornou muito popular pela sua simplicidade, flexibilidade e bom poder discriminativo. Nos últimos anos inúmeros trabalhos têm referenciado e desenvolvido novas variações e aplicações do método. Este desenvolvimento permitiu que o descritor ganhasse robustez, principalmente com relação à invariância à rotação (OJALA; PIETIKAINEN; MAENPAA, 2002). No entanto, como apresentado por Maenpaa e Pietikainen (2004), o LBP apresenta baixo desempenho quando há variação de iluminação.

De fato, um dos principais desafios na descrição e classificação de texturas coloridas é a robustez do descritor de texturas a mudanças na fonte de iluminação. Mudanças na intensidade, direção e temperatura da fonte de iluminação podem também afetar a cor da textura observada, interferindo no desempenho do descritor. A Figura 1 mostra a mesma textura, capturada sob o mesmo ângulo e escala, em três fontes de iluminação diferentes.

Figura 1: Mesma textura sob três fontes de iluminação diferentes.

Uma alternativa para este problema é a normalização das texturas, antes da extração de características, na tentativa de remover a dependência da iluminação (FUNT; FIN-

LAYSON, 1995), (HANBURY; KANDASWAMY; ADJEROH, 2005), (KANDASWAMY et al., 2012), (ZHU; BICHOT; CHEN, 2010), (FINLAYSON; XU, 2003), (CUSANO; NAPOLETANO; SCHETTINI, 2016). No entanto, os resultados apresentados por Cusano, et al. (2016) indicam que a normalização requer alto custo computacional e melhora o desempenho do descritor apenas em determinadas condições.

Um novo descritor local de textura, baseado em números *fuzzy* e denominado *Local Fuzzy Pattern* (LFP), foi proposto por Vieira et al. (2012) (VIEIRA et al., 2012). Posteriormente, Ferraz et al. (2014) publicaram uma evolução do LFP, o qual denominaram *Local Mapped Pattern* (LMP) (FERRAZ; PEREIRA JR.; GONZAGA, 2014). O descritor LMP considera a soma das diferenças de cada nível de cinza de uma vizinhança para o pixel central como um padrão local que pode ser mapeado para um *bin* de um histograma usando uma função de mapeamento. Esta nova abordagem por micropadrões locais é uma generalização de técnicas já publicadas anteriormente como o *Texture Unit* (HE; WANG, 1990), *Fuzzy Number Edge Detector* (FUNED) (BOAVENTURA; GONZAGA, 2009) e o próprio LBP.

Com base no bom desempenho que o LMP tem apresentado, superando o já consolidado LBP em muitas aplicações, este trabalho propõe investigar e desenvolver novas variações deste método para aplicações em texturas coloridas, especialmente quando há variações na fonte de iluminação.

1.2 Motivação

A dificuldade na classificação de texturas coloridas sob variação de iluminação tem levado os pesquisadores a investigar diferentes formas de lidar com esse problema. Novos descritores vêm sendo criados para tratar exclusivamente desta abordagem, enquanto alguns métodos já existentes são aprimorados e até mesmo utilizados juntamente com outras técnicas na tentativa de melhorar a classificação (CONNAH; FINLAYSON, 2006), (CUSANO; NAPOLETANO; SCHETTINI, 2013) e (CUSANO; NAPOLETANO; SCHETTINI, 2014).

O LBP apresenta bom desempenho na descrição de texturas coloridas quando a iluminação é constante. Grande parte dos novos descritores desenvolvidos para lidar com a variação de iluminação utilizam o LBP no processo de descrição das características, e a princípio, estes descritores superam as demais técnicas apresentadas na literatura (CONNAH; FINLAYSON, 2006), (CUSANO; NAPOLETANO; SCHETTINI, 2013) e (CUSANO; NAPOLETANO; SCHETTINI, 2014).

O fato do LMP ser uma generalização do descritor LBP, induz a investigar o desempenho deste método para imagens coloridas, principalmente em texturas sob diferentes fontes de iluminação.

1.3 Objetivos

O principal objetivo desta tese de doutoramento é o desenvolvimento de novos descritores de textura, baseados no método *Local Mapped Pattern* (LMP) para a classificação de texturas coloridas com variação de iluminação.

1.4 Contribuições desta Tese

São contribuições desta tese de doutoramento:

- Desenvolvimento do descritor *Opponent Color Local Mapped Pattern* (OCLMP), que une a abordagem LMP com a teoria de cores oponentes do sistema visual humano;
- Desenvolvimento do descritor *Color Intensity Local Mapped Pattern* (CILMP) que explora informações da textura colorida por meio da comparação da magnitude dos vetores de cor contidos em um cubo RGB. Este descritor combina informações de luminância e crominância da textura em uma análise multiresolução, considerando a relação entre o pixel central e os pixels vizinhos contidos em uma vizinhança circular de um padrão local de uma textura;
- Desenvolvimento do descritor *Extended Color Local Mapped Pattern* (ECLMP) que estende a teoria utilizada pelo descritor CILMP ao comparar a relação entre os pixels de diferentes resoluções de forma conjunta, e utiliza uma nova abordagem para extrair informações dos pixels de uma vizinhança;

1.5 Estrutura do Trabalho

Este trabalho está organizado da seguinte maneira:

Capítulo 2: São apresentados e discutidos os métodos existentes na literatura para a classificação de texturas coloridas, considerando-se a variação de iluminação.

Capítulo 3: São apresentados os descritores propostos nesta tese.

Capítulo 4: Os experimentos realizados para validação dos métodos propostos são detalhados e amplamente discutidos.

Capítulo 5: Apresenta os resultados obtidos e as comparações com métodos da literatura.

Capítulo 6: Apresenta as conclusões, vantagens e limitações dos métodos propostos, e sugestões para continuidade deste trabalho.

2 MÉTODOS PARA CLASSIFICAÇÃO DE TEXTURAS COLORIDAS COM VARIAÇÃO DE ILUMINAÇÃO

2.1 Considerações Iniciais

As cores percebidas de um objeto são determinadas pela natureza da luz refletida por ele. Se a luz for acromática (sem cores), sua única característica será sua intensidade, refletindo níveis de cinza. A luz cromática envolve o espectro de energia eletromagnética entre aproximadamente 400 e 700 nm (Figura 2)(GONZALEZ; WOODS, 2006).

Figura 2: Comprimento de onda englobando a faixa visível do espectro eletromagnético.

Fonte: (GONZALEZ; WOODS, 2006)

No processamento de texturas coloridas são geralmente considerados dois atributos: crominância (responsável pela cor) e luminância (relacionada a intensidade dos pixels). Nos descritores de texturas, estas duas características podem ser extraídas de forma independente e combinadas posteriormente, ou consideradas como uma característica única, que estão intrinsecamente relacionadas.

As cores são expressadas a partir de modelos matemáticos chamados espaços de cores. Os espaços de cores mais utilizados no processamento de texturas são os baseados no modelo RGB (*red, green, blue* - vermelho, verde, azul), o espaço HSI (*hue, saturation, intensity* - matiz, saturação, intensidade), o espaço HSV (*hue, saturation, value* - matiz, saturação, valor), e o espaço CIELAB ($L^*a^*b^*$) (JAIN; HEALEY, 1998).

Um dos principais desafios na classificação de texturas coloridas é a variação de iluminação geralmente encontrada em texturas de cenas reais. Muitas pesquisas têm sido conduzidas neste sentido a fim de encontrar descritores robustos a estas variações.

Uma das alternativas utilizadas é a normalização das imagens para uma iluminação padrão (FUNT; FINLAYSON, 1995), (HANBURY; KANDASWAMY; ADJEROH, 2005), (KANDASWAMY et al., 2012), (ZHU; BICHOT; CHEN, 2010), (FINLAYSON; XU, 2003), (CUSANO; NAPOLETANO; SCHETTINI, 2016), reduzindo o efeito da iluminação gerado pela variação da luz. Uma outra alternativa é extrair, diretamente da imagem,

características que sejam invariantes às mudanças de iluminação. O fato da primeira abordagem requerer muito esforço computacional tem levado pesquisadores a investir esforços na construção de descritores invariantes à iluminação.

Neste capítulo serão apresentadas algumas das abordagens encontradas na literatura, que foram utilizadas na classificação de texturas coloridas considerando a variação de iluminação. Algumas destas técnicas são apenas extensões dos descritores de textura em níveis de cinza adaptados para serem aplicados em imagens coloridas. Outras, por sua vez, foram criadas especificamente para lidar com a crominância da imagem.

2.2 Color Indexing

Swain e Ballard (1991) propuseram um método utilizando histogramas de cor (*Color Histograms*) como um descritor de características de texturas coloridas denominado *Color Indexing* (SWAIN; BALLARD, 1991). Dado um espaço de cores discreto definido por alguns eixos de cor (por exemplo vermelho, verde, azul - RGB), o histograma da cor é obtido discretizando-se as cores da imagem e contando-se o número de vezes que cada uma delas ocorre. Cada cor é vista como um *bin* de um histograma 3D centrado no valor que a representa no espaço de cores, como mostra a Figura 3.

Figura 3: Histograma de cor 3D da imagem de *Crunchberries* com o fundo preto subtraído.

Fonte: (SWAIN; BALLARD, 1991)

Neste método, os histogramas são comparados usando uma medida de similaridade chamada *Histogram Intersection*. Dado um par de histogramas I e M , a intersecção dos histogramas é dada por

$$d(I, M) = \sum_{i,j,k} \min \{I(i, j, k), M(i, j, k)\} \quad (2.1)$$

em que i, j, k são os eixos do espaço de cores utilizado. Os autores demonstram que quando os histogramas em comparação possuem o mesmo tamanho, a intersecção destes histogramas é uma métrica, comumente denominada distância *city-block* (SWAIN; BALLARD, 1991).

No entanto, como citado pelos próprios autores, o método não é capaz de lidar com mudanças nas condições de iluminação. É sugerido no artigo que para trabalhos futuros seja aplicada uma normalização para lidar com este problema. Um segundo desafio é encontrar uma maneira mais eficaz de comparar os histogramas, visto que a intersecção de histogramas é bastante insensível aos pixels do *background*. Neste sentido, delimitar o objeto de interesse seria uma tarefa importante.

2.3 Color Constant Color Indexing

Na tentativa de aprimorar a metodologia *Color Indexing*, Funt e Finlayson (1995), introduziram o método *Color Constant Color Indexing* (FUNT; FINLAYSON, 1995). Para tratar o problema da variação na iluminação, ao invés de pré-processar as imagens aplicando uma normalização em busca de constância na cor, como sugerido por Swain e Ballard (1991), os autores propõem o cálculo de taxas de cor para o histograma (*Color Ratios*). A técnica leva em consideração o logaritmo de uma imagem RGB convoluido com um filtro derivativo (Laplaciano da Gaussiana). O cálculo das taxas de cor é dado por:

$$d_c(x, y) = \nabla^2 G * \ln t_c(x, y), \quad (2.2)$$

em que t_c indica o canal de cor c , $c \in \{1, 2, 3\}$ e G representa um filtro Gaussiano.

O histograma é construído a partir da seguinte regra:

$$H(i, j, k) = \sum_{x, y} z = \begin{cases} 1 & \text{se } \begin{matrix} d_1(x, y) = i \\ d_2(x, y) = j \\ d_3(x, y) = k \end{matrix} \\ 0 & \text{caso contrário} \end{cases} \quad (2.3)$$

A comparação dos histogramas se dá como no método de Swain e Ballard (1991), a partir da intersecção dos histogramas.

Segundo os autores, a normalização sugerida por Swain e Ballard (1991) não trabalha muito bem neste caso porque o método identifica os objetos baseando-se apenas na cor. A constância da cor obtida com a normalização prejudica o desempenho na tarefa de reconhecimento. Por este motivo, os autores buscaram modificar o descritor para ser invariante a iluminação, utilizando as taxas de cor.

Assim, como citado por Swain e Ballard (1991), os autores sugerem que em trabalhos futuros sejam utilizadas novas formas de comparação entre histogramas. Eles acreditam que o método trabalharia melhor utilizando o classificador K-Vizinhos Mais Próximos (*K-Nearest Neighbor*). Neste caso, a intersecção de histogramas, ou distância *city-block*, seria a métrica utilizada.

2.4 LBP para descrição de texturas coloridas

Os descritores de textura para imagens em níveis de cinza como o LBP podem também ser diretamente aplicados a imagens coloridas, combinando os resultados dos canais de cor. As subseções 2.4.1, 2.4.2 e 2.4.3 descrevem a metodologia LBP, inicialmente criada para trabalhar com imagens monocromáticas. A subseção 2.4.4 apresenta como os descritores LBP são utilizados na classificação de texturas coloridas. Por fim, as subseções 2.4.5 e 2.4.6 apresentam métodos desenvolvidos especialmente para tratar de imagens coloridas, utilizando o descritor LBP.

2.4.1 *Local Binary Pattern* (LBP)

O descritor LBP foi introduzido em 1996 por Ojala, Pietikainen e Harwood e ganhou grande popularidade e ampla adoção por sua simplicidade e bom desempenho (OJALA; PIETIKAINEN; HARWOOD, 1996). A primeira versão do operador considera uma vizinhança 3×3 (Figura 4) em que os pixels da vizinhança são limiarizados pelo valor do pixel central: os vizinhos que têm valor igual ou superior ao pixel central recebem valor 1 e os demais recebem valor 0. Em seguida, os valores da vizinhança limiarizada são multiplicados pelos pesos dados aos pixels correspondentes. Por fim, estes valores são somados, resultando no código LBP. A Figura 5 exemplifica o processo.

g_1	g_2	g_3
g_4	g_c	g_5
g_6	g_7	g_8

Figura 4: Vizinhança 3×3 .

Figura 5: Cálculo do LBP a) Imagem em nível de cinza b) Vizinhança limiarizada c) Matriz de pesos d) Padrão gerado LBP=169.

Fonte: (OJALA; PIETIKAINEN; HARWOOD, 1996)

Considerando uma vizinhança genérica 3×3 como na Figura 4, o código LBP pode ser equacionado por (2.4).

$$LBP = \sum_{i=1}^8 s(g_i - g_c) 2^{i-1}, \quad s(x) = \begin{cases} 1, & \text{se } x \geq 0 \\ 0, & \text{se } x < 0 \end{cases} \quad (2.4)$$

Apesar do seu poder discriminativo, o método original não é invariante à rotação devido ao uso da matriz de pesos baseada em potências de dois (OJALA; PIETIKAINEN; HARWOOD, 1996). Para resolver este problema, Ojala, Pietikainen e Maenpaa (2002) estenderam a definição do LBP para vizinhanças circulares e apresentaram o LBP invariante à rotação.

2.4.2 LBP invariante à rotação (LBP^{ri})

O LBP invariante à rotação foi criado para trabalhar com texturas rotacionadas. Dado um pixel central g_c em uma imagem, um padrão numérico é calculado comparando o valor deste pixel com os valores dos pixels de uma vizinhança circular g_p , $p = 0, \dots, P-1$, em que P é a quantidade de pixels igualmente espaçados em um círculo de raio r ($r > 0$) que formam a região circular. Se as coordenadas de g_c são $(0, 0)$, então as coordenadas de g_p são dadas por

$$\left(-r \sin\left(\frac{2\pi p}{P}\right), r \cos\left(\frac{2\pi p}{P}\right) \right). \quad (2.5)$$

Exemplos de regiões circulares simétricas para diferentes configurações de (P, r) são apresentados na Figura 6. Os valores de cinza da vizinhança que não estão exatamente no centro do pixel são estimados por interpolação.

Figura 6: Vizinhanças circulares simétricas para diferentes configurações de (P, r) .

Fonte: Adaptado de (OJALA; PIETIKAINEN; MAENPAA, 2002)

O código LBP gerado a partir de uma vizinhança (P, r) é dado por

$$LBP_{P,r} = \sum_{p=0}^{P-1} s(g_p - g_c) 2^p \quad (2.6)$$

$$s(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (2.7)$$

Após a obtenção do código LBP de cada pixel (i, j) de uma imagem $N \times M$, pode-se representar a textura desta imagem usando-se um histograma:

$$H(k) = \sum_{i=1}^N \sum_{j=1}^M f(LBP_{P,r}(i, j), k), \quad k \in [0, K] \quad (2.8)$$

$$f(x, y) = \begin{cases} 1, & x = y \\ 0, & \text{caso contrário} \end{cases} \quad (2.9)$$

em que K é o máximo valor LBP possível. Note que o número de valores possíveis para determinada configuração (P, r) é 2^P .

A fim de se obter invariância à rotação, uma operação de *bitshifting* circular é aplicada no código LBP. O novo código LBP será o menor valor encontrado entre todos os valores iterados:

$$LBP_{P,r}^i = \min \{ROR(LBP_{P,r}, i) \mid i = 0, 1, \dots, P-1\} \quad (2.10)$$

em que $ROR(x, i)$ executa i vezes a operação de *bitshifting* circular à direita no número binário x . Com esta operação, o número de padrões LBP é reduzido de forma considerável. Para o caso de $P = 8$ e $r = 1$, o número de padrões que era $2^P = 256$ passa a ser apenas 36. Estes padrões são ilustrados na Figura 7. Usualmente, denota-se o LBP invariante à rotação por $LBP_{P,r}^i$.

2.4.3 LBP uniforme invariante à rotação (LBP^{riu2})

Ojala e Pietikainen (2002) observaram ainda, que era possível reduzir o número de padrões gerados considerando apenas os padrões de uma “uniformidade” específica (OJALA; PIETIKAINEN; MAENPAA, 2002). A uniformidade é definida como o número de transições que ocorrem no *string* binário $b_0 b_1 \dots b_{N-1}$, em que a transição é uma mudança de 1 para 0 ou vice-versa. O cálculo da uniformidade pode ser escrito como:

$$U(LBP_{P,r}) = |s(g_{P-1} - g_c) - s(g_0 - g_c)| + \sum_{p=1}^{P-1} |s(g_p - g_c) - s(g_{p-1} - g_c)| \quad (2.11)$$

Por exemplo, o padrão LBP 00000000 tem uniformidade zero, enquanto 01000000 tem uniformidade 2. Os autores observaram que em muitas imagens naturais, padrões com uniformidade ≤ 2 representam a maioria dos padrões existentes, e pouca informação é perdida ao se considerar apenas estes padrões. A primeira linha da Figura 7 apresenta

os nove padrões uniformes do $LBP_{8,1}^{riu2}$. O sobrescrito $riu2$ refere-se ao uso dos padrões uniformes invariantes à rotação com $U \leq 2$.

Os padrões com uniformidade maior do que dois, podem ser agrupados em um único *bin* do histograma. Desta forma, o histograma do LBP uniforme invariante à rotação possui $P + 2$ *bins*.

Figura 7: Os 36 padrões do $LBP_{8,1}^{riu2}$. Os círculos pretos e brancos correspondem aos valores 0 e 1, respectivamente. A primeira linha contém os nove padrões uniformes do $LBP_{8,1}^{riu2}$.

Fonte: (OJALA; PIETIKAINEN; MAENPAA, 2002)

2.4.4 LBP aplicado a imagens coloridas

Maenppa e Pietikainen (2004) realizaram testes aplicando o descritor LBP a imagens coloridas em diferentes espaços de cores. Para esta aplicação eles utilizaram o LBP formado por vizinhanças circulares considerando-se os padrões de uniformidade $U \leq 2$. Este descritor não considera a operação de *bitshifting*, e foi por eles denominado LBP^{u2} (MAENPAA; PIETIKAINEN, 2004).

Para a geração do vetor de características de uma imagem, o descritor é aplicado nos canais de cor individuais e os histogramas gerados são concatenados como mostrado na Figura 8. Eles ainda concatenaram configurações diferentes gerando novos descritores, como por exemplo, o $LBP_{(8,1+16,3+24,5)}^{u2}$ que concatena os histogramas obtidos aplicando-se o $LBP_{8,1}$, o $LBP_{16,3}^{u2}$ e o $LBP_{24,5}^{u2}$.

Nos experimentos, os autores utilizaram uma modificação da função de log-

verossimilhança como medida de dissimilaridade:

$$d(S, M) = - \sum_{i=0}^{N-1} S_i \log M_i \quad (2.12)$$

em que S e M são os histogramas da amostra e do modelo respectivamente, e N representa o número de *bins* do histograma.

Os testes foram realizados em banco de dados de texturas com iluminação fixa e com iluminação variante. Bons resultados foram obtidos quando a iluminação é fixa. No entanto, quando a iluminação varia o desempenho do método é bastante reduzido. Além disso, os testes mostraram que a metodologia trabalha melhor com o espaço de cores $L^*a^*b^*$.

Figura 8: Histograma concatenado a partir dos histogramas LBP de cada canal de cor do espaço de cores RGB.

2.4.5 Opponent Color Local Binary Pattern (OCLBP)

Maenppa e Pietikainen (2004) também propuseram utilizar o descritor LBP aliado a teoria de cores oponentes, proposta por Jain e Healey (1998), para extrair informações de cor de uma textura no espaço RGB. A teoria de cores oponentes inspira a utilização de dois canais de cores do espaço RGB como sendo cores opostas, ou seja, R-G, G-R, R-B, B-R, G-B e B-G são pares de cores oponentes. No processo de extração de características, o descritor LBP^{u2} é aplicado na textura, considerando-se o pixel central da vizinhança centrado em um canal de cor e sua vizinhança é tomada no canal de cor oponente. Como os pares como R-G e G-R, R-B e B-R, G-B e B-G são altamente redundantes, apenas 3 pares de cores oponentes foram considerados: R-G, G-B e R-B. Além da extração de informação a partir dos pares de cores oponentes, o operador é também aplicado a cada canal de cor separadamente para capturar as características de cada canal individualmente. Os seis histogramas obtidos são então concatenados em um único vetor.

Os testes realizados pelos autores (MAENPAA; PIETIKAINEN, 2004), envolvendo imagens capturadas sob fontes de luz de diferentes temperaturas, mostraram que o descritor não é adequado para descrever imagens que sofram esse tipo de mudança na iluminação. No entanto, nos testes realizados por Cusano et al. (2016), o descritor OCLBP obteve bons resultados para descrição de imagens coloridas adquiridas sob diferentes direções da fonte de luz (CUSANO; NAPOLETANO; SCHETTINI, 2016).

2.4.6 LBP 3D

Pensando em uma forma de aprimorar a metodologia LBP para ser aplicada a imagens coloridas, Connah e Finlayson (2006) desenvolveram um LBP 3D (CONNAH; FINLAYSON, 2006). A ideia principal é gerar um histograma 3D a partir dos códigos LBP, calculado como nas Equações (2.13) e (2.14)

$$H(u, v, w) = \sum_x \sum_y g(x, y) \quad (2.13)$$

$$g(x, y) = \begin{cases} 1, & \text{se } LBP_R(x, y) = u \\ & \text{e } LBP_G(x, y) = v \\ & \text{e } LBP_B(x, y) = w \\ 0 & \text{caso contrário} \end{cases} \quad (2.14)$$

em que LBP_R , LBP_G e LBP_B correspondem ao LBP aplicado aos canais de cores R, G e B, respectivamente, considerando-se o espaço de cores RGB.

Considerando-se o LBP uniforme invariante à rotação, existem 10 padrões possíveis para cada pixel em cada canal de cor. Assim, o histograma 3D requer $10 \times 10 \times 10 = 1000$ bins. De acordo com os autores, e dependendo da aplicação, este número pode ser reduzido

considerando-se, por exemplo, apenas os padrões com uniformidade 1 e 2, o que levaria a um histograma 3D com 343 *bins*.

Foram realizados testes para a tarefa de Recuperação de Imagens baseada em Conteúdo (*Content-Based Image Retrieval* - CBIR). Os resultados mostraram que o histograma 3D apresenta melhor desempenho que a concatenação de histogramas tanto para iluminação fixa, quanto para a iluminação variante.

2.5 Filtros de Gabor aplicados a Texturas Coloridas

Os filtros de Gabor são amplamente utilizados para a análise de texturas em níveis de cinza (BOVIK; CLARK; GEISLER, 1990) (JAIN; FARROKHNI, 1990) (MANJUNATH; MA, 1996). Maenpaa e Pietikainen (2004) propõem a utilização dos filtros de Gabor para a análise de texturas coloridas da seguinte maneira: o descritor é aplicado a cada canal de cor separadamente; a média e o desvio padrão de cada imagem filtrada, considerando todas as escalas e orientações do filtro, são utilizados como características, organizadas como um vetor dado pela Equação (2.15)

$$f = (\mu_{11}\sigma_{11}\mu_{21}\sigma_{21} \dots \mu_{SO}\sigma_{SO}), \quad (2.15)$$

em que cada μ_{so} e σ_{so} representa a média e o desvio padrão da imagem convoluída com o filtro de Gabor na escala s e orientação o . As letras maiúsculas S e O denotam o número total de escalas e orientações, respectivamente (MAENPAA; PIETIKAINEN, 2004).

Em seguida, os vetores de características de cada canal são concatenados produzindo um único descritor. A medida de dissimilaridade sugerida pelos autores é baseada na distância *city-block*:

$$d(S, M) = \sum_{i=0}^{N-1} \frac{|S_i - M_i|}{\sigma_i} \quad (2.16)$$

em que S e M são vetores de características, σ_i é o desvio padrão das características i , e N é o tamanho do vetor de características.

A utilização dos filtros da Gabor é uma abordagem espectral de textura baseada em filtragem, diferente do LBP que considera micropadrões locais. Maenpaa e Pietikainen (2004), realizaram testes com diversas configurações dos filtros de Gabor. Os resultados mostraram que esta abordagem tem desempenho similar ao LBP tanto para iluminação constante quanto para iluminação variante.

2.5.1 Filtros de Gabor e Cores Oponentes

Motivados pelos processos oponentes do sistema visual humano, Jain e Healey (1998) usaram as saídas do filtro de Gabor para introduzir uma representação utilizando

características unicromáticas, calculadas a partir de cada canal de cor independente e, características de cores oponentes, que capturam a correlação espacial entre os canais de cores (MAENPAA; PIETIKAINEN, 2004) (JAIN; HEALEY, 1998).

Seja $i_{so}^{(c)}(x, y)$ o canal de cor filtrado de uma imagem, onde c representa o canal, s a escala e o a orientação. As características unicromáticas podem ser escritas como:

$$\mu_{so}^{(c)} = \sqrt{\sum_{x,y} (i_{so}^{(c)}(x, y))^2}. \quad (2.17)$$

As características de cores oponentes consideram as diferenças entre os canais de cores. As diferenças são calculadas entre todos os pares de canais de um espaço de cores, para todas as orientações e para cada par de escalas i, j satisfazendo $|i - j| \leq 1$. Assim, as características de cores oponentes são definidas como na Eq. (2.18).

$$\mu_{s_1 s_2 o}^{(c_1 c_2)} = \sqrt{\sum_{x,y} \left(\frac{i_{s_1 o}^{(c_1)}(x, y)}{\mu_{s_1 o}^{(c_1)}} - \frac{i_{s_2 o}^{(c_2)}(x, y)}{\mu_{s_2 o}^{(c_2)}} \right)^2} \quad (2.18)$$

As características unicromáticas e de cores oponentes são então concatenadas em um único descritor. Dessa forma, se for considerado, por exemplo, o espaço de cores RGB e um filtro de Gabor com 3 escalas e 4 orientações, serão extraídas $3 \times 3 \times 4 = 36$ características unicromáticas e, como existem 7 possibilidades para $|i - j| \leq 1$, obtém-se $3 \times 4 \times 7 = 84$ características de cores oponentes. Sendo assim, após a concatenação será gerado um vetor de 120 características.

A medida de dissimilaridade entre dois vetores S e M adotada pelos autores foi

$$d(S, M) = \sum_{i=0}^{N-1} \frac{(S_i - M_i)^2}{\sigma_i^2}, \quad (2.19)$$

em que σ_i^2 é a variância da característica i .

Os autores destacaram a importância das informações de cores na classificação e verificaram que o uso das características de cores oponentes juntamente com as unicromáticas resultam em desempenho superior quando comparado ao uso apenas das características unicromáticas. No entanto, como apresentado por Maenpaa e Pietikainen (2004), o método não trabalha bem quando há mudanças na iluminação (MAENPAA; PIETIKAINEN, 2004).

2.6 Intensity Color Contrast Descriptor (ICCD)

Cusano et al. (2013) propuseram um novo método especialmente criado para lidar com mudanças de iluminação em imagens coloridas. O método, denominado *Intensity Color*

Contrast Descriptor (ICCD) combina a metodologia LBP com informações relacionadas ao contraste de cor local da imagem (CUSANO; NAPOLETANO; SCHETTINI, 2013).

Sejam os pixels de uma imagem colorida representados pela terna $\mathbf{c} = (c_1, c_2, c_3)$ de valores não-negativos correspondentes aos três canais de um espaço de cores. As informações de cores são obtidas pela diferença angular entre o vetor de cor do pixel $\mathbf{c}(i, j)$ na localização i, j e a média $\bar{\mathbf{c}}(i, j)$ dos vetores de cor de uma vizinhança circular, dada por

$$\bar{\mathbf{c}}(i, j) = \frac{1}{(2W + 1)^2} \sum_{x=i-W}^{i+W} \sum_{y=j-W}^{j+W} \frac{\mathbf{c}(x, y)}{\|\mathbf{c}(x, y)\|}, \quad (2.20)$$

em que W determina o tamanho da vizinhança. A diferença angular é definida como

$$\alpha(\mathbf{c}_1, \mathbf{c}_2) = \begin{cases} \frac{2}{\pi} \arccos \frac{\langle \mathbf{c}_1, \mathbf{c}_2 \rangle}{\|\mathbf{c}_1\| \|\mathbf{c}_2\|}, & \text{se } \mathbf{c}_1 \neq 0 \wedge \mathbf{c}_2 \neq 0 \\ 0, & \text{caso contrário} \end{cases} \quad (2.21)$$

em que $\langle \cdot, \cdot \rangle$ denota o produto interno no espaço de cores e, $\|\cdot\|$ indica a norma Euclidiana.

A distribuição das diferenças angulares é quantizada em Q bins e codificada por um histograma. Os valores de W e Q são treinados para obter melhores resultados. O $LBP_{16,2}^{riu2}$ é utilizado para extrair informações de intensidade da imagem transformada em níveis de cinza e seu histograma é concatenado ao histograma das informações de cores, gerando o ICCD.

Para a classificação os autores sugerem a distância chi-quadrado:

$$\chi^2(\mathbf{x}, \mathbf{y}) = \frac{1}{2} \sum_{i=1}^N \frac{(x_i - y_i)^2}{x_i + y_i} \quad (2.22)$$

em que $\mathbf{x}$ e $\mathbf{y}$ são dois vetores de características de valores não-negativos.

Os resultados apresentados mostram que o descritor tem bom desempenho na classificação de imagens coloridas quando a iluminação é fixa, e apesar da queda de desempenho na classificação de texturas com variação de iluminação, o método é mais robusto do que os descritores em comparação.

2.7 Local Color Contrast (LCC)

Posteriormente, os mesmos autores do ICCD utilizaram ideias similares para o desenvolvimento do *Local Color Contrast* (LCC) (CUSANO; NAPOLETANO; SCHETTINI, 2014). Assim como o ICCD, o LCC é medido comparando-se a cor de um pixel com a média de cor de sua vizinhança. O ângulo LCC é também calculado em termos de diferença angular entre dois vetores

$$\theta = \arccos \left(\frac{\langle \hat{\mathbf{c}}, \bar{\mathbf{c}} \rangle}{\|\hat{\mathbf{c}}\| \cdot \|\bar{\mathbf{c}}\|} \right) \quad (2.23)$$

em que $\hat{c}$ é a cor do pixel atual e $\bar{c}$ é a média de cor da vizinhança.

Inspirados pelo LBP, a média de cor é calculada, conforme mostra a Equação (2.24) em uma vizinhança circular de raio r e cardinalidade n :

$$\bar{c} = \frac{1}{n} \sum_{p=0}^{n-1} c_p, \quad (2.24)$$

sendo os vetores c_p os valores dos pixels da vizinhança que, quando não estão exatamente no centro do pixel são estimados por interpolação, seguindo a metodologia do LBP invariante a rotação. A Figura 9 mostra um diagrama do cálculo de uma diferença angular θ para o LCC.

Figura 9: Diagrama representando o cálculo do LCC correspondente à vizinhança circular com 16 pontos amostrados e raio igual a 2.

Fonte: (CUSANO; NAPOLETANO; SCHETTINI, 2014)

O descritor final D é formado pela concatenação do histograma LBP (H_{LBP}) com o histograma dos valores LCC (H_{LCC}). Um parâmetro w é introduzido ponderando-se o histograma mais relevante para determinada aplicação.

$$D = \begin{pmatrix} H_{LBP} \\ w \times H_{LCC} \end{pmatrix} \quad (2.25)$$

Assim como no ICCD, a classificação é realizada considerando-se a distância chi-quadrado.

Os autores sugerem que além do ajuste da vizinhança de acordo com a aplicação, pode-se também avaliar a influência da quantidade de *bins* do histograma. O parâmetro w necessita ser treinado e, seu valor ótimo depende das condições de variabilidade de iluminação. Desta forma, por ser paramétrico, o método permite que seja realizado um estudo dos parâmetros envolvidos de forma a se adequar às necessidades de uso. Os

experimentos realizados por Cusano et al. (2014) mostraram que o descritor supera a taxa de classificação correta das demais metodologias existentes, quando se considera a iluminação variante.

2.8 Considerações Finais

Este capítulo apresentou diversos métodos encontrados na literatura utilizados para lidar com texturas coloridas. Na maioria dos trabalhos existentes nota-se a grande dificuldade em se trabalhar com texturas coloridas com variações de iluminação e a necessidade do desenvolvimento de novos métodos para lidar com este problema.

Conforme apresentado na Seção 2.4.5, o descritor OCLBP apresentou bons resultados para imagens capturadas sob variação da direção da fonte de luz. Neste sentido, propõe-se no capítulo seguinte o descritor *Opponent Color Local Mapped Pattern* (OCLMP), o qual une a teoria de cores oponentes e a abordagem LMP, na tentativa de alcançar invariância à iluminação.

Além disso, o descritor LCC (Seção 2.7), o qual combina informações de textura da cor e informações de textura (luminância), apresentou bons resultados na classificação de texturas coloridas com variação de iluminação (CUSANO; NAPOLETANO; SCHETTINI, 2014). Dessa maneira, propõe-se investigar a combinação destas informações, extraídas em uma análise multiresolução, por dois novos descritores - *Color Intensity Local Mapped Pattern* (CILMP) e *Extended Color Local Mapped Pattern* (ECLMP) - que também são apresentados no capítulo seguinte e avaliados para descrição de imagens adquiridas sob iluminação variante.

3 DESCRITORES PROPOSTOS

3.1 Considerações Iniciais

A proposta desta tese é desenvolver descritores de textura que sejam robustos na classificação de texturas coloridas sob variação de iluminação. De acordo com os resultados apresentados na literatura, os descritores que utilizam a abordagem LBP superam as demais técnicas encontradas (CONNAH; FINLAYSON, 2006), (CUSANO; NAPOLETANO; SCHETTINI, 2013) e (CUSANO; NAPOLETANO; SCHETTINI, 2014). Por outro lado, considerando-se texturas em níveis de cinza, o LMP tem alcançado melhores resultados quando comparado ao LBP (VIEIRA et al., 2012) (VIEIRA, 2013) (FERRAZ; PEREIRA JR.; GONZAGA, 2014).

Neste sentido, este trabalho propõe desenvolver descritores capazes de extrair características de textura de imagens coloridas, com iluminação variante, baseados no método LMP. A Subseção 3.1.1 deste capítulo trata de uma breve revisão, contextualizando a abordagem LMP criada para trabalhar com imagens em níveis de cinza, e em seguida são descritos os métodos propostos nesta tese, baseados nesta abordagem, para a descrição de texturas coloridas.

3.1.1 A abordagem *Local Mapped Pattern*

Em 2012, Vieira et al. apresentaram um novo descritor baseado em números *fuzzy* chamado *Local Fuzzy Pattern* (LFP). Esta metodologia assume que cada distribuição de níveis de cinza dentro de uma vizinhança é um conjunto *fuzzy* e, gera um código LFP por meio de uma função de pertinência.

A partir do método LFP, Ferraz et al. (2014) propuseram a abordagem *Local Mapped Pattern* (LMP). O operador LMP considera a soma das diferenças de cada nível de cinza de uma dada vizinhança para o pixel central como um padrão local que pode ser mapeado para um histograma utilizando uma função de mapeamento.

Consideremos uma vizinhança $v = W \times W$, como na Figura 10, em que $v = 9$ e o pixel central $g_c = g_5$. Seu padrão pode ser mapeado para um *bin* h_b de um histograma usando a Equação (3.1), sendo que f é a função de mapeamento, m_i são elementos de uma matriz de pesos M de valores pré-definidos para cada posição do pixel (Eq. (3.2)), e B é o número de *bins* do histograma.

$$h_b = \text{round} \left(\frac{\sum_{i=1}^v f(g_i) m_i}{\sum_{i=1}^v m_i} (B - 1) \right) \quad (3.1)$$

g_1	g_2	g_3
g_4	g_5	g_6
g_7	g_8	g_9

Figura 10: Exemplo de vizinhança $v = W \times W$, $W = 3$ e $g_c = g_5$.

$$M = \begin{bmatrix} m_1 & m_2 & m_3 \\ m_4 & m_5 & m_6 \\ m_7 & m_8 & m_9 \end{bmatrix}. \quad (3.2)$$

Usando a Equação (3.1) é possível derivar algumas abordagens já publicadas anteriormente para análise de padrões locais aplicando diferentes funções de mapeamento e matrizes de pesos. Dentre elas podem ser citados o descritor *Texture Unit* (HE; WANG, 1990), o *Fuzzy Number Edge Detector* (FUNED) (BOAVENTURA; GONZAGA, 2009) e o LBP.

O LBP pode ser derivado da Equação (3.1) usando a função degrau apresentada na Equação (3.3) como função de mapeamento.

$$f(g_i) = H[g_i - g_c] = \begin{cases} 1, \text{ se } g_i - g_c \geq 0 \\ 0, \text{ se } g_i - g_c < 0 \end{cases} \quad (3.3)$$

Considerando a metodologia inicial do LBP, definida em uma vizinhança 3×3 , a matriz de pesos será:

$$M = \begin{bmatrix} 1 & 2 & 4 \\ 128 & 0 & 8 \\ 64 & 32 & 16 \end{bmatrix}. \quad (3.4)$$

É possível notar, então, que o LBP é um caso particular da abordagem LMP.

De acordo com a aplicação desejada, o LMP permite o uso de diferentes funções de mapeamento e matrizes de pesos para a extração de características específicas de uma imagem. Além disso, o número de *bins* do histograma pode ser ajustado para um melhor desempenho do método. Para análise de texturas, os autores sugerem o uso de uma curva logística ou uma curva sigmóide como apresentado na Equação (3.5), em que β

é a inclinação da curva.

$$f(g_i) = \frac{1}{1 + e^{\frac{-[g_i - g_c]}{\beta}}} \quad (3.5)$$

Para que o descritor seja robusto a mudanças na rotação, a matriz de pesos proposta é

$$M = \begin{bmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{bmatrix}. \quad (3.6)$$

Fazendo uma comparação com o LBP, a utilização da função sigmóide pode ser vista como uma aproximação suave para a função degrau a fim de captar nuances que a característica *crisp* (0 ou 1) da função degrau não é capaz. A Figura 11 apresenta uma comparação entre os códigos LBP e LMP gerados para a mesma vizinhança de uma amostra de textura, considerando $B = 256$.

Figura 11: Comparação entre os códigos LBP e LMP.

Fonte: Adaptado de (NEGRI; GONZAGA, 2014)

Figura 12: Diferença do mapeamento dos níveis de cinza utilizando as funções (a) sigmoidal (b) degrau.

Funções sigmóides são curvas em forma de S e aparecem em uma grande variedade de contextos, tais como funções de transferências de muitas redes neurais. Sua ubiquidade não é acidental, estas curvas estão entre as curvas não lineares mais simples, encontrando um equilíbrio entre o comportamento linear e não-linear. A Figura 12 mostra as funções de mapeamento sigmóide e degrau, utilizadas na Equação (3.1) para as abordagens LMP e LBP, respectivamente.

Assim como o LBP, a metodologia LMP pode ser estendida para vizinhanças circulares (CHIERICI, 2015). Considerando uma janela de análise formada por uma vizinhança circular contendo P amostras, simétrica em relação ao pixel central, de raio r , $r > 0$, sendo $(0, 0)$ as coordenadas do pixel central g_c , então as coordenadas da vizinhança circular g_p , $p = 1, \dots, P$, são dadas por

$$\left(-r \sin\left(\frac{2\pi p}{P}\right), r \cos\left(\frac{2\pi p}{P}\right) \right). \quad (3.7)$$

Os valores do nível de cinza dos vizinhos não localizados no centro exato de um pixel são estimados por interpolação bilinear, como sugerido por Ojala et al. (2002). Esta nova versão do LMP é denominada *Sampled Local Mapped Pattern* (S-LMP).

A Figura 13 apresenta uma vizinhança de $P = 8$ pontos amostrados e raio $r = 1$, com ordem de disposição anti-horária.

Assim como no LMP, o S-LMP utiliza uma função de mapeamento f para mapear cada padrão para um *bin* h_b de um histograma. Nesta abordagem a matriz de pesos não é utilizada; utiliza-se apenas o número de pixels amostrados P . O cálculo do padrão S-LMP é dado pela Equação (3.8).

$$h_b = \text{round}\left(\frac{\sum_{p=1}^P f(g_p)}{P}(B-1)\right) \quad (3.8)$$

Figura 13: Ordem de disposição da vizinhança circular para $(P,r)=(8,1)$.

A função de mapeamento depende da aplicação. Considerando uma função sigmóide, como a apresentada na Eq. (3.9), o método trabalha como no LMP, sendo os pixels vizinhos referenciados pela ordem de seu posicionamento e não por suas coordenadas:

$$f(g_p) = \frac{1}{1 + e^{\frac{-[g_p - g_c]}{\beta}}} \quad (3.9)$$

De acordo com a aplicação a ser utilizada, os parâmetros B e β são ajustados de modo a garantir um melhor desempenho, da mesma maneira que na metodologia LMP.

3.2 Opponent Color Local Mapped Pattern (OCLMP)

A primeira abordagem proposta nesta tese para descrever texturas coloridas é denominada *Opponent Color Local Mapped Pattern* (OCLMP). Este novo descritor, inspirado no método OCLBP proposto por Maenpaa e Pietikainen (2004), combina a abordagem LMP com a teoria de cores oponentes (JAIN; HEALEY, 1998). Conforme apresentado por Cusano et al. (2016), o descritor OCLBP obteve bons resultados para a descrição de texturas coloridas submetidas à variações na direção da fonte de luz. Por outro lado, o descritor LMP tem superado o descritor LBP em diversas aplicações (FERRAZ; PEREIRA JR.; GONZAGA, 2014; VIEIRA et al., 2012). Estes dois fatores motivaram o desenvolvimento do descritor OCLMP buscando robustez na descrição de texturas coloridas com variação de iluminação.

No sistema visual humano, os campos receptores, formados pelos fotorreceptores (bastonetes e cones) das células da retina, são organizados de maneira circular contendo um centro e uma periferia. A região central responde a estímulos luminosos com excitação ou inibição, enquanto a região periférica responde com sinal oposto ao da região central. Este comportamento é denominado antagonismo espacial. O mesmo acontece no chamado antagonismo cromático, em que a região central do campo é estimulada pela resposta de uma classe de fotorreceptores (cor) e a periferia por outra classe (JAIN; HEALEY, 1998). Este mecanismo, denominado teoria dos processos oponentes, resulta em uma melhor

percepção do contraste de cores entre as cores oponentes (HURVICH; JAMESON, 1957), facilitando, portanto, a descrição das mesmas.

A representação de texturas coloridas utilizando cores oponentes considera os pares oponentes dentro de um espaço de cores. Para os espaços de cores baseados no modelo de cor RGB, são oponentes os pares R-G, R-B, G-R, G-B, B-R e B-G. Como destacado em (MAENPAA; PIETIKAINEN, 2004), os pares simétricos como R-B e B-R por exemplo, são altamente redundantes, e um deles pode ser descartado na análise da textura utilizando-se essa teoria. A Figura 14 mostra um padrão local 3×3 de uma textura em um espaço de cores RGB.

Figura 14: Padrão Local 3×3 de uma textura em um espaço de cores RGB.

Para a extração de características utilizando a teoria de cores oponentes, considera-se o relacionamento do pixel central deste padrão localizado em um dos planos do espaço de cores, e seus vizinhos pertencentes a uma região circular localizada no canal de cor oponente, como mostrado na Figura 15.

Figura 15: Canais de cores oponentes G-R, B-R, B-G.

Para a formação do vetor de características de uma imagem, o descritor S-LMP apresentado na Seção 3.1.1 é aplicado a cada par de cores oponentes e também a cada canal de cor separadamente, obtendo-se assim, seis vetores de características que são então concatenados em um único vetor (Figura 16). O tamanho do vetor de características gerado pelo descritor OCLMP depende da quantidade B de *bins* adotada na construção do histograma; para $B = 256$, o vetor de características OCLMP de uma imagem possui $256 \times 6 = 1536$ elementos.

É importante notar que o método proposto utiliza a concatenação de seis histogramas provenientes do descritor S-LMP. Para a geração de cada histograma utilizando-se a Eq. (3.8), uma função de mapeamento como a expressada pela Eq. (3.9) é necessária, e portanto, existem seis parâmetros β a serem ajustados. O ajuste destes parâmetros será tratado no Capítulo 4.

Figura 16: Processo de geração do vetor de características do descritor OCLMP.

Fonte: (NEGRI; VIEIRA; GONZAGA, 2017)

3.3 Color Intensity Local Mapped Pattern (CILMP)

O segundo descritor proposto nesta tese é denominado *Color Intensity Local Mapped Pattern* (CILMP), o qual combina informações de cor e textura para a descrição de imagens coloridas. A combinação dessas características apresentou bons resultados para a classificação de texturas coloridas com o descritor LCC (CUSANO; NAPOLETANO;

SCHETTINI, 2014), e desta maneira, motivou sua investigação ao ser combinada com a teoria LMP.

No processo de extração de características realizado pelo descritor CILMP, as informações de cor e textura são extraídas de forma integrada, levando-se em consideração então a “textura da cor”. Além disso, o descritor combina estas informações com características extraídas da luminância da textura (denominadas simplesmente como “textura”) em uma análise multiresolução, visando diminuir a influência da iluminação e aumentar seu desempenho nas tarefas de classificação (NEGRI et al., 2017).

As informações relacionadas à textura são extraídas utilizando-se o descritor S-LMP (apresentado na Seção 3.1.1) aplicado à luminância da imagem (canal L do espaço de cores CIELAB ($L^*a^*b^*$)).

Para a extração das informações de textura da cor, este trabalho propõe uma nova abordagem baseada na magnitude dos vetores de cores localizados em um cubo RGB.

Em um espaço de cores tridimensional, cada eixo representa um canal de cor, e assim cada cor pode ser representada como um ponto, ou vetor, dentro do espaço 3D. Por exemplo, em um espaço de cores RGB, uma cor é caracterizada por suas componentes primárias vermelho, verde e azul (GONZALEZ; WOODS, 2006). Um padrão local 3×3 de uma textura colorida nada mais é do que uma matriz tridimensional, onde cada pixel é descrito por três coordenadas $g_i = (R_i, G_i, B_i)$, assim como mostrado na Figura 14.

Para estender o descritor S-LMP de modo a permitir a análise de texturas coloridas, as diferenças entre os quadrados das magnitudes dos vetores em um espaço RGB são utilizadas como entrada de uma função sigmóide, dada pela Eq. (3.10)

$$f(g_p) = \frac{1}{1 + \exp\left(\frac{-(\|g_p\|^2 - \|g_c\|^2)}{\beta}\right)}, \quad (3.10)$$

em que β está relacionado à inclinação da curva, g_c é o pixel central do padrão local e g_p é um pixel localizado na vizinhança circular de g_c . Os padrões são então mapeados para um *bin* de um histograma utilizando-se a Eq. (3.8). A Figura 17 apresenta um exemplo de dois pixels (vetores) g_p e g_c em um espaço de cores RGB.

A Figura 18 apresenta uma textura RGB e a imagem resultante do mapeamento realizado pelo CILMP utilizando a função dada pela Eq. (3.10), considerando-se oito vizinhos e raio igual a dois: (P,r)=(8,2).

Para realizar uma análise multiresolução, e assim capturar informação de padrões localizados em diversas escalas espaciais, o descritor é aplicado às texturas coloridas usando diferentes configurações de vizinhança (P,r), tanto para extração de características de textura, quanto para extração de características de cor. Os histogramas obtidos são então concatenados em um único vetor de características. A Figura 19 apresenta a análise

Figura 17: Dois pixels (vetores) g_p e g_c em um espaço de cores RGB.

Figura 18: Exemplo de uma textura RGB e sua imagem resultante após o mapeamento realizado pelo CILMP utilizando a Eq. (3.10).

Fonte: (NEGRI et al., 2017)

multiresolução realizada pelo descritor CILMP.

O tamanho do vetor de características CILMP de uma imagem depende da quantidade de *bins* (B) especificada para a construção do histograma, e ainda do número de configurações (P,r) adotadas na composição do descritor. Para o exemplo da Figura 19, considerando $B = 256$, o vetor final de características conterá $256 \times 5 = 1280$ elementos. O número de configurações do descritor influencia também na quantidade de parâmetros β a serem ajustados: uma função de mapeamento como a expressada pela Eq. (3.10) é necessária para a construção de cada histograma relativo a uma configuração do descritor. No caso do descritor CILMP mostrado na Figura 19, cinco parâmetros β precisam ser ajustados. O ajuste destes parâmetros será tratado no Capítulo 4.

Figura 19: Exemplo de uma análise multiresolução realizada pelo CILMP utilizando cinco configurações de vizinhança: $(8, 1) + (16, 3) + (24, 5)$ para a imagem de luminância e $(8, 2) + (16, 3)$ para a imagem RGB.

Fonte: Adaptado de (NEGRI et al., 2017)

3.4 Extended Color Local Mapped Pattern (ECLMP)

O terceiro e último descritor proposto nesta tese é denominado *Extended Color Local Mapped Pattern* (ECLMP). O descritor ECLMP utiliza dois operadores, $ECLMP_c$ e $ECLMP_r$, para extrair informações de cor e textura de forma integrada (textura da cor) e também informações apenas de textura (sem cor) de uma imagem. O operador $ECLMP_c$ explora uma nova abordagem para extrair informações de pixels vizinhos: os pixels de uma vizinhança circular são comparados à média dos pixels pertencentes à vizinhança, incluindo o pixel central, objetivando com isso, reduzir a influência da variação de iluminação na vizinhança considerada. Por outro lado, o operador $ECLMP_r$ captura a relação entre os pixels provenientes de diferentes resoluções de vizinhança de uma imagem. As informações de textura são extraídas da luminância da imagem (canal L do espaço de cores $L^*a^*b^*$), e as informações de textura da cor são incorporadas utilizando a magnitude dos vetores de cor localizados no cubo RGB.

Na Seção 3.4.1 é primeiramente apresentado como o descritor ECLMP incorpora informações de textura a partir da luminância da imagem utilizando os operadores $ECLMP_c$ e $ECLMP_r$. A Seção 3.4.2 explica como o método é estendido para texturas coloridas em um espaço RGB e, a Seção 3.4.3 apresenta como o descritor ECLMP combina as informações de textura e textura da cor em uma análise multiresolução.

3.4.1 Extração da informação de textura

Para um melhor entendimento do método, seja um padrão local 5×5 proveniente de uma textura, como apresentado na Figura 20. O descritor ECLMP extrai informações de textura deste padrão considerando a luminância dos pixels localizados em vizinhanças circulares simétricas como a mostrada na Figura 21. Cada vizinhança é definida por P pixels $g_{p,r}$ ($p = 1, \dots, P$) igualmente espaçados em um círculo de raio $r, r > 0$. Assumindo que o pixel central g_c está localizado nas coordenadas $(x, y) = (0, 0)$, as coordenadas dos pixels vizinhos $g_{p,r}$ são dadas pela Eq. (3.7). Assim como no S-LMP, quando as coordenadas dos pixels não são valores inteiros, os valores de nível de cinza do pixel são estimados por interpolação.

g_1	g_2	g_3	g_4	g_5
g_6	g_7	g_8	g_9	g_{10}
g_{11}	g_{12}	g_{13}	g_{14}	g_{15}
g_{16}	g_{17}	g_{18}	g_{19}	g_{20}
g_{21}	g_{22}	g_{23}	g_{24}	g_{25}

Figura 20: Padrão local 5×5 .

Figura 21: Vizinhanças circulares concêntricas.

Fonte: (NEGRI et al., 2018)

A extração de informação de textura é realizada por dois operadores - $ECLMP_c$ e $ECLMP_r$ - aplicados à imagem de luminância.

O operador $ECLMP_c$ considera a relação entre a média dos pixels locais e a vizinhança circular de maior raio r_{out} (Figura 21). Esta informação é capturada utilizando-se a função sigmóide definida na Eq. (3.11)

$$f(g_{p,r_{out}}) = \frac{1}{1 + \exp\left(\frac{-[g_{p,r_{out}} - m_1]}{\beta_{c1}}\right)}, \quad (3.11)$$

na qual β_{c1} está relacionado à inclinação da curva e m_1 é a média dos níveis de cinza dos pixels da vizinhança circular, incluindo o pixel central, conforme apresentado na Eq. (3.12)

$$m_1 = \frac{1}{n+1} \left[\left(\sum_{i=1}^n g_{p,r_{out}} \right) + g_c \right]. \quad (3.12)$$

Cada padrão local é representado por um código gerado utilizando-se a Eq. (3.13), sendo f a função de mapeamento definida na Eq. (3.11). Os códigos da imagem são

armazenados em uma matriz denominada “mapa de códigos”. Estes códigos são então uniformemente quantizados em Q elementos.

$$ECLMP_c = \text{round} \left(\frac{\left(\sum_{p=1}^P f(g_{p,r_{out}}) \right) + f(g_c)}{P+1} (Q-1) \right). \quad (3.13)$$

Inspirado por (LIU et al., 2016), o operador $ECLMP_r$ captura a relação entre os pixels $g_{p,r_{in}}$ localizados na vizinhança circular de menor raio (r_{in}), e os pixels $g_{p,r_{out}}$ localizados na vizinhança circular de maior raio (r_{out}). As diferenças entre os valores de $g_{p,r_{in}}$ e $g_{p,r_{out}}$ são utilizadas como argumento da função de mapeamento conforme a Eq. (3.14), sendo β_{r1} a inclinação da curva sigmóide.

$$z(g_{p,r_{out}}, g_{p,r_{in}}) = \frac{1}{1 + \exp \left(\frac{-[g_{p,r_{out}} - g_{p,r_{in}}]}{\beta_{r1}} \right)}, \quad (3.14)$$

A média dos valores das comparações entre os pixels da vizinhança é então realizada, gerando os códigos $ECLMP_r$ utilizando-se a Eq. (3.15), na qual z é a função de mapeamento definida na Eq. (3.14). Assim como no operador $ECLMP_c$, os códigos são uniformemente quantizados em Q elementos e armazenados em um segundo mapa de códigos.

$$ECLMP_r = \text{round} \left(\frac{\sum_{p=1}^P z(g_{p,r_{out}}, g_{p,r_{in}})}{P} (Q-1) \right). \quad (3.15)$$

O vetor de características ECLMP é gerado combinando as informações extraídas pelos operadores $ECLMP_c$ e $ECLMP_r$ em um histograma conjunto (OJALA; PIETIKAINEN; MAENPAA, 2002), o qual é construído levando-se em consideração a frequência dos valores entre os mapas de códigos, conforme apresentado na Figura 22. Nesta representação, uma vizinhança em uma imagem será representada por um código $ECLMP_c$ (em um intervalo de $0, \dots, Q-1$) e um código $ECLMP_r$ (em um intervalo de $0, \dots, Q-1$). O histograma conjunto de códigos $ECLMP_c$ e $ECLMP_r$ contém $Q \times Q$ entradas, em que cada entrada corresponde a um determinado código $ECLMP_c$ e um determinado código $ECLMP_r$. O valor armazenado nesta entrada é o número de vizinhanças da imagem que contém esta determinada combinação de códigos.

3.4.2 Extração da informação de textura da cor

Os operadores $ECLMP_c$ e $ECLMP_r$ foram também estendidos para análise de texturas coloridas utilizando-se a mesma abordagem empregada no descritor CILMP, em que as características de textura da cor são extraídas de uma imagem considerando-se o quadrado das magnitudes dos vetores de cores no espaço RGB. Neste caso, para incorporar informações de textura da cor, o operador $ECLMP_c$ utiliza a função de mapeamento

Figura 22: Geração do vetor de características ECLMP de uma imagem de luminância, considerando $P = 8$, $r_{out} = 2$, $r_{in} = 1$, $Q = 16$ e $\beta_{c1} = \beta_{r1} = 0, 1$.

Fonte: Adaptado de (NEGRI et al., 2018)

definida na Eq. (3.16), na qual β_{c2} está relacionado à inclinação da curva sigmóide e m_2 é a média dos quadrados das magnitudes dos pixels localizados na vizinhança circular analisada, incluindo o pixel central (Eq. (3.17)). O mapa de códigos $ECLMP_c$ é então gerado pela Eq. (3.13), e os códigos são posteriormente quantizados de maneira uniforme em Q elementos.

$$f(g_{p,r_{out}}) = \frac{1}{1 + \exp\left(\frac{-[||g_{p,r_{out}}||^2 - m_2]}{\beta_{c2}}\right)}, \quad (3.16)$$

$$m_2 = \frac{1}{n+1} \left[\left(\sum_{i=1}^n ||g_{p,r_{out}}||^2 \right) + ||g_c||^2 \right]. \quad (3.17)$$

O mapa de códigos $ECLMP_r$ de uma textura colorida é também obtido usando-se a Eq. (3.15), seguindo o mesmo procedimento apresentado para extração das informações de textura. No entanto, as diferenças da textura da cor entre os pixels $g_{p,r_{in}}$ e $g_{p,r_{out}}$ são capturadas pela função de mapeamento definida na Eq. (3.18), em que β_{r2} é relativo à inclinação da curva sigmóide.

$$z(g_{p,r_{out}}, g_{p,r_{in}}) = \frac{1}{1 + \exp\left(\frac{-[||g_{p,r_{out}}||^2 - ||g_{p,r_{in}}||^2]}{\beta_{r2}}\right)}, \quad (3.18)$$

Assim como ocorre para a extração de informação de textura, o vetor de características ECLMP da informação de cor é gerado combinando-se as informações extraídas

Figura 23: Geração do vetor de características ECLMP de uma imagem RGB, considerando $P = 8$, $r_{out} = 2$, $r_{in} = 1$, $Q = 16$ e $\beta = 0, 1$.

Fonte: Adaptado de (NEGRI et al., 2018)

pelos operadores $ECLMP_c$ e $ECLMP_r$ em um histograma conjunto (Figura 23). Cada entrada do histograma conjunto armazena o número de vizinhanças da imagem descrita que contém uma determinada combinação de códigos $ECLMP_c$ e $ECLMP_r$.

Note que para medir as diferenças entre os pixels localizados em vizinhanças circulares de raios diferentes, o número de pixels amostrados P deve ser o mesmo para ambas as vizinhanças. Por exemplo, considerando-se a vizinhança mostrada na Figura 21, pode-se ter $r_{out} = 2$, $r_{in} = 1$, e $P = 8$ para ambos os raios. Para simplificar a notação, esta configuração pode ser denotada por $ECLMP(P, r_{out}, r_{in}) = ECLMP(8, 2, 1)$.

3.4.3 Combinação das informações de textura e textura da cor

A fim de aumentar o desempenho do descritor ECLMP, uma análise multiresolução é realizada considerando características extraídas usando diferentes configurações de raios (r_{out}, r_{in}) e número de vizinhos (P). Os histogramas conjuntos provenientes desta análise são convertidos em um histograma unidimensional, e são então concatenados gerando o vetor de características da imagem.

A Figura 24 apresenta um exemplo de análise multiresolução realizada pelo descritor ECLMP, que utiliza duas configurações para a extração de informação de textura da cor: $(P, r_{out}, r_{in}) = (8, 2, 1)$ e $(P, r_{out}, r_{in}) = (16, 3, 2)$, e estas mesmas duas configurações para a extração de informação de textura da imagem de luminância, totalizando quatro configurações. É sugerido que o mapa de códigos provenientes dos operadores $ECLMP_c$ e $ECLMP_r$ sejam quantizados em 16 elementos ($Q = 16$) para que o histograma conjunto

contenha $Q \times Q = 16 \times 16 = 256$ bins. Dessa maneira, o vetor de características gerado pelo descritor ECLMP da Figura 24 contém $256 \times 4 = 1024$ elementos.

Figura 24: Vetor de características multiresolução ECLMP.

Para cada configuração ECLMP, o descritor utiliza duas funções de mapeamento: a função de mapeamento f do operador $ECLMP_c$ e a função de mapeamento z do operador $ECLMP_r$. Desde que as informações extraídas por elas são relativas à mesma configuração e combinadas em um histograma conjunto, é sugerida a utilização do mesmo parâmetro para as duas funções, ou seja, $\beta_{c1} = \beta_{r1}$ no caso da informação de textura, e $\beta_{c2} = \beta_{r2}$ no caso da informação de textura da cor. Sendo assim, o número de parâmetros a serem otimizados para o descritor ECLMP depende da quantidade de configurações utilizadas na sua construção. No exemplo da Figura 24 é necessário otimizar quatro parâmetros β , um para cada configuração ECLMP.

3.5 Considerações Finais

Neste capítulo foram apresentados três novos descritores de texturas coloridas: *Opponent Color Local Mapped Pattern* (OCLMP), *Color Intensity Local Mapped Pattern* (CILMP) e *Extended Color Local Mapped Pattern* (ECLMP).

O descritor OCLMP combina a abordagem LMP com a teoria de cores oponentes. Este descritor foi inspirado no método OCLBP, o qual apresentou bom desempenho na classificação de imagens capturadas em diferentes direções da fonte de luz (CUSANO; NAPOLETANO; SCHETTINI, 2014).

Os decritores CILMP e ECLMP combinam informações de textura da cor e informações de textura (luminância) na descrição de imagens coloridas. A combinação destas informações, utilizando-se o contraste da imagem, foi investigada em (CUSANO; NAPOLETANO; SCHETTINI, 2014) com o descritor LCC, e mostrou bons resultados na classificação de texturas coloridas com variação de iluminação. Inspirado pelo LCC, o descritor CILMP apresentado nesta tese propõe a extração das informações de cor e textura de forma conjunta, considerando a magnitude dos vetores de cor em um cubo RGB. Por fim, o descritor ECLMP combina a abordagem proposta pelo CILMP a uma nova forma de comparar os pixels de uma vizinhança em uma textura, com o objetivo de reduzir a influência da variação de iluminação na vizinhança considerada.

Todos os métodos descritos nesta seção foram desenvolvidos com o intuito de serem utilizados na classificação de texturas coloridas, em especial quando se tem variação na iluminação das imagens. Neste sentido, o próximo capítulo apresenta os experimentos realizados para avaliar a robustez dos descritores propostos.

4 MATERIAL E MÉTODOS

4.1 Considerações Iniciais

Os descritores propostos nesta tese foram avaliados na classificação de texturas coloridas em diferentes condições de iluminação. Esta avaliação foi realizada em duas bases de dados: RawFooT (*Raw Food Texture Database*) (CUSANO; NAPOLETANO; SCHETTINI, 2016) e KTH-TIPS-2b (*Textures under varying Illumination, Pose and Scale*) (CAPUTO; HAYMAN; MALLIKARJUNA, 2005) descritas na Seção 4.2. Em seguida, a Seção 4.3 descreve o processo empregado para avaliação do desempenho dos descritores.

Os descritores baseados na metodologia LMP possuem alguns parâmetros que precisam ser sintonizados/otimizados de acordo com a aplicação pretendida. No caso dos descritores propostos nesta tese, o principal parâmetro a ser sintonizado é a inclinação da curva sigmóide utilizada como função de mapeamento. A Seção 4.4 deste capítulo apresenta o método para realizar essa sintonização utilizando algoritmo genético.

4.2 Bases de Dados

4.2.1 Base de dados RawFooT

A base de dados RawFooT foi proposta por Cusano et al. (2016), especialmente para investigar a robustez de descritores na classificação de texturas coloridas em diferentes condições de iluminação. A base de dados é composta por 68 texturas de alimentos crus (Fig. 25), de tamanho 800×800 pixels, adquiridas sob 46 condições de iluminações diferentes. Tais condições incluem mudanças na direção, cor, temperatura e intensidade da fonte de luz, e também combinações destes fatores, como por exemplo, temperatura e direção.

As imagens originais foram divididas em 16 amostras, sem sobreposição, de 200×200 pixels: 8 amostras para treinamento e 8 amostras para teste. Dessa forma, a base de dados possui $68 \times (8 + 8) = 1088$ amostras para cada uma das 46 condições de iluminação, totalizando 50.048 imagens. A Figura 26 apresenta a mesma amostra capturada sob as 46 condições de iluminações, que são também listadas a seguir:

- **(1-4) Variação de intensidade:** 4 capturas sob luz neutra/natural a 6500 K e quatro níveis de intensidade: 100%, 75%, 50% e 25% (D65, I=100%, 75%, 50% e 25%);
- **(5-13) Direção da luz:** 9 capturas sob luz neutra/natural a 6500 K e 9 ângulos de incidência: 24°, 30°, 36°, 42°, 48°, 54°, 60° e 90° (D65, $\theta = 24^\circ, 30^\circ, 36^\circ, 42^\circ, 48^\circ, 54^\circ, 60^\circ, 66^\circ$ e 90°);

Figura 25: As 68 classes da base de dados RawFooT.

Fonte: ([CUSANO; NAPOLETANO; SCHETTINI, 2016](#))

- **(14-25) Temperatura da luz neutra:** 12 capturas sob luz neutra em 12 diferentes temperaturas variando de 4000 K a 9500 K em intervalos de 500 K (D40, D45, D50, ..., D95);
- **(26-31) Temperatura da luz de LED:** 6 capturas sob fontes de luz de LED em 6 diferentes temperaturas: 2700 K, 3000 K, 4000 K, 5000 K, 5700 K e 6500 K (L27, L30, L40, L50, L57, L65);
- **(32-40) Temperatura e Direção:** 9 capturas sob combinações de fonte de luz em três temperaturas (D65, D95 e L27) e três ângulos de incidência (24°, 60° e 90°);
- **(41-43) Múltiplas fonte de luz:** 3 capturas sob combinações de duas fontes de luz variando entre D65, D95 e L27 (D65-D95, D65-L27, D95-L27);
- **(44-46) Cores primárias:** Fontes de luz vermelha, verde e azul.

Para avaliação dos descritores na base de dados RawFooT foram reproduzidos os nove experimentos propostos em ([CUSANO; NAPOLETANO; SCHETTINI, 2016](#)) e descritos a seguir:

Figura 26: Exemplo de uma das texturas (lentilha) da base de dados RawFooT adquirida sob as 46 condições de iluminação.

1. **Sem variação:** 46 subconjuntos. Em cada subconjunto, as amostras de treinamento e de teste foram adquiridas sob a mesma condição de iluminação;
2. **Intensidade da luz:** 12 subconjuntos, cada um composto por amostras de treinamento e de teste adquiridas sob diferentes níveis de intensidade;
3. **Direção da luz:** 72 subconjuntos, cada um composto por amostras de treinamento e de teste adquiridas sob diferentes direções da fonte de luz;
4. **Temperatura da luz neutra:** 132 subconjuntos, cada um composto por amostras de treinamento e de teste adquiridas sob fontes de luz neutra em diferentes temperaturas;
5. **Temperatura da luz de LED:** 30 subconjuntos, cada um composto por amostras de treinamento e de teste adquiridas sob fonte de luz de LED em diferentes temperaturas;
6. **Luz neutra x LED:** 72 subconjuntos combinando as doze temperaturas de luz neutra com as seis temperaturas de luz de LED;
7. **Temperatura ou direção:** 72 subconjuntos combinando as condições de iluminação 32 a 40, em que amostras de treinamento e de teste diferem em temperatura e direção ou ambas, temperatura e direção;

8. **Temperatura e direção:** 36 subconjuntos combinando as condições de iluminação 32 a 40, em que amostras de treinamento e de teste diferem obrigatoriamente em ambas, temperatura e direção;
9. **Múltiplas fontes de luz:** 6 subconjuntos combinando as condições de iluminação 41 a 43.

Cada um dos nove experimentos avalia a robustez dos descritores a uma determinada condição de iluminação. Sendo assim, cada experimento envolve subconjuntos contendo imagens de treinamento e teste que diferem em algum aspecto na aquisição dentro da condição de iluminação a ser analisada. Por exemplo, o experimento 2 envolve amostras adquiridas sob 4 intensidades de luz. Se as amostras do conjunto de teste foram adquiridas com intensidade 100%, é possível formar 3 subconjuntos (teste, treinamento), considerando as amostras de treinamento adquiridas sob os outros três níveis de intensidade: (100%, 75%), (100%, 50%) e (100%, 25%). Desde que as imagens foram adquiridas sob 4 níveis de intensidade, é possível formar $4 \times 3 = 12$ subconjuntos.

4.2.2 Base de dados KTH-TIPS-2b

A base de dados KTH-TIPS-2b apresenta imagens adquiridas sob variação controlada de iluminação, variação de escala e ponto de vista. Esta base de dados é formada por 11 categorias, em que cada uma delas possui 4 texturas de uma mesma classe. (Figura 27). Cada textura é adquirida considerando 9 escalas, 3 poses e 4 condições de iluminação, totalizando 4752 amostras de 200×200 pixels.

Figura 27: Quatro amostras de cada uma das onze categorias da base de dados KTH-TIPS-2b (amostras adquiridas na escala 4, pose frontal e iluminação frontal).

Como o objetivo desta tese é investigar a robustez dos descritores propostos à variação de iluminação, o protocolo usual de avaliação, apresentado pela maioria dos

trabalhos que utilizam esta base de dados, não foi considerado. As imagens da base de dados foram selecionadas de forma a proporcionar uma avaliação direcionada ao problema abordado. Para isso, foram selecionadas as imagens adquiridas sob a pose frontal, nas escalas 2, 3, 4, 5 e 6, considerando-se três direções de iluminação: Frontal, 45° a partir do topo (45° Top) e 45° a partir da lateral (45° Side). As amostras nas escalas 3, 4 e 6 foram utilizadas como conjunto de treinamento e as amostras nas escalas 2 e 5 foram utilizadas como conjunto de teste.

Note que a escala de aquisição das imagens varia entre os conjuntos de treinamento e teste. Isto foi necessário devido ao pequeno número de amostras (4) em cada iluminação em uma dada escala. Por este motivo, a robustez dos descritores a mudanças na iluminação não é acessada isoladamente. Os resultados refletem a robustez a mudanças em iluminação e escala combinadas. Os três experimentos realizados na base de dados KTH-TIPS-2b são descritos na Tabela 1. Desde que a base de dados RawFooT contém 9 experimentos, os experimentos da base KTH-TIPS-2b foram numerados em continuação: experimentos 10, 11 e 12.

Tabela 1: Experimentos realizados na base de dados KTH-TIPS-2b

Experimentos	Direção da Iluminação	
	Imagens de Teste	Imagens de Treinamento
10	Frontal	45° Top
	45° Top	Frontal
11	Frontal	45° Side
	45° Side	Frontal
12	45° Top	45° Side
	45° Side	45° Top

4.3 Classificação e Avaliação

No processo de classificação, o descritor a ser avaliado é aplicado às amostras de treinamento e de teste gerando seus respectivos vetores de características.

A dissimilaridade entre as amostras de treinamento e teste é medida calculando-se a distância entre os vetores de características utilizando a distância L_1 apresentada na Eq. (4.1),

$$D(S, M) = \sum_{b=1}^{B_t} |S_b - M_b| \quad (4.1)$$

em que S é o vetor de características da amostra de treinamento, M é o vetor de características da amostra de teste e B_t corresponde ao número de *bins* do vetor de características.

Em todos os experimentos, o classificador *K-nearest neighbor* (K-NN), com $K = 1$ foi utilizado para estimar a classe das imagens de teste: os vetores de características de

cada amostra de teste são comparados aos vetores de características de todas as amostras de treinamento, e a classe da amostra de treinamento que fornecer a menor medida de dissimilaridade é considerada como a predição da amostra de teste. Os resultados das classificações são armazenados em uma matriz de confusão e o desempenho dos descritores é reportado pela medida de acurácia (proporção entre o número de amostras classificadas corretamente e o número de amostras de teste). A Figura 28 ilustra o processo de classificação das amostras.

Figura 28: Processo de classificação.

Para a base de dados RawFoot, cada experimento utiliza diversos subconjuntos, sendo que cada um avalia uma configuração da condição de iluminação analisada. Tomando o experimento 2 novamente como exemplo, este possui 12 subconjuntos, e cada um desses subconjuntos gera uma acurácia de classificação, conforme apresentado na Figura 29. Dessa maneira é possível avaliar o desempenho do descritor em cada experimento por meio da acurácia média e acurácia mínima obtidas. Desde que são realizados nove experimentos, é possível ainda obter a acurácia geral (acurácia média geral) da classificação considerando-se os nove experimentos. Assim, os descritores são avaliados na base de dados RawFoot

utilizando-se três medidas: acurácia média, acurácia mínima e acurácia geral.

Figura 29: Subconjuntos que compõem o experimento 2 da base de dados RawFooT.

Para a base de dados KTH-TIPS-2b, são consideradas três condições de iluminação, todas relacionadas a direção da fonte de luz: Frontal, 45° a partir do topo (45° Top) e 45° a partir da lateral (45° Side). Dessa maneira, é possível formar seis subconjuntos a serem analisados, divididos em três experimentos, conforme apresentado na Seção 4.2.2. Os descritores são então avaliados por meio da acurácia geral (acurácia média geral) obtida considerando-se os três experimentos (Figura 30).

Uma medida que também pode ser avaliada no desempenho dos descritores de textura é o tempo de processamento exigido pelo método. Esta medida diz respeito à complexidade do método e viabilidade de sua execução em aplicações em tempo real. Para realizar esta avaliação, foram consideradas amostras de texturas coloridas de cinco tamanhos diferentes: 64×64 , 128×126 , 256×256 , 512×512 , 1024×1024 pixels. Para cada um dos tamanhos, o tempo de construção do vetor de características de uma imagem foi medido 10 (dez) vezes, e considerou-se o tempo médio obtido. Este experimento foi conduzido em um computador com processador Intel® Core™ i7-6560U CPU 2,2GHz, 8GB de RAM e MATLAB R2016a, rodando Windows 8 Enterprise, sem privilégio de processos.

Figura 30: Experimentos realizados na base de dados KTH-TIPS-2b.

4.4 Sintonização dos Parâmetros

Os parâmetros β apresentados nas funções de mapeamento descritas nas Equações (3.5), (3.9), (3.10), (3.11), (3.14), (3.16), (3.18) determinam a inclinação da curva sigmóide. Mudanças no valor destes parâmetros modificam a sensibilidade do método às nuances dos pixels em uma imagem, afetando diretamente o desempenho do descritor.

A Figura 31 apresenta o comportamento da curva sigmóide, descrita na Eq. (3.10), para um intervalo de valores β . Quando valores pequenos são atribuídos a este parâmetro, a diferença entre os pixels é saturada rapidamente para 0 ou 1, de forma semelhante ao LBP. Para valores maiores de β , a curva se aproxima de uma linha reta paralela ao eixo das abcissas, tal que as diferenças entre os pixels são mapeadas para valores próximos de 0,5.

Os parâmetros β afetam o resultado do mapeamento da textura, impactando no desempenho do método e, portanto, a otimização destes parâmetros de forma eficiente faz-se necessária. Em trabalhos anteriores que utilizam métodos baseados na abordagem LMP, a sintonização dos parâmetros era feita manualmente, ou de forma empírica, testando vários valores e selecionando aquele que resultasse em maior sensibilidade (CHIERICI,

Figura 31: Comportamento da curva sigmóide para um intervalo de valores de β .

2015; FERRAZ; PEREIRA JR.; GONZAGA, 2014; VIEIRA, 2013). No entanto, além de demandar muito tempo, a seleção manual dos parâmetros exige uma ordem de sintonização, e em descritores com mais de um parâmetro, isto pode ser bastante custoso.

A quantidade de parâmetros a ser sintonizada para um descritor varia conforme a configuração adotada em sua construção. Tomando como exemplo o descritor OCLMP proposto nesta tese, seis operadores são utilizados em sua construção, e portanto é necessário o ajuste de seis parâmetros. Estes parâmetros podem ser sintonizados individualmente ou em conjunto, em que todos são otimizados simultaneamente.

Nesta tese, propõe-se a sintonização simultânea dos parâmetros, de modo automático utilizando-se um algoritmo genético. A sintonização dos parâmetros foi realizada utilizando-se uma *toolbox* de otimização disponível no software MATLAB (*Global Optimization Toolbox*). A acurácia foi utilizada como função objetivo a ser maximizada.

Os descritores propostos nesta tese possuem outros parâmetros que podem ser otimizados para um melhor desempenho do método, como o número de *bins* B dos histogramas, o parâmetro Q responsável pela quantização dos valores na geração dos mapas de códigos do descritor ECLMP e o número de pixels amostrados P e raio r para a determinação das configurações dos descritores. Neste trabalho, estes valores foram testados e selecionados empiricamente. Os histogramas dos descritores OCLMP e CILMP foram construídos considerando-se $B = 256$, e os mapas de códigos do descritor ECLMP foram quantizados em $Q = 16$ elementos.

Para sintonização dos parâmetros β dos descritores propostos faz-se necessário um conjunto de imagens, aqui denominado conjunto de sintonização ou *tuning set*. Para cada base de dados, um conjunto de sintonização foi gerado selecionando-se aleatoriamente 2 amostras por classe do total de amostras de treinamento da base de dados, independente da iluminação. Assim, para a base de dados RawFoot, o conjunto de sintonização é composto

por $68 \times 2 = 136$ amostras e o conjunto de sintonização para a base de dados KTH-TIPS-2b contém $11 \times 2 = 22$ amostras. Estes conjuntos foram utilizados na sintonização de todos os parâmetros β dos três descritores propostos.

4.5 Considerações Finais

Neste capítulo foram apresentadas as bases de dados utilizadas para a avaliação dos descritores propostos na classificação de texturas coloridas com variação de iluminação. Os experimentos realizados foram descritos, bem como o processo de avaliação e classificação utilizados. Além disso, foi apresentado o método utilizado para a otimização dos parâmetros relacionados ao método. No próximo capítulo são exibidos os resultados obtidos pelos descritores propostos, bem como uma comparação do desempenho destes descritores com outros descritores de textura tradicionalmente utilizados.

5 RESULTADOS E DISCUSSÃO

5.1 Considerações Iniciais

Neste capítulo são apresentados os resultados experimentais obtidos na classificação de texturas coloridas em diferentes condições de iluminação, aplicando-se os descritores propostos no Capítulo 3. Estes resultados são comparados aos resultados apresentados por outros descritores comumente utilizados na classificação de texturas coloridas. Para esta avaliação foram utilizadas duas bases de dados: RawFooT e KTH-TIPS-2b, as quais foram descritas no Capítulo 4.

As Seções 5.2 e 5.3 apresentam a acurácia dos métodos propostos para os experimentos de classificação das bases de dados RawFooT e KTH-TIPS-2b, respectivamente. A Seção 5.4, exibe uma análise do tempo de processamento exigido pelos descritores para a construção dos vetores de características de imagens de diferentes tamanhos, conforme apresentado na Seção 4.3 do Capítulo 4.

5.2 Resultados Experimentais para a base de dados RawFooT

Para avaliar o desempenho dos descritores propostos na base de dados RawFooT, foram reproduzidos os nove experimentos de classificação sugeridos por Cusano et al. (2016) e descritos na seção 4.2.1. As Seções 5.2.1, 5.2.2 e 5.2.3 apresentam o desempenho dos descritores OCLMP, CILMP e ECLMP, respectivamente, para esta base de dados. Desde que o descritor OCLMP é baseado na teoria de cores oponentes, assim como o OCLBP, os desempenhos destes dois descritores são comparados na Seção 5.2.4. Por fim, a Seção 5.2.5, compara os resultados obtidos pelos descritores propostos com outros descritores da literatura.

5.2.1 OCLMP

Nesta seção é apresentado o desempenho do descritor proposto OCLMP na base de dados RawFooT. Por ser um descritor paramétrico, o OCLMP possui alguns parâmetros a serem ajustados, conforme descrito na Seção 4.4. A Tabela 2 apresenta os valores dos parâmetros ajustados para este descritor no conjunto de sintonização da base de dados RawFooT, considerando diferentes configurações (P,r). Os resultados obtidos pelo descritor nos nove experimentos propostos por Cusano et al. (2016) (CUSANO; NAPOLETANO; SCHETTINI, 2016) e descritos na Seção 4.2.1, são reportados na Tabela 3.

Considerando-se os resultados reportados na Tabela 3 é possível observar que todas as configurações apresentam bom desempenho no experimento 1, em que não há variação de iluminação (aproximadamente 98% de acurácia média). No entanto, quando

Tabela 2: Parâmetros ajustados para as diferentes configurações (P,r) do descritor OCLMP para a base de dados RawFoot.

OCLMP	Parâmetros (β)	OCLMP	Parâmetros (β)
(8,1) R - G	1,3644	(16,3) R - G	1,3698
(8,1) R - B	0,1104	(16,3) R - B	0,3542
(8,1) G - B	0,2682	(16,3) G - B	0,0625
(8,1) R	0,2920	(16,3) R	1,2119
(8,1) G	1,8584	(16,3) G	0,6073
(8,1) B	0,4439	(16,3) B	4,7581
(8,2) R - G	1,3833	(24,3) R - G	1,2638
(8,2) R - B	3,1174	(24,3) R - B	0,0527
(8,2) G - B	0,5992	(24,3) G - B	0,0908
(8,2) R	4,0560	(24,3) R	1,5860
(8,2) G	0,2497	(24,3) G	0,7639
(8,2) B	4,7899	(24,3) B	0,9246
(16,2) R - G	1,6497	(24,5) R - G	0,7707
(16,2) R - B	0,0665	(24,5) R - B	0,0705
(16,2) G - B	0,0386	(24,5) G - B	0,3374
(16,2) R	1,9842	(24,5) R	1,3276
(16,2) G	0,8978	(24,5) G	0,4484
(16,2) B	0,6336	(24,5) B	0,7136

Tabela 3: Acurácias médias (%) obtidas pelas diferentes configurações do descritor OCLMP nos nove experimentos da base de dados RawFoot.

Exp.	1	2	3	4	5	6	7	8	9	-
OCLMP	Sem Var.	Intens.	Dir.	Temp. Neutra	Temp. LED	Neutra x LED	Temp. OU Dir.	Temp. E Dir.	Múltip. Fontes	Acurác. Geral
(8,1)	98,41	69,04	65,59	68,63	56,88	59,42	21,02	13,77	71,11	58,21
(8,2)	98,25	69,27	63,16	71,88	60,42	64,60	21,39	14,38	68,60	59,11
(16,2)	97,43	79,27	62,73	61,53	53,68	56,59	19,74	11,91	56,37	55,47
(16,3)	98,04	72,81	64,16	68,42	60,48	63,58	21,00	13,84	63,51	58,43
(24,3)	97,59	87,06	65,17	64,02	57,08	58,81	21,94	14,31	62,50	58,72
(24,5)	98,05	88,31	67,64	66,99	59,96	61,53	25,42	17,62	69,33	61,65

há mudanças na fonte de luz, a quantidade de pontos amostrados P e raio r influenciam no poder de descrição do método. Para o experimento 2, por exemplo, em que há variação na intensidade da fonte de luz, a variação na acurácia média entre a pior e a melhor configuração é de 19,27 pontos percentuais (pp.).

As condições de iluminação dos experimentos 7 e 8, as quais envolvem variação na temperatura *ou* direção, e temperatura *e* direção da fonte de luz, foram as condições que apresentaram menores taxas de classificação.

Nota-se ainda que não existe uma configuração única que seja ótima para todas as variações. De modo geral, a configuração $(P, r) = (24, 5)$ apresenta a maior acurácia geral quando são considerados os nove experimentos, obtendo o melhor desempenho em cinco deles. Por outro lado, a configuração $(P, r) = (16, 2)$ foi a que apresentou a menor

acurácia geral (55,47%) e menor desempenho em oito, dos nove experimentos realizados.

5.2.2 CILMP

Nesta seção são apresentados os resultados obtidos pelo descritor CILMP, considerando-se diferentes configurações, na base de dados RawFooT. Assim como o OCLMP, o descritor CILMP é paramétrico e, portanto, possui alguns parâmetros a serem ajustados. A Tabela 4 apresenta os parâmetros ajustados no conjunto de sintonização da base de dados RawFooT para as diferentes configurações do descritor. A Tabela 5 apresenta o desempenho das diferentes configurações do descritor CILMP nas nove tarefas de classificação desta base de dados.

Tabela 4: Parâmetros ajustados para as diferentes configurações (P,r) do descritor CILMP para a base de dados RawFooT.

CILMP	Parâmetros (β)	CILMP	Parâmetros (β)
(8,1) RGB	0,1867	(8,2) RGB	0,1712
(8,1) L	0,0774	(16,3) RGB	0,1386
(8,2) RGB	0,8856	(8,1) L	0,0844
(8,2) L	0,0281	(16,3) L	0,1320
(16,3) RGB	0,0088	(24,5) L	0,9797
(16,3) L	0,7610	(8,2) RGB	0,0462
(8,2) RGB	0,6094	(16,3) RGB	0,2543
(16,3) RGB	0,3529	(24,5) RGB	0,1524
(8,1) L	0,9514	(8,1) L	0,0352
(16,3) L	0,9174	(16,3) L	0,2902
		(24,5) L	0,9787

Observando-se a Tabela 5 é possível notar que, assim como o OCLMP, todas as configurações do CILMP apresentam bom desempenho na classificação de texturas coloridas quando não há variação de iluminação (experimento 1). Quando a intensidade da fonte de luz sofre modificações, como no experimento 2, a configuração $(16,3)RGB + (16,3)L$ se mostrou mais robusta, alcançando 85,82% de acurácia média.

Quando há variações na temperatura da luz neutra (experimento 4) os descritores compostos por mais combinações de (P,r) apresentam melhor desempenho, chegando a 97,34% de classificações corretas com o descritor $(8,2)RGB + (16,3)RGB + (24,5)RGB + (8,1)L + (16,3)L + (24,5)L$. Para as outras sete condições de iluminação, o descritor formado por cinco configurações $((8,2)RGB + (16,3)RGB + (8,1)L + (16,3)L + (24,5)L)$ superou as demais combinações. Esta configuração foi ainda a que apresentou maior acurácia geral quando se considera os nove experimentos, alcançando 77,79% de classificações corretas.

Analisando as três primeiras linhas da Tabela 5 é possível perceber que, a quantidade de pontos amostrados P e o raio r , influenciam diretamente no desempenho do descritor. A configuração $(P,r) = (16,3)$ obteve melhores resultados nos experimentos em que há

Tabela 5: Acurácias médias (%) obtidas pelas diferentes configurações do descritor CILMP nos nove experimentos da base de dados RawFooT.

Exp.	1	2	3	4	5	6	7	8	9	-
CILMP	Sem Var.	Intens.	Dir.	Temp. Neutra	Temp. LED	Neutra x LED	Temp. OU Dir.	Temp. E Dir.	Múltip. Fontes	Acurác. Geral
(8,1) RGB (8,1) L	95,71	51,32	52,7	90,95	77,12	82,44	25,95	16,15	87,99	64,48
(8,2) RGB (8,2) L	96,75	65,71	54,66	95,29	87	87,83	28,93	18,92	91,54	69,63
(16,3) RGB (16,3) L	95,66	85,82	61,43	95,65	93,18	92,18	38,51	26,04	93,29	75,75
(8,2) RGB (16,3) RGB (8,1) L (16,3) L	96,86	72,82	58,7	96,09	93,17	92,01	34,64	22,35	93,69	73,37
(8,2) RGB (16,3) RGB (8,1) L (16,3) L (24,5) L	97,98	82,46	64,01	97,27	95,24	94,11	43,67	29,44	95,96	77,79
(8,2) RGB (16,3) RGB (24,5) RGB (8,1) L (16,3) L (24,5) L	97,35	82,51	63,95	97,34	94,98	94,05	39,56	26,61	95,74	76,90

variação de iluminação (experimentos 2 a 9), quando comparada as que possuem raio e quantidade de pontos amostrados menores. A maior variação ocorre no experimento 2, em que há mudanças na intensidade da fonte de luz: a diferença entre as acurácias médias das configurações $(P, r) = (16, 3)$ e $(P, r) = (8, 1)$ é de 34,50 pp..

Os resultados apresentados na Tabela 5 mostram também que a combinação de várias configurações em multiresolução aumentam o desempenho do descritor na classificação de texturas coloridas sob diferentes condições de iluminação. Observa-se ainda que os experimentos em que o descritor obteve menores acurácias médias são aqueles que envolvem variação na direção da fonte de luz (experimentos 3, 7 e 8).

5.2.3 ECLMP

Esta seção destina-se a apresentar o desempenho do descritor ECLMP na base de dados RawFooT. A Tabela 6 exibe os valores dos parâmetros das diferentes configurações do descritor, ajustados para esta base de dados. A Tabela 7, por sua vez, apresenta os resultados obtidos pelo descritor em cada um dos nove experimentos propostos.

A partir da Tabela 7 observa-se que as acurácias gerais obtidas pelas diferentes configurações do descritor ECLMP são bastante próximas. No entanto, os descritores que combinam duas resoluções de (P, r_{out}, r_{in}) para extrair informações de textura da cor, e mais duas resoluções de (P, r_{out}, r_{in}) para extrair informações de textura, apresentaram

Tabela 6: Parâmetros ajustados para as diferentes configurações (P, r_{out}, r_{in}) do descritor ECLMP para a base de dados RawFoot.

ECLMP	Parâmetros (β)	ECLMP	Parâmetros (β)
(8,2,1) RGB	0,0254	(8,2,1) RGB	0,3401
(8,2,1) L	0,0402	(16,3,2) RGB	0,9204
(16,2,1) RGB	0,2551	(8,2,1) L	0,0131
(16,2,1) L	0,0452	(16,3,2) L	0,1176
(16,3,2) RGB	0,5059	(16,2,1) RGB	0,3500
(16,3,2) L	0,0639	(24, 3,2) RGB	0,1485
(24,3,2) RGB	0,4234	(16,2,1) L	0,1139
(24,3,2) L	0,1068	(24,3,2) L	0,1799

Tabela 7: Acurácias médias (%) obtidas pelas diferentes configurações do descritor ECLMP nos nove experimentos da base de dados RawFoot.

Exp.	1	2	3	4	5	6	7	8	9	-
ECLMP	Sem Var.	Intens.	Dir.	Temp. Neutra	Temp. LED	Neutra x LED	Temp. OU Dir.	Temp. E Dir.	Múltip. Fontes	Acurác. Geral
(8,2,1) RGB	98,51	86,00	67,52	97,47	92,30	93,30	40,65	28,74	94,33	77,65
(8,2,1) L										
(16,2,1) RGB	98,14	89,41	65,84	96,04	93,93	94,06	44,82	32,89	93,72	78,76
(16,2,1) L										
(16,3,2) RGB	97,36	88,13	64,79	95,10	94,45	94,16	47,65	34,60	93,18	78,82
(16,3,2) L										
(24,3,2) RGB	97,64	90,06	64,99	96,55	96,00	95,71	46,06	33,69	93,51	79,36
(24,3,2) L										
(8,2,1) RGB										
(16,3,2) RGB	98,72	90,35	69,71	97,51	95,53	95,00	47,26	33,56	95,83	80,39
(8,2,1) L										
(16,3,2) L										
(16,2,1) RGB										
(24,3,2) RGB	98,70	92,17	68,33	97,60	96,60	96,50	47,87	34,91	95,53	80,91
(16,2,1) L										
(24,3,2) L										

um melhor desempenho.

Considerando-se todos os experimentos, o descritor $(16, 2, 1)RGB + (24, 3, 2)RGB + (16, 2, 1)L + (24, 3, 2)L$ obteve a maior acurácia geral, classificando 80,91% das amostras corretamente.

Observando-se as quatro primeiras linhas da Tabela 7 é possível notar que o descritor ECLMP é mais robusto que o CILMP em relação à quantidade de pontos amostrados P e raio r . A maior variação ocorre no experimento 7, em que a configuração $(24, 3, 2)RGB + (24, 3, 2)L$ obteve uma acurácia média 4 pp. maior que a configuração $(8, 2, 1)RGB + (8, 2, 1)L$. Por outro lado, conforme apresentado na Seção 5.2.2, o descritor CILMP apresenta uma variação de acurácia média de até 34,50 pp., a qual ocorre no experimento 2.

Assim como o descritor CILMP, o descritor ECLMP apresenta maiores limitações

na descrição de texturas em que o ângulo de incidência da fonte de luz varia, que é o caso dos experimentos 3, 7 e 8.

5.2.4 OCLMP x OCLBP

O descritor OCLMP, proposto nesta tese, combina a abordagem LMP com a teoria de cores oponentes, assim como o descritor OCLBP proposto por Maenpaa e Pietikainen (2004). Com o intuito de comparar os dois descritores, a Figura 32 apresenta as acurácias gerais obtidas pelas diferentes configurações dos dois descritores, considerando-se os nove experimentos da base de dados RawFooT. Optou-se por considerar os descritores OCLBP compostos pelos padrões LBP de uniformidade menor ou igual a dois (LBP^{u2}), assim como proposto por Maenpaa e Pietikainen (2004).

Figura 32: Comparação das acurácias gerais obtidas pelos descritores OCLMP e OCLBP na base de dados RawFooT.

Observa-se na Figura 32 que ambos os descritores obtiveram seus melhores resultados na configuração $(P, r) = (24, 5)$. O descritor proposto alcançou 61,65% de acurácia geral, enquanto o OCLBP obteve 61,15%. De modo geral, os descritores apresentaram desempenhos muito próximos ao se comparar as configurações utilizadas. Uma exceção ocorre com a configuração $(P, r) = (16, 2)$ em que o descritor OCLBP obteve uma acurácia geral aproximadamente 4 pp. acima da obtida pelo OCLMP.

5.2.5 Comparação com outros descritores da literatura

Para avaliar os resultados obtidos pelos descritores propostos em relação a descritores similares publicados recentemente, foram selecionadas as melhores configurações de cada um deles, conforme apresentado nas Seções 5.2.1, 5.2.2 e 5.2.3: OCLMP(24, 5), CILMP $(8, 2)RGB + (16, 3)RGB + (8, 1)L + (16, 3)L + (24, 5)L$ e ECLMP $(16, 2, 1)RGB + (24, 3, 2)RGB + (16, 2, 1)L + (24, 3, 2)L$. Os descritores propostos foram comparados a outros cinco descritores locais de textura, apresentados no Capítulo 2 e listados a seguir:

- *Local Color Contrast* (LCC), aplicado ao espaço de cores RGB (CUSANO; NAPOLETANO; SCHETTINI, 2014);
- *Local Binary Pattern* (LBP) (OJALA; PIETIKAINEN; MAENPAA, 2002), (MAENPAA; PIETIKAINEN, 2004), utilizando a configuração de vizinhança $(P, r) = (16, 2)$, aplicado nos espaços de cores RGB, $L^*a^*b^*$, $I_1I_2I_3$ e canal de luminância L (imagem em nível de cinza), conforme apresentado por Cusano et. al (2016);
- *Opponent Color Local Binary Pattern* (OCLBP) (MAENPAA; PIETIKAINEN, 2004), utilizando a configuração de vizinhança $(P, r) = (24, 5)$, conforme resultados apresentados na Seção 5.2.4;
- Filtros de Gabor aplicados ao espaço de cores RGB e ao canal de luminância L, conforme descrito em (CUSANO; NAPOLETANO; SCHETTINI, 2016);
- *Opponent Gabor features* aplicado ao espaço de cores RGB, conforme descrito em (CUSANO; NAPOLETANO; SCHETTINI, 2016).

A Tabela 8 apresenta as acurácias gerais obtidas pelos descritores em comparação, considerando-se os nove experimentos da base de dados RawFooT. Os valores reportados para os descritores LCC, LBP, Filtros de Gabor e *Opponent Gabor features* foram retirados da referência (CUSANO; NAPOLETANO; SCHETTINI, 2016).

Tabela 8: Acurácias gerais (%) obtidas pelos descritores em comparação, considerando-se os nove experimentos da base de dados RawFooT, em ordem decrescente.

Descritor	Acurácia Geral
ECLMP	80,91
CILMP	77,79
LCC	65,60
OCLMP	61,65
OCLBP	61,15
LBP Lab	58,61
LBP L	58,61
LBP $I_1I_2I_3$	57,44
LBP RGB	57,05
Gabor RGB	53,49
Gabor L	52,25
Opp Gabor RGB	46,76

Nota-se na Tabela 8 que os descritores que obtiveram as três melhores acurácias gerais (ECLMP, CILMP e LCC) combinam informação de textura da imagem de luminância e textura da cor no espaço de cores RGB. O descritor proposto ECLMP alcançou uma acurácia geral de 80,91%, superando os resultados reportados pelos descritores CILMP e

LCC em 3,12 pp. e 15,31 pp., respectivamente. O descritor proposto OCLMP aparece em quarto lugar, seguido pelo OCLBP.

As Figuras 33 a 41 mostram uma comparação dos cinco melhores descritores, de acordo com os resultados apresentados na Tabela 8, considerando cada um dos nove experimentos que compõem a base de dados RawFooT. Como cada experimento é composto por vários subconjuntos e a acurácia reportada é a média das acurácias obtidas entre os subconjuntos, os gráficos de comparação apresentam além da acurácia média, a acurácia mínima obtida pelos descritores em cada experimento, o que permite avaliar a regularidade do método.

No experimento 1 (Fig. 33), em que não há variação na condição de iluminação, os descritores propostos apresentam as maiores acurácias médias. O melhor resultado é obtido pelo descritor ECLMP (98,70%), seguido pelo OCLMP (98,05%) e CILMP (97,98%). O descritor LCC é o que apresenta menor variabilidade entre a acurácia mínima e a acurácia média. No entanto, esse foi o descritor que obteve o pior desempenho neste experimento dentre os cinco em comparação: a acurácia média obtida pelo LCC é menor, por exemplo, que a acurácia mínima obtida pelo CILMP.

Observando-se a Figura 34, quando a intensidade da fonte de luz varia entre as amostras de treinamento e de teste (experimento 2), o descritor ECLMP obteve a maior acurácia média (92,17%), seguido pelo OCLBP (89,08%) e OCLMP (88,31%). O descritor ECLMP também é o que apresenta a maior regularidade: a variação entre a acurácia mínima e a acurácia média é de 8,35 pp., enquanto a segunda menor variação (16,29) pp. é obtida pelo OCLBP.

No experimento 3 (Fig. 35), o qual envolve variação na direção da iluminação, todos os descritores apresentam queda no desempenho. A maior acurácia média é obtida pelo descritor OCLBP (69,28%), seguido pelos descritores ECLMP (68,33%) e OCLMP

Figura 33: Avaliação dos descritores no experimento 1 da base de dados RawFooT.

Figura 34: Avaliação dos descritores no experimento 2 da base de dados RawFooT.

Figura 35: Avaliação dos descritores no experimento 3 da base de dados RawFooT.

(67,64%). Observa-se ainda que a acurácia mínima atingida por todos os descritores é muito baixa, não ultrapassando 19,00%, o que reforça a grande dificuldade dos métodos em descreverem texturas de forma robusta à variação na direção da fonte de luz.

Os experimentos 4, 5 e 6 envolvem variações na temperatura da fonte de luz. Nos experimentos 4 e 5 (Fig. 36 e 37) as amostras sofrem variações nas temperaturas da luz neutra e luz de LED, respectivamente. No experimento 6 (Fig. 38), a aquisição das amostras de treinamento e teste variam entre luz neutra e luz de LED, em diferentes temperaturas. Nos três experimentos, o descritor ECLMP obteve a maior acurácia média, seguido pelo CILMP e LCC. No entanto, os descritores ECLMP e CILMP apresentam uma maior regularidade que o LCC, obtendo menor variabilidade entre as acurácias média e mínima. Analisando-se as Figuras 36, 37 e 38 é possível notar, ainda, que os descritores baseados na teoria de cores oponentes (OCLMP e OCLBP) sofrem uma grande queda no desempenho quando há mudanças na temperatura da fonte de luz.

Figura 36: Avaliação dos descritores no experimento 4 da base de dados RawFooT.

Figura 37: Avaliação dos descritores no experimento 5 da base de dados RawFooT.

Figura 38: Avaliação dos descritores no experimento 6 da base de dados RawFooT.

Figura 39: Avaliação dos descritores no experimento 7 da base de dados RawFoot.

Figura 40: Avaliação dos descritores no experimento 8 da base de dados RawFoot.

Os experimentos 7 e 8 envolvem variações na temperatura ou/e direção da fonte de luz. É possível notar, nas Figuras 39 e 40, que nenhum descritor obteve bom desempenho nestes dois experimentos, apresentando acurácias médias menores que 50%. O descritor ECLMP apresentou a maior acurácia média para os dois experimentos, seguido pelo CILMP e LCC. Assim como nos experimentos que envolviam apenas mudanças na temperatura da luz (experimentos 4, 5 e 6), os descritores OCLMP e OCLBP obtiveram as piores taxas de classificação dentre os cinco descritores comparados.

Por fim, no experimento 9 (Fig. 41), o qual envolve imagens adquiridas sob múltiplas fontes de luz, os descritores CILMP e ECLMP apresentaram as maiores acurácias médias: 95,96% e 95,53%, respectivamente. Em seguida, o descritor LCC atingiu 85,91% de acertos na classificação das amostras. Estes três descritores também apresentaram pequenas variações entre acurácia média e acurácia mínima, indicando regularidade na classificação de amostras sob esta condição de iluminação.

Figura 41: Avaliação dos descritores no experimento 9 da base de dados RawFooT.

De modo geral, observou-se que o descritor ECLMP foi o que apresentou melhor desempenho na classificação das imagens da base de dados RawFooT, obtendo maior acurácia em sete dos nove experimentos propostos. Nota-se, ainda, que ele foi o descritor que apresentou menor variabilidade entre acurácia mínima e média nos experimentos de classificação.

5.3 Resultados Experimentais para a base de dados KTH-TIPS-2b

Para avaliar o desempenho dos descritores propostos na base de dados KTH-TIPS-2b, foram realizados três experimentos descritos na Seção 4.2.2. As amostras utilizadas nos experimentos realizados para essa base de dados foram adquiridas sob três diferentes direções da fonte de luz, em diferentes escalas. Dessa maneira, os resultados reportados expressam a robustez do descritor a mudanças na direção da iluminação e escala combinadas. As Seções 5.3.1, 5.3.2 e 5.3.3 exibem os resultados obtidos pelos descritores OCLMP, CILMP e ECLMP, respectivamente, na realização destes experimentos. Na Seção 5.3.4 os descritores OCLMP e OCLBP são comparados. Por fim, a Seção 5.3.5, compara os resultados obtidos pelos descritores propostos com resultados de descritores similares publicados recentemente na literatura da área.

5.3.1 OCLMP

Nesta seção é apresentado o desempenho do descritor OCLMP na execução dos três experimentos com as imagens da base de dados KTH-TIPS-2b. A Tabela 9 apresenta os parâmetros ajustados para as diferentes configurações do descritor, utilizando-se o conjunto de sintonização para esta base. A Tabela 10 exhibe os resultados obtidos pelo descritor OCLMP nos experimentos propostos.

A partir dos resultados apresentados na Tabela 10, observa-se que a configuração

Tabela 9: Parâmetros ajustados para as diferentes configurações (P,r) do descritor OCLMP para a base de dados KTH-TIPS-2b.

OCLMP	Parâmetros (β)	OCLMP	Parâmetros (β)
(8,1) R - G	0,1496	(16,3) R - G	0,0068
(8,1) R - B	0,1093	(16,3) R - B	4,9262
(8,1) G - B	0,0095	(16,3) G - B	2,6563
(8,1) R	0,8406	(16,3) R	2,4125
(8,1) G	0,9699	(16,3) G	2,8889
(8,1) B	0,0350	(16,3) B	4,6292
(8,2) R - G	0,2151	(24,3) R - G	0,3646
(8,2) R - B	3,2980	(24,3) R - B	4,7601
(8,2) G - B	3,1966	(24,3) G - B	2,6803
(8,2) R	4,4924	(24,3) R	3,3467
(8,2) G	4,9142	(24,3) G	4,7969
(8,2) B	0,2133	(24,3) B	3,4669
(16,2) R - G	0,1592	(24,5) R - G	0,1419
(16,2) R - B	2,9745	(24,5) R - B	0,8443
(16,2) G - B	4,3769	(24,5) G - B	0,8200
(16,2) R	4,4538	(24,5) R	0,5277
(16,2) G	2,7589	(24,5) G	0,2348
(16,2) B	3,6159	(24,5) B	0,1841

Tabela 10: Acurácias (%) obtidas pelas diferentes configurações do descritor OCLMP nos três experimentos com a base de dados KTH-TIPS-2b.

Experimentos	10		11		12		Ac. Geral
Conj. Teste	Frontal	45 Top	Frontal	45 Side	45 Top	45 Side	
Conj. Treinamento	45 Top	Frontal	45 Side	Frontal	45 Side	45 Top	
OCLMP (8,1)	79,55	87,50	78,41	85,23	87,50	84,09	83,71
OCLMP (8,2)	77,27	86,36	76,14	80,68	82,95	82,95	81,06
OCLMP (16,2)	76,14	84,09	76,14	78,41	81,82	79,55	79,36
OCLMP (16,3)	79,55	88,64	80,68	82,95	87,50	81,82	83,52
OCLMP (24,3)	78,41	86,36	80,68	84,09	85,23	80,68	82,58
OCLMP (24,5)	84,09	90,91	84,09	86,36	92,05	87,50	87,50

que obteve melhor desempenho para todos os experimentos foi a OCLMP(24, 5) com acurácia geral de 87, 50%, seguida pelo OCLMP(8, 1) que obteve 83, 71% de classificações corretas.

Assim como nos experimentos realizados na base de dados RawFooT, o descritor OCLMP(16, 2) foi o que apresentou o menor desempenho. Para a base de dados KTH-TIPS-2b, esta configuração obteve a menor acurácia para todos os experimentos, resultando em uma acurácia geral de 79, 36%.

5.3.2 CILMP

Esta seção destina-se a apresentar os resultados obtidos pelo descritor CILMP nos experimentos com a base de dados KTH-TIPS-2b, considerando-se diferentes combinações

(P, r) na composição do descritor proposto. A Tabela 11 apresenta os parâmetros ajustados para diferentes configurações do descritor CILMP no conjunto de sintonização desta base de dados. Os resultados obtidos pelo descritor nos três experimentos de classificação são reportados na Tabela 12.

Tabela 11: Parâmetros ajustados para as diferentes configurações (P, r) do descritor CILMP para a base de dados KTH-TIPS-2b.

CILMP	Parâmetros (β)	CILMP	Parâmetros (β)
(8,1) RGB	0,1849	(8,2) RGB	0,9502
(8,1) L	0,5020	(16,3) RGB	0,7537
(8,2) RGB	0,3211	(8,1) L	0,8693
(8,2) L	0,0045	(16,3) L	0,1835
(16,3) RGB	0,9016	(24,5) L	0,2217
(16,3) L	0,4250	(8,2) RGB	0,5372
(8,2) RGB	0,5318	(16,3) RGB	0,6622
(16,3) RGB	0,3562	(24,5) RGB	0,6888
(8,1) L	0,6675	(8,1) L	0,3376
(16,3) L	0,3017	(16,3) L	0,0012
		(24,5) L	0,4928

Tabela 12: Acurácias (%) obtidas pelas diferentes configurações do descritor CILMP nos três experimentos com a base de dados KTH-TIPS-2b.

Experimentos	10		11		12		Ac. Geral
Conj. Teste	Frontal	45 Top	Frontal	45 Side	45 Top	45 Side	
Conj. Treinamento	45 Top	Frontal	45 Side	Frontal	45 Side	45 Top	
(8,1) RGB							
(8,1) L	76,14	75,00	69,32	71,59	71,59	71,59	72,54
(8,2) RGB							
(8,2) L	69,32	68,18	62,50	68,18	65,91	64,77	66,48
(16,3) RGB							
(16,3) L	75,00	73,86	69,32	69,32	68,18	69,32	70,83
(8,2) RGB							
(16,3) RGB	73,86	77,27	64,77	72,73	72,73	76,14	72,92
(8,1) L							
(16,3)							
(8,2) RGB							
(16,3) RGB							
(8,1) L	75,00	79,55	68,18	70,45	72,73	71,59	72,92
(16,3) L							
(24,5) L							
(8,2) RGB							
(16,3) RGB							
(24,5) RGB	78,41	81,82	75,00	72,73	79,55	72,73	76,70
(8,1) L							
(16,3) L							
(24,5) L							

Analisando-se a Tabela 12 é possível notar que de modo geral, o descritor composto por seis configurações apresentou melhor desempenho na classificação, obtendo uma acurácia geral de 76,70%. Em segundo lugar, empatam os descritores formados por quatro e cinco configurações de (P, r_{out}, r_{in}) , os quais obtiveram uma acurácia geral de 72,92%.

Os resultados obtidos reforçam a ideia de que a análise multiresolução realizada pelos descritores aumentam o seu poder de descrição de texturas coloridas, tornando-os mais robustos a mudanças nas condições de iluminação.

5.3.3 ECLMP

Nesta seção são apresentados os resultados obtidos pelas diferentes configurações do descritor ECLMP com a base de dados KTH-TIPS-2b. A Tabela 13 exibe os parâmetros ajustados para o descritor no conjunto de sintonização desta base de dados. Os resultados obtidos pelas diferentes configurações do descritor são apresentados na Tabela 14.

Tabela 13: Parâmetros ajustados para as diferentes configurações do descritor ECLMP para a base de dados KTH-TIPS-2b.

ECLMP	Parâmetros (β)	ECLMP	Parâmetros (β)
(8,2,1) RGB	0,9597	(8,2,1) RGB	66,7373
(8,2,1) L	0,0196	(16,3,2) RGB	32,5745
(16,2,1) RGB	86,4417	(8,2,1) L	5,1321
(16,2,1) L	75,3863	(16,3,2) L	2,6885
(16,3,2) RGB	0,4898	(16,2,1) RGB	1,1992
(16,3,2) L	0,0445	(24, 3,2) RGB	0,5000
(24,3,2) RGB	29,6881	(16,2,1) L	0,4080
(24,3,2) L	33,9511	(24,3,2) L	0,8131

Na Tabela 14 nota-se que para o experimento 10, quando a direção da iluminação varia entre frontal e 45° a partir do topo, a configuração $(16, 3, 2)RGB + (16, 3, 2)L$ foi a que apresentou maiores acurácias. No entanto, não houve uma configuração única que se mostrou ótima para os experimentos 11 e 12.

As configurações $(16, 3, 2)RGB + (16, 3, 2)L$ e aquelas que combinam quatro resoluções de vizinhança apresentaram a mesma acurácia geral, quando se considera os três experimentos: 73,86%. A maior acurácia geral foi de 74,24%, obtida pela configuração $(8, 2, 1)RGB + (8, 2, 1)L$.

Esta “não uniformidade” pode ser explicada pelo fato de que nesta base de dados a escala de aquisição das texturas também é um fator variante. Desde que a quantidade de pontos amostrados P e raio r determinam a resolução espacial em que as características são extraídas da textura, a “configuração ótima” do descritor é influenciada pela escala das amostras.

Tabela 14: Acurácias (%) obtidas pelas diferentes configurações do descritor ECLMP nos três experimentos com a base de dados KTH-TIPS-2b.

Experimentos	10		11		12		Ac. Geral
Conj. Teste	Frontal	45 Top	Frontal	45 Side	45 Top	45 Side	
Conj. Treinamento	45 Top	Frontal	45 Side	Frontal	45 Side	45 Top	
(8,2,1) RGB	78,41	73,86	73,86	73,86	72,73	72,73	74,24
(8,2,1) L							
(16,2,1) RGB	68,18	67,05	73,86	67,05	70,45	71,59	69,70
(16,2,1) L							
(16,3,2) RGB	81,82	79,55	76,14	65,91	70,45	69,32	73,86
(16,3,2) L							
(24,3,2) RGB	73,86	77,27	68,18	63,64	70,45	70,45	70,64
(24,3,2) L							
(8,2,1) RGB	77,27	76,14	71,59	70,45	75,00	72,73	73,86
(16,3,2) RGB							
(8,2,1) L							
(16,3,2) L							
(16,2,1) RGB	79,55	75,00	73,86	68,18	76,14	70,45	73,86
(24,3,2) RGB							
(16,2,1) L							
(24,3,2) L							

5.3.4 OCLMP x OCLBP

Nesta seção são comparados os descritores OCLMP e OCLBP (MAENPAA; PIETIKAINEN, 2004) na base de dados KTH-TIPS-2b. A Figura 42 mostra uma comparação das acurácias gerais obtidas pelos dois descritores, considerando-se os três experimentos da base de dados KTH-TIPS-2b.

Figura 42: Comparação das acurácias gerais obtidas pelos descritores OCLMP e OCLBP com a base de dados KTH-TIPS-2b.

Observa-se, na Figura 42, que o descritor proposto OCLMP supera o OCLBP em quatro das seis configurações. A configuração $(P, r) = (24, 5)$ é a que apresenta melhor desempenho para ambos os métodos.

É interessante notar que a configuração $(P, r) = (8, 1)$ apresenta o segundo melhor resultado para o OCLMP, e o pior resultado para o OCLBP. Analisando-se os resultados apresentados nas Seções 5.3.2 e 5.3.3, observa-se que as configurações que utilizam apenas oito pontos amostrados ($P = 8$) para a extração das características das texturas desta base de dados também apresentaram bons resultados para os descritores CILMP e ECLMP.

5.3.5 Comparação com outros descritores da literatura

Esta seção compara o desempenho dos descritores propostos com outros descritores similares e publicados na literatura da área, nos experimentos de classificação utilizando-se a base de dados KTH-TIPS-2b. Para realizar essa avaliação, foram selecionadas as configurações que obtiveram maiores acurácias gerais para cada descritor, conforme apresentado nas Seções 5.3.1, 5.3.2 e 5.3.3. Para comparação, foram escolhidos os descritores LCC e OCLBP, com base no desempenho que eles apresentaram nos experimentos da base RawFooT (Seção 5.2.5). Os resultados são exibidos na Tabela 15, e aparecem por ordem de melhor acurácia geral.

Tabela 15: Acurácias gerais (%) obtidos pelos descritores em comparação, considerando-se os três experimentos com a base de dados KTH-TIPS-2b.

Descritor	Configuração	Ac. Geral
OCLMP	(24,5)	87,50
OCLBP	(24,5)	83,33
CILMP	(8,2) RGB	76,70
	(16,3) RGB	
	(24,5) RGB	
	(8,1) L	
	(16,3) L	
	(24,5) L	
ECLMP	(8,2,1) RGB	74,24
	(8,2,1) L	
LCC	(16,2)	65,53

A análise da Tabela 15 mostra que os descritores baseados na teoria de cores oponentes, apresentaram melhor desempenho nos experimentos com a base de dados KTH-TIPS-2b. O descritor proposto OCLMP obteve a maior acurácia geral (87,50%), seguido pelo OCLBP (83,33%). O pior resultado foi reportado pelo descritor LCC, com acurácia geral de 65,53%.

Analisando-se os resultados obtidos por estes descritores no experimento 3 da base de dados RawFooT (Figura 35, página 73), o qual também envolve variação na direção da fonte de luz, observa-se o bom desempenho que os descritores OCLMP e OCLBP apresentam para essa condição de iluminação.

5.4 Análise do tempo de processamento

Essa seção apresenta uma análise do tempo requerido para cada descritor na geração do vetor de características de uma amostra de textura colorida. Estes experimentos foram conduzidos em um computador com processador Intel® Core™ i7-6560U CPU 2,2GHz e 8GB de RAM, rodando Windows 8 Enterprise, sem privilégio de processos. Os softwares utilizados para esta análise foram prototipados utilizando o MATLAB R2016a. Os códigos referentes aos descritores OCLBP e LCC foram cedidos por seus autores.

As Figuras 43, 44 e 45 apresentam o comportamento do tempo médio de processamento exigido pelos descritores propostos para gerar o vetor de características de uma amostra, conforme seu tamanho aumenta em potências de dois. A Figura 46 exibe o tempo de processamento das diferentes configurações do descritor OCLBP. Por fim, a Figura 47 apresenta o tempo de processamento do descritor LCC. As legendas dos gráficos exibem a configuração do descritor, e a quantidade de *bins* do vetor de características de cada uma delas.

Analisando-se as Figuras 43 a 47 é possível notar que o tempo de processamento para uma textura aumenta quadraticamente em relação à quantidade de pixels da amostra, para todos os descritores avaliados.

Para o descritor OCLMP (Fig. 43), em que os vetores de características de todas as configurações possuem a mesma quantidade de elementos, o tempo de processamento depende da quantidade de pixels P amostrados na vizinhança circular e do tamanho da amostra descrita.

No descritor CILMP, a quantidade de *bins* do vetor de características gerado depende da configuração do descritor. Neste sentido, observa-se na Figura 44, que o tempo de processamento do descritor depende não só do tamanho da amostra e do número de pontos P amostrados na vizinhança circular, mas também da configuração do descritor. O mesmo comportamento é observado para o descritor ECLMP (Fig. 45).

Observa-se ainda, que os descritores OCLMP e CILMP apresentam tempo de processamento similar ao se considerar o tamanho da amostra e quantidade de pixels amostrados, não ultrapassando 5 segundos para a descrição de uma textura de 1024×1024 pixels em sua configuração de maior custo computacional. Por sua vez, o descritor ECLMP possui um tempo de processamento mais elevado se comparado aos outros dois descritores propostos, exigindo até 18 segundos para processar a mesma textura em sua configuração mais custosa. Isso se deve ao fato de que no OCLMP e CILMP as características são combinadas apenas de forma concatenada, enquanto o ECLMP é necessário construir um histograma conjunto em sua formulação, além de realizar a concatenação de diferentes configurações.

Uma comparação do custo computacional entre os descritores OCLMP e OCLBP

pode ser realizada observando-se as Figuras 43 e 46. Na Figura 46, o gráfico que apresenta o tempo de processamento do OCLBP é dividido em dois subgráficos para permitir uma melhor visualização de seu comportamento. É possível notar que, ao se comparar as mesmas configurações de (P, r) e tamanho da amostra, o tempo de processamento exigido pelo descritor proposto OCLMP para a descrição de uma amostra é sempre menor do que aquele exigido pelo OCLBP. Para a configuração $(24, 5)$, por exemplo, a qual obteve a maior acurácia geral nas duas bases de dados para os dois descritores, o OCLMP necessita em média de 0,19 segundos para gerar o vetor de características de uma amostra de 256×256 pixels, enquanto para o OCLBP esse tempo é de 65,41 segundos. Isso acontece porque o número de *bins* do vetor de características gerado pelo descritor OCLBP depende da quantidade de pontos P amostrados. O mesmo não ocorre no OCLMP, visto que os códigos gerados pela função de mapeamento podem ser quantizados na quantidade de *bins* mais adequada para a aplicação.

A formulação do descritor LCC, conforme apresentada em Cusano et al. (2014), utiliza a configuração $(P, r) = (16, 2)$ para a extração de características de uma amostra. Levando isso em consideração, observa-se a partir das Figuras 43 e 47, que o tempo de processamento do descritor LCC é similar ao tempo de processamento do descritor OCLMP nesta mesma configuração.

Figura 43: Tempo de processamento para a geração do vetor de características de uma amostra, considerando-se as diferentes resoluções do descritor OCLMP.

Figura 44: Tempo de processamento para a geração do vetor de características de uma amostra, considerando-se as diferentes resoluções do descritor CILMP.

5.5 Considerações Finais

Neste capítulo foram apresentados os resultados experimentais obtidos pelos descritores propostos na classificação de texturas coloridas com variação de iluminação, considerando-se suas diferentes configurações. Os descritores foram avaliados em duas bases de dados, RawFooT e KTH-TIPS-2b, e seus desempenhos foram comparados aos desempenhos de outros descritores comumente utilizados para a descrição de texturas coloridas.

Nas duas bases de dados utilizadas para avaliação, o descritor OCLMP obteve seu melhor desempenho com a configuração $(P, r) = (24, 5)$, alcançando 61,65% de acurácia geral na base de dados RawFooT e 87,50% de acurácia geral na base KTH-TIPS-2b.

O descritor CILMP apresentou desempenho semelhante para as duas bases de dados. Para a base de dados RawFooT, o descritor CILMP composto por cinco configurações de vizinhança (CILMP $(8, 2)RGB + (16, 3)RGB + (8, 1)L + (16, 3)L + (24, 5)L$) foi o que obteve a melhor acurácia geral (77,79%). Para a base de dados KTH-TIPS-2b, a maior acurácia geral obtida pelo CILMP foi 76,50%, alcançada com o descritor composto por

Figura 45: Tempo de processamento para a geração do vetor de características de uma amostra, considerando-se as diferentes resoluções do descritor ECLMP.

seis configurações de vizinhança. De modo geral, observa-se que a análise multiresolução realizada pelo CILMP aumenta o seu poder discriminativo e a sua robustez a variações na fonte de iluminação.

O descritor ECLMP não apresentou uma configuração ótima para todos os experimentos. Para a base de dados RawFooT, o descritor obteve a maior acurácia geral (80, 91%) com a configuração $(16, 2, 1)RGB + (24, 3, 2)RGB + (16, 2, 1)L + (24, 3, 2)L$. Na base de dados KTH-TIPS-2b, o descritor obteve seu melhor desempenho com a configuração $(8, 2, 1)RGB + (8, 2, 1)L$, alcançando 74, 24% de acurácia geral.

Quando comparados aos descritores da literatura comumente utilizados na classificação de texturas coloridas, os descritores propostos nesta tese superaram as demais abordagens nas duas bases de dados. Para a base RawFooT, a maior acurácia geral foi obtida pelo ECLMP, superando os métodos previamente publicados em mais de 15 pp.. Na base de dados KTH-TIPS-2b, o descritor OCLMP apresentou a maior acurácia geral, superando o segundo melhor descritor para esta base, o OCLBP, em mais de 4 pp..

A análise do tempo de processamento mostrou que o tempo requerido pelos descri-

Figura 46: Tempo de processamento para a geração do vetor de características de uma amostra, considerando-se as diferentes resoluções do descritor OCLBP.

Figura 47: Tempo de processamento para a geração do vetor de características de uma amostra pelo descritor LCC.

tores para a construção do vetor de características de uma imagem depende diretamente da quantidade de pontos amostrados, definido pela configuração do descritor, e do tamanho da imagem descrita. Os descritores OCLMP e CILMP exigem um tempo de processamento similar, não ultrapassando 0,2 segundos para processar uma amostra de 256×256 pixels. Este tempo sobe para 0,9 segundos, quando o descritor ECLMP é utilizado. Observou-se ainda, que a abordagem LCC apresenta tempo de processamento similar ao do OCLMP, enquanto o OCLBP pode demorar até 65 segundos para processar uma amostra de

256×256 pixels. De modo geral, os testes indicaram que o tempo de processamento varia quadraticamente com o tamanho da amostra a ser descrita, para todos os descritores analisados.

6 CONCLUSÃO

Esta tese de doutoramento propõe três novos descritores de textura para serem empregados na classificação de texturas coloridas sob variação de iluminação. São eles: *Opponent Color Local Mapped Pattern* (OCLMP), *Color Intensity Local Mapped Pattern* (CILMP) e *Extended Color Local Mapped Pattern* (ECLMP).

O descritor OCLMP aplica a teoria de cores oponentes, utilizada pelo OCLBP, na abordagem LMP. Como o descritor OCLBP apresenta bons resultados na classificação de texturas coloridas adquiridas sob diferentes ângulos da fonte de luz, e a abordagem LMP tem mostrado resultados superiores ao LBP na análise de texturas em níveis de cinza, a combinação destes métodos merece atenção para a análise de texturas coloridas sujeitas a variação de iluminação.

Os descritores CILMP e ECLMP combinam informações de textura, provenientes da luminância da imagem, e informações de textura da cor, que refletem o comportamento estrutural dos pixels coloridos. A combinação de informações de cor e de textura para a descrição de texturas coloridas apresentou bons resultados para a classificação de texturas coloridas com o descritor LCC, e dessa maneira, inspirou a sua investigação ao ser combinada com a teoria LMP.

A validação dos métodos foi realizada em duas bases de dados que possuem imagens adquiridas sob diferentes condições de iluminação. O desempenho dos descritores foi avaliado pela medida da acurácia de um classificador K-NN ($K=1$). O tempo de processamento para geração dos vetores de características de cada descritor foi analisado. Os resultados obtidos foram comparados com os métodos comumente utilizados na classificação de texturas coloridas.

O primeiro conjunto de experimentos foi conduzido na base de dados RawFooT. Os nove experimentos realizados nesta base englobam texturas adquiridas sem variação da iluminação e com variação na intensidade da luz, na direção da luz, na temperatura da luz neutra e na temperatura da luz de LED, além de combinações entre variações da luz neutra e LED, temperatura ou direção, temperatura e direção, e imagens adquiridas com múltiplas fontes de luz. Pode-se concluir que o descritor mais apropriado para este banco de dados foi o ECLMP, por possuir maior acurácia geral considerando-se os nove experimentos propostos. O descritor ECLMP obteve 80,91% de acurácia geral, sendo superior em aproximadamente 15 pp. ao LCC, que é o melhor descritor apontado pela literatura da área, que apresentou 65,60% de acurácia geral. O descritor ECLMP também apresenta maior regularidade na descrição das amostras que possuem variações na intensidade da luz, na temperatura da luz neutra e da luz de LED e quando a imagem é adquirida sob

múltiplas fontes de luz, o que pode ser observado pela menor diferença entre as acurácias média e mínima obtidas na classificação.

O segundo conjunto de experimentos utilizou a base de dados KTH-TIPS-2b, que possui amostras adquiridas sob variação do ângulo de incidência da fonte de luz, e em diferentes escalas. Neste caso, o descritor OCLMP apresentou melhor desempenho para este tipo de variação. O descritor OCLMP(24,5) obteve o melhor desempenho para todos os experimentos desta base de dados, alcançando acurácia geral de 87,50%. Vale destacar que, no experimento 3 da base de dados RawFooT, em que a direção da fonte de iluminação varia, o melhor desempenho foi obtido pelo descritor OCLBP mas, com ganho na acurácia de apenas 1,64 pp. sobre o OCLMP, e de 0,95 pp. sobre o ECLMP. O conjunto de resultados indica que a utilização de cores oponentes na construção do descritor faz com que sua robustez a variações no ângulo de incidência da fonte de iluminação seja melhorada.

O descritor proposto CILMP apresentou desempenho geral similar nas duas bases de dados. A acurácia geral foi de 77,79% para a base RawFooT e de 76,50% para a base KTH-TIPS-2b. Para a primeira base o descritor CILMP ficou em segundo lugar, perdendo apenas para o descritor ECLMP (80,91%), e para a segunda base obteve o terceiro lugar, sendo pior que o OCLMP(87,50%) e o OCLBP(83,33%). Como neste descritor, as informações de cor e de textura são extraídas de forma integrada, levando-se em consideração a “textura da cor”, combinada com características extraídas da luminância da textura em uma análise multiresolução, seus resultados foram bons com imagens adquiridas com variações na direção da luz e foram excelentes (95,96% de acurácia média) com imagens adquiridas com diversas fontes de iluminação. Ou seja, como o problema de análise de texturas coloridas com variações de iluminação é bastante complexo, conclui-se que os descritores propostos representam uma nova área de investigação para que se possa obter novos avanços que justifiquem apenas um descritor que seja eficiente para todo o tipo de variações encontradas em imagens de texturas gerais.

Como resultado dos experimentos conclui-se que: para variações do tipo “direção da luz” sugere-se os decritores baseados na teoria de cores oponentes, como o OCLMP; para variações que envolvam “múltiplas fontes de luz” sugere-se o descritor CILMP; e para variações do tipo “intensidade da luz” ou aquelas que envolvam a temperatura da luz, como “temperatura da luz neutra”, “temperatura da luz LED”, “variações da luz neutra e LED”, “temperatura ou direção”, e “temperatura e direção”, sugere-se o descritor ECLMP. Estas conclusões são sintetizadas na Tabela 16.

A análise do custo de processamento mostrou que, como esperado, o tempo médio para a construção do vetor de características de uma imagem depende diretamente da quantidade de pontos amostrados, definido pela configuração do descritor, e do tamanho da imagem descrita. Os testes indicaram que o tempo de processamento varia quadraticamente

Tabela 16: Descritores indicados para cada tipo de variação na iluminação.

Tipo de Variação	Descritor indicado
Direção da Luz	Cores Oponentes (OCLMP ou OCLBP)
Múltiplas Fontes de Luz	CILMP
Intensidade da Luz	ECLMP
Temperatura da Luz	ECLMP
Temperatura ou Direção	ECLMP
Temperatura e Direção	ECLMP

com o tamanho da amostra descrita, para todos os descritores analisados. O tempo de processamento do descritor OCLMP depende da quantidade de pixels P amostrados em uma vizinhança da imagem; no entanto, para amostras de 256×256 pixels, por exemplo, este tempo não ultrapassa 0,2 segundos em sua configuração mais custosa (OCLMP(24,5)). Por outro lado, o tempo requerido para o descritor OCLBP processar uma amostra do mesmo tamanho pode chegar a 65,0 segundos na configuração OCLBP(24,5). Para o descritor CILMP, o tempo de processamento depende da quantidade de configurações combinadas em sua construção, porém na configuração de maior custo analisada, o tempo de processamento para uma imagem de 256×256 pixels é similar ao tempo do CILMP, não ultrapassando 0,2 segundos. O descritor ECLMP é o descritor mais custoso dentre os propostos nesta tese, necessitando de até 0,9 segundos para processar uma imagem de 256×256 pixels, mas ainda muito rápido comparado ao OCLBP.

Trabalhos Futuros

Para trabalhos futuros sugere-se:

- Investigar o uso de novas funções de mapeamentos nos descritores propostos;
- Otimizar o número de *bins* na construção dos vetores de características;
- Otimizar o número de pontos amostrados P e raio r na construção do descritor;
- Avaliar o desempenho dos métodos propostos em outros classificadores;
- Combinar diferentes configurações de pontos amostrados P e raio r na construção do vetor de características do descritor OCLMP;
- Incluir a teoria de cores oponentes no descritor ECLMP.

Trabalhos Publicados

1. NEGRI, T. T.; GONZAGA, A. Color Texture Classification under Varying Illumination. In: X Workshop de Visão Computacional, Uberlândia. 2014. p.61 - 66.

2. NEGRI, T. T.; GONZAGA, A. Color texture classification by a local multistiscale descriptor. In: XI Workshop de Visão Computacional, São Carlos. 2015. p.292 - 297.
3. VIEIRA, R. T.; NEGRI, T. T.; GONZAGA, A. Robustness of Rotation Invariant Descriptors for Texture Classification. In: Lecture Notes in Computer Science. 1 ed. Springer International Publishing, 2016, p. 268-277.
4. NEGRI, T. T.; ZHOU, F.; OBRADOVIC, Z.; GONZAGA, A. A Robust Descriptor for Color Texture Classification Under Varying Illumination In: 12th International Joint Conference on Computer Vision, Imaging and Computer Graphics Theory and Applications (VISIGRAPP 2017), Porto. SCITEPRESS, 2017. v.4. p.378 - 388.
5. VIEIRA R. T.; NEGRI, T. T.; CAVICHIOLLI, A.; GONZAGA, A. Human epithelial type 2 cell classification using a multiresolution texture descriptor. In: XIII Workshop de Visão Computacional, Natal. 2017.
6. NEGRI, T. T.; VIEIRA, R. T.; GONZAGA, A. Color texture classification by using opponent color and local mapped pattern. In: XIII Workshop de Visão Computacional, Natal. 2017.
7. VIEIRA R. T.; NEGRI, T. T.; GONZAGA, A. Improving the classification of rotated images by adding the signal and magnitude information to a local texture descriptor. Multimedia Tools and Applications. 2017. (submetido).
8. NEGRI, T. T.; ZHOU, F.; OBRADOVIC, Z.; GONZAGA, A. Extended color local mapped pattern for color texture classification under varying illumination. Journal of Electronic Imaging. v. 26, n. 1, 2018.

REFERÊNCIAS

- ARIVAZHAGAN, S.; GANESAN, L. Texture classification using wavelet transform. **Pattern Recognition Letters**, v. 24, p. 1513 – 1521, 2003.
- BACKES, A. R.; CASANOVA, D.; BRUNO, O. M. A complex network-based approach for boundary shape analysis. **Pattern Recognition**, v. 42, n. 1, p. 54 – 67, 2009.
- _____. Texture analysis and classification: A complex network-based approach. **Information Sciences**, v. 219, p. 168 – 180, 2013.
- BIANCONI, F. et al. Theoretical and experimental comparison of different approaches for color texture classification. **Journal of Electronic Imaging**, v. 20, n. 4, p. 043006–043006–17, 2011.
- BLAS, M. et al. Fast color/texture segmentation for outdoor robots. In: **2008 IEEE/RSJ International Conference on Intelligent Robots and Systems**. Nice, France: IEEE, 2008. p. 4078–4085.
- BOAVENTURA, I. A. G.; GONZAGA, A. Edge detection in digital images using fuzzy numbers. **Int. J. Innov. Comput. Appl.**, Inderscience Publishers, Inderscience Publishers, Geneva, SWITZERLAND, v. 2, n. 1, p. 1–12, 2009.
- BOVIK, A.; CLARK, M.; GEISLER, W. Multichannel texture analysis using localized spatial filters. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 12, n. 1, p. 55–73, Jan 1990.
- BUSCH, A.; BOLES, W.; SRIDHARAN, S. Texture for script identification. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 27, n. 11, p. 1720–1732, Nov 2005.
- CAPUTO, B.; HAYMAN, E.; MALLIKARJUNA, P. Class-specific material categorisation. In: **Tenth IEEE International Conference on Computer Vision (ICCV'05)**. Washington, DC, USA: IEEE Computer Society, 2005. v. 2, p. 1597–1604.
- CHANG, Q.; ZHANG, B.; LIU, R. Texture analysis method for shape-based segmentation in medical image. In: **4th International Congress on Image and Signal Processing (CISP)**. Shanghai, China: IEEE, 2011. v. 3, p. 1146–1149.
- CHIERICI, C. E. **Classificação de texturas com diferentes orientações baseada em descritores locais**. 2015. Dissertação (Mestrado) — Universidade de São Paulo, 2015.
- CHINDARO, S.; SIRLANTZIS, K.; DERAVIDI, F. Texture classification system using colour space fusion. **Electronics Letters**, v. 41, n. 10, p. 589–590, May 2005.
- COGGINS, J. M. **A Framework for Texture Analysis Based on Spatial Filtering**. 1983. Tese (Doutorado) — Michigan State University East Lansing, MI, USA, East Lansing, MI, USA, 1983.

CONNAH, D.; FINLAYSON, G. D. Using local binary pattern operators for colour constant image indexing. **Conference on Colour in Graphics, Imaging, and Vision**, v. 2006, n. 1, p. 60–64, 2006.

CUSANO, C.; NAPOLETANO, P.; SCHETTINI, R. Illuminant invariant descriptors for color texture classification. In: TOMINAGA, S.; SCHETTINI, R.; TRÉMEAU, A. (Ed.). **Computational Color Imaging**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2013. p. 239–249.

_____. Combining local binary patterns and local color contrast for texture classification under varying illumination. **J. Opt. Soc. Am. A**, OSA, v. 31, n. 7, p. 1453–1461, Jul 2014.

_____. Evaluating color texture descriptors under large variations of controlled lighting conditions. **J. Opt. Soc. Am. A**, v. 33, n. 1, p. 17–30, Jan 2016.

DRIMBAREAN, A.; WHELAN, P. Experiments in colour texture analysis. **Pattern Recognition Letters**, v. 22, n. 10, p. 1161 – 1167, 2001.

FERRAZ, C. T.; PEREIRA JR., O.; GONZAGA, A. Feature description based on center-symmetric local mapped patterns. In: **Proceedings of the 29th Annual ACM Symposium on Applied Computing**. Gyeongju, Republic of Korea: ACM, 2014. (SAC '14), p. 39–44.

FINLAYSON, G.; XU, R. Illuminant and gamma comprehensive normalisation in log rgb space. **Pattern Recogn. Lett.**, Elsevier Science Inc., New York, NY, USA, v. 24, n. 11, p. 1679–1690, 2003.

FUNT, B. V.; FINLAYSON, G. D. Color constant color indexing. **IEEE Trans. Pattern Anal. Mach. Intell.**, IEEE Computer Society, Washington, DC, USA, v. 17, n. 5, p. 522–529, 1995.

GABOR, D. Theory of communication. **Journal of the Institute of Electrical Engineers**, v. 93, p. 429–457, 1946.

GONZALEZ, R. C.; WOODS, R. E. **Digital Image Processing (3rd Edition)**. Upper Saddle River, NJ, USA: Prentice-Hall, Inc., 2006.

HANBURY, A.; KANDASWAMY, U.; ADJEROH, D. A. Illumination-invariant morphological texture classification. In: **Mathematical Morphology: 40 Years On**. Dordrecht: Springer Netherlands, 2005, (Computational Imaging and Vision, v. 30). p. 377–386.

HARALICK, R.; SHANMUGAM, K.; DINSTEN, I. Textural features for image classification. **IEEE Transactions on Systems, Man and Cybernetics**, SMC-3, n. 6, p. 610–621, Nov 1973.

HE, D.-C.; WANG, L. Texture unit, texture spectrum and texture analysis. **IEEE Transactions on Geoscience and Remote Sensing**, v. 28, p. 509–512, Jul 1990.

HUANG, D. et al. Local binary patterns and its application to facial image analysis: A survey. **IEEE Transactions on Systems, Man, and Cybernetics, Part C: Applications and Reviews**, v. 41, n. 6, p. 765–781, Nov 2011.

HURVICH, L. M.; JAMESON, D. An opponent-process theory of color vision. **Psychological Review**, v. 64, n. 6, p. 384–404, 1957.

JAIN, A.; FARROKHNI, F. Unsupervised texture segmentation using gabor filters. In: **IEEE International Conference on Systems, Man and Cybernetics, 1990. Conference Proceedings**. Los Angeles, CA, USA: IEEE, 1990. p. 14–19.

JAIN, A.; HEALEY, G. A multiscale representation including opponent color features for texture recognition. **IEEE Transactions on Image Processing**, v. 7, n. 1, p. 124–128, Jan 1998.

JULESZ, B. Textons, the elements of texture perception, and their interactions. **Nature**, v. 290, p. 91–97, 1981.

KANDASWAMY, U. et al. Robust color texture features under varying illumination conditions. **IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics**, v. 42, n. 1, p. 58–68, Feb 2012.

LIU, L. et al. Extended local binary patterns for face recognition. **Information Sciences**, v. 358, n. Supplement C, p. 56 – 72, 2016.

MAENPAA, T. **The local binary pattern approach to texture analysis - extensions and applications**. 2003. Tese (Doutorado) — University of Oulu, Finland, 2003.

MAENPAA, T.; PIETIKAINEN, M. Classification with color and texture: jointly or separately? **Pattern Recognition**, v. 37, n. 8, p. 1629 – 1640, 2004.

MANJUNATH, B.; MA, W. Texture features for browsing and retrieval of image data. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 18, n. 8, p. 837–842, Aug 1996.

NEGRI, T. T.; GONZAGA, A. Color texture classification under varying illumination. In: **Proceedings of the X Workshop of Computer Vision (WVC 2014)**. Uberlândia, Brazil: [s.n.], 2014. p. 61–66.

NEGRI, T. T.; VIEIRA, R. T.; GONZAGA, A. Color texture classification by using opponent color and local mapped pattern. In: **Proceedings of the XIII Workshop of Computer Vision (WVC 2017)**. Natal, Brazil: [s.n.], 2017.

NEGRI, T. T. et al. A robust descriptor for color texture classification under varying illumination. In: INSTICC. **Proceedings of the 12th International Joint Conference on Computer Vision, Imaging and Computer Graphics Theory and Applications - Volume 4: VISAPP, (VISIGRAPP 2017)**. Porto, Portugal: SciTePress, 2017. p. 378–388.

_____. Extended color local mapped pattern for color texture classification under varying illumination. **Journal of Electronical Imaging**, v. 26, n. 1, p. 011008–1 – 011008–12, 2018.

OJALA, T. et al. Outex - new framework for empirical evaluation of texture analysis algorithms. In: **16th International Conference on Pattern Recognition, 2002. Proceedings**. Quebec, Canada: IEEE, 2002. v. 1, p. 701–706.

OJALA, T.; PIETIKAINEN, M.; HARWOOD, D. A comparative study of texture measures with classification based on featured distributions. **Pattern Recognition**, v. 29, n. 1, p. 51 – 59, 1996.

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

PALM, C. Color texture classification by integrative co-occurrence matrices. **Pattern Recognition**, v. 37, n. 5, p. 965 – 976, 2004.

PLA, F. et al. Multi-spectral texture characterisation for remote sensing image segmentation. In: ARAÚJO, H. et al. (Ed.). **Pattern Recognition and Image Analysis**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2009, (Lecture Notes in Computer Science, v. 5524). p. 257–264.

SWAIN, M. J.; BALLARD, D. H. Color indexing. **International Journal of Computer Vision**, v. 7, p. 11–32, 1991.

TUCERYAN, M.; JAIN, A. K. Texture analysis. In: CHEN, C. H.; PAU, L. F.; WANG, P. S. P. (Ed.). **Handbook of Pattern Recognition & Computer Vision**. River Edge, NJ, USA: World Scientific Publishing Co., Inc., 1993. p. 235–276.

VIEIRA, R. T. **Análise de micropadrões em image digitais baseada em números fuzzy**. 2013. Dissertação (Mestrado) — Universidade de São Paulo, 2013.

VIEIRA, R. T. et al. Local fuzzy pattern: A new way for micro-pattern analysis. In: YIN, H.; COSTA, J.; BARRETO, G. (Ed.). **Intelligent Data Engineering and Automated Learning - IDEAL 2012**. Natal, Brazil: Springer Berlin Heidelberg, 2012, (Lecture Notes in Computer Science, v. 7435). p. 602–611.

XIANGHUA, X.; MIRMEHDI, M. Texems: Texture exemplars for defect detection on random textured surfaces. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 29, n. 8, p. 1454–1464, Aug 2007.

XIE, X. A review of recent advances in surface defect detection using texture analysis techniques. **Electronic Letters on Computer Vision and Image Analysis**, v. 7, n. 3, 2008.

ZHU, C.; BICHOT, C.-E.; CHEN, L. Multi-scale color local binary patterns for visual object classes recognition. In: **20th International Conference on Pattern Recognition (ICPR)**. Istanbul, Turkey: IEEE, 2010. p. 3065–3068.