

Color Texture Classification by using Opponent Color and Local Mapped Pattern

Tamiris Trevisan Negri^{1,2}, Raissa Tavares Vieira¹, Adilson Gonzaga¹

¹ Department of Electrical Engineering and Computing, EESC/USP - University of São Paulo, São Carlos, SP - Brazil

² Federal Institute of Education, Science and Technology of São Paulo - IFSP, Araraquara, Brazil

E-mail: tamirisnegri@ifsp.edu.br, raissa@ieee.org, agonzaga@sc.usp.br

Abstract— This paper presents a new color texture descriptor combining the Local Mapped Pattern (LMP) and Opponent Colors methodologies. Considering the RGB space, the new descriptor named Opponent Color Local Mapped Pattern (OCLMP) considers the differences between the central pixel - taken from a color channel - and its neighbors - taken from the opponent channel. The OCLMP descriptor is evaluated over two color texture databases, Outex and USPTex, and compared with Opponent Color Local Binary Pattern descriptor (OCLBP), which also considers opponent colors in its approach. The experimental results have shown that OCLMP performs better than OCLBP reporting better accuracy and lower processing time.

Keywords—Opponent Color, Local Mapped Pattern, Local Binary Pattern, Color Texture Classification

I. INTRODUÇÃO

A classificação de texturas é uma importante tarefa na área de visão computacional. O uso da cor na tentativa de melhorar a acurácia dos métodos de classificação tem sido comprovado em muitos trabalhos, como o estudo feito por Bianconi et al. [1].

Dentre os desafios de se usar a “cor da textura” ou textura colorida, estão a forma como ela é extraída e o espaço de cores considerado. Jain e Healey [2] introduziram a representação de texturas coloridas utilizando cores oponentes, processo que é baseado no sistema visual humano. Eles propõem a extração de características de uma textura colorida utilizando pares de cores oponentes dentro de um espaço de cores, juntamente com características unicromáticas, ou seja, de um único canal de cor. Essas características são computadas a partir das saídas de um filtro de Gabor, combinando informações de diferentes bandas espectrais em diferentes escalas.

Maenpaa e Pietikainen [3] propuseram o descriptor Opponent Color Local Binary Pattern (OCLBP). O OCLBP utiliza a representação de cores oponentes proposta em [2] aplicada ao descriptor de texturas Local Binary Pattern (LBP) e, segundo os resultados reportados, apresenta melhor desempenho que o descriptor baseado nos filtros de Gabor.

Em 2012, Vieira et al. [4], introduziram um novo descriptor baseado em números fuzzy, que posteriormente evoluiu para o

Local Mapped Pattern (LMP) [5]. Este novo descriptor mapeia os padrões locais de uma textura para os *bins* de um histograma utilizando uma função de mapeamento que pode ser modificada de acordo com a aplicação. Os autores ainda mostram que o LMP é uma generalização do LBP, e que este último pode ser obtido modificando-se alguns parâmetros do primeiro.

Motivado pelo alto desempenho do LMP em diversas aplicações [4-8] propomos, neste trabalho, a investigação da sua utilização na classificação de texturas coloridas, juntamente com a teoria de cores oponentes proposta por Jain e Healey [2], introduzindo o descriptor Opponent Color Local Mapped Pattern (OCLMP).

Este artigo está estruturado em seis seções. Nesta seção I foram apresentadas as justificativas e a motivação para classificação de texturas coloridas. A seção II resume o método base para o descriptor OCLMP, o qual é proposto neste trabalho na seção III. O método e o material utilizado são descritos na seção IV, sendo os resultados obtidos discutidos na seção V. Finalmente, a seção VI conclui o trabalho.

II. LOCAL MAPPED PATTERN

O descriptor Local Mapped Pattern (LMP) utiliza uma função de mapeamento para construir um histograma que representa as frequências dos padrões locais contidos em uma determinada imagem (Fig. 1). Estes padrões são baseados nas diferenças dos valores entre o pixel central e seus vizinhos.

g_1	g_2	g_3
g_4	g_c	g_5
g_6	g_7	g_8

Figura 1: Padrão Local 3x3.

Considerando-se uma vizinhança $v = W \times W$ de uma textura como sendo um padrão local, este pode ser mapeado para um bin h_b de um histograma a partir da Equação (1)

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

em que f é a função de mapeamento aplicada a diferença entre cada vizinho g_i e o pixel central g_c , M é uma matriz de pesos pré-definida e B é o número de *bins* do histograma.

A matriz de pesos, função de mapeamento e número de *bins* do histograma são parâmetros a serem definidos de acordo com a aplicação pretendida. Para a classificação de texturas, os autores sugerem $B=256$ e uma curva sigmóide como função de mapeamento (Eq. (2))

$$f_g = \frac{1}{1 + e^{-\frac{|g_i - g_c|}{\beta}}} \quad (2)$$

na qual, $[g_i - g_c]$ são as diferenças entre o valor do pixel central g_c e seus vizinhos g_i ($i = 1, \dots, v - 1$) e β é o parâmetro que determina a inclinação da curva. A Equação (3) mostra a matriz de pesos proposta.

$$M = \begin{bmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{bmatrix} \quad (3)$$

A metodologia pode ainda ser estendida para vizinhanças circulares [6]. Dado um par ordenado (P, R) de inteiros positivos, onde P é o número de pontos amostrados e R é o raio, uma região simétrica circular pode ser definida como na Figura 2.

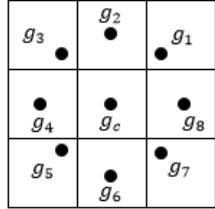


Figura 2: Vizinhança circular simétrica com $P=8$ e $R=1$.

As coordenadas de cada pixel vizinho g_p ($p = 1, \dots, P - 1$), são dadas por $(-R \sin(2\pi p/P), R \cos(2\pi p/P))$ em relação ao pixel central g_c localizado nas coordenadas $(0,0)$. Os valores dos vizinhos que não estão localizados no centro do pixel são estimados por interpolação. Nessa nova versão denominada Sampled-Local Mapped Pattern (S-LMP), a matriz de pesos não é considerada a fim de obter invariância a rotação. Os padrões locais são então mapeados para um bin h_b do

histograma utilizando a Eq. (4) e a função de mapeamento apresentada na Eq. (5).

$$h_b = \text{round} \left(\frac{\sum_{p=1}^P f_{g_p}}{P} (B - 1) \right) \quad (4)$$

$$f_{g_p} = \frac{1}{1 + e^{-\frac{|g_p - g_c|}{\beta}}} \quad (5)$$

III. OPPONENT COLOR LOCAL MAPPED PATTERN

A representação de texturas coloridas utilizando cores oponentes considera os pares oponentes dentro de um espaço de cores. Para o espaço de cores RGB, por exemplo, temos os pares R-G, R-B, G-R, G-B, B-R e B-G. Como destacado em [3], os pares simétricos como R-B e B-R por exemplo, são altamente redundantes e por isso optamos por utilizar somente 3 pares de cores oponentes R-G, R-B e G-B.

O descritor OCLMP combina a metodologia LMP com a teoria de cores oponentes. Para isso, considera-se o pixel central em um espaço de cores, e seus vizinhos são extraídos da cor oponente, como mostrado na Figura 3. O descritor S-LMP 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 (Fig. 4).

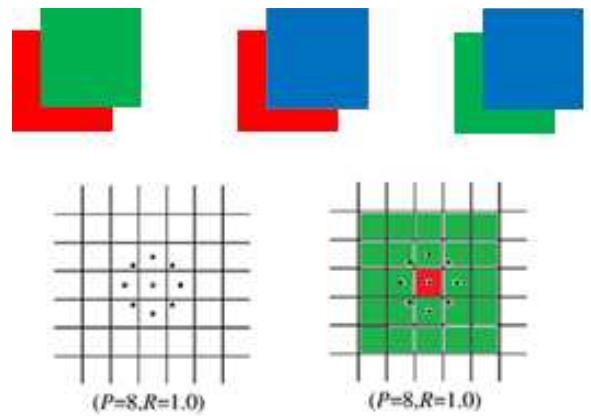


Figura 3: Pares de cores oponentes e processo de seleção dos pixels para um descritor de configuração $(P, R) = (8, 1)$.

IV. MATERIAIS E MÉTODO

A avaliação do método foi realizada em duas bases de dados: Outex [9] e USPTex [10]. A base de dados Outex é disponibilizada pela Universidade de Oulu e possui várias suítes de testes previamente organizadas de acordo com a aplicação. Neste trabalho foi utilizada a suíte Outex 13 [3], que possui 68 texturas (Fig. 5), de tamanho 746 x 538 pixels, adquiridas sob

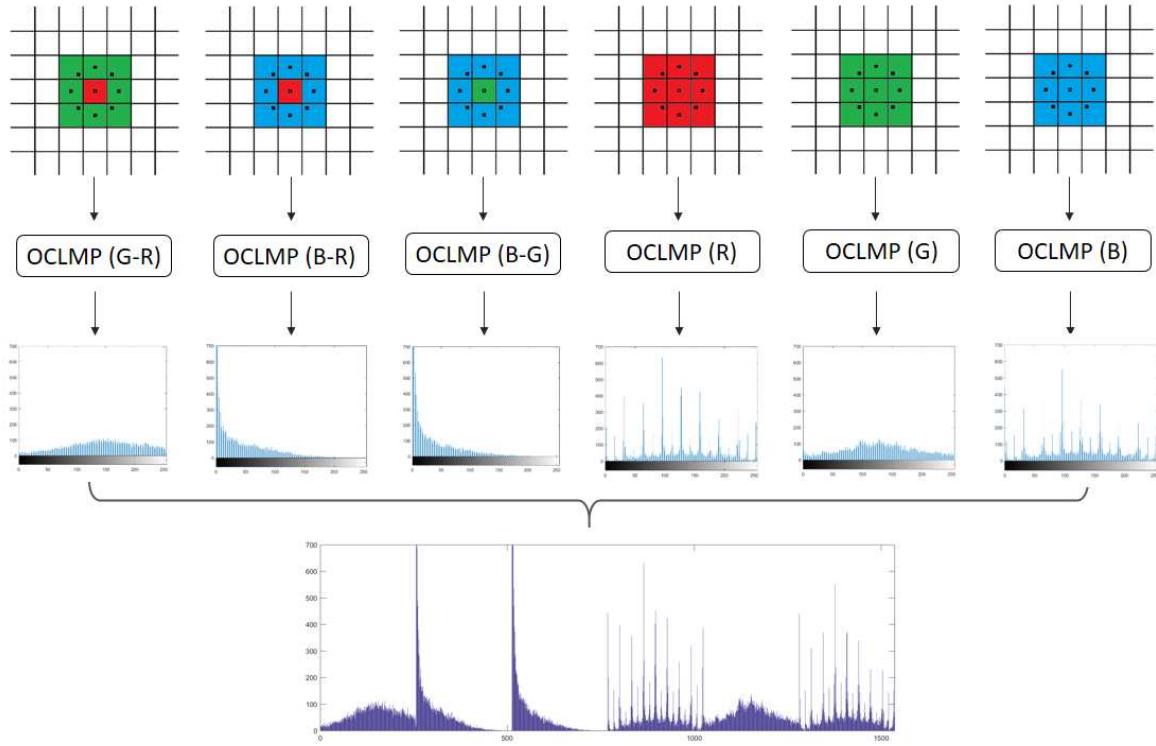


Figura 4: Processo de geração do vetor de características do descritor OCLMP.

uma luz CIE A incandescente 2856 K. Cada textura é subdividida em 20 amostras de 128 x 128 pixels, gerando 1360 amostras. Metade das amostras é utilizada como conjunto de teste e a outra metade como conjunto de treinamento (conjunto de busca). Essa divisão é realizada seguindo um padrão de tabuleiro de xadrez, em que a primeira amostra do canto superior esquerdo pertence ao conjunto de treinamento.



Figura 5: As 68 texturas da suíte Outex 13.

A base de texturas USPTex contém 191 texturas adquiridas utilizando uma câmera digital com 512×384 pixels de resolução. As texturas incluem feijões, arroz, tecido, vegetação, nuvens, etc. (Fig. 6). Neste experimento foram utilizadas 12 amostras de

128 x 128 pixels para uma das 191 classes, totalizando 2292 amostras. Metade das amostras foram utilizadas como conjunto de teste e metade como conjunto de treinamento. As amostras foram separadas da mesma forma que na base Outex, seguindo um padrão de tabuleiro de xadrez.



Figura 6: Exemplos de texturas da base de dados UPSTex

O descritor é aplicado a cada amostra dos conjuntos de teste e de treinamento, gerando um vetor de características que

representa cada imagem. Cada vetor de características do conjunto de teste é comparado a todos os vetores do conjunto de treinamento utilizando-se uma medida de distância.

A fim de avaliar como o descritor se comporta quando diferentes medidas de distâncias são utilizadas, seu desempenho foi analisado mediante duas métricas: distância L1 (Eq. (6)) e distância chi-quadrado (Eq.(7)), nas quais, S refere-se à amostra de busca do conjunto de testes e M refere-se à amostra do conjunto de treinamento, sendo B o número de *bins*.

$$D(S, M) = \sum_{b=1}^B |S_b - M_b| \quad (6)$$

$$X(S, M) = \frac{1}{2} \sum_{b=1}^B \frac{(S_b - M_b)^2}{(S_b + M_b)} \quad (7)$$

Para a classificação utilizou-se o classificador k-NN (k vizinhos mais próximos) com $k=1$, ou seja, a classe da amostra do conjunto de treinamento que possui a menor distância da amostra de teste é considerada a predição do classificador.

O desempenho da classificação é reportado através da acurácia, ou taxa de acerto (Eq. (9)).

$$A = \frac{\text{número de amostras classificadas corretamente}}{\text{número de amostras de teste}} \quad (9)$$

V. RESULTADOS E DISCUSSÕES

O descritor OCLMP possui parâmetros que devem ser definidos de acordo com a aplicação, como número de bins do histograma, função de mapeamento e configuração de raio e número de vizinhos. Pra esta aplicação os histogramas foram construídos com 256 bins ($B=256$), e a função sigmóide foi utilizada no mapeamento.

Conforme apresentado na Eq. (5), a função sigmóide possui o parâmetro β que determina sua inclinação. Para otimização deste parâmetro foi aplicado um algoritmo genético da Toolbox de otimização do Matlab (versão R2014a). A função objetivo a ser maximizada é a acurácia, e as imagens do conjunto de treinamento foram utilizadas para realizar a otimização. O intervalo de possíveis valores para a inclinação da curva é $]0, \infty[$. No entanto, a fim de tornar a otimização mais rápida e, baseando-se em testes realizados previamente, optou-se por restringir este intervalo para $]0, 5]$.

Após testes preliminares, os parâmetros de vizinhança e raio (P,R) que obtiveram os melhores desempenhos foram (8,1) e (16,2). Sendo assim, todos os experimentos foram realizados considerando estas duas configurações.

A Tabela I apresenta os parâmetros otimizados por meio de algoritmo genético para cada caso considerando-se a base de dados Outex. Na Tabela II são apresentados os parâmetros otimizados para a base de dados USPTex. Os resultados obtidos

(acurácia) são apresentados nas Tabelas III e IV, as quais apresentam ainda uma comparação entre o desempenho dos descritores OCLBP [3] e OCLMP.

TABELA I: Valores dos parâmetros β otimizados para o banco de dados Outex para cada configuração de vizinhança e raio (P,R) em cada métrica utilizada.

Distância	Canais	(P,R) = (8,1)	(P,R) = (16,2)
		β	β
L1	R - G	2,4918	2,0196
	R - B	2,3554	0,5644
	G - B	2,0229	0,9495
	R	0,1094	0,4221
	G	0,0743	0,0394
	B	0,3347	0,2095
Chi-quadrado	R - G	1,4755	1,8357
	R - B	1,4567	2,1820
	G - B	1,6712	0,0177
	R	0,3440	1,1866
	G	1,0874	1,4281
	B	0,4051	0,3688

TABELA II: Valores dos parâmetros β otimizados para o banco de dados USPTex para cada configuração de vizinhança e raio (P,R) em cada métrica utilizada.

Distância	Canais	(P,R) = (8,1)	(P,R) = (16,2)
		β	β
L1	R - G	4,7392	4,3220
	R - B	0,8520	0,3417
	G - B	2,5253	1,4337
	R	0,0743	0,0532
	G	0,1488	4,6046
	B	0,2685	0,0424
Chi-quadrado	R - G	0,3108	3,1781
	R - B	0,7493	0,4475
	G - B	1,1202	0,2973
	R	0,7326	0,3307
	G	0,4336	2,4226
	B	0,4454	0,2503

TABELA III: Acurácia (%) obtida pelos descritores OCLMP e OCLBP no banco de dados Outex.

Distância	Descriptor	Acurácia
L1	OCLMP (8,1)	94,26
	OCLMP (16,2)	94,12
	OCLBP (8,1)	91,18
	OCLBP (16,2)	92,94
Chi-quadrado	OCLMP (8,1)	92,50
	OCLMP (16,2)	93,68
	OCLBP (8,1)	91,62
	OCLBP (16,2)	92,35

TABELA IV: Acurácia obtida pelos descritores OCLMP e OCLBP no banco de dados USPTex.

Distância	Descriptor	Acurácia
L1	OCLMP (8,1)	91,97
	OCLMP (16,2)	93,80
	OCLBP (8,1)	91,62
	OCLBP (16,2)	91,56
Chi-quadrado	OCLMP (8,1)	91,27
	OCLMP (16,2)	93,80
	OCLBP (8,1)	91,97
	OCLBP (16,2)	93,46

A partir dos resultados reportados na Tabela III, é possível verificar que o descritor OCLMP supera o OCLBP na base de dados Outex 13, independente da métrica de distância utilizada na avaliação. A vizinhança (8,1) se mostrou melhor para a distância L1, e a vizinhança (16,2) obteve melhor resultado com a distância chi-quadrado. Para a base de texturas USPTex, de acordo com os resultados apresentados na Tabela IV, o OCLMP também obteve melhor desempenho que o OCLBP, tanto utilizando-se a distância L1, quanto a chi-quadrado. Além disso, a vizinhança (16,2) apresentou melhores resultados, independente da medida de distância utilizada. De modo geral, tanto o OCLBP, quanto o OCLMP apresentam melhores resultados utilizando a vizinhança (16,2), o que pode ser explicado pelo fato dessa configuração utilizar mais pixels na composição do valor de representação do padrão local.

Outra análise realizada foi o tempo de execução. Para isso calculou-se o tempo que cada descritor necessita para construir o vetor de características relativo a uma amostra do banco de dados USPTex. O computador utilizado para o teste possui processador Intel® Core™ i7-6560U CPU 2,2GHz, 8GB de RAM e sistema operacional Windows 10 Home. Os resultados são reportados na Tabela V.

TABELA V: Tempo de processamento (em segundos) para geração de um vetor de características, utilizando os descritores OCLMP e OCLBP.

Descriptor	Tempo (s)
OCLMP (8,1)	0,1184
OCLMP (16,2)	0,1522
OCLBP (8,1)	0,1081
OCLBP (16,2)	0,4859

Por meio dos resultados apresentados na Tabela V podemos verificar que para a vizinhança (8,1) os dois descritores apresentaram tempo de execução muito próximo, perto de 0,11 segundos. No entanto, para a configuração (16,2), a qual apresenta os melhores resultados de acurácia, o descritor OCLMP se mostrou em média 3 vezes mais rápido que o OCLBP, gerando um vetor de características em aproximadamente 0,15 segundos, enquanto o OCLBP precisa de 0,48 segundos para realizar a mesma tarefa.

VI. CONCLUSÕES

Neste artigo, foi apresentado um novo descritor de texturas coloridas baseado na metodologia Local Mapped Pattern (LMP) e utilizando cores oponentes, nomeado Opponent Color Local Mapped Pattern (OCLMP). O descritor proposto foi avaliado em dois bancos de texturas coloridas disponíveis na internet, Outex e USPTex, sendo os resultados comparados com os resultados obtidos pelo descritor Opponent Color Local Binary Pattern (OCLBP). O desempenho do descritor proposto (OCLMP) foi superior ao do OCLBP nos dois bancos de texturas coloridas utilizados, com ganho de acurácia superior a 3% comparativamente ao OCLBP, e apresentando menor tempo de processamento, sendo até 3 vezes mais rápido.

AGRADECIMENTOS

Os autores agradecem o apoio financeiro da FAPESP, processo #2015/20812- 5, para a realização deste trabalho.

REFERÊNCIAS

- [1] F. Bianconi, R. Harvey, P. Southam, and A. Fernández. Theoretical and experimental comparison of different approaches for color texture classification, *J. Electron. Imaging* 20, 2011.
- [2] A. Jain and G. Healey. A multiscale representation including opponent color features for texture recognition. *IEEE Transactions on Image Processing*, vol. 7, no. 1, pp. 124–128, Jan 1998.
- [3] T. Mäenpää and M. Pietikäinen. Classification with color and texture: jointly or separately? *Pattern Recognition*, 37, 2004.
- [4] R. T. Vieira, C. E. de Oliveira Chierici, C. T. Ferraz, and A. Gonzaga. Local fuzzy pattern: A new way for micro-pattern analysis. *Intelligent Data Engineering and Automated Learning - IDEAL 2012*, ser. Lecture Notes in Computer Science, H. Yin, J. Costa, and G. Barreto, Eds. Springer Berlin Heidelberg, 2012, vol. 7435, pp. 602–611.
- [5] C. T. Ferraz, O. P. Junior, and A. Gonzaga. Feature description base on center-symmetric local mapped patterns. *Symposium on Applied Computing, ACM-SAC 2014*, Gyeongju, Korea, March 24 - 28 2014, pp. 39–44.

- [6] T. T. Negri, A. Gonzaga. Color texture classification by a local multiscale descriptor. XI Workshop de Visão Computacional, São Carlos, 2015, pp. 292-297.
- [7] C. T. Ferraz and A. Gonzada. Improving image classification performance by descriptor size reduction and Bag-of-Features. XI Workshop de Visão Computacional, São Carlos, 2015, pp. 358-363.
- [8] C. Chierici, R.T. Vieira, C.T. Ferraz, J. Travaiani and A. Gonzaga. A new approach for analyzing rotated textures. IX Workshop de Visão Computacional, Rio de Janeiro, 2013.
- [9] T. Ojala, T. Maenpaa, M. Pietikainen, J. Viertola, J. Kyllonen, S. Huovinen, Outex—new framework for empirical evaluation of texture analysis algorithms, in: Proceedings of the 16th International Conference on Pattern Recognition, Vol. 1, Quebec, Canada, 2002, pp. 701–706, <http://www.outex.oulu.fi/>.
- [10] A. R. Backes, D. Casanova, and O. M. Bruno. Color texture analysis based on fractal descriptors. Pattern Recognition, vol. 45, no. 5, pp. 1984–1992, 2012.