

# Compound Local Binary Pattern (CLBP) for Robust Facial Expression Recognition

Faisal Ahmed, Emam Hossain, ASM Hossain Bari and ASM Shihavuddin

Alunos: André Pires e Geovane Menezes

Professor: Dr. Geraldo Braz Junior

Disciplina: Visão Computacional

# Introdução

- Análise de expressões faciais tem atraído muita atenção nos anos recentes devido ao seu potencial de aplicabilidade em muitas áreas como interação humano-computador, animação dirigida a dados (data-driven animation) e aplicações personalizadas.
- As técnicas de extração de características geralmente utilizadas incluem métodos baseados em características geométricas e métodos baseados em aparência.

# Local Binary Pattern (LBP)

- Recentemente, análise de expressões faciais baseadas em padrão binário local (LBP) e suas variantes ganharam muita popularidade pelas seus desempenhos superiores. Originalmente utilizado para análise de textura, o método foi aplicado com sucesso na autenticação de face e reconhecimento de expressões faciais.
- O método LBP extrai informação de textura local por estabelecer um limiar para um número  $P$  de vizinhos, no valor do pixel central em uma vizinhança local.

# Local Binary Pattern (LBP)

- Prós:

- Computacionalmente eficiente e robusto a variação monotônica de iluminação.
- Simples.

- Limitações:

- Desempenho ruim na presença de ruídos aleatórios
- Considera apenas o sinal da diferença entre dois valores de cinza, descartando a magnitude.

$$LBP_{P,R}(x_c, y_c) = \sum_{p=0}^{P-1} s(i_p - i_c) 2^p$$

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

# Local Binary Pattern (LBP)




Figure 2. Generation of inconsistent binary pattern in the LBP encoding process.

# Compound Local Binary Pattern (CLBP)

- Atribui um código de **2P bits** ao pixel central baseado nos valores de cinza de uma vizinhança local que compreende P vizinhos.
- Usa dois bits para cada vizinho para representar o **sinal**, bem como a informação de **magnitude** da diferença entre o centro e seus vizinhos.
- O primeiro bit representa o sinal de diferença entre o centro e o vizinho

e o segundo bit é usado para codificar a magnitude da diferença com relação a um valor limitante, nesse caso a **magnitude média**.

$$s(i_p, i_c) = \begin{cases} 00 & i_p - i_c < 0, & |i_p - i_c| \leq M_{avg} \\ 01 & i_p - i_c < 0, & |i_p - i_c| > M_{avg} \\ 10 & i_p - i_c \geq 0, & |i_p - i_c| \leq M_{avg} \\ 11 & \text{otherwise} \end{cases}$$

# Compound Local Binary Pattern (CLBP)

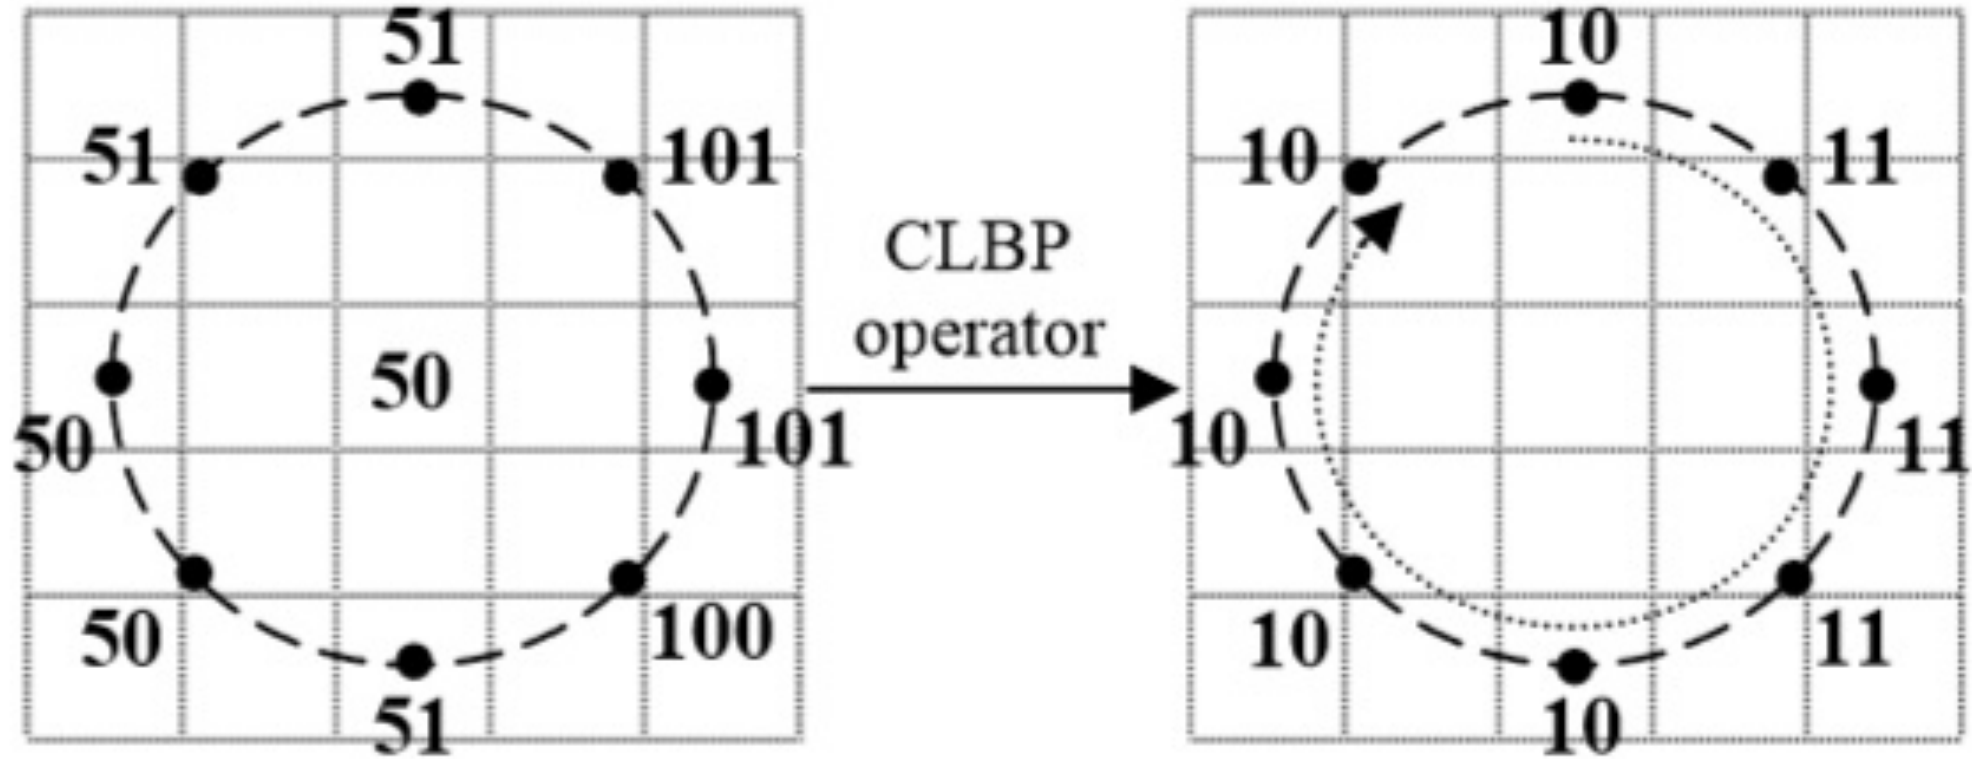


Figure 3. Illustration of the basic CLBP operator. Here, the binary pattern is 1011111110101010.

# Compound Local Binary Pattern (CLBP)

- Como códigos de 16 bits são usados para classificar os pixels, o número de padrões binários possíveis é de  $2^{16}$ .
- Para diminuir o número de padrões possíveis, é feita uma abordagem onde todos os padrões CLBP são divididos em dois sub-CLBP.
- Esse método reduz significativamente o número de possíveis padrões, resultando em um total de  $2^{18}$  diferentes padrões sub-CLBP.
- Os dois padrões sub-CLBP são tratados como códigos binários separados e posteriormente combinados durante a geração do vetor de características.



# Compound Local Binary Pattern (CLBP)

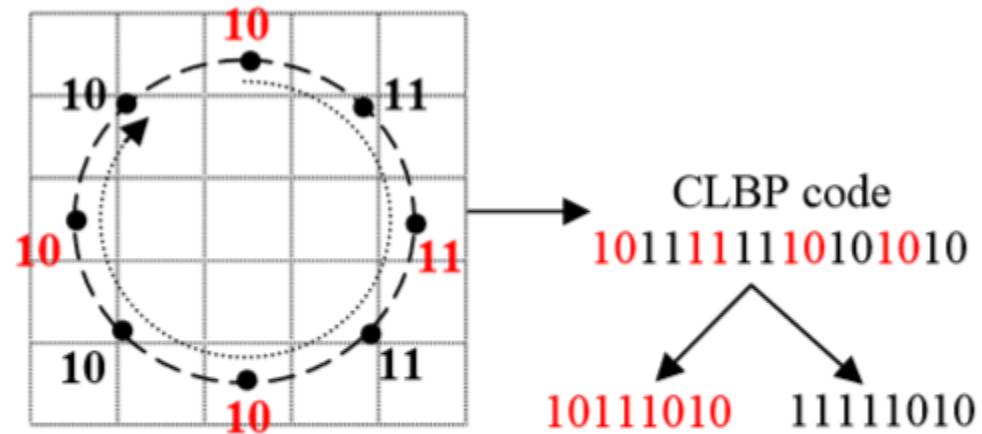


Figure 4. Generation of the two sub-CLBP patterns 10111010 and 11111010 from the original CLBP code 1011111110101010.

# Representação de Características usando CLBP

1. O histograma de 16-bits do CLBP é dividido em 2 sub-padrões de 8-bits;
2. Depois estes dois sub-padrões são concatenados para gerar um único histograma.




(a)




(b)




(c)



(d)



(e)



(f)

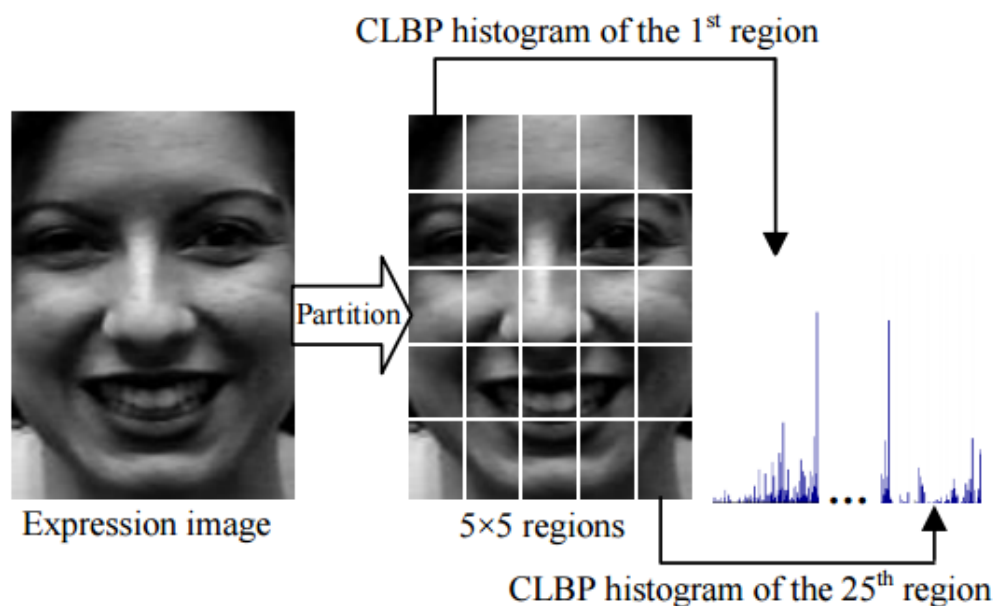
Figura: Exemplo do processo de geração do vetor de características.

# Representação de Características usando CLBP

- Histogramas gerados pela codificação de toda uma imagem não contêm informações dos micro-padrões, somente ocorrências são expressas;
- A presença de informação local e relação espacial ajuda em uma melhor representação e descreve a imagem com maior acurácia.

# Representação de Características usando CLBP

Cada imagem é particionada em um número de regiões individuais e histogramas individuais são gerados a partir destas regiões e após isso são concatenados visando incorporar algum grau de informação local.



# Classificação usando Máquina de Vetores de Suporte (MVS)

A MVS é uma abordagem de aprendizado de máquina baseado na moderna teoria da aprendizagem estatística.

- Dado um conjunto identificado de treino  $T = \{(x_i, l_i), i=1, 2, \dots, L\}$ , onde  $x_i \in \mathbb{R}^P$  e  $l_i \in \{-1, 1\}$ , o novo dado de teste é classificado por:

$$f(\mathbf{x}) = \text{sign}\left(\sum_{i=1}^L \alpha_i l_i K(\mathbf{x}_i, \mathbf{x}) + b\right)$$


- O kernel Radial Basis Function (RBF) foi usado e é definido como:

$$K(\mathbf{x}_i, \mathbf{x}) = \exp(-\gamma \|\mathbf{x}_i - \mathbf{x}\|^2), \quad \gamma > 0$$

$$\|\mathbf{x}_i - \mathbf{x}\|^2 = (\mathbf{x}_i - \mathbf{x})^t (\mathbf{x}_i - \mathbf{x})$$

# Resultados Experimentais

- Base de imagens: Banco de dados de expressões faciais de Cohn-Kanade;
- 1224 imagens de 6 expressões emocionais;



- Incluídas imagens 408 imagens neutras;
- Normalizadas a 150x110 pixels.

# Resultados Experimentais

- Validação Cruzada de 10-fold utilizada;
- Particionamento utilizados: 3x3, 5x5 e 7x6;
- A performance do CLBP foi comparada com o Local Binary Pattern (LBP) e com o Local Ternary Pattern (LTP);

# Resultados Experimentais

Operator	Classification rate (%) for different number of regions		
	3×3	5×5	7×6
LBP <sub>8,1</sub>	79.3	89.7	90.1
LTP	87.3	92.3	93.6
CLBP	88.2	94.4	94.2

Tabela 1: Resultados Utilizando a base de 6 expressões faciais

Operator	Classification rate (%) for different number of regions		
	3×3	5×5	7×6
LBP <sub>8,1</sub>	73.8	80.9	83.3
LTP	81.3	88.5	88.9
CLBP	82.1	90.4	89.2

Tabela 1: Resultados Utilizando a base de 7 expressões faciais



# Conclusão

Como os resultados experimentais indicam, o CLBP provê uma abordagem efetiva e eficiente para representação de características faciais com alta habilidade discriminativa, superando o LBP.

## Trabalhos Futuros:

Incorporar informação temporal com o CLBP para reconhecer expressões em imagens sequenciais.