



## **DESCRITOR DE TEXTURA BASEADO EM DADOS SIMBÓLICOS**

Ronaldo Medeiros Pessoa Filho <sup>1</sup> Carlos Wilson Dantas de Almeida <sup>2</sup>

### **RESUMO**

Na revolução informacional que estamos inseridos atualmente há um crescente fluxo de dados, principalmente de imagens e vídeos, nesse contexto surge a necessidade de extrair informações significativas dessa grande quantidade de dados, visando sua aplicação em diversas áreas do conhecimento. Na tentativa de suprir essa necessidade, propomos uma nova abordagem no domínio de Técnicas de Recuperação de Imagens por Conteúdo para desenvolver um descritor de imagens baseado em textura como critério discriminativo, utilizando estruturas mais complexas de dados denominadas dados simbólicos cuja a função é reduzir o processamento de dados e obtendo uma representação eficiente das características únicas de um conjunto de dados. Uma abordagem que se mostrou promissora obtendo bons índices quando aplicada a testes utilizando o algoritmo FKCN para dados intervalares e uma base de imagens com classes pré-definidas.

**Palavras-chave:** Dados Simbólicos, Recuperação de Imagens por Conteúdo, Análise de Texturas.

---

<sup>1</sup> Aluno do curso de Ciência da Computação, Departamento de Sistemas e Computação (DSC), UFPG, Campina Grande, PB, e-mail: ronaldo.medeiros.filho@ccc.ufcg.edu.br

<sup>2</sup> Doutor em Ciência da Computação, Professor, Departamento de Sistemas e Computação (DSC), UFPG, Campina Grande, PB, email: carlos.wilson@computacao.ufcg.edu.br

## ***DESCRITOR DE TEXTURA BASEADO EM DADOS SIMBÓLICOS***

### **ABSTRACT**

In the information revolution we are currently entering, there is a growing flow of data, especially of images and videos. In this context, the need arises to extract significant information from this large amount of data, aiming its application in several areas of knowledge. In an attempt to address this need, we propose a new approach in the field of Content-Image Retrieval Techniques to develop a texture-based image descriptor as a discriminative criterion using more complex data structures called symbolic data whose function is to reduce processing of data and obtaining an efficient representation of the unique characteristics of a data set. An approach that was promising obtaining good indexes when applied to tests using the FKCN algorithm for interval data and a base of images with predefined classes.

**Keywords:** Symbolic Data, Content-Image Retrieval, Texture Analysis.

## INTRODUÇÃO

A informação é um dos principais mercados da atualidade, sendo considerado um *commodity* extremamente valioso no contexto da revolução informacional proporcionada pela *World-Wide Web*. Com milhões de *bytes* caminhando por essa rede na forma de um fluxo distribuído de dados, surge a necessidade de extrair informações a partir desses dados, de modo que o conhecimento proveniente da análise, entendimento e síntese dessas informações possa ser aplicado ao desenvolvimento de diversas áreas, tais como medicina, educação, sistemas de informação geográfica, jornalismo, publicidade, arqueologia, biologia, segurança, entretenimento, etc (OUSSALAH, 2008).

Direcionando nossa atenção mais especificamente para os dados do tipo visual, temos que o domínio de Técnicas de Recuperação de Imagens Baseado por Conteúdo (RIBC) tem como objetivo oferecer mecanismos que possibilitem a indexação desses dados (LEW, 2010), utilizando para isso características discriminativas para representar o conteúdo visual das imagens capturadas através de descritores (OUSSALAH, 2008; ARANDJELOVIĆ; ZISSERMAN, 2012), cuja função é caracterizar as propriedades visuais mais relevantes de uma imagem, por meio da extração de um conjunto de vetores de características que as representam.

Neste trabalho, outro conceito importante é o de dados simbólicos, que são representações de estruturas mais complexas de dados, tais como intervalos reais, distribuições de probabilidade e conjuntos de categorias. A análise desses dados simbólicos(usaremos o acrônimo SDA, do inglês, *Symbolic Data Analysis*) (BOCK; DIDAY, 2000) tem como objetivo construir grupos homogêneos de observações a partir de grandes conjuntos de dados, tendo em vista a necessidade da criação de uma nova forma de tratamento de dados surgiu pelo fato do modelo clássico ser demasiado simples para representar características importantes, tais como variabilidade e incerteza. Esses dados simbólicos são descritos por variáveis multi-valoradas que podem não somente assumir um valor numérico ou categórico, mas um conjunto de categorias, intervalos ou distribuições de pesos.

No processo de obtenção desses dados simbólicos, deve-se conservar ao máximo as informações, ao mesmo tempo em que se reduz consideravelmente a tabela de dados iniciais. Como resultado desse processo temos novas tabelas de dados com estruturas mais complexas e significativas, na qual cada célula contém informações complexas como subconjuntos, intervalos, funções de diferentes semânticas (probabilista, possibilista, credibilista etc).

## MATERIAIS E MÉTODOS

Para o desenvolvimento do método proposto foi utilizado o Software Numérico *MATLAB*, devido a sua grande biblioteca de funções de tratamento de dados e manipulação de imagens, apresentando uma série de funcionalidades para geração e análise de matrizes de coocorrência. Também foi utilizada uma implementação do *Fuzzy Kohonen Clustering Network* (FKCN) (ALMEIDA; SOUZA; CANDEIAS, 2013) para dados intervalares com o objetivo de testar a qualidade discriminativa dos dados intervalares criados. Para o âmbito de testes foi usada a base de imagens *UUIC* (LAZEBNIK; SCHMID; PONCE, 2005) que contém 25 classes diferentes cada uma com 40 elementos que apresentam padrões de textura similares, onde cada classe possui características diferentes.

### GRAY-LEVEL CO-OCCURRENCE MATRIX (GLCM)

Uma matriz de coocorrência ou de ocorrência simultânea de níveis de cinza consiste de uma matriz quadrada que quantifica as combinações diferentes de valores de intensidade de pixel (níveis de cinza) que ocorrem em uma imagem, considerando uma certa distância entre o chamado pixel de referência e o vizinho, sob um ângulo que determina a direção em que essa distância é tomada. Cada pixel da imagem se torna o de referência iniciando-se do canto superior esquerdo e procedendo até o canto inferior direito, de modo que haverá casos particulares em que o vizinho não poderá ser definido, visto que ele excede as dimensões da imagem, como por exemplo: considerando uma distância maior ou igual a 1 (um) e uma angulação de  $0^\circ$ , utilizando os pixels da margem direita da imagem como pixels de referência.

A coocorrência em sua forma geral pode ser definida como uma matriz de frequências relativas  $P(i, j, d, \theta)$  na qual o número de linhas e colunas é igual o número de níveis de cinza diferentes presentes na imagem. Para cada elemento  $E_{ij}$  da matriz temos o número de vezes em que ocorreu uma transição do nível de cinza  $G_i$  para  $G_j$  a uma distância  $d$  e um ângulo  $\theta$ .

$$\mathbf{I} = \begin{pmatrix} 0 & 0 & 0 & 1 & 2 \\ 1 & 1 & 0 & 1 & 1 \\ 2 & 2 & 1 & 0 & 0 \\ 1 & 1 & 0 & 2 & 0 \\ 0 & 0 & 1 & 0 & 1 \end{pmatrix}$$

A matriz de coocorrência pode ser normalizada através da divisão de cada célula  $E_{ij}$  da matriz pela soma dos elementos de todas as células. Feito esse processo, o

Tabela 1 – Matriz de coocorrência da imagem I para  $d = 1$  e  $\theta = 0^\circ$

$G_i \backslash G_j$	0	1	2
0	4	4	1
1	4	3	1
2	1	2	1

valor de cada célula  $P_{ij}$  agora representa um valor de uma probabilidade da ocorrência da transição do nível  $G_i$  para o nível  $G_j$  de acordo com os parâmetros  $d$  e  $\theta$ , onde  $N_G$  representa o total de níveis de cinza diferentes, sendo então calculado pela equação:

$$P_{ij} = \frac{E_{ij}}{\sum_{i=1}^{N_G} \sum_{j=1}^{N_G} E_{ij}}$$

Tabela 2 – Matriz de coocorrência normalizada da imagem I para  $d = 1$  e  $\theta = 0^\circ$

$G_i \backslash G_j$	0	1	2
0	0,19047619	0,19047619	0,047619048
1	0,19047619	0,142857143	0,047619048
2	0,047619048	0,095238095	0,047619048

As matrizes de coocorrência são consideradas uma boa abordagem para análise e classificação de texturas em imagens visto que a partir dela muitos parâmetros informativos podem ser retirados como por exemplo medidas estatísticas como: correlação, variância e etc. No entanto elas possuem alto custo computacional a medida que o número de níveis de cinza diferentes na imagem aumenta.

#### ALGORITMO FKCN PARA DADOS INTERVALARES

A rede Kohonen de Categorização Nebulosa, ou *Fuzzy Kohonen Clustering Network* (FKCN) (TSAO; BEZDEK; PAL, 1994; BEZDEK; TSAO; PAL, 1992) é um algoritmo de agrupamento não supervisionado, que combina ideias de valores de pertinência para as taxas de aprendizado e o paralelismo do algoritmo *Fuzzy C-means* (FCM) (BEZDEK, 1981) com as regras de atualização auto-organizáveis do algoritmo *Kohonen Clustering Network* (KCN) (KOHONEN, 2001).

O treinamento é feito de maneira sequencial, onde os pesos da rede são atualizados após a apresentação de cada amostra. O conjunto de amostras é apresentado repetidas vezes à rede até que esta atinja a estabilidade. Uma função de atualização de vizinhança deve ser definida e decrementada com o tempo (KOHONEN, 2001).

Sousa e de Almeida (ALMEIDA; SOUZA; CANDEIAS, 2013) desenvolveram o algoritmo *Fuzzy Kohonen Clustering Network* para dados intervalares com e sem distâncias adaptativas. Neste novo método, a taxa de aprendizado é controlada automaticamente e com treinamento em lote (batch).

## DESCRITOR DE TEXTURAS BASEADO EM DADOS SIMBÓLICOS

No desenvolvimento do método proposto, procuramos extrair a partir da matriz de coocorrência de níveis de cinza (GLCM) para criação de dados simbólicos do tipo intervalo, de maneira que esses intervalos sejam o mais significativos possíveis, e consigam capturar as características únicas de cada imagem de maneira que possam ser usados para identificação e classificação de uma determinada imagem a um baixo custo computacional.

Para isto utilizamos uma matriz de coocorrência de dimensões menores ou seja considerando menos níveis de cinza diferentes na imagem visto que apesar de uma imagem apresentar variados tons de cinza grande parte das ocorrências simultâneas de níveis de cinza não ocorrem ou ocorrem em baixa quantidade, ocasionado uma grande quantidade de valores nulos na matriz, que podem afetar seu valor representativo principalmente em imagens que apresentam padrões texturais característicos, visto que estas tem como característica padrões de repetição de primitivas tonais.

Considerando o número de níveis de cinza diferentes  $N_G = 8$  na geração da matriz de coocorrência, uma distância  $d = 1$  e uma angulação  $\theta = 0^\circ$ , o vetor de dados intervalares é composto pela concatenação de 6 outros vetores de dados intermediários de tamanho igual as dimensões da matriz de coocorrência.

O vetor  $V_1$  guarda os valores mínimos de cada coluna da matriz de coocorrência,  $V_2$  guarda os valores mínimos de cada linha, ambos ignorando o valor zero como mínimo,  $V_3$  e  $V_4$  são semelhantes ao primeiro e segundo porém invés do valor mínimo guardam o valor máximo,  $V_5$  e  $V_6$  guardam os valores medianos das colunas e linhas respectivamente, como representado no esquema abaixo em relação a matriz de coocorrência  $J$ :

$$\mathbf{J} = \begin{pmatrix} 3786 & 1903 & 357 & 59 & 12 & 1 & 0 & 0 \\ 1976 & 16912 & 6476 & 1627 & 319 & 32 & 2 & 0 \\ 223 & 6970 & 21479 & 10409 & 2482 & 398 & 17 & 0 \\ 70 & 1083 & 11128 & 33211 & 16595 & 3007 & 235 & 1 \\ 27 & 327 & 2136 & 17025 & 38096 & 16104 & 1597 & 7 \\ 8 & 82 & 353 & 2867 & 1615 & 32009 & 9455 & 75 \\ 3 & 2 & 38 & 237 & 1782 & 9294 & 16217 & 777 \\ 0 & 0 & 0 & 2 & 9 & 78 & 771 & 419 \end{pmatrix}$$

$$\mathbf{V}_1 = ( 3 \ 2 \ 38 \ 2 \ 9 \ 1 \ 2 \ 1 )$$

$$\mathbf{V}_2 = ( 1 \ 2 \ 17 \ 1 \ 7 \ 8 \ 2 \ 2 )$$

$$\mathbf{V}_3 = ( 3786 \ 16912 \ 21479 \ 33211 \ 38096 \ 32009 \ 16217 \ 777 )$$

$$\mathbf{V}_4 = ( 3786 \ 16912 \ 21479 \ 33211 \ 38096 \ 32009 \ 16217 \ 777 )$$

$$\mathbf{V}_5 = ( 48.5 \ 705 \ 1246.5 \ 2247 \ 2132 \ 1702.5 \ 503 \ 4 )$$


$$\mathbf{V}_6 = ( 35.5 \ 973 \ 1440 \ 2045 \ 1866.5 \ 1610 \ 507 \ 5.5 )$$

O vetor de dados intervalares será constituído da concatenação dos vetores intermediários  $V_1, V_2, V_3, V_4, V_5$  e  $V_6$  em um único vetor seguindo esta mesma ordem de disposição. Aplicando esse processo teremos um vetor resultante de tamanho 48 que será utilizado como dado simbólico intervalar no processo de classificação proposto, esse vetor será gerado para cada elemento da base de dados, esses vetores serão passados como entrada no algoritmo FKCN para dados intervalares, de forma que cada vetor representa o elemento do qual ele foi extraído na base de dados.

O Algoritmo FKCN para dados intervalares recebe os dados intervalares gerados a partir da matriz de coocorrência como entrada iniciando seu processo de clusterização utilizando distância euclidiana para o cálculo das distâncias entre os *Clusters*, especificando o número de *Clusters* a serem formados igual ao numero de classes da base de


imagens, no caso da base *UIUC* que apresenta 25 classes e utilizando o critério de votação, onde é verificada as classes da base imagens a qual os elementos presentes em um *Cluster* pertencem, a classe que aparece mais vezes é eleita representante daquele cluster, assim comparamos o resultado com a clusterização ideal onde todos os elementos de de uma classe estão agrupados em único cluster de modo que temos um cluster para cada classe. A variedade de texturas presentes na base de dados é mostrado na Figura 1.

Figura 1 – Diferentes amostras do banco de imagens UIUC.



A partir dessa comparação podemos extrair o Índice de Rand Corrigido (CR) (HUBERT; ARABIE, 1985) que mensura o nível de similaridade entre dois *Clusters*, um índice que tem como valor mínimo zero, significando que dois clusters discordam em todos os pontos que os formam, e valor máximo igual a um o que implica que dois *Clusters* são exatamente iguais. A partir do índice de Rand podemos medir a qualidade do agrupamento e por consequência a capacidade discriminativa dos dados intervalares criados em representar de maneira eficiente as características únicas de uma imagem.

Figura 2 – Arquitetura do processo de obtenção e avaliação dos dados intervalares






## RESULTADOS E DISCUSSÃO

Foi utilizado o *software* Octave para o desenvolvimento do projeto. Na execução final do experimento utilizando todas as 1000 imagens da base UIUC agrupadas em 25 classes, com o critério de 15 repetições chegamos ao valor de índice de Rand que varia entre 0.20 e 0.28 convergindo para valores em torno de 0.25

Esse valor significa que ao fim da clusterização os dados simbólicos extraídos a partir das matrizes coocorrência possibilitaram agrupar em torno de 25% dos elementos da base de dados nas respectivas classes as quais esses elementos pertencem. O resultado obtido pode ser considerado apropriado dentro do domínio da pesquisa, visto que a base de dados *UIUC* é considerada uma base de difícil identificação por métodos não supervisionados de classificação.

Em uma realização reduzida do experimento, utilizando apenas as duas primeiras classes da base de imagens com 15 repetições de Monte Carlo, foi observado uma grande sobreposição de dados, isto é elementos de classes diferentes com conjunto de características semelhantes. Isso ocorre devido a natureza dos elementos da base apresentarem padrões texturais e outras primitivas tonais em comum, uma fator que persistiu na extração dos dados simbólicos. Temos como hipótese que a sobreposição de dados pode ser a principal razão que pode ter influenciado na representatividade dos dados e por consequência no processo de agrupamento do algoritmo na execução completa do experimento, sobreposição essa que pode estar ocorrendo de forma múltipla entre varias classes da base de imagens.

Figura 3 – Projeção dos Dados Intervalares extraídos das duas primeiras classes da base *UIUC*



## **CONCLUSÃO**

Com os resultados obtidos pudemos concluir que a utilização de dados simbólicos como descritores baseados em textura, pode ser caracterizada como uma abordagem promissora na recuperação e indexação de imagens por conteúdo, a partir utilização desse novo tipo de dado foi possível desenvolver uma melhor modelagem dos dados os tornando mais compactos e significativos. Porém ainda é preciso eliminar uma ampla gama de obstáculos para o aperfeiçoamento do método, como por exemplo problemas de sobreposição e representatividade dos dados, dessa forma a criação de mecanismos que trabalhem de maneira a reduzir a similaridade entre os dados no processo de classificação pode levar a um grande progresso no desenvolvimento de técnicas de descrição baseada em dados simbólicos.

## **AGRADECIMENTOS**

Aos meus pais, pelo amor, incentivo e apoio incondicional. Ao professor Carlos Wilson Dantas de Almeida, pela orientação, apoio e confiança. O presente trabalho foi realizado com apoio do CNPq, Conselho Nacional de Desenvolvimento Científico e Tecnológico - Brasil no programa PIBIC/UFCG.

## REFERÊNCIAS

ALMEIDA, C. W. D. de; SOUZA, R. M. C. R.; CANDEIAS, A. L. B. Fuzzy kohonen clustering networks for interval data. **Neurocomputing**, Elsevier Science Publishers B. V., Amsterdam, The Netherlands, The Netherlands, v. 99, p. 65–75, 2013. ISSN 0925-2312.

ARANDJELOVIĆ, R.; ZISSERMAN, A. Three things everyone should know to improve object retrieval. In: **IEEE Conference on Computer Vision and Pattern Recognition**. [S.l.: s.n.], 2012.

BEZDEK, J. C. **Pattern Recognition with Fuzzy Objective Function Algorithms**. Norwell, MA, USA: Kluwer Academic Publishers, 1981. ISBN 0306406713.

BEZDEK, J. C.; TSAO, E. C.-K.; PAL, N. R. Fuzzy kohonen clustering networks. In: **Proc. of the First IEEE Conference on Fuzzy Systems, 1992**. San Diego, USA: [s.n.], 1992.

BOCK, H.-H.; DIDAY, E. **Analysis of Symbolic Data: Exploratory Methods for Extracting Statistical Information from Complex Data**. Secaucus, NJ, USA: Springer-Verlag, 2000. ISBN 978-3540666196.

HUBERT, L.; ARABIE, P. Comparing partitions. **Journal of Classification**, v. 2, n. 1, p. 193–218, 1985.

KOHONEN, T. **Self-Organizing Maps**. 3rd edition. ed. [S.l.]: Springer-Verlag, 2001.

LAZEBNIK, S.; SCHMID, C.; PONCE, J. A sparse texture representation using local affine regions. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, IEEE Computer Society, Washington, DC, USA, v. 27, n. 8, p. 1265–1278, ago. 2005. ISSN 0162-8828.

LEW, M. S. (Ed.). **Principles of Visual Information Retrieval (Advances in Computer Vision and Pattern Recognition)**. [S.l.]: Springer, 2010.

OUSSALAH, M. Content based image retrieval: Review of state of art and future directions. In: **Image Processing Theory, Tools and Applications, 2008. IPTA 2008. First Workshops on**. [S.l.: s.n.], 2008. p. 1–10.

TSAO, E. C.-K.; BEZDEK, J. C.; PAL, N. R. Fuzzy kohonen clustering networks. **Pattern Recognition**, v. 27, n. 5, p. 757–764, 1994.