

Classificação de Texturas Usando a Métrica de Centralidade *Closeness*

Whendell Magalhães
Laboratório de Modelagem e
Análise de Redes Complexas
Universidade Federal de Alagoas
Arapiraca - AL

Email: whendell.magalhaes@arapiraca.ufal.br

Fabiane Queiroz
Centro de Ciência Agrárias
Universidade Federal de Alagoas
Rio Largo - AL
Email: fabiane.queiroz@ceca.ufal.br

Raquel Cabral
Laboratório de Modelagem e
Análise de Redes Complexas
Universidade Federal de Alagoas
Arapiraca - AL
Email: raquel.cabral@arapiraca.ufal.br

Resumo—Neste artigo, propomos um método para descrição e classificação automática de texturas em imagens modeladas como Redes Complexas direcionadas e ponderadas. Dessa forma, métricas de redes complexas, especificamente o *closeness* e o grau de entrada, são utilizadas para gerar um vetor de características que descreve as informações de textura. Para validar o método, treinamos um classificador *k-Nearest Neighbors classifier* e comparamos os resultados obtidos com técnicas tradicionais e do estado da arte em descrição de texturas. Usamos a base de dados pública KTH-TIPS e a acurácia obtida pela nossa solução foi de 95,52% que supera as técnicas comparadas.

Abstract—In this paper, we propose a method for automatic description and classification of image texture. The images are modeled as weighted directed graphs. We use the centrality measure closeness and in-degree to generate a feature vector that describes the texture information. To validate the method, we train a *k-Nearest Neighbors classifier* and compare the obtained results with the Co-occurrence Matrix and Local Binary Patterns texture description techniques. For the experiments, we use the public dataset, KTH-TIPS. The accuracy of the proposed method is 95,52% that overcome the compared techniques.

I. INTRODUÇÃO

Texturas são padrões visuais complexos com características particulares que podem ser vistos como poderosos discriminantes em imagens [1]. O processo de classificação de texturas consiste em uma etapa fundamental em tarefas de Processamento Digital de Imagens (PDI) e de Visão Computacional (VC) e nas suas mais variadas aplicações, auxiliando em processos como a recuperação de imagem baseada em conteúdo [2] e a segmentação de objetos em imagens [3]. Um dos principais desafios em classificação de texturas consiste no desenvolvimento de um método eficiente, que seja, invariante a rotações, mudanças de escala e variações de iluminação nas imagens.

Redes Complexas são redes de estrutura irregular e abrangente que progridem dinamicamente [4], [5]. Tais redes são descritas por diversas métricas, que representam suas propriedades topológicas. Dessa forma, uma rede, na sua forma mais simples, é definida como um conjunto de vértices ligados aos pares por arestas.

O uso destas redes tem se mostrado eficiente para classificação de texturas [6]–[9]. Nesse caso, as imagens são caracterizadas por meio de métricas de Redes Complexas [10],

que descrevem suas características topológicas, sendo possível realizar uma análise específica para extrair características relevantes da imagem.

Assim, este trabalho propõe a utilização da métrica *Closeness Centrality*, ou *Closeness*, para extração de características e classificação de texturas, a partir da modelagem destas imagens como redes complexas.

O restante do trabalho está estruturado da seguinte forma: A revisão de literatura e discussão dos trabalhos correlatos é feita na Seção II. Na Seção III é descrito o método adotado para desenvolvimento deste trabalho. Os resultados são apresentados e discutidos na Seção IV e por fim, apresentamos as conclusões do trabalho na Seção V.

II. TRABALHOS RELACIONADOS

Na literatura, diversos trabalhos propõem métodos para classificação de texturas e extração de características em imagens. Dentre as abordagens mais tradicionais, destacam-se a técnica baseada no uso de matriz de co-ocorrência (*Gray Level Co-occurrence Matrix*–GLCM) [11] e a técnica de Padrões Binários Locais (*Local Binary Patterns*–LBP) [12]. Em geral esses métodos baseiam-se na detecção de padrões em imagens ao se aplicar filtros diretamente sobre valores de níveis de cinza de uma imagem.

Atualmente, as Redes Complexas vêm sendo usadas para este problema. Os trabalhos de Backes et al. [6] e Backes et al. [7] propõem dois métodos baseados em caminhadas determinísticas (*deterministic walks*) para geração das redes; no primeiro utiliza-se uma abordagem baseada na distribuição de probabilidade conjunta em histogramas com o objetivo de extrair as características das texturas; enquanto o segundo utiliza medidas de posição estatística (*statistical position*) e dispersão (*dispersion*). Nesse contexto, vale destacar os métodos de Gonçalves et al. [8] e Couto et al. [9]. Ambos os trabalhos usam técnicas baseadas em caminhadas, que são feitas com base nos valores dos graus de entrada (*In-Degree Centrality*) dos vértices da rede, nesse caso, o grau é considerado uma medida de centralidade. Afim de fazer uma análise sobre os valores de grau obtidos, Gonçalves et al. [8] utilizam um algoritmo de caminhos aleatórios (*random*

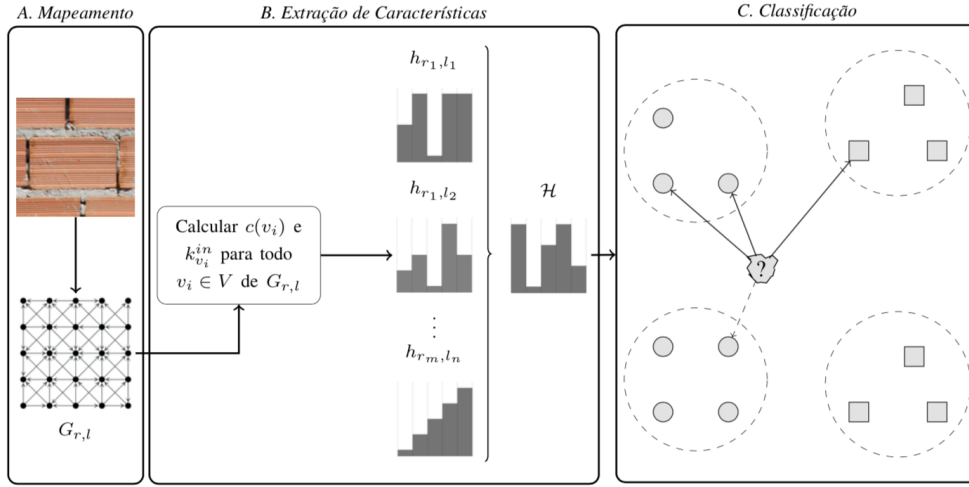


Figura 1. Classificação de texturas usando a métrica de centralidade *Closeness* em imagens modeladas como Redes Complexas.

walks), já Couto et al. [9] utilizam um algoritmo de caminhos determinísticos.

Os trabalhos citados anteriormente mostram-se eficientes, contudo eles abordam o problema da extração de características e classificação de texturas considerando aspectos locais da rede. Entretanto, diferentemente de descritores locais, que são usados para propósitos de identificação e reconhecimento em imagens; descritores globais são mais comumente utilizados em problemas de detecção, descrição e classificação de objetos em imagens. A exemplo de recursos globais comumente aplicados na descrição de texturas, tem-se os previamente citados LBP e GLCM. A combinação de recursos globais e locais melhora a precisão do processo de descrição e classificação.

Neste trabalho, propomos um método que utiliza o *Closeness* (descriptor global) e o grau de entrada do vértice (descriptor local) para análise da rede, em detrimento do uso de caminhadas. Dessa forma, realizamos uma análise do estado global da rede e das relações de cada vértice com todos os outros vértices.

III. CLASSIFICAÇÃO DE TEXTURAS USANDO O *Closeness*

A Figura 1 apresenta uma visão geral do método proposto, que consiste nas seguintes etapas: (A) Mapeamento, (B) Extração de Características e (C) Classificação. Estas etapas serão descritas em mais detalhes nas seções a seguir.

A. Mapeamento

O processo de mapeamento da imagem para uma rede foi realizado com base no método proposto por Gonçalves et al. [8] que consiste na transformação da imagem em um conjunto \mathcal{G} de grafos $G = (V, E)$ direcionados e ponderados, onde cada vértice $v_i \in V$ é um pixel da imagem, gerando dessa forma um grafo totalmente desconexo. Em seguida as arestas são criadas seguindo a Equação 1:

$$e_{v_i, v_j} = \begin{cases} I(p_i) - I(p_j), & \text{se } \delta(p_i, p_j) \leq r \\ \text{NaN}, & \text{caso contrário} \end{cases} \quad (1)$$

onde $I(p_i)$ refere-se ao valor de intensidade de um dado pixel i e r refere-se ao valor do raio. Dois vértices conectam-se, se a Distância Euclidiana $\delta(p_i, p_j)$ entre os pixels p_i e p_j for menor ou igual a r . O peso da aresta é definido como a diferença de intensidade dos pixels correspondentes aos vértices conectados.

Uma vez que os vértices estejam conectados, é realizada uma operação de limiarização sobre o conjunto de arestas E , como descrito na Equação 2. Essa operação tem como finalidade descartar arestas com pesos não positivos e com pesos acima de um dado limiar l . Nesta etapa, os pesos das arestas são definidos como o complemento da diferença de intensidade, para que as arestas que representam alta variação de intensidade tenham um peso baixo e as arestas que representam baixa variação tenham um peso alto. Considerando que o valor máximo da diferença de intensidade $I(p_i) - I(p_j)$ é de 255, adotamos o valor 256 na Equação 2 para que não existam arestas com peso $e_{v_i, v_j} = 0$.

$$e_{v_i, v_j} = \begin{cases} 256 - e_{v_i, v_j}, & \text{se } 0 < e_{v_i, v_j} \leq l \\ \text{NaN}, & \text{caso contrário} \end{cases} \quad (2)$$

A modelagem de diferentes redes a partir da variação dos parâmetros raio (r_1, r_2, \dots, r_m) e limiar (l_1, l_2, \dots, l_n) permite analisar diferentes estados da rede para uma mesma imagem e, a partir destes estados, estudar a dinâmica da topologia da rede. Sendo assim, é gerado, para uma dada imagem, um conjunto de redes $\mathcal{G} = \{G_{r_1 l_1}, G_{r_1 l_2}, \dots, G_{r_1 l_n}, G_{r_2 l_1}, G_{r_2 l_2}, \dots, G_{r_2 l_n}, \dots, G_{r_m l_n}\}$. A etapa A da Figura 1 ilustra o processo de mapeamento de uma imagem para um grafo $G_{r, l}$.

B. Extração de Características

A etapa de extração de características é iniciada a partir do cálculo do *Closeness* para todos os vértices de cada rede de $G_{r, l} \in \mathcal{G}$, como ilustrado na etapa B da Figura 1. A Figura 2 ilustra uma imagem e sua representação em cores de acordo

com o valor do *Closeness*, quanto maior o valor da métrica mais claro será o pixel.




Figura 2. Comparação entre a imagem de entrada e a representação gerada a partir dos valores de *Closeness*.

Na teoria de Redes Complexas, as métricas de centralidade são indicadores da importância de um vértice em uma rede. De modo geral estas métricas levam em consideração a relação de um vértice para com todos os outros vértices que compõem a rede.

Neste trabalho, utilizamos as métricas de centralidade Grau de entrada (de amplitude local) e *Closeness* (de amplitude global). Em uma rede dirigida, o Grau de entrada do vértice v_i é definido pelo número de arestas que incidem nele. O *Closeness* [13] é uma métrica baseada em caminhos, sendo calculado como o inverso da soma das distâncias Geodésicas entre um vértice e todos os outros vértices da rede, matematicamente definido por $c(v_i) = \frac{1}{\sum_j d(v_i, v_j)}$. Para permitir a

aplicação do *Closeness* em grafos desconexos, calculamos a métrica como a média harmônica destas mesmas distâncias, matematicamente definida por $c(v_i) = \sum_{j \neq i} \frac{1}{d(v_i, v_j)}$, em que $d(v_i, v_j)$ indica a distância geodésica entre v_i e v_j . Tal escolha se deu para evitar valores de centralidade iguais a zero em vértices desconexos. Desta forma, o *Closeness* indica o quão próximo um vértice está dos demais vértices da rede.

Para avaliar o impacto da utilização dos pesos na descrição das texturas, a métrica foi calculada de duas formas: uma com pesos e_{v_i, v_j} definidos pela Equação 1 e outra em que consideramos os pesos $e_{v_i, v_j} = 1$ para todas as arestas.

Após calcular os valores de *Closeness* para todos os grafos de $G_{r,l} \in \mathcal{G}$, são gerados os histogramas que correlacionam os valores de *Closeness* $c(v_i)$ com o grau de entrada $k_{v_i}^{in}$ para todos os vértices de $G_{r,l} \in \mathcal{G}$. O histograma para cada grafo é calculado de acordo com a Equação 3, como proposto por Gonçalves et al. [8].

$$h_{r,l} = \begin{cases} \sum_{v_i \in V} c_{r,l}(v_i), & \text{se } k_{v_i}^{in} = \kappa \\ 0, & \text{caso contrário,} \end{cases} \quad (3)$$

em que $\kappa = [k_{\min}^{in}, k_{\max}^{in}]$. A partir dos histogramas $h_{r,l}$ define-se o vetor de características $\mathcal{H}_r = \{h_{r,l_0}, h_{r,l_1}, \dots, h_{r,l_n}\}$, concatenando os histogramas para um mesmo valor de raio (Figura 1). Por fim, obtém-se o vetor de características final $\mathcal{H} = \{\mathcal{H}_{r_0}, \dots, \mathcal{H}_{r_n}\}$ para os diferentes valores de raio.

C. Classificação

Os vetores de características gerados para cada imagem na etapa *B* são utilizados em um processo de classificação. Assim, utilizamos o algoritmo de classificação *K* vizinhos mais próximos, como ilustrado na etapa *C* da Figura 1. Optamos pela utilização de um algoritmo de classificação mais simples para evidenciar a robustez do método proposto quanto a etapa de extração de características.

Utilizamos junto ao classificador o método de validação cruzada *k-fold* para separar os conjuntos de treinamento e teste. A acurácia do método foi calculada a partir da média aritmética da acurácia do classificador para cada subconjunto.

IV. RESULTADOS E DISCUSSÃO

Nesta seção, nós avaliamos o desempenho do método proposto quando comparado aos métodos GLCM [11], LBP [12] e o método apresentado em Gonçalves et al. [8]. Os experimentos foram conduzidos na base de imagens de domínio público KTH-TIPS [14] que é formada por imagens de 200×200 pixels, de 10 materiais diferentes e cada material com 80 imagens, totalizando 800 imagens. Todas elas obtidas a partir de diferentes condições de iluminação, posicionamento de câmera e escala. A Figura 3 mostra duas das 10 classes de texturas que podem ser encontradas nesta base.




Figura 3. Amostras de texturas da base KTH-TIPS [14].

Tendo em vista que a base possui um total de 800 imagens e que o tempo de processamento para cada imagem original seria em média 70 minutos, consideramos, para este conjunto de testes, cortes das imagens de 100×100 pixels, resultando em um tempo de processamento médio de 20 minutos por imagem. Os experimentos foram realizados em uma máquina com 2 processadores Intel® Xeon® E5-2670 @ 2.60GHz 20MiB L3 cache funcionando em paralelo com 8 núcleos e 16 threads cada, 8 pentes de 16GiB DIMM DDR3 1600 MHz, totalizando 128GB de memória RAM e Sistema Operacional GNU/Linux Debian 3.16.51-3+deb8u1. Não foram utilizados recursos de GPU neste processo.

Os algoritmos foram implementados na linguagem Python 3.6.5, usando as bibliotecas graph-tools 2.26 [15] para modelagem dos grafos e cálculo do *Closeness* e scikit-learn 0.19.1 [16] para classificação.

Os parâmetros utilizados na simulação são o raio r e o limiar l . Os valores de raio r foram selecionados pela maximização do valor de acurácia do

Tabela I
RESULTADOS EXPERIMENTAIS USANDO A BASE KTH-TIPS

Método	# Características	Acurácia Média	Desvio Padrão
Matriz de coocorrência (GLCM)	24	76,50 %	05,09 %
Padrões binários locais (LBP)	18	90,00 %	04,47 %
Gonçalves et al. [8]	816	90,77 %	00,50 %
Método proposto - com pesos	2688	94,99 %	00,43 %
Método proposto - sem pesos	2688	95,52 %	00,41 %

classificador para diferentes intervalos de raios escolhidos $\{\sqrt{1}, [\sqrt{1}, \sqrt{2}], [\sqrt{1}, \dots, \sqrt{3}], \dots, [\sqrt{1}, \dots, \sqrt{16}]\}$, como pode-se observar na Figura 4. O conjunto de valores de limiar $\mathcal{L} = \{l_0, l_1, \dots, l_j, \dots, l_n\}$, foram definidos de acordo com Gonçalves et al. [8]. Neste caso, o conjunto de valores para o limiar é definido pela expressão $l_j = l_0 + x \times l_i$, em que $l_0 = 10$ é o limiar inicial, $l_i = 50$ é o valor do incremento e $x \in \{0, 1, 2, 3, 4, 5\}$ é o número de iterações, assim temos $\mathcal{L} = \{10, 60, 110, 160, 210, 260\}$.




Figura 4. Avaliação da acurácia do classificador em função do intervalo para valores de raio escolhido.

A Tabela I apresenta o número de características extraídas por cada método testado, o valor da acurácia da classificação e o desvio padrão. Como pode ser visto, nosso método obteve um resultado superior aos demais métodos com a acurácia de 95,52% quando não consideramos os pesos para cálculo do *Closeness*. Para os grafos ponderados, obtivemos uma acurácia de 94,99%, pois ainda que o peso acrescente informação sobre a imagem, os parâmetros utilizados não foram parâmetros ótimos.

V. CONCLUSÃO E TRABALHOS FUTUROS

Neste trabalho, propusemos um método para descrição e classificação de texturas utilizando a métrica de centralidade *Closeness* em imagens modeladas como Redes Complexas. Os resultados apontam a viabilidade do uso do método de classificação proposto, que atingiu uma acurácia de 95,52% para grafos não ponderados, sendo superior aos métodos comparados. Como trabalhos futuros, pretendemos identificar os parâmetros ótimos para diferentes bases, utilizar recursos de GPU afim de diminuir o tempo decorrido na experimentação e avaliar a viabilidade de utilização de outras métricas de redes complexas para classificação de texturas.

AGRADECIMENTOS

Os autores agradecem o apoio do Programa Institucional de Bolsas de Iniciação Científica (PIBIC) da Universidade Federal de Alagoas (UFAL) e a Fundação de Amparo à Pesquisa do Estado de Alagoas (FAPEAL).

REFERENCES

- [1] J. Zhang, J. Liang, C. Zhang, and H. Zhao, "Scale invariant texture representation based on frequency decomposition and gradient orientation," *Pattern Recognition Letters*, vol. 51, pp. 57 – 62, 2015.
- [2] P. S. Hiremath and J. Pujari, "Content based image retrieval using color, texture and shape features," in *15th International Conference on Advanced Computing and Communications (ADCOM 2007)*, 2007, pp. 780–784.
- [3] C.-H. Lin, M.-D. Hsiao, and W.-T. Lin, "Object-based image segmentation and retrieval for texture images," *The Imaging Science Journal*, vol. 63, no. 4, pp. 220–234, 2015.
- [4] R. S. Cabral, A. C. Frery, and J. A. Ramírez, "Variability analysis of complex networks measures based on stochastic distances," *Physica A: Statistical Mechanics and its Applications*, vol. 415, pp. 73 – 86, 2014.
- [5] S. Boccaletti, V. Latora, Y. Moreno, M. Chavez, and D.-U. Hwang, "Complex networks: Structure and dynamics," *Physics Reports*, vol. 424, no. 4, pp. 175 – 308, 2006.
- [6] A. R. Backes, W. N. Gonçalves, A. S. Martinez, and O. M. Bruno, "Texture analysis and classification using deterministic tourist walk," *Pattern Recognition*, vol. 43, no. 3, pp. 685–694, 2010.
- [7] A. R. Backes, A. S. Martinez, and O. M. Bruno, "Texture analysis using graphs generated by deterministic partially self-avoiding walks," *Pattern Recognition*, vol. 44, no. 8, pp. 1684–1689, 2011.
- [8] W. N. Gonçalves, N. R. da Silva, L. da Fontoura Costa, and O. M. Bruno, "Texture recognition based on diffusion in networks," *Information Sciences*, vol. 364, no. C, pp. 51–71, 2016.
- [9] L. N. Couto, A. R. Backes, and C. A. Barcelos, "Texture characterization via deterministic walks' direction histogram applied to a complex network-based image transformation," *Pattern Recognition Letters*, vol. 97, pp. 77 – 83, 2017.
- [10] O. Cuadros, G. Botelho, F. Rodrigues, and J. B. Neto, "Segmentation of large images with complex networks," in *2012 25th SIBGRAP Conference on Graphics, Patterns and Images*, 2012, pp. 24–31.
- [11] R. M. Haralick, K. Shanmugam, and I. Dinstein, "Textural features for image classification," *IEEE Transactions on Systems, Man, and Cybernetics*, vol. SMC-3, no. 6, pp. 610–621, 1973.
- [12] T. Ojala, M. Pietikäinen, and D. Harwood, "A comparative study of texture measures with classification based on featured distributions," *Pattern Recognition*, vol. 29, no. 1, pp. 51 – 59, 1996.
- [13] A. Bavelas, "Communication patterns in task-oriented groups," *Journal of the Acoustical Society of America*, vol. 22, pp. 725–730, 1950.
- [14] M. Fritz, E. Hayman, B. Caputo, and J.-O. Eklundh, "The kthtips and kth-tips2 databases."
- [15] T. P. Peixoto, "The graph-tool python library," *figshare*, 2014.
- [16] F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, P. Prettenhofer, R. Weiss, V. Dubourg, J. Vanderplas, A. Passos, D. Cournapeau, M. Brucher, M. Perrot, and E. Duchesnay, "Scikit-learn: Machine learning in Python," *Journal of Machine Learning Research*, vol. 12, pp. 2825–2830, 2011.