

Relatório Final de Atividades

Reconhecimento de cultivares e plantas daninhas por imagem vinculado ao projeto Métodos para análise, caracterização e classificação de bioimagens.

Thullyo Radeli Castilho

Bolsista CNPq

Engenharia de Computação

Data de ingresso no programa: 08/2014

Prof(º). Dr(º). Fabrício Martins Lopes

Área do Conhecimento: 1.03.00.00-7 - ciência da computação

CAMPUS CORNÉLIO PROCÓPIO, 2015

THULLYO RADELI CASTILHO
FABRÍCIO MARTINS LOPES

RELATÓRIO FINAL DE INICIAÇÃO TECNOLÓGICA

Relatório Técnico do Programa de
Iniciação Tecnológica da Universidade
Tecnológica Federal do Paraná.

CORNÉLIO PROCÓPIO, 2015

SUMÁRIO

INTRODUÇÃO	2
REVISÃO BIBLIOGRÁFICA	2
MATERIAIS E MÉTODOS	6
RESULTADOS E DISCUSSÕES	8
CONCLUSÕES	11
REFERÊNCIAS	12

INTRODUÇÃO

Devido aos avanços das tecnologias atuais, em especial dos computadores, internet e *smartphones*, se tornou possível o uso e geração maciços de dados digitais, mais especificamente, conteúdos de mídia, como áudio, vídeo e imagens digitais [4].

Em especial, as imagens digitais apresentam diversas aplicações muito importantes, bem como diversos desafios a serem superados. Atualmente, ainda é extremamente comum a supervisão e classificação de imagens por pessoas, na maioria das vezes com o objetivo de se encontrar sentido ou padrões, para os mais diversos propósitos [3].

Na maioria das situações, a classificação de imagens por pessoas pode ser ineficiente e demorada, resultando em um processo muito custoso em termos financeiros. Portanto, a automatização deste processo se faz necessária e de extrema importância.

Mas para que se atinja o objetivo da automatização, há a necessidade primordial de se encontrar métodos de caracterização e classificação dessas imagens, que sejam mais eficientes o possível, e esta é uma busca de constantes descobertas, com diversos campos ainda a serem explorados [2, 6].

Considerando o contexto apresentado, o objetivo do presente trabalho foi estudar o método desenvolvido inicialmente por [14], o qual se trata de uma estratégia inovadora no processamento de imagens, consistindo da representação destas por meio de redes complexas e posterior extração de suas características, e por fim, treinamento e classificação por meio de classificadores já implementados na plataforma *Weka* [7]. Em relação aos resultados, destaca-se a realização em coautoria, baseado neste trabalho, de artigo aceito para publicação na conferência CIARP 2015, sob o título de *A Complex Network-Based Approach to the Analysis and Classification of Images*.

REVISÃO BIBLIOGRÁFICA

Imagens digitais. Enquanto uma imagem gravada em um filme pode ser representada eletronicamente por uma onda analógica contínua, a imagem digital é representada por valores digitais obtidos a partir de amostras da forma analógica [2].

Uma imagem digital monocromática é representada por um conjunto de elementos chamados de *pixels* (*picture elements* ou elementos de imagem) que contém valores representando o nível de intensidade de cinza de cada ponto da imagem, que são armazenados juntos, formando um mapa de *bits*, o qual reproduz a imagem digitalmente, conhecido como *bit-map* o qual pode ser observado na Figura 1.




Figura 1. Ilustração do mapa de bits de uma imagem digital monocromática em uma região de interesse de 10x10 pixels [2].

Cada pixel pode ser representado como uma função $f(x,y)$, como pode ser visto na Figura 2. Sendo $x=0\dots m-1$ e $y=0\dots n-1$, onde m é o total de *pixels* na horizontal da imagem e y o total de *pixels* na vertical. Para cada par ordenado há um valor L que é o nível de cinza daquele ponto(*pixel*), onde $L_{min} \leq f(x,y) \leq L_{max}$ e $L = L_{max} - L_{min} + 1$ [1].

Além dos níveis de cinza, uma imagem também pode ser colorida, e normalmente estas são representadas por uma combinação de valores de intensidade para cada pixel pelo sistema RGB, no qual se utiliza a combinação da intensidade das cores vermelho(R), verde(G) e azul(B) para se gerar a cor final do pixel [2].




Figura 2. Imagem digital como uma função $f(x,y)$ [2].

Distância euclidiana. Em matemática, distância euclidiana (ou distância métrica) é a distância entre dois pontos, que pode ser provada pela aplicação repetida do teorema de Pitágoras [2, 3]. Aplicando essa fórmula como distância, o espaço euclidiano torna-se um espaço métrico. A distância euclidiana entre os pontos, que para o presente projeto serão os *bins*, num espaço euclidiano n -dimensional, é definida como na Equação (1).

$$\sum_{i=0}^n \sqrt{(b_i - b_{i+1})^2} \quad (1)$$

onde:

- n é o número de *bins*, em todos os histogramas calculados utilizaram-se 256 (0 à 255 níveis de cinza).

- b_i é o valor do *bin* de número i .

Histogramas. De acordo com [2, 3], o histograma de uma imagem digital com níveis de intensidade da sua cor no intervalo $[0, L-1]$, sendo que para o presente trabalho $L=256$ como pode ser observado na Figura 3, é uma função discreta $f(i_n)=m_n$, onde i_n é um *n-ésimo* valor de intensidade e m_n a quantidade de pixels da imagem com a referida intensidade i_n .

$$[0, 255] = [0, 15] \cup [16, 31] \cup \dots \cup [240, 255]$$

$$\text{range} = \text{bin}_1 \cup \text{bin}_2 \cup \dots \cup \text{bin}_{n=15}$$

Figura 3. Composição de um histograma por *bins*, dado um *range* (intervalo) de cor [3].

Uma forma gráfica de representação de um histograma é mostrada na Figura 4, onde cada cor representa uma quantidade de pixels com determinada intensidade L , sendo, para um $L=256$ níveis de cinza, um *bin* ($b_{i=1...b_{16}}$) representaria um intervalo de 16 níveis de cinza.




Figura 4. Representação da composição de um histograma por *bins* na forma de intervalos [2].

Grafos. Grafos são estruturas abstratas que representam conjuntos de elementos denominados vértices com suas relações de interdependência, também chamadas de arestas. Matematicamente, se denominarmos n o conjunto de vértices e m o conjunto de arestas, um grafo pode ser representado por $G = (n, m)$ [13].

Redes complexas. Este termo refere-se a grafos que apresentam uma estrutura topográfica não trivial, sendo composto por um conjunto de vértices interligados por meio de arestas. Um grafo só será uma rede complexa se ele apresentar certas propriedades topográficas que não estão presentes em grafos simples [9].

Medidas de redes complexas. As redes complexas apresentam diversas propriedades que podem ser úteis para análises nos mais diversos aspectos e propósitos, como no presente trabalho, tais medidas são utilizadas para caracterização e classificação de imagens [10, 11, 15]. As medidas utilizadas no presente trabalho são: grau de vértice, grau médio, histograma de graus, caminho mínimo médio, centralidade média, transitividade, número de comunidades e os motifs.

Grau de vértice. O grau de um vértice é a quantidade de vizinhos que ele possui, sendo que tais vizinhos precisam necessariamente estar conectados por meio de arestas à tal vértice [10].

Grau médio. O grau médio de um grafo é a soma do número de arestas dividido pela soma do número de vértices deste mesmo grafo [10].

Histograma de conectividade. Um histograma de conectividade $p(c)$ representa quantos vértices existem em cada conectividade c da rede complexa [10].

Caminho mínimo. O caminho mais curto entre os vértices v e w de um grafo, é aquele que acumula o menor número de arestas entre tais vértices [13].

Caminho mínimo médio. O caminho mínimo médio é a média de todos os caminhos mínimos da rede.

Centralidade. Quantifica o número de vezes em que um vértice se encontra no caminho mais curto entre dois outros vértices [13, 10].

Centralidade média. É a média da soma das centralidades da rede.

Transitividade. Também chamada de *clustering*, é a probabilidade de que se dois vértices estão conectados à um terceiro, então eles também estarão conectados entre si [13].

Número de comunidades. Uma comunidade de um grafo é um subgrafo no qual os vértices estão conectados fortemente. Existem diferentes formas de se quantificar um subgrafo, mas a definição mais comum é a de que todos os nós de uma comunidade estejam conectados entre eles mesmos. Tal abordagem faz necessária a definição de um *clique*, o qual é um subgrafo completo em que cada vértice é adjacente a todos os outros vértices [10].

Motifs. Motifs são pequenos subgrafos conectados que podem ocorrer em grafos direcionados ou não, cuja frequência de ocorrência é significativamente maior do que em suas versões geradas aleatoriamente [15].

Classificadores. Em reconhecimentos de padrões, classificador é um conjunto ordenado de categorias relacionadas usadas para agrupar dados de acordo com suas similaridades. Um classificador é, portanto, um algoritmo que dada várias entradas irá agrupá-las através do reconhecimento de suas características em comum únicas, onde para se chegar a um bom classificador faz-se uso de técnicas como o treinamento [3, 5].

Através da visualização das características encontradas para uma determinada imagem, pode-se concluir, considerando um exemplo em que ela possua apenas um tomate e uma cenoura, uma forma precisa de se diferenciar tais vegetais é se utilizar das diferenças entre suas componentes RGB. Mas como se pretende utilizar resultados que sejam válidos também para outras imagens, que por sua vez podem conter diversas diferenças, há a necessidade de se encontrar um padrão comum à maioria das imagens que contenham tais objetos de interesse, o que é normalmente feito através da extração de características e posterior classificação de um conjunto de imagens, a este processo denomina-se treinamento [3].

Framework WEKA. O WEKA (*Weikato Environment for Knowledge Analysis*) é uma coleção de algoritmos para aprendizado de máquina [7]. O framework possui um tipo de arquivo único para utilização, chamado de *arff*, o qual é constituído de um arquivo de texto ASCII para descrever um conjunto de atributos, os quais serão utilizados posteriormente por classificadores para a geração dos resultados finais.

Validação cruzada. A divisão de um *dataset* entre diversos conjuntos de dados, alguns para treinamentos e outros para testes, se faz necessária para evitar resultados falsos, os

quais seriam obtidos ao se testar os classificadores sobre a mesma base de dados sobre as quais eles construíram o seu modelo de classificação. Considerando-se que o estudo seja sobre um conjunto grande de dados o suficiente para ser dividido por n partes mais ou menos iguais entre dados para treinamento e teste e, ainda gerar bons resultados, este processo resultaria em uma validação cruzada de n -vias[3].

iGraph. O *iGraph* é um pacote para o *software* R, o qual contém dezenas de algoritmos já implementados para a geração e análise de grafos [17]. Em especial, o pacote possui rotinas para extração de características, tais como transitividade, caminhos mínimos, número de comunidades, etc.

MATERIAIS E MÉTODOS

Materiais utilizados. Para a realização do estudo proposto, foram utilizadas as linguagens de programação C++ [8], Java e R. Os Ambientes de Desenvolvimento Integrado (*IDE – Integrated Development Environment*) utilizados foram o Visual Studio 2013, para a linguagem C++, o NetBeans 8, para Java, e o Rstudio, para a edição de scripts R.

O método estudado já estava com todos os algoritmos implementados como em [14], tanto em Java, para a extração das redes complexas a partir das imagens de entrada, como o script em R, o qual realiza a extração das características da rede gerada por esse.

O *hardware* utilizado tanto para o desenvolvimento como para processamento dos dados foi um computador do tipo desktop, o qual possui processador Intel Core i7 de 3,00GHz, 32GB de memória RAM, HD de 1TB e monitor LCD de 21”.

Dataset KTH-TIPS. Obtido em [18], é um banco de imagens, o qual é uma extensão do banco de imagens CURET. O KTH-TIPS consiste de 10 classes de textura com 81 imagens cada. As imagens possuem tamanho de 200x200 pixels e foram capturadas em nove escalas, vistas sob três diferentes posições e direções de iluminação. A Figura 5 mostra alguns exemplos deste banco de imagens.




Figura 5. Imagens representativas do *dataset* KTH-TIPS.

Dataset Brodatz. Ele é composto por 112 imagens em níveis de cinza, com tamanho 640x640 pixels, sendo que cada imagem representa uma textura [16]. A Figura 6 apresenta algumas amostras deste banco de imagens.




Figura 6. Imagens representativas do banco de imagens Brodatz.

Tipo de pesquisa utilizada. A pesquisa realizada, de acordo com [1], foi de natureza aplicada e descritiva, objetivando o registro e a análise das características pertinentes ao método estudado, mais especificamente à sua utilização em dois estudos de caso. Tais estudos se deram através da aplicação dos algoritmos já descritos nos arquivos gerados e ainda não processados em [14], bem como a aplicação do método em um novo *dataset*.

Método estudado. O método consistiu na execução de 4 etapas principais: (1) geração de um grafo a partir da imagem; (2) extração de características deste grafo; (3) aprendizado e treinamento dos classificadores; (4) classificação dos dados pelos modelos gerados [14]. Um esquema representativo pode ser visto na Figura 7.

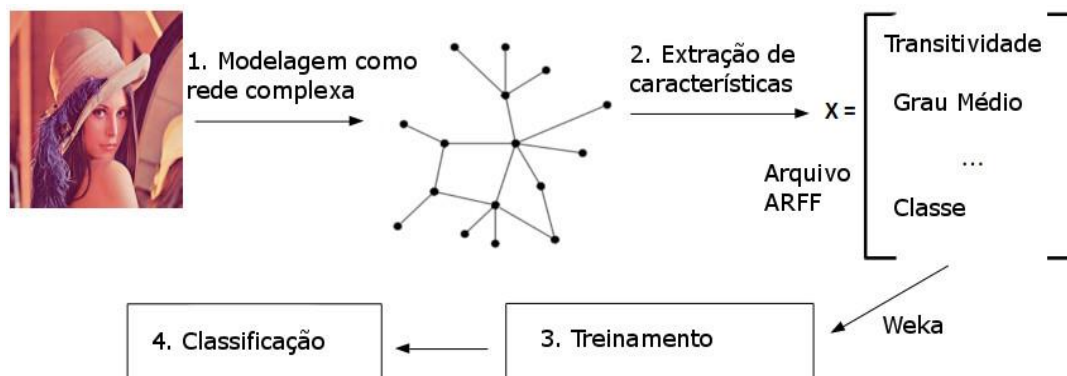


Figura 7. Diagrama esquemático do método estudado. Fonte: Adaptado de [14].

Em (1.), o algoritmo, que está implementado em Java, realiza a representação da imagem por meio de uma rede complexa. Para tanto, cada pixel passa a ser um vértice da rede, enquanto que na geração de arestas, foi utilizado o método de construção de adjacência de *lattice* conectada por raio, em que são conectados todos os vértices que representam pixels vizinhos que estejam dentro de um raio r [11].

Escolhido um pixel, é calculada a distância euclidiana em relação a seus vizinhos, caso essa distância não seja maior que $r = 5$, os dois vértices que representam os pixels analisados são conectados por uma aresta. Após a varredura de todos os pixels, é gerado um grafo não orientado, ponderado e com ausência de laços.

Para cada aresta do grafo final, é associado um peso, o qual é calculado utilizando-se as coordenadas e intensidades dos dois pixels que formaram tal aresta, de acordo com a Equação (2).

$$d(e)z(i - i'')^2 + (j - j'')^2 + (v_{ij} - v_{i''j''})^2 \forall e = (i, j), (i'', j'') \in E \quad (2)$$

Como o valor de $d(e)$ pode estar em uma grande escala de valores, é aplicada uma normalização através da Equação (3).

$$N(e) = \frac{d(e)}{255^2 + r^2} \quad (3)$$

Mas, mesmo após todos estes passos, o grafo apresenta um comportamento regular e, portanto, este não é reconhecido como uma rede complexa [14].

Então para que se possa extrair informações relevantes do grafo, é necessário realizar uma análise comportamental, mais precisamente de subgrafos derivados. Isso é feito através da aplicação de um limiar t no conjunto de arestas do grafo da imagem, resultando em um subconjunto em que cada aresta deste possui um peso menor que t . O valor de t é incrementado de forma regular, sendo de $t=0,005...0,165$, em intervalos de 0,005.

Inicia-se então (2.), em que há extração de características das redes complexas finais pelo *software* R. Após a geração dos vetores de características pelo R, eles são gravados em um arquivo *ARFF*, o qual será utilizado como entrada para o *WEKA*, iniciando-se o processo de aprendizado e treinamento (3.).

E, por fim, há a classificação (4.) dos dados de teste com base nos modelos gerados na etapa de anterior.

Experimentos. O primeiro experimento consistiu na classificação de dados que não puderam ser processados durante a pesquisa realizada em [14]. Esses dados são provenientes da aplicação do método descrito no *dataset* Brodatz.

Foram classificados os dados obtidos por meio de uma abordagem de clusterização do *dataset*, que resultou em 2 clusters, um de 50 e outro de 100 classes. Também foi realizada a classificação dos dados sem clusters, mas apenas com os classificadores Multilayer Perceptron (MP) e Support Vector Machine (SVM).

Em um segundo experimento, foi aplicada a metodologia estudada no *dataset* KTH-TIPS.

RESULTADOS E DISCUSSÕES

Em uma tentativa de se otimizar o desempenho dos softwares desenvolvidos em [14], os algoritmos para extração de características, os quais estavam implementados em script R, foram portados para a linguagem C++, utilizando-se da biblioteca *iGraph* para esta linguagem. Mesmo assim, optou-se por continuar utilizando as versões originais pois diversos problemas foram encontrados durante a realização do porte dos códigos. O principal fator, o desempenho, acabou sendo apenas tão rápido quanto ou, para a extração de determinadas características, mais lento que os algoritmos em script R.

Os resultados dos experimentos estão apresentados nas tabelas abaixo. Em relação à primeira parte dos experimentos, os resultados constam nas Tabelas 1 e 2, onde há os valores de performance obtidos originalmente por [14], utilizando-se os classificadores IBK, J48, Naive Bayes (NB) e Random Forest (RF), bem como aqueles obtidos neste trabalho, pela realização da classificação com MultiLayer Perceptron (MLP) e Support Vector Machine (SVM) [7].

Tabela 2. Resultados da classificação do *dataset* Brodats, sem cluster e sem seleção de atributos. Os resultados dos classificadores IBK, J48, NB e RF foram obtidos por [G], já o SVM e MLP foram obtidos por este trabalho. O * indica que não foi possível obter os resultados devido à falta de recursos computacionais.

Classificador	Precisão	Recall	F-Score	Área ROC	Acurácia
IBK	0,75	0,75	0,75	0,88	75,14
J48	0,67	0,67	0,67	0,85	67,00
NB	0,74	0,73	0,73	0,96	73,19
RF	0,76	0,75	0,75	0,97	75,28
SVM	0,64	0,64	0,63	0,82	64,08
MLP	*	*	*	*	*

Tabela 3. Resultados da classificação do *dataset* Brodats, sem cluster, com seleção de atributos. Os resultados dos classificadores IBK, J48, NB e RF foram obtidos por [G], já o SVM e MLP foram obtidos por este trabalho. O * indica que não foi possível obter os resultados devido à falta de recursos computacionais.

Classificador	Precisão	Recall	F-Score	Área ROC	Acurácia
IBK	0,80	0,80	0,80	0,90	79,93
J48	0,71	0,70	0,70	0,87	70,28
NB	0,80	0,80	0,79	0,99	79,61
RF	0,81	0,81	0,80	0,98	80,76
SVM	*	*	*	*	*
MLP	0,87	0,87	0,87	1,00	87,32

Considerando as Tabelas 2 e 3, o melhor resultado de classificação em termos de acurácia do *dataset* Brodats, sem clusters, foi conseguido pelo Multilayer Perceptron (MLP) com 87,32%, e, ao e considerar os outros valores, pode-se constatar que a seleção de atributos foi bastante impactante, melhorando consideravelmente os resultados.

Tabela 4. Resultados da classificação após do *dataset* Brodats, após cluster 50, sem seleção de atributos. Os resultados dos classificadores IBK, J48, NB e RF foram obtidos por [G], já o SVM e MLP foram obtidos por este trabalho. O * indica que não foi possível obter os resultados devido à falta de recursos computacionais.

Classificador	Precisão	Recall	F-Score	Área ROC	Acurácia
IBK	0,90	0,89	0,89	0,95	89,44
J48	0,77	0,76	0,76	0,90	76,33
NB	0,90	0,89	0,89	0,99	89,01
RF	0,88	0,87	0,87	0,99	87,24
SVM	0,55	0,57	0,54	0,78	56,59
MLP	*	*	*	*	*

Tabela 5. Resultados da classificação do *dataset* Brodats, após cluster 50, com seleção de atributos. Os resultados dos classificadores IBK, J48, NB e RF foram obtidos por [G], já o SVM e MLP foram obtidos por este trabalho.

Classificador	Precisão	Recall	F-Score	Área ROC	Acurácia
IBK	0,89	0,89	0,89	0,94	89,08
J48	0,77	0,77	0,77	0,90	76,98
NB	0,89	0,89	0,89	1,00	88,76
RF	0,88	0,87	0,87	0,99	87,31
SVM	0,50	0,51	0,48	0,75	50,79
MLP	0,90	0,90	0,90	1,00	89,81

Em relação às Tabelas 4 e 5, onde estão os resultados para o *dataset* Brodats com cluster 50, pode-se observar que a seleção de atributos não foi muito impactante, tendo resultados até mesmo piores que sem seleção, mas mesmo assim o melhor resultado geral foi com o Multilayer Perceptron (MLP) com 89,81% de acurácia.

Vale ressaltar que a comparação de resultados ficou ligeiramente comprometida devido aos problemas encontrados com o MLP.

Tabela 6. Resultados da classificação do *dataset* Brodats, após cluster 100, sem seleção de atributos. Os resultados dos classificadores IBK, J48, NB e RF foram obtidos por [G], já o SVM e MLP foram obtidos por este trabalho. O * indica que não foi possível obter os resultados devido à falta de recursos computacionais.

Classificador	Precisão	Recall	F-Score	Área ROC	Acurácia
IBK	0,86	0,86	0,86	0,93	85,62
J48	0,73	0,72	0,72	0,88	72,11
NB	0,87	0,86	0,86	0,99	86,41
RF	0,82	0,82	0,82	0,99	82,24
SVM	0,59	0,59	0,58	0,79	59,15
MLP	*	*	*	*	*

Tabela 7. Resultados da classificação do *dataset* Brodats, após cluster 100, com seleção de atributos. Os resultados dos classificadores IBK, J48, NB e RF foram obtidos por [G], já o SVM e MLP foram obtidos por este trabalho.

Classificador	Precisão	Recall	F-Score	Área ROC	Acurácia
IBK	0,86	0,86	0,86	0,93	85,84
J48	0,73	0,73	0,73	0,89	72,83
NB	0,87	0,86	0,86	1,00	86,09
RF	0,84	0,84	0,84	0,99	83,89
SVM	0,79	0,79	0,79	0,90	79,36
MLP	0,86	0,86	0,86	1,00	86,27

Analisando os resultados das Tabelas 6 e 7, o classificador Naive Bayes (NB) foi o que obteve a melhor acurácia geral, alcançando 86,41%. Mais uma vez, a seleção de atributos não alterou os resultados de forma significativa.

Tabela 8. Resultados da classificação do *dataset* KTH-TIPS, sem seleção de atributos.

O * indica que não foi possível obter os resultados devido à falta de recursos computacionais.

Classificador	Precisão	Recall	F-Score	Área ROC	Acurácia
IBK	0,51	0,51	0,50	0,73	50,61
J48	0,59	0,60	0,59	0,83	59,50
NB	0,47	0,40	0,38	0,82	39,63
RF	0,69	0,69	0,69	0,95	69,01
SVM	*	*	*	*	*
MLP	0,59	0,58	0,57	0,90	57,53

Tabela 9. Resultados da classificação do *dataset* KTH-TIPS, com seleção de atributos.

Classificador	Precisão	Recall	F-Score	Área ROC	Acurácia
IBK	0,58	0,58	0,58	0,77	58,02
J48	0,64	0,64	0,64	0,86	63,58
NB	0,45	0,37	0,41	0,81	42,22
RF	0,71	0,71	0,71	0,96	70,62
SVM	0,54	0,49	0,48	0,72	49,01
MLP	0,65	0,64	0,63	0,91	63,58

Comparando os resultados das Tabelas 8 e 9, as quais foram obtidas pelo processamento do *dataset* KTH-TIPS, o melhor valor obtido foi de 70,62% de acurácia, conseguido pelo classificador Random Forest (RF) e é também possível perceber que com a seleção foi possível obter resultados ligeiramente melhores.

Como resultado, houve também a realização em coautoria de um artigo já aceito para publicação, sob o título *A Complex Network-Based Approach to the Analysis and Classification of Images*, na CIARP – Conferência Ibero-americana em Reconhecimento de Padrões, que está em sua 20ª edição, a qual irá ocorrer entre os dias 9 e 12 de novembro de 2015, em Montevideo, Uruguay. Realizada todos os anos, a CIARP é a mais importante conferência ibero-americana em reconhecimento de padrões, visão computacional e multimídia.

CONCLUSÕES

No presente trabalho foram ampliados os estudos na área de processamento de imagens, mais especificamente a aplicação de um método que utiliza a representação de imagens por meio de redes complexas, prosseguindo à extração de suas características, treinamento e classificação.

Ao se considerar os desafios inerentes ao processamento de imagens e aqueles específicos do método estudado, pode-se concluir que os resultados atingidos foram

satisfatórios, sendo os melhores resultados encontrados no trabalho as acurácias de 89,81% por meio do MultiLayer Perceptron no *dataset* Brodatz e 70,62% no *dataset* KTH-TIPS, utilizando-se o Random Forest.

Dados os resultados e potenciais do presente trabalho, verifica-se a existência de diversas possibilidades para sua futura expansão. Os pontos sugeridos para melhoria seriam: aprimoramentos do método, tornando-o mais eficiente e robusto; aplicação deste em outros bancos de imagens; e por fim, um estudo mais aprofundado sobre as diversas implicações de cada característica extraída da rede complexa, de forma a se compreender seus efeitos individuais específicos na classificação de imagens por textura.

REFERÊNCIAS

- [1] NETTO, A. A. de O. **Metodologia da Pesquisa Científica**: Guia prático para apresentação de trabalhos acadêmicos. 3ª ed. Editora Atual. Florianópolis: Axcell Books, 2008.
- [2] GONZALEZ, R. C. **Processamento de Imagens Digitais**. 3ª ed. São Paulo: Edgard Blucher, 2000.
- [3] PARKER, J. R. *Algorithms for image processing and computer vision*. 2ª ed. Indianapolis: Wiley Publishing, Inc., 2011.
- [4] FILHO, W. P. P. **Multimídia**: conceitos e aplicações. 2ª ed. Rio de Janeiro: LTC, 2011.
- [5] CESAR, R. M.; Costa, L. F. *Shape classification and analysis: theory and practice*. 2ª ed. Flórida: CRC Press, 2009.
- [6] BISHOP, C. M. *Pattern recognition and machine learning*. Nova Iorque: Springer Science, 2006.
- [7] WAIKATO, U. O. *Weka data mining software in java*. Weka – The University of Waikato, Disponível em: <<http://www.cs.waikato.ac.nz/ml/weka/>>. Acesso em 02 set. 2014.
- [8] DEITEL, H. M.; DEITEL, P.J. **C++ como programar**. 5ª ed. São Paulo: Pearson Education do Brasil, 2006.
- [9] NEWMAN, M. E. *The structure and function of complex networks*. SIAM review, SIAM, v. 45, n. 2, p. 167–256, 2003.
- [10] BOCCALETTI, S. et al. *Complex networks: Structure and dynamics*. Physics Reports, v. 424, n. 4-5, p. 175–308, 2006. ISSN 0370-1573.
- [11] CASANOVA, D. **Redes complexas em visão computacional com aplicações em bioinformática**. Tese (Doutorado) — Universidade de São Paulo, 2013.
- [12] CORSO, G.; FOSSA, C. R.; OLIVEIRA, G. B. de. **Uma aplicação da teoria de redes a estilometria**: Comparando Machado de Assis e tribuna do norte. Revista Brasileira de Ensino de Física, SciELO Brasil, v. 27, n. 2, p. 389–393, 2005.
- [13] GOLDBARG, M. C.; GOLDBARG, E. **Grafos**: conceitos, algoritmos e aplicações. 1ª ed. São Paulo: Elsevier – Campus, 2012.
- [14] LIMA, G. V. L. **Uma abordagem baseada em redes complexas para a análise e classificação de imagens**. Trabalho de Conclusão de Curso – Universidade Tecnológica Federal do Paraná, 2014.
- [15] MILO, R. et al. *Network motifs: simple building blocks of complex networks*. Science, American Association for the Advancement of Science, v. 298, n. 5594, p. 824–827, 2002.
- [16] BRODATZ, P. *Textures: a photographic album for artists and designers*. [S.l.]: Dover, New York, 1966.

- [17] CSARDI, G.; NEPUSZ, T. *The igraph software package for complex network research*. InterJournal, Complex Systems, p. 1695, 2006. Disponível em: <<http://igraph.org>>.
- [18] HAYMAN, E.; CAPUTO, B.; FRITZ, M.; EKLUNDH, J.O. *On the significance of real-world conditions for material classification*. In: ECCV. vol. 3024, pp. 253–266, 2004.