

Redes complexas na extração de características em imagens de peixes

Alexander Scaranti¹, Ronaldo Bernardi¹

¹Universidade Paulista - UNIP

Resumo

Este trabalho apresenta uma abordagem sobre a análise de imagens utilizando as técnicas de Redes Complexas para a obtenção de similaridades entre imagens. Inicialmente serão extraídas as características da borda das imagens, as quais serão entendidas computacionalmente como matrizes. Através dessas matrizes serão geradas matrizes de adjacências, que serão utilizadas para a verificação das conexões dos vértices (pixels) das imagens. Extraída a matriz de adjacência, será realizada a extração do grau dos vértices para um limiar T e a extração do grau médio dos vértices. Na extração do grau dos vértices cada limiar será aplicado no cálculo e retornará uma matriz que será analisada com outras matrizes extraídas verificando a probabilidade de isomorfismo.

Palavras-chave: Extração de características, redes complexas, teoria dos grafos, grau dos vértices, matriz de adjacência.

Complex networks in the extraction of features from fish of images

Abstract

This paper presents an approach to image analysis using the techniques of Complex Networks for obtaining similarities between images. Initially, the features are extracted from the edge of images, which will be understood computationally as arrays. Through these matrices are generated adjacency matrices, which will be used to check the connections of the vertices (pixels) of images. Extracted from the adjacency matrix will be performed to extract the degree of the vertices to a threshold T and the extraction of the average degree of the vertices. In the extraction of the degree of the vertices each threshold is applied in the calculation and returns an array that will be analyzed with other matrices extracted by checking the likelihood of isomorphism.

Keywords: Feature extraction, complex networks, graph theory, degree of vertices, adjacency matrix.

Introdução

Com a ascensão tecnológica nas mais diversas áreas de pesquisa como Medicina e/ou Biologia, torna-se de extrema necessidade a realização mais acelerada de tarefas como identificação de espécies vegetais ou a verificação das características de doenças dos mais variados tipos. Com base nesses problemas, visando maior dinâmica em suas resoluções e também o auxílio aos profissionais do ramo, as pesquisas com Extração de Características de Imagens vêm ganhando espaço na contribuição para um processo mais acelerado e resultados mais exatos utilizando métodos como Transformada de Wavelets, Transformada de Fourier (COSTA; CESAR, 2000), Redes Complexas, entre outros. Neste trabalho, o estudo das Redes Complexas será de extrema importância, pois sua aplicação será essencial na extração das características, em que os resultados obtidos em cada imagem analisada fornecerão uma estrutura de dados que constituirá uma matriz. Cada elemento da matriz representará um pixel da imagem, contendo as cores e os níveis de cinza. A verificação de similaridade será facilitada com a utilização de matrizes e grafos. Cada grafo gerado terá uma quantidade de nós que serão entendidos como os dados das imagens e uma quantidade de arestas que serão interpretadas como as conexões com as regiões das imagens. A comparação dos grafos se dará por meio do isomorfismo, o qual analisa a quantidade de nós, arestas, se o grafo é dirigido ou não, entre outras características. Para se obter um maior número de resultados, a busca por similaridade será realizada em subgrafos por intermédio de métodos estatísticos de reconhecimento de padrões. Se a busca fosse realizada no grafo inteiro, seria necessário que tanto o grafo do banco de dados (já conhecido) quanto o grafo de consulta (conhecido em tempo real) fossem exatamente iguais.

Extração de características de imagens

As técnicas de análise de imagens e/ou extração de características utilizam as informações extraídas de imagens digitalizadas, tais como informações de cor, textura ou forma como conteúdo a ser compreendido através de uma matriz. Cada elemento da matriz é entendido como um pixel, que corresponde a uma coordenada da imagem (FALCÃO et al., 2004). O valor de cada pixel define a intensidade de luz e cor no setor da imagem (SCHWARTZ; PEDRINI, 2003), possibilitando assim, a comparação entre outras imagens visando a obtenção de características similares para a classificação em suas respectivas classes.

Métodos como a utilização do algoritmo genético podem ser utilizados para a extração das características. Os algoritmos genéticos são usados não só para a extração das características, mas também para outros processos de manipulação de imagens como: detecção de borda, segmentação e compressão.

Nas imagens onde consideraremos a característica cor como fator importante na busca de similaridade em imagens, a utilização de histogramas (SCLAROFF et al., 1997) e a métrica Euclidiana são bastante usuais para calcular a distribuição estatística da imagem. Os histogramas são ferramentas muito utilizadas em extração de características. Um exemplo da utilização de histograma (SCLAROFF et al., 1997) é a sua aplicação em uma imagem de exemplo e a comparação com os histogramas das imagens existentes no banco de dados. A comparação entre histogramas pode ser baseada na norma euclidiana (MATHIAS; CONCI, 1997). Na comparação, devem-se considerar informações baseadas em valores relativos e não absolutos. Isto é importante, pois nem sempre se tem imagens com mesmas dimensões e sim imagens que podem possuir similaridade através de

conexões em suas subclasses. Diversos estudos relacionados à extração de características de imagens têm utilizado o tema das Redes Complexas no processamento dos dados, utilizando-se dos mesmos para descrever as relações entre os objetos de uma imagem.

Redes Complexas

Entende-se por rede um conjunto de elementos conectados entre si (NEWMAN, 2003). Tais elementos podem ter relações dos mais variados tipos, onde apenas o estudo dos mesmos seria insuficiente para compreender o comportamento de toda a rede. É necessário fazer um levantamento detalhado com as características de cada elemento.

A interpretação da rede fica mais viável quando possui poucos elementos, como por exemplo, uma rede de computadores, onde cada computador tem suas configurações listadas, podendo assim, tirar certas conclusões a respeito da rede. Já quando se trata de uma rede com muito mais elementos, como as características extraídas de uma imagem, devemos considerar um grupo de elementos para poder chegar a uma conclusão e obter um resultado significativo (AIELLO et al., 2000).

Recentemente o estudo das redes começou a analisar o comportamento de redes com milhões de elementos, definindo desta forma, uma rede complexa. Uma rede de grande porte como a rede de seres vivos, depende de vários subgrupos, como o das espécies que, por sua vez, também depende de inúmeros outros subgrupos, para serem formadas, assim como uma imagem dividida em várias partes e/ou subgrupos. Esta classificação se deve ao fato de que estas redes de grande porte, formam estruturas complexas, gerando assim uma imprecisão na sua interpretação (ABERT; BARABÁSI, 1999).

Uma possível solução, para estas indefinições, é uma interação entre o estudo das Redes Complexas com a Teoria dos Grafos.

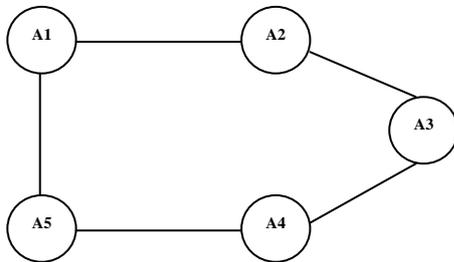
Teoria dos Grafos

A Teoria dos Grafos é o ramo da matemática que estuda o conjunto de elementos (nós ou vértices) interligados através de conexões (arestas ou edges), formando assim um grafo. Aplicando no mundo real, um grafo pode representar uma rede social, onde os nós são representados pelas pessoas e a relação entre elas representa as arestas. Um grafo pode também ser aplicado a um sistema de busca, onde deve ser encontrado o menor caminho até seu destino, de modo que a aplicação seja concretizada em tempo reduzido. Um caminho é uma seqüência de nós ($A_1, A_2, A_3 \dots A_n$) conectados por arestas ((e_1, e_2) , (e_2, e_3) , ..., (e_{n-1}, e_n)) que serão percorridos até o n-ésimo ponto. Pode ser introduzida na aplicação, uma rotina com laços (loops) (BOAVENTURA NETTO, 2003), que são arestas que iniciam e terminam no mesmo vértice. Grafos podem também ser tratados como árvores, como é o caso de um grafo que representa a árvore genealógica de uma família, em que o nó raiz pode ser o patriarca da família, e gerando “filhos” que são os nós subordinados a ele. Outro exemplo de árvore é a hierarquia de uma imagem dividida em partes, onde a imagem toda seria o pai e as sub-partes seriam os “filhos”, “netos” etc.

A representação computacional de um grafo é feita implementando-o com o uso de matrizes, onde os nós são representados como linhas e as arestas como colunas. Existem duas formas de representá-los: com a matriz de adjacência e com a matriz de incidência.

Na construção de uma matriz de adjacência a conexão entre os nós deve ser analisada. A Figura 1 apresenta um exemplo de

um grafo simples e sua respectiva matriz de adjacência.



	A1	A2	A3	A4	A5
A1	0	1	0	0	1
A2	1	0	1	0	0
A3	0	1	0	1	0
A4	0	0	1	0	1
A5	1	0	0	1	0

Figura 1. Grafo simples e sua respectiva matriz de adjacência.

Métodos

Até o momento os assuntos sobre extração de características de imagens e de redes complexas foram abordados expondo suas principais características detalhadamente, porém os dois temas foram expostos de maneiras distintas sem uma conexão entre eles. Este tópico colocará em destaque a interação entre Extração de Características de imagens e Redes Complexas, de modo que o entendimento do processo de Reconhecimento de Padrões seja facilitado.

Nos experimentos, foi utilizada uma base de dados de contorno de peixes conforme demonstra a Figura 2. O conjunto de imagens utilizadas nos experimentos são disponíveis em (MOKHTARIAN et al., 1996). A ferramenta utilizada para implementação será o Matlab. Para ilustrar o funcionamento dos métodos propostos neste trabalho, utilizaremos a imagem Peixe_2 com uma resolução menor, detalhando todo o processo de extração de características por meio de redes complexas.

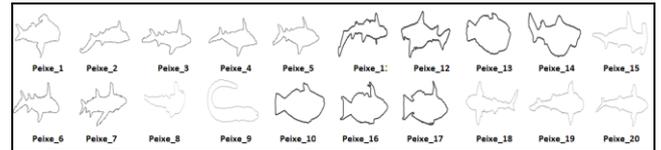


Figura 2. Imagens de peixes.

Para iniciar o procedimento, foram extraídas as características das imagens. O processo consiste em extrair as características das bordas das imagens, utilizando o comando EDGE e o atributo canny, que gera uma imagem binária onde o valor 1 representa o valor preenchido da imagem que é visualizada pela cor preta e o valor 0 correspondente à cor branca. Posteriormente foram armazenadas em um arquivo .txt. A tabela 1 contém as informações do arquivo .txt salvo com as coordenadas x e y das bordas da imagem Peixe_2, onde sua resolução foi reduzida em 97% para exemplificar a metodologia.

Tabela 1. Dados das coordenadas x e y das bodas da imagem salvas no arquivo .txt.

53	197
48	173
57	143
43	109
28	77
20	45
27	18
35	45
53	76
80	94
71	126
78	155
81	185
95	213
100	247
101	279
121	303
91	318
84	350
65	378

57	351
53	319
52	285
53	253
53	221

As coordenadas X,Y dos vértices verificando os valores iguais a 1 referenciando um pixel preenchido de preto. Este processo é essencial, pois como os experimentos foram realizados com base no tema das Redes Complexas, a utilização da borda da imagem é o fator que mais se enquadra no assunto. A borda é uma seqüência de pixels preenchidos, onde os mesmos têm (ou não) conexões com os demais, semelhantes aos nós de um grafo. Esses são os principais pontos que devem ser destacados na Extração de Características de Imagens utilizando Redes Complexas (BACKES et al., 2007).

O processo seguinte deverá obter a distância entre os pontos (vértices) $A(x_1, y_1)$ e

$B(x_2, y_2)$ que é o comprimento do (módulo) do vetor $|\overrightarrow{AB}|$, isto é, $d(A, B) = |\overrightarrow{AB}|$.

Como $|\overrightarrow{AB}| = B - A = (x_2 - x_1, y_2 - y_1)$ temos a métrica euclidiana. A Equação 1 expõe a fórmula utilizada.

Para isso será contabilizado o número total de vértices da imagem e gerada uma matriz quadrada com a quantidade de linhas e colunas igual ao número de vértices. Adquirida a matriz de distância há a necessidade de normalizá-los. Na Tabela 2, podemos visualizar os dados da matriz com a distância euclidiana aplicada nos pontos da Tabela 1 de acordo com a Equação 1.

$$d(A, B) = \sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2}$$

Equação 1

Tabela 2. Matriz gerada com a aplicação do método da distância euclidiana .

0,0	24,5	54,1	88,6	122,6	155,5	180,9	153,1	121,0	106,5	73,2	48,9	30,5	44,9	68,6	95,0	125,9	126,8	156,1	181,4	154,1	122,0	88,0	56,0	24,0
24,5	0,0	31,3	64,2	98,1	131,0	156,4	128,7	97,1	85,2	52,3	35,0	35,1	61,7	90,4	118,5	149,1	151,2	180,6	205,7	178,2	146,1	112,1	80,2	48,3
54,1	31,3	0,0	36,8	72,1	104,8	128,5	100,4	67,1	54,1	22,0	24,2	48,4	79,6	112,5	142,9	172,3	178,3	208,8	235,1	208,0	176,0	142,1	110,1	78,1
88,6	64,2	36,8	0,0	35,3	68,0	92,4	64,5	34,5	39,9	32,8	57,8	85,0	116,3	149,3	179,6	209,1	214,4	244,5	269,9	242,4	210,2	176,2	144,3	112,4
122,6	98,1	72,1	35,3	0,0	33,0	59,0	32,8	25,0	54,7	65,2	92,6	120,3	151,6	184,6	214,8	244,4	249,1	278,7	303,3	275,5	243,3	209,4	177,8	146,2
155,5	131,0	104,8	68,0	33,0	0,0	27,9	15,0	45,3	77,5	95,7	124,4	152,7	184,0	217,3	247,6	277,1	282,1	311,6	336,0	308,2	276,0	242,1	210,6	179,1
180,9	156,4	128,5	92,4	59,0	27,9	0,0	28,2	63,6	92,7	116,6	146,2	175,5	206,5	240,4	271,3	300,1	306,8	336,9	362,0	334,3	302,1	268,2	236,4	204,7
153,1	128,7	100,4	64,5	32,8	15,0	28,2	0,0	35,8	66,5	88,6	118,1	147,4	178,4	212,2	243,1	272,0	278,7	308,9	334,3	306,8	274,6	240,6	208,8	176,9
121,0	97,1	67,1	34,5	25,0	45,3	63,6	35,8	0,0	32,4	53,1	82,9	112,5	143,3	177,3	208,6	237,0	245,0	275,7	302,2	275,0	243,0	209,0	177,0	145,0
106,5	85,2	54,1	39,9	54,7	77,5	92,7	66,5	32,4	0,0	33,2	61,0	91,0	119,9	154,3	186,2	213,0	224,3	256,0	284,4	258,0	226,6	193,0	161,3	129,8
73,2	52,3	22,0	32,8	65,2	95,7	116,6	88,6	53,1	33,2	0,0	29,8	59,8	90,2	124,4	155,9	183,9	193,0	224,4	252,1	225,4	193,8	160,1	128,3	96,7
48,9	35,0	24,2	57,8	92,6	124,4	146,2	118,1	82,9	61,0	29,8	0,0	30,1	60,4	94,6	126,1	154,1	163,5	195,1	223,4	197,1	165,9	132,6	101,1	70,6
30,5	35,1	48,4	85,0	120,3	152,7	175,5	147,4	112,5	91,0	59,8	30,1	0,0	31,3	64,8	96,1	124,6	133,4	165,0	193,7	167,7	136,9	104,1	73,5	45,6
44,9	61,7	79,6	116,3	151,6	184,0	206,5	178,4	143,3	119,9	90,2	60,4	31,3	0,0	34,4	66,3	93,7	105,1	137,4	167,7	143,1	114,0	83,9	58,0	42,8
68,6	90,4	112,5	149,3	184,6	217,3	240,4	212,2	177,3	154,3	124,4	94,6	64,8	34,4	0,0	32,0	59,8	71,6	104,2	135,6	112,5	86,0	61,2	47,4	53,7
95,0	118,5	142,9	179,6	214,8	247,6	271,3	243,1	208,6	186,2	155,9	126,1	96,1	66,3	32,0	0,0	31,2	40,3	73,0	105,3	84,4	62,5	49,4	54,6	75,3
125,9	149,1	172,3	209,1	244,4	277,1	300,1	272,0	237,0	213,0	183,9	154,1	124,6	93,7	59,8	31,2	0,0	33,5	59,8	93,6	80,0	69,9	71,3	84,4	106,5
126,8	151,2	178,3	214,4	249,1	282,1	306,8	278,7	245,0	224,3	193,0	163,5	133,4	105,1	71,6	40,3	33,5	0,0	32,8	65,4	47,4	38,0	51,1	75,3	104,2
156,1	180,6	208,8	244,5	278,7	311,6	336,9	308,9	275,7	256,0	224,4	195,1	165,0	137,4	104,2	73,0	59,8	32,8	0,0	33,8	27,0	43,8	72,4	101,8	132,7
181,4	205,7	235,1	269,9	303,3	336,0	362,0	334,3	302,2	284,4	252,1	223,4	193,7	167,7	135,6	105,3	93,6	65,4	33,8	0,0	28,2	60,2	93,9	125,6	157,5
154,1	178,2	208,0	242,4	275,5	308,2	334,3	306,8	275,0	258,0	225,4	197,1	167,7	143,1	112,5	84,4	80,0	47,4	27,0	28,2	0,0	32,2	66,2	98,1	130,1
122,0	146,1	176,0	210,2	243,3	276,0	302,1	274,6	243,0	226,6	193,8	165,9	136,9	114,0	86,0	62,5	69,9	38,0	43,8	60,2	32,2	0,0	34,0	66,0	98,0
88,0	112,1	142,1	176,2	209,4	242,1	268,2	240,6	209,0	193,0	160,1	132,6	104,1	83,9	61,2	49,4	71,3	51,1	72,4	93,9	66,2	34,0	0,0	32,0	64,0
56,0	80,2	110,1	144,3	177,8	210,6	236,4	208,8	177,0	161,3	128,3	101,1	73,5	58,0	47,4	54,6	84,4	75,3	101,8	125,6	98,1	66,0	32,0	0,0	32,0
24,0	48,3	78,1	112,4	146,2	179,1	204,7	176,9	145,0	129,8	96,7	70,6	45,6	42,8	53,7	75,3	106,5	104,2	132,7	157,5	130,1	98,0	64,0	32,0	0,0

A normalização dos dados consistirá em adaptar valores extremamente altos (ou baixos) e “transformá-los” em valores que estarão dentro de uma faixa de valores padrão. Em outras palavras adaptará valores que vão de 20 a 35000 no intervalo que vai de 0 a 1. Esse processo de normalização é demonstrado na Tabela 3.

Tabela 3. Matriz de Distâncias com os dados normalizados.

0,00	0,07	0,15	0,24	0,34	0,43	0,50	0,42	0,33	0,29	0,20	0,14	0,08	0,12	0,19	0,26	0,35	0,35	0,43	0,50	0,43	0,34	0,24	0,15	0,07
0,07	0,00	0,09	0,18	0,27	0,36	0,43	0,36	0,27	0,24	0,14	0,10	0,10	0,17	0,25	0,33	0,41	0,42	0,50	0,57	0,49	0,40	0,31	0,22	0,13
0,15	0,09	0,00	0,10	0,20	0,29	0,36	0,28	0,19	0,15	0,06	0,07	0,13	0,22	0,31	0,39	0,48	0,49	0,58	0,65	0,57	0,49	0,39	0,30	0,22
0,24	0,18	0,10	0,00	0,10	0,19	0,26	0,18	0,10	0,11	0,09	0,16	0,23	0,32	0,41	0,50	0,58	0,59	0,68	0,75	0,67	0,58	0,49	0,40	0,31
0,34	0,27	0,20	0,10	0,00	0,09	0,16	0,09	0,07	0,15	0,18	0,26	0,33	0,42	0,51	0,59	0,68	0,69	0,77	0,84	0,76	0,67	0,58	0,49	0,40
0,43	0,36	0,29	0,19	0,09	0,00	0,08	0,04	0,13	0,21	0,26	0,34	0,42	0,51	0,60	0,68	0,77	0,78	0,86	0,93	0,85	0,76	0,67	0,58	0,49
0,50	0,43	0,36	0,26	0,16	0,08	0,00	0,08	0,18	0,26	0,32	0,40	0,48	0,57	0,66	0,75	0,83	0,85	0,93	1,00	0,92	0,83	0,74	0,65	0,57
0,42	0,36	0,28	0,18	0,09	0,04	0,08	0,00	0,10	0,18	0,24	0,33	0,41	0,49	0,59	0,67	0,75	0,77	0,85	0,92	0,85	0,76	0,66	0,58	0,49
0,33	0,27	0,19	0,10	0,07	0,13	0,18	0,10	0,00	0,09	0,15	0,23	0,31	0,40	0,49	0,58	0,65	0,68	0,76	0,83	0,76	0,67	0,58	0,49	0,40
0,29	0,24	0,15	0,11	0,15	0,21	0,26	0,18	0,09	0,00	0,09	0,17	0,25	0,33	0,43	0,51	0,59	0,62	0,71	0,79	0,71	0,63	0,53	0,45	0,36
0,20	0,14	0,06	0,09	0,18	0,26	0,32	0,24	0,15	0,09	0,00	0,08	0,17	0,25	0,34	0,43	0,51	0,53	0,62	0,70	0,62	0,54	0,44	0,35	0,27
0,14	0,10	0,07	0,16	0,26	0,34	0,40	0,33	0,23	0,17	0,08	0,00	0,08	0,17	0,26	0,35	0,43	0,45	0,54	0,62	0,54	0,46	0,37	0,28	0,19
0,08	0,10	0,13	0,23	0,33	0,42	0,48	0,41	0,31	0,25	0,17	0,08	0,00	0,09	0,18	0,27	0,34	0,37	0,46	0,53	0,46	0,38	0,29	0,20	0,13
0,12	0,17	0,22	0,32	0,42	0,51	0,57	0,49	0,40	0,33	0,25	0,17	0,09	0,00	0,09	0,18	0,26	0,29	0,38	0,46	0,40	0,31	0,23	0,16	0,12
0,19	0,25	0,31	0,41	0,51	0,60	0,66	0,59	0,49	0,43	0,34	0,26	0,18	0,09	0,00	0,09	0,17	0,20	0,29	0,37	0,31	0,24	0,17	0,13	0,15
0,26	0,33	0,39	0,50	0,59	0,68	0,75	0,67	0,58	0,51	0,43	0,35	0,27	0,18	0,09	0,00	0,09	0,11	0,20	0,29	0,23	0,17	0,14	0,15	0,21
0,35	0,41	0,48	0,58	0,68	0,77	0,83	0,75	0,65	0,59	0,51	0,43	0,34	0,26	0,17	0,09	0,00	0,09	0,17	0,26	0,22	0,19	0,20	0,23	0,29
0,35	0,42	0,49	0,59	0,69	0,78	0,85	0,77	0,68	0,62	0,53	0,45	0,37	0,29	0,20	0,11	0,09	0,00	0,09	0,18	0,13	0,11	0,14	0,21	0,29
0,43	0,50	0,58	0,68	0,77	0,86	0,93	0,85	0,76	0,71	0,62	0,54	0,46	0,38	0,29	0,20	0,17	0,09	0,00	0,09	0,07	0,12	0,20	0,28	0,37
0,50	0,57	0,65	0,75	0,84	0,93	1,00	0,92	0,83	0,79	0,70	0,62	0,53	0,46	0,37	0,29	0,26	0,18	0,09	0,00	0,08	0,17	0,26	0,35	0,43
0,43	0,49	0,57	0,67	0,76	0,85	0,92	0,85	0,76	0,71	0,62	0,54	0,46	0,40	0,31	0,23	0,22	0,13	0,07	0,08	0,00	0,09	0,18	0,27	0,36
0,34	0,40	0,49	0,58	0,67	0,76	0,83	0,76	0,67	0,63	0,54	0,46	0,38	0,31	0,24	0,17	0,19	0,11	0,12	0,17	0,09	0,00	0,09	0,18	0,27
0,24	0,31	0,39	0,49	0,58	0,67	0,74	0,66	0,58	0,53	0,44	0,37	0,29	0,23	0,17	0,14	0,20	0,14	0,20	0,26	0,18	0,09	0,00	0,09	0,18
0,15	0,22	0,30	0,40	0,49	0,58	0,65	0,58	0,49	0,45	0,35	0,28	0,20	0,16	0,13	0,15	0,23	0,21	0,28	0,35	0,27	0,18	0,09	0,00	0,09
0,07	0,13	0,22	0,31	0,40	0,49	0,57	0,49	0,40	0,36	0,27	0,19	0,13	0,12	0,15	0,21	0,29	0,29	0,37	0,43	0,36	0,27	0,18	0,09	0,00

Uma vez que os dados estejam normalizados, o próximo item da sequência será gerar a matriz de adjacência contendo também o número de colunas e o número de linhas com o mesmo valor do número de vértices contabilizados pela extração da borda. Através desta matriz de adjacência foram computadas todas as conexões de cada vértice com base em limiares preestabelecidos, onde o número de conexões de cada vértice determina o grau do mesmo. Os limiares preestabelecidos foram 0.1 (Tabela 4), 0.25 (Tabela 5), 0.5 (Tabela 6) , 0.75 (Tabela 7) e 0.95 (Tabela 8). Quanto maior o

limiar, maior será o grau de cada vértice, definindo assim um resultado mais preciso, porém é importante que haja uma variação dos valores dos limiares para que seja realizada uma análise mais concreta da similaridade. Com os graus dos vértices registrados, será necessário encontrar o grau máximo e o grau mínimo dos vértices para cada limiar aplicado, com o resultado obtido deverá ser encontrado também o grau médio, onde deverá ser somado o valor do grau máximo e o valor do grau mínimo dividido por dois.

0	1	1	1	0	0	0	0	0	0	0	1	1	1	1	1	0	0	0	0	0	0	0	1	1	1
1	0	1	1	0	0	0	0	0	1	1	1	1	1	1	0	0	0	0	0	0	0	0	0	1	1
1	1	0	1	1	0	0	0	1	1	1	1	1	1	0	0	0	0	0	0	0	0	0	0	0	1
1	1	1	0	1	1	0	1	1	1	1	1	1	1	0	0	0	0	0	0	0	0	0	0	0	0
0	0	1	1	0	1	1	1	1	1	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	1	1	0	1	1	1	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	1	1	0	1	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	1	1	1	1	0	1	1	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	1	1	1	1	1	1	0	1	1	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	1	1	1	1	1	0	1	1	0	1	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0
1	1	1	1	1	0	0	1	1	1	0	1	1	1	0	0	0	0	0	0	0	0	0	0	0	0
1	1	1	1	0	0	0	0	1	1	1	0	1	1	0	0	0	0	0	0	0	0	0	0	0	1
1	1	1	1	0	0	0	0	0	0	1	1	0	1	1	0	0	0	0	0	0	0	0	0	1	1
1	1	1	0	0	0	0	0	0	0	1	1	0	1	1	0	0	0	0	0	0	0	0	1	1	1
1	1	0	0	0	0	0	0	0	0	0	0	1	1	0	1	1	1	0	0	0	1	1	1	1	1
0	0	0	0	0	0	0	0	0	0	0	0	0	1	1	0	1	1	1	0	1	1	1	1	1	1
0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	1	0	1	1	1	1	1	1	1	1	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	1	1	0	1	1	1	1	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	1	1	1	1	1	0	1	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	1	1	1	1	1	1	0	1	1	0
1	0	0	0	0	0	0	0	0	0	0	0	0	1	1	1	1	1	1	0	1	1	0	1	1	1
1	1	0	0	0	0	0	0	0	0	0	1	1	1	1	1	0	0	0	1	1	0	1	1	0	1
1	1	1	0	0	0	0	0	0	0	1	1	1	1	1	0	0	0	0	0	0	1	1	0	1	0

Grau Máximo	Grau Mínimo	Grau Médio
11	4	7,5

Tabela 6. Matriz de Adjacência gerada pelo limiar 0.5 e seus respectivos Graus.

0	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	0	1	1	1	1	1
1	0	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	0	1	1	1	1	1
1	1	0	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	0	0	0	1	1	1	1
1	1	1	0	1	1	1	1	1	1	1	1	1	1	1	1	0	0	0	0	0	0	1	1	1
1	1	1	1	0	1	1	1	1	1	1	1	1	1	1	0	0	0	0	0	0	0	0	1	1
1	1	1	1	1	0	1	1	1	1	1	1	1	1	0	0	0	0	0	0	0	0	0	0	1
1	1	1	1	1	1	0	1	1	1	1	1	1	1	0	0	0	0	0	0	0	0	0	0	0
1	1	1	1	1	1	1	0	1	1	1	1	1	1	1	0	0	0	0	0	0	0	0	0	1
1	1	1	1	1	1	1	1	0	1	1	1	1	1	1	1	0	0	0	0	0	0	0	1	1
1	1	1	1	1	1	1	1	1	0	1	1	1	1	1	1	0	0	0	0	0	0	0	1	1
1	1	1	1	1	1	1	1	1	1	0	1	1	1	1	1	1	0	0	0	0	0	0	1	1
1	1	1	1	1	1	1	1	1	1	1	0	1	1	1	1	1	1	0	0	0	0	0	1	1
1	1	1	1	1	1	1	1	1	1	1	1	0	1	1	1	1	1	1	0	0	0	1	1	1
1	1	1	1	1	0	0	1	1	1	1	1	1	0	1	1	1	1	1	1	1	1	1	1	1
1	1	1	1	0	0	0	0	1	1	1	1	1	1	0	1	1	1	1	1	1	1	1	1	1
1	1	1	1	0	0	0	0	0	0	1	1	1	1	1	0	1	1	1	1	1	1	1	1	1
1	1	1	0	0	0	0	0	0	0	0	1	1	1	1	1	0	1	1	1	1	1	1	1	1
1	1	0	0	0	0	0	0	0	0	0	0	1	1	1	1	1	1	0	1	1	1	1	1	1
0	0	0	0	0	0	0	0	0	0	0	0	0	1	1	1	1	1	1	0	1	1	1	1	1
1	1	0	0	0	0	0	0	0	0	0	0	1	1	1	1	1	1	1	0	1	1	1	1	1
1	1	1	0	0	0	0	0	0	0	0	1	1	1	1	1	1	1	1	1	0	1	1	1	1
1	1	1	1	0	0	0	0	0	0	1	1	1	1	1	1	1	1	1	1	1	0	1	1	1
1	1	1	1	1	0	0	0	1	1	1	1	1	1	1	1	1	1	1	1	1	1	0	1	1
1	1	1	1	1	1	0	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	0

Grau Máximo	Grau Mínimo	Grau Médio
23	11	17

O limiar 0.1 é o que menos apresenta precisão nos resultados, pois permite que várias imagens sejam selecionadas dentro da faixa de tolerância. São selecionadas as imagens que possuem certos pontos com os mesmos valores de características da imagem Peixe_2. Demonstrado na Tabela 9, as imagens que obtiveram o grau médio dentro da tolerância que vai de 690 a 700 são: Peixe_2, Peixe_4, Peixe_11, Peixe_12, Peixe_14, Peixe_15 e Peixe_18.

Tabela 9. Análise para o limiar 0.1.

Imagens	Máximo	Mínimo	Médio
Peixe_1	127	45	86
Peixe_2	1325	68	696,5
Peixe_3	1325	80	702,5
Peixe_4	1325	62	693,5
Peixe_5	1255	58	656,5
Peixe_6	1652	75	863,5
Peixe_7	185	62	123,5
Peixe_8	122	57	89,5
Peixe_9	1325	47	686
Peixe_10	1325	46	685,5
Peixe_11	1325	68	696,5
Peixe_12	1325	62	693,5
Peixe_13	1325	41	683
Peixe_14	1325	62	693,5
Peixe_15	1325	69	697
Peixe_16	1325	36	680,5
Peixe_17	1325	44	684,5
Peixe_18	1325	68	696,5
Peixe_19	160	68	114
Peixe_20	167	65	116

Utilizando o limiar 0.25, foi utilizada a mesma base de imagens, porém os resultados foram razoavelmente mais precisos, pois das sete imagens selecionadas para o limiar 0.1, apenas cinco ficaram dentro da margem de tolerância que vai de 740 a 760. Limiares com valor menor são utilizados como um filtro, possibilitando uma análise detalhada em cada um dos limiares através dos dados obtidos e também visualmente através das imagens especificadas neste filtro. As imagens similares no limiar 0.25 são Peixe_2, Peixe_4, Peixe_11, Peixe_14 e Peixe_15. Conforme apresenta a Tabela 10.

Tabela 10. Análise para o limiar 0.25.

Imagens	Máximo	Mínimo	Médio
Peixe_1	332	129	230,5

Peixe_2	1325	182	753,5
Peixe_3	1325	231	778
Peixe_4	1325	165	745
Peixe_5	1255	162	708,5
Peixe_6	1652	208	930
Peixe_7	570	181	375,5
Peixe_8	370	156	263
Peixe_9	1325	154	739,5
Peixe_10	1325	133	729
Peixe_11	1325	174	749,5
Peixe_12	1325	208	766,5
Peixe_13	1325	117	721
Peixe_14	1325	175	750
Peixe_15	1325	192	758,5
Peixe_16	1325	101	713
Peixe_17	1325	119	722
Peixe_18	1325	203	764
Peixe_19	420	190	305
Peixe_20	436	117	306,5

O limiar 0.5 é o terceiro mais preciso, destacou uma imagem a menos dentro da faixa de tolerância. As imagens selecionadas foram Peixe_2, Peixe_4, Peixe_11 e Peixe_15, confirmadas na Tabela 11, onde a faixa de tolerância vai de 840 a 860. Os resultados a partir deste limiar determinam as imagens que possuem características consideravelmente semelhantes, porém visualmente ainda são notadas certas diferenças.

Tabela 11. Análise para o limiar 0.5.

Imagens	Máximo	Mínimo	Médio
Peixe_1	671	321	496
Peixe_2	1325	384	854,5
Peixe_3	1325	510	917,5
Peixe_4	1325	376	850,5
Peixe_5	1255	391	823
Peixe_6	1652	503	1077,5
Peixe_7	1011	412	711,5
Peixe_8	685	311	498
Peixe_9	1325	297	811
Peixe_10	1325	320	822,5
Peixe_11	1325	383	854
Peixe_12	1325	400	862,5
Peixe_13	1325	274	799,5
Peixe_14	1325	353	839
Peixe_15	1325	396	860
Peixe_16	1325	266	795,5
Peixe_17	1325	339	832
Peixe_18	1325	431	878
Peixe_19	836	398	617
Peixe_20	839	380	609,5

Utilizando o limiar 0.75, segundo mais preciso, ficaram dentro da tolerância de 940 a 960, apenas três imagens das sete que foram pré-selecionadas no limiar 0.1. Comprovada na Tabela 12, estão dentro da faixa de tolerância as

imagens Peixe_2, Peixe_4 e Peixe_11. Assim como o limiar 0.5, também determina as imagens que são relativamente similares. Mais exato, porém ainda exibe algumas inconformidades visuais quanto à comparação entre a imagem Peixe_2 e as imagens selecionadas Peixe_4 e Peixe_11.

Tabela 12. Análise para o limiar 0.75.

Imagens	Máximo	Mínimo	Médio
Peixe_1	684	514	599
Peixe_2	1325	569	947
Peixe_3	1325	774	1049,5
Peixe_4	1325	579	952
Peixe_5	1255	598	926,5
Peixe_6	1652	756	1204
Peixe_7	1019	749	884
Peixe_8	689	494	591,5
Peixe_9	1325	604	964,5
Peixe_10	1325	480	902,5
Peixe_11	1325	565	945
Peixe_12	1325	606	965,5
Peixe_13	1325	421	873
Peixe_14	1325	539	932
Peixe_15	1325	654	989,5
Peixe_16	1325	440	882,5
Peixe_17	1325	490	907,5
Peixe_18	1325	704	1014,5
Peixe_19	840	609	724,5
Peixe_20	843	617	730

O limiar 0.95 é o último limiar a ser analisado e também o mais preciso entre os cinco estabelecidos. Este limiar apresenta os resultados finais do experimento. Dentre todas as imagens analisadas, a que mais se aproximou da similaridade referente à imagem Peixe_2 foi a imagem Peixe_11, pois ambas ficaram na faixa de tolerância que vai de 1020 a 1040, conforme exibe a Tabela 13.

Tabela 13. Análise para o limiar 0.95.

Imagens	Máximo	Mínimo	Médio
Peixe_1	684	637	660,5
Peixe_2	1325	744	1034,5
Peixe_3	1325	1020	1172,5
Peixe_4	1325	771	1048
Peixe_5	1255	773	1014
Peixe_6	1652	980	1316
Peixe_7	1019	963	991

Peixe_8	689	645	667
Peixe_9	1325	834	1079,5
Peixe_10	1325	595	960
Peixe_11	1325	741	1033
Peixe_12	1325	807	1066
Peixe_13	1325	528	926,5
Peixe_14	1325	699	1012
Peixe_15	1325	861	1093
Peixe_16	1325	576	950,5
Peixe_17	1325	645	985
Peixe_18	1325	940	1132,5
Peixe_19	840	794	817
Peixe_20	843	801	822

Discussão

A análise de imagens se tornou um desafio para os pesquisadores da área de visão computacional por ter o objetivo de reconhecer formas do mundo real. Para obter resultados mais concretos, os métodos das Redes Complexas foram utilizados para dar eficiência nas comparações de similaridade entre as imagens. O objetivo dos experimentos foi provar que extraindo o grau máximo, mínimo e médio, e aplicando um determinado limiar a este, um resultado preciso é adquirido, em que quanto maior o valor do limiar, maior será a precisão nos resultados. Fazendo uso de cinco limiares diferentes, no limiar 0.95 foi encontrada a similaridade entre as imagens Peixe_2 e Peixe_11.

Referências

- AIELLO, W.; CHUNG, F.; LU, L. A. Random Graph Model for Massive Graphs. Proceedings of 32nd Annual ACM Symposium on Theory of Computing, Association of Computing Machinery. New York. 2000. p.171-180.
- ALBERT, R.; BARABÁSI, A. L. Emergence of Scaling in Random Networks. Science. v.286, p.509-512, 1999.
<http://dx.doi.org/10.1126/science.286.5439.509>
- BERRETTI, S.; DEL BIMBO, A.; VICARIO, E. Efficient Matching and Indexing of Graph Models in Content-Based Retrieval. IEEE Transactions on Pattern Analysis and Machine Intelligence, v.23,

n.10, p.1089-1105, 2001.

<http://dx.doi.org/10.1109/34.954600>

COSTA, L. F.; CESAR, R. M. Shape Analysis and Classification: Theory and Practice. Pennsylvania: CRC Press, 2000.

<http://dx.doi.org/10.1201/9781420037555>

FALCÃO, A. X.; STOLFI, J.; LOTUFO, R. A. The image foresting transform: Theory, algorithms, and applications. IEEE Transactions on Pattern Analysis and Machine Intelligence, v.26, n.1, p.19-29, 2004.

<http://dx.doi.org/10.1109/TPAMI.2004.1261076>

JAIN, A. K. Fundamentals of Digital Image Processing. London: Prentice Hall, 1989.

MATHIAS, E.; CONCI, A. Pesquisa de Imagens em Banco de Dados por Semelhança de Cor. In: X Simpósio Brasileiro de Computação Gráfica e Processamento de Imagens, Campos do Jordão, SP, Out. 1997.

BOAVENTURA NETTO, P. O. Grafos: Teoria, Modelos, Algoritmos. 3.ed. Ed. Edgard Blücher. 2003. 314p.

NEWMAN, M. E. J. The Structure and Function of Complex Networks. SIAM Review. v.45, n.2, p.167-256, 2003.

<http://dx.doi.org/10.1137/S003614450342480>

SCHWARTZ, W. R.; PEDRINI, H. Método para Classificação de Imagens Baseada em Matrizes de Co-ocorrência Utilizando Características de Textura. In: Proceedings of III Colóquio Brasileiro de Ciências Geodésicas, Maio 2003. p.1-11.

SCLAROFF, S.; TAYCHER, L.; CASCIA, M. ImageRover: A Content-Based Image Browser for the World Wide Web. In: Proceedings IEEE Workshop on Content-based Access of Image and Video Libraries, EUA: 1997.

SONKA, M.; HLAVAC, V. et al. Image Processing Analysis, and Machine Vision. Pacific Grove: PWS Publishing, 1999. 770 p.

ULLMANN, J. R. An Algorithm for Subgraph Isomorphism. Journal of the ACM, v.23, p.31-42, 1976. <http://dx.doi.org/10.1145/321921.321925>

RABUSKE, M. A. Introdução à Teoria dos Grafos. Editora da UFSC, Santa Catarina, 1992.

MOKHTARIAN, F.; ABBASI, S.; KITTLER, J. Robust and efficient shape indexing through curvature scale space, in *Proceedings of the 1996 British Machine and Vision Conference BMVC'96*, Edinburgh, U.K., pp. 53-62, 1996.

BACKES, A. R.; CASANOVA, D.; BRUNO, O. M. Journal of Computer Science, v. 6, n. 2, p.71-80, 2007.