



UNIVERSIDADE FEDERAL RURAL DO SEMI-ÁRIDO
PRÓ-REITORIA DE GRADUAÇÃO
DEPARTAMENTO DE CIÊNCIAS DA COMPUTAÇÃO
CURSO DE CIÊNCIA DA COMPUTAÇÃO

IVERTON PERBOYRE LOIOLA MAIA

**SEGMENTAÇÃO DE IMAGENS ATRAVÉS DE REDUÇÃO DE PIXELS
UTILIZANDO DIFUSÃO GEOMÉTRICA MARKOVIANA**

MOSSORÓ

2017

IVERTON PERBOYRE LOIOLA MAIA

**SEGMENTAÇÃO DE IMAGENS ATRAVÉS DE REDUÇÃO DE PIXELS
UTILIZANDO DIFUSÃO GEOMÉTRICA MARKOVIANA**

Monografia apresentada à Universidade Federal Rural do Semiárido como requisito parcial para obtenção do título de Bacharel em Ciência da Computação.

Orientador: Prof. Dr. Leandro Carlos de Souza.

MOSSORÓ

2017

©Todos os direitos estão reservados à Universidade Federal Rural do Semi-Árido. O conteúdo desta obra é de inteira responsabilidade do (a) autor (a), sendo o mesmo, passível de sanções administrativas ou penais, caso sejam infringidas as leis que regulamentam a Propriedade Intelectual, respectivamente, Patentes: Lei nº 9.279/1996, e Direitos Autorais: Lei nº 9.610/1998. O conteúdo desta obra tornar-se-á de domínio público após a data de defesa e homologação da sua respectiva ata, exceto as pesquisas que estejam vinculadas ao processo de patenteamento. Esta investigação será base literária para novas pesquisas, desde que a obra e seu (a) respectivo (a) autor (a) seja devidamente citado e mencionado os seus créditos bibliográficos.

Ficha catalográfica elaborada pelo Sistema de Bibliotecas
da Universidade Federal Rural do Semiárido, com os dados fornecidos pelo(a) autor(a)

M217s Maia, Iverton Perboyre Loiola.
Segmentação de imagens através da redução de
pixels utilizando difusão geométrica Markoviana /
Iverton Perboyre Loiola Maia. - 2017.
44 f. : il.

Orientador: Leandro Carlos de Souza.
Monografia (graduação) - Universidade Federal
Rural do Semi-árido, Curso de , 2017.

1. Segmentação. 2. imagens. 3. difusão. 4.
geométrica. 5. Markoviana. I. de Souza, Leandro
Carlos, orient. II. Título.

O serviço de Geração Automática de Ficha Catalográfica para Trabalhos de Conclusão de Curso (TCC's) foi desenvolvido pelo Instituto de Ciências Matemáticas e de Computação da Universidade de São Paulo (USP) e gentilmente cedido para o Sistema de Bibliotecas da Universidade Federal Rural do Semi-Árido (SISBI-UFERSA), sendo customizado pela Superintendência de Tecnologia da Informação e Comunicação (SUTIC) sob orientação dos bibliotecários da instituição para ser adaptado às necessidades dos alunos dos Cursos de Graduação e Programas de Pós-Graduação da Universidade.


IVERTON PERBOYRE LOIOLA MAIA

**SEGMENTAÇÃO DE IMAGENS ATRAVÉS DE REDUÇÃO DE PIXELS
UTILIZANDO DIFUSÃO GEOMÉTRICA MARKOVIANA**

Monografia apresentada a Universidade
Federal Rural do Semi-Árido como
requisito parcial para obtenção do título
de Bacharel em Ciências da Computação.

Defendida em: 25/09/2017.

BANCA EXAMINADORA



Prof. Dr. Leandro Carlos de Souza (UFERSA)
Orientador e Presidente



Prof.ª Dra. Angélica Félix de Castro (UFERSA)
Membro Examinador



Prof.ª M.ª Flávia Estéla Silva Coelho (UFERSA)
Membro Examinador

AGRADECIMENTOS

Agradeço imensamente a minha amada mãe, Iolanda, por ter sido parte imprescindível de valor incomensurável durante a minha caminhada no decorrer do curso. Sou eternamente grato por você fazer por mim, durante toda a sua vida, tudo o que mais ninguém faria. Amo-te. Obrigado, mãe!

Agradeço imensamente ao meu amado pai, Gabriel, por ser o meu primeiro e mais admirável exemplo de fé no Pai criador e na força do trabalho diário, bem como suporte absoluto para que eu chegasse ao fim de minha graduação. Amo-te. Obrigado, pai!

Agradeço imensamente a minha amada irmã, Gabrielle, por ter me apoiado e por ter me oferecido suporte de grandíssima importância durante minha graduação. Estarei sempre disponível para retribuí-la com igual prontidão. Amo-te. Obrigado, “Gabi”!

Agradeço ao Orientador, Leandro Carlos de Souza, pela assiduidade nos compromissos firmados e pela dedicação ao ensino de excelente qualidade transmitido durante o curso. Obrigado, professor Leandro!

Agradeço a todos os meus amigos por terem acreditado em meu potencial e por terem me apoiado e me ajudado em todas as vezes em que precisei. Em especial, agradeço aos amigos: José Dijon, por ter elucidado minhas dúvidas inúmeras vezes, me ajudando de todas as formas possíveis; Ricardo Gomes e Leonardo David, por serem meus “irmãos mais novos”, mas que me ensinam a cada dia o valor da verdadeira amizade; Marianne Ribeiro, por compartilhar comigo inúmeras experiências, boas e más, e por me acompanhar tão dedicada e carinhosamente durante este ciclo que se encerra. Obrigado a cada um de vocês!

RESUMO

A Segmentação clássica de imagens está dividida basicamente em três técnicas: global, que se baseia em conhecimento relativo à intensidade do pixel; baseada em regiões, que consiste na divisão da imagem em regiões que exibem propriedades similares; e baseada na borda, que consiste na detecção de bordas para achar contornos fechados na imagem. Este trabalho utiliza uma abordagem diferente para realizar a segmentação de imagens: a Difusão Geométrica Markoviana (DGM). A DGM possibilita a extração de informações sobre a representatividade dos vértices de um grafo. Isto permite a eliminação de elementos do grafo que possuem baixa representatividade. No contexto de imagens digitais, a imagem é convertida em um grafo, e a DGM destina-se à redução de *pixels* baseando-se na representatividade de cada *pixel*. O método desenvolvido neste trabalho constrói descritores para objetos através da eliminação de informações pouco relevantes da imagem, gerando como produto final a imagem segmentada.

Palavras-chave: Segmentação. técnicas. imagens. pixels. difusão. Markoviana.

ABSTRACT

The classical segmentation of images is basically subdivided into three main techniques: global, which is based on the relative knowledge about the intensity of the components from the pixels; region-based, which consists of dividing the images in similar regions; and edge-based, which consists of edge detection to build closed lines around the detected object in the image. This work describes a different approach to apply the segmentation of images: the Markovian Geometric Diffusion (MGD). The MDG enables the extraction of the representativeness of the vertices from a graph, which propitiates the elimination of the elements from the graph that hold few representativeness. In the context of digital images, the image is converted into a graph, and the MGD is intended for pixels, being representativeness-based from each of them. The method developed in this work builds descriptors for objects by eliminating few relevant information from the image, generating as result a segmented image.

Keywords: Segmentation. technique. images. pixels. diffusion. Markovian.

LISTA DE FIGURAS

Figura 1	– (a) imagem original monocromática. (b) imagem representada em forma matricial.	17
Figura 2	– (a) imagem original (b) canais separados: vermelho, verde, azul; imagem em escala de cinza.	19
Figura 3	– (a) exemplo de um ponto candidato a ser detectado pela detecção de pontos e linhas. (b) Exemplo da aplicação de operadores de diferenciação para detecção de bordas.	22
Figura 4	– (a) imagem original (b) imagem processada pelo método de Canny.....	24
Figura 5	– (a) Cadeia de Markov com 5 estados. (b) Matriz de transição da cadeia ilustrada.	26
Figura 6	– (a) gaussiana colorida de acordo com a representatividade dos vértices da malha. (b) modelo <i>bunny</i> ilustrando os vértices de acordo com a distribuição gaussiana.	28
Figura 7	– (a) imagem original. (b) imagem processada pela primeira etapa com parâmetro fixo em 0.50. (c) imagem processada pela segunda etapa com parâmetro fixo em 0.75.	32
Figura 8	– (a) imagem original. (b) imagem não segmentada, indicando falha de execução no método S-DGM.	34
Figura 9	– (a) imagem original. (b) imagem processada pela primeira etapa do método S-DGM com parâmetro fixo em 0.59. (c) imagem processada pela segunda etapa do método S-DGM com parâmetro fixo em 0.66. (d) imagem final processada pela remoção de ruído.	34

LISTA DE TABELAS

Tabela 1	–	Imagens de teste com resoluções inferiores a 1000x1000.	35
Tabela 2	–	Imagens de teste com resoluções superiores a 1000x1000.	37

LISTA DE ALGORITMOS

1	Montagem da matriz de transição associada a um conjunto X	29
2	Cálculo das importâncias aplicando-se DGM.	30
3	Eliminação de <i>pixels</i> baseada em percentil.	31
4	Eliminação de ruídos.	33

LISTA DE ABREVIATURAS E SIGLAS

CMY	Sistema de cor que utiliza ciano, magenta e amarelo como cores básicas
CMYK	Sistema de cor que utiliza ciano, magenta, amarelo e preto como cores básicas
DGM	Difusão Geométrica Markoviana
PDI	Processamento Digital de Imagens
QUADTREE	<i>Quadratic Picture Tree</i>
RGB	Sistema de cor que utiliza vermelho, verde e azul como cores básicas
S-DGM	Segmentação por Difusão Geométrica Markoviana
YIQ	Sistema de cor que utiliza luminância (Y), interpolação (I) e quadratura (Q) como componentes básicas

SUMÁRIO

1	INTRODUÇÃO	14
1.1	Problema	15
1.2	Objetivos	15
1.3	Justificativa	16
1.4	Organização	16
2	REFERENCIAL TEÓRICO	17
2.1	Sistema de cores	18
2.2	Segmentação	19
2.2.1	Detecção de descontinuidade	20
2.2.2	Detecção de pontos e linhas	20
2.2.3	Detecção de bordas	21
2.2.4	Detecção de similaridade	22
2.2.5	Crescimento de regiões	23
2.2.6	Pirâmides	23
2.2.7	Detecção de bacias	23
2.2.8	Limiarização	24
2.2.9	Agrupamento (<i>Clustering</i>)	25
2.3	Difusão Geométrica Markoviana (DGM)	25
2.3.1	Cadeias de Markov	25
2.3.2	Definição do núcleo de difusão	28
3	MÉTODO DA SEGMENTAÇÃO POR DIFUSÃO GEOMÉTRICA MARKOVIANA (S-DGM)	30
3.1	S-DGM	30
3.1.1	Cálculo das importâncias	30
3.1.2	Eliminação de <i>pixels</i>	31
3.1.3	Remoção de ruídos	32
4	RESULTADOS	35
5	CONCLUSÃO E TRABALHOS FUTUROS	41
	REFERÊNCIAS	42

1 INTRODUÇÃO

A segmentação é uma habilidade humana utilizada para detectar objetos. Com o avanço dos sistemas computacionais, surgiu o interesse por métodos capazes de realizar a segmentação de forma automatizada. O conceito de segmentação de imagens consiste em isolar *pixels* da imagem que correspondem ao mesmo conjunto característico de informação. Isto passa a ideia de separar objetos relevantes presentes em imagens de acordo com restrições específicas. Um exemplo disto é a análise geofísica de cobertura, na qual se deseja medir a cobertura de nuvens ou de determinado minério em uma foto de satélite.

Dentre vários outros exemplos, pode-se citar a aplicação de segmentação no ambiente médico, no que diz respeito à análise morfológica de doenças através de isolamento parcial de imagens. Apesar de ser muito difundida no tratamento de imagens, a segmentação é uma estratégia avançada e complexa, tendo extensão também no ramo da Inteligência Artificial como parte dos processos de reconhecimento de formas e aprendizado de máquina. A partir deste ponto, juntamente com o maior acesso a computadores devido à redução de custos e aumento significativo de desempenho das máquinas, o número de áreas com aplicações utilizando segmentação cresceu significativamente.

Existem variadas técnicas de segmentação de imagens na literatura desta área, porém a grande maioria se baseia na utilização de limiares e parâmetros pré-definidos (GONZALEZ e WOODS, 2008). A Difusão Geométrica Markoviana (DGM) é um método probabilístico não-supervisionado que permite a extração de informações sobre a importância dos vértices de um grafo de forma anisotrópica (SOUZA, 2011). Ou seja, independe de valores pré-estabelecidos para que se realize a eliminação de informações pouco relevantes sobre a forma analisada. Agora, no contexto de imagens digitais, a DGM é utilizada para realizar a eliminação de *pixels*. Em virtude disto, este trabalho propõe uma nova abordagem para o problema de segmentação de imagens digitais.

Este estudo modela uma expansão da DGM para segmentação de imagens digitais. Esta extensão se dá pela construção de um grafo ponderado utilizando os *pixels* da imagem. Para o cálculo das importâncias de cada *pixel*, são consideradas as vizinhanças e as intensidades de cor dos *pixels*. A imagem é segmentada pela remoção dos *pixels* menos significativos. Isto é feito aplicando-se a DGM para extrair os dados mais relevantes da imagem, destacando, assim, os descritores de cada imagem.

1.1 Problema

A segmentação de imagens digitais tem como objetivo separar objetos presentes nas imagens. Entretanto, esta é uma tarefa árdua no que diz respeito à representação destes objetos. Obter descritores para objetos em imagens digitais engloba estudos pertencentes a áreas como Visão Computacional e Inteligência Artificial, e sua complexidade se dá pelo fato de não haver padrões estabelecidos nas imagens do mundo real quanto à representação de objetos. Detectar objetos genericamente de forma a cobrir todos os elementos de interesse ainda é um estudo não concluído.

Este trabalho enfatiza a segmentação de imagens, e o problema neste ramo de estudo é o fato de não haver técnicas de segmentação que cubram todos os objetos de interesse, sendo esta tarefa especialmente importante para a obtenção de descritores de objetos. Algumas técnicas de segmentação de imagens alcançam resultados satisfatórios de acordo com os propósitos aos quais se aplicam. Entretanto, uma forma genérica de segmentação de imagens ainda é inexistente na literatura desta área.

1.2 Objetivos

O objetivo deste trabalho é a implementação de um método capaz de segmentar imagens utilizando uma abordagem diferente das técnicas já existentes no Processamento Digital de Imagens (PDI). Para isto, pretende-se aplicar a DGM a fim de segmentar imagens baseando-se em suas variações de cor. Para alcançar os objetivos gerais, este trabalho tem como objetivos específicos:

- Construir um método que calcula a importância de cada *pixel* da imagem;
- Utilizar as importâncias para aplicar o critério de eliminação de *pixels* menos relevantes;
- Filtrar a imagem com um método específico para eliminação de ruído e apresentar o resultado visualmente.

1.3 Justificativa

Os métodos que utilizam segmentação em imagens tendem a ser aplicados de forma específica em variadas áreas de estudo, tais como medicina, geofísica, etc. O processamento de imagens voltado para a detecção de objetos é uma tarefa complexa devido à dificuldade em se obter uma solução genérica isto, e é uma atividade mesclada entre o PDI e a Visão Computacional que se utiliza de técnicas de segmentação (GONZALEZ e WOODS, 2008). Desta forma, um dos principais objetivos dos estudos nestas áreas é construir métodos eficazes para o tratamento de imagens genéricas, que permitam identificar objetos de interesse com o máximo de acurácia. Neste trabalho, uma nova abordagem é utilizada para segmentar imagens tendo como objetivo agregar conhecimento para a literatura das áreas de interesse.

1.4 Organização

Além deste capítulo introdutório, este documento é constituído de mais quatro capítulos:

Capítulo 2 – Referencial Teórico

Este capítulo expõe os fundamentos da área de estudo na qual o trabalho foi construído. Os conceitos de PDI, sistema de cores e representação digital de imagens são abordados. Também são apresentados conceitos sobre segmentação e difusão geométrica Markoviana.

Capítulo 3 – Método S-DGM

Neste capítulo é exposto todo o desenvolvimento do método proposto, especificando detalhes sobre sua aplicação e funcionamento.

Capítulo 4 - Resultados

Neste capítulo são apresentados e discutidos os resultados obtidos.


Capítulo 5 – Conclusão e Trabalhos Futuros

Este capítulo apresenta as percepções da solução proposta e direciona trabalhos futuros.

2 REFERENCIAL TEÓRICO

O conceito de imagem pode ser definido por uma função bidimensional $f(x, y)$, em que x e y representam coordenadas no espaço e f representa um valor de intensidade na coordenada (x, y) . Uma imagem pode ser definida como imagem digital se suas coordenadas e suas funções são representadas por valores finitos e discretos. A estrutura básica de representação de imagens digitais é o *pixel*, que armazena os valores de cor da imagem. A imagem também detém informações sobre altura e largura, como uma matriz numérica, e a quantidade de *pixels* presentes na imagem define o tamanho de sua resolução. A Figura 1 exibe (a) uma imagem monocromática de resolução 390x390 e (b) a mesma imagem representada matricialmente.

Figura 1 – (a) imagem original monocromática. (b) imagem original representada em forma matricial.



Fonte: Gonzalez e Woods (2008).

O PDI aborda o tratamento de imagens digitais por meio de funções e transformadas que recebem uma imagem como entrada e geram uma imagem como saída. Uma das vantagens de usar o PDI é o fato de ser possível tratar imagens no domínio de espaço e no domínio de frequência, ou seja, há técnicas que manipulam imagens nas bandas não visíveis. Estes tipos de imagens são comumente adquiridos por meio de aparelhos específicos para captar frequências em infravermelho, ultravioleta ou gama, por exemplo.

2.1 Sistemas de cores

Baseando-se nas propriedades e limitações do olho humano, o PDI desenvolve-se a fim de melhorar ao máximo a capacidade de adquirir informações além da percepção visual do homem. No que se refere às cores, o olho humano é capaz de detectar um número determinado de variações. As cores são ondas cujo o comprimento varia, e o olho humano é capaz de detectar colorações diferentes para cada comprimento diferente de onda.

No PDI, existem sistemas de cores amplamente utilizados para representação destas ondas. Cada sistema convencionou sua representação de forma diferente. No sistema RGB (*red, green, blue*), as cores vermelho, verde e azul são estabelecidas como cores primárias. Isto significa que todas as outras variações de cor deste sistema são derivadas destas três cores. O sistema CMY (*cyan, magenta, yellow*) utiliza como cores primárias o ciano, o magenta e o amarelo. O sistema CMYK (*cyan, magenta, yellow, black*) utiliza como cores primárias as mesmas cores do sistema CMY, acrescentando apenas o preto. No sistema YIQ, a componente Y representa a luminância do *pixel*, a componente I representa a interpolação e a componente Q representa a quadratura. A Equação (1) representa a conversão das componentes de cor do sistema RGB em componentes de cor do sistema YIQ. A Equação (2) representa a conversão inversa. A Figura 2 exibe (a) uma imagem original (b) com seus respectivos canais de cores RGB separados juntamente com sua representação no sistema YIQ.

$$\begin{cases} Y = 0.299*R + 0.587*G + 0.114*B \\ I = 0.596*R - 0.275*G - 0.321*B \\ Q = 0.212*R - 0.528*G + 0.311*B \end{cases} \quad (1)$$

$$\begin{cases} R = Y - 0.9563*I + 0.6210*Q \\ G = Y - 0.2721*I - 0.6474*Q \\ B = Y - 1.1070*I + 1.7046*Q \end{cases} \quad (2)$$

Figura 2 – (a) imagem original (b) canais separados: vermelho, verde, azul; imagem em escala de cinza.



Fonte: Flores (2017a).

2.2 Segmentação

A segmentação é uma habilidade humana utilizada para detectar objetos. Com o avanço dos sistemas computacionais, surgiu o interesse por métodos capazes de realizar a segmentação de forma automatizada. No contexto de imagens digitais, a segmentação divide-se em três principais técnicas: global, baseada em regiões e baseada em bordas. A primeira baseia-se nos valores relacionados à intensidade dos *pixels*. A segunda caracteriza-se por considerar regiões da imagem que apresentam características semelhantes. A terceira utiliza o conceito de bordas para detectar e representar bordas fechadas ao redor dos objetos da imagem.

Funções de processamento que incluem reconhecimento e interpretação estão associadas às aplicações de análise cujo o objetivo é a extração automática – ou mesmo parcialmente automática – de informações a partir de uma imagem (GONZALEZ e WOODS, 2008). Uma questão central acerca da segmentação de imagens é a redução de informações consideradas pouco relevantes, à medida que devem permanecer as informações mais relevantes. Na Visão Computacional, a segmentação consiste na decomposição de uma imagem nas regiões menores que a formam. Os objetos que compõem uma imagem possuem características específicas, tais como apresentar uniformidade nas propriedades dos *pixels* que o compõem e contrastar com os objetos espacialmente vizinhos.

A segmentação de imagens digitais trabalha basicamente sob dois princípios: decompor a imagem em partes para análises posteriores e realizar mudança no contexto de representação dos dados (SHAPIRO e STOCKMAN, 2001). O resultado final de um processo de segmentação é um conjunto de regiões homogêneas que enfatizam as diferentes regiões contidas na imagem.

A segmentação de imagens é basicamente um problema de percepção geofísica, e, portanto, não susceptível de uma solução puramente analítica (NIKHIL e SANKAR, 1993). Desta forma, grande parte dos algoritmos de segmentação de imagens são complementados por heurísticas que envolvem desde informação semântica até o conhecimento prévio da imagem de entrada. De forma geral, o desenvolvimento destes algoritmos leva em consideração duas características básicas dos *pixels*: similaridade e descontinuidade. Baseado nisto, a abordagem mais utilizada para segmentação de imagens digitais é a detecção de bordas e detecção de similaridade (GONZALEZ e WOODS, 2008).

2.2.1 Detecção de descontinuidade

As descontinuidades detectadas em uma imagem podem ser de três tipos: pontuais, linhas ou bordas de objetos. Estas feições se sobressaem das demais feições da imagem por possuírem tons de cinza contrastantes com a região em que se encontram (caso de pontos e linhas) ou por apontarem mudanças bruscas de tons de cinza entre regiões (caso de bordas e linhas).

Os algoritmos utilizados para detectar estas descontinuidades geralmente utilizam convolução, implicando o uso de máscara. Os métodos de detecção de descontinuidades, especialmente o de bordas e linhas, geralmente apresentam falhas de detecção. Portanto, grande parte destes métodos necessitam de tratamento após sua aplicação visando sanar estas falhas.

2.2.2 Detecção de pontos e linhas

A ideia principal empregada nesta técnica é que pontos e linhas possuem tons de cinza muito destoantes de seus vizinhos. Por isto, a detecção destas feições se realiza através da aplicação de uma máscara que forneça uma resposta R e um limiar não negativo T adequado. Ao aplicar a máscara nos *pixels* da imagem, aqueles que possuem valores acima do limiar estabelecido são detectados (GONZALEZ e WOODS, 2008).

Um ponto é detectado no local (x, y) em que a máscara está centrada se o módulo do valor de resposta da máscara nesse ponto exceder o limiar estabelecido. Esses pontos são

rotulados como 1 na imagem de saída, e todos os outros são rotulados 0, produzindo, assim, uma imagem binária. A Figura 3(a) exibe um exemplo de ponto a ser detectado pela aplicação desta abordagem, e a saída é obtida utilizando a expressão

$$g(x, y) = \begin{cases} 1 & \text{se } |R(x, y)| \geq T \\ 0 & \text{caso contrário.} \end{cases} \quad (3),$$

em que R representa um valor calculado pela aplicação da máscara e T representa um limiar fixo utilizado como critério de eliminação de *pixels*.

2.2.3 Detecção de bordas


A detecção de bordas é a abordagem mais utilizada na detecção de discontinuidades. Uma borda em uma imagem é interpretada como sendo o limite entre duas regiões com diferentes propriedades (GONZALEZ e WOODS, 2008). É importante ressaltar que, devido ao processo de amostragem, uma borda aparece com uma pequena suavização em torno do verdadeiro limite entre as regiões. Esta transição pode ser representada por uma função $f(x)$. Portanto, a detecção de bordas pode ser obtida através de operadores de diferenciação, como ilustra a Figura 3(b).

Existem três passos fundamentais a serem considerados na detecção de bordas: suavização da imagem para a redução de ruído, detecção de pontos de borda e detecção de localização da borda (GONZALEZ e WOODS, 2008). O primeiro passo pode ser aplicado utilizando um filtro gaussiano, por exemplo. O segundo passo é uma operação local que tira da imagem todos os pontos potencialmente candidatos a serem pontos de borda. O terceiro passo seleciona apenas os pontos com mais chances de serem uma borda, de fato. Para imagens, a função deve ser representada em espaço bidimensional, assumindo a forma $f(x, y)$, sendo as duas direções da Figura 3(b) representadas pelas derivadas em função do eixo x (direção vertical) e em função do eixo y (direção horizontal).

Figura 3 – (a) exemplo de um ponto candidato a ser detectado pela detecção de pontos e linhas.
 (b) Exemplo da aplicação de operadores de diferenciação para detecção de bordas.



(a)



(b)

Fonte: Gonzalez e Woods (2008).

2.2.4 Detecção de similaridade

A detecção de similaridade tem como objetivo analisar o interior dos objetos. Para isto, esta abordagem baseia-se na ideia de que *pixels* que compõem um mesmo objeto possuem propriedades semelhantes, enquanto que *pixels* que não possuem propriedades semelhantes são interpretados como pertencentes a objetos diferentes. A formulação estabelecida para este tipo de abordagem é dada por FU e MUI (1981). Considerando R uma imagem, a segmentação é a decomposição de R em n regiões $R_1, R_2, \dots, R_n$ de forma tal que:

$$\left\{ \begin{array}{l} \bigcup_{i=1}^n R_i = R \\ R_i \text{ é conectada, } i = 1, 2, \dots, n \\ R_i \cap R_j = \emptyset, \forall i \neq j \\ P_u(R_i) = \text{verdadeiro } \forall i \\ P_u(R_i \cap R_j) = \text{falso } \forall i \neq j \end{array} \right. \quad (4)$$

Pode existir um número de possíveis partições, mas a seleção adequada de um conjunto de partições depende da escolha da propriedade P_u associada à região, ou seja, do predicado de uniformidade dos *pixels* da região (PAVLIDIS, 1997).

2.2.5 Crescimento de regiões

O crescimento de regiões consiste em agrupar *pixels* ou sub-regiões em regiões maiores. Primeiramente, adota-se um conjunto de *pixels* “sementes”, a partir dos quais é realizado o crescimento das regiões por meio de inclusão de seus vizinhos que possuem atributos similares, tais como intensidade, textura, cor, etc. O crescimento se dá de forma iterativa até que as diferentes regiões possam ser definidas por polígonos fechados.

Apesar de seu funcionamento aparentemente simples, algumas dificuldades relacionadas à sua fundamentação podem ser apontadas. Uma dessas, é justamente a escolha do conjunto inicial de “sementes”. Uma outra dificuldade está na escolha do critério utilizado para estabelecer a similaridade dos *pixels*, já que as imagens variam de formatos e escala de cores.

2.2.6 Pirâmides

A abordagem de pirâmides divide a imagem em elementos de área arbitrários e disjuntos para que, após esta etapa, seja realizada a junção ou divisão das regiões. A abordagem mais utilizada para esta técnica é subdividir a imagem em quadrantes usando a estrutura de dados denominada QUADTREE (abreviatura da expressão em inglês *Quadratic Picture Tree*).

Nesta estrutura, a imagem é representada por um nó “pai” (nível $n = 0$), enquanto que os quatro quadrantes são representados por quatro nós “filhos” (nível $n = 1$). O problema com esta abordagem é definir o limite máximo dos níveis da *quadtree*, dado que as imagens podem variar de tamanho.

2.2.7 Detecção de bacias

A detecção de bacias pode ser vista como uma combinação entre a detecção de bordas e junção de regiões. Esta abordagem parte do princípio de que uma imagem em tons de cinza pode ser vista como um relevo topográfico formada por vales, os quais representam as regiões mais escuras da imagem, e por “montanhas”, as quais representam as porções mais claras da imagem.

É possível visualizar a “inundação” dos vales de duas maneiras distintas: a água vinda de cima, como se fosse chuva; ou vinda de baixo, como se o relevo estivesse perfurado nos pontos de altitude mínima e fosse imerso em um lago (ROERDINK e MEIJSTER, 2000). Conforme as bacias vão sendo inundadas, águas provenientes de diferentes bacias são

denominadas *watersheds*. Quando a água atinge o maior pico no relevo, o processo termina. O resultado da inundação é a separação das regiões que compõe a imagem delimitada pelas linhas divisórias das bacias.

2.2.8 Limiarização

O processo de limiarização se baseia na análise do histograma de frequências da imagem, em que as faixas de intensidades correspondem às bandas do histograma. Considerando um histograma bimodal, pode-se interpretar que haverá dois picos de frequência separados por um vale entre eles. Desta forma, pode-se assumir que há dois objetos na imagem, bem como um fundo e um objeto.

A limiarização simples é eficiente quando a imagem possui níveis de cinza bem distintos, regiões com intensidade uniforme resultam em picos elevados no histograma. O objetivo é encontrar o vale entre os dois picos estabelecendo um limiar apropriado que separe duas classes distintas. A escolha do limiar influencia diretamente na qualidade dos resultados. Em geral, um bom limiar pode ser selecionado se os picos do histograma são altos, estreitos, simétricos e separados por vales profundos. A Figura 4 exibe (a) uma imagem antes de ser submetida ao método de detecção de bordas baseado em limiarização de *Canny* e (b) o resultado depois da aplicação.

Figura 4 – (a) imagem original (b) imagem processada pelo método de Canny.



(a)

(b)

Fonte: Gonzalez e Woods (2008).

2.2.9 Agrupamento (*Clustering*)

Técnicas de agrupamento encontradas na literatura de reconhecimento de padrões aplicam a ideia de considerar a similaridade de *pixels* em regiões que apresentam características em comum. No *Clustering*, um conjunto de dados é substituído por grupos ou *clusters*. A definição de *cluster* parte da ideia de que valores de atributo (x) são vistos como pontos em um espaço com dimensão variável. Sendo assim, *clusters* são regiões contínuas deste espaço que contém uma alta densidade de pontos, podendo ser separadas de outras regiões por regiões com baixa densidade de pontos (EVERITT et al. 2001).

A partir desse ponto, duas abordagens para fundamentação dos algoritmos podem ser encontradas. A primeira leva em consideração o conceito de agrupamento rígido (em inglês, *hard* ou *crisp*), no qual cada ponto pertence a um único grupo. A segunda considera o conceito de agrupamento nebuloso (do termo em inglês *fuzzy*), onde cada ponto pertence a todos os grupos até certo grau. A abordagem mais adequada para fins de aplicação na segmentação de imagens, entretanto, é a primeira, pois não fere os princípios de segmentação por regiões estipulados por FU e MUI (1981).

2.3 Difusão Geométrica Markoviana (DGM)

Todas as técnicas de segmentação de imagens apresentadas nas seções anteriores abordam conceitos que envolvem propriedades pontuais de *pixels*. Algumas limitam-se a analisar o espaço geométrico entre regiões de interesse e levam em consideração parâmetros dependentes da percepção visual do usuário. Isto geralmente resulta em ineficiência dos algoritmos, pois os critérios utilizados nas abordagens se tornam susceptíveis a falhas. Nesta seção será introduzida uma nova abordagem para a segmentação de imagens digitais: a Difusão Geométrica Markoviana.

2.3.1 Cadeia de Markov


Uma cadeia de Markov pode ser descrita da seguinte maneira: seja $S = \{S_1, S_2, \dots, S_n\}$ um conjunto de estados. O processo começa em um desses estados e move-se sucessivamente de um estado para outro. Cada movimento é chamado de passo. Se a cadeia está atualmente no estado S_i , então ela se move para o estado S_j no próximo passo com uma probabilidade denotada

por S_{ij} , e essa probabilidade não depende dos estados ocorridos nos passos anteriores, apenas do estado atual. A probabilidade p_{ij} é chamada probabilidade de transição. O processo pode permanecer no estado em que se encontra e isso ocorre com probabilidade p_{ii} .

A matriz de transição construída pela DGM detém a estrutura geométrica local de um elemento. A representação geométrica local depende das propriedades utilizadas para a definição da função núcleo sobre o conjunto. A matriz de transição captura a anisotropia do conjunto utilizado para construí-la e se torna dependente da distribuição estacionária associada. O espectro da matriz de transição revela diversas propriedades estruturais do grafo que ela representa.

A vizinhança imediata de um vértice (estado) consiste no conjunto v de n vértices que estão ligados diretamente a ele. O grau de vizinhança de um vértice é flexível, sendo possível alterá-lo de acordo com a abordagem utilizada para cada solução. No caso das malhas triangulares tratadas pelo método de SOUZA (2011), os vértices possuem pesos em suas arestas que correspondem às probabilidades de sua relação com cada vizinho. Estes valores numéricos representam as relações existentes entre os estados das cadeias de Markov. A Figura 5 exibe (a) uma cadeia de Markov com 5 estados e (b) sua respectiva matriz de transição.

Figura 5 – (a) Cadeia de Markov com 5 estados. (b) Matriz de transição da cadeia ilustrada.



Fonte: Autoria própria.

A redução de vértices realizada nas malhas triangulares utilizando a DGM tem como um de seus princípios manter a conectividade do grafo. Isto permite que a redução seja realizada

sem prejudicar as características mais relevantes da forma analisada. A DGM é aplicada no cálculo das importâncias de cada vértice com o objetivo de extrair o máximo de precisão em relação às suas relevâncias. Isto minimiza eliminações inapropriadas, conservando as principais características das formas analisadas.

A diagonal principal da matriz de transição representa a semelhança de cada vértice com sua vizinhança. Quanto menor for o valor de x_{ij} presente na diagonal principal, maior a semelhança entre o vértice v_{ij} e sua vizinhança. Quanto maior for o valor de x_{ij} presente na diagonal principal, menor a semelhança entre o vértice v_{ij} e sua vizinhança. Neste caso, isto significa que o vértice v_{ij} que destoa dos demais de sua vizinhança corresponde a um vértice com alta importância para a composição da malha (detém feições do objeto), não podendo ser removido.

As probabilidades geradas pelo núcleo de difusão são calculadas levando em consideração a vizinhança dos vértices. Isto caracteriza atribuição probabilística dos pesos de forma genérica. A aplicação da DGM resolve o problema de atribuir os pesos das arestas manualmente. Estes pesos são obtidos através do cálculo realizado pelo núcleo de difusão tendo em vista a distância entre os vértices da malha. A multiplicação entre o grau de cada vértice e sua probabilidade correspondente na diagonal principal da matriz de transição se dá por

$$V(x_i) = P_{ii} * Deg(x_i) \quad (5) ,$$


em que $Deg(x_i)$ e P_{ii} são, respectivamente, o grau do ponto x_i e o seu valor correspondente na diagonal principal da matriz de transição.

Como cada valor de $V(x_i)$ é dependente dos valores dos seus respectivos grau e peso, não existe uma escala fixa que indique um limite para os valores nos vértices que são ou não representativos (SOUZA, 2011). Visando contornar isto, adotou-se um modelo gaussiano para a distribuição normal do conjunto de valores devido a sua capacidade de aprender sobre este conjunto. Esta distribuição fornece um intervalo de confiança utilizado para determinar a faixa de vértices a serem eliminados da malha. Como a distribuição gaussiana é uma distribuição estatística normal, valores com baixa probabilidade indicam pouca representatividade na composição da malha, podendo ser eliminados. Seguindo o mesmo raciocínio, aqueles com maiores probabilidades na distribuição indicam vértices que devem ser preservados.

O intervalo de confiança é construído pelos valores da média e do desvio padrão (μ e σ , respectivamente) do conjunto de dados. Sua definição se dá por $]0, \mu - k\sigma]$, em que k representa

um valor não nulo que especifica uma margem de segurança para a escolha do intervalo. Isto garante que nenhum dos pontos representativos sejam eliminados (SOUZA, 2011). A Figura 6 ilustra (a) uma distribuição gaussiana com cores representando os intervalos, indicando a representatividade dos vértices da malha e (b) um modelo *bunny* colorido de acordo com a representatividade de vértices definida na gaussiana.

Figura 6 – (a) gaussiana colorida de acordo com a representatividade dos vértices da malha. (b) modelo *bunny* ilustrando os vértices de acordo com a distribuição gaussiana.



Fonte: Souza (2011).

2.3.2 Definição do núcleo de difusão

Uma propriedade essencial de um método de simplificação é a avaliação da representatividade dos elementos sobre os quais ele atua. Aqueles considerados pouco representativos são removidos sem que o conjunto perca sua configuração característica. Um modo de agregar informação a cada elemento do conjunto está associado à análise das variações de suas propriedades (SOUZA, 2011).

A utilização de difusão geométrica no estudo das variações de propriedades avalia a concentração de informação que cada elemento detém. As variações locais das propriedades pertencentes à forma avaliada estão diretamente relacionadas à difusão. O núcleo de difusão é responsável por associar uma estrutura de vizinhança de um vértice com o conjunto de vetores

normais dos vértices da malha. No caso do método proposto por SOUZA (2011), utiliza-se um núcleo gaussiano definido por diferenças de normais dado por

$$k_n(x_i, x_j) = \begin{cases} e^{-\|N_i - N_j\|^2}, & \text{se } x_i \text{ e } x_j \text{ estão conectados por uma aresta.} \\ 0 & \text{se não.} \end{cases} \quad (6),$$

em que N_i e N_j são os vetores normais unitários definidos nos vértices x_i e x_j , respectivamente.

O Algoritmo 1 que SOUZA (2011) definiu indica os passos necessários para a construção de uma cadeia de Markov para um determinado conjunto X de elementos. Esta cadeia é descrita como uma matriz de probabilidades de transição (P) que guarda os pesos que a função núcleo atribui ao relacionamento existente entre os elementos do conjunto trabalho. O Algoritmo 1 é de forma tal que:

Algoritmo 1: Montagem da matriz de transição associada a um conjunto X .

Entrada: O conjunto X .

Saída: A matriz de transição P .

1. $\forall x_i, x_j \in X$, calcula-se $k(x_i, x_j) = e^{-\|N_i - N_j\|^2}$.
 2. Calcula-se o fator normalizador para cada um dos elementos, $d(x_i) = \sum_{x_j \in X} k(x_i, x_j)$.
 3. Calculam-se as probabilidades de transição pela normalização dos pesos,
- $$p(x_i, x_j) = \frac{k(x_i, x_j)}{d(x_i)}.$$
-

No caso do método proposto por este trabalho, os valores de N_i e N_j são analogamente representados pelos valores de cor dos *pixels* analisados em cada iteração. O parâmetro utilizado para calcular a importância de cada *pixel* é a distância de cor entre eles, que é calculada através da diferença entre a cor do *pixel* corrente e seus respectivos vizinhos imediatos.

3 MÉTODO DA SEGMENTAÇÃO POR DIFUSÃO GEOMÉTRICA MARKOVIANA (S-DGM)

O desenvolvimento do método S-DGM foi realizado utilizando a linguagem Java. Foram utilizadas classes nativas desta linguagem para manipular imagens em formato digital. Optou-se por Java pela sua vasta quantidade de bibliotecas que dão suporte à manipulação de imagens e pela simplicidade de leitura de dados.

3.1 S-DGM

O método S-DGM tem como principal característica a utilização de cadeias de Markov e núcleos geométricos de difusão para eliminar *pixels*. Esta seção apresenta o funcionamento do método, exibindo os algoritmos utilizados para sua construção. O método S-DGM é subdividido em três etapas: cálculo das importâncias, eliminação de *pixels* e redução de ruídos.

3.1.1 Cálculo das importâncias

O Algoritmo 2 implementa o núcleo da DGM e mapeia as importâncias dos *pixels* na matriz B . Aqui é estabelecido o uso das fórmulas de exponencial levando em consideração a distância entre as cores dos *pixels*. O Algoritmo 2 exhibe os passos para calcular as importâncias.

Algoritmo 2: Cálculo das importâncias aplicando-se DGM.

Entrada: A imagem I_I .

Saída: A matriz de importâncias B .

1. Inicializa-se a matriz B .
2. Define-se o núcleo da DGM tal que $k(p_{ij}, p_{kw}) = e^{-|p_{ij} - p_{kw}|}$, em que $|p_{ij} - p_{kw}|$ representa a distância entre o *pixel* (x_i, x_j) e o *pixel* (x_k, x_w) .
3. Para cada *pixel* de I_I , calcula-se o seu número de vizinhos $viz(p_i)$ e sua relação com a sua vizinhança aplicando-se o núcleo definido no passo 2.
4. Para cada $viz(p_i)$ e $k(p_i, p_k)$ calculados, calcula-se a importância do *pixel* p_i tal que

$$importância(p_i) = \frac{viz(p_i)}{1 + \sum e^{-|p_{ij} - p_{kw}|}} \text{ e armazena-se em } B.$$

3.1.2 Eliminação de *pixels*

O Algoritmo 3 apresenta os passos das duas primeiras etapas do método S-DGM, as quais consistem em duas chamadas ao mesmo método com passagem de parâmetros diferentes. Aqui, realiza-se a eliminação dos *pixels* que detêm menor importância na matriz de transição, implicando em uma remoção segura de *pixels*.

Algoritmo 3: Eliminação de *pixels* baseada em percentil.


Entrada: A imagem I_I e o valor numérico *valor*.

Saída: A imagem *retorno*.

1. Transforma-se I_I para a escala de cor YIQ e inicializa-se a matriz de booleanos C para mapeamento de *pixels* removidos em I_I .
 2. Calculam-se e mapeiam-se as importâncias de cada *pixel* de I_I em uma matriz D .
 3. Copia-se D para um vetor v ordenado e calcula-se $percentil = TamV * valor$, em que $TamV$ corresponde ao tamanho de v .
 4. Para cada elemento de D , eliminam-se os elementos que obedecem a $D(x, y) < percentil$ e mapeiam-se, em C , os *pixels* eliminados.
 5. Retorna-se a imagem segmentada *retorno*.
-

Ao término das duas primeiras etapas, obtém-se duas imagens segmentadas de acordo com o parâmetro *valor* passado para o Algoritmo 3. Todos os *pixels* eliminados das duas imagens obedecem à condição $D(x, y) < percentil$, e estão devidamente mapeados em suas respectivas matrizes associadas. A eliminação é realizada verificando-se todos os elementos de D , que consistem em importâncias calculadas pelo núcleo da DGM. A Figura 7 exibe uma imagem processada pelas duas primeiras etapas do método S-DGM.

Figura 7 – (a) imagem original. (b) imagem processada pela primeira etapa com parâmetro fixo em 0.50. (c) imagem processada pela segunda etapa com parâmetro fixo em 0.75.



Fonte: Águias, 2017.

3.1.3 Remoção de ruído

O método para a remoção de ruído visa eliminar os ruídos remanescentes nas imagens obtidas pelas duas primeiras etapas do método S-DGM. A abordagem deste método baseia-se na utilização de matrizes para mapear os *pixels* removidos e os não removidos de cada imagem. Para cada imagem obtida pelas duas primeiras etapas de S-DGM, associa-se uma matriz de

mapeamento de *pixels* eliminados, e o funcionamento deste método segue os passos descritos no Algoritmo 4.

Algoritmo 4: Eliminação de ruídos.

Entrada: As imagens I_1 e I_2 .


Saída: A imagem segmentada *retorno*.

1. Cria-se a matriz E e copia-se a matriz de mapeamento associada à I_1 para E .
 2. Para cada elemento $[i][j]$ da matriz F de mapeamento de *pixels* removidos em I_2 , é verificado se o *pixel* permanece ativo em I_2 pela condição $F_{[i][j]} == true$ e, caso esteja, $E_{[i][j]} = false$;
 3. Para cada $E_{[i][j]} == true$, elimina-se o *pixel* $I_{1[i,j]}$.
 4. Para cada *pixel* $I_{1[i,j]}$, elimina-se o *pixel* que possui menos de seis vizinhos imediatos.
 5. Retorna-se a imagem segmentada *retorno*.
-

Esta abordagem não elimina todos os ruídos possíveis presentes na imagem. O resultado consiste em uma imagem com ruído reduzido, porém não completamente removido. Para isto, deve-se elaborar um estudo específico voltado à eliminação genérica de ruídos em imagens. Esta tarefa é, ainda, área de pesquisa no PDI e na Visão Computacional, dada sua complexidade de desenvolvimento.

O método S-DGM baseia-se na difusão geométrica aplicada à imagem considerando a vizinhança imediata de cada *pixel* processado. Isto implica que o método calcula a relevância de cada *pixel* baseando-se nas diferenças de cor entre o *pixel* corrente e sua vizinhança. Devido a essa abordagem, o método apresenta uma falha de execução em imagens que possuem pouca variação de cor, resultando em uma imagem não segmentada. A Figura 8 exibe um exemplo de falha numérica do método S-DGM. A Figura 9 exibe uma imagem processada pelo método de remoção de ruído.

Figura 8 – (a) imagem original. (b) imagem não segmentada, indicando falha de execução no método S-DGM.



(a)

(b)

Fonte: Gonzalez e Woods (2008).

Figura 9 – (a) imagem original. (b) imagem processada pela primeira etapa de S-DGM com parâmetro fixo em 0.59. (c) imagem processada pela segunda etapa de S-DGM com parâmetro fixo em 0.66. (d) imagem final processada pela remoção de ruído.



(a)

(b)



(c)

(d)

Fonte: Cavalos, 2017.


4 RESULTADOS

Este capítulo apresenta os resultados obtidos com o método S-DGM e uma breve discussão acerca destes. As imagens utilizadas para testes variam de resolução e de níveis de cinza a fim de expor o poder de desempenho do método. Algumas imagens possuem pouca variação de cor, explorando a capacidade do método de determinar a importância dos *pixels*, segmentando a imagem de acordo com a relevância dos objetos detectados.

Por se tratar de um método não linear, os resultados não seguem um padrão constante de comportamento. Isto significa que o método S-DGM pode ser melhorado em propostas futuras. Para abordar o desempenho do método com imagens de resolução baixa, a Tabela 1 exibe apenas imagens com resolução abaixo de 1000x1000. Para exibir a eficácia do método na associação de importâncias aos *pixels* da imagem, a Tabela 2 exibe apenas imagens com resolução acima de 1000x1000.

Tabela 1 – Imagens de teste com resoluções inferiores a 1000x1000.

 1	 2	 3
 4	 5	 6




Fonte: Amoras (2017), Araras (2017), Árvores (2017), Castelos (2017), Dados (2017), Fingerprint (2017), Gonzalez e Woods (2008), Ursos (2017).

Tabela 2 – Imagens de teste com resoluções superiores a 1000x1000.



1



2




3



4



5



6




7



8



9



10




11



12




13




14




15



16




17



18



19



20

Fonte: Balões (2017), Cadeiras (2017), Continentes (2017a), Continentes (2017b), Falcões (2017), Flores (2017b), Microscópio (2017), Motores (2017), Rodas (2017), Tapetes (2017).

O método S-DGM considera importantes os *pixels* da imagem que apresentam importâncias maiores ou iguais ao percentil calculado no Algoritmo 3. Nas imagens 10 e 11 da Tabela 1 nota-se que há perda de bordas durante a eliminação de *pixels*. Isto pode ocorrer devido à pequena variação de cor entre os objetos de um plano da imagem e objetos de outro plano. Para os objetos que não possuem bordas definidas, a probabilidade de perda de suas características tende a ser maior que para objetos com bordas bem definidas.

De modo geral, imagens que apresentam baixa resolução tendem a apresentar perdas em relação às características dos objetos, uma vez que estas imagens podem ser provenientes de pré-processamentos ou compressão/compactação de imagens. Imagens com alta resolução tendem a preservar as características dos objetos presentes, e o S-DGM associa importâncias altas para estas características. Isto significa que a variação de cinza entre as bordas do objeto e o fundo é grande, o que torna o método eficaz e permite a eliminação adequada de *pixels*.

As imagens da Tabela 2 foram processadas com o mínimo de perda nas características dos objetos presentes. Além da eliminação adequada de *pixels*, o método S-DGM elimina uma quantidade relevante de ruídos, implicando em maior qualidade visual nos resultados. É possível perceber que nas imagens 1, 15 e 17 da Tabela 2 a quantidade de *pixels* internos aos objetos é maior. Isto significa que a imagem de entrada possui alto nível de detalhes visuais identificados pelo método e, como esperava-se, foram associadas importâncias altas a estes detalhes, preservando-os na imagem.

5 CONCLUSÃO E TRABALHOS FUTUROS

A partir da ideia de uma nova abordagem para explorar o ramo da segmentação de imagens no PDI, este trabalho propôs uma expansão da DGM a fim de segmentar imagens de acordo com a aplicação das cadeias de Markov. O enfoque deste trabalho é possibilitar a segmentação de imagens digitais através do método S-DGM. O método S-DGM é resultado de pesquisas iniciais nesta área, o que significa que sua aplicação pode ganhar novos significados, se estudado de forma aprofundada e testado de forma genérica.

Os resultados obtidos se mostram satisfatórios dependendo do nível de precisão exigido por cada aplicação do mundo real. Como visto, a Tabela 1 exibe um conjunto de exemplos e resultados para imagens com resolução baixa e pouca variação de cinza. Isto explora a capacidade do método de atribuir representatividade aos *pixels*, ainda que a percepção de usuário deixe a desejar no que se refere a identificar todas as características relevantes dos objetos (tais como bordas totalmente representadas e sem falhas).

A qualidade dos resultados depende diretamente da qualidade da imagem que o método S-DGM recebe como entrada. É possível notar na Tabela 2 que as imagens que foram submetidas ao método possuem maiores resoluções e variações de cor mais acentuadas. Isto permite que o método associe com mais precisão as importâncias que cada *pixel* possui na imagem, o que possibilita a segmentação com pouco ruído e com preservação do maior número de características relevantes de cada objeto.

Como trabalhos futuros, pretende-se explorar o método S-DGM visando sua aplicação em imagens de forma genérica. Isto requer um estudo especializado e integração com outras áreas relacionadas ao PDI, tais como Inteligência Artificial e Visão Computacional. Pretende-se, ainda, elaborar meios de validação dos resultados, seja por percepção de usuário ou por interpretação computacional. O método S-DGM sintetiza de forma concisa uma aplicação real para a Difusão Geométrica Markoviana. Além disso, trabalhos futuros podem ser feitos explorando-se mais núcleos, além do exponencial, e utilizando-se outras estratégias para a determinação de vizinhanças entre os *pixels*.

REFERÊNCIAS

Águias. Disponível em: <<http://1.bp.blogspot.com/-OssSZFc057w/Uoy85mfbAi/AAAAAAAAABBY/0ACnI5N-5IE/s1600/0000000.jpg>>. Último acesso em 03/08/2017.

Amoras. Disponível em: <https://http2.mlstatic.com/5-mudas-de-amora-preta-produz-no-primeiro-ano-D_NQ_NP_14004-MLB4173366194_042013-O.jpg> . Último acesso em 03/08/2017.

Araras. Disponível em: <http://www.patobranco.com/arquivos/noticias/gde_f7eaf6eeb109e27ab05f0adc39d086bc.jpg>. Último acesso em 03/08/2017.

Árvores. Disponível em: <https://vontadedemaismyblog.files.wordpress.com/2011/01/santa_clara_182.jpg> . Último acesso em 03/08/2017.

Balões. Disponível em: <<https://i.ytimg.com/vi/9FqBJILuK9o/maxresdefault.jpg>>. Último acesso em 03/08/2017.

Cadeiras. Disponível em: <<http://1.bp.blogspot.com/-vnGg7gPBFhs/U6HPjczpR2I/AAAAAAAAAXk/wBD8fzPRjMo/s1600/Cadeiras-Vintage-Color-REuse.jpg>> .Último acesso em 03/08/2017.

Castelos. Disponível em: <https://joaquimnery.files.wordpress.com/2013/05/dsc_0861.jpg?w=640&h=425> . Último acesso em 03/08/2017.

Cavalos. Disponível em: <<http://www.racas-cavalos.com/Imagens/cavalo-mustang-selvagem.jpg>>. Último acesso em 03/08/2017.

Continentes. 2017 a. Disponível em: <http://www.intelligence-airbusds.com/files/pmedia/public/r341_9_satellite_image_spot5_oleron_island_france_2003-2.jpg>

Continentes. 2017 b. Disponível em:
 <<http://content.satimagingcorp.com/static/galleryimages/rapideye-burghausen-germany.jpg>>.
 Último acesso em 03/08/2017.

Dados. Disponível em: <<https://www.papeldeparedede.etc.br/fotos/wp-content/uploads/Dado16.jpg>> .Último acesso em 03/08/2017.

DUÍLIO, A. N. S. S.; SOUZA, L. C.; MOTTA, G. H. M. B. **An instance selection method for large datasets based on markov geometric diffusion.** *Data & Knowledge Engineering*, vol.101, pp. 24-41, ISSN 0169-023X, 2016.

EVERITT, B. S (2001). **Cluster Analysis.** Wiley, 5th edition.

Falcões. Disponível em: <<http://img.animal-photos.ru/birds/hawk/hawk9.jpg>>. Último acesso em 03/08/2017.

Fingerprint. Disponível em: <<http://uploads.static.vosizneias.com/2009/02/fingerprint.jpg>> .
 Último acesso em 03/08/2017.

Flores. 2017a. Disponível em: <https://http2.mlstatic.com/painel-adesivo-parede-flores-coloridas-rosa-tulipas-orquidea-D_NQ_NP_12736-MLB20065180610_032014-F.jpg>.
 Último acesso em 03/08/2017.

Flores. 2017b. Disponível em: <http://1.bp.blogspot.com/-kS5mNK6XwUk/UF7uc7zll4I/AAAAAAAAABXM/63qEFFXKWH4/s1600/JineshVarghese411-15-2011%2B12_59_53%2BPM.jpg>. Último acesso em 03/08/2017.

FU, K. S.; MUI, J. K. **A survey on image Segmentation.** *Pattern Recognition*, vol 13, pp 3-16, ISSN 0031-3203, 1981.

GONZALEZ, R. C.; WOODS, R. E. (2010). **Processamento Digital de Imagens.** Pearson, 3rd edition.

NIKHIL, R. P.; SANKAR, K. P. **A review on image segmentation techniques.** *Pattern Recognition*, vol. 26, pp 1277-1294, ISSN 0031-3203,1993.

Microscópio. Disponível em: <https://fullerfuture.files.wordpress.com/2015/01/biomimicry-misc_pollen.jpg>. Último acesso em 03/08/2017.

Motores. Disponível em: <https://www.zr.ru/_ah/img/eKoPE0hMQUGOV2eZRWa4gg=s800> . Último acesso em 03/08/2017.

PAVLIDIS, T. (1997) **Structural Pattern Recognition.** New York: Springer Verlag.

Rodas. Disponível em: <<http://automoveis.freewords.com.br/wp-content/gallery/aros-esportivos/aros-esportivos-carro-esportivo9.jpg>> . Último acesso em 03/08/2017.

ROERDINK, J. B. MEIJSTER, A. **The watershed transform: Definitions, algorithms and Parallelizations strategies.** *Fundamenta Informaticae*, vol. 41, ISSN:0169-2968, pp. 187-228, 2000.

SHAPIRO, L. G.; STOCKMAN, G. C. **Computer Vision.** New Jersey: Prentice-Hall, 2001.

SOUZA, L. C. **Simplificação de malhas com preservação de feições baseada em difusão geométrica markoviana.** Dissertação de mestrado defendida no programa de PÓS GRADUAÇÃO EM MATEMÁTICA na Pontifícia Universidade Católica do Rio de Janeiro (PUC-Rio), 2011.

Tapetes. Disponível em: <<https://img.elo7.com.br/product/original/105205D/jogo-tapete-xadrez-tapete-croche.jpg>> . Último acesso em 03/08/2017.

Ursos. Disponível em: <<http://www.educationquizzes.com/library/KS1-Science/Living-Things-9.jpg>> . Último acesso em 03/08/2017.