

UNIVERSIDADE ESTADUAL DE MARINGÁ
CENTRO DE TECNOLOGIA
DEPARTAMENTO DE INFORMÁTICA
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

SÉRGIO GRIJÓ DE SOUSA FILHO

**Análise de Critérios e Métricas para Filtragem por Atributo em
Imagens Coloridas**

Maringá

2018

SÉRGIO GRIJÓ DE SOUSA FILHO

**Análise de Critérios e Métricas para Filtragem por Atributo em
Imagens Coloridas**

Dissertação apresentada ao Programa de Pós-Graduação em Ciência da Computação do Departamento de Informática, Centro de Tecnologia da Universidade Estadual de Maringá, como requisito parcial para obtenção do título de Mestre em Ciência da Computação.

Orientador: Prof. Dr. Franklin Cesar Flores

Maringá
2018

Dados Internacionais de Catalogação-na-Publicação (CIP)
(Biblioteca Central - UEM, Maringá – PR, Brasil)

S725a Sousa Filho, Sérgio Grijó de
Análise de critérios e métricas para filtragem
por atributo em imagens coloridas / Sérgio Grijó de
Sousa Filho. -- Maringá, PR, 2018.
46 f.: il. col.

Orientador: Prof. Dr. Franklin Cesar Flores.
Dissertação (mestrado) - Universidade Estadual de
Maringá, Centro de Tecnologia, Departamento de
Informática, Programa de Pós-Graduação em Ciência da
Computação, 2018.

1. Processamento de imagens. 2. Filtragem por
atributo. 3. Processamento de cor. I. Flores,
Franklin Cesar, orient. II. Universidade Estadual de
Maringá. Centro de Tecnologia. Departamento de
Informática. Programa de Pós-Graduação em Ciência da
Computação. III. Título.

CDD 23.ed. 006.42

Márcia Regina Paiva de Brito – CRB-9/1267

FOLHA DE APROVAÇÃO

SÉRGIO GRIJÓ DE SOUSA FILHO

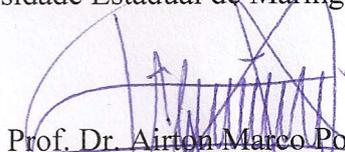
Análise de critérios e métricas para filtragem por atributo em imagens coloridas

Dissertação apresentada ao Programa de Pós-Graduação em Ciência da Computação do Departamento de Informática, Centro de Tecnologia da Universidade Estadual de Maringá, como requisito parcial para obtenção do título de Mestre em Ciência da Computação pela Banca Examinadora composta pelos membros:

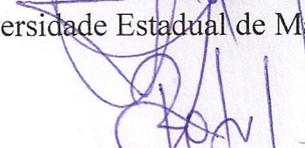
BANCA EXAMINADORA



Prof. Dr. Franklin César Flores
Universidade Estadual de Maringá – DIN/UEM


Prof. Dr. Airton Marco Polidorio

Universidade Estadual de Maringá – DIN/UEM


Prof. Dr. Roberto de Alencar Lotufo

Universidade Estadual de Campinas – DCA/Unicamp

Aprovada em: 08 de fevereiro de 2018.

Local da defesa: Sala 101, Bloco C56, *campus* da Universidade Estadual de Maringá.

AGRADECIMENTOS

Agradeço primeiramente a Deus por me acompanhar nessa longa jornada, sempre me oferecendo sua luz nos momentos onde uma solução parecia não existir, para que pudesse ter o olhar de serenidade necessário para a exploração de novas trilhas. Agradeço também a todas as pessoas que contribuíram de alguma forma para meu desempenho no desenvolvimento deste trabalho, especialmente queria agradecer:

Ao meu pai Sérgio Grijó de Sousa por me incentivar a sempre buscar meu desenvolvimento pessoal e profissional e à minha mãe Zilda Moda pelo suporte estrutural, financeiro e moral.

À minha namorada Fernanda Tamy Ishii, que conheci no mestrado, pelo companheirismo, por me aguentar nos momentos difíceis, respeitar os meus momentos e por compartilhar todos os outros.

Ao meu orientador professor Dr. Franklin César Flores pela amizade, pelo ensino, pelas sugestões, por me guiar e por não me deixar perder o foco.

Aos demais professores que durante toda minha vida ajudaram no meu crescimento e a quem devo o conhecimento, o entendimento e o discernimento que possuo hoje.

Aos colegas de mestrado pelas quartas-feiras do sonho na igreja, pelos tabuleiros de sexta a noite e pelas eventuais idas ao mercadinho que ajudaram a aliviar a pressão provendo alguns minutos de distração.

E ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pela bolsa de mestrado concedida para a realização desta pesquisa.

Análise de Critérios e Métricas para Filtragem por Atributo em Imagens Coloridas

RESUMO

Aberturas e afinamentos por atributo são operadores conexos morfológicos que removem estruturas de imagens de acordo com um dado critério. Tais operadores foram estendidos com sucesso de imagens binárias para escala de cinza, mas tal extensão para imagens coloridas não é trivial. Este trabalho propõe operadores por atributo colorido por uma combinação de gradientes coloridos e decomposição por valor de limiar. Nesta abordagem, não somente critérios estruturais podem ser aplicados, mas também critérios baseados em características e estatísticas de cor. São apresentadas duas aplicações: 1) dois critérios baseados na avaliação não-supervisionada de segmentação para a melhorar resultados de segmentação colorida; exemplos de segmentação com aplicação desses operadores conquistaram resultados 80% mais qualitativo e quantitativo e que dois métodos recomendados na literatura em um estudo de casos com 300 imagens; 2) um critério baseado na divergência do histograma de cor para um modelo harmônico; outro experimento realizado mostra que o uso da segmentação harmônica permitiu uma correção de matiz que preserva regiões harmônicas.

Palavras-chave: Filtragem por Atributo. Segmentação de Imagem. Decomposição por valor de limiar. Processamento de Cor.

Metric and Criteria Analysis for Color Image Attribute Filtering

ABSTRACT

Attribute openings and thinnings are morphological connected operators that remove structures from images according to a given criterion. These operators were successfully extended from binary to grayscale images, but such extension to color images is not straightforward. This work proposes color attribute operators by a combination of color gradients and thresholding decomposition. In this approach, not only structural criteria may be applied, but also criteria based on color features and statistics. This work presented: 1) two criteria based on unsupervised segmentation evaluation for improvement of color segmentation; segmentation using these operators performed better than two state-of-the-art methods in 80% of the results of a experiment done using 300 images; 2) a criterion based on color histogram divergence from a harmonic model; another experiment concluded that using the harmonic segmentation permitted a hue correction that preserved harmonic regions.

Keywords: Attribute Filter. Image Segmentation. Thresholding Decomposition. Color Processing.

LISTA DE FIGURAS

Figura - 2.1	Modelos de cor RGB e CMYK	13
Figura - 2.2	Exemplo de operações morfológicas	16
Figura - 2.3	Exemplo de <i>Watershed</i>	18
Figura - 2.4	Exemplo de filtragem por atributos.	23
Figura - 3.1	Fluxograma da filtragem por atributo colorido.	25
Figura - 3.2	Modelos harmônicos T_m . Uma área em cinza representa um setor de valores de matiz que compõe o modelo harmônico. . .	29
Figura - 4.1	Exemplo de segmentação: (b), (c), (d), (e), (f) e (g) são segmentações de (a) com 8 regiões.	32
Figura - 4.2	Curvas geradas a partir da experimentação com a amostra "138078".	33
Figura - 4.3	Síntese dos resultados: (a), (b), (c), (d), (e), (f), (g) e (h) mostram quão bem um método foi em relação a outro.	35
Figura - 4.4	Exemplo do gradiente usando a distância harmônica.	37
Figura - 4.5	Exemplo da segmentação harmônica.	38
Figura - 4.6	Exemplo de divisão do círculo cromático.	38
Figura - 4.7	Comparação do mapeamento de cor sem e com o suporte do critério de harmonia.	39

LISTA DE SIGLAS E ABREVIATURAS

BSDS500: *Berkeley Segmentation Dataset and Benchmark 500*

CIE: *Commission Internationale de l'Éclairage*

CNPq: Conselho Nacional de Desenvolvimento Científico e Tecnológico

MAMBA: *Mathematical Morphology Library*

MM: Morfologia Matemática

SLIC: *Simple Linear Iterative Clustering*

SUMÁRIO

1	Introdução	9
1.1	Motivação e Justificativa	10
1.2	Objetivo	10
1.2.1	Objetivos Específicos	11
1.3	Organização do Trabalho	11
2	Revisão de Literatura	12
2.1	Imagens Digitais	12
2.2	Morfologia Matemática	14
2.3	Segmentação	16
2.4	Filtragem por Atributos	18
3	Filtragem por Atributo Colorido	24
3.1	Visão Geral	24
3.2	Definição	24
3.3	Algoritmo	25
3.4	Aplicação	26
3.5	Crterios de Avaliao de Segmentao	26
3.5.1	Erro Mdio	27
3.5.2	Entropia	27
3.6	Crterio de Harmonia de Cor	27
3.6.1	Divergncia de Kullback-Leibler	28
4	Experimentos	30
4.1	Implementao	30
4.2	Base de Dados	30
4.3	Melhorias para a Segmentao de Imagens Coloridas	31
4.3.1	Resultados Experimentais	31
4.4	Melhorias para Harmonizao de Cores	34
5	Conclusões	40
5.1	Dificuldades Encontradas	41
5.2	Trabalhos Futuros	41
	REFERÊNCIAS	42

Introdução

A Morfologia Matemática (MM) une uma base matemática sólida com foco em aplicações práticas que compuseram 5 décadas de contribuições fantásticas para o processamento de imagens. Fundada na Escola Nacional Superior de Minas de Paris em Fontainebleau, França por Matheron e Serra (Matheron, 1975; Serra, 1982, 1988), a morfologia foi expandida por três gerações de pesquisadores e aplicada a ciência geodésica e sensoriamento remoto (Soille e Pesaresi, 2002), imageamento biomédico (Yu-qian et al., 2006), ciência dos materiais (Coster e Chermant, 2001), análise de dados (Haralick et al., 1987), processamento de documentos (Hasan e Karam, 2000), recuperação de informação baseada em conteúdo (Karvonen et al., 2010), vigilância por vídeo (Foresti, 1999), controle industrial (Serra, 1996) e visualização (Roerdink, 2011), entre outras aplicações.

A MM baseia-se em 2 operadores básicos e na definição de um elemento estruturante (Najman e Talbot, 2013), que tem a função de definir a relação de vizinhança entre pixels de uma região da imagem. Esses dois operadores, a dilatação e a erosão, formam a base da MM, de tal forma que todos os outros operadores e filtros podem ser definidos a partir deles. Para que tais operadores básicos sejam definidos é necessário que os pixels da imagem possuam uma relação de ordem parcial, ou seja, que para qualquer par de pixel seja necessário saber um valor que seja maior ou igual e um valor que é menor ou igual a ambos.

Um dos filtros da MM, definido por Breen e Jones (1996) é a filtragem por atributos. Nela é possível realizar uma análise estrutural na imagem e remover componentes que não atingem um dado critério. Critérios estruturais amplamente utilizados são: área, altura e volume. Essa filtragem foi primeiramente definida para imagens binárias e

expandida para imagens em tons de cinza pela decomposição por valor de limiar, onde uma imagem cinza é decomposta em uma sequência de imagens binárias de tal forma que suas somas resultam na imagem original. A filtragem é realizada em cada uma dessas imagens e o resultado é composto pela soma de todas as imagens filtradas.

A filtragem por atributos entra em uma categoria de filtros morfológicos tida como operadores conectados. Esses operadores, definidos por Serra e Salembier (1993), tem a função de fundir regiões planas de uma imagem e possuem a propriedade de, apesar de remover, não criar novas bordas. Para os operadores anti-extensivos, como é o caso da filtragem por atributos, é possível, ao representar formalmente uma imagem como uma *max-tree*, realizar a filtragem como uma poda na árvore (Salembier et al., 1998). A filtragem por atributos é definida pra imagens binárias e estendida para imagens em tons de cinza, porém não é aplicável em imagens coloridas pois essas não possuem uma relação de ordem.

Existem diversos trabalhos que abordam a extensão da MM para imagens coloridas. Por não ser uma extensão trivial, eles aplicam alguma restrição para torná-la possível e portanto não são genericamente aplicáveis. Alguns trabalhos forçam uma ordem como por *bit interlacing* (Chanussot e Lambert, 1997) e cascata lexicográfica (Angulo, 2007). Outros trabalhos abordam a criação de um gradiente colorido (Angulo e Serra, 2003) que servem como base para uma segmentação. Mais recentemente Boroujerdi et al. (2015) se utiliza da formalização da dilatação e da erosão em termos de equações diferenciais parciais.

1.1 Motivação e Justificativa

Pontos que são motivadores e justificam este trabalho: o crescimento da disposição e utilização de imagens coloridas por conta principalmente da popularização dos *smartphones* e da expansão da internet móvel, de que não existe uma solução definitiva para MM colorida, a importância da filtragem por atributos e os ganhos possíveis pelo uso de dados de cor na análise de imagens.

1.2 Objetivo

Este trabalho propõe a expansão da filtragem por atributos para utilizar critérios de cor. Esse novo filtro opera uma imagem colorida e retorna um gradiente filtrado. Para

tal, ele utiliza um gradiente colorido e uma função para avaliar a imagem a cores no cálculo do atributo.

1.2.1 Objetivos Específicos

Este trabalho também apresenta dois novos critérios de cor baseados em métodos de avaliação de segmentação e um critério baseado na harmonia de cores.

1.3 Organização do Trabalho

O texto está organizado em 6 seções, sendo que nesta primeira foram introduzidos o contexto, as motivações e o objetivo deste trabalho. Na seção 2 é apresentada uma revisão de literatura contendo os conceitos em que este trabalho se baseia. A extensão da filtragem por atributos para imagens coloridas, bem como a investigação dos critérios de cor utilizados é feita na seção 3. Os experimentos realizados são apresentados e discutidos na seção 4. Por fim, retomando o que foi visto, na seção 5 é feita a conclusão deste trabalho.

Revisão de Literatura

2.1 Imagens Digitais

Fisicamente, uma imagem é representada no espaço contínuo. Esse espaço ao ser imageado por um sensor de aquisição é convertido para a forma digital. Esses dispositivos são capazes de discretizar esse espaço bem como a quantizar a energia associada com essas regiões discretizadas do espaço.

A *imagem digital* mais simples é a imagem em preto e branco, também chamada de binária. Pode ser representada por uma matriz contendo apenas 0s e 1s; um conjunto de pontos (também chamados de pixels); e por uma função que associa valores com esses pixels (Gonzalez e Woods, 2002).

Seja $E \subset \mathbb{N} \times \mathbb{N}$ um subconjunto retangular finito de pontos. Uma *imagem binária* X é um subconjunto de E e o conjunto potência $\mathcal{P}(E)$ é o conjunto de todas as imagens possíveis de E . Também pode ser representada pela função:

$$F : E \longrightarrow \{0,1\} \quad (2.1)$$

onde $X = \{p \in E : F(p) = 1\}$.

A expansão para *imagens em tons de cinza* se dá por simplesmente alterar o contra-domínio para um intervalo de números inteiros e pode ser representada pela função:

$$F : E \longrightarrow [0,2^k) \quad (2.2)$$

onde k é a resolução radiométrica do sensor. Determina o número de bits que deve ser usado para quantizar a energia radiante refletida pelos elementos dispostos no espaço

discretizado. Pode-se dizer que uma imagem binária é uma imagem cinza onde o valor de $k = 1$.

Para representar *imagens coloridas*, é alterada a dimensão do contra-domínio da função para representar dados adquiridos de diferentes faixas do espectro eletromagnético. A representação é dada pela função:

$$F : E \longrightarrow [0, 2^k) \times [0, 2^k) \times [0, 2^k) \quad (2.3)$$

Cada banda pode ser interpretada como uma imagem em tom de cinza que são combinadas por *modelos de cores* para representar o espectro de cor visível. A figura Figura - 2.1 mostra os modelos de cor RGB e CMYK, nesses modelos as bandas são combinadas de forma aditiva e subtrativas, respectivamente.

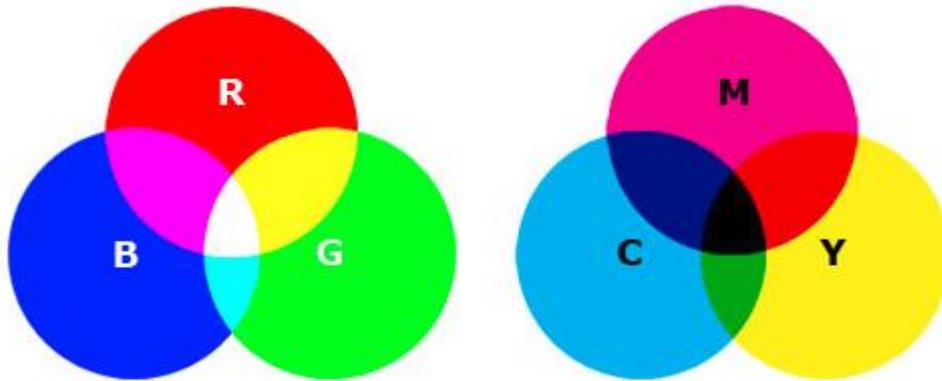


Figura 2.1: Modelos de cor RGB e CMYK

O CMYK é mais utilizado na impressão de imagens, enquanto o RGB é utilizado por dispositivos que emitem luz, como é o caso dos monitores. Porém o RGB não possui a capacidade de representar todo o espectro de cor e é dependente do dispositivo que capturou a imagem.

Outro espaço de cor relevante é o Lab, o qual é utilizado neste trabalho. Ele é independente de dispositivo e tem a propriedade de que a distância euclidiana calculada a entre duas cores é proporcional a diferença entre essas cores pela percepção humana (Pauli, 1976).

2.2 Morfologia Matemática

Inicialmente com aplicações para a análise de minerais, a *morfologia matemática* foi expandida utilizando a abstração de *reticulado completo* e tem hoje aplicações em inúmeros problemas de processamento de imagens (Matheron, 1975; Serra, 1982, 1988).

A *morfologia* é construída a partir de *quatro operações básicas* que transformam a imagem de acordo com o chamado *elemento estruturante*. Esse elemento pode ser representado por uma imagem binária e define uma relação de *vizinhança* e *conectividade* em que a operação é realizada (Najman e Talbot, 2013).

A *vizinhança* B_x de um pixel x de acordo com um elemento estruturante B é dada por $\{x + b : b \in B\}$. Ou seja, y pertence a B_x se for igual a x transladado de acordo com algum pixel b do elemento estruturante. A origem é o elemento neutro da translação, ela estar contida no elemento estruturante implica que os pixels são vizinhos a eles mesmos. Sendo \check{B} o conjunto simétrico de B (isto é, $\check{B} = \{-b, b \in B\}$), quando $B = \check{B}$, $y \in B_x$ implica em $x \in B_y$. Diz-se 4-conexo a vizinhança definida pelo elemento estruturante $\{(0, -1), (-1, 0), (0, 0), (0, 1), (1, 0)\}$, e 8-conexo a vizinhança definida pelo elemento estruturante do 4-conexo unido com o conjunto $\{(-1, -1), (-1, 1), (1, 1), (1, -1)\}$.

Em uma imagem binária X , um par de pixel x_0 e x_n são ditos *conexos* se existe um caminho $\pi = \langle x_0, \dots, x_n \rangle$ onde, para todo $i \in [1, n]$, x_{i-1} é vizinho de x_i e x_{i-1} e x_i pertencem a X . Um subconjunto C de uma imagem é chamado de *componente conexo* se, e somente se, todo par de pixel x_0 e x_n pertencentes a C estão conexos.

Uma *zona plana* Z é uma expansão desse conceito para uma imagem em tons de cinza F . De maneira similar, todo par de pixel x_0 e x_n pertencentes a Z são conexos por um caminho onde todos os pixels pertencentes ao caminho tem o mesmo valor.

A morfologia se utiliza do conceito de *reticulado* (E, \leq) com o conjunto E dotado de uma relação de ordem \leq . Um reticulado é dito completo se para qualquer subconjunto P de E possui um *supremo* $\bigvee P$ e um *ínfimo* $\bigwedge P$ pertencentes a E . O *supremo* é basicamente o menor elemento de E que é maior ou igual a todos os elementos de P . Reciprocamente, o *ínfimo* é o maior elemento de E que é menor ou igual a todos os elementos de P . Além disso, se a relação de ordem é total o supremo e o ínfimo vão estar contidos em P .

Reticulados podem ser definidos de forma trivial para as imagens em preto e branco, e imagens em tons de cinza mas não para as imagens coloridas. Como a relação de ordem entre cores é parcial, o uso de supremo e ínfimo em uma imagem colorida pode ocasionar o efeito de falsa cor, isto é, o aparecimentos de cores que não

pertenciam à imagem. Uma maneira de tentar contornar isso é definir uma relação de ordem entre as bandas, realizar uma técnica chamada de entrelaçamento de bits, ou o mais usual, gerar uma imagem cinza a partir da imagem colorida.

O operador de *erosão*, equação 2.4, tem a propriedade de expandir as regiões mais escuras e nivelar as regiões mais claras menores que o elemento estruturante. Seja F a imagem a ser operada, B o elemento estruturante e x e y pixels da imagem, o valor do pixel x na imagem erodida é o menor valor dentre seus vizinhos em F .

$$\varepsilon_B(F)(x) = (F \ominus B)(x) = \bigwedge_{y \in B_x} F(y) \quad (2.4)$$

De maneira dual, a *dilatação*, equação 2.5, tem a propriedade de expandir as regiões mais claras e nivelar as regiões mais escuras menores que o elemento estruturante. O valor do pixel x na imagem dilatada é o maior valor dentre seus vizinhos, de acordo com o simétrico do elemento estruturante, em F .

$$\delta_B(F)(x) = (F \oplus B)(x) = \bigvee_{y \in (\check{B})_x} F(y) \quad (2.5)$$

A *abertura*, equação 2.6, é a aplicação do operador de erosão seguida pela dilatação. Essa sequencia molda o contorno da imagem de acordo com o elemento estruturante das regiões claras maiores que o elemento estruturante, e nivela as outras.

$$\gamma_B(F) = F \circ B = (F \ominus B) \oplus B \quad (2.6)$$

De maneira dual à abertura, o *fechamento*, equação 2.7, tem a propriedade de nivelar as regiões mais escuras, moldando os contornos não removidos.

$$\varphi_B(F) = F \bullet B = (F \oplus B) \ominus B \quad (2.7)$$

Esses operadores básicos são como blocos de construção da morfologia e a partir deles é possível definir outros operadores e filtros. O *gradiente*, equação 2.8, é um desses operadores que tem a propriedade de destacar os contornos da imagem por calcular a diferença entre a dilatação e a erosão. Normalmente apenas se considera a magnitude do gradiente em cada ponto, que é um escalar independente da dimensão da imagem.

$$\nabla_B(F)(x) = \delta_B(F)(x) - \varepsilon_B(F)(x) \quad (2.8)$$

Um gradiente similar, equação 2.9, possibilita que o supremo seja aplicado apenas no resultado da diferença. Nesse caso, uma função de distância, cuja imagem (da função) possibilite um reticulado completo com uma relação de ordem, permite que o gradiente seja aplicado em imagens coloridas.

$$\nabla_{B,D}(F)(x) = \bigvee_{y_1 \in (\check{B})_x, y_2 \in B_x} D(F(y_1), F(y_2)), \quad (2.9)$$

sendo D uma função de distância entre valores da imagem.

Um exemplo de operações morfológicas básicas pode ser visualizado na Figura - 2.2. Nesse exemplo foi utilizado um elemento estruturante em formato de diamante com raio 2.

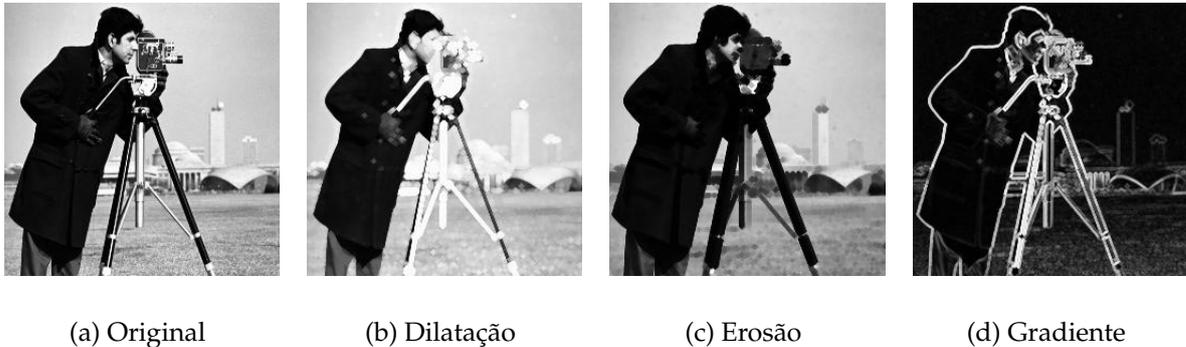


Figura 2.2: Exemplo de operações morfológicas

2.3 Segmentação

Considera-se uma *região* de uma imagem como um subconjunto de pixels. Uma *partição* é realizada quando todo pixel em uma imagem é associado a uma região e não mais que uma, ou seja, as regiões são conjuntos disjuntos e a união destas engloba a imagem toda. *Segmentação* é então uma partição onde todas as regiões são componentes conexos. O *watershed* é uma segmentação morfológica e pode ser definida utilizando teoria dos grafos (Cousty et al., 2009).

Uma imagem F e o elemento estruturante B podem ser representados por meio de um grafo $G = (V, A)$. Nesse, o conjunto de vértices $V = E$ representam os pixels, o conjunto de arestas $A = \{(x, y) : x, y \in V, y \in B_x\}$ ligam os pares de vértices vizinhos, e o valor das arestas P é uma função que associa um peso a cada aresta, como por exemplo o valor da diferença entre os valores dos pixels $P((x, y)) = F(x) - F(y)$.

Um *mínimo regional* $M = (V_M, A_M)$ é um subgrafo conexo de $G = (V, A)$ que atende as duas condições a seguir. Sejam $\overline{V}_M = V \setminus V_M$ e $\overline{A}_M = A \setminus A_M$ os complementos de V_M e A_M em V e A , respectivamente. Se $a_1, a_2 \in A_M$ então $P(a_1) = P(a_2)$, ou seja, em um mínimo toda aresta tem o mesmo valor. Se $a_1 \in A_M$ e $a_2 = (v_1 \in V_M, v_2) \in \overline{A}_M$ então $P(a_2) > P(a_1)$, ou seja, toda aresta que não faz parte do mínimo mas conecta pelo menos um de seus vértices tem o valor maior que o das arestas pertencentes ao mínimo.

Um caminho $\pi = \langle x_0, \dots, x_n \rangle$ em $G = (V, A)$ é um *caminho de descendência mais íngreme* se, para todo $i \in [1, n]$, $P((x_{i-1}, x_i)) = \min\{P((x_{i-1}, y)) : (x_{i-1}, y) \in A\}$. Um subgrafo CB é uma bacia de captação de água em G de um mínimo M , se para todo vértice de CB existe um caminho de descendência mais íngreme em G para todo vértice de M .

Um subconjunto de arestas W é dito *linha de partição de água (watershed)* de $G = (V, A)$ se cada componente do grafo $R = (V, A \setminus W)$ é uma bacia de captação de água em R de um mínimo de G . Em outras palavras, o *watershed* W segmenta uma imagem em regiões que são bacias de captação de água para cada mínimo de G .

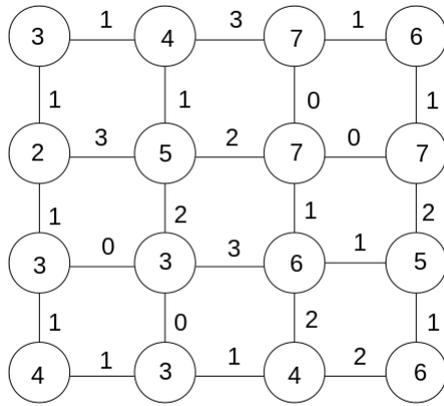
Um problema do *watershed* comumente discutido é o da supersegmentação, pois nem todo mínimo gera uma região relevante na imagem. Para contrabalancear esse problema, os mínimos podem ser removidos através de uma operação chamada de *alagamento*. Tal operação pode ser construída por meio de *operadores conexos*, como pode ser visto nas próximas seções.

Dado P' , um *alagamento* de P , todo mínimo de G usando P' contém ao menos um mínimo de G usando P . Tal propriedade permite construir uma família de alagamentos $\langle P_0, \dots, P_n \rangle$ onde $P_0 = P$ e $i > j$ implica em $P_i \geq P_j$. Para tanto, é suficiente que P_j seja um alagamento de P_{j-1} . Com essa família é possível construir uma *hierarquia de segmentações*.

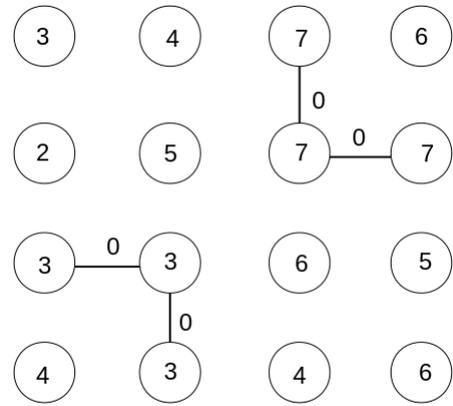
Se W_i e W_j , $i > j$, são *watersheds* de G usando P_i e P_j , respectivamente, e $W_i \subseteq W_j$, então $\langle W_0, \dots, W_n \rangle$ é então uma *hierarquia de segmentações* (Meyer, 2001). Nesse caso, W_0 é a segmentação mais fina, a supersegmentação, em que nenhum mínimo foi removido e $W_n = \emptyset$ é a segmentação mais grosseira, na qual restou apenas um mínimo.

A Figura - 2.3 mostra um exemplo completo dos passos para a construção de um possível *watershed* para uma certa imagem. Nele é ilustrado a construção do grafos 4-conexo, a identificação dos mínimos regionais, a construção de caminhos mínimos (neste ponto que algoritmos para o *watershed* diferem, já que podem existir mais de um caminho mínimo, isto é, caminhos com o mesmo menor valor possível, para o mesmo vértice, incluindo caminhos para mínimos diferentes), e, por fim, a identificação do

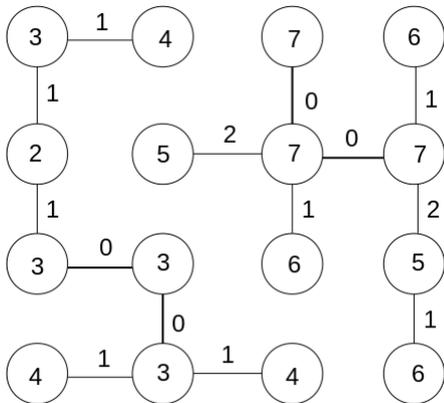
watershed (arestas em vermelho) e das bacias de captação de água (cada subgrafo de vértices da mesma cor).



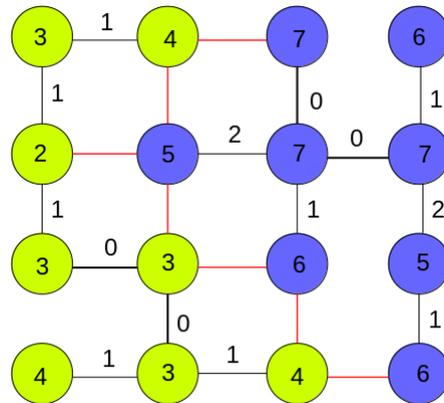
(a) Representação de uma imagem em grafo



(b) Mínimos regionais da imagem



(c) Uma solução possível



(d) Bacias de captação de água e *watershed*

Figura 2.3: Exemplo de *Watershed*.

2.4 Filtragem por Atributos

Uma classe de operadores da morfologia matemática, os *operadores conexos*, funcionam por remover componentes conexos em imagens binárias, ou juntar zonas planas adjacentes de imagen em nível de cinza. Esses operadores não criam novos contornos,

e por consequência, não introduzem na imagem resultante estruturas novas (Serra e Salembier, 1993).

Um operador ψ é conexo se para todas as imagens F e para todo par de pixel x e x' vizinhos, $\psi(F)(x) \neq \psi(F)(x')$ implica em $F(x) \neq F(x')$. Alternativamente, ψ é conexo se a partição constituída pelas zonas planas de F é mais fina que a partição de $\psi(F)$, isto é, $\mathcal{P}_F \subseteq \mathcal{P}_{\psi(F)}$, para todo F .

Dentre os operadores conexos, este trabalho destaca a filtragem por atributos. Para ser um filtro implica que o operador ψ é anti-extensivo, ou seja, para todo F e x $\psi(F)(x) \leq F(x)$. A filtragem por atributos consiste em remover componentes conexos de uma imagem que não atendem a um dado critério (Breen e Jones, 1996).

No caso binário, dada uma função de cálculo de atributo e um critério de remoção, cada componente é avaliado pela função e se o resultado não atender ao critério, então o componente conexo é removido da imagem.

A base da extensão para imagens em nível de cinza é a decomposição por limiarização. A limiarização de uma imagem F por um valor t são os pixels cujo valor é maior ou igual a t . Uma função de limiarização $\mathcal{X}_t(F)$ é definida como:

$$\mathcal{X}_t(F) = \{x \in E : F(x) \geq t\} = \bigcup_{i=1}^n C_{t,i} \quad (2.10)$$

onde $C_{t,i}$ representa o i -ésimo componente conexo da limiarização por t .

A decomposição consiste em, a partir de uma imagem em nível de cinza, gerar um conjunto de imagens binárias de tal modo que o limiar máximo em que um pixel pertença a imagem binária equivalha ao valor daquele pixel na imagem cinza.

$$F(x) = \bigvee_{x \in X, X \in \mathcal{X}_t(F)} t = \bigvee_{x \in X, X \in \bigcup_n C_{t,n}} t \quad (2.11)$$

Uma propriedade da decomposição é que para todo componente conexo $C_{t,n}$ onde $t > 0$, existe um, e um único, componente conexo $C_{t-1,m}$ tal que $C_{t-1,m} \subseteq C_{t,n}$. Essa propriedade permite que a decomposição seja representada por uma estrutura de árvore (Jones, 1999), um grafo direcionado conexo sem ciclo, onde cada componente conexo é representado por um vértice, a raiz sendo o vértice que representa o componente $C_{0,0}$, e as arestas representam a relação de inclusão. Definimos $C(v)$ como o componente conexo representado por v . Dado uma imagem F , a função $Arvore(F)$ retorna a árvore T . Dado uma árvore T , a função $Reconstrói(T)$ retorna a imagem reconstruída a partir dos componentes conexos associados as vértices de T . Essa árvore é chamada de árvore de componentes.

Nessa representação um pixel de valor k aparece em k vértices diferentes. Em uma outra representação (Salembier et al., 1998), a *Max-Tree*, um pixel é representado por um, e um único, vértice de tal forma que todos os pixels representados por um vértice de altura k possuem o valor k . Além disso, valor de um pixel x representado por um vértice v , $F(x)$, é diretamente o valor de limiar do componente conexo deste vértice. Nessa representação, o componente conexo é representado pela união dos pixels de um vértice com os pixels de todos os seus descendentes. Além de diminuir o número de pixels por vértice, essa representação tem uma menor complexidade computacional em relação ao número de vértices, enquanto que na árvore de componentes o número máximo de vértices depende também do maior valor de pixel na imagem, na *Max-Tree* o número máximo de vértices depende apenas do número de *flat zones* na imagem.

Após a construção da árvore a próxima etapa é o cálculo do atributo. Isto é feito definindo uma função Att para cada vértice, tomando como base uma função $C(v)$ que retorna o componente conexo representado por v e a imagem F . O atributo é dito crescente se, para cada caminho $\langle v_0, v_1, \dots, v_n \rangle$, $Att_{C,F}(v_i) \leq Att_{C,F}(v_j)$ e $i > j$, sendo que v_n é uma folha, v_0 é a raiz e, para todo vértice do caminho, existe uma aresta para o vértice seguinte. Exemplo de funções de atributo são as chamadas estruturais, nomeadamente altura, área e volume são apresentadas nas equações 2.12, 2.13 e 2.14, respectivamente.

$$Altura_{C,F}(v) = \bigvee_{x \in C(v)} F(x) - \bigwedge_{y \in C(v)} F(y) \quad (2.12)$$

$$Area_{C,F}(v) = \sum_{x \in C(v)} 1 \quad (2.13)$$

$$Volume_{C,F}(v) = \sum_{x \in C(v)} (F(x) - \bigwedge_{y \in C(v)} F(y) + 1) \quad (2.14)$$

Quando o atributo é crescente, uma filtragem por atributos, a abertura por atributos, pode ser realizada por uma poda na árvore. Para tanto, dada uma árvore $T_1 = (V_1, A_1)$, a imagem F e um critério $CP = (Att, p)$, onde p é um valor de atributo, uma poda $Poda_{F,CP}(T_1)$ resulta em uma árvore $T_2 = (V_2, A_2)$, onde $v \in A_2$ se, e somente se, $v \in V_1$ e $Att_{C,F}(v)$ é menor que p , e $a = (v_1, v_2) \in A_2$ se, e somente se, $a \in A_1$ e $v_1, v_2 \in V_2$. Na *Max-Tree* os pixels representados pelos vértices removidos passam a ser representados pelo primeiro vértice superior não removido. Dado uma imagem F e um critério CP , o operador da filtragem por atributos $\Gamma_{CP}(F) =$

$Reconstroi(Poda_{F,CP}(Arvore(F)))$ constrói a árvore de F , poda a árvore de acordo com CP e F e retorna a imagem reconstruída a partir da árvore podada.

Quando o atributo é não-crescente há a possibilidade de vértices que não atendam a um determinado critério, mas têm descendentes que atendam a esse mesmo critério. Nesse caso pode-se escolher uma estratégia de poda, como cortar a partir do primeiro que não atenda ao critério, cortar a partir do primeiro que não atenda e ao mesmo tempo não tenha nenhum descendente que não atenda, ou ainda utilizar um algoritmo de otimização para escolher os pontos de poda de tal modo que elimine o máximo de vértices que não atendam ao mesmo tempo que elimine o mínimo de vértices que atendem.

Uma outra abordagem é utilizar um outro tipo de filtragem por atributos, o afinamento. Para se realizar o afinamento, dada uma árvore $T_1 = (V_1, A_1)$, constrói-se uma árvore $T_2 = (V_2, A_2)$, onde V_2 é construída como na poda e A_2 é inicializada como na poda com o adicional de $a_n = (v_1, v_n)$, onde $a_2 = (v_1, v_2)$, $a_{n-1} = (v_{n-1}, v_n)$, $a_2, a_{n-1} \in A_1$, $a_2, a_{n-1} \notin A_2$ e $v_1, v_n \in V_2$. Na *Max-Tree*, a mudança de representação dos pixels nos vértices removidos ocorre da mesma forma como na poda. Observe que para todos os casos que a poda pode ser realizada, o afinamento gera a mesma árvore, por isso pode-se dizer também que a abertura é um tipo de afinamento.

Outra filtragem por atributos é a filtragem por extinção (Vachier e Meyer, 1995), que pode ser realizada por um tipo de poda onde um vértice é removido somente se seu ramo é removido por inteiro, isto é, se seu antecedente também é removido ou se ele tem mais de um filho na árvore resultante. Para se realizar esse tipo de poda, altera-se o critério para utilizar uma função que considere esta restrição:

$$EAtt_{C,F}(v) = \begin{cases} EAtt_{C,F}(v_p) & \text{se } \exists a_1 = (v_p, v), \nexists a_2 = (v_p, v_f), Att_{C,F}(v_f) > Att_{C,F}(v) \\ Att_{C,F}(v) & \text{caso contrário.} \end{cases} \quad (2.15)$$

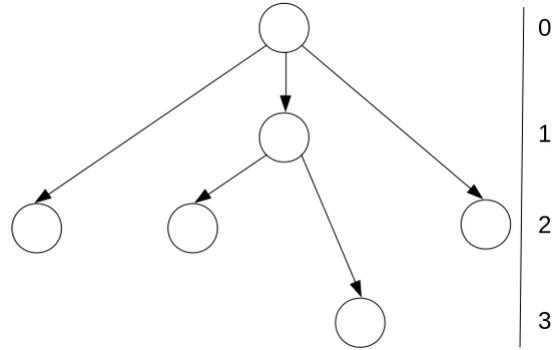
Esse tipo de poda nunca transforma um dos vértices resultantes em folha, com a exceção de quando só sobra a raiz. Esta propriedade é especialmente relevante para a segmentação na simplificação de gradientes. Ao construir uma árvore T com o complemento do gradiente $\nabla(F)$, as folhas representam os mínimos regionais. Uma poda por extinção em T remove os mínimos, além disso o atributo de extinção das folhas determina a ordem em que os mínimos são removidos. Uma sequência de podas em T por estes valores de extinção ordenados resulta em uma sequência de

complementos de alagamentos de $\nabla(F)$, que pode ser usada para construir uma hierarquia de segmentações.

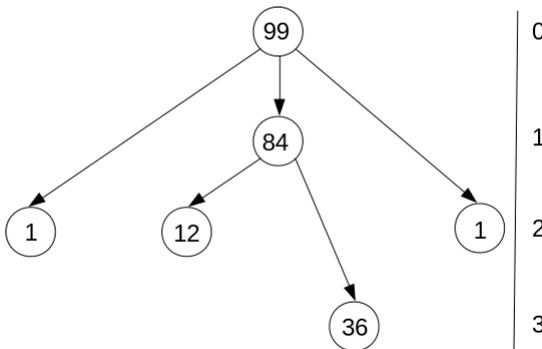
A Figura - 2.4 traz um exemplo com as etapas de como realizar uma filtragem por extinção utilizando a *Max-Tree*. Primeiramente, a imagem, apresentada em Figura - 2.4(a), é convertida em sua representação na árvore considerando uma conectividade 4 (Figura - 2.4(b)). Em seguida, o atributo de área é calculado para cada vértice (Figura - 2.4(c)). Depois é calculado o atributo de extinção (Figura - 2.4(d)). A poda por extinção é realizada na sequência utilizando um valor de atributo 47 (Figura - 2.4(e)). E, finalizando, a imagem é reconstruída a partir da árvore podada (Figura - 2.4(f)).

3	3	3	3	3	3	3	3	3	3	3
3	1	1	1	1	1	1	1	1	1	3
3	1	0	0	0	1	2	2	2	1	3
3	1	0	2	0	1	2	1	2	1	3
3	1	0	0	0	1	2	1	2	1	3
3	1	0	2	0	1	2	1	2	1	3
3	1	0	0	0	1	2	2	2	1	3
3	1	1	1	1	1	1	1	1	1	3
3	3	3	3	3	3	3	3	3	3	3

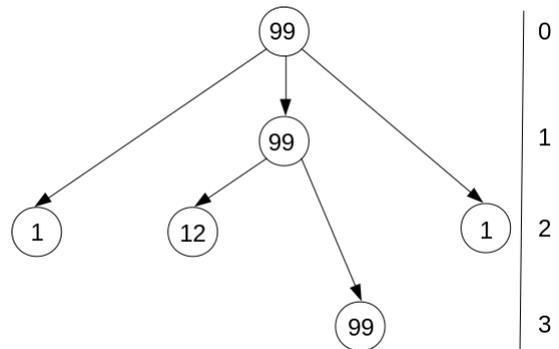
(a) Imagem não filtrada



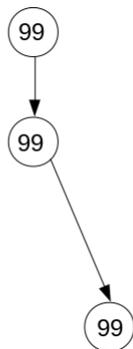
(b) Construção da *Max-Tree*



(c) Cálculo do atributo de área



(d) Atualização do atributo por extinção



(e) Poda por parâmetro de área 47

3	3	3	3	3	3	3	3	3	3	3
3	1	1	1	1	1	1	1	1	1	3
3	1	0	0	0	1	1	1	1	1	3
3	1	0	0	0	1	1	1	1	1	3
3	1	0	0	0	1	1	1	1	1	3
3	1	0	0	0	1	1	1	1	1	3
3	1	1	1	1	1	1	1	1	1	3
3	3	3	3	3	3	3	3	3	3	3

(f) Imagem Reconstruída

Figura 2.4: Exemplo de filtragem por atributos.

Filtragem por Atributo Colorido

3.1 Visão Geral

Na seção anterior se fez uma revisão da definição da filtragem por atributos além de mostrar a limitação da morfologia matemática em imagens coloridas, essa limitação não permite que a árvore seja construída a partir de uma imagem colorida. A fim de contornar essa limitação, nessa seção é introduzida filtragem por atributo colorido. Ela consiste basicamente em adicionar uma etapa de cálculo do gradiente da imagem colorida, o qual é utilizado para a construção da árvore, o critério de poda continua o mesmo, ou seja, ao mensurar os componentes conexos, a imagem (colorida) é usada nos cálculos do atributo, com isso critérios de cor podem ser utilizados. Uma visão geral do método é ilustrada no fluxograma da Figura - 3.1.

3.2 Definição

Define-se o operador de filtragem por atributo colorido:

$$\bar{\Gamma}_{\nabla_B, CP}(F) = Reconstroi(Poda_{F, CP}(Arvore(\nabla_B(F))), \quad (3.1)$$

onde F é uma imagem colorida, ∇ é um operador de gradiente, B é um elemento estruturante, $Reconstroi(T_2)$ é uma função que retorna uma imagem reconstruída a partir da árvore T_2 , $Poda_{F, CP}(T_1)$ é uma função que retorna a árvore T_1 podada de acordo com a função F e o critério $CP = (Att, p)$, Att é uma função de cálculo de atributo colorido e p é um valor de atributo. Se a imagem for em tons de cinza e

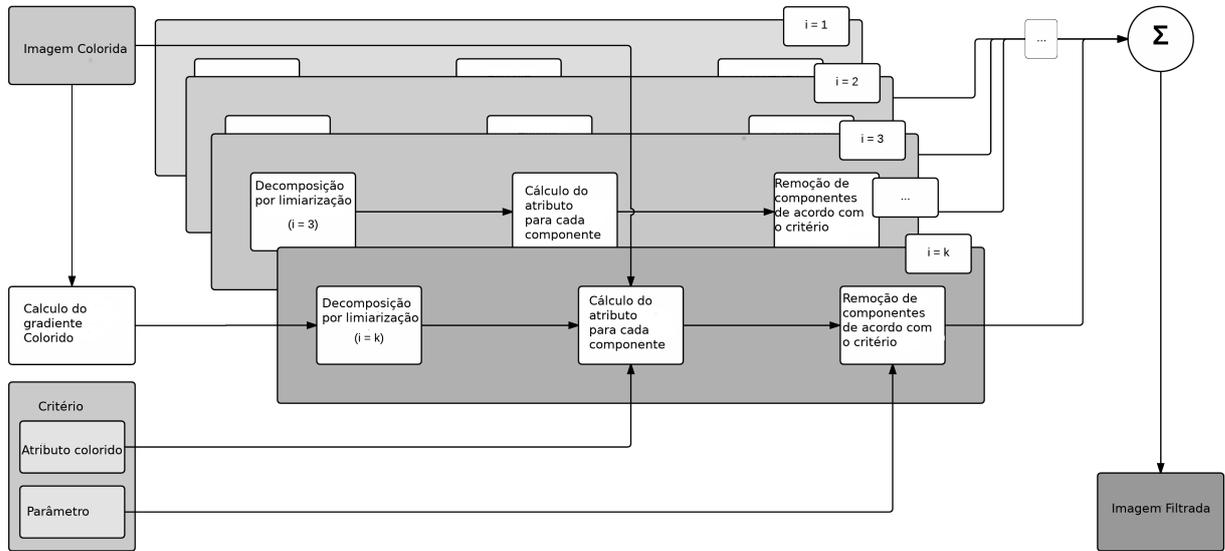


Figura 3.1: Fluxograma da filtragem por atributo colorido.

o operador de gradiente for a função identidade, então esse operador tem o mesmo comportamento da filtragem por atributos.

3.3 Algoritmo

Em outros termos, o cálculo do operador de filtragem por atributo colorido é apresentado no algoritmo 1. Assim como no fluxograma, é utilizada apenas a filtragem por atributos sobre a decomposição por limiarização.

Algorithm 1: Operador por atributo colorido

Input:

- imagem F ;
- critério $CP = (Att, p)$;

Output: imagem $\bar{\Gamma}_{\nabla_B, CP}(F)$;**begin**

```

1  |  Grad =  $\nabla_B(F)$ ;
2  |  foreach  $t$  in  $[0 - 2^k[$  do
3  |  |   $C_t = \mathcal{X}_t(F)$ ;
4  |  |  foreach  $C_{t,n}$  in  $C_t$  do
5  |  |  |  if  $Att_F(C_{t,n}) \geq p$  then
6  |  |  |  |   $\bar{\Gamma}_{\nabla_B, CP}(F)(x) = \bigvee_{x \in \cup C_{t,n}} t$ ;
   |  |  |  end
   |  |  end
   |  end
   end

```

end

3.4 Aplicação

Em relação a escolha do gradiente a ser utilizado, depende da aplicação do método. Um exemplo, é possível o uso do *resíduo*, $\nabla_B(F) - \bar{\Gamma}_{\nabla_B, CP}(F)$ (Flores et al., 2018). Outra abordagem é utilizar o complemento do gradiente $\bar{\nabla}_B$ e aplicar o operador *watershed* (Beucher e Lantuéj, 1979) em $\bar{\Gamma}_{\nabla_B, CP}(F)$ com o objetivo de calcular uma segmentação hierárquica (Meyer, 2001) de F (Sousa Filho e Flores, 2017, 2018).

Para critérios baseados em estatísticas ou *features* de cor, é válido citar a entropia (Duda et al., 2012), o erro de cor (Borsotti et al., 1998) e a harmonia de cor (Ou e Luo, 2006). Neste trabalho, aplicamos estes critérios como pode ser visto na seção 4.

3.5 Critérios de Avaliação de Segmentação

Haralick e Shapiro (1985) afirmaram que uma boa segmentação provê regiões homogêneas. E realmente, métodos de avaliação não-supervisionados para verificação de qualidade usualmente possuem um componente para medir este aspecto (Zhang

et al., 2008). É proposto usar uma métrica de homogeneidade em um operador por atributo de cor com o objetivo de obter uma segmentação com regiões homogêneas.

Como o objetivo é obter uma segmentação mais precisa, é alterado o operador para, ao calcular o valor do atributo, não só coletar dados do componente conectado, como também de sua zona de influência.

Seja C_t um conjunto de componentes conectados de $\bar{\nabla}(F)$ dado um limiar t . Seja W_t um *watershed* do complemento de $\bar{\nabla}(F)$ usando C_t como marcadores. Seja $C_{t,n} \in C_t$ um componente conectado. Seja R_w a região gerada por $C_{t,n}$ em W_t . $R(v)$ é uma função, que dado um vértice v , retorna a sua região.

3.5.1 Erro Médio

Define-se um operador baseado no erro médio de cor assim como já usado para avaliar a homogeneidade de segmentações (Borsotti et al., 1998; Liu et al., 1994). O operador trivial de erro médio de cor é dado pela soma da distância euclidiana entre o dado de cor de cada elemento do componente conectado e a média dos dados de cor da região:

$$e_{R,F}(v) = \sum_{x \in R(v)} D(F(x), \mu(R(v), F)), \quad (3.2)$$

onde μ é o valor médio dos dados de cor de cada banda na região e D é a distância euclidiana.

3.5.2 Entropia

Define-se também um operador baseado em entropia que é usado na função E (Zhang et al., 2003) para calcular a homogeneidade de regiões de uma segmentação. O operador trivial de entropia é dado pela entropia dos dados de cor dos elementos da região:

$$S_{R,F}(v) = - \sum_{x \in R(v)} p(F(x)) \log_2 p(F(x)), \quad (3.3)$$

onde p é a probabilidade do dado de cor na região.

3.6 Critério de Harmonia de Cor

De maneira geral a harmonia de cor pode ser entendida como uma combinação de cor que cause um efeito agradável ao observador. Subjetiva, a harmonia pode variar a

definição conforme o contexto de sua aplicação como design de produtos, criação de obras de arte ou melhoramento de imagens.

Para os cientistas ainda não existe uma teoria harmônica amplamente aceita. Vários trabalhos ao longo dos séculos tentaram explicar os efeitos psicológicos causados pelas cores. Alguns trabalhos tentam explicar através de um arranjo ordenado de cores (Itten, 1961; Munsell, 1969; Ostwald, 1969) enquanto que outros abordam relações individuais entre cores (Chevreul, 1967; Moon e Spencer, 1944; Von Goethe, 1840).

3.6.1 Divergência de Kullback-Leibler

Clássica da estatística, a divergência de Kullback-Leibler (Kullback e Leibler, 1951) é uma entropia relativa entre duas distribuições de probabilidades e pode ser interpretada como a perda de informação quando se usa uma distribuição de probabilidades Q para aproximar uma distribuição P . Para o caso discreto é definida como:

$$D_{KL}(P\|Q) = \sum_i P(i) \ln \frac{P(i)}{Q(i)}. \quad (3.4)$$

Uma aplicação dessa divergência é quando P é uma distribuição obtida a partir de dados reais e Q representa um modelo. O modelo Q que minimize a divergência é o que melhor representa a distribuição P .

Baveye et al. (2013) utilizaram essa aplicação para encontrar qual *template* harmônico definido no círculo cromático (Matsuda, 1995) melhor descreve uma imagem colorida. P é obtido por meio do histograma de matiz ponderado da imagem calculado no espaço de cor HSV usando 360 categorias:

$$P(i) = \frac{\sum_{x \setminus H(x)=i} S(x) \times V(x)}{\sum_x S(x) \times V(x)}, \quad (3.5)$$

$i \in [0, 359]$.

Q é calculado para cada rotação de cada um dos *templates* harmônicos T_m ($m \in \{i, V, L, J, I, T, Y, X\}$) ilustrados na Figura - 3.2. Cada *template* é constituído de setores, cada setor possui um centro e uma largura. A distribuição de Q dado um *template* m e uma rotação α é dada por:

$$Q_m^\alpha(i) = \begin{cases} \sum_{k=1}^n S_m^\alpha(i, k) & \text{se } \sum_{k=1}^n S_m^\alpha(i, k) \neq 0 \\ \frac{0,01}{360} \times \sum_i (\sum_{k=1}^n S_m^\alpha(i, k)) & \text{caso contrário,} \end{cases} \quad (3.6)$$

onde n é o número de setores definidos para o *template* T_m e

$$S_m^\alpha(i, k) = \begin{cases} \exp\left(-\frac{1}{1 - \left(\frac{2 \times \|i - \alpha_k\|}{w}\right)^{10}}\right) & \text{se } i \in]\alpha_k - \frac{w}{2}, \alpha_k + \frac{w}{2}[\\ 0 & \text{caso contrário,} \end{cases} \quad (3.7)$$

onde $\|\cdot\|$ denota distância angular no círculo cromático e α_k e w são respectivamente o centro e a largura do setor k do *template* T_m .

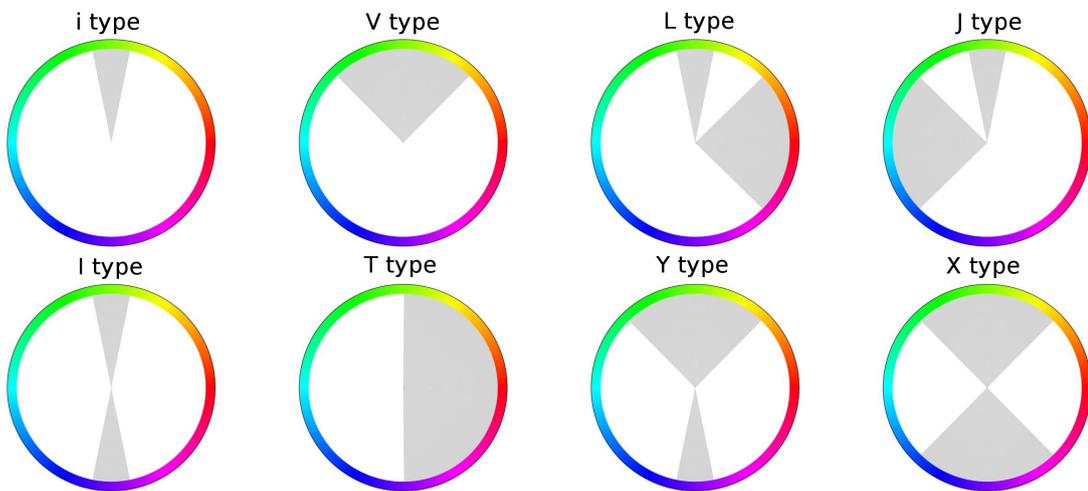


Figura 3.2: Modelos harmônicos T_m . Uma área em cinza representa um setor de valores de matiz que compõe o modelo harmônico.

Define-se então um operador baseado nessa divergência para calcular a harmonia das regiões. O operador trivial da divergência harmônica é dado pela mínima divergência das distribuições harmônicas para o histograma dos dados de cores dos elementos da região:

$$D_{R,F}(v) = \min D_{KL}(P \| Q_m^\alpha) \quad (3.8)$$

Esse atributo é decrescente, portanto a poda deve ser feita quando o atributo calculado for maior que o parâmetro.

Experimentos

Para a validação do método e dos critérios propostos, estes foram implementados e se utilizando de um base de dados de imagens foram realizados alguns experimentos computacionais descritos nessa seção.

4.1 Implementação

A implementação foi realizada em duas partes. A primeira consistiu na construção da biblioteca de filtragem por atributos coloridos e está disponível no *github* (Sousa Filho, 2017). A segunda parte se refere ao desenvolvimento das duas aplicações utilizadas para o experimento da segmentação colorida e para o experimento da harmonização de cores, respectivamente.

O desenvolvimento foi realizado em Python, utilizando as bibliotecas NumPy, Pandas, scikit-image (van der Walt et al., 2014) e a MAMBA.

4.2 Base de Dados

No experimento foi utilizada a base de dados *Berkeley Segmentation Dataset and Benchmark 500* (BSDS500) (Martin et al., 2001).

4.3 Melhorias para a Segmentação de Imagens Coloridas

4.3.1 Resultados Experimentais

Para cada imagem foi aplicada várias vezes a filtragem por atributos, para cada um dos dois critérios propostos (erro médio e entropia), utilizando o modelo de cor Lab, o gradiente da equação 2.9 com a distância euclidiana, incrementando o valor de atributo o que resultou em uma sequência de segmentações onde o número de regiões diminuía.

Então foram confrontados com os atributos estruturais (nomeadamente os de área, altura e volume) usando o mesmo *framework* e também com o *Simple Linear Iterative Clustering* (SLIC) (Achanta et al., 2011). Para cada segmentação resultante foi obtida uma segmentação comparativa com o mesmo número de regiões.

O passo a passo completo para uma iteração se traduz em, a partir de uma imagem colorida, calcular o gradiente colorido, inverter o gradiente, calcular a *Max-Tree*, calcular o atributo na árvore utilizando como base a imagem colorida, podar a árvore, reconstruir o gradiente invertido (agora filtrado), inverter novamente o gradiente, calcular o *watershed* a partir do gradiente filtrado e calcular uma segmentação para os outros métodos com o mesmo número de região.

Figura - 4.1 ilustra algumas segmentações obtidas durante o experimento da amostra "138078". Observa-se como os operadores deste trabalho são sensíveis a detalhes ao mesmo tempo identificando grandes regiões homogêneas.

A análise foi realizada mensurando-se as segmentações utilizando o método de avaliação E , proposto por Zhang et al. (2003). Ele utiliza de uma combinação de entropias para avaliar uniformidade intra-região e uma entropia de *layout* para avaliar uniformidade inter-região. A primeira diminui conforme a segmentação é refinada enquanto que a última aumenta. Uma boa segmentação encontra mais regiões homogêneas segmentando menos.

Para balancear os componentes intra e inter da função de Zhang, o primeiro componente foi multiplicado pela constante 22 e dividido pela entropia máxima. A divisão pela entropia máxima tem o papel de normalizar o peso para imagens com diferente diversidade de cor. A constante foi encontrada empiricamente rodando-se o experimento algumas vezes. Não houve a necessidade de um peso específico para o segundo componente pois todas as imagens possuíam o mesmo número de pixels.

Foi plotado um gráfico para o experimento em cada imagem da base. Tais gráficos contêm uma curva para cada método e que mostra como tal método desempenhou

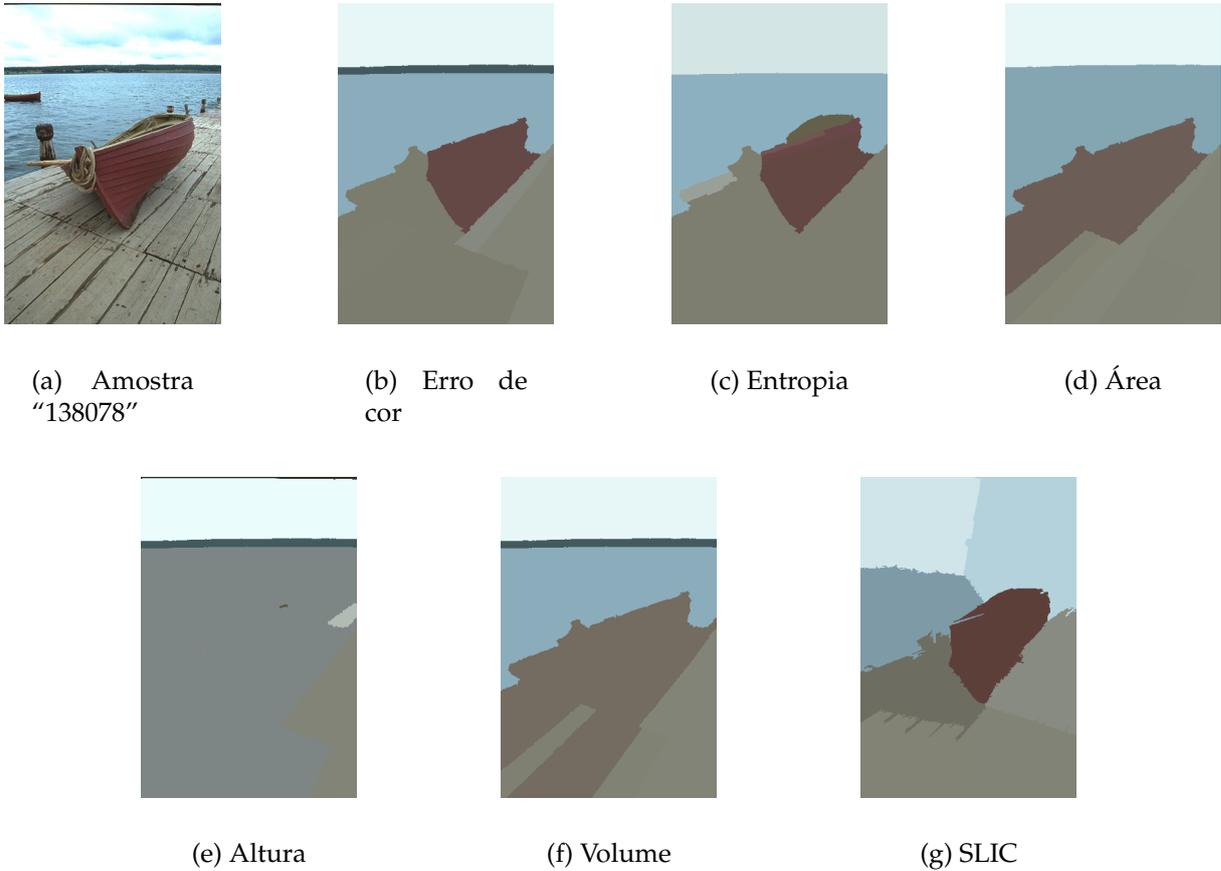


Figura 4.1: Exemplo de segmentação: (b), (c), (d), (e), (f) e (g) são segmentações de (a) com 8 regiões.

com base no número de regiões. Como foi considerado que é mais importante analisar segmentações com menos regiões, a dimensão do número de regiões foi plotada em escala logarítmica. Destaca-se que como um menor E significa uma melhor segmentação, um método é melhor quando sua curva está mais abaixo.

Para uma comparação dois a dois entre os métodos deste trabalho com os outros, foi calculado um *score*, equação 4.1, baseado na área entre as curvas do gráfico. É calculado como a proporção dessa área em que o método deste trabalho esteve abaixo. Um gráfico de barras ordenadas foi gerado contendo o resultado para todas as imagens. Quando a barra é maior que 50% significa que o método deste trabalho superou o outro para aquela imagem.

$$score(st, sc) = \frac{\sum_{i, diff_{st,sc}(i) < 0} diff_{st,sc}(i)}{\sum_i diff_{st,sc}(i)}, \quad (4.1)$$

onde st é uma função que mapeia um número de região a uma segmentação obtida por um método deste trabalho para uma imagem, sc é uma função que mapeia um número de região a uma segmentação obtida por um método comparativo para a mesma imagem, e

$$diff_{st,sc}(i) = E(st(i)) - E(sc(i)). \quad (4.2)$$

Figura - 4.2 mostra um exemplo das curvas geradas para a amostra "138078". É relevante destacar que o *score* pode chegar a 100% mesmo quando o método foi apenas ligeiramente melhor em todas as segmentações daquela imagem.

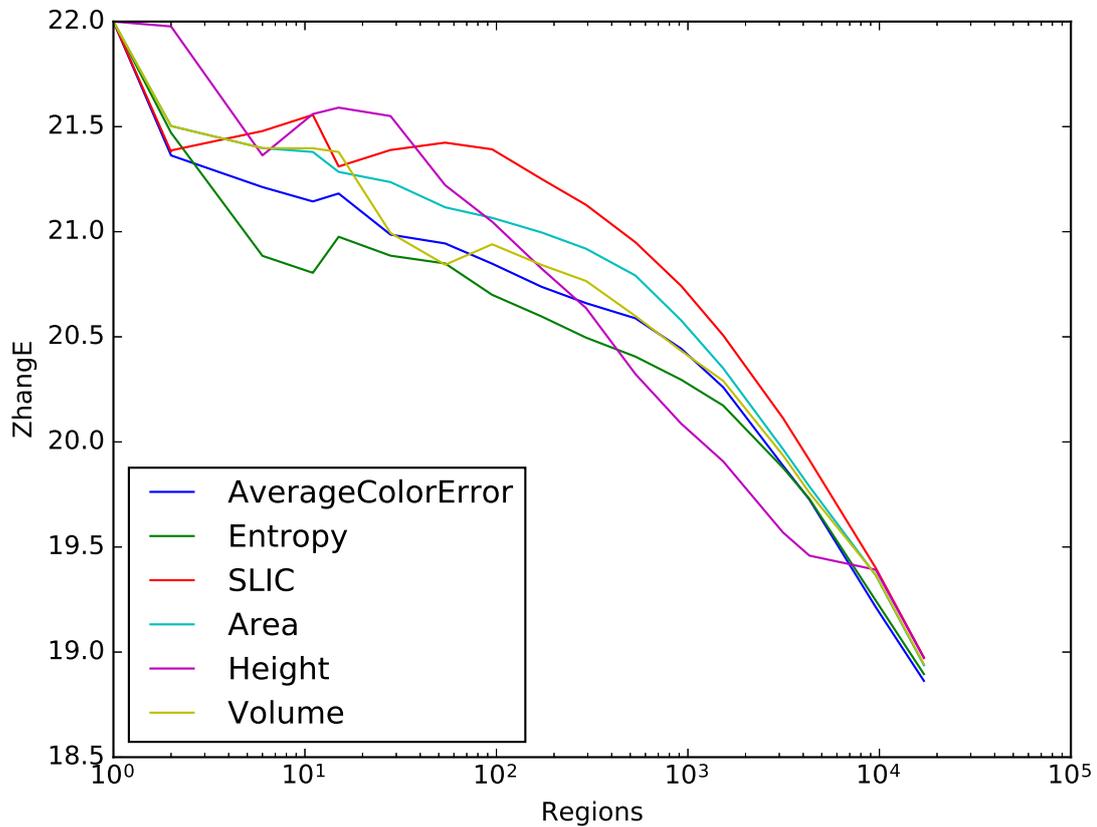


Figura 4.2: Curvas geradas a partir da experimentação com a amostra "138078".

Figura - 4.3 exibe todos os gráficos de barras obtidos no experimento. O erro de cor médio foi melhor em 80%, 83%, 87% e 75% das imagens como um *score* médio de 74.33%, 81.10%, 75.23% e 72.04% em relação ao área, altura, volume e SLIC, respectivamente. Adicionalmente, a entropia foi melhor em 77%, 86.33%, 71.67% e 78%

das imagens com um *score* médio de 69.78%, 82.83%, 66.07% e 72.34% em relação aos mesmos métodos, respectivamente.

Os resultados indicam que, apesar de não para todo caso, os operadores de cor foram capazes de, além de encontrar boa segmentação, encontrar segmentações peculiares.

4.4 Melhorias para Harmonização de Cores

O critério de Kullback-Leibler foi utilizado em uma aplicação para correção harmônica. Como medida de distância para o gradiente colorido foi escolhido uma variação da harmonia entre duas cores de Ou e Luo (2006). O uso dessa distância teve por objetivo realçar fronteiras entre regiões harmônicas. A distância harmônica foi definida como:

$$D_H = \begin{cases} -CH & \text{se } CH < 0 \\ 0 & \text{caso contrário,} \end{cases} \quad (4.3)$$

onde

$$CH = H_C + H_L + H_H, \quad (4.4)$$

$$H_C = 0,04 + 0,53 \times \tanh(0,8 - 0,045 \times \Delta C), \quad (4.5)$$

$$\Delta C = \left((\Delta H_{ab}^*)^2 + \left(\frac{\Delta C_{ab}^*}{1,46} \right)^2 \right)^{\frac{1}{2}}, \quad (4.6)$$

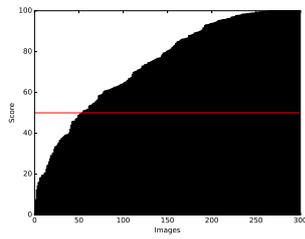
ΔH_{ab}^* e ΔC_{ab}^* sendo respectivamente as diferenças dos valores de matiz e *chroma* no CIELAB,

$$H_L = H_{Lsum} + H_{\Delta L}, \quad (4.7)$$

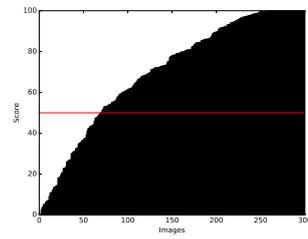
$$H_{Lsum} = 0,28 + 0,54 \times \tanh(-3,88 + 0,029 \times L_{sum}), \quad (4.8)$$

L_{sum} sendo a soma dos valores de luminosidade no CIELAB,

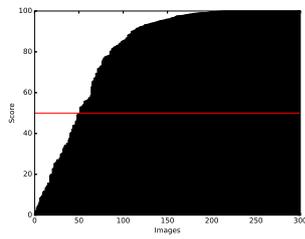
$$H_{\Delta L} = 0,14 + 0,15 \times \tanh(-2 + 0,2 \times \Delta L), \quad (4.9)$$



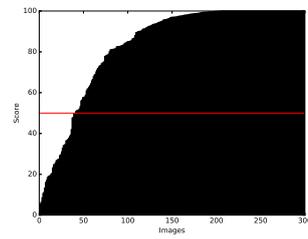
(a) Erro de Cor / Área



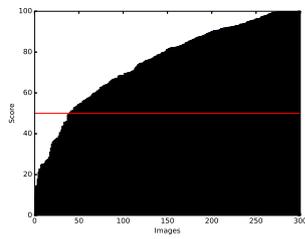
(b) Entropia / Área



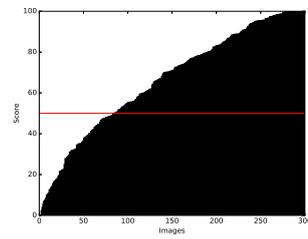
(c) Erro de Cor / Altura



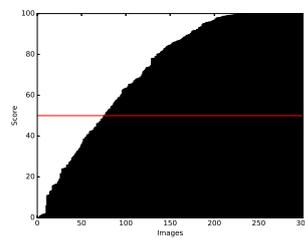
(d) Entropia / Altura



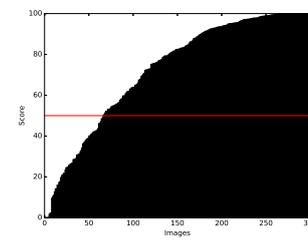
(e) Erro de Cor / Volume



(f) Entropia / Volume



(g) Erro de Cor / SLIC



(h) Entropia / SLIC

Figura 4.3: Síntese dos resultados: (a), (b), (c), (d), (e), (f), (g) e (h) mostram quão bem um método foi em relação a outro.

Δ_L sendo a diferença absoluta dos valores de luminosidade no CIELAB,

$$H_H = H_{SY1} + H_{SY2}, \quad (4.10)$$

$$H_{SY} = E_C \times (H_S + E_Y), \quad (4.11)$$

$$E_C = 0,5 + 0,5 \times \tanh(-2 + 0,5 \times C_{ab}^*), \quad (4.12)$$

C_{ab}^* sendo o valor de *chroma* no CIELAB,

$$H_S = -0,08 - 0,14 \times \sin(h_{ab} + 50^\circ) - 0,07 \times \sin(2 \times h_{ab} + 90^\circ), \quad (4.13)$$

h_{ab} sendo o valor de matiz no CIELAB,

$$E_Y = \left(\frac{0,22 \times L^* - 12,8}{10} \right) \times \exp \left(\frac{90^\circ - h_{ab}}{10} - \exp \left(\frac{90^\circ - h_{ab}}{10} \right) \right). \quad (4.14)$$

Um exemplo do uso desse gradiente pode ser visto na Figura - 4.4. Seu comportamento é parecido com a distância entre cores, porém a borda só é realçada onde não há harmonia significativa na transição de cores.

Como na aplicação da melhoria de segmentação, foi obtida uma segmentação com o *watershed* na negação $\bar{\Gamma}_{\nabla_B, CP}(F)$. Porém, ao invés de variar o valor do atributo de poda, foi fixado gerar uma segmentação contendo 0,5% regiões de menor divergência em relação ao número máximo de segmentos (quando nenhum componente conexo é filtrado). Isso foi realizado ordenando os mínimos pelo seu valor de extinção, escolhendo os melhores e utilizando-os como marcadores para o *watershed*.

A Figura - 4.5 exemplifica o resultado da segmentação obtida a partir da imagem filtrada utilizando o critério de harmonia de cor. Esse método foi capaz de segmentar grupos harmônicos independente do tamanho, no caso desse exemplo foi possível segmentar a região que era dominada pela cor rosa do resto da imagem.

Então para cada segmento, foi escolhido o *template* e a rotação que minimizam a divergência naquele segmento e uma função é aplicada para transformar os valores de matiz como definido por Baveye et al. (2013):

$$H'(x) = C(x) + Sinal_{quadrante} \times \frac{w}{2} \times \tanh \left(\frac{2 \times \| H(x) - C(x) \|}{w} \right), \quad (4.15)$$



(a) Amostra "23050"



(b) Gradiente harmônico

Figura 4.4: Exemplo do gradiente usando a distância harmônica.

onde $C(x)$ e w representam o valor de matiz central e o comprimento angular, respectivamente, do setor associado ao pixel x e $\| \cdot \|$ é a distância angular no círculo cromático.

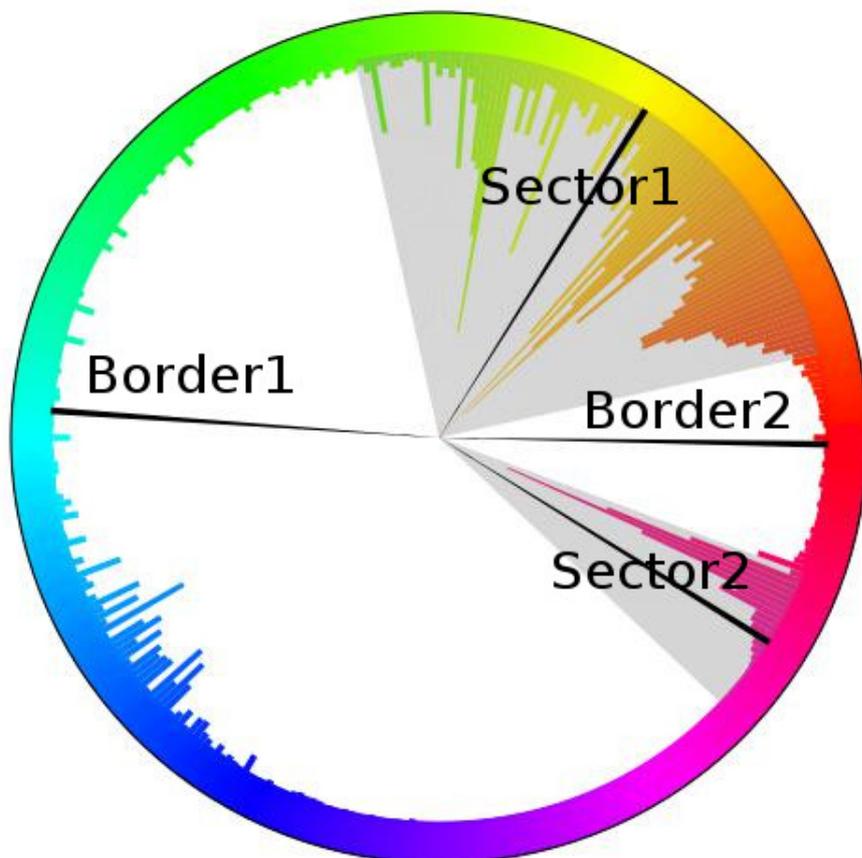
Para encontrar o setor o sinal que um pixel deve ser mapeado foi dividido o círculo cromático em 4 (ou em 2 para *templates* com apenas um setor) separados pelos centros de cada setor e por duas fronteiras como ilustrado na Figura - 4.6.



(a) Amostra "23050"



(b) Segmentação harmônica

Figura 4.5: Exemplo da segmentação harmônica.**Figura 4.6:** Exemplo de divisão do círculo cromático.

Essas fronteiras definem para qual setor os pixels são mapeados e, juntamente com os centros, definem qual o sinal do mapeamento. Essas fronteiras foram encontradas partindo-se do pressuposto de que cada uma delas dividem uma parte bi-modal do histograma, desta maneira foi utilizado o método de Otsu (1975).

A Figura - 4.7 exibe um resultado da aplicação (Figura - 4.7(c)) comparando com o resultado obtido com o mapeamento realizado na imagem como um todo, sem o uso da segmentação (Figura - 4.7(b)).



(a) Amostra "23050"



(b) Mapeamento harmônico



(c) Mapeamento em regiões harmônicas maximais

Figura 4.7: Comparação do mapeamento de cor sem e com o suporte do critério de harmonia.

Conclusões

Este trabalho propôs uma extensão dos operadores de atributos para imagens coloridas, a qual é suportada por dois pilares: i) o processamento do gradiente de cor por decomposição por limiarização; e ii) a escolha de um critério de cor como estatísticas ou *features* de cor, em adição aos bem conhecidos estruturais.

Objetos são bem representados por vales no gradiente colorido. Esse gradiente é decomposto em um conjunto de fatias binárias e seus componentes conectados são medidos e avaliados de acordo com o critério do operador escolhido. Componentes conectados que não atendem ao critério são descartados; os restantes são somados para compor o operador resultante.

Este trabalho também apresentou a aplicação de dois operadores por atributo de cor com o fim de melhorar a segmentação de imagens coloridas. Eles possibilitam aumentar a homogeneidade das regiões resultantes ao custo de aumentar o número de regiões ao ajustar um valor de limiar. Em um experimento os métodos deste trabalho conseguiram uma melhor segmentação na maioria das imagens usadas nos experimentos, quando comparadas com as filtragens por atributos estruturais e o *SLIC*.

Além da extensão dos operadores por atributos para imagens coloridas, eles se tornaram mais versáteis com a extensão do critério para usar dados de cor. Os operadores por atributo também foram utilizados para compressão de imagens. Em Flores et al. (2018), a entropia do dados de cor locais (Duda et al., 2012) foi aplicada para codificar imagens coloridas para compressão de dados.

5.1 Dificuldades Encontradas

- Tempo computacional alto em decorrência da tecnologia utilizada;
- Tempo de design de solução alto em decorrência da necessidade de soluções com o mínimo de estruturas de repetição;
- Segmentação obtida não estritamente hierárquica (flutuação de linhas *watershed* pela *tie-zone* entre filtragens).

5.2 Trabalhos Futuros

Trabalhos futuros incluem melhorias na implementação dos operadores como a utilização de algoritmos mais eficientes para as operações na *Max-Tree*, a utilização de outro algoritmo de *watershed* e que se investigue novos critérios para o processamento por atributo colorido.

REFERÊNCIAS

- ACHANTA, R.; SHAJI, A.; SMITH, K.; LUCCHI, A.; FUA, P.; SÜSSTRUNK, S. SLIC Superpixels Compared to State-of-the-Art Superpixel Methods. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, v. 34, n. 11, p. 2274–2282, 2011.
- ANGULO, J. Morphological colour operators in totally ordered lattices based on distances: Application to image filtering, enhancement and analysis. *Computer Vision and Image Understanding*, v. 107, n. 1-2, p. 56–73, 2007.
- ANGULO, J.; SERRA, J. Color segmentation by ordered mergings. *Image Processing, 2003. ICIP 2003. Proceedings. 2003 International Conference on*, v. 2, p. II–8 vol. 3, 2003.
- BAVEYE, Y.; URBAN, F.; CHAMARET, C.; DEMOULIN, V.; HELLIER, P. Saliency-guided consistent color harmonization. In: *CCIW, 2013*, p. 105–118.
- BEUCHER, S.; LANTUÉJ, C. Use of watersheds in contour detection. In: *Workshop on image processing, real-time edge and motion detection*, 1979.
- BOROUJERDI, A. S.; BREUSS, M.; BURGETH, B.; KLEEFELD, A. *Pde-based color morphology using matrix fields* Cham: Springer International Publishing, p. 461–473, 2015.
- BORSOTTI, M.; CAMPADELLI, P.; SCHETTINI, R. Quantitative evaluation of color image segmentation results. *Pattern Recognition Letters*, v. 19, n. 8, p. 741–747, 1998.
- BREEN, E. J.; JONES, R. Attribute Openings, Thinnings, and Granulometries. *Computer Vision and Image Understanding*, v. 64, n. 3, p. 377–389, 1996.
- CHANUSSOT, J.; LAMBERT, P. Bit mixing paradigm for multivalued morphological filters. In: *6th International Conference on Image Processing and its Applications, IET, 1997*, p. 804–808.

CHEVREUL, M. E. The principles of harmony and contrast of colors,(1839). *Reprinted, Van Nostrand Reinhold, New York, 1967.*

COSTER, M.; CHERMANT, J.-L. Image analysis and mathematical morphology for civil engineering materials. *Cement and Concrete Composites*, v. 23, n. 2, p. 133–151, 2001.

COUSTY, J.; BERTRAND, G.; NAJMAN, L.; COUPRIE, M. Watershed cuts: Minimum spanning forests and the drop of water principle. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 31, n. 8, p. 1362–1374, 2009.

DUDA, R. O.; HART, P. E.; STORK, D. G. *Pattern classification*. John Wiley & Sons, 2012.

FLORES, F. C.; SOUSA FILHO, S.; EVANS, A. N. Attribute Operators for Color Images: The Use of Entropy from Local Color Information to Image Compression, submitted, 2018.

FORESTI, G. L. Object recognition and tracking for remote video surveillance. *IEEE Transactions on Circuits and Systems for Video Technology*, v. 9, n. 7, p. 1045–1062, 1999.

GONZALEZ, R. C.; WOODS, R. E. *Digital Image Processing*. 2 ed. Prentice Hall, 793 p., 2002.

HARALICK, R. M.; SHAPIRO, L. G. Image Segmentation Techniques. *Computer vision, graphics, and image processing*, v. 29, n. 1, p. 100–132, 1985.

HARALICK, R. M.; STERNBERG, S. R.; ZHUANG, X. Image analysis using mathematical morphology. *IEEE transactions on pattern analysis and machine intelligence*, , n. 4, p. 532–550, 1987.

HASAN, Y. M.; KARAM, L. J. Morphological text extraction from images. *IEEE Transactions on Image Processing*, v. 9, n. 11, p. 1978–1983, 2000.

ITTEN, J. *Kunst der farbe*. Reinhold Pub. Corp, 1961.

JONES, R. Connected Filtering and Segmentation Using Component Trees. *Computer Vision and Image Understanding*, v. 75, n. 3, p. 215–228, 1999.

KARVONEN, M.; LAITINEN, M.; LEMSTRÖM, K.; VIKMAN, J. Error-tolerant content-based music-retrieval with mathematical morphology. In: *International Symposium on Computer Music Modeling and Retrieval*, Springer, 2010, p. 321–337.

- KULLBACK, S.; LEIBLER, R. A. On information and sufficiency. *The annals of mathematical statistics*, v. 22, n. 1, p. 79–86, 1951.
- LIU, J.; YANG, Y.-H.; MEMBER, S. Multiresolution Color Image Segmentation. *Ieee Transactions on Pattern Analysis and Machine Intelligence*, v. 16, n. 7, p. 689–700, 1994.
- MARTIN, D.; FOWLKES, C.; TAL, D.; MALIK, J. A Database of Human Segmented Natural Images and its Application to Evaluating Segmentation Algorithms and Measuring Ecological Statistics. In: *Proc. 8th Int'l Conf. Computer Vision*, 2001, p. 416–423.
- MATHERON, G. *Random sets and integral geometry*. John Wiley & Sons, 1975.
- MATSUDA, Y. Color design. *Asakura Shoten*, v. 2, n. 4, p. 10, 1995.
- MEYER, F. Hierarchies of partitions and morphological segmentation. In: *International Conference on Scale-Space Theories in Computer Vision*, Springer, 2001, p. 161–182.
- MOON, P.; SPENCER, D. E. Geometric formulation of classical color harmony. *JOSA*, v. 34, n. 1, p. 46–59, 1944.
- MUNSELL, A. H. *A grammar of color*. Van Nostrand Reinhold, 1969.
- NAJMAN, L.; TALBOT, H., eds. *Mathematical Morphology*. Hoboken, NJ, USA: John Wiley & Sons, Inc., 2013.
- OSTWALD, W. *The color primer*. 1969.
- OTSU, N. A threshold selection method from gray-level histograms. *Automatica*, v. 11, n. 285-296, p. 23–27, 1975.
- OU, L. C.; LUO, M. R. A colour harmony model for two-colour combinations. *Color Research and Application*, v. 31, n. 3, p. 191–204, 2006.
- PAULI, H. Proposed extension of the CIE recommendation on Uniform color spaces, color difference equations, and metric color terms. *Journal of the Optical Society of America*, v. 66, n. 8, p. 866–867, 1976.
- ROERDINK, J. B. Mathematical morphology in computer graphics, scientific visualization and visual exploration. In: *International Symposium on Mathematical Morphology and Its Applications to Signal and Image Processing*, Springer, 2011, p. 367–380.

SALEMBIER, P.; OLIVERAS, A.; GARRIDO, L. Antiextensive connected operators for image and sequence processing. *IEEE Transactions on Image Processing*, v. 7, n. 4, p. 555–570, 1998.

SERRA, J. *Image analysis and mathematical morphology*. Academic press, 1982.

SERRA, J. *Image analysis and mathematical morphology. volume 2: Theoretical advances*. Academic Press, 1988.

SERRA, J. Use of mathematical morphology in industrial control. *Microscopy Microanalysis Microstructures*, v. 7, n. 5-6, p. 297–302, 1996.

SERRA, J. C.; SALEMBIER, P. Connected operators and pyramids. 1993, p. 65–76.

SOILLE, P.; PESARESI, M. Advances in mathematical morphology applied to geoscience and remote sensing. *IEEE Transactions on Geoscience and Remote Sensing*, v. 40, n. 9, p. 2042–2055, 2002.

SOUSA FILHO, S. 2017.

Disponível em <https://github.com/filaboia/colorattributefiltering>

SOUSA FILHO, S.; FLORES, F. C. Attribute operators for color images: Image segmentation improved by the use of unsupervised segmentation evaluation methods. In: *International Symposium on Mathematical Morphology and Its Applications to Signal and Image Processing*, Springer, 2017, p. 249–260.

SOUSA FILHO, S.; FLORES, F. C. Attribute Operators for Color Images: Color Harmonization Based on Maximal Harmonic Segmentation, submitted, 2018.

VACHIER, C.; MEYER, F. Extinction Value: A New Measurement of Persistence. In: *Proceedings of 1995 IEEE Workshop on Nonlinear Signal and Image Processing*, IEEE, 1995, p. 254–257.

VON GOETHE, J. W. *Theory of colours*, v. 3. Mit Press, 1840.

VAN DER WALT, S.; SCHÖNBERGER, J. L.; NUNEZ-IGLESIAS, J.; BOULOGNE, F.; WARNER, J. D.; YAGER, N.; GOUILLART, E.; YU, T.; THE SCIKIT-IMAGE CONTRIBUTORS scikit-image: image processing in Python. *PeerJ*, v. 2, p. e453, 2014.

YU-QIAN, Z.; WEI-HUA, G.; ZHEN-CHENG, C.; JING-TIAN, T.; LING-YUN, L. Medical images edge detection based on mathematical morphology. In: *Engineering in*

Medicine and Biology Society, 2005. IEEE-EMBS 2005. 27th Annual International Conference of the, IEEE, 2006, p. 6492–6495.

ZHANG, H.; FRITTS, J. E.; GOLDMAN, S. A. An entropy-based objective evaluation method for image segmentation. In: YEUNG, M. M.; LIENHART, R. W.; LI, C.-S., eds. *Storage and Retrieval Methods and Applications for Multimedia 2004*, 2003, p. 38–49.

ZHANG, H.; FRITTS, J. E.; GOLDMAN, S. A. Image segmentation evaluation: A survey of unsupervised methods. *Computer Vision and Image Understanding*, v. 110, n. 2, p. 260–280, 2008.