

4 Avaliação Experimental

Neste capítulo são descritos os experimentos realizados e apresentados os resultados obtidos.

4.1. Avaliação das Métricas de Discrepância

Nesta seção é apresentado um estudo sobre métricas de discrepância para a avaliação supervisionada da qualidade da segmentação. Este estudo foi realizado com quatro objetivos principais.

O primeiro objetivo foi avaliar o grau de correlação entre diferentes métricas (Seção 4.1.2) disponíveis na literatura utilizando o coeficiente de correlação de ordem de Kendall (Seção 2.5), que mede quão bem a relação entre dois conjuntos de dados pode ser descrita por uma função monotônica.

O segundo objetivo foi verificar se as métricas conduziam um algoritmo de otimização a regiões próximas no espaço de parâmetros (Seção 4.1.3). Este experimento foi realizado utilizando-se o SPT (Feitosa06), um programa para ajuste de parâmetros de segmentação baseado em algoritmos genéticos. O método de segmentação implementado neste programa é o Segmentação Multiresolução original (Seção 2.1.4) e não o proposto.

Em terceiro, procurou-se estimar, utilizando o mesmo método de correlação de ordem, o grau de correlação que um conjunto de observadores humanos possui ao avaliar visualmente uma segmentação em relação a um conjunto de segmentos de referência (Seção 4.1.4).

Por último, com base nos experimentos da terceira etapa, se verificou quais métricas se mostravam mais correlacionadas com os observadores humanos (Seção 4.1.5). A métrica que obteve melhor desempenho nestes experimentos foi utilizada nos experimentos para avaliação do método proposto (Seção 4.2).

4.1.1. Banco de Dados

A avaliação das métricas de discrepância foi realizada sobre um recorte de 418x599 pixels de uma imagem de sensoriamento remoto, produzida pelo satélite *Quickbird*. A resolução espacial da imagem é de 0,67m e ela possui 4 bandas espectrais (azul, verde, vermelho e infravermelho próximo). Uma composição RGB é mostrada na Figura 4.1. A área representada na imagem consiste principalmente de telhados de casas e prédios, ruas e árvores.

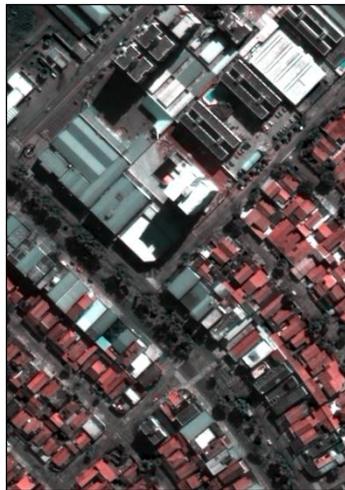


Figura 4.1: Imagem *Quickbird*.

Três conjuntos de referências foram delineados manualmente por um fotointérprete para essa imagem. O primeiro grupo consiste de segmentos altamente homogêneos espectralmente. O segundo grupo de referências consiste de segmentos não homogêneos compostos de algumas partes homogêneas. O terceiro grupo é a união dos outros dois e será chamado de mesclados. As figuras 4.2 (a) a 4.2 (c) mostram os conjuntos de segmentos de referência para cada grupo.

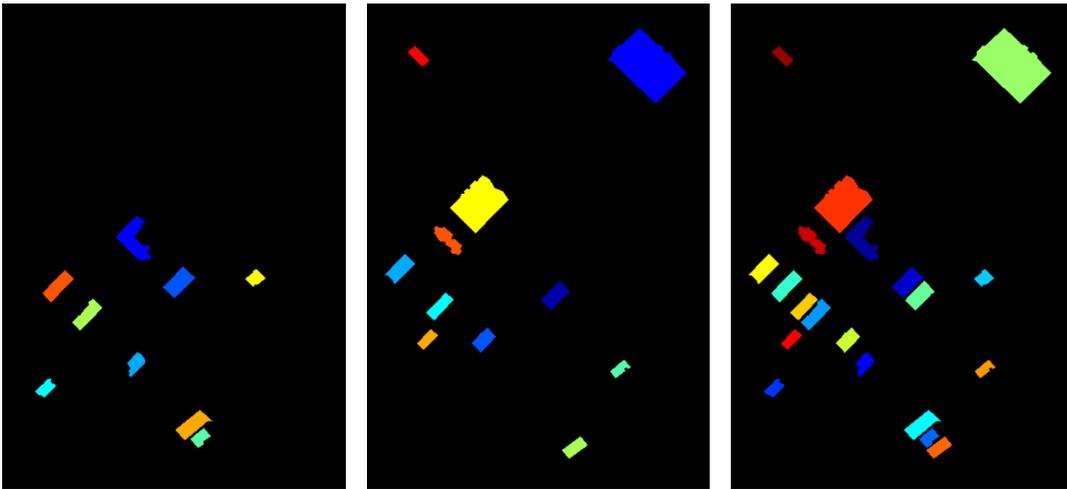


Figura 4.2: Grupos de referências (a) homogêneas, (b) heterogêneas e (c) mescladas.

4.1.2.

Correlação de Ordem entre Métricas de Discrepância

O objetivo deste primeiro conjunto de experimentos foi verificar quais métricas tendiam a concordar quanto à qualidade relativa de um conjunto de segmentações distintas. Para isso, a imagem mostrada na Figura 4.1 foi segmentada 110 vezes por um programa de segmentação baseado no algoritmo proposto por Baatz e Shäpe (Baatz00). Cada segmentação consistiu de uma combinação diferente de parâmetros de escala e peso cor/forma, realizada a partir desses valores:

- a) Peso cor/forma – 0,0; 0,1; 0,2; 0,3; 0,4; 0,5; 0,6; 0,7; 0,8; 0,9; 1,0;
- b) Escala – 5,0; 10,0; 15,0; 20,0; 25,0; 30,0; 35,0; 40,0; 45,0; 50,0;
- c) Compacidade – foi mantida constante em 0,5.

As 110 segmentações foram avaliadas por cada uma das oito métricas apresentadas na seção 2.4, gerando oito conjuntos com 110 avaliações cada. As correlações de ordem de Kendall (Seção 2.5) foram calculadas para cada par de conjuntos. Este mesmo procedimento foi ainda repetido para cada conjunto de referências apresentados na introdução dessa seção. Para melhorar a visibilidade, as células redundantes (as tabelas são simétricas) e irrelevantes (os elementos da diagonal principal são iguais a 100%) foram suprimidas das tabelas.

	RBSB	LSB	JANS	SE	DARA	DPASM	DPSRMS
LSB	33						
JANS	72	63					
SE	70	66	96				
DARA	85	39	71	69			
DPASM	85	44	78	75	82		
DPSRMS	83	41	74	73	80	93	
DPASM_x	77	40	70	69	75	85	89

Tabela 4.1: Coeficiente de correlação de ordem de Kendall (%) para o grupo de referências homogêneas.

	RBSB	LSB	JANS	SE	DARA	DPASM	DPSRMS
LSB	-7						
JANS	55	57					
SE	51	62	94				
DARA	72	33	71	68			
DPASM	65	33	69	66	78		
DPSRMS	65	32	68	65	77	94	
DPASM_x	66	23	60	57	72	78	82

Tabela 4.2: Coeficiente de correlação de ordem de Kendall (%) para o grupo de referência mescladas.

	RBSB	LSB	JANS	SE	DARA	DPASM	DPSRMS
LSB	-23						
JANS	41	41					
SE	35	48	92				
DARA	56	20	67	64			
DPASM	54	17	65	61	76		
DPSRMS	56	16	64	60	76	93	
DPASM_x	64	1	53	48	66	76	80

Tabela 4.3: Coeficiente de correlação de ordem de Kendall (%) para o grupo de referências heterogêneas.

As tabelas mostram que os coeficientes de correlação, para todas as métricas, tendem a ser maiores para o grupo de referências homogêneas, a decrescer para o grupo de referências heterogêneas e a atingir os níveis mais baixos para o grupo mesclado. Isto indica a dificuldade crescente de achar uma segmentação satisfatória na medida em que as amostras de referências vão ficando mais heterogêneas.

Para as referências homogêneas todos os coeficientes ficaram acima do valor crítico que neste caso é 10,59% para o nível de significância de 5%. Para os grupos mesclados e heterogêneos a métrica LSB fica abaixo desse nível em alguns casos (mostrados em células sombreadas), indicando evidência insuficiente de uma relação monotônica com as outras métricas. Como explicado em (Fredrich08), era esperado que a métrica LSB se comportasse como as outras para objetos homogêneos, e que deveria se comportar de maneira diferente para objetos heterogêneos, o que é consistente com os resultados apresentados nas Tabelas 4.1 a 4.3.

4.1.3. Similaridade entre as Soluções do AG para Diferentes Métricas

Neste segundo experimento, o objetivo foi identificar que métricas atingiam os seus valores ótimos em regiões próximas do espaço de parâmetros. Em cada rodada, o AG foi configurado da seguinte maneira:

- Número de gerações: 50
- Tamanho da população: 80
- Taxa de *crossover* inicial: 0,65
- Taxa de *crossover* final: 0,45
- Taxa de mutação inicial: 0,7
- Taxa de mutação final: 0,6
- Taxa de *steady state* inicial: 0,8
- Taxa de *steady state* final: 0,8
- Número de experimentos: 3

A compacidade foi mantida em 0,5 e os pesos das bandas em 1,0, apenas o parâmetro de escala e o peso cor/forma foram evoluídos. O AG foi executado para cada um dos três conjuntos de referência mostrados anteriormente e os resultados são apresentados nas Tabelas 4.4 a 4.6.

	Escala	Cor
RBSB	34,0	0,11
LSB	34,3	0,11
JAN	34,5	0,11
SE	31,8	0,11
DARA	24,6	0,07
DPASM	33,6	0,11
DPSRMS	34,8	0,11
DPASMx	32,3	0,09

Tabela 4.4: Valores dos parâmetros obtidos para o grupo homogêneo.

	Escala	Cor
RBSB	22,8	0,06
LSB	30,2	0,07
JAN	24,4	0,06
SE	30,4	0,08
DARA	26,4	0,05
DPASM	24,4	0,06
DPSRMS	24,4	0,06
DPASMx	30,9	0,08

Tabela 4.5: Valores dos parâmetros obtidos para o grupo mesclado.

	Escala	Cor
RBSB	24,4	0,06
LSB	31,4	0,07
JAN	24,4	0,06
SE	24,4	0,05

DARA	24,0	0,05
DPASM	24,5	0,06
DPSRMS	24,5	0,06
DPASM_x	28,2	0,05

Tabela 4.6: Valores dos parâmetros obtidos para o grupo heterogêneo.

É possível observar que os valores de escala e cor de cada tabela estão concentrados em um intervalo relativamente pequeno. Embora não seja possível afirmar que o mesmo comportamento se observará para qualquer imagem e conjunto de referência, os resultados obtidos mostram que a otimização baseada em Algoritmos Genéticos pode, de fato, ajudar no processo de definição de parâmetros de segmentação. Os resultados também mostram que as métricas não levam sempre à mesma solução. Até mesmo as métricas JAN e SE, que se mostraram altamente correlacionadas no experimento anterior, conduziram a soluções sensivelmente diferentes em termos dos parâmetros de segmentação para o grupo mesclado de referências. Contudo, não há nenhuma garantia de que o método de adaptação genético sempre encontre o ótimo global.

4.1.4. Consistência entre as Avaliações dos Observadores Humanos

O objetivo desta sequência de experimentos era avaliar a variação da percepção humana em relação à qualidade da segmentação. Para isto, três grupos de segmentações foram criados da seguinte maneira.

Os valores dos parâmetros obtidos na etapa anterior foram alterados de forma de forma a produzir cinco segmentações diferentes para cada conjunto de segmentos de referência. As mudanças realizadas nos valores dos parâmetros foram cuidadosamente realizadas de forma que, para todas as métricas, a qualidade de todas as segmentações do grupo homogêneo fossem melhores do que todas as segmentações do grupo mesclado que, por sua vez, fossem melhores do que todas as segmentações do grupo heterogêneo.

Na sequência, 25 pesquisadores e alunos de graduação da PUC-Rio e do INPE, que trabalham na área de análise de imagens de sensoriamento remoto e afins, realizaram uma ordenação da qualidade das segmentações para cada grupo

baseado em imagens como as mostradas nas Figuras 4.3(a) a 4.3(c). Nas figuras, a imagem original (submetida ao processo de segmentação) foi intencionalmente omitida para que a avaliação desses observadores não fosse influenciada pela segmentação em áreas não relacionadas aos segmentos de referência.

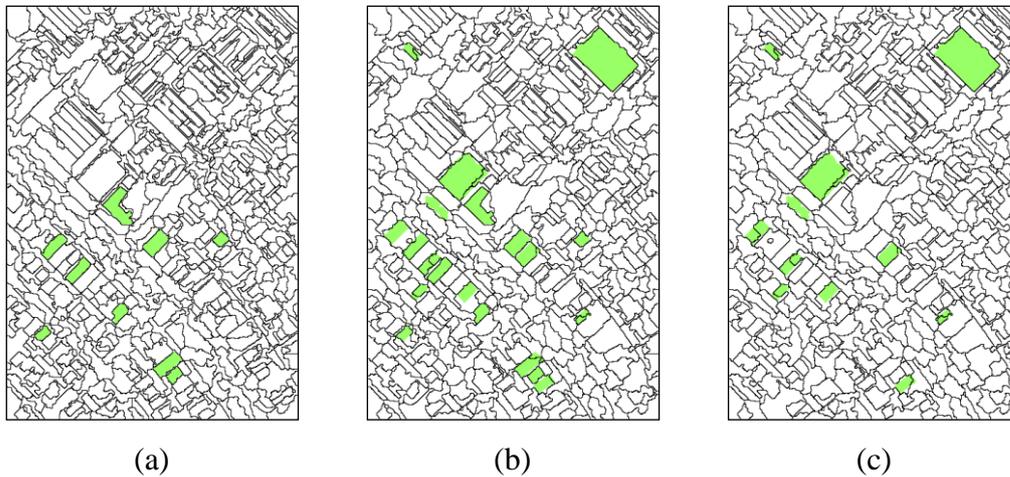


Figura 4.3: Exemplos das figuras de segmentações ordenadas pelos observadores humanos.

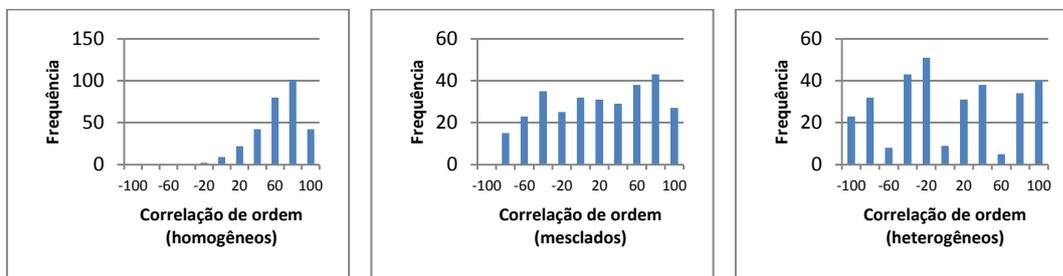


Figura 4.4: Histogramas da correlação de ordem entre 25 observadores para três grupos de resultados de segmentações.

Os gráficos na Figura 4.4 mostram o histograma dos valores da correlação de ordem calculados para todos os pares de observadores, para cada grupo de referências. Ao olhar para o histograma do grupo heterogêneo é possível perceber uma evidente discordância entre os observadores. De fato, a média e o desvio-padrão dos valores de correlação para este grupo foram respectivamente 5% e 59%, indicando uma relação quase caótica entre as avaliações. Para o grupo mesclados, o comportamento foi levemente melhor, com média e desvio-padrão iguais a 17% e 50% respectivamente, mas ainda mostrando uma divergência

considerável entre os observadores. Entretanto, uma concordância é mostrada para as segmentações do grupo homogêneo. O valor de correlação médio sobe para 65% e o desvio-padrão cai para 22%.

Estes resultados revelam que o olho humano pode levar a avaliações bem discrepantes quando as segmentações sendo comparadas possuem qualidade ruim. Entretanto, ao passo que as segmentações se aproximam da segmentação ideal, os humanos tendem a concordar.

Ainda nesta sequência os observadores humanos foram substituídos pelas métricas de discrepância e a correlação de ordem foi medida entre as respectivas avaliações. Os resultados são mostrados na Figura 4.5.

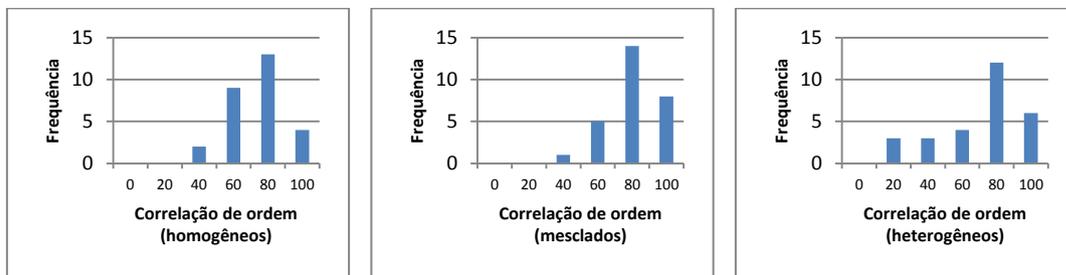


Figura 4.5: Histogramas da correlação de ordem entre as métricas de discrepância definidas na Seção 2.4.

A correlação média foi de 74%, 71% e 76% para os grupos homogêneo, mesclado e heterogêneo, enquanto os desvios-padrão foram, respectivamente, 5%, 21% e 18%. Desta forma, a concordância entre as métricas de discrepância foi muito maior do que entre os observadores humanos e se manteve alta para todos os três grupos.

4.1.5. Métricas Consistentes com a Percepção Humana

A sequência final de experimentos teve por objetivo verificar qual métrica de discrepância melhor expressa a percepção humana da qualidade da segmentação. Usando os mesmos resultados obtidos no experimento anterior foi calculada a correlação de ordem entre cada observador e cada métrica de discrepância. Uma vez que nenhuma concordância substancial entre os observadores foi alcançada para os grupos heterogêneo e mesclado, esta análise se

limitou ao grupo homogêneo. Os histogramas das correlações de ordem são mostrados na Figura 4.6.

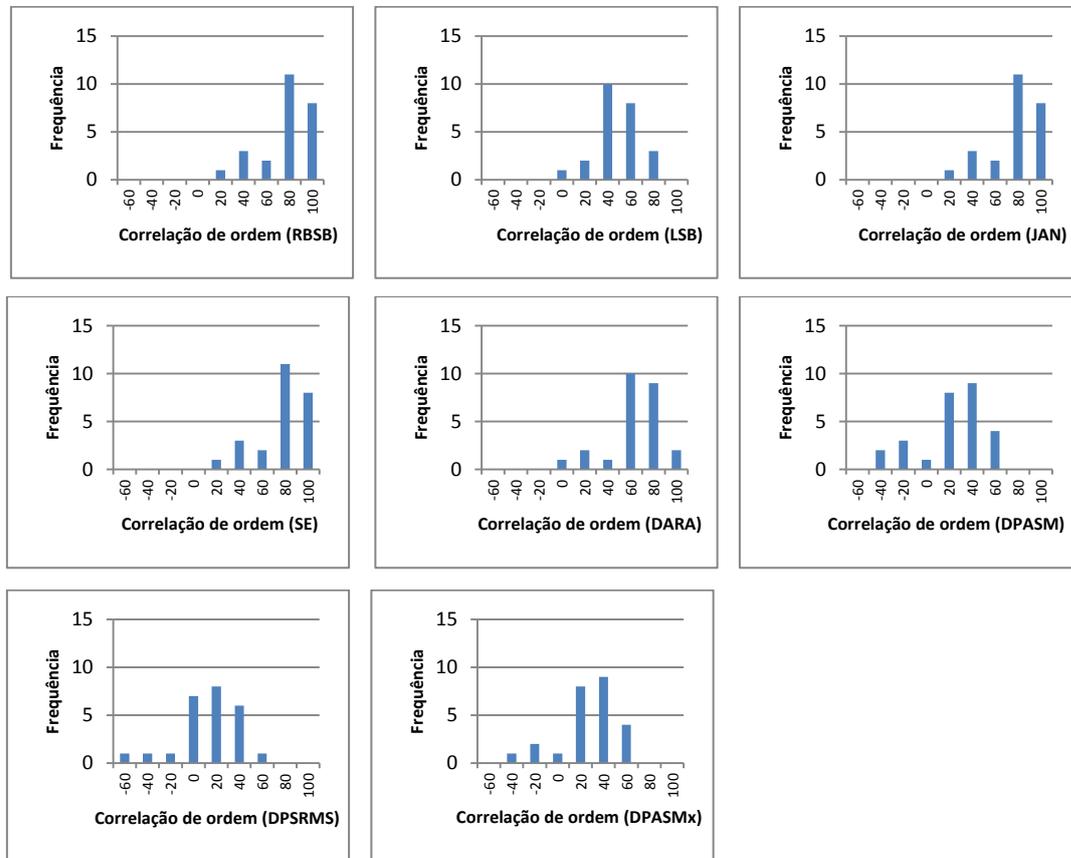


Figura 4.6: Histogramas da correlação entre cada métrica de discrepância e 25 observadores com relação à qualidade da segmentação no grupo homogêneo.

Já que os histogramas são baseados em 5 segmentações, apenas correlações de 80% ou acima podem ser consideradas significativas para um nível de significância α de 5%. Portanto, as métricas RBSB, JAN e SE, cujos histogramas são indistinguíveis na Figura 4.6, alcançaram em nossos experimentos a maior correlação com a percepção humana da qualidade da segmentação. A métrica DARA vem depois, acompanhada pela LSB. As ordenações produzidas pelas métricas DPASM, DPSRMS e DPASMx não apresentaram em nossos experimentos nenhuma correlação significativa com as ordenações realizadas pelos observadores humanos.

4.2. Avaliação dos Atributos de Forma na Segmentação

Nesta seção são avaliados os resultados obtidos com o método de segmentação de imagens proposto descrito na seção 3.1. Os resultados são analisados quantitativamente, sendo uma análise visual conduzida para os casos com melhor e pior desempenho. Cabe ressaltar que assim como as referências utilizadas em cada experimento se referem a apenas uma classe de objetos de interesse, a análise visual se limitará a analisar os resultados com base nas mesmas referências, deixando de lado o desempenho da segmentação sobre os outros objetos presentes na imagem.

Na seção 4.2.1 é apresentado o banco de imagens utilizado nos experimentos. A seção 4.2.2 apresenta como o método de otimização foi configurado. As outras seções apresentam os experimentos realizados.

Os experimentos possuem três etapas. A primeira teve por objetivo selecionar os parâmetros para uma segmentação baseada somente em valores espectrais (cor) (Seção 4.2.3), através do procedimento de otimização descrito na seção anterior. Desta forma, com base nas referências, para cada imagem foram determinados valores ótimos para o parâmetro de escala, fixando o peso de forma w_{forma} igual a zero.

Na segunda etapa, o segmentador proposto foi configurado para utilizar um único atributo de forma (Seção 4.2.4) de cada vez. Para cada atributo de forma o parâmetro de escala e o peso de forma w_{forma} foram determinados através do procedimento de otimização descrito na seção anterior. Os resultados da segmentação de cada imagem foram avaliados e comparados com os obtidos na etapa anterior.

Na terceira etapa, o segmentador foi configurado para utilizar dois atributos de forma (4.2.5). Para cada imagem, um desses dois atributos foi mantido fixo – utilizou-se o melhor atributo avaliado na etapa anterior. Para cada par de atributos de forma, para cada imagem, foram determinados o parâmetro de escala, o peso da forma w_{forma} e o peso relativo entre os dois atributos de forma. Os resultados das segmentações foram então comparados com os da etapa anterior.

4.2.1. Banco de Imagens

Os experimentos para avaliação do método proposto foram realizados em um conjunto de doze imagens com diferentes características para um conjunto de quinze classes de objetos-alvo. Foram utilizadas três imagens de sensoriamento remoto recortadas do software Google Earth, uma imagem de microscopia, uma imagem de tomografia computadorizada, obtida no site da conferência SLiver07 (Heimann07), uma imagem de raios X e seis imagens de um banco de avaliação de segmentações (Alpert07).

A Figura 4.7 apresenta as três imagens de sensoriamento remoto utilizadas e as respectivas referências. A imagem (a) é um recorte de 272x287 pixels, de uma área residencial da Barra da Tijuca. Nesta imagem, delinear-se dez referências de árvores isoladas. A imagem (b) é um recorte de 219x257 pixels, de um conjunto de tanques da refinaria do município de Duque de Caxias. Delinearam-se cinco referências de tanques. A terceira imagem (c) é um recorte de 350x393 pixels, de uma área residencial na Barra da Tijuca. Foram delineadas 10 referências de telhados cerâmicos. Todas as imagens possuem três bandas (RGB).

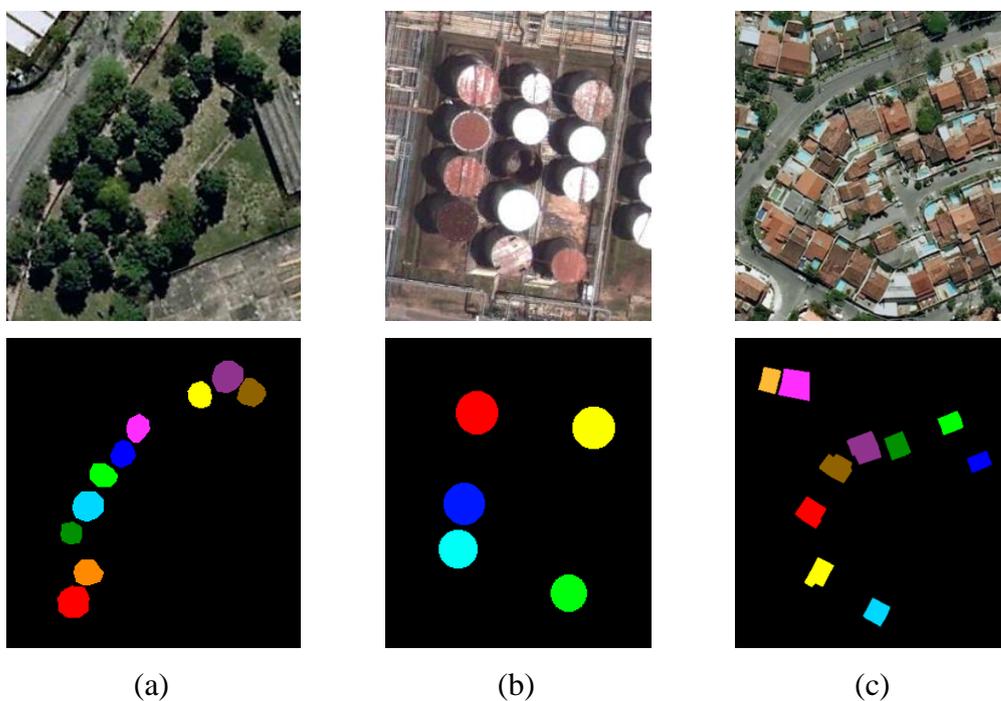


Figura 4.7: Imagens de sensoriamento remoto: (a) árvores, (b) refinaria e (c) telhados, com respectivas referências.

Na Figura 4.8 são apresentadas a imagem de microscopia e as duas imagens de referência utilizadas. A imagem é um recorte de 725x334 pixels de cristais de hematita sob luz polarizada obtidas com o Departamento de Engenharia de Materiais da PUC-Rio. As referências delineadas se referem às duas classes desses cristais presentes na imagem: lamelar e granular. A imagem possui três bandas espectrais (RGB).

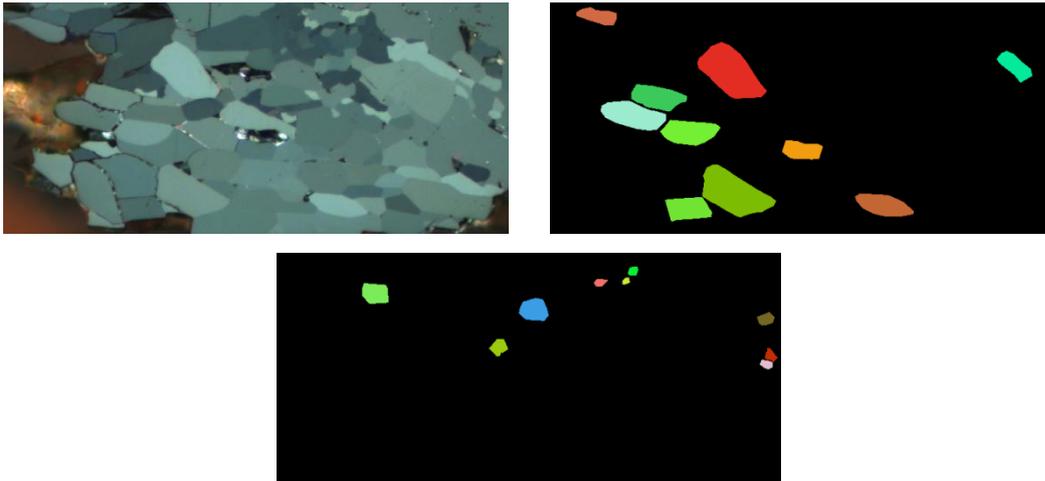


Figura 4.8: Imagem de microscopia: cristais de hematita (minério de ferro) e referências da classe lamelar (direita) e granular (abaixo).

A Figura 4.9 apresenta a imagem de tomografia computadorizada e a respectiva referência. A imagem de 512x512 pixels representa uma fatia de um exame do tórax. A referência representa o fígado e foi delineada por um especialista. A imagem possui apenas uma banda espectral.

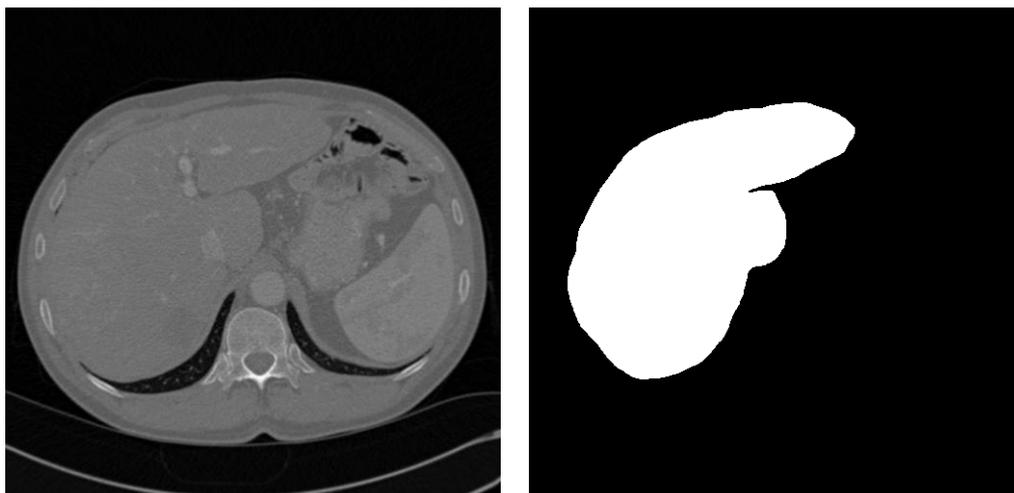
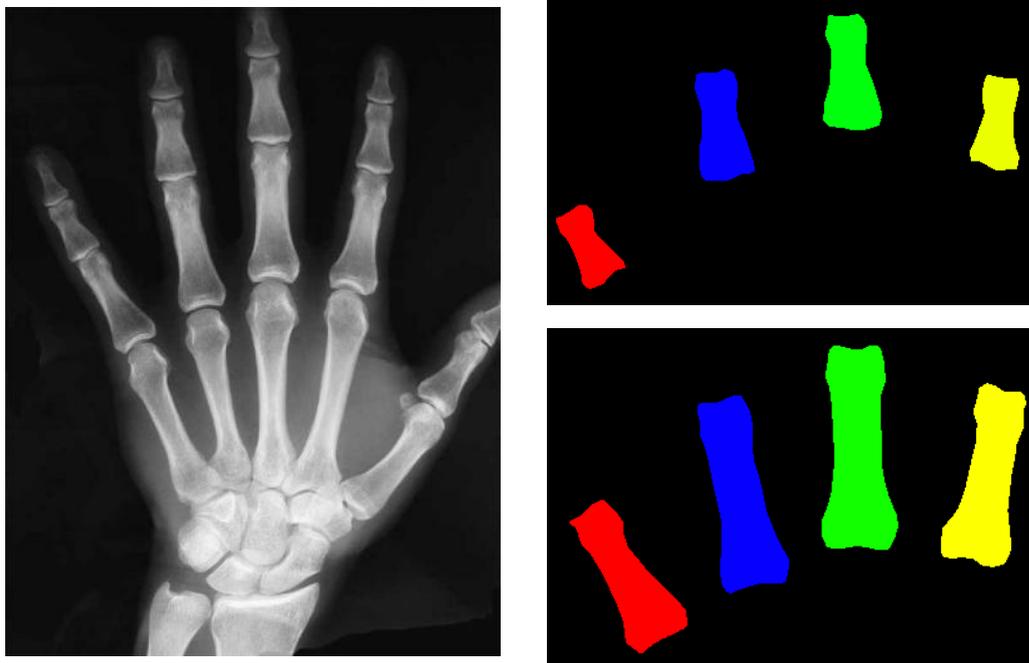


Figura 4.9: Imagem de ressonância magnética e respectiva referência.

Na Figura 4.10, são apresentados o exame de raios X e as respectivas referências. A imagem de 576x762 pixels é um exame de raios X da mão. As referências representam três grupos de ossos presentes no exame: falange média, falange proximal e metacarpo. A imagem possui três bandas espectrais (RGB).



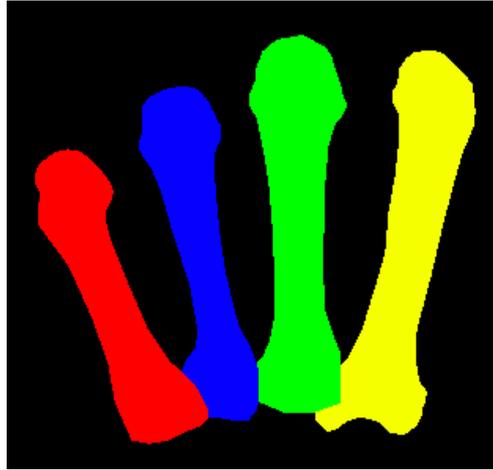


Figura 4.10: Imagem de raios X da mão e referências das classes falange média (acima), falange proximal (centro) e metacarpo (abaixo).

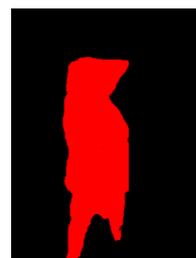
A Figura 4.11 apresenta um conjunto de seis imagens obtidas de um banco de avaliação de segmentações (Alpert07). A imagem (a), de um sapo, possui 300x225 pixels. A imagem (b), de uma estrela-do-mar, possui 300x225 pixels. A imagem (c), de um suricato, possui 300x400 pixels. A imagem (d) mostra um monumento de pedras e possui 300x200 pixels. A imagem (e) mostra uma lagarta e possui 300x200 pixels e a imagem (f), um ninho com ovos, possui 300x214 pixels. As referências foram obtidas pela interseção de referências delineadas por 3 analistas diferentes obtidas no próprio banco de imagens (Alpert07). Todas as imagens possuem três bandas espectrais (RGB).



(a)



(b)



(c)

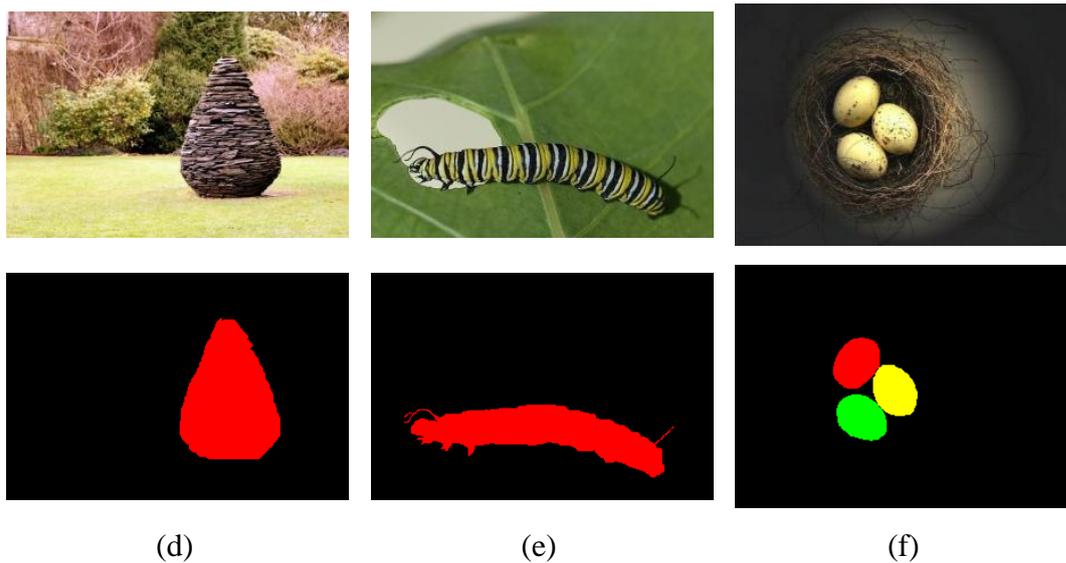


Figura 4.11: Imagens do banco de avaliação de segmentações: (a) sapo, (b) estrela-do-mar, (c) suricato, (d) pedras, (e) lagarta e (f) ovos, com respectivas referências.

4.2.2. Otimização dos Parâmetros de Segmentação

Para a determinação automática dos parâmetros de segmentação, utilizou-se o método de busca direta *Generalized Pattern Search* descrito na Seção 2.6.2, implementado no programa MATLAB (Mathworks11). Neste método, cada ponto de busca corresponde a um conjunto de valores dos parâmetros do método de segmentação. A avaliação de cada ponto é dada pela comparação entre a segmentação produzida pelo método proposto e a segmentação de referência utilizando a métrica de avaliação RBSB apresentada na seção 2.4.1 e que obteve uma boa correlação com a percepção humana da qualidade da segmentação nos experimentos apresentados na Seção 4.1.

Como descrito na seção 3.1, o método de segmentação possui 4 parâmetros a serem otimizados: p_e , w_{forma} , vetor de pesos w_c para cada banda c , e vetor de pesos w_s para cada atributo de forma s .

Cada ponto inicial é gerado randomicamente, respeitando o intervalo de valores permitidos para parâmetro. Depois disso, o método foi configurado para realizar uma busca antes da seleção, tentando com isso minimizar a possibilidade de que o otimizador estagnasse em um mínimo local. Na busca foi utilizado o padrão MADS Base Positiva $2n$. Esse padrão é semelhante ao utilizado na

seleção, sendo que os vetores são gerados randomicamente, possibilitando ao otimizador procurar um ponto melhor em diversas direções.

Na etapa de seleção foi utilizado o padrão Base Positiva $2n$, que foi brevemente descrito na seção 2.6.2.1. Esse padrão possui um conjunto fixo de vetores que selecionam um conjunto de pontos para avaliação na vizinhança do ponto corrente.

O processo de otimização termina quando o limiar do tamanho do *mesh* é atingido. Nesse ponto, os valores do ponto corrente são definidos como os parâmetros finais (otimizados) do método de segmentação. A Figura 4.12 ilustra o processo de avaliação dos parâmetros.

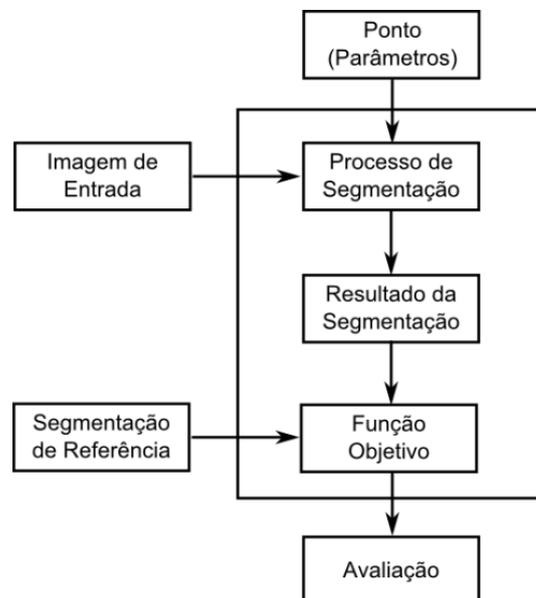


Figura 4.12: Avaliação dos parâmetros de segmentação.

Neste trabalho, o otimizador foi configurado da seguinte maneira:

- a) Método de busca: MADS Base Positiva $2n$
- b) Método de seleção: Base Positiva $2n$
- c) Busca completa: Sim
- d) Seleção completa: Sim
- e) Expansão do tamanho do *mesh*: 6
- f) Contração do tamanho do *mesh*: 0,7
- g) Limiar do tamanho do *mesh*: 10^{-3}

Cabe aqui uma breve descrição dos parâmetros busca completa e seleção completa. Na sua configuração padrão oferecida pelo MATLAB (MATHWORKS11), o otimizador para a busca ou seleção assim que encontra algum ponto com um valor de função objetivo menor do que o do ponto corrente e passa para a próxima iteração com o ponto atualizado. Com os parâmetros busca e seleção completa ativos, o otimizador sempre avalia todos os pontos dentro do *mesh*, e escolhe aquele com menor valor de função objetivo para ser o ponto corrente da iteração seguinte. Com isso se garante de que o ponto escolhido possui a menor avaliação possível dentre os pontos disponíveis.

4.2.3. Segmentação sem Atributos de Forma

A primeira etapa teve por objetivo avaliar segmentações realizadas apenas usando informações espectrais (cor), ou seja, com $w_{forma} = 0.0$ e com os pesos das bandas fixados em um. Devido à configuração utilizada no otimizador GPS ser essencialmente estocástica, para cada imagem foram realizados 10 experimentos e tomados o mínimo entre eles. Os valores estimados para o parâmetro de escala p_e e as respectivas avaliações são mostrados na Tabela 4.7:

Classes	p_e	Avaliação
Sensoriamento Remoto		
Refinaria	35,841243	0,373797
Telhados	31,988594	0,607871
Árvores	20,271478	0,675946
Microscopia		
Lamelar	59,305370	0,203551
Granular	16,721759	0,333380
Tomografia Computadorizada		
Fígado	321,36440	0,396451
Raios X		
Falange Média	95,469467	0,586371
Falange Proximal	81,239302	0,643428
Metacarpo	96,172675	0,740160

Banco da imagens		
Estrela-do-mar	237,13009	0,291993
Sapo	75,461925	0,640515
Lagarta	213,71187	0,669883
Ovos	31,413037	0,237095
Pedras	102,19906	0,690106
Suricato	218,05430	0,398757

Tabela 4.7: Parâmetros estimados para uma segmentação baseada somente na cor.

4.2.4. Segmentação com um Único Atributo de Forma

Nestes experimentos, um único atributo de forma foi utilizado nas segmentações. Com isso, três parâmetros foram estimados: o parâmetro de escala p_e , o peso forma/cor w_{forma} e o peso do atributo de forma w_s . Novamente, os pesos das bandas foram fixados em um. O objetivo desta etapa foi verificar, num primeiro momento, se a introdução de um atributo de forma levava a soluções (segmentações) com melhores avaliações do que aquelas realizadas considerando apenas a cor, conduzidas na etapa anterior; e num segundo momento, verificar que atributo ou conjunto de atributos de forma contribuía para o desempenho da segmentação para cada imagem e classes de objetos alvo. Novamente, foram realizados 10 experimentos, onde o mínimo (a melhor avaliação) foi tomado. Os resultados comparados com os resultados da primeira etapa (seção anterior) são mostrados nas Figuras 4.13-4.17.

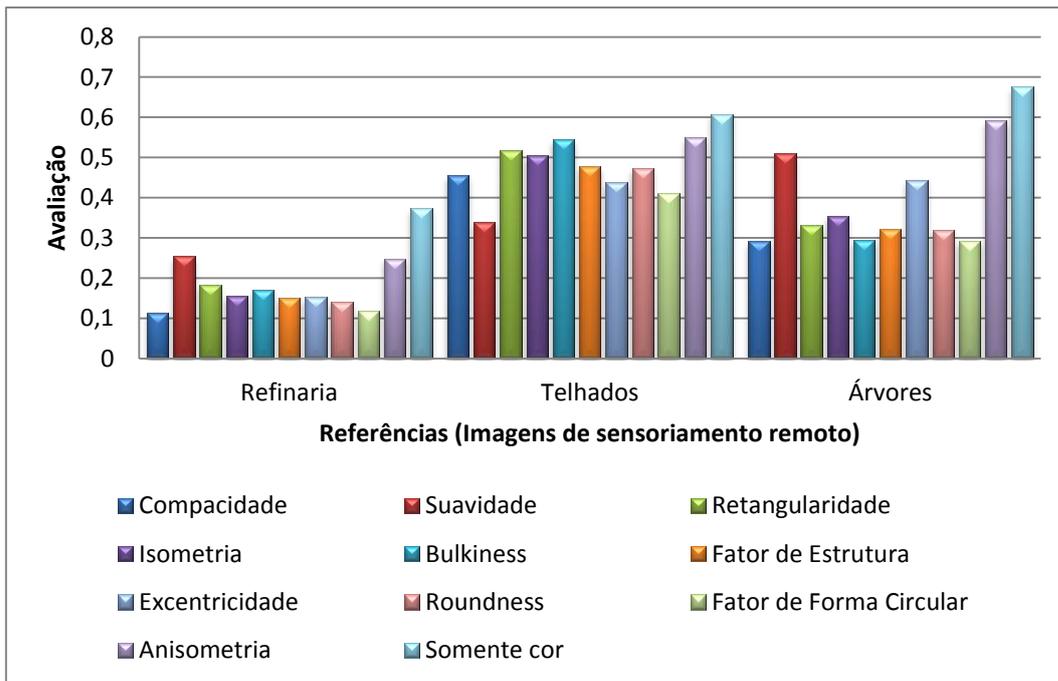


Figura 4.13: Comparação entre as avaliações das segmentações com um único atributo de forma e as com apenas a cor para as referências das imagens de sensoriamento remoto.

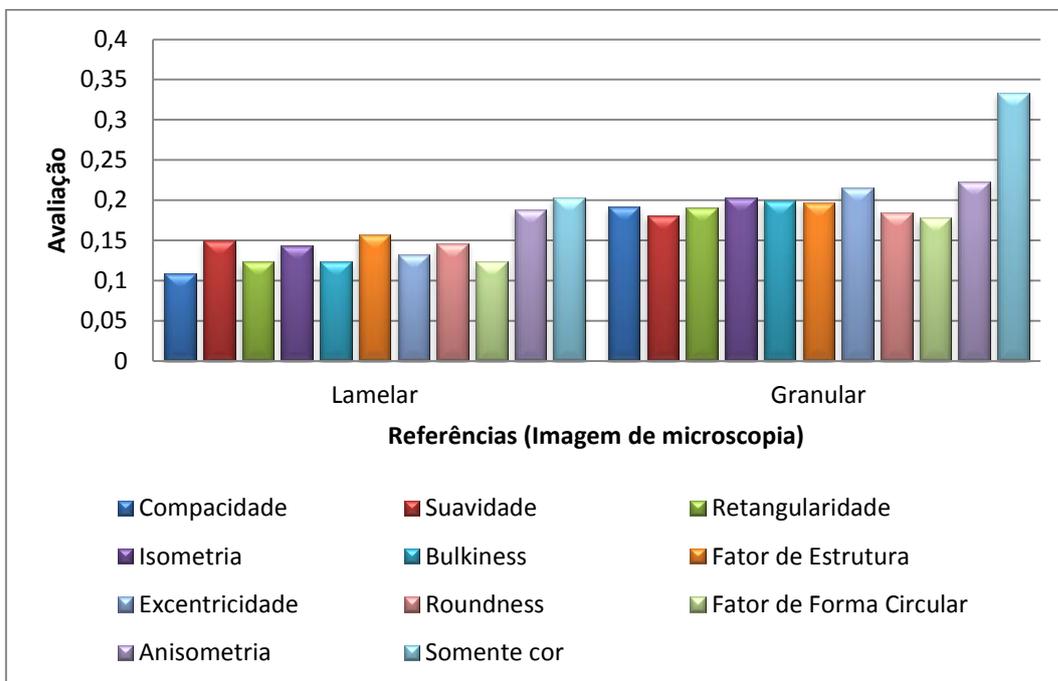


Figura 4.14: Comparação entre as avaliações das segmentações com um único atributo de forma e as com apenas a cor para as referências da imagem de microscopia.

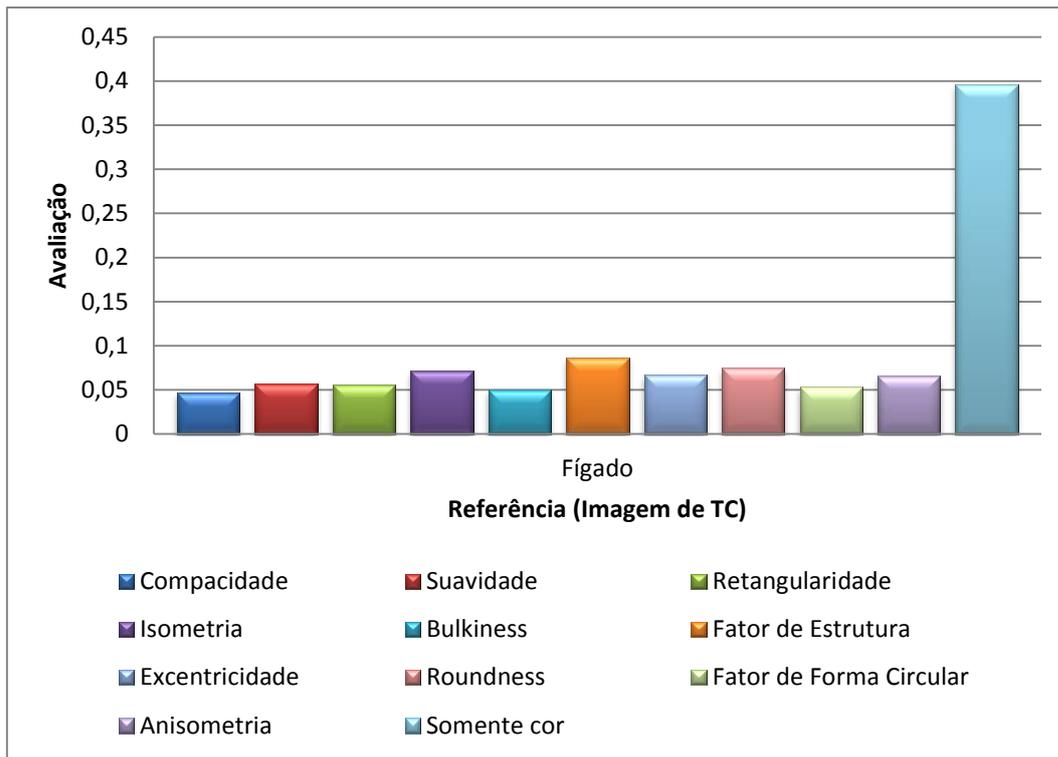


Figura 4.15: Comparação entre as avaliações das segmentações com um único atributo de forma e as com apenas a cor para a referência da imagem de TC.

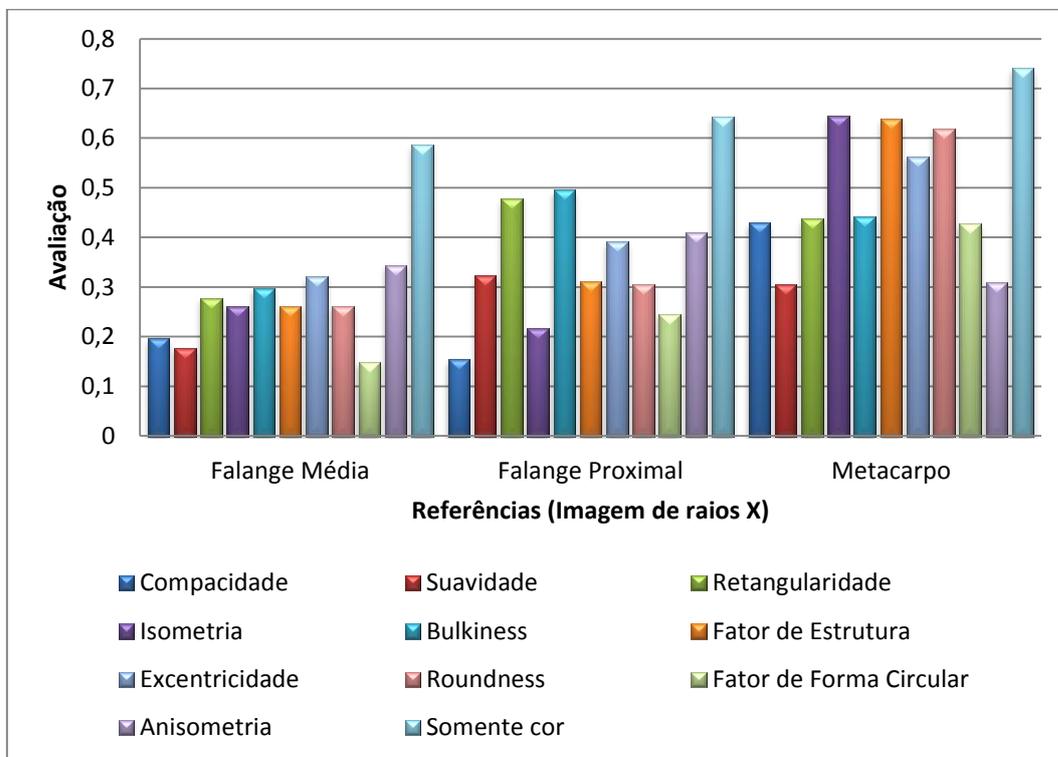


Figura 4.16: Comparação entre as avaliações das segmentações com um único atributo de forma e as com apenas a cor para as referências da imagem de raios X.

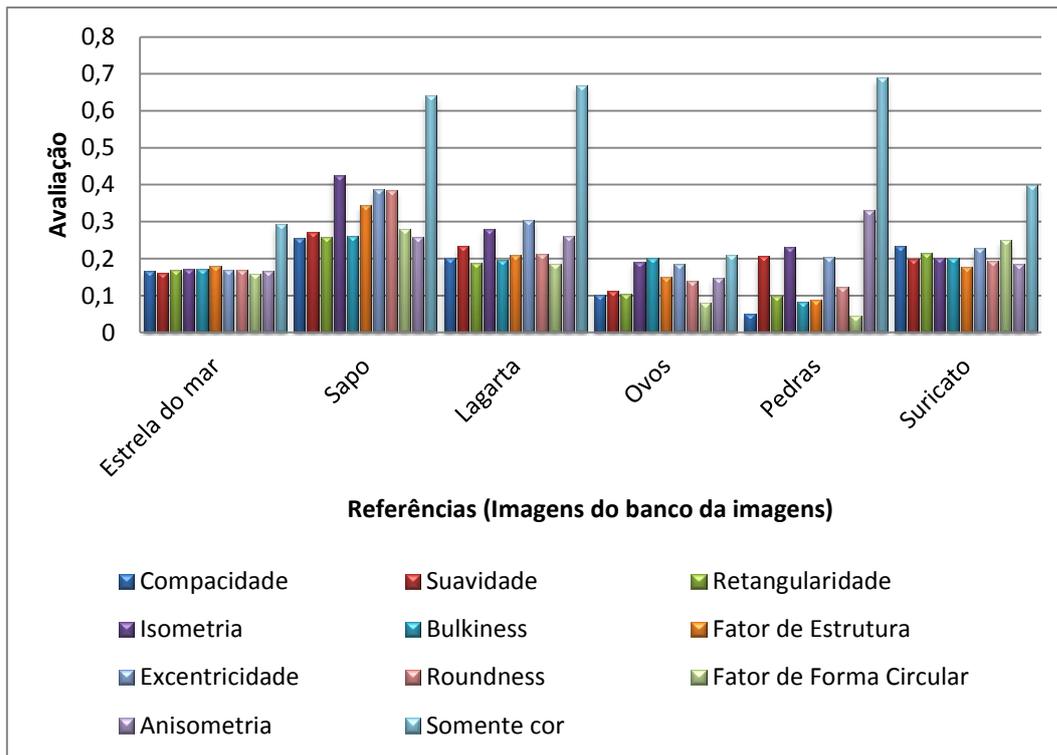


Figura 4.17: Comparação entre as avaliações das segmentações com um único atributo de forma e as com apenas a cor para as referências das imagens do banco de imagens.

Pelos gráficos das Figuras 4.13-4.17 é possível perceber que, para todas as imagens, as avaliações com um atributo de forma foram consistentemente melhores do que a avaliação da segmentação baseada apenas na cor (sem atributo de forma), o que representa uma forte evidência de que os atributos de forma podem desempenhar um papel importante na segmentação. Esta observação fica mais evidente quando analisamos o gráfico da média e desvio-padrão dos experimentos para algumas imagens como mostram as Figuras 4.18-4.22.

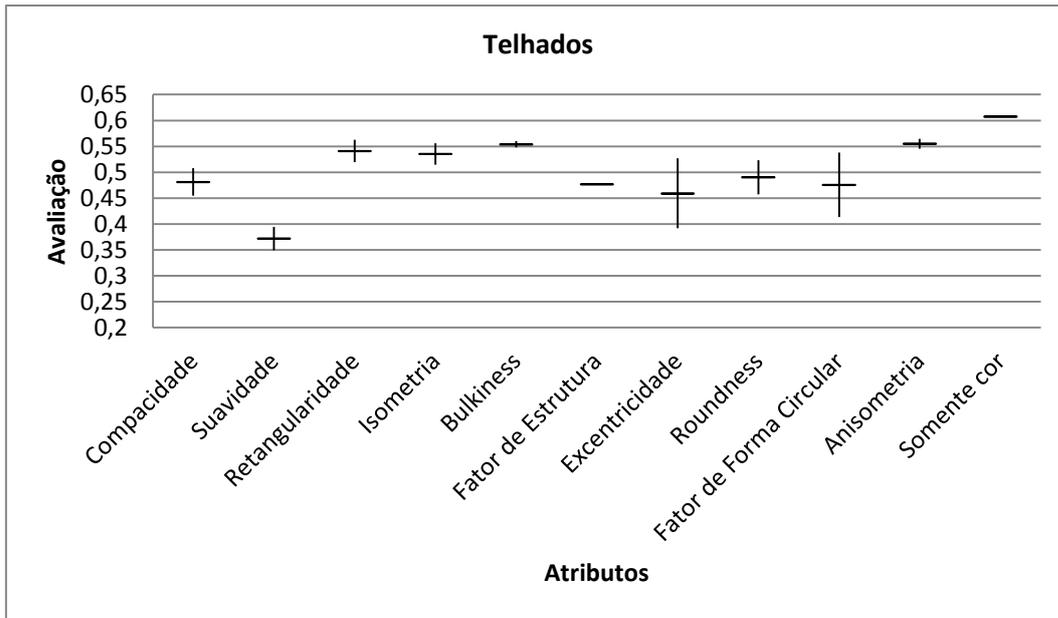


Figura 4.18: Média e desvio-padrão das avaliações para os experimentos da imagem Telhados.

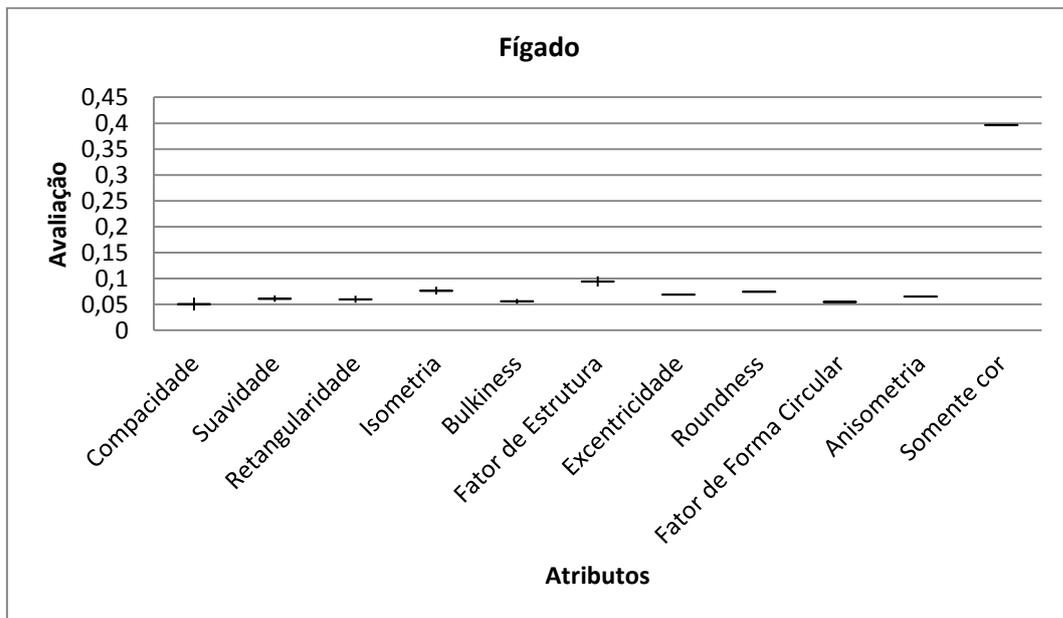


Figura 4.19: Média e desvio-padrão das avaliações para os experimentos da imagem Fígado.

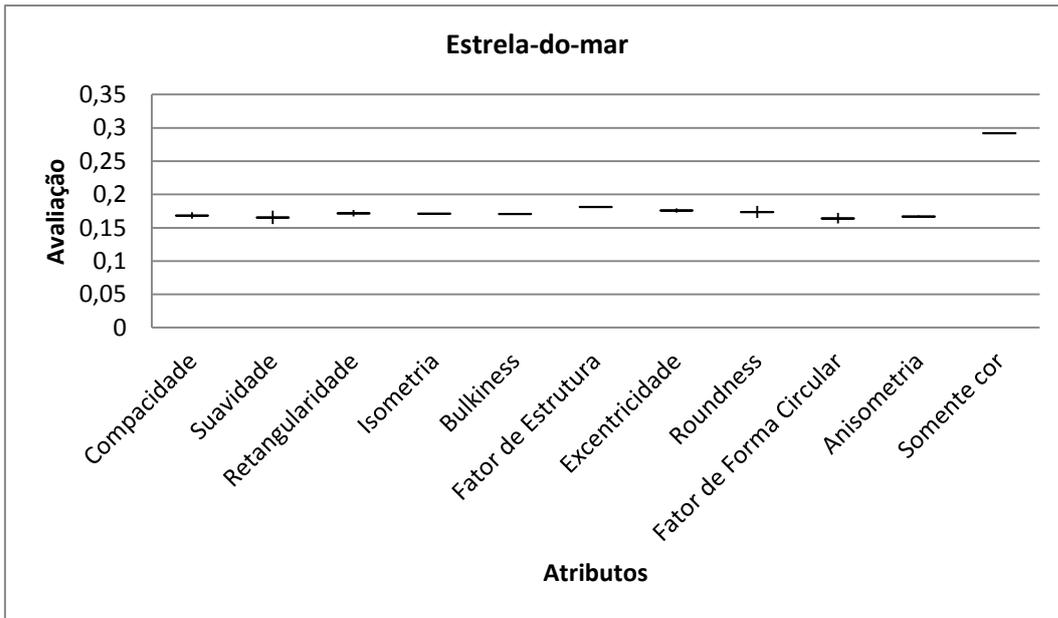


Figura 4.20: Média e desvio-padrão das avaliações para os experimentos da imagem Estrela-do-mar.

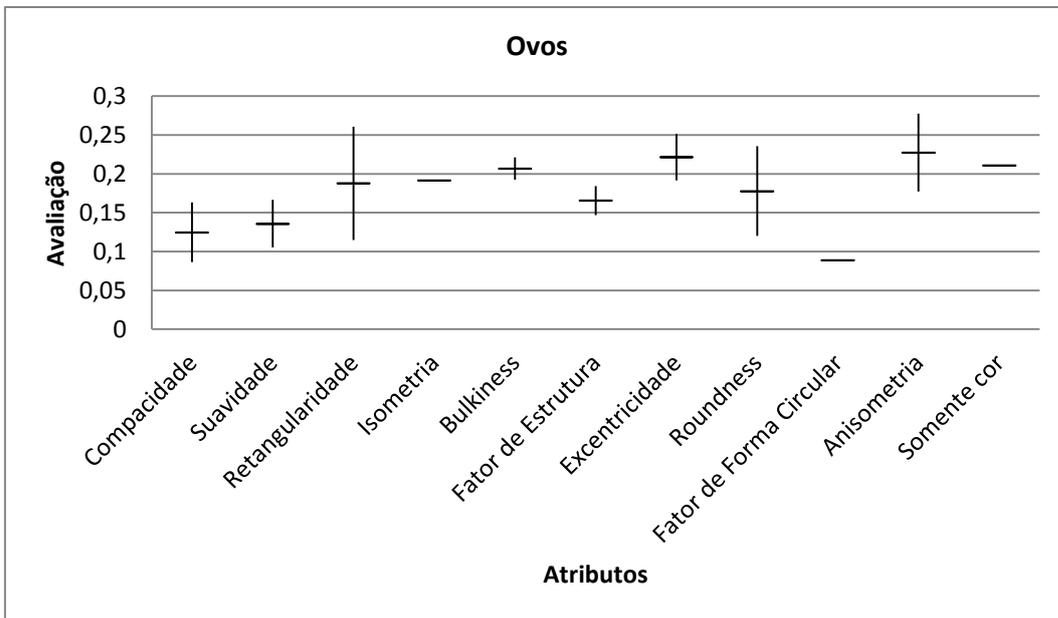


Figura 4.21: Média e desvio-padrão das avaliações para os experimentos da imagem Ovos.

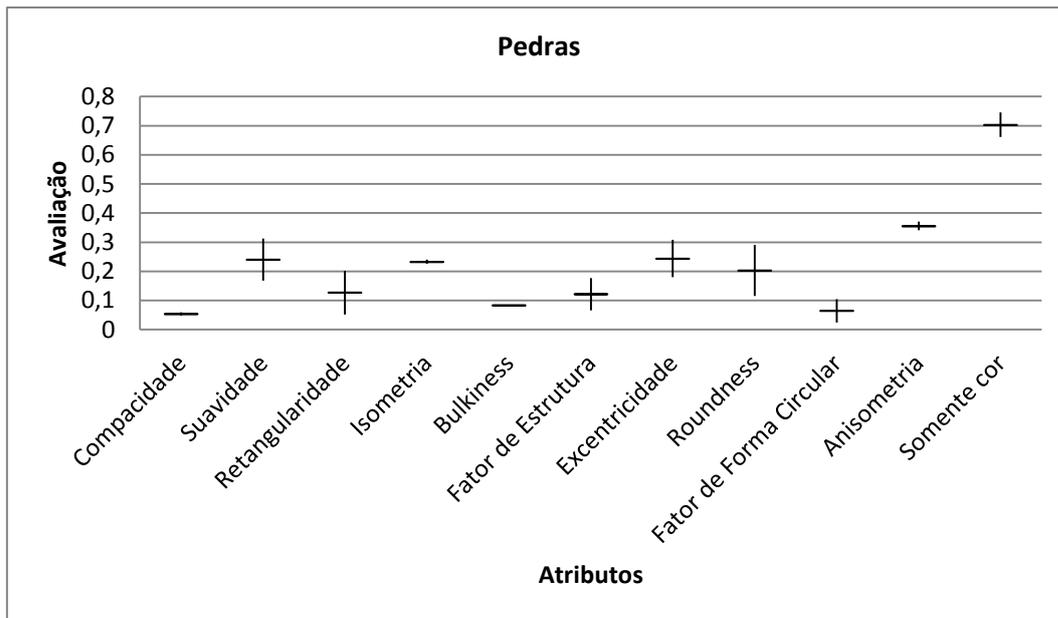


Figura 4.22: Média e desvio-padrão das avaliações para os experimentos da imagem Pedras.

Através desses gráficos podemos observar que a média dos experimentos com atributos de forma é consistentemente menor do que a média dos experimentos da segmentação baseada somente na cor, o que é evidenciado pela separação entre os desvios-padrão no gráfico. Entretanto, para a imagem Ovos há uma grande intercessão entre os desvios-padrão, o que indica a dificuldade de alguns atributos em superar a avaliação obtida pela segmentação baseada na cor para esta imagem.

Ao analisar esses gráficos, também podemos ter uma boa indicação de que, em geral, o otimizador obteve sucesso em estimar bons parâmetros de segmentação, entretanto não se pode afirmar que ele sempre alcança o mínimo global. Nesse contexto, é interessante notar que todas as imagens obtiveram desvios-padrão relativos médios abaixo de 28,5%. E este valor é impulsionado pela imagem Pedras, que teve um desvio-padrão relativo médio de 28,5%. Desconsiderando esta imagem, o maior valor de desvio-padrão relativo médio cai para 15,6%.

O fato de a imagem Pedras ter obtido um desvio-padrão relativo médio mais elevado se deve ao atributo Fator de Forma Circular, que obteve um desvio-padrão relativo de 62%, o que indica a dificuldade do otimizador em alcançar bons valores de parâmetros para este atributo. Entretanto, este atributo foi o que

obteve o maior ganho de desempenho para esta imagem: 93%, como mostra o gráfico da Figura 4.23. Neste caso, é provável que o otimizador tenha ficado preso em algum mínimo local ruim, mas por fim, conseguiu alcançar um ótimo mínimo local/global.

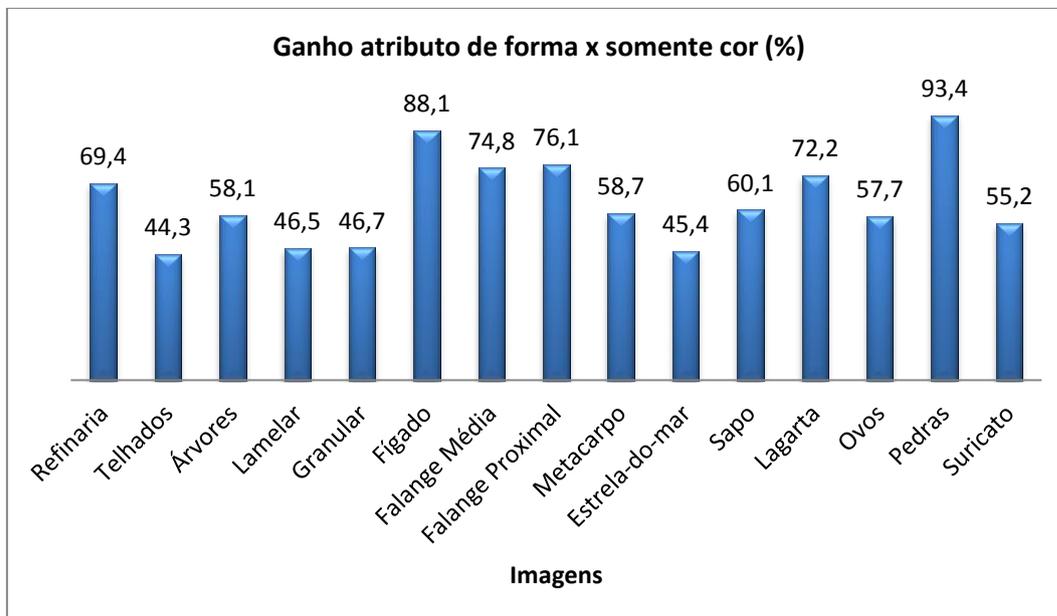


Figura 4.23: Porcentagem de ganho entre o mínimo das avaliações das segmentações com 1 atributo de forma e a baseada somente na cor.

O gráfico da Figura 4.23 também nos permite ter uma boa noção das imagens em que a introdução do atributo de forma teve maior impacto na avaliação da segmentação. As imagens Pedras e Fígado são as que apresentaram o maior percentual de ganho, tendo respectivamente 93,4% e 88,1%. As duas que tiveram o menor percentual são Estrela-do-mar e Telhados, com 45,4% e 44,3% respectivamente.



(a)



(b)

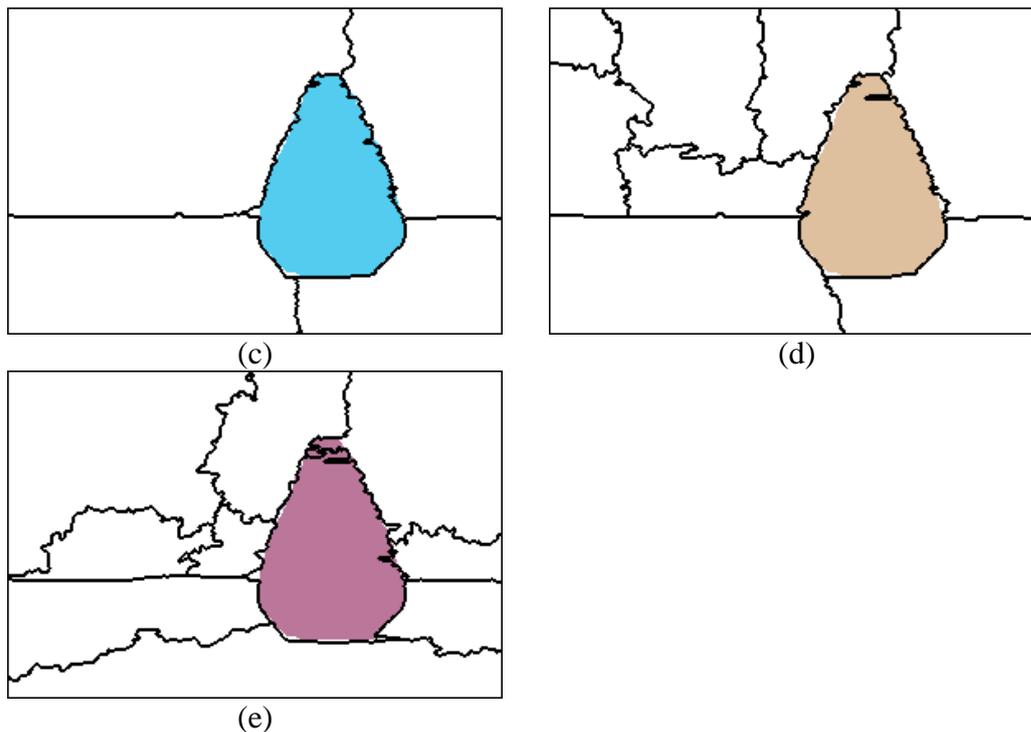


Figura 4.24: (a) Imagem original e (b) segmentação baseada apenas na cor. As imagens (c), (d) e (e) apresentam as segmentações com os três atributos de forma que obtiveram melhor desempenho: Fator de Forma Circular, Compacidade e Bulkiness.

A imagem Pedras tem como referência a escultura de pedras localizada na região central da imagem. A área da imagem coberta pela referência é altamente texturizada, com variações bruscas de iluminação, o que dificulta um bom delineamento da referência através de uma segmentação baseada somente na cor.

Pode-se verificar pela Figura 4.24 (b) que na segmentação baseada na cor a área da referência foi supersegmentada e que os segmentos resultantes em geral tentam delinear as variações de iluminação presentes. O contorno do objeto, entretanto, está razoavelmente bem definido, sendo a segmentação da imagem, como um todo, bastante irregular e ramificada.

Nesta figura estão também dispostas as imagens segmentadas com os três atributos de forma que obtiveram melhor desempenho. A segmentação com o atributo Fator de Forma Circular, mostrada na Figura 4.24 (c) foi a que obteve a melhor avaliação, com um ganho de 93,4%. Esta segmentação é sensivelmente melhor que a anterior, conseguindo delinear muito bem a referência fornecida, a menos de alguns pequenos desvios no contorno do objeto.

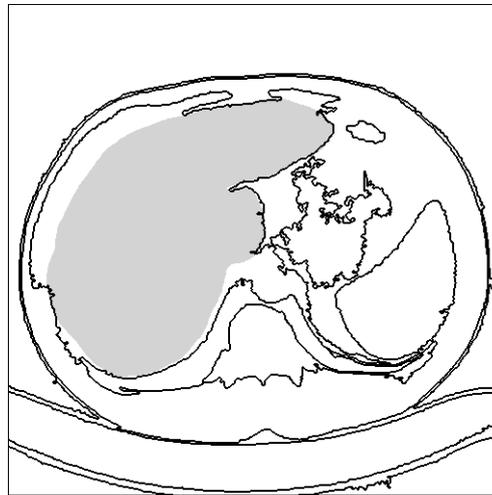
As segmentações que usaram os atributos Compacidade e Bulkiness obtiveram avaliações levemente piores, com ganhos de 92,7% e 87,9% respectivamente. Pode-se perceber que a segmentação passa a não delinear tão bem a referência, possuindo maior número de irregularidades no contorno e algumas partes da referência sendo englobadas por outros objetos.

O resultado é interessante, pois os atributos com melhor avaliação possuem em comum a característica de privilegiarem formas compactas. É possível perceber pelo gráfico da Figura 4.17 que os atributos Fator de Forma Circular, Compacidade, Bulkiness, Fator de Estrutura, Retangularidade e Roundness obtiveram um desempenho destacadamente melhor para esta referência do que os atributos Excentricidade, Suavidade e Isometria.

É de se estranhar talvez que o atributo Suavidade não tenha tido um melhor desempenho, já que também privilegia formas compactas. Acontece que ele penaliza bastante as formas com bordas muito franjadas (não suaves), ainda que sejam compactas, exatamente o caso desta imagem. De qualquer forma, todos os atributos de forma obtiveram ganhos superiores a 66,6%.



(a)



(b)

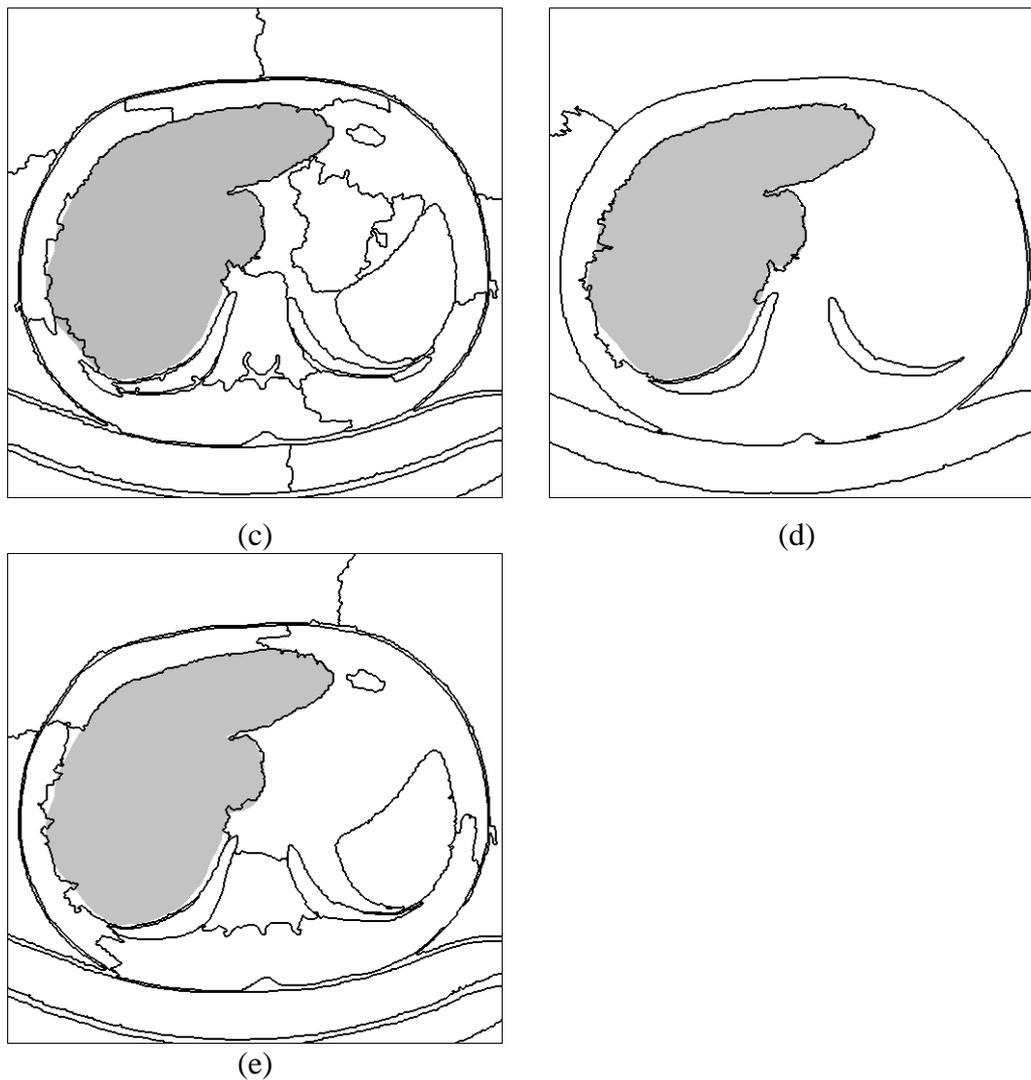


Figura 4.25: (a) Imagem original e (b) segmentação baseada apenas na cor. As imagens (c), (d) e (e) apresentam as segmentações com os três atributos de forma que obtiveram melhor desempenho: Compacidade, Bulkiness e Fator de Forma Circular.

A imagem Fígado é uma fatia de um exame de tomografia computadorizada do tórax e tem como referência o órgão fígado localizado à esquerda da imagem. Apesar da região da imagem coberta pela referência possuir pouco contraste, apresentando muitas áreas com tons de cinza parecidos, a segmentação baseada apenas na cor, mostrada na Figura 4.25 (b), obteve um resultado até razoável. Porém, é possível perceber uma subsegmentação já que o objeto que envolve o fígado também envolve algumas outras estruturas adjacentes, como a caixa torácica.

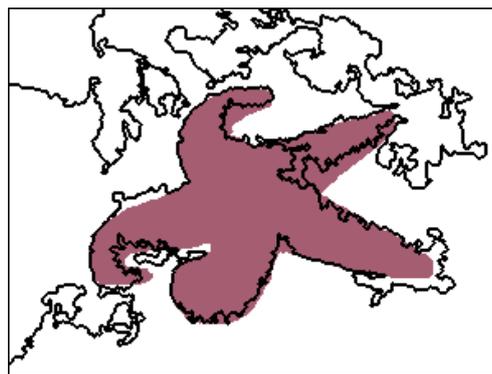
Na Figura 4.25 (a), é apresentada a segmentação obtida com o atributo Compacidade, o qual obteve a melhor avaliação, com um ganho de 88,1%. A segmentação consegue delinear muito bem a referência, a menos de alguns pequenos desvios e irregularidades no contorno do objeto.

As outras duas segmentações que usaram os atributos Bulkiness e Fator de Forma Circular obtiveram avaliações levemente piores, com ganhos de 87,4% e 86,4%, respectivamente. Pode-se observar que o contorno do objeto passa a se desviar um pouco mais da referência e também apresenta maiores irregularidades.

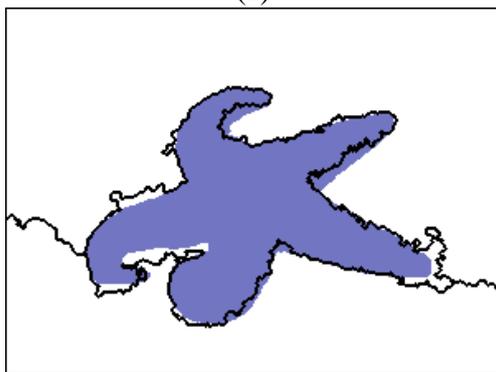
A referência possui uma forma razoavelmente compacta e é possível perceber pelo gráfico da Figura 4.15 que todos os atributos de forma obtiveram um desempenho bem semelhante. De fato, todos os atributos apresentaram ganhos acima de 78%.



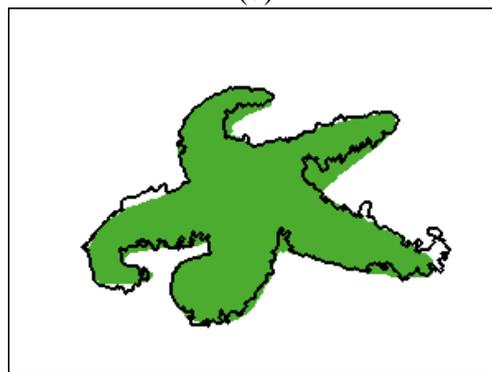
(a)



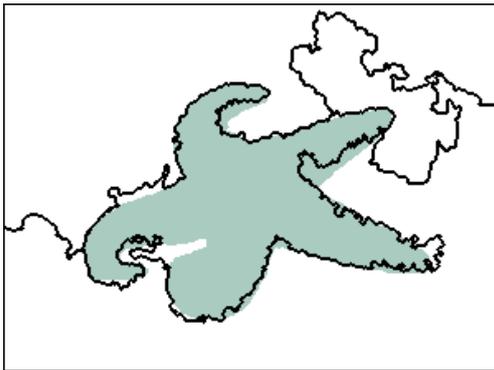
(b)



(c)



(d)



(e)

Figura 4.26: (a) Imagem original e (b) segmentação baseada apenas na cor. As imagens (c), (d) e (e) apresentam as segmentações com os três atributos de forma que obtiveram melhor desempenho: Fator de Forma Circular, Suavidade e Compacidade.

A imagem Estrela-do-mar possui uma referência de um elemento de mesmo nome na região central da imagem. Apesar da região da imagem coberta pela referência possuir uma característica texturizada, ela não possui muitas variações de iluminação, com exceção das poucas áreas de sombra, e se destaca com certa facilidade do fundo. É possível perceber uma protuberância no contorno do objeto próxima à ponta da estrela mais a direita que parece ser devido a uma imprecisão por parte dos analistas na hora da definição da referência.

Pode-se verificar pela Figura 4.26 (b) que, na segmentação baseada apenas na cor, a área da referência se encontra supersegmentada, com desvios acentuados no contorno do objeto. A segmentação apresenta muitas irregularidades e ramificações.

A segmentação obtida com o atributo Fator de Forma Circular, mostrada na Figura 4.26 (c), foi a que obteve a melhor avaliação, com um ganho de 45,4%. A segmentação é sensivelmente melhor que a anterior, apresentando um contorno de objeto que delinea com mais exatidão a referência fornecida e que possui menos irregularidades, ainda que essas ainda estejam presentes.

A segmentação obtida com o atributo Suavidade, mostrada na Figura 4.26 (d), obteve a segunda melhor avaliação, com um ganho de desempenho de 44,9%. A segmentação conseguiu destacar o objeto de interesse do fundo, dando uma impressão de melhor qualidade, entretanto possui um número maior de irregularidades no contorno, o que parece ter contrabalanceado o menor desvio do

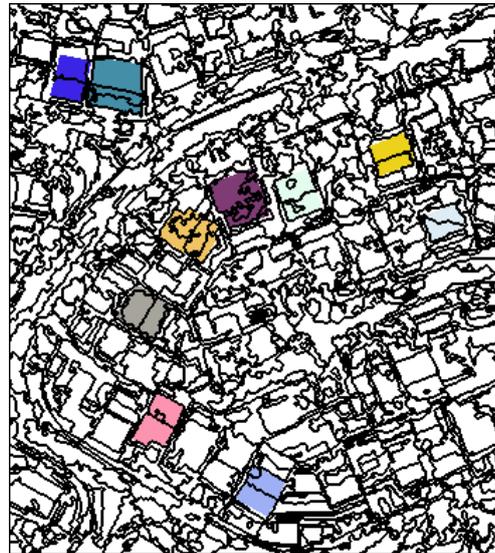
contorno em relação à referência. Além disso, algumas áreas da referência foram englobadas pelo fundo.

A segmentação obtida com o terceiro atributo Compacidade, que obteve um ganho de 43%, está apresentada na Figura 4.26 (e). Claramente, o motivo da pior nota está no maior desvio do contorno que passou a envolver uma maior área do fundo da imagem na área próxima à ponta inferior da estrela.

Fica claro que nenhum dos atributos privilegia um objeto de forma tão irregular (não compacta). Este é um dos principais motivos para, nesta imagem, os atributos de forma terem obtido um desempenho inferior. A Figura 4.17 evidencia esta inadequação comum ao apresentar um desempenho bem semelhante para todos os atributos. Entretanto, este resultado, que num primeiro momento pode não parecer bom, acaba por fortalecer o argumento deste trabalho ao passo que evidencia que mesmo atributos de forma tão inadequados a certo tipo de classe de objetos, podem ter um ganho razoável em relação a segmentação baseada apenas na cor. De fato, em todos os atributos os ganhos foram superiores a 38,1%.



(a)



(b)

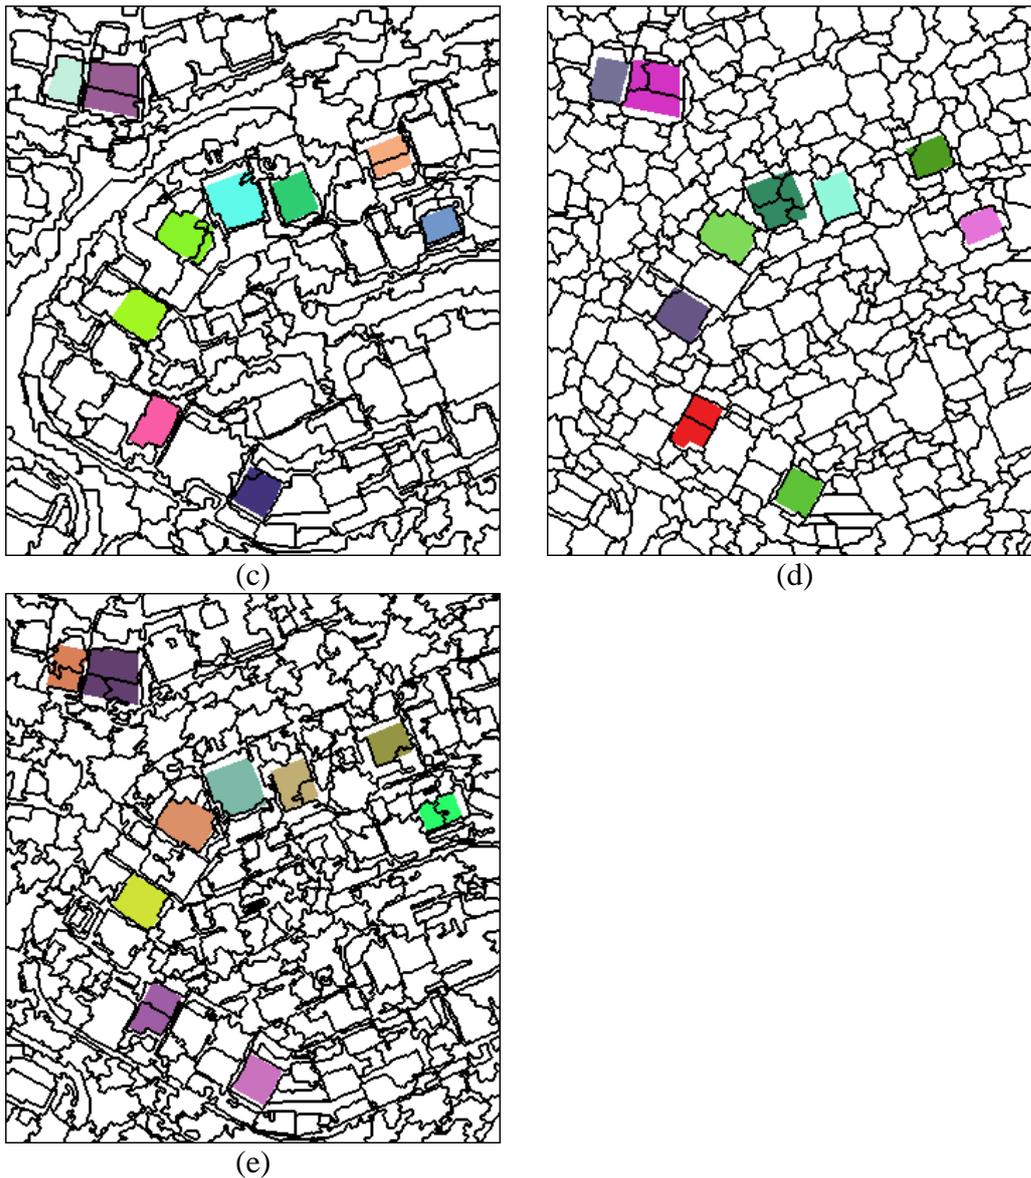


Figura 4.27: (a) Imagem original e (b) segmentação baseada apenas na cor. As imagens (c), (d) e (e) apresentam as segmentações com os três atributos de forma que obtiveram melhor desempenho: Suavidade, Fator de Forma Circular e Excentricidade.

A figura Telhados possui um conjunto de 10 referências de telhados cerâmicos delineadas. A textura, ainda que suave, e a variação de iluminação causada pela reflexão da luz nas diferentes inclinações das águas do telhado dificultam um bom delineamento das referências através de uma segmentação baseada apenas na cor.

A Figura 4.27 (b) evidencia essa dificuldade, apresentando o resultado da segmentação sem atributos de forma. É possível perceber uma supersegmentação,

tanto devido à divisão provocada pela cumeeira dos telhados em algumas referências quanto à variação de iluminação e textura em outras. Além disso, o contorno dos objetos apresentam muitas irregularidades e ramificações.

A Figura 4.27 (c) apresenta a segmentação obtida com o atributo Suavidade, que obteve a melhor avaliação, com um ganho de desempenho de 44,3%. Nesta segmentação, algumas referências continuam sendo divididas em dois objetos na cumeeira do telhado. Os contornos dos objetos se mostram mais coerentes com as referências fornecidas e possuem menos irregularidades, entretanto, alguns objetos aparecem englobando áreas adjacentes aos telhados, que possuem uma característica espectral semelhante.

A segmentação obtida com o atributo Fator de Forma Circular, mostrada na Figura 4.27 (d) obteve a segunda melhor avaliação, com um desempenho de 32,4%. Esta segmentação apresenta contornos ainda menos irregulares, porém supersegmenta algumas referências. É possível observar ainda mais objetos englobando regiões adjacentes às referências.

A Figura 4.27 (e) apresenta a segmentação obtida com o atributo Excentricidade, que obteve a terceira melhor avaliação, com um desempenho de 28%. Esta segmentação volta a apresentar objetos com contornos irregulares, que já lembram os objetos produzidos pela segmentação baseada apenas na cor. Há supersegmentação em algumas referências e alguns objetos engolem regiões adjacentes às referências.

É possível perceber pelo gráfico da Figura 4.13 que o atributo Suavidade obteve um desempenho destacadamente melhor para estas referências do que os outros atributos, embora todos os atributos tenham apresentado um desempenho apenas razoável para esta imagem. O resultado é interessante, pois o atributo Suavidade privilegia objetos que tenham contornos suaves, como é o caso de retângulos e quadrados. De fato, os ganhos de todos os atributos ficaram abaixo de 39%.

Estes resultados indicam que o motivo dos atributos de forma terem obtido um desempenho inferior nesta imagem se deve às características intrínsecas dos objetos-alvo. Baatz argumenta em seu artigo (Baatz00) que sem a informação espectral não há objetos significativos sobre os quais a forma possa ser otimizada. No contexto desta análise, é possível perceber que os atributos de forma não

foram capazes de obter um desempenho melhor pois a dificuldade principal de produzir objetos coerentes com as referências está no campo espectral.

Figuras com as segmentações das outras imagens, como as utilizadas nesta análise, podem ser encontradas no Apêndice A.

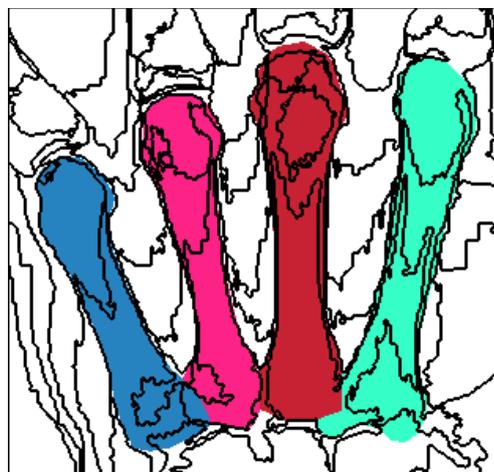
A análise visual desses resultados vem corroborar com os resultados apresentados nas Figuras 4.13-4.17. As segmentações com atributos de forma se mostram mais convincentes quando comparadas visualmente com as referências, mesmo para aquelas imagens em que o ganho foi mínimo. Em geral, essas segmentações produziram contornos menos irregulares, menos ramificados e mais próximos dos contornos das referências. Para as imagens onde as segmentações espectrais supersegmentaram as referências, as segmentações com os atributos de forma minimizaram bastante este efeito, quando não o removeram.

Quando se trata da comparação dos atributos de forma entre si, foi possível perceber que para algumas imagens eles obtiveram desempenhos muito próximos, sendo igualmente bons ou inadequados para delinear as referências fornecidas. Entretanto, para outras imagens alguns atributos se mostraram destacadamente mais adequados para delinear as referências do que outros.

Pode-se destacar o desempenho do atributo Suavidade na análise da imagem Telhados, que apesar da dificuldade apresentada pela classe de objetos em si, apresentou um ganho superior ao dos outros atributos. Neste sentido, também cabe destacar o desempenho dos atributos Suavidade e Anisometria para a referência Metacarpo da imagem Raios X:



(a)



(b)

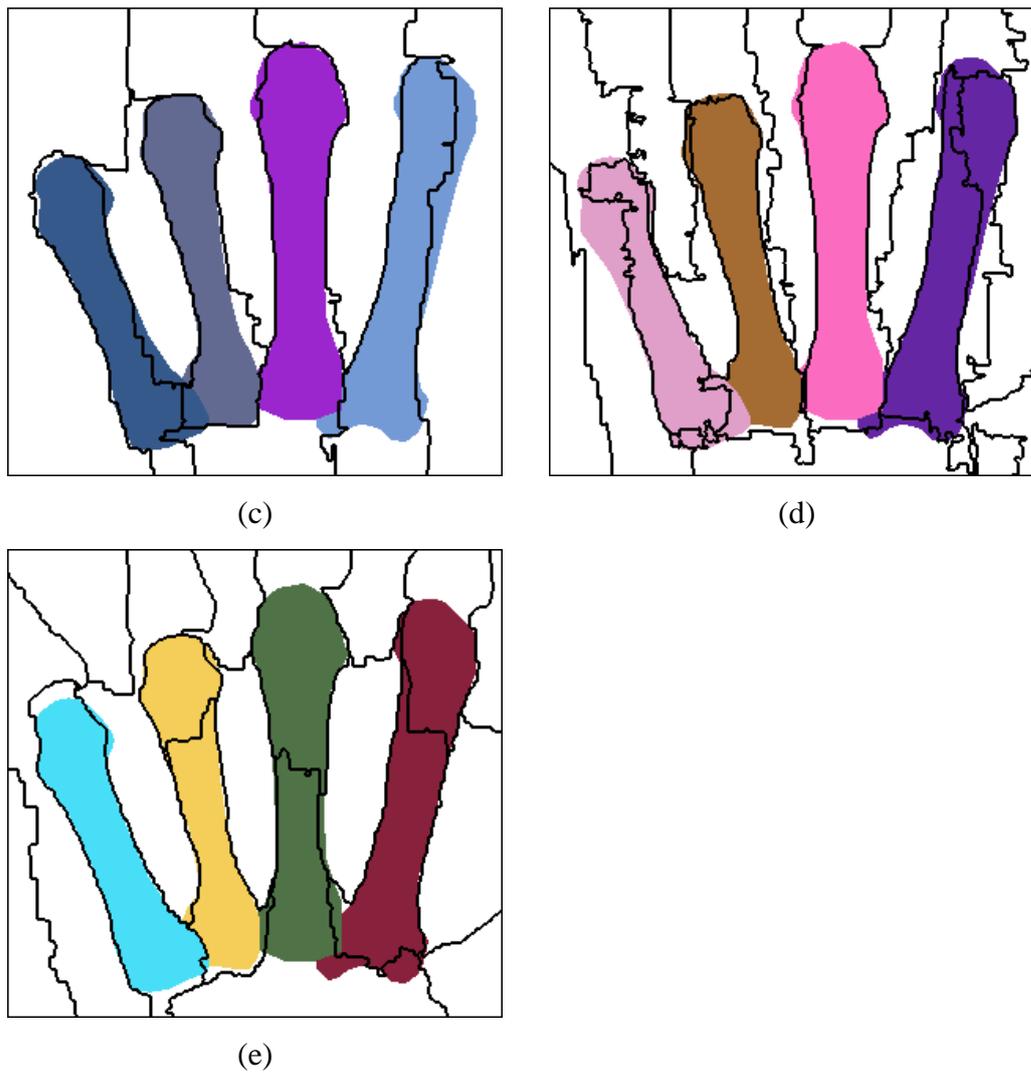


Figura 4.28: (a) Imagem original e (b) segmentação baseada apenas na cor. As imagens (c), (d) e (e) apresentam as segmentações com os três atributos de forma que obtiveram melhor desempenho: Suavidade, Anisometria e Fator de Forma Circular.

Pelo gráfico da Figura 4.16, é possível perceber que, na referência Metacarpo da Imagem Raios X, o desempenho dos atributos Suavidade e Anisometria sobressaem-se aos dos outros atributos. Como mostrado na Figura 4.28 (b), a segmentação baseada apenas na cor apresenta muitas irregularidades no contorno devido à variação na iluminação presente nos objetos alvo. Os contornos dos objetos produzidos pela segmentação se desviam bastante das referências apresentando uma segmentação supersegmentada.

A segmentação obtida com os atributos Suavidade e Anisometria produziram as melhores segmentações, com 58,7% e 58,2% de ganho em relação à segmentação baseada apenas na cor. Na segmentação com o atributo Suavidade (Figura 4.28 (c)) é possível ver que as irregularidades no contorno são mínimas e os objetos delinham bem as referências, ainda que os objetos que envolvem as duas referências mais à direita também estejam também envolvendo regiões adjacentes às referências.

Na segmentação realizada com o atributo Anisometria (Figura 4.28 (d)), o resultado é um pouco pior, com desvios no contorno mais acentuados e um pouco mais de irregularidades, mais ainda assim esta segmentação consegue delinear razoavelmente as referências.

A quarta segmentação (Figura 4.28 (e)) foi produzida pelo terceiro melhor atributo, Fator de Forma Circular, com ganho de 42,3%. É possível perceber que nesta segmentação os contornos são menos irregulares e se desviam menos dos contornos das referências, entretanto alguns objetos envolvem áreas adjacentes às referências. A avaliação desta segmentação se distancia das outras, principalmente, porque há uma supersegmentação das referências, com pelo menos três delas sendo divididas entre dois objetos.

O resultado mostra que os atributos Suavidade e Anisometria obtiveram desempenhos sensivelmente melhores do que os outros atributos, conseguindo delinear razoavelmente bem as referências fornecidas. O resultado é interessante, ao passo que o atributo Suavidade busca objetos com bordas suaves, mas não faz restrição ao alongamento do objeto e o atributo Anisometria privilegia objetos alongados. Como quase todos os outros atributos privilegiam formas isométricas, esses dois atributos claramente são os mais indicados quando se tratam de referências alongadas.

Para as referências da imagem Árvores e da imagem Refinaria, que são bem próximas de círculos, pode-se perceber que os atributos Compacidade e Fator de Forma Circular se mostraram os mais adequados nos experimentos realizados (Figura 4.13), um resultante interessante já que esses atributos privilegiam justamente formas circulares e compactas. Para essas mesmas referências, o atributo Suavidade é destacadamente o que obteve pior desempenho, pois penaliza as formas com bordas franjadas (não suaves) que é exatamente a característica das bordas das formas circulares em imagens digitais.

4.2.5. Segmentação com Dois Atributos de Forma

Na terceira etapa, dois atributos de forma foram utilizados nas segmentações. Com isso, três parâmetros foram estimados: o parâmetro de escala p_e , o peso forma/cor w_{forma} e o peso de um atributo de forma w_s . O peso do outro atributo foi calculado como $1 - w_s$, de forma que os dois somassem 1. Novamente, os pesos das bandas foram fixados em um.

O objetivo desta etapa consistiu em verificar que par de atributos apresentava melhor desempenho para cada imagem e classe de objetos alvo. Entretanto, a verificação de todas as combinações de atributos, multiplicada pelo número de experimentos e o número de imagens tornou esta abordagem impossível dentro do tempo disponível, já que a segmentação é um processo computacionalmente custoso. Desta forma, optou-se por uma abordagem sub-ótima, onde se fixou um atributo como sendo o atributo que obteve o melhor desempenho na etapa anterior, e este atributo então foi avaliado com os outros atributos em pares.

Novamente, foram realizados 10 experimentos, onde o mínimo (melhor avaliação) foi tomado. Os resultados comparados com os resultados da segunda etapa (seção anterior) são mostrados nas Figuras 4.29-4.33.

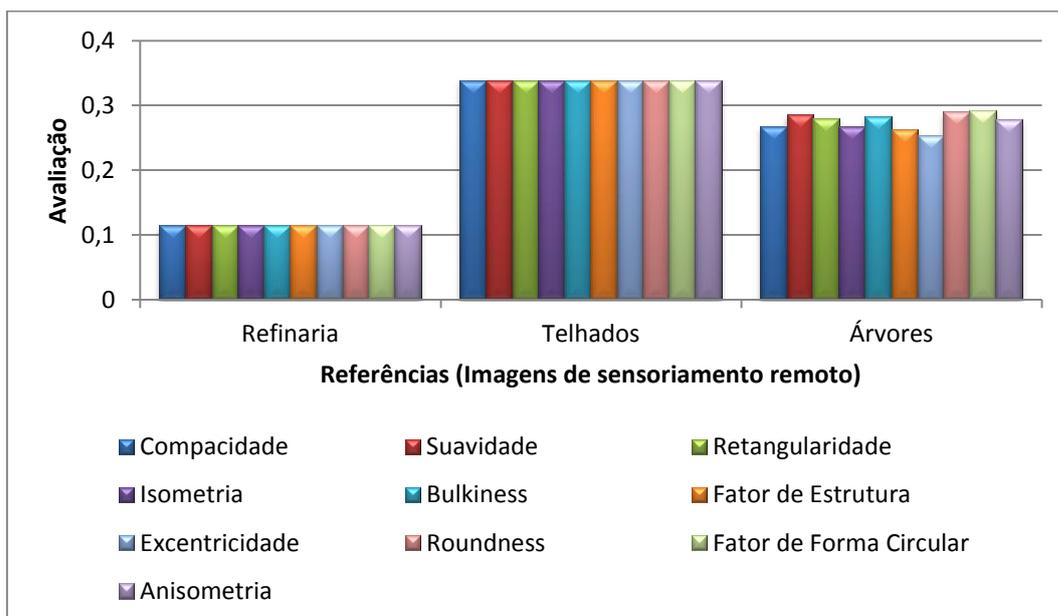


Figura 4.29: Comparação entre as avaliações das segmentações obtidas com um e com dois atributos de forma para as referências das imagens de sensoriamento remoto.

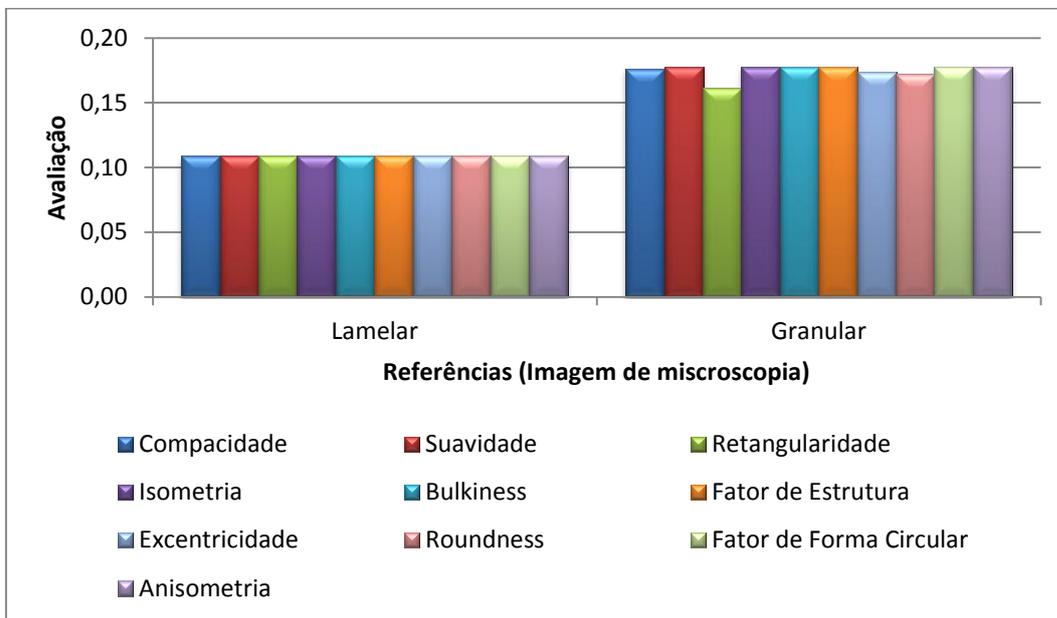


Figura 4.30: Comparação entre as avaliações das segmentações obtidas com um e com dois atributos de forma para as referências da imagem de microscopia.

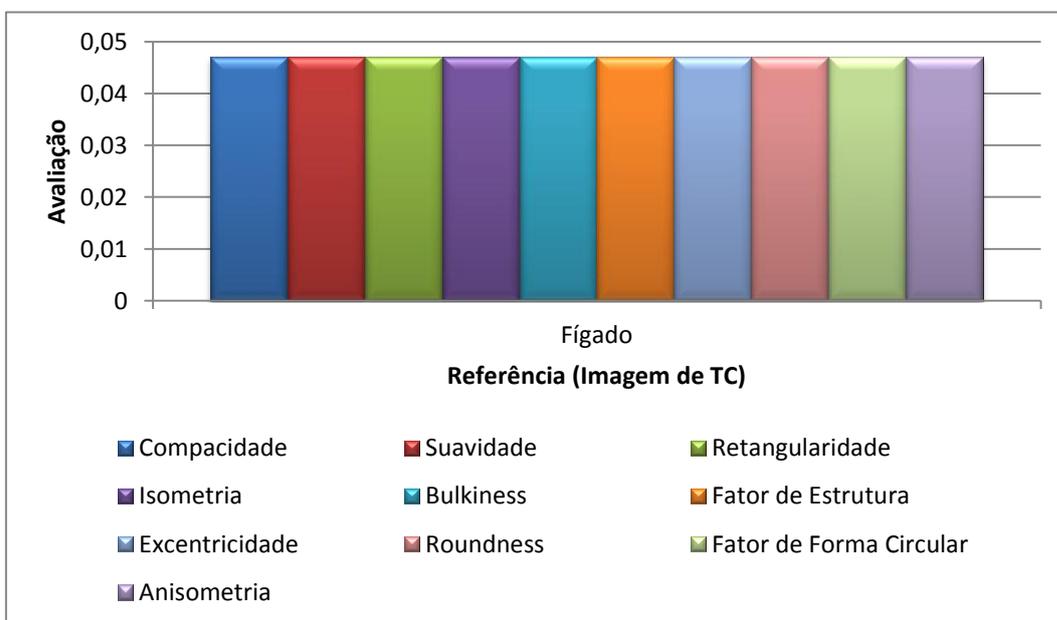


Figura 4.31: Comparação entre as avaliações das segmentações obtidas com um e com dois atributos de forma para a referência da imagem de TC.

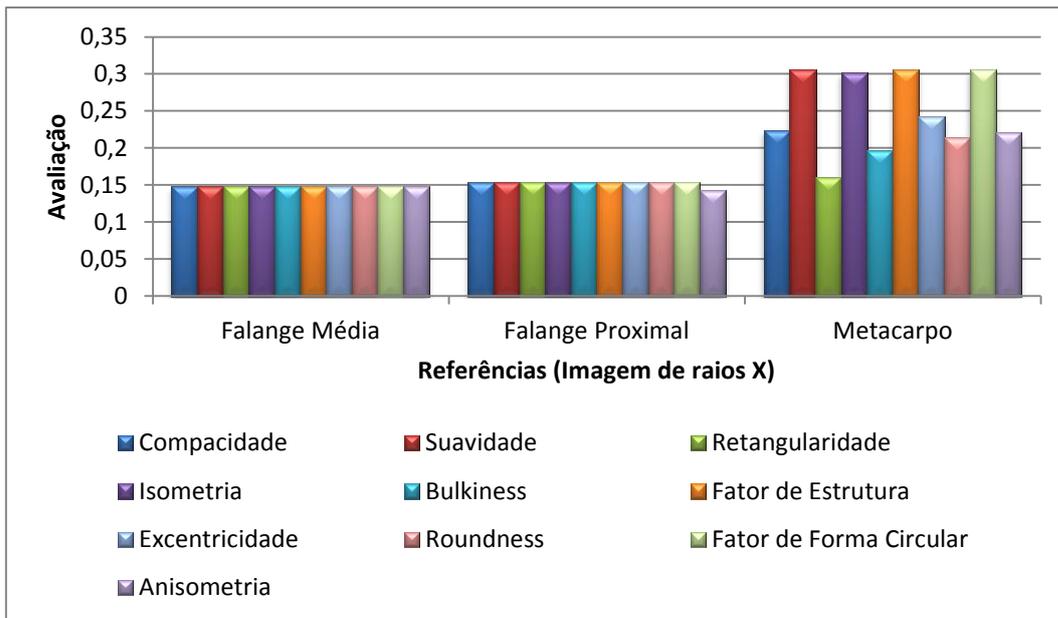


Figura 4.32: Comparação entre as avaliações das segmentações obtidas com um e com dois atributos de forma para as referências da imagem de raios X.

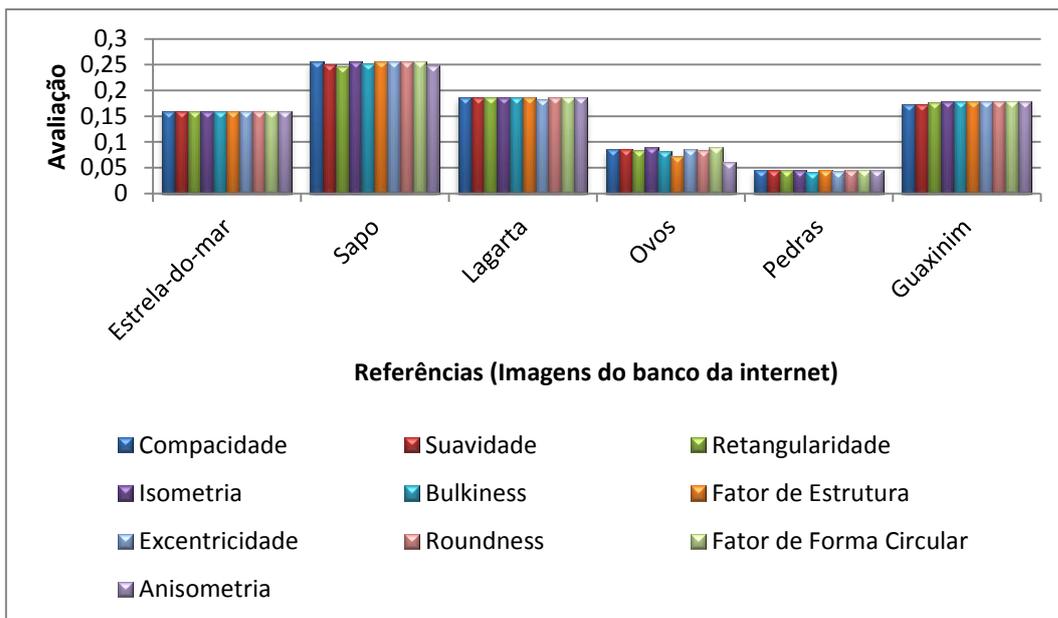


Figura 4.33: Comparação entre as avaliações das segmentações obtidas com um e com dois atributos de forma para as referências das imagens do banco de imagens.

Pode-se perceber pelos gráficos nas Figuras 4.29-4.33 que para algumas imagens nenhuma das combinações de atributos conseguiu melhorar o desempenho obtido com apenas um atributo de forma. Nestes casos, o otimizador zerou o peso do segundo atributo levando a segmentações iguais às da etapa anterior. Nessas imagens o gráfico apresenta todas as barras com a mesma altura.

Entretanto, para algumas imagens, a combinação com um segundo atributo levou, de fato, a melhores avaliações.

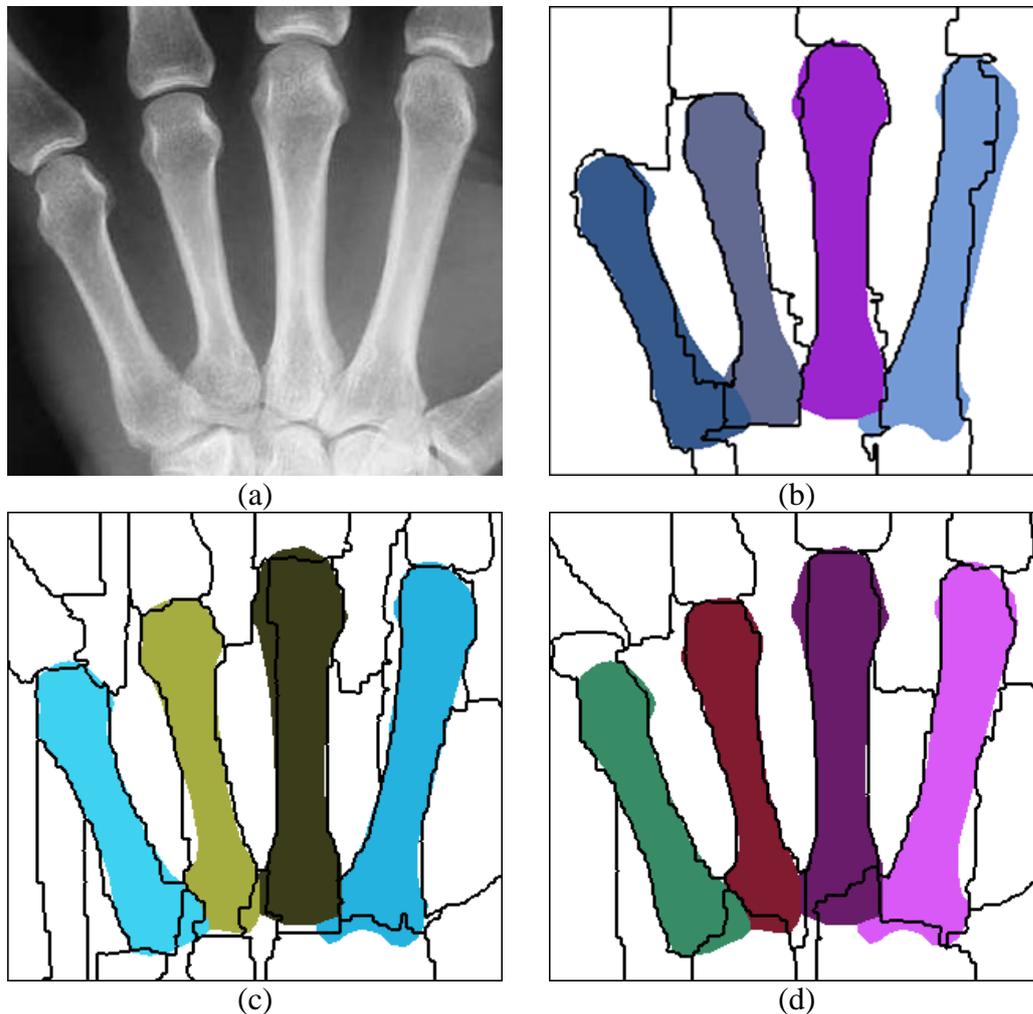


Figura 4.34: (a) Imagem original e (b) segmentação com o melhor atributo de forma da etapa anterior. (c) e (d) apresentam as segmentações com os dois atributos de forma de melhor desempenho na combinação com o atributo Suavidade: Retangularidade e Bulkiness.

O gráfico da Figura 4.32 mostra que, para a referência Metacarpo da imagem Raios X, a combinação do atributo Retangularidade com o atributo Suavidade, melhor atributo da etapa anterior, foi a que obteve o melhor desempenho com um ganho de 47,6% em relação à segmentação com apenas um atributo de forma. A Figura 4.34 (b) mostra a melhor segmentação obtida na etapa anterior com o atributo Suavidade.

A Figura 4.34 (c) mostra a segmentação obtida com a combinação do atributo Suavidade com o atributo Retangularidade. A segmentação obtida é visivelmente melhor, os contornos são menos irregulares e se desviam menos do contorno das referências. É possível observar que os objetos que antes envolviam outras regiões da imagem agora estão bem justos com a referência.

A segunda melhor combinação foi com o atributo Bulkiness (Figura 4.34 (d)), cuja segmentação obteve um ganho de 35,5% em relação à segmentação com apenas um atributo de forma. Esta segmentação também é visualmente muito boa, entretanto dois objetos aparecem envolvendo regiões adjacentes à referência.

É interessante notar que além dos três atributos que obtiveram as melhores avaliações para esta referência, na etapa anterior, o atributo Retangularidade é o único atributo que também não faz restrições ao alongamento do objeto. Ele se preocupa principalmente com concavidades no objeto, privilegiando objetos próximos de quadrados ou retângulos. Esta característica faz com que ele também seja indicado em caso de objetos alongados que possuam formas desse tipo.