

**UNIVERSIDADE FEDERAL DE SANTA CATARINA
DEPARTAMENTO DE INFORMÁTICA E ESTATÍSTICA**

Luís Eduardo Ramos de Carvalho

**APLICAÇÃO DE UMA MÉTRICA DE SIMILARIDADE NÃO
LINEAR EM ALGORITMOS DE SEGMENTAÇÃO**

Florianópolis

2015

RESUMO

Um dos principais processos utilizados no campo de processamento digital de imagens é a segmentação, processo no qual a imagem é separada em seus elementos ou partes constituintes. Na literatura, existem diferentes e bem conhecidos métodos usados para segmentação, tais como clusterização, limiarização, segmentação com redes neurais e segmentação por crescimento de regiões. No intuito de melhorar o desempenho dos algoritmos de segmentação, um estudo sobre o efeito da aplicação de uma métrica não linear em algoritmos de segmentação foi realizado neste trabalho. Foram selecionados três algoritmos de segmentação (Mumford-Shah, Color Structure Code e Felzenszwalb and Huttenlocher) provenientes do método de crescimento de regiões e nestes se alterou a parte de análise de similaridade utilizando para tal uma métrica não linear. A métrica não linear utilizada, denominada Polinomial Mahalanobis, é uma variação da distância de Mahalanobis utilizada para medir a distância estatística entre distribuições. Uma avaliação qualitativa e uma análise empírica foram realizadas neste trabalho para comparar os resultados obtidos em termos de eficácia. Os resultados desta comparação, apresentados neste estudo, apontam uma melhoria nos resultados de segmentação obtidos pela abordagem proposta. Em termos de eficiência, foram analisados os tempos de execução dos algoritmos com e sem o aprimoramento e os resultados, e o resultado desta análise mostrou um aumento do tempo de execução dos algoritmos com abordagem proposta.

Palavras-chave: Segmentação, Métrica não linear, Polinomial Mahalanobis

ABSTRACT

One of the main procedures used on digital image processing is segmentation, where the image is split into its constituent parts or objects. In the literature, there are different well-known methods used for segmentation, such as clustering, thresholding, segmentation using neural network and segmentation using region growing. Aiming to improve the performance of the segmentation algorithms, a study off the effect of the application of a non-linear metric on segmentation algorithms was performed in this work. Three segmentation algorithms were chosen (Mumford-Shah, Color Structure Code, Felzenszwalb and Huttenlocher) originating from region growing techniques, and on those the similarity metric was enhanced with a non-linear metric. The non-linear metric used, known as Polynomial Mahalanobis, is a variation from the statistical Mahalanobis distance used for measure the distance between distributions. A qualitative evaluation and empirical analysis was performed in this work to compare the obtained results in terms of efficacy. The results from these comparison, presented in this study, indicate an improvement on the segmentation result obtained by the proposed approach. In terms of efficiency, the execution time of the algorithms with and without the proposed improvement were analyzed and the result of this analysis showed an increase of the execution time for the algorithms with the proposed approach.

Keywords: Segmentation, non-linear metric, Polynomial Mahalanobis

LISTA DE FIGURAS

Figura 1	Passos fundamentais do processamento digital de imagens (GONZALEZ; WOODS, 2006).....	29
Figura 2	Convenção dos eixos para representação de imagens digitais (GONZALEZ; WOODS, 2006).....	31
Figura 3	Espaços de cor RGB, YIQ, HSV, Lab, CIE.....	31
Figura 4	Distribuição das componentes de cor da imagem no espaço RGB.....	32
Figura 5	Mapas topológicos. Em (a) distância Euclidiana, (b) distância de Mahalanobis e (c-f) Polinomial Mahalanobis de q-ordem $2^{(1,2,3,4)}$, respectivamente. Imagem extraída de (SOBIERANSKI; COMUNELLO; WANGENHEIM, 2011)......	36
Figura 6	Estrutura hierárquica de ilhas hexagonais do CSC mostrando três níveis, parcialmente coloridos para enfatizar vários graus de sobreposição de parte das ilhas.....	39
Figura 7	Ilustração da ligação de ilhas hexagonais do nível 0 para o próximo nível da hierarquia.....	40
Figura 8	Figura mostrando, respectivamente, a imagem original e seu GT.....	46
Figura 9	Ilustração mostrando respectivamente imagem de entrada, padrão selecionado e resultado da execução do WCSC.....	58
Figura 10	Fluxograma do WCSC, ilustrando a função de similaridade utilizada.....	59
Figura 11	Ilustração mostrando respectivamente imagem de entrada, padrão selecionado e resultado da execução do SMS.....	60
Figura 12	Fluxograma do SMS, ilustrando a função de similaridade utilizada.....	61
Figura 13	Ilustração mostrando respectivamente imagem de entrada, padrão selecionado e resultado da execução do WFH.....	62
Figura 14	Fluxograma do WFH, ilustrando a função de similaridade utilizada.....	63
Figura 15	Comparação entre os resultados obtidos com o CSC e o WCSC. (A) Imagem original, (B) Imagem com a linha branca mostrando o padrão selecionado, (C) CSC, (D) CSCW.....	67
Figura 16	Comparação entre os resultados obtidos com o CSC e o WCSC. (A) Imagem original, (B) Imagem com a linha branca mostrando o padrão	

selecionado, (C) CSC, (D) CSCW.	68
Figura 17 Comparação do CSC e WCSC performance. (a) <i>boxplot</i> comparando o índice de dissimilaridade, índice Rand, entre CSC e o WCSC. (b) comparação pareada da sequência de imagens relacionadas com o <i>ground truth</i>	69
Figura 18 Comparação entre os resultados obtidos com o MS e o SMS. (A) Imagem original, (B) Imagem com a linha branca mostrando o padrão selecionado, (C) MS, (D) SMS.	71
Figura 19 Comparação entre os resultados obtidos com o MS e o SMS. (A) Imagem original, (B) Imagem com a linha branca mostrando o padrão selecionado, (C) MS, (D) SMS.	72
Figura 20 Comparação do MS e SMS performance. (a) <i>boxplot</i> comparando o índice de dissimilaridade, índice Rand, entre MS e o SMS. (b) comparação pareada da sequência de imagens relacionadas com o <i>Ground Truth</i>	73
Figura 21 Comparação entre os resultados obtidos com o FH e o WFH. (A) Imagem original, (B) Imagem com a linha branca mostrando o padrão selecionado, (C) FH, (D) WFH.	74
Figura 22 Comparação entre os resultados obtidos com o FH e o WFH. (A) Imagem original, (B) Imagem com a linha branca mostrando o padrão selecionado, (C) FH, (D) WFH.	75
Figura 23 Comparação do FH e WFH performance. (a) <i>boxplot</i> comparando o índice de dissimilaridade, índice Rand, entre FH e o WFH. (b) comparação pareada da sequência de imagens relacionadas com o <i>Ground Truth</i>	76
Figura 24 Índice Rand dos resultados dos métodos de segmentação utilizados na comparação para a imagem 368078.	78
Figura 25 Comparação visual dos resultados obtidos pelos métodos para a imagem 368078. (A) Imagem original, (B) Ground Truth, (C) SMS, (D) WCSC, (E) WFH, (F) CSC+GNM2, (G) MS+GNM2, (H) CSC+GNM, (I) MS+GNM, (J) CSC, (K) MS, (L) FH, (M) EDISON, (N) WS, (O) JSEG, (P) RHSEG.	78
Figura 26 Comparação visual dos resultados obtidos pelos métodos para a imagem 46076. (A) Imagem original, (B) Ground Truth, (C) SMS, (D) WCSC, (E) WFH, (F) CSC+GNM2, (G) MS+GNM2, (H) CSC+GNM, (I) MS+GNM, (J) CSC, (K) MS, (L) FH, (M) EDISON, (N) WS, (O) JSEG, (P) RHSEG.	79
Figura 27 Índice Rand dos resultados dos métodos de segmentação utilizados na comparação para a imagem 46076.	79

Figura 28 Comparação entre vários métodos de segmentação com as abordagens propostas com base no valor de índice Rand.	80
Figura 29 Tempo de execução, em milissegundos, dos algoritmos utilizados. Gráfico representado na escala logarítmica.	81
Figura 30 (A) imagem 2092, (B) padrão selecionado, (C) CSC e (D) WCSC.	97
Figura 31 (A) imagem 3096, (B) padrão selecionado, (C) CSC e (D) WCSC.	97
Figura 32 (A) imagem 12003, (B) padrão selecionado, (C) CSC e (D) WCSC.	97
Figura 33 (A) imagem 15088, (B) padrão selecionado, (C) CSC e (D) WCSC.	98
Figura 34 (A) imagem 16052, (B) padrão selecionado, (C) CSC e (D) WCSC.	98
Figura 35 (A) imagem 22090, (B) padrão selecionado, (C) CSC e (D) WCSC.	98
Figura 36 (A) imagem 24004, (B) padrão selecionado, (C) CSC e (D) WCSC.	98
Figura 37 (A) imagem 24063, (B) padrão selecionado, (C) CSC e (D) WCSC.	99
Figura 38 (A) imagem 35070, (B) padrão selecionado, (C) CSC e (D) WCSC.	99
Figura 39 (A) imagem 42049, (B) padrão selecionado, (C) CSC e (D) WCSC.	99
Figura 40 (A) imagem 46076, (B) padrão selecionado, (C) CSC e (D) WCSC.	99
Figura 41 (A) imagem 48055, (B) padrão selecionado, (C) CSC e (D) WCSC.	100
Figura 42 (A) imagem 60079, (B) padrão selecionado, (C) CSC e (D) WCSC.	100
Figura 43 (A) imagem 61060, (B) padrão selecionado, (C) CSC e (D) WCSC.	100
Figura 44 (A) imagem 62096, (B) padrão selecionado, (C) CSC e (D) WCSC.	100
Figura 45 (A) imagem 66075, (B) padrão selecionado, (C) CSC e (D) WCSC.	101
Figura 46 (A) imagem 67079, (B) padrão selecionado, (C) CSC e (D)	

WCSC.....	101
Figura 47 (A) imagem 68077, (B) padrão selecionado, (C) CSC e (D) WCSC.....	101
Figura 48 (A) imagem 69015, (B) padrão selecionado, (C) CSC e (D) WCSC.....	102
Figura 49 (A) imagem 80099, (B) padrão selecionado, (C) CSC e (D) WCSC.....	102
Figura 50 (A) imagem 94079, (B) padrão selecionado, (C) CSC e (D) WCSC.....	102
Figura 51 (A) imagem 97017, (B) padrão selecionado, (C) CSC e (D) WCSC.....	103
Figura 52 (A) imagem 97033, (B) padrão selecionado, (C) CSC e (D) WCSC.....	103
Figura 53 (A) imagem 100075, (B) padrão selecionado, (C) CSC e (D) WCSC.....	103
Figura 54 (A) imagem 100080, (B) padrão selecionado, (C) CSC e (D) WCSC.....	103
Figura 55 (A) imagem 113009, (B) padrão selecionado, (C) CSC e (D) WCSC.....	104
Figura 56 (A) imagem 113016, (B) padrão selecionado, (C) CSC e (D) WCSC.....	104
Figura 57 (A) imagem 113044, (B) padrão selecionado, (C) CSC e (D) WCSC.....	104
Figura 58 (A) imagem 118035, (B) padrão selecionado, (C) CSC e (D) WCSC.....	104
Figura 59 (A) imagem 124084, (B) padrão selecionado, (C) CSC e (D) WCSC.....	105
Figura 60 (A) imagem 126007, (B) padrão selecionado, (C) CSC e (D) WCSC.....	105
Figura 61 (A) imagem 135069, (B) padrão selecionado, (C) CSC e (D) WCSC.....	105
Figura 62 (A) imagem 143090, (B) padrão selecionado, (C) CSC e (D) WCSC.....	105
Figura 63 (A) imagem 151087, (B) padrão selecionado, (C) CSC e (D) WCSC.....	106
Figura 64 (A) imagem 159091, (B) padrão selecionado, (C) CSC e (D) WCSC.....	106
Figura 65 (A) imagem 161062, (B) padrão selecionado, (C) CSC e (D)	

WCSC.....	106
Figura 66 (A) imagem 163014, (B) padrão selecionado, (C) CSC e (D) WCSC.....	107
Figura 67 (A) imagem 167062, (B) padrão selecionado, (C) CSC e (D) WCSC.....	107
Figura 68 (A) imagem 167083, (B) padrão selecionado, (C) CSC e (D) WCSC.....	107
Figura 69 (A) imagem 183055, (B) padrão selecionado, (C) CSC e (D) WCSC.....	107
Figura 70 (A) imagem 196073, (B) padrão selecionado, (C) CSC e (D) WCSC.....	108
Figura 71 (A) imagem 207056, (B) padrão selecionado, (C) CSC e (D) WCSC.....	108
Figura 72 (A) imagem 208001, (B) padrão selecionado, (C) CSC e (D) WCSC.....	108
Figura 73 (A) imagem 216053, (B) padrão selecionado, (C) CSC e (D) WCSC.....	108
Figura 74 (A) imagem 225017, (B) padrão selecionado, (C) CSC e (D) WCSC.....	109
Figura 75 (A) imagem 227092, (B) padrão selecionado, (C) CSC e (D) WCSC.....	109
Figura 76 (A) imagem 238011, (B) padrão selecionado, (C) CSC e (D) WCSC.....	109
Figura 77 (A) imagem 247085, (B) padrão selecionado, (C) CSC e (D) WCSC.....	109
Figura 78 (A) imagem 249061, (B) padrão selecionado, (C) CSC e (D) WCSC.....	110
Figura 79 (A) imagem 253036, (B) padrão selecionado, (C) CSC e (D) WCSC.....	110
Figura 80 (A) imagem 260058, (B) padrão selecionado, (C) CSC e (D) WCSC.....	110
Figura 81 (A) imagem 291000, (B) padrão selecionado, (C) CSC e (D) WCSC.....	111
Figura 82 (A) imagem 295087, (B) padrão selecionado, (C) CSC e (D) WCSC.....	111
Figura 83 (A) imagem 299091, (B) padrão selecionado, (C) CSC e (D) WCSC.....	111
Figura 84 (A) imagem 300091, (B) padrão selecionado, (C) CSC e (D)	

WCSC.....	112
Figura 85 (A) imagem 304034, (B) padrão selecionado, (C) CSC e (D) WCSC.....	112
Figura 86 (A) imagem 310007, (B) padrão selecionado, (C) CSC e (D) WCSC.....	112
Figura 87 (A) imagem 368078, (B) padrão selecionado, (C) CSC e (D) WCSC.....	112
Figura 88 (A) imagem 374067, (B) padrão selecionado, (C) CSC e (D) WCSC.....	113
Figura 89 (A) imagem 388016, (B) padrão selecionado, (C) CSC e (D) WCSC.....	113
Figura 90 (A) imagem 2092, (B) padrão selecionado, (C) MS e (D) SMS.	114
Figura 91 (A) imagem 3096, (B) padrão selecionado, (C) MS e (D) SMS.	114
Figura 92 (A) imagem 12003, (B) padrão selecionado, (C) MS e (D) SMS.....	114
Figura 93 (A) imagem 15088, (B) padrão selecionado, (C) MS e (D) SMS.....	114
Figura 94 (A) imagem 16052, (B) padrão selecionado, (C) MS e (D) SMS.....	114
Figura 95 (A) imagem 22090, (B) padrão selecionado, (C) MS e (D) SMS.....	115
Figura 96 (A) imagem 24004, (B) padrão selecionado, (C) MS e (D) SMS.....	115
Figura 97 (A) imagem 24063, (B) padrão selecionado, (C) MS e (D) SMS.....	115
Figura 98 (A) imagem 35070, (B) padrão selecionado, (C) MS e (D) SMS.....	115
Figura 99 (A) imagem 42049, (B) padrão selecionado, (C) MS e (D) SMS.....	115
Figura 100(A) imagem 46076, (B) padrão selecionado, (C) MS e (D) SMS.....	116
Figura 101(A) imagem 48055, (B) padrão selecionado, (C) MS e (D) SMS.....	116
Figura 102(A) imagem 60079, (B) padrão selecionado, (C) MS e (D) SMS.....	116
Figura 103(A) imagem 61060, (B) padrão selecionado, (C) MS e (D) SMS.....	116
Figura 104(A) imagem 62096, (B) padrão selecionado, (C) MS e (D)	

SMS.....	117
Figura 105(A) imagem 66075, (B) padrão selecionado, (C) MS e (D) SMS.....	117
Figura 106(A) imagem 67079, (B) padrão selecionado, (C) MS e (D) SMS.....	117
Figura 107(A) imagem 68077, (B) padrão selecionado, (C) MS e (D) SMS.....	117
Figura 108(A) imagem 69015, (B) padrão selecionado, (C) MS e (D) SMS.....	118
Figura 109(A) imagem 80099, (B) padrão selecionado, (C) MS e (D) SMS.....	118
Figura 110(A) imagem 94079, (B) padrão selecionado, (C) MS e (D) SMS.....	118
Figura 111(A) imagem 97017, (B) padrão selecionado, (C) MS e (D) SMS.....	118
Figura 112(A) imagem 97033, (B) padrão selecionado, (C) MS e (D) SMS.....	118
Figura 113(A) imagem 100075, (B) padrão selecionado, (C) MS e (D) SMS.....	119
Figura 114(A) imagem 100080, (B) padrão selecionado, (C) MS e (D) SMS.....	119
Figura 115(A) imagem 113009, (B) padrão selecionado, (C) MS e (D) SMS.....	119
Figura 116(A) imagem 113016, (B) padrão selecionado, (C) MS e (D) SMS.....	119
Figura 117(A) imagem 113044, (B) padrão selecionado, (C) MS e (D) SMS.....	120
Figura 118(A) imagem 118035, (B) padrão selecionado, (C) MS e (D) SMS.....	120
Figura 119(A) imagem 124084, (B) padrão selecionado, (C) MS e (D) SMS.....	120
Figura 120(A) imagem 126007, (B) padrão selecionado, (C) MS e (D) SMS.....	121
Figura 121(A) imagem 135069, (B) padrão selecionado, (C) MS e (D) SMS.....	121
Figura 122(A) imagem 143090, (B) padrão selecionado, (C) MS e (D) SMS.....	121
Figura 123(A) imagem 151087, (B) padrão selecionado, (C) MS e (D)	

SMS.....	121
Figura 124(A) imagem 159091, (B) padrão selecionado, (C) MS e (D) SMS.....	121
Figura 125(A) imagem 161062, (B) padrão selecionado, (C) MS e (D) SMS.....	122
Figura 126(A) imagem 163014, (B) padrão selecionado, (C) MS e (D) SMS.....	122
Figura 127(A) imagem 167062, (B) padrão selecionado, (C) MS e (D) SMS.....	122
Figura 128(A) imagem 167083, (B) padrão selecionado, (C) MS e (D) SMS.....	122
Figura 129(A) imagem 183055, (B) padrão selecionado, (C) MS e (D) SMS.....	123
Figura 130(A) imagem 196073, (B) padrão selecionado, (C) MS e (D) SMS.....	123
Figura 131(A) imagem 207056, (B) padrão selecionado, (C) MS e (D) SMS.....	123
Figura 132(A) imagem 208001, (B) padrão selecionado, (C) MS e (D) SMS.....	123
Figura 133(A) imagem 216053, (B) padrão selecionado, (C) MS e (D) SMS.....	123
Figura 134(A) imagem 225017, (B) padrão selecionado, (C) MS e (D) SMS.....	124
Figura 135(A) imagem 227092, (B) padrão selecionado, (C) MS e (D) SMS.....	124
Figura 136(A) imagem 238011, (B) padrão selecionado, (C) MS e (D) SMS.....	124
Figura 137(A) imagem 247085, (B) padrão selecionado, (C) MS e (D) SMS.....	124
Figura 138(A) imagem 249061, (B) padrão selecionado, (C) MS e (D) SMS.....	125
Figura 139(A) imagem 253036, (B) padrão selecionado, (C) MS e (D) SMS.....	125
Figura 140(A) imagem 260058, (B) padrão selecionado, (C) MS e (D) SMS.....	125
Figura 141(A) imagem 291000, (B) padrão selecionado, (C) MS e (D) SMS.....	125
Figura 142(A) imagem 295087, (B) padrão selecionado, (C) MS e (D)	

SMS.....	125
Figura 143(A) imagem 299091, (B) padrão selecionado, (C) MS e (D) SMS.....	126
Figura 144(A) imagem 300091, (B) padrão selecionado, (C) MS e (D) SMS.....	126
Figura 145(A) imagem 304034, (B) padrão selecionado, (C) MS e (D) SMS.....	126
Figura 146(A) imagem 310007, (B) padrão selecionado, (C) MS e (D) SMS.....	126
Figura 147(A) imagem 368078, (B) padrão selecionado, (C) MS e (D) SMS.....	126
Figura 148(A) imagem 374067, (B) padrão selecionado, (C) MS e (D) SMS.....	127
Figura 149(A) imagem 388016, (B) padrão selecionado, (C) MS e (D) SMS.....	127
Figura 150(A) imagem 2092, (B) padrão selecionado, (C) FH e (D) WFH.....	128
Figura 151(A) imagem 3096, (B) padrão selecionado, (C) FH e (D) WFH.....	128
Figura 152(A) imagem 12003, (B) padrão selecionado, (C) FH e (D) WFH.....	128
Figura 153(A) imagem 15088, (B) padrão selecionado, (C) FH e (D) WFH.....	129
Figura 154(A) imagem 16052, (B) padrão selecionado, (C) FH e (D) WFH.....	129
Figura 155(A) imagem 22090, (B) padrão selecionado, (C) FH e (D) WFH.....	129
Figura 156(A) imagem 24004, (B) padrão selecionado, (C) FH e (D) WFH.....	130
Figura 157(A) imagem 24063, (B) padrão selecionado, (C) FH e (D) WFH.....	130
Figura 158(A) imagem 35070, (B) padrão selecionado, (C) FH e (D) WFH.....	130
Figura 159(A) imagem 42049, (B) padrão selecionado, (C) FH e (D) WFH.....	130
Figura 160(A) imagem 46076, (B) padrão selecionado, (C) FH e (D) WFH.....	131
Figura 161(A) imagem 48055, (B) padrão selecionado, (C) FH e (D) WFH.....	131
Figura 162(A) imagem 60079, (B) padrão selecionado, (C) FH e (D)	

WFH.....	131
Figura 163(A) imagem 61060, (B) padrão selecionado, (C) FH e (D) WFH.....	131
Figura 164(A) imagem 62096, (B) padrão selecionado, (C) FH e (D) WFH.....	132
Figura 165(A) imagem 66075, (B) padrão selecionado, (C) FH e (D) WFH.....	132
Figura 166(A) imagem 67079, (B) padrão selecionado, (C) FH e (D) WFH.....	132
Figura 167(A) imagem 68077, (B) padrão selecionado, (C) FH e (D) WFH.....	132
Figura 168(A) imagem 69015, (B) padrão selecionado, (C) FH e (D) WFH.....	133
Figura 169(A) imagem 80099, (B) padrão selecionado, (C) FH e (D) WFH.....	133
Figura 170(A) imagem 94079, (B) padrão selecionado, (C) FH e (D) WFH.....	133
Figura 171(A) imagem 97017, (B) padrão selecionado, (C) FH e (D) WFH.....	134
Figura 172(A) imagem 97033, (B) padrão selecionado, (C) FH e (D) WFH.....	134
Figura 173(A) imagem 100075, (B) padrão selecionado, (C) FH e (D) WFH.....	134
Figura 174(A) imagem 100080, (B) padrão selecionado, (C) FH e (D) WFH.....	135
Figura 175(A) imagem 113009, (B) padrão selecionado, (C) FH e (D) WFH.....	135
Figura 176(A) imagem 113016, (B) padrão selecionado, (C) FH e (D) WFH.....	135
Figura 177(A) imagem 113044, (B) padrão selecionado, (C) FH e (D) WFH.....	135
Figura 178(A) imagem 118035, (B) padrão selecionado, (C) FH e (D) WFH.....	136
Figura 179(A) imagem 124084, (B) padrão selecionado, (C) FH e (D) WFH.....	136
Figura 180(A) imagem 126007, (B) padrão selecionado, (C) FH e (D) WFH.....	136
Figura 181(A) imagem 135069, (B) padrão selecionado, (C) FH e (D)	

WFH.	136
Figura 182(A) imagem 143090, (B) padrão selecionado, (C) FH e (D) WFH.	136
Figura 183(A) imagem 151087, (B) padrão selecionado, (C) FH e (D) WFH.	137
Figura 184(A) imagem 159091, (B) padrão selecionado, (C) FH e (D) WFH.	137
Figura 185(A) imagem 161062, (B) padrão selecionado, (C) FH e (D) WFH.	137
Figura 186(A) imagem 163014, (B) padrão selecionado, (C) FH e (D) WFH.	138
Figura 187(A) imagem 167062, (B) padrão selecionado, (C) FH e (D) WFH.	138
Figura 188(A) imagem 167083, (B) padrão selecionado, (C) FH e (D) WFH.	138
Figura 189(A) imagem 183055, (B) padrão selecionado, (C) FH e (D) WFH.	138
Figura 190(A) imagem 196073, (B) padrão selecionado, (C) FH e (D) WFH.	139
Figura 191(A) imagem 207056, (B) padrão selecionado, (C) FH e (D) WFH.	139
Figura 192(A) imagem 208001, (B) padrão selecionado, (C) FH e (D) WFH.	139
Figura 193(A) imagem 216053, (B) padrão selecionado, (C) FH e (D) WFH.	139
Figura 194(A) imagem 225017, (B) padrão selecionado, (C) FH e (D) WFH.	140
Figura 195(A) imagem 227092, (B) padrão selecionado, (C) FH e (D) WFH.	140
Figura 196(A) imagem 238011, (B) padrão selecionado, (C) FH e (D) WFH.	140
Figura 197(A) imagem 247085, (B) padrão selecionado, (C) FH e (D) WFH.	140
Figura 198(A) imagem 249061, (B) padrão selecionado, (C) FH e (D) WFH.	141
Figura 199(A) imagem 253036, (B) padrão selecionado, (C) FH e (D) WFH.	141
Figura 200(A) imagem 260058, (B) padrão selecionado, (C) FH e (D)	

WFH.	141
Figura 201(A) imagem 291000, (B) padrão selecionado, (C) FH e (D) WFH.	141
Figura 202(A) imagem 295087, (B) padrão selecionado, (C) FH e (D) WFH.	141
Figura 203(A) imagem 299091, (B) padrão selecionado, (C) FH e (D) WFH.	142
Figura 204(A) imagem 300091, (B) padrão selecionado, (C) FH e (D) WFH.	142
Figura 205(A) imagem 304034, (B) padrão selecionado, (C) FH e (D) WFH.	142
Figura 206(A) imagem 310007, (B) padrão selecionado, (C) FH e (D) WFH.	142
Figura 207(A) imagem 368078, (B) padrão selecionado, (C) FH e (D) WFH.	143
Figura 208(A) imagem 374067, (B) padrão selecionado, (C) FH e (D) WFH.	143
Figura 209(A) imagem 388016, (B) padrão selecionado, (C) FH e (D) WFH.	143
Figura 210 Comparação visual dos resultados obtidos pelos métodos para a imagem 2092. (A) Imagem original, (B) Ground Truth, (C) SMS, (D) WCSC, (E) WFH, (F) CSC+GNM2, (G) MS+GNM2, (H) CSC+GNM, (I) MS+GNM, (J) CSC, (K) MS, (L) FH, (M) EDISON, (N) WS, (O) JSEG, (P) RHSEG.	147
Figura 211 Comparação visual dos resultados obtidos pelos métodos para a imagem 15088. (A) Imagem original, (B) Ground Truth, (C) SMS, (D) WCSC, (E) WFH, (F) CSC+GNM2, (G) MS+GNM2, (H) CSC+GNM, (I) MS+GNM, (J) CSC, (K) MS, (L) FH, (M) EDISON, (N) WS, (O) JSEG, (P) RHSEG.	148
Figura 212 Comparação visual dos resultados obtidos pelos métodos para a imagem 22090. (A) Imagem original, (B) Ground Truth, (C) SMS, (D) WCSC, (E) WFH, (F) CSC+GNM2, (G) MS+GNM2, (H) CSC+GNM, (I) MS+GNM, (J) CSC, (K) MS, (L) FH, (M) EDISON, (N) WS, (O) JSEG, (P) RHSEG.	148
Figura 213 Comparação visual dos resultados obtidos pelos métodos para a imagem 24004. (A) Imagem original, (B) Ground Truth, (C) SMS, (D) WCSC, (E) WFH, (F) CSC+GNM2, (G) MS+GNM2, (H) CSC+GNM, (I) MS+GNM, (J) CSC, (K) MS, (L) FH, (M) EDISON, (N) WS, (O) JSEG, (P) RHSEG.	149

Figura 214	Comparação visual dos resultados obtidos pelos métodos para a imagem 42049. (A) Imagem original, (B) Ground Truth, (C) SMS, (D) WCSC, (E) WFH, (F) CSC+GNM2, (G) MS+GNM2, (H) CSC+GNM, (I) MS+GNM, (J) CSC, (K) MS, (L) FH, (M) EDISON, (N) WS, (O) JSEG, (P) RHSEG.	149
Figura 215	Comparação visual dos resultados obtidos pelos métodos para a imagem 46076. (A) Imagem original, (B) Ground Truth, (C) SMS, (D) WCSC, (E) WFH, (F) CSC+GNM2, (G) MS+GNM2, (H) CSC+GNM, (I) MS+GNM, (J) CSC, (K) MS, (L) FH, (M) EDISON, (N) WS, (O) JSEG, (P) RHSEG.	150
Figura 216	Comparação visual dos resultados obtidos pelos métodos para a imagem 48055. (A) Imagem original, (B) Ground Truth, (C) SMS, (D) WCSC, (E) WFH, (F) CSC+GNM2, (G) MS+GNM2, (H) CSC+GNM, (I) MS+GNM, (J) CSC, (K) MS, (L) FH, (M) EDISON, (N) WS, (O) JSEG, (P) RHSEG.	150
Figura 217	Comparação visual dos resultados obtidos pelos métodos para a imagem 60079. (A) Imagem original, (B) Ground Truth, (C) SMS, (D) WCSC, (E) WFH, (F) CSC+GNM2, (G) MS+GNM2, (H) CSC+GNM, (I) MS+GNM, (J) CSC, (K) MS, (L) FH, (M) EDISON, (N) WS, (O) JSEG, (P) RHSEG.	151
Figura 218	Comparação visual dos resultados obtidos pelos métodos para a imagem 68077. (A) Imagem original, (B) Ground Truth, (C) SMS, (D) WCSC, (E) WFH, (F) CSC+GNM2, (G) MS+GNM2, (H) CSC+GNM, (I) MS+GNM, (J) CSC, (K) MS, (L) FH, (M) EDISON, (N) WS, (O) JSEG, (P) RHSEG.	151
Figura 219	Comparação visual dos resultados obtidos pelos métodos para a imagem 80099. (A) Imagem original, (B) Ground Truth, (C) SMS, (D) WCSC, (E) WFH, (F) CSC+GNM2, (G) MS+GNM2, (H) CSC+GNM, (I) MS+GNM, (J) CSC, (K) MS, (L) FH, (M) EDISON, (N) WS, (O) JSEG, (P) RHSEG.	152
Figura 220	Comparação visual dos resultados obtidos pelos métodos para a imagem 118035. (A) Imagem original, (B) Ground Truth, (C) SMS, (D) WCSC, (E) WFH, (F) CSC+GNM2, (G) MS+GNM2, (H) CSC+GNM, (I) MS+GNM, (J) CSC, (K) MS, (L) FH, (M) EDISON, (N) WS, (O) JSEG, (P) RHSEG.	153
Figura 221	Comparação visual dos resultados obtidos pelos métodos para a imagem 143090. (A) Imagem original, (B) Ground Truth, (C) SMS, (D) WCSC, (E) WFH, (F) CSC+GNM2, (G) MS+GNM2, (H) CSC+GNM, (I) MS+GNM, (J) CSC, (K) MS, (L) FH, (M) EDISON, (N) WS, (O)	

JSEG, (P) RHSEG. 154

Figura 222 Comparação visual dos resultados obtidos pelos métodos para a imagem 196073. (A) Imagem original, (B) Ground Truth, (C) SMS, (D) WCSC, (E) WFH, (F) CSC+GNM2, (G) MS+GNM2, (H) CSC+GNM, (I) MS+GNM, (J) CSC, (K) MS, (L) FH, (M) EDISON, (N) WS, (O) JSEG, (P) RHSEG. 155

Figura 223 Comparação visual dos resultados obtidos pelos métodos para a imagem 253036. (A) Imagem original, (B) Ground Truth, (C) SMS, (D) WCSC, (E) WFH, (F) CSC+GNM2, (G) MS+GNM2, (H) CSC+GNM, (I) MS+GNM, (J) CSC, (K) MS, (L) FH, (M) EDISON, (N) WS, (O) JSEG, (P) RHSEG. 156

Figura 224 Comparação visual dos resultados obtidos pelos métodos para a imagem 310007. (A) Imagem original, (B) Ground Truth, (C) SMS, (D) WCSC, (E) WFH, (F) CSC+GNM2, (G) MS+GNM2, (H) CSC+GNM, (I) MS+GNM, (J) CSC, (K) MS, (L) FH, (M) EDISON, (N) WS, (O) JSEG, (P) RHSEG. 157

Figura 225 Comparação visual dos resultados obtidos pelos métodos para a imagem 368068. (A) Imagem original, (B) Ground Truth, (C) SMS, (D) WCSC, (E) WFH, (F) CSC+GNM2, (G) MS+GNM2, (H) CSC+GNM, (I) MS+GNM, (J) CSC, (K) MS, (L) FH, (M) EDISON, (N) WS, (O) JSEG, (P) RHSEG. 157

LISTA DE TABELAS

Tabela 1	Técnicas básicas e suas adaptações	54
Tabela 2	Tabela comparando os tempos de execução médio dos métodos com e sem a abordagem.	80
Tabela 3	Tabela comparando os resultados de RAND entre CSC e WCSC para as 60 imagens selecionadas. A coluna imagem é o número de referência no data set de Berkeley.	162
Tabela 4	Tabela comparando os resultados de RAND entre MS e SMS para as 60 imagens selecionadas. A coluna imagem é o número de referência no data set de Berkeley.	163
Tabela 5	Tabela comparando os resultados de RAND entre FH e WFH para as 60 imagens selecionadas. A coluna imagem é o número de referência no data set de Berkeley.	164
Tabela 6	Tabela comparando os resultados de tempo de execução em milissegundos entre CSC e WCSC para as 60 imagens selecionadas. A coluna imagem é o número de referência no data set de Berkeley.	168
Tabela 7	Tabela comparando os resultados de tempo de execução em milissegundos entre MS e SMS para as 60 imagens selecionadas. A coluna imagem é o número de referência no data set de Berkeley.	169
Tabela 8	Tabela comparando os resultados de tempo de execução em milissegundos entre FH e WFH para as 60 imagens selecionadas. A coluna imagem é o número de referência no data set de Berkeley.	170

LISTA DE ABREVIATURAS E SIGLAS

PM	Polinomial Mahalanobis	33
DM	Distância de Mahalanobis	33
CSC	Color Structure Code	35
MS	Mumford-Shah	35
KNN	K-Nearest Neighbor	35
FH	Felzenszwalb and Huttenlocher	43
GT	Ground Truth	45
SVM	Support Vector Machine	54
HCF	Highest Confidence First	54
PCA	Principal Component Analysis	54
FCM	Fuzzy c-Means	55
VSCH	Vector Supported Convex Hull	55
MRF	Markov Random Field	55
SOM	Self Organization Maps	55
LS-SVM	Least Squares Support Vector Machine	55
GMM	Gaussian Mixture Models	55
AMS	Adaptative Mean Shift	55
MF	Meanfield Annealing	55
KPCA	Kernel Principal Component Analysis	55
MBF	Modified Bacterial Foraging	56
LVQ	Learning Vector Quantization	56
WCSC	Weighted Color Structure Code	57
DEP	Distância Euclidiana Ponderada	57
DE	Distância Euclidiana	57
SMS	Supervised Mumford-Shah	58
WFH	Weighted Felzenszwalb and Huttenlocher	61

SUMÁRIO

1	INTRODUÇÃO	25
1.1	APRESENTAÇÃO DO PROBLEMA DE PESQUISA	25
1.2	OBJETIVOS	26
1.3	JUSTIFICATIVA	26
1.4	ESTRUTURA DA DISSERTAÇÃO	26
2	FUNDAMENTAÇÃO TEÓRICA	29
2.1	PROCESSAMENTO DIGITAL DE IMAGENS	29
2.2	DEFINIÇÃO DE IMAGEM	30
2.3	DEFINIÇÃO DE ESPAÇO DE COR	30
2.4	MÉTRICAS NÃO LINEARES	32
2.4.1	Distância de Mahalanobis	33
2.5	SEGMENTAÇÃO	35
2.5.1	Métodos de Segmentação	35
2.5.2	<i>Split and merge</i>	38
2.5.2.1	Color Structure Code	38
2.5.3	Modelos variacionais	40
2.5.3.1	Mumford-Shah	41
2.5.4	Teoria de grafos	43
2.5.4.1	Felzenszwalb and Huttenlocher	43
2.6	ÍNDICE RAND	45
3	REVISÃO DA LITERATURA	47
3.1	EXTRAÇÃO DE DADOS	47
3.2	ANÁLISE DOS RESULTADOS	48
3.3	TRABALHOS CORRELATOS	48
3.4	CONSIDERAÇÕES SOBRE O CAPÍTULO	53
4	DESENVOLVIMENTO DOS MÉTODOS DE SEGMENTAÇÃO COM A MÉTRICA NÃO LINEAR	57
4.1	WEIGHTED COLOR STRUCTURE CODE	57
4.2	SUPERVISED MUMFORD-SHAH	58
4.3	WEIGHTED FELZENSZWALB AND HUTTENLOCHER	61
5	AMBIENTE E RESULTADOS EXPERIMENTAIS	65
5.1	AMBIENTE EXPERIMENTAL	65
5.2	EXPERIMENTO 1: COMPARAÇÃO ENTRE OS MÉTODOS E SUAS ABORDAGENS NÃO LINEARES	65
5.2.1	Comparação entre CSC e WCSC	66
5.2.2	Comparação entre MS e SMS	70
5.2.3	Comparação entre FH e WFH	73

5.3	EXPERIMENTO 2: ANÁLISE GERAL ADICIONANDO OUTROS MÉTODOS	77
5.4	EXPERIMENTO 3: COMPARAÇÃO DOS MÉTODOS COM BASE EM TEMPO DE EXECUÇÃO	79
6	CONCLUSÃO	83
6.1	CONTRIBUIÇÕES	83
6.2	TRABALHOS FUTUROS	84
	REFERÊNCIAS	85
	APÊNDICE A – Imagens CSC-WCSC, MS-SMS e FH-WFH	97
	APÊNDICE B – Imagens comparando todos os métodos ...	147
	APÊNDICE C – Tabelas Índice Rand CSC-WCSC, MS-SMS e FH-WFH	161
	APÊNDICE D – Tabelas de tempos de execução em milissegundos CSC-WCSC, MS-SMS e FH-WFH	167

1 INTRODUÇÃO

As áreas de processamento digital de imagens e visão computacional são utilizadas em diversas áreas, como por exemplo, na área médica auxiliando nos procedimentos que utilizam imagem ou na área de segurança fazendo o rastreamento de objetos de interesse nas imagens de câmeras de segurança. Para tanto, é utilizado um encadeamento de métodos de forma a montar um *pipeline* de execução afim de, com base na imagem de entrada, obter o resultado esperado, seja a identificação de algum objeto de interesse ou a melhoria na visualização de uma imagem. Neste encadeamento de métodos, um processo muito utilizado é a segmentação de imagens, a qual consiste em separar a imagem em partes ou segmentos que a constituem.

1.1 APRESENTAÇÃO DO PROBLEMA DE PESQUISA

A segmentação de imagens é um processo muito utilizado em diversos tipos de aplicações que variam desde aplicações voltadas para a parte de análise de imagens médicas até a parte de compressão de imagens. Nestas aplicações a segmentação entra como um processo intermediário o qual simplifica a representação da imagem fornecendo uma visão geral da imagem o que auxilia na utilização de outros algoritmos de análise de imagem. Com uma revisão da literatura pode-se notar que os métodos de segmentação mais citados são limiarização, clusterização, método de crescimento de regiões, métodos utilizando bordas, métodos utilizando redes neurais e segmentação baseada em grafos. Cada método possui suas vantagens e desvantagens, entretanto o grande problema na área de segmentação está em se obter algoritmos que possam ser adaptáveis e que evitem a super-segmentação e sub-segmentação, os quais dizem respeito, respectivamente, a segmentar em muitas regiões e segmentar em poucas regiões. Afim de obter resultados que evitem os problemas citados, diversos métodos foram propostos combinando e adaptando métodos já conhecidos. Entretanto há ainda pesquisa de novos métodos com a finalidade de obter melhores resultados, mostrando a necessidade de novos algoritmos de segmentação. Neste contexto, a adaptação proposta tenta suprir esta necessidade de algoritmos adaptáveis que obtenham bons resultados.

1.2 OBJETIVOS

O objetivo geral é fazer um estudo do efeito da aplicação de uma métrica de similaridade não linear nos algoritmos de segmentação que se baseiam em métrica de similaridade, analisando do ponto de vista de eficácia e eficiência.

Como objetivos específicos tem-se:

- Validar os resultados obtidos, com os algoritmos que obtiveram a adaptação proposta, com base em um padrão ouro (segmentação manual) fornecido por um *dataset* especializado em validação de métodos de segmentação.
- Analisar de forma comparativa e empírica as versões adaptadas com e sem a métrica de similaridade não linear.
- Analisar os tempos de execução dos métodos de segmentação com e sem a métrica não linear.

1.3 JUSTIFICATIVA

Este estudo surgiu da necessidade de algoritmos de segmentação que possam ser adaptáveis a diferentes situações e possam fornecer bons resultados de segmentação, onde bons resultados de segmentação é definido como resultados que se aproximem das segmentações manuais.

A aplicação prática, que iniciou este estudo, é a utilização destes algoritmos adaptáveis na navegação de veículos autônomos. Nesta área existem diversos tipos de terreno e o resultado da segmentação precisa ser o melhor possível afim de fornecer a melhor imagem resultante possível para a parte de controle do veículo.

1.4 ESTRUTURA DA DISSERTAÇÃO

Essa dissertação está dividido em 6 capítulos. Inicialmente se tem o capítulo de introdução onde é feita a apresentação do tema sendo trabalhado, os objetivos do estudo, a justificativa do estudo e a estrutura do mesmo. O segundo capítulo apresenta uma visão geral da parte de processamento digital de imagens, a definição de imagem e de espaço de cor, explana sobre métricas não lineares mais especificamente a distância de Mahalanobis e sua variação o Polinomial Mahalanobis, o qual é a métrica não linear utilizada.

Neste mesmo capítulo há a explicação sobre métodos de segmentação, salientando suas vantagens e desvantagens, explanando de forma mais aprofundada sobre os métodos de segmentação os quais obtiveram a inserção da métrica não linear. Por fim, este capítulo termina com uma explicação sobre métodos de validação aprofundando-se no método de validação utilizado. O terceiro capítulo possui a revisão do estado da arte, no qual é feita uma pesquisa de algoritmos de segmentação que levem em conta a não linearidade da distribuição das cores na imagem. O capítulo quatro detalha toda a parte de desenvolvimento e aprimoramento dos métodos de segmentação sendo utilizados. O capítulo cinco faz uma análise dos resultados obtidos por meio de experimentos realizados. O último capítulo apresenta as conclusões do estudo realizado nessa dissertação e as expectativas de trabalhos futuros.

2 FUNDAMENTAÇÃO TEÓRICA

Este capítulo tem como propósito fornecer uma base sobre processamento de imagens, por exemplo, *pipeline* de execução, definição do espaço de cor e definição de imagem. No final do capítulo, têm-se a explicação sobre a distância de Mahalanobis e sua variação o Polinomial Mahalanobis, os tipos de métodos de segmentação mais utilizados e uma explicação sobre os algoritmos base selecionados para o estudo (Color Structure Code, Mumford-Shah, Felzenszwalb and Huttenlocher), explicando o porque foram selecionados e suas principais características.

2.1 PROCESSAMENTO DIGITAL DE IMAGENS

Não há um consenso entre os autores da área sobre a fronteira onde termina o processamento de imagens digitais e começa a visão computacional. Um dos autores que escrevem sobre processamento de imagem define este como sendo o processo onde tanto a entrada como a saída são imagens (GONZALEZ; WOODS, 2006). Um *pipeline* dos passos fundamentais no processamento de imagem pode ser visualizado na figura 1. Os passos básicos são:




Figura 1: Passos fundamentais do processamento digital de imagens (GONZALEZ; WOODS, 2006)

- Aquisição de imagens: Existem diversas formas de se obter uma imagem digital, entretanto, elas basicamente se resumem a transformar os

sinais analógicos em representações digitais.

- **Pré-processamento:** Engloba as aplicações de filtros para restauração e aprimoramento da imagem e a compressão da imagem em formatos de armazenamento.
- **Segmentação:** A imagem de entrada é dividida em partes ou objetos que a constituem. As abordagens mais utilizadas para segmentação serão melhores explicadas no decorrer deste trabalho.
- **Representação e descrição:** Nesta etapa escolhe-se a melhor forma de representação dos dados da imagem para o posterior processamento. Nesta etapa procura-se extrair as características que resultam em uma informação de interesse ou são básicas para a realização da diferenciação entre objetos.
- **Reconhecimento e interpretação:** O reconhecimento e interpretação são os últimos estágios do pipeline do processamento de imagens. Nestes passos são utilizadas as informações extraídas na parte de representação e descrição para identificar os objetos na imagem.

2.2 DEFINIÇÃO DE IMAGEM

Uma das possíveis definições para imagem digital é por meio de uma função de duas dimensões $f(x,y)$ onde x e y são coordenadas no espaço da imagem e o valor f , para qualquer par (x,y) , é a intensidade da imagem ou valor em tons de cinza naquele ponto (GONZALEZ; WOODS, 2006). Como pode ser observado na figura 2 a função $f(x,y)$ destaca um determinado elemento da imagem. Outro fator também visualizado é o padrão, arbitrariamente escolhido, mais comumente utilizado para representação de imagens digitais, tendo como ponto de origem $(0,0)$ o canto superior esquerdo e os eixos x e y definindo o espaço da imagem. Cada coordenada (x,y) referencia um elemento da imagem comumente chamado de pixel.

2.3 DEFINIÇÃO DE ESPAÇO DE COR

Espaço de cores é um modelo abstrato matemático para formalizar a descrição de cores através de tuplas de números, tipicamente formadas por três ou quatro elementos. Existem vários modelos de espaço de cor utilizados atualmente, como exemplo tem-se: RGB (padrão industrial), HSV, YIQ,



Figura 2: Convenção dos eixos para representação de imagens digitais (GONZALEZ; WOODS, 2006)

CIE, Lab, CMYK (padrão de impressoras) e Y'UV como ilustrado pela figura 3. O espaço utilizado neste trabalho é o RGB, por ser o espaço de cor mais utilizado nos monitores, TV, câmeras digitais, *scanners* e *displays* de celulares. O RGB utiliza as cores vermelho, verde e azul para formar todas as cores possíveis através da combinação da intensidade destas três cores. Como pode ser visualizado na figura 3 o cubo RGB é definido pelos vértices em que cada vértice é a combinação de vermelho, verde e azul nos valores mínimo ou máximo sendo a cor preta a combinação do mínimo das três cores e o branco a combinação do máximo das mesmas. As demais partes do cubo são uma combinação da intensidade de forma variada das três componentes.




Figura 3: Espaços de cor RGB, YIQ, HSV, Lab, CIE

A figura 4 mostra uma análise das componentes de cor da imagem no espaço RGB. Nesta análise pode-se perceber a distribuição dos *pixels* no espaço o que possibilita uma visualização de padrões da imagem.




Figura 4: Distribuição das componentes de cor da imagem no espaço RGB

2.4 MÉTRICAS NÃO LINEARES

Métricas não lineares são métricas utilizadas para representar comportamentos que não apresentam um único sentido ou padrão de comportamento, mostrando estruturas e padrões com múltiplos caminhos. Alguns exemplo de utilização destas métricas são: na medição da similaridade de distribuições que apresentam características de não linearidade em suas distribuições, na classificação de elementos em classes e na parte de reconhecimento de fala. Dois exemplos deste tipo de métrica são a distância de Bhattacharyya (A., 1943) e a distância de Mahalanobis (MAHALANOBIS, 1936). A distância de Bhattacharyya foi apresentada em 1943 por Anil Kumar Bhattacharyya, matemático indiano, e mede a similaridade entre duas distribuições de probabilidade. O coeficiente de Bhattacharyya pode ser utilizado para determinar a proximidade relativa entre duas amostras. A distância de Mahalanobis foi apresentada em 1936 por Prasanta Chandra Mahalanobis, matemático indiano, e serve tanto para medir a similaridade entre distribuições quanto para medir a similaridade entre um ponto e uma distribuição.

A escolha pela a distância de Mahalanobis para o estudo se deu devido a trabalhos realizados anteriormente em que está métrica mostrou-se bastante robusta no quesito de medir valores de similaridade entre pontos e distribuições. Uma explicação mais aprofundada sobre a distâncias de Mahalanobis e sua variação o Polinomial Mahalanobis será apresentada na próxima secção.

2.4.1 Distância de Mahalanobis

A Distância de Mahalanobis (DM) é uma métrica de distância usada para determinar a similaridade entre distribuições e entre um ponto e uma distribuição. A DM utiliza para este propósito os atributos estatísticos, matriz de covariância e média, da distribuição utilizada como referência. A utilização desta métrica serve como um substituto da distância Euclidiana quando a representação pictorial do padrão no espaço apresenta flutuações aleatórias de diferentes magnitudes no espaço de cor (JOHNSON; WICHERN, 2007). Formalmente, a DM é definida por:

$$DM(a, b) = \sqrt{(a - b)^T A^{-1} (a - b)}. \quad (2.1)$$

onde: $DM(a, b)$ é a distância de Mahalanobis entre dois vetores de cor $a = (r_a, g_a, b_a)$ e $b = (r_b, g_b, b_b)$ no espaço de cor RGB e A é a matriz de covariância da distribuição usada como referência.

Quando a distribuição usada como referência demonstra características de não linearidade, uma variação da distância de Mahalanobis denominado Polinomial Mahalanobis (PM) é utilizado. O PM é a combinação polinomial dos vetores de entrada e a projeção destes vetores sob uma perspectiva dimensional superior. Obtido a partir da distância de Mahalanobis descrita pela Eq. 2.1, a qual é a primeira ordem de projeção de q -ordens de projeção em uma sequência polinomial. Enquanto a DM segue a estrutura linear o PM utiliza projeções pelo mapeamento do dado de entrada em termos polinomiais de alta ordem, obtendo uma discriminação não linear para um dado de entrada fornecido. Por exemplo considerando um vetor bi-dimensional $\mathbf{W} = \{\mathbf{w}_1, \mathbf{w}_2\}$, o qual é também a primeira das q -ordens de projeção em uma sequência do PM, o mapeamento deste vetor bi-dimensional em um termo polinomial de segunda ordem de projeção é:

$$W_{O2} = (w_1, w_2, w_1 w_2, w_1^2, w_2^2). \quad (2.2)$$

Para mapear em um termo polinomial de terceira ordem de projeção, omitindo as combinações repetidas, tem-se:

$$W_{O3} = (w_1, w_2, w_1 w_2, w_1^2, w_1^2 w_2, w_1^2 w_2^2, w_1^3, w_2^3, w_1^4, w_2^4). \quad (2.3)$$

E assim sucessivamente para ordens de projeções maiores. De um ponto de vista computacional, a q -ordem de projeção da DM pode ser obtida através do mapeamento direto de todos os pontos em seus respectivos

termos polinomiais, e então utilizá-la na Eq. 2.1. Entretanto o número de combinação de termos faz com que esta métrica de distância seja computacionalmente inviável se realizado pela simples utilização dos vetores de entrada e pela procura exaustiva de todos os possíveis termos polinomiais. Um modo de fazer este cálculo de termos polinomiais grandes é através da utilização do *framework* proposto por (GRUDIC, 2006), o qual cria um mapeamento de termos polinomiais de alta ordem através de um espaço de vetorial, tal como o RGB. Este mapeamento é realizado através da sucessiva projeção de dados de alta dimensão em um espaço coluna k de baixa dimensão, obtendo termos polinomiais de segunda ordem de projeção neste espaço. Estes espaços colunas são de baixa dimensão pelo fato de serem construídos utilizando a vizinhança local, a qual é projetada em k componentes principais. Este espaço polinomial de segunda ordem de projeção por sua vez, têm uma projeção de espaços coluna de pequena dimensão para o qual pode ser computado um espaço de ordem de projeção maior através da Eq. 2.4 descrita a seguir.

$$PM(a, b) = DM_{\sigma^2}(a, b) + \sum_{l=1}^{L-1} D_{M_{\sigma^2}}(q_l^i, q_l^j). \quad (2.4)$$

Nesta equação o primeiro termo $DM_{\sigma^2}(a, b)$ é a distância de Mahalanobis com um pequeno valor positivo σ^2 utilizado para anular limitações de inversão de matrizes se algum valor singular for zero, $L > 1$ é um parâmetro informado que resulta na ordem do polinômio ($q = 2^{L-1}$), por exemplo, para $L = 1$ calcula-se a distância de Mahalanobis, para $L = 2$ utiliza o Polinomial Mahalanobis obtendo-se um polinômio de grau 2; $L = 3$ um polinômio de 4 grau; $L = 4$ um polinômio de grau 8 e assim sucessivamente. E os argumentos q_l^i e q_l^j são as próximas projeções ($q + 1$) de a e b dentro de seus termos polinomiais. Se mais precisão for necessária, é possível aumentar o grau de projeção do polinômio, isto é, aumentar o valor do parâmetro L , restringindo a área de influência do padrão selecionado. A figura 5 mostra os mapas de projeção obtidos pelo PM utilizando um padrão previamente selecionado representado pelo azul na figura. Nesta mesma figura pode ser visualizado uma comparação da distância Euclidiana, da distância de Mahalanobis e do Polinomial Mahalanobis. As colunas 1-3 mostram as respostas de similaridade para cada mapa topológico na sua decomposição no espaço RGB (RG, RB e GB faces). Os pontos azuis representam a distribuição do padrão selecionado, a qual possui seu centro mostrado por um quadrado vermelho. As respostas para cada métrica de distância são mostradas em cada linha, onde quanto mais próximo do branco o agrupamento está, maior a similaridade com o centro da distribuição. Esta forma de cálculo de distância é utilizada na análise de métodos de classificação e é fortemente relacionado com testes

estáticos de múltiplas variáveis. O *framework* utilizado para o cálculo do Polinomial Mahalanobis é explicado de forma mais aprofundada em (GRUDIC, 2006).

2.5 SEGMENTAÇÃO

Segmentação é o processo que particiona a imagem em partes ou objetos constituintes (GONZALEZ; WOODS, 2006). Formalmente a segmentação pode ser definida como: se F é o conjunto de todos os *pixels* e P é um predicado uniforme (homogeneidade) definido em grupos de *pixels*, então segmentação é o particionamento do conjunto F em um conjunto de vários subconjuntos conectados (PAL; PAL, 1993) ou regiões $(S_1, S_2, \dots, S_n)$ tal que $\bigcup_{i=1}^n S_i = F$ com $S_i \cap S_j = \emptyset, i \neq j$. O predicado uniforme $P(S_i) = \text{verdadeiro}$ para todas as regiões S_i e $P(S_i \cup S_j) = \text{falso}$, quando S_i é adjacente a S_j .

O processo de segmentação é utilizado em diversas áreas, por exemplo, na medicina, em veículos autônomos e na área de segurança e em cada uma delas lida com um tipo de imagem. Essa variação dos tipos de imagem e de escopo de aplicação faz com que algoritmos de segmentação especializados para lidar com este nicho sejam desenvolvidos, gerando uma grande gama de métodos de segmentação, novos métodos ou evolução dos métodos anteriormente desenvolvidos. Os métodos de segmentação mais utilizados e os métodos selecionados para este estudo serão melhor explorados nas seções seguintes.

2.5.1 Métodos de Segmentação

Como mostrado na parte de revisão da literatura existem vários métodos para segmentação de imagens. Dentre os métodos existentes os mais citados na literatura são:

- Limiarização ou *Thresholding*: métodos de limiarização ou *thresholding* utilizam um valor de intensidade para decidir a qual classe um *pixel* sendo analisado pertence. Dois aspectos positivos dos métodos de *thresholding* são a fácil implementação e o tempo de execução quase sem custo, entretanto os resultados obtidos são geralmente binários e ignoram uma grande quantidade de informações úteis da imagem.
- Segmentação baseada na detecção de bordas: os métodos baseados na detecção de bordas envolvem a localização de regiões da imagem onde




Figura 5: Mapas topológicos. Em (a) distância Euclidiana, (b) distância de Mahalanobis e (c-f) Polinomial Mahalanobis de q -ordem $2^{(1,2,3,4)}$, respectivamente. Imagem extraída de (SOBIERANSKI; COMUNELLO; WANGENHEIM, 2011).

a variação dos tons de cinza ocorre de maneira relativamente abrupta. Apesar de obter melhor os limites dos objetos, este método acaba se tornando inviável para imagens em que a transição de uma região para outra ocorre de forma sutil.

- *Clustering* ou Clusterização: métodos de clusterização tentam agrupar, de uma forma natural, tipos de dados similares. Estes métodos procuram por grupos de *pixels* dispersos no espaço de cor, e para cada um destes atribui um rótulo. Na literatura K-Nearest Neighbor (KNN) (FIX; HODGES, 1989) e K-means (MACQUEEN, 1967) são os métodos de clusterização mais conhecidos. Os métodos de clusterização podem ser aplicados para qualquer processo de categorização que tem como base o uso de características. Entretanto o aspecto negativo destes métodos é a utilização apenas de características do pixel sem considerar a informação do domínio de espaço.
- Segmentação utilizando redes neurais: a segmentação utilizando redes neurais utiliza como entrada os níveis de cinza ou as componentes RGB da imagem em um processo composto de duas etapas. A primeira é a etapa de treinamento, onde ocorre o aprendizado através de imagens exemplo. A segunda etapa é o processo de segmentação onde ocorre a identificação das n regiões da imagem, em que n é o número possível de regiões que se pretende treinar a rede para a identificação (LIN; TSAO; CHEN, 1992).
- Segmentação baseada em grafos: a segmentação de imagens utilizando grafos geralmente descreve o problema como um grafo $G = (V, E)$, onde cada nodo $v_i \in V$ corresponde a um pixel na imagem e uma aresta (V_i, V_j) pertencente a E conecta V_i e V_j com um peso associado baseado em alguma propriedade do pixel (FELZENSZWALB; HUTTENLOCHER, 2004a).
- Segmentação baseada em regiões: métodos baseado em regiões usualmente procuram a similaridade entre regiões vizinhas ou *pixels* vizinhos de forma iterativa, agrupando-os em grandes regiões. Exemplos típicos destes métodos são Mumford-Shah (MS) (Mumford, D. and Shah, J., 1989), Watershed (WS) (VINCENT; SOILLE, 1991) e Color Structure Code (CSC) (PRIESE; STURM, 2003). Esta categoria de métodos possui a vantagem de levar em consideração informações locais e de intensidade no processo de segmentação, entretanto o problema levantado por esses métodos, também presente nos métodos anteriores, são super-segmentação e sub-segmentação, ou seja, gerar muitos segmentos e gerar poucos segmentos, respectivamente.

Dentro dos algoritmos de segmentação baseados em regiões existem vários enfoques para a realização da segmentação, entre eles existem três que consideramos os principais, seja pela constante referencia na literatura, ou pelas peculiaridades (velocidade de execução, pelos resultados obtidos ou pela simplicidade do algoritmo) do enfoque em questão. São eles os enfoques baseados em *split and merge*, modelos variacionais e na teoria de grafo. Esses três enfoques serão melhor explicados nas sessões subsequentes.

2.5.2 *Split and merge*

Os algoritmos que tem como enfoque o *Split and merge* subdividem uma imagem em um conjunto de regiões disjuntas e sobre este conjunto realizar a junção e separação das mesmas com o objetivo de satisfazer os critérios estabelecidos para algoritmos baseados em regiões.

Um dos exemplos deste enfoque de segmentação é o Color Structure Code (CSC). O CSC foi o algoritmo escolhido para ser testado com a métrica não linear devido a sua rapidez na execução e sua forma hierárquica eficiente de manter a estrutura de segmentação e será explicado com mais detalhes no item subsequente.

2.5.2.1 Color Structure Code

A ideia principal do CSC é a de construir uma estrutura hierárquica de ilhas hexagonais a partir da imagem e sobre esta hierarquia realizar o processo de segmentação. A estrutura hierárquica é uma forma eficiente de manter o resultado da segmentação, pois permite uma fácil navegação por entre as ilhas e por entre os níveis da estrutura. Uma vantagem de utilizar a estrutura hierárquica é o fato de que o algoritmo mantém uma visão local e global das características da imagem. A figura 6 ilustra um exemplo da hierarquia de ilhas hexagonais montada pelo CSC. O nível zero consiste de sete *pixels*; um pixel central e seus seis vizinhos. A divisão da imagem é organizada de forma que as ilhas se sobrepõem, onde cada segundo pixel de cada segunda linha é o centro de uma ilha do nível zero. As ilhas de nível $n + 1$ são construídas de forma similar, com sete ilhas sobrepostas do nível n . Isto é repetido até que uma ilha cubra toda a imagem. Isto direciona para a propriedade que o número de ilhas decresce de um nível para outro por um fator de quatro.

A ideia da topologia hexagonal veio originalmente de (HARTMANN, 1987). Esta topologia traz algumas dificuldades, dado que imagens digitais possuem os *pixels* organizados em uma grade ortogonal. A solução para este




Figura 6: Estrutura hierárquica de ilhas hexagonais do CSC mostrando três níveis, parcialmente coloridos para enfatizar vários graus de sobreposição de parte das ilhas.

problema é também apresentada em (PRIESE; STURM, 2003), onde a hierarquia de ilhas hexagonais é utilizada apenas como uma estrutura lógica que guia a representação da grade original da imagem. Para este propósito, o eixo vertical da grade lógica hexagonal é posto em uma escala pelo fator de $2\sqrt{3}$. Adicionalmente, cada coluna par é movida meia unidade para a esquerda. Esta transformação deixa o formato das ilhas hexagonais distorcido. As ilhas distorcidas podem ser utilizadas diretamente com a grade ortogonal.

O algoritmo pode ser descrito em 4 passos fundamentais:

1. Pré-processamento: etapa opcional onde ocorre a aplicação de filtros na imagem, como por exemplo, filtro passa baixo, filtro mediana, filtro de média, filtro gaussiano, entre outros.
2. Inicialização: nesta etapa a imagem é dividida em pequenas e indivisíveis regiões de cores, também denominados códigos de elemento de cor, construindo os níveis iniciais da estrutura hierárquica de ilhas hexagonais.
3. *Linking* ou fase de ligação: nesta etapa os códigos de elemento de cor definidos no nível zero da hierarquia começam a ser combinados em sub-regiões de forma hierárquica, formando segmentos de cor. A Figura 7 ilustra o processo de ligação.
4. *Splitting* ou fase de separação: nesta etapa é realizada a separação de regiões as quais foram incorretamente conectadas. Na fase de ligação (etapa anterior), percebe-se, pela diferença de cor, quando existem regiões que foram conectadas incorretamente, mostrando que estas regiões devem ser divididas. Nesta caso, a separação da região comum a dois

segmentos deve ser realizada e o elemento separado deve ser atribuído a região com maior similaridade com o segmento. É possível realçar duas características deste algoritmo. A primeira é o processo de crescimento de região, como o CSC começa o processo de segmentação com sementes ou mais especificamente com conjuntos de ilhas hexagonais justifica-se a categorização do CSC como um método de crescimento de região. A segunda característica é a parte de fusão dos segmentos associado com a separação, caracterizando o CSC como um algoritmo de ligação e fusão.




Figura 7: Ilustração da ligação de ilhas hexagonais do nível 0 para o próximo nível da hierarquia .

Nas etapas de ligação e separação, a métrica de similaridade tem a responsabilidade pelo controle das duas etapas e é a principal responsável pelo resultado final. Na abordagem proposta neste estudo foi inserida nestas duas etapas do algoritmo a métrica não linear. Uma análise mais aprofundada da implementação e das características do CSC pode ser encontrada em (PRIESE; STURM, 2003), onde uma revisão das estruturas utilizadas na implementação e a ideia geral do algoritmo são apresentadas em detalhes.

2.5.3 Modelos variacionais

Modelos variacionais são técnicas baseadas em equações diferenciais parciais que permitem modelar propriedades de um modelo através de uma funcional de energia. A energia funcional tenta encontrar funções que consigam minimizar a energia final gerada pela adição de termos penalizadores definidos pelas propriedades do modelo (BROX, 2005). Os métodos variacionais baseados em equações diferenciais parciais são bastante genéricos

podendo-se reformular problemas complexos de forma que a modelagem dos termos penalizadores possibilitam uma flexibilidade na formalização do modelo.

Um exemplo de modelo variacional para a área de segmentação de imagens é o Mumford-Shah, o qual foi escolhido para os testes utilizando uma métrica não linear devido a simplicidade da sua equação e pela forma com que esta equação define como devem ser as regiões e as fronteiras que dividem essas regiões. O Mumford-Shah será explicado com mais detalhes no item subsequente.

2.5.3.1 Mumford-Shah

O Mumford-Shah é um modelo variacional que tem como base uma funcional de energia E definida pela Eq.2.5. Essa funcional de energia utiliza equações diferenciais parciais para modelar propriedades $A_1, \dots, A_n$ de um modelo e encontrar as funções $u_1(x), \dots, u_n(x)$ que consigam minimizar a energia final gerada pela adição das propriedades do modelo. Cada propriedade A é definida através de termos de penalização, onde cada termo produz grandes valores de energia quando alguma propriedade A não for satisfeita e baixos valores para os casos contrários.

$$E(u_1(x), \dots, u_n(x)) = \int_{\Omega} (A_1 + \dots + A_n) dx \quad (2.5)$$

Pela soma dos valores de energia das propriedades tem-se o valor da energia funcional, onde quanto menor o valor de E , melhor é a aproximação das funções u e consequentemente, melhor é a formalização do modelo com base na equação funcional definida. Em geral em segmentação de imagens os penalizadores são baseados na seguinte equação funcional:

$$E(u) = \int_{\Omega} ((u - I)^2 + \alpha |\delta u|^2) dx \quad (2.6)$$

onde: o primeiro termo penaliza as diferenças do resultado u em relação a imagem I , o segundo termo penaliza as diferenças de suavidade na região do segmento e a constante α controla a importância do segundo termo em relação ao primeiro. A ideia do MS (Mumford, D. and Shah, J., 1985)(Mumford, D. and Shah, J., 1989) foi a de utilizar uma funcional que preze pela suave aproximação dos segmentos Ω e ao mesmo tempo separe os segmentos através de um conjunto de fronteiras qualitativas K , para os segmentos não suaves. A formalização deste modelo é a energia funcional $E(u, K)$, tendo como base a equação 2.6, composta de três termos:

$$E(u, K) = \beta \int_{\Omega} (u - I)^2 + \int_{\frac{\Omega}{K}} |\delta u|^2 dx + \lambda \int_K d\sigma \quad (2.7)$$

onde: u é uma função aplicável em cada peça Ω_i , mas não aplicável a todo domínio. Os termos da equação 2.7 podem ser decompostos em:

- O primeiro termo força a aproximação do resultado u para a imagem I ;
- O segundo termo computa e controla a suavidade interna de u em subconjuntos abertos e conectados Ω_i de $\frac{\Omega}{K}$ em um domínio planar;
- O terceiro termo controla o comprimento, a suavidade, a locação e a parcimônia das fronteiras K .
- Os coeficientes β e λ são coeficientes que controlam, respectivamente, a aproximação de I por u , referindo-se à escala, e a regularização de contraste o qual controla o comprimento das fronteiras.

Com base na equação 2.7 apresenta-se uma simplificação da mesma, a qual se mantém em pleno acordo com as suposições originais, para o contexto de segmentação de imagens. Essa simplificação é possível dado que quando $\lambda \rightarrow \infty$, o que requer que u seja *picewise* constante em cada função derivável em Ω_i de Ω . Logo $|\delta u|^2 = 0$, sendo um problema de partição mínima (Mumford, D. and Shah, J., 1989) denominado limite de *cartoon*. A equação simplificada é então definida:

$$E(u, K) = \beta \int_{\Omega_i} (u_i - I)^2 + \lambda \int_K d\sigma \quad (2.8)$$

resultando em uma aproximação constante em u das fronteiras K . Neste caso, devido à penalização quadrática que uma região Ω_i é submetida, u_i colapsa simplesmente em valores escalares de intensidade.

O algoritmo do MS pode ser descrito nas seguintes etapas:

1. A Inicialização das estruturas simbólicas, inicializa as estruturas tais como valores de intensidade de cada região, adjacências e estimativas de custo entre fronteiras adjacentes. O resultado deste passo é a construção de uma pilha de regiões que é ordenada crescentemente pelas menores energias estimadas entre todas as regiões adjacentes.
2. Fusão entre regiões Ω_i e Ω_j que apresentam a menor energia. Depois da fusão computa-se novamente as energias dos adjacentes imediatos dos segmentos envolvidos e reordena-se a pilha de regiões.
3. Repetição do passo anterior até que se alcance o valor de número de regiões fornecido como parâmetro.

4. Como último passo, após alcançar o número de regiões informado ocorre a reconstrução das estruturas simbólicas em uma imagem resultante.

Na etapa de fusão ocorre o cálculo de energia, responsável pela parte de discriminação das regiões e definição da ordem da pilha das regiões. A nova abordagem ocorre através da inserção da métrica não linear nesta etapa, fazendo com que seja levado em consideração a seleção de um padrão proporcionado pelo usuário. Vários estudos aprofundando sobre as características deste modelo podem ser encontradas em (Mumford, D. and Shah, J., 1985) (Mumford, D. and Shah, J., 1989) (BROX, 2005) (BROX; CREMERS, 2009).

2.5.4 Teoria de grafos

Os métodos de segmentação utilizando grafos como estrutura para representar as imagens têm se tornado bastante comum. Estes métodos inicialmente utilizam a ideia de representar a imagem na forma de um grafo. Remetendo a definição de grafo o qual é definido como um conjunto não-vazio de nós (vértices) e um conjunto de arcos (arestas) tais que cada arco conecta dois nós. E, com base nesta representação da imagem em forma de grafo, utilizam-se técnicas frequentemente utilizadas na teoria de grafos, como por exemplo corte em grafos, afim de se obter a segmentação da imagem.

Um exemplo de algoritmo de segmentação utilizando a teoria de grafo é o *Felzenszwalb and Huttenlocher* (FH). O FH foi utilizado neste estudo com algoritmos de segmentação associado a uma métrica não linear devido a sua rapidez e a frequente presença na literatura quando fala-se em algoritmos de segmentação com enfoque na teoria de grafos. O FH será explicado de forma mais detalhada no item subsequente.

2.5.4.1 Felzenszwalb and Huttenlocher

O algoritmo de segmentação utilizando grafo, denominado *Felzenszwalb and Huttenlocher* (FH) (PENG; ZHANG; ZHANG, 2013), proposto em (FELZENSZWALB; HUTTENLOCHER, 2004a), tem como base um predicado para medir os limites entre duas regiões, utilizando um grafo para a representação da imagem. Com base na definição de grafo, defini-se a imagem como um grafo $G = (V, A)$ não direcionado com vértices $v_i \in V$ sendo o conjunto de elementos a ser segmentado e as arestas $(v_i, v_j) \in A$ correspondendo o par de vértices vizinhos. Cada aresta $(v_i, v_j) \in A$ possui um peso não negativo $w(v_i, v_j)$ correspondente a medida de dissimilaridade entre dois

elementos vizinhos v_i e v_j . No caso de imagens os elementos em V são os *pixels* e o peso w de uma aresta é uma medida de dissimilaridade (por exemplo, diferença de cor, textura ou outra característica local) entre dois *pixels* conectados por uma aresta.

No FH uma segmentação S é uma partição de V em componentes tal que cada componente $C \in S$ corresponde a uma componente conexa em um grafo $G' = (V, A')$ onde $A' \subseteq A$. Explicando de outra forma, toda segmentação é induzida por um subconjunto de arestas em A . Em termos de resultado de segmentação espera-se que o resultado obtido tenha arestas que conectem vértices na mesma componente conexa com pesos baixos e arestas que conectem vértices de componentes conexas diferentes com pesos maiores. Para o cálculo da medida de dissimilaridade define-se um predicado que compara a diferença entre as componentes com a diferença interna de uma componente. Para tal inicialmente se define a diferença interna de uma componente $C \subseteq V$ como sendo o maior peso da árvore de custo mínimo da componente. Isto é:

$$Int(C) = \max w(e)_{e \in MinimumSpanningTree(C,E)} \quad (2.9)$$

Para a diferença entre duas componentes $C_1, C_2 \subseteq V$ define-se como sendo o valor da aresta de menor peso que liga duas componentes. Definido formalmente pela Eq. 2.10

$$Dif(C_1, C_2) = \min w(v_i, v_j)_{v_i \in C_1, v_j \in C_2 \text{ e } (v_i, v_j) \in E} \quad (2.10)$$

O predicado definido para comparação de regiões calcula se existe alguma evidência de limites entre duas componentes através da conferência se a diferença entre as componentes $Dif(C_1, C_2)$ é relativamente maior que a diferença interna de ao menos uma das componentes, $Int(C_1)$ e $Int(C_2)$. Logo o predicado fica definido como:

$$D = \begin{cases} true & \text{se } Dif(C_1, C_2) > MInt(C_1, C_2) \\ false & \text{caso contrário} \end{cases} \quad (2.11)$$

Onde a mínima diferença interna, $MInt$, é definida por:

$$MInt(C_1, C_2) = \min (Int(C_1) + \tau(C_1), Int(C_2) + \tau(C_2)) \quad (2.12)$$

De tal forma que o τ é a uma função de *threshold* que é utilizada para controlar o grau para o qual a diferença entre as componentes deve ser maior que a diferença interna. A função τ é definida por:

$$\tau(C) = \frac{k}{|C|} \quad (2.13)$$

onde:

- $|C|$ é o tamanho da componente C .
- k um parâmetro constante.

Uma vantagem desta função de *threshold* é o fato que se pode alterar a função para escolher componentes de certos formatos sem alterar o algoritmo. Isto é possível através da definição de um τ que seja maior para componentes que não se encaixem em um formato desejado.

Com base no predicado e na representação de grafo $G = (V, A)$ com m arestas, pode-se resumir a abordagem do algoritmo proposto em 3 passos fundamentais gerando um resultado de segmentação $S = (C_1, \dots, C_r)$:

1. Ordenação das arestas em A pelos pesos em ordem crescente obtendo $T = o_1, \dots, o_m$.
2. Inicialização do resultado da segmentação S como se cada vértice v_i fosse o seu próprio componente.
3. Construção do resultado da segmentação S^q dado um S^{q-1} da seguinte forma. Assuma que v_i e v_j denotam vértices conectados pela q -ésima aresta na ordem, isto é, $o_q = (v_i, v_j)$. Se v_i e v_j estão em componentes disjuntas de S^{q-1} e $w(o_q)$ é pequeno se comparado a diferença interna das duas componentes, então se junta as duas componentes, caso contrário nada é feito. No final das m iterações retorna-se o S^m referente ao resultado da segmentação.

Na etapa de construção e agrupamento das componentes conexas, o controle de agrupamento possui a responsabilidade pelo resultado final. A abordagem proposta neste estudo tem como principal característica a modificação desta etapa do algoritmo que, assim como nos outros dois métodos de segmentação utilizados, se resume na inserção da métrica não linear. Uma análise detalhada do algoritmo pode ser encontrada em (FELZENSZWALB; HUTTENLOCHER, 2004a), onde propriedades, características e resultados obtidos pelo mesmo são explanadas com maior detalhamento.

2.6 ÍNDICE RAND

Com o intuito de avaliar um método para a área de segmentação de imagens e evitar a análise subjetiva utilizam-se mecanismos de validação. Um destes mecanismos é a validação baseada em *Ground Truth* (GT). Esta forma de validação é uma técnica a qual compara o resultado de segmentação obtido

pelo algoritmo sendo avaliado com as segmentações realizadas manualmente por avaliadores, o GT, resultando em um valor ou índice de similaridade entre o GT e o resultado do algoritmo. A figura 8 mostra o exemplo de um GT extraído de uma imagem. Na imagem do GT as linhas brancas representam o resultado da média dos resultados das segmentações realizadas manualmente por avaliadores. Existem diferentes métodos para validação por GT, alguns exemplos são: Rand (RAND, 1971), Fowlkes-Mallows (FOWLKES; MALLOWS, 1983), Jaccard (BEN-HUR; ELISSEFF; GUYON, 2002) e Dongen (DONGEN, 2000). A escolha pelo uso do Rand como método de análise dos resultados tem como base experimentos realizados anteriormente com outros métodos de análise GT (SOBIERANSKI; COMUNELLO; WANGENHEIM, 2011). Nestes experimentos a avaliação obtida utilizando Rand demonstrou ser mais coerente que os outros métodos de GT citados. O Rand será descrito de forma mais detalhada na seção seguinte.




Figura 8: Figura mostrando, respectivamente, a imagem original e seu GT.

O Algoritmo Rand retorna uma análise comparativa entre duas imagens, resultando em um valor que varia de 0 até 1, onde quanto mais próximo de 0 é o valor retornado, maior a similaridade do resultado de segmentação obtido com a segmentação realizada de forma manual. O índice Rand trabalha com os segmentos da imagem como se estes fossem *clusters* calculando a similaridade entre eles. A motivação para o uso dos segmentos como *clusters* tem como base três principais considerações. Primeiro, clusterização é discreta o que significa que um ponto é sem erro atribuído a um *cluster* em específico. Segundo, *clusters* são definidos ao mesmo tempo pelos pontos dentro e fora do *cluster*. Terceiro aspecto, todos os pontos dentro do *cluster* possuem o mesmo peso na definição do *cluster*.

3 REVISÃO DA LITERATURA

Com a finalidade de revisar os algoritmos de segmentação de imagens que possuam um aspecto de não linearidade, uma revisão sistemática da literatura foi realizada seguindo os procedimentos descritos em (KITCHENHAM, 2004). Com base em (KITCHENHAM, 2004) definiu-se a pergunta de pesquisa, **Qual o efeito da inserção de uma métrica de similaridade não linear em algoritmos de segmentação?**, a qual teve como foco algoritmos de segmentação de imagens que utilizem aspectos de não linearidade. A pesquisa inicial foi realizada em janeiro de 2013 e foram examinados todos os artigos escritos em inglês que mostravam melhorias em algoritmos de segmentação de imagem publicados entre 2002 e 2012. Duas bases de artigos científicos foram utilizadas IEEE e ScienceDirect com as seguintes chaves de busca: **ScienceDirect:** *pub-date > 2001 and pub-date < 2013 and (Image Segmentation) and (nonlinear) AND LIMIT-TO(topics, "image segmentation")* **IEEE:** *Content Type: Conference Publications, Journals & Magazines Topic: Computing & Processing (Hardware/Software). Publication Year: 2002-2012.*

Obteve-se um total de 172 artigos que foram analisados suas palavras chaves eliminando artigos que não continham segmentação de imagens, obtendo um total de 132 artigos. Destes foram lidos os *abstracts* eliminando todos os artigos que não mencionavam melhorias nos algoritmos de segmentação, apenas utilizando-os como um estágio intermediário ou aplicando em determinado problema, resultando um total de 62 de artigos que foram lidos na íntegra e categorizados segundo a técnica básica utilizada.

3.1 EXTRAÇÃO DE DADOS

Na revisão sistemática descrita anteriormente foram identificados 10 métodos básicos utilizados e as modificações propostas para cada técnica. Estes métodos e modificações estão listados na tabela 1. A tabela está montada de forma a manter a referência ao artigo, o qual propõe a modificação à técnica, isto é, tem-se na primeira coluna a técnica, na segunda coluna a modificação proposta separada por “;” e a referência ao artigo também separado por “;” de forma a ser possível rastrear o artigo o qual propõe a modificação salientada.

3.2 ANÁLISE DOS RESULTADOS

Nos 10 métodos básicos identificados, as modificações propostas dizem respeito ao aprimoramento da métrica de similaridade, mudanças na estrutura utilizada, simplificações na representação da imagem, combinação entre algoritmos de segmentação e mudanças na descrição do modelo utilizado. A maior parte dos artigos analisados propõe modificações para os métodos de clusterização, segmentação baseada em grafos e segmentação por crescimento de regiões. Nestes, as modificações propostas priorizam o uso de outros algoritmos de segmentação associados com a técnica básica, funções de minimização, cálculo de entropia, uso de outras informações da imagem, isto é, uso de textura, modificações do espaço de cor e uso de filtros.

3.3 TRABALHOS CORRELATOS

A abordagem proposta em (PRASAD; SKOURIKHINE, 2006) descreve o passo a passo do algoritmo proposto, o qual transforma a imagem composta de *pixels* em uma imagem segmentada descrita através de vetores. Para tal são realizados os seguintes passos: sobre a imagem de entrada, aplica-se um algoritmo de detecção de contorno, por exemplo Canny (CANNY, 1986), seguido pela obtenção dos atributos dos traços de contorno. Depois com base nestes conjunto de traços de contorno aplica-se a triangulação de Delaunay (GOODMAN; O'ROURKE, 1997) para obter uma lista de triângulos denominado *trixels* formando um mosaico das regiões entre os contornos. O próximo passo é a estimativa média da cor dos triângulos através da amostragem de Monte Carlo. Então extrai-se as bordas dos *trixels* que pertencem simultaneamente a dois *trixels*. Depois monta-se vetores booleanos das propriedades de borda caracterizando a relação entre as bordas dos *trixels*, contornos e cores. Próximo passo é a construção de um vetor de agrupamento de *trixels* que determina quais bordas são mantidas e quais são excluídas com base no percentual das propriedades que possuem ou faltam. Monta-se um grafo com os vértices representando os *trixels* e as arestas representando a existência de uma borda compartilhada pelos *trixels* a qual foi excluída. Então é feita a rotulação de *trixels* pertencentes a mesma componente conexa do grafo com um número de componentes em comum. Por fim consolidam-se os *trixels* que possuem um número de componentes em comum atribuindo a cor média dos *trixels* em cada componente para todos os *trixels* na componente e extrai-se os contornos dos polígonos que formam cada componente formando a segmentação resultante. Os resultados mostrados derivam da aplicação do método em imagens naturais. O artigo mos-

tra ainda que o trabalho está em desenvolvimento buscando uma forma de avaliação qualitativa dos resultados obtidos pela abordagem proposta.

Em (SZCZYPIŃSKI et al., 2012) é apresentado um algoritmo de segmentação o qual tem como base as características de cor e textura demonstrando sua aplicação em imagens provenientes de vídeos de endoscopia e comparando os resultados obtidos com outro algoritmo, o *Support Vector Machine* (SVM). O algoritmo desenvolvido denominado *Vector Supported Convex Hull* é essencialmente um método discriminante de análise de aprendizagem supervisionada para redução de dimensão de vetores e classificação de dados. Os dados de entrada consistem de dois conjuntos de vetores de características em um espaço n -dimensional. O primeiro conjunto representa as imagens de uma patologia e o segundo conjunto representa as imagens sem patologia. Um subespaço k -dimensional ($k < n$) é procurado tal que os vetores do conjunto um formem um *cluster* cercado por vetores do conjunto dois. Para cada subespaço o *convex hull*, menor espaço convexo contendo um conjunto de pontos, dos vetores pertencentes a primeira classe ou conjunto é computado. Então se conta o número de vetores da segunda classe incluso pelo *convex hull*. O subespaço com o menor número desses vetores é selecionado, no caso de se obter mais de um subespaço com menor número desses vetores o *convex hull* é ampliado de forma máxima em torno de seu centróide para não incluir nenhum vetor adicional da segunda classe. O fator de escala é computado e o subespaço com maior valor é selecionado. Por fim o algoritmo procura o subconjunto de características com base no subespaço selecionado e as utiliza para fazer as regras para a classificação. Os resultados são mostrados em imagens de endoscopias e comparados com o SVM de forma visual e quantitativa através do índice Jaccard (BEN-HUR; ELISSEEFF; GUYON, 2002).

Em (SOBIERANSKI; COMUNELLO; WANGENHEIM, 2011) é proposto um método de segmentação de imagens com base no modelo de Mumford-Shah (MS) (Mumford, D. and Shah, J., 1989) associado com uma métrica de distância a qual otimiza o modelo. Esta abordagem é separada em 2 passos. Primeiro passo é a aprendizagem da métrica de distância através de algumas características da imagem. O segundo passo é a otimização do modelo MS através do uso desta métrica. A métrica utilizada é a distância de Mahalanobis (MAHALANOBIS, 1936), mais especificamente uma evolução desta métrica, o Polinomial Mahalanobis, o qual utiliza uma alta combinação de termos polinomiais extraíndo características não lineares das distribuições. Obtendo como resultado mapas topológicos utilizados no cálculo de similaridade. A proposta é executada em diversas imagens do *dataset* de Berkeley e comparadas com outros algoritmos de forma visual e numérica mostrando melhores resultados para a técnica proposta.

Em (LIU; KU; LEUNG, 2012) é proposta a integração do método de *Total Variation Minimization*(TVM)(BLOMGREN; CHAN, 1998) dentro do algoritmo de Expectation-Maximization (EM)(BOCCIGNONE; FERRARO; NAPOLETANO, 2004) para realizar a tarefa de segmentação de imagens. Inicialmente é proposto um método variacional unificado juntando o EM e o TVM tomando vantagem das duas abordagens. A ideia de junção é baseada no operador de troca e otimização. Depois é utilizado um método de separação em duas fases. Na primeira fase aplica-se o EM classificando inicialmente os *pixels* com base nas medidas de similaridade. Esta primeira classificação é provisória dado que nenhuma informação geométrica foi levada em consideração. Na segunda parte aplica-se o TVM diretamente no resultado obtido pela aplicação do EM, obtendo um refinamento e uma melhor classificação dos *pixels*. Mostram-se, além de uma descrição dos passos do algoritmo, os resultados obtidos em imagens naturais e sintéticas e uma pequena comparação contra um algoritmo de Expectation-Maximization através de um índice de precisão da segmentação

Na abordagem proposta em (PAN et al., 2012) é apresentado um modelo para segmentação de imagens com base em atenção visual simulada através de aprendizagem por amostragem. No estágio de amostragem dois tipos de atenção visual são utilizadas (*top-down* e *bottom-up*), juntamente com a simulação do movimento dos olhos, resultando em um foco em poucas regiões de interesse as quais possuem um alto valor de gradiente gerando conjuntos de treinamento. Estes conjuntos servem de entrada para o treinamento do *Support Vector Machine* (SVM) (XUHAIXIANG; CAOWANHUA; CHENWEI, 2008) que por fim classifica os *pixels*. Os resultados obtidos vem da aplicação do mesmo em imagens para identificação de leucócitos e são comparados com algoritmos baseados em Watershed(VINCENT; SOILLE, 1991) e Scale-Space Filter(CARLOTTO, 1987) através de quatro medidas de erro: *Over-Segmentation Rate*, *Under-Segmentation Rate*, *overall Error Rate* e *Relative Distance Error*, proposta por (YANG-MAO; CHAN; CHU, 2008).

Com base na utilização da estrutura de árvore para a representação da imagem, é apresentado em (GRAU et al., 2004) um algoritmo de segmentação de imagens. Nesta representação as regiões da imagem são atribuídas para os nodos da árvore, seguido por um processo de correspondência com uma árvore modelo, a qual possui um conhecimento prévio sobre as imagens. Para o processo de correspondência, propõe-se um algoritmo de minimização de uma função de erro que quantifica a diferença entre árvore derivada da imagem de entrada e a árvore modelo. O artigo propõe também um algoritmo para o cálculo da árvore modelo partindo de um conjunto de imagens segmentadas. Os resultados do método são apresentados em imagens sintéticas e imagens de ressonância magnética do cérebro e a qualidade dos resultados

foi avaliada através do índice de similaridade definido em (ZIJDENBOS et al., 1994), não há comparação contra outros métodos.

Em (BHANU; FONDER, 2004) é mostrado um algoritmo de segmentação no qual o usuário define um conjunto de exemplos e contra exemplos e, por meio do uso de um algoritmo genético, o algoritmo proposto aprende o subconjunto apropriado e a coleção de funções discriminantes de combinação espacial associada as características da imagem. Primeiramente o algoritmo genético codifica as funções discriminantes em uma representação de modelo funcional, o qual pode ser aplicado na imagem de entrada para produzir segmentações candidatas. A performance de cada segmentação candidata é avaliada pelo algoritmo genético através da comparação de dois métodos básicos de crescimento de regiões e detecção de bordas. Através do processo de segmentação, avaliação e recombinação o algoritmo genético obtém a forma do modelo funcional. Os resultados obtidos pela abordagem foram da aplicação do método em imagens de radar (*Synthetic Aperture Radar*).

Na abordagem apresentada em (NAKIB; OULHADJ; SIARRY, 2008) é proposto o uso de otimização de múltiplos objetivos afim de encontrar o *threshold* ótimo para dois critérios, critério interno da classe e o critério da probabilidade global do erro. Utiliza para tal o método denominado *Combination of Segmentation Objectives* (CSO). Na primeira fase, com base na descrição da imagem na forma de histograma, um algoritmo para encontrar picos em histogramas é utilizado. Na segunda fase o histograma é adaptado para uma soma de curvas gaussianas com a finalidade de encontrar o primeiro critério de segmentação (critério interno da classe). O segundo critério considerado, a homogeneidade é calculada para cada pixel, informações local e global são consideradas neste passo. A terceira e última fase consiste em aplicar o processo de *thresholding* pela otimização da função de múltiplos objetivos, para tal é utilizada a técnica de *Simulated Annealing* (P. et al., 1997). Os resultados obtidos são da aplicação do método em algumas imagens reais.

Em são propostas adaptações ao algoritmo de segmentação denominado *Constraint Satisfaction Neural Networks* (CSNN) (LIN; TSAO; CHEN, 1992). São propostas 4 novas abordagens para adaptação do CSNN: *Boundary CSNN* (B-CSNN), *Multiscan CSNN* (MS-CSNN), *Pyramidal CSNN* (P-CSNN) e *Markov Random Field CSNN* (MRF-CSNN). B-CSNN: Utiliza *Canny Edge Detector* (CANNY, 1986) para guiar a segmentação. Com esta restrição de bordas o número de iterações e o erro de convergência são reduzidos drasticamente. MS-CSNN: utiliza o mesmo processo de estruturação e dinâmica proposto para o CSNN, mas o padrão de escaneamento bem como o processo de atualização são alterados. O algoritmo começa com amostra de *pixels* mais esparsas, mas que possuem maiores vizinhanças, o que leva a rótulos mais confiáveis. Em cada ciclo subsequente de escaneamento os

pixels são visitados em um crescente padrão, mas com menores vizinhanças. Os *pixels* previamente visitados são deixados intactos, mas contribuem para a atualização dos novos *pixels* na vizinhança. A medida que cada padrão escaneado converge, muda-se para o próximo padrão escaneado. Com esta metodologia evita-se iterações inúteis tendo em vista que os *pixels* visitados nos primeiros estágios não são alterados nos estágios posteriores acelerando o processo. P-CSNN: visa fornecer segmentação em diferentes escalas. Usa uma estrutura com base em uma estrutura piramidal em que em cada nível de resolução da pirâmide consiste de uma imagem rotulada diferente construindo uma estrutura de dependência em que um pixel pai nos níveis superiores está relacionado com os *pixels* filhos no níveis inferiores. Uma votação entre os *pixels* filhos é feita e o segmento máximo encontrado é atribuído ao pixel pai. Quando o algoritmo converge a uma solução respeitando as restrições em cada nível o resultado da segmentação é o estado da base da pirâmide. MRF-CSNN: associa a estrutura do CSNN com a ideia do MRF, alterando o esquema de atualização dos neurônios. Mostra-se entre todas as abordagens descritas ser o melhor tanto em resultado de segmentação quanto em velocidade de convergência. Os resultados das propostas (com exceção da P-CSNN) são mostrados de forma qualitativa e quantitativa em imagens sintéticas e imagens de *datasets*.

A Abordagem proposta em (HAHN; LEE, 2010) propõe um algoritmo de segmentação de imagens com base na detecção do contorno de objetos. Para tal utiliza *Geometric Attraction-Driven Flow* (GADF), *Binary Edge Function*, e *Binary Balloon Forces* para realizar a detecção em casos de formatos complexos e variação de luminosidade. Inicialmente se utiliza o GADF para representar o limite dos objetos na imagem. Depois se utiliza a propriedade de orientação proveniente do GADF e o *Binary Edge Function* para reduzir a interferência de outras forças e por fim se faz o uso do *Binary Ballon Forces* associado com o teorema das quatro cores (ROBERTSON et al., 1997). O objetivo do *Binary Ballon Forces* é mover os contornos iniciais em direção ao limite dos contornos dos objetos, indiferente da posição dos contornos, que associado com as funções dos níveis iniciais resolve problemas topológicos tais como detecção de buracos ou múltiplas junções e dependência das posições iniciais dos contornos. Os resultados da aplicação do método em imagens reais foram comparadas com outros métodos de forma visual.

3.4 CONSIDERAÇÕES SOBRE O CAPÍTULO

De forma geral os trabalhos correlatos apresentam limitações. Um exemplo é o uso do método proposto em apenas uma determinada área, mostrando a aplicação do algoritmo para um nicho em específico. Esta limitação ocasiona a não demonstração do potencial do método como um método de segmentação, não se tendo uma evidência da possibilidade de generalização do método. Outras limitações são: a ausência de validação contra um padrão ouro, a não comparação contra outros métodos ou quando há a comparação utilizam comparação de forma visual, sem uma avaliação quantitativa. E, para os trabalhos que mostram um avaliação quantitativa, não há um estudo empírico para comprovar a melhoria efetiva do método.

Tabela 1: Técnicas básicas e suas adaptações

Técnica básica	Alterações acrescentadas	Referências
Descrição de um novo modelo	Modelo de regularizadores não convexos com divisão e rebalanceamento iterativo; Equação de Allen-Cahn; Simulated visual attention e SVM; Equações diferenciais parciais e função de cálculo de energia;	(HAN; WANG; FENG, 2012); (LI; KIM, 2011); (PAN et al., 2012);(DONG; POLLAK, 2006)
Maximização e expectativa	Pirâmides gaussianas e difusão; <i>Total Variational Minimization</i> ;	(BOCCIGNONE et al., 2007);(LIU; KU; LEUNG, 2012)
Segmentação em grafo	Triangulação de Delaunay; Técnica gulosa de HCF; Simplificação da representação; Teoria de quatro cores e corte em grafos; PCA e algoritmo aglomerativo; Melhoria na representação do grafo associado com a técnica de <i>Random Walk</i> ; Montagem do grafo inicial com Watershed e distância de Mahalanobis e segmenta com <i>Vertex-Collapse</i> ; Watershed para a representação do grafo e associa um processo iterativo de fusão e suavização; Técnica de corte e grafo associado a textura; Watershed multi-escala para estrutura inicial associado com a teoria de corte em grafos; Watershed com teoria de grafos;	(PRASAD; SKOURIKHINE, 2006); (LUO; GUO, 2003); (TA et al., 2009); (LIU; TAO, 2011); (DUPUIS; VASSEUR, 2006); (DAKUA; ABINAHED, 2013); (QIMIN; YUNDE, 2004); (LEZORAY; ELMOATAZ, 2003); (HAN et al., 2009); (VANHAMEL; PRATIKAKIS; SAHLI, 2006); (VANHAMEL; SAHLI; PRATIKAKIS, 2006)
Segmentação em árvore	Minimização de função de erro; Level set e <i>adaptive operator splitting</i> ;	(GRAU et al., 2004); (JEON et al., 2005)
Segmentação baseada em bordas	<i>Geometric attraction-driven flow</i> , <i>Binary ballon</i> e <i>binary edge function</i> ; Utiliza um <i>framework(minimal description lenght)</i> associado a uma técnica de <i>active contour model</i> ; Detecção de borda associado a tensores métricos e a minimização de funções não lineares;	(HAHN; LEE, 2010);(WANG; OLIENSIS, 2010); (MAHMOODI; SHARIF, 2007);

Algoritmo genético	Crescimento de regiões e bordas;	(BHANU; FONDER, 2004)
Clusterização	FCM e Mudança dos descritores; SVM e FCM; Corte em dendrograma e minimização de função; VSCH; MRF, distribuição gaussiana, textura e espaço de cor CIE-L*u*v*; MRF com a teoria de métricas entre distribuições discretas; SVM, FCM e textura; SOM, LQV e FCM; GMM, AMS e MF <i>Meanfield Annealing</i> ; <i>Expectation-Maximization</i> ; SVM e FCM; FCM alterando para uma versão com <i>kernels</i> e adicionando uma função de penalidade; LS-SVM, <i>Arimoto entropy</i> , textura e espaço de cor HSV; Espaço de cor híbrido, Watershed e Mahalanobis; SOM, autovalores, autovetores e <i>principal curves</i> ; Detecção de bordas e regressão ortogonal; Filtro de difusão anisotrópica, histograma e filtro gaussiano; SVM e FCM; Descritores estatísticos; Aprendizagem de múltiplos pontos de vista associado a um processo não linear de classificação; KPCA associado com K-means e GMM; SVM com base em <i>kernels</i> ; Espaço de cor CIELab, com as métodos de <i>level-set</i> , <i>fusion</i> e a técnica de clusterização(GMM, Kmeans, SOM e FCM);Utiliza MDS técnica associado a textura; Aplicação de dois <i>Mean Shift</i> com uso de pesos;	(CAI; CHEN; ZHANG, 2007) (WANG; WANG; BU, 2011) (TUIA; MARÍ; CAMPS-VALLS, 2012); (SZCZYPIŃSKI et al., 2012); (KATO; PONG, 2006); (DALMAU; RIVERA, 2011); (WANG et al., 2012); (BELKASIM et al., 2008); (PARK; LEE; PARK, 2009); (WANG et al., 2011); (ZHANG; CHEN, 2004); (YANG et al., 2012); (ZHAO et al., 2003); (WE-SOLKOWSKI, 2002); (LINGER, 2011); (BAKALEXIS; BOUTALIS; MERTZIOS, 2002); (JUANG; CHIU; SHIU, 2007); (KUSKA et al., 2006); (DING; YILMAZ; YAN, 2012); (LI et al., 2005); (BERTELLI et al., 2011); (EMAM-BAKHSH; SEDAAGHI; EBRAHIM-NEZHAD, 2009); (MIGNOTTE, 2011); (BACKHOUSE; GU; WANG, 2007);

Crescimento em regiões	Múltiplos <i>threshold</i> , textura e <i>level set</i> ; Método de mistura determinística e monte carlo; Mumford-Shah com distância de Mahalanobis; Watershed com vetor gradiente e espaço de cor L^*a^*b ; Watershed associado a lógica <i>fuzzy</i> e ajuste nas características extraídas; Watershed dividido em 2 módulos um para medida de saliência e outro para organização da hierarquia; Simplificação da imagem para posterior aplicação do Watershed; Três técnicas de segmentação associadas com uma métrica de similaridade não linear;	(DU; CHO; BUI, 2011); (CREVIER, 2008); (SOBIERANSKI; COMUNELLO; WANGENHEIM, 2011); (YUAN; BARNER, 2006); (CHANG; SHIE; WANG, 2002); (VANHAMEL; PRATIKAKIS; SAHLI, 2003); (YOO; DINH; LEE, 2007); Esta dissertação ;
<i>Thresholding</i> ou Limiarização	Otimização de função, soma de curvas gaussianas e histogramas; MBF, entropia e variância entre classes; Múltiplos níveis de <i>thresholding</i> associado com cálculo de entropia; Programação genética para <i>thresholding</i> de múltiplos níveis;	(NAKIB; OULHADJ; SIARRY, 2008); (SATHYA; KAYALVIZHI, 2011); (QUWEIDER, 2010); (HONG-GUI; RANG-LIANG; ZHENG-RONG, 2009);
Redes Neurais	<i>Constraint Satisfaction Neural Networks</i> com abordagens utilizando borda, mudanças na parte de atualização, múltiplas escalas e MRF; Simplificação da <i>Pulse Coupled Neural Network</i> associado ao cálculo de entropia; <i>Stationary Wavelet Transform</i> , SOM e LVQ; <i>Wavelet decomposition</i> associado com SOM;	(KURUGOLLU; SANKUR; HARMANCI, 2002); (WEI; HONG; HOU, 2011); (DEMIRHAN; GÜLER, 2011); (ZHANG; DENG, 2010)

4 DESENVOLVIMENTO DOS MÉTODOS DE SEGMENTAÇÃO COM A MÉTRICA NÃO LINEAR

O desenvolvimento dos métodos de segmentação associados a métrica não linear iniciou com as modificações nos algoritmos selecionados, para inserir a métrica não linear à já existente estrutura dos algoritmos. Inicialmente, uma análise foi realizada nos algoritmos selecionados, identificando o lugar de inserção da métrica não linear. Depois a adaptação e a inserção da métrica foi realizada. Como último passo, obtiveram-se os resultados provenientes dos experimentos conduzidos de forma a prover um contexto de validação e comparação entre os métodos. Neste capítulo será descrita toda a parte de desenvolvimento envolvendo a métrica não linear e os algoritmos de segmentação selecionados, incluindo uma visão geral do funcionamento do algoritmo com o aprimoramento proposto.

4.1 WEIGHTED COLOR STRUCTURE CODE

Para o desenvolvimento do *Weighted Color Structure Code* (WCSC) foi analisado o código do CSC (PRIESE; STURM,) e realizada uma modificação na função de similaridade. O CSC utiliza um critério de variabilidade local para o cálculo da similaridade, usando a Distância Euclidiana (**DE**) para este propósito. No nível zero da hierarquia, calcula-se a distância Euclidiana entre *pixels* e para os níveis superiores calcula-se a distância Euclidiana entre as média dos segmentos sendo comparados. O WCSC, emprega o uso do Polinomial Mahalanobis (**PM**), fazendo o uso de um conjunto de *pixels* selecionados da imagem para construir o centro do espaço de similaridade, com o intuito de obter a matriz de covariância e a matriz de valores médios. O padrão selecionado utilizado na supervisão da segmentação é previamente preparado e é considerado um parâmetro de entrada do algoritmo. Após o treinamento com o padrão de entrada calcula-se a similaridade entre o padrão selecionado e o segmento sendo analisado. Este valor de similaridade é utilizado como peso no cálculo da Distância Euclidiana Ponderada (**DEP**), decidindo se os segmentos sendo analisados devem ser unidos ou não. A figura 9 demonstra duas das entradas do WCSC (imagem de entrada e o padrão selecionado) e a saída (a segmentação resultante).

Outro importante fator do CSC e WCSC são as variações dos parâmetros de entrada, *threshold* (**th**) e contraste (**c**). O *threshold* determina o limite da similaridade para um segmento ser conectado ou não a outro segmento e pode variar de 0 até $+\infty$. O contraste, utilizado apenas no WCSC, determina



Figura 9: Ilustração mostrando respectivamente imagem de entrada, padrão selecionado e resultado da execução do WCSC.

ção delimitada as curvas de níveis referente ao treinamento do **PM** com o padrão selecionado serão e pode variar de 0 até $-\infty$. Nos testes executados os parâmetros **th** e o **c** foram obtidos pela comparação dos resultados do WCSC com os resultados do CSC utilizando o parâmetro **th** com a mesma variação para ambas as métodos. Nos testes realizados foram utilizados valores de 15 a 55 para a *threshold* e de -0,01 até -1 para contraste.

A figura 10 ilustra o procedimento executado pela função de similaridade descrita a seguir. O primeiro passo é o cálculo da **DE** entre os segmentos **A** e **B** (**B** é o segmento sendo testado). Se a distância for menor que o **th** informado, os dois segmentos são conectados. Caso contrário, o segmento **B** será analisado conferindo sua **DEP** em relação ao segmento **A** com o valor resultante do **PM** do segmento **B** e o padrão **P** sendo utilizado como valor de ponderação. Com o valor de **DEP** obtido, testa-se se o valor obtido é menor que o **th**, conferindo se os segmentos podem ser conectados, em caso negativo os segmentos não são conectados ou, em alguns casos, devem ser separados. A seleção do melhor resultado e dos parâmetros mais indicados para cada imagem ocorreu através da análise de *ground truth* e serão melhor explorados no capítulo de resultados. Uma explicação com mais detalhes do método pode ser encontrado em (CARVALHO et al., 2014)

4.2 SUPERVISED MUMFORD-SHAH

Com base na função simplificada de Mumford-Shah apresentada no capítulo 3, Eq. 2.8, associado ao conhecimento prévio extraído da imagem de interesse (abordagem supervisionada) mostra-se o *Supervised Mumford-Shah* (SMS). Esta abordagem proposta em (SOBIERANSKI; COMUNELLO; WANGENHEIM, 2011) utiliza as informações de um padrão extraído da imagem para melhor orientar o processo de segmentação por crescimento de regiões, realizado pelo MS, através da inserção deste conhecimento sobre a imagem por meio do uso do Polinomial Mahalanobis. A figura 11 mostra a imagem




Figura 10: Fluxograma do WCSC, ilustrando a função de similaridade utilizada.

de entrada, o padrão selecionado e o resultado da utilização do SMS. Com o uso desta métrica e da equação simplificada Eq. 2.8 o modelo supervisionado proposto pode ser descrito pela seguinte função $E(u, K)$:

$$E(u, K) = \lambda \leq \frac{|\Omega_i| \cdot |\Omega_j|}{|\Omega_i| + |\Omega_j|} \cdot \frac{\delta(u_i, u_j)}{K} \cdot \phi \quad (4.1)$$

onde:

- λ - Parâmetro de escala que controla a quantidade de agrupamento que uma imagem de entrada I será submetida;
- $\frac{|\Omega_i| \cdot |\Omega_j|}{|\Omega_i| + |\Omega_j|}$ é o termo β regularizador de área descrito na equação inicial do MS. Sua característica de crescimento exponencial faz com regiões grandes mantenham a característica de absorver regiões pequenas, dependendo do critério de similaridade entre vetores de cores;
- $\delta(u_i, u_j)$ verifica a similaridade entre os vetores u_i e u_j médios das regiões Ω_i e Ω_j no polinômio de Mahalanobis sob uma ordem q . Como

este termo é baseado no mapa topológico $\mathbf{M}$, mesmo regiões que apresentem resistência à fusão devido à grandes escalares β tendem a serem agrupadas caso exista similaridade no mapa;

- ϕ é um escalar ≥ 0 que penaliza a equação segundo um método de equivalência de fronteira, que objetiva mensurar divergências entre duas distribuições multivariadas no mapa topológico $\mathbf{M}$. Este termo atua penalizando a equação, tentando equilibrar o agrupamento das regiões no sentido de convergir para S (conjunto de treinamento).



Figura 11: Ilustração mostrando respectivamente imagem de entrada, padrão selecionado e resultado da execução do SMS.

A Figura 12 ilustra o procedimento executado pela função de similaridade descrita a seguir. Primeiro calcula-se a distância entre as regiões adjacentes que serão agrupadas Ω_i e Ω_j utilizando para tal a média interna de cada região (u_i e u_j), o mapa topológico $\mathbf{M}$, proveniente do treinamento com o padrão da imagem selecionado e um valor de contraste (c). Com o resultado do cálculo de similaridade entre as regiões adjacentes Ω_i e Ω_j por meio do Polinomial Mahalanobis ($\mathbf{PM}$), referente ao termo $\delta(u_i, u_j)$ da equação 4.1, parte-se para o cálculo do termo regularizador de área, isto é, o β da equação 4.1. Para tal utiliza-se a quantidade de *pixels* que fazem fronteira entre as regiões Ω_i e Ω_j . Depois, calcula-se o último termo da funcional ϕ com base nas distribuições das duas regiões e por fim se obtém o valor da Eq. 4.1. Com base neste valor o algoritmo faz a atualização da pilha de segmentos adjacentes e continua neste processo de cálculo e atualização até alcançar a condição de parada informada.

Os parâmetros de entrada da abordagem proposta são a imagem, o padrão selecionado da imagem e o número de regiões. Utilizou-se a variação do número de regiões em um intervalo de 1 até 1024 e os resultados obtidos foram submetidos a validação por GT. Uma análise sobre os resultados obtidos pela abordagem está presente no capítulo de resultados.




Figura 12: Fluxograma do SMS, ilustrando a função de similaridade utilizada.

4.3 WEIGHTED FELZENSZWALB AND HUTTENLOCHER

O primeiro passo para o desenvolvimento do *Weighted Felzenszwalb and Huttenlocher* (WFH) foi o estudo do método e sua posterior análise e alteração do código fonte disponível em (FELZENSZWALB; HUTTENLOCHER, 2004b). Após a identificação da parte de controle do grau de dissimilaridade o próximo passo foi a substituição da técnica utilizada, distância Euclidiana simples, para a Distância Euclidiana Ponderada (**DEP**) usando como valor de ponderação o Polinômio Mahalanobis (**PM**). Com esta alteração foi inserida, na parte de controle do processo de segmentação, uma inferência por parte do usuário fornecendo uma abordagem que utiliza conhecimentos específicos da imagem para o algoritmo em questão. Apesar de utilizar uma abordagem similar do WCSC, ao utilizar o **DEP** associado ao **PM**, foram inseridas ao WFH duas pequenas modificações na forma como o valor de similaridade é calculado. Enquanto o WCSC utiliza o **DEP** apenas se o valor da distância Euclidiana for maior que um *threshold*, o WFH utiliza o **DEP** sempre que sua função de similaridade é utilizada.

Outra modificação esta no cálculo do fator de ponderação por meio do **PM**, no qual se leva em conta não só a similaridade do vértice **B** em relação ao padrão, mas também utiliza-se o valor de similaridade do vértice **A** para com

o padrão. Esta alteração foi realizada para potencializar a união de vértices que possuem um elevado grau de similaridade com o padrão. No início do processo de segmentação os vértices representam os *pixels* da imagem e com a evolução do processo de segmentação a estrutura como um todo representa as componentes conexas (segmentos). A figura 13 mostra a imagem de entrada, o padrão selecionado e o resultado utilizando o WFH.



Figura 13: Ilustração mostrando respectivamente imagem de entrada, padrão selecionado e resultado da execução do WFH.

A Figura 14 ilustra o procedimento executado pela função de similaridade descrita posteriormente. Primeiro, executa-se o cálculo do **PM** dos vértices **A** e **B** com padrão **P** e o contraste **c**. Com os resultados de similaridade obtidos, calcula-se a **DEP**, obtendo-se um valor **W** referente ao peso da aresta que conecta os vértices **A** e **B**. Após o cálculo do peso **W**, inicia-se o processo de montagem das componentes conexas, verificando o valor de peso das arestas com o valor de *threshold* **th** informado. Se o valor de **W** for menor que o de **th** agrupa-se os vértices **A** e **B** na mesma componente conexa e ajusta-se o peso da componente, caso contrário mantém-se o estado atual da segmentação.

Os parâmetros de entrada, além do contraste, do padrão e da imagem de entrada, para o algoritmo são:

- **sigma**: utilizado na função de suavização da imagem antes de ser segmentada;
- **k**: indicando o valor de *threshold*;
- **min**: indicando o tamanho mínimo da componente;

Os valores sugeridos para os parâmetros **sigma**, **k** e **min** são, respectivamente, 0,5, 500 e 20. Tendo como ponto de partida estes valores sugeridos, utilizou-se a variação e combinação dos parâmetros **k** e **min** até alcançarem os valores máximos de 2000 e 300, respectivamente. Estes valores máximos foram estipulados com base nos testes realizados com o algoritmo. As imagens resultantes desta busca pelos melhores parâmetros foram submetidas ao processo de validação pelo GT de forma a selecionar os melhores resultados




Figura 14: Fluxograma do WFH, ilustrando a função de similaridade utilizada.

e consequentemente os parâmetros mais apropriados dentro deste intervalo. Os resultados obtidos serão analisados no capítulo de resultados.

5 AMBIENTE E RESULTADOS EXPERIMENTAIS

Neste capítulo serão apresentados os resultados obtidos pela alteração nos métodos citados no capítulo anterior. A análise dos resultados obtidos foi realizada através de 3 experimentos. O primeiro experimento é proveniente da comparação entre o método original e o mesmo método associado a métrica não linear. O segundo experimento realiza não só a comparação entre as abordagens exploradas, mas também realiza a comparação da abordagem proposta com outros métodos de segmentação. O terceiro experimento realiza uma análise contrapondo os resultados obtidos com o tempo de execução com e sem o aprimoramento.

5.1 AMBIENTE EXPERIMENTAL

Para a realização dos experimentos um subconjunto de 60 imagens do *dataset* de Berkeley foi escolhido. Em cada uma das 60 imagens foram selecionados padrões de interesse com base em alguma característica da cena. Depois, para cada método modificado com a inserção da métrica não linear, foram gerados os resultados através em uma combinação dos parâmetros de entrada. O próximo passo correspondeu na geração de índices Rand para todas as imagens resultantes e na seleção da melhor imagem resultante, com base nos menores valores de Rand. Por fim foi realizada a análise dos melhores resultados de forma subjetiva e empírica e os resultados dessas análise serão apresentados nas seções subsequentes. Todas as imagens geradas pela combinação dos parâmetros de entrada e valores de índice Rand estão disponíveis no site <http://www.lapix.ufsc.br/wcsc/> para o WCSC, <http://www.lapix.ufsc.br/sms/> para o SMS e <http://www.lapix.ufsc.br/wfh/> para o WFH/.

5.2 EXPERIMENTO 1: COMPARAÇÃO ENTRE OS MÉTODOS E SUAS ABORDAGENS NÃO LINEARES

Com base nos resultados de segmentação obtidos, o primeiro experimento visa demonstrar através de uma análise inicialmente subjetiva e depois com base em uma análise empírica a melhoria obtida pelo aprimoramento proposto.

5.2.1 Comparação entre CSC e WCSC

Inicialmente partindo das imagens resultantes para as duas abordagens (CSC e WCSC) foram selecionadas as melhores pelo menor índice Rand e estas comparadas de forma visual. Partindo desta análise pode-se notar uma segmentação orientada ao padrão por parte do WCSC, de forma que no pareamento entre as duas abordagens mostrou melhorias nos resultados obtidos com a abordagem supervisionada. Esta característica de segmentação orientada pelo padrão pode ser melhor ilustrada na figura 15, onde uma maior quantidade de regiões similares foram agrupadas. Também foi notado que menos segmentos foram gerados no processo e uma melhor coerência dos objetos da imagem é apresentada. O fato que o plano de fundo possui mais segmentos é diretamente relacionado com o padrão selecionado, como pode ser observado na figura 15-b na primeira linha. O padrão selecionado é a estrela, gerando um resultado de segmentação onde quanto mais similar com a estrela é o segmento sendo analisado, maior a probabilidade de unir os segmentos.

Na figura 15, na linha 2 o padrão selecionado não possuiu nenhuma influência no resultado final gerando assim o mesmo resultado de segmentação para ambas as abordagens. Este fato pode ser explicado pela baixa variabilidade da distribuições dos *pixels* na imagem. Na terceira linha da mesma figura, é possível perceber que o resultado obtido pelo WCSC identifica 2 grandes segmentos e mantém o formato dos objetos. Diferentemente do resultado obtido com o CSC, onde, apesar da existência de 2 grandes segmentos, perde-se a forma do barco. O fato do barco não ser um único grande segmento no resultado do WCSC é explicado pelo padrão de interesse selecionado para esta imagem, como pode ser observado na mesma linha figura 15-b.

A quarta linha da figura 15 mostra um caso similar ao da estrela, linha 1 da mesma figura. O resultado de segmentação do WCSC mostra uma melhor segmentação do cogumelo, onde o cogumelo é segmentado como um único segmento homogêneo, fato derivado diretamente da seleção do padrão figura 15-b na mesma linha. A Figura 16 mostra alguns resultados onde WCSC associado com um padrão específico fornece melhores resultados quando comparado com o CSC, exemplificando a principal característica deste algoritmo, segmentação orientada ao padrão de selecionado. Como pode ser observado nos resultados obtidos, o padrão selecionado intensifica a geração de segmentos homogêneos, proveniente da tendência de melhor segmentar áreas que possuem alta similaridade com o mesmo.

Mais que uma comparação visual ou uma análise subjetiva dos resultados dos algoritmos, é necessário mostrar uma evidência forte sob a perfor-




Figura 15: Comparação entre os resultados obtidos com o CSC e o WCSC. (A) Imagem original, (B) Imagem com a linha branca mostrando o padrão selecionado, (C) CSC, (D) CSCW.

mance dos algoritmos. A figura 17 ilustra a análise gráfica do experimento, a qual indica uma melhor performance do WCSC em relação ao CSC.

Um teste de hipótese foi realizado nos valores médios para confirmar se a diferença entre os dois algoritmos é realmente significativa. O propósito é verificar se existe uma melhoria real no valor de dissimilaridade do índice Rand entre os dois algoritmos quando estes são comparados ao *ground truth*. Um teste pareado de hipótese unilateral com região crítica na parte superior




Figura 16: Comparação entre os resultados obtidos com o CSC e o WCSC. (A) Imagem original, (B) Imagem com a linha branca mostrando o padrão selecionado, (C) CSC, (D) CSCW.

da distribuição normal foi realizado com nível de significância $\alpha = 5\%$ comparando a diferença entre as respostas médias x_{difCSC} dos índices Rand do CSC x_1 e do WCSC x_2 :

H0: $x_{difCSC} = 0$ or $x_1 - x_2 = 0$; Os algoritmos possuem performance similar.

H1: $x_{difCSC} > 0$ or $x_1 - x_2 > 0$; O WCSC possui uma melhor performance (menor dissimilaridade).




Figura 17: Comparação do CSC e WCSC performance. (a) *boxplot* comparando o índice de dissimilaridade, índice Rand, entre CSC e o WCSC. (b) comparação pareada da sequência de imagens relacionadas com o *ground truth*.

A comparação pareada pode ser utilizada, pois dois diferentes testes estão sendo comparados com o mesmo padrão ouro (*ground truth*). O tamanho da amostra sendo utilizado é relativamente grande (>30) podendo-se assumir uma distribuição normal, resultado direto do teorema do limite central, e as amostras são consideradas independentes. Da tabela 3 é obtido o valor médio e o desvio padrão para o CSC ($x_1 = 0,15142$, $s_1 = 0,08937$) e para o WCSC ($x_2 = 0,12142$, $s_2 = 0,07302$), com uma população $n = 60$. A diferença média x_{difCSC} é calculada através da simples subtração dos valores médios, ou seja, $x_{difCSC} = x_1 - x_2$, totalizando um valor para $x_{difCSC} = 0,03$. A diferença dos desvios padrão é calculada por:

$$s_{difCSC} = \sqrt{\frac{s_1^2}{n} + \frac{s_2^2}{n}} = \sqrt{\frac{0,08937^2}{60} + \frac{0,07302^2}{60}} = 0,014899$$

A normalização do valor de x_{difCSC} pelo valor s_{difCSC} , permite uma comparação direta do seu valor de *z-score* com o valor crítico:

$$z_{difCSC} = \frac{x_{difCSC}}{s_{difCSC}} = \frac{0,03}{0,014899} = 2,013557$$

O valor crítico $z_c = 1,65$ foi obtido através de uma tabela estatística da distribuição normal (MONTGOMERY; RUNGER, 2003) para um valor acumulado igual a 0,950529. Analisando os *z-scores* da média com o valor crítico de forma que ($z_{difCSC} > z_c$), rejeita-se a hipótese nula com 95% de garantia. Em outras palavras significa dizer que o algoritmo proposto possui

uma melhor performance em relação a sua versão com métrica linear, dado que existem evidências estatísticas suficientes obtidas da amostragem realizada para apoiar esta afirmação.

5.2.2 Comparação entre MS e SMS

Com base nas imagens resultantes das duas abordagens (MS e SMS) foram selecionadas as melhores pelo menor índice Rand e estas comparadas de forma visual. Partindo desta análise pode-se notar uma melhor definição das regiões obtidas pela segmentação utilizando a abordagem não linear. Este fato está diretamente relacionado com a definição do padrão de interesse na imagem, de forma que no pareamento entre as duas abordagens percebem-se melhorias nos resultados obtidos com a abordagem supervisionada. Isto pode ser melhor ilustrado na figura 18 linha 1, onde as regiões resultantes geradas estão definidas de forma mais coerente com o resultado esperado. No caso do resultado da segmentação da estrela é perceptível a melhoria obtida com a definição da estrela como sendo o padrão de interesse, 18 linha 1-B. Na figura 18, na linha 2 pode-se visualizar que com a seleção do padrão de interesse como sendo o plano de fundo há uma melhor definição dos limites do objeto principal, fato este também encontrado no resultado da segmentação do barco, na linha 3 da mesma figura.

A quarta linha da figura 18 mostra outro caso onde a seleção do objeto de interesse, no caso o cogumelo (18 linha 4-B), gera uma melhoria no poder de simplificação da imagem gerando menos segmentos. A Figura 19 mostra mais exemplos onde o uso da abordagem com a métrica não linear resulta em uma melhor definição dos segmentos e em uma geração de resultados mais próximos ao *Ground Truth* tido como referência.

Assim como na análise do WCSC é necessário mostrar uma evidência forte sob a performance dos algoritmos. A figura ilustra a análise gráfica do experimento, a qual indica uma melhor performance do SMS em relação ao MS.

Fazendo o mesmo teste de hipótese realizado para a análise do WCSC. Monta-se um teste pareado de hipótese unilateral com região crítica na parte superior da distribuição normal, com um nível de significância $\alpha = 5\%$ comparando a diferença entre as respostas médias x_{diffMS} dos índices Rand do MS x_3 e do SMS x_4 :

H0: $x_{diffMS} = 0$ or $x_3 - x_4 = 0$; Os algoritmos possuem performance similar.

H1: $x_{diffMS} > 0$ or $x_3 - x_4 > 0$; O SMS possui uma melhor performance (menor dissimilaridade).




Figura 18: Comparação entre os resultados obtidos com o MS e o SMS. (A) Imagem original, (B) Imagem com a linha branca mostrando o padrão selecionado, (C) MS, (D) SMS.

Assim como no caso anterior a comparação pareada pode ser utilizada, dado que a quantidade de imagens utilizadas é a mesma podendo-se assumir, pelo teorema do limite central, uma distribuição normal. Da tabela com os valores de Rand para os resultados de segmentação das abordagens, tabela 4, é obtido o valor médio e o desvio padrão para o MS ($x_3 = 0,21296$, $s_3 = 0,12277$) e para o SMS ($x_4 = 0,10308$, $s_4 = 0,07562$), com uma população $n = 60$. A diferença média x_{difMS} é calculada através da simples subtração dos




Figura 19: Comparação entre os resultados obtidos com o MS e o SMS. (A) Imagem original, (B) Imagem com a linha branca mostrando o padrão selecionado, (C) MS, (D) SMS.

valores médios, ou seja, $x_{difMS} = x_3 - x_4$, totalizando um valor para $x_{difMS} = 0,10988$. A diferença dos desvios padrão é calculada por:

$$s_{difMS} = \sqrt{\frac{s_3^2}{n} + \frac{s_4^2}{n}} = \sqrt{\frac{0,12277^2}{60} + \frac{0,07562^2}{60}} = 0,0186148943$$

A normalização do valor de x_{difMS} pelo valor s_{difMS} , permite uma comparação direta do seu valor de $z-score$ com o valor crítico:




Figura 20: Comparação do MS e SMS performance. (a) *boxplot* comparando o índice de dissimilaridade, índice Rand, entre MS e o SMS. (b) comparação pareada da sequência de imagens relacionadas com o *Ground Truth*.

$$z_{difMS} = \frac{x_{difMS}}{s_{difMS}} = \frac{0,10988}{0,0186148943} = 5,902800116$$

Usando o mesmo valor crítico $z_c = 1,65$ e analisando os z -scores da média com o valor crítico, como o ($z_{difMS} < z_c$), mostra-se uma prova estatística para rejeitar a hipótese nula com 95% de garantia. Em outras palavras significa dizer que o algoritmo SMS possui uma melhor performance em relação a sua versão original, dado que existem evidências estatísticas suficientes obtidas da amostragem realizada para apoiar esta afirmação. Esta diferença estatística pode ser visualizado na forma de um gráfico no *boxplot* da figura 20-(a), na qual pode se ter uma noção visual do comparativo entre as duas abordagens e como estão distribuídos os valores de índice Rand para ambas.

5.2.3 Comparação entre FH e WFH

Assim como nas comparações anteriores, com base nas imagens resultantes das duas abordagens (FH e WFH) foram selecionadas as melhores pelo menor índice Rand e estas comparadas de forma visual. Partindo desta análise pode-se notar o mesmo comportamento encontrado na abordagem do WCSC, ou seja, obteve-se uma segmentação orientada ao padrão de forma que no pareamento entre as duas abordagens percebem-se melhorias nos resultados obtidos pela abordagem com a métrica não linear. Isto pode ser melhor ilustrado na figura 21, onde nas linhas 1, 2 e 3 são mostrados exemplos onde a

seleção do padrão gerou um número menor de segmentos e estes possuem seus limites definidos de forma mais coerente. Em contrapartida na linha 4 desta mesma imagem mostra-se um resultado onde a seleção do padrão em pouco ou nada interfere no resultado de segmentação gerando resultados semelhantes para a mesma imagem.




Figura 21: Comparação entre os resultados obtidos com o FH e o WFH. (A) Imagem original, (B) Imagem com a linha branca mostrando o padrão selecionado, (C) FH, (D) WFH.

Na Figura 22 são mostrados resultados onde o padrão selecionado gera resultados mais próximos ao padrão ouro para a abordagem que utiliza a

métrica não linear.




Figura 22: Comparação entre os resultados obtidos com o FH e o WFH. (A) Imagem original, (B) Imagem com a linha branca mostrando o padrão selecionado, (C) FH, (D) WFH.

Assim como nas abordagens anteriormente citadas torna-se necessário mostrar uma evidência forte sob a performance dos algoritmos. A figura 23 ilustra a análise gráfica do experimento, a qual indica uma melhor performance do WFH em relação ao FH.

Fazendo o mesmo teste de hipótese realizado para a abordagem anterior. Monta-se um teste pareado de hipótese unilateral com região crítica na parte superior da distribuição normal com um nível de significância $\alpha = 5\%$




Figura 23: Comparação do FH e WFH performance. (a) *boxplot* comparando o índice de dissimilaridade, índice Rand, entre FH e o WFH. (b) comparação pareada da sequência de imagens relacionadas com o *Ground Truth*.

comparando a diferença entre as respostas médias x_{difFH} dos índices Rand do FH x_5 e do WFH x_6 :

$H_0: x_{difFH} = 0$ or $x_5 - x_6 = 0$; Os algoritmos possuem performance similar.

$H_1: x_{difFH} > 0$ or $x_5 - x_6 > 0$; O WFH possui uma melhor performance (menor dissimilaridade).

Assim como no caso anterior, a comparação pareada pode ser utilizada, pois dois diferentes testes estão sendo comparados com o mesmo padrão ouro (*Ground Truth*) e o tamanho da amostra sendo utilizado é relativamente grande (>30) podendo-se assumir uma distribuição normal e as amostras são consideradas independentes. Da tabela 5 é obtido o valor médio e o desvio padrão para o FH ($x_5 = 0,14642$, $s_5 = 0,10821$) e para o WFH ($x_6 = 0,11713$, $s_6 = 0,08153$), com uma população $n = 60$. A diferença média x_{difFH} é calculada através da simples subtração dos valores médios, ou seja, $x_{difFH} = x_5 - x_6$, totalizando um valor para $x_{difFH} = 0,02929$. A diferença dos desvios padrão é calculada por:

$$s_{difFH} = \sqrt{\frac{s_5^2}{n} + \frac{s_6^2}{n}} = \sqrt{\frac{0,10821^2}{60} + \frac{0,08153^2}{60}} = 0,01749121$$

A normalização do valor de x_{difFH} pelo valor s_{difFH} , permite uma comparação direta do seu valor de *z-score* com o valor crítico: $z_{difFH} = \frac{x_{difFH}}{s_{difFH}} = \frac{0,02929}{0,01749121} = 1,67455542$.

Usando o mesmo valor crítico $z_c = 1.65$ e analisando os *z-scores* da média com o valor crítico, como o ($z_{difFH} < z_c$), mostra-se uma prova es-

tatística para rejeitar a hipótese nula com 95% de garantia. Em outras palavras significa dizer que o algoritmo WFH possui uma melhor performance em relação a sua versão sem a utilização da métrica não linear, dado que existem evidências estatísticas suficientes obtidas da amostragem realizada para apoiar esta afirmação. Esta diferença estatística pode ser visualizada na forma de um gráfico no *boxplot* da figura 23-(a) a qual pode se ter uma noção visual do comparativo entre as duas abordagens e como estão distribuídos os valores de índice Rand para ambas.

5.3 EXPERIMENTO 2: ANÁLISE GERAL ADICIONANDO OUTROS MÉTODOS

O segundo experimento utiliza todos os resultados obtidos com os métodos apresentados e adiciona resultados obtidos por outros algoritmos de segmentação (*Edge Detection and Image Segmentation* (EDISON) (CHRISTOUDIAS; GEORGESCU; MEER, 2002), Watershed (WS) (VINCENT; SOILLE, 1991), *J measure based SEGmentation* (JSEG) (DENG; MANJUNATH, 2001) e *Recursive Hierarchical Segmentation* (RHSEG) (TILTON, 2006), Gradient Network Method (GNM and GNM2) combined with MS and CSC (WANGENHEIM et al., 2009)).

A Figura 24 mostra os valores de índice Rand para a imagem 368078 do *dataset* de Berkeley (MARTIN et al., 2001) para cada algoritmo testado. Nesta comparação os métodos que utilizam métricas não lineares aparecem entre os que possuem os menores valores de Rand, indicando uma maior similaridade com o GT.

A Figura 25 mostra as segmentações resultantes para a imagem 368078 para cada algoritmo utilizado. Nesta figura pode-se notar que a imagem resultante produzida pelo RHSEG gera uma segmentação com muitos segmentos agrupados de forma incorreta, o que reflete diretamente no valor de índice Rand obtido como mostrado no gráfico da figura 24. Em contra partida ao se observar a imagem resultante obtida pelo EDISON pode-se perceber que um menor número de segmentos foram gerados e que há uma maior coerência entre os objetos formadores da imagem. Como resultado ele contém o menor índice Rand como mostrado na figura 24.

A mesma análise realizada para a imagem 368078 pode ser feita para a imagem 46076, onde, como mostrado na figura 26, tem-se o RHSEG com um número elevado de segmentos agrupados de forma incorreta o que reflete em um elevado valor de Rand como mostra o gráfico na figura 27. De forma oposta pode-se notar que o resultado de segmentação do SMS possui um menor número e que há uma maior coerência entre os objetos formadores da




Figura 24: Índice Rand dos resultados dos métodos de segmentação utilizados na comparação para a imagem 368078.




Figura 25: Comparação visual dos resultados obtidos pelos métodos para a imagem 368078. (A) Imagem original, (B) Ground Truth, (C) SMS, (D) WCSC, (E) WFH, (F) CSC+GNM2, (G) MS+GNM2, (H) CSC+GNM, (I) MS+GNM, (J) CSC, (K) MS, (L) FH, (M) EDISON, (N) WS, (O) JSEG, (P) RHSEG.

imagem. Como resultado o seu índice Rand é o menor como mostra a figura 27.

Por fim, de uma forma mais geral, pode-se comparar os resultados dos métodos avaliados em um *boxplot*, figura 28, que tem como base o valor de Rand de 16 imagens para cada método. Nele nota-se valores mais baixos, sem muita variabilidade e sem pontos discrepantes para os métodos com o aprimoramento o que indica que estes métodos possuem uma maior estabilidade nos resultados de segmentação obtidos.




Figura 26: Comparação visual dos resultados obtidos pelos métodos para a imagem 46076. (A) Imagem original, (B) Ground Truth, (C) SMS, (D) WCSC, (E) WFH, (F) CSC+GNM2, (G) MS+GNM2, (H) CSC+GNM, (I) MS+GNM, (J) CSC, (K) MS, (L) FH, (M) EDISON, (N) WS , (O) JSEG, (P) RHSEG.




Figura 27: Índice Rand dos resultados dos métodos de segmentação utilizados na comparação para a imagem 46076.

5.4 EXPERIMENTO 3: COMPARAÇÃO DOS MÉTODOS COM BASE EM TEMPO DE EXECUÇÃO

Com base nos tempos de execução dos métodos com e sem o aprimoramento, o terceiro experimento visa comparar os mesmos em termos de eficiência, fazendo um paralelo com a eficácia obtida pelo método e a eficiência do mesmo.

Para tal análise inicialmente foram anotados os tempos de execução,




Figura 28: Comparação entre vários métodos de segmentação com as abordagens propostas com base no valor de índice Rand.

em um Core 2 Duo CPU P8700 2.53GHz, de todos os métodos com alguns parâmetros de execução para todas as 60 imagens selecionadas, os valores obtidos para cada imagem podem ser observados nas tabelas 6 para os valores do CSC e WCSC, 7 para os valores do MS e SMS e 8 para os valores do FH e WFH. Depois para cada método calculou-se o tempo de execução médio como mostra a tabela 2.

Método	Tempo médio (ms)	Método	Tempo Médio (ms)
FH	123,1239	WFH	15599,9033
CSC	112,287	WCSC	4616,2972
MS	28970,4060	SMS	169411,3950

Tabela 2: Tabela comparando os tempos de execução médio dos métodos com e sem a abordagem.

Através de uma análise dos tempos médios de execução pode-se notar que os métodos com o aprimoramento possuem um aumento em seu tempo

de execução, justificado pela adição do Polinomial Mahalanobis ao cálculo de similaridade. Entretanto apesar deste decréscimo de eficiência tem-se um ganho em termos de eficácia, onde, como mostram os experimentos anteriores, com uma análise subjetiva seguida de uma análise empírica dos dados mostrou-se que houve uma melhoria nos resultados de segmentação obtidos. Em termos de comparação dos tempos entre os métodos com o aprimoramento nota-se um tempo de execução relativamente mais baixo do WCSC justificado pelo fato que sua versão sem aprimoramento possui o menor tempo entre os métodos. O contrário também é justificado da mesma forma, o SMS possui o maior tempo de execução devido ao fato de que sua versão sem a métrica não linear, o MS, possui o segundo maior tempo de execução. Dado que a inserção do Polinomial Mahalanobis inseriu o aumento no tempo de execução decidiu-se por avaliar o mesmo no quesito tempo. Fazendo uma análise constatou-se que das duas etapas do algoritmo, treinamento e execução, o treinamento possui um uso de tempo mínimo, deixando para a parte de execução a maior fatia de tempo utilizada.




Figura 29: Tempo de execução, em milissegundos, dos algoritmos utilizados. Gráfico representado na escala logarítmica.

Com base na figura 29, a qual mostra os tempos de execução dos algoritmos utilizados para todas as 60 imagens algumas considerações podem ser feitas. Pode-se notar de forma geral que os algoritmos que utilizam a métrica não linear mostram um acréscimo em termos de tempo de execução, como já comentado anteriormente com base nas médias dos algoritmos. Especificamente nas linhas de tempo do MS e no SMS há dois pontos em que o MS exige um maior tempo de execução, isso pode ser explicado ao se observar

as imagens em questão. Em ambos os casos as imagens possuem uma grande quantidade de textura o que faz com que o MS tenha mais trabalho em identificar as regiões de adjacência. No caso no SMS a métrica não linear auxilia na identificação das adjacências o que faz com que ocorra a redução de tempo em relação ao MS.

6 CONCLUSÃO

Devido a abrangência de áreas em que o processamento digital de imagens atua, surgiu a necessidade de métodos de segmentação, cada um com suas peculiaridades e áreas de aplicação. Com base nestas peculiaridades, buscou-se propor um aprimoramento adaptável o qual, associado as peculiaridades de cada método de segmentação, obtivesse uma melhoria na qualidade da segmentação.

Neste capítulo serão resumidas as contribuições do uso da abordagem proposta para os algoritmos de segmentação e por fim serão apresentadas os trabalhos futuros.

6.1 CONTRIBUIÇÕES

A proposta deste estudo e aprimoramento de métodos, foi a de mostrar uma forma de aproveitar as peculiaridades de um método de segmentação, por exemplo, baixo tempo de execução e eficiente estrutura hierárquica, e inserir um aprimoramento a estes métodos. Buscando tomar proveito das peculiaridades dos métodos de segmentação, obter melhores resultados e adicionar ao método uma forma de adaptação a outros contextos, o Polinomial Mahalanobis foi adaptado aos métodos de segmentação utilizados neste trabalho. Com a finalidade de demonstrar o potencial do aprimoramento proposto três experimentos, utilizando imagens do *dataset* de Berkeley, foram realizados.

O primeiro experimento comparou os resultados dos métodos de segmentação sem e com o aprimoramento. Para evitar o uso apenas de uma análise subjetiva dos resultados utilizou-se o teste de hipótese, com a finalidade de avaliar se uma melhoria real foi alcançada pelos métodos com o aprimoramento posposto. Os resultados obtidos indicam uma melhor performance dos métodos que possuem o aperfeiçoamento proposto, tendo como base a análise do índice Rand para 60 imagens. Em uma comparação visual das imagens pode-se notar que uma maior quantidade de regiões similares foram agrupadas, um menor número de segmentos foi gerado e uma maior coerência dos objetos que constituem a imagem.

No segundo experimento, onde há a comparação com os demais métodos, pode-se notar, além de um melhor resultado dos métodos com o aprimoramento proposto uma maior estabilidade destes. Esta estabilidade pode ser percebida através da análise empírica realizada, na qual se percebe uma menor flutuação nos valores de índice Rand para os métodos que possuem a abordagem proposta.

No terceiro experimento analisou-se os tempos de execução dos algoritmos, onde se pode notar que os tempos médios de execução dos métodos com a abordagem proposta são maiores devido a inserção da métrica não linear. Entretanto, os resultados de segmentação obtidos são melhores, como mostram os experimentos anteriores, indicando um compromisso entre eficácia e eficiência.

Por fim, com o uso desta forma de aperfeiçoamento do algoritmo o mesmo pode ser aplicado em áreas que necessitem de uma seleção de padrões de cores para segmentação e rastreamento de objetos específicos da imagem.

6.2 TRABALHOS FUTUROS

Apesar dos resultados promissores obtidos com a análise e validação dos métodos desenvolvidos, ainda há aperfeiçoamentos a serem desenvolvidos afim de melhorar os resultados obtidos. Um problema introduzido com a adição do Polinomial Mahalanobis foi o aumento do tempo de execução. Uma possibilidade de contorno deste problema seria fazer uma implementação utilizando computação paralela, como por exemplo unidades de processamento gráfico e processadores com múltiplos núcleos, afim de acelerar os cálculos que não possuam dependência entre si.

Quando considerada a melhoria dos métodos de segmentação a partir da adição do Polinomial Mahalanobis como uma métrica, nota-se que ainda há a possibilidade de estudo na otimização dos parâmetros de entrada. O que consiste em achar parâmetros ótimos para os dados de entrada, como por exemplo *threshold*, contraste e padrão. Outro campo de estudo é a possibilidade de adição de textura à métrica de similaridade, o que é facilitado pelo uso do Polinomial Mahalanobis, dado que o mesmo pode analisar a similaridade em um espaço n -dimensional

Outra melhoria a ser explorada esta na variação do espaço de cor sendo utilizado mantendo o uso desta mesma métrica. Esta abordagem utilizada em alguns trabalhos correlatos visa explorar melhor característica específicas de alguns espaços de cor, os quais possuem uma forma diferente de representação quando comparadas com o espaço RGB.

REFERÊNCIAS

A., B. On A Measure of Divergence Between Two Statistical Populations Defined by their Probability Distributions. *Bulletin of Cal. Math. Soc.*, v. 35, p. 99 – 109, 1943.

BACKHOUSE, A.; GU, I.; WANG, T. ML Nonlinear Smoothing for Image Segmentation and its Relationship to the Mean Shift. In: **Image Processing, 2007. ICIP 2007. IEEE International Conference on**. [S.l.: s.n.], 2007. v. 4, p. 337–340.

BAKALEXIS, S.; BOUTALIS, Y.; MERTZIOS, B. Edge detection and image segmentation based on nonlinear anisotropic diffusion. In: **Digital Signal Processing, 2002. DSP 2002. 2002 14th International Conference on**. [S.l.: s.n.], 2002. v. 2, p. 1203 – 1206.

BELKASIM, S. et al. Multi-resolution border segmentation for measuring spatial heterogeneity of mixed population biofilm bacteria. **Computerized Medical Imaging and Graphics**, v. 32, n. 1, p. 11 – 16, 2008.

BEN-HUR, A.; ELISSEEFF, A.; GUYON, I. A stability based method for discovering structure in clustered data. **Pacific Symposium on Biocomputing, Pacific Symposium on Biocomputing**, BioWulf Technologies LLC, 2030 Addison st. Suite 102, Berkeley, CA 94704, USA., p. 6–17, 2002.

BERTELLI, L. et al. Kernelized structural SVM learning for supervised object segmentation. In: **Computer Vision and Pattern Recognition (CVPR), 2011 IEEE Conference on**. [S.l.: s.n.], 2011. p. 2153 – 2160.

BHANU, B.; FONDER, S. Functional template-based SAR image segmentation. **Pattern Recognition**, v. 37, n. 1, p. 61 – 77, 2004.

BLOMGREN, P.; CHAN, T. Color TV: total variation methods for restoration of vector valued images. **IEEE Trans. Image Process.**, v. 7, n. 18, p. 304 – 309, 1998.

BOCCIGNONE, G.; FERRARO, M.; NAPOLETANO, P. Diffused expectation maximisation for image segmentation. **Electronics Letters**, v. 40, n. 18, p. 1107– 1108, 2004.

BOCCIGNONE, G. et al. A multiresolution diffused expectation-maximization algorithm for medical image segmentation. **Computers in Biology and Medicine**, v. 37, n. 1, p. 83 – 96, 2007.

BROX, T. **From Pixels to Regions: Partial Differential Equations in Image Analysis**. Tese (Doutorado) — Mathematical Image Analysis Group, Department of Mathematics and Computer Science, Saarland University, Germany, apr 2005.

BROX, T.; CREMERS, D. On Local Region Models and a Statistical Interpretation of the Piecewise Smooth Mumford-Shah Functional. **Int. J. Comput. Vision**, Kluwer Academic Publishers, Hingham, MA, USA, v. 84, n. 2, p. 184–193, aug 2009.

CAI, W.; CHEN, S.; ZHANG, D. Fast and robust fuzzy c-means clustering algorithms incorporating local information for image segmentation. **Pattern Recognition**, v. 40, n. 3, p. 825 – 838, 2007.

CANNY, J. A computational approach to edge detection. **IEEE Trans. Pattern Anal. Mach. Intell.**, v. 8, p. 679 – 698, 1986.

CARLOTTO, M. J. Histogram Analysis Using a Scale-Space Approach. **Pattern Analysis and Machine Intelligence, IEEE Transactions on, PAMI-9**, n. 1, p. 121–129, Jan 1987.

CARVALHO, L. E. et al. Hybrid color segmentation method using a customized nonlinear similarity function. **International Journal of Image and Graphics**, v. 14, n. 01n02, p. 1450005, 2014.

CHANG, C.-Y.; SHIE, W.-S.; WANG, J.-H. Color image segmentation via fuzzy feature tuning and feature adjustment. In: **Systems, Man and Cybernetics, 2002 IEEE International Conference on**. [S.l.: s.n.], 2002. v. 4, p. 6.

CHRISTOUDIAS, C.; GEORGESCU, B.; MEER, P. Synergism in low level vision. In: **Pattern Recognition, 2002. Proceedings. 16th International Conference on**. [S.l.: s.n.], 2002. v. 4, p. 150–155.

CREVIER, D. Image segmentation algorithm development using ground truth image data sets. **Computer Vision and Image Understanding**, v. 112, n. 2, p. 143 – 159, 2008.

DAKUA, S. P.; ABI-NAHED, J. Patient oriented graph-based image segmentation. **Biomedical Signal Processing and Control**, v. 8, n. 3, p. 325 – 332, 2013.

DALMAU, O.; RIVERA, M. Alpha Markov Measure Field model for probabilistic image segmentation. **Theoretical Computer Science**, v. 412, n. 15, p. 1434 – 1441, 2011.

DEMIRHAN, A.; GÜLER İnan. Combining stationary wavelet transform and self-organizing maps for brain MR image segmentation. **Engineering Applications of Artificial Intelligence**, v. 24, n. 2, p. 358 – 367, 2011.

DENG, Y.; MANJUNATH, B. Unsupervised segmentation of color-texture regions in images and video. **Pattern Analysis and Machine Intelligence, IEEE Transactions on**, v. 23, p. 800–810, 2001.

DING, L.; YILMAZ, A.; YAN, R. Interactive Image Segmentation Using Dirichlet Process Multiple-View Learning. **Image Processing, IEEE Transactions on**, v. 21, n. 4, p. 2119 –2129, april 2012.

DONG, X.; POLLAK, I. Circle-Valued Nonlinear Diffusions with Application to Texture Segmentation. In: **Image Processing, 2006 IEEE International Conference on**. [S.l.: s.n.], 2006. p. 1105 –1108.

DONGEN, S. V. **Performance Criteria for Graph Clustering and Markov Cluster Experiments**. [S.l.], 2000.

DU, X.; CHO, D.; BUI, T. D. Image segmentation and inpainting using hierarchical level set and texture mapping. **Signal Processing**, v. 91, n. 4, p. 852 – 863, 2011.

DUPUIS, A.; VASSEUR, P. Image segmentation by cue selection and integration. **Image and Vision Computing**, v. 24, n. 10, p. 1053 – 1064, 2006.

EMAMBAKHSH, M.; SEDAAGHI, M.; EBRAHIMNEZHAD, H. Locating texture boundaries using a fast unsupervised approach based on clustering algorithms fusion and level set. In: **Signal and Image Processing Applications (ICSIPA), 2009 IEEE International Conference on**. [S.l.: s.n.], 2009. p. 129 – 134.

FELZENSZWALB, P. F.; HUTTENLOCHER, D. P. Efficient Graph-Based Image Segmentation. **Int. J. Comput. Vision**, Kluwer Academic Publishers, v. 59, n. 2, p. 167–181, sep 2004.

FELZENSZWALB, P. F.; HUTTENLOCHER, D. P. **Efficiente Graph-Based Image Segmentation**. 2004. Disponível em: <cs.brown.edu/ pff/segment/>.

FIX, E.; HODGES, J. An important contribution to nonparametric discriminant analysis and density estimation: Commentary on Fix and Hodges. **International Statistical Review/Revue Internationale de Statistique**, v. 3, p. 233–238, 1989.

FOWLKES, E. B.; MALLOWS, C. L. A Method for Comparing Two Hierarchical Clusterings. **Journal of the American Statistical Association**, American Statistical Association, v. 78, n. 383, p. 553–569, 1983.

GONZALEZ, R. C.; WOODS, R. E. **Digital Image Processing (Second Edition)**. Upper Saddle River, NJ, USA: Prentice-Hall, Inc., 2006. ISBN 013168728X.

GOODMAN, J.; O'ROURKE, J. **Handbook of Discrete and Computational Geometry**. [S.l.]: CRC Press, 1997.

GRAU, V. et al. Hierarchical image segmentation using a correspondence with a tree model. **Pattern Recognition**, v. 37, n. 1, p. 47 – 59, 2004.

GRUDIC, G. Outdoor path labeling using polynomial mahalanobis distance. In: **in Proceedings of Robotics: Science and Systems**. [S.l.: s.n.], 2006. p. 4.

HAHN, J.; LEE, C.-O. Geometric attraction-driven flow for image segmentation and boundary detection. **Journal of Visual Communication and Image Representation**, v. 21, n. 1, p. 56 – 66, 2010.

HAN, S. et al. Image Segmentation Based on GrabCut Framework Integrating Multiscale Nonlinear Structure Tensor. **Image Processing, IEEE Transactions on**, v. 18, n. 10, p. 2289 –2302, oct. 2009.

HAN, Y.; WANG, W.-W.; FENG, X.-C. A new fast multiphase image segmentation algorithm based on nonconvex regularizer. **Pattern Recognition**, v. 45, n. 1, p. 363 – 372, 2012.

HARTMANN, G. Recognition of Hierarchically Encoded Images by Technical and Biological Systems. **Biological Cybernetics**, v. 57, p. 73 – 84, 1987.

HONG-GUI, D.; RANG-LIANG, W.; ZHENG-RONG, L. Image Segmentation of Drosophila's Compound Eyes via Two-Dimensional OTSU Thresholding on the Basis of AGA. In: **Image and Signal Processing, 2009. CISP '09. 2nd International Congress on**. [S.l.: s.n.], 2009. p. 1 –5.

JEON, M. et al. Unsupervised hierarchical image segmentation with level set and additive operator splitting. **Pattern Recognition Letters**, v. 26, n. 10, p. 1461 – 1469, 2005.

JOHNSON, R. A.; WICHERN, D. A. **Applied Multivariate Staistical Analysis**. [S.l.]: Pearson Education, 2007.

JUANG, C.-F.; CHIU, S.-H.; SHIU, S.-J. Fuzzy System Learned Through Fuzzy Clustering and Support Vector Machine for Human Skin Color Segmentation. **Systems, Man and Cybernetics, Part A: Systems and Humans, IEEE Transactions on**, v. 37, n. 6, p. 1077 –1087, nov. 2007.

KATO, Z.; PONG, T.-C. A Markov random field image segmentation model for color textured images. **Image and Vision Computing**, v. 24, n. 10, p. 1103 – 1114, 2006.

KITCHENHAM, B. **Procedures for Performing Systematic Reviews**. [S.l.], 2004.

KURUGOLLU, F.; SANKUR, B.; HARMANCI, A. E. Image segmentation by relaxation using constraint satisfaction neural network. **Image and Vision Computing**, v. 20, n. 7, p. 483 – 497, 2002.

KUSKA, J.-P. et al. Image Registration of Differently Stained Histological Sections. In: **Image Processing, 2006 IEEE International Conference on**. [S.l.: s.n.], 2006. p. 333 –336.

LEZORAY, O.; ELMOATAZ, A. Graph based smoothing and segmentation of color images. In: **Signal Processing and Its Applications, 2003. Proceedings. Seventh International Symposium on**. [S.l.: s.n.], 2003. v. 1, p. 517 – 520.

LI, J. et al. Kernel principle component analysis in pixels clustering. In: **Web Intelligence, 2005. Proceedings. The 2005 IEEE/WIC/ACM International Conference on**. [S.l.: s.n.], 2005. p. 786 – 789.

LI, Y.; KIM, J. Multiphase image segmentation using a phase-field model. **Computers & Mathematics with Applications**, v. 62, n. 2, p. 737 – 745, 2011.

LIN, W.; TSAO, E.; CHEN, C. Constraint satisfaction neural networks for image segmentation. **Pattern Recognition**, v. 25, p. 679–693, 1992.

LINGER, M. Color image segmentation algorithm: An approach to image segmentation through ellipsoidal clustering and edge detection. In: **Aerospace and Electronics Conference (NAECON), Proceedings of the 2011 IEEE National**. [S.l.: s.n.], 2011. p. 253 –260.

LIU, J.; KU, Y.-B.; LEUNG, S. Expectation-maximization algorithm with total variation regularization for vector-valued image segmentation. **Journal of Visual Communication and Image Representation**, v. 23, n. 8, p. 1234 – 1244, 2012.

- LIU, L.; TAO, W. Image segmentation by iterative optimization of multiphase multiple piecewise constant model and Four-Color relabeling. **Pattern Recognition**, v. 44, n. 12, p. 2819 – 2833, 2011.
- LUO, J.; GUO, C. en. Perceptual grouping of segmented regions in color images. **Pattern Recognition**, v. 36, n. 12, p. 2781 – 2792, 2003.
- MACQUEEN, J. B. Some Methods for classification and Analysis of Multivariate Observations. **Proceedings of 5th Berkeley Symposium on Mathematical Statistics and Probability**, p. 281–297, 1967.
- MAHALANOBIS, P. C. On the generalised distance in statistics. In: **Proceedings National Institute of Science, India**. [S.l.: s.n.], 1936. v. 2, n. 1, p. 49–55.
- MAHMOODI, S.; SHARIF, B. Geometrical-based algorithm for variational segmentation and smoothing of vector-valued images. **Image Processing, IET**, v. 1, n. 2, p. 112 –122, june 2007.
- MARTIN, D. et al. 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**. [S.l.: s.n.], 2001. v. 2, p. 416–423.
- MIGNOTTE, M. MDS-Based Multiresolution Nonlinear Dimensionality Reduction Model for Color Image Segmentation. **Neural Networks, IEEE Transactions on**, v. 22, n. 3, p. 447 – 460, march 2011.
- MONTGOMERY, D. C.; RUNGER, G. C. **Applied Statistics and Probability for Engineers**. [S.l.]: John Wiley & Sons Inc, 2003.
- Mumford, D. and Shah, J. Boundary detection by minimizing functionals. In: **IEEE Conference on Computer Vision and Pattern Recognition**. [S.l.: s.n.], 1985.
- Mumford, D. and Shah, J. Optimal Approximations by Piecewise Smooth Functions and Associated Variational Problems. **Comm. Pure Appl. Math.**, 1989.
- NAKIB, A.; OULHADJ, H.; SIARRY, P. Non-supervised image segmentation based on multiobjective optimization. **Pattern Recognition Letters**, v. 29, n. 2, p. 161 – 172, 2008.
- P., S. et al. Enhanced simulated annealing for globally minimizing functions of many continuous variables. **ACM Trans. Math. Software**, v. 23, n. 2, p. 209 – 228, 1997.

PAL, N. R.; PAL, S. K. A review on image segmentation techniques. **Pattern Recognition**, v. 26, n. 9, p. 1277 – 1294, 1993.

PAN, C. et al. Leukocyte image segmentation using simulated visual attention. **Expert Systems with Applications**, v. 39, n. 8, p. 7479 – 7494, 2012.

PARK, J. H.; LEE, G. S.; PARK, S. Y. Color image segmentation using adaptive mean shift and statistical model-based methods. **Computers & Mathematics with Applications**, v. 57, n. 6, p. 970 – 980, 2009.

PENG, B.; ZHANG, L.; ZHANG, D. A survey of graph theoretical approaches to image segmentation . **Pattern Recognition**, v. 46, n. 3, p. 1020 – 1038, 2013. ISSN 0031-3203.

PRASAD, L.; SKOURIKHINE, A. N. Vectorized image segmentation via trixel agglomeration. **Pattern Recognition**, v. 39, n. 4, p. 501 – 514, 2006.

PRIESE, L.; STURM, P. **Color Structure Code source code**. Disponível em: <http://www.uni-koblenz.de/lb/lb_downloads/>.

PRIESE, L.; STURM, P. **Introduction to the Color Structure Code and its Implementation**. 2003.

QIMIN, P.; YUNDE, J. A fast morphological algorithm for color image multi-scale segmentation using vertex-collapse. In: **Multi-Agent Security and Survivability, 2004 IEEE First Symposium on**. [S.l.: s.n.], 2004. p. 60 – 63.

QUWEIDER, M. Color image segmentation with an entropy-based cost function. In: **Image and Signal Processing (CISP), 2010 3rd International Congress on**. [S.l.: s.n.], 2010. v. 3, p. 1358 –1363.

RAND, W. M. Objective Criteria for the Evaluation of Clustering Methods. **Journal of the American Statistical Association**, American Statistical Association, v. 66, n. 336, p. 846–850, 1971.

ROBERTSON, N. et al. **The four color theorem**. [S.l.]: J. Combin. Theory, Ser., 1997. 2 - 44 p.

SATHYA, P.; KAYALVIZHI, R. Modified bacterial foraging algorithm based multilevel thresholding for image segmentation. **Engineering Applications of Artificial Intelligence**, v. 24, n. 4, p. 595 – 615, 2011.

SOBIERANSKI, A. C.; COMUNELLO, E.; WANGENHEIM, A. von. Learning a nonlinear distance metric for supervised region-merging image segmentation. In: **Computer Vision and Image Understanding**. [S.l.: s.n.], 2011. v. 115, p. 127 – 139.

SOBIERANSKI, A. C.; COMUNELLO, E.; WANGENHEIM, A. von. Learning a nonlinear distance metric for supervised region-merging image segmentation. **Computer Vision and Image Understanding**, v. 115, n. 2, p. 127 – 139, 2011.

SZCZYPIŃSKI, P. et al. Texture and color based image segmentation and pathology detection in capsule endoscopy videos. **Computer Methods and Programs in Biomedicine**, n. 0, 2012.

TA, V.-T. et al. Graph-based tools for microscopic cellular image segmentation. **Pattern Recognition**, v. 42, n. 6, p. 1113 – 1125, 2009.

TILTON, J. **D-dimensional formulation and implementation of recursive hierarchical segmentation**. [S.l.: s.n.], 2006.

TUIA, D.; MARÍ, J. M. noz; CAMPS-VALLS, G. Remote sensing image segmentation by active queries. **Pattern Recognition**, v. 45, n. 6, p. 2180 – 2192, 2012.

VANHAMEL, I.; PRATIKAKIS, I.; SAHLI, H. Multiscale gradient watersheds of color images. **Image Processing, IEEE Transactions on**, v. 12, n. 6, p. 617 – 626, june 2003.

VANHAMEL, I.; PRATIKAKIS, I.; SAHLI, H. Multiscale Graph Theory Based Color Segmentation. In: **Image Processing, 2006 IEEE International Conference on**. [S.l.: s.n.], 2006. p. 769 – 772.

VANHAMEL, I.; SAHLI, H.; PRATIKAKIS, I. Nonlinear Multiscale Graph Theory based Segmentation of Color Images. In: **Pattern Recognition, 2006. ICPR 2006. 18th International Conference on**. [S.l.: s.n.], 2006. v. 2, p. 407 – 411.

VINCENT, L.; SOILLE, P. Watersheds in digital spaces: An efficient algorithm based on immersion simulations. v. 9, p. 735–744, 1991.

WANG, H.; OLIENSIS, J. Generalizing edge detection to contour detection for image segmentation. **Computer Vision and Image Understanding**, v. 114, n. 7, p. 731 – 744, 2010.

- WANG, X.-Y. et al. Color image segmentation using automatic pixel classification with support vector machine. **Neurocomputing**, v. 74, n. 18, p. 3898 – 3911, 2011.
- WANG, X.-Y.; WANG, T.; BU, J. Color image segmentation using pixel wise support vector machine classification. **Pattern Recognition**, v. 44, n. 4, p. 777 – 787, 2011.
- WANG, X.-Y. et al. A pixel-based color image segmentation using support vector machine and fuzzy C-means. **Neural Networks**, v. 33, n. 0, p. 148 – 159, 2012.
- WANGENHEIM, A. et al. Color image segmentation using an enhanced Gradient Network Method. **Pattern Recognition Letters**, v. 30, p. 1404–1412, 2009.
- WEI, S.; HONG, Q.; HOU, M. Automatic image segmentation based on PCNN with adaptive threshold time constant. **Neurocomputing**, v. 74, n. 9, p. 1485 – 1491, 2011.
- WESOLKOWSKI, S. Clustering with a mixture of self-organizing maps. In: **Neural Networks, 2002. IJCNN '02. Proceedings of the 2002 International Joint Conference on**. [S.l.: s.n.], 2002. v. 3, p. 2363 –2368.
- XUHAIXIANG; CAOWANHUA; CHENWEI. Performance evaluation of SVM in image segmentation. In: . [S.l.: s.n.], 2008. p. 1207 – 1210.
- YANG, H.-Y. et al. LS-SVM based image segmentation using color and texture information. **Journal of Visual Communication and Image Representation**, v. 23, n. 7, p. 1095 – 1112, 2012.
- YANG-MAO, S.-F.; CHAN, Y.-K.; CHU, Y.-P. Edge Enhancement Nucleus and Cytoplasm Contour Detector of Cervical Smear Images. **Systems, Man, and Cybernetics, Part B: Cybernetics, IEEE Transactions on**, v. 38, n. 2, p. 353–366, April 2008.
- YOO, J.; DINH, T. N.; LEE, G. Segmentation by Morphological Reconstruction and Non-linear Diffusion. In: **Computer and Information Technology, 2007. CIT 2007. 7th IEEE International Conference on**. [S.l.: s.n.], 2007. p. 701 –708.
- YUAN, Y.; BARNER, K. Color Image Segmentation Using Watersheds and Joint Homogeneity-Edge Integrity Region Merging Criteria. In: **Image Processing, 2006 IEEE International Conference on**. [S.l.: s.n.], 2006. p. 1117 –1120.

ZHANG, D.-Q.; CHEN, S.-C. A novel kernelized fuzzy C-means algorithm with application in medical image segmentation. **Artificial Intelligence in Medicine**, v. 32, n. 1, p. 37 – 50, 2004.

ZHANG, L.; DENG, X. The Research of Image Segmentation Based on Improved Neural Network Algorithm. In: **Semantics Knowledge and Grid (SKG), 2010 Sixth International Conference on**. [S.l.: s.n.], 2010. p. 395 –397.

ZHAO, P. et al. Automatic cell analysis for P53 immunohistochemistry in bladder inverted papilloma. In: **Biomedical Engineering, 2003. IEEE EMBS Asian-Pacific Conference on**. [S.l.: s.n.], 2003. p. 168 – 169.

ZIJDENBOS, A. et al. Morphometric analysis of white matter lesions in MR images: method and validation. **Medical Imaging, IEEE Transactions on**, v. 13, n. 4, p. 716–724, Dec 1994.

APÊNDICE A – Imagens CSC-WCSC, MS-SMS e FH-WFH

As imagens a seguir mostram, para todas as 60 imagens selecionadas do *dataset* de Berkeley, uma comparação visual dos resultados dos métodos de segmentação com e sem a métrica não linear. O objetivo destas imagens é fazer uma comparação dos resultados de segmentação obtidos com um padrão específico da imagem para os três métodos selecionados para receberem a modificação proposta.




Figura 30: (A) imagem 2092, (B) padrão selecionado, (C) CSC e (D) WCSC.



Figura 31: (A) imagem 3096, (B) padrão selecionado, (C) CSC e (D) WCSC.



Figura 32: (A) imagem 12003, (B) padrão selecionado, (C) CSC e (D) WCSC.



Figura 33: (A) imagem 15088, (B) padrão selecionado, (C) CSC e (D) WCSC.



Figura 34: (A) imagem 16052, (B) padrão selecionado, (C) CSC e (D) WCSC.



Figura 35: (A) imagem 22090, (B) padrão selecionado, (C) CSC e (D) WCSC.




Figura 36: (A) imagem 24004, (B) padrão selecionado, (C) CSC e (D) WCSC.



Figura 37: (A) imagem 24063, (B) padrão selecionado, (C) CSC e (D) WCSC.



Figura 38: (A) imagem 35070, (B) padrão selecionado, (C) CSC e (D) WCSC.



Figura 39: (A) imagem 42049, (B) padrão selecionado, (C) CSC e (D) WCSC.



Figura 40: (A) imagem 46076, (B) padrão selecionado, (C) CSC e (D) WCSC.



Figura 41: (A) imagem 48055, (B) padrão selecionado, (C) CSC e (D) WCSC.



Figura 42: (A) imagem 60079, (B) padrão selecionado, (C) CSC e (D) WCSC.



Figura 43: (A) imagem 61060, (B) padrão selecionado, (C) CSC e (D) WCSC.




Figura 44: (A) imagem 62096, (B) padrão selecionado, (C) CSC e (D) WCSC.




Figura 45: (A) imagem 66075, (B) padrão selecionado, (C) CSC e (D) WCSC.



Figura 46: (A) imagem 67079, (B) padrão selecionado, (C) CSC e (D) WCSC.



Figura 47: (A) imagem 68077, (B) padrão selecionado, (C) CSC e (D) WCSC.



Figura 48: (A) imagem 69015, (B) padrão selecionado, (C) CSC e (D) WCSC.



Figura 49: (A) imagem 80099, (B) padrão selecionado, (C) CSC e (D) WCSC.



Figura 50: (A) imagem 94079, (B) padrão selecionado, (C) CSC e (D) WCSC.



Figura 51: (A) imagem 97017, (B) padrão selecionado, (C) CSC e (D) WCSC.



Figura 52: (A) imagem 97033, (B) padrão selecionado, (C) CSC e (D) WCSC.



Figura 53: (A) imagem 100075, (B) padrão selecionado, (C) CSC e (D) WCSC.




Figura 54: (A) imagem 100080, (B) padrão selecionado, (C) CSC e (D) WCSC.




Figura 55: (A) imagem 113009, (B) padrão selecionado, (C) CSC e (D) WCSC.



Figura 56: (A) imagem 113016, (B) padrão selecionado, (C) CSC e (D) WCSC.




Figura 57: (A) imagem 113044, (B) padrão selecionado, (C) CSC e (D) WCSC.



Figura 58: (A) imagem 118035, (B) padrão selecionado, (C) CSC e (D) WCSC.



Figura 59: (A) imagem 124084, (B) padrão selecionado, (C) CSC e (D) WCSC.



Figura 60: (A) imagem 126007, (B) padrão selecionado, (C) CSC e (D) WCSC.



Figura 61: (A) imagem 135069, (B) padrão selecionado, (C) CSC e (D) WCSC.



Figura 62: (A) imagem 143090, (B) padrão selecionado, (C) CSC e (D) WCSC.



Figura 63: (A) imagem 151087, (B) padrão selecionado, (C) CSC e (D) WCSC.



Figura 64: (A) imagem 159091, (B) padrão selecionado, (C) CSC e (D) WCSC.



Figura 65: (A) imagem 161062, (B) padrão selecionado, (C) CSC e (D) WCSC.




Figura 66: (A) imagem 163014, (B) padrão selecionado, (C) CSC e (D) WCSC.



Figura 67: (A) imagem 167062, (B) padrão selecionado, (C) CSC e (D) WCSC.



Figura 68: (A) imagem 167083, (B) padrão selecionado, (C) CSC e (D) WCSC.



Figura 69: (A) imagem 183055, (B) padrão selecionado, (C) CSC e (D) WCSC.



Figura 70: (A) imagem 196073, (B) padrão selecionado, (C) CSC e (D) WCSC.



Figura 71: (A) imagem 207056, (B) padrão selecionado, (C) CSC e (D) WCSC.



Figura 72: (A) imagem 208001, (B) padrão selecionado, (C) CSC e (D) WCSC.



Figura 73: (A) imagem 216053, (B) padrão selecionado, (C) CSC e (D) WCSC.



Figura 74: (A) imagem 225017, (B) padrão selecionado, (C) CSC e (D) WCSC.



Figura 75: (A) imagem 227092, (B) padrão selecionado, (C) CSC e (D) WCSC.



Figura 76: (A) imagem 238011, (B) padrão selecionado, (C) CSC e (D) WCSC.



Figura 77: (A) imagem 247085, (B) padrão selecionado, (C) CSC e (D) WCSC.



Figura 78: (A) imagem 249061, (B) padrão selecionado, (C) CSC e (D) WCSC.



Figura 79: (A) imagem 253036, (B) padrão selecionado, (C) CSC e (D) WCSC.



Figura 80: (A) imagem 260058, (B) padrão selecionado, (C) CSC e (D) WCSC.



Figura 81: (A) imagem 291000, (B) padrão selecionado, (C) CSC e (D) WCSC.



Figura 82: (A) imagem 295087, (B) padrão selecionado, (C) CSC e (D) WCSC.



Figura 83: (A) imagem 299091, (B) padrão selecionado, (C) CSC e (D) WCSC.



Figura 84: (A) imagem 300091, (B) padrão selecionado, (C) CSC e (D) WCSC.



Figura 85: (A) imagem 304034, (B) padrão selecionado, (C) CSC e (D) WCSC.



Figura 86: (A) imagem 310007, (B) padrão selecionado, (C) CSC e (D) WCSC.



Figura 87: (A) imagem 368078, (B) padrão selecionado, (C) CSC e (D) WCSC.




Figura 88: (A) imagem 374067, (B) padrão selecionado, (C) CSC e (D) WCSC.




Figura 89: (A) imagem 388016, (B) padrão selecionado, (C) CSC e (D) WCSC.



Figura 90: (A) imagem 2092, (B) padrão selecionado, (C) MS e (D) SMS.



Figura 91: (A) imagem 3096, (B) padrão selecionado, (C) MS e (D) SMS.



Figura 92: (A) imagem 12003, (B) padrão selecionado, (C) MS e (D) SMS.




Figura 93: (A) imagem 15088, (B) padrão selecionado, (C) MS e (D) SMS.




Figura 94: (A) imagem 16052, (B) padrão selecionado, (C) MS e (D) SMS.



Figura 95: (A) imagem 22090, (B) padrão selecionado, (C) MS e (D) SMS.




Figura 96: (A) imagem 24004, (B) padrão selecionado, (C) MS e (D) SMS.



Figura 97: (A) imagem 24063, (B) padrão selecionado, (C) MS e (D) SMS.



Figura 98: (A) imagem 35070, (B) padrão selecionado, (C) MS e (D) SMS.




Figura 99: (A) imagem 42049, (B) padrão selecionado, (C) MS e (D) SMS.



Figura 100: (A) imagem 46076, (B) padrão selecionado, (C) MS e (D) SMS.




Figura 101: (A) imagem 48055, (B) padrão selecionado, (C) MS e (D) SMS.



Figura 102: (A) imagem 60079, (B) padrão selecionado, (C) MS e (D) SMS.



Figura 103: (A) imagem 61060, (B) padrão selecionado, (C) MS e (D) SMS.



Figura 104: (A) imagem 62096, (B) padrão selecionado, (C) MS e (D) SMS.



Figura 105: (A) imagem 66075, (B) padrão selecionado, (C) MS e (D) SMS.



Figura 106: (A) imagem 67079, (B) padrão selecionado, (C) MS e (D) SMS.



Figura 107: (A) imagem 68077, (B) padrão selecionado, (C) MS e (D) SMS.



Figura 108: (A) imagem 69015, (B) padrão selecionado, (C) MS e (D) SMS.



Figura 109: (A) imagem 80099, (B) padrão selecionado, (C) MS e (D) SMS.



Figura 110: (A) imagem 94079, (B) padrão selecionado, (C) MS e (D) SMS.



Figura 111: (A) imagem 97017, (B) padrão selecionado, (C) MS e (D) SMS.



Figura 112: (A) imagem 97033, (B) padrão selecionado, (C) MS e (D) SMS.



Figura 113: (A) imagem 100075, (B) padrão selecionado, (C) MS e (D) SMS.




Figura 114: (A) imagem 100080, (B) padrão selecionado, (C) MS e (D) SMS.



Figura 115: (A) imagem 113009, (B) padrão selecionado, (C) MS e (D) SMS.



Figura 116: (A) imagem 113016, (B) padrão selecionado, (C) MS e (D) SMS.




Figura 117: (A) imagem 113044, (B) padrão selecionado, (C) MS e (D) SMS.



Figura 118: (A) imagem 118035, (B) padrão selecionado, (C) MS e (D) SMS.



Figura 119: (A) imagem 124084, (B) padrão selecionado, (C) MS e (D) SMS.



Figura 120: (A) imagem 126007, (B) padrão selecionado, (C) MS e (D) SMS.



Figura 121: (A) imagem 135069, (B) padrão selecionado, (C) MS e (D) SMS.



Figura 122: (A) imagem 143090, (B) padrão selecionado, (C) MS e (D) SMS.



Figura 123: (A) imagem 151087, (B) padrão selecionado, (C) MS e (D) SMS.



Figura 124: (A) imagem 159091, (B) padrão selecionado, (C) MS e (D) SMS.



Figura 125: (A) imagem 161062, (B) padrão selecionado, (C) MS e (D) SMS.



Figura 126: (A) imagem 163014, (B) padrão selecionado, (C) MS e (D) SMS.




Figura 127: (A) imagem 167062, (B) padrão selecionado, (C) MS e (D) SMS.



Figura 128: (A) imagem 167083, (B) padrão selecionado, (C) MS e (D) SMS.



Figura 129: (A) imagem 183055, (B) padrão selecionado, (C) MS e (D) SMS.



Figura 130: (A) imagem 196073, (B) padrão selecionado, (C) MS e (D) SMS.



Figura 131: (A) imagem 207056, (B) padrão selecionado, (C) MS e (D) SMS.



Figura 132: (A) imagem 208001, (B) padrão selecionado, (C) MS e (D) SMS.



Figura 133: (A) imagem 216053, (B) padrão selecionado, (C) MS e (D) SMS.



Figura 134: (A) imagem 225017, (B) padrão selecionado, (C) MS e (D) SMS.



Figura 135: (A) imagem 227092, (B) padrão selecionado, (C) MS e (D) SMS.



Figura 136: (A) imagem 238011, (B) padrão selecionado, (C) MS e (D) SMS.



Figura 137: (A) imagem 247085, (B) padrão selecionado, (C) MS e (D) SMS.



Figura 138: (A) imagem 249061, (B) padrão selecionado, (C) MS e (D) SMS.



Figura 139: (A) imagem 253036, (B) padrão selecionado, (C) MS e (D) SMS.




Figura 140: (A) imagem 260058, (B) padrão selecionado, (C) MS e (D) SMS.




Figura 141: (A) imagem 291000, (B) padrão selecionado, (C) MS e (D) SMS.



Figura 142: (A) imagem 295087, (B) padrão selecionado, (C) MS e (D) SMS.



Figura 143: (A) imagem 299091, (B) padrão selecionado, (C) MS e (D) SMS.



Figura 144: (A) imagem 300091, (B) padrão selecionado, (C) MS e (D) SMS.




Figura 145: (A) imagem 304034, (B) padrão selecionado, (C) MS e (D) SMS.



Figura 146: (A) imagem 310007, (B) padrão selecionado, (C) MS e (D) SMS.



Figura 147: (A) imagem 368078, (B) padrão selecionado, (C) MS e (D) SMS.



Figura 148: (A) imagem 374067, (B) padrão selecionado, (C) MS e (D) SMS.



Figura 149: (A) imagem 388016, (B) padrão selecionado, (C) MS e (D) SMS.



Figura 150: (A) imagem 2092, (B) padrão selecionado, (C) FH e (D) WFH.




Figura 151: (A) imagem 3096, (B) padrão selecionado, (C) FH e (D) WFH.



Figura 152: (A) imagem 12003, (B) padrão selecionado, (C) FH e (D) WFH.



Figura 153: (A) imagem 15088, (B) padrão selecionado, (C) FH e (D) WFH.



Figura 154: (A) imagem 16052, (B) padrão selecionado, (C) FH e (D) WFH.




Figura 155: (A) imagem 22090, (B) padrão selecionado, (C) FH e (D) WFH.




Figura 156: (A) imagem 24004, (B) padrão selecionado, (C) FH e (D) WFH.



Figura 157: (A) imagem 24063, (B) padrão selecionado, (C) FH e (D) WFH.



Figura 158: (A) imagem 35070, (B) padrão selecionado, (C) FH e (D) WFH.




Figura 159: (A) imagem 42049, (B) padrão selecionado, (C) FH e (D) WFH.




Figura 160: (A) imagem 46076, (B) padrão selecionado, (C) FH e (D) WFH.



Figura 161: (A) imagem 48055, (B) padrão selecionado, (C) FH e (D) WFH.



Figura 162: (A) imagem 60079, (B) padrão selecionado, (C) FH e (D) WFH.



Figura 163: (A) imagem 61060, (B) padrão selecionado, (C) FH e (D) WFH.




Figura 164: (A) imagem 62096, (B) padrão selecionado, (C) FH e (D) WFH.




Figura 165: (A) imagem 66075, (B) padrão selecionado, (C) FH e (D) WFH.



Figura 166: (A) imagem 67079, (B) padrão selecionado, (C) FH e (D) WFH.



Figura 167: (A) imagem 68077, (B) padrão selecionado, (C) FH e (D) WFH.




Figura 168: (A) imagem 69015, (B) padrão selecionado, (C) FH e (D) WFH.



Figura 169: (A) imagem 80099, (B) padrão selecionado, (C) FH e (D) WFH.




Figura 170: (A) imagem 94079, (B) padrão selecionado, (C) FH e (D) WFH.



Figura 171: (A) imagem 97017, (B) padrão selecionado, (C) FH e (D) WFH.



Figura 172: (A) imagem 97033, (B) padrão selecionado, (C) FH e (D) WFH.



Figura 173: (A) imagem 100075, (B) padrão selecionado, (C) FH e (D) WFH.



Figura 174: (A) imagem 100080, (B) padrão selecionado, (C) FH e (D) WFH.



Figura 175: (A) imagem 113009, (B) padrão selecionado, (C) FH e (D) WFH.




Figura 176: (A) imagem 113016, (B) padrão selecionado, (C) FH e (D) WFH.




Figura 177: (A) imagem 113044, (B) padrão selecionado, (C) FH e (D) WFH.



Figura 178: (A) imagem 118035, (B) padrão selecionado, (C) FH e (D) WFH.



Figura 179: (A) imagem 124084, (B) padrão selecionado, (C) FH e (D) WFH.



Figura 180: (A) imagem 126007, (B) padrão selecionado, (C) FH e (D) WFH.




Figura 181: (A) imagem 135069, (B) padrão selecionado, (C) FH e (D) WFH.




Figura 182: (A) imagem 143090, (B) padrão selecionado, (C) FH e (D) WFH.




Figura 183: (A) imagem 151087, (B) padrão selecionado, (C) FH e (D) WFH.



Figura 184: (A) imagem 159091, (B) padrão selecionado, (C) FH e (D) WFH.



Figura 185: (A) imagem 161062, (B) padrão selecionado, (C) FH e (D) WFH.



Figura 186: (A) imagem 163014, (B) padrão selecionado, (C) FH e (D) WFH.



Figura 187: (A) imagem 167062, (B) padrão selecionado, (C) FH e (D) WFH.




Figura 188: (A) imagem 167083, (B) padrão selecionado, (C) FH e (D) WFH.




Figura 189: (A) imagem 183055, (B) padrão selecionado, (C) FH e (D) WFH.



Figura 190: (A) imagem 196073, (B) padrão selecionado, (C) FH e (D) WFH.



Figura 191: (A) imagem 207056, (B) padrão selecionado, (C) FH e (D) WFH.



Figura 192: (A) imagem 208001, (B) padrão selecionado, (C) FH e (D) WFH.



Figura 193: (A) imagem 216053, (B) padrão selecionado, (C) FH e (D) WFH.



Figura 194: (A) imagem 225017, (B) padrão selecionado, (C) FH e (D) WFH.



Figura 195: (A) imagem 227092, (B) padrão selecionado, (C) FH e (D) WFH.



Figura 196: (A) imagem 238011, (B) padrão selecionado, (C) FH e (D) WFH.



Figura 197: (A) imagem 247085, (B) padrão selecionado, (C) FH e (D) WFH.



Figura 198: (A) imagem 249061, (B) padrão selecionado, (C) FH e (D) WFH.



Figura 199: (A) imagem 253036, (B) padrão selecionado, (C) FH e (D) WFH.




Figura 200: (A) imagem 260058, (B) padrão selecionado, (C) FH e (D) WFH.




Figura 201: (A) imagem 291000, (B) padrão selecionado, (C) FH e (D) WFH.



Figura 202: (A) imagem 295087, (B) padrão selecionado, (C) FH e (D) WFH.



Figura 203: (A) imagem 299091, (B) padrão selecionado, (C) FH e (D) WFH.



Figura 204: (A) imagem 300091, (B) padrão selecionado, (C) FH e (D) WFH.




Figura 205: (A) imagem 304034, (B) padrão selecionado, (C) FH e (D) WFH.



Figura 206: (A) imagem 310007, (B) padrão selecionado, (C) FH e (D) WFH.



Figura 207: (A) imagem 368078, (B) padrão selecionado, (C) FH e (D) WFH.




Figura 208: (A) imagem 374067, (B) padrão selecionado, (C) FH e (D) WFH.



Figura 209: (A) imagem 388016, (B) padrão selecionado, (C) FH e (D) WFH.

APÊNDICE B – Imagens comparando todos os métodos

As imagens comparativas a seguir mostram os melhores resultados de segmentação, para um subconjunto de 16 das 60 selecionadas imagens selecionadas para este estudo, com o objetivo de mostrar uma comparação visual dos resultados de segmentação obtidos para todos os métodos utilizados neste trabalho.




Figura 210: Comparação visual dos resultados obtidos pelos métodos para a imagem 2092. (A) Imagem original, (B) Ground Truth, (C) SMS, (D) WCSC, (E) WFH, (F) CSC+GNM2, (G) MS+GNM2, (H) CSC+GNM, (I) MS+GNM, (J) CSC, (K) MS, (L) FH, (M) EDISON, (N) WS, (O) JSEG, (P) RHSEG.




Figura 211: Comparação visual dos resultados obtidos pelos métodos para a imagem 15088. (A) Imagem original, (B) Ground Truth, (C) SMS, (D) WCSC, (E) WFH, (F) CSC+GNM2, (G) MS+GNM2, (H) CSC+GNM, (I) MS+GNM, (J) CSC, (K) MS, (L) FH, (M) EDISON, (N) WS, (O) JSEG, (P) RHSEG.




Figura 212: Comparação visual dos resultados obtidos pelos métodos para a imagem 22090. (A) Imagem original, (B) Ground Truth, (C) SMS, (D) WCSC, (E) WFH, (F) CSC+GNM2, (G) MS+GNM2, (H) CSC+GNM, (I) MS+GNM, (J) CSC, (K) MS, (L) FH, (M) EDISON, (N) WS, (O) JSEG, (P) RHSEG.




Figura 213: Comparação visual dos resultados obtidos pelos métodos para a imagem 24004. (A) Imagem original, (B) Ground Truth, (C) SMS, (D) WCSC, (E) WFH, (F) CSC+GNM2, (G) MS+GNM2, (H) CSC+GNM, (I) MS+GNM, (J) CSC, (K) MS, (L) FH, (M) EDISON, (N) WS, (O) JSEG, (P) RHSEG.




Figura 214: Comparação visual dos resultados obtidos pelos métodos para a imagem 42049. (A) Imagem original, (B) Ground Truth, (C) SMS, (D) WCSC, (E) WFH, (F) CSC+GNM2, (G) MS+GNM2, (H) CSC+GNM, (I) MS+GNM, (J) CSC, (K) MS, (L) FH, (M) EDISON, (N) WS, (O) JSEG, (P) RHSEG.




Figura 215: Comparação visual dos resultados obtidos pelos métodos para a imagem 46076. (A) Imagem original, (B) Ground Truth, (C) SMS, (D) WCSC, (E) WFH, (F) CSC+GNM2, (G) MS+GNM2, (H) CSC+GNM, (I) MS+GNM, (J) CSC, (K) MS, (L) FH, (M) EDISON, (N) WS, (O) JSEG, (P) RHSEG.



Figura 216: Comparação visual dos resultados obtidos pelos métodos para a imagem 48055. (A) Imagem original, (B) Ground Truth, (C) SMS, (D) WCSC, (E) WFH, (F) CSC+GNM2, (G) MS+GNM2, (H) CSC+GNM, (I) MS+GNM, (J) CSC, (K) MS, (L) FH, (M) EDISON, (N) WS, (O) JSEG, (P) RHSEG.




Figura 217: Comparação visual dos resultados obtidos pelos métodos para a imagem 60079. (A) Imagem original, (B) Ground Truth, (C) SMS, (D) WCSC, (E) WFH, (F) CSC+GNM2, (G) MS+GNM2, (H) CSC+GNM, (I) MS+GNM, (J) CSC, (K) MS, (L) FH, (M) EDISON, (N) WS, (O) JSEG, (P) RHSEG.




Figura 218: Comparação visual dos resultados obtidos pelos métodos para a imagem 68077. (A) Imagem original, (B) Ground Truth, (C) SMS, (D) WCSC, (E) WFH, (F) CSC+GNM2, (G) MS+GNM2, (H) CSC+GNM, (I) MS+GNM, (J) CSC, (K) MS, (L) FH, (M) EDISON, (N) WS, (O) JSEG, (P) RHSEG.




Figura 219: Comparação visual dos resultados obtidos pelos métodos para a imagem 80099. (A) Imagem original, (B) Ground Truth, (C) SMS, (D) WCSC, (E) WFH, (F) CSC+GNM2, (G) MS+GNM2, (H) CSC+GNM, (I) MS+GNM, (J) CSC, (K) MS, (L) FH, (M) EDISON, (N) WS, (O) JSEG, (P) RHSEG.



Figura 220: Comparação visual dos resultados obtidos pelos métodos para a imagem 118035. (A) Imagem original, (B) Ground Truth, (C) SMS, (D) WCSC, (E) WFH, (F) CSC+GNM2, (G) MS+GNM2, (H) CSC+GNM, (I) MS+GNM, (J) CSC, (K) MS, (L) FH, (M) EDISON, (N) WS, (O) JSEG, (P) RHSEG.




Figura 221: Comparação visual dos resultados obtidos pelos métodos para a imagem 143090. (A) Imagem original, (B) Ground Truth, (C) SMS, (D) WCSC, (E) WFH, (F) CSC+GNM2, (G) MS+GNM2, (H) CSC+GNM, (I) MS+GNM, (J) CSC, (K) MS, (L) FH, (M) EDISON, (N) WS, (O) JSEG, (P) RHSEG.



Figura 222: Comparação visual dos resultados obtidos pelos métodos para a imagem 196073. (A) Imagem original, (B) Ground Truth, (C) SMS, (D) WCSC, (E) WFH, (F) CSC+GNM2, (G) MS+GNM2, (H) CSC+GNM, (I) MS+GNM, (J) CSC, (K) MS, (L) FH, (M) EDISON, (N) WS, (O) JSEG, (P) RHSEG.



Figura 223: Comparação visual dos resultados obtidos pelos métodos para a imagem 253036. (A) Imagem original, (B) Ground Truth, (C) SMS, (D) WCSC, (E) WFH, (F) CSC+GNM2, (G) MS+GNM2, (H) CSC+GNM, (I) MS+GNM, (J) CSC, (K) MS, (L) FH, (M) EDISON, (N) WS, (O) JSEG, (P) RHSEG.



Figura 224: Comparação visual dos resultados obtidos pelos métodos para a imagem 310007. (A) Imagem original, (B) Ground Truth, (C) SMS, (D) WCSC, (E) WFH, (F) CSC+GNM2, (G) MS+GNM2, (H) CSC+GNM, (I) MS+GNM, (J) CSC, (K) MS, (L) FH, (M) EDISON, (N) WS, (O) JSEG, (P) RHSEG.



Figura 225: Comparação visual dos resultados obtidos pelos métodos para a imagem 368068. (A) Imagem original, (B) Ground Truth, (C) SMS, (D) WCSC, (E) WFH, (F) CSC+GNM2, (G) MS+GNM2, (H) CSC+GNM, (I) MS+GNM, (J) CSC, (K) MS, (L) FH, (M) EDISON, (N) WS, (O) JSEG, (P) RHSEG.

**APÊNDICE C – Tabelas Índice Rand CSC-WCSC, MS-SMS e
FH-WFH**

Todas as tabelas a seguir foram montadas com base nos valores de índice Rand para o conjunto de resultados gerados para todas as 60 imagens utilizadas do *dataset* de Berkeley. O objetivo destas tabelas é mostrar, além dos valores de índice Rand para os resultados de segmentação obtidos, uma comparação dos métodos com e sem o aprimoramento proposto, evitando assim apenas uma análise subjetiva dos resultados.

Imagem	CSC	WCSC	Imagem	CSC	WCSC
2092	0,081278	0,089485	126007	0,065295	0,045721
3096	0,125768	0,124438	135069	0,008492	0,008657
12003	0,223386	0,223546	143090	0,145574	0,091344
15088	0,111304	0,117548	151087	0,138024	0,046386
16052	0,431980	0,432682	159091	0,194022	0,190438
22090	0,048320	0,106830	161062	0,121885	0,089685
24004	0,179329	0,178972	163014	0,068575	0,051907
24063	0,143915	0,109812	167062	0,008164	0,012066
35070	0,214940	0,133496	167083	0,192318	0,136630
42049	0,029893	0,021697	183055	0,117385	0,136973
46076	0,11425	0,098458	196073	0,037833	0,030059
48055	0,116151	0,148105	207056	0,133168	0,098769
60079	0,035820	0,049819	208001	0,177263	0,169963
61060	0,226430	0,465956	216053	0,081426	0,085216
62096	0,177575	0,029907	225017	0,140514	0,147524
66075	0,337382	0,163891	227092	0,099710	0,119282
67079	0,213572	0,276334	238011	0,058452	0,060693
68077	0,080651	0,077884	247085	0,162087	0,164978
69015	0,169971	0,122520	249061	0,039038	0,038878
80099	0,119595	0,113296	253036	0,049900	0,048144
94079	0,461042	0,477020	260058	0,211042	0,278946
97017	0,072283	0,084696	291000	0,216970	0,238310
97033	0,213602	0,127268	295087	0,199440	0,112108
100075	0,171117	0,261000	299091	0,260756	0,266607
100080	0,163531	0,173120	300091	0,18631	0,091983
113009	0,106282	0,081762	304034	0,273082	0,402106
113016	0,192084	0,213175	310007	0,158886	0,157214
113044	0,161389	0,181437	368078	0,134156	0,07945
118035	0,098686	0,096801	374067	0,132188	0,115518
124084	0,278222	0,339678	388016	0,173283	0,179485

Tabela 3: Tabela comparando os resultados de RAND entre CSC e WCSC para as 60 imagens selecionadas. A coluna imagem é o número de referência no data set de Berkeley.

Imagem	MS	SMS	Imagem	MS	SMS
2092	0,115130	0,065700	126007	0,058700	0,035100
3096	0,209188	0,124200	135069	0,029100	0,009000
12003	0,333300	0,136800	143090	0,231997	0,0957456
15088	0,177317	0,103300	151087	0,166500	0,031300
16052	0,465000	0,279396	159091	0,351200	0,126300
22090	0,064126	0,051600	161062	0,551800	0,174300
24004	0,200664	0,183278	163014	0,078000	0,035100
24063	0,259340	0,1174064	167062	0,478500	0,006800
35070	0,341500	0,029600	167083	0,393100	0,021300
42049	0,062835	0,0239522	183055	0,158200	0,094400
46076	0,144229	0,0518368	196073	0,0436338	0,0238042
48055	0,143963	0,0706055	207056	0,090020	0,0256982
60079	0,069718	0,03371358	208001	0,173435	0,294480
61060	0,280400	0,028500	216053	0,224700	0,056300
62096	0,211200	0,025900	225017	0,152200	0,085600
66075	0,450500	0,141600	227092	0,189800	0,101400
67079	0,368700	0,333600	238011	0,304700	0,057800
68077	0,230974	0,076659	247085	0,148705	0,072825
69015	0,178274	0,095419	249061	0,031624	0,029241
80099	0,141374	0,106960	253036	0,065215	0,0502535
94079	0,431516	0,0545236	260058	0,134200	0,087700
97017	0,273700	0,067300	291000	0,219700	0,178900
97033	0,204000	0,134600	295087	0,198331	0,1074947
100075	0,251800	0,182800	299091	0,408900	0,222900
100080	0,196796	0,1657676	300091	0,197100	0,1058826
113009	0,103400	0,071700	304034	0,255995	0,1421066
113016	0,397300	0,264100	310007	0,128416	0,0199146
113044	0,252400	0,218800	368078	0,137051	0,0867431
118035	0,101951	0,0975172	374067	0,143900	0,096500
124084	0,203585	0,211074	388016	0,169012	0,1618933

Tabela 4: Tabela comparando os resultados de RAND entre MS e SMS para as 60 imagens selecionadas. A coluna imagem é o número de referência no data set de Berkeley.

Imagem	FH	WFH	Imagem	FH	WFH
2092	0,044220	0,045968	126007	0,062812	0,055695
3096	0,128811	0,125527	135069	0,023211	0,023114
12003	0,136357	0,086375	143090	0,096349	0,087688
15088	0,572747	0,115167	151087	0,109572	0,048593
16052	0,407235	0,394484	159091	0,264033	0,166851
22090	0,050232	0,050285	161062	0,123406	0,116048
24004	0,169150	0,168529	163014	0,029559	0,032458
24063	0,124915	0,122162	167062	0,021517	0,016839
35070	0,116106	0,043770	167083	0,153901	0,153586
42049	0,019881	0,017693	183055	0,147289	0,124244
46076	0,107775	0,082992	196073	0,030090	0,023184
48055	0,105250	0,091935	207056	0,297166	0,027712
60079	0,037177	0,035914	208001	0,198326	0,197246
61060	0,091690	0,081247	216053	0,060315	0,049150
62096	0,156149	0,027222	225017	0,113167	0,113296
66075	0,140280	0,136632	227092	0,098252	0,101258
67079	0,183070	0,181152	238011	0,065641	0,062971
68077	0,060753	0,073801	247085	0,124367	0,101779
69015	0,199378	0,168533	249061	0,028461	0,027018
80099	0,109695	0,111236	253036	0,054984	0,053777
94079	0,442236	0,371363	260058	0,091138	0,097960
97017	0,064901	0,077197	291000	0,291926	0,279249
97033	0,186998	0,128887	295087	0,154263	0,144436
100075	0,229698	0,169472	299091	0,252700	0,232279
100080	0,178778	0,160111	300091	0,098231	0,095472
113009	0,115885	0,085432	304034	0,365709	0,339360
113016	0,229000	0,180162	310007	0,069309	0,098220
113044	0,219726	0,160354	368078	0,079972	0,078775
118035	0,118248	0,117863	374067	0,123985	0,125565
124084	0,235416	0,146139	388016	0,174171	0,196351

Tabela 5: Tabela comparando os resultados de RAND entre FH e WFH para as 60 imagens selecionadas. A coluna imagem é o número de referência no data set de Berkeley.

**APÊNDICE D – Tabelas de tempos de execução em milissegundos
CSC-WCSC, MS-SMS e FH-WFH**

Todas as tabelas a seguir foram montadas com base nos tempos de execução dos métodos de segmentação com e sem o aprimoramento proposto para todo o subconjunto de 60 imagens selecionadas do *dataset* de Berkeley. O propósito desta tabela comparativa é mostrar o efeito, em termos do tempo de execução, da aplicação da métrica não linear nos algoritmos de segmentação.

Imagem	CSC	WCSC	Imagem	CSC	WCSC
2092	107,705	1966,93	126007	110,832	3797,8
3096	102,327	737,136	135069	102,18	1285,44
12003	122,006	3664,71	143090	107,773	3245,17
15088	119,685	4211,32	151087	116,868	5821,66
16052	117,996	4407,04	159091	121,022	6716,72
22090	109,989	3297,36	161062	104,821	3003,01
24004	115,836	4940,85	163014	111,127	5439,36
24063	105,79	2076,34	167062	102,516	2311,31
35070	107,311	3212,63	167083	127,81	9192,43
42049	106,367	2312,35	183055	108,648	4118,99
46076	108,264	3220,27	196073	104,8	2486,55
48055	115,735	7646,69	207056	107,895	5275,02
60079	102,2	1690,75	208001	117,638	8520,94
61060	115,906	6229,2	216053	111,669	6746,11
62096	113,909	6650,57	225017	118,304	7693,73
66075	107,241	4755,37	227092	105,487	3897,01
67079	115,957	6762,26	238011	104,248	4516,98
68077	110,161	7464,57	247085	113,655	5232,64
69015	115,682	6564,44	249061	110,773	8092,48
80099	102,625	2683,4	253036	104,817	2153,35
94079	124,966	8214,99	260058	107,278	1611,88
97017	110,106	6853,44	291000	131,551	7186,73
97033	119,195	7333,02	295087	114,139	4552,03
100075	114,542	4951,72	299091	105,519	2210,01
100080	104,913	2960,39	300091	109,288	2777,13
113009	109,428	5358,02	304034	130,139	5434,16
113016	121,152	7785,87	310007	112,587	2610,43
113044	120,344	7136,67	368078	119,056	2773,07
118035	106,358	3210,7	374067	109,597	1462,43
124084	114,513	5979,14	388016	116,976	2535,12

Tabela 6: Tabela comparando os resultados de tempo de execução em milissegundos entre CSC e WCSC para as 60 imagens selecionadas. A coluna imagem é o número de referência no data set de Berkeley.

Imagem	MS	SMS	Imagem	MS	SMS
2092	7540,43	195768	126007	3064,68	92376
3096	15158,4	90524,4	135069	1341,61	90745,6
12003	1505,14	146141	143090	1109,49	87240,4
15088	2547,98	123641	151087	1570,43	123112
16052	1404,69	83266,2	159091	1938,45	178115
22090	1503,59	114995	161062	9185,57	323599
24004	1412,7	186094	163014	1565,4	139396
24063	1453,42	119349	167062	147972	389892
35070	1937,23	142195	167083	26941,4	192935
42049	2272,64	87856,8	183055	4336,04	122693
46076	2794,43	132624	196073	1071250	678009
48055	1866,21	158731	207056	62877,6	680926
60079	2953,28	118657	208001	1479,96	116879
61060	173865	111673	216053	18085	178496
62096	1234,72	154573	225017	3826,09	173315
66075	3864,53	98686,2	227092	8131,67	106068
67079	2072,01	119657	238011	3399,03	459714
68077	1892,84	168742	247085	1649,92	92440,9
69015	18137,2	95635,7	249061	1271,45	229227
80099	2504,7	297710	253036	1994,86	92730
94079	1522,34	148152	260058	23525,5	117616
97017	43961,8	134768	291000	1986,84	253749
97033	1129,68	92660,2	295087	1827,85	121381
100075	1648,99	110910	299091	12837,3	113706
100080	1175,84	95413,3	300091	4152,1	127903
113009	5399,94	186439	304034	1288,49	99501,2
113016	2416,6	125743	310007	1354,02	260927
113044	1838,7	166215	368078	1632,64	132067
118035	3206,5	202054	374067	2897,66	73740,8
124084	1362,25	145255	388016	2147,53	162055

Tabela 7: Tabela comparando os resultados de tempo de execução em milissegundos entre MS e SMS para as 60 imagens selecionadas. A coluna imagem é o número de referência no data set de Berkeley.

Imagem	FH	WFH	Imagem	FH	WFH
2092	130,918	19880,4	126007	102,723	10206,4
3096	133,938	16234,4	135069	104,42	9708,03
12003	139,73	23235,1	143090	101,923	10574,8
15088	137,958	16946,1	151087	104,189	11480,4
16052	144,863	16119,6	159091	104,465	15095,5
22090	135,89	17223,6	161062	102,496	11916
24004	135,258	20389,3	163014	104,326	12721,3
24063	139,254	16275,8	167062	93,8246	9410,88
35070	135,84	23732,6	167083	105,574	10550,4
42049	120,645	13843,6	183055	105,248	10549,5
46076	135,934	16305,4	196073	104,293	9701,05
48055	134,701	18919,5	207056	104,507	15037,4
60079	136,437	15998,3	208001	104,242	13064,1
61060	135,155	17111,7	216053	102,078	12945,4
62096	135,344	16295,8	225017	103,828	10992,2
66075	138,059	17392,8	227092	99,8877	12345,7
67079	136,578	15913,3	238011	102,934	17659,9
68077	138,052	23522,7	247085	104,835	10620,7
69015	136,862	16036	249061	103,018	16013
80099	142,263	22364,4	253036	104,339	10499,4
94079	142,679	16334,8	260058	137,809	17831,5
97017	137,955	20129,3	291000	142,73	22579,7
97033	138,939	14811,8	295087	130,739	17153,4
100075	142,231	17073,1	299091	136,475	16359,5
100080	135,151	17048,9	300091	137,829	15494,5
113009	143,157	20321,8	304034	105,386	10463
113016	135,497	18106	310007	103,982	13788,4
113044	139,339	23009,4	368078	104,582	10620,8
118035	138,322	17666,1	374067	105,247	9601,84
124084	136,238	21612,8	388016	106,32	11155,1

Tabela 8: Tabela comparando os resultados de tempo de execução em milissegundos entre FH e WFH para as 60 imagens selecionadas. A coluna imagem é o número de referência no data set de Berkeley.