

Universidade Federal do Pampa

Thiarles Soares Medeiros

**Segmentação de Nanotubos de Carbono em
Imagens de Microscopia Eletrônica de
Transmissão**

Alegrete

2013

Thiarles Soares Medeiros

Segmentação de Nanotubos de Carbono em Imagens de Microscopia Eletrônica de Transmissão

Trabalho de Conclusão de Curso apresentado ao Curso de Graduação em Ciência da Computação da Universidade Federal do Pampa como requisito parcial para a obtenção do título de Bacharel em Ciência da Computação.

Orientador: Alessandro Bof de Oliveira

Alegrete

2013

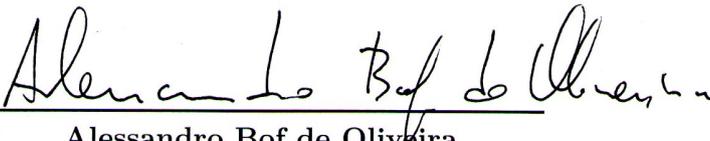
Thiarles Soares Medeiros

Segmentação de Nanotubos de Carbono em Imagens de Microscopia Eletrônica de Transmissão

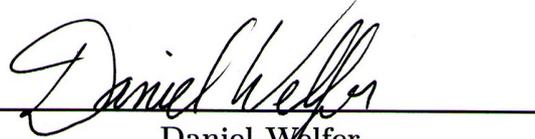
Trabalho de Conclusão de Curso apresentado ao Curso de Graduação em Ciência da Computação da Universidade Federal do Pampa como requisito parcial para a obtenção do título de Bacharel em Ciência da Computação.

Trabalho de Conclusão de Curso defendido e aprovado em 05 de março de 2013

Banca examinadora:



Alessandro Bof de Oliveira
Orientador



Daniel Welfer
(UNIPAMPA)



Patricia Rodrigues da Silva
(UNIPAMPA)

Este trabalho é dedicado à minha esposa pela compreensão, ajuda e apoio incondicional.

Resumo

Cada vez mais o processamento de imagens digitais é utilizado para facilitar a análise das informações contidas em uma imagem. Como uma das diversas técnicas de processamento tem-se a segmentação como processo simples e geralmente de baixo consumo computacional. O objetivo da segmentação é isolar as estruturas que estão sendo analisadas, removendo o que não é necessário ser considerado. Quando aplicada a imagens de microscopia eletrônica de transmissão (MET), a segmentação de nanotubos de carbono (NTC) possibilita o estudo quantitativo e análise estatística do material, fornecendo dados para o estudo de novos materiais e suas propriedades. A segmentação pode ser realizada com diferentes métodos que avaliam características da imagem, sendo uma delas o histograma, que representa a distribuição quantitativa da intensidade dos pixels. O presente trabalho tem como finalidade segmentar NTCs em imagens de MET utilizando análise do histograma de regiões da imagem, utilizando diversos métodos de comparação de histogramas, buscando determinar dentre eles qual possui os melhores resultados dadas as características do problema em questão. Além da determinação do método também deseja-se determinar qual o melhor tamanho de região analisada se adequa ao propósito principal. A metodologia será dividida em análise do ruído, processamento com diferentes medidas de distância entre histogramas, análise dos resultados e segmentação utilizando parâmetros definidos. Primeiramente, a análise do ruído contido nas imagens irá fornecer dados para a geração de um modelo estatístico do mesmo, que servirá como base de comparação entre os histogramas. Seguindo, a aplicação dos diferentes métodos de cálculo de distância dos histogramas entre o histograma de uma região e o do modelo de ruído, podendo citar os métodos de distância Euclidiana, Bhattacharyya e Minkowski. Também foi levado em consideração o tamanho da área analisada, extendendo a análise à determinação do tamanho mais adequado para o processamento do histograma, sendo a aplicação dos métodos realizada sobre cada tamanho testado. Como medida comparativa é utilizada a análise da segmentação utilizando os métodos de distância de histogramas com o resultado esperado (ground truth). Com o trabalho pode-se perceber que a distância de Manhattan apresentou melhores resultados que outras medidas de distâncias. Além disso observou-se que dentro os melhores resultados os tamanhos de janela mais frequentes são os entre 3x3 e 17x17 pixels.

Palavras-chave: Processamento de Imagens. Segmentação. Nanotubos de Carbono. Histograma.

Abstract

Nowadays, digital image processing is used to facilitate the analysis of information contained in an image. As one of several processing techniques has been the segmentation process as simple and generally with low computation. The goal of segmentation is to isolate the structures that are being analyzed, removing what isn't need to be considered. When applied to images of transmission electron microscopy (TEM), the segmentation of carbon nanotubes (CNT) enables the quantitative and statistical analysis of the material, providing data for the study of new materials and their properties. The segmentation can be performed using various methods that evaluate image characteristics, one is the histogram, which represents the quantitative distribution of the intensity of the pixels. This paper aims to segment CNTs on TEM images using analysis of the histogram of image regions, using various comparison histograms methods, to determine which among them has the best results given the characteristics of the problem in question. In addition to determining the method also want to determine the best size of the analyzed region fits main purpose. The methodology is divided into noise analysis, processing with different distance measures between histograms, result analysis and segmentation using defined parameters. First, the analysis of noise contained in the images will provide data for generating a statistical model thereof, which serve as the basis of comparison between the histograms. Following the application of different methods for histogram distance calculation between a region histogram and the noise model, may cite the methods of Euclidean distance, Minkowski and Bhattacharyya. It was also taken into account the size of the analyzed area, extending the analysis to determine the most suitable size for processing the histogram, and the application of the methods performed on each size tested. As a comparative measure is used segmentation analysis using the histograms distance methods with the expected result (ground truth). With work can be seen that the Manhattan distance yielded better results than other distance measures. Also it was observed that the best results within the window sizes are more frequent among 3x3 and 17x17 pixels.

Key-words: Image Processing. Segmentation. Carbon Nanotubes. Histogram.

Lista de ilustrações

Figura 1	Estrutura de um nanotubo de carbono	24
Figura 2	Segmento de uma imagem de microscopia eletrônica de transmissão contendo nanotubos de carbono	24
Figura 3	Esquema de um microscópio eletrônico de transmissão	25
Figura 4	Representação da incidência de elétrons em função da densidade do material analisado	26
Figura 5	Exemplo de distribuição de Gauss	27
Figura 6	Exemplo de distribuição de Epanechnikov	28
Figura 7	Exemplo de histograma	29
Figura 8	Metodologia para geração do modelo de ruído	38
Figura 9	Metodologia para processamento da imagem	38
Figura 10	Metodologia para processamento da imagem utilizando pesos	39
Figura 11	Exemplo de padrão de comparação	40
Figura 12	Resultado insatisfatório - exemplo	41
Figura 13	Resultado satisfatório - exemplo	41
Figura 14	Curvas das medidas de qualidade e de threshold para o método de Bhattacharyya	44
Figura 15	Curvas da ocorrência do número de bits utilizados para definir o número de bins dos histogramas utilizados para o método de Bhattacharyya	45
Figura 16	Curvas de ocorrência da utilização ou não da máscara de pesos para o método de Bhattacharyya	45
Figura 17	Curvas de ocorrência da dimensão das janelas para o método de Bhattacharyya	46
Figura 18	Curva da dimensão das janelas mais frequentes para o método de Bhattacharyya	46
Figura 19	Curvas das medidas de qualidade e de threshold para o método de Minkowski suas e variantes	47
Figura 20	Curvas das ocorrências do número de bits utilizados para definir o número de bins dos histogramas utilizados para o método de Minkowski e suas variantes	48
Figura 21	Curvas das ocorrências da utilização ou não da máscara de pesos para o método de Minkowski e suas variantes	49

Figura 22	Curvas das ocorrências da dimensão das janelas para o método de Minkowski e variantes	50
Figura 23	Curvas da dimensão das janelas mais frequentes para o método de Minkowski e variantes	50
Figura 24	Curvas das medidas de qualidade e de threshold para o método de Hellinger	51
Figura 25	Comparação entre as curvas de ocorrência do número de bits utilizados para definir o número de bins dos histogramas utilizados das distâncias de Hellinger e Bhattacharyya	51
Figura 26	Comparação entre as curvas de ocorrência da utilização ou não da máscara de pesos das distâncias de Hellinger e Bhattacharyya	52
Figura 27	Comparação entre as curvas de ocorrência da dimensão das janelas para as distâncias de Hellinger e Bhattacharyya	52
Figura 28	Curvas das medidas de qualidade e de threshold para o método do Ângulo Cosseno	53
Figura 29	Curvas de ocorrência do número de bits utilizados para definir o número de bins dos histogramas utilizados para o método do Ângulo Cosseno	53
Figura 30	Curvas de ocorrência da utilização ou não da máscara de pesos para o método do Ângulo Cosseno	54
Figura 31	Curvas de ocorrência da dimensão das janelas para o método do Ângulo Cosseno	54
Figura 32	Curva da dimensão das janelas mais frequentes para o método do Ângulo Cosseno	55
Figura 33	Curvas das medidas de qualidade e de threshold para o método Qui-quadrado	55
Figura 34	Curvas de ocorrência do número de bits utilizados para definir o número de bins dos histogramas utilizados para o método Qui-quadrado	56
Figura 35	Curvas de ocorrência da utilização ou não da máscara de pesos para o método Qui-quadrado	57
Figura 36	Curvas de ocorrência da dimensão das janelas para o método Qui-quadrado	57
Figura 37	Curvas das medidas de qualidade e de threshold para o método de entropia de Rényi e variantes	58
Figura 38	Curvas das ocorrências do número de bits utilizados para definir o número de bins dos histogramas utilizados da entropia de Rényi e variantes	59
Figura 39	Curvas das ocorrências da utilização ou não da máscara de peso da entropia de Rényi e variantes	59
Figura 40	Curvas das ocorrências da dimensão das janela da entropia de Rényi e variantes	60

Figura 41	Curvas da dimensão das janelas mais frequentes para a entropia de Rényi e variantes	60
Figura 42	Curvas das medidas de qualidade e de threshold considerando todos os resultados	62
Figura 43	Curvas das ocorrências do número de bits utilizados para definir o número de bins dos histogramas utilizados considerando todos os resultados	62
Figura 44	Curvas das ocorrências da utilização ou não da máscara de pesos considerando todos os resultados	63
Figura 45	Curvas da dimensão das janelas mais frequentes considerando todos os resultados	63
Figura 46	Curvas das ocorrências da dimensão das janelas considerando todos os resultados	65
Figura 47	Curvas das médias do fator SP das distâncias apresentadas	66
Figura 48	Curvas das ocorrências das distâncias apresentadas	67
Figura 49	Curvas das distâncias mais frequentes	68
Figura 50	Exemplos de resultados obtidos	69

Lista de tabelas

Tabela 1	Tabelas com os melhores resultados para a distância de Minkowski e seus casos especiais	47
Tabela 2	Dados dos 20 melhores resultados gerais	61
Tabela 3	Dados dos resultados apresentados na figura 50	68

Sumário

1	Introdução	19
1.1	Tema	19
1.2	Delimitação do problema	20
1.3	Objetivo	20
1.4	Primeira análise do problema	20
1.5	Organização dos capítulos seguintes	21
2	Revisão Bibliográfica	23
2.1	Imagem Digital	23
2.2	Nanotubos de Carbono	23
2.3	Microscopia Eletrônica de Transmissão	25
2.4	Segmentação	26
2.5	Ponderação	27
2.5.1	Gauss	27
2.5.2	Epanechnikov	28
2.6	Histogramas	28
2.7	Medidas e Métricas	29
2.8	Medidas de qualidade	30
2.8.1	Precisão	30
2.8.2	Sensibilidade	31
2.8.3	Especificidade	31
3	Fundamentação teórica	33
3.1	Distância de Bhattacharyya	33
3.2	Distância de Minkowski (L_p)	33
3.3	Distância de Manhattan (L_1)	34
3.4	Distância Euclidiana (L_2)	34
3.5	Distância de Chebyshev (L_∞)	35
3.6	Distância de Hellinger	35
3.7	Distância de Ângulo Cosseno	35
3.8	Qui-quadrado (X^2)	35
3.9	Diferença de Entropia	36
3.9.1	Entropia de Shannon (parâmetro $\alpha = 1$)	36
3.9.2	Entropia de Rényi (parâmetro $\alpha = 2$)	36
3.9.3	Min-entropia (parâmetro $\alpha = \infty$)	36

4	Metodologia	37
4.1	Modelo de histograma	37
4.2	Comparação entre os histogramas	37
4.3	Padrões de resultado	39
4.4	Normalização dos resultados	39
4.5	Comparação dos resultados	40
5	Resultados	43
5.1	Resultados por método	43
5.1.1	Distância de Bhattacharyya	43
5.1.2	Distância de Minkowski e suas variantes	47
5.1.3	Distância de Hellinger	49
5.1.4	Ângulo Cosseno	49
5.1.5	Qui-quadrado	52
5.1.6	Entropia de Rényi e suas variantes	56
5.2	Resultados Gerais	61
6	Considerações Finais	71
	Referências	73

1 Introdução

Diversas são as aplicações de imagens no dia a dia, auxiliando a obtenção de informações de um modo mais prático através da representação gráfica. Alguns exemplos de aplicações são: a utilização em diagnósticos médicos facilitando a avaliação do estado de saúde dos pacientes, tendo como métodos mais conhecidos os exames de raio-X e tomografia computadorizada; a análise da qualidade de peças na indústria metalúrgica, verificando a presença ou ausência de fissuras e trincas nos materiais; e, controle de qualidade na produção de grãos identificando impurezas e grãos defeituosos. As aplicações utilizam uma ou várias imagens na obtenção da informação desejada. Vídeos também são utilizados como sendo sequências de imagens, e o processamento é feito sobre cada quadro de forma semelhante a que é realizado em apenas uma imagem. Neste caso o conjunto de imagens armazena informação temporal que é considerada na análise dos quadros seguintes. Alguns exemplos para o processamento de vídeos são o controle de tráfego e realidade aumentada.

A segmentação de nanotubos de carbono em imagens de microscopia eletrônica de transmissão possibilita o estudo quantitativo e análise de dados estatísticos dos nanotubos de carbono (como sua dispersão(OLIVEIRA et al., 2011)), fornecendo dados para o conhecimento detalhado da microestrutura dos materiais possibilitando o entendimento e, em muitos casos, até a previsão das propriedades e do comportamento dos mesmos , o que torna este estudo de grande importância na área de ciência dos materiais.

1.1 Tema

Como tema principal tem-se a área de processamento de imagens que surge a partir de duas categorias de interesse que são: “melhoria de informação visual para a interpretação humana e o processamento de dados de cenas para percepção automática de máquinas” (GONZALEZ; WOODS, 2000, p. 1).

Na tentativa de atender a estes interesses, o processamento de imagens apresenta situações em que é alta a complexidade de extração da informação. A análise apropriada do problema conduz à busca de uma solução satisfatória. Um dos fatos que aumenta a complexidade é a presença de ruído. Ruído são anomalias que se manifestam como pontos ou regiões que não seguem o padrão esperado como, por exemplo, pontos escuros onde se esperava pontos claros.

Outros problemas surgem quando tenta-se segmentar uma imagem na busca de isolar informação contida na mesma. A segmentação é uma das áreas de atuação do processamento de imagens, sendo uma das primeiras etapas realizadas e que a partir dela é feita a análise mais detalhada da imagem.

A segmentação consiste em dividir a imagem em grupos de elementos com características similares. Estes grupos podem ser compostos de pontos, contornos, tonalidades, entre outros. Os grupos fazem parte de regiões de interesse, que é onde se concentra a busca da informação. Desta forma tenta-se isolar a informação desejada na imagem eliminando tudo aquilo que não se deseja.

1.2 Delimitação do problema

O foco do estudo é a análise dos métodos de distância de histogramas aplicados a imagens de Microscopia Eletrônica de Transmissão (MET, em inglês, Transmission Electron Microscopy - TEM) de materiais que contenham Nanotubos de Carbono (NTCs, em inglês, Carbon NanoTubes - CNT's). A utilização do histograma foi escolhida devido ao histograma não depender da orientação das estruturas analisadas, já que o histograma é uma forma de diminuir o número de dimensões analisadas.

1.3 Objetivo

Tem-se como objetivo segmentar NTCs em imagens de MET através do processamento de imagens digitais. A abordagem escolhida é a análise dos diferentes métodos de medida de distância entre histogramas afim de determinar dentre eles qual é mais indicado. Não bastando, também será analisado a influência do tamanho da área analisada(janela), a quantidade de bits utilizados para a representação dos níveis de cinza e a utilização de pesos para a priorizar a localidade espacial dos pixels vizinhos. Após a análise tem-se como objetivo a determinação de um procedimento para a segmentação de NTCs com o uso das configurações que apresente resultados satisfatórios.

Conforme questionamento feito por [Wojnar \(1998\)](#) a respeito de quanto tempo se dispõe para buscar uma solução adequada, este trabalho se propõe a ajudar a minimizar o tempo gasto na busca de uma metodologia de segmentação de NTCs em imagens de MET.

1.4 Primeira análise do problema

Avaliando o problema e a estrutura das imagens de MET, observa-se as dificuldades que serão encontradas. Primeiramente, o ruído está presente em toda ou quase toda a

imagem, o que irá dificultar na segmentação direta da imagem. Sendo assim, pressupõe-se que terá que ser utilizada alguma estatística para que a ocorrência do ruído não influencie no resultado final. Nota-se também que a tonalidade que representa as estruturas em alguns casos não difere significativamente do que é considerado como fundo na imagem. Isto se dá ao fato da baixa densidade dos NTCs. Além disso, as estruturas têm formas variadas, diferindo em largura, comprimento e tonalidade, podendo estar sobrepostas ou não, dificultando em prever o que é um NTC.

1.5 Organização dos capítulos seguintes

No capítulo seguinte será apresentado alguns conceitos básicos fundamentais para a compreensão da proposta do trabalho e dos resultados obtidos ao longo da pesquisa. Na continuidade serão mostrados os métodos de distância que foram analisados e suas características. A metodologia será apresentada em um capítulo aparte contendo a descrição dos procedimentos utilizados para a análise dos métodos estudados. Os resultados serão apresentados na continuidade do capítulo da metodologia. E por fim estará a conclusão, que sintetizará a análise dos resultados.

2 Revisão Bibliográfica

Para uma boa compreensão deste trabalho é necessário que tenha-se conhecimento dos conceitos que serão empregados. Para isso, será apresentado aqueles que julga-se ser os necessários ao entendimento, sendo descritos nas seções seguintes. Primeiramente será apresentado o conceito de imagem digital seguido dos conceitos de nanotubos de carbono, microscopia eletrônica de transmissão, segmentação, ponderação, histogramas, medidas e métricas, e por fim, medidas de qualidade.

2.1 Imagem Digital

Uma imagem digital pode ser definida como um conjunto de pixels (do inglês - picture elements - pixel). Estes pixels estão dispostos no formato de uma matriz bi ou tridimensional, e armazenam informações sobre cores ou luminância (GONZALEZ; WOODS, 2000, p. 5). Imagens coloridas podem ser representadas como a composição das cores primárias vermelho, verde e azul. Este sistema é conhecido como sistema RGB (Red, Green e Blue), sendo que cada cor compõe uma dimensão da imagem. Cada dimensão contém a intensidade da cor em cada posição da imagem e a imagem final é a combinação destas dimensões. Existem também outras formas de representar imagens coloridas que utilizam de outras técnicas para compor a informação das cores, mas que não serão descritas neste trabalho.

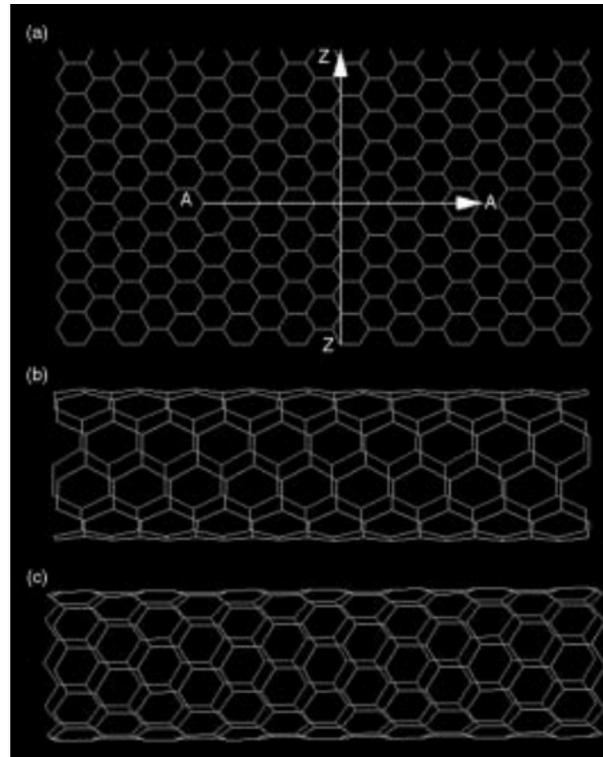
Além das imagens coloridas há também as imagens em níveis de cinza onde, o pixel armazena apenas a intensidade luminosa. Os valores utilizados podem variar em função do número de bits utilizados para a representação da luminosidade, variando de 0 a $2^n - 1$ onde n é o número de bits utilizados para armazenar essa informação.

2.2 Nanotubos de Carbono

Nanotubos de carbono são estruturas cilíndricas formadas por átomos de carbono conectados em formato de hexágonos. Estes hexágonos formam o cilindro com se eles estivessem “enrolados” como mostra a figura 1. A figura 2 mostra a imagem de um nanotubo obtida a partir da microscopia eletrônica de transmissão.

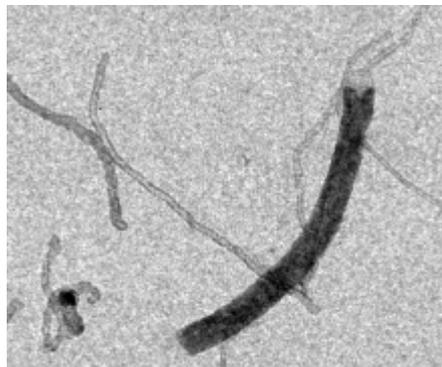
Segundo Meyyappan e Srivastava (2003), desde que foram descobertos os nanotubos, pesquisadores o estudam e exploram suas propriedades elétricas e mecânicas. A alta resistência à tensão e outras propriedades mecânicas induzem a um promissor uso

Figura 1 – Estrutura de um nanotubo de carbono



Fonte: Meyyappan e Srivastava (2003, p. 2)

Figura 2 – Segmento de uma imagem de microscopia eletrônica de transmissão contendo nanotubos de carbono



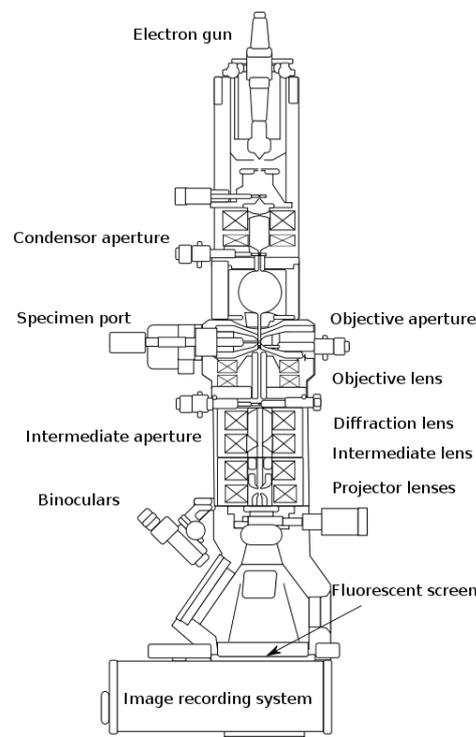
Fonte: Patricia Rodrigues da Silva. Imagem obtida no centro de microscopia da UFRGS (CME) <http://www.cme.ufrgs.br> no equipamento Microscópio Eletrônico de Transmissão JEOL JEM 1200ExII.

em compostos altamente resistentes. NTC são utilizados em uma grande variedade de aplicações, tais como nanoeletrônica, baterias e equipamento de proteção pessoal.

2.3 Microscopia Eletrônica de Transmissão

A MET consiste de um feixe de elétrons direcionados para uma amostra através de lentes e espelhos. Os elétrons são acelerados na direção da amostra por meio de uma diferença de potencial de milhares de Volts. A análise do material é feita observando como os elétrons se comportaram ao atravessar a amostra. A figura 3 mostra a composição de um microscópio eletrônico de transmissão.

Figura 3 – Esquema de um microscópio eletrônico de transmissão



Fonte: [Wikipedia](#) (2011)

A imagem resultante da MET é formada pela taxa de incidência de elétrons em uma tela fluorescente. As regiões com baixa incidência de elétrons caracterizam maior densidade do material, sendo representadas por tons escuros já que uma maior quantidade de elétrons foram desviados. Regiões com tonalidade clara representa baixa densidade do material devido a alta incidência de elétrons. A figura 4 representa esta situação, mostrando através de setas o fluxo dos elétrons. Nota-se que o material mais denso desvia uma quantidade maior de elétrons que o material menos denso.

Como a representação do resultado da MET é em função da densidade, regiões densas sobrepostas geram apenas uma curva resultante da combinação destas. Como dito

Figura 4 – Representação da incidência de elétrons em função da densidade do material analisado

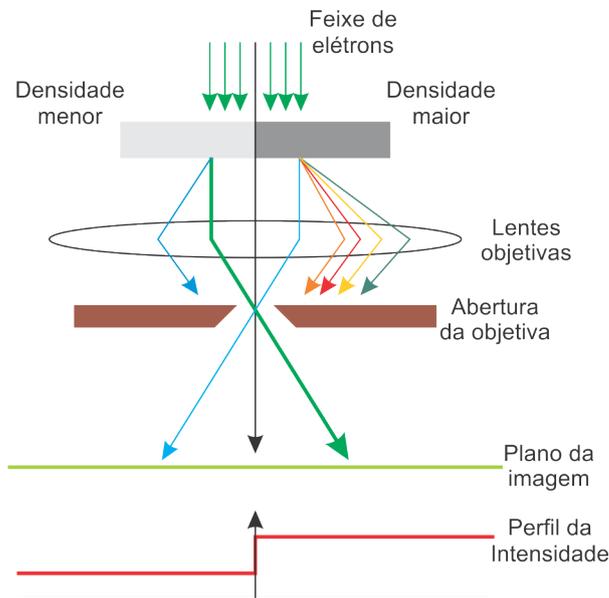


Figura adaptada de (WILLIAMS; CARTER, 2009, p. 374, part 3)

por (WILLIAMS; CARTER, 2009, p. 9, part 1, tradução nossa), “MET apresenta a nós uma imagem em 2 dimensões de amostras que são compostas de 3 dimensões”. Isto dificulta a análise da imagem e obtenção da informação desejada sobre o material analisado.

Em imagens de MET, a segmentação se torna difícil devido ao ruído que a imagem apresenta (ruído térmico dos elétrons), como apresentado por Wortmann e Fatikow (2009). Além disso, quando se trata de segmentar nanotubos de carbono, esse processo se torna mais difícil em vista que os nanotubos são estruturas cilíndricas que assumem diferentes arranjos espaciais. Podendo ter formas helicoidais, retilíneas ou curvas e sobreposição das estruturas. Além disso são quase “transparentes” devido a sua baixa densidade.

2.4 Segmentação

Segundo Bhattacharyya, Maulik e Dutta (2011) e Michailovich, Rathi e Tannenbaum (2007) o objetivo da segmentação de imagens é particionar uma imagem em algumas regiões homogêneas distintas (mutualmente exclusivas) baseado na seleção de características que representem cada região. A segmentação de uma imagem procura melhorar a descrição e compreensão da informação contida na imagem. Para Krstinic, Skelin e Slapnicar (2011) isto é um passo fundamental no processo de compreensão da informação visual.

No domínio binário, a tarefa de segmentação resume ao problema de subtração do fundo da imagem (BHATTACHARYYA; MAULIK; DUTTA, 2011).

2.5 Ponderação

Para avaliação da influência do valor de um pixel dada a sua localidade espacial foram utilizadas distribuições de pesos. Quanto mais próximo do pixel avaliado maior será a influência de um pixel. A distribuição de pesos pode variar de acordo com o método escolhido, a seguir são apresentados dois métodos comumente utilizados para cálculo da distribuição de pesos.

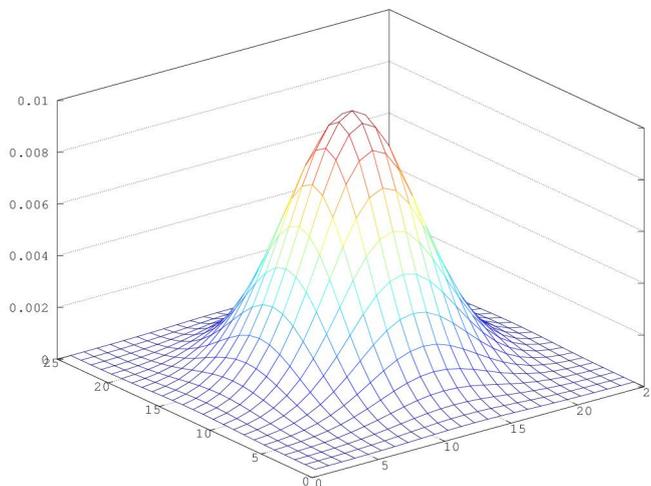
2.5.1 Gauss

Segundo Dougherty (2009) esta distribuição dada pela equação:

$$h(i, j) = A \exp^{[-1/2(d/\sigma)^2]} \quad (2.1)$$

onde A é um fator de escala, d é a distância entre o ponto e o centro da máscara ($d = \sqrt{x^2 + y^2}$) e σ é a amplitude. Essa distribuição apresenta a forma da figura 5, sendo o tamanho da máscara de 25x25, $A = 1$, e $\sigma = 4$.

Figura 5 – Exemplo de distribuição de Gauss



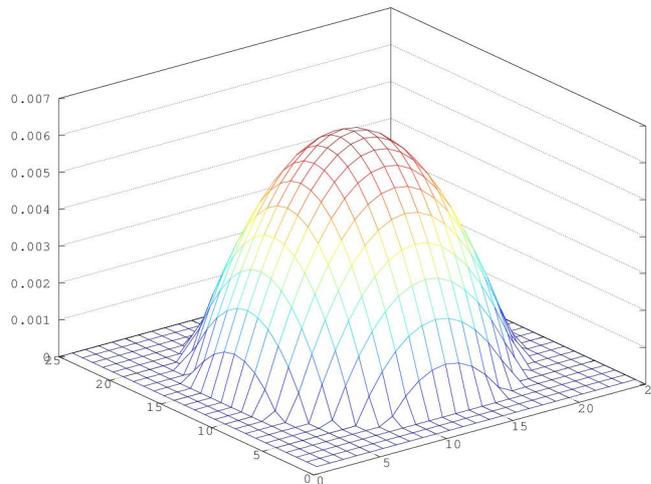
2.5.2 Epanechnikov

Distribuição dada pela equação:

$$f(x) = \frac{3}{4}(1 - (x/\sigma)^2) \quad (2.2)$$

Essa distribuição apresenta a forma da figura 6

Figura 6 – Exemplo de distribuição de Epanechnikov



2.6 Histogramas

A informação contida em uma imagem pode ser representada através de sua distribuição de probabilidades. Essa distribuição é construída a partir da análise da intensidade dos níveis de cinza ou da luminância e é conhecida como histogramas. Para a construção do histograma é calculada a probabilidade de ocorrência de cada nível de cinza conforme a equação 2.3 (BOVIK, 2009).

A informação contida em uma imagem pode ser representada através da distribuição construída a partir da análise da intensidade dos níveis de cinza ou da luminância que é conhecida como histogramas. Basicamente o processo de construção do histograma de uma imagem é a contagem da ocorrência de cada nível de cinza. Se os valores das ocorrências de cada nível de cinza forem divididos pelo número total de pixels da imagem que se está analisando tem-se a probabilidade de ocorrência de cada nível de cinza. Esta formulação pode ser expressa pela equação 2.3 (BOVIK, 2009).

$$H_f(k) = \frac{1}{MN} J \quad (2.3)$$

onde H_f é o histograma de uma imagem f , J é o número de ocorrências de k , que é o nível de cinza analisado e que varia de 0 a $2^n - 1$ sendo n o número de bits utilizados. O denominador MN é o número total de pixels (linhas(M)*colunas(N)).

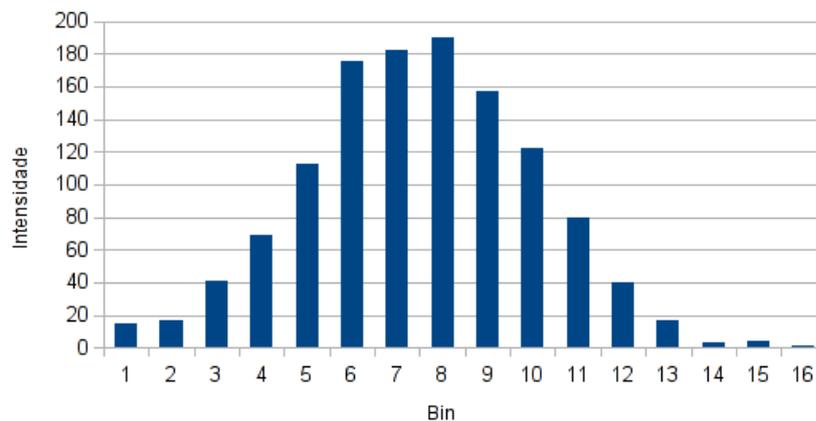
Para [Dubuisson \(2011\)](#) este agrupamento das distribuições de probabilidades é um modo de simplificar a imagem, e variando a quantização dos grupos(bins) permite controlar quanto esta distribuição é simplificada.

A complexidade do cálculo do histograma é $\theta(M \cdot N)$ visto que depende apenas do número de pixels da imagem.

Conforme [Weken, Nachtegaele e Kerre \(2007\)](#) histogramas também podem ser vistos como vetores, já que cada posição guardará o valor da ocorrência de pixels classificados em determinado bin.

A figura 7 mostra a representação gráfica de um histograma de 16 bins.

Figura 7 – Exemplo de histograma



2.7 Medidas e Métricas

Medida é a forma de quantificar a relação entre dois ou mais objetos de forma a calcular a similaridade ou diferença. Medidas de distância são utilizadas para este cálculo e, quanto menor a distância maior a semelhança entre os elementos comparados ([ACHARYA; RAY, 2005](#)). Medidas e métricas apresentam conceitos similares, sendo a métrica um caso especial de medida pois atende a algumas restrições, que são as seguintes:

- Não negativa: $d(x, y) \geq 0$
- Identidade: $d(x, y) = 0$ se e somente se $x = y$
- Simetria: $d(x, y) = d(y, x)$

- Desigualdade triangular: $d(x, y) \leq d(x, z) + d(z, y)$

O primeiro item diz que a distância é sempre positiva. Já o segundo item garante que a distância entre dois elementos somente será zero se estes forem iguais. O terceiro item assegura que a distância do elemento x até o elemento y é igual a distância do elemento y até x . O quarto restringe que a distância entre dois elementos é sempre menor ou igual a distância do primeiro elemento a um terceiro e então deste até o segundo elemento.

Serão utilizados as medidas de distância de Bhattacharyya, Hellinger, Minkowski, Manhattan, Euclidiana, Chebyshev. Estas distância serão descritas na seção 3. Algumas destas são métricas como por exemplo distância de Minkowski e suas variações. Outras não são métricas como por exemplo a distância de Bhattacharyya que não respeita o quarto item.

2.8 Medidas de qualidade

Após a segmentação é necessário que se avalie o quão bom estão os resultados obtidos. Para isso, a utilização de algum parâmetro de avaliação se torna imprescindível. Desta forma auxiliando a análise e a compreensão dos resultados.

Os pixels que compõem o resultado, serão classificados em 4 categorias que são, verdadeiros positivos, falsos positivos, falsos negativos e verdadeiros negativos. Neste trabalho a classificação positiva representa que o pixel classificado é dito como sendo parte de um nanotubo. Já classificações negativas dizem que os pixels fazem parte do fundo da imagem. Os verdadeiros positivos serão aqueles pixels classificados como positivos e que realmente são. Já os falsos positivos serão os que foram classificados como positivo, mas que na verdade deveriam ser classificados como negativo. Os pixels classificados como negativos mas que deveriam ser positivos serão classificados como falsos negativos. E os classificados como negativos e que realmente são fazem parte dos verdadeiros negativos.

Sendo assim podemos realizar algumas operações matemáticas que quantizarão a qualidade de uma óptica diferentee relacionando estas 4 classificações. A seguir serão apresentadas algumas das medidas mais utilizadas que foram descritas por (DOUGHERTY, 2009).

2.8.1 Precisão

Precisão (P), é utilizada para mostrar a porcentagem de acerto dentre os resultados classificados como positivos. A equação 2.4 é utilizada para calcular este valor.

$$\text{Precisão} = \frac{\text{N}^{\circ}\text{de Verdadeiros Positivos}}{\text{N}^{\circ}\text{de Verdadeiros Positivos} + \text{N}^{\circ}\text{de Falsos Positivos}} \quad (2.4)$$

2.8.2 Sensibilidade

Também será utilizado para avaliação dos resultados a medida de sensibilidade (S) que é a probabilidade de um pixel classificado como positivo ser realmente positivo, equacionando tem-se:

$$\text{Sensibilidade} = \frac{\text{N}^\circ\text{de Verdadeiros Positivos}}{\text{N}^\circ\text{de Verdadeiros Positivos} + \text{N}^\circ\text{de Falsos Negativos}} \quad (2.5)$$

2.8.3 Especificidade

Outra medida usada é a especificidade (E), que é a probabilidade de um pixel classificado como negativo ser realmente negativo, isto pode ser representado pela equação 2.6.

$$\text{Especificidade} = \frac{\text{N}^\circ\text{de Verdadeiros Negativos}}{\text{N}^\circ\text{de Verdadeiros Negativos} + \text{N}^\circ\text{de Falsos Positivos}} \quad (2.6)$$

3 Fundamentação teórica

A seguir serão apresentados os métodos para o cálculo da distância entre histogramas que foram comparados. Os métodos apresentados foram escolhidos dada à popularidade de seu emprego. Alguns destes métodos são mais comumente utilizados, podendo citar distâncias Euclidiana e Manhattan, conforme dito por [Kamarainen et al. \(2003\)](#). Todos os métodos apresentam complexidade $\theta(N)$, onde N é o número de bins do histograma, o que significa que o tempo de execução é linear.

3.1 Distância de Bhattacharyya

Mede a similaridade entre duas distribuições de probabilidades através do cálculo da sobreposição entre as funções de distribuição de probabilidade ou populacional. A distância de Bhattacharyya não é uma métrica pois não obedece a condição de desigualdade triangular que foi descrita na seção [2.7](#).

Exemplos de uso desta distância pode ser encontrado em [Leichter \(2012\)](#), utilizada para rastrear um “alvo” em uma sequência de imagens e em [Guorong, Peiqi e Minhui \(1996\)](#) como critério de seleção da característica para o reconhecimento de padrões.

A distância de Bhattacharyya pode ser definida pela equação [3.1](#).

$$D_B = -\ln(BC) \quad (3.1)$$

onde BC é o coeficiente de Bhattacharyya, que é definido por:

$$BC = \sum_{x=1}^n \sqrt{P(x) * Q(x)} \quad (3.2)$$

onde $P(x)$ e $Q(x)$ são duas distribuições de probabilidades(histogramas) e n é o número de bins, ou seja, níveis de cinza utilizados.

3.2 Distância de Minkowski (L_p)

Quando os histogramas são vistos como vetores uma das mais populares métricas é a distância de Minkowski ([WEKEN; NACHTEGAEL; KERRE, 2007](#)), Esta distância também é conhecida como distância L_p pois é parametrizada por p . A equação matemática da

distância de Minkowski apresentada por [Castelli e Bergman \(2002, p. 381\)](#) é descrita abaixo:

$$D_{Mink} = L_p = \left[\sum_{x=1}^n |P(x) - Q(x)|^p \right]^{\frac{1}{p}} \quad (3.3)$$

onde $P(x)$ e $Q(x)$ são os pontos analisados, que no caso estudado são os bins dos histogramas comparados.

A distância de Minkowski é comumente utilizada com o parâmetro p sendo 1 ou 2, podendo no limite ser igual a ∞ . Para estes casos esta distância é conhecida por nomes distintos, sendo distância de Manhattan, Euclidiana e de Chebyshev, respectivamente. Estes casos serão apresentados a seguir.

O parâmetro p do método da distância de Minkowski para ser utilizado como expoente foi definido como sendo igual a 3, pois como visto os valores de p sendo 1 e 2 são definidos como casos especiais. Esta distância é uma métrica assim como as suas variantes.

3.3 Distância de Manhattan (L_1)

A distância de Manhattan pode ser entendida como sendo a distância percorrida para ir de um ponto a outro dentro de uma cidade onde os quarteirões são quadrados de mesmo tamanho. Logo esta distância é a soma das distâncias em cada dimensão do espaço analisado. Em [Castelli e Bergman \(2002, p. 380\)](#) temos a seguinte definição da distância de Manhattan:

$$D_{Manh} = L_1 = \sum_{x=1}^n |P(x) - Q(x)| \quad (3.4)$$

3.4 Distância Euclidiana (L_2)

Em um plano cartesiano a distância Euclidiana é a menor distância entre dois pontos, sendo a linha reta que conecta estes pontos. [Castelli e Bergman \(2002, p. 380\)](#) define a distância euclidiana da seguinte forma:

$$D_{Eucl} = L_2 = \sqrt{\sum_{x=1}^n (P(x) - Q(x))^2} \quad (3.5)$$

3.5 Distância de Chebyshev (L_∞)

É a máxima diferença entre os valores das dimensões analisadas. A equação 3.6 é utilizada para calcular esta distância (CASTELLI; BERGMAN, 2002, p. 380).

$$D_C = L_\infty = \max_x (|P(x) - Q(x)|) \quad (3.6)$$

3.6 Distância de Hellinger

Quantifica a similaridade entre distribuições de probabilidade. Utilizada em (DAVIES et al., 2007) e (DAVIES et al., 2009) para medir a qualidade dos histogramas gerados, como apresentado por (ROZENHOLC, 2006). Rozenholc, Mildenberg e Gather (2010, p. 3314) apresenta a distância de hellinger elevada ao quadrado na forma de uma integral. O equacionamento na forma não quadrada para uma distribuição discreta é dada pela equação 3.7.

$$D_h = \frac{1}{\sqrt{2}} \sqrt{\sum_{x=1}^n (\sqrt{P(x)} - \sqrt{Q(x)})^2} \quad (3.7)$$

3.7 Distância de Ângulo Cosseno

Esta distância trata o histograma como sendo um vetor, sendo cada bin uma dimensão do espaço. O ângulo formado entre dois vetores pode dizer o quanto estes vetores são similares, ou seja, avaliando se possuem direção e sentido semelhantes.

$$D_{\cos} = \frac{P(x) \cdot Q(x)}{|P(x)| \times |Q(x)|} \quad (3.8)$$

3.8 Qui-quadrado (X^2)

Calcula a similaridade entre duas distribuições de probabilidade. Segundo Weken, Nachtegael e Kerre (2007, p. 188) “é uma função de distância para histogramas baseada em estatística”, ele define matematicamente como:

$$D_{X^2} = \sum_{x=1}^n \frac{(P(x) - Q(x))^2}{P(x) + Q(x)} \quad (3.9)$$

3.9 Diferença de Entropia

A entropia utilizada é a Entropia de Rényi (1961), dada pela equação 3.10, que generaliza outras três entropias. A entropia quantifica a diversidade, incerteza ou aleatoriedade do sistema.

$$DR_\alpha = \frac{1}{1-\alpha} \log_2 \left(\sum_{x=1}^n P(x)^\alpha \right) \quad (3.10)$$

onde $\alpha > 0$ e $\alpha \neq 1$.

A seguir as variações da entropia de Rényi que são casos especiais para valores de α .

3.9.1 Entropia de Shannon (parâmetro $\alpha = 1$)

Em Rényi (1961) há a prova que

$$\lim_{\alpha \rightarrow 1} \left[\frac{1}{1-\alpha} \log_2 \left(\sum_{x=1}^n P(x)^\alpha \right) \right] \quad (3.11)$$

é igual a entropia de Shannon, que é obtida com a equação 3.12.

$$DR_1 = - \sum_{x=1}^n P(x) \log_2 P(x) \quad (3.12)$$

3.9.2 Entropia de Rényi (parâmetro $\alpha = 2$)

Apesar da definição da entropia de Rényi permitir a variação do parâmetro α a entropia de Rényi é comumente utilizada com $\alpha = 2$, desta forma temos a equação 3.13 para o cálculo desta entropia.

$$DR_2 = - \log_2 \sum_{x=1}^n P(x)^2 \quad (3.13)$$

3.9.3 Min-entropia (parâmetro $\alpha = \infty$)

Dentre as entropia de Rényi é a apresenta menor valor.

$$DR_\infty = - \log_2 \max_x P(x) \quad (3.14)$$

4 Metodologia

Os métodos de medida de distância entre histogramas foram aplicados em oito imagens de microscopia eletrônica de transmissão, cada uma com resolução de 512x512 pixels, que utilizam 8 bits para representação dos níveis de cinza. Todas estão no formato TIFF e foram cedidas por Patricia Rodrigues da Silva e Pamela A. M. dos Santos, e foram obtidas no centro de microscopia da UFRGS (CME) (<http://www.cme.ufrgs.br>) no equipamento Microscópio Eletrônico de Transmissão JEOL JEM 1200ExII.

O ambiente utilizado para executar os algoritmos dos métodos foi o ambiente matemático de código fonte aberto Octave¹, que é um software semelhante ao software proprietário MatLab², utilizado juntamente com o pacote para processamento de imagens. O computador utilizado possui um processador Intel Core i5, modelo M460 de 2.53GHz, com 4 GB de memória RAM. O sistema operacional é Linux, distribuição Gentoo, com kernel versão 3.1.4 para x86_64(32 e 64 bits).

4.1 Modelo de histograma

Para realizar a classificação primeiramente foram extraídos os modelos de ruído, que são as médias de 20 áreas das imagens que contêm apenas ruído. Este cálculo foi feito para cada tamanho de janela analisado. A figura 8 mostra graficamente o método utilizado. Este procedimento foi realizado para janelas de tamanho de 3x3 variando até 35x35 pixels sendo sempre o valor da lateral um número ímpar.

4.2 Comparação entre os histogramas

A metodologia utilizada para o processamento da imagem é a seguinte, para cada janela extraída da imagem que está sendo segmentada calcula-se o seu histograma, para então compará-lo ao histograma do modelo de ruído que já foi previamente calculado. A figura 9 representa esta metodologia.

As medidas de distância foram obtidas através das formulações apresentadas no capítulo 3. Para os métodos que utilizam o valor da entropia a distância é a diferença de entropia entre os histogramas do ruído e da janela analisada.

¹<http://www.gnu.org/software/octave/>

²<http://www.mathworks.com/products/matlab/>

Figura 8 – Metodologia para geração do modelo de ruído

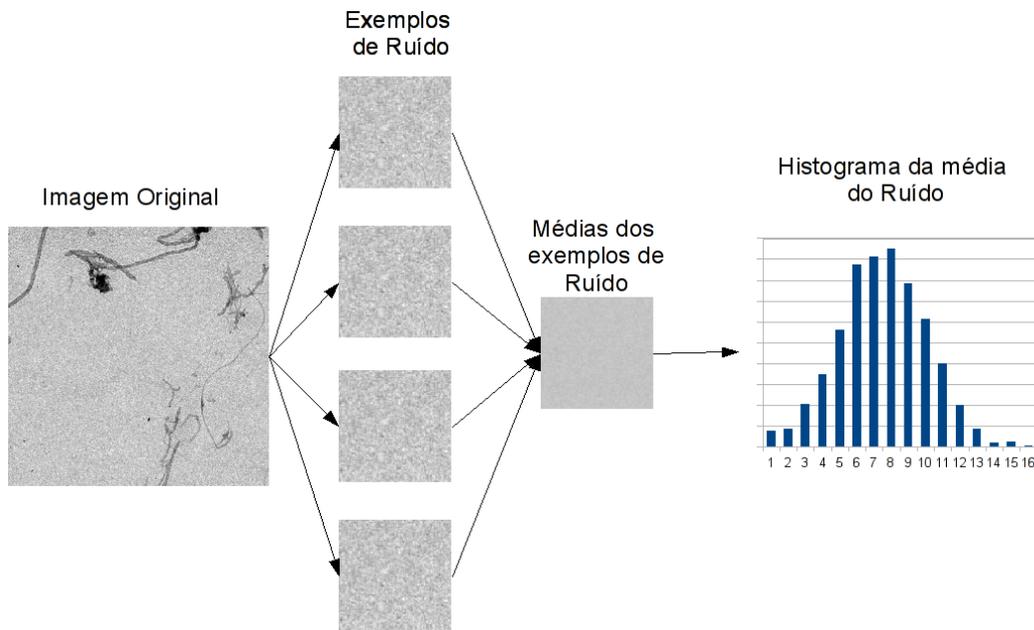
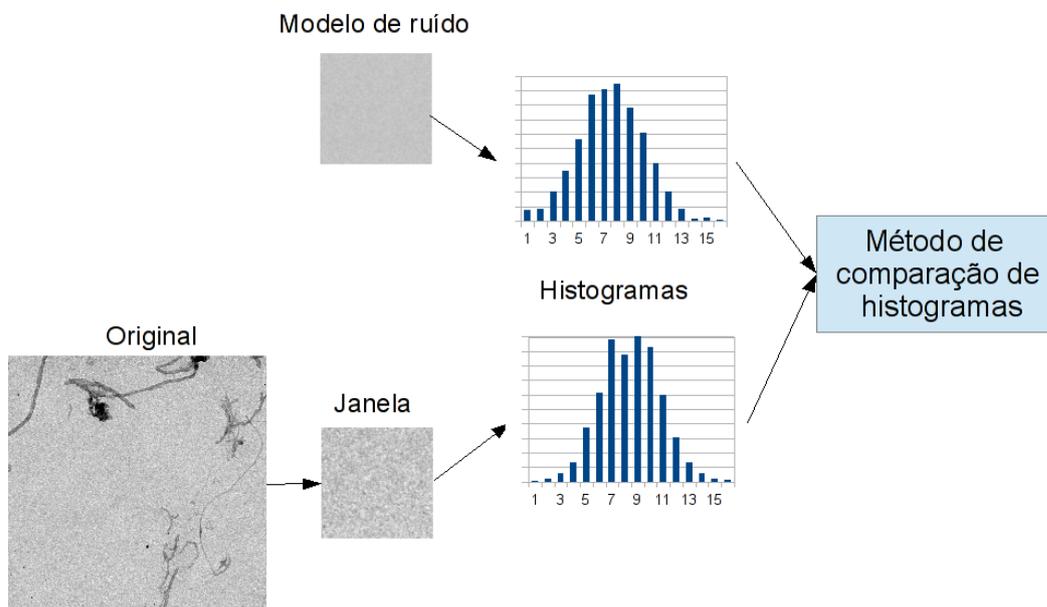


Figura 9 – Metodologia para processamento da imagem



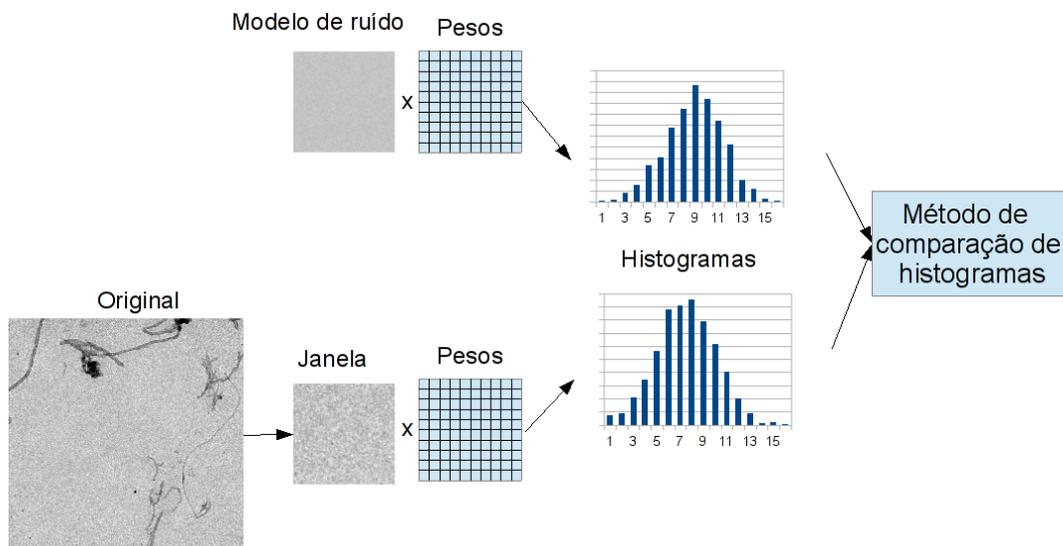
O valor das distâncias encontradas para cada método foram atribuídos a uma matriz de distâncias na posição referente ao centro da janela que foi extraída da imagem.

Além dos testes feitos com diferentes tamanhos de janelas, foram realizados testes com variação do número de bits da representação dos níveis de cinza, variando de 3 a 8 bits, representando assim de 8 a 256 níveis de cinza respectivamente. Esta avaliação foi feita para saber se a quantidade de bits, ou seja, quantidade de informação da luminosidade, influencia na comparação entre os histogramas. Desta forma, quanto menor o número de bits utilizado maior é a aglomeração de níveis de cinza em um mesmo bin. Isto avalia por

exemplo a redução do espalhamento dos níveis de cinza em um histograma com muitos bins de uma região pequena ou aumentar o espalhamento quando se tem regiões grandes e avalia-se um pequeno número de bins.

Além do cálculo simples das distâncias dos histogramas também foi avaliado histogramas gerados a partir de janelas onde foram atribuídos pesos aos valores dos pixels. Foi utilizado a distribuição de Gauss e de Epanechnikov para atribuir pesos a cada valor. Cada janela foi ponderada no momento da análise, mas antes da geração do histograma. A figura 10 exemplifica este processo.

Figura 10 – Metodologia para processamento da imagem utilizando pesos



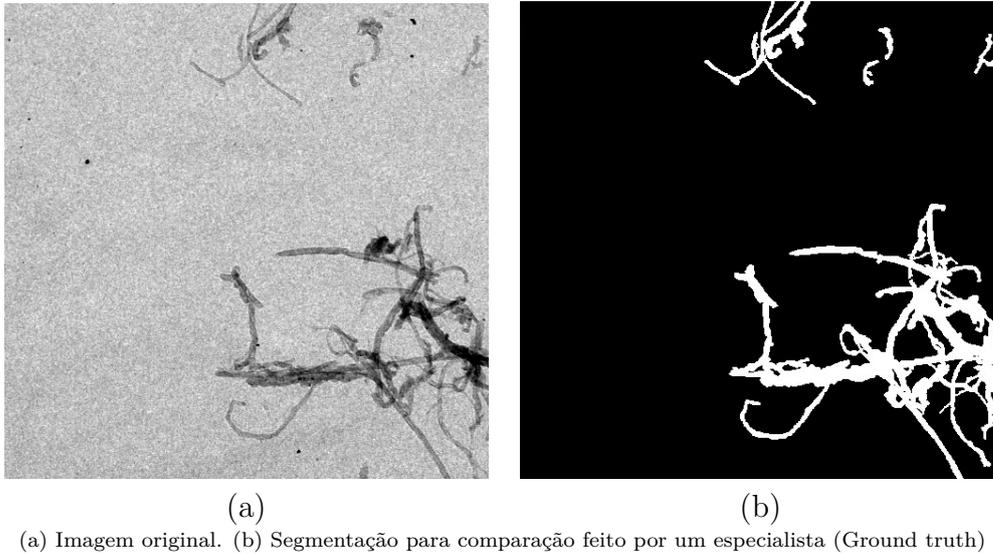
4.3 Padrões de resultado

Os padrões para comparação foram feitos manualmente por um especialista, utilizando de ferramentas gráficas para marcação das áreas que continham nanotubos. Após este procedimento, a imagem foi binarizada. Desta forma os pixels foram classificados como fundo (valor lógico 0) e regiões que continham NTC (valor lógico 1). A figura 11 mostra um exemplo de padrão gerado.

4.4 Normalização dos resultados

As distâncias apresentam proporções diferente, por exemplo, a distâncias de Hellinger apresenta resultados entre 0 e 1, já a distância de Manhattan varia de 0 a $2^*(n^{\circ}\text{de pixels da janela})$. Para melhor comparação entre os métodos as distâncias encontradas foram normalizadas, ficando compreendidas entre 0 e 1. Deste modo a análise ficou em função da porcentagem da distâncias do histograma do ruído. Sendo, por exemplo, segmentados os 12% mais próximos do histograma do ruído.

Figura 11 – Exemplo de padrão de comparação



Alguns métodos exigem a normalização do histograma antes de aplicar os métodos, já que o tratam como sendo uma distribuição de probabilidades, sendo assim seu somatório tem que ser igual a 1. Por exemplo a distância de Bhattacharyya e Hellinger. Outros métodos não exigem tal normalização, mas que se for realizada não afetará os resultados finais.

4.5 Comparação dos resultados

O ranqueamento é feito em função da multiplicação entre sensibilidade e precisão. Isto por causa que mesmo para casos em que a sensibilidade e especificidade tenham valores altos não significa que o resultado seja o esperado. Por exemplo, na imagem 12 é apresentado um caso em que a sensibilidade e especificidade possuem valor de 96%. Como pode ser observado não é um bom resultado embora a sensibilidade e especificidade tenham valores altos. Isto se dá ao fato que o número de verdadeiros negativos é muito maior que o número de falsos positivos, mascarando assim os defeitos encontrados. Para sanar este problema e utilizar apenas um fator para comparação entre os métodos é utilizado um fator que compreende sensibilidade e precisão. Este fator neste trabalho será chamado de fator SP.

As medidas de sensibilidade e precisão foram escolhidas por compreender os valores dos verdadeiros positivos, falsos negativos e falsos positivos. Desta forma a grande quantidade de verdadeiros negativos não influencia no fator de comparação. Esta medida apresenta as características de uma probabilidade, já que seu domínio e imagem estão entre 0 e 1. Quando a sensibilidade for 1, significa que não há falsos negativos. Se a precisão for igual a 1 significa que os falsos positivos não ocorreram. Se ambos forem

Figura 12 – Resultado insatisfatório - exemplo

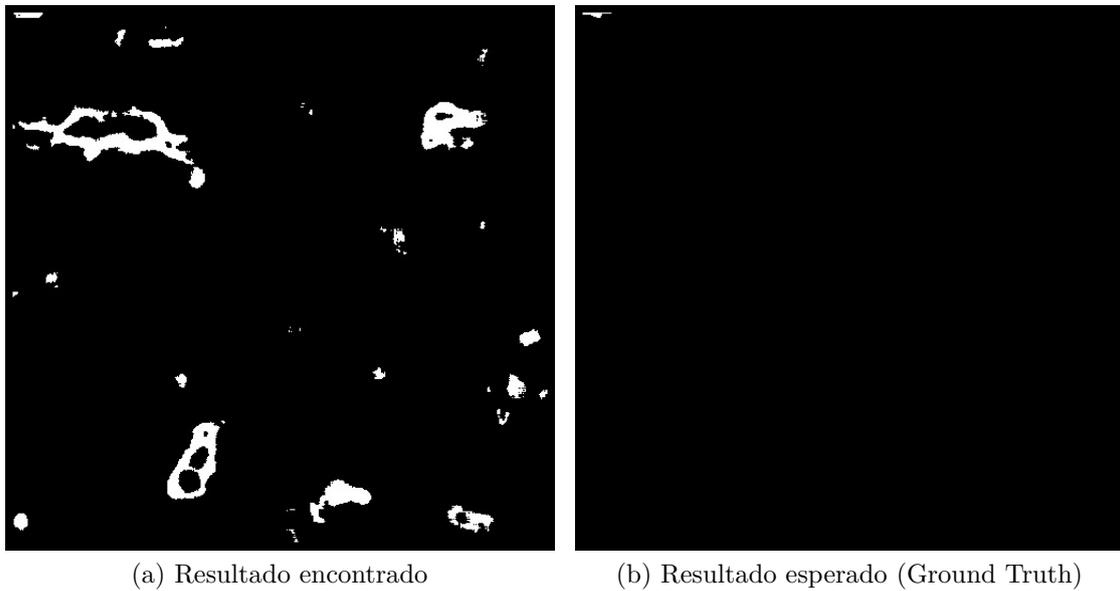
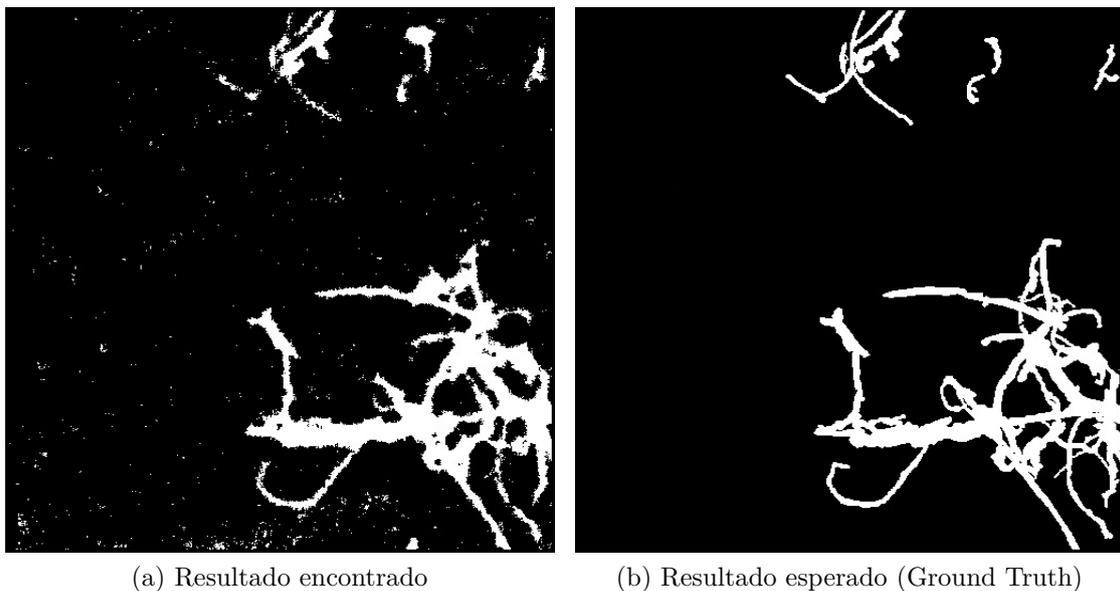


Figura 13 – Resultado satisfatório - exemplo



iguais a 1 significa que não há ocorrência de classificação errada e logo o fator também assume valor 1, garantindo assim que o valor da sensibilidade também será máximo, ou seja, 1, não importando a sua proporção em relação aos verdadeiros positivos. A figura 13 mostra um caso classificado como bom por esta metodologia. O resultado da figura 12 foi classificado com 6º melhor considerando o ponto de interseção entre as curvas de sensibilidade e especificidade. Adotando o fator SP passa a ser classificado na posição 16627. Já o melhor resultado considerando o fator SP subiu sua classificação de 77º para 1º.

5 Resultados

Para avaliação dos resultados foi feito o seguinte procedimento, os resultados de cada método foram ordenados de modo decrescente com base no valor do fator SP, que é o valor da sensibilidade multiplicado pela precisão (como descrito na seção 4.5). Então, foi feita a análise com base na porcentagem dos resultados. Ou seja, qual a configuração predominante em uma dada porcentagem contendo os melhores resultados.

O valor do threshold mostrados nos resultados representa a porção considerada das distâncias, ou seja, a porcentagem das maiores distâncias encontradas. Já que a comparação foi feita com o histograma do modelo de ruído o que se deseja é o que possui maior distância.

5.1 Resultados por método

5.1.1 Distância de Bhattacharyya

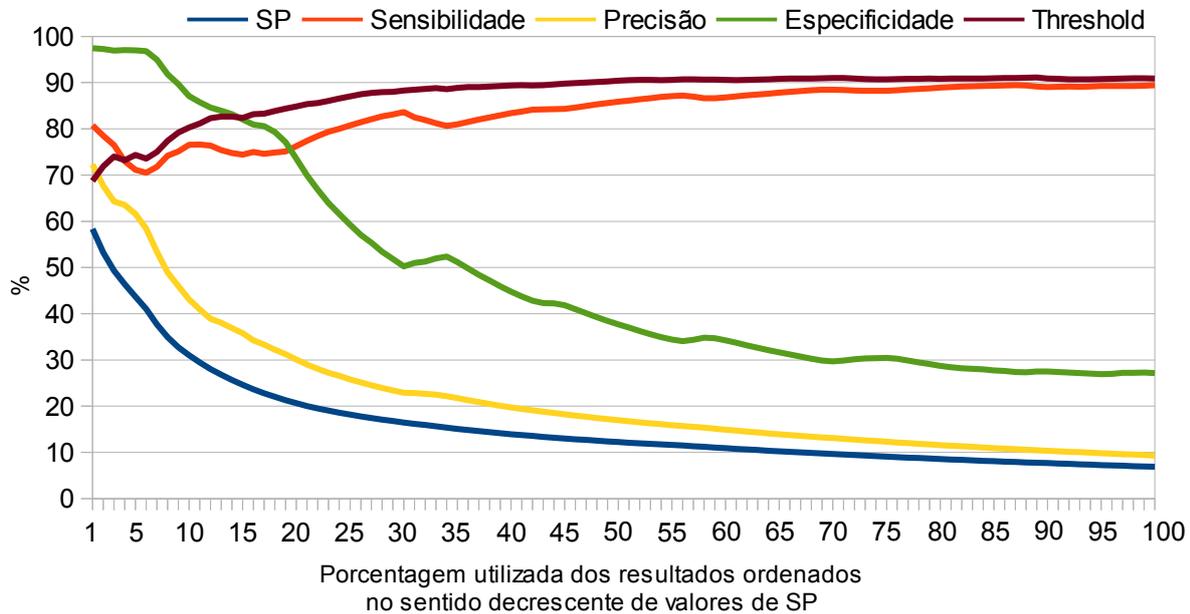
Como melhor resultado o método de Bhattacharyya apresentou a seguinte configuração: 8 bits para representação dos níveis de cinza, distribuição de pesos de Gauss, janela de tamanho 7x7 pixels e threshold de 64%. Com esta configuração obteve fator SP de 66,58%. Mas se a análise se estender para os outros resultados temos que o valor máximo da média do fator SP para este método foi de 58,4% para 1% dos resultados. Percebe-se que quanto maior a porcentagem analisada menor é o valor encontrado. Isto pode ser observado na figura 14 que mostra as curvas do fator SP, da sensibilidade, especificidade, precisão e threshold. Estas curvas representam a situação de cada variável dada a porcentagem dos resultados que está sendo considerada. Lembrando que estes resultados estão ordenados com base no valor do fator SP, de forma de decrescente.

Ainda na mesma figura é observado que o valor do threshold dos resultados está entre 68,71% e 91,12% das maiores distâncias.

Assim como no melhor resultado, até 66% dos resultados a quantidade de 8 bits para a representação dos níveis de cinza é a mais utilizada. Analisando os percentuais percebe-se que os até 6% dos resultados 8 bits é o único a ser utilizado, sendo que a partir deste percentual as outras quantidades começam a ocorrerem.

Quanto a distribuição de pesos utilizada, para 1% dos melhores resultados a distribuição utilizada é a de Gauss, da mesma forma que o melhor resultado do método. Se estender a análise para porcentagens maiores, a não utilização de pesos se torna mais

Figura 14 – Curvas das medidas de qualidade e de threshold para o método de Bhattacharyya



frequente dentre 61% dos resultados.

Analisando a ocorrência de cada tamanho de janela utilizada nos testes, percebe-se que para este método não há um tamanho que possa ser dito que se sobressaia aos demais. As distribuições apresentam ocorrência com percentuais próximos, com desvio padrão de 2%. Semelhante ao melhor caso, 1% dos resultados apresentam 23,5% de ocorrência da janela de tamanho 7x7. A oscilação entre o tamanho de janela mais frequentemente utilizada é representada na figura 18.

As figuras 15, 16, 17 e 18 apresentam as curvas de ocorrência para as porcentagens analisadas. Na figura 15 é mostrado o comportamento da ocorrência dos diferentes números de bits utilizados para a representação dos níveis de cinza. As ocorrências das distribuições de pesos é apresentada na figura 16. A frequência da dimensão das janelas é apresentada na figura 17 e a indicação da dimensão de janelas mais frequente por porcentagem analisada é mostrada na figura 18.

Figura 15 – Curvas da ocorrência do número de bits utilizados para definir o número de bins dos histogramas utilizados para o método de Bhattacharyya

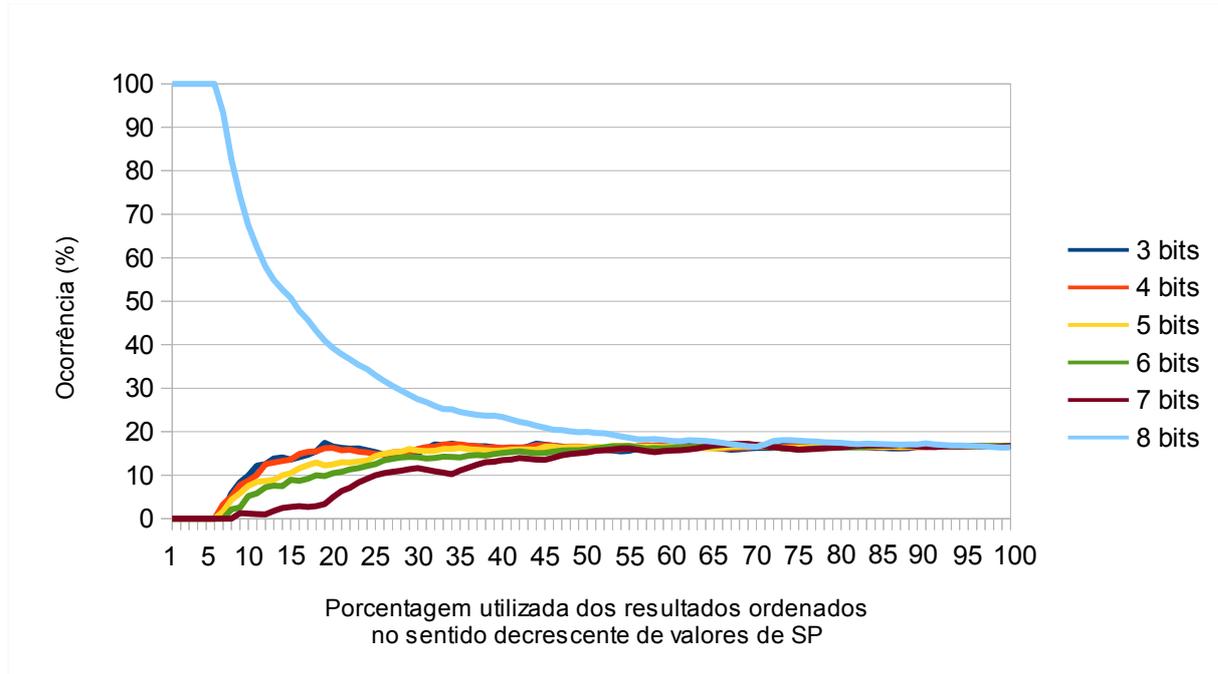


Figura 16 – Curvas de ocorrência da utilização ou não da máscara de pesos para o método de Bhattacharyya

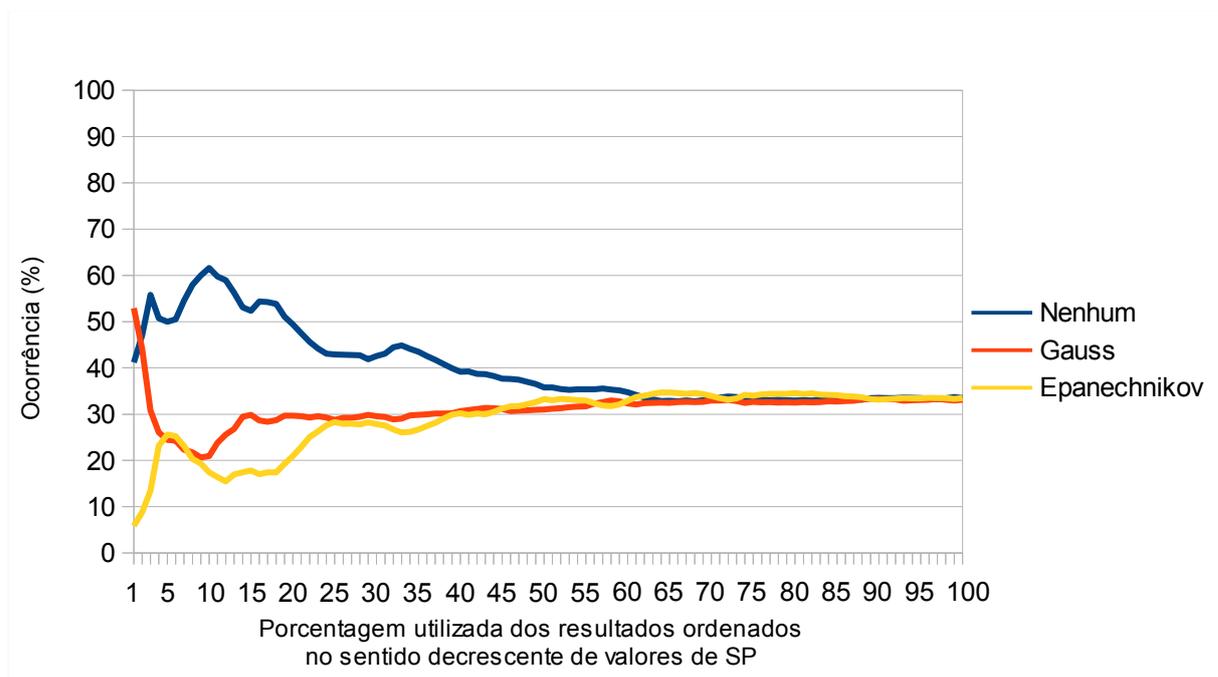


Figura 17 – Curvas de ocorrência da dimensão das janelas para o método de Bhattacharyya

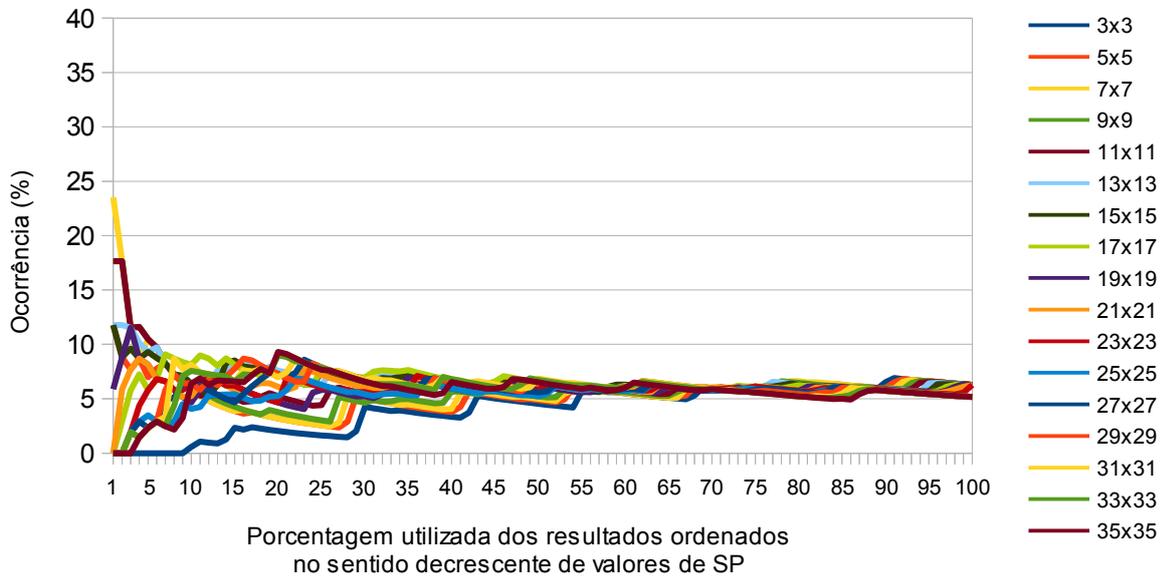
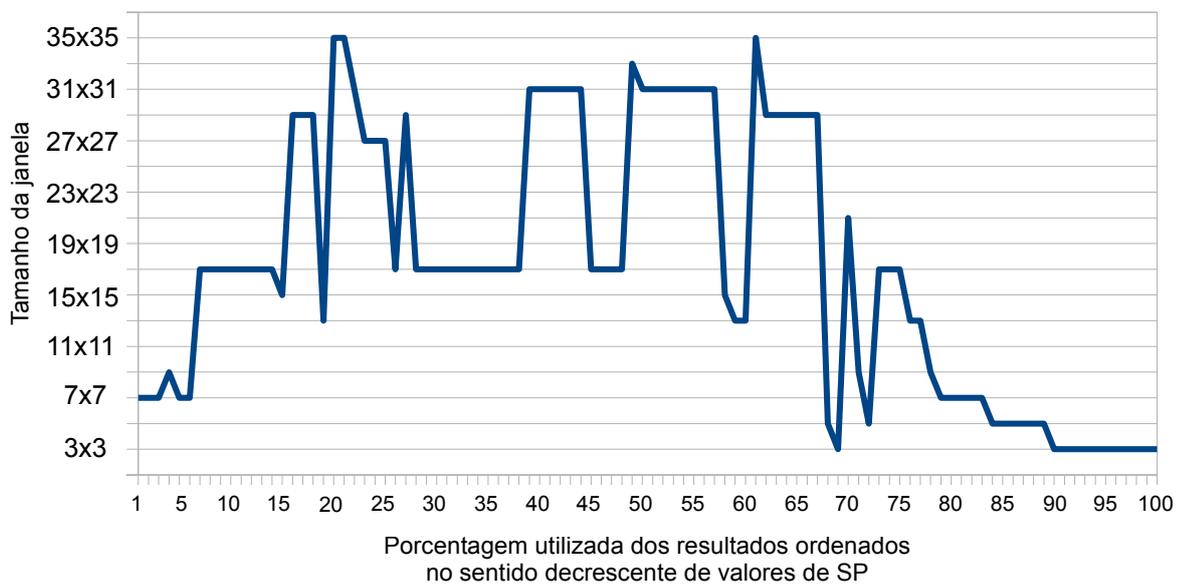


Figura 18 – Curva da dimensão das janelas mais frequentes para o método de Bhattacharyya



5.1.2 Distância de Minkowski e suas variantes

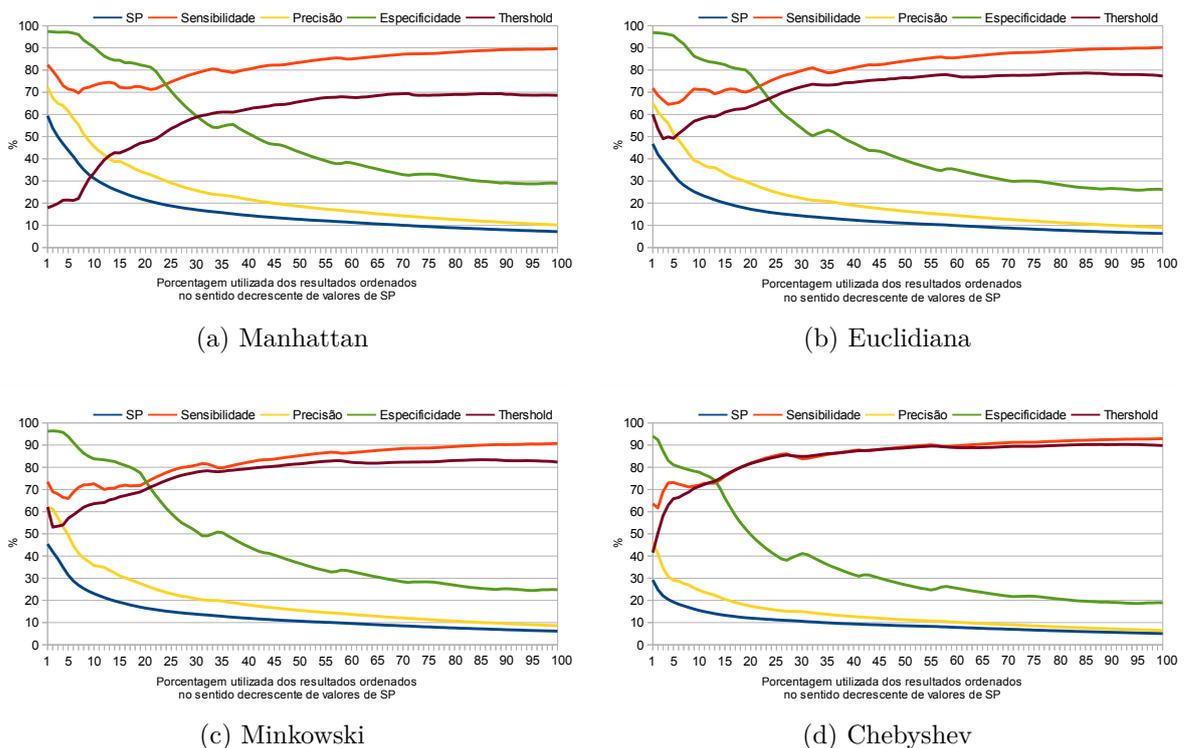
Analisando a distância de Minkowski e suas variantes, distância de Manhattan, Euclidiana e Chebyshev, percebe-se uma grande semelhança entre as curvas que caracterizam as frequências das variáveis analisadas. Mas embora estas curvas sejam parecidas os melhores resultados de cada distância apresentam diferenças. Estas diferenças estão discriminadas na tabela 1.

Tabela 1 – Tabelas com os melhores resultados para a distância de Minkowski e seus casos especiais

Distância	SP	NºBits	Dist. de peso	Tam. da janela	Threshold
Manhattan(L_1)	67,5%	8	Gauss	7x7	18%
Euclidiana(L_2)	53,7%	8	Gauss	11x11	73%
Minkowski(L_3)	52,7%	8	Gauss	11x11	83%
Chebyshev(L_∞)	32,6%	8	Nenhuma	31x31	56%

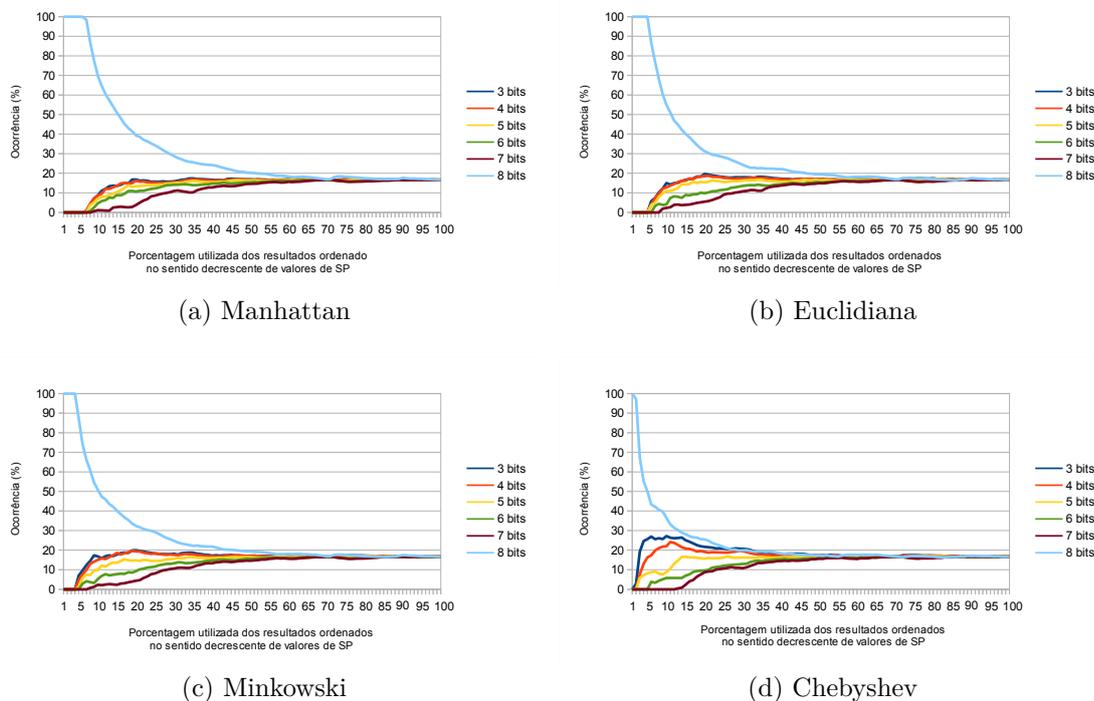
As medidas de distância baseadas na distância de Minkowski apresentam curvas de medida de qualidade semelhantes. Pode-se notar que a curva dos valores de threshold possui valores mais altos e que os valores da curva do fator SP diminuem quando aumenta o parâmetro p . Os gráficos da figura 19 mostram estas diferenças.

Figura 19 – Curvas das medidas de qualidade e de threshold para o método de Minkowski suas e variantes



Para todas as variantes, 8 bits é a quantidade mais utilizada pelo menos em 25% dos resultados. A distância de Chebyshev, apresenta a porcentagem de 8 bits com decaimento mais rápido que as outras medidas, possuindo uma maior participação das outras quantidades de bits. Na figura 20 pode ser vista a semelhança entre as distâncias de Manhattan, Euclidiana e Minkowski em relação à participação da quantidade de bits dentre os resultados. Também pode ser visto a diferença apresentada pela distância de Chebyshev em 20(d).

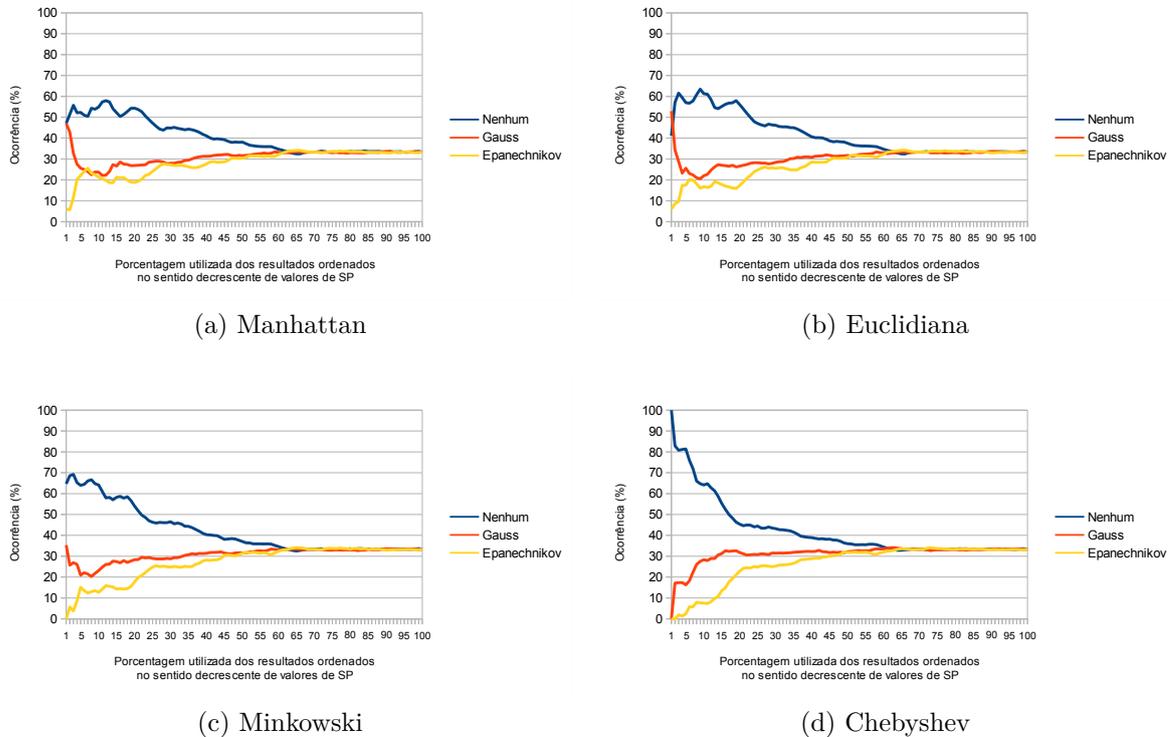
Figura 20 – Curvas das ocorrências do número de bits utilizados para definir o número de bins dos histogramas utilizados para o método de Minkowski e suas variantes



Novamente a distância de Chebyshev apresenta diferença das demais distâncias derivadas da distância de Minkowski, só que desta vez é na análise da utilização da distribuição de pesos. Enquanto as outras distâncias apresentam a não utilização ou a distribuição de Gauss como as mais frequentes entre os melhores resultados, a distância de Chebyshev apresenta para qualquer porcentagem a não utilização de distribuições de pesos com mais frequência. Quando analisa-se percentuais maiores a diferença entre os métodos diminui. A semelhança entre as distâncias fica mais evidente a partir de porcentagens maiores que 15%. A figura 21 apresenta as curvas de ocorrência das distribuições de peso em função da porcentagem considerada dos resultados.

Do mesmo modo que a distância de Bhattacharyya, as distâncias baseadas na distância de Minkowski apresentam grande variação na ocorrência dos diferentes tamanhos de janelas. Os gráficos apresentados na figura 22 mostram tal variação. A figura 23 apresenta as curvas que mostram qual o tamanho de janela mais frequente dada a porcen-

Figura 21 – Curvas das ocorrências da utilização ou não da máscara de pesos para o método de Minkowski e suas variantes



tagem analisada. Percebe-se novamente que os métodos apresentam curvas semelhantes, com pequenas diferenças.

5.1.3 Distância de Hellinger

Apresenta curvas de qualidade semelhantes às apresentadas pelos outros métodos tendo 58,4% como maior valor da média do fator SP. Suas curvas de qualidade (figura 24) são praticamente iguais as da distância de Bhattacharyya (figura 14) diferindo apenas na curva da média do valor de threshold. A curva de threshold da distâncias de Hellinger possui valores inferiores à da distância de Bhattacharyya. Nas figuras 25, 26 e 27 mostram a semelhança entre os métodos da distância de Hellinger e Bhattacharyya. Sendo assim a análise feita para o método de Bhattacharyya também se aplica à distância de Hellinger.

5.1.4 Ângulo Cosseno

Esta medida de distância apresenta resultados diferentes das vistas anteriormente. Primeiramente, possui a segunda menor média do fator SP, aproximadamente 21% e que pode ser visto na figura 28. Além disso a quantidade de bits utilizada com maior frequência entre os melhores resultados (cerca de 51%) desta distância é 7 bits, diferentemente das outras distâncias que apresentaram 8 bits. A ocorrência dos diferentes números de

Figura 22 – Curvas das ocorrências da dimensão das janelas para o método de Minkowski e variantes

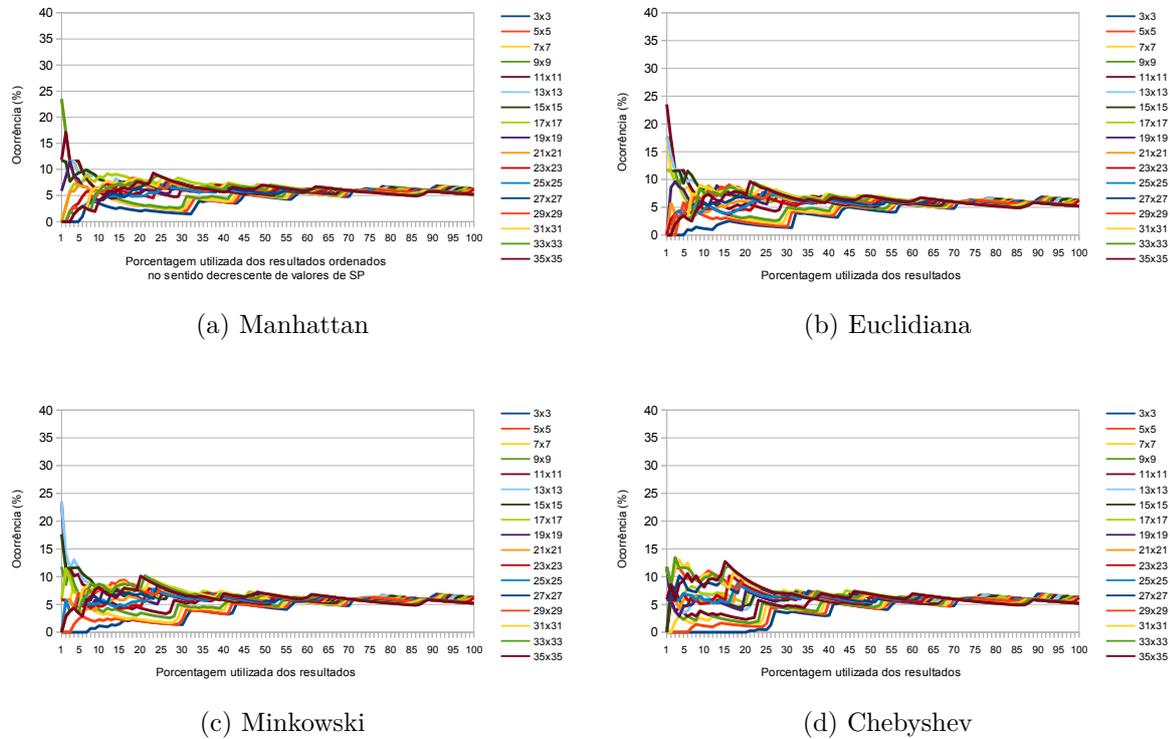
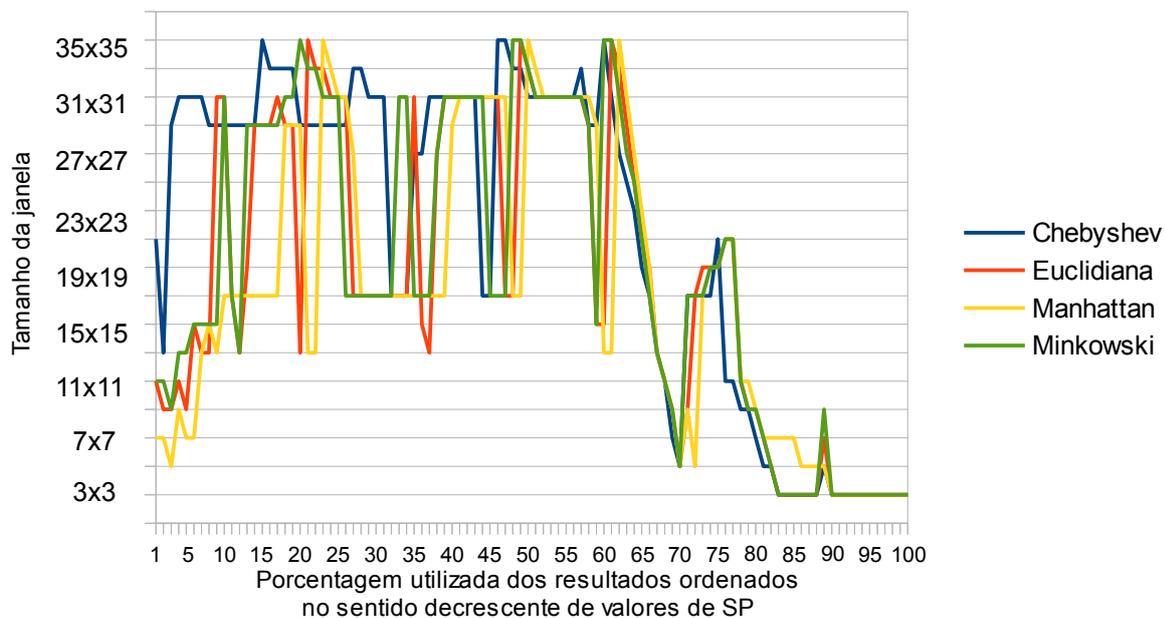


Figura 23 – Curvas da dimensão das janelas mais frequentes para o método de Minkowski e variantes



bits pode ser vista na figura 29. Analisando a utilização da distribuição de pesos, até 22% das respostas a distribuição de Gauss foi a mais utilizada entre os resultados con-

Figura 24 – Curvas das medidas de qualidade e de threshold para o método de Hellinger

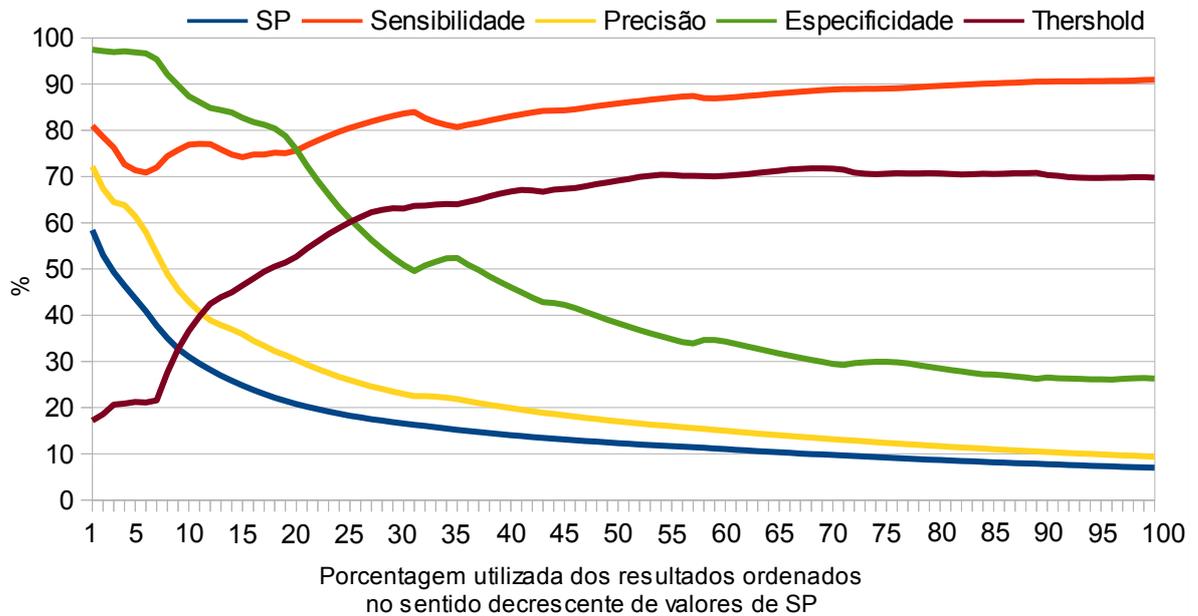


Figura 25 – Comparação entre as curvas de ocorrência do número de bits utilizados para definir o número de bins dos histogramas utilizados das distâncias de Hellinger e Bhattacharyya

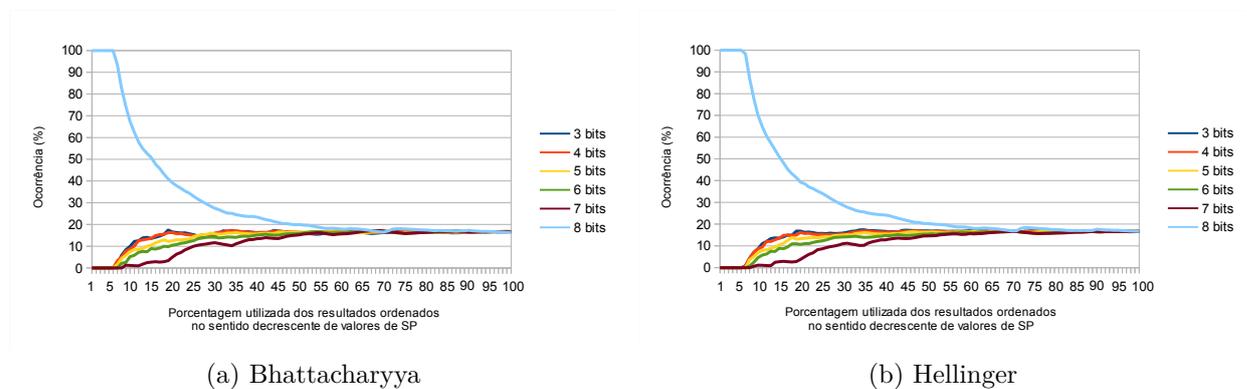


Figura 26 – Comparação entre as curvas de ocorrência da utilização ou não da máscara de pesos das distâncias de Hellinger e Bhattacharyya

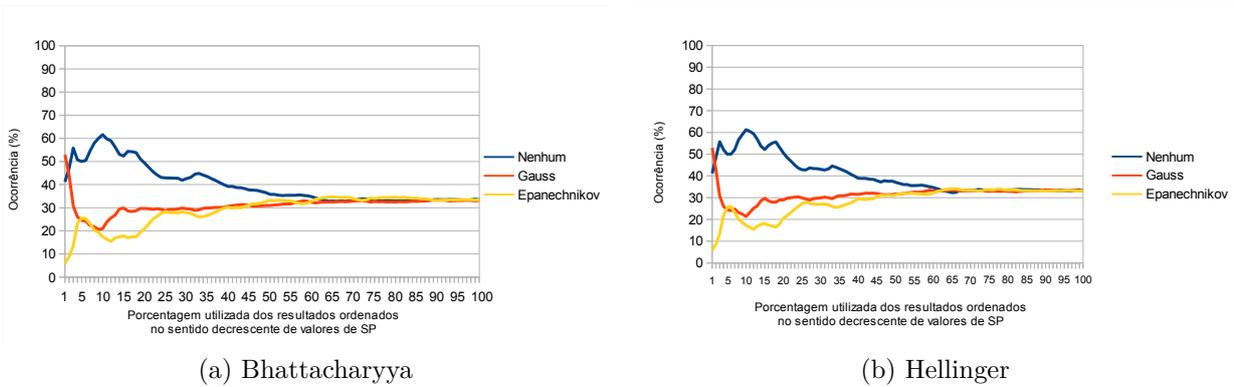
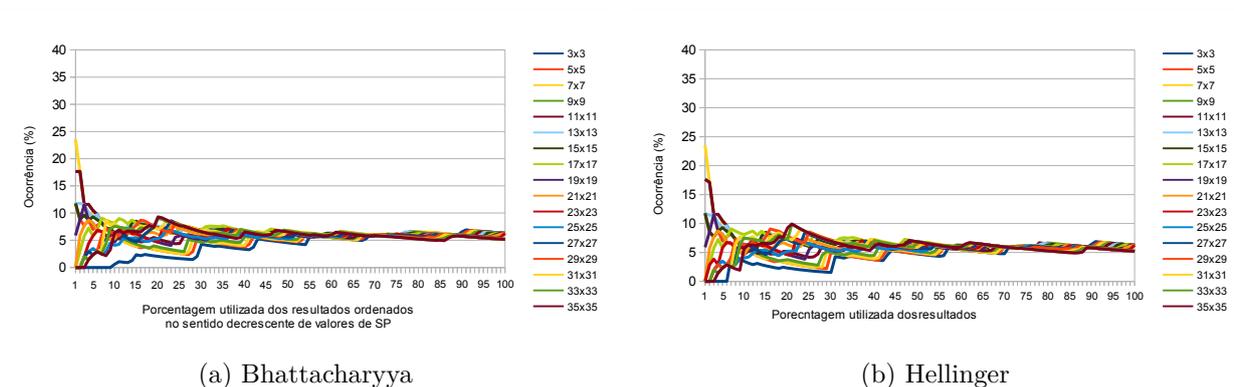


Figura 27 – Comparação entre as curvas de ocorrência da dimensão das janelas para as distâncias de Hellinger e Bhattacharyya



forme apresentado pela figura 30. Considerando as porcentagens dos resultados até 26%, percebe-se que o tamanho da janela mais utilizado está entre 24x24 e 35x35. A partir desta porcentagem, oscila entre 11x11 e 35x35 sendo que para porcentagens maiores que 60% o tamanho de janela mais frequente está entre 3x3 e 17x17. Nas figuras 31 e 32 estão apresentadas as curvas de ocorrência das janelas e o tamanho mais frequente dentro da porcentagem analisada, respectivamente.

5.1.5 Qui-quadrado

A distância Qui-quadrado apresentou a pior média do fator SP para os melhores resultado dentre os métodos apresentados. O maior valor da média ficou em 15,9% para a avaliação de 1% dos resultados. As curvas das medidas de qualidade e de threshold podem ser vistas na figura 33.

A medida de distância Qui-quadrado apresenta como mais frequente dentre os melhores resultados a utilização de menos bits para a representação dos níveis de cinza.

Figura 28 – Curvas das medidas de qualidade e de threshold para o método do Ângulo Cosseno

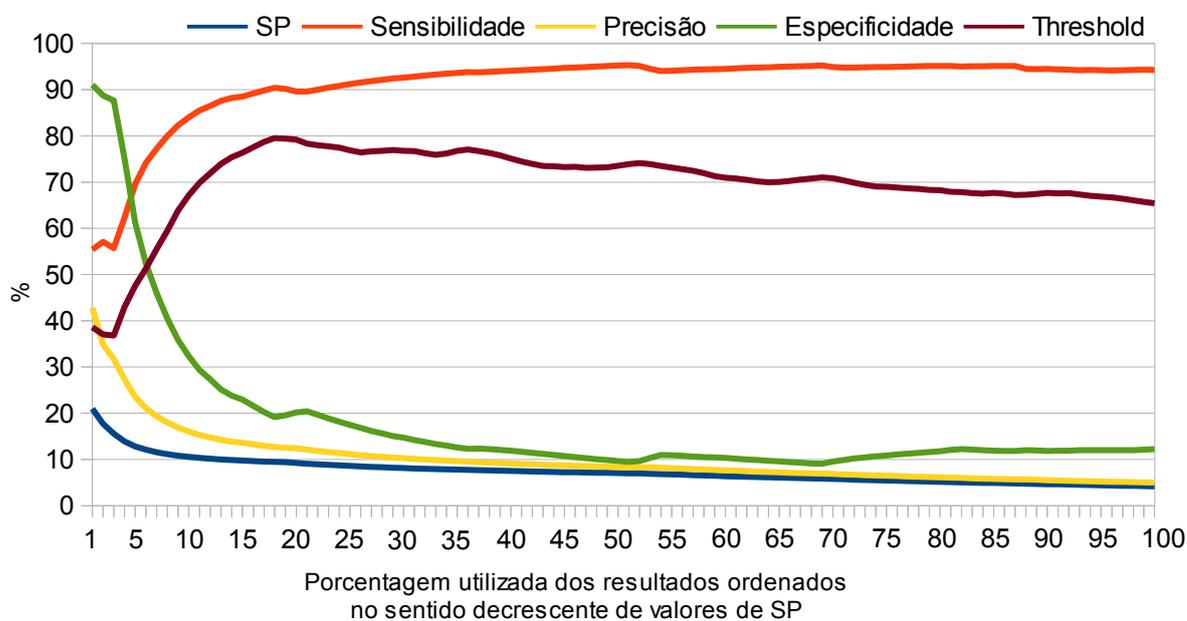


Figura 29 – Curvas de ocorrência do número de bits utilizados para definir o número de bins dos histogramas utilizados para o método do Ângulo Cosseno

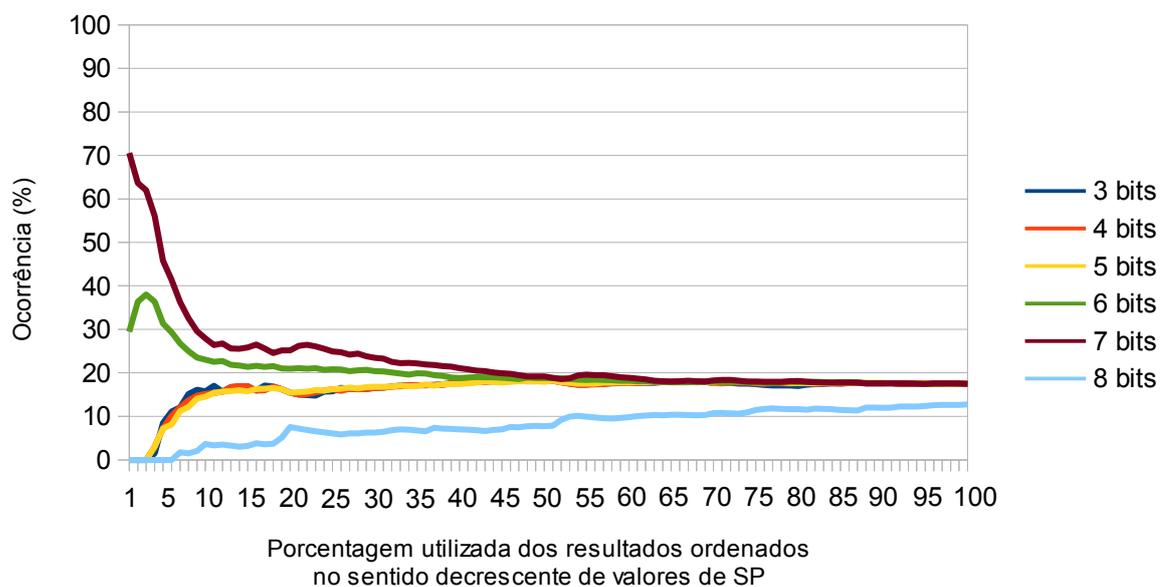


Figura 32 – Curva da dimensão das janelas mais frequentes para o método do Ângulo Cosseno

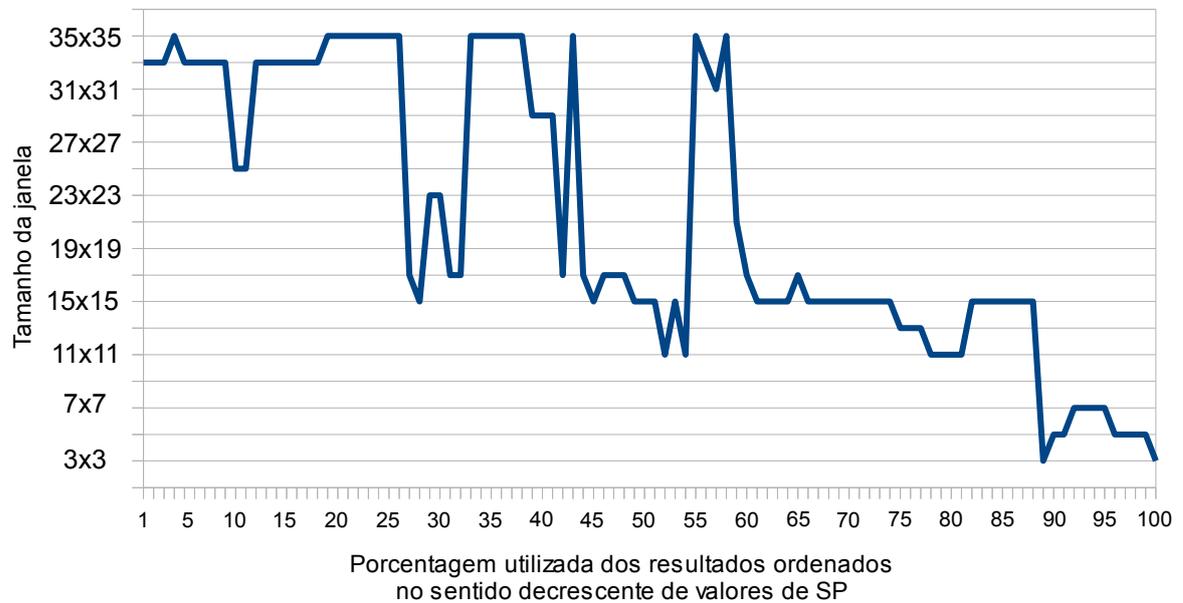
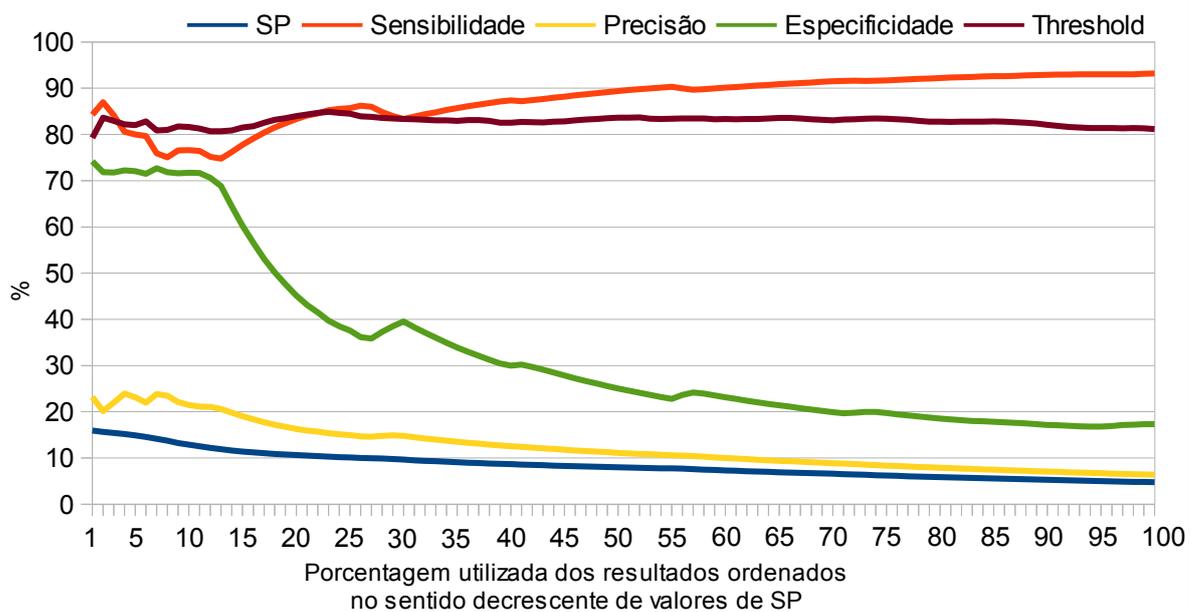
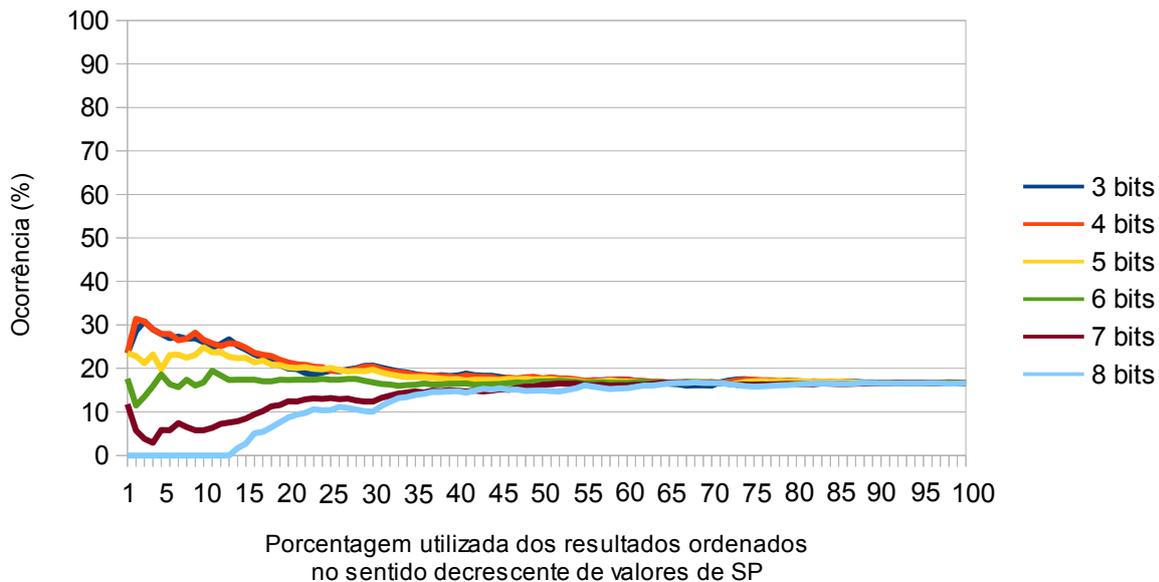


Figura 33 – Curvas das medidas de qualidade e de threshold para o método Qui-quadrado



Conforme a figura 34 quanto menor a quantidade de bits utilizados maior é a frequência entre os melhores resultados da distância Qui-quadrado.

Figura 34 – Curvas de ocorrência do número de bits utilizados para definir o número de bins dos histogramas utilizados para o método Qui-quadrado



Dentre os 59% dos resultados da distância Qui-quadrado a não utilização de pesos surge como a mais frequente entre as distribuições de pesos avaliadas. As curvas que apresentam como as distribuições ocorrem dentre as porcentagens dos resultados são mostradas na figura 35.

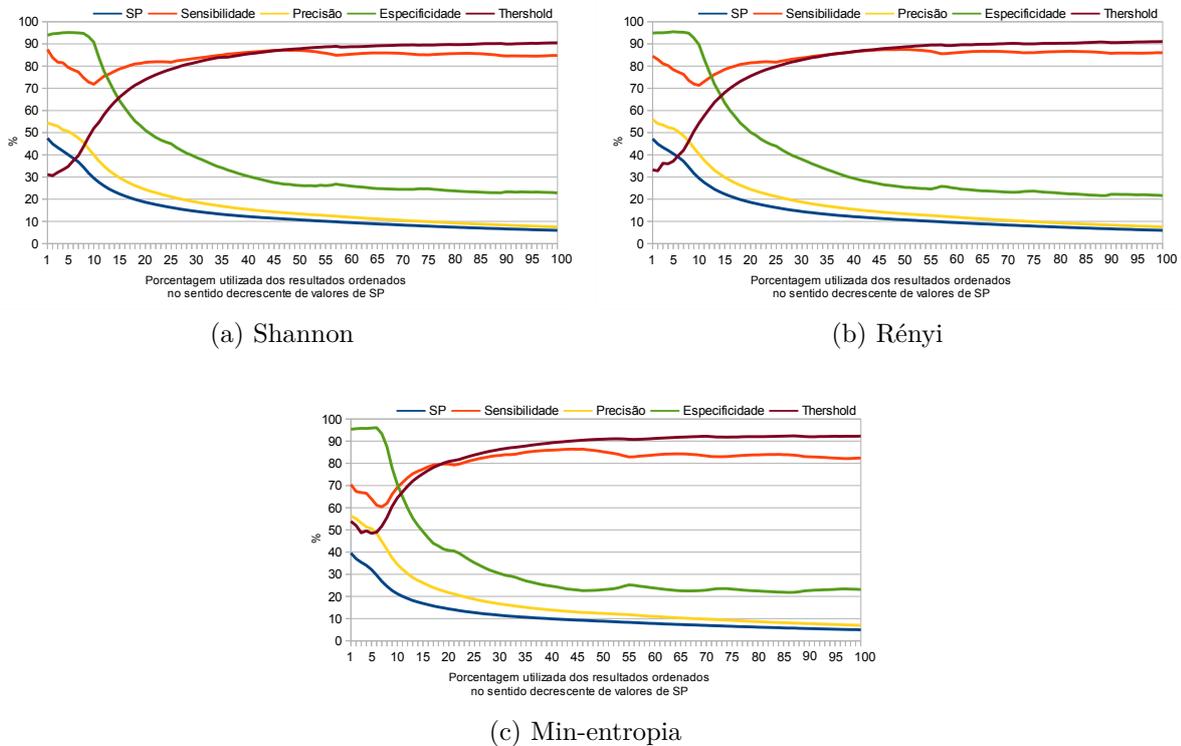
Tamanhos de janelas de 3x3 a 9x9 apresentam menor participação nos melhores resultados, os melhores resultados estão entre janelas de tamanho 29x29. Janelas de tamanhos pequenos como 3x3, 5x5, 7x7, 9x9 e 11x11 não apresentam bons resultados. Por exemplo, janelas de 3x3 não aparecem entre os 25% das melhores respostas como pode ser visto na figura 36.

5.1.6 Entropia de Rényi e suas variantes

Semelhante ao que ocorre na distância de Minkowski, as distâncias baseadas na entropia de Rényi também apresentam semelhanças entre si, o que pode ser observado na figura 37. Ainda na mesma figura percebe-se que min-entropia apresenta fator SP menor que as distâncias de Shannon e Rénye.

O método da distância de Rényi, Shannon e Min-entropia apresentam como mais freqüente a quantidade de 8 bits para a representação dos níveis de cinza. As curvas de

Figura 37 – Curvas das medidas de qualidade e de threshold para o método de entropia de Rényi e variantes



ocorrência de cada número de bits para estas distâncias são mostradas na figura 38 onde pode ser visualmente percebido a semelhança entre elas.

Dos três casos, a entropia de Shannon é a única que apresenta a não utilização de distribuição de pesos, mas somente para 1% dos resultados. Após, entre 5 e 7% Gauss é a distribuição mais utilizada pelas distâncias. Na avaliação geral a distribuição de Gauss apresenta bons resultado para o método da entropia de Rényi. A figura 39 apresenta as curvas de ocorrência das distribuições de pesos para a entropia de Rényi e suas variantes. Estas ocorrências são apresentadas em função da porcentagem dos resultados obtidos que se está considerando.

A figura 40 mostra a semelhança entre as ocorrência da dimensão das janelas para a distância de Rényi e suas variantes. Visualmente se torna difícil a análise de qual tamanho de janela é o mais utilizado por estas distâncias. O que se percebe é que janelas menores, como por exemplo de tamanho 3x3, não apresentam grande ocorrência entre os melhores resultados. Na figura 41 mostra os tamanhos de janelas mais frequentes para cada distância de acordo com a porcentagem analisada dos resultados. É possível perceber que até 6% dos melhores resultados apresentam janelas de tamanho entre 11x11 e 19x19.

Figura 38 – Curvas das ocorrências do número de bits utilizados para definir o número de bins dos histogramas utilizados da entropia de Rényi e variantes

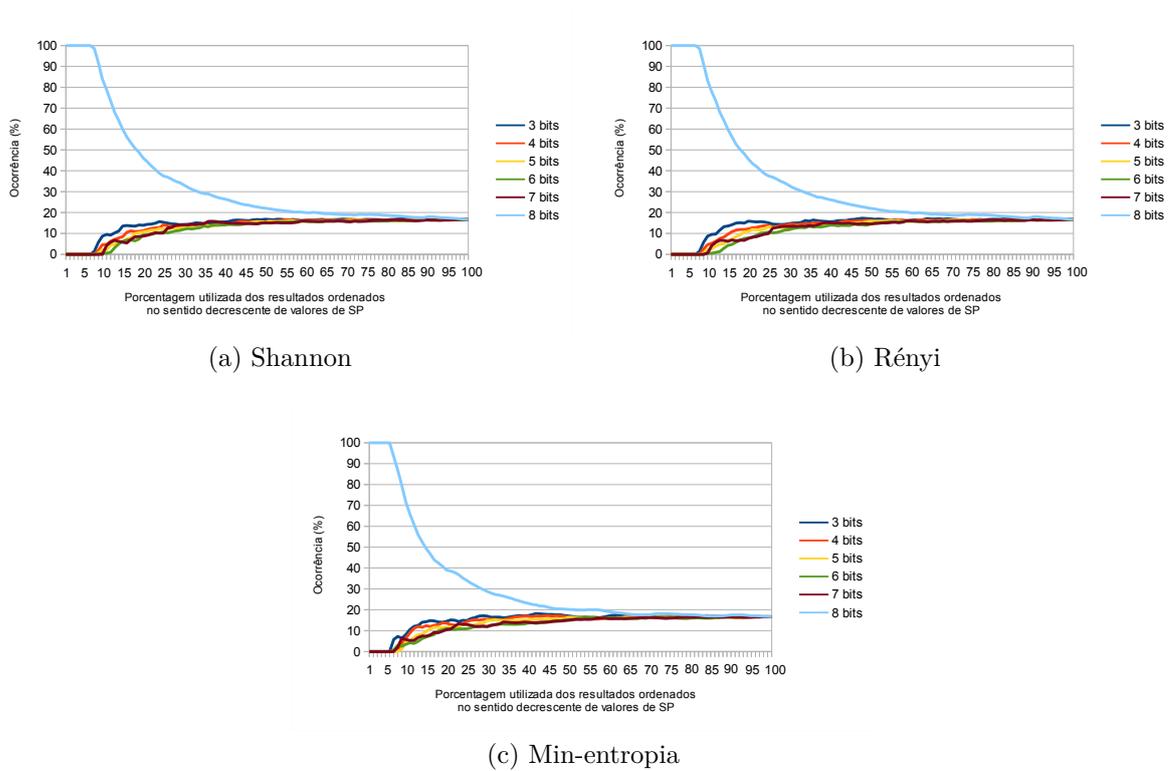


Figura 39 – Curvas das ocorrências da utilização ou não da máscara de peso da entropia de Rényi e variantes

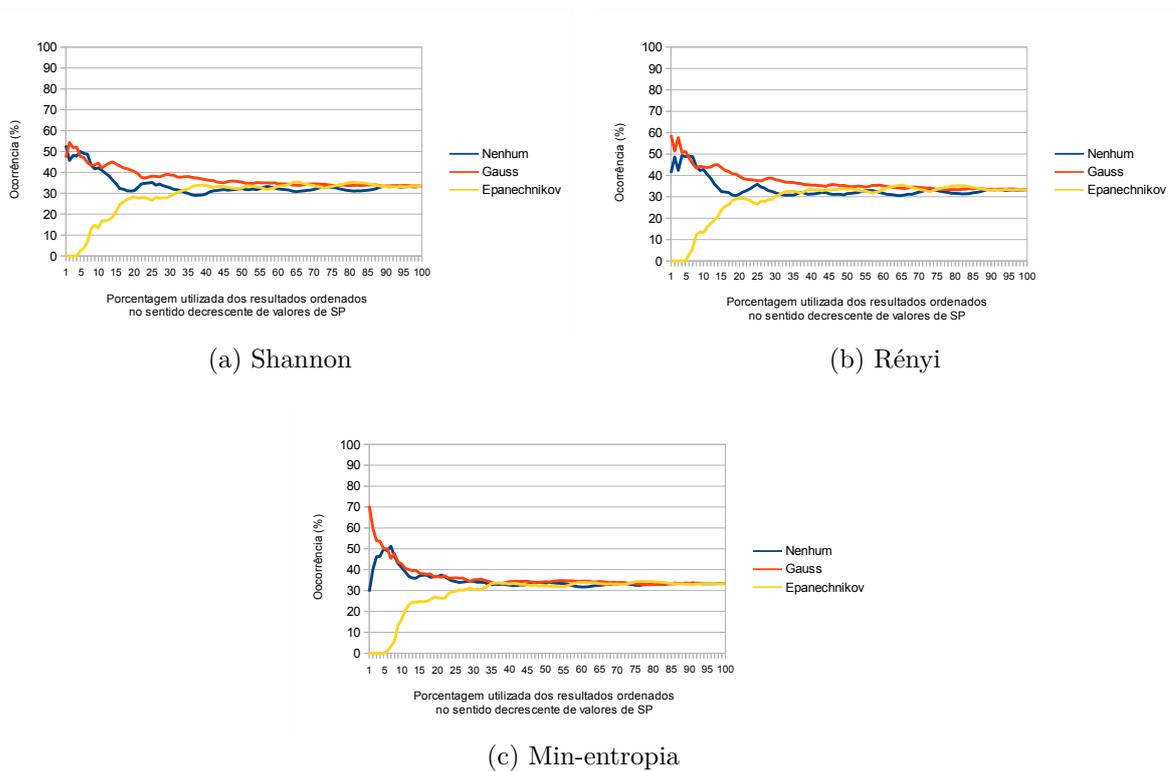


Figura 40 – Curvas das ocorrências da dimensão das janela da entropia de Rényi e variantes

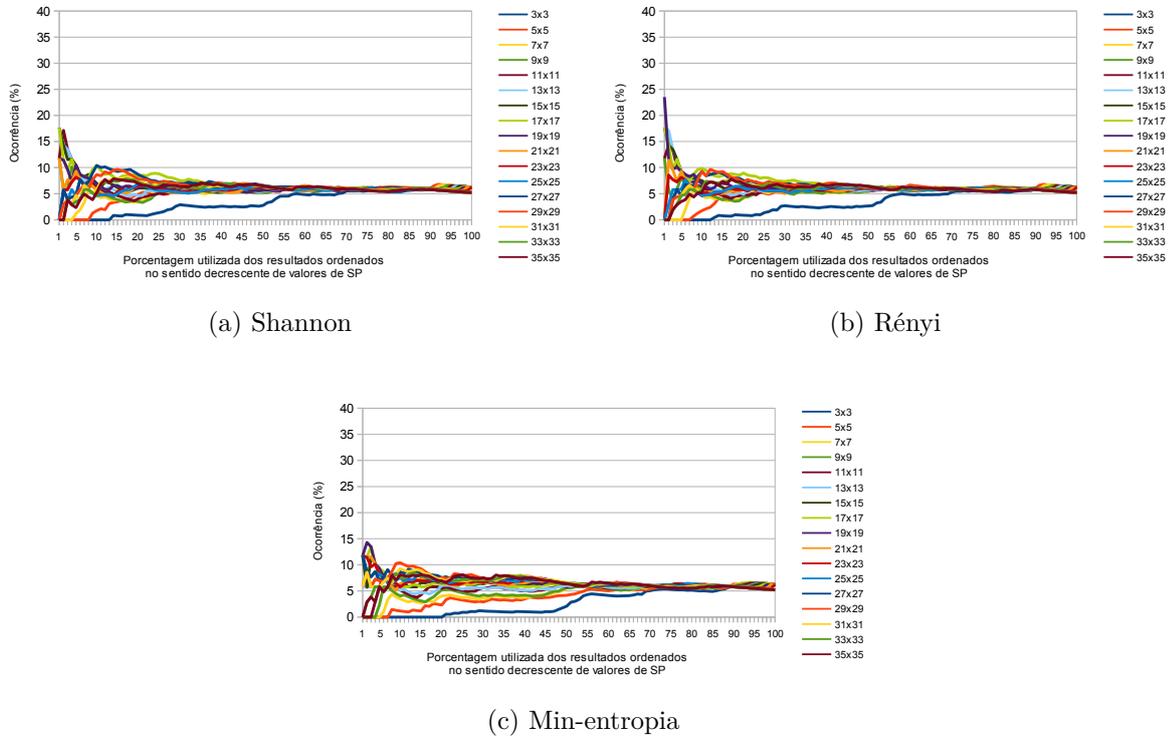


Figura 41 – Curvas da dimensão das janelas mais frequentes para a entropia de Rényi e variantes

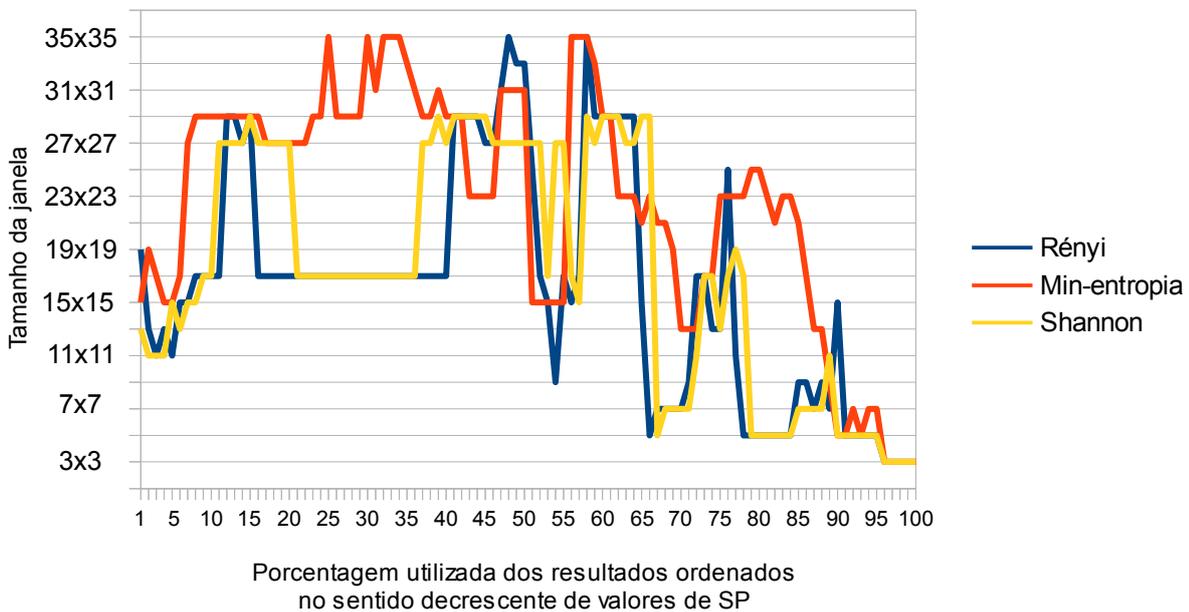


Tabela 2 – Dados dos 20 melhores resultados gerais

Pos.	SP(%)	Sens.(%)	Prec.(%)	Esp.(%)	Thres.(%)	Bits	Dist. Pesos	Distância	Dim. Janela
1	67,5	86,7	77,9	97,8	82	8	Gauss	Manhattan	7x7
2	66,6	83,6	79,6	98,1	36	8	Gauss	Bhattacharyya	7x7
3	66,4	82,9	80,2	98,2	87	8	Gauss	Hellinger	7x7
4	65,6	84,2	77,9	97,9	82	8	Gauss	Manhattan	9x9
5	65,5	83,4	78,5	98,0	86	8	Nenhuma	Manhattan	7x7
6	65,4	83,5	78,3	98,0	84	8	Nenhuma	Manhattan	9x9
7	64,8	84,8	76,4	97,7	26	8	Gauss	Bhattacharyya	9x9
8	64,7	83,4	77,6	97,9	83	8	Gauss	Hellinger	9x9
9	63,7	82,1	77,6	97,9	85	8	Nenhuma	Hellinger	9x9
10	63,7	82,5	77,2	97,9	29	8	Nenhuma	Bhattacharyya	9x9
11	63,6	81,3	78,2	98,0	41	8	Nenhuma	Bhattacharyya	7x7
12	63,5	84,5	75,2	97,5	81	8	Nenhuma	Manhattan	11x11
13	63,4	84,7	74,9	97,5	77	8	Gauss	Manhattan	11x11
14	63,4	82,3	77,0	97,8	89	8	Nenhuma	Hellinger	7x7
15	63,0	84,7	74,4	97,4	77	8	Gauss	Hellinger	11x11
16	62,8	83,6	75,1	97,6	19	8	Gauss	Bhattacharyya	11x11
17	61,9	82,8	74,8	97,5	22	8	Nenhuma	Bhattacharyya	11x11
18	61,8	81,8	75,6	97,7	81	8	Nenhuma	Hellinger	11x11
19	59,2	83,9	70,6	96,9	77	8	Gauss	Manhattan	13x13
20	59,0	83,9	70,3	96,8	80	8	Nenhuma	Manhattan	13x13

5.2 Resultados Gerais

A seguir serão apresentadas as análises dos resultados considerando todos os resultados. Os resultados das análises serão apresentadas da mesma forma que os resultados por métodos foram apresentados. A análise será em função do percentual analisado dos resultados, que estão ordenados em ordem decrescente em função do valor do fator SP.

O maior valor encontrado para o fator SP é de 67,5%, conforme a tabela 2 que apresenta os 20 melhores resultados encontrados. Mas quando a análise das curvas das medidas de qualidade, percebe-se que a média do fator SP é aproximadamente 50%, quando se analisa apenas 1% dos resultados, isto pode ser visto na figura 42.

Assim como a maioria dos resultados das distâncias apresentados anteriormente, a avaliação de todos os resultados mostra que 8 bits é a quantidade mais utilizada entre 94% dos resultados. A ocorrência das outras quantidades não apresentam grande participação entre os 50% dos melhores resultados. A figura 43 mostra a ocorrência de cada quantidade de bits em função do percentual analisado.

Da mesma forma que a quantidade de bits, a distribuição de pesos também apresentou resultado similar à maioria das distâncias, ou seja, a não utilização é mais frequente entre os melhores resultados encontrados. A figura 44 mostra que depois da não utilização de pesos a distribuição de Gauss é a que mais ocorre, ficando por último a distribuição de Epanechnikov.

Tamanho de janelas mais frequente está entre 11x11 e 15x15 para os primeiros 6% dos resultados. Após este percentual há uma variação de 15x15 a 35x35 até um percentual de 66% dos resultados. Resultado semelhante foi encontrado nas distâncias baseadas na distância de Minkowski, nas distâncias de entropia, em Bhattacharyya e Hellinger. Estas

Figura 42 – Curvas das medidas de qualidade e de threshold considerando todos os resultados

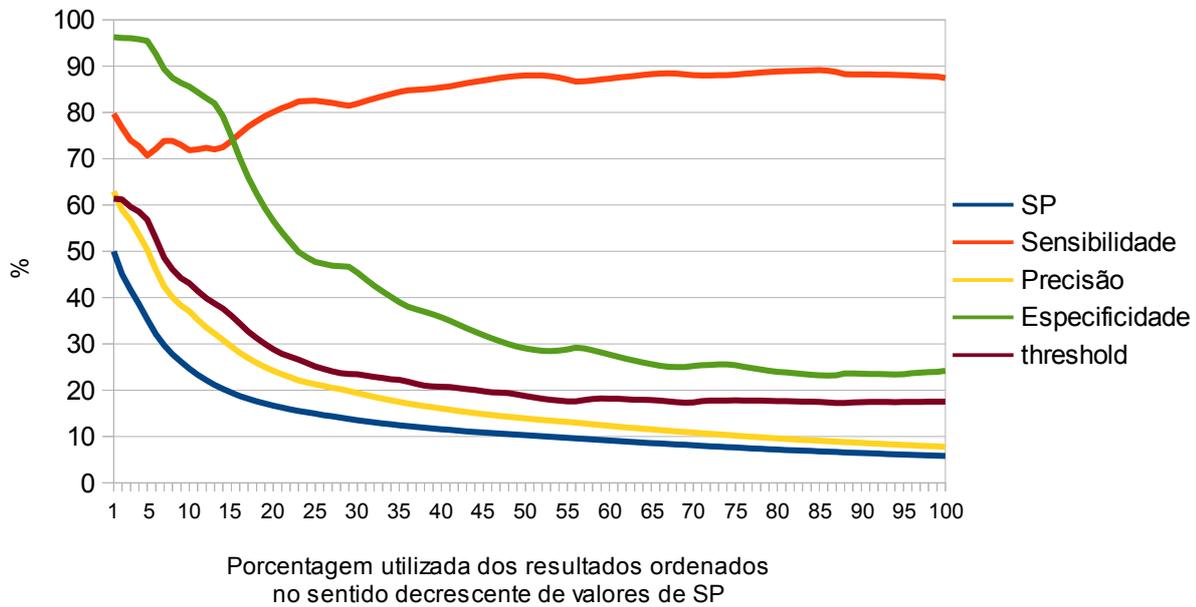


Figura 43 – Curvas das ocorrências do número de bits utilizados para definir o número de bins dos histogramas utilizados considerando todos os resultados

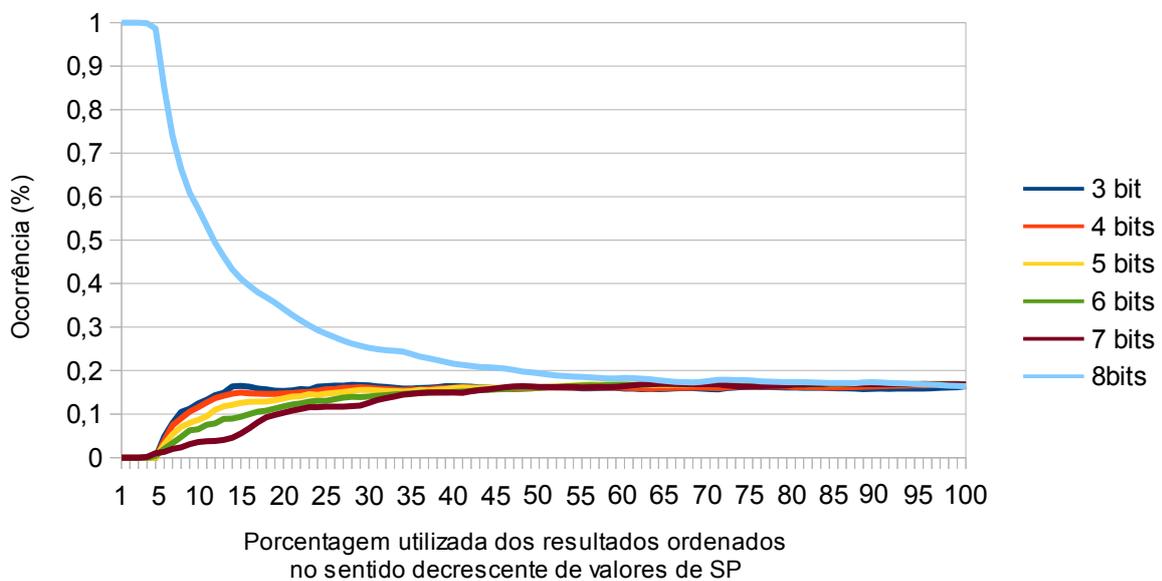
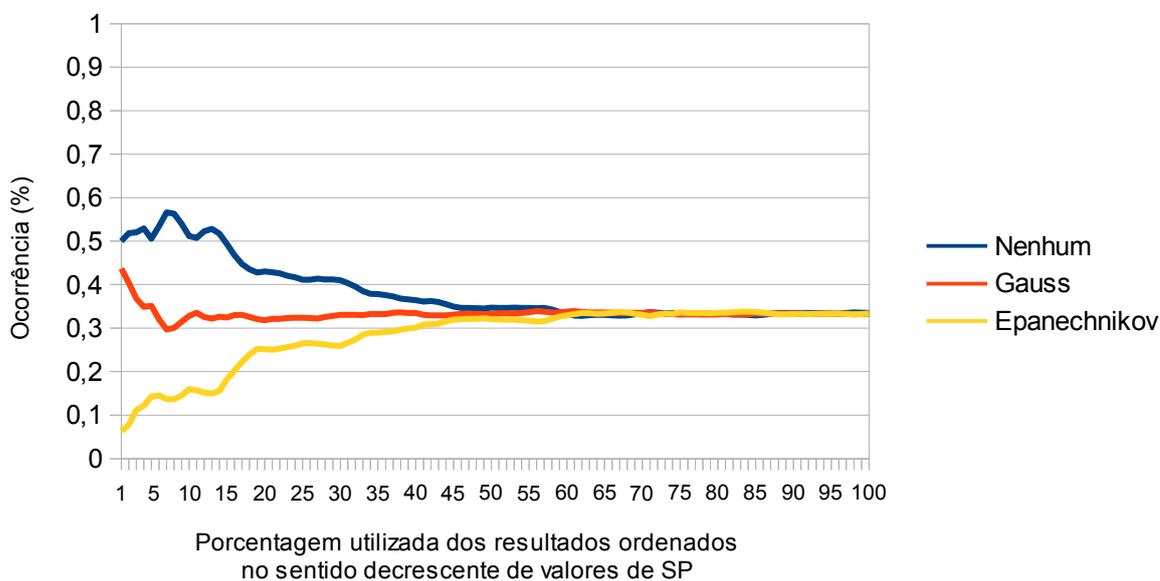
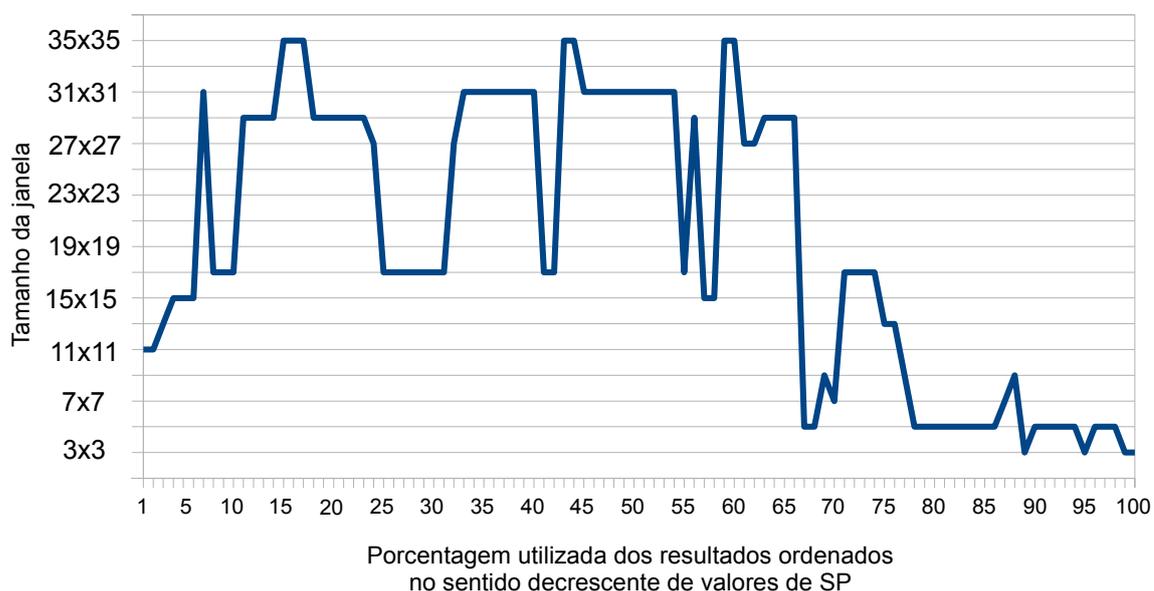


Figura 44 – Curvas das ocorrências da utilização ou não da máscara de pesos considerando todos os resultados



distâncias influenciaram os resultados gerais que são apresentados pelas figuras 46 e 45. As distâncias de ângulo cosseno e qui-quadrado apresentaram uma pequena diferença entre os primeiros 8%, tendo como janelas mais frequentes as de maior tamanho, ficando entre 29x29 e 35x35.

Figura 45 – Curvas da dimensão das janelas mais frequentes considerando todos os resultados



A figura 47 apresenta em um só gráfico as curvas das médias do fator SP para as distâncias estudadas. Percebe-se que as distâncias de Manhattan, Bhattacharyya e Hellinger possuem curvas muito similares pois, estão praticamente sobrepostas o que dificulta a visualização. A ocorrência de cada método pode ser vista na figura 48. Para facilitar a análise a figura 49 apresenta a curva que mostra qual método é mais frequente dada a porcentagem analisada dos resultados.

Alguns resultados são apresentados na figura 50 e os dados sobre cada um deles são descritos na tabela 3 onde pode ser visto o valor do fator SP, número de bits, método, entre outras características.

Figura 46 – Curvas das ocorrências da dimensão das janelas considerando todos os resultados

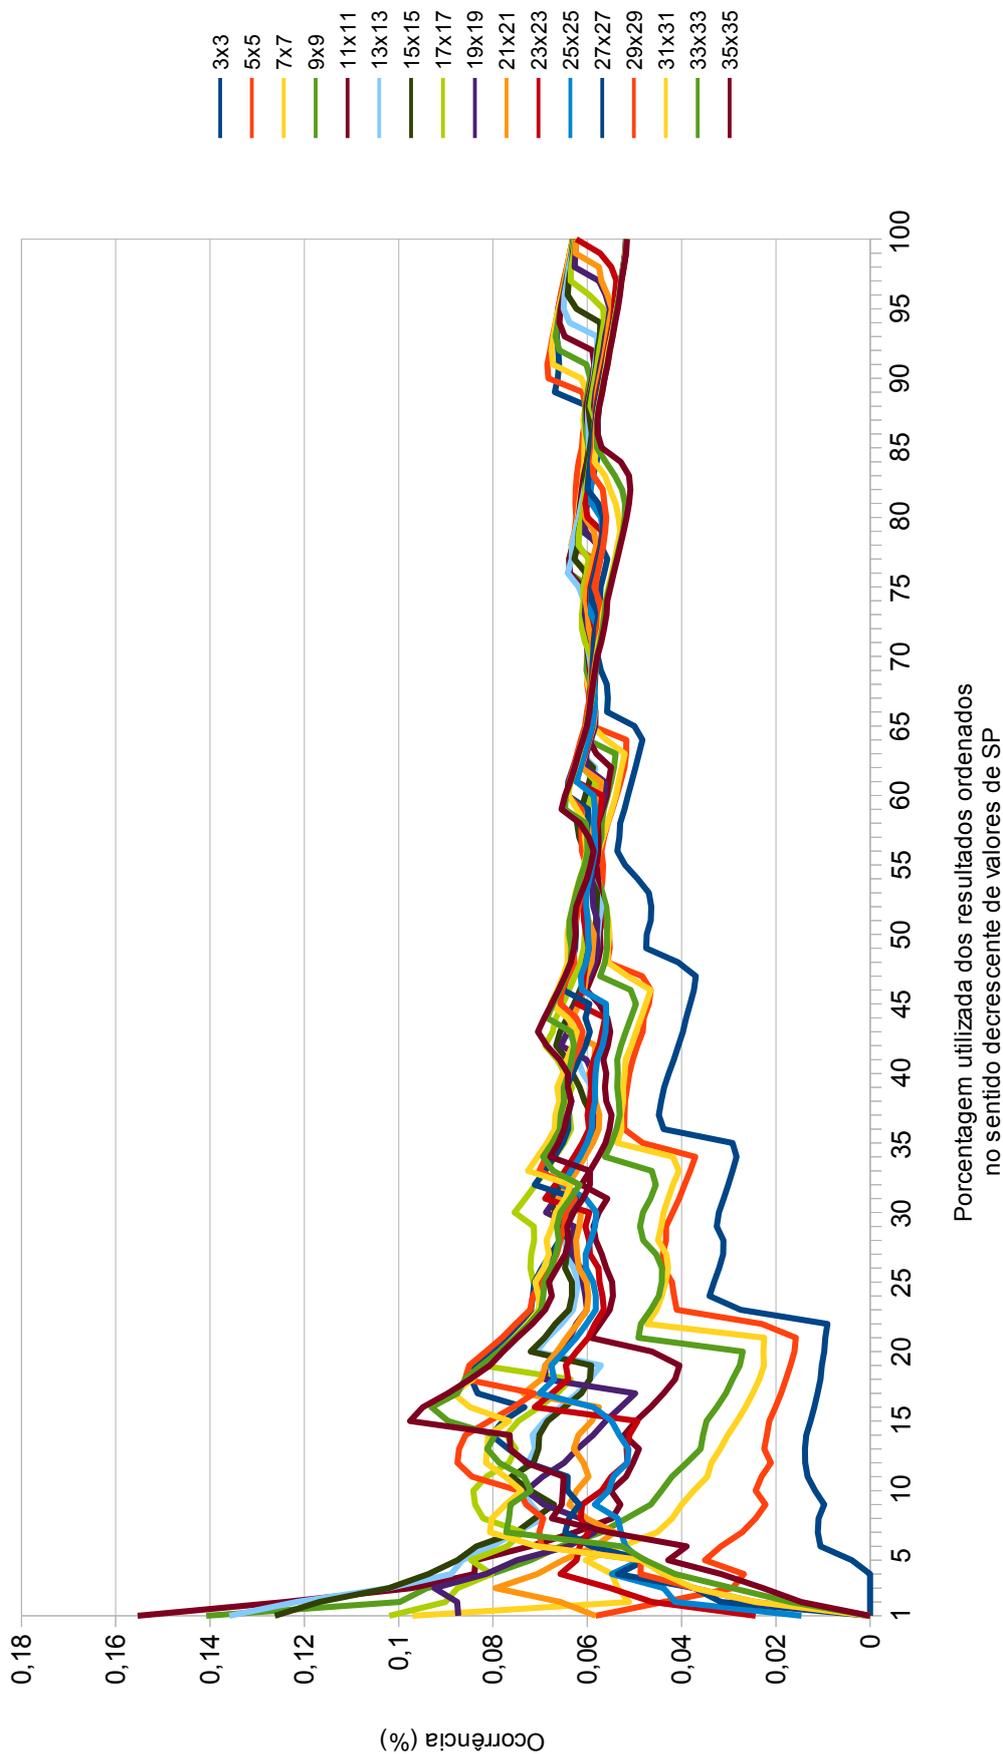


Figura 47 – Curvas das médias do fator SP das distâncias apresentadas

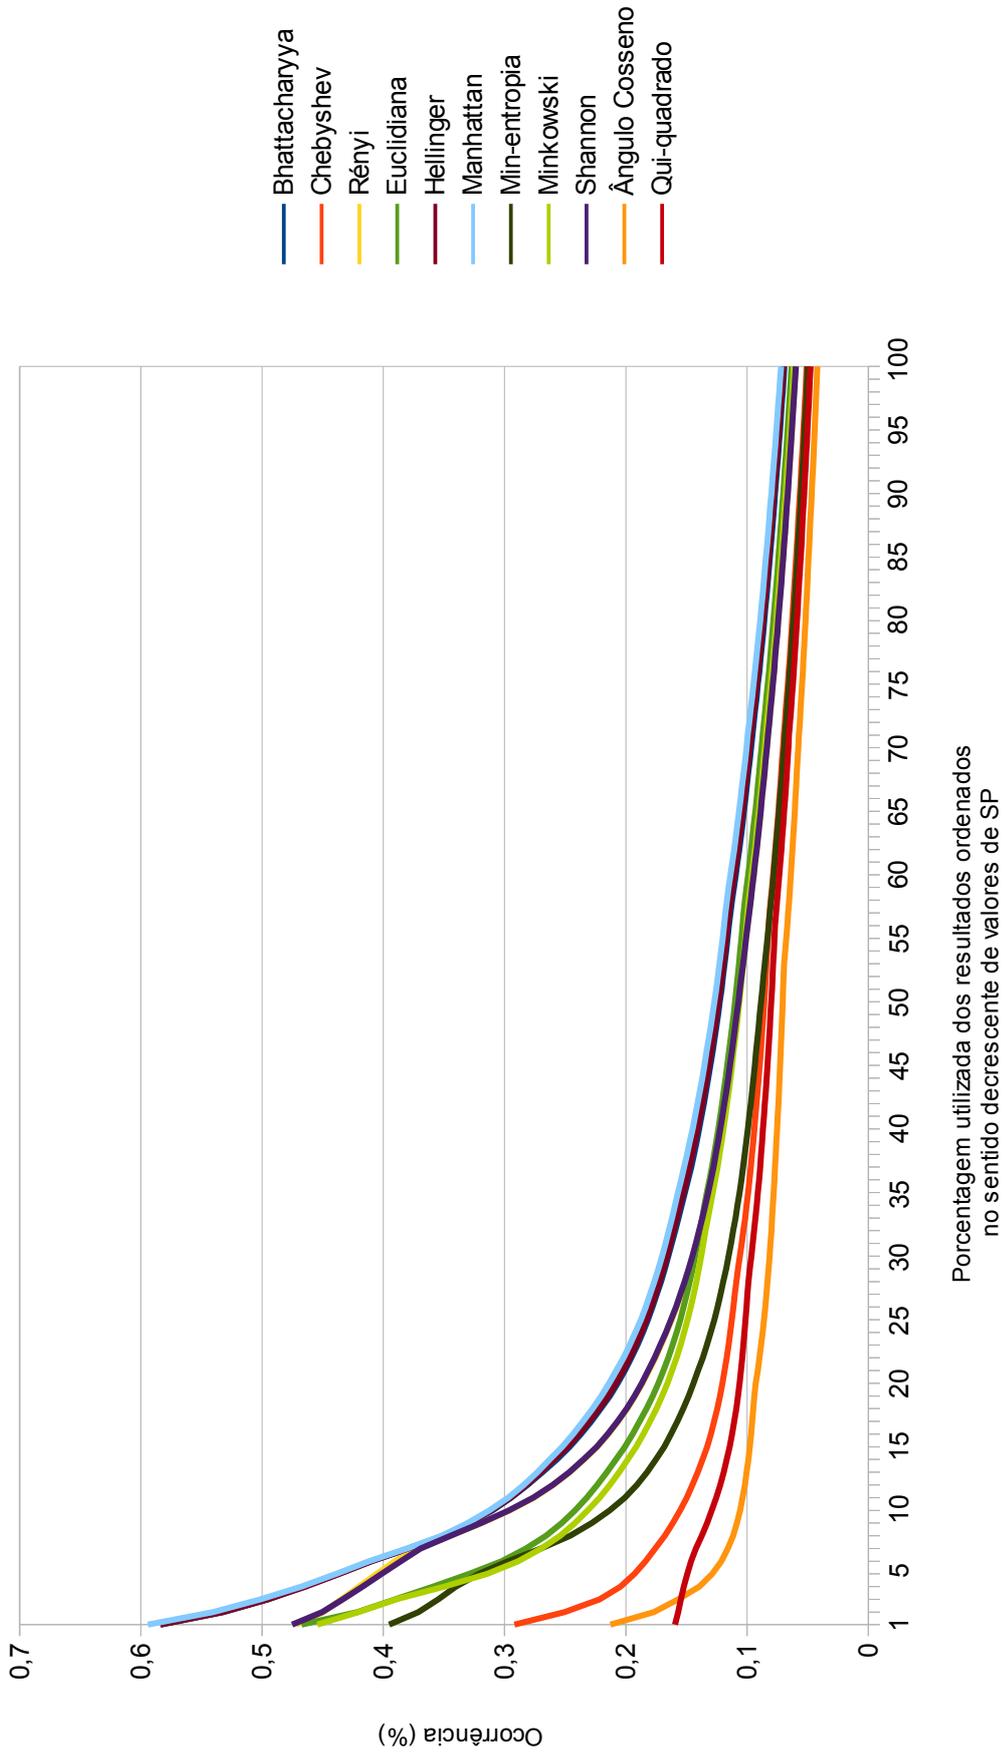


Figura 48 – Curvas das ocorrências das distâncias apresentadas

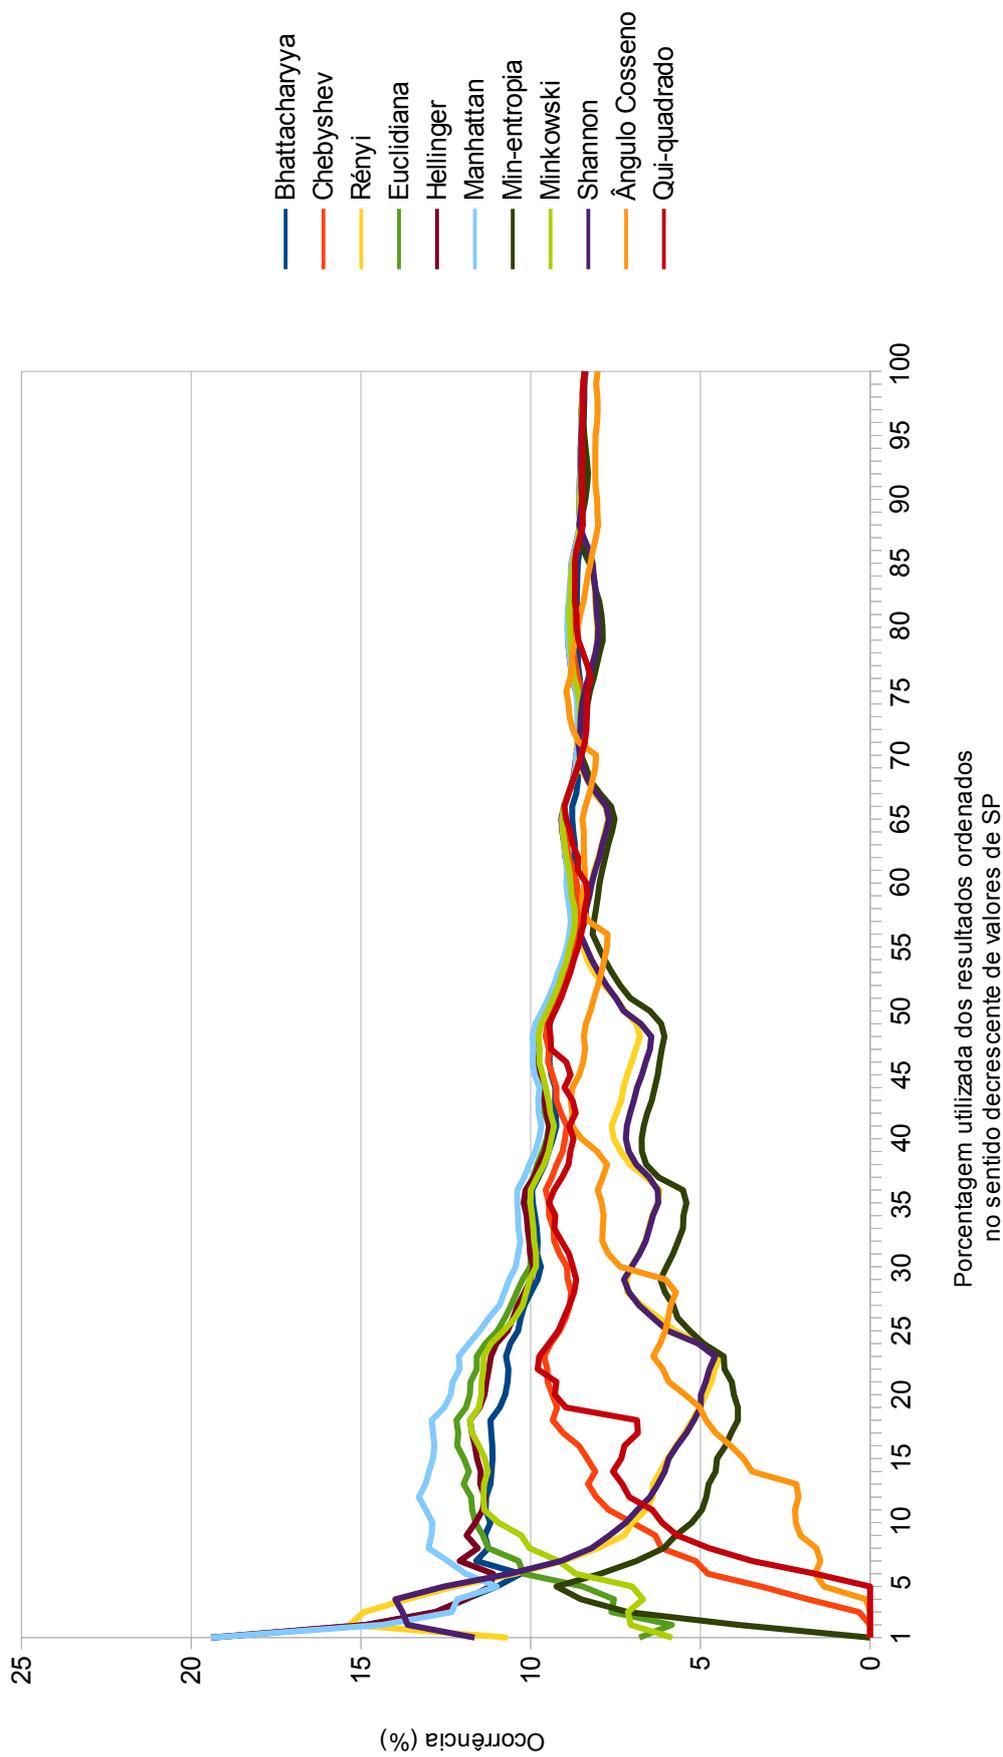


Figura 49 – Curvas das distâncias mais frequentes

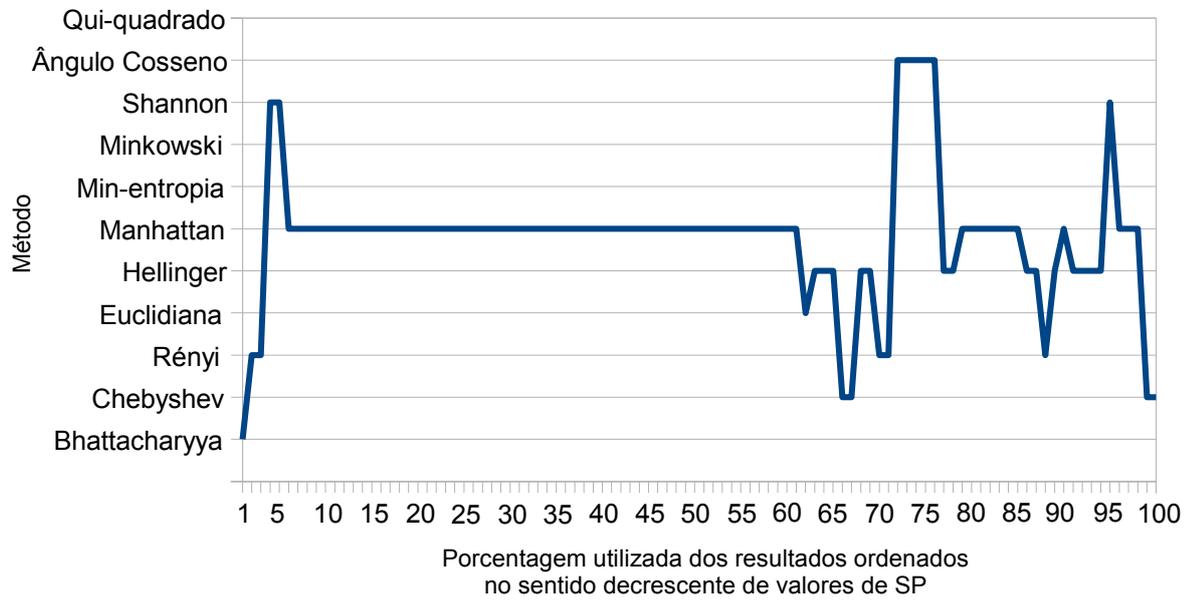
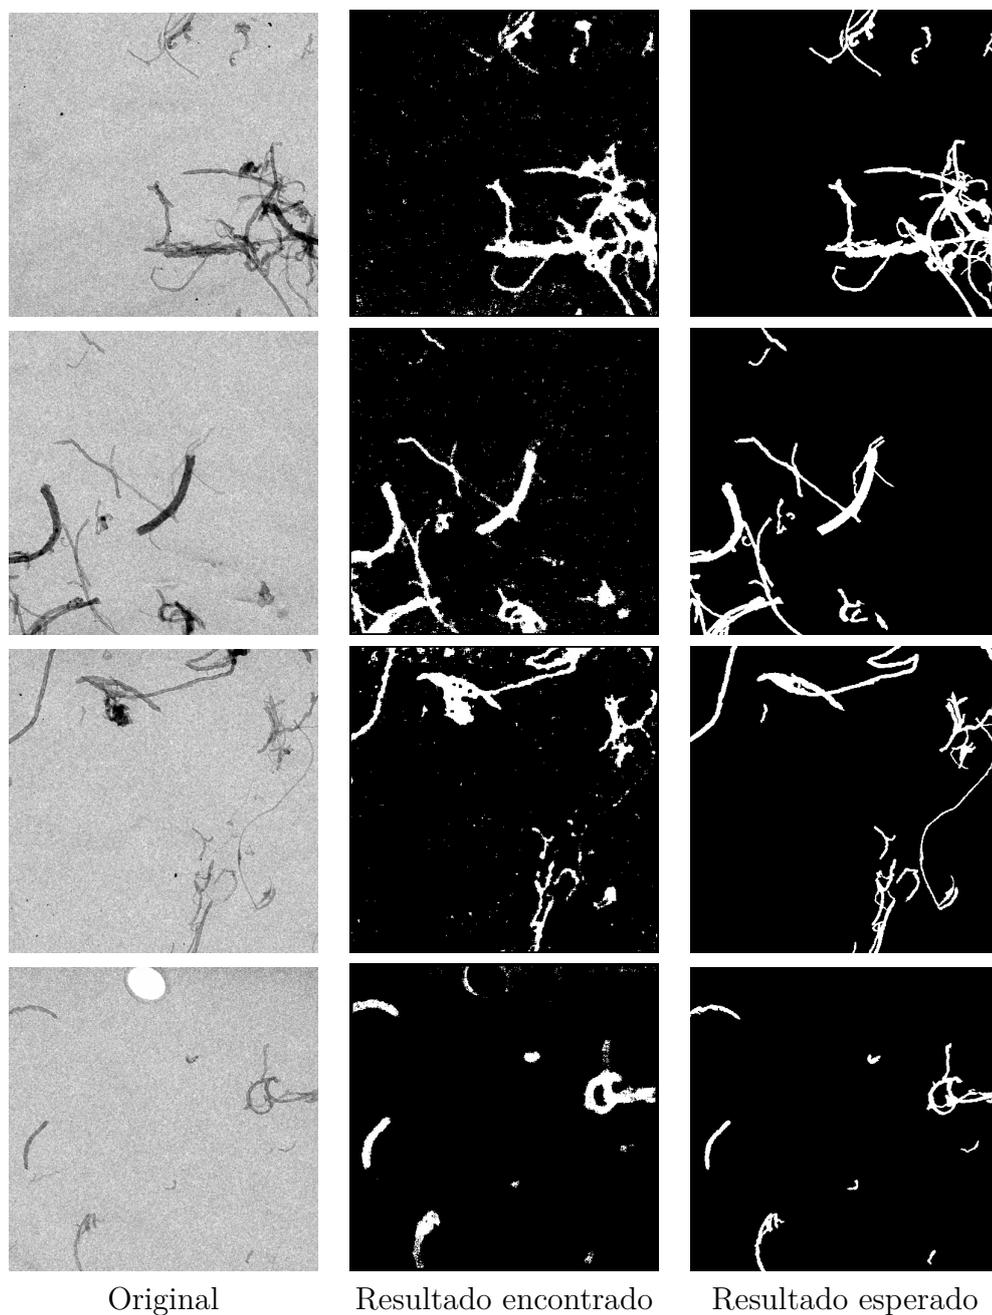


Tabela 3 – Dados dos resultados apresentados na figura 50

Resultado	SP(%)	Sens.(%)	Prec.(%)	Esp.(%)	Thres.(%)	Bits	Dist. Pesos	Distância	Dim. Janela
Linha 1	67,5	86,7	77,9	97,8	82	8	Gauss	Manhattan	7x7
Linha 2	58,5	83,4	70,2	97,8	82	8	Gauss	Manhattan	3x3
Linha 3	49,8	77,7	64,1	97,6	84	8	Nunhuma	Manhattan	3x3
Linha 4	45,4	82,8	54,9	98,5	78	8	Gauss	Rényi	13x13

Figura 50 – Exemplos de resultados obtidos



Os dados de cada resultado podem ser vistos na tabela 3

Fonte: Imagens originais cedidas por Patricia Rodrigues da Silva e Pamela A. M. dos Santos

6 Considerações Finais

Analisando todos os resultados obtidos e a frequência que determinadas configurações aparecem como sendo as mais utilizadas pode-se chegar a algumas conclusões. A primeira delas é que a quantidade de 8 bits é a que fornece melhores resultados. Isto ficou comprovado na maioria das distâncias quando analisadas individualmente e na análise de todos os resultados juntos. Este resultado pode ser atribuído ao fato de que um maior número de bits representa mais níveis de cinza, e ao que parece isto é importante na segmentação de NTCs. Além disso, o fato de que os NTCs possuem tonalidade semelhante à apresentada pelo fundo da imagem também pode exigir que seja necessário a representação de mais níveis de cinza, para que não se perca nenhuma informação.

A utilização das distribuições de peso de Gauss e Epanechnikov não obtiveram bons resultados. A maioria dos melhores resultados não utilizaram ponderação para avaliar as imagens.

Outro fato que pode-se concluir é que não há grandes diferenças entre as distâncias baseadas na distância de Minkowski. Como apresentado na seção 3.2 a distância de Minkowski e suas variantes apresentam resultados bastante similares. Apenas a distância de Chebyshev foge um pouco do padrão apresentado pelas distâncias de Minkowski, Euclidiana e Manhattan. Além das distâncias baseadas em Minkowski, as distâncias de entropia de Rényi também apresentam grande semelhança.

Bhattacharyya e Hellinger também apresentaram similaridade entre os resultados obtidos. Este fato é compreensível já que a distância de Hellinger e de Bhattacharyya estão relacionadas através do coeficiente de Bhattacharyya. Embora o cálculo das distâncias seja diferente seus resultados foram bastante similares.

A busca de uma definição de qual distância é a mais indicada para a segmentação de NTCs, depende da porcentagem que está sendo analisada dos resultados encontrados. Se considerar 1% dos melhores resultados a resposta seria o método de Bhattacharyya, de 2 a 3% seria a distância da entropia de Rényi, de 4 a 5% a entropia de Shannon e de 6% até 61% a distância de Manhattan.

Apesar da distância de Manhattan somente ser a mais utilizada a partir de 6% não significa que ela não seja a adequada. Se considerar que a curva das médias para a distância de Manhattan possui valores maiores que todos os outros métodos não inportando a porcentagem analisada, e que a partir de 6% até 61% dos resultados é a distância mais frequente, faz com que ela seja a candidada com maior potencial para ser escolhida

com distância mais adequada ao problema em questão.

Analisando os tamanhos de janelas, percebe-se que os melhores resultados de cada método geralmente utilizam janelas entre 7x7 e 19x19. Isto pode ser observado também para a análise que considerou todos os resultados como apresentado pela figura 45. Se for considerar a distância de Manhattan como a mais indicada para a segmentação e analisar o tamanho de janela dos seus melhores resultados, percebe-se que estão dentro da faixa de 3x3 a 17x17. Isto caracteriza que janelas menores apresentaram os melhores resultados.

Finalizando a análise dos resultados obtidos ao longo do trabalho, percebe-se que para a maioria das distâncias seus melhores resultados ocorrem quando se tinha uma alta especificidade, mostrando que o maior problema é a ocorrência de falsos positivos, a excessão foi a distância qui-quadrado. O fator SP, que foi proposto mostrou-se uma boa solução para medir a qualidade dos resultados obtidos mas não foi comparada com outras medidas para que possa ser dita como medida eficiente de classificação dos resultados.

Para trabalhos futuros fica a realização de testes de distribuições de pesos direcionais, que considerem a direção em que os níveis de cinza variam. Outra possibilidade é a utilização de pesos para determinar a influência de cada bin na distância entre os histogramas.

Referências

- ACHARYA, T.; RAY, A. K. *Image Processing: principles and applications*. Hoboken, New Jersey, USA: John Wiley & Sons Inc., 2005. Citado na página 29.
- BHATTACHARYYA, S.; MAULIK, U.; DUTTA, P. Multilevel image segmentation with adaptive image context based thresholding. In: *Applied Soft Computing*. [S.l.]: Elsevier, 2011. v. 11, p. 946–962. Citado 2 vezes nas páginas 26 e 27.
- BOVIK, A. (Ed.). *The Essential Guide to Image Processing*. Burlington, USA: Elsevier, 2009. Citado na página 28.
- CASTELLI, V.; BERGMAN, L. D. *Image Database: Search and Retrieval of Digital Imagery*. New York: Wiley, 2002. Citado 2 vezes nas páginas 34 e 35.
- DAVIES, P. L. et al. Constructing a regular histogram: a comparison of methods. In: *Technical Report // Sonderforschungsbereich 475, Komplexitätsreduktion in Multivariaten Datenstrukturen, Universität Dortmund*. [S.l.: s.n.], 2007. v. 2007, n. 14. Citado na página 35.
- DAVIES, P. L. et al. A comparison os automatic histogram constructions. In: *ESAIM: Probability and Statistics*. [S.l.: s.n.], 2009. v. 13, p. 181–196. Citado na página 35.
- DOUGHERTY, G. *Digital Image Processing for Medical Applications*. 2nd. ed. New York: Cambridge, 2009. Citado 2 vezes nas páginas 27 e 30.
- DUBUISSON, S. Tree-structured image difference for fast histogram and distance between histograms computation. In: *Pattern Recognition Letters*. [S.l.]: Elsevier, 2011. v. 32, p. 411–422. Citado na página 29.
- GONZALEZ, R. C.; WOODS, R. E. *Processamento de Imagens Digitais*. São Paulo: Blucher, 2000. Citado 2 vezes nas páginas 19 e 23.
- GUORONG, X.; PEIQI, C.; MINHUI, W. Bhattacharyya distance feature selection. In: *Proceedings of the 13th International Conference on Patter Recogniton*. [S.l.: s.n.], 1996. v. 2, p. 195–199. Citado na página 33.
- KAMARAINEN, J.-K. et al. Improving similarity measures of histograms using smoothing projections. In: *Patter Recognition Letters*. [S.l.]: Elsevier, 2003. v. 24, p. 2009–2019. Citado na página 33.
- KRSTINIC, D.; SKELIN, A.; SLAPNICAR, I. Fast two-step histogram-based image segmentation. In: *IET Image Processing*. [S.l.: s.n.], 2011. v. 5, n. 1, p. 63–72. Citado na página 26.
- LEICHTER, I. Mean shift trackers with cross-bin metrics. In: *IEEE Transactions on Pattern Analysis and Machine Intelligence*. [S.l.: s.n.], 2012. v. 34, n. 4. Citado na página 33.

- MEYYAPPAN, M.; SRIVASTAVA, D. blallalalal. In: _____. [S.l.]: CRC Press, 2003. cap. 18 Carbon Nanotubes. Citado 2 vezes nas páginas 23 e 24.
- MICHAILOVICH, O.; RATHI, Y.; TANNENBAUM, A. Image segmentation using active contours driven by the bhattacharrya gradient flow. In: *IEEE Transactions on Image Processing*. [S.l.: s.n.], 2007. v. 16, n. 11, p. 2787–2801. Citado na página 26.
- OLIVEIRA, A. B. et al. An approach for quantifying dispersion of carbon nanotubes in ceramic composites using tem images. In: *X Encontro da SBPMat*. [s.n.], 2011. Disponível em: <<http://www.sbpomat.org.br/10encontro/proceedings/pdf/4HJQ.pdf>>. Acesso em: 25.01.2013. Citado na página 19.
- RÉNYI, A. On measures of entropy and information. In: *Proceedings of the Fourth Berkeley Symposium*. [S.l.: s.n.], 1961. v. 1, p. 547–561. Citado na página 36.
- ROZENHOLC, L. B. Y. How many bins should be put in a regular histogram. In: *ESAIM: Probability and Statistics*. [S.l.: s.n.], 2006. v. 10, p. 24–45. Citado na página 35.
- ROZENHOLC, Y.; MILDENBERG, T.; GATHER, U. Combining regular and irregular histograms by penalized likelihood. In: *Computational Statistics and Data Analysis*. [S.l.]: Elsevier, 2010. v. 54, p. 3313–3323. Citado na página 35.
- WEKEN, D. V. D.; NACHTEGAEL, M.; KERRE, E. Combining neighbourhood-based and histogram similarity measures for the desing of image quality measures. In: *Image an Vision Computing*. [S.l.]: Elsevier, 2007. v. 25, p. 184–195. Citado 3 vezes nas páginas 29, 33 e 35.
- WIKIPEDIA. 2011. Disponível em: <http://en.wikipedia.org/wiki/File:Scheme_TEM_en.svg>. Acesso em: 27.12.2011. Citado na página 25.
- WILLIAMS, D. B.; CARTER, C. B. *Transmission Electron Microscopy*. 2nd. ed. New York, USA: Springer, 2009. Citado na página 26.
- WOJNAR, L. *Image Analysis applications in materials engineering*. Boca Raton, USA: CRC Press, 1998. Citado na página 20.
- WORTMANN, T.; FATIKOW, S. Carbon nanotubes detection by scanning electron microscopy. In: *Conference on Machine Vision Applications*. [S.l.: s.n.], 2009. p. 370–373. Citado na página 26.