



**UNIVERSIDADE FEDERAL DO CEARÁ**  
**DEPARTAMENTO DE COMPUTAÇÃO**  
**MESTRADO E DOUTORADO EM CIÊNCIA DA COMPUTAÇÃO**  
**CRAb - COMPUTAÇÃO GRÁFICA, REALIDADE VIRTUAL E ANIMAÇÃO**

**Rômulo Lopes Frutuoso**

**Classificação de texturas utilizando métodos de busca com informação**

**Fortaleza/CE**

**2016**

Rômulo Lopes Frutuoso

Classificação de texturas utilizando métodos de busca com informação

Dissertação submetida à Coordenação do Curso de Pós-Graduação em Ciência da Computação, da Universidade Federal do Ceará, como requisito parcial para a obtenção do grau de Mestre em Ciências da Computação.

Orientador: Prof. Dr. Joaquim Bento Cavalcante Neto

Coorientador: Prof. Dr. João Paulo Pordeus Gomes

Fortaleza/CE

2016

Dados Internacionais de Catalogação na Publicação  
Universidade Federal do Ceará  
Biblioteca Universitária  
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

---

- F962c Frutuoso, Rômulo Lopes.  
Classificação de texturas utilizando métodos de busca com informação / Rômulo Lopes Frutuoso. – 2016.  
108 f. : il. color.
- Dissertação (mestrado) – Universidade Federal do Ceará, Centro de Ciências, Programa de Pós-Graduação em Ciência da Computação, Fortaleza, 2016.  
Orientação: Prof. Dr. Joaquim Bento Cavalcante Neto.  
Coorientação: Prof. Dr. João Paulo Pordeus Gomes.
1. Análise de texturas. 2. Grafos. 3. Caminhos mínimos. 4. Busca com informação.. I. Título.  
CDD 005
-

Rômulo Lopes Frutuoso

Classificação de texturas utilizando métodos de busca com informação

Dissertação submetida à Coordenação do Curso de Pós-Graduação em Ciência da Computação, da Universidade Federal do Ceará, como requisito parcial para a obtenção do grau de Mestre em Ciências da Computação.

BANCA EXAMINADORA

---

**Prof. Dr. Joaquim Bento Cavalcante  
Neto**  
(Presidente)  
Universidade Federal do Ceará - UFC

---

**Prof. Dr. João Paulo Pordeus Gomes**  
(Coorientador)  
Universidade Federal do Ceará - UFC

---

**Prof. Dr. Creto Augusto Vidal**  
Universidade Federal do Ceará - UFC

---

**Prof. Dr. Ajalmar Rego da Rocha  
Neto**  
Instituto Federal de Educação, Ciência e  
Tecnologia do Ceará - IFCE

Fortaleza, 26 de Agosto de 2016.

# Agradecimentos

Aos meus Pais Antônio Lopes e Maria Goreti, pois sem eles nunca teria oportunidades de chegar até aqui.

Aos meus colegas de turma da graduação Jonas Rodrigues e Adonias Caetano, que hoje os considero amigos.

Ao meu orientador Joaquim Bento pelo apoio e suporte e ao meu co-orientador João Paulo pela paciência e imensa ajuda que me forneceu para a conclusão desta dissertação e ao professor Creto Vidal pelo suporte neste trabalho.

À Fundação Cearense de Amparo à pesquisa (FUNCAP) pela concessão de bolsa de estudo como apoio financeiro ao desenvolvimento científico.

# Resumo

Classificação de texturas em imagens é um tema com várias áreas de aplicações, tais como: reconhecimento de faces, sensoriamento remoto e reconhecimento de folhas de plantas. Vários métodos vem sendo propostos ao longo do tempo. Recentemente, um novo método para extração de características baseado em grafos, intitulado de caminhos mínimos em grafos (CMG) foi criado, onde, de forma simplificada, transforma a imagem em um grafo e extrai algumas estatísticas, baseado no caminho mínimo de Dijkstra, entre pontos definidos. Neste trabalho são propostas modificações no método CMG com o objetivo de reduzir a quantidade de estados visitados no grafo e reduzir o custo computacional. Os experimentos são realizados nas bases: Brodatz, UIUC, 2D HeLa e Virus. Os resultados mais promissores trazem uma redução de até 89% nos estados que são visitados no grafo, mantendo a porcentagem de acertos.

**Palavras-chaves:** Análise de texturas, grafos, caminhos mínimos, busca com informação.

# Abstract

Texture classification in images is a research subject of interest to many areas of application such as: face recognition, remote sensing and recognition of plant leaves. Several methods have been proposed in the literature. Recently, a new method for feature extraction, named Shortest Paths in Graphs (SPG), was presented. That method, in a simplified fashion, transforms an image into a graph and extracts some statistic measures based on Dijkstra's minimum path through a set of points. In our work, we modify SPG in order to reduce the number of states visited in the graph and lower the computational cost. We carried out a number of experiments on the following image databases: Brodatz, UIUC, 2D HeLa and Virus. The best results achieved a reduction of 89

**Key-words:** Texture analysis, Graphs, shortest paths, Search with information.

# Lista de ilustrações

Figura 1 – Exemplos de texturas (Brodatz e UIUC). . . . .	23
Figura 2 – Exemplos de grafos não orientados. . . . .	24
Figura 3 – Exemplos de grafos ponderados. . . . .	24
Figura 4 – Exemplo do cálculo do LBP. (a) Imagem a ser processada, apenas uma região é usada no exemplo. (b) Vizinhança 8 do pixel. (c) Valores decimais dos pixels. (d) Valores limiarizados, comparando se o pixel central é maior aos vizinhos. (e) Valor binário criado com o resultado da limiarização. (f) Histograma gerado para todos os pixels da imagem.	28
Figura 5 – Exemplo dos ângulos $\theta$ para cálculo da GLCM (NASCIMENTO, 2003).	29
Figura 6 – Exemplo de cálculo de matrizes de co-ocorrência para uma imagem com níveis de cinza [0..3] para os ângulos $0^\circ$ , $45^\circ$ , $90^\circ$ e $135^\circ$ (NASCIMENTO, 2003). . . . .	29
Figura 7 – Exemplo de um grafo criado para um fragmento de uma imagem de textura. . . . .	30
Figura 8 – Ilustração do relevo no percurso do caminho mínimo (SÁ, 2013). . . . .	31
Figura 9 – Quatro diferentes caminhos( $0^\circ$ , $45^\circ$ , $90^\circ$ e $135^\circ$ ). . . . .	31
Figura 10 – Visão geral da obtenção dos vetores de características (SÁ, 2013). . . . .	33
Figura 11 – Exemplo com as etapas do método CMG. (a) Representa a imagem de entrada para o método. A imagem deve ser em tons de cinza.(b) Criação do grafo para a imagem de entrada, seguindo a Equação 2.5 para a criação do pesos das arestas do grafo. (c) e (d) Subdivisão do grafo. No exemplo, em quatro subgrafos. (e) e (f) Calculam, para cada subgrafo, os caminhos nos quatro diferentes ângulos ( $0^\circ$ , $45^\circ$ , $90^\circ$ e $135^\circ$ ) usando o Algoritmo 1. (g) Para cada subgrafo são extraídos os custos de cada caminho. (h) Exemplos de custos extraídos de cada um dos quatro subgrafos. (i) Nesta etapa é calculado as médias para cada ângulo ( $\alpha_{0^\circ}$ , $\alpha_{45^\circ}$ , $\alpha_{90^\circ}$ e $\alpha_{135^\circ}$ ), os desvios padrões ( $\beta_{0^\circ}$ , $\beta_{45^\circ}$ , $\beta_{90^\circ}$ e $\beta_{135^\circ}$ ) e o vetor de concatenação das médias e desvios padrões ( $\vec{\psi}$ ). Note que $\vec{\psi}$ é o vetor de características extraído da imagem. . . . .	34
Figura 12 – Exemplo gráfico da superfície de decisão gerada por um método linear.	35
Figura 13 – Exemplo gráfico da superfície de decisão gerada por um método não linear. . . . .	35
Figura 14 – Exemplo de rede neural com multiplas camadas (OLIVEIRA, 2001). . . . .	37
Figura 15 – Exemplo de um trecho de caminho percorrido com heurística. . . . .	43
Figura 16 – Influência do parâmetro $C$ no caminho de uma imagem. . . . .	43



Figura 17 – Estados visitados para diferentes valores de $C$ . As colunas da esquerda para direita indicam pontos intermediários dos estados que foram visitados. Os pixels vermelhos são os estados que foram visitados na imagem. .....	44
Figura 18 – Fluxograma para escolha automática do parâmetro $C$ . . . . .	45
Figura 19 – Exemplos de texturas de Brodatz. . . . .	46
Figura 20 – Exemplos de texturas UIUC . . . . .	47
Figura 21 – Exemplos de texturas de Virus. . . . .	48
Figura 22 – Exemplos de texturas de 2D HeLa. . . . .	48
Figura 23 – Exemplos de grafos com diferentes graus médios. . . . .	49
Figura 24 – Taxa de acerto com desvio padrão em função do parâmetro $C$ para o conjunto de imagens Brodatz com as janelas $\{4, 5, 8, 10, 20, 25, 40, 50\}$ ao se aplicar o classificador LDA (Grau médio 8). . . . .	52
Figura 25 – Taxa de acerto com desvio padrão em função do parâmetro $C$ para o conjunto de imagens Brodatz com as janelas $\{4, 5, 8, 10, 20, 25, 40, 50\}$ ao se aplicar o classificador LDA (Grau médio 4). . . . .	52
Figura 26 – Porcentagem de estados visitados pelo aumento do parâmetro $C$ (Base de imagens Brodatz), para as janelas $\{4, 5, 8, 10, 20, 25, 40, 50\}$ com classificador LDA (Grau médio 8). . . . .	53
Figura 27 – Porcentagem de estados visitados pelo aumento do parâmetro $C$ (Base de imagens Brodatz), para as janelas $\{4, 5, 8, 10, 20, 25, 40, 50\}$ com classificador LDA (Grau médio 4). . . . .	53
Figura 28 – Taxa de acerto com desvio padrão em função do parâmetro $C$ para o conjunto de imagens UIUC com as janelas $\{4, 5, 8, 10, 20, 25, 40, 50\}$ ao se aplicar o classificador LDA (Grau médio 8). . . . .	55
Figura 29 – Taxa de acerto com desvio padrão em função do parâmetro $C$ para o conjunto de imagens UIUC com as janelas $\{4, 5, 8, 10, 20, 25, 40, 50\}$ ao se aplicar o classificador LDA (Grau médio 4). . . . .	55
Figura 30 – Porcentagem de estados visitados pelo aumento do parâmetro $C$ (Base de imagens UIUC), para as janelas $\{4, 5, 8, 10, 20, 25, 40, 50\}$ com classificador LDA (Grau médio 8). . . . .	56
Figura 31 – Porcentagem de estados visitados pelo aumento do parâmetro $C$ (Base de imagens UIUC), para as janelas $\{4, 5, 8, 10, 20, 25, 40, 50, 100\}$ com classificador LDA (Grau médio 4). . . . .	56
Figura 32 – Taxa de acerto com desvio padrão em função do parâmetro $C$ para o conjunto de imagens Virus com as janelas $\{4, 5, 8, 10, 20\}$ ao se aplicar o classificador LDA (Grau médio 8). . . . .	57

Figura 33 – Taxa de acerto com desvio padrão em função do parâmetro $C$ para o conjunto de imagens Virus com as janelas $\{4, 5, 8, 10, 20\}$ ao se aplicar o classificador LDA (Grau médio 4). . . . .	57
Figura 34 – Porcentagem de estados visitados pelo aumento do parâmetro $C$ (Base de imagens Virus), para as janelas $\{4, 5, 8, 10, 20\}$ com classificador LDA (Grau médio 8). . . . .	58
Figura 35 – Porcentagem de estados visitados pelo aumento do parâmetro $C$ (Base de imagens Virus), para as janelas $\{4, 5, 8, 10, 20\}$ com classificador LDA (Grau médio 4). . . . .	58
Figura 36 – Taxa de acerto com desvio padrão em função do parâmetro $C$ para o conjunto de imagens 2D HeLa com as janelas $\{4, 5, 8, 10, 20, 25, 40, 50\}$ ao se aplicar o classificador LDA (Grau médio 8). . . . .	60
Figura 37 – Taxa de acerto com desvio padrão em função do parâmetro $C$ para o conjunto de imagens 2D HeLa com as janelas $\{4, 5, 8, 10, 20, 25, 40, 50, 100\}$ ao se aplicar o classificador LDA (Grau médio 4). . . . .	60
Figura 38 – Porcentagem de estados visitados pelo aumento do parâmetro $C$ (Base de imagens 2D HeLa), para as janelas $\{4, 5, 8, 10, 20, 25, 40, 50\}$ com classificador LDA (Grau médio 8). . . . .	61
Figura 39 – Porcentagem de estados visitados pelo aumento do parâmetro $C$ (Base de imagens 2D HeLa), para as janelas $\{4, 5, 8, 10, 20, 25, 40, 50, 100\}$ com classificador LDA (Grau médio 4). . . . .	61
Figura 40 – Taxa de classificação com desvio padrão pelo aumento do parâmetro $C$ (Base de imagens Brodatz), com classificador LDA (Grau médio 8). . . . .	74
Figura 41 – Porcentagem de estados visitados pelo aumento de $C$ (Base de imagens Brodatz), com classificador LDA (Grau médio 8). . . . .	75
Figura 42 – Taxa de classificação com desvio padrão pelo aumento do parâmetro $C$ (Base de imagens Brodatz), com classificador LDA (Grau médio 4). . . . .	76
Figura 43 – Porcentagem de estados visitados pelo aumento de $C$ (Base de imagens Brodatz), com classificador LDA (Grau médio 4). . . . .	77
Figura 44 – Taxa de classificação com desvio padrão pelo aumento do parâmetro $C$ (Base de imagens Brodatz), com classificador MLP (Grau médio 8). . . . .	79
Figura 45 – Porcentagem de estados visitados pelo aumento de $C$ (Base de imagens Brodatz), com classificador MLP (Grau médio 8). . . . .	80
Figura 46 – Taxa de classificação com desvio padrão pelo aumento do parâmetro $C$ (Base de imagens Brodatz), com classificador MLP (Grau médio 4). . . . .	81
Figura 47 – Porcentagem de estados visitados pelo aumento de $C$ (Base de imagens Brodatz), com classificador MLP (Grau médio 4). . . . .	82
Figura 48 – Taxa de classificação com desvio padrão pelo aumento do parâmetro $C$ (Base de imagens UIUC), com classificador LDA (Grau médio 8). . . . .	84

Figura 49 – Porcentagem de estados visitados pelo aumento de $C$ (Base de imagens UIUC), com classificador LDA (Grau médio 8). . . . .	85
Figura 50 – Taxa de classificação com desvio padrão pelo aumento do parâmetro $C$ (Base de imagens UIUC), com classificador LDA (Grau médio 4). . . .	86
Figura 51 – Porcentagem de estados visitados pelo aumento de $C$ (Base de imagens UIUC), com classificador LDA (Grau médio 4). . . . .	87
Figura 52 – Taxa de classificação com desvio padrão pelo aumento do parâmetro $C$ (Base de imagens UIUC), com classificador MLP (Grau médio 8). . . .	89
Figura 53 – Porcentagem de estados visitados pelo aumento de $C$ (Base de imagens UIUC), com classificador MLP (Grau médio 8). . . . .	90
Figura 54 – Taxa de classificação com desvio padrão pelo aumento do parâmetro $C$ (Base de imagens UIUC), com classificador MLP (Grau médio 4). . . .	91
Figura 55 – Porcentagem de estados visitados pelo aumento de $C$ (Base de imagens UIUC), com classificador MLP (Grau médio 4). . . . .	92
Figura 56 – Taxa de classificação com desvio padrão pelo aumento do parâmetro $C$ (Base de imagens 2D HeLa), com classificador LDA (Grau médio 8). . .	94
Figura 57 – Porcentagem de estados visitados pelo aumento de $C$ (Base de imagens 2D HeLa), com classificador LDA (Grau médio 8). . . . .	95
Figura 58 – Taxa de classificação com desvio padrão pelo aumento do parâmetro $C$ (Base de imagens 2D HeLa), com classificador LDA (Grau médio 4). . .	96
Figura 59 – Porcentagem de estados visitados pelo aumento de $C$ (Base de imagens 2D HeLa), com classificador LDA (Grau médio 4). . . . .	97
Figura 60 – Taxa de classificação com desvio padrão pelo aumento do parâmetro $C$ (Base de imagens 2D HeLa), com classificador MLP (Grau médio 8). . .	99
Figura 61 – Porcentagem de estados visitados pelo aumento de $C$ (Base de imagens 2D HeLa), com classificador MLP (Grau médio 8). . . . .	100
Figura 62 – Taxa de classificação com desvio padrão pelo aumento do parâmetro $C$ (Base de imagens 2D HeLa), com classificador MLP (Grau médio 4). . .	101
Figura 63 – Porcentagem de estados visitados pelo aumento de $C$ (Base de imagens 2D HeLa), com classificador MLP (Grau médio 4). . . . .	102
Figura 64 – Taxa de classificação com desvio padrão pelo aumento do parâmetro $C$ (Base de imagens Virus), com classificador LDA (Grau médio 8). . . .	103
Figura 65 – Porcentagem de estados visitados pelo aumento de $C$ (Base de imagens Virus), com classificador LDA (Grau médio 8). . . . .	104
Figura 66 – Taxa de classificação com desvio padrão pelo aumento do parâmetro $C$ (Base de imagens Virus), com classificador LDA (Grau médio 4). . . .	105
Figura 67 – Porcentagem de estados visitados pelo aumento de $C$ (Base de imagens Virus), com classificador LDA (Grau médio 4). . . . .	105

Figura 68 – Taxa de classificação com desvio padrão pelo aumento do parâmetro $C$ (Base de imagens Virus), com classificador MLP (Grau médio 8). . . . .	106
Figura 69 – Porcentagem de estados visitados pelo aumento de $C$ (Base de imagens Virus), com classificador MLP (Grau médio 8). . . . .	107
Figura 70 – Taxa de classificação com desvio padrão pelo aumento do parâmetro $C$ (Base de imagens Virus), com classificador MLP (Grau médio 4). . . . .	108
Figura 71 – Porcentagem de estados visitados pelo aumento de $C$ (Base de imagens Virus), com classificador MLP (Grau médio 4). . . . .	108

# Lista de tabelas

Tabela 1 – $D_{crítico}$ do Teste de Kolmogorov-Smirnov (SIEGEL; CASTELLAN, 2008).	40
Tabela 2 – Comparativo de resultados CMG e método proposto (Brodatz) com grau 8 usando o classificador LDA. . . . .	51
Tabela 3 – Comparativo de resultados CMG e método proposto (Brodatz) com grau 4 usando o classificador LDA. . . . .	51
Tabela 4 – Comparativo de resultados CMG e método proposto (UIUC) com grau 4 usando o classificador LDA. . . . .	54
Tabela 5 – Comparativo de resultados CMG e método proposto (UIUC) com grau 8 usando o classificador LDA. . . . .	54
Tabela 6 – Comparativo de resultados CMG e método proposto (Virus) com grau 8 usando o classificador LDA. . . . .	55
Tabela 7 – Comparativo de resultados CMG e método proposto (Virus) com grau 4 usando o classificador LDA. . . . .	55
Tabela 8 – Comparativo de resultados CMG e método proposto (2D HeLa) com grau 8 usando o classificador LDA. . . . .	59
Tabela 9 – Comparativo de resultados CMG e método proposto (2D HeLa) com grau 4 usando o classificador LDA. . . . .	59
Tabela 10 – Comparativo de resultados com métodos clássicos usando o classificador LDA. . . . .	59
Tabela 11 – Comparativo de resultados CMG e método proposto (Brodatz) com grau 8 usando o classificador MLP. . . . .	62
Tabela 12 – Comparativo de resultados CMG e método proposto (Brodatz) com grau 4 usando o classificador MLP. . . . .	62
Tabela 13 – Comparativo de resultados CMG e método proposto (UIUC) com grau 8 usando o classificador MLP. . . . .	63
Tabela 14 – Comparativo de resultados CMG e método proposto (UIUC) com grau 4 usando o classificador MLP. . . . .	63
Tabela 15 – Comparativo de resultados CMG e método proposto (Virus) com grau 8 usando o classificador MLP. . . . .	63
Tabela 16 – Comparativo de resultados CMG e método proposto (Virus) com grau 4 usando o classificador MLP. . . . .	63
Tabela 17 – Comparativo de resultados CMG e método proposto (2d HeLa) com grau 8 usando o classificador MLP. . . . .	64
Tabela 18 – Comparativo de resultados CMG e método proposto (2d HeLa) com grau 4 usando o classificador MLP. . . . .	64

Tabela 19 – Comparativo de resultados com métodos clássicos usando o classificador

MLP. . . . . 64

# Lista de abreviaturas e siglas

LBP	<i>Local binary patterns</i>
KS-Test	<i>two-sample Kolmogorov-Smirnov test</i>
TH	Teste de hipótese
MC	Matriz de co-ocorrência
CMG	Caminhos mínimos em grafos

# Lista de símbolos

$G$	Representação de Grafo
$V$	Conjunto de vértices de um grafo
$E$	Conjunto de arestas de um grafo
$w(e)$	Valor de uma aresta
$deg_G(G)$	Grau médio de um grafo $G$
$J(v)$	Custo de visitar o nó $v$
$g(v)$	Custo do caminho da origem até o nó $v$
$h(v)$	Heurística que estima o custo de chegar até o destino
$I$	Imagem Digital
$l$	Tamanho da janela
$\mu_{i^\circ}$	Média para uma janela com grau $i^\circ$
$\vec{\alpha}_l$	Vetor com as médias para uma janela $l$
$\sigma_{i^\circ}$	Desvio padrão para uma janela com grau $i^\circ$
$\vec{\beta}_l$	Vetor com os Desvios padrões para uma janela $l$
$\vec{\psi}_l$	Vetor concatenado com as médias e os desvios padrões
$v_{l_1, l_2, \dots, l_n}^{\vec{\alpha}}$	Vetor de médias para diferentes tamanhos de janelas $l$
$\omega_{l_1, l_2, \dots, l_n}^{\vec{\beta}}$	Vetor com os desvios padrões para diferentes tamanhos de janelas $l$
$\varphi_{l_1, l_2, \dots, l_n}^{\vec{\psi}}$	Vetor concatenado com as médias e os desvios padrões para diferentes tamanhos de janelas $l$
$P(i)$	Probabilidade associada à classe $i$



# Sumário

<b>1</b>	<b>Introdução</b>	<b>19</b>
1.1	Objetivo Geral	20
1.1.1	Objetivos específicos	20
1.2	Organização do Trabalho	20
<b>2</b>	<b>Fundamentação teórica</b>	<b>22</b>
2.1	Texturas em imagens	22
2.2	Grafos	23
2.2.1	Grafo não orientado	23
2.2.2	Grafo ponderado	23
2.2.3	Grau de um grafo	24
2.2.4	Caminhos mais curtos	25
2.2.4.1	Algoritmo de Dijkstra	25
2.2.4.2	Busca com informação	25
2.3	Métodos de extração de características em texturas	27
2.3.1	Padrão Binário Local	27
2.3.2	Matrizes de co-ocorrência	28
2.3.3	Caminhos mais curtos em grafos	29
2.3.3.1	Extração das características	31
2.4	Classificação	32
2.4.1	Análise linear discriminante	33
2.4.2	Perceptron de multicamadas	36
2.4.2.1	Backpropagation	37
2.5	Métodos para análise de classificação	38
2.5.1	Validação cruzada	38
2.5.2	Teste de hipótese	38
<b>3</b>	<b>Método proposto</b>	<b>41</b>
3.1	Descrição	41
3.1.1	Extração das características	41
3.1.2	Impacto da escolha do parâmetro $C$	42
3.1.3	Escolha automática do parâmetro $C$	44
<b>4</b>	<b>Experimentos e Resultados</b>	<b>46</b>
4.1	Conjuntos de imagens	46
4.1.1	Texturas de Brodatz	46
4.1.2	Texturas UIUC	47
4.1.3	Texturas Virus	47
4.1.4	Texturas 2D HeLa	48

4.2	Parâmetros empregados . . . . .	49
4.3	Resultados com LDA . . . . .	50
4.3.1	Resultados para as texturas Brodatz . . . . .	50
4.3.2	Resultados para as texturas UIUC . . . . .	52
4.3.3	Resultados para as texturas Virus . . . . .	54
4.3.4	Resultados para as texturas 2D HeLa . . . . .	58
4.3.5	Comparação com métodos clássicos . . . . .	59
4.4	Resultados com MLP . . . . .	61
4.4.1	Resultados para as texturas Brodatz . . . . .	62
4.4.2	Resultados para as texturas UIUC . . . . .	62
4.4.3	Resultados para as texturas Virus . . . . .	63
4.4.4	Resultados para as texturas 2D HeLa . . . . .	64
4.4.5	Comparação com métodos clássicos . . . . .	64
<b>5</b>	<b>Conclusão e trabalhos futuros . . . . .</b>	<b>66</b>
	<b>Referências . . . . .</b>	<b>67</b>
	<b>Apêndices . . . . .</b>	<b>72</b>
	<b>APÊNDICE A Resultados Brodatz com LDA . . . . .</b>	<b>73</b>
A.1	Grau médio 8 . . . . .	73
A.1.1	Taxa de classificação . . . . .	73
A.1.2	Porcentagem de estados visitados . . . . .	73
A.2	Grau médio 4 . . . . .	73
A.2.1	Taxa de classificação . . . . .	73
A.2.2	Porcentagem de estados visitados . . . . .	73
	<b>APÊNDICE B Resultados Brodatz com MLP . . . . .</b>	<b>78</b>
B.1	Grau médio 8 . . . . .	78
B.1.1	Taxa de classificação . . . . .	78
B.1.2	Porcentagem de estados visitados . . . . .	78
B.2	Grau médio 4 . . . . .	78
B.2.1	Taxa de classificação . . . . .	78
B.2.2	Porcentagem de estados visitados . . . . .	78
	<b>APÊNDICE C Resultados UIUC com LDA . . . . .</b>	<b>83</b>
C.1	Grau médio 8 . . . . .	83
C.1.1	Taxa de classificação . . . . .	83
C.1.2	Porcentagem de estados visitados . . . . .	83
C.2	Grau médio 4 . . . . .	83
C.2.1	Taxa de classificação . . . . .	83

---

C.2.2	Porcentagem de estados visitados . . . . .	83
<b>APÊNDICE D</b>	<b>Resultados UIUC com MLP . . . . .</b>	<b>88</b>
D.1	Grau médio 8 . . . . .	88
D.1.1	Taxa de classificação . . . . .	88
D.1.2	Porcentagem de estados visitados . . . . .	88
D.2	Grau médio 4 . . . . .	88
D.2.1	Taxa de classificação . . . . .	88
D.2.2	Porcentagem de estados visitados . . . . .	88
<b>APÊNDICE E</b>	<b>Resultados 2D HeLa com LDA . . . . .</b>	<b>93</b>
E.1	Grau médio 8 . . . . .	93
E.1.1	Taxa de classificação . . . . .	93
E.1.2	Porcentagem de estados visitados . . . . .	93
E.2	Grau médio 4 . . . . .	93
E.2.1	Taxa de classificação . . . . .	93
E.2.2	Porcentagem de estados visitados . . . . .	93
<b>APÊNDICE F</b>	<b>Resultados 2D HeLa com MLP . . . . .</b>	<b>98</b>
F.1	Grau médio 8 . . . . .	98
F.1.1	Taxa de classificação . . . . .	98
F.1.2	Porcentagem de estados visitados . . . . .	98
F.2	Grau médio 4 . . . . .	98
F.2.1	Taxa de classificação . . . . .	98
F.2.2	Porcentagem de estados visitados . . . . .	98
<b>APÊNDICE G</b>	<b>Resultados Virus com LDA . . . . .</b>	<b>103</b>
G.1	Grau médio 8 . . . . .	103
G.1.1	Taxa de classificação . . . . .	103
G.1.2	Porcentagem de estados visitados . . . . .	103
G.2	Grau médio 4 . . . . .	104
G.2.1	Taxa de classificação . . . . .	104
G.2.2	Porcentagem de estados visitados . . . . .	104
<b>APÊNDICE H</b>	<b>Resultados Virus com MLP . . . . .</b>	<b>106</b>
H.1	Grau médio 8 . . . . .	106
H.1.1	Taxa de classificação . . . . .	106
H.1.2	Porcentagem de estados visitados . . . . .	106
H.2	Grau médio 4 . . . . .	107
H.2.1	Taxa de classificação . . . . .	107
H.2.2	Porcentagem de estados visitados . . . . .	107

# 1 Introdução

O campo de Processamento Digital de Imagens (PDI) teve seu crescimento com os primeiros computadores digitais de grande porte e o início do programa espacial norte-americano (FILHO; VIEIRA, 1999). Neste contexto, com o crescimento da capacidade de processamento dos computadores pessoais, houve uma grande mudança da computação que antes era apenas efetuada por supercomputadores, sendo desenvolvida em máquinas comuns. Assim, o PDI, que em algumas décadas atrás era unicamente desenvolvido em computadores de grande porte, pode ser realizado em computadores pessoais.

Na vasta área de PDI, a análise de imagens é uma de suas subáreas mais relevantes e busca a extração de informações pertinentes em imagens (SÁ, 2013) a fim de obter informações necessárias para diferenciar regiões de interesse em uma imagem (GONZALEZ; WOODS, 1997).

Dentre os diversos atributos relevantes de uma imagem, a textura é um dos mais significativos pelo fato de se tratar de uma fonte rica de informações. Assim, a identificação de texturas é um problema com muitas áreas de aplicação, como sensoriamento remoto (SHIRAIISHI et al., 2014) (TONG; XIE; WENG, 2013) (KHAN; MASSELLI; ZELL, 2012) e a área médica (CASTELLANO et al., 2004) (GHIDONI et al., 2014).

Embora seres humanos possam reconhecer e diferenciar texturas de maneira simples e rápida, a classificação de texturas é um dos problemas mais desafiadores em reconhecimento automático de padrões (SÁ; BACKES; CORTEZ, 2013).

Uma textura pode ser definida como uma das formas mais importantes para classificar e fazer o reconhecimento de objetos em imagens, podendo ser caracterizada por variações locais em valores de pixels que se repetem de maneira regular ou aleatória. A etapa de classificação visa a extração de informações relevantes em imagens, com o intuito de reconhecer determinados padrões.

Várias estratégias para a classificação de texturas têm sido propostas na literatura. Essas estratégias se baseiam principalmente baseados em estatísticas de segunda ordem (HARALICK; SHANMUGAM; DINSTEN, 1973; BELIAKOV; JAMES; TROIANO, 2008) e análise espectral (AZENCOTT; WANG; YOUNES, 1997; MANJUNATH; MA, 1996). Recentemente, alguns métodos baseados em modelos físicos (SÁ; BACKES, 2012), teoria dos grafos (SÁ; BACKES; CORTEZ, 2013) e teoria complexa de redes (COSTA et al., 2005) mostraram resultados promissores. Entretanto, ainda não há um método genérico ou uma abordagem formal que seja útil para uma grande variedade de imagens (AKSOY, 1998).

Contudo, um método recente para extração de características em texturas, denominado caminhos mínimos em grafos (CMG), proposto por SÁ, BACKES e CORTEZ (2013), mostrou resultados superiores quando comparado com métodos clássicos. O trabalho consiste em modelar a imagem como grafo, a partir do qual são traçados caminhos mínimos com o algoritmo de Dijkstra (DIJKSTRA, 1959), em algumas orientações. O vetor de características da imagem é obtido através do cálculo de medidas estatísticas nesses caminhos.

Apesar do grande desempenho, o método CMG pode ser impraticável em aplicações com processamento e memória limitada, pelo fato do algoritmo de Dijkstra possuir tempo exponencial e, conseqüentemente, pode dificultar o processamento de imagens de alta resolução.

Portanto, o objetivo principal deste trabalho é efetuar a classificação de texturas em imagens, fazendo uma variação no método CMG, onde é proposta a utilização de busca com informação. O método de busca com informação usa uma heurística para guiar o caminho, reduzindo a quantidade de estados que são visitados e o custo computacional.

## 1.1 Objetivo Geral

Seguindo a abordagem de classificação de texturas, o objetivo principal deste trabalho é realizar um estudo comparativo entre métodos para classificação de texturas e propor um aprimoramento no método dos caminhos mínimos em grafos com base em busca com informação. Além disso é realizado um estudo no qual se compara os resultados com diferentes configurações de grafos.

### 1.1.1 Objetivos específicos

Os objetivos específicos desta dissertação são:

1. Apresentar os métodos para classificação de texturas;
2. Apresentar um estudo comparativo entre métodos clássicos da literatura, CMG e o método proposto;
3. Propor uma heurística para guiar o caminho no grafo e
4. Propor nova estruturação do grafo do método CMG.

## 1.2 Organização do Trabalho

O restante deste trabalho está dividido em quatro capítulos.

---

O Capítulo 2 é apresentada a fundamentação teórica para esta dissertação, bem como é mostrada a definição do que é uma textura, algumas definições sobre teoria dos grafos, uma breve introdução aos métodos mais empregados na literatura para extração de características em textura de imagens e a teoria do classificador empregado nesta dissertação. O funcionamento e as etapas utilizadas do método proposto neste trabalho podem ser observadas no Capítulo 3. No Capítulo 4 são apresentados os experimentos e resultados que foram obtidos. Detalha as bases de imagens e os parâmetros que foram adotados para os experimentos. Por fim, o Capítulo 5 são mostrados a conclusão desta dissertação e os trabalhos futuros.

## 2 Fundamentação teórica

Este capítulo detalha a fundamentação teórica deste trabalho. Inicialmente discute-se a definição do que é uma textura em imagens digitais. Na Seção 2.2 são apresentadas definições sobre teoria dos grafos. Alguns métodos de extração de características em textura são apresentados na Seção 2.3. A Seção 2.4 descreve a teoria necessária relacionada ao do classificador utilizado nesta dissertação, da mesma maneira que, o teste de kolmogorov-smirnov empregado como teste de hipótese neste trabalho.

### 2.1 Texturas em imagens

Não existe na literatura uma definição formal que represente de forma ampla o conceito de textura (EBERT et al., 2002), embora vários autores definam de forma similar. A seguir são apresentadas algumas definições.

Segundo RAO (1990), uma textura pode ser caracterizada como a qualidade visual de uma imagem relacionada com a sua variação espacial de cor ou tons de cinza.

De acordo com HARALICK, SHANMUGAM e DINSTEN (1973), a textura pode ser definida por sua uniformidade, densidade, aspereza, regularidade, entre outras características em uma imagem. A textura é caracterizada como um conceito bidimensional, onde uma dimensão contém as propriedades primitivas da tonalidade e a outra os relacionamentos espaciais entre elas. As definições de textura e tonalidade não são independentes, onde em algumas imagens a textura é dominante e, em outras, a tonalidade é dominante.

A textura é uma característica importante na percepção de imagens, sendo interpretada como a relação espacial entre o arranjo de elementos básicos de uma imagem (CHRISTODOULOU; MICHAELIDES; PATTICHIS, 2003). Geralmente, as texturas são usadas para indicar propriedades intrínsecas de superfícies ou regiões, principalmente as que apresentam uma variação suave de intensidade, sendo tão pequenas que não conseguem separar objetos na resolução observada (SABINO et al., 2004).

Assim, o problema de textura em imagens sofre por não ter uma definição formal, dificultando encontrar uma solução para o problema. Esse motivo pode ser levado em conta quando é realizada uma análise da quantidade de diferentes métodos criados para classificação de texturas em imagens.

Para ilustrar, a Figura 1 apresenta alguns exemplos de texturas extraídas das bases de imagens Brodatz (BRODATZ, 1966) e UIUC (LAZEBNIK; SCHMID; PONCE, 2005).




Figura 1 – Exemplos de texturas (Brodatz e UIUC).

## 2.2 Grafos

Um grafo é caracterizado como uma estrutura constituída por dois elementos básicos, os vértices e as arestas. Em geral, cada aresta possui dois vértices conectados a ela. Os grafos são considerados estruturas que podem representar um grande número de diferentes situações e eventos em domínios distintos (DROZDEK, 2000).

Formalmente, um grafo é um par  $G = (V, E)$ , tal que  $V(G) = \{v_1, v_2, \dots, v_n\}$  é o conjunto de vértices e  $E(G)$  é o conjunto das arestas entre os vértices, onde,  $E(G) = \{a_1, a_2, \dots, a_m\}$  de tal maneira que  $a_k = (v_{ki}, v_{kj})$ , para  $k, i, j \in \{1, 2, \dots, m\}, (|V| = n, |E| = m)$  (CORMEN et al., 2009).

### 2.2.1 Grafo não orientado

Um grafo não orientado é um par  $G = (V, E)$ , onde  $V$  e  $E$  representam os conjuntos de vértices e de arestas, respectivamente, no qual uma aresta  $(u, v)$  é igual a  $(v, u)$ . Portanto, no grafo não orientado, as arestas não são pares ordenados de vértices. A Figura 2 exhibe alguns exemplos de grafos não orientados.

### 2.2.2 Grafo ponderado

No grafo ponderado, cada aresta  $(u, v) \in G(V, E)$  tem um valor  $w(u, v)$  associado a ela, como visto na Figura 3.






Figura 2 – Exemplos de grafos não orientados.




Figura 3 – Exemplos de grafos ponderados.

A vantagem do emprego de grafos ponderados é a resolução de problemas reais. Por exemplo, um grafo com cada vértice representando uma cidade e as arestas representando as distâncias entre elas e, assim, pode ser submetido a algoritmos de busca em grafos calcular para a menor distância entre essas duas cidades (DROZDEK, 2000).

### 2.2.3 Grau de um grafo

O grau de um determinado vértice  $v$ , denotado por  $d_G(v)$  é o número de arestas  $|E(v)|$  em  $v$  (BONDY, 1976). Em outras palavras, o grau é a quantidade de arestas que um determinado vértice possui. Por exemplo, todos os vértices da Figura 2a têm grau igual a dois, ou seja, todos os vértices possuem duas arestas; enquanto na Figura 2b todos os vértices têm grau quatro.

Um vértice com grau zero é chamado de isolado, ou seja, não possui nenhuma aresta que faça a ligação com outro vértice do grafo.

O grau médio de um grafo  $G$  é a soma das quantidades de arestas  $|E(v)|$  para cada vértice  $v$  do grafo, dividido pelas quantidades de vértices, conforme expressa a equação

$$deg_G(G) = \frac{1}{|V|} \sum_{i \in V} |E(v_i)|, \tag{2.1}$$

em que  $deg_G(G)$  é o grau médio de todos os vértices  $v$  do grafo  $G$ .

## 2.2.4 Caminhos mais curtos

O problema do Caminho Mínimo é bem conhecido na teoria dos grafos, e inúmeras soluções já foram propostas (DROZDEK, 2000). Muitos dos problemas do mundo real implicam encontrar o menor caminho entre dois pontos quaisquer (ORTEGA-ARRANZ et al., 2014).

Por definição, um caminho de um vértice  $u$  até  $u'$  em um grafo  $G(V, E)$  é uma sequência  $\langle v_0, v_1, v_2, \dots, v_k \rangle$  de vértices tais que  $u = v_0$ ,  $u' = v_k$  e  $(v_{i-1}, v_i)$  para  $i = 1, 2, \dots, k$ . O comprimento de caminho é a quantidade de arestas do caminho (CORMEN et al., 2009). O custo de um caminho é a soma dos pesos das arestas do caminho.

### 2.2.4.1 Algoritmo de Dijkstra

O algoritmo de Dijkstra (DIJKSTRA, 1959) é um algoritmo que soluciona o problema de encontrar o menor caminho entre dois pontos quaisquer em um grafo ponderado  $G = (V, E)$ , onde os valores das arestas devem ser não-negativos  $w(u, v) \geq 0$  para cada aresta  $(u, v) \in E$ . Nesse algoritmo, supõe-se a existência de pelo menos um caminho entre os nós.

Assim, o algoritmo tem a capacidade de encontrar um caminho (se existir) entre origem e destino, sendo considerado um algoritmo completo. Também, sempre encontra a solução ótima, o caminho mínimo. Além disso, o algoritmo não possui nenhuma informação adicional sobre os estados, além das fornecidas pelo problema, realizando uma busca cega (RUSSELL; NORVIG, 2009).

A função objetivo é definida por,

$$J(v) = g(v), \quad (2.2)$$

em que  $J(v)$  é o custo de visitar o nó  $v$  e  $g(v)$  o custo do caminho da origem até o nó  $v$ .

Portanto, o Algoritmo 1 são apresentas as etapas do algoritmo de Dijkstra. No algoritmo as entradas são o grafo e os vértices de origem e destino. A função  $Antecessor(v)$  fornece o nó anterior ao nó  $v$ ,  $adjacente(v)$  é uma lista com nós adjacentes de  $v$  e  $custo(v)$  informa o custo do caminho do vértice  $v$  até a origem. As saídas são o caminho mínimo e o custo do menor caminho.

### 2.2.4.2 Busca com informação

O algoritmo de Dijkstra, apresentado anteriormente, é um algoritmo que encontra o caminho mínimo em um grafo usando uma busca cega, não tendo nenhum conhecimento

---

**Algoritmo 1** Algoritmo de Dijkstra.

---

**ENTRADA:** $G$  : Grafo ponderado. $o$  : Vértice origem. $d$  : Vértice destino.**SAÍDA:** $custo(d)$  : Custo do menor caminho entre os vértices  $o$  e  $d$ .

```

1: para todo  $v \in V(G)$  faça
2:    $custo(v) \leftarrow \infty$ 
3: fim para
4:  $custo(o) \leftarrow 0$ 
5:  $Antecessor(o) \leftarrow 0$ 
6: enquanto existe Vértice não visitado faça
7:    $b \leftarrow$  vértice não visitado com menor custo.
8:   marca  $b$  como visitado.
9:   para cada  $a \in adjacente(b)$  faça
10:    se  $custo(b) + custo(b, a) < custo(a)$  então
11:       $custo(a) = custo(b) + custo(b, a)$ 
12:       $Antecessor(a) = b$ 
13:    fim se
14:  fim para
15: fim enquanto

```

---

prévio sobre o problema.

Diferente do algoritmo de Dijkstra, onde não existe nenhum conhecimento do problema, na busca informada ou busca heurística, é utilizado um conhecimento prévio (heurística) sobre o domínio para encontrar soluções mais eficientes. O objetivo é aprimorar o processo de busca pela redução do número de nós explorados e, conseqüentemente, reduzir o tempo de processamento (RUSSELL; NORVIG, 2009).

Uma heurística pode ser definida como uma estimativa para a função custo, com o objetivo de melhorar o desempenho no caso médio em problemas de busca. Mesmo no pior caso, pode ocorrer uma melhoria no desempenho (RUSSELL; NORVIG, 2009).

Em geral, as heurísticas melhoram os caminhos a serem percorridos, porém podem ignorar o melhor caminho. Podem-se obter boas soluções usando uma boa heurística em problemas difíceis. Assim, a escolha de uma função heurística é de grande importância para obter um bom desempenho.

Portanto, pode-se dizer que a heurística fornece uma informação adicional para guiar o caminho. Com o emprego de uma heurística adequada em um grafo acarreta em uma diminuição da quantidade de vértices percorridos pelo algoritmo.

Assim, no algoritmo Dijkstra pode-se ter uma informação adicional sobre o problema,

uma heurística, adicionando-se na função objetivo essa heurística, como definido por

$$J(v) = g(v) + h(v), \quad (2.3)$$

em que  $J(v)$  é o custo de visitar o nó  $v$ ,  $g(v)$  é o custo do caminho da origem até o nó  $v$  e  $h(v)$  é a heurística que estima o custo de chegar até o destino a partir de  $v$ .

O algoritmo de Dijkstra com a heurística é também conhecido como A\* (HART; NILSSON; RAPHAEL, 1968), sendo a forma mais amplamente conhecida de busca com heurística (RUSSELL; NORVIG, 2009).

Por fim, para que o algoritmo ainda seja completo (encontre um caminho entre origem e destino, se existir) e ótimo (sempre encontre o caminho mínimo), a heurística utilizada deve ser admissível, ou seja, não deve superestimar o custo de alcançar o nó objetivo (RUSSELL; NORVIG, 2009).

## 2.3 Métodos de extração de características em texturas

Os métodos de análise de texturas em imagens têm o objetivo de extrair determinados padrões que as texturas possuem.

Para este trabalho, são apresentados dois métodos amplamente estudados na literatura: Padrão Binário Local e Matrizes de co-ocorrência. Também é apresentado o método dos Caminhos mínimos em grafos, que é a base para o trabalho proposto nesta dissertação.

### 2.3.1 Padrão Binário Local

O Padrão binário local (*Local Binary Pattern*, LBP) é um algoritmo para extração de informações em textura. O LBP apresenta robustez em relação a variações de escala de cinza, em virtude de ser invariante a transformação monótona da escala de cinza. Além disso, é um método computacionalmente simples e pode ser realizado com algumas operações em uma pequena área e uma tabela de pesquisa (OJALA; PIETIKÄINEN; MÄENPÄÄ, 2002).

O funcionamento do LBP tem por base a comparação do pixel central com seus vizinhos, para toda a imagem. A partir do valor do pixel central, a vizinhança é limiarizada em um padrão binário (RAJU; DURAI, 2013). Após esta etapa, o padrão binário é transformado em seu respectivo valor decimal que é usado para gerar um histograma que representa o descritor extraído pelo método.

Para ilustrar o processo, a Figura 4 mostra as etapas do procedimento.

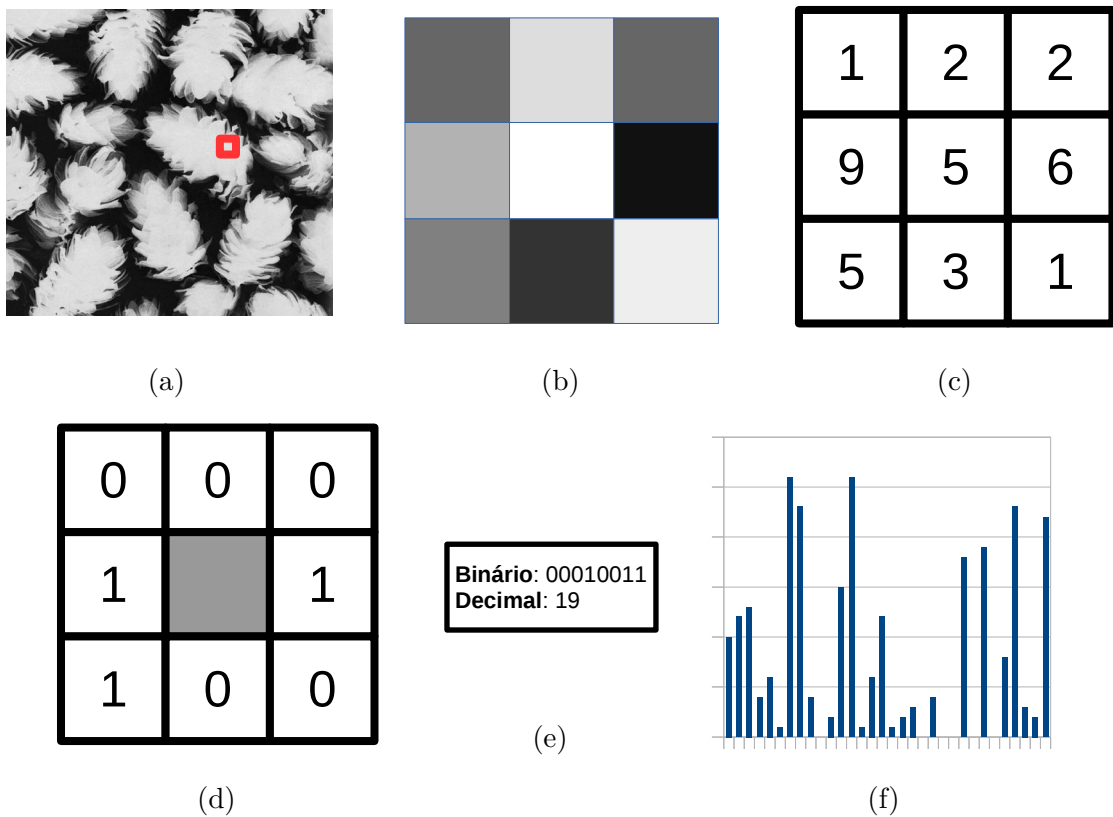


Figura 4 – Exemplo do cálculo do LBP. (a) Imagem a ser processada, apenas uma região é usada no exemplo. (b) Vizinhança 8 do pixel. (c) Valores decimais dos pixels. (d) Valores limiarizados, comparando se o pixel central é maior aos vizinhos. (e) Valor binário criado com o resultado da limiarização. (f) Histograma gerado para todos os pixels da imagem.

### 2.3.2 Matrizes de co-ocorrência

Observa-se que uma característica da textura está relacionada com a distribuição e dependência espacial entre os níveis de intensidade dos pixels em uma área local (HARALICK; SHANMUGAM; DINSTEN, 1973).

As matrizes de co-ocorrência (MC) são matrizes que apresentam a organização espacial da ocorrência de níveis de cinza em uma imagem. As matrizes de co-ocorrência são dispostas em duas dimensões, onde pares de pixels são separados por uma relação espacial fixa (MEDEIROS, 2001).

Uma MC de textura considera a relação entre dois pixels por vez, um chamado de pixel referência e o outro de pixel vizinho. Isto pode ser expresso como uma relação (1,0), ou seja, 1 pixel no eixo  $x$  e 0 pixels no eixo  $y$  (NASCIMENTO, 2003).

A co-ocorrência pode ser especificada por uma matriz de frequências relativas  $P(i, j; d, \theta)$ , na qual dois elementos de textura vizinhos, separados por uma distância  $d$  em uma determinada orientação  $\theta$  ( $0^\circ$ ,  $45^\circ$ ,  $90^\circ$  e  $135^\circ$ ) ocorrem na imagem, um com propriedade  $i$  e o outro com propriedade  $j$  (NASCIMENTO, 2003). Para ilustrar, a Figura

5 apresenta as possíveis direções do cálculo da MC para a vizinhança de um pixel.




Figura 5 – Exemplo dos ângulos  $\theta$  para cálculo da GLCM (NASCIMENTO, 2003).

A Figura 6 ilustra um exemplo do cálculo da matriz de co-ocorrência para os ângulos  $0^\circ$ ,  $45^\circ$ ,  $90^\circ$  e  $135^\circ$  em uma imagem com níveis de intensidade de  $[1..3]$ .

Com a MC criada, algumas características podem ser extraídas, como exemplo: energia, contraste, homogeneidade, valor absoluto, correlação e entropia.

### 2.3.3 Caminhos mais curtos em grafos

O método dos caminhos mais curtos em grafos (CMG) realiza a extração de características de textura em imagens digitais. As características são constituídas pela exploração dos caminhos mais curtos entre pontos definidos da imagem.

O processo de exploração é similar a encontrar a menor rota entre dois computadores em uma determinada rede de computadores.

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

$$P(i, j, 1, 0^\circ) = \begin{bmatrix} 2 & 2 & 1 & 0 \\ 0 & 2 & 0 & 0 \\ 0 & 0 & 3 & 1 \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad P(i, j, 1, 45^\circ) = \begin{bmatrix} 2 & 1 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 2 & 2 & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix}$$

$$P(i, j, 1, 90^\circ) = \begin{bmatrix} 3 & 0 & 0 & 0 \\ 0 & 2 & 0 & 0 \\ 2 & 2 & 1 & 0 \\ 0 & 0 & 2 & 0 \end{bmatrix} \quad P(i, j, 1, 135^\circ) = \begin{bmatrix} 2 & 0 & 0 & 0 \\ 2 & 2 & 0 & 0 \\ 1 & 0 & 3 & 0 \\ 0 & 0 & 1 & 1 \end{bmatrix}$$

Figura 6 – Exemplo de cálculo de matrizes de co-ocorrência para uma imagem com níveis de cinza  $[0..3]$  para os ângulos  $0^\circ$ ,  $45^\circ$ ,  $90^\circ$  e  $135^\circ$  (NASCIMENTO, 2003).

A primeira etapa é a criação de um grafo não-direcionado que represente a relação de vizinhança entre os pixels de uma imagem (SÁ, 2013). Assim, é construído um grafo  $G = (V, E)$  considerando cada pixel  $I(x, y)$ ,  $x = 1 \dots M$  e  $y = 1 \dots N$  como um vértice  $v \in V$  do grafo  $G$ . Cada um dos vértices do grafo representa um pixel na imagem. As arestas são criadas baseadas na distância de Chebyshev quando a distância entre dois vértices não for maior do que um valor  $r_d$ , definido

$$E = \{e = (v, v') \in V \times V | \max(|x - x'|, |y - y'|) = r_d\}. \quad (2.4)$$

Para cada aresta  $e \in E(G)$  é associado um peso

$$w(e) = |I(x, y) - I(x', y')| + \frac{I(x, y) + I(x', y')}{2}, \quad (2.5)$$

em que  $I(x, y)$  é o valor do pixel que está sendo calculado,  $I(x', y')$  denota o valor do pixel vizinho. O módulo da diferença ( $|I(x, y) - I(x', y')|$ ) calcula o custo de um pixel para outro; já a média dos valores ( $\frac{I(x, y) + I(x', y')}{2}$ ) determina a intensidade média na qual essa transição ocorre.

A Figura 7 ilustra a criação dos pesos do grafo para um trecho de uma imagem. Cada pixel é associado com um vértice, cujo valor é a intensidade do pixel e o peso da aresta é definido pela Equação 2.5.




Figura 7 – Exemplo de um grafo criado para um fragmento de uma imagem de textura.

O cálculo da média da Equação 2.5 tem como objetivo distinguir classes de textura que apresentam padrões similares, mas possuem intensidades médias de nível de cinza diferentes (SÁ, 2013). Para ilustrar a importância da média, a Figura 8 apresenta os quatro diferentes caminhos mínimos em um gráfico de três dimensões. A relevância da média na Equação 2.5 é a capacidade de caracterizar picos e vales.




Figura 8 – Ilustração do relevo no percurso do caminho mínimo (SÁ, 2013).

### 2.3.3.1 Extração das características

A partir do grafo criado, são traçados quatro caminhos mínimos entre diferentes vértices definidos no grafo, sendo a primeira etapa para a criação do vetor de características. Os vértices escolhidos podem ser vistos na Figura 9, sendo eles: diagonais (caminho 45° e caminho 135°), horizontal (caminho 0°) e vertical (caminho 90°). Cada caminho mínimo é encontrado usando o algoritmo de Dijkstra.




Figura 9 – Quatro diferentes caminhos(0°, 45°, 90° e 135°).

Para fornecimento de informações locais da textura, a textura original é dividida em janelas de tamanho  $l \times l$ , de tal maneira que o tamanho da imagem seja divisível por  $l$ , ou seja, o resto da divisão seja igual a zero. Portanto, para cada janela, são encontrados os caminhos mais curtos nas quatro orientações. Vale ressaltar que as janelas não se sobrepõem, exceto quando o valor  $l$  não é divisor das dimensões da imagem.

Para caracterizar o padrão da textura, para cada janela  $l \times l$ , são computados a média ( $\vec{\alpha}_l$ ) e o desvio-padrão ( $\vec{\beta}_l$ ) de todos os caminhos em um mesmo ângulo (0°, 45°, 90°



ou  $135^\circ$ ) para compor os seguintes vetores,  $\vec{\alpha}_l$  e  $\vec{\beta}_l$ , onde

$$\vec{\alpha}_l = [\mu_{0^\circ}, \mu_{45^\circ}, \mu_{90^\circ}, \mu_{135^\circ}] \quad (2.6)$$

e

$$\vec{\beta}_l = [\sigma_{0^\circ}, \sigma_{45^\circ}, \sigma_{90^\circ}, \sigma_{135^\circ}], \quad (2.7)$$

em que  $\mu_{d^\circ}$  e  $\sigma_{d^\circ}$  representam, respectivamente, a média e o desvio-padrão de todos os caminhos em uma mesma direção. Os dois vetores são concatenados, gerando um vetor  $\vec{\psi}_l$ , definido como

$$\vec{\psi}_l = [\vec{\alpha}_l, \vec{\beta}_l]. \quad (2.8)$$

Para garantir a análise das texturas em diferentes tamanhos de janelas, como mostra a Figura 10, são concatenados vetores com diferentes valores de janela  $l$ , demonstrado pelas equações

$$v_{l_1, l_2, \dots, l_n} = [\vec{\alpha}_{l_1}, \vec{\alpha}_{l_2}, \dots, \vec{\alpha}_{l_n}]; \quad (2.9)$$

$$\omega_{l_1, l_2, \dots, l_n} = [\vec{\beta}_{l_1}, \vec{\beta}_{l_2}, \dots, \vec{\beta}_{l_n}]; \quad (2.10)$$

$$\varphi_{l_1, l_2, \dots, l_n} = [\vec{\psi}_{l_1}, \vec{\psi}_{l_2}, \dots, \vec{\psi}_{l_n}]. \quad (2.11)$$

Portanto, a finalidade do uso de diferentes escalas é a obtenção de mais informações sobre as imagens. A Figura 10 mostra a visão geral da criação dos vetores de características para uma textura, onde, para diferentes tamanhos de janelas, é gerado um único vetor.

Para esclarecer o processo do método CMG, a Figura 11 apresenta um exemplo com as etapas do método para uma imagem com subdivisão de 4 subgrafos.

## 2.4 Classificação

Em problemas de classificação automática de padrões por aprendizagem supervisionada, a classificação tem o objetivo de atribuir uma classe a um delimitado padrão. Caso o conjunto de classes seja constituído por dois elementos, então o problema é denominado binário (FACELI; GAMA; CARVALHO, 2011).

De uma forma geral, o objetivo da classificação é encontrar uma forma de separar duas ou mais classes e, dado um novo exemplo, conseguir identificá-lo com a respectiva região à qual ele pertence.

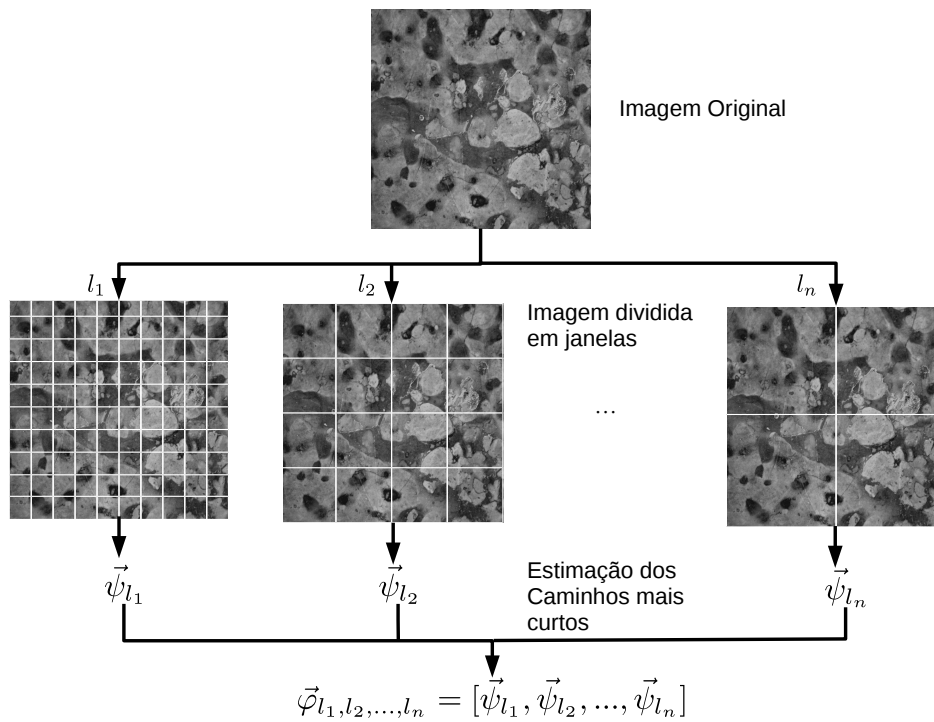


Figura 10 – Visão geral da obtenção dos vetores de características (SÁ, 2013).

Os métodos de classificação podem ser divididos em dois grupos, daqueles que geram superfície de decisão lineares e daqueles que geram superfície de decisão não lineares.

Nos métodos lineares, os algoritmos supõem que as classes podem ser separadas por um hiperplano. A Figura 12 exemplifica um conjunto de dados separados em duas classes linearmente. A reta na figura ilustra a separação entre as duas regiões da classe 1 e classe 2, onde  $X_1$  e  $X_2$  representam alguma característica definida das classes.

Já nos métodos não lineares, as classes não podem ser separadas linearmente. Para ilustrar a classificação não linear, a Figura 13 apresenta um exemplo dessa classificação de duas classes. O círculo na figura mostra a separação não linear entre a classe 1 e classe 2.

#### 2.4.1 Análise linear discriminante

A análise linear discriminante (*Linear Discriminant Analysis*, LDA) (FUKUNAGA, 1990) (HAIR et al., 1998) é uma técnica estatística multivariada empregada para a separação de um determinado conjunto de amostras por meio de combinações lineares de seus atributos (treinamento), e para atribuir novos exemplos para uma das classes definidas previamente (teste) (SÁ; BACKES; CORTEZ, 2013).

O objetivo do LDA é a identificação das variáveis que discriminam os grupos e, assim, elaborar previsões a respeito de uma nova observação, identificando o grupo mais adequado a que ela deverá pertencer, em função de suas características (FÁVERO et al., 2009). O LDA baseia-se na determinação de funções discriminantes lineares (combinações

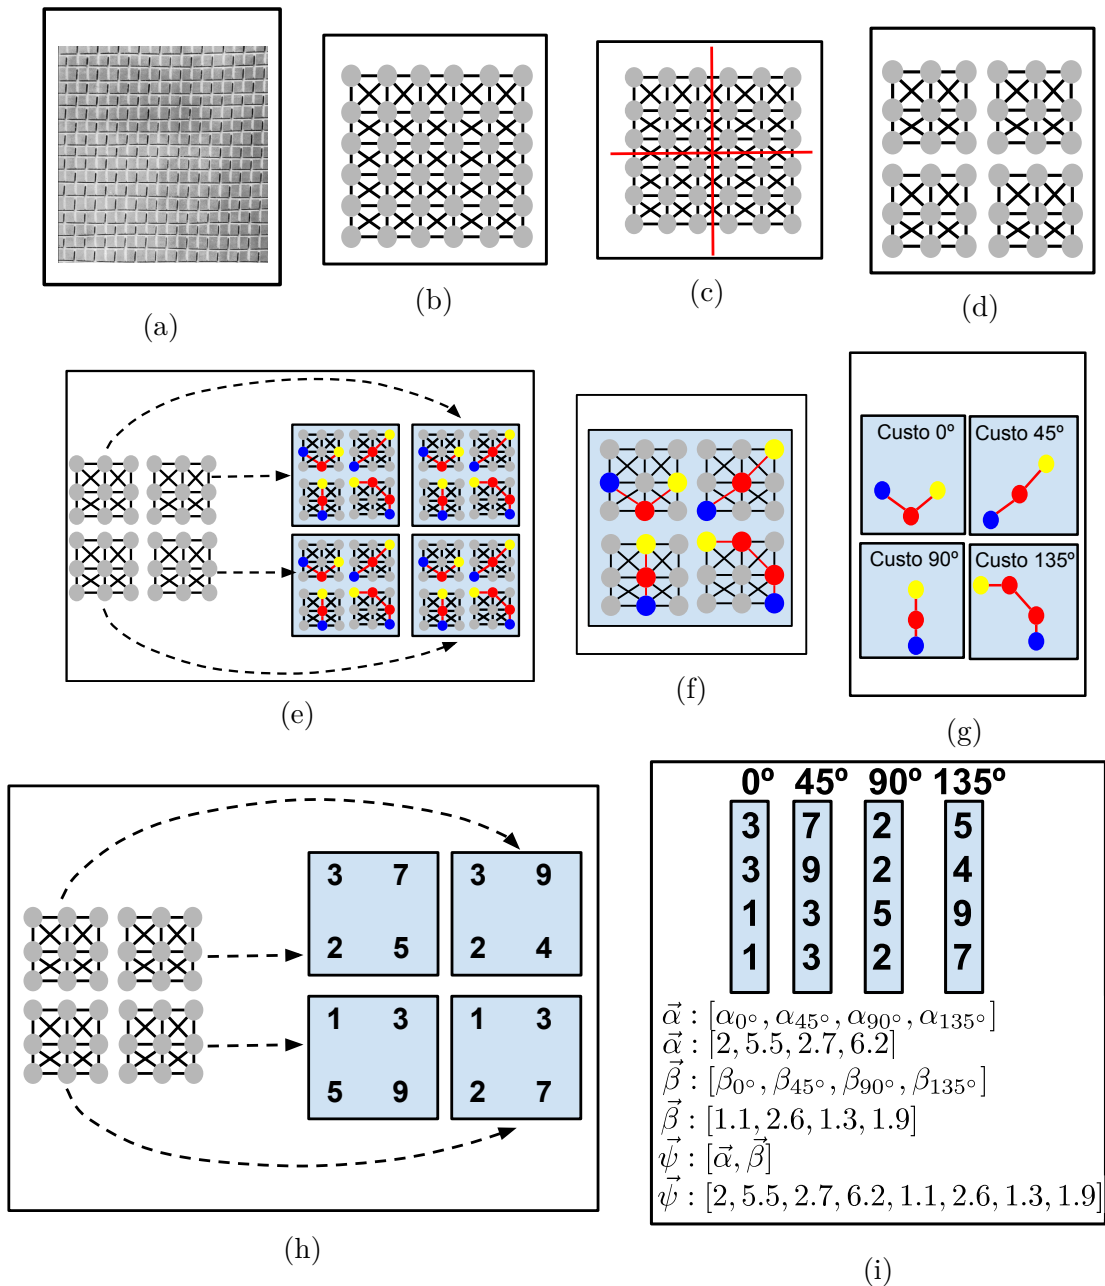


Figura 11 – Exemplo com as etapas do método CMG. (a) Representa a imagem de entrada para o método. A imagem deve ser em tons de cinza. (b) Criação do grafo para a imagem de entrada, seguindo a Equação 2.5 para a criação dos pesos das arestas do grafo. (c) e (d) Subdivisão do grafo. No exemplo, em quatro subgrafos. (e) e (f) Calculam, para cada subgrafo, os caminhos nos quatro diferentes ângulos (0°, 45°, 90° e 135°) usando o Algoritmo 1. (g) Para cada subgrafo são extraídos os custos de cada caminho. (h) Exemplos de custos extraídos de cada um dos quatro subgrafos. (i) Nesta etapa é calculado as médias para cada ângulo ( $\alpha_{0^\circ}$ ,  $\alpha_{45^\circ}$ ,  $\alpha_{90^\circ}$  e  $\alpha_{135^\circ}$ ), os desvios padrões ( $\beta_{0^\circ}$ ,  $\beta_{45^\circ}$ ,  $\beta_{90^\circ}$  e  $\beta_{135^\circ}$ ) e o vetor de concatenação das médias e desvios padrões ( $\vec{\psi}$ ). Note que  $\vec{\psi}$  é o vetor de características extraído da imagem.

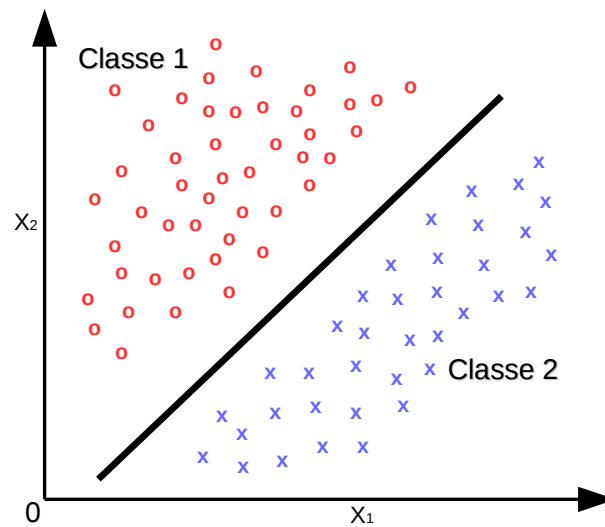


Figura 12 – Exemplo gráfico da superfície de decisão gerada por um método linear.




Figura 13 – Exemplo gráfico da superfície de decisão gerada por um método não linear.

lineares das variáveis), as quais maximizam a variância entre classes e minimizam a razão da variância dentro de cada classe (PONTES, 2009). As classes são ditas seguir uma distribuição normal multivariada e ser linearmente separada (DINIZ, 2013).

Assim, o LDA cria uma projeção dos dados em um subespaço linear, com o objetivo de diminuir a dimensionalidade do problema (SHI; HU, 2012). A projeção tem o objetivo de tornar a variância entre as classes máxima e a variância entre os dados de uma mesma classe mínima. O critério de classificação é designar uma amostra para a classe com a mais alta probabilidade posteriori. Esse critério é conhecido como regra de Bayes, a qual designa uma amostra representada por  $x$  para a classe  $i$  (SÁ; BACKES; CORTEZ, 2013), representado pela equação

$$P(i|x) > P(j|x), \forall j \neq i. \quad (2.12)$$

O objetivo é calcular a probabilidade de um padrão pertencer à classe  $i$ -ésima classe, dado um conjunto de observações  $x$ .

Como  $P(i|x)$  é difícil de ser obtida, dado que é conhecida a  $P(x|i)$  (probabilidade de obter um conjunto particular de observações  $x$ , dado que a amostra pertence à classe  $i$  (SÁ; BACKES; CORTEZ, 2013)), então, pelo teorema de Bayes, é possível calcular  $P(i|x)$ , onde

$$P(i|x) = \frac{P(x|i)P(i)}{\sum_{\forall j} P(x|j)P(j)}, \quad (2.13)$$

no qual o valor a priori  $P(i)$  é uma probabilidade associada à classe  $i$ -ésima classe. É comum a suposição de que a probabilidade a priori é a igual para todas as classes. O cálculo de  $P(x|i)$  apresenta dificuldades pois precisa de um grande número de amostras (FUKUNAGA, 1990).

Assim, geralmente, é comum supor que as classes possuem uma distribuição gaussiana multivariada e suas classes têm a mesma matriz de covariância. E assim, com essas restrições, a equação do classificador LDA é dada por

$$f_i = \mu_i \zeta^{-1} x_k^T - \frac{1}{2} \mu_i \zeta^{-1} \mu_i^T + \log(P(i)), \quad (2.14)$$

sendo  $\zeta$  a matriz de covariância do conjunto de dados e  $\mu_i$  a média dos atributos das amostras de uma determinada classe  $i$ . Cada amostra representada por  $x_k$  é atribuída à classe  $i$  que provê o mais alto valor de  $f_i$ . Observe que  $\mu_i \zeta^{-1} \mu_i^T$  é a distância de Mahalanobis (MAHALANOBIS, 1936).

Uma desvantagem da LDA em relação aos outros métodos de Reconhecimento de Padrões é que a mesma é apropriada apenas para conjuntos de dados de pequenas dimensões. Além disso, a capacidade de generalização de modelos LDA pode ser comprometida por problemas de colinearidade (NÆS; MEVIK, 2001).

## 2.4.2 Perceptron de multicamadas

A rede Perceptron de Multicamadas (*Multilayer Perceptron*, MLP) é uma Rede Neural Artificial (RNA) bastante utilizada para encontrar a solução de problemas difíceis em reconhecimento de padrões (HAYKIN, 1998). Também, a rede MLP pode aproximar qualquer função contínua com uma precisão pré-estabelecida (CHERKASSKY; MULIER, 2007).

Pode-se dizer que uma rede neural é uma máquina com a capacidade de modelar a maneira que o cérebro realiza uma específica tarefa ou função. RNAs usam células que possuem um funcionamento simples, altamente interconectadas que trabalham em paralelo, chamadas de neurônios (HAYKIN, 1998).

Assim, como em outros algoritmos de aprendizado de máquina, na RNA o conhecimento é adquirido através do processo de “aprendizagem”, que consiste nos ajustes dos pesos da rede para que esta atinja o objetivo especificado. Este processo é chamado de treinamento (OLIVEIRA, 2001).

As redes neurais feedforward são redes em que os neurônios são organizados em camadas. Os valores de entrada são capturados pelos neurônios da camada de entrada fornecendo uma resposta na camada de saída, podendo existir camadas intermediárias (ocultas). O fluxo da resposta de cada neurônio só ocorre em um único sentido de entrada-saída. Todas as saídas dos neurônios de uma camada são conectadas com todos os neurônios da camada posterior, em uma rede completamente conectada. A Figura 14 representa uma rede feedforward com quatro camadas com os neurônios totalmente conectados (OLIVEIRA, 2001).

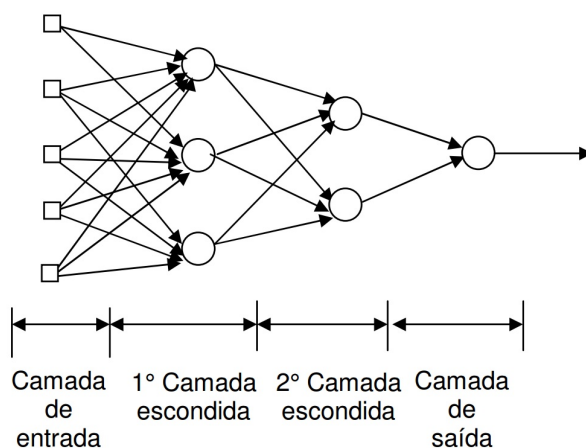


Figura 14 – Exemplo de rede neural com multiplas camadas (OLIVEIRA, 2001).

#### 2.4.2.1 Backpropagation

Uma rede MLP é formada por uma camada de saída que possui neurônios lineares ou não-lineares e uma ou mais camadas intermediárias compostas por neurônios somadores com função de ativação não-linear (ARBIB, 2002). O sinal se propaga sempre para a frente, camada por camada. A rede MLP tem sido aplicada a problemas através de seu treinamento de forma supervisionada com o algoritmo de retropropagação do erro (*backpropagation*). O algoritmo é baseado na regra de correção de erro, que ajusta os pesos dos neurônios de acordo com o erro (NETO, 2014).

A MLP é uma rede supervisionada, ou seja, os pesos de cada camada são reajustados de acordo com o valor da saída da rede comparada com o valor real da saída (ARBIB, 2002). Assim, o treinamento, geralmente, é dividido em duas etapas, uma chamada de sentido direto na qual o trânsito de informações flui da entrada até a saída, gerando o valor de saída da rede. Na segunda etapa, chamada de sentido inverso, é utilizado o valor

do erro gerado no sentido direto, e este é retropropagado para as camadas intermediárias para ajustar os pesos destas (BISHOP, 2006; WIDROW; WINTER, 1988).

A primeira fase envolve o cálculo dos dados das ativações e saídas de todos os neurônios, desde a entrada passando pela camada oculta, até a saída (NETO, 2014). Para calcular a saída dos neurônios da camada oculta é necessário calcular a ativação da saída dos neurônios da camada oculta (HAYKIN, 2008).

Na etapa seguinte ocorre a sequência inversa dos dados, calculando a última camada e o erro é retropropagado para as camadas ocultas. O cálculo do erro na camada oculta é feito através da propagação do erro vindo da camada de saída, onde é propagado através do gradiente local do neurônio (NETO, 2014).

## 2.5 Métodos para análise de classificação

Os métodos para a análise de classificação têm a finalidade de especificar o critério de escolha dos dados e avaliar o resultado obtido. A seguir seguem os métodos usados neste trabalho.

### 2.5.1 Validação cruzada

A técnica de validação cruzada tem o objetivo de avaliar a capacidade de generalização de um determinado modelo. Consiste em particionar aleatoriamente os dados em dois conjuntos, um para treinamento e o outro para teste (KOHAVI, 1995). A partição de treinamento é empregada para ajustar os parâmetros de um modelo (classificador). O conjunto de teste é usado para estimar o erro de validação. O objetivo é obter o menor erro de generalização. Para tanto, o classificador é treinado até atingir o erro mínimo de validação. Geralmente, o conjunto de teste não deve incluir dados usados na fase de treinamento (DUDA; HART; STORK, 2000).

### 2.5.2 Teste de hipótese

O teste de Kolmogorov-Smirnov (MASSEY FRANK J., 1951) é um teste de aderência. Geralmente é utilizado quando existe a necessidade de avaliar se uma distribuição de valores que compõem uma amostra pode ser considerada como proveniente de uma população com uma distribuição teórica especificada (SIEGEL; CASTELLAN, 2008). Isto é, avalia o grau de concordância entre a distribuição de um conjunto de valores amostrais (valores observados) e determinada distribuição teórica específica (BRANDÃO, 2012).

Para realizar o teste, o método utiliza as funções de distribuições acumuladas das duas funções, determinando o ponto em que elas mais se diferenciam e assim decidindo se o ponto em questão possui uma divergência significativa ou não.

Assim, considere dois exemplos,  $x_1, \dots, x_n$ , associado com uma função de distribuição desconhecida  $F(x)$ . O outro exemplo  $y_1, \dots, y_n$ , associado com uma função de distribuição desconhecida  $G(x)$ .

A hipótese nula  $h_0$  e a alternativa  $h_a$  são definidas como

$$H_0 : F(x) = G(x) \quad (2.15)$$

e

$$H_a : F(x) \neq G(x), \quad (2.16)$$

em que  $H_0$  indica que as funções de distribuição  $F(x)$  e  $G(x)$  são significativamente equivalentes e  $H_a$  informa que as distribuições não são significativamente equivalentes.

Assim,  $\hat{F}(x)$  sendo a função de distribuição acumulada (FDA) para os exemplos  $x_1, \dots, x_n$  e  $\hat{G}(x)$  a FDA para os exemplos  $y_1, \dots, y_m$ , com  $m = n$ , resulta

$$\hat{F}(x) = \frac{1}{n} \sum_{i=1}^n \begin{cases} 1, & \text{se } F(x_i) \leq x \\ 0, & \text{caso contrário} \end{cases}, \quad (2.17)$$

e

$$\hat{G}(x) = \frac{1}{n} \sum_{i=1}^n \begin{cases} 1, & \text{se } G(x_i) \leq x \\ 0, & \text{caso contrário} \end{cases}. \quad (2.18)$$

O teste estatístico,  $D$ , é calculado pela máxima diferença entre as duas FDAs,  $\hat{F}(x)$  e  $\hat{G}(x)$ , apresentado pela equação

$$D = \max_x (|\hat{F}(x) - \hat{G}(x)|). \quad (2.19)$$

Portanto, caso a estatística  $D$  seja maior que um determinado valor crítico ( $D_{\text{crítico}}$ ) é rejeitado a hipótese nula  $H_0$ . A Tabela 1 mostra valores críticos para diferentes tamanhos de amostras e níveis de significância.

Um ponto positivo do teste de Kolmogorov-Smirnov em relação a outros testes é que ele pode ser utilizado sem depender de um número definido de observações para que seja considerado válido (WETZEL; TOMEI, 2002).



Tamanho da amostra	Nível de significância ( $D_{crítico}$ )				
	0.1	0.05	0.025	0.01	0.005
4	0.4927	0.5652	0.6239	0.6889	0.7342
8	0.3583	0.4096	0.4543	0.5065	0.5418
12	0.2958	0.3382	0.3754	0.4192	0.4490
16	0.2578	0.2947	0.3273	0.3657	0.3920
20	0.2316	0.2647	0.2941	0.3287	0.3524
24	0.2120	0.2424	0.2693	0.3010	0.3229
28	0.1968	0.2250	0.2499	0.2794	0.2997
32	0.1844	0.2108	0.2342	0.2619	0.2809
36	0.1742	0.1991	0.2212	0.2473	0.2653
40	0.1655	0.1891	0.2101	0.2349	0.2521
Acima de 40	$\frac{1.07}{\sqrt{n}}$	$\frac{1.22}{\sqrt{n}}$	$\frac{1.36}{\sqrt{n}}$	$\frac{1.52}{\sqrt{n}}$	$\frac{1.63}{\sqrt{n}}$

Tabela 1 –  $D_{crítico}$  do Teste de Kolmogorov-Smirnov (SIEGEL; CASTELLAN, 2008).

## 3 Método proposto

Este capítulo aborda o funcionamento do método proposto nesta dissertação. A Seção 3.1 apresenta a descrição geral do método. O Tópico 3.1.1 mostra como é realizada a extração de características.

### 3.1 Descrição

Baseado no trabalho de (SÁ, 2013), que define a extração de características pelo CMG, o qual cria um grafo representando uma textura e, a partir disto, são extraídas informações relevantes, este trabalho propõe uma variação no método CMG através da adição de uma heurística na busca do caminho.

O principal objetivo da heurística na busca é a diminuição da quantidade de estados que são percorridos na busca do caminho, visando a redução do custo computacional.

Portanto, o presente método dispõe das mesmas etapas do CMG, diferenciando na extração das características, especificamente na busca do caminho mínimo.

#### 3.1.1 Extração das características

No CMG, a extração de características é efetuada através de caminhos mínimos em grafos. Neste trabalho é realizado uma busca direcionada ao objetivo com a adição de uma heurística.

Assim, como apresentado pelo Algoritmo de Dijkstra 1, o objetivo é adicionar uma heurística  $h$  na etapa de escolha do próximo vértice que será visitado ( $custo(b) + custo(b, a) < custo(a)$ ). A heurística  $h$  proposta é a distância euclidiana do vértice  $v$  até o objetivo multiplicado por um parâmetro  $C$ , conforme a equação

$$h(v) = C \left[ (x - x^*)^2 + (y - y^*)^2 \right]^{\frac{1}{2}}, \quad (3.1)$$

em que  $C$  é um parâmetro para aumentar a importância da heurística  $h$  na escolha do próximo vértice,  $x$  e  $y$  são as coordenadas do vértice  $v$  e  $x^*$  e  $y^*$  são coordenadas do vértice destino.

Valores elevados de  $C$  indicam que a distância entre origem e destino é a distância euclidiana e valores baixos de  $C$  indicam que a heurística  $h$  tem pouca, ou nenhuma, influência na escolha do próximo vértice.

Assim, o Algoritmo 2 apresenta o método proposto para realizar a busca, com a heurística  $h$  adicionada. A diferença entre o algoritmo de Dijkstra e o proposto encontra-se na heurística para realizar a busca da origem até o destino.

---

**Algoritmo 2** Algoritmo Proposto.

---

**ENTRADA:**

$G$  : Grafo ponderado.

$o$  : Vértice origem.

$d$  : Vértice destino.

**SAÍDA:**

$custo(d)$  : Custo do menor caminho entre os vértices  $o$  e  $d$ .

```

1: para todo  $v \in V(G)$  faça
2:    $custo(v) \leftarrow \infty$ 
3: fim para
4:  $custo(o) \leftarrow 0$ 
5:  $Antecessor(o) \leftarrow 0$ 
6: enquanto existe Vértice não visitado faça
7:    $b \leftarrow$  vértice não visitado com menor custo.
8:   marca  $b$  como visitado.
9:   para cada  $a \in adjacente(b)$  faça
10:    se  $custo(b) + custo(b, a) + h(a) < custo(a)$  então
11:       $custo(a) = custo(b) + custo(b, a) + h(a)$ 
12:       $Antecessor(a) = b$ 
13:    fim se
14:  fim para
15: fim enquanto

```

---

Para melhor esclarecer, a Figura 15 apresenta um exemplo do cálculo dos valores de  $custo(b)$ ,  $custo(b, a)$ ,  $h(a)$  e  $custo(a)$ , para o Algoritmo 2.

### 3.1.2 Impacto da escolha do parâmetro $C$

O parâmetro  $C$  utilizado neste trabalho tem a finalidade de direcionar a busca ao destino. O intuito do parâmetro é prover uma direção para caminho.

A Figura 16 ilustra modificações no caminho ao se aumentar o valor de  $C$ . Pode ser observado, que quanto mais elevado o valor de  $C$ , maior é a tendência do caminho entre origem e destino se tornar a distância euclidiana.

Além disto, a importância do parâmetro  $C$  também pode ser visualizada pela Figura 17, que mostra o efeito da variação de  $C$  no processo de busca. Cada linha na figura apresenta um diferente valor de  $C$  enquanto a coluna apresenta o progresso da busca. Os pixels em vermelho indicam que o pixel foi visitado durante a busca. Assim, o algoritmo de Dijkstra ( $C = 0$ ) visita todos os pixels da imagem na busca do caminho mínimo. No entanto, quando  $C = 350$  resulta em uma busca mais direcionada ao objetivo e visitam-se

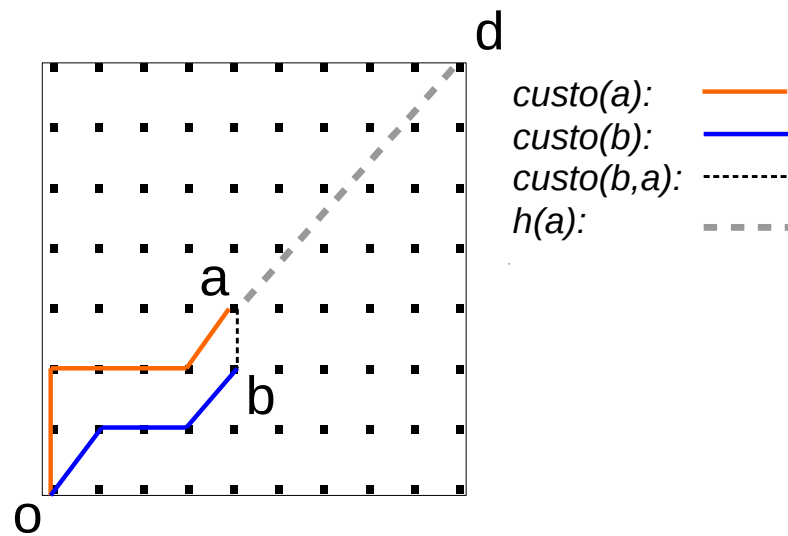


Figura 15 – Exemplo de um trecho de caminho percorrido com heurística.




Figura 16 – Influência do parâmetro  $C$  no caminho de uma imagem.

menos nós. Vale destacar que valores elevados de  $C$  não resultam em uma solução ótima (não encontram o caminho mínimo), mas não há uma garantia teórica que indique que o menor caminho é a melhor solução.

Assim, como já mencionado, não existe nenhuma garantia que o caminho mínimo seja o melhor caminho a ser adotado para a extração de informações da textura em uma imagem. No trabalho de SÁ, BACKES e CORTEZ (2013) não é apresentada uma justificativa para a escolha do caminho mínimo em que ela seja a melhor opção, outros

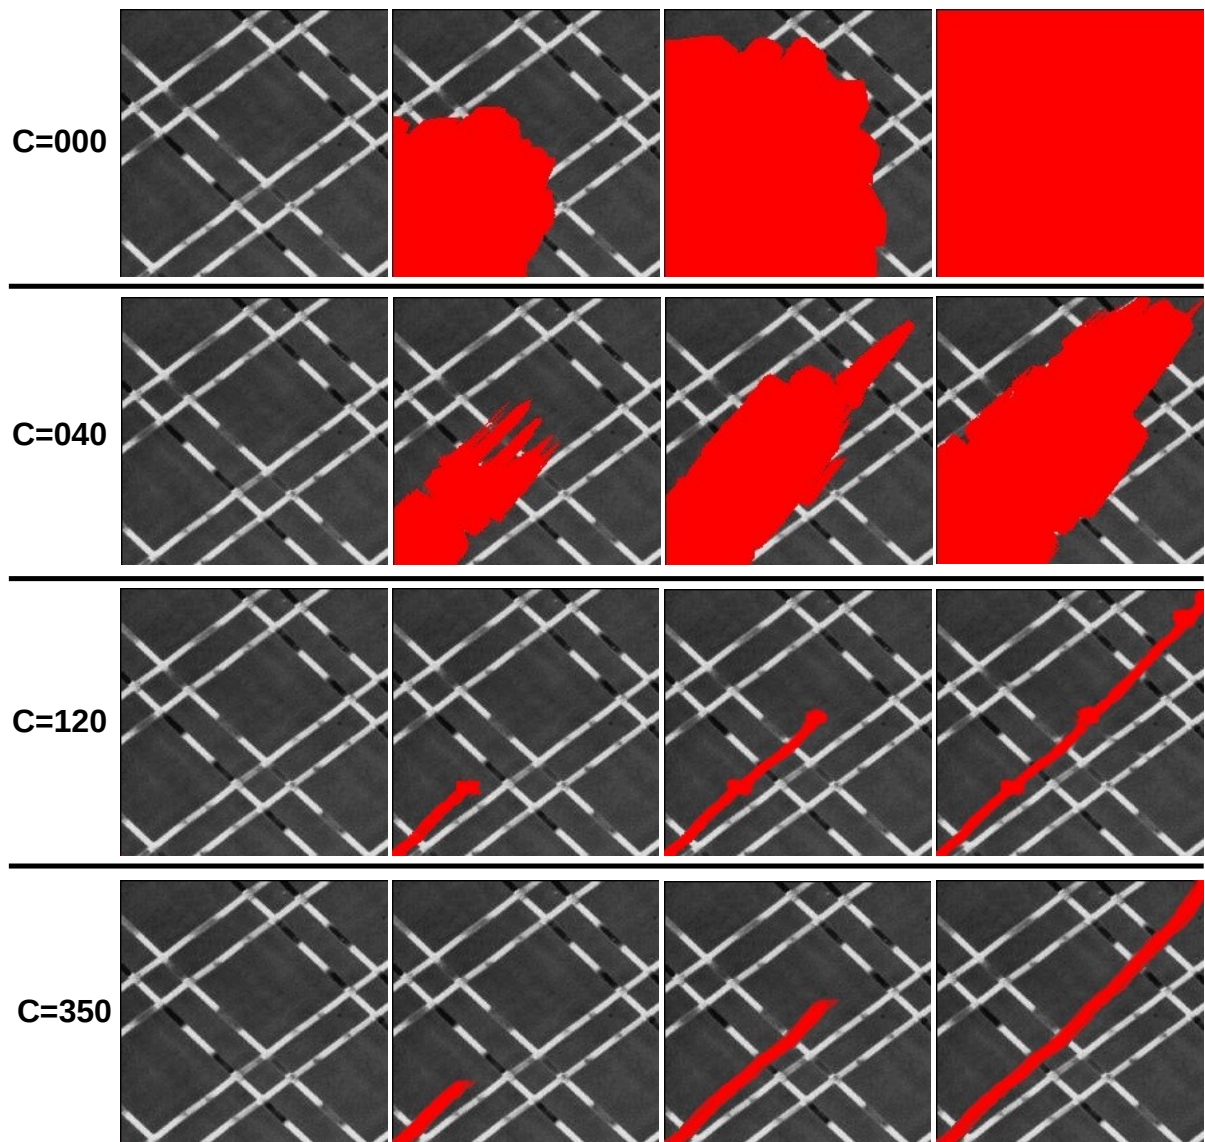


Figura 17 – Estados visitados para diferentes valores de  $C$ . As colunas da esquerda para direita indicam pontos intermediários dos estados que foram visitados. Os pixels vermelhos são os estados que foram visitados na imagem.

caminhos também trazem relevância na extração de características. Portanto, a heurística da Equação 3.1, utilizada neste trabalho, tem por finalidade direcionar e modificar o caminho. Note que o caminho resultante possivelmente não será o caminho mínimo.

### 3.1.3 Escolha automática do parâmetro $C$

Como o parâmetro  $C$  utilizado nessa dissertação tem grande importância no caminho percorrido, a escolha desse parâmetro deve ser tomada de forma eficiente.

Conforme abordado anteriormente, valores elevados do parâmetro  $C$  fazem com que todos os caminhos sejam a distância euclidiana entre a origem e o destino, como ilustra a Figura 16d.

Para evitar a escolha inapropriada de um valor de  $C$ , é utilizado o teste de hipótese two-sample Kolmogorov-Smirnov test (KS-Test)(MASSEY FRANK J., 1951). Esse teste é normalmente usado para determinar se duas distribuições de probabilidade diferem uma da outra. Assim, deseja-se escolher um valor de  $C$  que reduza o número de estados visitados sem reduzir a taxa de classificação do método proposto.

Por fim, a Figura 18 apresenta o fluxograma para escolha do parâmetro  $C$ . No fluxograma,  $\mathbf{R}$  representa o vetor com as taxas de classificação para o método CMG e  $\mathbf{P}$  o vetor com as taxas de acertos para o método proposto para o parâmetro  $C$ . Note que a taxa de classificação é definida para todo o banco de imagens. Também, o parâmetro  $C$  é somente calculado uma única vez para o banco de imagens.

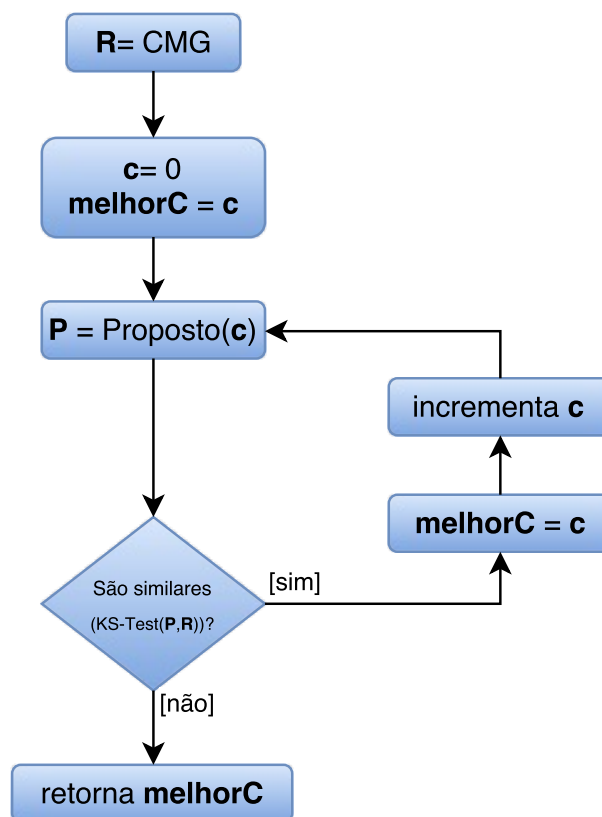


Figura 18 – Fluxograma para escolha automática do parâmetro  $C$ .

## 4 Experimentos e Resultados

Este capítulo aborda os resultados obtidos pelo método proposto, apresentado no Capítulo 3. Descreve também as bases de imagens utilizadas e detalha os experimentos realizados.

### 4.1 Conjuntos de imagens

Para esta dissertação, são empregadas quatro bases de imagens (Brodatz, UIUC, Virus e 2D HeLa) que são detalhados nos próximos tópicos.

#### 4.1.1 Texturas de Brodatz

Brodatz é um banco de imagens que possui 1.110 imagens extraídas do álbum de Brodatz (1966). Esse conjunto de imagens é geralmente empregado como benchmark na literatura sobre visão computacional e processamento de imagens para avaliação de métodos de análise de textura (SÁ, 2013). A Figura 19 mostra alguns exemplos de texturas desse banco de imagens.




Figura 19 – Exemplos de texturas de Brodatz.

Para os experimentos é usado um subconjunto de 40 classes, com 10 amostras de imagens de tamanho definido por 200 pixels de largura por 200 de altura, em tons de cinza

(256 níveis). Para a criação das amostras, é extraída uma subamostra aleatoriamente a partir da imagem original de tamanho 640 x 420.

As classes utilizadas para a extração das amostras são: D4, D5, D7, D12, D13, D15, D16, D31, D32, D33, D37, D40, D47, D49, D50, D51, D63, D71, D73, D83, D84, D85, D88, D89, D90, D92, D93, D94, D95, D96, D98, D99, D100, D103, D104, D105, D106, D108, D111 e D112.

#### 4.1.2 Texturas UIUC

Essa base de imagens, apresentada por Lazebnik, Schmid e Ponce (2005), consiste em 1.000 imagens de textura com 25 classes, cada uma com 40 amostras.

As imagens foram adquiridas por uma câmera localizada em posições diferentes e apresentando mudanças de escala, distorções de perspectiva e transformações não-rígidas (SÁ, 2013). A Figura 20 ilustra algumas amostras de texturas.




Figura 20 – Exemplos de texturas UIUC

Para padronizar os experimentos com a base Brodatz e reduzir o custo computacional, é extraída uma janela de tamanho 200 x 200 pixes do canto superior esquerdo de cada imagem original, que possui 640 x 480 pixels.

#### 4.1.3 Texturas Virus

O banco de imagens Virus tem um total de 1.500 imagens com resolução de 41x41 pixels. O banco tem 15 classes com 100 imagens por classe. As imagens foram geradas por



um microscópio eletrônico de transmissão; o banco de imagens foi inicialmente usado por Kylberg, Uppström e Sintorn (2011). A Figura 21 mostra alguns exemplos do banco de texturas.




Figura 21 – Exemplos de texturas de Virus.

Os testes realizados extraem uma janela de tamanho 40x40 pixels do canto superior esquerdo de cada imagem original, que possui 41x41 pixels.

#### 4.1.4 Texturas 2D HeLa

2D HeLa é um banco de imagens microscópicas fluorescente de células HeLa (BOLAND; MURPHY, 2001). Consiste em um conjunto de 10 classes, com quantidade de imagens por classe variando de 73 a 98. Para exemplificar, a Figura 22 ilustra alguns exemplos de imagens.




Figura 22 – Exemplos de texturas de 2D HeLa.

Para os experimentos, cada imagem é redimensionada da resolução de 512x512 pixels para 200x200 pixels, com a finalidade de manter as mesmas janelas usadas nos bancos Brodatz e UIUC.

## 4.2 Parâmetros empregados

Para a classificação, o particionamento dos bancos de imagens empregados neste trabalho foram de 70% para treinamento e 30% para teste de forma aleatória e sem interseção entre os conjuntos.

O valor  $r_d = 1$  é adotado para a Equação 2.4, que considera apenas os pixels vizinhos imediatos da imagem para a criação do grafo. Os tamanhos das janelas  $l$  são escolhidos para que elas sejam divisoras do tamanho da imagem original. Também são empregados duas configurações do grau médio do grafo, abordadas a seguir.

Na criação do grafo são considerados dois tipos de configurações de grau médio, ilustrados na Figura 23. A primeira configuração com grau médio 8, e a segunda, com redução do grau médio de 8 para 4, onde cada vértice do grafo possui 4 vizinhos, horizontais e verticais. Vale ressaltar que na região de borda da imagem o grau dos vértices é inferior ao grau médio do grafo. O intuito da utilização da redução do grau médio (grau médio 4) é a diminuição do espaço de busca para encontrar os caminhos no grafo e assim obter uma redução no custo computacional do método. Note que o método CMG, em sua publicação original, usa grau médio 8.




Figura 23 – Exemplos de grafos com diferentes graus médios.

No teste de hipótese, é usado o teste de kolmogorov-Smirnov com nível de significância de 5%. O parâmetro  $C$  é escolhido como o máximo valor válido do teste de hipótese entre o CMG e o método proposto.

Para o MLP, é usada uma camada oculta com o número de neurônios definidos como

$$N_e = \frac{N_a + N_c}{2}, \quad (4.1)$$

em que  $N_e$  é o número de neurônios na camada oculta,  $N_a$  o número de atributos e  $N_c$  a quantidade de classes.

## 4.3 Resultados com LDA

Todos os resultados apresentados nesta dissertação fazem um comparativo com o método CMG.

Os experimentos que comparam as quantidades de estados visitados consideram os vértices para todo o banco de imagens. Ou seja, se o banco de imagens possui 1.000 imagens, os vértices visitados referem-se a todos os vértices percorridos pelo método para as 1.000 imagens.

Também são usados dois classificadores para comparar os resultados obtidos, um classificador linear (LDA) e um não-linear (MLP).

Vale ressaltar que são analisadas duas variações de graus médios, 8 e 4.

### 4.3.1 Resultados para as texturas Brodatz

Os resultados obtidos pelo método proposto comparado com o CMG para diferentes tamanhos de janelas são mostrados nas tabelas 2 (grau médio 8) e 3 (grau médio 4). Pelas tabelas, evidencia-se que os resultados são similares em suas taxas de acerto, mostrando que a redução do grau médio, para o banco Brodatz, não afeta significativamente o resultado. Em ambas as tabelas, o aumento da quantidade de janelas implica na tendência do crescimento da porcentagem de acertos. Quanto maior o número de janelas, melhor o método consegue obter informações locais das regiões da imagem. O parâmetro  $C$  nas tabelas representa o parâmetro encontrado de forma automática através do teste de hipótese. As tabelas apresentam também a redução de estados visitados do método proposto. Pode ser notado que o aumento do conjunto de janelas  $\{l_1, l_2, \dots, l_n\}$  proporciona a redução de estados visitados pelo método proposto.

Tabela 2 – Comparativo de resultados CMG e método proposto (Brodatz) com grau 8 usando o classificador LDA.

Conjuntos de tamanhos de janelas $\{l_1, l_2, \dots, l_n\}$	Acertos CMG	Acertos método proposto	C	Redução de Estados
{4, 5}	0,9333 $\pm$ 0,0264	0,9388 $\pm$ 0,0172	445	0,7367
{4, 5, 8}	0,9562 $\pm$ 0,0162	0,9421 $\pm$ 0,0178	445	0,7789
{4, 5, 8, 10}	0,9558 $\pm$ 0,0130	0,9412 $\pm$ 0,0192	375	0,8073
{4, 5, 8, 10, 20}	0,9575 $\pm$ 0,0175	0,9437 $\pm$ 0,0150	445	0,8358
{4, 5, 8, 10, 20, 25}	0,9604 $\pm$ 0,0166	0,9483 $\pm$ 0,0172	445	0,8521
{4, 5, 8, 10, 20, 25, 40}	0,9537 $\pm$ 0,0214	0,9429 $\pm$ 0,0203	445	0,8705
<b>{4, 5, 8, 10, 20, 25, 40, 50}</b>	0,9925 $\pm$ 0,0076	0,9796 $\pm$ 0,0131	280	0,8846
{4, 5, 8, 10, 20, 25, 40, 50, 100}	0,9912 $\pm$ 0,0074	0,9796 $\pm$ 0,0131	445	0,8971

Tabela 3 – Comparativo de resultados CMG e método proposto (Brodatz) com grau 4 usando o classificador LDA.

Conjuntos de tamanhos de janelas $\{l_1, l_2, \dots, l_n\}$	Acertos CMG	Acertos método proposto	C	Redução de Estados
{4, 5}	0,9441 $\pm$ 0,0160	0,9371 $\pm$ 0,0257	445	0,6134
{4, 5, 8}	0,9492 $\pm$ 0,0160	0,9219 $\pm$ 0,0185	445	0,6717
{4, 5, 8, 10}	0,9483 $\pm$ 0,0134	0,9412 $\pm$ 0,0163	445	0,7114
{4, 5, 8, 10, 20}	0,9533 $\pm$ 0,0201	0,9479 $\pm$ 0,0195	445	0,7532
{4, 5, 8, 10, 20, 25}	0,9575 $\pm$ 0,0129	0,9425 $\pm$ 0,0187	425	0,7741
{4, 5, 8, 10, 20, 25, 40}	0,9558 $\pm$ 0,0169	0,9492 $\pm$ 0,0143	445	0,8042
<b>{4, 5, 8, 10, 20, 25, 40, 50}</b>	0,9862 $\pm$ 0,0116	0,9779 $\pm$ 0,0133	445	0,8256
{4, 5, 8, 10, 20, 25, 40, 50, 100}	0,9808 $\pm$ 0,0127	0,9825 $\pm$ 0,0135	445	0,8442

Para melhor avaliar o método, foram escolhidas as janelas {4, 5, 8, 10, 20, 25, 40, 50} com o intuito de observar seu comportamento ao longo do crescimento do parâmetro  $C$ . Para as demais janelas da Tabela 2, o Apêndice A exibe os resultados.

Além disso, as figuras 24 e 25 apresentam as taxas de acerto com desvio padrão do método proposto (Proposto) neste trabalho comparado com o método de caminhos mínimos em grafos (CMG) para os graus médios 8 e 4, respectivamente.

Nas figuras, do início até a reta que representa o teste de hipótese (TH), os métodos são similares em seu resultado. Com o aumento do parâmetro  $C$ , a tendência do método proposto é diminuir a taxa de classificação, o que é notado em ambas as figuras. Valores de  $C$  acima do TH ocasionam uma perda no desempenho, devendo-se ao fato de que, com o aumento do parâmetro  $C$ , a distância tende a se tornar a distância euclidiana entre o ponto de origem e o ponto de destino. A diferença entre as figuras encontra-se no valor do parâmetro  $C$ . Observa-se que o valor obtido com o grau médio igual a 4 foi maior.

Nos gráficos exibidos nas figuras 26 e 27 para grau médio 8 e 4 respectivamente, apresentam-se as porcentagens de estados visitados totais do método proposto comparado com o método CMG. A reta que representa o método CMG não se altera com o aumento do parâmetro  $C$ , pois o método não depende de  $C$ . O aumento do parâmetro  $C$  gera uma redução na porcentagem dos estados totais visitados, pelo fato de que, quanto maior for o valor de  $C$ , maior será a tendência da distância se tornar a euclidiana. Por fim, o grau médio 4, proporciona uma redução inferior na quantidade de estados com o aumento do




Figura 24 – Taxa de acerto com desvio padrão em função do parâmetro  $C$  para o conjunto de imagens Brodatz com as janelas  $\{4, 5, 8, 10, 20, 25, 40, 50\}$  ao se aplicar o classificador LDA (Grau médio 8).




Figura 25 – Taxa de acerto com desvio padrão em função do parâmetro  $C$  para o conjunto de imagens Brodatz com as janelas  $\{4, 5, 8, 10, 20, 25, 40, 50\}$  ao se aplicar o classificador LDA (Grau médio 4).

parâmetro  $C$ , comparado com grau médio 8.

### 4.3.2 Resultados para as texturas UIUC

Os mesmos testes empregados anteriormente para as texturas de Brodatz são realizados para as texturas UIUC.

As Tabela 4 e 5 mostram os resultados obtidos pelo método com diferentes tamanhos de janelas, de forma análoga à base de imagens de Brodatz. Nota-se que o aumento da quantidade de janelas melhora a porcentagem de acertos e a redução de estados visitados pelo método proposto. Assim, como em Brodatz, os resultados são similares em suas taxas




Figura 26 – Porcentagem de estados visitados pelo aumento do parâmetro  $C$  (Base de imagens Brodatz), para as janelas {4, 5, 8, 10, 20, 25, 40, 50} com classificador LDA (Grau médio 8).




Figura 27 – Porcentagem de estados visitados pelo aumento do parâmetro  $C$  (Base de imagens Brodatz), para as janelas {4, 5, 8, 10, 20, 25, 40, 50} com classificador LDA (Grau médio 4).

de acerto para os dois graus médios.

Tabela 4 – Comparativo de resultados CMG e método proposto (UIUC) com grau 4 usando o classificador LDA.

Conjuntos de tamanhos de janelas $\{l_1, l_2, \dots, l_n\}$	Acertos CMG	Acertos método proposto	C	Redução de Estados
{4, 5}	0,6760 $\pm$ 0,0225	0,6538 $\pm$ 0,0263	35	0,0775
{4, 5, 8}	0,6970 $\pm$ 0,0239	0,6683 $\pm$ 0,0262	75	0,1899
{4, 5, 8, 10}	0,6970 $\pm$ 0,0262	0,6775 $\pm$ 0,0216	45	0,1081
{4, 5, 8, 10, 20}	0,6993 $\pm$ 0,0258	0,6667 $\pm$ 0,0258	100	0,3026
{4, 5, 8, 10, 20, 25}	0,6918 $\pm$ 0,0252	0,6695 $\pm$ 0,0234	125	0,3997
{4, 5, 8, 10, 20, 25, 40}	0,7035 $\pm$ 0,0250	0,6850 $\pm$ 0,0295	105	0,3336
<b>{4, 5, 8, 10, 20, 25, 40, 50}</b>	0,8393 $\pm$ 0,0162	0,8193 $\pm$ 0,0160	170	0,6213
{4, 5, 8, 10, 20, 25, 40, 50, 100}	0,8385 $\pm$ 0,0155	0,8293 $\pm$ 0,0236	150	0,5631

Tabela 5 – Comparativo de resultados CMG e método proposto (UIUC) com grau 8 usando o classificador LDA.

Conjuntos de tamanhos de janelas $\{l_1, l_2, \dots, l_n\}$	Acertos CMG	Acertos método proposto	C	Redução de Estados
{4, 5}	0,5820 $\pm$ 0,0175	0,5778 $\pm$ 0,0241	445	0,7394
{4, 5, 8}	0,6333 $\pm$ 0,0237	0,6118 $\pm$ 0,0290	445	0,7826
{4, 5, 8, 10}	0,6560 $\pm$ 0,0270	0,6342 $\pm$ 0,0255	145	0,7426
{4, 5, 8, 10, 20}	0,6918 $\pm$ 0,0207	0,6695 $\pm$ 0,0274	060	0,3400
{4, 5, 8, 10, 20, 25}	0,6831 $\pm$ 0,0308	0,6575 $\pm$ 0,0272	110	0,6605
{4, 5, 8, 10, 20, 25, 40}	0,6845 $\pm$ 0,0250	0,6593 $\pm$ 0,0272	105	0,6458
<b>{4, 5, 8, 10, 20, 25, 40, 50}</b>	0,8205 $\pm$ 0,0205	0,7947 $\pm$ 0,0295	120	0,7410
{4, 5, 8, 10, 20, 25, 40, 50, 100}	0,8146 $\pm$ 0,0202	0,7940 $\pm$ 0,0200	135	0,8164

Foram escolhidas as janelas  $\{4, 5, 8, 10, 20, 25, 40, 50\}$  com o intuito de observar seu comportamento em função do crescimento do parâmetro  $C$ . O Apêndice C mostra as demais janelas das tabelas 4 e 5.

Os gráficos apresentados nas figuras 28 e 29 exibem as taxas de acerto com desvio padrão do método proposto comparado com o CMG. Pelas figuras, com o aumento do parâmetro  $C$ , a tendência é a queda da taxa de classificação. Comparando as figuras, para o grau médio 4, existe a diminuição na taxa de acerto do método CMG.

Por fim, as figuras 30 e 31 mostram a porcentagem de estados visitados totais do método proposto comparado com CMG. Comparando as figuras, nota-se que a redução do grau médio, resulta em uma menor redução na quantidade de estados com o aumento do parâmetro  $C$ , o mesmo ocorrido na base Brodatz.

### 4.3.3 Resultados para as texturas Virus

Esta seção apresenta os resultados para as texturas da base de imagens Virus, para os graus médios 8 e 4.

As tabelas 6 e 7 mostram os resultados obtidos pelo método com diferentes tamanhos de janelas, com graus médios 8 e 4, de forma análoga às bases de imagens anteriores. Para a base de imagens Virus o grau médio 4 obteve melhores taxas de acerto, quando




Figura 28 – Taxa de acerto com desvio padrão em função do parâmetro  $C$  para o conjunto de imagens UIUC com as janelas  $\{4, 5, 8, 10, 20, 25, 40, 50\}$  ao se aplicar o classificador LDA (Grau médio 8).




Figura 29 – Taxa de acerto com desvio padrão em função do parâmetro  $C$  para o conjunto de imagens UIUC com as janelas  $\{4, 5, 8, 10, 20, 25, 40, 50\}$  ao se aplicar o classificador LDA (Grau médio 4).






Figura 30 – Porcentagem de estados visitados pelo aumento do parâmetro  $C$  (Base de imagens UIUC), para as janelas  $\{4, 5, 8, 10, 20, 25, 40, 50\}$  com classificador LDA (Grau médio 8).




Figura 31 – Porcentagem de estados visitados pelo aumento do parâmetro  $C$  (Base de imagens UIUC), para as janelas  $\{4, 5, 8, 10, 20, 25, 40, 50, 100\}$  com classificador LDA (Grau médio 4).




Figura 32 – Taxa de acerto com desvio padrão em função do parâmetro  $C$  para o conjunto de imagens Virus com as janelas  $\{4, 5, 8, 10, 20\}$  ao se aplicar o classificador LDA (Grau médio 8).

comparado com o grau médio 8, entretanto o grau médio 4 obtém uma menor redução dos estados visitados.

Tabela 6 – Comparativo de resultados CMG e método proposto (Virus) com grau 8 usando o classificador LDA.

Conjuntos de tamanhos de janelas $\{l_1, l_2, \dots, l_n\}$	Acertos CMG	Acertos método proposto	C	Redução de Estados
$\{4, 5\}$	$0,3216 \pm 0,0177$	$0,3149 \pm 0,0241$	445	0,7371
$\{4, 5, 8\}$	$0,3368 \pm 0,0209$	$0,3112 \pm 0,0178$	45	0,3396
$\{4, 5, 8, 10\}$	$0,3401 \pm 0,0197$	$0,3156 \pm 0,0176$	160	0,7576
<b><math>\{4, 5, 8, 10, 20\}</math></b>	<b><math>0,3968 \pm 0,0270</math></b>	<b><math>0,3804 \pm 0,0110</math></b>	75	<b>0,5013</b>

Tabela 7 – Comparativo de resultados CMG e método proposto (Virus) com grau 4 usando o classificador LDA.

Conjuntos de tamanhos de janelas $\{l_1, l_2, \dots, l_n\}$	Acertos CMG	Acertos método proposto	C	Redução de Estados
$\{4, 5\}$	$0,3230 \pm 0,0178$	$0,3011 \pm 0,0278$	75	0,2408
$\{4, 5, 8\}$	$0,3697 \pm 0,0196$	$0,3481 \pm 0,0181$	50	0,1836
$\{4, 5, 8, 10\}$	$0,3941 \pm 0,0207$	$0,3673 \pm 0,0148$	35	0,1312
<b><math>\{4, 5, 8, 10, 20\}</math></b>	<b><math>0,4430 \pm 0,0153</math></b>	<b><math>0,4166 \pm 0,0159</math></b>	40	<b>0,1527</b>

Foram escolhidas as janelas  $\{4, 5, 8, 10, 20\}$  para observar seu comportamento em função do crescimento do parâmetro  $C$ . O Apêndice G mostra as demais janelas das tabelas 6 e 7.

Os gráficos apresentados nas figuras 32 e 33 exibem as taxas de acerto com desvio padrão do método proposto comparado com CMG. Analogamente ao ocorrido com as bases anteriores, com o crescimento do parâmetro  $C$  ocorre a queda da taxa de classificação do método proposto.

Por fim, as figuras 34 e 35 apresentam as porcentagens de estados visitados totais do método proposto comparado com o CMG. Assim como ocorre nos bancos de imagens




Figura 33 – Taxa de acerto com desvio padrão em função do parâmetro  $C$  para o conjunto de imagens Virus com as janelas  $\{4, 5, 8, 10, 20\}$  ao se aplicar o classificador LDA (Grau médio 4).




Figura 34 – Porcentagem de estados visitados pelo aumento do parâmetro  $C$  (Base de imagens Virus), para as janelas  $\{4, 5, 8, 10, 20\}$  com classificador LDA (Grau médio 8).

anteriores, o crescimento do parâmetro  $C$  diminui a quantidade de estados visitados pelo método proposto.

#### 4.3.4 Resultados para as texturas 2D HeLa

Esta seção apresenta os resultados para as texturas da base de imagens 2D HeLa, para os graus médios 8 e 4.

As tabelas 8 e 9 mostram os resultados obtidos pelo método com diferentes tamanhos de janelas, para os graus médio 8 e 4.




Figura 35 – Porcentagem de estados visitados pelo aumento do parâmetro  $C$  (Base de imagens Virus), para as janelas  $\{4, 5, 8, 10, 20\}$  com classificador LDA (Grau médio 4).

Tabela 8 – Comparativo de resultados CMG e método proposto (2D HeLa) com grau 8 usando o classificador LDA.

Conjuntos de tamanhos de janelas $\{l_1, l_2, \dots, l_n\}$	Acertos CMG	Acertos método proposto	C	Redução de Estados
$\{4, 5\}$	$0,5947 \pm 0,0328$	$0,5839 \pm 0,0232$	445	0,7102
$\{4, 5, 8\}$	$0,6250 \pm 0,0225$	$0,6508 \pm 0,0299$	445	0,7411
$\{4, 5, 8, 10\}$	$0,6346 \pm 0,0210$	$0,6545 \pm 0,0269$	445	0,7671
$\{4, 5, 8, 10, 20\}$	$0,6507 \pm 0,0258$	$0,6380 \pm 0,0260$	445	0,7950
$\{4, 5, 8, 10, 20, 25\}$	$0,6476 \pm 0,0255$	$0,6589 \pm 0,0256$	445	0,8177
$\{4, 5, 8, 10, 20, 25, 40\}$	$0,6633 \pm 0,0312$	$0,6347 \pm 0,0210$	400	0,8045
<b><math>\{4, 5, 8, 10, 20, 25, 40, 50\}</math></b>	$0,6672 \pm 0,0347$	$0,6374 \pm 0,0343$	065	0,8376
$\{4, 5, 8, 10, 20, 25, 40, 50, 100\}$	$0,6600 \pm 0,0270$	$0,6643 \pm 0,0213$	445	0,8601

Tabela 9 – Comparativo de resultados CMG e método proposto (2D HeLa) com grau 4 usando o classificador LDA.

Conjuntos de tamanhos de janelas $\{l_1, l_2, \dots, l_n\}$	Acertos CMG	Acertos método proposto	C	Redução de Estados
$\{4, 5\}$	$0,5995 \pm 0,0243$	$0,6241 \pm 0,0365$	445	0,6043
$\{4, 5, 8\}$	$0,6360 \pm 0,0309$	$0,6494 \pm 0,0312$	445	0,6590
$\{4, 5, 8, 10\}$	$0,6418 \pm 0,0262$	$0,6669 \pm 0,0310$	445	0,6937
$\{4, 5, 8, 10, 20\}$	$0,6495 \pm 0,0221$	$0,6694 \pm 0,0261$	445	0,7326
$\{4, 5, 8, 10, 20, 25\}$	$0,6434 \pm 0,0261$	$0,6729 \pm 0,0209$	445	0,7553
$\{4, 5, 8, 10, 20, 25, 40\}$	$0,6449 \pm 0,0341$	$0,6684 \pm 0,0272$	445	0,7801
$\{4, 5, 8, 10, 20, 25, 40, 50\}$	$0,6498 \pm 0,0338$	$0,6684 \pm 0,0222$	445	0,7996
<b><math>\{4, 5, 8, 10, 20, 25, 40, 50, 100\}</math></b>	$0,6505 \pm 0,0310$	$0,6762 \pm 0,0281$	445	0,8152

Foram escolhidas as janelas  $\{4, 5, 8, 10, 20, 25, 40, 50\}$  com o intuito de observar seu comportamento em função do crescimento do parâmetro  $C$ . O Apêndice E mostra as demais janelas das tabelas 8 e 9.

Os gráficos mostrados nas figuras 36 e 37 exibem as taxas de acerto com desvio padrão do método proposto comparado com o CMG, para graus médios 8 e 4, respectivamente. A taxa de classificação do método proposto obtém uma melhor taxa de classificação,




Figura 36 – Taxa de acerto com desvio padrão em função do parâmetro  $C$  para o conjunto de imagens 2D HeLa com as janelas  $\{4, 5, 8, 10, 20, 25, 40, 50\}$  ao se aplicar o classificador LDA (Grau médio 8).




Figura 37 – Taxa de acerto com desvio padrão em função do parâmetro  $C$  para o conjunto de imagens 2D HeLa com as janelas  $\{4, 5, 8, 10, 20, 25, 40, 50, 100\}$  ao se aplicar o classificador LDA (Grau médio 4).

diferente dos resultados apresentados anteriormente para os outros bancos de imagens.

Por fim, as figuras 38 e 39 apresentam as porcentagens de estados visitados totais do método proposto comparado com o CMG. Analogamente aos resultados anteriores, o crescimento do parâmetro  $C$  acarreta diminuição dos estados visitados para o método proposto e é constante para o método CMG.

#### 4.3.5 Comparação com métodos clássicos

A Tabela 10 apresenta os resultados comparativos entre CMG, método proposto, LBP e GLCM para o classificador LDA. O método proposto e o CMG estão em duas




Figura 38 – Porcentagem de estados visitados pelo aumento do parâmetro  $C$  (Base de imagens 2D HeLa), para as janelas  $\{4, 5, 8, 10, 20, 25, 40, 50\}$  com classificador LDA (Grau médio 8).




Figura 39 – Porcentagem de estados visitados pelo aumento do parâmetro  $C$  (Base de imagens 2D HeLa), para as janelas  $\{4, 5, 8, 10, 20, 25, 40, 50, 100\}$  com classificador LDA (Grau médio 4).

configurações de grau médio (8 e 4). Pela tabela, evidencia-se que o método proposto consegue bons resultados, comparáveis ao método CMG. O único banco de imagens que apresenta uma perda significativa é o 2D HeLa. Para esse banco, o método LBP consegue as melhores taxas de acerto.

Tabela 10 – Comparativo de resultados com métodos clássicos usando o classificador LDA.

	LBP	GLCM	CMG - 8	Proposto - 8	CMG - 4	Proposto - 4
Brodatz	0,9896 ± 0,0108	0,7908 ± 0,0266	0,9925 ± 0,0076	0,9796 ± 0,0131	0,9862 ± 0,0116	0,9779 ± 0,0133
UIUC	0,7958 ± 0,0157	0,3445 ± 0,0204	0,8393 ± 0,0162	0,8193 ± 0,0160	0,8205 ± 0,0205	0,7947 ± 0,0295
Virus	0,4521 ± 0,0258	0,2461 ± 0,0168	0,3968 ± 0,0270	0,3804 ± 0,0110	0,4430 ± 0,0153	0,4166 ± 0,0159
2D HeLa	0,7343 ± 0,0182	0,4795 ± 0,0264	0,6672 ± 0,0347	0,6374 ± 0,0343	0,6505 ± 0,0310	0,6762 ± 0,0281

Portanto, o método proposto e o método CMG apresentam resultados promissores, comparados a métodos clássicos. Comparados ao LBP, conseguem resultados melhores na maioria das bases de imagens. Um motivo para o bom desempenho do LBP é o fato dele possuir uma grande quantidade de atributos- no total 256- enquanto o método CMG e o método proposto possuem no máximo 72 atributos para as janelas {4, 5, 8, 10, 20, 25, 40, 50, 100}.

## 4.4 Resultados com MLP

O emprego do MLP tem como finalidade tentar extrair com melhor eficiência os atributos extraídos tanto pelo método proposto nesta dissertação quanto os atributos dos métodos CMG, LBP e GLCM.

Assim, nesta seção são apresentados os resultados usando o classificador MLP. Diferentemente de como foram apresentados os resultados para o LDA, na Seção 4.3, são apenas exibidas as tabelas com os resultados para diferentes janelas. Os gráficos para cada janela encontram-se nos Apêndices B, D, H e F.

### 4.4.1 Resultados para as texturas Brodatz

As tabelas 11 e 12 mostram os resultados para diferentes conjuntos de janelas, para os graus médios 8 e 4. O conjunto de janelas {4, 5, 8, 10, 20, 25, 40, 50} em ambos os graus médios, obtém a mesma média de acertos para o método CMG e para o proposto.

Tabela 11 – Comparativo de resultados CMG e método proposto (Brodatz) com grau 8 usando o classificador MLP.

Conjuntos de tamanhos de janelas $\{l_1, l_2, \dots, l_n\}$	Acertos CMG	Acertos método proposto	C	Redução de Estados
$\{4, 5\}$	$0,9161 \pm 0,0123$	$0,9081 \pm 0,0132$	070	0,4098
$\{4, 5, 8\}$	$0,9407 \pm 0,0144$	$0,9327 \pm 0,0111$	015	0,1017
$\{4, 5, 8, 10\}$	$0,9169 \pm 0,0105$	$0,9080 \pm 0,0127$	125	0,6273
$\{4, 5, 8, 10, 20\}$	$0,9655 \pm 0,0126$	$0,9582 \pm 0,0133$	060	0,3700
$\{4, 5, 8, 10, 20, 25\}$	$0,9580 \pm 0,0101$	$0,9497 \pm 0,0118$	085	0,5209
$\{4, 5, 8, 10, 20, 25, 40\}$	$0,9504 \pm 0,0112$	$0,9423 \pm 0,0105$	115	0,6431
<b><math>\{4, 5, 8, 10, 20, 25, 40, 50\}</math></b>	$0,9660 \pm 0,0124$	$0,9589 \pm 0,0108$	105	0,5871
$\{4, 5, 8, 10, 20, 25, 40, 50, 100\}$	$0,9587 \pm 0,0106$	$0,9495 \pm 0,0126$	015	0,0657

Tabela 12 – Comparativo de resultados CMG e método proposto (Brodatz) com grau 4 usando o classificador MLP.

Conjuntos de tamanhos de janelas $\{l_1, l_2, \dots, l_n\}$	Acertos CMG	Acertos método proposto	C	Redução de Estados
$\{4, 5\}$	$0,8841 \pm 0,0154$	$0,8746 \pm 0,0160$	055	0,1674
$\{4, 5, 8\}$	$0,9333 \pm 0,0112$	$0,9262 \pm 0,0147$	170	0,4679
$\{4, 5, 8, 10\}$	$0,9331 \pm 0,0134$	$0,9315 \pm 0,0109$	445	0,7114
$\{4, 5, 8, 10, 20\}$	$0,9498 \pm 0,0106$	$0,9418 \pm 0,0112$	045	0,1580
$\{4, 5, 8, 10, 20, 25\}$	$0,9497 \pm 0,0104$	$0,9415 \pm 0,0106$	175	0,5696
$\{4, 5, 8, 10, 20, 25, 40\}$	$0,9331 \pm 0,0128$	$0,9248 \pm 0,0102$	105	0,3934
<b><math>\{4, 5, 8, 10, 20, 25, 40, 50\}</math></b>	$0,9582 \pm 0,0114$	$0,9494 \pm 0,0102$	150	0,5596
$\{4, 5, 8, 10, 20, 25, 40, 50, 100\}$	$0,9496 \pm 0,0128$	$0,9407 \pm 0,0119$	180	0,6632

#### 4.4.2 Resultados para as texturas UIUC

As tabelas 14 e 13 mostram os resultados para diferentes conjuntos de janelas, para os graus médios 8 e 4. O conjunto de janelas  $\{4, 5, 8, 10, 20, 25, 40, 50\}$  para o grau médio 4 possui um resultado inferior, comparado com o grau médio 8.



Tabela 13 – Comparativo de resultados CMG e método proposto (UIUC) com grau 8 usando o classificador MLP.

Conjuntos de tamanhos de janelas $\{l_1, l_2, \dots, l_n\}$	Acertos CMG	Acertos método proposto	C	Redução de Estados
$\{4, 5\}$	$0,6833 \pm 0,0193$	$0,6667 \pm 0,0192$	030	0,2036
$\{4, 5, 8\}$	$0,6667 \pm 0,0164$	$0,6500 \pm 0,0173$	005	0,0900
$\{4, 5, 8, 10\}$	$0,6433 \pm 0,0169$	$0,6300 \pm 0,0170$	120	0,6678
$\{4, 5, 8, 10, 20\}$	$0,6767 \pm 0,0146$	$0,6533 \pm 0,0168$	005	0,0500
$\{4, 5, 8, 10, 20, 25\}$	$0,7000 \pm 0,0147$	$0,6767 \pm 0,0149$	005	0,0000
$\{4, 5, 8, 10, 20, 25, 40\}$	$0,6633 \pm 0,0152$	$0,6433 \pm 0,0157$	120	0,7267
<b><math>\{4, 5, 8, 10, 20, 25, 40, 50\}</math></b>	<b><math>0,8033 \pm 0,0097</math></b>	<b><math>0,7967 \pm 0,0100</math></b>	<b>020</b>	<b>0,0805</b>
$\{4, 5, 8, 10, 20, 25, 40, 50, 100\}$	$0,8017 \pm 0,0095$	$0,8033 \pm 0,0095$	035	0,1621

Tabela 14 – Comparativo de resultados CMG e método proposto (UIUC) com grau 4 usando o classificador MLP.

Conjuntos de tamanhos de janelas $\{l_1, l_2, \dots, l_n\}$	Acertos CMG	Acertos método proposto	C	Redução de Estados
$\{4, 5\}$	$0,6367 \pm 0,0186$	$0,6200 \pm 0,0190$	035	0,0776
$\{4, 5, 8\}$	$0,6900 \pm 0,0158$	$0,6833 \pm 0,0160$	080	0,2053
$\{4, 5, 8, 10\}$	$0,7000 \pm 0,0144$	$0,6867 \pm 0,0149$	050	0,1228
$\{4, 5, 8, 10, 20\}$	$0,7367 \pm 0,0130$	$0,7167 \pm 0,0135$	010	0,0145
$\{4, 5, 8, 10, 20, 25\}$	$0,7200 \pm 0,0137$	$0,7000 \pm 0,0139$	025	0,0505
$\{4, 5, 8, 10, 20, 25, 40\}$	$0,7300 \pm 0,0129$	$0,7233 \pm 0,0132$	005	0,0000
<b><math>\{4, 5, 8, 10, 20, 25, 40, 50\}</math></b>	<b><math>0,8800 \pm 0,0074</math></b>	<b><math>0,8633 \pm 0,0080</math></b>	<b>065</b>	<b>0,1795</b>
$\{4, 5, 8, 10, 20, 25, 40, 50, 100\}$	$0,8467 \pm 0,0081$	$0,8367 \pm 0,0094$	140	0,5184

#### 4.4.3 Resultados para as texturas Virus

As tabelas 15 e 16 mostram os resultados para diferentes conjuntos de janelas, para os graus médios 8 e 4. O conjunto de janelas  $\{4, 5, 8, 10, 20\}$  para o grau médio 4 obtém resultados melhores do que o grau médio 8.

Tabela 15 – Comparativo de resultados CMG e método proposto (Virus) com grau 8 usando o classificador MLP.

Conjuntos de tamanhos de janelas $\{l_1, l_2, \dots, l_n\}$	Acertos CMG	Acertos método proposto	C	Redução de Estados
$\{4, 5\}$	$0,3467 \pm 0,0499$	$0,3400 \pm 0,0501$	445	0,7372
$\{4, 5, 8\}$	$0,3689 \pm 0,0474$	$0,3444 \pm 0,0491$	445	0,7796
$\{4, 5, 8, 10\}$	$0,3844 \pm 0,0452$	$0,3644 \pm 0,0467$	045	0,3324
<b><math>\{4, 5, 8, 10, 20\}</math></b>	<b><math>0,4022 \pm 0,0412</math></b>	<b><math>0,3833 \pm 0,0450</math></b>	<b>165</b>	<b>0,7919</b>

Tabela 16 – Comparativo de resultados CMG e método proposto (Virus) com grau 4 usando o classificador MLP.

Conjuntos de tamanhos de janelas $\{l_1, l_2, \dots, l_n\}$	Acertos CMG	Acertos método proposto	C	Redução de Estados
$\{4, 5\}$	$0,3711 \pm 0,0498$	$0,3467 \pm 0,0505$	025	0,0855
$\{4, 5, 8\}$	$0,4385 \pm 0,0454$	$0,4033 \pm 0,0457$	030	0,1080
$\{4, 5, 8, 10\}$	$0,3958 \pm 0,0443$	$0,3622 \pm 0,0467$	165	0,5332
<b><math>\{4, 5, 8, 10, 20\}</math></b>	<b><math>0,4644 \pm 0,0388</math></b>	<b><math>0,4422 \pm 0,0405</math></b>	<b>005</b>	<b>0,0500</b>

#### 4.4.4 Resultados para as texturas 2D HeLa

As tabelas 17 e 18 mostram os resultados para diferentes conjuntos de janelas, para grau médio 8 e 4. Diferentemente dos resultados das outras bases de imagens, os melhores resultados são obtidos com o conjunto de janelas  $\{4, 5, 8, 10, 20, 25\}$  em ambos os graus médios. O aumento do conjunto de janelas impacta na diminuição da taxa de acerto, mostrando que a adição de informações, para esta base de imagens, não é tão relevante quanto para as demais.

Tabela 17 – Comparativo de resultados CMG e método proposto (2d HeLa) com grau 8 usando o classificador MLP.

Conjuntos de tamanhos de janelas $\{l_1, l_2, \dots, l_n\}$	Acertos CMG	Acertos método proposto	C	Redução de Estados
$\{4, 5\}$	$0,7562 \pm 0,0469$	$0,7485 \pm 0,0474$	445	0,7102
$\{4, 5, 8\}$	$0,8064 \pm 0,0417$	$0,8005 \pm 0,0428$	020	0,6743
$\{4, 5, 8, 10\}$	$0,8180 \pm 0,0412$	$0,7716 \pm 0,0428$	015	0,6688
$\{4, 5, 8, 10, 20\}$	$0,7716 \pm 0,0411$	$0,8025 \pm 0,0393$	445	0,7950
<b><math>\{4, 5, 8, 10, 20, 25\}</math></b>	<b><math>0,8218 \pm 0,0389</math></b>	<b><math>0,7948 \pm 0,0403</math></b>	235	0,8177
$\{4, 5, 8, 10, 20, 25, 40\}$	$0,7848 \pm 0,0399$	$0,7537 \pm 0,0449$	130	0,8335
$\{4, 5, 8, 10, 20, 25, 40, 50\}$	$0,8025 \pm 0,0400$	$0,7723 \pm 0,0416$	065	0,8376
$\{4, 5, 8, 10, 20, 25, 40, 50, 100\}$	$0,8013 \pm 0,0391$	$0,7725 \pm 0,0395$	060	0,8472

Tabela 18 – Comparativo de resultados CMG e método proposto (2d HeLa) com grau 4 usando o classificador MLP.

Conjuntos de tamanhos de janelas $\{l_1, l_2, \dots, l_n\}$	Acertos CMG	Acertos método proposto	C	Redução de Estados
$\{4, 5\}$	$0,7755 \pm 0,0469$	$0,7407 \pm 0,0469$	025	0,5442
$\{4, 5, 8\}$	$0,7948 \pm 0,0425$	$0,7897 \pm 0,0448$	445	0,6590
$\{4, 5, 8, 10\}$	$0,8064 \pm 0,0435$	$0,7716 \pm 0,0423$	205	0,6925
$\{4, 5, 8, 10, 20\}$	$0,8295 \pm 0,0379$	$0,7986 \pm 0,0396$	265	0,7324
<b><math>\{4, 5, 8, 10, 20, 25\}</math></b>	<b><math>0,8307 \pm 0,0369</math></b>	<b><math>0,8025 \pm 0,0393</math></b>	215	0,7544
$\{4, 5, 8, 10, 20, 25, 40\}$	$0,8218 \pm 0,0370$	$0,7909 \pm 0,0406$	150	0,7770
$\{4, 5, 8, 10, 20, 25, 40, 50\}$	$0,8295 \pm 0,0372$	$0,8064 \pm 0,0371$	090	0,7883
$\{4, 5, 8, 10, 20, 25, 40, 50, 100\}$	$0,8334 \pm 0,0363$	$0,8257 \pm 0,0336$	015	0,6727

#### 4.4.5 Comparação com métodos clássicos

A Tabela 19 apresenta os resultados comparativos entre os métodos CMG, método proposto, LBP e GLCM para o classificador MLP, similar ao que foi apresentado na Seção 4.3.5 para o LDA. Assim como na seção para o LDA, fica evidente que o método proposto consegue bons resultados, comparáveis ao método CMG. Além disso, o único momento em que há perda em comparação com os métodos clássicos é com o banco de imagens 2D HeLa.

Tabela 19 – Comparativo de resultados com métodos clássicos usando o classificador MLP.

	LBP	GLCM	CMG - 8	Proposto - 8	CMG - 4	Proposto - 4
Brodatz	$0,9133 \pm 0,0317$	$0,7500 \pm 0,0118$	$0,9583 \pm 0,0029$	$0,9500 \pm 0,0030$	$0,9583 \pm 0,0031$	$0,9500 \pm 0,0032$
UIUC	$0,7867 \pm 0,0011$	$0,4967 \pm 0,0016$	$0,8033 \pm 0,0097$	$0,7967 \pm 0,0100$	$0,8800 \pm 0,0074$	$0,8633 \pm 0,0080$
Virus	$0,4478 \pm 0,0024$	$0,3556 \pm 0,0023$	$0,4022 \pm 0,0412$	$0,3833 \pm 0,0450$	$0,4644 \pm 0,0388$	$0,4422 \pm 0,0405$
2D HeLa	$0,8308 \pm 0,0313$	$0,8115 \pm 0,0579$	$0,8218 \pm 0,0389$	$0,7948 \pm 0,0403$	$0,8307 \pm 0,0369$	$0,8025 \pm 0,0393$

De forma análoga ao LDA, no MLP, o método proposto e o CMG apresentam resultados promissores quando comparados a métodos clássicos. No geral, existe um aumento da taxa de classificação do MLP comparado ao LDA, indicando que a textura possui informações que uma classificação não-linear não consegue obter.

## 5 Conclusão e trabalhos futuros

Este trabalho abordou um ramo recente na classificação de texturas de imagens, através de caminhos mínimos em grafos, proposto inicialmente por SÁ, BACKES e CORTEZ (2013).

Conforme discutido no Capítulo 3, o método proposto nesta dissertação consiste de uma heurística para direcionar a busca do caminho no grafo. O método obtém bons resultados, comparado com o método CMG, como observado no Capítulo 4, por exemplo nas tabelas 2 e 5. Existe também a redução significativa nos estados visitados na busca do caminho.

Assim, com o emprego da heurística, fica evidente que não existe a necessidade do caminho mínimo para extrair as características da textura, já que caminhos que não são mínimos trazem bons resultados, com a vantagem de contar com um custo computacional inferior ao que seria obtido ao percorrer o grafo completo.

Vale destacar que a redução do grau médio do grafo (grau médio 4) traz resultados significativos para os métodos, tanto para o CMG quanto para o método proposto. A vantagem do uso da redução do grau médio é a diminuição dos possíveis estados que podem ser visitados.

Desse modo, algumas contribuições deste trabalho são:

- Testes do método CMG para diversas bases de texturas públicas;
- Elaboração de uma heurística capaz de diminuir significativamente a busca de um caminho em uma imagem de textura e
- Comparação do método proposto com o método CMG.

Para trabalhos futuros pode-se citar alguns possíveis temas:

- Empregar invariação à rotação na imagem para qualquer ângulo, pois o método CMG é invariante à rotação apenas em ângulos múltiplos de 45°;
- Usar o histograma do método LBP para cada região ao redor do percurso do trajeto do caminho, com o objetivo de obter uma nova característica que melhor identifique a textura;
- Implementar o método em hardware embarcado e analisar a real redução de consumo de recursos.

## Referências

- AKSOY, S. *Textural features for image database retrieval*. Dissertação (Mestrado) — Seattle, Universidade de Washington, 1998. Citado na página 19.
- ARBIB, M. A. (Ed.). *The Handbook of Brain Theory and Neural Networks*. 2nd. ed. Cambridge, MA, USA: MIT Press, 2002. ISBN 0262011972. Citado na página 37.
- AZENCOTT, R.; WANG, J.-P.; YOUNES, L. Texture classification using windowed fourier filters. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, v. 19, n. 2, p. 148–153, Feb 1997. ISSN 0162-8828. Citado na página 19.
- BELIAKOV, G.; JAMES, S.; TROIANO, L. Texture recognition by using glcm and various aggregation functions. In: *Fuzzy Systems, 2008. FUZZ-IEEE 2008. (IEEE World Congress on Computational Intelligence). IEEE International Conference on*. [S.l.: s.n.], 2008. p. 1472–1476. ISSN 1098-7584. Citado na página 19.
- BISHOP, C. M. *Pattern Recognition and Machine Learning (Information Science and Statistics)*. Secaucus, NJ, USA: Springer-Verlag New York, Inc., 2006. ISBN 0387310738. Citado na página 38.
- BOLAND, M. V.; MURPHY, R. F. A neural network classifier capable of recognizing the patterns of all major subcellular structures in fluorescence microscope images of hela cells. *Bioinformatics*, v. 17, n. 12, p. 1213–1223, 2001. Disponível em: <<http://dblp.uni-trier.de/db/journals/bioinformatics/bioinformatics17.html#BolandM01>>. Citado na página 48.
- BONDY, J. A. *Graph Theory With Applications*. Oxford, UK, UK: Elsevier Science Ltd., 1976. ISBN 0444194517. Citado na página 24.
- BRANDÃO, B. B. *PROCESSAMENTO DIGITAL DE SINAIS ULTRASSOM DOPPLER PARA O CÁLCULO DO DÉBITO CARDÍACO*. Dissertação (Mestrado) — Universidade Federal da Bahia, Instituto de Matemática e Escola Politécnica, Salvador, 2012. Citado na página 38.
- BRODATZ, P. *Textures : a photographic album for artists and designers*. New York: Dover Publications, 1966. ISBN 0-486-21669-1. Disponível em: <<http://opac.inria.fr/record=b1084586>>. Citado 2 vezes nas páginas 22 e 46.
- CASTELLANO, G. et al. Texture analysis of medical images. *Clinical Radiology*, v. 59, n. 12, p. 1061 – 1069, 2004. ISSN 0009-9260. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S000992600400265X>>. Citado na página 19.
- CHERKASSKY, V.; MULIER, F. M. *Learning from Data: Concepts, Theory, and Methods*. [S.l.]: Wiley-IEEE Press, 2007. ISBN 0471681822. Citado na página 36.
- CHRISTODOULOU, C.; MICHAELIDES, S.; PATTICHIS, C. Multifeature texture analysis for the classification of clouds in satellite imagery. *Geoscience and Remote Sensing, IEEE Transactions on*, v. 41, n. 11, p. 2662–2668, Nov 2003. ISSN 0196-2892. Citado na página 22.

- CORMEN, T. H. et al. *Introduction to Algorithms*. 3rd. ed. [S.l.]: The MIT Press, 2009. ISBN 978-0-262-03384-8. Citado 2 vezes nas páginas 23 e 25.
- COSTA, L. daF. et al. Characterization of complex networks: A survey of measurements. *Advances in Physics*, v. 56, n. 1, p. 167–242, January 2005. Citado na página 19.
- DIJKSTRA, E. W. A note on two problems in connexion with graphs. *NUMERISCHE MATHEMATIK*, v. 1, n. 1, p. 269–271, 1959. Citado 2 vezes nas páginas 20 e 25.
- DINIZ, P. H. G. D. *Novas estratégias para classificação simultânea do tipo e origem geográfica de chás*. Tese (Doutorado) — Universidade Federal da Paraíba, Centro de Ciências Exatas e da Natureza, Departamento de Química, João Pessoa - Paraíba, 2013. Citado na página 35.
- DROZDEK, A. *Data Structures and Algorithms in C++*. 2nd. ed. Pacific Grove, CA, USA: Brooks/Cole Publishing Co., 2000. ISBN 0534375979. Citado 3 vezes nas páginas 23, 24 e 25.
- DUDA, R. O.; HART, P. E.; STORK, D. G. *Pattern Classification (2Nd Edition)*. [S.l.]: Wiley-Interscience, 2000. ISBN 0471056693. Citado na página 38.
- EBERT, D. S. et al. *Texturing and Modeling: A Procedural Approach*. [S.l.]: Morgan Kaufmann, 2002. Citado na página 22.
- FACELI, K.; GAMA, A. C. L. J.; CARVALHO, A. C. de. *Inteligência Artificial: Uma Abordagem de Aprendizado de Máquina*. 1. ed. [S.l.]: LTC - Livros Técnicos e Científicos, 2011. Citado na página 32.
- FILHO, O. M.; VIEIRA, H. *Processamento Digital de Imagens*. Rio de Janeiro, Brazil: Editora Brasport, 1999. Citado na página 19.
- FUKUNAGA, K. *Introduction to Statistical Pattern Recognition (2Nd Ed.)*. San Diego, CA, USA: Academic Press Professional, Inc., 1990. ISBN 0-12-269851-7. Citado 2 vezes nas páginas 33 e 36.
- FÁVERO, L. et al. *Análise de dados: modelagem multivariada para tomada de decisões*. [S.l.]: Elsevier, 2009. Citado na página 33.
- GHIDONI, S. et al. Texture descriptors based on dijkstra’s algorithm for medical image analysis. *KES Innovation in Medicine and Healthcare (InMed-14)*, San Sabastian, Spain, 2014. Citado na página 19.
- GONZALEZ, R. C.; WOODS, R. E. *Digital Image Processing*. 3th. ed. [S.l.]: Prentice Hall, 1997. Citado na página 19.
- HAIR, J. F. et al. *Multivariate Data Analysis (5th Edition)*. 5th. ed. Prentice Hall, 1998. Hardcover. ISBN 0138948585. Disponível em: <<http://www.amazon.com/exec/obidos/redirect?tag=citeulike07-20&path=ASIN/0138948585>>. Citado na página 33.
- HARALICK, R.; SHANMUGAM, K.; DINSTEN, I. Textural features for image classification. *Systems, Man and Cybernetics, IEEE Transactions on*, SMC-3, n. 6, p. 610–621, Nov 1973. ISSN 0018-9472. Citado 3 vezes nas páginas 19, 22 e 28.

- HART, P. E.; NILSSON, N. J.; RAPHAEL, B. A formal basis for the heuristic determination of minimum cost paths. *IEEE Transactions on Systems, Science, and Cybernetics*, SSC-4, n. 2, p. 100–107, 1968. Citado na página 27.
- HAYKIN, S. *Neural Networks: A Comprehensive Foundation*. 2nd. ed. Upper Saddle River, NJ, USA: Prentice Hall PTR, 1998. ISBN 0132733501. Citado na página 36.
- HAYKIN, S. *Neural Networks and Learning Machines (3rd Edition)*. 3. ed. Prentice Hall, 2008. Hardcover. ISBN 0131471392. Disponível em: <<http://www.amazon.com/exec/obidos/redirect?tag=citeulike07-20&path=ASIN/0131471392>>. Citado na página 38.
- KHAN, Y.; MASSELLI, A.; ZELL, A. Visual terrain classification by flying robots. In: *Robotics and Automation (ICRA), 2012 IEEE International Conference on*. [S.l.: s.n.], 2012. p. 498–503. ISSN 1050-4729. Citado na página 19.
- KOHAVI, R. A study of cross-validation and bootstrap for accuracy estimation and model selection. In: *Proceedings of the 14th International Joint Conference on Artificial Intelligence - Volume 2*. San Francisco, CA, USA: Morgan Kaufmann Publishers Inc., 1995. (IJCAI'95), p. 1137–1143. ISBN 1-55860-363-8. Disponível em: <<http://dl.acm.org/citation.cfm?id=1643031.1643047>>. Citado na página 38.
- KYLBERG, G.; UPPSTRÖM, M.; SINTORN, I.-M. Virus texture analysis using local binary patterns and radial density profiles. In: *Progress in Pattern Recognition, Image Analysis, Computer Vision, and Applications*. [S.l.: s.n.], 2011. (Lecture Notes in Computer Science, 7042), p. 573–580. Citado na página 48.
- LAZEBNIK, S.; SCHMID, C.; PONCE, J. A sparse texture representation using local affine regions. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, v. 27, n. 8, p. 1265–1278, Aug 2005. ISSN 0162-8828. Citado 2 vezes nas páginas 22 e 47.
- MAHALANOBIS, P. C. On the generalised distance in statistics. In: *Proceedings National Institute of Science, India*. [s.n.], 1936. v. 2, n. 1, p. 49–55. Disponível em: <<http://ir.isical.ac.in/dspace/handle/1/1268>>. Citado na página 36.
- MANJUNATH, B.; MA, W. Texture features for browsing and retrieval of image data. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, v. 18, n. 8, p. 837–842, Aug 1996. ISSN 0162-8828. Citado na página 19.
- MASSEY FRANK J., J. The kolmogorov-smirnov test for goodness of fit. *Journal of the American Statistical Association*, Taylor & Francis, Ltd. on behalf of the American Statistical Association, v. 46, n. 253, p. pp. 68–78, 1951. ISSN 01621459. Disponível em: <<http://www.jstor.org/stable/2280095>>. Citado 2 vezes nas páginas 38 e 45.
- MEDEIROS, G. C. F. *Uso de texturas para o acompanhamento da evolução do tratamento de úlceras dermatológicas*. Dissertação (Mestrado) — Universidade de São Paulo - USP, São Paulo, 2001. Citado na página 28.
- NASCIMENTO, J. P. R. *Análise e classificação de imagens baseadas em características de textura utilizando matrizes de co-ocorrência*. Dissertação (Mestrado) — Universidade Federal do Paraná, Curitiba, 2003. Citado 3 vezes nas páginas 7, 28 e 29.

NETO, E. C. *SFPT NEURAL: NOVA TÉCNICA DE SEGMENTAÇÃO DE FISSURAS PULMONARES BASEADA EM TEXTURAS EM IMAGENS DE TOMOGRAFIA COMPUTADORIZADAS DO TÓRAX*. Dissertação (Mestrado) — Universidade Federal do Ceará - UFC, Fortaleza - Ceará, 2014. Citado 2 vezes nas páginas 37 e 38.

Næs, T.; MEVIK, B.-H. Understanding the collinearity problem in regression and discriminant analysis. *Journal of Chemometrics*, John Wiley & Sons, Ltd., v. 15, n. 4, p. 413–426, 2001. ISSN 1099-128X. Disponível em: <<http://dx.doi.org/10.1002/cem.676>>. Citado na página 36.

OJALA, T.; PIETIKÄINEN, M.; MÄENPÄÄ, T. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. *IEEE Trans. Pattern Anal. Mach. Intell.*, IEEE Computer Society, Washington, DC, USA, v. 24, n. 7, p. 971–987, jul. 2002. ISSN 0162-8828. Disponível em: <<http://dx.doi.org/10.1109/TPAMI.2002.1017623>>. Citado na página 27.

OLIVEIRA, M. P. B. *VERIFICAÇÃO AUTOMÁTICA DO LOCUTOR, DEPENDENTE DO TEXTO, UTILIZANDO SISTEMAS HÍBRIDOS MLP/HMM*. Dissertação (Mestrado) — Instituto Militar de Engenharia, Rio de Janeiro, 2001. Citado 2 vezes nas páginas 7 e 37.

ORTEGA-ARRANZ, H. et al. The all-pair shortest-path problem in shared-memory heterogeneous systems. In: \_\_\_\_\_. *High-Performance Computing on Complex Environments*. John Wiley & Sons, Inc., 2014. p. 283–299. ISBN 9781118711897. Disponível em: <<http://dx.doi.org/10.1002/9781118711897.ch15>>. Citado na página 25.

PONTES, M. J. C. d. *Algoritmo das Projeções Sucessivas para Seleção de Variáveis espectrais em Problemas de Classificação*. Tese (Doutorado) — Universidade Federal da Paraíba, Centro de Ciências Exatas e da Natureza, Departamento de Química, João Pessoa - Paraíba, 2009. Citado na página 35.

RAJU, J.; DURAI, C. A survey on texture classification techniques. In: *Information Communication and Embedded Systems (ICICES), 2013 International Conference on*. [S.l.: s.n.], 2013. p. 180–184. Citado na página 27.

RAO, A. R. *A Taxonomy for Texture Description and Identification*. New York, NY, USA: Springer-Verlag New York, Inc., 1990. ISBN 0-387-97302-8. Citado na página 22.

RUSSELL, S.; NORVIG, P. *Artificial Intelligence: A Modern Approach*. 3rd. ed. Upper Saddle River, NJ, USA: Prentice Hall Press, 2009. ISBN 0136042597, 9780136042594. Citado 3 vezes nas páginas 25, 26 e 27.

SABINO, D. M. U. et al. A texture approach to leukocyte recognition. *Real-Time Imaging*, Academic Press Ltd., London, UK, UK, v. 10, n. 4, p. 205–216, ago. 2004. ISSN 1077-2014. Disponível em: <<http://dx.doi.org/10.1016/j.rti.2004.02.007>>. Citado na página 22.

SHI, Z.; HU, J. Local linear discriminant analysis with composite kernel for face recognition. In: *Neural Networks (IJCNN), The 2012 International Joint Conference on*. [S.l.: s.n.], 2012. p. 1–5. ISSN 2161-4393. Citado na página 35.

SHIRAISHI, T. et al. Comparative assessment of supervised classifiers for land use land cover classification in a tropical region using time-series palsar mosaic data. *Selected*



*Topics in Applied Earth Observations and Remote Sensing, IEEE Journal of*, v. 7, n. 4, p. 1186–1199, April 2014. ISSN 1939-1404. Citado na página 19.

SIEGEL, S.; CASTELLAN, N. J. J. *Estatística Não-Paramétrica para Ciências do Comportamento*. 2ª edição. ed. [S.l.]: Artmed, 2008. Citado 3 vezes nas páginas 12, 38 e 40.

SÁ, J. M. *Novos métodos de análise de texturas baseados em modelos gravitacionais simplificados e caminhos mais curtos em grafos*. Tese (Doutorado) — Universidade Federal do Ceará, Programa de pós-graduação em engenharia de teleinformática, 2013. Citado 8 vezes nas páginas 7, 19, 30, 31, 33, 41, 46 e 47.

SÁ, J. M.; BACKES. A simplified gravitational model to analyze texture roughness. *Pattern Recognition*, v. 45, n. 2, p. 732 – 741, 2012. ISSN 0031-3203. Citado na página 19.

SÁ, J. M.; BACKES, A.; CORTEZ, P. Texture analysis and classification using shortest paths in graphs. *Pattern Recognition Letters*, v. 34, n. 11, p. 1314 – 1319, 2013. ISSN 0167-8655. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0167865513001633>>. Citado 7 vezes nas páginas 19, 20, 33, 35, 36, 43 e 66.

TONG, X.; XIE, H.; WENG, Q. Urban land cover classification with airborne hyperspectral data: What features to use? *Selected Topics in Applied Earth Observations and Remote Sensing, IEEE Journal of*, PP, n. 99, p. 1–12, 2013. ISSN 1939-1404. Citado na página 19.

WETZEL, U.; TOMEI, P. A. *Estudo em negócios II*. 3th. ed. [S.l.]: MAUAD, 2002. Citado na página 39.

WIDROW, B.; WINTER, R. Neural nets for adaptive filtering and adaptive pattern recognition. *Computer*, v. 21, n. 3, p. 25–39, March 1988. ISSN 0018-9162. Citado na página 38.

# Apêndices

# APÊNDICE A – Resultados Brodatz com LDA

## A.1 Grau médio 8

Os gráficos para diferentes configurações de janelas da Tabela 2 são mostrados a seguir.

### A.1.1 Taxa de classificação

A Figura 40 apresenta os resultados das taxas classificações para o banco Brodatz com diferentes configurações de janelas.

### A.1.2 Porcentagem de estados visitados

A Figura 41 apresenta os resultados dos estados visitados para o banco Brodatz com diferentes configurações de janelas.

## A.2 Grau médio 4

Os gráficos para diferentes configurações de janelas da Tabela 3 são mostrados a seguir.

### A.2.1 Taxa de classificação

A Figura 42 apresenta os resultados das taxas classificações para o banco Brodatz com diferentes configurações de janelas.

### A.2.2 Porcentagem de estados visitados

A Figura 43 apresenta os resultados dos estados visitados para o banco Brodatz com diferentes configurações de janelas.

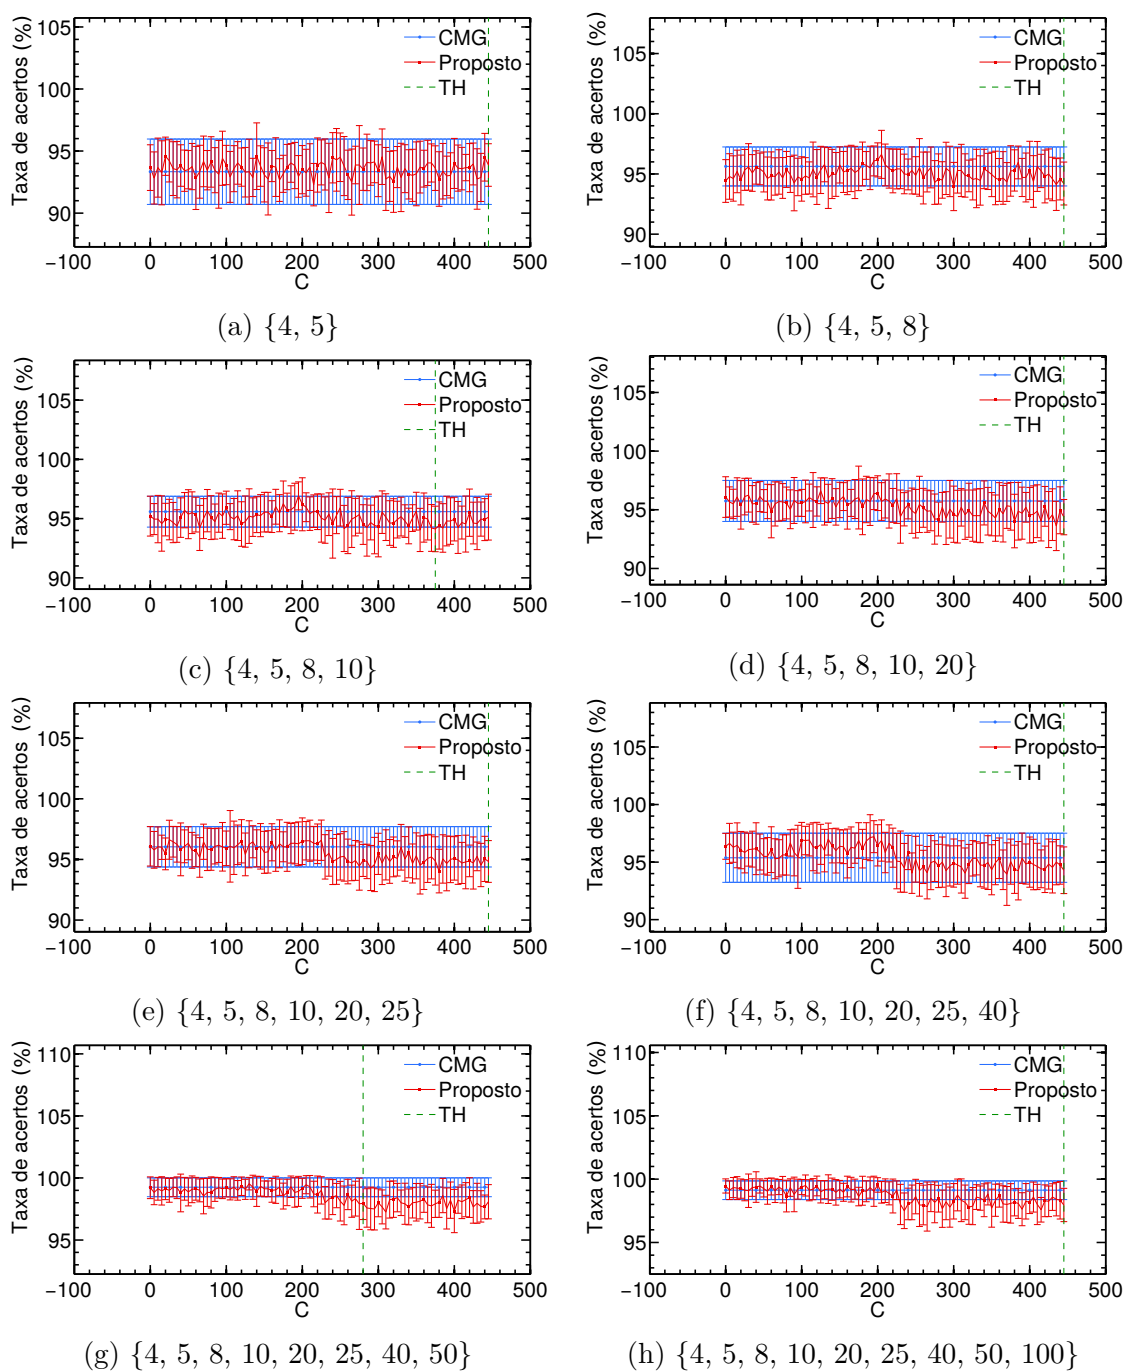


Figura 40 – Taxa de classificação com desvio padrão pelo aumento do parâmetro  $C$  (Base de imagens Brodatz), com classificador LDA (Grau médio 8).

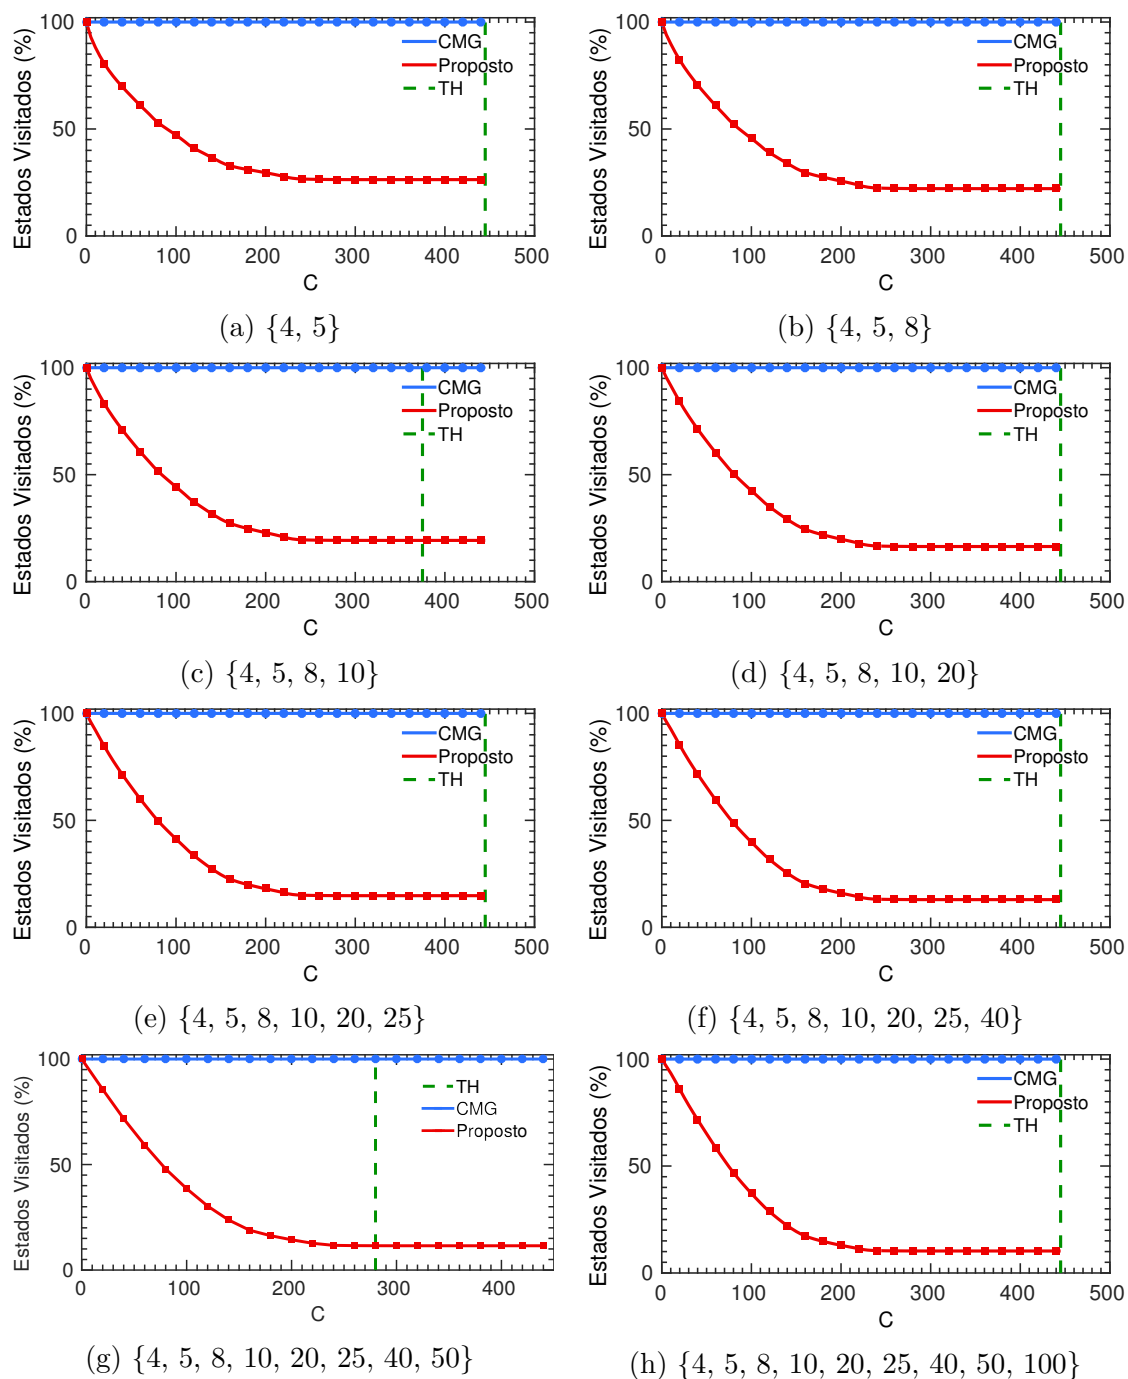


Figura 41 – Porcentagem de estados visitados pelo aumento de C (Base de imagens Brodatz), com classificador LDA (Grau médio 8).

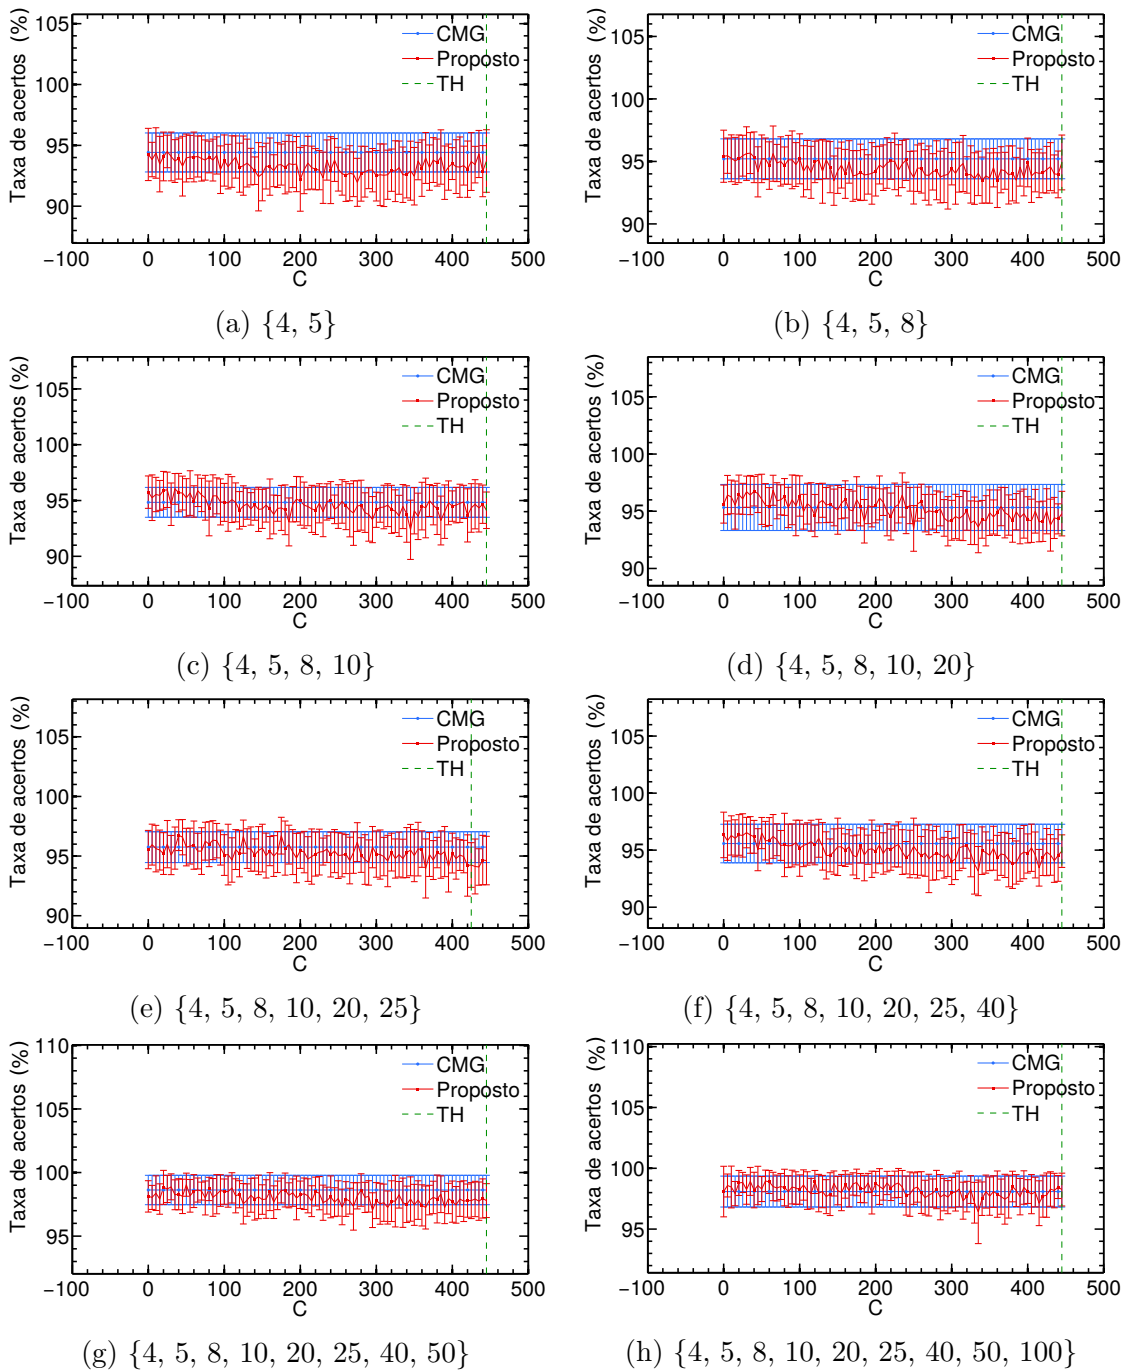


Figura 42 – Taxa de classificação com desvio padrão pelo aumento do parâmetro  $C$  (Base de imagens Brodatz), com classificador LDA (Grau médio 4).

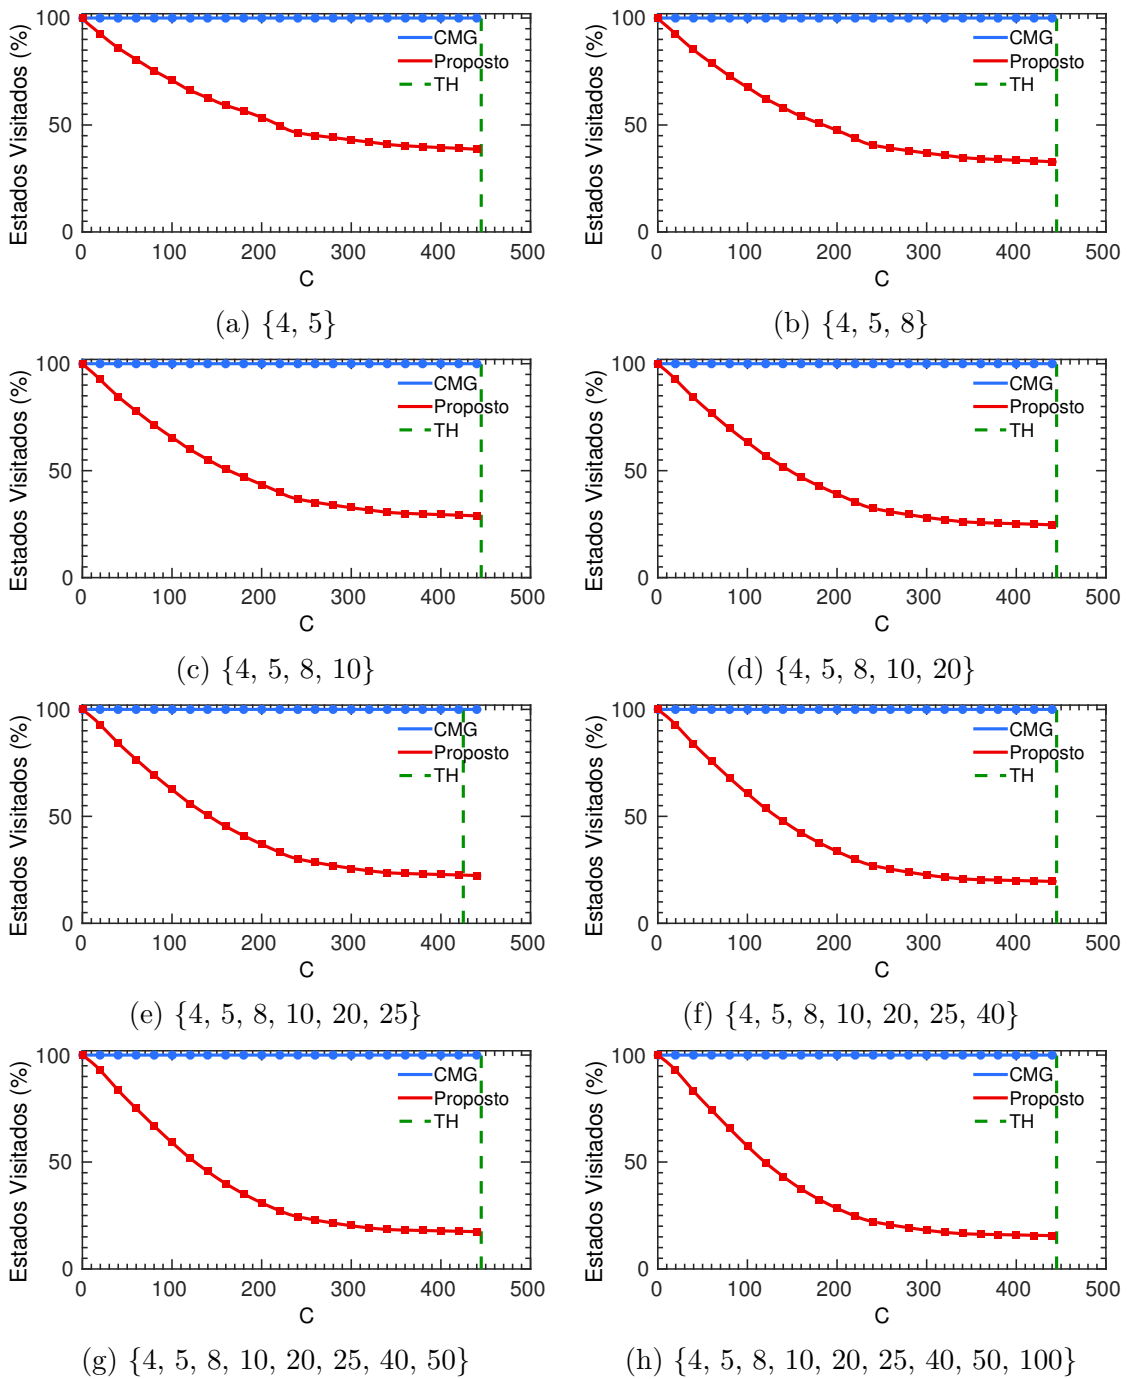


Figura 43 – Porcentagem de estados visitados pelo aumento de C (Base de imagens Brodatz), com classificador LDA (Grau médio 4).

# APÊNDICE B – Resultados Brodatz com MLP

## B.1 Grau médio 8

Os gráficos para diferentes configurações de janelas da Tabela 11 são mostrados a seguir.

### B.1.1 Taxa de classificação

A Figura 44 apresenta os resultados das taxas classificações para o banco Brodatz com diferentes configurações de janelas.

### B.1.2 Porcentagem de estados visitados

A Figura 45 apresenta os resultados dos estados visitados para o banco Brodatz com diferentes configurações de janelas.

## B.2 Grau médio 4

Os gráficos para diferentes configurações de janelas da Tabela 12 são mostrados a seguir.

### B.2.1 Taxa de classificação

A Figura 46 apresenta os resultados das taxas classificações para o banco Brodatz com diferentes configurações de janelas.

### B.2.2 Porcentagem de estados visitados

A Figura 47 apresenta os resultados dos estados visitados para o banco Brodatz com diferentes configurações de janelas.



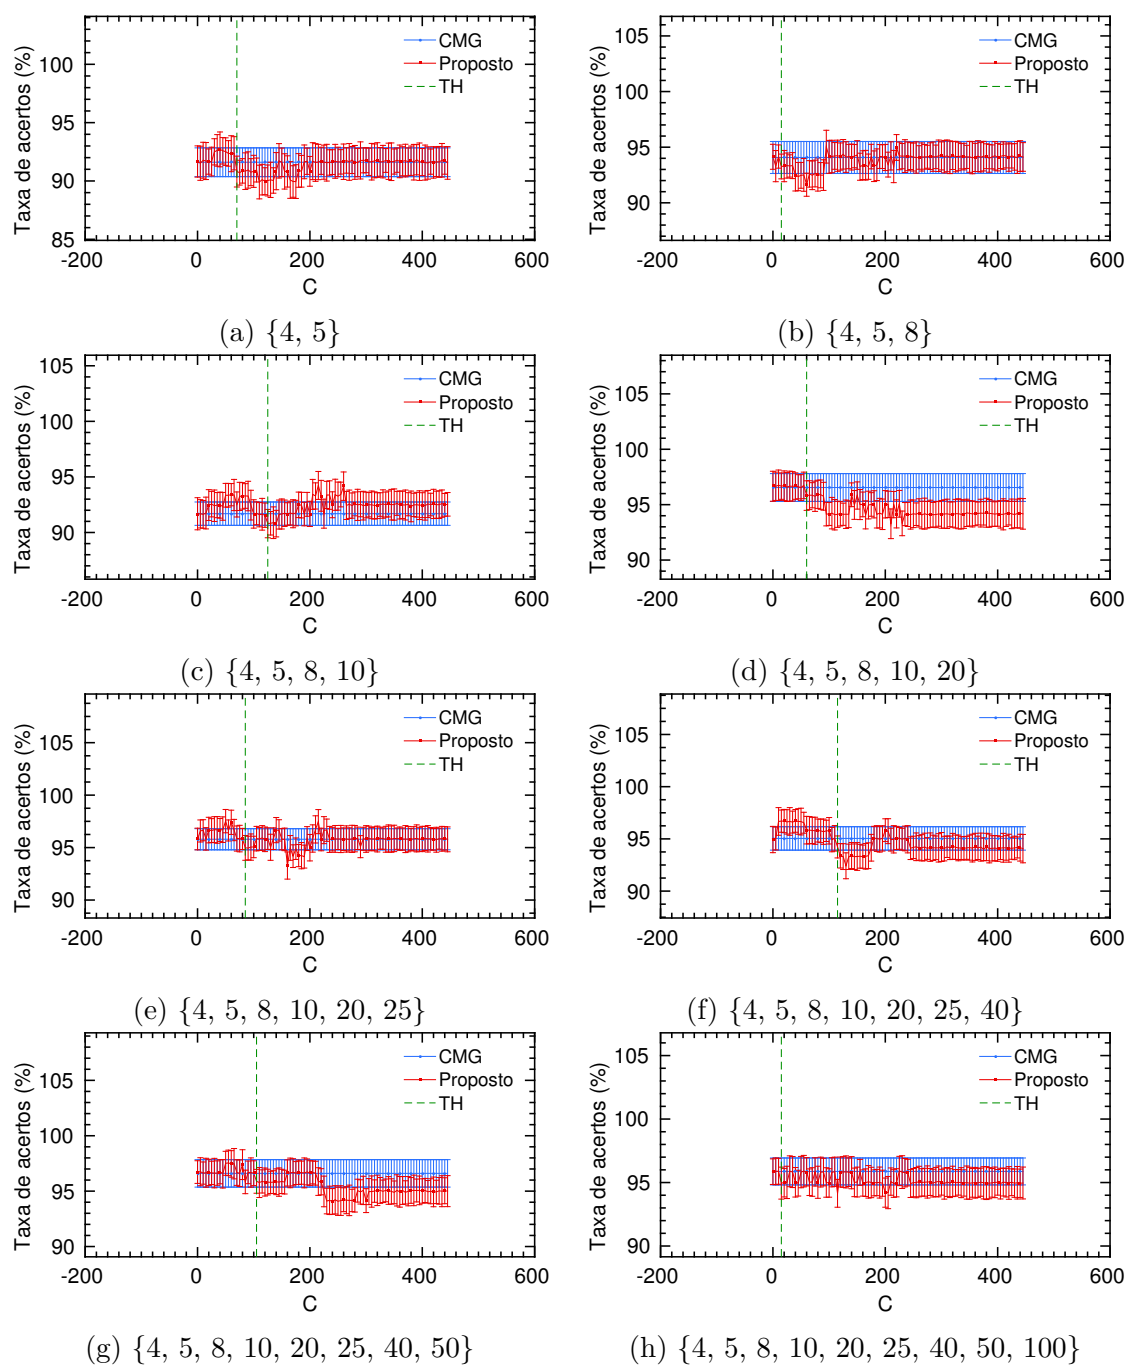


Figura 44 – Taxa de classificação com desvio padrão pelo aumento do parâmetro  $C$  (Base de imagens Brodatz), com classificador MLP (Grau médio 8).

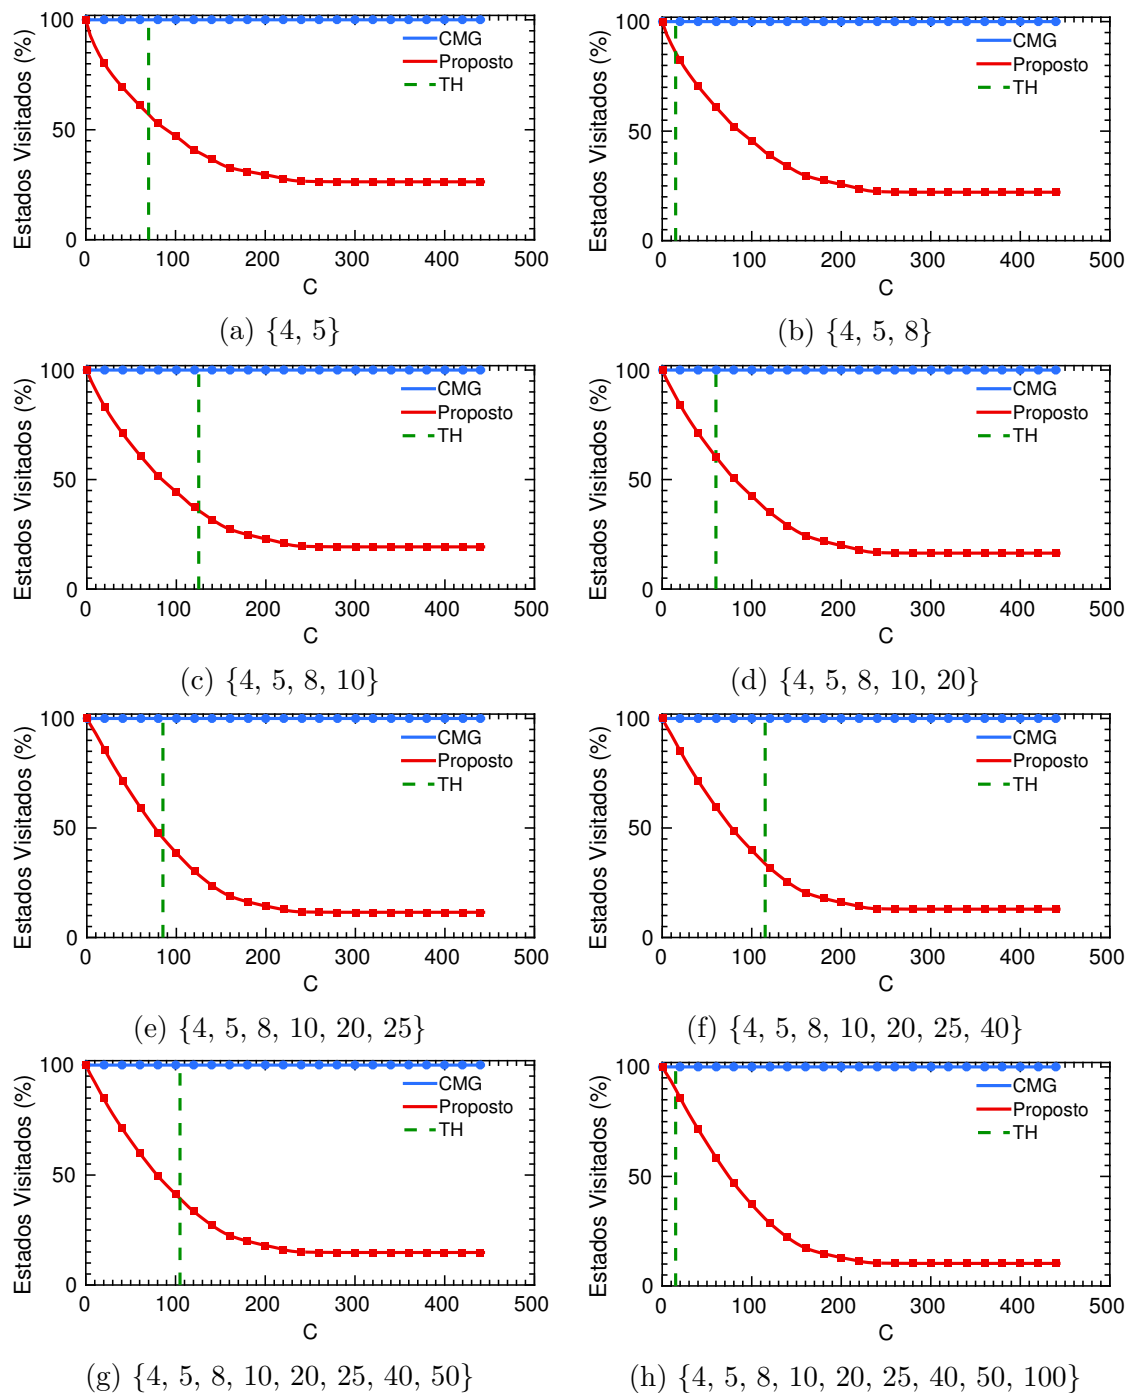


Figura 45 – Porcentagem de estados visitados pelo aumento de C (Base de imagens Brodatz), com classificador MLP (Grau médio 8).

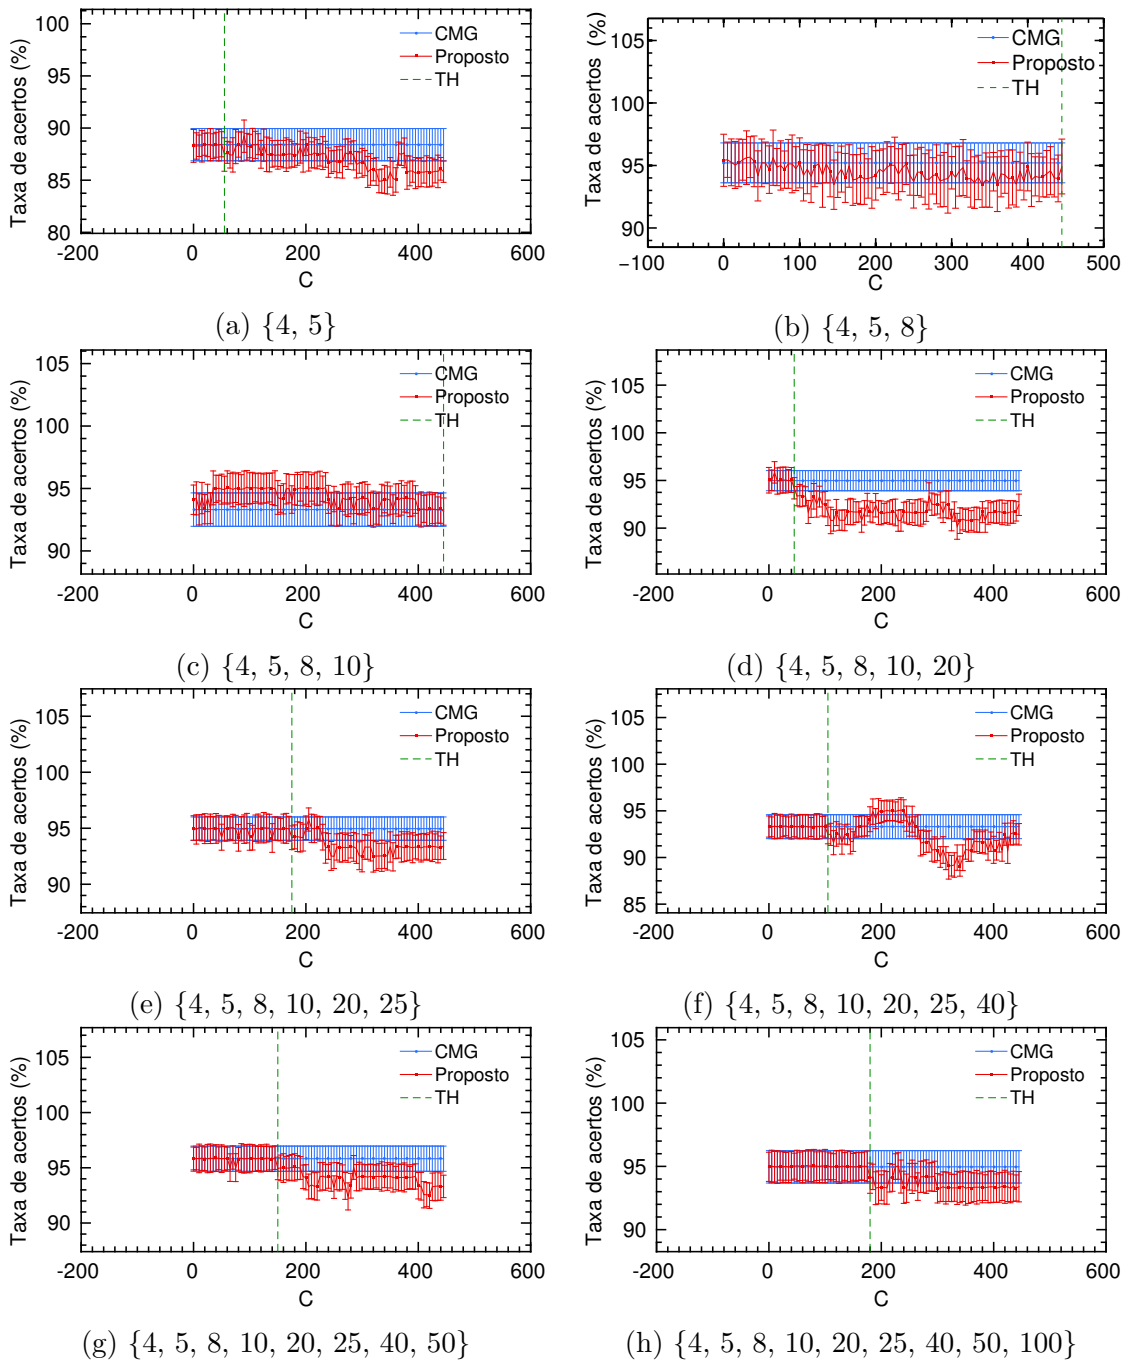


Figura 46 – Taxa de classificação com desvio padrão pelo aumento do parâmetro  $C$  (Base de imagens Brodatz), com classificador MLP (Grau médio 4).

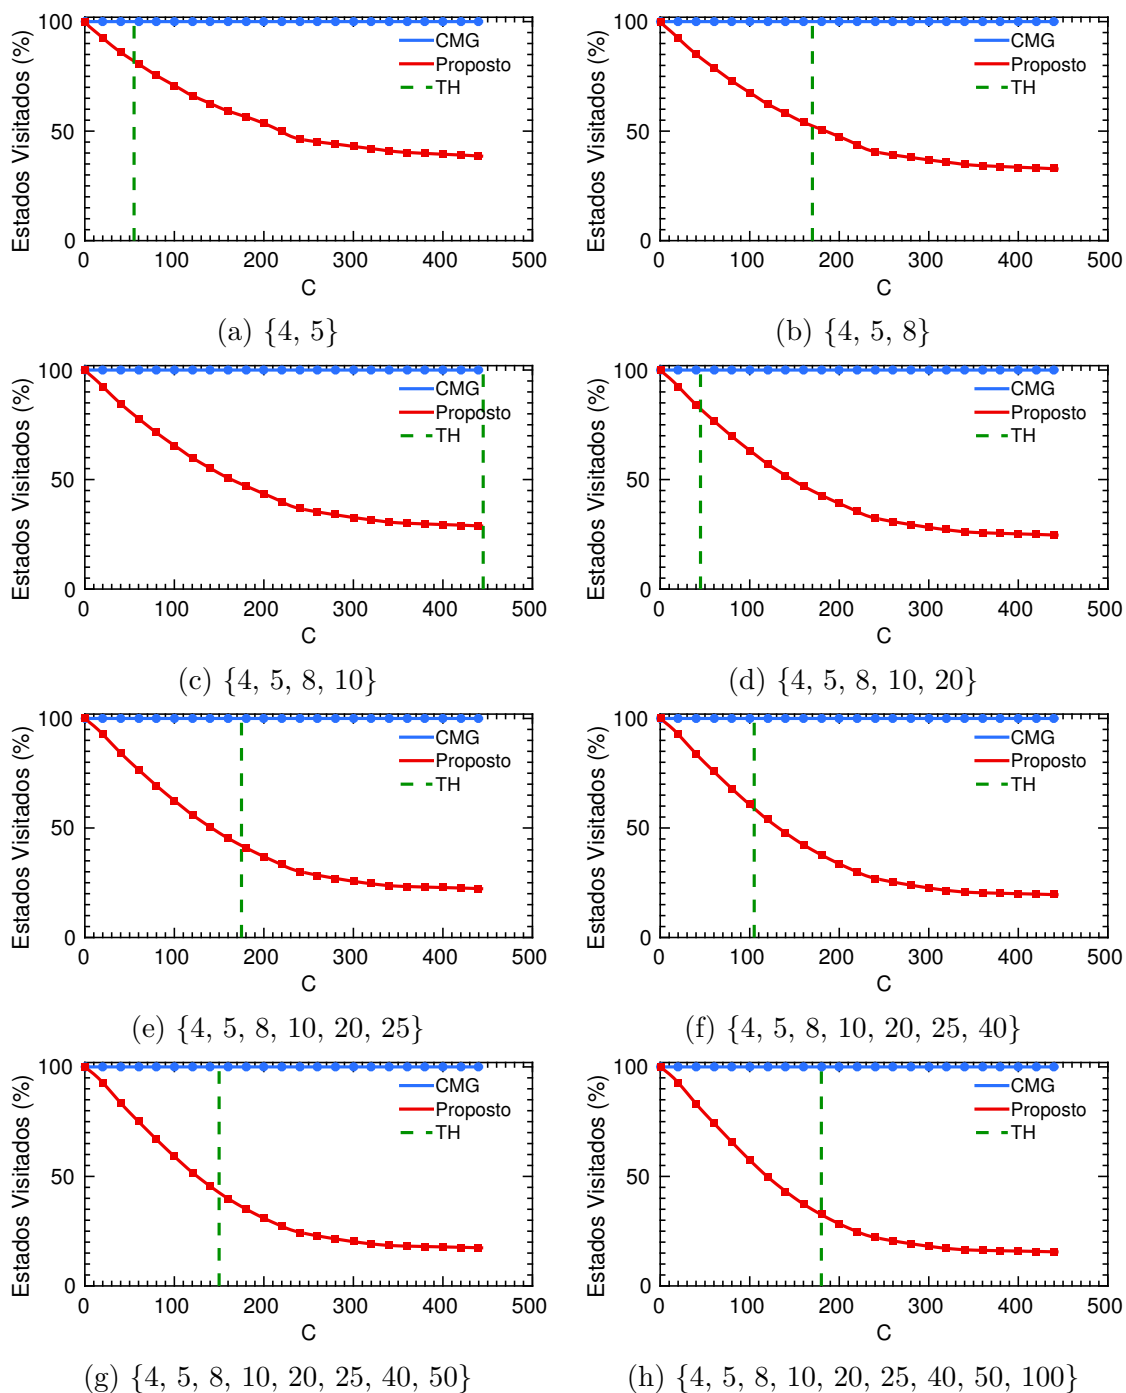


Figura 47 – Porcentagem de estados visitados pelo aumento de C (Base de imagens Brodatz), com classificador MLP (Grau médio 4).

# APÊNDICE C – Resultados UIUC com LDA

## C.1 Grau médio 8

Os gráficos para diferentes configurações de janelas da Tabela 5 são mostrados a seguir.

### C.1.1 Taxa de classificação

A Figura 48 apresenta os resultados das taxas classificações para o banco UIUC com diferentes configurações de janelas.

### C.1.2 Porcentagem de estados visitados

A Figura 49 apresenta os resultados dos estados visitados para o banco UIUC com diferentes configurações de janelas.

## C.2 Grau médio 4

Os gráficos para diferentes configurações de janelas da Tabela 4 são mostrados a seguir.

### C.2.1 Taxa de classificação

A Figura 50 apresenta os resultados das taxas classificações para o banco UIUC com diferentes configurações de janelas.

### C.2.2 Porcentagem de estados visitados

A Figura 51 apresenta os resultados dos estados visitados para o banco UIUC com diferentes configurações de janelas.

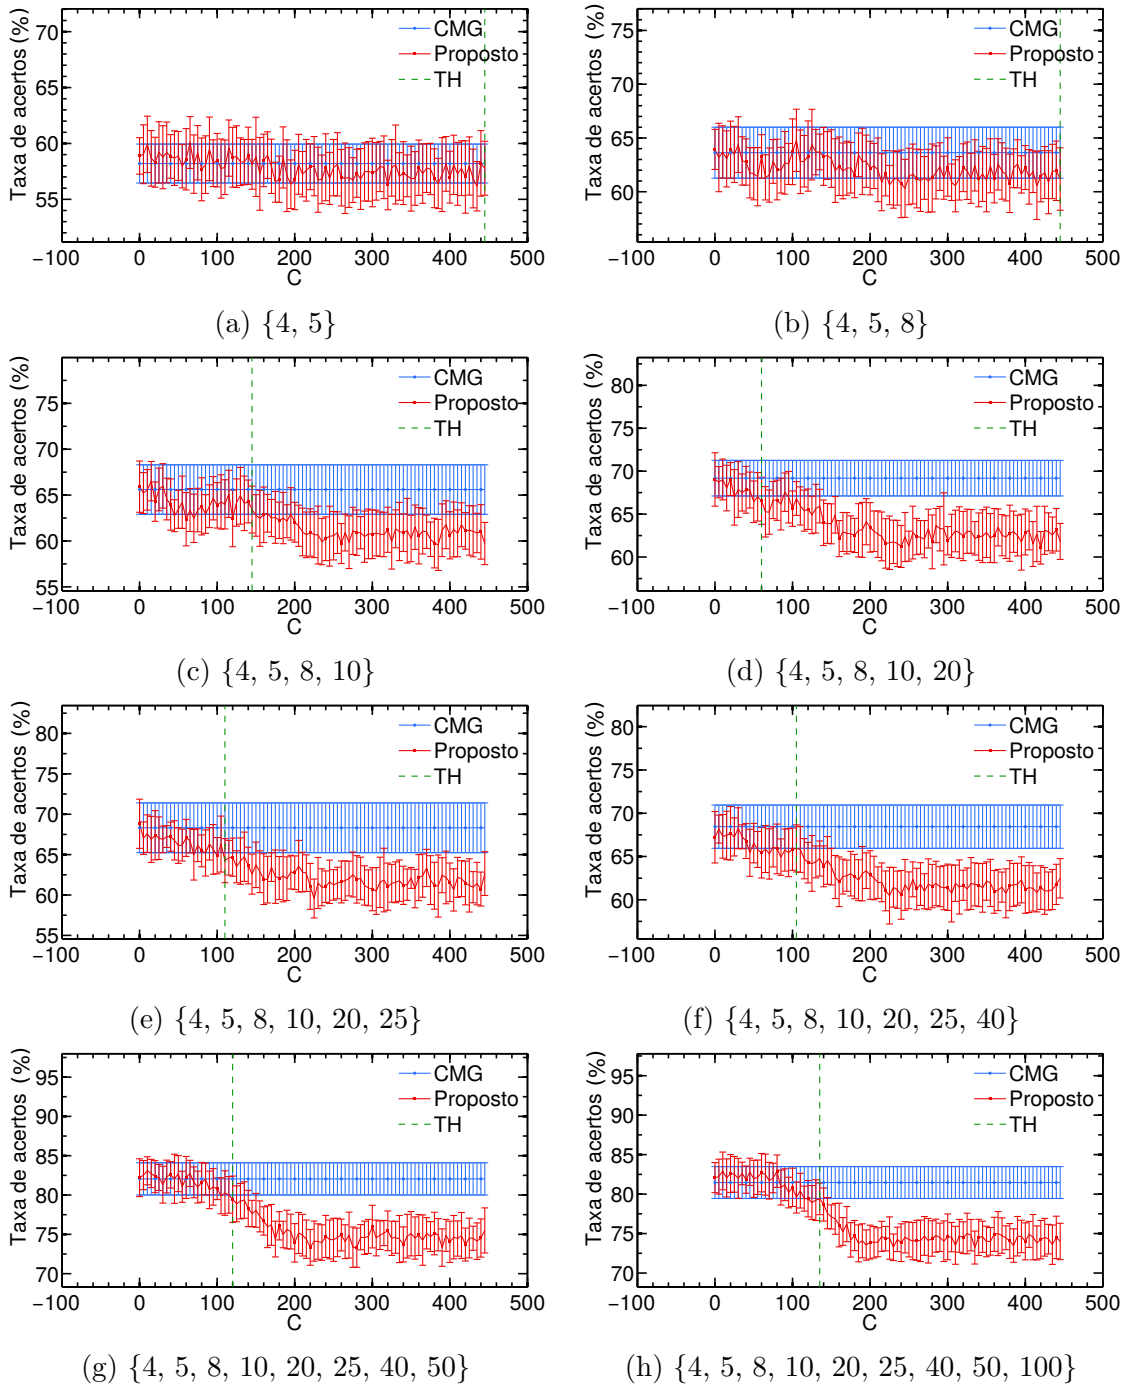


Figura 48 – Taxa de classificação com desvio padrão pelo aumento do parâmetro  $C$  (Base de imagens UIUC), com classificador LDA (Grau médio 8).

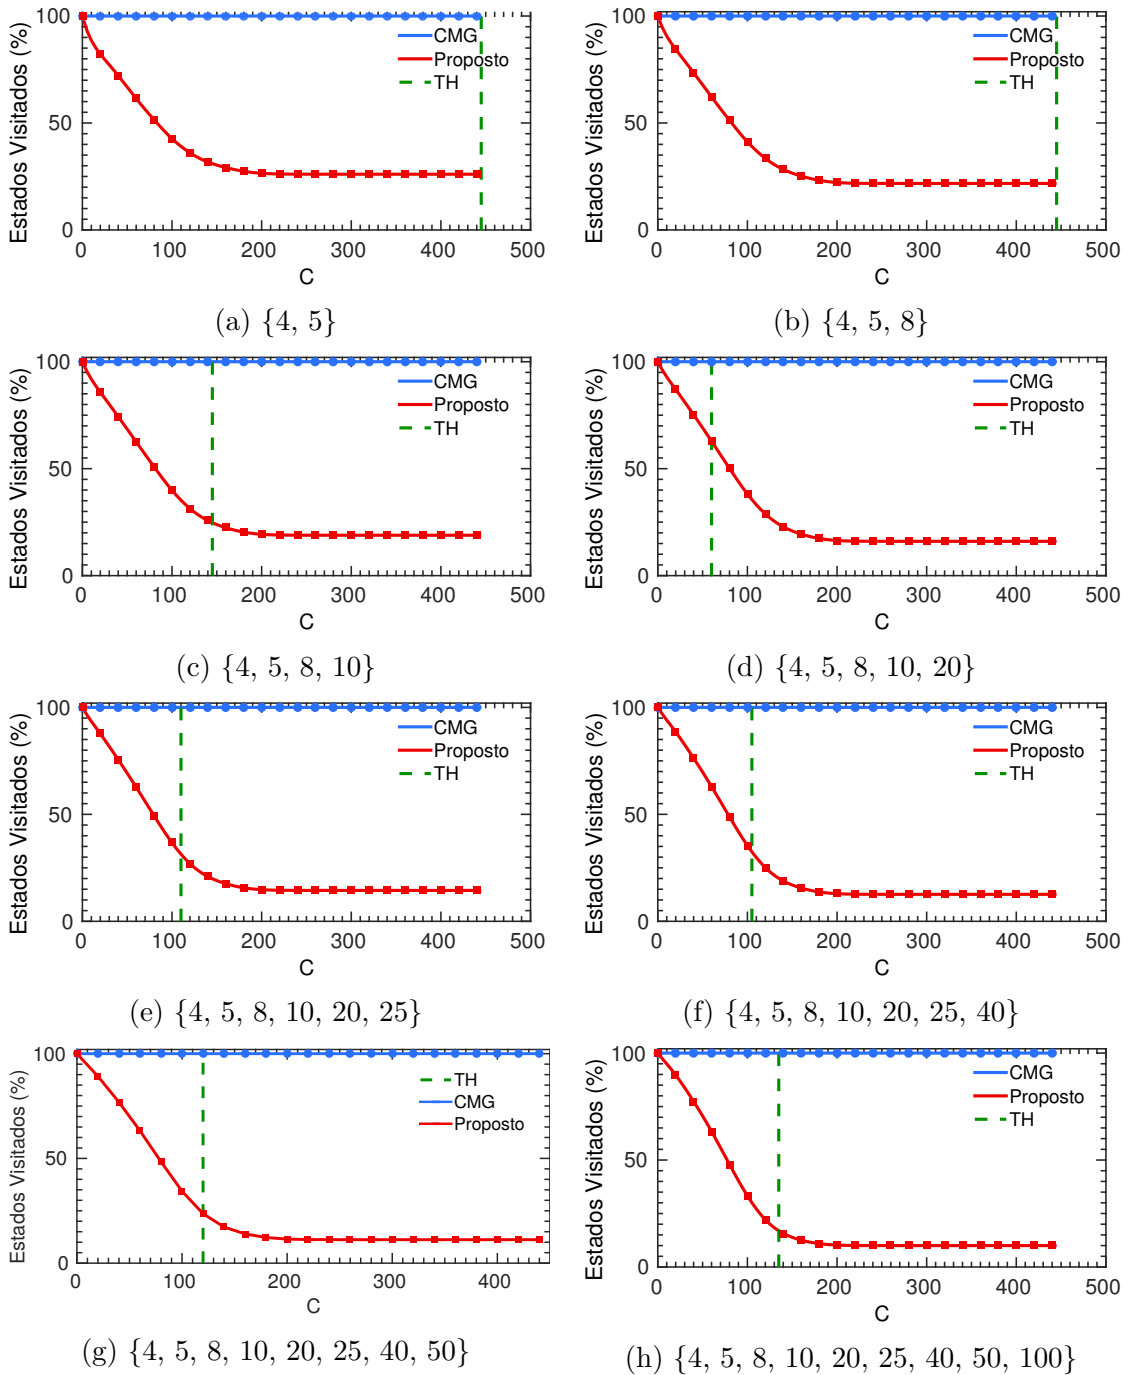


Figura 49 – Porcentagem de estados visitados pelo aumento de C (Base de imagens UIUC), com classificador LDA (Grau médio 8).

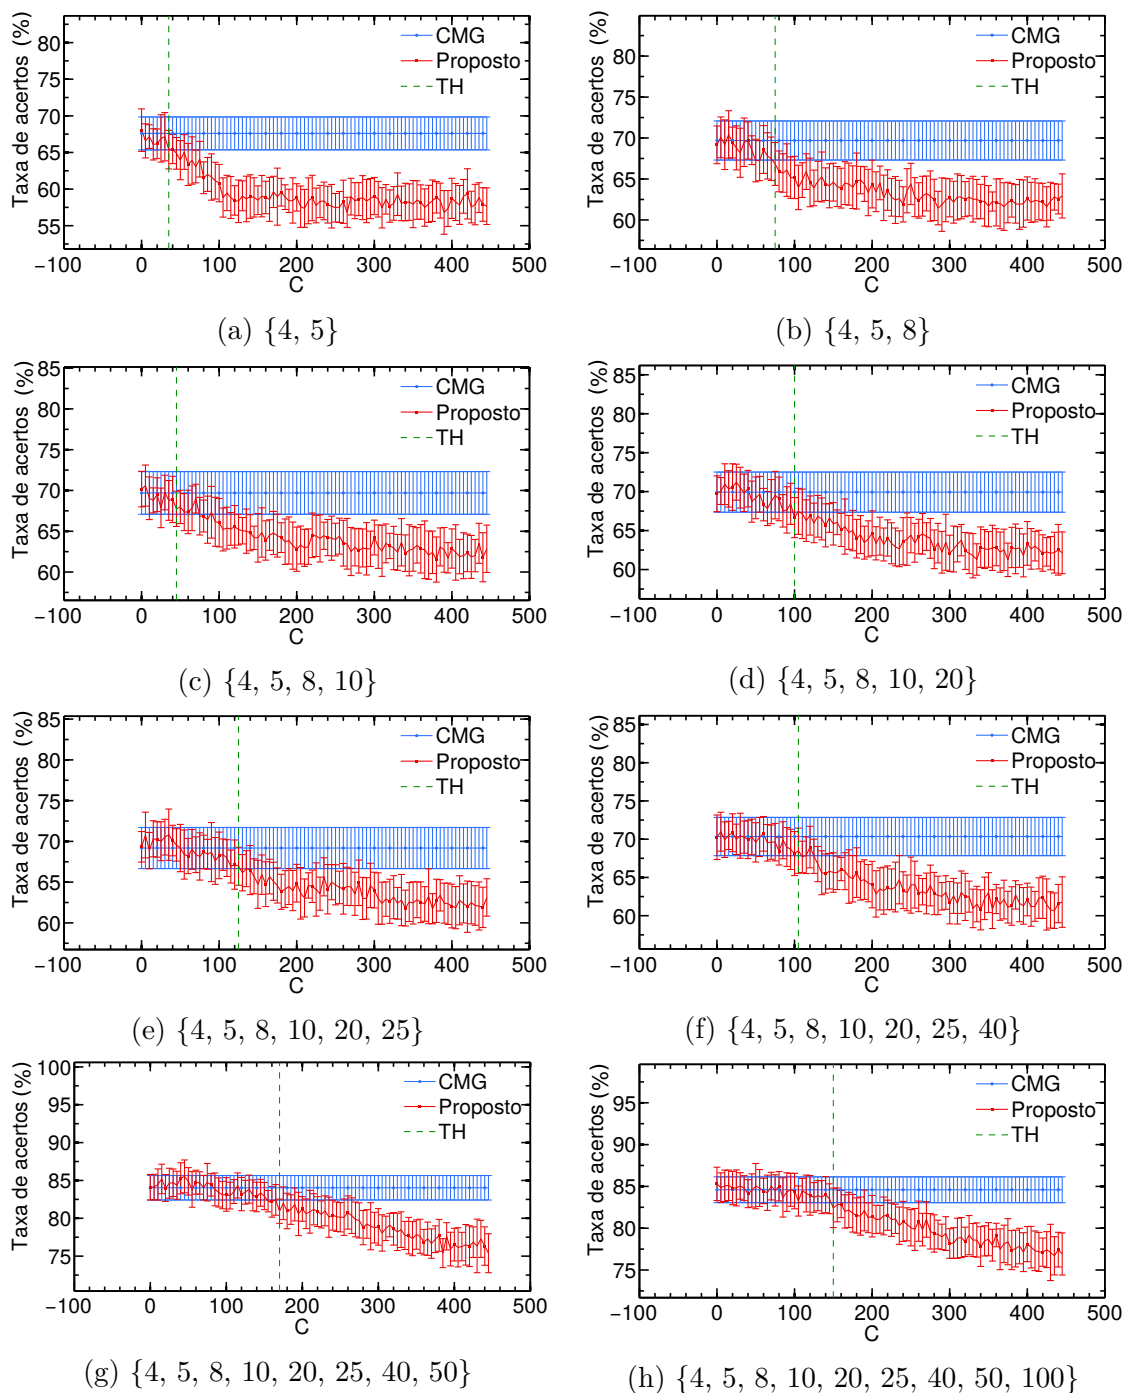


Figura 50 – Taxa de classificação com desvio padrão pelo aumento do parâmetro  $C$  (Base de imagens UIUC), com classificador LDA (Grau médio 4).



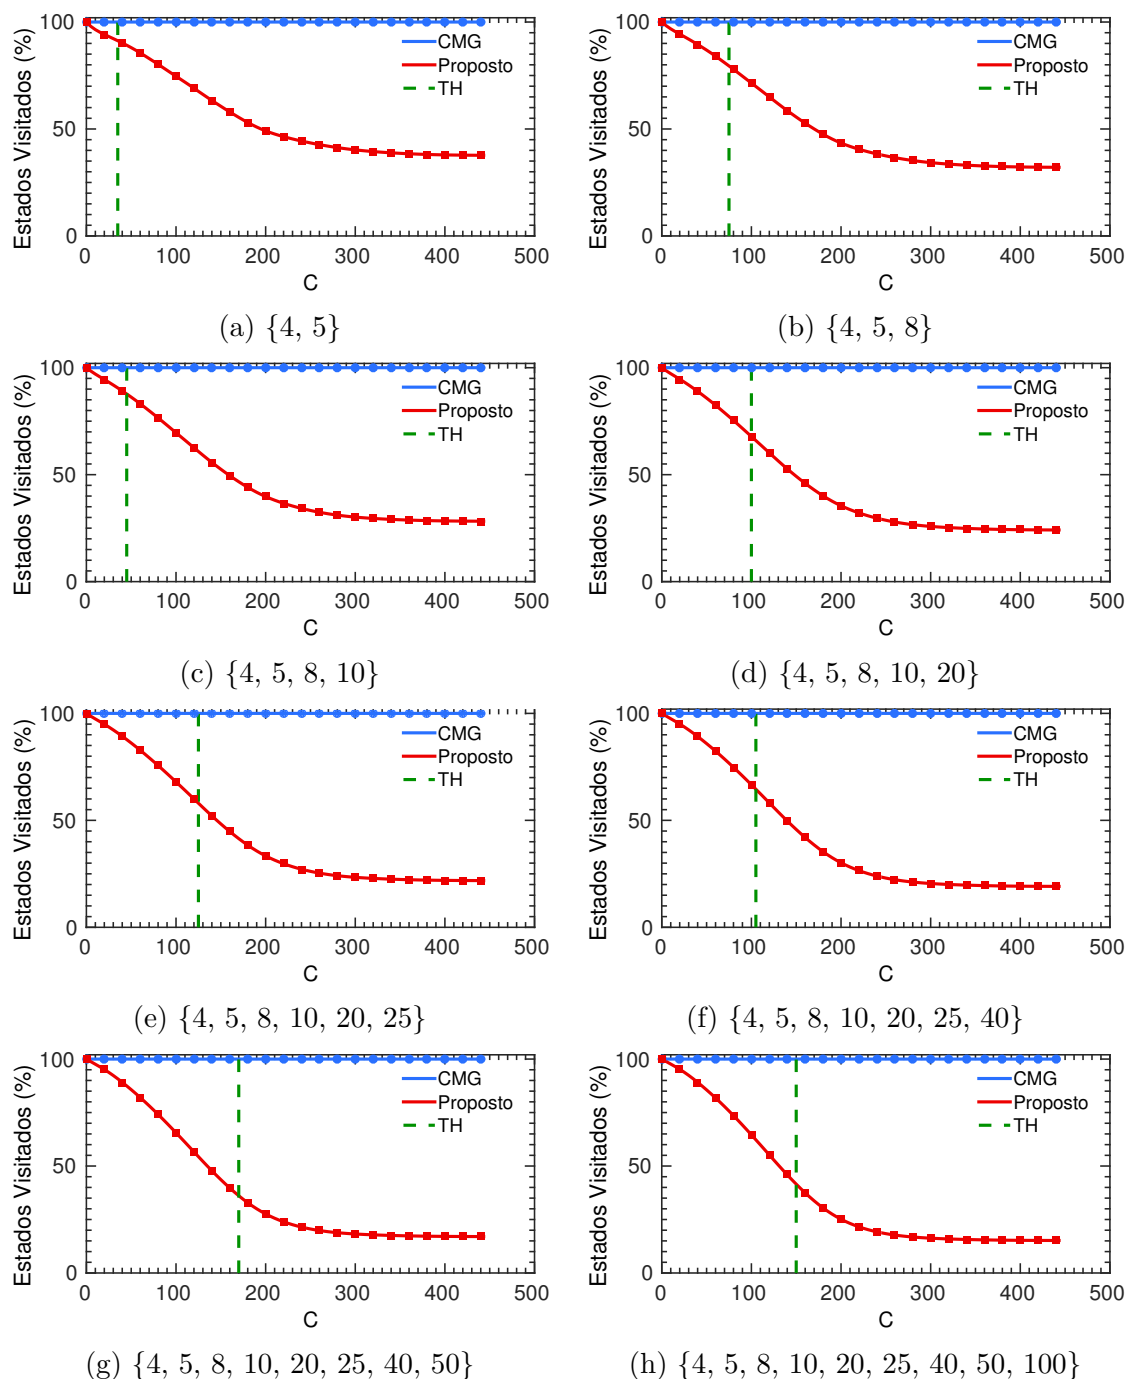


Figura 51 – Porcentagem de estados visitados pelo aumento de C (Base de imagens UIUC), com classificador LDA (Grau médio 4).

# APÊNDICE D – Resultados UIUC com MLP

## D.1 Grau médio 8

Os gráficos para diferentes configurações de janelas da Tabela 13 são mostrados a seguir.

### D.1.1 Taxa de classificação

A Figura 52 apresenta os resultados das taxas classificações para o banco UIUC com diferentes configurações de janelas.

### D.1.2 Porcentagem de estados visitados

A Figura 53 apresenta os resultados dos estados visitados para o banco UIUC com diferentes configurações de janelas.

## D.2 Grau médio 4

Os gráficos para diferentes configurações de janelas da Tabela 14 são mostrados a seguir.

### D.2.1 Taxa de classificação

A Figura 54 apresenta os resultados das taxas classificações para o banco UIUC com diferentes configurações de janelas.

### D.2.2 Porcentagem de estados visitados

A Figura 55 apresenta os resultados dos estados visitados para o banco UIUC com diferentes configurações de janelas.

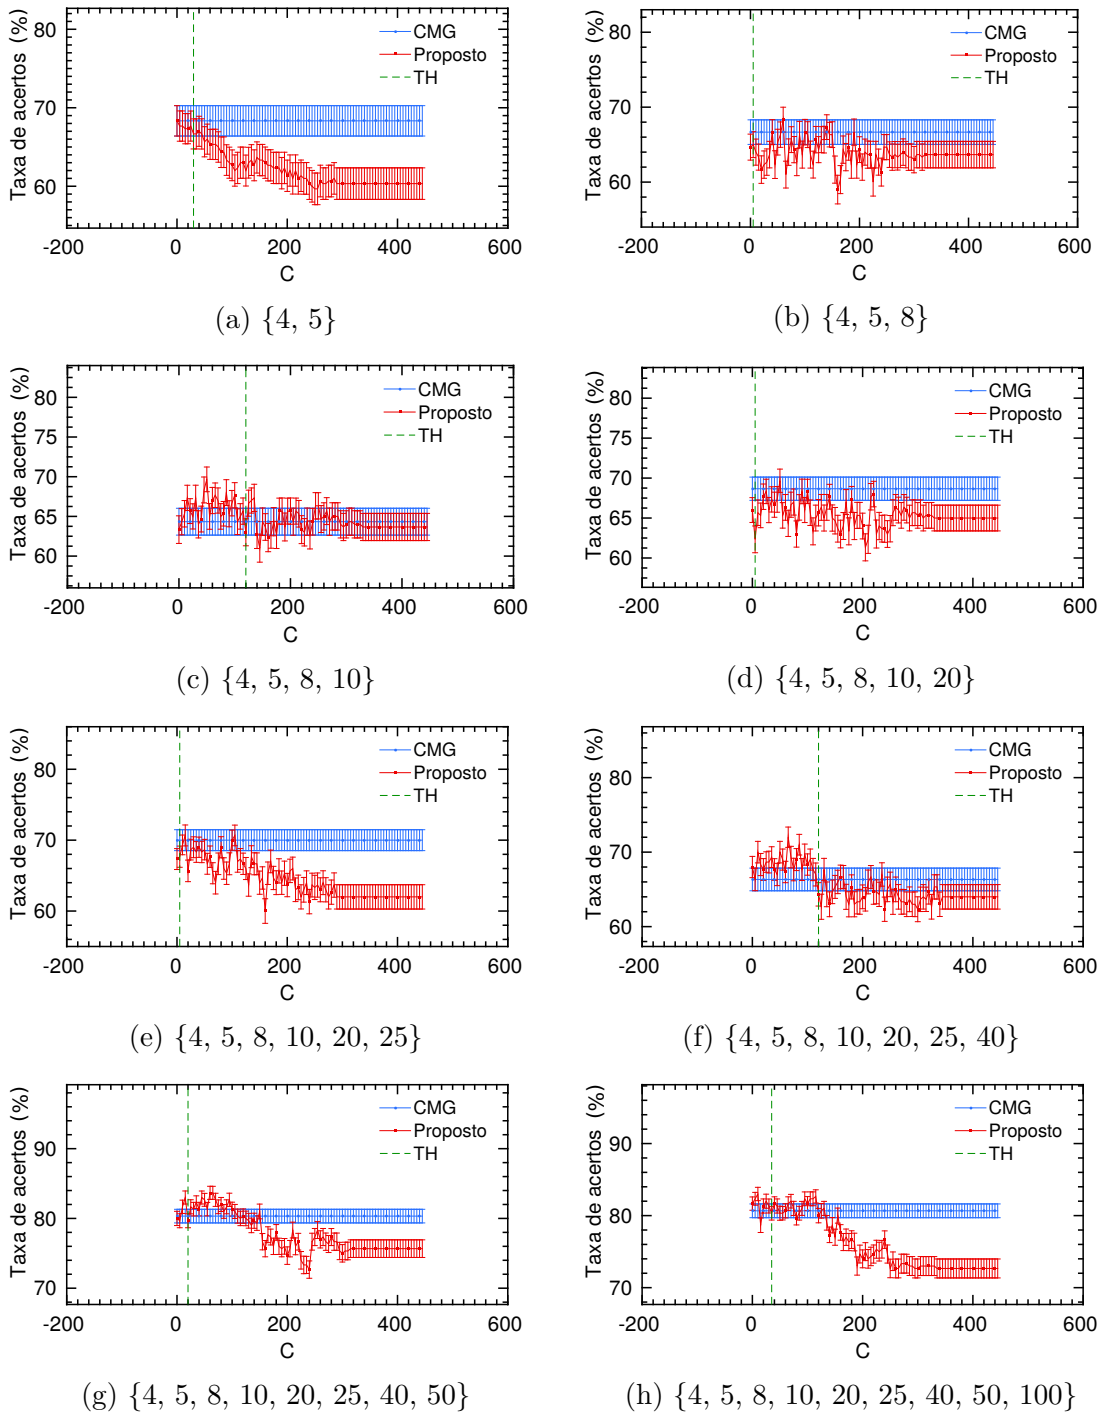


Figura 52 – Taxa de classificação com desvio padrão pelo aumento do parâmetro  $C$  (Base de imagens UIUC), com classificador MLP (Grau médio 8).

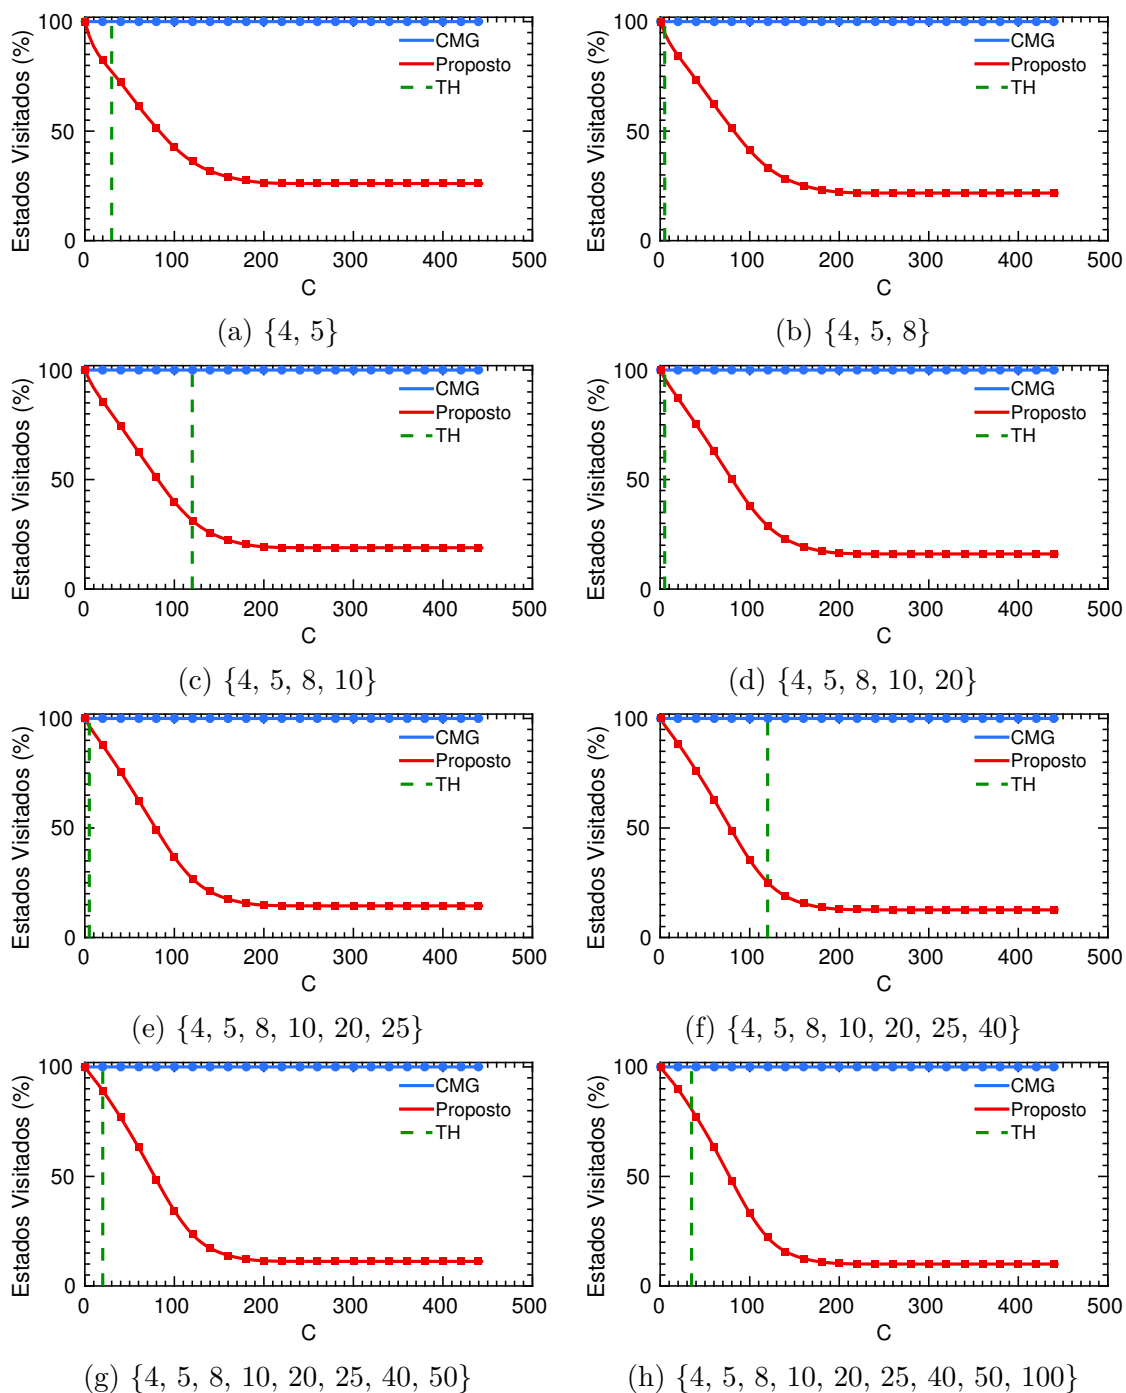


Figura 53 – Porcentagem de estados visitados pelo aumento de C (Base de imagens UIUC), com classificador MLP (Grau médio 8).

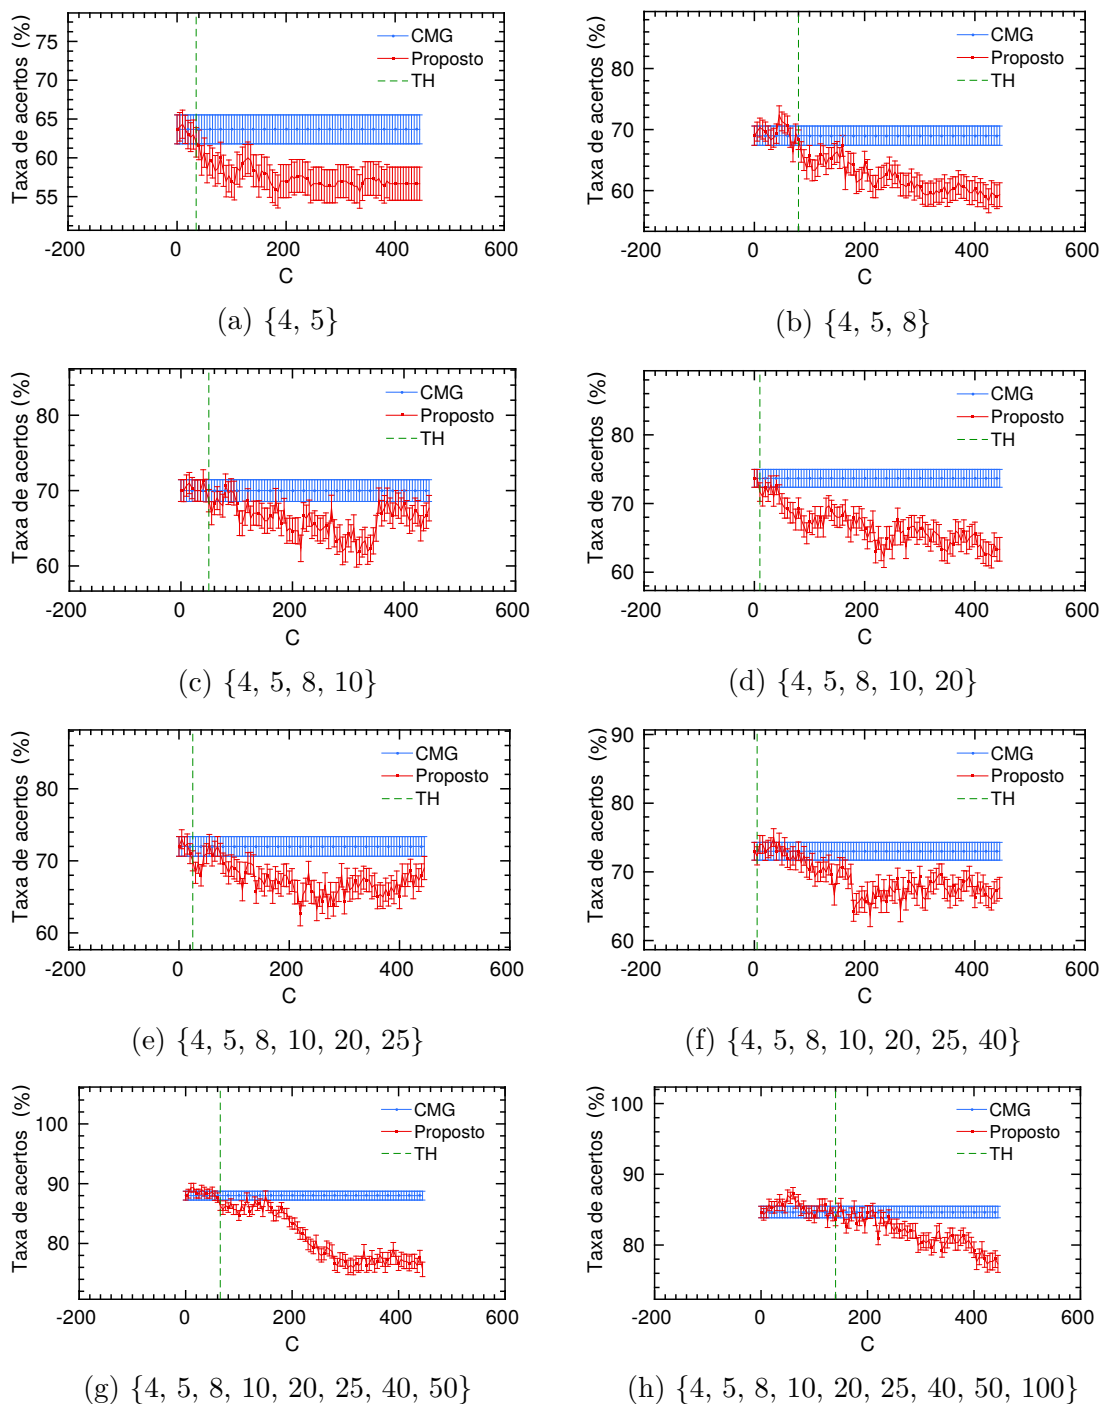


Figura 54 – Taxa de classificação com desvio padrão pelo aumento do parâmetro  $C$  (Base de imagens UIUC), com classificador MLP (Grau médio 4).

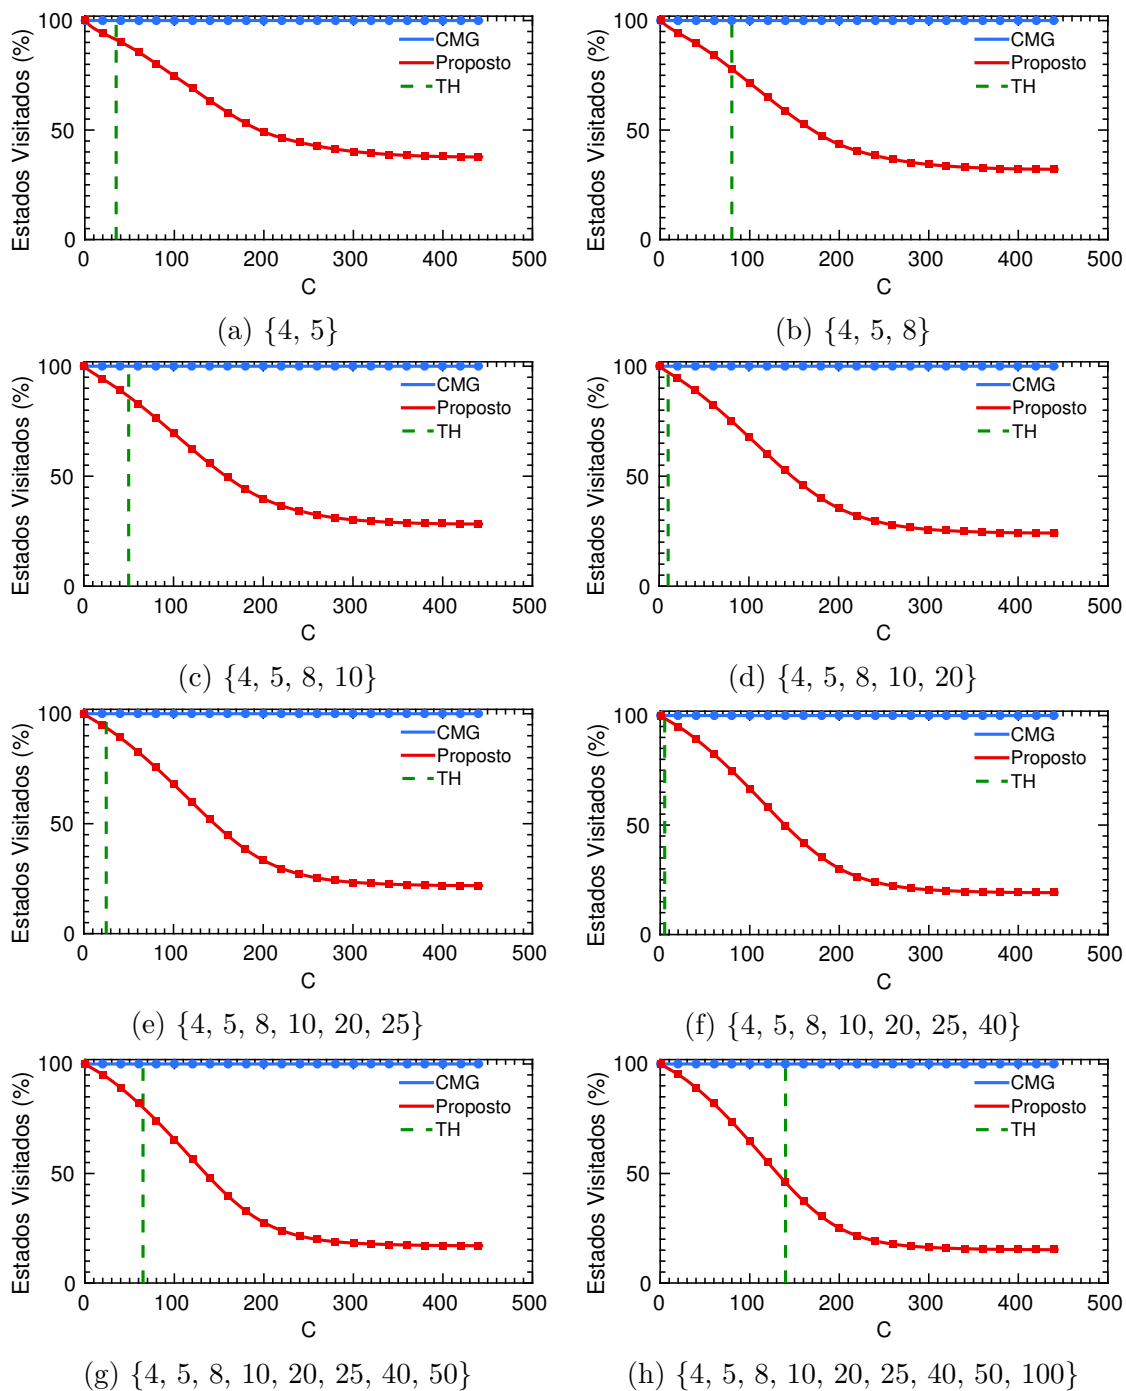


Figura 55 – Porcentagem de estados visitados pelo aumento de C (Base de imagens UIUC), com classificador MLP (Grau médio 4).

# APÊNDICE E – Resultados 2D HeLa com LDA

## E.1 Grau médio 8

Os gráficos para diferentes configurações de janelas da Tabela 8 são mostrados a seguir.

### E.1.1 Taxa de classificação

A Figura 56 apresenta os resultados das taxas classificações para o banco 2D HeLa com diferentes configurações de janelas.

### E.1.2 Porcentagem de estados visitados

A Figura 57 apresenta os resultados dos estados visitados para o banco 2D HeLa com diferentes configurações de janelas.

## E.2 Grau médio 4

Os gráficos para diferentes configurações de janelas da Tabela 9 são mostrados a seguir.

### E.2.1 Taxa de classificação

A Figura 58 apresenta os resultados das taxas classificações para o banco 2D HeLa com diferentes configurações de janelas.

### E.2.2 Porcentagem de estados visitados

A Figura 59 apresenta os resultados dos estados visitados para o banco 2D HeLa com diferentes configurações de janelas.

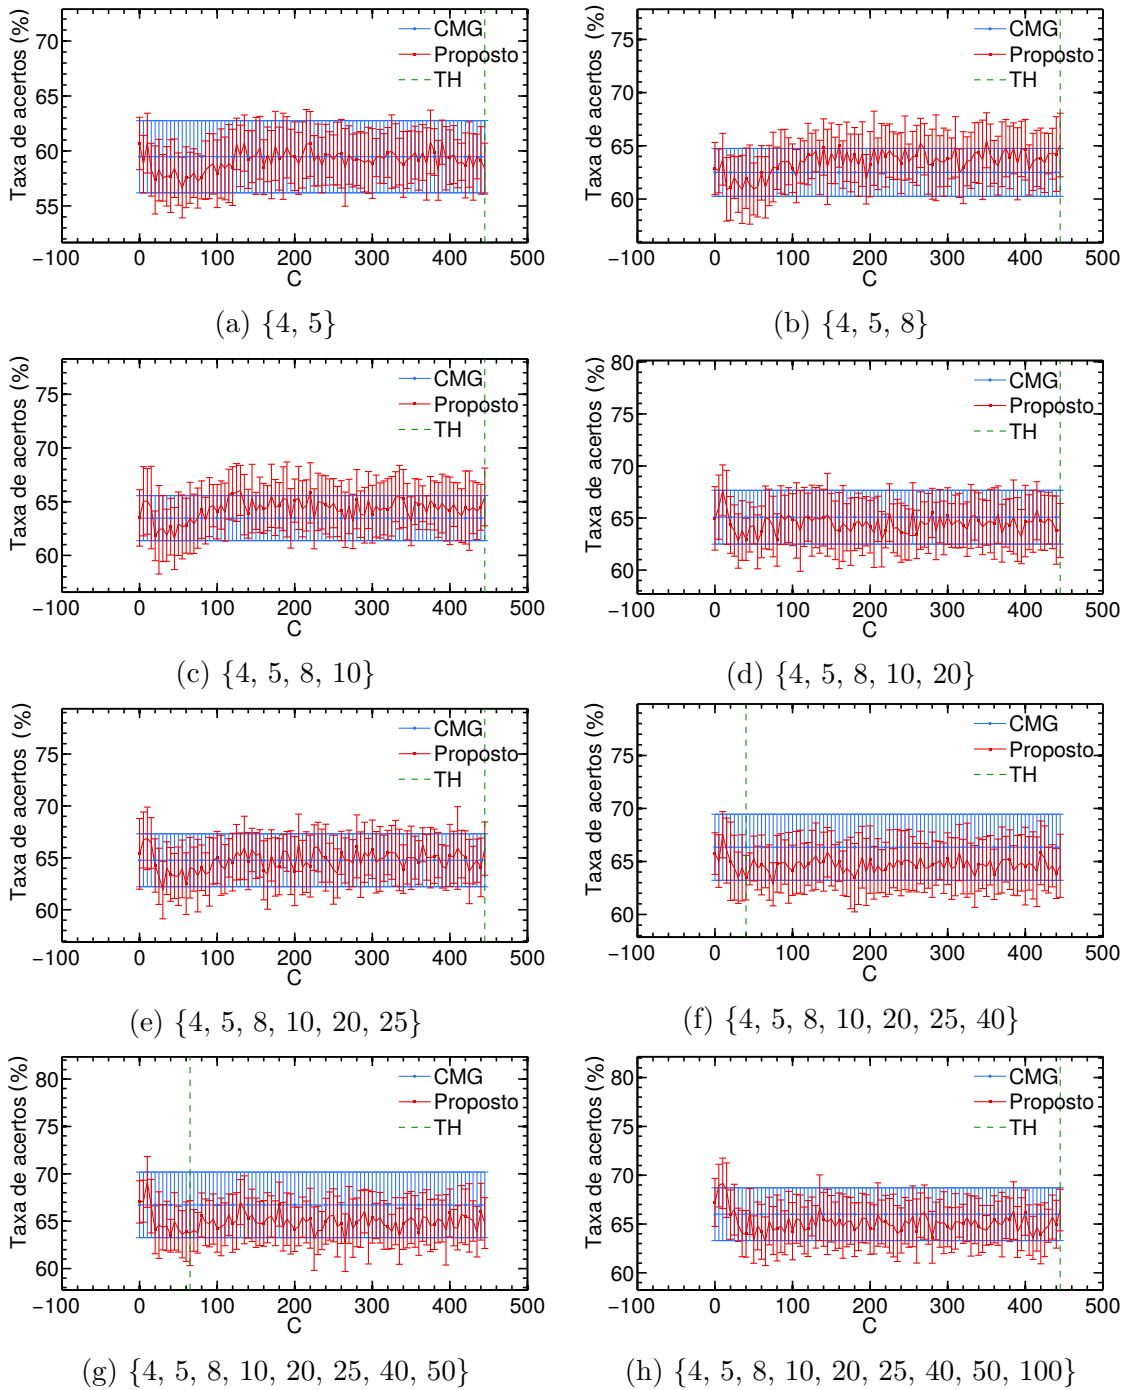


Figura 56 – Taxa de classificação com desvio padrão pelo aumento do parâmetro  $C$  (Base de imagens 2D HeLa), com classificador LDA (Grau médio 8).



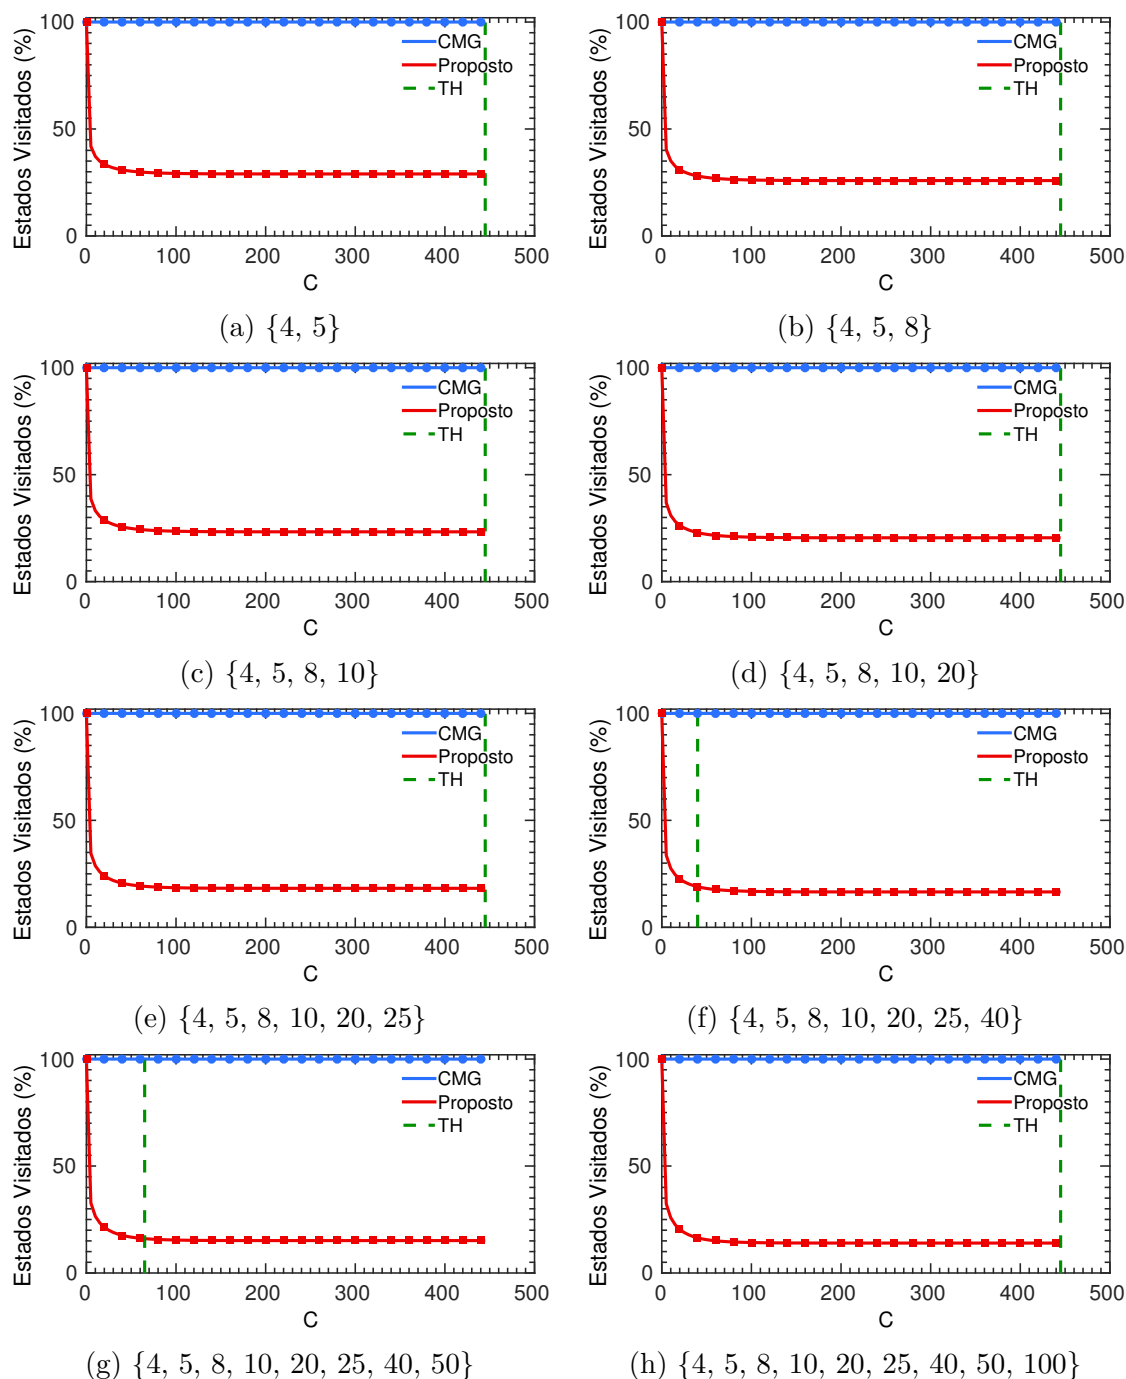


Figura 57 – Porcentagem de estados visitados pelo aumento de C (Base de imagens 2D HeLa), com classificador LDA (Grau médio 8).

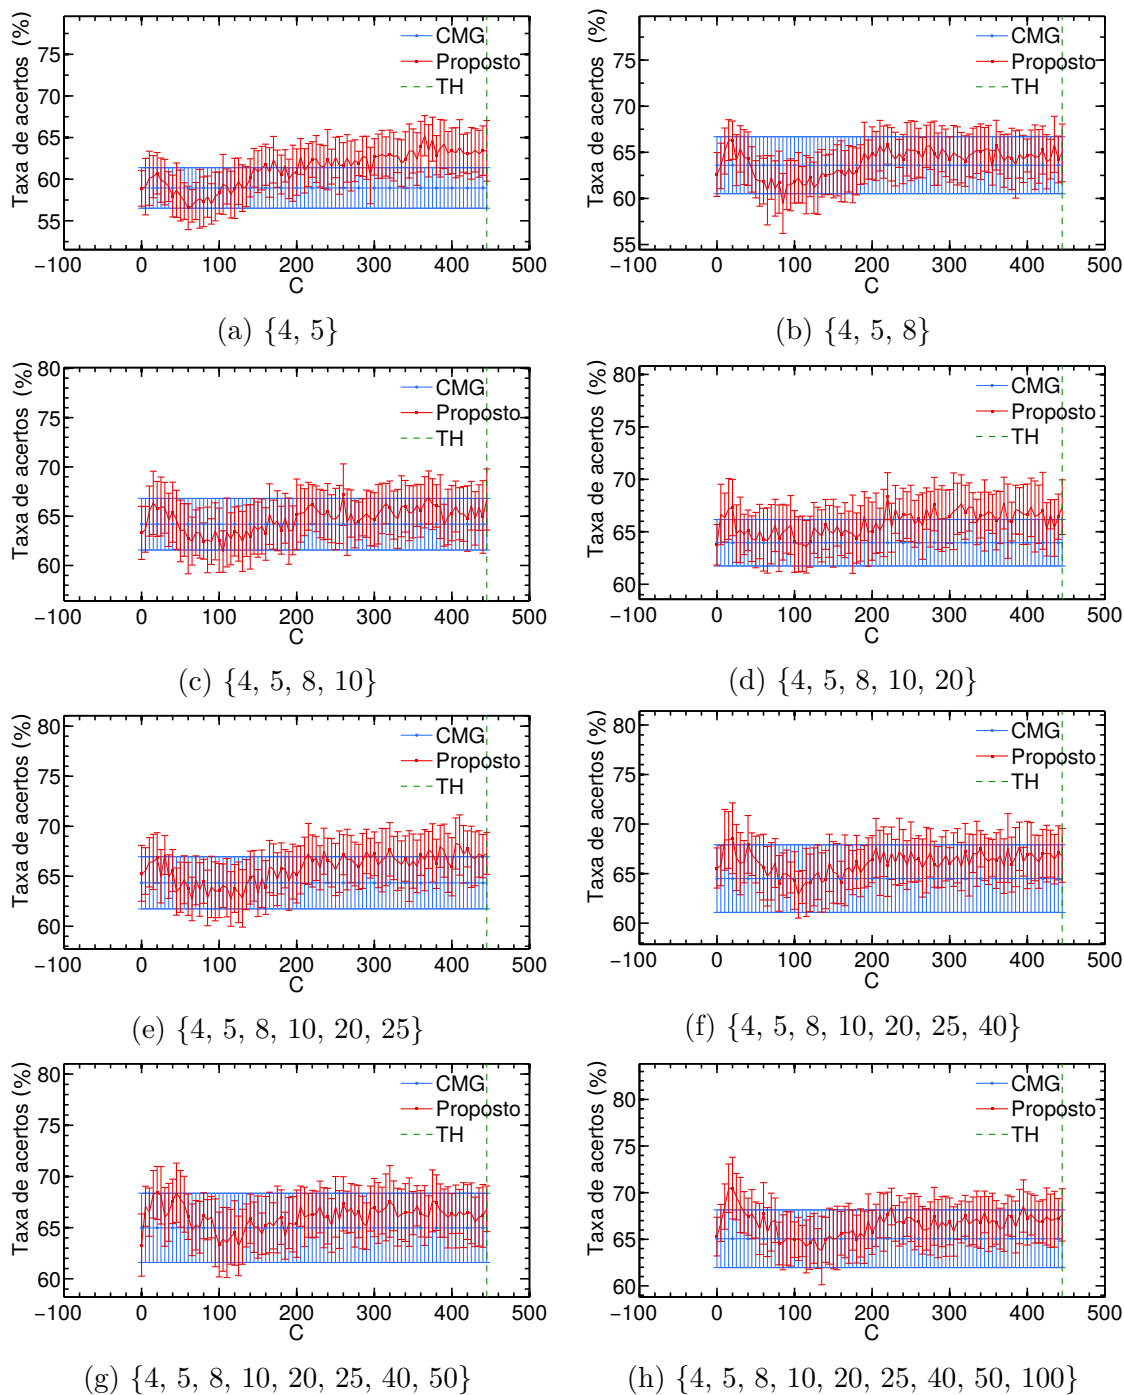


Figura 58 – Taxa de classificação com desvio padrão pelo aumento do parâmetro  $C$  (Base de imagens 2D HeLa), com classificador LDA (Grau médio 4).

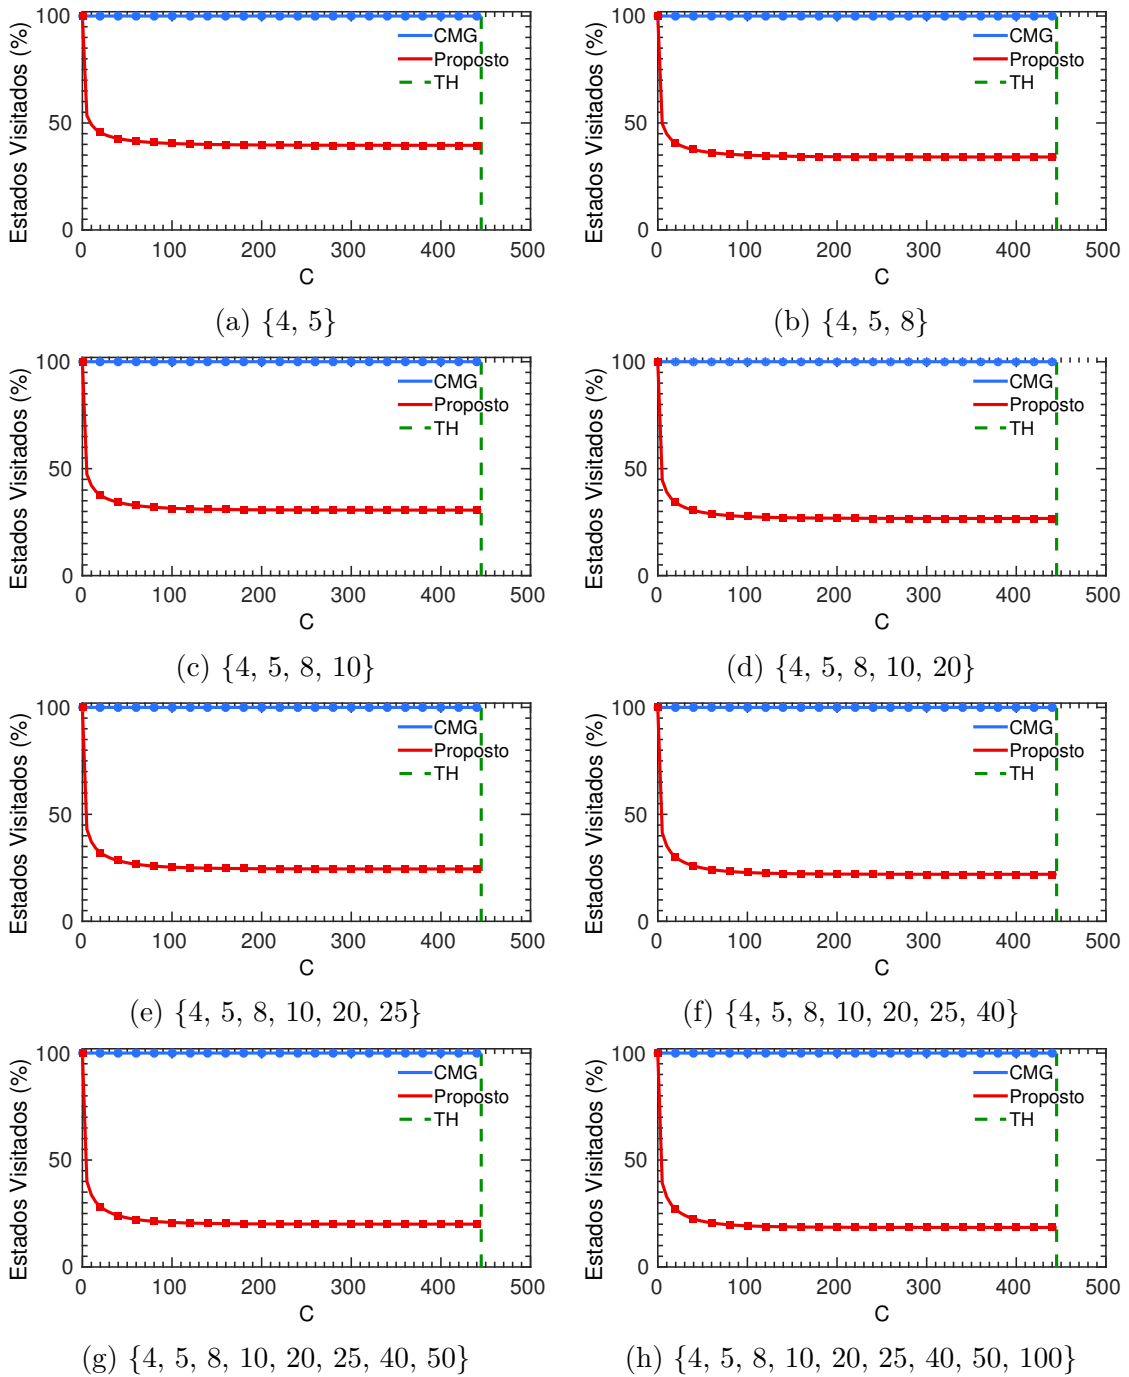


Figura 59 – Porcentagem de estados visitados pelo aumento de C (Base de imagens 2D HeLa), com classificador LDA (Grau médio 4).

# APÊNDICE F – Resultados 2D HeLa com MLP

## F.1 Grau médio 8

Os gráficos para diferentes configurações de janelas da Tabela 17 são mostrados a seguir.

### F.1.1 Taxa de classificação

A Figura 60 apresenta os resultados das taxas classificações para o banco 2D HeLa com diferentes configurações de janelas.

### F.1.2 Porcentagem de estados visitados

A Figura 61 apresenta os resultados dos estados visitados para o banco 2D HeLa com diferentes configurações de janelas.

## F.2 Grau médio 4

Os gráficos para diferentes configurações de janelas da Tabela 18 são mostrados a seguir.

### F.2.1 Taxa de classificação

A Figura 62 apresenta os resultados das taxas classificações para o banco 2D HeLa com diferentes configurações de janelas.

### F.2.2 Porcentagem de estados visitados

A Figura 63 apresenta os resultados dos estados visitados para o banco 2D HeLa com diferentes configurações de janelas.

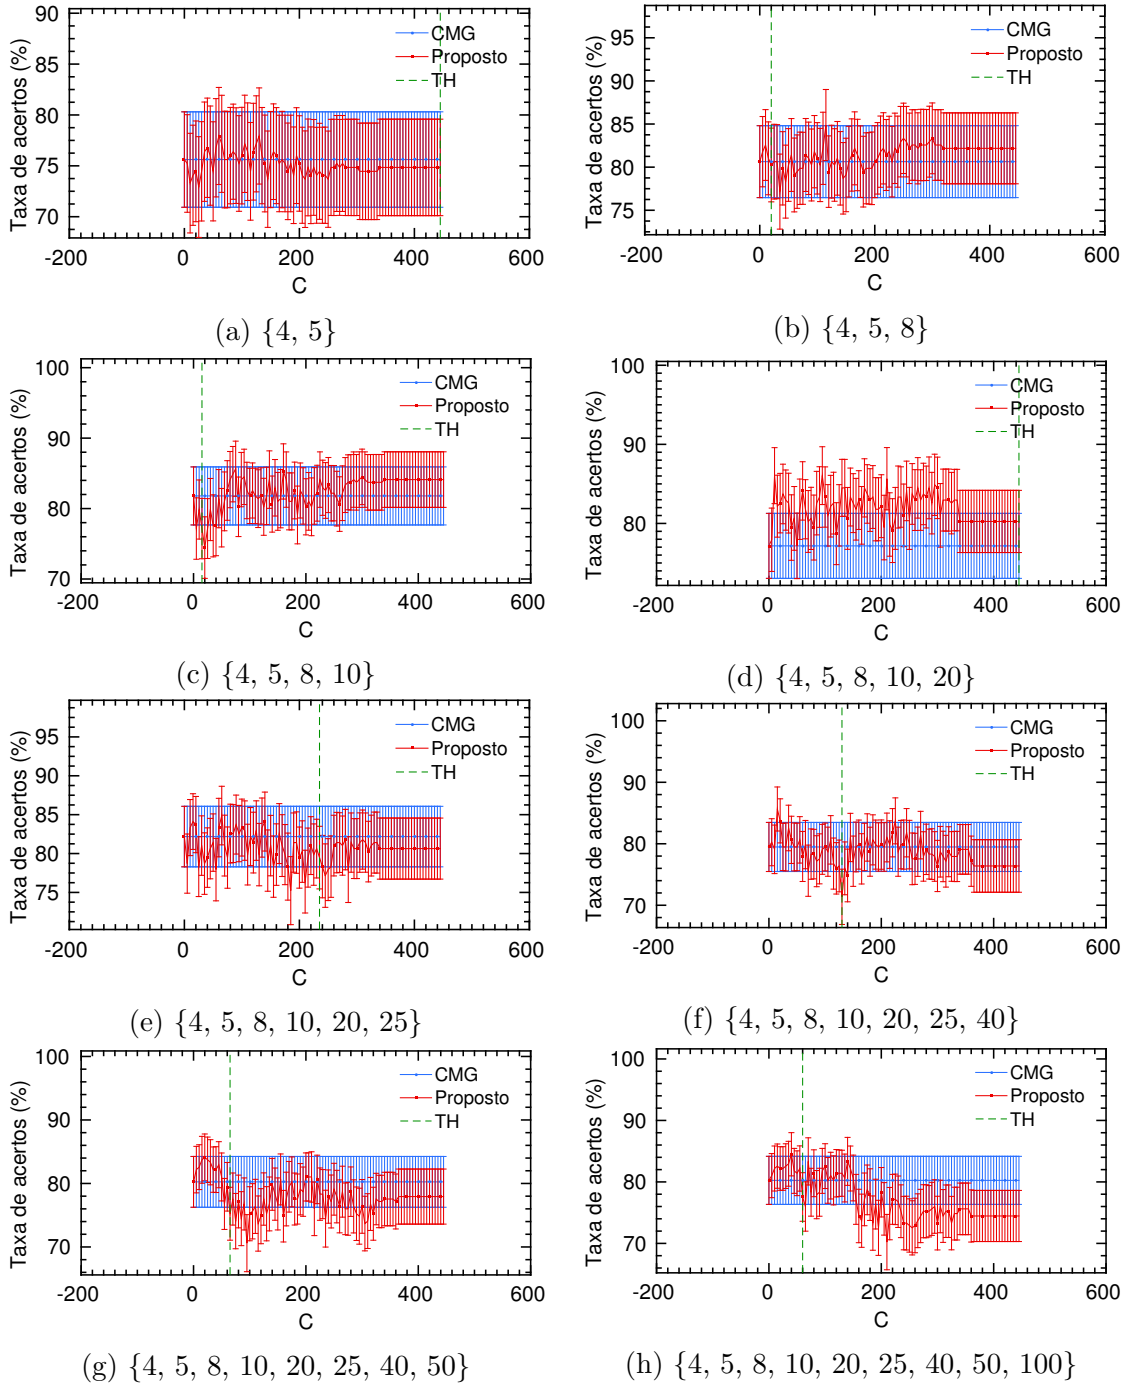


Figura 60 – Taxa de classificação com desvio padrão pelo aumento do parâmetro  $C$  (Base de imagens 2D HeLa), com classificador MLP (Grau médio 8).

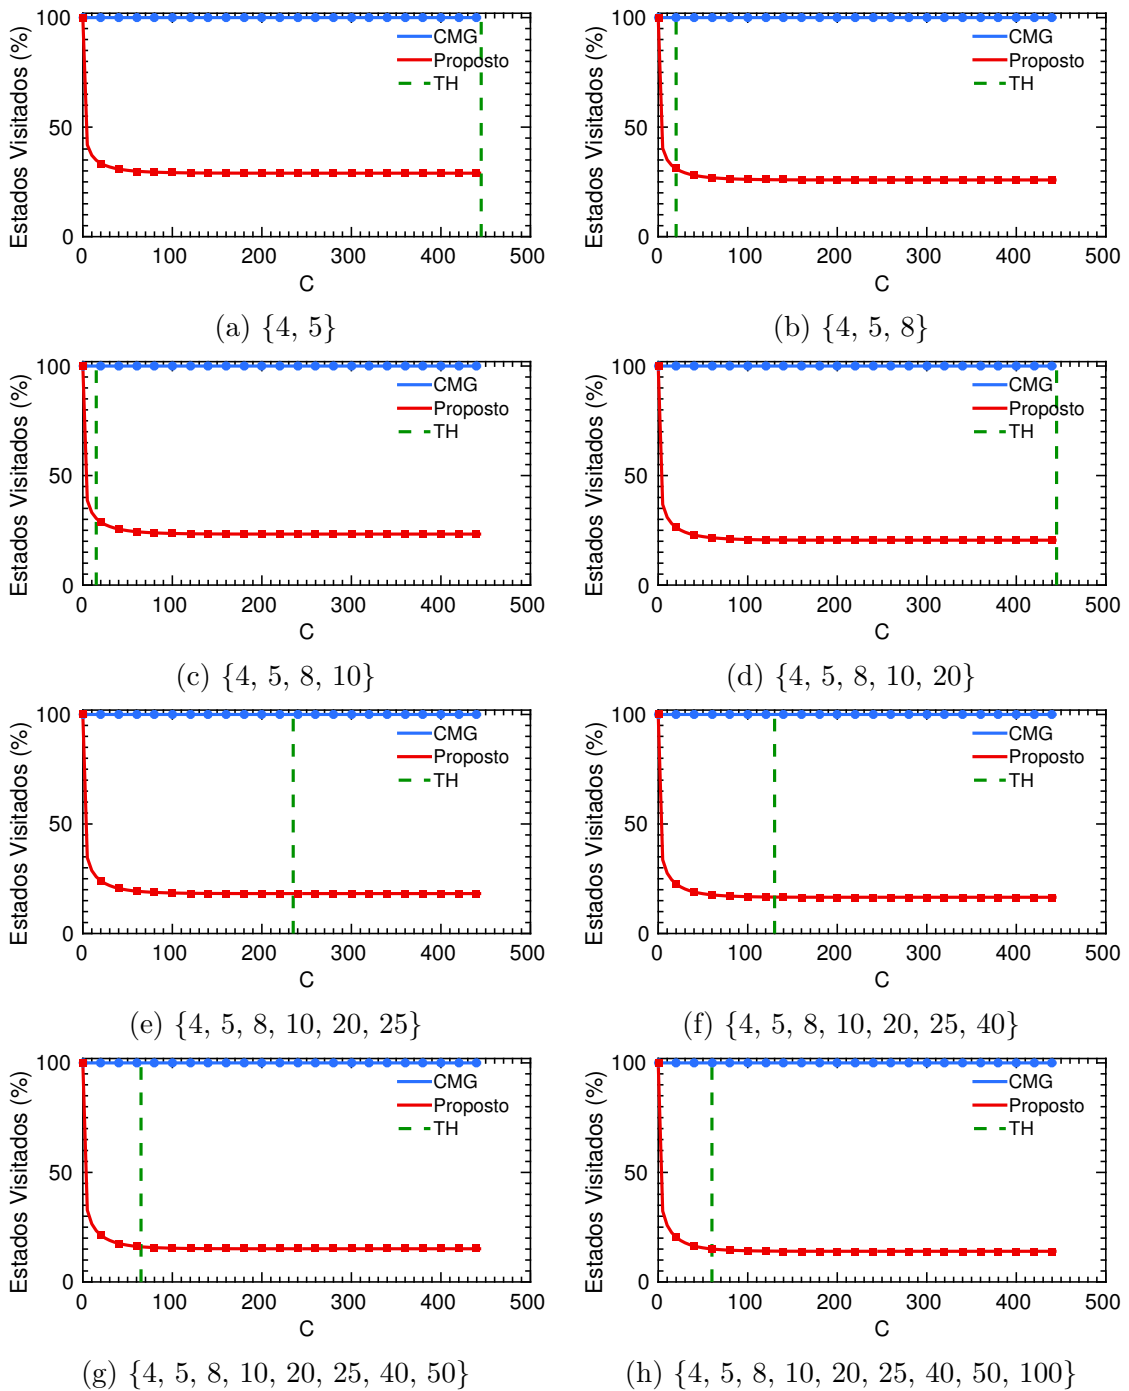


Figura 61 – Porcentagem de estados visitados pelo aumento de  $C$  (Base de imagens 2D HeLa), com classificador MLP (Grau médio 8).

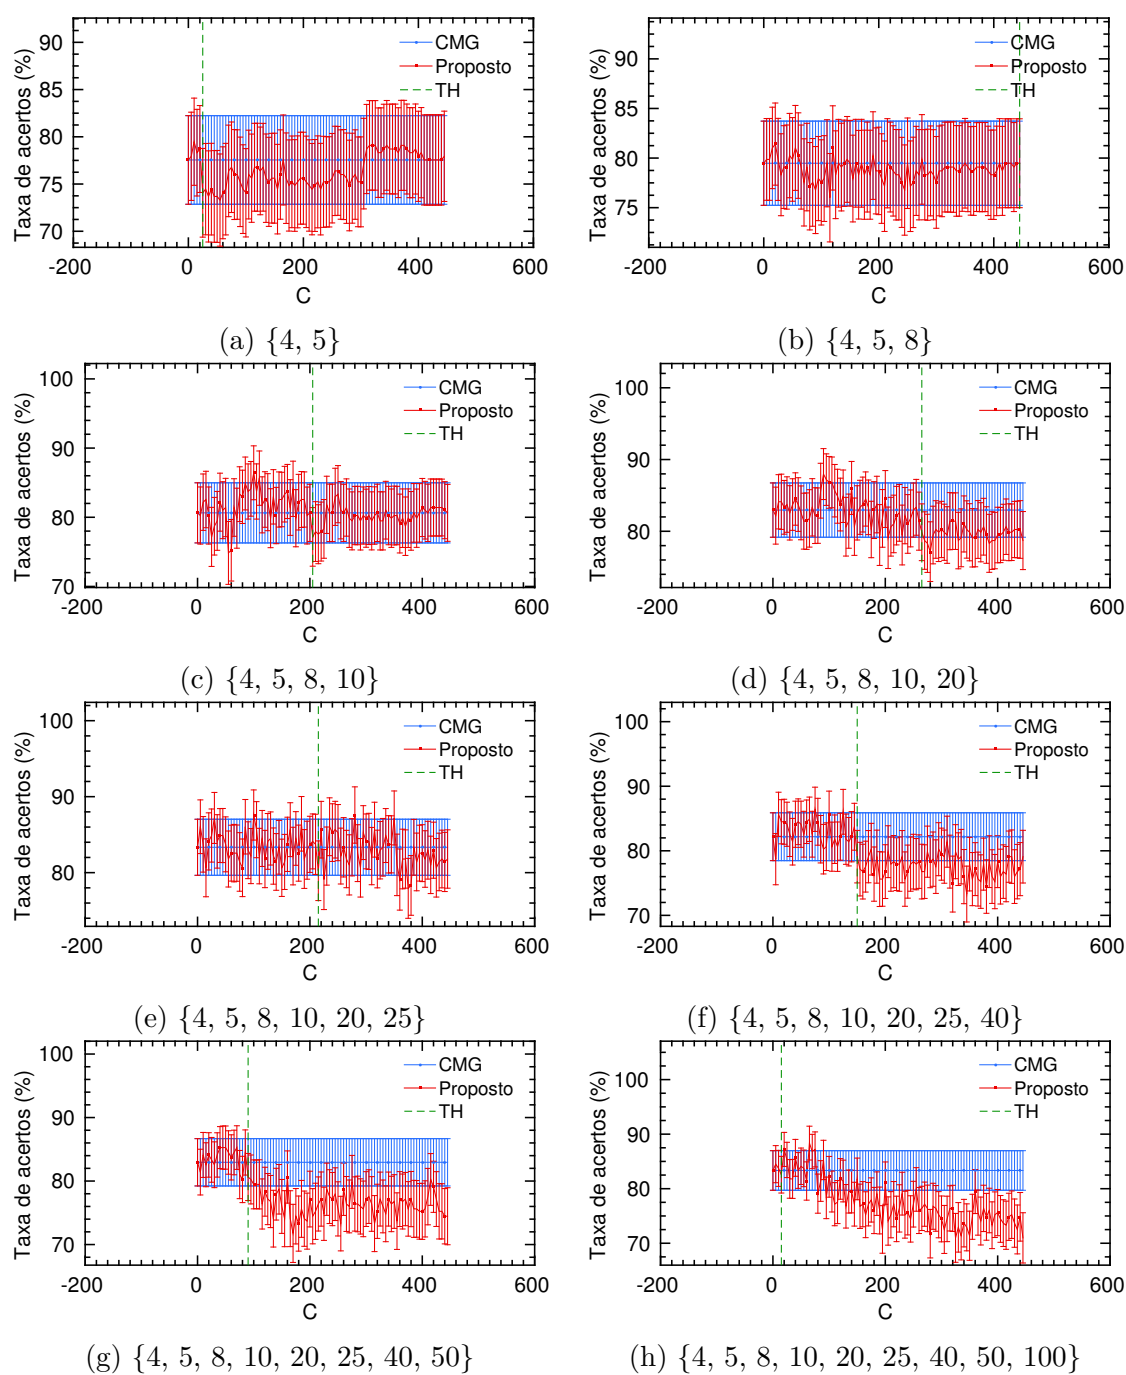


Figura 62 – Taxa de classificação com desvio padrão pelo aumento do parâmetro  $C$  (Base de imagens 2D HeLa), com classificador MLP (Grau médio 4).

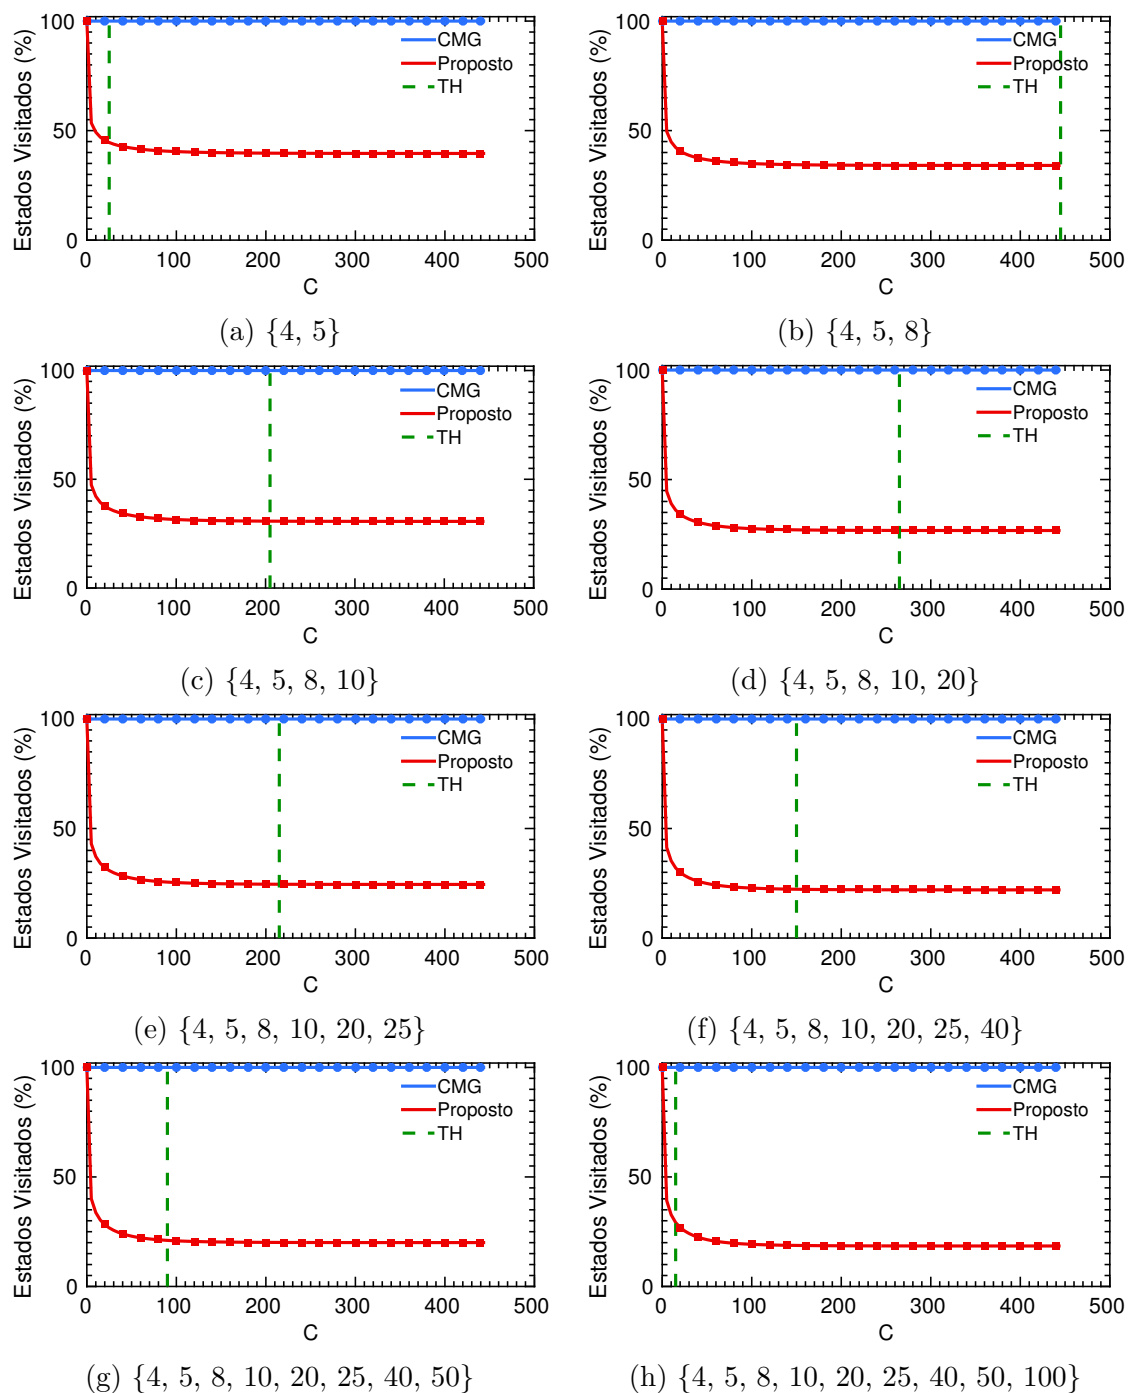


Figura 63 – Porcentagem de estados visitados pelo aumento de C (Base de imagens 2D HeLa), com classificador MLP (Grau médio 4).



# APÊNDICE G – Resultados Virus com LDA

## G.1 Grau médio 8

Os gráficos para diferentes configurações de janelas da Tabela 6 são mostrados a seguir.

### G.1.1 Taxa de classificação

A Figura 64 apresenta os resultados das taxas classificações para o banco Virus com diferentes configurações de janelas.

### G.1.2 Porcentagem de estados visitados

A Figura 65 apresenta os resultados dos estados visitados para o banco Virus com diferentes configurações de janelas.




Figura 64 – Taxa de classificação com desvio padrão pelo aumento do parâmetro  $C$  (Base de imagens Virus), com classificador LDA (Grau médio 8).

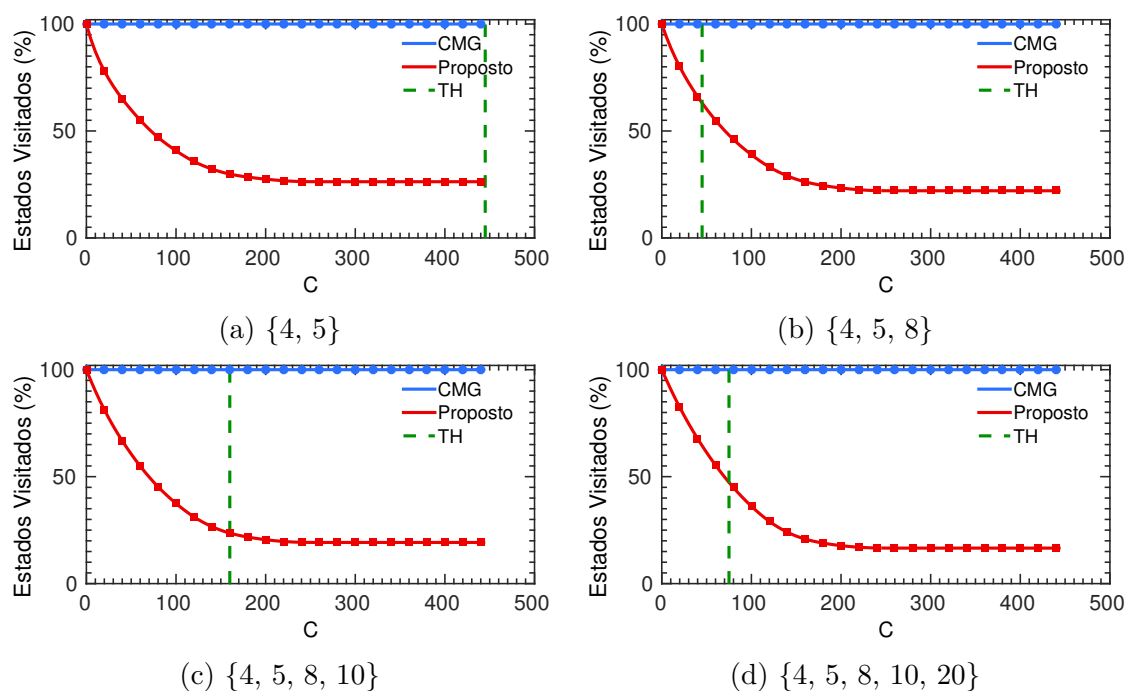


Figura 65 – Porcentagem de estados visitados pelo aumento de C (Base de imagens Virus), com classificador LDA (Grau médio 8).

## G.2 Grau médio 4

Os gráficos para diferentes configurações de janelas da Tabela 7 são mostrados a seguir.

### G.2.1 Taxa de classificação

A Figura 66 apresenta os resultados das taxas classificações para o banco Virus com diferentes configurações de janelas.

### G.2.2 Porcentagem de estados visitados

A Figura 67 apresenta os resultados dos estados visitados para o banco Virus com diferentes configurações de janelas.




Figura 66 – Taxa de classificação com desvio padrão pelo aumento do parâmetro  $C$  (Base de imagens Virus), com classificador LDA (Grau médio 4).




Figura 67 – Porcentagem de estados visitados pelo aumento de  $C$  (Base de imagens Virus), com classificador LDA (Grau médio 4).

# APÊNDICE H – Resultados Virus com MLP

## H.1 Grau médio 8

Os gráficos para diferentes configurações de janelas da Tabela 15 são mostrados a seguir.

### H.1.1 Taxa de classificação

A Figura 68 apresenta os resultados das taxas classificações para o banco Virus com diferentes configurações de janelas.

### H.1.2 Porcentagem de estados visitados

A Figura 69 apresenta os resultados dos estados visitados para o banco Virus com diferentes configurações de janelas.

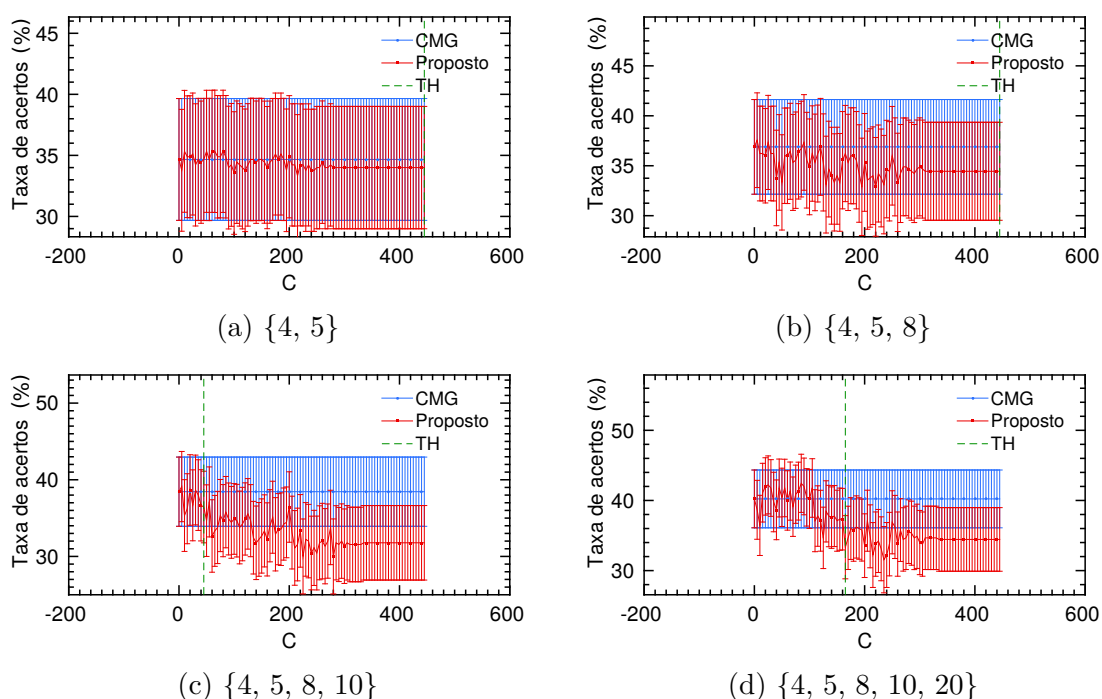


Figura 68 – Taxa de classificação com desvio padrão pelo aumento do parâmetro  $C$  (Base de imagens Virus), com classificador MLP (Grau médio 8).




Figura 69 – Porcentagem de estados visitados pelo aumento de C (Base de imagens Virus), com classificador MLP (Grau médio 8).

## H.2 Grau médio 4

Os gráficos para diferentes configurações de janelas da Tabela 16 são mostrados a seguir.

### H.2.1 Taxa de classificação

A Figura 70 apresenta os resultados das taxas classificações para o banco Virus com diferentes configurações de janelas.

### H.2.2 Porcentagem de estados visitados

A Figura 71 apresenta os resultados dos estados visitados para o banco Virus com diferentes configurações de janelas.




Figura 70 – Taxa de classificação com desvio padrão pelo aumento do parâmetro  $C$  (Base de imagens Virus), com classificador MLP (Grau médio 4).

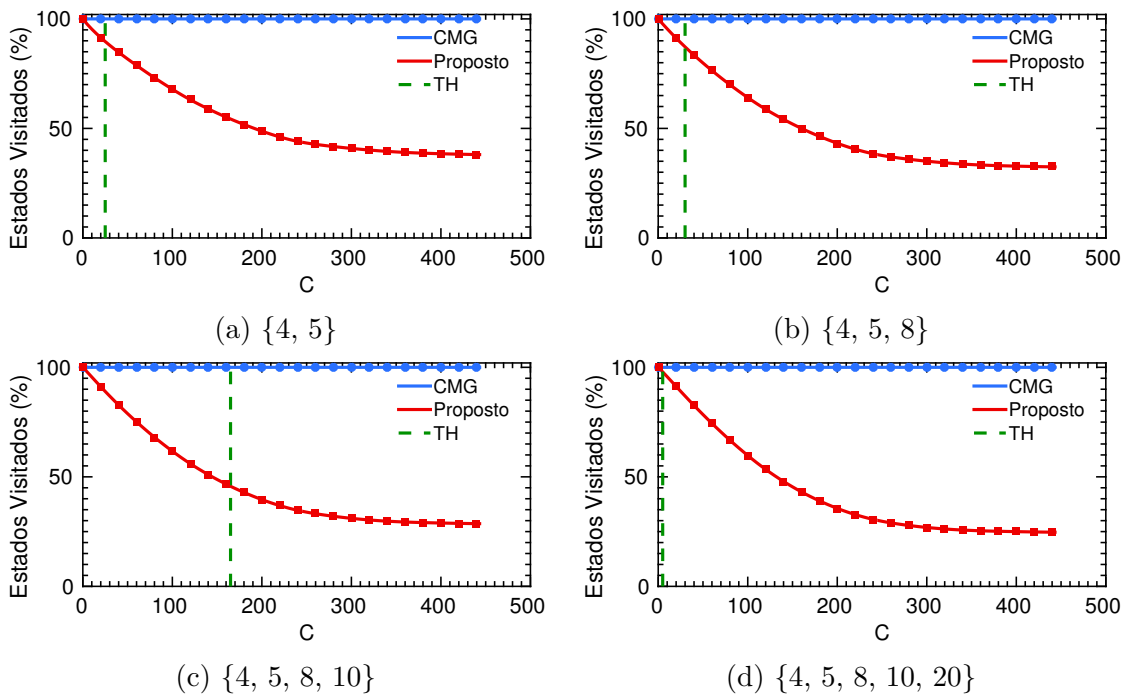


Figura 71 – Porcentagem de estados visitados pelo aumento de  $C$  (Base de imagens Virus), com classificador MLP (Grau médio 4).