

Dissertação de Mestrado

**Segmentação de Regiões de AVC Isquêmicos
em Imagens de TC por meio da Classificação
de Textura**

Emmanuel Diego Gonçalves de Freitas

Instituto Federal de Educação, Ciência e Tecnologia da Paraíba
Programa de Pós Graduação em Engenharia Elétrica

Segmentação de Regiões de AVC Isquêmicos em Imagens de TC por meio da Classificação de Textura

Emmanuel Diego Gonçalves de Freitas

Dissertação de Mestrado submetida à Coordenação do Programa de Pós Graduação em Engenharia Elétrica do Instituto Federal de Educação, Ciência e Tecnologia da Paraíba como requisito necessário para obtenção do grau de Mestre em Engenharia Elétrica.

Área de Concentração: Processamento de Sinais.

Suzete Élide Nóbrega Correia, D.Sc.
Orientadora

Carlos Danilo Miranda Regis, D.Sc.
Co-Orientador

João Pessoa, Paraíba, Brasil
19 de Julho de 2016

©Emmanuel Diego Gonçalves de Freitas

Dados Internacionais de Catalogação na Publicação – CIP
Biblioteca Nilo Peçanha – IFPB, *campus* João Pessoa

F866s

Freitas, Emmanuel Diego Gonçalves de.

Segmentação de regiões de AVC Isquêmicos em imagens de TC por meio da classificação de textura / Emmanuel Diego Gonçalves de Freitas. – 2016.

162 f. : il.

Dissertação (Mestrado em Engenharia Elétrica) – Instituto Federal de Educação, Ciência e Tecnologia da Paraíba – IFPB / Coordenação de Pós-Graduação em Engenharia Elétrica, 2016.

Orientador: Prof.^a Dr.^a Suzete Élide Nóbrega Correia.
Co-Orientador: Carlos Danilo Miranda Regis.

1. Processamento de imagens. 2. Tomografia computadorizada. 3. Análise de textura. I. Título.

CDU 621.391

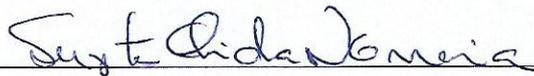
Instituto Federal de Educação, Ciência e Tecnologia da Paraíba
Programa de Pós Graduação em Engenharia Elétrica

Segmentação de Regiões de AVC Isquêmicos em Imagens de TC por meio Classificação de Textura

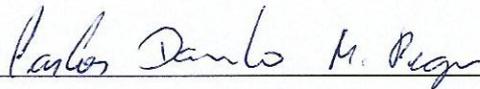
Emmanuel Diego Gonçalves de Freitas

Dissertação de Mestrado defendida e aprovada em 22 / 07 / 2016 .

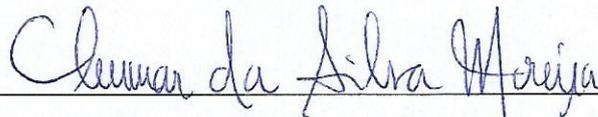
Banca examinadora:



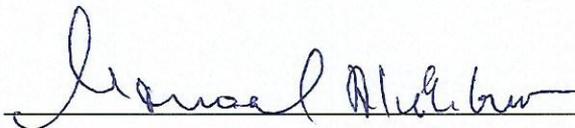
Profª. Suzete Élide Nóbrega Correia, D.Sc.
Orientadora (IFPB)



Prof. Carlos Danilo Miranda Régis, D.Sc.
Co-Orientador (IFPB)



Prof. Cleumar da Silva Moreira, D.Sc.
Membro da Banca (IFPB)



Prof. Manoel Alves Filho, D.Sc.
Membro da Banca (IFPB)



Prof. Severino Aires de Araújo Neto, Dr.
Membro da Banca (UFPB)

*Dedico este trabalho a todos que me ensinaram o que aprendi: aos meus queridos, por meio do amor; e aos meus desafetos, por meio da dor.
Especialmente à Sr^a Raimunda Gonçalves (Lêda) e ao Sr José de Freitas (Freitas), meus amados pais; e à Nayara, minha querida esposa.*

Agradecimentos

- A Deus, Senhor do Universo, pelo dom da vida, por tudo que eu pude fazer até hoje, pelas pessoas que conheci, e por tudo que ainda está por vir;
- Aos meus pais, Lêda e Freitas, por não medirem esforços enquanto providenciavam os meios pelos quais pude chegar até aqui, pelo amor incondicional e por depositaram esperança e fé em mim;
- À minha esposa Nayara, pelo companheirismo afetuoso, pelo amor gratuito e por entender a minha ausência nos muitos momentos desde que ingressei no mestrado, até a conclusão desta dissertação;
- Ao amigo Renato William, pela irmandade e apoio em muitos momentos importantes que estive presente pela simples vontade de me ajudar;
- Ao amigo Jorge Henrique, pela amizade sincera, pela companhia fiel e pelos ensinamentos de serenidade e calma para as situações de nervosismo;
- À Professora Suzete Correia, por compreender as situações pelas quais passei enquanto realizava a pesquisa, e por depositar sua confiança em mim, ao tempo em que incentivava e me ensinava, indiretamente, como deverei orientar meus alunos;
- Ao Professor Danilo Regis, por me aceitar em seu grupo de pesquisa, pela paciência com a qual conduziu sua orientação e por confiar à minha pessoa a ideia que fez nascer o objetivo deste trabalho;
- Aos colegas Victor (de Natal-RN), Ismael Feitosa (de Santana do Cariri), Francildo (de Cedro), Ventura (de Lavras) e Hernando (de Iguatu), por terem compartilhado comigo momentos únicos enquanto dividimos o apartamento em João Pessoa;
- Aos colegas Paulo, Evandson e Francisco Alves, pela ajuda e contribuição nos momentos de estudo.

*"Julgue seu sucesso pelas coisas que você teve que renunciar para conseguir."
(Dalai Lama)*

Resumo

Imagens de Tomografia Computadorizada (TC) são utilizadas como instrumentos de auxílio ao diagnóstico médico, possibilitando a detecção precoce, bem como o acompanhamento, de diversas doenças tais como o Acidente Vascular Cerebral (AVC), cuja análise da imagem do crânio é realizada pelo médico de forma visual, o qual localiza a lesão, diferencia o AVC isquêmico do hemorrágico e realiza a demarcação manualmente. Técnicas de análise computacional dessas imagens, podem ampliar a quantidade de informação adquirida e contribuir para o diagnóstico correto em um procedimento médico. Tal razão motiva o desenvolvimento de sistemas computadorizados para o auxílio à detecção e ao diagnóstico (*Computer-Aided Detection and Diagnosis - CADDx*) para doenças, empregando técnicas de Processamento Digital de Imagens e Visão Computacional. Neste contexto, são utilizados vários métodos com a finalidade de segmentar, reconhecer e identificar detalhes da região de interesse na imagem de TC analisada. Esta pesquisa centraliza seus esforços em estabelecer um método de segmentação da região das áreas isquêmicas, no acidente vascular cerebral, em imagens de Tomografia Computadorizada. Ao final do processo de segmentação, um contorno é delineado automaticamente em volta da região segmentada sem a necessidade de uma intervenção humana. Para tanto, é feita a classificação de informações de textura extraídas da imagem, obtidas com os descritores de Haralick. Duas investigações foram realizadas: a determinação do melhor conjunto de descritores de Haralick usados como medidas de textura e análise de desempenho dos descritores selecionados para segmentação. Em ambas foram empregadas Redes Neurais Artificiais MLP (*Multilayer Perceptron*) para a classificação de áreas de textura com e sem Acidente Vascular Cerebral Isquêmico (AVCi). Para a análise dos descritores de Haralick foram feitos testes de significância estatística e testes de classificação com a RNA para 1, 2 e 3 descritores de Haralick combinados entre si. Os resultados obtidos foram comparados com o padrão ouro, dado pela segmentação manual das regiões isquêmicas. Nos testes realizados o sistema obteve bons resultados com o conjunto de descritores Correlação, Homogeneidade e Soma das Médias, que mostrou-se capaz de promover a classificação necessária para segmentar a região cerebral atingida pelo AVC com precisão.

Palavras-Chave: Processamento Digital de Imagens, Segmentação, AVCi, Análise de Textura.

Abstract

Images of Computed Tomography (CT) are often used as aid instruments on medical diagnosis, allowing early detection and monitoring of various diseases such as cerebrovascular accident (CVA), whose skull image analysis is performed, visually, by the physician who locates the lesion, differentiating ischemic from hemorrhagic stroke and performs segmentation manually. The computational analysis techniques of these images can increase the amount of information acquired and contribute to the correct diagnosis in a medical procedure. Such reason motivates the development of computerized systems in order to aid in the detection and diagnosis (CADD) of diseases, by using digital processing techniques and computer vision. In this context, various methods are used in order to segment, recognize, and identify details about the region of interest in the analyzed CT image. This research focuses on establishing a method of segmenting the region of ischemic areas in stroke in plain CT images. By the end of the process, the system automatically delineates a contour around the segmented region without the need of human intervention. Therefore, the proposed system makes the classification of texture information extracted from the image, obtained with the Haralick features. With this in mind, two investigations were performed: determining the best set of Harlick features used as measures of texture and analyzing features performance which were selected for segmentation. For both, the system applied Artificial Neural Networks (ANN) MLP (Multilayer Perceptron) to classify texture areas with and without Ischemic Stroke (AIS). For the analysis of Haralick features, statistical significance tests and classification tests with ANN 1, 2, and 3 combined Haralick features were performed. The results were compared to the gold standard obtained by manual segmentation of ischemic regions. In the tests, the system achieved good results with the features set formed by correlation, Homogeneity, and the Sum of Means which proved to be able to promote the necessary classification to segment, accurately, the brain region affected by the stroke.

Key-Words: Digital Image Processing, Segmentation, ischemic stroke, texture analysis.

Lista de Siglas e Abreviaturas

AC – Acurácia

ACR – *American College of Radiology*

ANSI – *American National Standards Institute*

AS – *Sum Average* (Média da Soma)

ASM – *Angular Second Moment* (Segundo Momento Angular)

AUC – *Area Under Curve*

AVC – Acidente Vascular Cerebral

AVCh – Acidente Vascular Cerebral Hemorrágico

AVCi – Acidente Vascular Isquêmico

AVE – Acidente Vascular Encefálico

CBF – *Cerebral Blood Flow*

CBV – *Cerebral Blood Volume*

CCD – *Charge-Coupled Device*

CMOS – *Complementary Metal Oxide Semiconductor*

CT – *Computed Tomography*

DCMTK – *DICOM ToolKit*

DICOM – *Digital Imaging and Communication in Medicine*

DV – *Diference Variance* (Variância da Diferença)

EMI – *Electrical and Musical Industries*

Esp – Especificidade

FLAIR – *Free Liquid Atenuated Inversion Recovery*

FN – Falso Negativo

FOV – *Field of View*

FP – FALSO Positivo

GLCM – *Gray Level Co-Occurrence Matrix*

HU – *Hounsfield Units*

IMD – *Inverse Diference Moment* (Momento da diferença inversa)

JPEG – *Joint Photographic Experts Group*

MLP – *Multilayer Perceptron*

MTT – *Mean Transit Time*

NEMA – *National Electricol Manufacturers Association*

OCR – *Optical Character Recognition*

OFFIS – *Oldenburger Forschungs - Institut für Informatik*

PDI – *Processamento Digital de Imagens*

RM – *Ressonância Magnética*

RNA – *Rede Neural Artificial*

ROC – *Receiver Operating Characteristic*

ROI – *Region of Interest*

SE – *Sum Entropy* (Entropia da Soma)

Sen – *Sensibilidade*

SPSS – *Statistical Package to Social Sciences* SV – *Sum Variance* (Variância da Soma)

TC – *Tomografia Computadorizada*

VC – *Visão Computacional*

VN – *VERDADEIRO Negativo*

VP – *VERDADEIRO Positivo*

WL – *Window Level*

WW – *Window Width*

Lista de Símbolos

- μ – Coeficientes de Atenuação Linear
- μ_t – Coeficiente de Atenuação Linear do Tecido
- μ_{agua} – Coeficiente de Atenuação Linear da Água
- θ – Posição angular do nível de cinza j de um *pixel* dentro de sua vizinhança
- d é distância entre dois níveis de cinza em uma GLCM
- i – Referência horizontal para os *pixels* de uma imagem
- j – Referência vertical para os *pixels* de uma imagem
- N_g – Quantidade de níveis de cinza de uma imagem
- N_x – Número de *pixels* na direção horizontal de uma GLCM
- N_y – Número de *pixels* na direção vertical de uma GLCM
- $P(i, j)$ – Valor do elemento (i, j) em uma GLCM
- f_1 – Segundo Momento Angular
- f_2 – Contraste
- f_3 – Correlação
- f_4 – Variância
- f_5 – Homogeneidade
- f_6 – Soma das Médias
- f_7 – Soma da Variância
- f_8 – Entropia da Soma
- f_9 – Entropia
- f_{10} – Variância da Diferença
- f_{11} – Entropia da Diferença
- f_{12} – Informações de Medidas de Correlação 1
- f_{13} – Informações de Medidas de Correlação 2
- δ - Desvio Padrão

Lista de Figuras

1.1	Etapas de um sistema típico de Visão Computacional.	20
2.1	Princípio da planigrafia linear de Des Plantes.	26
2.2	Ilustração da emissão de raios-X para a formação de uma imagem de tomografia.	27
2.3	Representação do <i>pixel</i> e do <i>voxel</i>	29
2.4	A técnica de janelamento: O nível de contraste é inversamente proporcional ao valor de WW.	31
2.5	Secção coronal do cerebro no nível dos corpos mamilares.	33
2.6	Lobos Cerebrais.	33
2.7	Mecanismos fisiopatológicos do AVCi e do AVCh.	34
2.8	Imagens de TC: (a) AVCh (b) AVCi	35
3.1	Exemplo de uma co-ocorrência dos níveis de cinza i e j , com vizinhança $d=4$, alinhados na direção $\theta = 0$	42
3.2	Ângulos utilizados para cálculo da matriz de co-ocorrência com $d = 1$ [1].	42
3.3	(a) Imagem $N_x \times N_y$. (b) Matriz de co-ocorrência da imagem ($d = 1, \theta = 0$)	43
3.4	Exemplo de cálculo da matriz de co-ocorrência, mostrada em (c), e sua representação normalizada, mostrada em (b), para uma imagem hipotética 5×5 e $N_g = 4$, mostrada em (a).	44
3.5	Imagens cujos <i>pixels</i> trazem padrões de textura (a) elatório, (b) periódicos e (c) mistos.	44
3.6	Matrizes de co-ocorrência 256×256 (a) G_1 , (b) G_2 e (c) G_3 [2].	45
4.1	Imagens 1 à 15 da base utilizada	53
4.2	Imagens 16 à 30 da base utilizada	53
4.3	Representação da topologia adotada para a RNA.	54
4.4	Algoritmo para treinamento da RNA.	55
4.5	Processo realizado em cada pixel da imagem a ser segmentada.	56
4.6	(a) TC utilizada para teste. (b) resultado obtido com a binarização da saída oferecida pela RNA (c) pós processamento sobre a saída obtida.	56
4.7	Gráfico ROC básico com 5 classificadores discretos.	58
4.8	Curva ROC e a Qualidade no Diagnóstico.	60

5.1	Comportamento do descritores de Haralick individualmente.	64
5.2	Comportamento do descritores de Haralick indivisualmente.	65
5.3	Padrão ouro para as imagens 1 à 15 da base utilizada.	71
5.4	Padrão ouro para as imagens 16 à 30 da base utilizada.	71
5.5	Resultados com as figuras 1 a 15, obtidos com a combinação dos descritores correlação, homogeneidade e soma das médias.	73
5.6	Resultados com as figuras 16 a 30, obtidos com a combinação dos descritores correlação, homogeneidade e soma das médias.	73
5.7	Resultados com as figuras 1 a 15, obtidos com a combinação dos descritores segundo momento angular, homogeneidade e soma das médias.	75
5.8	Resultados com as figuras 16 a 30, obtidos com a combinação dos descritores segundo momento angular, homogeneidade e soma das médias.	75
5.9	Resultados com as figuras 1 a 15, obtidos com a combinação dos descritores segundo momento angular, correlação e soma das médias.	77
5.10	Resultados com as figuras 16 a 30, obtidos com a combinação dos descritores segundo momento angular, correlação e soma das médias.	77
5.11	Curva ROC para classificador configurado para a combinação Correlação, Homogeneidade e Soma das Médias.	79

Lista de Tabelas

2.1	Exemplos de números de CT.	30
4.1	Matriz de confusão em um teste de detecção da presença/ausência de doença. . . .	57
4.2	Qualidade do diagnóstico em relação a área da curva ROC.	59
5.1	Valores médios, desvios-padrão e níveis de significância de diferentes descritores de textura em regiões com e sem AVCi.	62
5.2	Códigos adotados para representação dos descritores.	66
5.3	Média dos resultados obtidos com um descritor.	67
5.4	Média dos resultados obtidos com dois descritores.	67
5.5	Resultados obtidos a partir da combinação dos descritores correlação, homogeneidade e soma das médias.	72
5.6	Resultados obtidos a partir da combinação dos descritores segundo momento angular, homogeneidade e soma das médias.	74
5.7	Resultados obtidos a partir da combinação dos descritores segundo momento angular, correlação e soma das médias.	76
A.1	Resultados com um descritor - Imagem 1	95
A.2	Resultados com um descritor - Imagem 2	95
A.3	Resultados com um descritor - Imagem 3	96
A.4	Resultados com um descritor - Imagem 4	96
A.5	Resultados com um descritor - Imagem 5	96
A.6	Resultados com um descritor - Imagem 6	97
A.7	Resultados com um descritor - Imagem 7	97
A.8	Resultados com um descritor - Imagem 8	97
A.9	Resultados com um descritor - Imagem 9	98
A.10	Resultados com um descritor - Imagem 10	98
A.11	Resultados com um descritor - Imagem 11	98
A.12	Resultados com um descritor - Imagem 12	99
A.13	Resultados com um descritor - Imagem 13	99
A.14	Resultados com um descritor - Imagem 14	99
A.15	Resultados com um descritor - Imagem 15	100
A.16	Resultados com um descritor - Imagem 16	100

A.17 Resultados com um descritor - Imagem 17	101
A.18 Resultados com um descritor - Imagem 18	101
A.19 Resultados com um descritor - Imagem 19	101
A.20 Resultados com um descritor - Imagem 20	102
A.21 Resultados com um descritor - Imagem 21	102
A.22 Resultados com um descritor - Imagem 22	102
A.23 Resultados com um descritor - Imagem 23	103
A.24 Resultados com um descritor - Imagem 24	103
A.25 Resultados com um descritor - Imagem 25	103
A.26 Resultados com um descritor - Imagem 26	104
A.27 Resultados com um descritor - Imagem 27	104
A.28 Resultados com um descritor - Imagem 28	104
A.29 Resultados com um descritor - Imagem 29	105
A.30 Resultados com um descritor - Imagem 30	105
B.1 Resultados com dois descritores - Imagem 1	106
B.2 Resultados com dois descritores - Imagem 2	108
B.3 Resultados com dois descritores - Imagem 3	110
B.4 Resultados com dois descritores - Imagem 4	111
B.5 Resultados com dois descritores - Imagem 5	113
B.6 Resultados com dois descritores - Imagem 6	115
B.7 Resultados com dois descritores - Imagem 7	117
B.8 Resultados com dois descritores - Imagem 8	119
B.9 Resultados com dois descritores - Imagem 9	121
B.10 Resultados com dois descritores - Imagem 10	123
B.11 Resultados com dois descritores - Imagem 11	124
B.12 Resultados com dois descritores - Imagem 12	126
B.13 Resultados com dois descritores - Imagem 13	128
B.14 Resultados com dois descritores - Imagem 15	130
B.15 Resultados com dois descritores - Imagem 16	132
B.16 Resultados com dois descritores - Imagem 17	134
B.17 Resultados com dois descritores - Imagem 19	136
B.18 Resultados com dois descritores - Imagem 21	138
B.19 Resultados com dois descritores - Imagem 22	139
B.20 Resultados com dois descritores - Imagem 23	141
B.21 Resultados com dois descritores - Imagem 24	143
B.22 Resultados com dois descritores - Imagem 25	145
B.23 Resultados com dois descritores - Imagem 26	147
B.24 Resultados com dois descritores - Imagem 27	149
B.25 Resultados com dois descritores - Imagem 28	151
B.26 Resultados com dois descritores - Imagem 29	152
B.27 Resultados com dois descritores - Imagem 30	154

C.1 Resultados Numéricos com Três Descritores 157

Sumário

1	Introdução	19
1.1	Motivação	21
1.2	Objetivos	22
1.2.1	Objetivo Geral	22
1.2.2	Objetivos Específicos	22
1.3	Organização da Dissertação	23
2	A tomografia computadorizada	24
2.1	Histórico do diagnóstico por imagem	24
2.2	Formação da Imagem	27
2.3	Apresentação da Imagem	30
2.4	Anatomia e Fisiologia Cerebral	32
2.5	Fisiopatologia do AVC	33
2.6	Trabalhos Relacionados	35
2.7	Considerações	38
3	Análise de Textura	40
3.1	Contextualização	40
3.2	Matriz de Co-ocorrência de Tons de Cinza	42
3.3	Descritores de Haralick	45
3.3.1	Segundo Momento Angular	46
3.3.2	Contraste	46
3.3.3	Correlação	47
3.3.4	Variância (soma dos quadrados) e desvio padrão	47
3.3.5	Homogeneidade ou momento da diferença inversa	48
3.3.6	Soma das Médias	48
3.3.7	Soma da Variância	48
3.3.8	Entropia da Soma	49
3.3.9	Entropia	49
3.3.10	Variância da Diferença	49

3.3.11 Entropia da Diferença	50
3.3.12 Informações de Medidas de Correlação 1	50
3.3.13 Informações de Medidas de Correlação 2	50
3.3.14 Coeficiente de Correlação Máximo	50
3.4 Considerações	51
4 Materiais e Métodos	52
4.1 Materiais	52
4.1.1 Base de Imagens	52
4.1.2 A Biblioteca DCMTK	53
4.1.3 O Classificador	54
4.1.4 Metodologia para a classificação e segmentação	54
4.1.5 Metodologia para avaliação e interpretação	56
4.2 Considerações	60
5 Resultados	61
5.1 Contextualização	61
5.2 Análise dos descritores de Haralick como medidas para classificação de texturas de TC do Cérebro	61
5.3 Análise de classificação com um descritor	66
5.4 Análise de grupos de dois descritores	67
5.5 Análise de grupos de três descritores	69
5.6 Análise das melhores combinações de três descritores	70
5.7 A detecção de AVCi com as três melhores combinações de descritores	78
5.8 Considerações	79
6 Conclusão	80
6.1 Considerações Finais	80
6.2 Contribuições da pesquisa	81
6.3 Sugestões para Trabalhos Futuros	81
Referências Bibliográficas	93
APÊNDICES	94
A Resultados com um Descritor	95
B Resultados Numéricos com Dois Descritores	106
C Resultados Numéricos com Três Descritores	157

Sistemas computacionais concebidos por meio da associação com o conhecimento médico têm possibilitado o desenvolvimento de equipamentos com importantes contribuições para a identificação de doenças e seus tratamentos. Atualmente, o uso desses equipamentos está eminentemente presente na medicina, em aplicações que vão desde simples exames laboratoriais até exames de elevada complexidade [3].

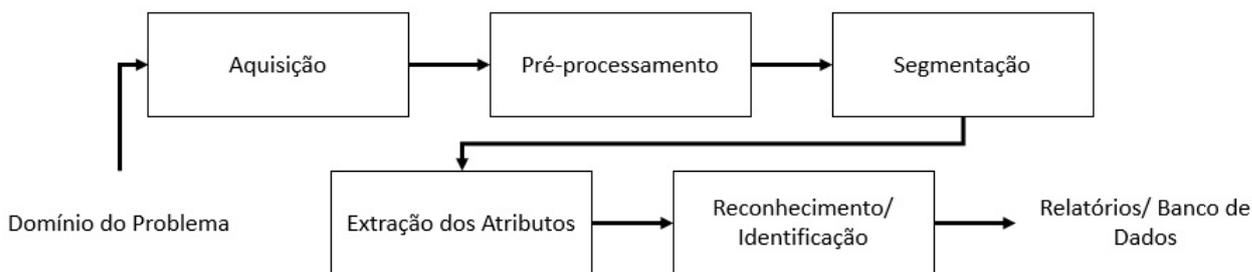
O impacto dessas tecnologias é tão grande que a abordagem diagnóstica médica sofreu relevantes influências e vem sendo progressivamente modificada, como por exemplo, com o uso de equipamentos radiológicos cada vez mais sofisticados que geram sinais de qualidade suficiente para evidenciar informações com mínimos detalhes [4], tais como a Tomografia Computadorizada (TC), considerada pelos profissionais da área como uma das inovações médicas mais importantes desde a descoberta dos raios-X [5].

Movidas pela importância deste contexto, diversas empresas vêm desenvolvendo diversos tipos de equipamentos médicos, com o propósito de oferecer ferramentas de auxílio ao diagnóstico capazes de diminuir a subjetividade dos resultados, bem como o tempo das análises médicas. Além do tomógrafo, também são exemplos dos referidos equipamentos: o eletroencefalógrafo, o eletrocardiógrafo, o ecocardiógrafo, o angiógrafo e endoscópios, dentre outros. Estes equipamentos são utilizados em diversas áreas da medicina, mas, segundo Alexandria *et al* [6], ambos possuem em comum as imagens e/ou gráficos como representação do estado do objeto em análise. Este fato traz à tona o uso de técnicas de Visão Computacional (VC), em aplicações para processos da medicina, baseadas em Processamento de Imagens Médicas.

A Visão Computacional utiliza várias técnicas de Processamento Digital de Imagens (PDI) com a finalidade de segmentar, reconhecer e/ou identificar detalhes de regiões de interesse em uma determinada imagem, de modo automático ou semiautomático. Normalmente um sistema de VC possui como entrada uma cena, e como saída uma fonte de atributos desta mesma cena. Estes sistemas são divididos basicamente em cinco etapas (Figura 1.1): aquisição, pré-processamento, segmentação, extração de atributos e reconhecimento e interpretação [2].

Na etapa de aquisição, a imagem é capturada por meio de um dispositivo sensor e convertida para uma representação adequada para a etapa subsequente. Usualmente

Figura 1.1 – Etapas de um sistema típico de Visão Computacional.



Fonte: [2]

utiliza-se câmeras de vídeo, máquinas fotográficas ou outros dispositivos com tecnologia CCD e CMOS.

Na aquisição de imagens médicas são utilizados equipamentos de raios-X, doppler colorido, tomógrafos, ultrassonografia, dentre outros. Dentre os aspectos envolvidos nesta etapa estão as condições de iluminação, preparação da cena, ajuste e aferição dos dispositivos de aquisição e número de cores ou tons de cinza da imagem digitalizada [1]. A imagem resultante desta primeira etapa pode apresentar imperfeições ou degradações decorrentes, por exemplo, das condições do ambiente ou do equipamento de aquisição.

A segunda etapa, de pré-processamento, tem por objetivo condicionar o aspecto visual de certas características estruturais, bem como fornecer outros subsídios para a sua interpretação, por meio da aplicação de técnicas de supressão de ruído, suavização de determinadas propriedades da imagem e correção de contraste ou brilho.

Na etapa de segmentação é realizada a extração e identificação de áreas de interesse, dividindo a imagem em regiões de similaridades de acordo com propriedades pré-definidas ou estabelecendo contornos baseados na detecção de descontinuidades (bordas). Conforme Alexandria [7], o processo de segmentação é de fundamental importância em qualquer sistema de Visão Computacional, de tal forma, que o desempenho destes sistemas é essencialmente dependente do desempenho da referida etapa, pois, uma segmentação realizada de forma adequada em um sistema de visão é um passo substancialmente importante para o seu funcionamento.

A etapa de extração de atributos consiste em escolher uma representação adequada para descrever os elementos segmentados na etapa anterior, por isso também referenciada como "etapa de representação e descrição", tal como é descrito por Pedrini [1]. Nesta fase as características ou atributos de regiões segmentadas são então obtidas e, muitas vezes, são representadas por dados métricos chamados de descritores. Para esta etapa a entrada ainda é uma imagem, mas a saída é um conjunto de dados correspondentes àquela imagem, cuja estrutura é conveniente ao sistema de reconhecimento de imagens que será utilizado na próxima etapa.

Na etapa de reconhecimento e interpretação são classificados os objetos selecionados, ou seja, reconhecimento ou interpretação é o processo que atribui um identificador ou uma etiqueta aos objetivos cujos descritores foram selecionados. Normalmente esse processo é realizado por algoritmos computacionais, que rotulam os objetos em grupos ou classes de acordo com informações pré-estabelecidas. Tais algoritmos baseiam-se, principalmente, em técnicas de Reconhecimento de Padrões, Estatística ou Inteligência Artificial.

Por fim, os dados obtidos são apresentados da forma mais conveniente para a aplicação, podendo ser na tela de um computador, relatórios, banco de dados ou outras formas de saída de dados, conforme se confere na Figura 1.1.

A seguir são listadas algumas das aplicações de Visão Computacional:

- Sistemas biométricos para identificação de pessoas [8,9];
- Reconhecimento Óptico de Caracteres (OCR) e reconhecimento de manuscritos [10-12];
- Processos industriais, tais como controle de medidas de peças e análise metalográfica de materiais [13,14];
- Rastreamento de objetos e sistema de percepção para robôs [15-17];
- Auxílio no diagnóstico de patologias em imagens médicas [7,18,19].

Tratando-se de auxílio no diagnóstico de patologias em imagens médicas, sistemas de VC são capazes, dentre outras coisas, de conseguir detalhes em imagens inalcançáveis à percepção natural da visão humana e, conseqüentemente, maior confiabilidade nas análises realizadas, proporcionando inclusive maior segurança quanto aos procedimentos de cirurgias, conforme é apresentado por Markman [20].

Desta forma, técnicas de visão computacional para segmentação e extração de atributos de um acidente vascular cerebral (AVC) em imagens de Tomografia Computadorizada (TC), aplicação na qual são centralizados os esforços deste trabalho, podem oferecer aos médicos e pacientes, mais uma importante ferramenta no auxílio ao diagnóstico e na avaliação de danos no tecido cerebral causados pelo AVC e sua resposta ao tratamento.

1.1. Motivação

Devido ao grande número de casos, as graves conseqüências das doenças vasculares cerebrais e o caráter emergencial do atendimento, pesquisas para desenvolvimento de ferramentas que auxiliem o diagnóstico do médico especialista, especificamente na análise

de imagens de TC simples do cérebro, podem contribuir com a oferta de meios para avaliação do desenvolvimento da doença, bem como a resposta da mesma ao tratamento adotado.

Contudo, o processo de segmentação das regiões de interesse para o exame é, muitas vezes, feito por análise visual humana, na qual um especialista ou radiologista realiza a classificação da patologia manualmente [18, 21, 22]. Quando não, os exames são conduzidos, em sua maioria, por médicos que utilizam *softwares* não especializados em uma determinada patologia, já existentes nos tomógrafos [23], apesar da existência de várias pesquisas a respeito do AVC, principalmente o isquêmico.

Neste sentido, o desenvolvimento de técnicas de segmentação de regiões de AVC em imagens de TC simples (sem contraste) do cérebro, pode acelerar o processo de análise dos exames feitos por um médico especialista, visto que essa é uma atividade que, geralmente, consome bastante do tempo (muitas vezes escasso) dos profissionais envolvidos. Além disto, pode-se citar como fator de contribuição a melhoria da precisão do diagnóstico do médico especialista, devido ao aumento do número de informações à sua disposição sobre o estado do paciente [24].

Portanto, como a interpretação cuidadosa de imagens radiográficas despende um valioso tempo com observação minuciosa, e treinar uma equipe de radiologistas para processar um maior número de imagens em menos tempo é uma opção relativamente cara, o desenvolvimento de um *software* que auxilie os médicos no diagnóstico de AVCi é de muita valia. Cabe ressaltar que mesmo as menores contribuições desse enfoque podem significar importante suporte para o desenvolvimento de técnicas de considerável relevância em trabalhos futuros.

1.2. Objetivos

1.2.1. Objetivo Geral

Esta dissertação propõe um método para a segmentação da região cerebral atingida por Acidente Vascular Cerebral isquêmico (AVCi) em imagens de TC simples (sem contraste), baseado na classificação de informações de textura, com o propósito de construir uma ferramenta de *software* computacional capaz de gerar tal segmentação.

1.2.2. Objetivos Específicos

Como objetivos específicos desta dissertação, podemos citar:

- Pesquisar e estudar métodos de segmentação de imagens baseados em textura;
- Empregar classificadores na detecção de regiões cerebrais com AVCi;

- Desenvolver um *software* de visão computacional capaz de segmentar uma região lesionada por AVC;
- Simular e avaliar o algoritmo implementado comparando os resultados com imagens segmentadas manualmente para quantificação de eficácia.

1.3. Organização da Dissertação

A dissertação está estruturada em quatro capítulos, além da introdução. O primeiro desses capítulos (Capítulo 2) aborda o referencial teórico, subdividido em breve histórico do diagnóstico por imagem e sua evolução, fisiologia cerebral, fisiopatologia do AVC e trabalhos relacionados. Enquanto que no segundo capítulo (Capítulo 3) é feita uma revisão bibliográfica sobre análise de texturas em imagens digitais e apresentados os descritores de Haralick, utilizados na metodologia do trabalho.

No Capítulo 4, é abordada a metodologia utilizada para o desenvolvimento do sistema proposto, bem como seus aspectos técnicos, a arquitetura do classificador e coleta de dados da investigação proposta.

No Capítulo 5, são apresentados os resultados obtidos dos processos de análise estatística, onde se estuda a aplicação de diferentes descritores de texturas em várias combinações, bem como a classificação com uma Rede Neural Artificial. No Capítulo 6, são apresentadas as considerações finais, bem como as contribuições da pesquisa e as sugestões para trabalhos futuros.

No Apêndice A são expostos os resultados obtidos com apenas um descritor, testado com cada uma das imagens da base. No Apêndice B estão os resultados obtidos a partir de testes com combinações de dois descritores, enquanto que, no Apêndice C, encontram-se resultados obtidos com grupos de três descritores, combinados entre si.

Capítulo 2

A tomografia computadorizada

2.1. Histórico do diagnóstico por imagem

Conforme Martins [25], em 28 de dezembro de 1895, o então professor de Física da Universidade de Würzburg, na Alemanha, Wilhelm Conrad Roentgen submeteu um relatório preliminar aos *Proceedings of the Würzburg Physico Medical Society* sobre seus experimentos que culminaram na descoberta de "um novo tipo de raios", enquanto realizava investigações relacionadas a fenômenos luminosos e outras emissões geradas por descargas de correntes elétricas em tubos de vidro com vácuo. Segundo Pereira [26], estes raios invisíveis que Röntgen designou por "X-strahlen", ou "raios-X", receberam o nome "X" por serem de natureza, até então, desconhecida.

Por tal descoberta, segundo Martins [25], Röntgen foi aclamado como o descobridor de um milagre médico, no entanto, o cientista recusou-se a patentear sua descoberta. Contudo fora o primeiro laureado com o Prêmio Nobel em Física, em 1901. Segundo Marder [27], esse feito é o motivo para alguns ainda se referirem a radiografia por Roentgenografia.

Silva [28] afirma que desde a descoberta dos raios X, até os dias de hoje, surgiram várias modificações nos aparelhos iniciais a fim de se reduzir a radiação ionizante usada nos pacientes, pois acima de certa quantidade é prejudicial à saúde. Assim foram surgindo tubos de Raios X, diafragmas e grades antidifusoras para diminuir a quantidade de Raios X assim diminuindo a radiação secundária que, além de prejudicar o paciente, prejudicava a imagem final.

Algumas destas modificações, e alguns acontecimentos, podem ser resumidos a partir de informações extraídas de um texto da Sociedade de Radiologia de Minas Gerais [29], conforme segue:

- abril de 1896: fez-se a primeira radiografia de um projétil de arma de fogo no interior do crânio de um paciente (radiografia feita na Inglaterra);
- dezembro de 1896: descoberta dos contrastes rádio-opacos de bário e bismuto, pelo fisiologista americano Walter B. Cannon [30];

- novembro de 1899: Oppenheim descreveu a destruição de sela túrcica por um tumor hipofisário;
- março de 1911: Hensxhen radiografou o conduto auditivo interno alargado por um tumor do nervo acústico;
- novembro de 1912: Lackett e Stenvard descobriram ar nos ventrículos ocasionados por uma fratura do crânio;
- em 1918, o cirurgião americano Walter E. Dandy (1886-1946) descobriu que, ao injetar ar por meio de uma agulha, diretamente nos ventrículos cerebrais, eles se destacavam na radiografia, permitindo assim um grau adicional de referência espacial, além dos acidentes ósseos. Essa técnica, denominada de pneumoencefalografia, foi usada por muitas décadas, até se descobrir que meios iodados injetados nos ventrículos forneciam um contraste melhor [31];
- julho de 1927: O neurologista português Antônio Egas Moniz descobriu a angiografia cerebral pela introdução de contrastes (solução de iodeto de sódio) na artéria carótida no pescoço.

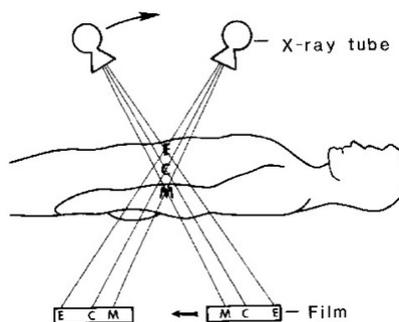
Segundo Sabbatini [31], Moniz inventou um equipamento que tirava rapidamente várias radiografias à medida em que o contraste intra-arterial progredia dentro do cérebro, e um outro, para mostrar rapidamente em sequência as radiografias tiradas, como em um filme ou em um desenho animado. Nascia, assim, um método indireto de estudar função através de um método eminentemente estrutural, como os raios X. Sabbatini [31] ainda afirma que os radiologistas logo descobriram que se tirassem várias radiografias em diferentes incidências e planos, podiam combinar essas imagens para obter uma localização espacial mais específica dentro do cérebro.

Em 1930, o holandês Ziedses des Plantes desenvolveu uma tecnologia específica, denominada de planigrafia linear, que se baseia no movimento linear simultâneo do filme e da fonte de raios X, em direções opostas (Figura 2.1), essa estratégia mantém o foco sobre a estrutura que se quer obter a imagem, no interior do corpo, que aparece mais nítida, em contraste com as estruturas distantes desta, que aparecem desfocadas, produzindo a visualização de uma espessura pré-determinada de tecido [32].

Segundo Sabbatini [31], tempos depois a planigrafia recebeu o nome mais apropriado de tomografia linear, palavra essa derivada do grego antigo *τόμος* (tomos), que significa "corte" ou "fatia" e *γραφω* (graphō) que significa "escrever" ou "escrita", atualmente também chamada de tomografia convencional.

Em 1931, o italiano Alessandro Vallebona desenvolveu uma técnica semelhante, no entanto, mais sofisticada, que fazia o equipamento girar em torno de um eixo onde estava localizado o paciente, a qual chamou de estratigrafia [33]. Posteriormente, esta

Figura 2.1 – Princípio da planigrafia linear de Des Plantes.



Fonte: [31]

técnica foi rebatizada com o nome de tomografia axial, e que foi a antecessora da tomografia computadorizada.

Carvalho [34] afirma que o engenheiro eletrônico escocês Sir Godfrey Newbold Hounsfield acreditava que um feixe de raios X continha mais informação do que aquela que era possível capturar com um filme e pensou que um computador talvez pudesse ajudar a obter essa informação. No início de século XX, o matemático austríaco Johann Radon desenvolveu uma equação matemática, a "transformada de Radon", que futuramente seria a base matemática da tomografia computadorizada, tal equação demonstra que um objeto tridimensional poderia ser reproduzido a partir de um conjunto de projeções.

No entanto, a contribuição matemática fundamental para o problema da reconstrução das regiões de radiação foi feita em 1963 e 1964 pelo físico norte-americano Allan M. Cormack. Hounsfield, engenheiro experiente com radares, particularmente interessado em computadores, e com total liberdade da EMI Ltd (*Electrical and Musical Industries Limited*) para realizar suas pesquisas, foi o criador do primeiro computador totalmente transistorizado da Inglaterra e já tinha ideias de estudar o interior de objetos tridimensionais a partir da reconstrução obtida pela absorção heterogênea de radiação pelos diferentes componentes [34].

Os experimentos de Hounsfield, utilizando as equações de Cormack, resultaram no desenvolvimento do primeiro aparelho prático de tomografia axial computadorizada, quando, em 1967, Hounsfield adquiriu um tubo e um gerador de raios X para realizar seus estudos. Hounsfield já havia feito experimentos com uma fonte de amerício-241, emissora de raios gama, contudo, focou no uso dos raios X provavelmente porque esses tinham suas propriedades bem conhecidas, sendo uma fonte confiável de informação [34]. Além do mais, segundo Carvalho [34], o protótipo de Hounsfield com raios Gama consumia o tempo de nove dias para aquisição da imagem e o computador levava 150 minutos para processar e reconstruir uma única imagem, enquanto que, com raios X, o novo protótipo teve o tempo de aquisição das imagens reduzido para nove horas. As primeiras imagens

diagnósticas (uso clínico) foram mostradas no congresso anual do *British Institute of Radiology*, em 20 de abril de 1972.

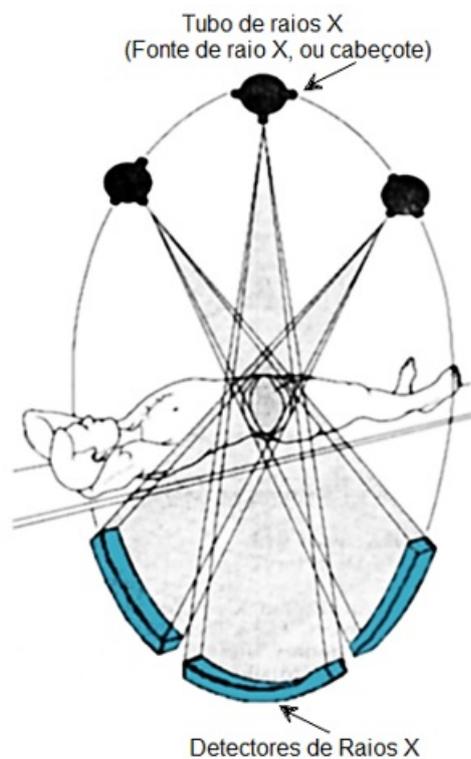
Hounsfield recebeu o prêmio Nobel de Medicina de 1979, juntamente com Cormack, pela invenção da tomografia computadorizada. Recebeu dezenas de homenagens em vida, entre elas diversos títulos de "Doutor Honoris Causa" de importantes universidades e o título de "Sir", por sua indicação a Cavaleiro do Império Britânico [34].

2.2. Formação da Imagem

Na tomografia computadorizada, um feixe de raios-X colimado é direcionado ao paciente, e a radiação atenuada em diferentes proporções é medida por detectores montados diametralmente opostos ao sistema emissor de raios-X, também chamado de cabeçote [35], conforme é ilustrado na Figura 2.2.

A intensidade de radiação detectada pelos sensores de raios-X varia de acordo com a densidade e número atômico de cada tecido biológico analisado e, para cada ângulo de incidência do feixe, obtém-se uma projeção da anatomia do paciente, tal como uma sombra da área iluminada no paciente [36].

Figura 2.2 – Ilustração da emissão de raios-X para a formação de uma imagem de tomografia.



Fonte: [36]

Para a formação da imagem, são necessárias múltiplas tomadas de dados em diferentes ângulos de projeção, esses dados são processados por um computador que, por sua vez, interpreta o grau de densidade dos diferentes tecidos, atribuindo a cada um deles um valor correspondente de uma escala níveis de cinza, o resultado final é apresentado em uma matriz de *pixels* que formam a imagem tomográfica [37].

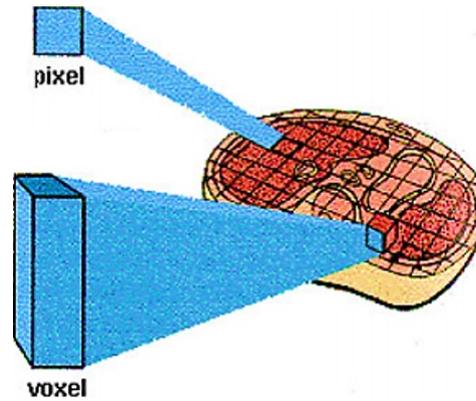
Normalmente são utilizadas matrizes de 256 x 256, 320 x 320, 512 x 512 ou 1024 x 1024 *pixels*. O tamanho de cada *pixel* é determinado pelo tamanho dessa matriz e pelo campo de visão configurado pelo técnico operador quando da realização do exame [38]. O campo de visão, ou FOV (*Field of View*), refere-se a área analisada pela tomografia, ou seja, pode ser vista como a largura do espaço de visualização da imagem e pode representar um quadrado de lado L ou um círculo de diâmetro L [39].

Conforme Caceres [38], considerando-se que quanto menor o tamanho do *pixel*, melhor a resolução da imagem, a seleção de um FOV pequeno para uma matriz grande otimiza a resolução espacial da imagem, portanto, com um mesmo FOV, a resolução de uma determinada imagem irá melhorar com a utilização de uma matriz maior, da mesma forma, com uma mesma matriz, a resolução dessa mesma imagem irá melhorar com o uso de um FOV pequeno.

No final da rotação, obtêm-se todos os ângulos de projeção necessários para a construção da imagem de uma secção (fatia ou *slice*) do corpo do paciente e o conjunto cabeçote-detector, acoplados mecanicamente, retorna para a posição inicial, nesse momento a mesa com o paciente pode se mover em alguns milímetros para que o tomógrafo possa realizar uma nova varredura ou corte, esse processo se repete várias vezes, tantas quantas forem o número de cortes solicitadas pelo médico [36].

A distância entre um corte e outro caracteriza uma espessura de fatia e, segundo Simoes [37], essa espessura traz uma terceira dimensão (eixo z), que está relacionada à profundidade do corte. Portanto, a densidade de tecido apresentada pelo nível de cinza em cada *pixel* da imagem na tela do computador representa na verdade, não uma área, mas um pequeno elemento de volume da fatia, denominado *voxel*.

Cada ponto de informação (*pixel* e *voxel*) possui sua orientação espacial e seu brilho ou intensidade designadas por um código com um tamanho fixo de N bits sequenciais (chamado de *word*), assim, em uma imagem na qual o *pixel* é caracterizado por 8 bits, cada ponto de informação pode assumir uma das 256 tonalidades de cinza possíveis. Segundo Bilinski [41], as imagens digitais radiográficas são concebidas em tons de cinza e podem ter seus *pixels* codificados com 8 bits (256 níveis de cinza), 12 bits (4096 níveis de cinza), ou 16 bits (65.636 níveis de cinza). Esses níveis de cinza são caracterizados por um valor numérico que representa as densidades dos tecidos, essas densidades são obtidas a partir dos coeficientes de atenuação linear, medidos pelos receptores de raios-X, por meio de complexos cálculos matemáticos que serão executados pelo computador do sistema de tomografia [42]. Porém, segundo Oliveira [43], os valores dos coeficientes de atenuação

Figura 2.3 – Representação do *pixel* e do *voxel*.

Fonte: [40]

linear, $\mu(x,y)$, são números reais de alta precisão úteis para computação, mas não para a exibição de imagens, pois a maioria dos hardwares de exibição usa números inteiros para representar imagens.

Outro problema para a formação da imagem é que, segundo Nersissian [44], para a visualização direta dos $\mu(x,y)$, seria necessário realizar uma comparação entre vários equipamentos em faixas de energia e filtração diferentes, o que é inviável. A solução para esses problemas, conforme Cheade [45] e Oliveira [43], é truncar os valores de atenuação linear para números inteiros, e normaliza-los com base em uma referência comum.

Para a normalização, Hounsfield criou uma escala, denominada escala Hounsfield (ou números de CT - *Computed Tomography*), utilizando a água como referência, pelo fato de que sua atenuação linear é similar ao dos tecidos moles e também por ser de fácil obtenção para calibrar os equipamentos. Nessa escala, Hounsfield atribuiu, arbitrariamente, o valor 0 (zero) para a água e, da mesma forma, atribuiu o valor -1000 ao ar (meio de menor atenuação de raios-X na tomografia), bem como o valor 1000 ao osso (meio de maior atenuação de raios-X na tomografia), atualmente medidos unidade Hounsfield (HU), em homenagem ao idealizador [43, 45, 46].

A definição do número de CT, em unidades de Hounsfield, é dada pela seguinte equação:

$$HU = 1000 \cdot \frac{\mu_t - \mu_{\text{agua}}}{\mu_{\text{agua}}} \quad (2.1)$$

Em que:

- μ_t é o coeficiente de atenuação linear do tecido;
- μ_{agua} é o coeficiente de atenuação linear da água.

Na Tabela 2.1, a seguir, pode ser verificado um resumo dos valores médios de número de CT para alguns órgãos e tecidos do corpo humano.

Tabela 2.1 – Exemplos de números de CT.

Tipo de Tecido	Valor Médio (HC)
Ósseo (compacto)	>250
Ósseo (esponjoso)	130 ±100
Sangue (coagulado)	80 ±10
Tiróide	70 ±10
Fígado	65 ±5
Sangue (venoso)	55 ±5
Pâncreas	50 ±10
Músculo	45 ±5
Baço	45 ±5
Linfoma	45 ±10
Substância cinzenta (cérebro)	45 ±5
Substância branca (cérebro)	35 ±10
Rim	30 ±10 %
Água	0
Gordura	-65 ±10
Pulmão	-650 ±250
Ar	-1000

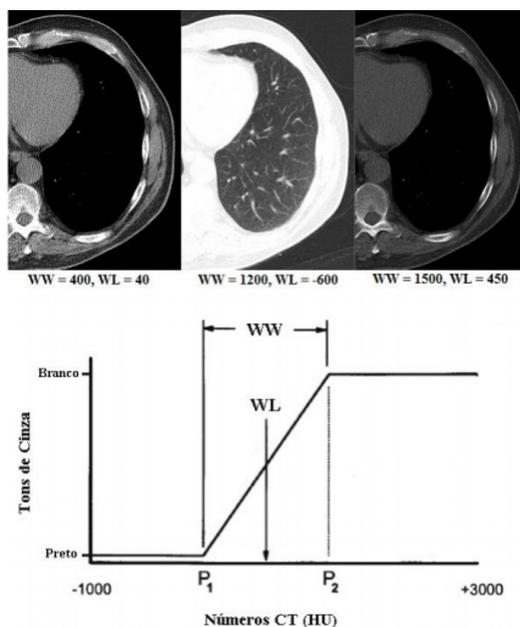
Fonte: [43, 45]

2.3. Apresentação da Imagem

É comum encontrar referências que fazem menção à faixa de -1000 a 3000 HU, para os níveis de cinza da escala de Hounsfield [46-49]. Tal consideração garante 4000 níveis de cinza para a representação de tecidos, sendo assim, as imagens de TC normalmente possuem palavras código de 12 *bits* [43]. No entanto, os *hardwares* de visualização de dados em computadores, tais como os monitores, estão dotados de *pixels* cujas cores são codificadas em componentes de 8 *bits* (256 níveis de cinza), portanto, a gama de tons de cinza que podem existir em uma só imagem é muito superior à capacidade de discriminação dos monitores do computador. Tal fato faz com que seja necessário um ajuste dos dados das imagens de TC, para que assim possam ser exibidos em uma tela computacional [43]. A definição de WW e WL são feitos a partir de uma tabela com valores padrão de número CT (tal como a Tabela 2.1) para os tecidos que se deseja observar, de forma que o nível da janela é o valor médio em HC do tecido e a largura da janela é a consideração da margem de erro para mais e para menos.

Segundo Oliveira [43], a técnica mais utilizada em TC para realizar esse ajuste de níveis de cinza é o janelamento (*windowing*), no qual a largura da janela (WW - *Window Width*) delimita o intervalo de números CT a serem exibidos, determinando o contraste da imagem, e o nível da janela (WL - *window level*) é o centro ou ponto médio do intervalo de números CT, tal ajuste pode ser realizado por meio de interpolação linear (Figura 2.4).

Figura 2.4 – A técnica de janelamento: O nível de contraste é inversamente proporcional ao valor de WW.



Fonte: [43]

Segundo Oliveira [43], os *pixels* que possuem números de CT acima do limite superior da janela são mostrados na cor branca, enquanto que aqueles cujos números de TC estão abaixo do limite inferior apresentam-se em preto. Valores de WL próximos de zero são ideais para visualização de tecidos moles; valores negativos, estruturas pulmonares; e valores muito altos irão evidenciar os ossos [43], portanto, a seleção da largura e do nível da janela é extremamente importante porque definem quais as estruturas serão visualizadas e posteriormente impressas de forma adequada em um filme para a interpretação pelo médico [43].

Quanto ao janelamento, fica claro que essa técnica se mostra como uma solução eficaz para a visualização de imagens de TC. Contudo, das diversas vantagens da TC, uma delas é a possibilidade de guardar exames em meios digitais, com a possibilidade de compartilhamento rápido e eficiente por meios de sistemas de informação. O problema é que existem vários fabricantes de *scanners*, cada qual com o seu formato próprio para as imagens resultantes, fato que inviabiliza a troca de dados médicos entre hospitais ou centros de diagnóstico que tenham equipamentos de marcas diferentes [50].

Segundo Rubio [50], em 1983, visando garantir a interoperabilidade entre equipamentos de marcas diferentes e garantir que a comunicação não ficasse prejudicada pela conversão em diferentes formatos, o ACR (*American College of Radiology*) e o NEMA (*National Electrical Manufacturers Association*) formaram um comitê e desenvolveram um método padrão para a transferência de imagens médicas e as informações associadas a elas.

Com os estudos dessa comissão, a ACR-NEMA publicou em 1985, a primeira versão do padrão DICOM (*Digital Imaging and Communication in Medicine*), visto hoje como o padrão mundial de formato de imagens médicas [45]. A versão 1.0 foi sucedida por duas subversões: a N^o 1, publicada em outubro de 1986 e a N^o 2, publicada em janeiro de 1988. No mesmo ano de 1988 foi publicada a versão 2.0 do padrão DICOM e, atualmente, o padrão DICOM está na sua versão 3.0 [50].

Rubio [50] afirma que o DICOM é mais do que um formato de arquivo, é uma infraestrutura de comunicação para operações de armazenamento e compartilhamento de imagens médicas, e foi concebido para cumprir os seguintes objetivos:

- Promover a comunicação de informações de imagens médicas digitais, independentemente de tipo de equipamento;
- Facilitar o desenvolvimento e a expansão de sistemas de arquivamento e comunicação de imagens, preparando-os também para a interação com outros sistemas hospitalares de informação;
- Permitir a criação e o compartilhamento de bancos de dados com informações de diagnósticos.

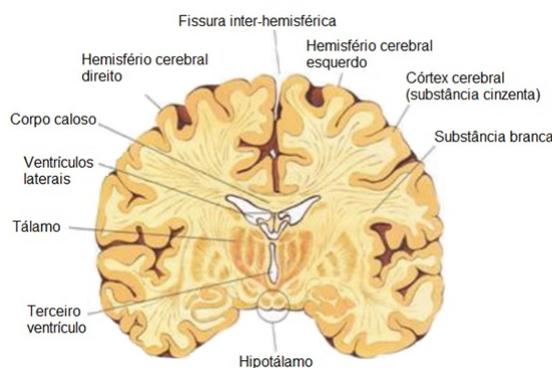
2.4. Anatomia e Fisiologia Cerebral

O cérebro é o principal órgão do sistema nervoso central no qual se integram e elaboram as grandes funções motoras, sensitivas e associativas do sistema nervoso [51]. Segundo [52], esse importante órgão está dividido em duas regiões, denominadas hemisférios cerebrais esquerdo e direito, interligados entre si pelo corpo caloso, largos feixes de fibras nervosas, situadas na parte inferior da fissura inter-hemisférica.

Cada hemisfério possui uma fina camada de 1 a 3 milímetros que envolve suas superfícies externas (Figura 2.5), chamada de córtex cerebral [53], composta de substância cinzenta, cuja coloração é produzida pela agregação de milhares de corpos celulares [52].

No córtex cerebral, uma das partes mais importantes do sistema nervoso, chegam impulsos provenientes de todas as vias da sensibilidade que aí se tornam conscientes e são interpretadas, bem como saem os impulsos nervosos que iniciam e comandam os movimentos voluntários e com ele estão relacionados os fenômenos psíquicos [54].

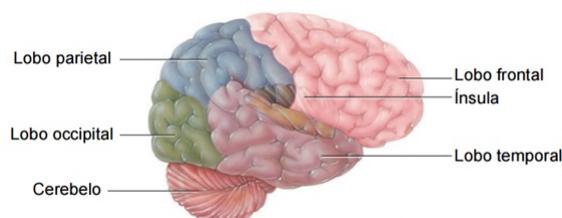
Situada debaixo do córtex cerebral está uma abundante camada de substância branca, contendo feixes de axônios neuronais mielinizados, que lhe conferem a aparência branca [52]. A mielina é uma substância branca e gordurosa que envolve axônios mais longos dos neurônios, isolando-os e protegendo-os de interferências elétricas de outros neurônios na área, acelerando a condução da informação [53].

Figura 2.5 – Secção coronal do cérebro no nível dos corpos mamilares.

Fonte: [52]

No trabalho desenvolvido por Silva [55] é afirmado que, entre os hemisférios, estão os ventrículos cerebrais, classificados como ventrículos laterais e terceiro ventrículo. Além desses conta-se ainda com um quarto ventrículo, localizado mais abaixo, ao nível do tronco encefálico, esses sistemas são reservatórios do chamado líquido céfalo-raquidiano, ou líquor, cujas atribuições são a nutrição, proteção e excreção do sistema nervoso.

Segundo Arruda [51], existem inúmeras subdivisões anatómicas para o cérebro. As mais evidentes são os hemisférios cerebrais, as circunvoluções e os sulcos. Para além destas existem outros pontos de referência que ajudam a subdividir cada hemisfério em quatro partes: o lobo occipital, o lobo parietal, o lobo temporal e o lobo frontal (Figura 2.6).

Figura 2.6 – Lobos Cerebrais.

Fonte: [51]

2.5. Fisiopatologia do AVC

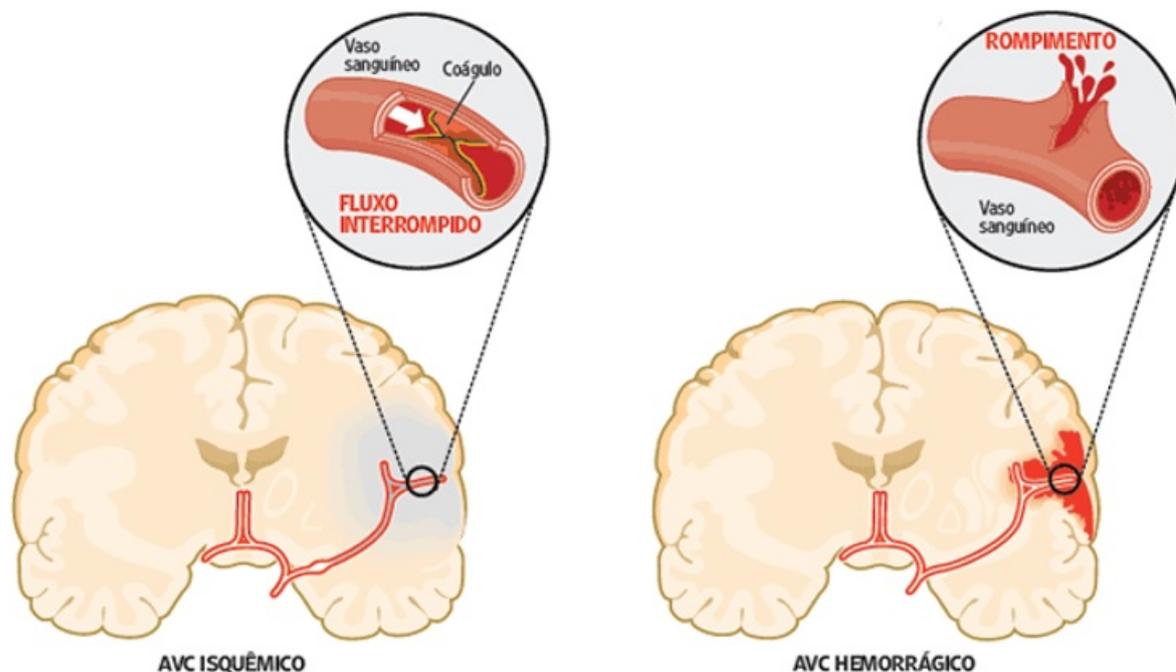
A expressão Acidente vascular cerebral (AVC), ou acidente vascular encefálico (AVE), ou ainda doença vascular encefálica, como está se tornando uma preferência recente, refere-se a um complexo de sintomas clínicos de deficiência neurológica, com distúrbio focal (ocasionalmente global), que duram pelo menos vinte e quatro horas e resultam de lesões cerebrais provocadas por alterações da irrigação sanguínea [56].

Isto porque o tecido nervoso é desprovido de reservas, sendo totalmente dependente da circulação sanguínea, pois seu metabolismo depende de oxigênio e glicose, portanto uma diminuição do fluxo sanguíneo tem como consequência uma parada ou diminuição da atividade cerebral na área que sofreu a alteração da irrigação [57].

Cacela [57] aponta que, se a interrupção do fluxo for inferior a 3 minutos, a alteração é reversível; se ultrapassar os 3 minutos, a alteração funcional pode ser irreversível, originando necrose do tecido nervoso, sendo que esta interrupção pode ser causada por dois mecanismos diferentes: a oclusão de um vaso provocando isquemia e enfarte da área dependente desse vaso (AVC isquêmico, ou AVCi, 80% dos casos) ou a ruptura vascular (AVC hemorrágico, ou AVCh, 20% dos casos) [18], conforme é ilustrado na Figura 2.7.

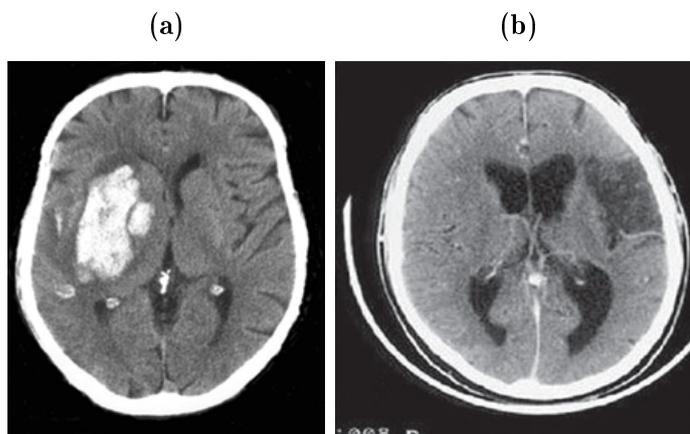
Conforme Dohmann [58], o padrão mais frequente em pacientes com AVC agudo possui uma área de necrose (core) envolvida por uma área de hipoperfusão de tecido cerebral isquêmico, mas ainda viável (penumbra). Ainda segundo Dohmann [58], este padrão normalmente persiste por 24h, contudo, as células localizadas na zona de penumbra morrem progressivamente e o core se expande em, aproximadamente, toda a área de hipoperfusão inicial.

Figura 2.7 – Mecanismos fisiopatológicos do AVCi e do AVCh.



Fonte: [59]

Segundo Oliveira [60], existem várias síndromes neurológicas vasculares que permitem um diagnóstico topográfico (localização da lesão no sistema nervoso) relativamente preciso, mas a definição correta da etiologia vascular e ainda, a diferenciação entre um evento isquêmico e hemorrágico só é possível com estudo de imagem de crânio.

Figura 2.8 – Imagens de TC: (a) AVCh (b) AVCi

Fonte: [61], [62]

Tal estudo normalmente está baseado em TC de crânio, sem a utilização de contraste, podendo evidenciar-se, dependendo do tempo de evolução, tipo do AVC e do território envolvido.

Visualizando a Figura 2.8 pode-se perceber duas TC simples do cérebro, na imagem (a), uma mancha branca no hemisfério cerebral direito, que caracteriza uma hemorragia intracerebral (AVCh), enquanto que na imagem (b) percebe-se uma mancha escura no hemisfério cerebral esquerdo, que por sua vez caracteriza uma região de isquemia (AVCi).

Conforme já mencionado, na TC os tecidos de baixa densidade como gordura ou o ar, são localizadas em imagens de TC nas regiões onde as cores são mais próximas à preta em uma escala de tons de cinza. Por sua vez, tecidos mais densos, como o sangue e ossos, possuem maiores valores de atenuação de raios-X e, por tanto, são representados por cores mais próximas à branca. Isto explica a cor escura para a região de isquemia (falta de suprimento sanguíneo para um tecido) ou a cor clara para a região de hemorragia (sangramento) cerebral.

2.6. Trabalhos Relacionados

O processamento de imagens médicas é um problema bastante explorado na literatura científica especializada. Existem diferentes trabalhos referentes ao tema, dentre os quais pode-se destacar:

- Classificação de lesões mamárias, de pele ou pulmonares [63-65], dentre outras;
- Segmentação de áreas, regiões e elementos em de Imagens [66-68].

Trabalhos com algum nível de relação ao que se propõe neste projeto (Segmentação de Regiões de AVC Isquêmicos em Imagens de TC por meio da Classificação

de Textura), também podem ser encontrados na literatura, como por exemplo o trabalho realizado por Alegro [21], onde é descrita a formulação de um sistema para segmentação de tumores de cérebro que emprega parâmetros de textura, extraídos de diferentes tipos de imagem (sequência T1, com a qual as regiões com predominância de água ficam escuras, sequencia T2 com contraste, com a qual as regiões com predominância de água brilham e FLAIR - T2 com supressão do líquido) para segmentação das regiões tumorais em Ressonância Magnética (RM) do crânio, que é um método de diagnóstico por imagem que usa ondas de radiofrequência e um forte campo magnético para obter informações detalhadas dos órgãos e tecidos internos do corpo, sem a utilização de radiação ionizante. Segundo a autora desse trabalho as segmentações concebidas com os primeiros testes foram consideradas relativamente precisas, haja vista que o sistema obteve uma taxa média de acerto de aproximadamente 83%, na classificação dos *pixels*, calculada em termos do número de Positivos Verdadeiros (PV) e dos pixels Padrão Ouro (PO), utilizando-se um classificador devidamente ajustado para o caso.

Em seu trabalho intitulado "Segmentação das Áreas Isquêmicas no Acidente Vascular Cerebral Utilizando Imagens de Tomografia Computadorizada de Perfusão", Contin [18] descreve a metodologia adotada para o desenvolvimento de um *software* para segmentação semiautomática das áreas isquêmicas, core e penumbra, no acidente vascular cerebral, utilizando técnicas de limiarização e segmentação baseada em regiões. Apesar do título, o sistema desenvolvido não consegue seus resultados de forma independente. O processamento realizado pelo *software* não é feito sobre imagens adquiridas diretamente de um equipamento de TC, ao invés disso o sistema é alimentado com os mapas de perfusão (representações gráficas de medidas sobre os processos de o fornecimento de oxigênio e nutrientes para o tecido cerebral, como fluxo e volume sanguíneo ou extração de oxigênio do sangue) calculados a partir das referidas imagens por meio do *software* de código fechado *Stroketool-CT* desenvolvido pelo Dr. H. J. Wittsack (*University of Düsseldorf*) na Alemanha. Portanto o sistema desenvolvido funciona como uma espécie de módulo do *Stroketool-CT*. Segundo a autora a confiabilidade da segmentação depende do método escolhido para calcular os mapas de perfusão. Utilizando o mapa de perfusão CBV (Volume de Sangue Cerebral) os resultados tiveram a sensibilidade oscilando entre 48% (casos de imagens simples, onde a área isquêmica é facilmente reconhecida porque seus valores de intensidade são muito diferentes daqueles encontrados no tecido saudável) e 20% (caso de imagens complexas, nas quais não se percebe uma barreira de *pixels* com valores que garantam a separação dos tecidos), utilizando o mapa de perfusão CBF (Fluxo de Sangue Cerebral) os resultados tiveram sensibilidade oscilando entre 17% (casos de imagens simples) e 5% (caso de imagens complexas) e utilizando o mapa de perfusão MTT (Tempo de Trânsito Médio) os resultados tiveram sensibilidade oscilando entre 22% (casos de imagens simples) e 13% (caso de imagens complexas). A autora ressalta que qualquer um dos resultados são obtidos em um tempo inferior a 5 minutos.

Por meio do trabalho intitulado de "Análise de Textura em Imagens Cerebrais: aplicações em Acidente Vascular Cerebral Isquêmico, Epilepsia Mioclônica Juvenil, Doença de Machado-Joseph, Déficit Cognitivo Leve e Doença de Alzheimer" [69], é realizada uma análise em imagens de TC de vítimas de AVCi e das imagens de RM de portadores de Epilepsia Mioclônica Juvenil, Doença de Machado-Joseph, Déficit Cognitivo Leve e Doença de Alzheimer, visando uma contribuição com alternativas para a identificação de áreas atingidas por estas doenças. Em sua metodologia, a autora realiza a seleção de regiões de interesse (ROI) em cada imagem e, a partir dessas ROI, são calculados descritores de Haralick para textura, baseados na matriz de coocorrência da seleção. Após o cálculo dos descritores de textura foi realizada uma análise estatística para verificar se há diferenciação entre os vários tipos de tecidos. Os esforços desse trabalho estão focados na análise da eficácia dos descritores de Haralick como indicadores para as doenças avaliadas, e não traz evidências do desenvolvimento de uma ferramenta computacional para uso das técnicas propostas, os resultados obtidos mostraram que a análise de textura pode, de fato, ser utilizada para a extração de características discriminantes, tanto nas imagens de TC quanto nas imagens de RM para as cinco patologias analisadas.

O trabalho desenvolvido por Antonio [70], aplica técnicas de inteligência computacional e processamento de imagens na identificação de áreas hiperdensas e/ou hipodensas anormais em exames de Tomografia Computadorizada de Crânio em conjunto com a história clínica do paciente. Segundo o próprio autor, os objetivos propostos no seu trabalho (Ferramenta de Auxílio Diagnóstico Para o Tratamento de Acidentes Vasculares Cerebrais) foram alcançados, pois foram obtidos valores de sensibilidade e especificidade de 96% e 94%, respectivamente. A metodologia utilizada por [70] utiliza uma Rede Neural Artificial MLP com 13 elementos na camada de entrada, 2 elementos na camada de saída e uma camada oculta com 7 elementos, conectando a camada de entrada à de saída. Dos 13 pontos de entrada da RNA, 11 recebem valores de parâmetros clínicos, concebidos por meio de respostas dadas pelo paciente às seguintes questões: Idade do paciente, Sexo, Fumante, Vômito, Diabetes, Cefaléia, Tempo de cefaleia, Angina, Déficit motor, Pressão alta e Depressão do estado de consciência. Cada uma das perguntas pode ter de duas a quatro respostas padronizadas, oferecidas através de um questionário com perguntas de múltipla escolha. Cada item de resposta é codificado por um valor numérico real entre 0 e 1, igualmente espaçados; os outros dois elementos de entrada recebem valores vindos de um processamento de imagens simples, na qual é realizada uma contagem dos *pixels* da TC que possuem valor de HU entre 60 e 75 (estipulada pelo autor como faixa de *pixels* possivelmente representantes de um AVC hemorrágico), e outra contagem daqueles que possuem valor de HU entre 15 e 20 (estipulada pelo autor como faixa de *pixels* possivelmente representantes de um AVC isquêmico). A metodologia também prevê a aplicação de técnicas de morfologia matemática com uma erosão seguida por uma dilatação, buscando diminuir os ruídos (falsos positivos),

como forma de normalizar os valores de entrada, o autor divide cada um dos resultados por 1000 e satura o máximo valor em 1. As possíveis saídas para a RNA são: 0 0, para exames normais; 0 1, para AVC hemorrágico; 1 0, para AVC isquêmico; 1 1, para AVC hemorrágico e Isquêmico. Apesar de os resultados dos testes se mostrarem como satisfatórios, o autor sugere o desenvolvimento de um módulo para a localização da lesão, pois, mesmo indicando existência ou inexistência de um dado tipo de AVC, o sistema proposto não realiza um diagnóstico topográfico, portanto, não aponta a localização da patologia.

Sarmiento *et al* [71], apresentam uma comparação entre duas metodologias semiautomáticas para segmentação de regiões de AVC, em uma dessas metodologias foi utilizada a *Watershed* (técnica de segmentação de imagens, pertence ao campo da morfologia matemática), na outra utilizou-se a técnica de Crescimento de Regiões. O processo é considerado semiautomático pelo fato de ser necessária uma seleção manual, por meio de eventos do click do mouse, de uma região de interesse (que compreende grosseiramente a localização do AVC) e outro para o fundo da imagem, pois a aplicação direta das técnicas apresentadas sobre toda a imagem pode ocasionar uma supersegmentação. Os dois algoritmos foram submetidos a testes de segmentação. Segundo os autores, a transformada *Watershed* forneceu valores de acurácia entre 89% e 92%, e a especificidade ficou entre 89% e 95%, excluindo corretamente os *pixels* que não são taxados como indício para doença, enquanto que a sensibilidade alcançou valores entre 90% e 99% mostrando que o algoritmo consegue distinguir corretamente os *pixels* que indicam a doença. Quanto ao método Crescimento de Regiões atingiu valores de acurácia entre 63% e 82%, especificidade entre 66% e 93% e sensibilidade entre 73% e 92%. Para os autores todos os resultados foram considerados satisfatórios, contudo, verificando os resultados obtidos em comparação com o padrão ouro, a transformada *Watershed* realizou o processo de forma mais confiável e eficiente.

2.7. Considerações

O Acidente Vascular Cerebral isquêmico, ou AVCi, é uma alteração neurológica provocada por bloqueio parcial do suprimento sanguíneo ou por bloqueio total de fluxo. Estima-se que, 1/3 das pessoas diagnosticadas com algum tipo de AVC vão a óbito e outros 1/3 ficam permanentemente incapacitados, fato este que caracteriza o AVC como uma das patologias que mais incapacitam para a realização das atividades cotidianas.

Existem várias síndromes neurológicas vasculares que permitem um diagnóstico para AVC, mas a definição correta da etiologia vascular e ainda, a diferenciação entre um evento isquêmico e hemorrágico só é possível com estudo de imagem de crânio, normalmente resultado de uma Tomografia Computadorizada.

Diversas pesquisas na área de processamento de imagens têm buscado técnicas para a segmentação, ou demarcação, de regiões que representam o AVCi em uma imagem digital. O principal objetivo é fazer com que um algoritmo computacional, a partir dos dados contidos na imagem, destaque a região afetada por essa patologia para que o especialista tenha informações da situação de forma automatizada.

Neste trabalho a segmentação de regiões de AVCi em TC é feita com a classificação, por uma Rede Neural Artificial, de medidas estatísticas, concebidas por Haralick em 1973, capazes de mensurar a concepção de texturas trazidas pelos *pixels* da imagem. Essas medidas foram denominadas descritores de textura, pelo próprio Haralick, e são melhor fundamentadas no próximo capítulo.

3.1. Contextualização

A interpretação de textura é um processo sofisticado realizado instintivamente pela percepção visual humana, na qual mostra-se como atividade crucial [72], porém se reveste de grande complexidade computacional quando analisada via *software* por métodos matemáticos [73].

Apesar disso, várias metodologias para classificação de imagens utilizando características de textura têm sido propostos na literatura [72, 74, 75], pois entende-se que a textura desempenha um papel importante em aplicações relacionadas com imagens, haja vista que, na maioria dos casos, essas imagens podem ser consideradas um composto de diversas regiões de texturas diferentes [76].

Gonzalez e Woods [2] relatam que, mesmo não exigindo uma definição formal de textura, entende-se intuitivamente que trata-se de uma propriedade que fornece medidas de características da superfície exibida em uma imagem, tais como suavidade, rugosidade e regularidade. Entretanto, segundo Aksoy [77], não há um método genérico ou uma abordagem formal que seja útil para uma grande variedade de imagens.

Pedrini e Schwartz [1] reforçam essa ideia afirmando que uma das tarefas mais complexas na análise de imagens seria a definição de um conjunto de características que possam descrever, de maneira concreta, cada região contida em uma imagem, de forma que o uso desse conjunto de características seja determinante em processos de mais alto nível, tais como a identificação de um padrão.

Na literatura específica não é difícil encontrar referências ao trabalho desenvolvido por Haralick, Shanmugam e Dinstein em 1978, quando esses autores publicaram um artigo no qual definem textura como uniformidade, densidade, aspereza, regularidade, intensidade, entre outras características da imagem. Segundo Nascimento [78], neste mesmo trabalho Haralick [74] caracteriza textura como um conceito bidimensional, no qual uma dimensão contém as propriedades primitivas da tonalidade e a outra corresponde aos relacionamentos espaciais entre elas, portanto, os referidos pesquisadores indicam em

outros termos que os conceitos de tonalidade e textura não são independentes, porém em algumas imagens a tonalidade é dominante e, em outras, a textura é dominante.

Conforme Gonzalez [2], são normalmente utilizadas três abordagens para descrever a textura em uma região de imagem:

- **Abordagens Estatísticas:** nas quais a textura é definida por um conjunto de medidas locais, extraídas do padrão, que podem produzir métricas para a ideia de textura suave, rugosa, granulada, dentre outras [79]. Medidas estatísticas comuns incluem entropia, correlação, contraste e variância;
- **Abordagens Estruturais:** utilizam a ideia de que texturas são compostas de arranjos de primitivas (elementos estruturantes primários), dispostos de forma aproximadamente regular e/ou periódica. Em outros termos, essas abordagens tratam a textura como um conjunto de subpadrões espaciais na imagem, cuja organização segue algum tipo de regra ou lógica bem definida. Como exemplo, pode-se citar a descrição da textura baseada em linhas paralelas regularmente espaçadas;
- **Abordagens Espectrais:** baseiam-se em propriedades do espectro de Fourier, sendo principalmente utilizadas na detecção de periodicidade global em uma imagem pela identificação de picos de alta energia no espectro.

Conforme o exposto, apesar da existência de vários métodos, nenhum deles sozinho é capaz de segmentar eficientemente todos os tipos de imagens, isto por que a caracterização de uma textura é um processo com muitas dificuldades específicas de cada situação (cena capturada), como por exemplo, o impacto das irregularidades em brilho, nos padrões geométricos e nas bordas de texturas naturais, logo a segmentação por textura é um assunto que ainda necessita de muita pesquisa [80].

Mesmo diante de tantas incertezas e dificuldades, a análise de textura é um tópico emergente de bastante relevância para sistemas de Visão Computacional. De acordo com [81], a análise de textura pode estabelecer o relacionamento de vizinhança dos elementos de textura e seu posicionamento em relação aos demais (conectividade), o número de elementos por unidade espacial (densidade) e a sua regularidade (homogeneidade), sendo assim útil para:

- **Segmentação:** divisão de uma imagem em regiões com mesmo perfil textural;
- **Descrição:** extração de características baseada na quantificação de seu conteúdo de textura para discriminação entre classes de objetos;
- **Classificação:** rotulação de uma região com determinada textura com base em exemplos de texturas conhecidas;
- **Identificação de Formas:** empregar a informação de textura para derivar a geometria de uma superfície tridimensional;

- Réplica: descrever uma textura visando sua reprodução.

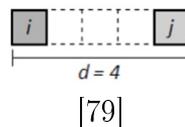
Pedrini e Schwartz [1] acreditam que grandes variações dos níveis de cinza entre os possíveis padrões primitivos que constituem a imagem caracterizam texturas finas, enquanto que regiões mais homogêneas caracterizam regiões ásperas. Como a abordagem estatística propõe métodos que associam uma medida de textura à impressão de rugosidade ou suavidade, esta foi a escolha inicial para o presente trabalho. Segundo Ballard [82] essa abordagem também é recomendada para texturas que não apresentam boa regularidade.

3.2. Matriz de Co-ocorrência de Tons de Cinza

Segundo Ventura [83], a Matriz de co-ocorrência de tons de cinza (GLCM - *Gray Level Co-Occurrence Matrix*) foi primeiramente descrita por Haralick, Shanmugam e Dinstein em 1973, neste método cada elemento P_{ij} que constitui a GLCM contém a frequência relativa com que dois *pixels* de uma vizinhança separados pela distância d ocorrem na imagem ao longo de uma direção θ , um com tom de cinza i e outro com tom cinza j , respectivamente [74]. Em outras palavras, cada elemento $P(i,j)$ da matriz de co-ocorrência indica o número de vezes que um *pixel* com tom de cinza i aparece na posição especificada pelo par (d, θ) em relação a um *pixel* de nível de cinza j . Em que:

- d é distância em *pixels* entre um nível de cinza i (*pixel* de referência) e um nível de cinza j na imagem (ver Figura 3.1);

Figura 3.1 – Exemplo de uma co-ocorrência dos níveis de cinza i e j , com vizinhança $d=4$, alinhados na direção $\theta = 0$



- θ define a posição angular do nível de cinza j dentro de uma vizinhança de *pixels*, que pode assumir um dos seguintes valores ilustrados na Figura 3.2, na qual o *pixel* central representa o nível de cinza i :

Figura 3.2 – Ângulos utilizados para cálculo da matriz de co-ocorrência com $d = 1$ [1].

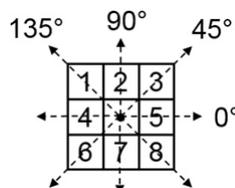
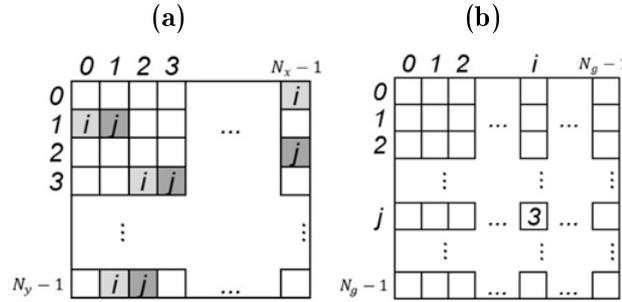


Figura 3.3 – (a) Imagem $N_x \times N_y$. (b) Matriz de co-ocorrência da imagem ($d = 1, \theta = 0$)

A GLCM possui número de linhas e colunas proporcional à quantidade de níveis de cinza (normalmente representado por N_g) contidos na textura, como apresentado em [1]. Por exemplo, a partir de uma imagem I com níveis de cinza no intervalo $[1, N_g]$, e tamanho $N_x \times N_y$, em que N_x é o número de *pixels* na direção horizontal e N_y é o número de *pixels* na direção vertical, de forma a se obter uma GLCM de tamanho $N_g \times N_g$, onde o valor em cada célula é definido por $P(i, j, d, \theta)$ [74], conforme é ilustrado na Figura 3.3. Nestes termos, fica evidente que a matriz de co-ocorrência independe do tamanho da textura analisada, fato este que, segundo [1], acarreta perda do relacionamento espacial contida nessa mesma textura.

Segundo Schwartz [84], uma vez calculada a matriz de co-ocorrência, esta pode ser convertida em uma tabela de probabilidades. Esse processo é chamado de normalização e resulta em apenas uma aproximação, já que uma probabilidade real requer valores contínuos, enquanto que os níveis de cinza são valores inteiros ou discretos.

Para normalizar a matriz de co-ocorrência cada índice é dividido pela soma total dos valores contidos na matriz, da seguinte forma:

$$P_{ij} = \frac{P_{ij}}{\sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} P_{ij}} \quad (3.1)$$

Em que:

- i é o índice da linha e j é o índice da coluna;
- P é o valor do elemento (i, j) na matriz de co-ocorrência;
- p_{ij} é a probabilidade para o elemento P_{ij} na matriz;
- N_g é o número de linhas ou colunas da matriz.

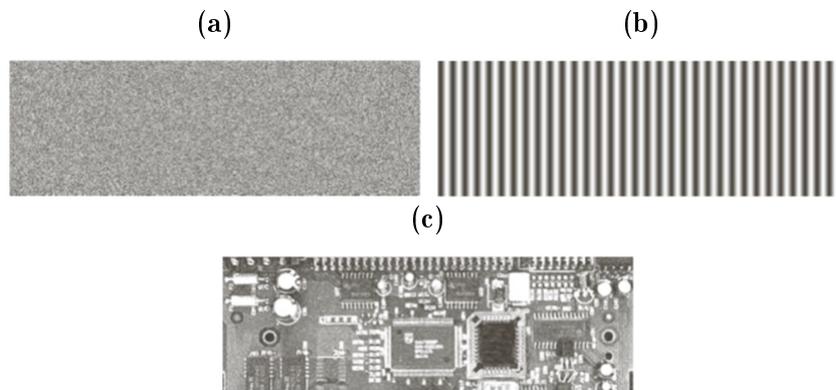
Pedrini e Schwartz [1] exemplificam o cálculo de uma matriz de co-ocorrência a partir de uma imagem hipotética, mostrada na Figura 3.4a, com a qual construiu-se uma GLCM com $N_g = 4, d = 1$ e $\theta = 0$, mostrada na Figura 3.4b, e uma matriz de co-ocorrência normalizada, mostrada na Figura 3.4c.

Figura 3.4 – Exemplo de cálculo da matriz de co-ocorrência, mostrada em (c), e sua representação normalizada, mostrada em (b), para uma imagem hipotética 5×5 e $N_g = 4$, mostrada em (a).

(a)	(b)	(c)																																																																											
<table style="border-collapse: collapse; width: 100%; text-align: center;"> <tr><td>3</td><td>2</td><td>0</td><td>1</td><td>0</td></tr> <tr><td>1</td><td>2</td><td>1</td><td>3</td><td>0</td></tr> <tr><td>3</td><td>1</td><td>0</td><td>2</td><td>3</td></tr> <tr><td>1</td><td>2</td><td>3</td><td>0</td><td>3</td></tr> <tr><td>0</td><td>0</td><td>0</td><td>0</td><td>1</td></tr> </table>	3	2	0	1	0	1	2	1	3	0	3	1	0	2	3	1	2	3	0	3	0	0	0	0	1	<table style="border-collapse: collapse; width: 100%; text-align: center;"> <tr><td></td><td>0</td><td>1</td><td>2</td><td>3</td></tr> <tr><td>0</td><td>3</td><td>2</td><td>1</td><td>1</td></tr> <tr><td>1</td><td>2</td><td>0</td><td>2</td><td>1</td></tr> <tr><td>2</td><td>1</td><td>1</td><td>0</td><td>2</td></tr> <tr><td>3</td><td>2</td><td>1</td><td>1</td><td>0</td></tr> </table>		0	1	2	3	0	3	2	1	1	1	2	0	2	1	2	1	1	0	2	3	2	1	1	0	<table style="border-collapse: collapse; width: 100%; text-align: center;"> <tr><td></td><td>0</td><td>1</td><td>2</td><td>3</td></tr> <tr><td>0</td><td>0.15</td><td>0.10</td><td>0.05</td><td>0.05</td></tr> <tr><td>1</td><td>0.10</td><td>0.00</td><td>0.10</td><td>0.05</td></tr> <tr><td>2</td><td>0.05</td><td>0.05</td><td>0.00</td><td>0.10</td></tr> <tr><td>3</td><td>0.10</td><td>0.05</td><td>0.05</td><td>0.00</td></tr> </table>		0	1	2	3	0	0.15	0.10	0.05	0.05	1	0.10	0.00	0.10	0.05	2	0.05	0.05	0.00	0.10	3	0.10	0.05	0.05	0.00
3	2	0	1	0																																																																									
1	2	1	3	0																																																																									
3	1	0	2	3																																																																									
1	2	3	0	3																																																																									
0	0	0	0	1																																																																									
	0	1	2	3																																																																									
0	3	2	1	1																																																																									
1	2	0	2	1																																																																									
2	1	1	0	2																																																																									
3	2	1	1	0																																																																									
	0	1	2	3																																																																									
0	0.15	0.10	0.05	0.05																																																																									
1	0.10	0.00	0.10	0.05																																																																									
2	0.05	0.05	0.00	0.10																																																																									
3	0.10	0.05	0.05	0.00																																																																									

Fonte: [1]

Figura 3.5 – Imagens cujos *pixels* trazem padrões de textura (a) elatório, (b) periódicos e (c) mistos.

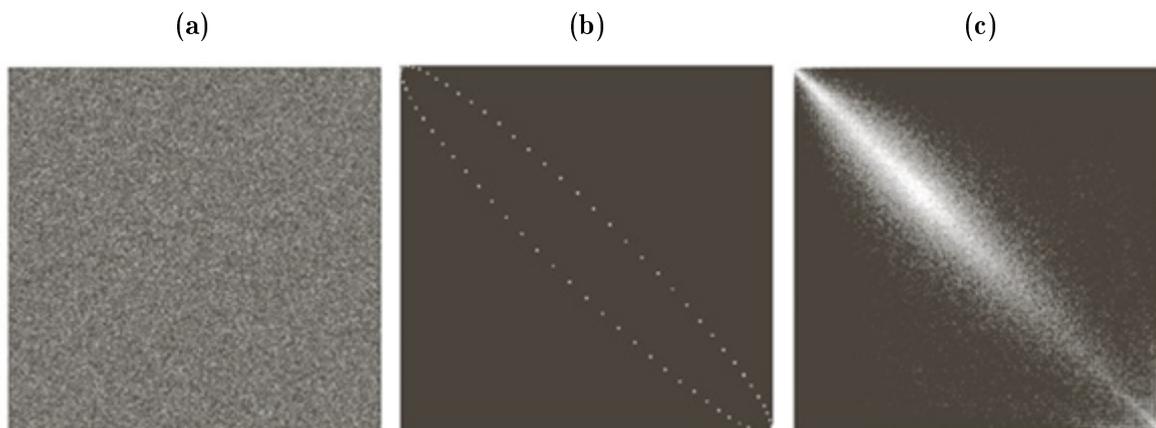


Fonte: [2]

Gonzalez [2], por meio de um experimento simples, como as GLCM podem ser interpretadas de maneira visual-humana. Para tanto, os referidos autores mostram três imagens diferentes padrões, onde: uma possui padrão de *pixels* aleatórios - Figura 3.5a, uma cuja variação de tonalidade é periódica (senoidal) no eixo horizontal - Figura 3.5b e, por fim, uma com padrões mistos - Figura 3.5c. Essas imagens, segundo [2], possuem tamanhos idênticos de 263×800 *pixels*.

Considerando $N_g = 256, d = 1$ e $\theta = 0$, [2] constroem três GLCM, denominadas G_1, G_2 e G_3 , que correspondem para as respectivas imagens. Os valores obtidos em cada matriz de co-ocorrência normalizada são plotados tal como imagens, onde os valores altos tendem à cor branca (cinzas claros), enquanto que valores baixos tendem ao preto (cinzas escuros). Os resultados podem ser observados por meio da Figura 3.6.

Na Figura 3.6c é possível observar uma maior concentração valores altos (cinzas claros) em regiões que cobrem a diagonal principal da matriz, fato este que não é percebido nas outras duas imagens. Segundo Gonzalez [2], a Figura 3.6c caracteriza uma imagem com grandes áreas de baixa variabilidade das intensidades de cor, em outras palavras, esta densidade de tons claros na região da diagonal principal caracteriza uma grande ocorrência de *pixels* vizinhos (ou muito próximos) cujos níveis de cinza são idênticos (ou pouco diferentes).

Figura 3.6 – Matrizes de co-ocorrência 256x256 (a) G_1 , (b) G_2 e (c) G_3 [2].

Gonzalez [2] também aponta a Figura 3.6a como a mais interessante, haja vista o evidente padrão simétrico sobre a diagonal principal. Isto acontece em virtude da simetria da onda senoidal, cuja natureza faz com que, na textura da imagem, o número de contagens para um par de intensidades (z_i, z_j) é o mesmo que aquele do par (z_j, z_i) . A onda senoidal constrói uma textura com um gradiente periódico, como não há vizinhos de um mesmo valor nesse gradiente a diagonal principal fica sem ocorrência e, portanto, escura.

O resultado mostrado na Figura 3.6a é aleatório, obviamente, pelo fato de que a mesma foi obtida a partir de imagem cuja natureza do padrão de textura formado pelos *pixels* é aleatória.

No entanto, todas as análises realizadas anteriormente, são apenas qualitativas, ou seja, trazem apenas respostas conceituais a partir de observações e não dá quantificação de textura [2]. Para sistemas computacionais é mais interessante que se tenham dados matemáticos que possam, com uma certa exatidão, representar por meios numéricos a textura que os originou.

Com o objetivo de conseguir tal representação, foi proposto Haralick [74] 14 medidas estatísticas calculadas a partir da matriz de co-ocorrência normalizada, vistas como sendo descritores para texturas em imagens [1].

3.3. Descritores de Haralick

Haralick [74] estabeleceu métricas de textura para uma imagem digital, ou parte dela, extraídas de sua GLCM. Essas métricas, denominadas Descritores de Haralick, são obtidas por cálculos de domínio espacial e na abordagem estatística de segunda ordem, e baseiam-se na ideia de que toda a informação de textura de uma imagem está contida total ou parcialmente em relações espaciais entre os seus tons de cinza.

Segundo Nascimento [78], tais medidas, apesar de antigas, são a base para a maioria dos trabalhos realizados nessa área. A principal desvantagem no uso das medidas de texturas baseadas em matriz de co-ocorrência é o grande custo computacional, ou seja, a exigência de memória e tempo de processamento. Por exemplo, para uma imagem de 8 *bits* (256 níveis de cinza), a matriz de co-ocorrência é composta por 65536 elementos, muitos deles com valor nulo [85].

Mesmo com essa desvantagem aparente os descritores de Haralick veem se mostrando eficientes para a análise e classificação de imagens, por conseguirem medidas capazes de discriminar as diferentes regiões de uma imagem e, portanto, podem ser vistos como assinatura de padrões definidos pelas respectivas regiões em estudo [86].

Robert Haralick e seus colaboradores apresentaram em 1973 um artigo com a descrição de métodos matemáticos que permitem a extração de 14 características diferentes da textura de uma imagem, a partir de sua matriz de co-ocorrência [74]. Essas medidas de características são chamadas de descritores de Haralick, e são definidas pelas equações f_1 à f_{14} :

3.3.1. Segundo Momento Angular

O cálculo do Segundo Memento Angular ou ASM (*Angular Second Moment*), também chamado de uniformidade, retorna valores elevados quando a imagem é muito ordenada, por tanto, pode indicar o quão suave é a textura analisada [25].

$$f_1 = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} p(i, j)^2 \quad (3.2)$$

A raiz quadrada do *ASM* também pode ser utilizada como medida de textura, e é chamada de energia.

$$ENERGIA = \sqrt{ASM} \quad (3.3)$$

3.3.2. Contraste

É uma estimativa das variações locais dos níveis de cinza entre pares de *pixels*. Por fazer essa estimativa com base na média quadrada da variação dos níveis de cinza entre os diversos pares de elementos da imagem, essa medida é também chamada de soma do quadrado da variância, e pode informar o quanto a tonalidade de um *pixel* difere de outro [25].

$$f_2 = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} p(i, j) \cdot (i - j)^2 \quad (3.4)$$

Hall [87] fundamenta que, quando i e j são iguais o elemento avaliado está na diagonal principal da GLCM, ou seja, possui uma contagem que representa os *pixels* cujo nível de cinza é idêntico ao do seu vizinho. Neste caso, o peso dado por $(i-j)$ é igual a zero, fazendo com que a resposta do contraste também seja, haja vista que não há diferença de cor.

Seguindo os mesmos termos, caso a diferença entre i e j seja igual a 1, o peso também será 1, pois existe um mínimo de contraste. Caso a diferença entre i e j seja igual a 2, existe mais contraste, e o peso é de 4, assim, medida que $(i-j)$ aumenta, o peso do contraste cresce exponencialmente.

3.3.3. Correlação

A correlação em textura mede a dependência linear de *pixels* em relação à sua vizinhança. Segundo Hall [87], o cálculo da correlação é bastante diferente dos demais, isto implica em resultados de valores muito distintos daqueles obtidos com outros descritores e, portanto, pode ser utilizado em combinação com outras medidas a fim de se obter classificações mais exatas.

$$f_3 = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} p(i, j) \cdot \frac{(i - \mu_i)(j - \mu_j)}{\delta_i \delta_j} \quad (3.5)$$

Esta medida também possui um significado mais intuitivo para os valores reais calculados, pois sabe-se que, quando sua resposta é igual a zero, os valores analisados não são correlacionados, seguindo o mesmo princípio, quando sua resposta é igual a um, os valores analisados são perfeitamente correlacionados.

3.3.4. Variância (soma dos quadrados) e desvio padrão

Segundo Schwartz [84], a variância, quando utilizada na textura, executa a mesma tarefa que a variância utilizada na estatística descritiva, e baseia-se na dispersão dos dados numéricos em torno de um valor médio, de valores dentro da GLCM. Cabe ressaltar que, conforme [87], a variância da GLCM trata especificamente das combinações do pixel de referência e do seu vizinho, portanto, não é o mesmo que a simples variância de níveis de cinza na imagem original.

$$f_4 = \delta_i^2 = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} p(i, j) \cdot (i - \mu_i)^2 \quad (3.6)$$

$$f_4 = \delta_j^2 = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} p(i, j) \cdot (i - \mu_j)^2 \quad (3.7)$$

As variâncias calculadas no sentido de i ou no sentido de j retornam o mesmo resultado, pois a GLCM é simétrica [87]. Tomando-se a raiz quadrada da variância, é obtido o desvio padrão, ou seja:

$$s_i = \delta_i = \sqrt{\delta_i^2} \quad (3.8)$$

$$s_j = \delta_j = \sqrt{\delta_j^2} \quad (3.9)$$

3.3.5. Homogeneidade ou momento da diferença inversa

Homogeneidade, momento da diferença inversa ou ainda IDM (*Inverse Difference Moment*), é uma medida que se refere à distribuição dos *pixels* dentro da área analisada. Diferentemente do contraste, os valores dos pesos da homogeneidade são inversamente proporcionais aos pesos do contraste, pois os pesos diminuem a medida em que se tornam mais distantes da diagonal, ou seja, seu resultado será maior em texturas de pouco contraste [84].

Em outras palavras, o cálculo da homogeneidade retorna valores grandes para níveis de cinza similares, pois, se os pesos diminuem distantes da diagonal, o resultado será maior para imagens com pouco contraste.

$$f_5 = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} \frac{p(i, j)}{1 + (i - j)^2} \quad (3.10)$$

3.3.6. Soma das Médias

Conforme Oliveira [69], a soma da média ou AS (*Sum Average*), expõe a média da distribuição da soma dos níveis de cinza analisados, e dada pela seguinte equação:

$$f_6 = \sum_{i=2}^{2N_g} i \cdot p_{x+y}(i) \quad (3.11)$$

3.3.7. Soma da Variância

Oliveira [69] afirma que a Variância da Soma ou SV (*Sum Variance*) traz uma medida da dispersão (em relação à média) da distribuição da soma dos níveis de cinza da imagem analisada. Esse descritor é definido por:

$$f_7 = \sum_{i=2}^{2N_g} (i - f_6)^2 \cdot p_{x+y}(i) \quad (3.12)$$

3.3.8. Entropia da Soma

A Entropia da Soma ou SE (*Sum Entropy*) é a medida da desordem relacionada com a distribuição da soma de níveis de cinza soma da imagem [69], sua equação é descrita como:

$$f_8 = - \sum_{i=2}^{2N_g} p_{x+y}(i) \cdot \log[p_{x+y}(i)] \quad (3.13)$$

Tendo em vista a possibilidade de $p_{x+y}(i)$ ser igual a zero, em Haralick [74] é recomendado que uma constante positiva de valor muito pequena seja adicionado ao logaritmando, de forma a evitar a expressão $\log(0)$, uma vez que não existe resposta para a mesma. Nesses termos, $\log[p_{x+y}(i) + e]$, em que "e" é uma pequena constante positiva escolhida arbitrariamente.

3.3.9. Entropia

Segundo Costa [88], a entropia mede o grau de desordem entre os *pixels* de uma imagem, portanto, quando a imagem não apresenta textura uniforme os valores da entropia tendem a ser muito baixos, da mesma forma, a entropia alcança seu valor máximo quando os *pixels* na área de interesse apresentam níveis de cinza com valores aleatórios. A entropia é dada pela seguinte equação:

$$f_9 = - \sum_{i=0}^{N_g-1} \sum_{j=2}^{N_g-1} p(i, j) \cdot \log[p(i, j)] \quad (3.14)$$

É demonstrado em Hall [87], por meios matemáticos, que o valor máximo retornado pela entropia é 0,5.

3.3.10. Variância da Diferença

Variância da Diferença ou DV (*Difference Variance*) é a medida da dispersão (em relação à média) da distribuição da diferença de níveis de cinza da imagem [69].

$$f_{10} = \sum_{i=0}^{N_g-1} (i - \mu_{x-y})^2 p_{x-y}(i) \quad (3.15)$$

Em que:

$$\mu_{x-y} = \sum_{i=0}^{N_g-1} i \cdot p_{x-y}(i) \quad (3.16)$$

3.3.11. Entropia da Diferença

Segundo Oliveira [69], a Entropia da Diferença é a medida da desordem relacionada com distribuição da diferença de níveis de cinza da imagem.

$$f_{11} = - \sum_{i=0}^{N_g-1} p_{x-y}(i) \cdot \log[p_{x-y}(i)] \quad (3.17)$$

3.3.12. Informações de Medidas de Correlação 1

É um indicador da correlação baseado na medida da entropia para elementos independentes e pares de elementos na imagem.

$$f_{12} = \frac{HXY - HXY1}{\max(HX, HY)} \quad (3.18)$$

em que HX e HY são entropias de px e py, e

$$HXY = - \sum_{i=0}^{N_g-1} \sum_{j=2}^{N_g-1} p(i, j) \cdot \log[p(i, j)] \quad (3.19)$$

$$HXY1 = - \sum_{i=0}^{N_g-1} \sum_{j=2}^{N_g-1} p(i, j) \cdot \log[p_x(i) \cdot p_y(j)] \quad (3.20)$$

3.3.13. Informações de Medidas de Correlação 2

É a medida da correlação baseada na similaridade entre entropias de elementos independentes da imagem e pares de elementos da imagem.

$$f_{13} = \sqrt{1 - e^{-2(HXY2 - HXY)}} \quad (3.21)$$

em que:

$$HXY2 = - \sum_{i=0}^{N_g-1} \sum_{j=2}^{N_g-1} p_x(i)p_y(j) \cdot \log[p_x(i) \cdot p_y(j)] \quad (3.22)$$

3.3.14. Coeficiente de Correlação Máximo

$$f_{14} = \sqrt{h(Q)} \quad (3.23)$$

em que $h(Q)$ é o segundo maior auto valor de Q e

$$Q(i, j) = \sum_{k=0}^{N_g-1} \frac{p(i, k) \cdot p(j, k)}{p_x(i) \cdot p_y(k)} \quad (3.24)$$

3.4. Considerações

Os descritores de Haralick são medidas estatísticas de segunda ordem capazes de quantificar a textura. Tais medidas são obtidas através de 14 equações, cuja finalidade é categorizar a concepção de texturas trazidas pelos *pixels* da imagem.

Neste capítulo, foram apresentados conceitos relativos à análise de textura em imagens digitais, técnica de PDI necessária para compreensão do método de discriminação de regiões de AVCi em TC proposto nesta pesquisa.

No próximo capítulo são apresentados esses métodos e os materiais utilizados, tais como a base de dados e os softwares que se fizeram necessários para a implementação do sistema, além da metodologia empregada para a validação dos resultados.

Nesta pesquisa, cujo objeto é desenvolver um método para avaliar, por meio de segmentação, regiões com AVCi em TC do cérebro por meio da classificação dos descritores de Haralick, foram considerados dois estudos de caso: 1) Análise do potencial classificativo dos descritores Haralick para o domínio de aplicação estudado no trabalho; e 2) Análise dos resultados obtidos na classificação feita por uma Rede Neural Artificial.

Este capítulo apresenta a base de dados utilizada nesta pesquisa, bem como as metodologias empregadas para o desenvolvimento do sistema e para os seus testes.

4.1. Materiais

4.1.1. Base de Imagens

Com o objetivo de avaliar as técnicas propostas, foram utilizadas 30 imagens de Tomografia Computadorizada de 512 x 512 *pixels*, em padrão DICOM de imagens médicas e obtidas segundo o protocolo crânio rotina sem contraste. Nessa base encontram-se 10 imagens de pacientes com ACVi e 20 imagens de pacientes sem AVC, e foram disponibilizadas pelo Núcleo de Estudos e Pesquisa em Imaginologia (NEPI) da Universidade Federal da Paraíba (UFPB).

Os laudos de cada paciente foram realizados por um médico especialista na área de radiologia, que são utilizados como padrão ouro de comparação. Esta pesquisa utiliza imagens obtidas de exames com seres humanos, portanto, para o uso da base foi necessária a avaliação do Comitê de Ética em Pesquisa do IFPB, cuja aprovação é dada pelo número de registro 1.293.095.

Na Figura 4.1 são ilustradas as imagens utilizadas.

Cada imagem pertence a um exame de TC completo que contém um conjunto de 21 imagens de cada paciente, codificadas segundo o padrão DICOM para imagens médicas. No entanto, como este trabalho se dedica ao estudo da segmentação da região afetada e não necessariamente da confirmação da presença da patologia, optou-se por selecionar apenas as fatias medianas de cada exame. As imagens foram convertidas ao formato JPEG utilizando uma técnica de janelamento, com o objetivo de realçar os níveis

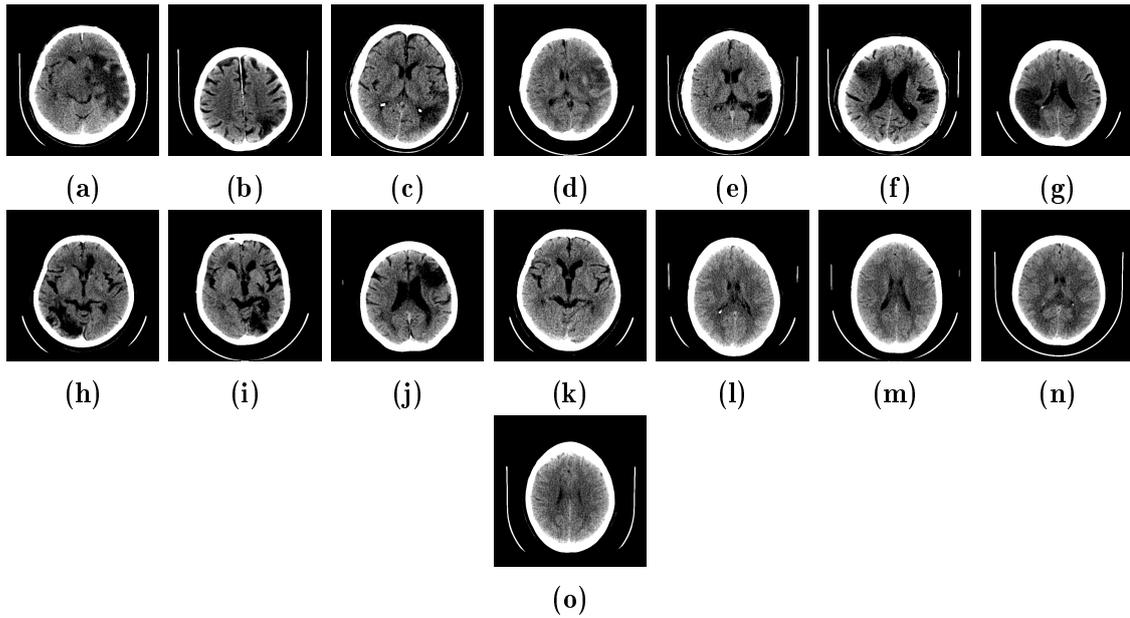


Figura 4.1 – Imagens 1 à 15 da base utilizada

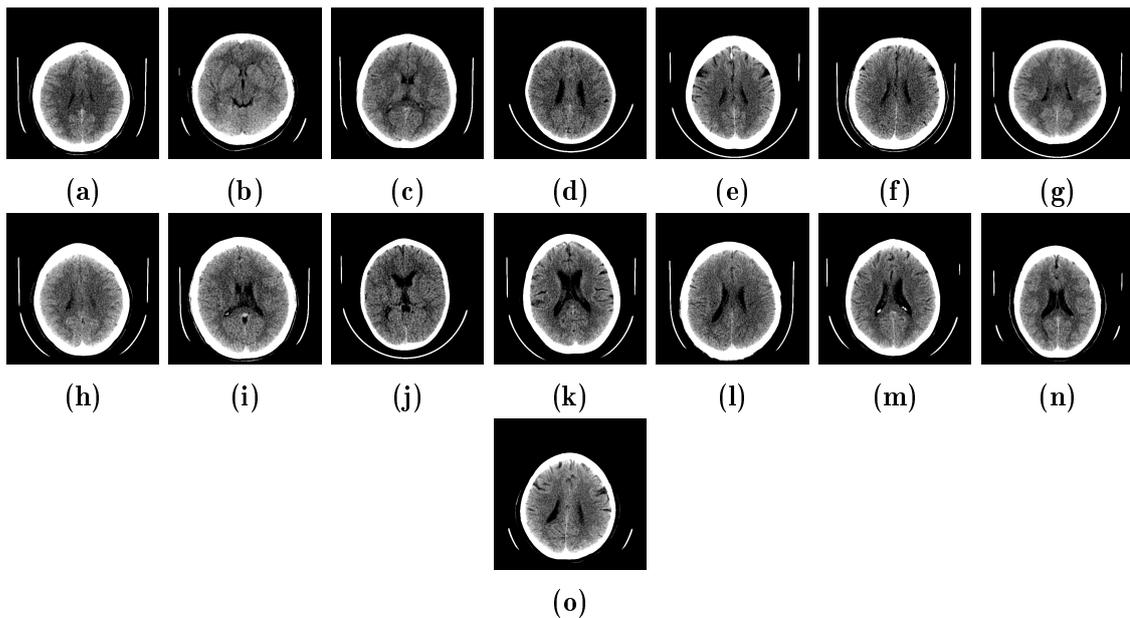


Figura 4.2 – Imagens 16 à 30 da base utilizada

de cinza dos *pixels* associados aos tecidos do cérebro. A janela nada mais é que uma estratégia para equalizar o histograma da imagem dentro de uma faixa de valores que torne possível a distinção dos níveis de cinza em uma análise visual humana, para este trabalho foi utilizada uma janela com nível 35 e largura 40.

4.1.2. A Biblioteca DCMTK

Segundo Sampaio [89], o Dicom Toolkit, conhecido como DCMTK, foi desenvolvido pela *Oldenburg University* e o centro de pesquisa CERIUM, em meio ao Comitê Europeu de Padronização, e oferece um conjunto de bibliotecas e aplicativos de

execução para codificação e decodificação de dados DICOM e atualmente é fornecida pela OFFIS. Este pacote contém uma coleção das bibliotecas e aplicações que executam as principais funções do padrão DICOM. Isso inclui funções para examinar, construir e converter arquivos de imagens DICOM, como também transmitir, receber e armazená-las através de uma rede de comunicação. O DCMTK está escrito nas linguagens ANSI C e C++ e obtido em código-fonte completo, disponibilizado como software "open source". Também está disponível para várias plataformas como Windows e sistemas UNIX incluindo Linux, Solaris, FreeBSD e MacOS X e pode ser baixado gratuitamente [90].

Segundo Guerra [91], o DCMTK é utilizado em hospitais e outras instituições espalhadas pelo mundo por diversos objetivos, desde simples ferramenta de teste, base para projetos de pesquisa, protótipos e até produtos comerciais. Com base nessa biblioteca foram desenvolvidas algumas rotinas para manipulação dos dados DICOM, tais como ler a imagem e seus parâmetros, bem como identificar e ordenar os arquivos do exame de TC.

4.1.3. O Classificador

O sistema proposto é baseado na classificação de cada *pixel* de uma TC a partir da avaliação da textura caracterizada por sua vizinhança. Esta classificação é feita uma Rede Neural Artificial (RNA) *Multilayer Perceptron* (MLP), cuja única saída deverá informar se o nível de cinza do *pixel* corresponde ou não a uma região de AVCi.

A RNA foi desenvolvida em linguagem C++ e emprega o algoritmo *backpropagation*, na fase de treinamento, para ajustes dos pesos. A topologia da rede neural implementada pode ser observada na Figura 4.3, por meio da qual é possível perceber o uso de uma camada de entradas contendo três neurônios (um para cada descritor de textura calculado), uma camada escondida com três neurônios e uma camada de saída com um único neurônio, que fornecerá o nível de cinza para o *pixel* central de uma vizinhança analisada. Para todos os neurônios foi empregada uma função de ativação do tipo sigmoide.

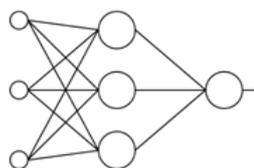


Figura 4.3 – Representação da topologia adotada para a RNA.

4.1.4. Metodologia para a classificação e segmentação

A metodologia empregada é analisada em dois procedimentos, um com os métodos desenvolvidos para o treinamento da RNA, outro com os métodos realizados para a

classificação, descritos graficamente pelos modelos de diagrama em blocos representados nas Figuras 4.4 e 4.5. Com a RNA devidamente treinada, é feita uma varredura na TC e para cada *pixel* analisado é feita a classificação de sua vizinhança, com o objetivo de classificar se o *pixel* analisado é um ponto da área um AVCi ou não.

Na fase de treinamento, após a leitura da imagem de TC, os pontos da imagem (*pixels*) que representarem os tecidos cerebrais são escolhidos por manualmente com o *mouse*, tais pontos servirão de amostras para treinamento da RNA. Após a conclusão das escolhas, são armazenadas as orientações (x e y) de cada um dos *pixels* selecionados, que por sua vez receberão um valor de saída desejada como, por exemplo, 1 (um) para os pontos de regiões com AVCi e 0 (zero) para *pixels* de outras regiões. Na Figura 4.4 é ilustrado o diagrama em blocos do algoritmo empregado para treinamento da rede neural artificial.

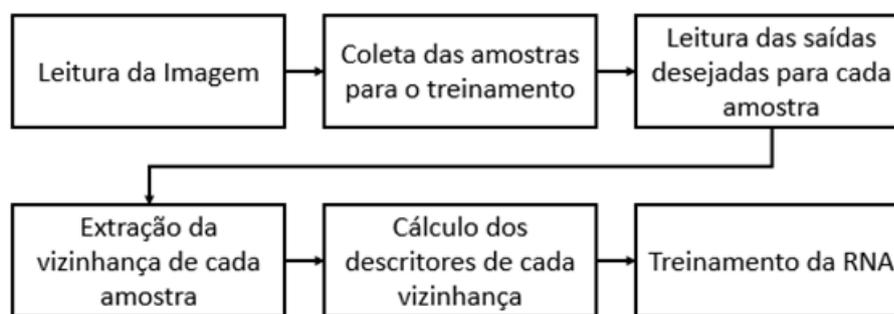


Figura 4.4 – Algoritmo para treinamento da RNA.

Para cada *pixel* selecionado é criada uma vizinhança, uma matriz 9x9, da qual calcula-se a matriz de co-ocorrência normalizada e dela obtêm-se os valores de textura a partir do cálculo dos descritores de Haralick. Esses descritores são apresentados como entradas para a RNA, que por sua vez será treinada seguindo o algoritmo *Backpropagation*. Os valores dos pesos são salvos em arquivo de texto e poderão ser carregados pelo módulo de execução da RNA. O algoritmo de teste, realizado para cada um dos *pixels* selecionados, pode ser observado na Figura 4.5.

O número de descritores oferecidos para o classificador é determinado através de testes com as combinações possíveis em agrupamentos com um, dois e três descritores. Para cada um dos casos utilizou-se a mesma metodologia de treinamento da RNA e os mesmos conjuntos de *pixels*.

Para o teste, uma imagem de TC é colocada na entrada do sistema. Para cada *pixel* dessa imagem é considerada uma vizinhança 9x9 e extraídos os descritores de Haralick. O resultado do algoritmo de teste da RNA é uma imagem em que cada pixel é a resposta do neurônio de saída aos descritores apresentados.

Como a função de ativação da camada de saída é uma sigmoide, a imagem de saída dessa etapa não é binarizada, ao invés disso cada *pixel* recebe um nível de cinza da RNA. Para garantir uma região melhor segmentada, a imagem de saída da RNA é processada por

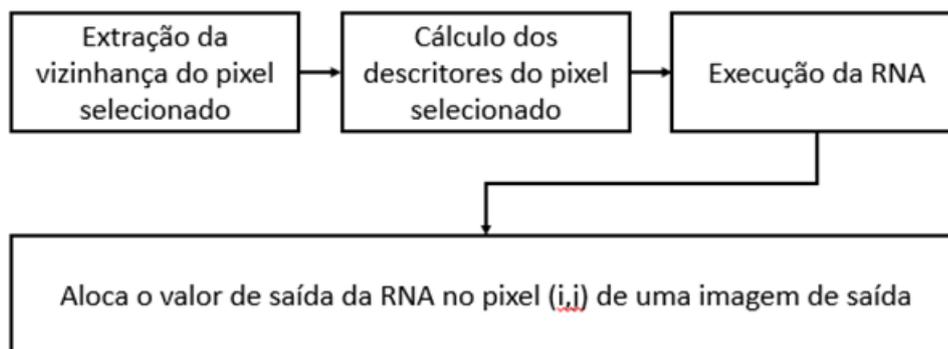


Figura 4.5 – Processo realizado em cada pixel da imagem a ser segmentada.

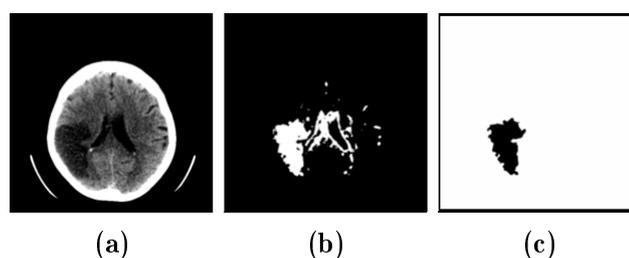


Figura 4.6 – (a) TC utilizada para teste. (b) resultado obtido com a binarização da saída oferecida pela RNA (c) pós processamento sobre a saída obtida.

uma função de binarização que segue o método de Otsu [92] para determinação do limiar. Na Figura 4.6 são ilustradas as etapas de processamento a metodologia empregadas para a segmentação da região de AVC através da RNA.

Como forma de eliminar falsos positivos, oriundos de regiões cuja textura se assemelha a do AVC, é realizada uma etapa de pós-processamento, na qual as regiões segmentadas são analisadas e, por meio dos momentos invariantes de Hu [93], são calculados seus centroides (coordenadas de centro de massa, x_c e y_c) e suas áreas (momento de ordem zero, m_{00}), de forma que, com esses valores quantificados, uma filtragem é realizada com o propósito de desconsiderar regiões de área muito pequena ou com centroide muito próximo ao centro. O resultado desse pós-processamento pode ser observado na Figura 4.6c.

4.1.5. Metodologia para avaliação e interpretação

Para mensurar a precisão do classificador empregado para segmentar a região de AVC_i, três medidas, comumente empregadas segundo [94], são utilizadas: a acurácia, a sensibilidade e a especificidade.

As respostas dessas medidas estão relacionadas, neste trabalho, à capacidade do classificador em diagnosticar o AVC_i em uma região de textura coletada da TC onde realmente há uma vizinhança de *pixels* correspondentes a representação da patologia (Verdadeiro Positivo - VP) ou correspondente a uma área saudável (Falso Positivo - FP), ou, ainda, diagnosticar uma região de textura como saudável quando a vizinhança de

Tabela 4.1 – Matriz de confusão em um teste de detecção da presença/ausência de doença.

Resultado	Doença	
	Presente	Ausente
Positivo	Verdadeiro Positivo (VP)	Falso Positivo (FP)
Negativo	Falso Negativo (FN)	Verdadeiro Negativo (VN)

Fonte: [94]

pixels analisada corresponde a uma área livre da patologia (Verdadeiro Negativo - VN) ou quando essa mesma vizinhança corresponde a uma região doente (Falso Negativo - FN). Cada um desses parâmetros aparece na chamada matriz de confusão (Tabela 1), que representa o resultado obtido no classificador.

A medida de acurácia (Ac) mede a taxa de classificação correta global, refletindo a capacidade do classificador de identificar corretamente quando há e quando não há a presença do distúrbio. A acurácia é definida como a relação entre o número de casos corretamente classificados e todos os casos apresentados ao classificador [95].

$$Ac = \frac{VP + VN}{(VP + VN + FP + FN)} \quad (4.1)$$

A medida de sensibilidade (Sen) mede a capacidade do classificador em identificar a presença do distúrbio quando ele de fato existe, sendo definida pela relação entre o número de casos corretamente classificados como presença do distúrbio e a quantidade total de casos com o distúrbio:

$$Sen = \frac{VP}{VP + FN} \quad (4.2)$$

Nesta pesquisa, a sensibilidade é utilizada como medida de percentagem dos acertos de *pixels* que pertencem a uma área atingida por AVCi.

A medida de especificidade (Esp) mede a capacidade do classificador em identificar corretamente a ausência do distúrbio quando de fato ele não existe, sendo definida pela relação entre o número de casos corretamente classificados como saudáveis e a quantidade total de casos de estado saudável:

$$Esp = \frac{VN}{VN + FP} \quad (4.3)$$

Nesta pesquisa, a sensibilidade é utilizada como medida de percentagem dos acertos de *pixels* que não pertencem a uma área atingida por AVCi.

A representação das medidas de sensibilidade e especificidade é mais clara quando se trata da discriminação entre uma classe saudável e uma classe patológica. Quando há a discriminação entre classes de textura, é necessário que seja definido, no classificador, qual grupo de sinais terá sua correta classificação medida pela sensibilidade e qual grupo terá sua correta classificação medida pela especificidade [95].

Em suma, o classificador apresenta bom desempenho caso seja capaz de obter altos valores para acurácia e sensibilidade, portanto, essas são medidas que tendem a representar o desempenho de um classificador. Contudo, segundo Ben-David [96], podem ser vistas como medidas problemáticas porque não compensam os sucessos que ocorrem devido ao acaso. Bissacot [97] complementa essa afirmação mencionando que, em um problema de classificação binária, em que as probabilidades de sucesso e fracasso sejam as mesmas, um classificador que acerta metade das classificações em metade dos casos tem o mesmo desempenho daquele obtido por um classificador aleatório. Ben-David [96] também afirma que existem alternativas de medidas que consideram a aleatoriedade e uma das destacadas é a curva da característica de operação do receptor (*Receiver Operating Characteristic* ou ROC).

Um gráfico ROC é uma técnica para visualizar, organizar e selecionar classificadores supervisionados baseada em suas performances, utilizada na teoria da detecção de sinais e visualização e análise do comportamento de sistemas de diagnósticos Bissacot [97]. Existe uma vasta literatura, nos mais diferentes campos, sobre o uso dos gráficos ROC [98-100]. Nesse gráfico, a sensibilidade é plotada no eixo Y e a taxa de falsos positivos (ou 1 - especificidade) é plotada no eixo X. Assim, um plotado no canto inferior esquerdo (0,0), por exemplo, representa a estratégia de nunca classificar um caso como positivo, nesse caso, o classificador não comete erros FP (falsos positivos) mas também não faz acertos VP (verdadeiros positivos). A estratégia oposta, de somente conceder classificações positivas é representada pelo ponto superior direito (1,1), enquanto que o ponto (0,1) representa classificação perfeita [97]. A Figura 4.7 mostra um gráfico ROC com cinco classificadores discretos nomeados de A até E.

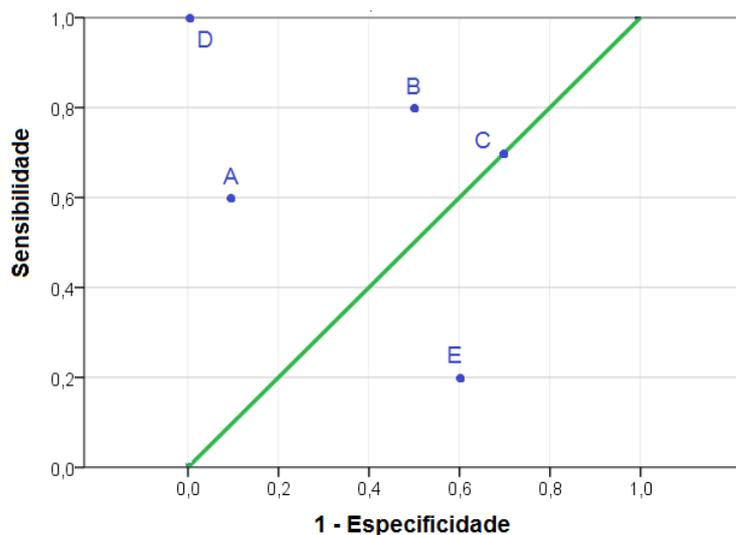


Figura 4.7 – Gráfico ROC básico com 5 classificadores discretos.
Fonte: [98]

Percebe-se, ainda na Figura 4.7, que o desempenho de D é perfeito, pois um ponto é melhor que outro quando mais a noroeste ele está no gráfico (taxa de verdadeiros

Tabela 4.2 – Qualidade do diagnóstico em relação a área da curva ROC.

Área (AUC)	Qualidade do diagnóstico
0.9 a 1.0	Excelente
0.8 a 0.9	Bom
0.7 a 0.8	Regular
0.6 a 0.7	Ruim
0.5 a 0.6	Insignificante

Fonte: [101]

positivos maior e taxa de falsos positivos menor). A medida que o ponto vai descendo no gráfico ele diminui sua performance. Nesses termos, os pontos A e B possuem performances similares e satisfatórias, a performance de C é exatamente igual a do acaso e a performance de E é pior do que aquela encontrada pelo acaso [97].

A área abaixo da curva ROC - AUC (do inglês *Area Under Curve*) é uma medida resumo usual do desempenho de um teste, já que ela é estimada levando-se em consideração todas as Sensibilidades e Especificidades relativas a cada um dos valores estipulados para a construção do gráfico, essa característica pode ser utilizada na comparação de testes diagnósticos, que terá uma exatidão tanto maior quanto maior for a área sob a curva ROC. Seguindo essa metodologia, o valor da área igual a 1 representa um teste perfeito, enquanto que uma área igual a 0.5 representa um valor sem importância, na Tabela 4.2 é mostrada uma associação entre a qualidade do diagnóstico a área da curva ROC [101].

Na Figura 4.8 são apresentadas três curvas ROC, de três classificadores diferentes. O classificador A tem uma área sob a curva maior e, portanto, uma performance média superior, enquanto que o classificador C apresenta desempenho insuficiente.

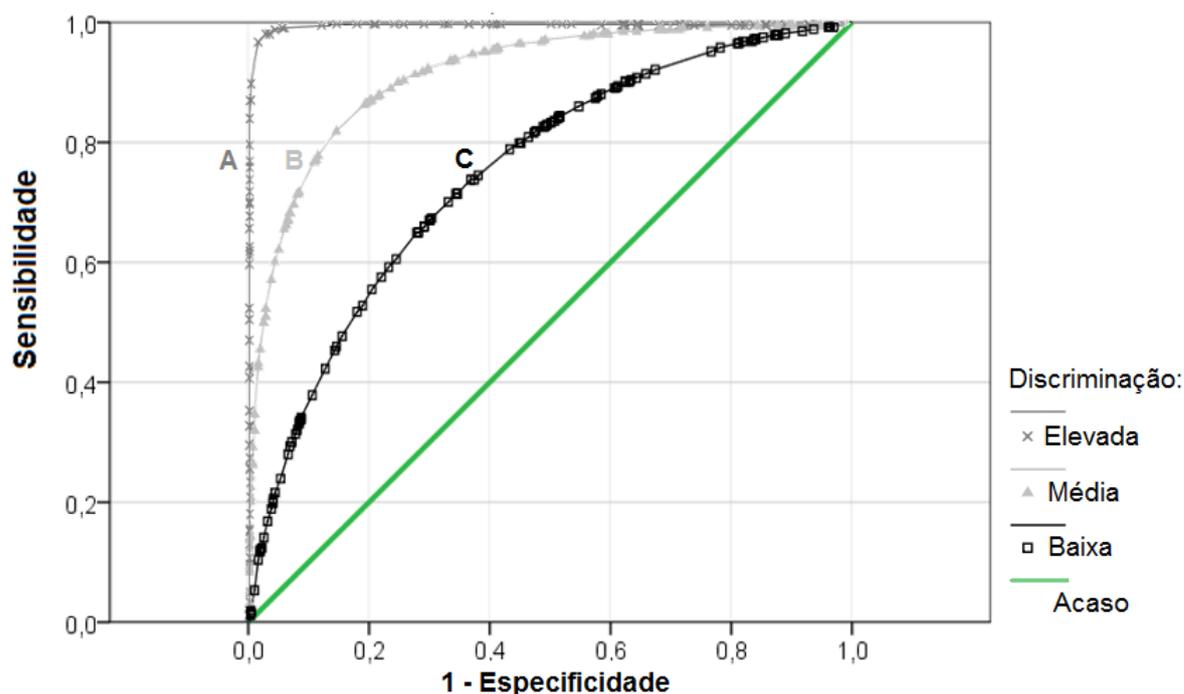


Figura 4.8 – Curva ROC e a Qualidade no Diagnóstico.
Fonte: [102]

4.2. Considerações

Propõe-se, como objetivo desse trabalho, o desenvolvimento de um sistema para segmentação de regiões de AVCi em TC do cérebro, baseado na classificação de textura em imagens. Para tanto, é investigado o potencial discriminativo dos descritores de Haralick para diferentes tipos de texturas encontrados em uma TC do crânio.

Além de investigar se descritores de Haralick são eficientes para esse tipo de aplicação, esta pesquisa extraiu as medidas de quantificação de acurácia, sensibilidade e especificidade para combinações com um, dois e três descritores como entrada para o classificador. Isso tem como objetivo observar com qual número mínimo de descritores, e melhor combinação, o método pode ser empregado com maior precisão.

Outros fatores concernentes a estes pontos são tratados de forma mais detalhada no Capítulo 5, na apresentação dos resultados obtidos.

5.1. Contextualização

Neste Capítulo, são apresentados os resultados obtidos na pesquisa, que compreendem, de acordo com a metodologia proposta no Capítulo 3, às etapas de análise estatística e classificação de texturas de TC do Cérebro, que tem como objetivo investigar o potencial discriminativo dos descritores de Haralick na segmentação de regiões de AVCi. Como o custo computacional para o cálculo dos descritores é relativamente alto, se pretende, com estas análises, encontrar a combinação com o menor número de descritores possível para uma classificação eficiente do AVCi.

5.2. Análise dos descritores de Haralick como medidas para classificação de texturas de TC do Cérebro

Na Tabela 5.1 estão apresentados os valores médios e os desvios-padrão das medidas calculadas a partir dos descritores de Haralick, as quais foram obtidas sobre 360 amostras de regiões de textura adquiridas de 10 imagens de TC. Das 360 amostras, 60 são colhidas em regiões com AVCi, 60 são colhidas de regiões de substância cinzenta sem AVCi, 60 são colhidas de regiões de substância branca sem AVCi, 60 são colhidas de regiões de líquido, 60 são colhidas de regiões de osso e 60 são colhidas de regiões de ar, definidas manualmente através de cliques com o *mouse* sobre as regiões de interesse.

Com o propósito de investigar possíveis diferenças estatísticas entre os grupos de áreas de texturas saudáveis e texturas de AVCi, são aplicados testes de hipótese para duas médias considerando-se amostras independentes e um nível de significância igual a 0,05. Nos testes estatísticos, realizados no software SPSS[©] Statistics [103], são indicadas diferenças significativamente estatísticas entre dois grupos se o nível de significância resultante seja menor que o nível de significância (ρ) aplicado no teste ($p < 0,05$).

Ainda na Tabela 5.1, estão apresentados os níveis de significância (ρ) obtidos dos testes estatísticos entre os grupos 0 (Sem AVCi) e 1 (com AVCi). Considerando os

Tabela 5.1 – Valores médios, desvios-padrão e níveis de significância de diferentes descritores de textura em regiões com e sem AVCi.

Descritor	Sem AVCi		Com AVCi		ρ
	Média	Desvio Padrão	Média	Desvio Padrão	
Contraste	87.1457	238.0894	131.3125	127.7855	<0,001
Correlação	0.87582	0.37232	0.789597	8.1105E-2	0.16801
Dif Variância	33.8492	144.8446	44.8111	69.7964	<0,001
Entropia	5.4752	1645791.341	6.02978	2260756.2919	<0,001
Soma Vari	14353.2695	40358.4596	27212.374	30204.7193	0,001
Homogeneidade	0.269298	0.3604	0.22	9.1203E-2	<0,001
Inf Correl1	0.9516	0.4516	0.98054	0.1273	<0,001
Seg Mom Ang	2.98E-2	0.4224	2.24E-2	1.44E-2	<0,001
Soma Ent	4.3448	2.2079	4.7202	0.685797	<0,001
Soma Médias	113.0277	116.9148	164.8819	76.7727	0,001
Variância	196.8767	583.2604	307.6127	699.6046	<0,001
Dif Entrop	2.8269	900460.103	3.18	1192392.372	<0,001

níveis de significância observados nos resultados, os testes estatísticos sugerem que, com exceção do descritor Correlação, os descritores de Haralick utilizados individualmente são sensíveis à variação de textura saudável e patológica, ou seja, há diferenças estatísticas significativas entre os grupos 0 e 1.

Por meio das Figuras 5.1 e 5.2 são apresentados os comportamentos dos descritores de Haralick utilizados, através de *boxplots*, gráficos estatísticos nos quais os valores obtidos das medidas são ordenados de forma decrescente, sendo resumidos em cinco partes [104]:

- Valor mínimo: também conhecido como bigode inferior, é o menor valor obtido da medida em análise;
- Primeiro quartil: é a base da caixa que representa os 50% centrais da distribuição;
- Segundo quartil: também conhecida como a mediana da distribuição, fica localizada no ponto médio da caixa que representa os 50% centrais da distribuição;
- Terceiro quartil: é o topo da caixa que representa os 50% centrais da distribuição;
- Valor máximo: também conhecido como bigode superior, é o maior valor obtido da medida em análise;

Cada parte é separada por um intervalo de 25% dos valores ordenados. Valores consideravelmente fora da distribuição são representados por pontos acima do bigode superior ou abaixo do bigode inferior. Os *boxplots* apresentados nas Figuras 5.1 e 5.2 representam a distribuição das medidas de quantificação de recorrência e estão organizados da seguinte maneira: os valores máximo e mínimo estão representados por uma pequena

linha horizontal que representa seus respectivos bigodes; os 50% centrais da distribuição (intervalo entre o primeiro e o terceiro quartil) estão representados por uma caixa com contorno de cor verde; já a mediana (segundo quartil) está representada por uma linha horizontal vermelha contida dentro da caixa com contorno de cor verde [105].

Como pode ser notado pela análise visual da distribuição dos valores obtidos para 12 descritores de Haralick, os resultados encontrados sugerem que, apesar de serem significantes para a classificação, com apenas um descritor como medida de textura não há como separar completamente a classe 1 (um), de área afetada pelo AVCi, das classes formadas pelos outros tecidos analisados (zero), pois apesar de alguns descritores apresentarem potencial para gerar uma boa classificação entre AVCi e outras regiões presentes em uma TC, percebe-se grande sobreposição entre as respostas de todas as classes e um grande número de *outliers*.

Figura 5.1 – Comportamento dos descritores de Haralick individualmente.

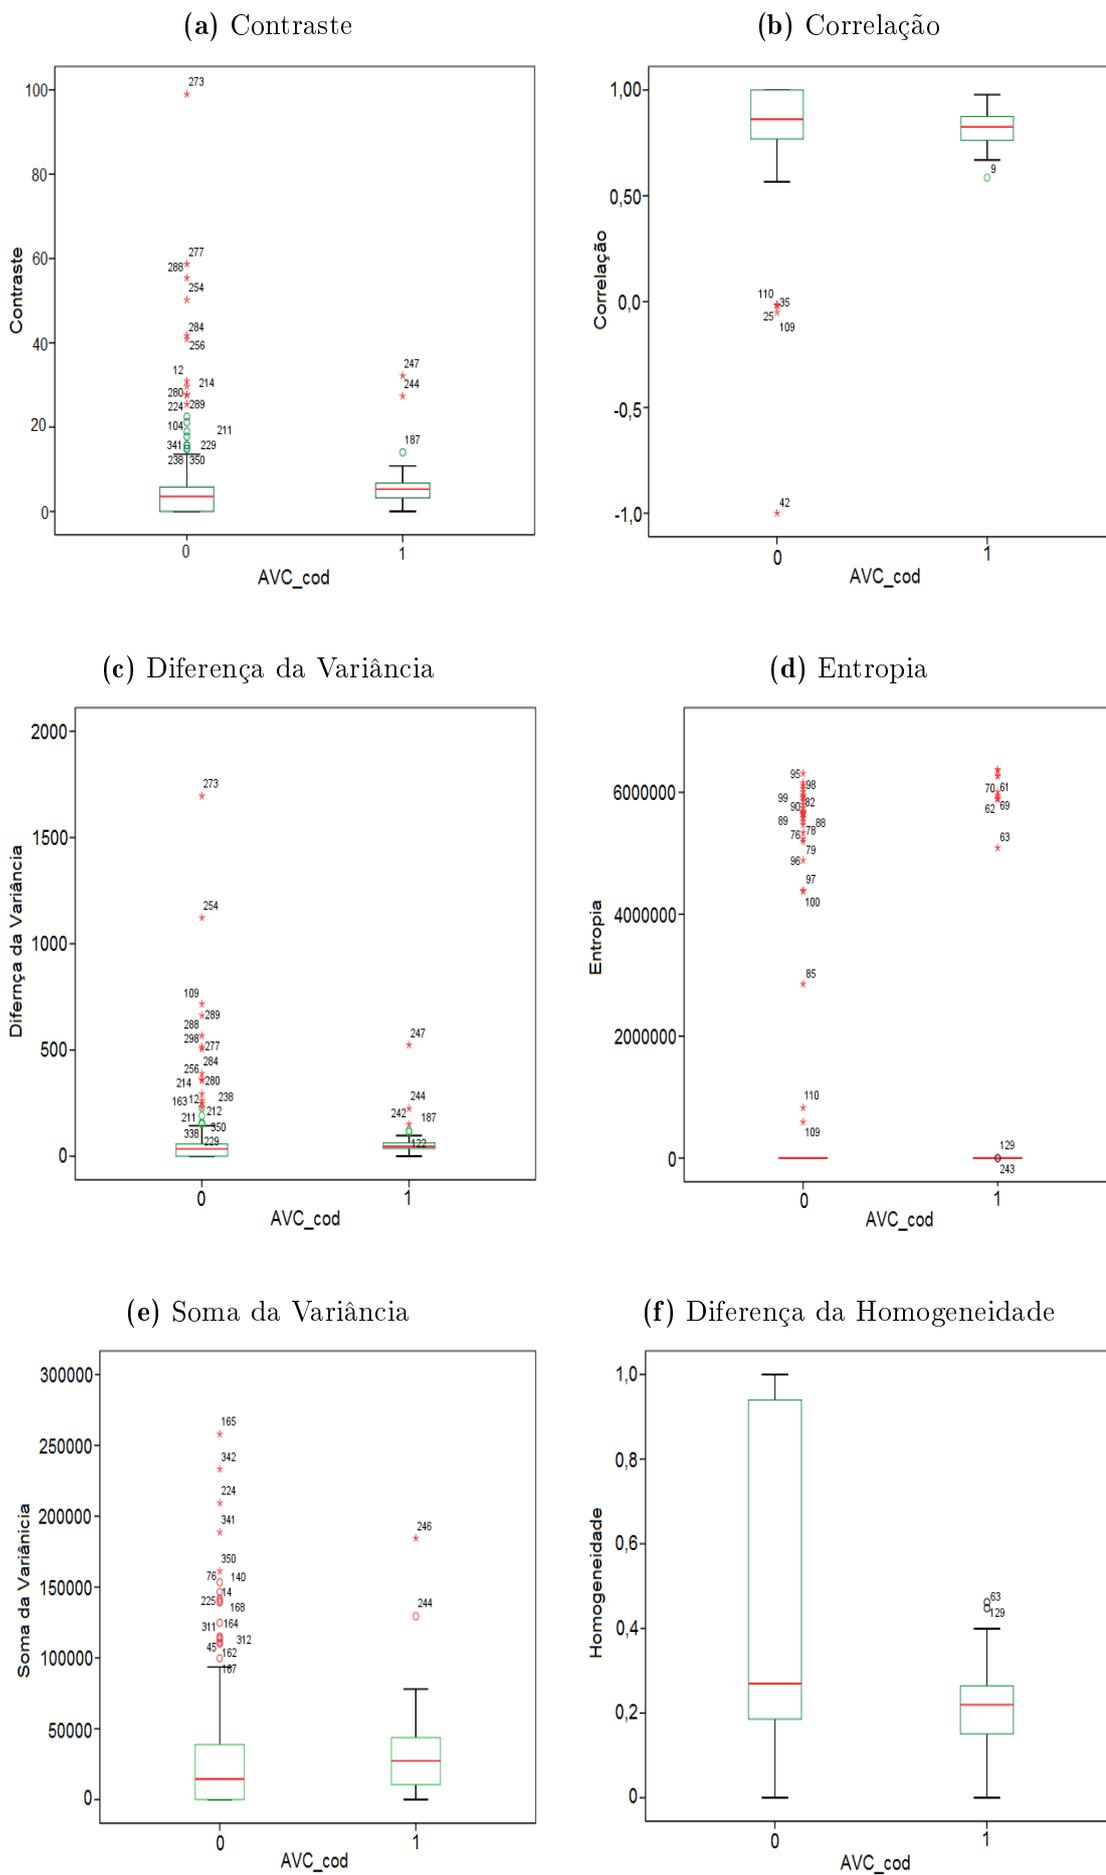
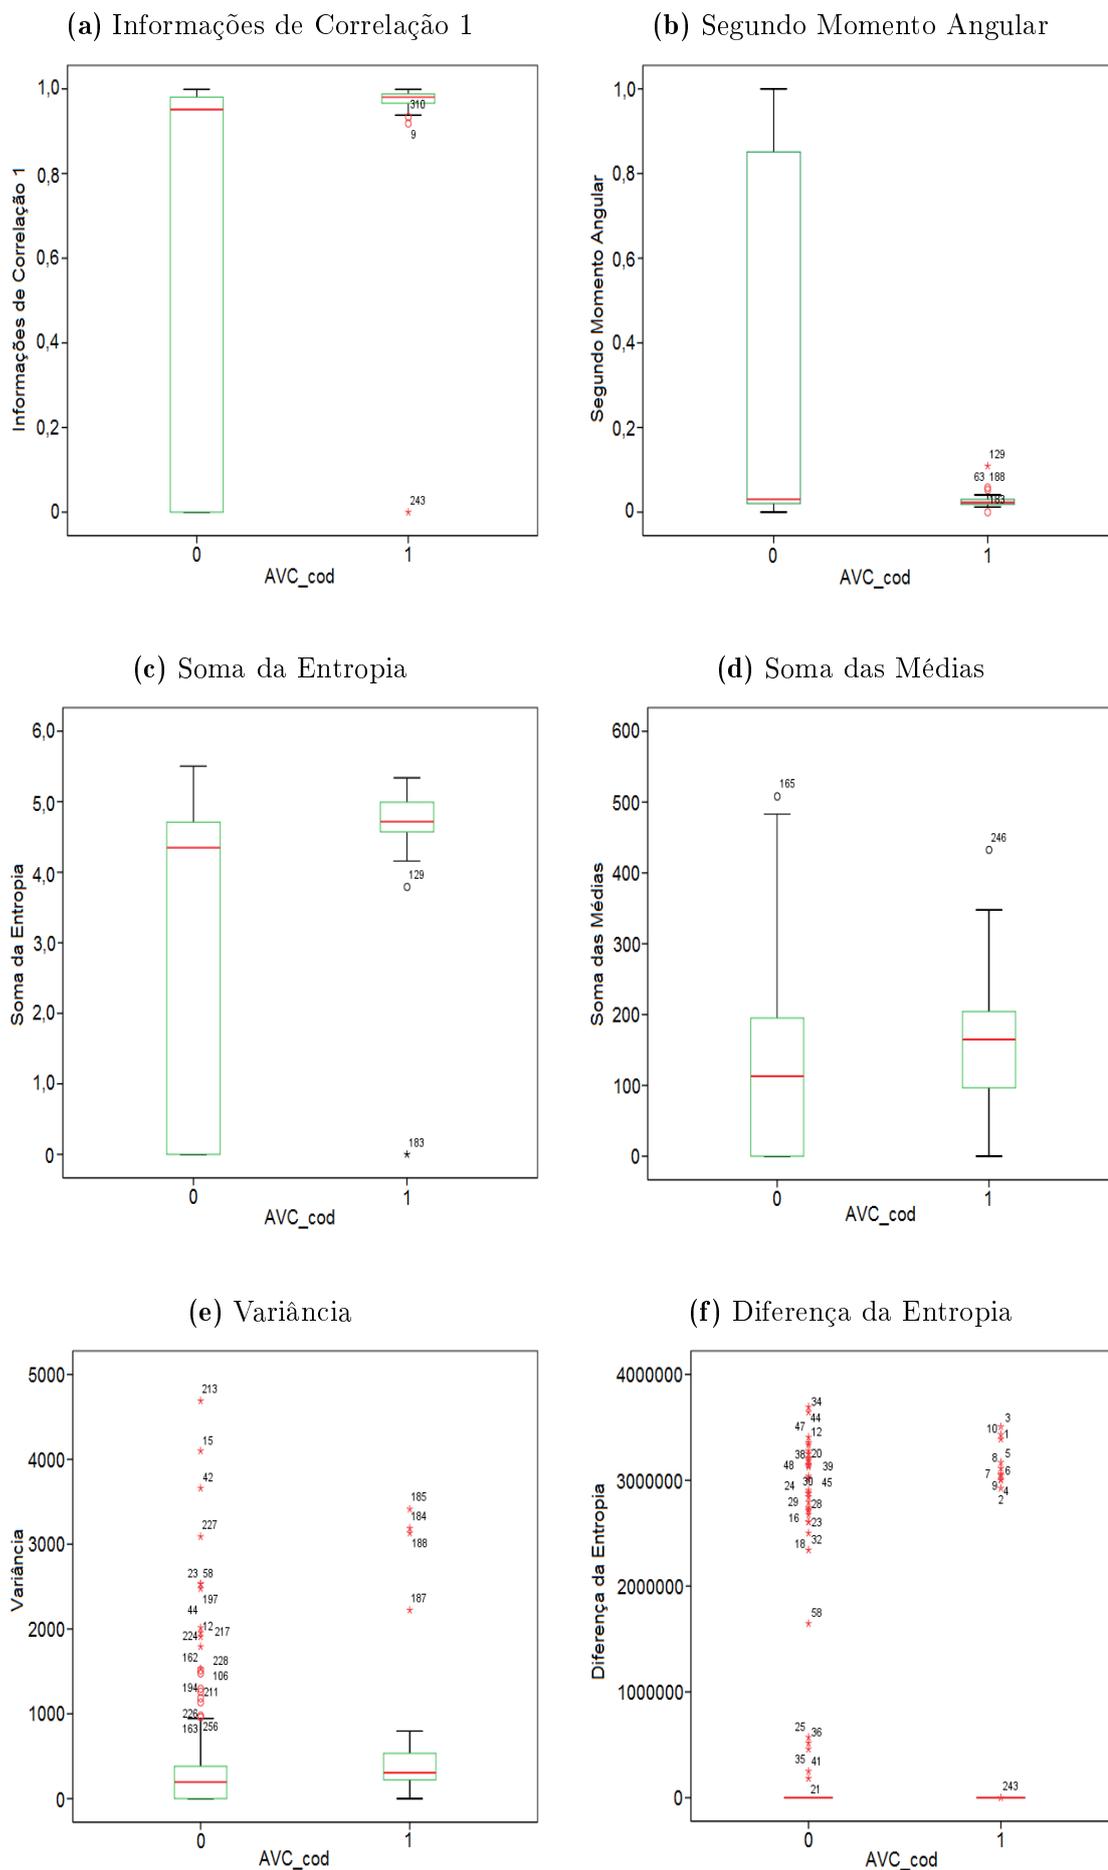


Figura 5.2 – Comportamento dos descritores de Haralick individualmente.



5.3. Análise de classificação com um descritor

Na Tabela 5.3 é possível observar a média dos resultados para as medidas de Sensibilidade, Especificidade e Acurácia, obtidos a partir das 30 imagens da base utilizada para testes. Nela percebe-se que nenhum descritor isoladamente possui grande relevância para a diferenciação entre as texturas de regiões com AVCi e de regiões que representam tecidos saudáveis nas imagens de TC, visto que a acurácia possui valores muito baixos para serem considerados significativos. Casos onde existe uma acurácia importante, por exemplo: descritor 4, acurácia = 83,98%, o valor da sensibilidade ou da especificidade é pequeno demais para validar a classificação.

Tanto na Tabela , quanto em todas as outras em que são exibidos os resultados obtidos nos testes realizados, cada descritor tem seu nome substituído por um código de identificação, como forma de melhorar o arranjo dos dados expostos. Esses códigos são conferidos por meio da Tabela 5.2.

Tabela 5.2 – Códigos adotados para representação dos descritores.

Código	Nome do Descritor
0	Segundo Momento Angular
1	Contraste
2	Correlação
3	Variância
4	Homogeneidade
5	Soma das Médias
6	Soma da Entropia
7	Entropia
8	Diferença da Variância
9	Diferença da Entropia
10	Informações de Correlação
11	Soma da Variância

A observando os dados contidos na Tabela 5.3, é possível perceber que os valores de especificidade obtidos com um único descritor são demasiadamente pequenos. Isto mostra que não há boa classificação de tecidos saudáveis, por tanto, há uma ocorrência muito alta de falsos positivos nos resultados da classificação.

Tabela 5.3 – Média dos resultados obtidos com um descritor.

Resultados - médias							
Descritor	VP	FP	VN	FN	Sensibilidade	Especificidade	Acurácia
0	2113	71816	94206	220	0.9055	0.5674	0.5721
1	2164	160687	5335	170	0.9273	0.0321	0.0445
2	1680	62705	103317	653	0.7200	0.6222	0.6237
3	2164	160687	5335	170	0.9273	0.0321	0.0445
4	535	25161	140861	1799	0.2293	0.8484	0.8398
5	2164	160687	5335	170	0.9273	0.0321	0.0445
6	1949	121991	44031	385	0.8346	0.2651	0.2731
7	1946	127900	38122	388	0.8338	0.2296	0.2379
8	2164	160687	5335	170	0.9273	0.0321	0.0445
9	2079	73918	92104	255	0.8907	0.5547	0.5594
10	2134	73622	92400	200	0.9143	0.5565	0.5615
11	2164	160687	5335	170	0.9273	0.0321	0.0445

5.4. Análise de grupos de dois descritores

Buscando a análise do potencial classificativo a partir de pares de descritores, foram testadas todas as combinações possíveis entre dois quaisquer descritores de Haralick. Na tabela 5.4 são expostos as médias dos resultados obtidos nos testes realizados, nela é possível perceber que, assim como ocorreu nos testes com descritores individuais, não foi possível obter valores significativos para o conjunto sensibilidade, especificidade, e acurácia. No Apêndice C, encontram-se outras tabelas, por meio das quais é possível analisar os dados que deram origem as médias contidas na Tabela 5.4.

Tabela 5.4 – Média dos resultados obtidos com dois descritores.

Descritor	VP	FP	VN	FN	Sensibilidade	Especificidade	Acurácia
0-11	1912	59451	107769	588	0.7647	0.6444	0.6462
0-1	2137	89235	77985	364	0.8544	0.4663	0.4721
0-2	1687	81996	85224	814	0.6745	0.5097	0.5121
0-3	2263	80849	86371	238	0.9049	0.5164	0.5222
0-4	269	41417	125803	2231	0.1077	0.7522	0.7428
0-5	2072	92047	75173	429	0.8286	0.4495	0.4551
0-6	1990	91215	76005	511	0.7957	0.4545	0.4595
0-7	2139	65674	101546	361	0.8556	0.6072	0.6109
0-8	2102	83560	83660	398	0.8407	0.5002	0.5052
0-9	2046	63922	103298	454	0.8184	0.6177	0.6207
10-11	2379	85177	82043	121	0.9515	0.4905	0.4974
1-10	2023	102903	64317	477	0.8092	0.3846	0.3909

1-11	2098	107527	59693	403	0.8388	0.3568	0.3640
1-2	2137	114458	52762	364	0.8544	0.3155	0.3235
1-3	2106	111018	56201	394	0.8424	0.3361	0.3436
1-4	2137	104537	62683	364	0.8544	0.3749	0.3819
1-5	2207	86942	80278	293	0.8827	0.4801	0.4859
1-6	2137	114238	52982	364	0.8544	0.3168	0.3247
1-7	2103	110135	57085	397	0.8410	0.3413	0.3487
1-8	2017	115251	51969	484	0.8064	0.3108	0.3180
1-9	2310	114899	52321	191	0.9236	0.3129	0.3219
2-10	1664	85270	81949	837	0.6653	0.4900	0.4927
2-11	1888	68350	98870	612	0.7550	0.5913	0.5937
2-3	2158	92994	74226	342	0.8630	0.4439	0.4501
2-4	646	65423	101797	1854	0.2584	0.6088	0.6036
2-5	1954	91399	75821	546	0.7815	0.4534	0.4582
2-6	1905	85879	81341	596	0.7617	0.4864	0.4904
2-7	1958	94510	72709	542	0.7831	0.4348	0.4399
2-8	2266	89105	78115	234	0.9063	0.4671	0.4736
2-9	2132	86893	80327	368	0.8527	0.4803	0.4859
3-10	2129	80978	86242	372	0.8512	0.5157	0.5207
3-11	2008	89357	77863	493	0.8028	0.4656	0.4706
3-4	299	75952	91268	2201	0.1198	0.5457	0.5394
3-5	2420	86240	80980	81	0.9677	0.4843	0.4914
3-6	2151	77146	90074	350	0.8600	0.5386	0.5433
3-7	2102	98163	69057	399	0.8404	0.4128	0.4193
3-8	1904	105817	61403	596	0.7614	0.3672	0.373
3-9	1979	110968	56252	522	0.7913	0.3363	0.3431
4-10	640	82758	84462	1861	0.2559	0.5050	0.5013
4-11	488	42545	124675	2012	0.1953	0.7456	0.7375
4-5	1994	87731	79489	507	0.7973	0.4753	0.4801
4-6	1622	80989	86231	878	0.6488	0.5157	0.5175
4-7	1966	82102	85118	534	0.7863	0.5090	0.5131
4-8	2232	89658	77562	269	0.8925	0.4637	0.4701
4-9	2150	73030	94190	351	0.8597	0.5633	0.5675
5-10	2016	87858	79362	485	0.8062	0.4746	0.4794
5-11	2038	105636	61584	463	0.8145	0.3683	0.3749
5-6	2106	119497	47723	394	0.8424	0.2853	0.2936
5-7	2103	110190	57030	397	0.8410	0.3410	0.3483

5-8	2092	95237	71983	409	0.8366	0.4304	0.4364
5-9	2053	108150	59070	447	0.8212	0.3532	0.3600
6-10	2009	82693	84527	491	0.8035	0.5054	0.5099
6-11	2043	99613	67607	457	0.8171	0.4042	0.4103
6-7	1926	78161	89059	574	0.7703	0.5325	0.5361
6-8	1895	84071	83149	606	0.7578	0.4971	0.5010
6-9	2185	89426	77794	315	0.874	0.4652	0.4712
7-10	2043	76453	90454	551	0.7876	0.5419	0.5456
7-11	1350	69511	97396	1244	0.5204	0.5835	0.5826
7-8	2032	82495	84412	561	0.7835	0.5057	0.51
7-9	2336	91785	75121	257	0.9006	0.4501	0.4570
8-10	2259	92374	74533	334	0.8712	0.4466	0.4531
8-11	2304	84186	82720	290	0.8882	0.4955	0.5016
8-9	1976	93423	73250	506	0.7960	0.4395	0.4446
9-10	2177	76491	90183	305	0.8770	0.5411	0.5460
9-11	2114	74109	92564	369	0.8515	0.5554	0.5596

Assim como ocorreu com a classificação feita com um descritor, os testes com dois descritores apresentaram muitos resultados com especificidade muito baixa. As combinações 0-5, 2-4 e 4-11 (5.4), se mostram como exceções, pois trazem valores relevantes de especificidade. No entanto seus valores de sensibilidade são baixos, mostrando a ineficiência dessas combinações para a detecção de AVCi. O fato de que todas as combinações com dois descritores trazem resultados com acurácia que não chegam a 65%, também é um indicador de que pares de descritores de textura não são suficientes para a classificação de texturas de tecidos saudáveis e patológicos.

5.5. Análise de grupos de três descritores

Na Tabela C.1 (Apêndice C), são mostrados os resultados da classificação, por parte de uma RNA devidamente treinada para esta aplicação, de uma imagem utilizando diferentes combinações de descritores de Haralick, em grupos de três.

Para facilitar a análise dos dados, todas as tabelas possuem seus registros ordenados pelo campo Acurácia, em ordem decrescente. Na Tabela C.1, todas as combinações de descritores a partir da "0-1-10" (quarto registro da Tabela), até a combinação "7-9-11", o número de verdadeiros positivos é nulo, fato que anula a possibilidade de uso das respectivas combinações, visto que, para todos os casos, foi utilizada a mesma imagem, na qual se encontra o resultado de um exame em paciente

com AVCi. Ainda na Tabela C.1, percebe-se que as combinações "0-2-7", "0-2-8" e "0-2-3" apresentam boa acurácia e boa especificidade, no entanto, possuem valores de sensibilidade muito baixos, mostrando que essas combinações não realizam a detecção de verdadeiros positivos de maneira aceitável.

Ainda na Tabela C.1, os dados encontrados com as combinações de descritores a partir da "0-2-7" até a combinação "1-8-9" (último registro da tabela), é possível perceber que os valores de falsos positivos (média de 52442 pontos) são muito mais altos que os valores de falsos positivos dos três primeiros registros da Tabela C.1 (média de 4325 pontos). Isto mostra que as combinações de descritores a partir da "0-2-7" até a combinação "1-8-9" (na Tabela C.1) não possuem as respostas mais interessantes do conjunto de resultados, levando-se em conta o grau de acerto em detecção de regiões com AVCi.

Com base nessa análise, nota-se que, no experimento realizado, as combinações de descritores "0-2-4", "0-4-5" e "2-4-5", são as mais indicadas para a detecção de texturas representativas de regiões com AVCi.

5.6. Análise das melhores combinações de três descritores

Nesta sessão são apresentados os resultados encontrados com o teste do classificador para os três grupos de três descritores identificados como mais eficientes para a separação entre texturas de ACVi e texturas de tecidos normais da TC, pois foram os que apresentaram melhores resultados na sessão 5.5. Esses resultados podem ser observados nas Tabelas 5.5, 5.6 e 5.7, e são obtidos das combinações dos seguintes descritores:

- Correlação, Homogeneidade (IDM - *Inverse Difference Moment*) e Soma das Médias;
- Segundo Momento Angular, Homogeneidade e Soma das Médias;
- Segundo Momento Angular, Correlação e Soma das Médias.

Os resultados são apresentados por meio das Tabelas 5.5, 5.6 e 5.7, bem como por meio das Figuras 5.5, 5.6, 5.7, 5.8, 5.9 e 5.10, cuja análise pode ser feita de forma comparativa com o padrão ouro apresentado por meio das Figuras 5.3 e 5.4.

Avaliando os dados na Tabela 5.6, se percebe que, das dez imagens de pacientes com AVCi (primeiras da lista), apenas três retornaram verdadeiros positivos com a combinação Segundo Momento Angular, Homogeneidade e Soma das Médias. Isto revela que a referida combinação não é a melhor opção para a detecção de regiões com AVCi.

Por sua vez, com a combinação formada pelos descritores Segundo Momento Angular, Correlação e Soma das Médias (Tabela 5.7), só é possível perceber dois casos

Figura 5.3 – Padrão ouro para as imagens 1 à 15 da base utilizada.

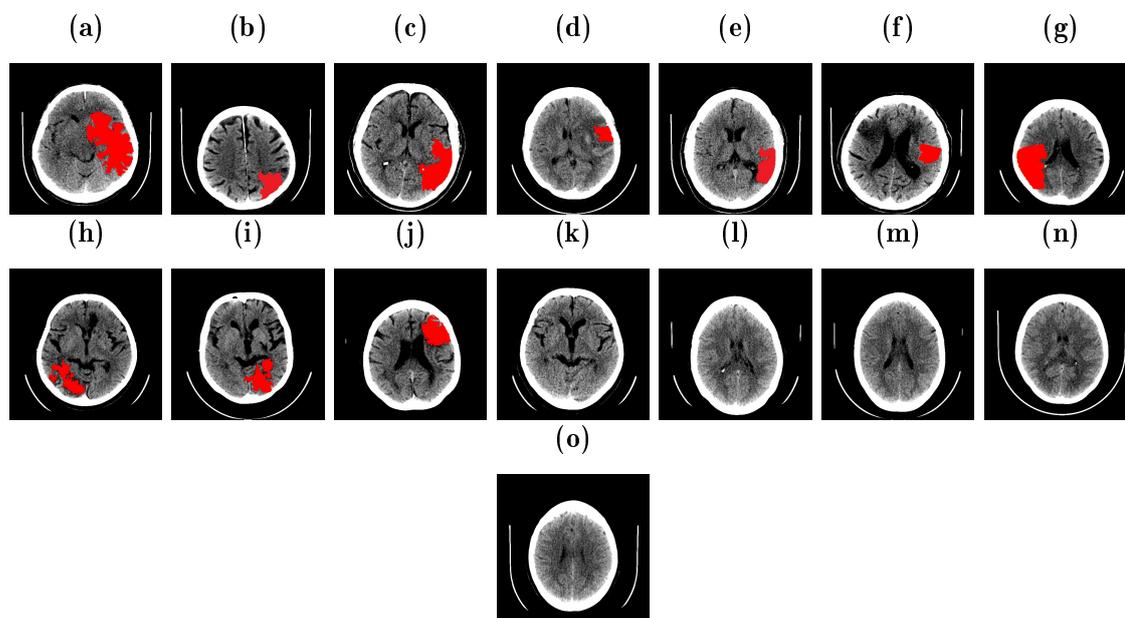
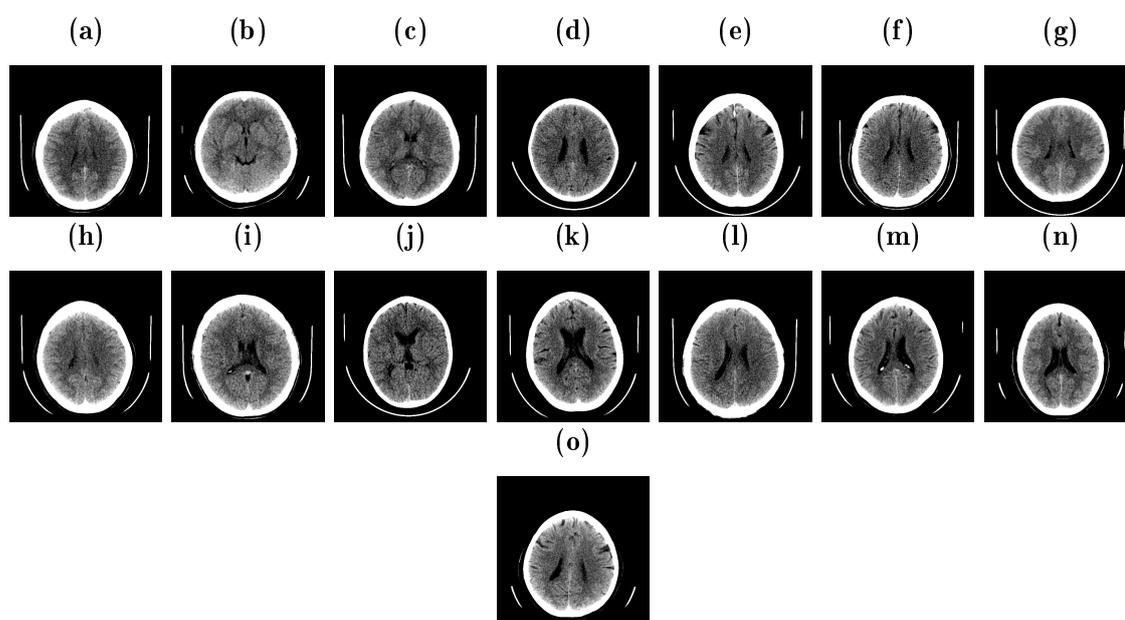


Figura 5.4 – Padrão ouro para as imagens 16 à 30 da base utilizada.



onde existe a presença de AVCi e não foram percebidos pelo classificador (amostras de imagens 2 e 6) e, com a combinação Correlação, Homogeneidade e Soma das Médias (Tabela 5.5), apenas nenhuma amostra da base com AVCi foi classificada sem verdadeiros positivos, casos que ascendem a preferência por uma das duas combinações.

Em termos de sensibilidade (medida do grau de acertos dos verdadeiros positivos), percebe-se que os valores da Tabela 5.5 estão mais interessantes que o da Tabela 5.6, pois na Tabela 5.6 considerando as dez imagens com AVCi, encontra-se uma média de 78% sensibilidade, enquanto que na Tabela 5.6 esse mesmo cálculo de média resulta em apenas 5% de acerto. Portanto, apesar de que ambas as combinações possuem valores de

relevantes acurácia (todos acima de 90%), percebe-se que a combinação dos descritores Correlação, Homogeneidade e Soma das Média é mais eficiente das possibilidades, pois conseguem melhor definir a existência do AVCi na imagem.

Tabela 5.5 – Resultados obtidos a partir da combinação dos descritores correlação, homogeneidade e soma das médias.

	VP	FP	VN	FN	Sensibilidade	Especificidade	Acurácia
imagem1	12769	609	156722	5670	0.6925	0.9960	0.9643
imagem2	2870	494	147717	819	0.7782	0.9967	0.9913
imagem3	5779	1048	167633	4820	0.5452	0.9938	0.9673
imagem4	1224	121	177247	1148	0.5161	0.9992	0.9929
imagem5	4155	4404	172006	413	0.9095	0.9748	0.9734
imagem6	2607	1331	168866	902	0.7429	0.9921	0.9870
imagem7	8494	573	137391	1697	0.8335	0.9958	0.9847
imagem8	4957	5796	154243	136	0.9733	0.9637	0.9640
imagem9	4891	6030	166951	578	0.8942	0.9650	0.9627
imagem10	5284	1327	135808	801	0.8683	0.9902	0.9850
imagem11	0	0	171395	0	0	1	1
imagem12	0	910	171890	0	0	0.9947	0.9947
imagem13	0	0	184900	0	0	1	1
imagem14	0	0	176688	0	0	1	1
imagem15	0	0	161942	0	0	1	1
imagem16	0	0	160580	0	0	1	1
imagem17	0	0	158625	0	0	1	1
imagem18	0	0	172865	0	0	1	1
imagem19	0	0	156455	0	0	1	1
imagem20	0	639	177757	0	0	0.9963	0.9963
imagem21	0	0	152817	0	0	1	1
imagem22	0	0	171901	0	0	1	1
imagem23	0	0	167371	0	0	1	1
imagem24	0	0	177963	0	0	1	1
imagem25	0	0	171738	0	0	1	1
imagem26	0	0	184025	0	0	1	1
imagem27	0	0	165568	0	0	1	1
imagem28	0	0	175671	0	0	1	1
imagem29	0	0	163296	0	0	1	1
imagem30	0	0	149344	0	0	1	1

Figura 5.5 – Resultados com as figuras 1 a 15, obtidos com a combinação dos descritores correlação, homogeneidade e soma das médias.

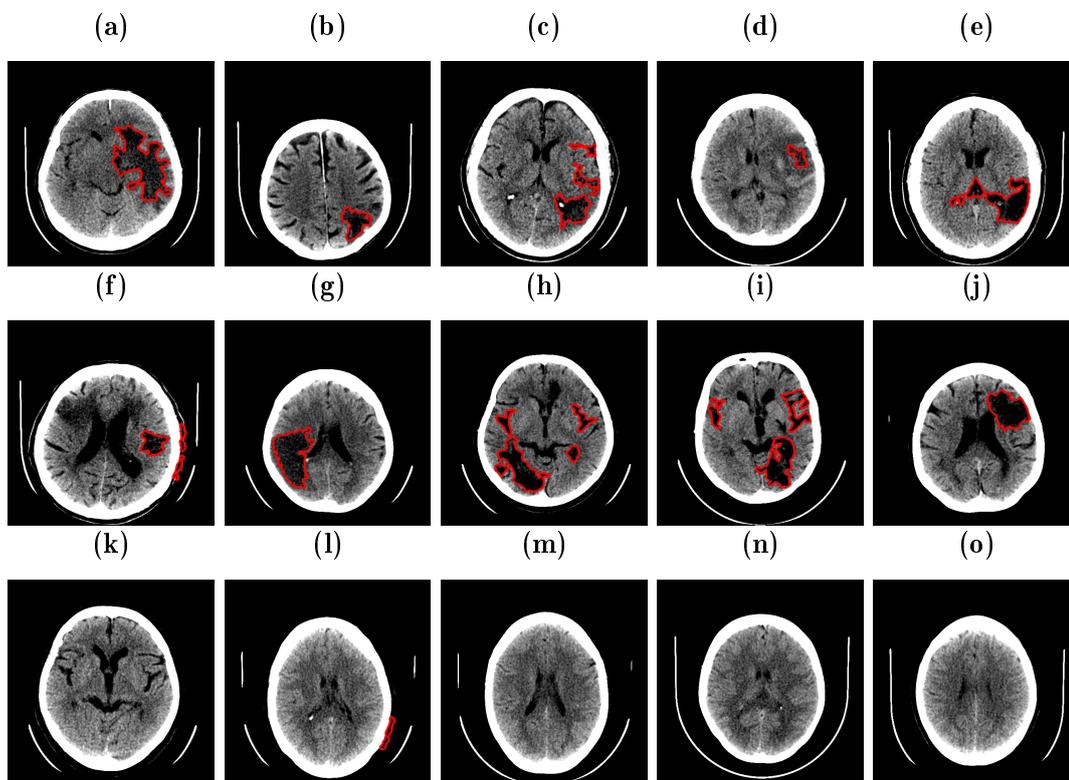


Figura 5.6 – Resultados com as figuras 16 a 30, obtidos com a combinação dos descritores correlação, homogeneidade e soma das médias.

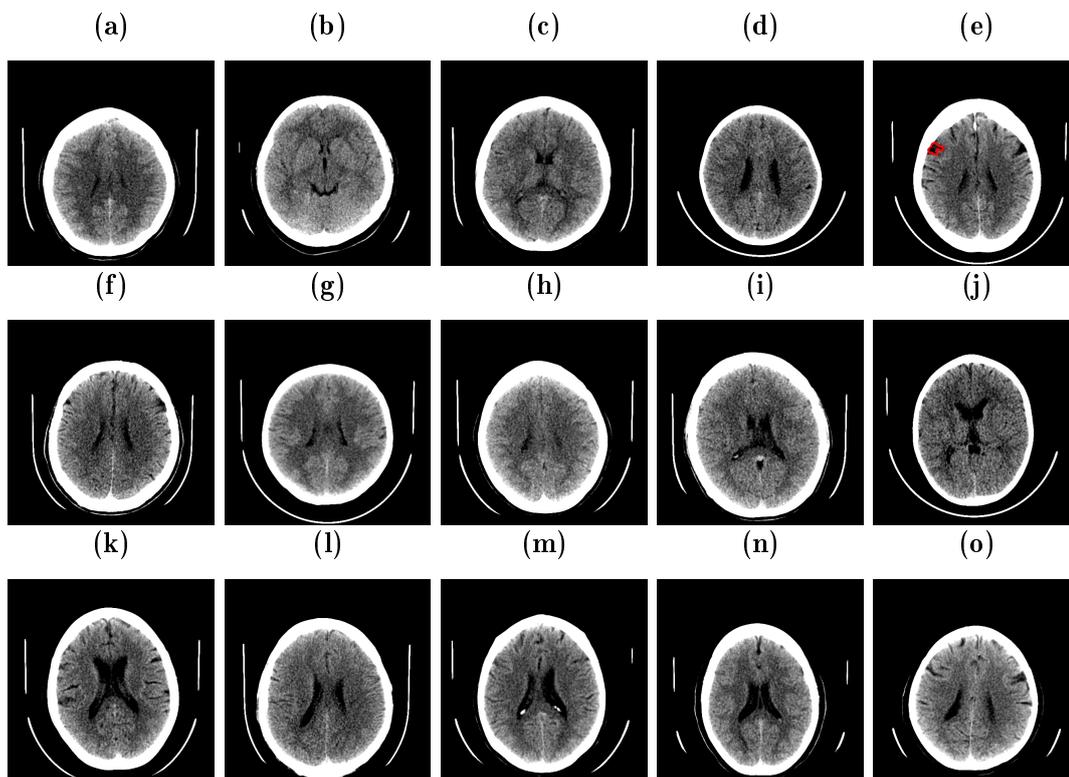


Tabela 5.6 – Resultados obtidos a partir da combinação dos descritores segundo momento angular, homogeneidade e soma das médias.

	VP	FP	VN	FN	Sensibilidade	Especificidade	Acurácia
imagem1	1818	0	157331	16621	0.0098	1	0.9053
imagem2	0	0	148211	3689	0	1	0.9757
imagem3	694	0	168681	9905	0.0065	1	0.9447
imagem4	0	0	174682	5058	0	1	0.9718
imagem5	0	0	176410	4568	0	1	0.9748
imagem6	0	939	169258	3509	0	0.9945	0.9744
imagem7	3395	0	137964	6796	0.3331	1	0.9540
imagem8	0	0	159528	5604	0	1	0.9660
imagem9	0	0	173187	5263	0	1	0.9705
imagem10	0	0	137500	5720	0	1	0.9600
imagem11	0	0	171395	0	0	1	1
imagem12	0	0	172800	0	0	1	1
imagem13	0	0	184900	0	0	1	1
imagem14	0	0	176688	0	0	1	1
imagem15	0	0	161942	0	0	1	1
imagem16	0	0	160580	0	0	1	1
imagem17	0	0	158625	0	0	1	1
imagem18	0	0	172865	0	0	1	1
imagem19	0	0	156455	0	0	1	1
imagem20	0	0	178396	0	0	1	1
imagem21	0	0	152817	0	0	1	1
imagem22	0	0	171901	0	0	1	1
imagem23	0	0	167371	0	0	1	1
imagem24	0	0	177963	0	0	1	1
imagem25	0	0	171738	0	0	1	1
imagem26	0	0	184025	0	0	1	1
imagem27	0	0	165568	0	0	1	1
imagem28	0	0	175671	0	0	1	1
imagem29	0	0	163296	0	0	1	1
imagem30	0	0	149344	0	0	1	1

Figura 5.7 – Resultados com as figuras 1 a 15, obtidos com a combinação dos descritores segundo momento angular, homogeneidade e soma das médias.

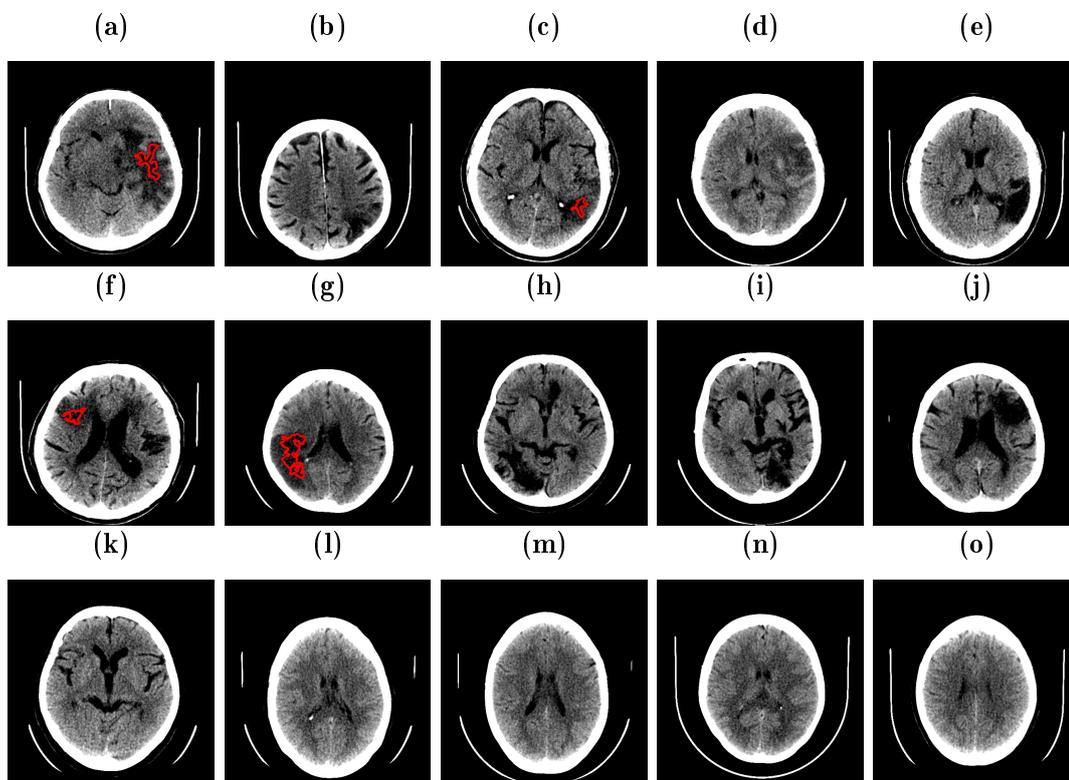


Figura 5.8 – Resultados com as figuras 16 a 30, obtidos com a combinação dos descritores segundo momento angular, homogeneidade e soma das médias.

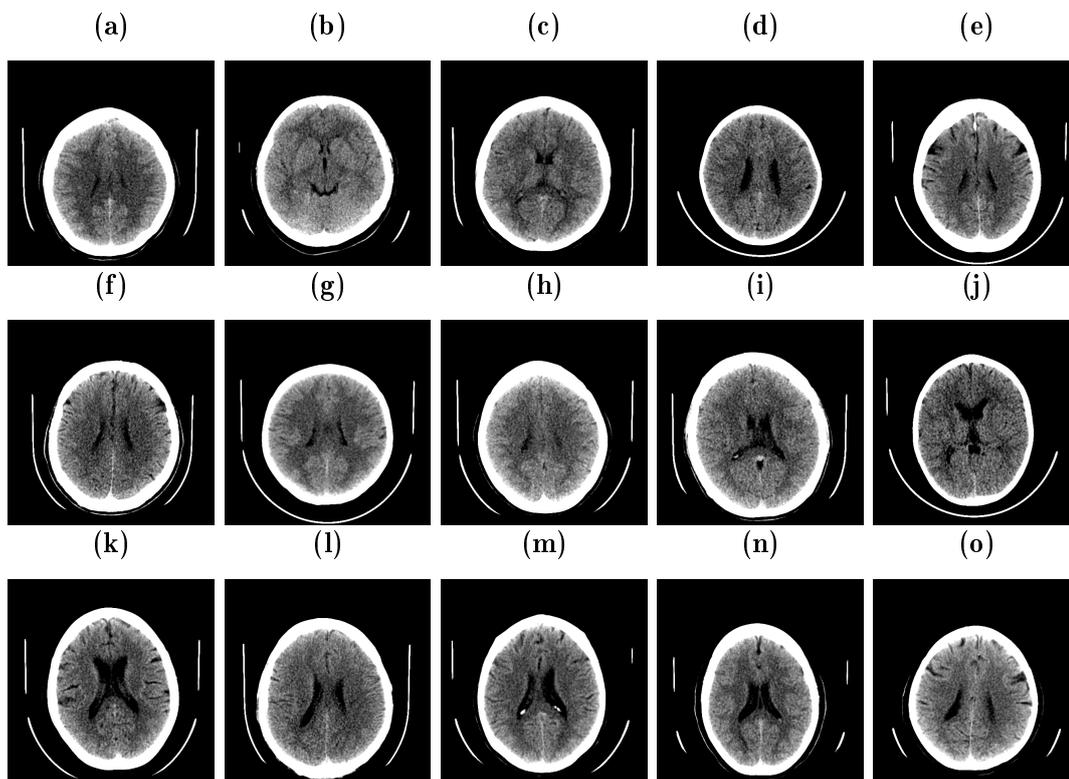


Tabela 5.7 – Resultados obtidos a partir da combinação dos descritores segundo momento angular, correlação e soma das médias.

	VP	FP	VN	FN	Sensibilidade	Especificidade	Acurácia
imagem1	2939	3445	153886	15500	0.1593	0.9780	0.8921
imagem2	0	523	147688	3689	0	0.9965	0.9723
imagem3	1963	3793	164888	8636	0.1852	0.9775	0.9306
imagem4	968	6	174676	4090	0.1913	1	0.9771
imagem5	2001	1794	174616	2567	0.438	0.9898	0.9758
imagem6	0	4693	165504	3509	0	0.9724	0.9527
imagem7	2664	0	137964	7527	0.2614	1	0.9492
imagem8	2218	2119	157409	3386	0.3957	0.9867	0.9667
imagem9	1110	7	173180	4153	0.2109	1	0.9767
imagem10	2915	240	137260	2805	0.5096	0.9982	0.9787
imagem11	0	1577	169818	0	0	0.9908	0.9908
imagem12	0	0	172800	0	0	1	1
imagem13	0	0	184900	0	0	1	1
imagem14	0	889	175799	0	0	0.995	0.995
imagem15	0	0	161942	0	0	1	1
imagem16	0	0	160580	0	0	1	1
imagem17	0	0	158625	0	0	1	1
imagem18	0	0	172865	0	0	1	1
imagem19	0	0	156455	0	0	1	1
imagem20	0	0	178396	0	0	1	1
imagem21	0	0	152817	0	0	1	1
imagem22	0	0	171901	0	0	1	1
imagem23	0	1439	165932	0	0	0.9913	0.9913
imagem24	0	0	177963	0	0	1	1
imagem25	0	1133	170605	0	0	0.9933	0.9933
imagem26	0	0	184025	0	0	1	1
imagem27	0	0	165568	0	0	1	1
imagem28	0	0	175671	0	0	1	1
imagem29	0	0	163296	0	0	1	1
imagem30	0	0	149344	0	0	1	1

Figura 5.9 – Resultados com as figuras 1 a 15, obtidos com a combinação dos descritores segundo momento angular, correlação e soma das médias.

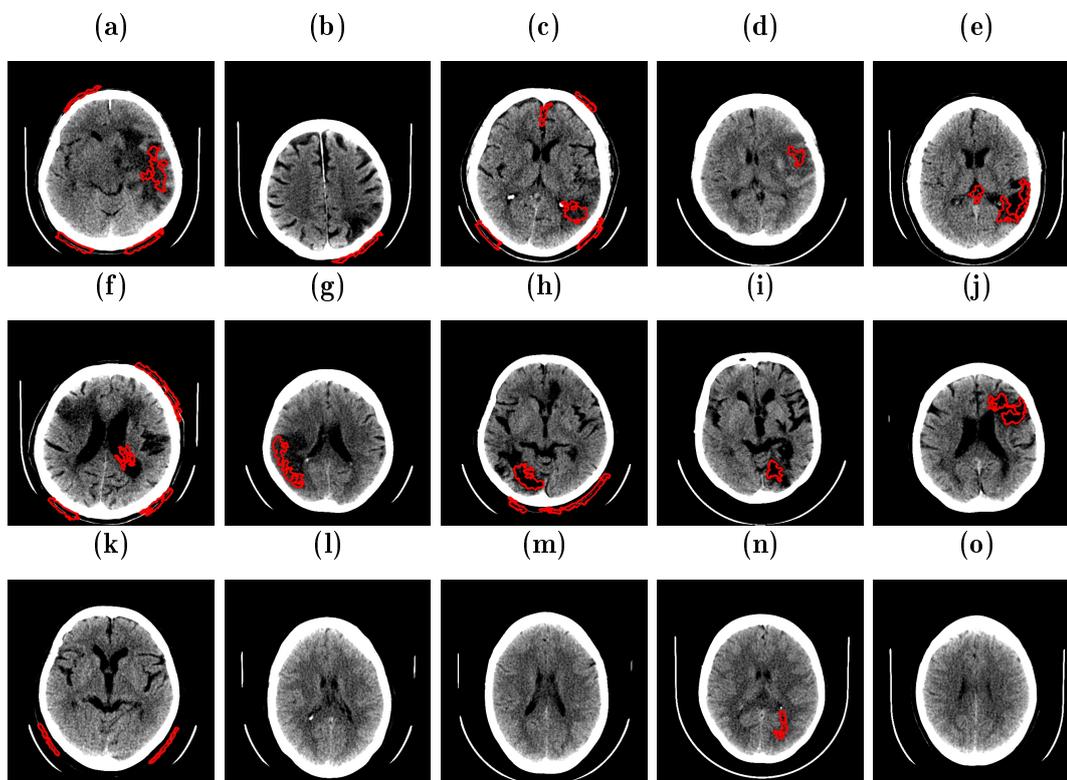
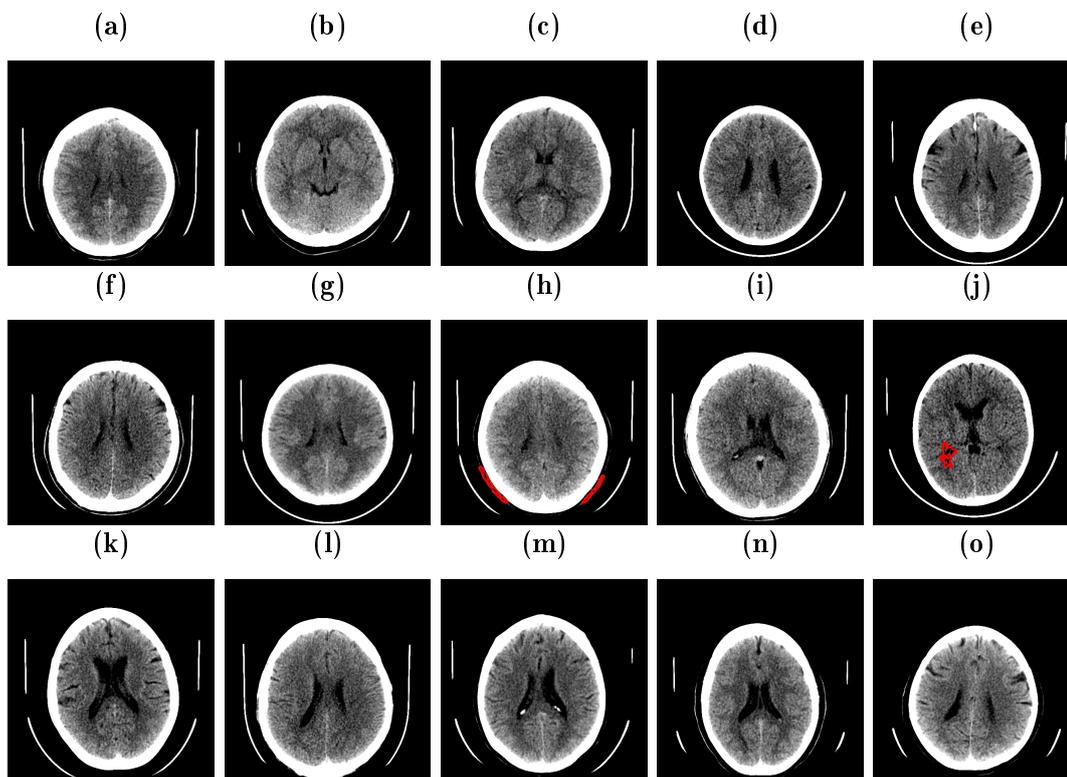


Figura 5.10 – Resultados com as figuras 16 a 30, obtidos com a combinação dos descritores segundo momento angular, correlação e soma das médias.



5.7. A detecção de AVCi com as três melhores combinações de descritores

Quanto a capacidade de detecção de AVCi (confirmação da patologia por meio de uma marcação, precisa ou não), a combinação dos descritores Correlação, Homogeneidade e Soma das Médias também é a melhor, observa-se que as 10 imagens com a patologia foram identificadas, das 20 imagens sem patologia, apenas duas imagens tiveram um AVCi erroneamente identificado, na Figura (5.5l) encontra-se uma demarcação fora da área compreendida pelo crânio e na Figura (5.6e) é feita uma marcação sobre uma região aquosa do cérebro.

A combinação dos descritores segundo momento angular, homogeneidade e soma das médias não trouxe nenhum erro em imagens sem AVCi (não foi afirmado regiões de AVCi nas 20 imagens sem patologia), no entanto, das 10 imagens com a patologia, apenas 4 foram tiveram alguma marcação indicadora de AVCi.

Os resultados vindos a partir da combinação dos descritores segundo momento angular, correlação e soma das médias, foram dados com muitas marcações fora da região do crânio (Figuras 5.9a, 5.9b, 5.9c, 5.9f, 5.9h, 5.9k e 5.10h). Dentre esses mesmos resultados, das 10 com AVCi, nove delas (Figuras 5.9a, 5.9c, 5.9d, 5.9e, 5.9f, 5.9g, 5.9h, 5.9i e 5.9j) foram demarcadas com indicações da patologia, enquanto que, das 20 imagens sem a patologia, 4 receberam um contorno em regiões, erroneamente, classificadas como AVCi (Figuras 5.9k, 5.9n, 5.10h e 5.10j).

Como forma de mensurar a qualidade do diagnóstico feito pelo classificador configurado com a combinação Correlação, Homogeneidade e Soma das Médias, calculou-se a área sob a curva ROC, utilizando um intervalo de confiança a 95%. A curva foi construída a partir de 200 amostras extraídas de 10 TC com AVCi processadas pelo classificador. De cada uma das imagens foram coletados 10 valores de *pixels* localizados em uma região de AVCi e 10 *pixels* de tecidos não atingidos pela patologia. Os dados receberam tratamento estatístico através do software SPSS 19.0 (*Statistical Package to Social Sciences for Windows*) onde, para critérios de decisão, foi adotado o nível de significância (ρ) de 5%.

Segundo Braga [102], o SPSS efetua o cálculo da área abaixo da curva ROC e o respectivo erro padrão pelo método não paramétrico da estatística de Wilcoxon-Mann-Whitney. A curva ROC obtida é mostrada na Figura 5.11.

A área sob a curva ROC obtida é de 0,861. Esse valor, segundo Silva [101], mostra que o classificador configurado com a combinação Correlação, Homogeneidade e Soma das Médias possui uma boa qualidade de diagnóstico, fato que certifica o desempenho do sistema como sendo satisfatório.

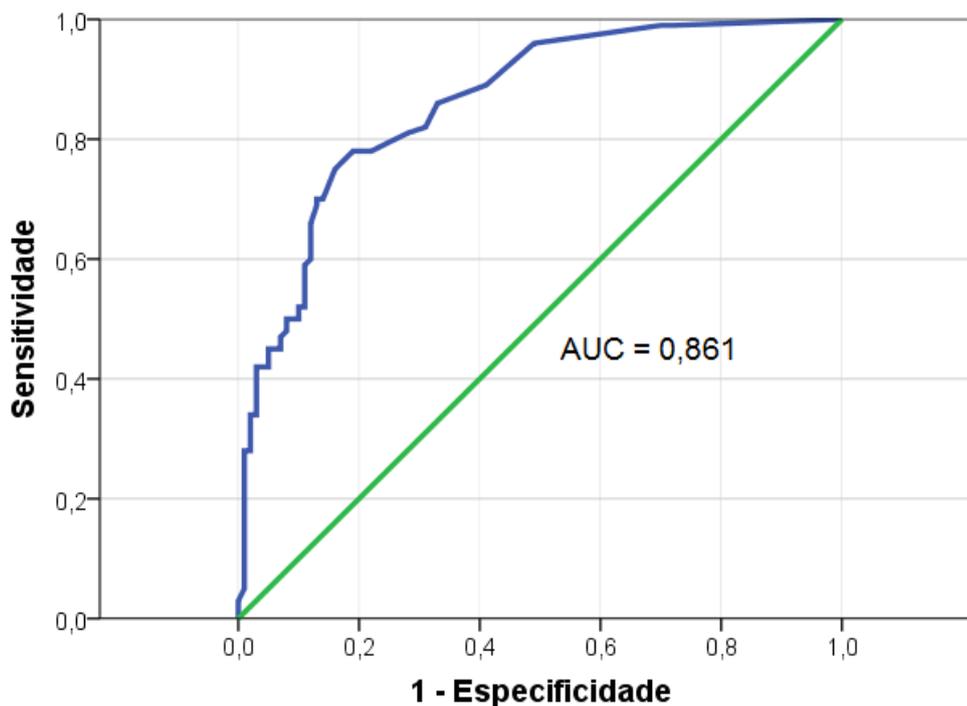


Figura 5.11 – Curva ROC para classificador configurado para a combinação Correlação, Homogeneidade e Soma das Médias.

5.8. Considerações

Propõe-se, neste capítulo a análise sobre agrupamentos de descritores de Haralick, empregados para a classificação de Textura em TC, com o propósito de segmentar regiões de AVCi, caso existam em um dado exame.

Por meio dos testes é possível perceber que um descritor isoladamente não é suficiente para realizar a tarefa que se propõe como objetivo deste trabalho, no entanto, associações de descritores podem retornar resultados interessantes. Com base nisso são testadas possibilidades de combinações buscando aquela que, com um menor número de descritores, trazem resultados significativos de classificação.

Nos testes com dois descritores não se percebeu a separação entre área de AVCi e os tecidos cerebrais não comprometidos, contudo, nos testes de agrupamentos com três descritores houve respostas relevantes principalmente com as combinações "correlação, homogeneidade e soma das médias", "segundo momento angular, homogeneidade e soma das médias" e "correlação, homogeneidade e soma das médias". Analisando isoladamente os resultados de cada combinação, é percebido que, apesar de que ambas as combinações possuem valores de acurácia e especificidade, de certa forma, equivalentes, a combinação dos descritores Correlação, Homogeneidade e Soma das Média é mais eficiente das três.

6.1. Considerações Finais

A análise de textura em imagens digitais pode ser utilizada para desenvolver sistemas de auxílio ao diagnóstico por imagem. Pesquisas mostram que, em imagens médicas, regiões com AVC e sem AVC podem apresentar características de textura capazes de diferenciá-las.

Neste trabalho foi realizada a análise de textura baseada nas respostas de combinações de descritores de Haralick, sobre imagens de tomografia computadorizada. Por meio de uma análise estatística com testes de hipóteses, percebe-se que tais descritores possuem, para a aplicação que se propõe nesta pesquisa, diferenças significantes entre os dois grupos de textura que se deseja classificar: região de AVCi e região sem AVCi, na TC. A partir disso, surgiu o interesse de aplicar técnicas de Processamento Digital de Imagens e de classificação de padrões para desenvolver uma sistema capaz de realizar a segmentação de regiões de AVCi em TC. O objetivo geral foi atingido e cabe ressaltar que o sistema desenvolve a segmentação proposta sem nenhuma intervenção humana.

As respostas obtidas foram positivas visto que, comparando com outros trabalhos da literatura, apresentaram resultados relevantes, atingindo taxas de classificação significativas que revelam um bom desempenho na detecção de presença ou ausência de AVCi.

Neste trabalho foi analisado o desempenho dos descritores em diferentes combinações, com uma, duas e três unidades. Com base nessa análise foi percebido que três descritores é a quantidade mínima de dados de textura para uma boa classificação em TC do crânio. Das possíveis combinações com três descritores, apenas três obtiveram resultados plausíveis, foram elas:

- Correlação, Homogeneidade e Soma das Médias;
- Segundo Momento Angular, Homogeneidade e Soma das Médias;
- Segundo Momento Angular, Correlação e Soma das Médias.

Por meio de testes com o classificador, definiu-se que a combinação formada pelos descritores Correlação, Homogeneidade e Soma das Médias é o mais eficiente, por apresentarem melhores resultados de sensibilidade (média de 78%), especificidade (média de 99%) e acurácia (média de 97%). A área sob a curva ROC obtida com classificador configurado para essa combinação foi de 0,861, isso mostra que o desempenho do sistema é satisfatório e o sistema proposto possui uma boa qualidade de diagnóstico.

De acordo com as análises realizadas neste estudo, o uso dos descritores de Haralick como parâmetros para segmentação de regiões de AVCi em TC mostra-se como uma técnica promissora.

6.2. Contribuições da pesquisa

As contribuições desta pesquisa de Dissertação são as seguintes:

- Estudo estatístico sobre o potencial discriminativo dos descritores de Haralick para classificação de texturas de TC;
- Investigação preliminar do número mínimo de entradas (descritores), para uma rede neural MLP, capaz de promover a classificação de área com e sem AVCi;
- Estudo da melhor combinação de descritores como entradas para um classificador baseado em RNA.
- Desenvolvimento de uma RNA em C++ para aprendizagem de padrões de textura;
- Desenvolvimento de uma biblioteca em C++ para cálculos de textura, baseados nos descritores de Haralick;

6.3. Sugestões para Trabalhos Futuros

As sugestões para trabalhos futuros estão elencadas a seguir.

- Aproveitar os estudos realizados e investigar, utilizando outras bases de dados, a aplicação dos métodos propostos em diferentes patologias do cérebro;
- Investigar a utilização de outros algoritmos para análise de texturas, como o *Local Binary Pattern* (LBP);
- Estudar a combinação entre diferentes métodos de mensuração de textura;

-
- Analisar resultados obtidos por outros classificadores, tais como Máquinas de Vetores Suporte (*Support Vector Machines* - SVM) e outras redes neurais além das MLP;
 - Melhoramento do algoritmo para atuação apenas na região interna do crânio, com o propósito de reduzir o tempo de processamento e os erros causados por marcações externas ao osso;
 - Melhoramento do algoritmo para atuação sobre todo o exame de TC, com o propósito de construção de uma representação 3D da região afetada pelo AVCi;
 - Buscar meios de integração direta entre o sistema desenvolvido e o tomógrafo, buscando um processamento online.

Referências Bibliográficas

- [1] H. Pedrini and W. R. Schwartz, *Análise de Imagens Digitais: Princípios, Algoritmos e Aplicações*. Thomson Learnig, 2008.
- [2] R. C. Gonzalez and W. R., *Digital Image Processing*. New Jersey: Pearson Prentice Hall, 2011.
- [3] J. G. Webster, *Medical Instrumentation Application Designer*. John Wiley and Sons Inc, 4 ed., 2009.
- [4] S. C. Salomão, “Integrando sistemas de auxilio ao diagnostico no sistema gerenciador de imagens médicas,” *Dissertação (Mestrado) - Escola de Engenharia de São Carlos/ Faculdade de Medicina de Ribeirão Preto/ Instituto de Química de São Carlos da Universidade de São Paulo*, 2010.
- [5] V. R. Fuchs and H. C. Sox Jr., “Physicians views of the relative importance of thirty medical innovations,” *HealthAffairs*, vol. 20, no. 5, pp. 300x9632., 2001.
- [6] A. R. d. Alexandria, P. C. Cortez, J. H. d. S. Felix, and J. S. d. Abreu, “Método de contornos ativos psnakes aplicado em imagens de ecocardiograma de eixo curto para cálculo de fração de ejeção,” *Revista Brasileira de Engenharia Biomédica*, Vol. 27, N. 3, p. 147-162, 2011.
- [7] A. R. d. Alexandria, “psnakes: Método de contornos ativos radial usando energia hilbertiana para a segmentação do ventrículo esquerdo em imagens de ultrassom,” *Tese (Doutorado em Engenharia de Teleinformática) - Universidade Federal do Cear0xE1. Fortaleza*, 2011.
- [8] S. Pankanti, R. M. Bolle, and A. Jain, “Biometrics: The future of identification.,” *Computer*, vol. r2046, p. 460x9649, 2000.
- [9] N. K. Ratha, A. Senior, and R. Bolle, “Automated biometrics,” *In Lecture Notes in Computer Science, Rio de Janeiro, Brasil. Springer-Verlag Press*, 2001.

- [10] A. R. d. Alexandria, “Sistema de reconhecimento Óptico de algarismos para medidores convencionais de energia,” *Dissertação (Mestrado em Engenharia de Teleinformática) - Universidade Federal do Ceará. Fortaleza*, 2005.
- [11] S. E. N. Correia, “Reconhecimento de caracteres manuscritos usando wavelets,” *Tese (Doutorado em Engenharia Elétrica) - Universidade Federal de Campina Grande. Campina Grande*, 2005.
- [12] C. Mori, S. and Suen and K. Yamamoto, “Historical review of ocr research and development,” *Proc. IEEE*, vol. 80, no. 7, p. 10290x961058, 1992.
- [13] V. H. d. Albuquerque, A. R. d. Alexandria, P. C. Cortez, and J. M. R. S. Tavares, “Evaluation of multilayer perceptron and self-organizing map neural network topologies applied on microstructure segmentation from metallographic images,” *NDT & E International*, vol. 42, no. 7, pp. 644–651, 2009.
- [14] P. C. Cortez, “Reconhecimento de formas 2d usando uma técnica sequencial integrada e modelos poligonais,” *Tese (Doutorado em Engenharia Elétrica) - Universidade Federal da Paraíba. João Pessoa*, 1996.
- [15] V. Srikrishnan and S. Chaudhuri, “Adaptive smoothness based robust active contours,” *Image and Vision Computing*, vol. 29, no. 5, pp. 317–328, 2011.
- [16] V. Grassi Jr, “Sistema de visão omnidirecional aplicado no controle de robôs móveis,” *Dissertação (Mestrado e Engenharia Mecatrônica) - Escola Politécnica da Universidade de São Paulo. São Paulo*, 2002.
- [17] R. Siegwart and I. R. Nourbakhsh, *Introduction to Autonomous Mobile Robots*. Bradford Book, 2004.
- [18] L. Contin, “Segmentação das Áreas isquêmicas no acidente vascular cerebral utilizando imagens de tomografia computadorizada de perfusão,” *Tese (Doutorado em Radiologia) - Universidade de São Paulo. São Paulo*, 2011.
- [19] K. A. Norton, H. Iyatomi, M. E. Celebi, G. Schaefer, M. TANAKA, and K. OGAWA, “Development of a novel border detection method for melanocytic and non-melanocytic dermoscopy images,” *Annual International Conference of the IEEE EMBS. 32nd. Buenos Aires, Argentina*, pp. 5403–5406, 2010.
- [20] F. B. Markman, M. C. Almeida, M. Markman, A. Chaves, M. A. Moretti, J. A. F. Ramires, and L. A. César, “Estratificando o risco na angina instável com a ecocardiografia sob estresse com dobutamina,” *Arquivos Brasileiros de Cardiologia. 86(3):259-64.*, 2006.

- [21] M. C. Alegro and R. d. D. Lopes, "Aplicação de análise de textura na segmentação de tumores de cérebro em imagens por ressonância magnética," *CBIS 2008 XI Congresso Brasileiro de Informática em Saúde. Campos do Jordão*, 2008.
- [22] G. Castellano, M. S. Oliveira, P. T. Fernandes, and L. M. Li, *Técnicas de processamento de imagens de tomografia computadorizada*. In: Li Li Min; Paula Teixeira Fernandes; Sheila Martins; Ayrton Massaro. (Org.). *Neurociências e Acidente Vascular Cerebral*. Editora Plêiade, 1 ed., 2009.
- [23] R. Charnovscki, "Desenvolvimento de uma metodologia computacional para análise do fluxo cerebral utilizando tomografia computadorizada dinâmica," *Dissertação (Mestrado em Ciência da Computação) - Universidade Federal de Santa Catarina. Florianópolis*, 2003.
- [24] P. P. Rebouças Filho, "Mca crisp: nova técnica de segmentação dos pulmões em imagens de tomografia computadorizada baseada no método de contorno ativo," *Dissertação (Mestrado em Engenharia de Teleinformática) - Universidade Federal do Ceará. Fortaleza*, 2010.
- [25] W. D. Martins, "Wilhelm conrad roentgen e a descoberta dos raios x," *Revista de Clínica e Pesquisa Odontológica/Journal of Dental Clinics and Research, Curitiba*, v. 1, n.3, p. 59-63, 2005.
- [26] A. M. R. Pereira, "Estudo do impacto da descoberta dos raios-x e das suas aplicações médicas em portugal," *Dissertação (Mestrado em Química) - Departamento de Bioquímica da Faculdade de Ciências da Universidade de Lisboa. Lisboa*, 2012.
- [27] R. Marder, "Tomografia computadorizada fan beam na odontologia," *Monografia (Especialização em Radiologia Odontológica e Imaginologia) - Universidade Federal do Rio Grande do Sul. Porto Alegre*, 2012.
- [28] N. O. Silva, J. N. S. Junior, J. B. Silva, and P. C. N. Cunha, "Incentivando a prática da radioproteção," *IX Latin American IRPA Regional Congress on Radiation Protection and Safety - IRPA 2013 da Sociedade Brasileira de Proteção Radiológica - SBPR. Rio de Janeiro, RJ, Brazil, April 15-19*, 2013.
- [29] C. R. Rodrigues, "Grupos estratégicos no setor de diagnóstico médico por imagem na região de florianópolis," *Monografia (Graduação em Ciências Econômicas) - Departamento de Ciências Econômicas da Universidade Federal de Santa Catarina. Florianópolis*, 2002.
- [30] A. E. Buzzi, "Walter bradford cannon: Pionero y mártir de la radiologia," *Rev. Argent. Radiol., Ciudad Autónoma de Buenos Aires*, v. 77, n. 1, 2013.

- [31] R. M. E. Sabbatini, “A história da neuroimagem,” *Artigo da Internet*, 2014. Disponível em: < <http://cdpsi.com.br/blog/index.php/2014/04/a-historia-da-neuroimagem-renato-m-e-sabbatini-phd/>>, Data de acesso: 28/12/2015.
- [32] A. L. Bastos, “Doses e risco de radiação em estudo tomográfico computadorizado do tórax tecnologia de quatro cortes,” *Dissertação (Mestrado em Ciência e Tecnologia das Radiações, Minerais e Materiais) - Programa de Pós-Graduação em Ciência e Tecnologia das Radiações, Minerais e Materiais do Centro De Desenvolvimento Da Tecnologia Nuclear. Belo Horizonte*, 2006.
- [33] A. E. Buzzi and M. Suarez, “Tomografia lineal: Nacimiento, gloria y ocaso de un método,” *Rev. Argent. Radiol., Ciudad Autónoma de Buenos Aires*, v. 77, n. 3, 2013.
- [34] A. C. P. Carvalho, “O acidente vascular cerebral: Classificação, principais consequências e reabilitação,” *História da tomografia computadorizada. In: Marcelo Souto Nacif; Edvaldo Severo dos Santos. (Org.). Manual de técnicas em tomografia computadorizada. 1ed. Rio de Janeiro: Rubio, v. 1, p. 7-23.*, 2009.
- [35] C. M. S. Magalhães, “Dosimetria em tomografia computadorizada utilizando fototransistor,” *Dissertação (Mestrado em Ciências) - Universidade Federal de Pernambuco. Recife*, 2007.
- [36] F. A. P. Soares, “Produção de raios x em ampolas radiográficas: Estudo do tomógrafo computadorizado do hospital regional de são josé-sc,” *Tese (Doutorado em Física Experimental) - Universidade Federal de Santa Catarina. Florianópolis*, 2006.
- [37] C. C. SIMÕES and P. S. F. CAMPOS, “Influência do tamanho do voxel na qualidade de imagem tomográfica: Revisão de literatura,” *Revista da Faculdade de Odontologia da UPF*, v. 18, p. 362-365, 2013.
- [38] K. P. S. Cáceres, “Efeitos da variação da espessura do corte tomográfico e da largura do campo de visão (fov) na reprodução de estruturas Ósseas finas, com a finalidade de prototipagem rápida - estudo in vitro,” *Monografia (Especialização em Radiologia Odontológica e Imaginologia) - Universidade Federal de Santa Catarina. Florianópolis*, 2005.
- [39] J. A. Marconato, “Redução de dose de radiação e aumento na vida Útil do tubo de raios-x em um equipamento de tomografia computadorizada,” *Dissertação (Mestrado em Medicina) - Faculdade de Medicina da Universidade Federal do Rio do Janeiro. Rio de Janeiro*, 2005.

- [40] W. C. Godoi, "Tomografia - apostila. curitiba," *Disponível em: http://www.walmorgodoi.com/arquivos/Apostila_Tomografia_Walmor.pdf*. Acesso em: 06/01/2016, 2009.
- [41] J. M. Bilinski, "Estudo comparativo entre as tomografias computadorizadas fan beam e cone beam: Revisão da literatura," *Monografia (Especialização em Radiologia Odontológica e Imaginologia) - Faculdade de Ciências Biológicas e de Saúde da Universidade Tuiuti do Paraná. Curitiba, 2011.*
- [42] D. G. e. a. Garib, "Physicians views of the relative importance of thirty medical innovations," *Tomografia computadorizada de feixe cônico (Cone beam): entendendo este novo método de diagnóstico por imagem com promissora aplicabilidade na Ortodontia. Rev. Dent. Press Ortodon. Ortop. Facial, Maringá , v. 12, n. 2, p. 139-156, 2007.*
- [43] L. C. G. Oliveira, "Estimativa da exposição à radiação de pacientes submetidos à angiografia coronariana por tomografia," *Tese (Doutorado em Engenharia Nuclear) - Universidade Federal do Rio de Janeiro. Rio de Janeiro, 2012.*
- [44] D. Y. Nersissian, "Tomografia computadorizada: Tecnologia e funcionamento dos equipamentos," *Universidade Tecnológica Federal do Paraná. Curitiba, 2012. Disponível em: http://rle.dainf.ct.utfpr.edu.br/hipermidia/images/documentos/Tomografia_computadorizada_tecnologia_e_funcionamento Equipamentos.pdf*. Data de acesso: 12/01/2016, 2012.
- [45] M. d. C. C. Cheade, "Correlação entre as densidades ósseas maxilo-mandibular, cabeças mandibulares, e vértebras cervicais c1,c2,c3 através de tomografia computadorizada com ct multislice (escala hounsfield): osteoporose localizada ou sistêmica," *Dissertação (Mestrado em Odontologia) - Faculdade de Odontologia da Universidade de São Paulo. São Paulo, 2014.*
- [46] A. C. H. d. Oliveira, "Influência da qualidade de imagens ct na avaliação da distribuição de dose em planejamento radioterápico baseado em métodos monte carlo," *Dissertação (Mestrado em Tecnologias Energéticas Nucleares) - Universidade Federal de Pernambuco. Recife, 2014.*
- [47] M. M. Pacheco, "Tomografia computadorizada por feixe cônico e outras técnicas de imagem na determinação do reparo periapical," *Monografia (Especialização em Endodontia) - Faculdade Unidas do nordeste de Minas. Governador Valadares, 2014.*
- [48] P. B. V. Zanatta, "Tomografia computadorizada de feixe em leque e tomografia computadorizada de feixe cônico: Revisão da literatura," *Monografia (Especialização*

- em Radiologia Odontológica*) - Instituto de Ciências da Saúde - FUNORTE. Florianópolis, 2013.
- [49] S. P. d. Oliveira, “Avaliações de lesões malignas nos maxilares na presença de artefatos dentários metálicos utilizando a tomografia computadorizada,” *Dissertação (Mestrado em Odontologia)* - Faculdade de Odontologia da Universidade de São Paulo. São Paulo, 2004.
- [50] C. A. Rúbio, “Estilização e visualização tridimensional de tumores intracranianos em exames de tomografia computadorizada,” *Dissertação (Mestrado em Informática)* - Universidade Federal do Paraná. Curitiba, 2003.
- [51] A. I. L. Arruda, “Automatização da medição do volume do hipocampo em doentes de alzheimer,” *Dissertação (Mestrado)* - Faculdade de Ciências e Tecnologia da Universidade Nova de Lisboa. Lisboa, 2012.
- [52] M. V. R. Gonçalves, “Processamento de dados em aquisição simultânea de eeg/iform,” *Dissertação (Mestrado)* - Faculdade de Ciências e Tecnologia da Universidade Nova de Lisboa. Lisboa,, 2009.
- [53] L. B. R. d. Melo, “Memória de trabalho e função executiva: Uma proposta de diálogo entre dois modelos teóricos,” *Dissertação (Mestrado em Psicologia)* - Programa de Pós-Graduação em Psicologia da Universidade Federal de Juiz de Fora. Juiz de Fora, 2011.
- [54] R. O. d. Santos, “Estrutura e funções do córtex cerebral,” *Monografia (Graduação em Ciências Biológicas)* - Faculdade de Ciências da Saúde do Centro Universitário de Brasília. Brasília, 2002.
- [55] S. M. Silva, “Incentivando a prática da radioproteção,” *Neurofisiologia Básica. In: Gomes, A. D. O. (Org.). VIII Curso de Inverno: Tópicos de Fisiologia Comparativa. Livro do curso de inverno do Programa de Pós-graduação em Fisiologia Geral do instituto de Biociências da USP. São Paulo, 2011*, Disponível em: <<http://www.ib.usp.br/cursodeinverno/old/2011/livro2011.pdf>>. Acesso em 10/02/2016.
- [56] M. I. d. F. G. Soares, “Acidente vascular cerebral isquêmico: Complicações infecciosas segundo o volume e a localização de enfarte,” *Dissertação (Mestrado em Medicina)* - Universidade da Beira Interior. Covilhã, 2011.
- [57] D. M. G. Cacela, “O acidente vascular cerebral: Classificação, principais consequências e reabilitação,” *Monografia (Licenciatura em Psicologia)* - Universidade Lusíada do Porto. Porto, Portugal, 2008.

- [58] H. F. R. Dohmann and J. Oliveira Filho, “Terapia celular para acidente vascular cerebral isquêmico: esperança ou panacéia?,” *Arquivos Brasileiros de Cardiologia*, vol. 86, pp. 85 – 86, 02 2006.
- [59] A. L. Hennemann, “Processamento de dados em aquisição simultânea de eeg/ifrm,” *Acidente Vascular Cerebral*, 2012. Disponível em: <<http://www.estudoadministracao.com.br/ler/16-11-2014-como-fazer-citacoes-internet/>>, Acesso em: 17/01/2015.
- [60] L. D. Oliveira, “Acidente vascular cerebral. neurologia/neurofisiologia,” *Hospital das Clínicas da UFMG*, 2002. Disponível em: <<http://www.ciape.org.br/matdidatico/leonardo/avc.doc>>, Acesso em: 17/01/2016.
- [61] S. A. Mayer, “Recombinant activated factor vii for acute intracerebral hemorrhage,” *Stroke*. 2007; 38[part 2]:763-767, 2007.
- [62] L. H. C. Garcia and B. C. Ferreira, “Abc... para a tomada de decisões,” *Radiologia Brasileira*, Mar/Abr;48(2):101-110, 2015.
- [63] P. E. Ambrósio, “Redes neurais auto-organizáveis na caracterização de lesões intersticiais de pulmão em radiografia do tórax,” *Tese (Doutorado) - Faculdade de Medicina de Ribeirão Preto, Universidade de São Paulo. Ribeirão Preto*, 2010.
- [64] H. B. Soares, “Análise e classificação de imagens de lesão da pele por atributos de cor, forma e textura utilizando máquina de vetor de suporte,” *Tese (Doutorado em Engenharia Elétrica) - Universidade Federal do Rio Grande do Norte. Natal*, 2008.
- [65] M. F. Angelo, “Sistema de processamento de imagens mamográficas e auxílio ao diagnóstico via-internet,” *Tese (Doutorado) - Escola de Engenharia de São Carlos, Universidade de São Paulo. São Carlos*, 2007.
- [66] M. L. d. Siqueira, “Reconhecimento automático de padrões em imagens ecocardiográficas,” *Tese (Doutorado em Computação) - Universidade Federal do Rio Grande do Sul. Porto Alegre*, 2010.
- [67] J. G. Souza, “Técnicas de computação natural para segmentação de imagens médicas,” *Dissertação (Mestrado em Engenharia Elétrica) - Universidade Federal do Rio Grande do Norte. Natal*, 2007.
- [68] D. R. Medaglia and I. H. Manssour, “Segmentação de imagens médicas baseada no uso das bibliotecas itk e vtk,” *Simpósio Brasileiro de Computação Gráfica e Processamento de Imagens - SIBGRAPI. Manaus*, 2006.

- [69] M. S. d. Oliveira, “Análise de textura em imagens cerebrais: aplicações em acidente vascular cerebral isquêmico, epilepsia mioclônica juvenil, doença de machado-joseph, déficit cognitivo leve e doença de alzheimer,” *Tese (Doutorado) - Universidade Estadual de Campinas, Instituto de Física "Gleb Wataghin". Campinas (SP)*, 2010.
- [70] E. R. Antonio, “Ferramenta de auxílio diagnóstico para o tratamento de acidentes vasculares cerebrais,” *Tese (Doutorado em Engenharia Civil) - Universidade Federal do Rio de Janeiro. Rio de Janeiro*, 2008.
- [71] R. M. Sarmiento, R. F. Pereira, P. P. A. Coimbra, A. C. N. Macedo, and P. P. Rebouças Filho, “Segmentação de acidente vascular cerebral em imagens de tomografia computadorizada: Um estudo comparativo,” *VII Simpósio de Instrumentação e Imagens Médicas (SIIM 2015). Campinas: UNICAMP*, 2015.
- [72] L. G. F. JIAN, M.; LIU, “Texture image classification using perceptual texture features and gabor wavelet features,” in *Information Processing, 2009. APCIP 2009. Asia-Pacific Conference on*, vol. 2, pp. 55–58, July 2009.
- [73] J. R. Parker, *Algorithms for Image Processing and Computer Vision*. John Wiley & Sons, Toronto, ISBN: 0-471-14056-2, 1997.
- [74] K. D. I. Haralick, R. M.; Shanmugam, “Textural features for image classification,” *IEEE Transactions on Systems, Man, and Cybernetics*, vol. SMC-3, pp. 610–621, Nov 1973.
- [75] M. M. T. Ojala, T.; Pietikäinen, “Multiresolution gray-scale and rotation invariant texture classification with local binary patterns,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 24, pp. 971–987, Jul 2002.
- [76] K. B. Kashyap, R. L.; Eom, “Texture boundary detection based on the long correlation model,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 11, pp. 58–67, Jan 1989.
- [77] R. M. AKSOY, S.; HARALICK, “Textural features for image database retrieval. content-based access of image and video libraries,”
- [78] J. P. R. d. Nascimento, “Análise e classificação de imagens baseadas em características de textura utilizando matrizes de co-ocorrência,” *Dissertação (Mestrado) - Programa de Pós-Graduação em Informática da Universidade Federal do Paraná*, 2003.
- [79] S. V. d. Rocha, “Diferenciação do padrão de malignidade e benignidade de massas em imagens mamográficas usando padrões locais binários, geoestatística e Índice

- de diversidade,” *Tese (Doutorado) - Programa de Pós-graduação em Engenharia Elétrica da Universidade Federal do Maranhão. São Luís*, 2014.
- [80] A. Nunes, E. O.; Conci, “Segmentação por textura e localização do contorno de regiões em imagens multibandas,” *Revista IEEE América Latina*, v. 5, p. 185-192, 2007.
- [81] A. J. Traina, “Suporte à visualização de consultas por similaridade em imagens médicas através de estruturas de indexação métrica,” *Tese de livre-docente em computação, Instituto de Ciências Matemática e de Computação - Universidade de São Paulo, São Paulo*, 2001.
- [82] C. Ballard, D.H.; Brown, “Computer vision,” *Nova Jersey: Prentice Hall*, 1982.
- [83] V. d. A. Ventura, “Representação de imagens através de grafos utilizando o algoritmo split-and-merge combinado com descritores de cor e textura,” *Dissertação (Mestrado) - Departamento de Informática da Universidade Federal do Espírito Santo. Vitória-ES*, 2009.
- [84] W. SCHWARTZ, “Segmentação de imagens baseada em dependência espacial utilizando campo aleatório de markov associado com características de texturas,” *Dissertação (Mestrado em Informática) - Universidade Federal do Paraná. Curitiba*, 2005.
- [85] C. D. Rennó, “Avaliação de medidas texturais na discriminação de classes de uso utilizando imagens sir-c/x-sar do perímetro irrigado de bebedouro, petrolina-pe,” *Dissertação (Mestrado) - Programa de Pós-Graduação em Sensoriamento Remoto do Instituto Nacional de Pesquisas Espaciais - INPE. São José dos Campos*, 2004.
- [86] J. T. L. I. C. B. FERNANDES, S. R.; ASSIS, “Desenvolvimento de uma metodologia para análise de imagens de microtomografia de raios-x baseada em abordagens estatísticas,” *Mecânica Computacional - MECOM, Buenos Aires, Vol XXIX, págs. 6257-6266*, 2010.
- [87] M. Hall-Beyer, “The glm texture tutorial: An online image textural resource within the university of calgary,” *Calgary, 2007. Disponível em: <http://www.fp.ucalgary.ca/mhallbey/tutorial.htm>. Acesso em: 15/03/2016*, 2007.
- [88] V. S. S. R. COSTA, R. M.; PATTO, “Aplicação de técnicas de visão computacional para avaliar qualidade de radiografias odontológicas,” *Revista de Exatas e Tecnológicas - RETEC*, v. 1, p. 1-9, 2010.
- [89] S. C. SAMPAIO, “Modelagem e implementação orientada a objetos de um cliente de rede para banco de dados de imagens médicas digitais utilizando o padrão dicom

- 3.0,” *Dissertação (Mestrado em Ciência da Computação) - Universidade Federal de Santa Catarina. Florianópolis, 1999.*
- [90] I. f. I. T. OFFIS, “Dcmk - dicom toolkit 3.6.0: Source code and documentation. disponível em: <<http://dicom.offis.de/dcmk.php.en>>. acesso em 07/02/2016,”
- [91] L. M. d. S. GUERRA, “Integração de exames de diagnóstico em sistemas de informação médica,” *Dissertação (Mestrado em Imagiologia Médica) - Universidade do Algarve. Faro, Portugal, 2008.*
- [92] N. A. OTSU, “Threshold selection method from gray-level histograms,” *IEEE Trans. Systems, Man and Cybernetics, vol. 9, n^o 1, pp. 62-66, 1979.*
- [93] M. K. HU, “Visual pattern recognition by moment invariants,” *IRE Transactions on Information Theory, vol. 8, n^o 2, pp. 179-187, 1962.*
- [94] M. O. SANTOS, “Análise acústica de desvios vocais infantis utilizando a transformada wavelet,” *Dissertação (Mestrado em Engenharia Elétrica) - Programa de Pós-Graduação em Engenharia Elétrica do Instituto Federal de Educação, Ciência e Tecnologia da Paraíba. João Pessoa, 2015.*
- [95] V. J. D. VIEIRA, “Avaliação de distúrbios da voz por meio de análise de quantificação de recorrência,” *Dissertação (Mestrado em Engenharia Elétrica) - Programa de Pós-Graduação em Engenharia Elétrica do Instituto Federal de Educação, Ciência e Tecnologia da Paraíba. João Pessoa, 2014.*
- [96] A. BEN-DAVID, “About the relationship between roc curves and cohen’s kappa. engineering applications of artificial intelligence, v. 21, n. 6, p. 874-882,” 2008.
- [97] A. C. G. Bissacot, “Estudo comparativo entre regressão logística binária e redes neurais artificiais na avaliação dos resultados clássicos de hosmer, lemeshow e sturdivant,” 2015.
- [98] T. FAWCETT, “An introduction to roc analysis,” *Pattern Recognition Letters, v. 27, n. 8, p. 861-874, 2006.*
- [99] D. J. Hand and R. J. Till, “A simple generalisation of the area under the roc curve for multiple class classification problems,” *Machine Learning, vol. 45, no. 2, pp. 171-186, 2001.*
- [100] K. SØREIDE, “Receiver-operating characteristic curve analysis in diagnostic, prognostic and predictive biomarker research,” *Journal of clinical pathology, v. 62, n. 1, p. 1-5, 2009.*

- [101] A. C. Silva, “Algoritmos para diagnóstico assistido de nódulos pulmonares solitários em imagens de tomografia computadorizada,” *Tese (Doutorado em informática) - PUC do Rio de Janeiro. Rio de Janeiro*, 2004.
- [102] A. C. d. S. Braga, “Curvas roc: Aspectos funcionais e aplicações,” *Tese (Doutorado em Engenharia de Produção e Sistemas) - Universidade do Minho. Braga*, 2000.
- [103] I. S. Statistics, “version 19,” 2010.
- [104] R. A. K. J. S. Williamson, D. F.; Parker, *The box plot: a simple visual method to interpret data. Annals of Internal Medicine* vol. 110 (11), pp. 916-921. 1989.
- [105] V. J. D. Vieira, “Caracterização de sinais de vozes saudáveis e sinais de vozes patológicas por meio da análise de quantificação de recorrência,” *Monografia (Tecnologia em Telecomunicações.) - IFPB Campus João Pessoa. João Pessoa*, 2012.

APÊNDICES

Resultados com um Descritor

Tabela A.1 – Resultados com um descritor - Imagem 1

Descritor	VP	FP	VN	FN	Sensibilidade	Especificidade	Acurácia
10	16246	64789	92542	2193	0.8810	0.5881	0.6189
11	18439	157331	0	0	1	0	0.1048
1	18439	157331	0	0	1	0	0.1048
2	12875	50010	107321	5564	0.6982	0.6821	0.6837
3	18439	157331	0	0	1	0	0.1048
4	7418	24665	132666	11021	0.4022	0.8431	0.7974
5	18439	157331	0	0	1	0	0.1048
6	16032	62307	95024	2407	0.8695	0.6038	0.6318
7	15998	61535	95796	2441	0.8676	0.6089	0.6361
8	18439	157331	0	0	1	0	0.1048
9	15470	58141	99190	2969	0.8387	0.6304	0.6522
0	15942	60521	96810	2497	0.8646	0.6152	0.6414

Tabela A.2 – Resultados com um descritor - Imagem 2

Descritor	VP	FP	VN	FN	Sensibilidade	Especificidade	Acurácia
10	2060	82246	65965	1629	0.5584	0.4451	0.4477
11	3689	148211	0	0	1	0	2.429E-2
1	3689	148211	0	0	1	0	2.429E-2
2	1850	68738	79473	1839	0.5014	0.5362	0.5353
3	3689	148211	0	0	1	0	2.429E-2
4	64	5035	143176	3625	1.729E-2	0.9657	0.9425
5	3689	148211	0	0	1	0	2.429E-2
6	2060	81656	66555	1629	0.5584	0.4491	0.4516
7	2060	81523	66688	1629	0.5584	0.45	0.4526
8	3689	148211	0	0	1	0	2.429E-2
9	2060	80662	67549	1629	0.5584	0.4557	0.4582
0	2060	81351	66860	1629	0.5584	0.4511	0.4536

Tabela A.3 – Resultados com um descritor - Imagem 3

Descritor	VP	FP	VN	FN	Sensibilidade	Especificidade	Acurácia
10	10335	61072	107609	264	0.9750	0.6379	0.6579
11	10599	168681	0	0	1	0	5.91E-2
1	10599	168681	0	0	1	0	5.91E-2
2	7210	42844	125837	3389	0.6803	0.746	0.7420
3	10599	168681	0	0	1	0	5.91E-2
4	1318	4234	164447	9281	0.1244	0.9748	0.9245
5	10599	168681	0	0	1	0	5.91E-2
6	10309	60315	108366	290	0.9726	0.6423	0.6623
7	10311	60117	108564	288	0.9728	0.6435	0.6631
8	10599	168681	0	0	1	0	5.91E-2
9	10233	58671	110010	366	0.9655	0.6522	0.6706
0	10305	59789	108892	294	0.9723	0.6454	0.6649

Tabela A.4 – Resultados com um descritor - Imagem 4

Descritor	VP	FP	VN	FN	Sensibilidade	Especificidade	Acurácia
10	2351	100287	77081	21	0.9910	0.4345	0.4419
11	2372	177368	0	0	1	0	1.32E-2
1	2372	177368	0	0	1	0	1.32E-2
2	1586	81469	95899	786	0.6685	0.5406	0.5423
3	2372	177368	0	0	1	0	1.32E-2
4	258	9408	167960	2114	0.1087	0.9465	0.9358
5	2372	177368	0	0	1	0	1.32E-2
6	2351	100075	77293	21	0.9910	0.4358	0.4430
7	2351	99939	77429	21	0.9910	0.4365	0.4439
8	2372	177368	0	0	1	0	1.32E-2
9	2351	98884	78484	21	0.9910	0.4425	0.4496
0	2351	99731	77637	21	0.9910	0.4376	0.4451

Tabela A.5 – Resultados com um descritor - Imagem 5

Descritor	VP	FP	VN	FN	Sensibilidade	Especificidade	Acurácia
10	3977	77790	98620	591	0.8706	0.5595	0.5668
11	4568	176410	0	0	1	0	2.52E-2
1	4568	176410	0	0	1	0	2.52E-2
2	3461	63469	112941	1107	0.7577	0.6401	0.6431
3	4568	176410	0	0	1	0	2.52E-2
4	212	3344	173066	4356	4.637E-2	0.9808	0.9575
5	4568	176410	0	0	1	0	2.52E-2
6	3977	76209	100201	591	0.8706	0.5675	0.5756
7	3977	76022	100388	591	0.8706	0.5691	0.5766
8	4568	176410	0	0	1	0	2.52E-2
9	3977	74201	102209	591	0.8706	0.5794	0.5867
0	3977	75470	100940	591	0.8706	0.5722	0.5796

Tabela A.6 – Resultados com um descritor - Imagem 6

Descritor	VP	FP	VN	FN	Sensibilidade	Especificidade	Acurácia
10	2982	75140	95057	527	0.8498	0.5585	0.5644
11	3509	170197	0	0	1	0	2.019E-2
1	3509	170197	0	0	1	0	2.019E-2
2	2167	63776	106421	1342	0.6176	0.6252	0.6250
3	3509	170197	0	0	1	0	2.019E-2
4	1148	26016	144181	2361	0.3271	0.8470	0.8366
5	3509	170197	0	0	1	0	2.019E-2
6	2884	72686	97511	625	0.8218	0.5728	0.5776
7	2860	71978	98219	649	0.8145	0.5770	0.5818
8	3509	170197	0	0	1	0	2.019E-2
9	2646	68903	101294	863	0.7540	0.5951	0.5984
0	2811	70663	99534	698	0.8011	0.5847	0.5891

Tabela A.7 – Resultados com um descritor - Imagem 7

Descritor	VP	FP	VN	FN	Sensibilidade	Especificidade	Acurácia
10	9757	70318	67646	434	0.9574	0.4903	0.5223
11	10191	137964	0	0	1	0	6.88E-2
1	10191	137964	0	0	1	0	6.88E-2
2	8204	52379	85585	1987	0.8055	0.6202	0.6331
3	10191	137964	0	0	1	0	6.88E-2
4	524	7986	129978	9667	5.141E-2	0.9421	0.8808
5	10191	137964	0	0	1	0	6.88E-2
6	9637	69278	68686	554	0.9456	0.4979	0.5286
7	9615	69039	68925	576	0.9435	0.4995	0.5301
8	10191	137964	0	0	1	0	6.88E-2
9	9517	67498	70466	674	0.9338	0.5108	0.5399
0	9651	68802	69162	540	0.9465	0.5012	0.5323

Tabela A.8 – Resultados com um descritor - Imagem 8

Descritor	VP	FP	VN	FN	Sensibilidade	Especificidade	Acurácia
10	5093	59774	100265	0	1	0.6264	0.6381
11	0	0	160039	5093	0	1	0.9691
1	0	0	160039	5093	0	1	0.9691
2	4637	52161	107878	456	0.9104	0.6741	0.6814
3	0	0	160039	5093	0	1	0.9691
4	3655	34429	125610	1438	0.7177	0.7849	0.7828
5	0	0	160039	5093	0	1	0.9691
6	0	0	160039	5093	0	1	0.9691
7	0	0	160039	5093	0	1	0.9691
8	0	0	160039	5093	0	1	0.9691
9	4924	57946	102093	169	0.9667	0.6379	0.6481
0	5093	59080	100959	0	1	0.6308	0.6421

Tabela A.9 – Resultados com um descritor - Imagem 9

Descritor	VP	FP	VN	FN	Sensibilidade	Especificidade	Acurácia
10	5469	82491	90490	0	1	0.5231	0.5376
11	5469	172981	0	0	1	0	3.059E-2
1	5469	172981	0	0	1	0	3.059E-2
2	4781	60389	112592	688	0.8741	0.6509	0.6576
3	5469	172981	0	0	1	0	3.059E-2
4	375	7746	165235	5094	6.854E-2	0.9552	0.9285
5	5469	172981	0	0	1	0	3.059E-2
6	5469	82223	90758	0	1	0.5247	0.5392
7	5469	81997	90984	0	1	0.5262	0.5404
8	5469	172981	0	0	1	0	3.059E-2
9	5469	79517	93464	0	1	0.5403	0.5544
0	5469	81788	91193	0	1	0.5272	0.5416

Tabela A.10 – Resultados com um descritor - Imagem 10

Descritor	VP	FP	VN	FN	Sensibilidade	Especificidade	Acurácia
10	5745	70749	66386	340	0.9441	0.4840	0.5036
11	6085	137135	0	0	1	0	4.253E-2
1	6085	137135	0	0	1	0	4.253E-2
2	3643	55641	81494	2442	0.5987	0.5943	0.5944
3	6085	137135	0	0	1	0	4.253E-2
4	1082	5724	131411	5003	0.1778	0.9583	0.9251
5	6085	137135	0	0	1	0	4.253E-2
6	5745	69893	67242	340	0.9441	0.4903	0.5096
7	5745	69893	67242	340	0.9441	0.4903	0.5096
8	6085	137135	0	0	1	0	4.253E-2
9	5713	68442	68693	372	0.9388	0.5009	0.5194
0	5744	69699	67436	341	0.9435	0.4917	0.5111

Tabela A.11 – Resultados com um descritor - Imagem 11

Descritor	VP	FP	VN	FN	Sensibilidade	Especificidade	Acurácia
10	0	72508	98887	0	0	0.5766	0.5766
11	0	171395	0	0	0	0	0
1	0	171395	0	0	0	0	0
2	0	56619	114776	0	0	0.6696	0.6696
3	0	171395	0	0	0	0	0
4	0	5173	166222	0	0	0.9698	0.9698
5	0	171395	0	0	0	0	0
6	0	71583	99812	0	0	0.5824	0.5824
7	0	71345	100050	0	0	0.5837	0.5837
8	0	171395	0	0	0	0	0
9	0	69650	101745	0	0	0.5936	0.5936
0	0	70837	100558	0	0	0.5867	0.5867

Tabela A.12 – Resultados com um descritor - Imagem 12

Descritor	VP	FP	VN	FN	Sensibilidade	Especificidade	Acurácia
10	0	86531	86269	0	0	0.4991	0.4991
11	0	172800	0	0	0	0	0
1	0	172800	0	0	0	0	0
2	0	73005	99795	0	0	0.5775	0.5775
3	0	172800	0	0	0	0	0
4	0	34217	138583	0	0	0.8025	0.8025
5	0	172800	0	0	0	0	0
6	0	172800	0	0	0	0	0
7	0	172800	0	0	0	0	0
8	0	172800	0	0	0	0	0
9	0	82053	90747	0	0	0.5252	0.5252
0	0	83255	89545	0	0	0.5181	0.5181

Tabela A.13 – Resultados com um descritor - Imagem 13

Descritor	VP	FP	VN	FN	Sensibilidade	Especificidade	Acurácia
10	0	77000	107900	0	0	0.5836	0.5836
11	0	184900	0	0	0	0	0
1	0	184900	0	0	0	0	0
2	0	64432	120468	0	0	0.6514	0.6514
3	0	184900	0	0	0	0	0
4	0	2712	182188	0	0	0.9852	0.9852
5	0	184900	0	0	0	0	0
6	0	75741	109159	0	0	0.5904	0.5904
7	0	75552	109348	0	0	0.5914	0.5914
8	0	184900	0	0	0	0	0
9	0	74745	110155	0	0	0.5958	0.5958
0	0	69645	115255	0	0	0.6232	0.6232

Tabela A.14 – Resultados com um descritor - Imagem 14

Descritor	VP	FP	VN	FN	Sensibilidade	Especificidade	Acurácia
10	0	70213	106475	0	0	0.6026	0.6026
11	0	176688	0	0	0	0	0
1	0	176688	0	0	0	0	0
2	0	65041	111647	0	0	0.6319	0.6319
3	0	176688	0	0	0	0	0
4	0	36620	140068	0	0	0.7926	0.7926
5	0	176688	0	0	0	0	0
6	0	176688	0	0	0	0	0
7	0	176688	0	0	0	0	0
8	0	176688	0	0	0	0	0
9	0	69213	107475	0	0	0.6082	0.6082
0	0	69645	107043	0	0	0.6058	0.6058

Tabela A.15 – Resultados com um descritor - Imagem 15

Descritor	VP	FP	VN	FN	Sensibilidade	Especificidade	Acurácia
10	0	69744	92198	0	0	0.5693	0.5693
11	0	161942	0	0	0	0	0
1	0	161942	0	0	0	0	0
2	0	63046	98896	0	0	0.6107	0.6107
3	0	161942	0	0	0	0	0
4	0	39119	122823	0	0	0.7583	0.7583
5	0	161942	0	0	0	0	0
6	0	161942	0	0	0	0	0
7	0	161942	0	0	0	0	0
8	0	161942	0	0	0	0	0
9	0	68580	93362	0	0	0.5765	0.5765
0	0	69205	92737	0	0	0.5726	0.5726

Tabela A.16 – Resultados com um descritor - Imagem 16

Descritor	VP	FP	VN	FN	Sensibilidade	Especificidade	Acurácia
10	0	60920	99660	0	0	0.6206	0.6206
11	0	160580	0	0	0	0	0
1	0	160580	0	0	0	0	0
2	0	55132	105448	0	0	0.6566	0.6566
3	0	160580	0	0	0	0	0
4	0	30651	129929	0	0	0.8091	0.8091
5	0	160580	0	0	0	0	0
6	0	160580	0	0	0	0	0
7	0	160580	0	0	0	0	0
8	0	160580	0	0	0	0	0
9	0	59443	101137	0	0	0.6298	0.6298
0	0	60065	100515	0	0	0.6259	0.6259

Tabela A.17 – Resultados com um descritor - Imagem 17

Descritor	VP	FP	VN	FN	Sensibilidade	Especificidade	Acurácia
10	0	69022	89603	0	0	0.5648	0.5648
11	0	158625	0	0	0	0	0
1	0	158625	0	0	0	0	0
2	0	59536	99089	0	0	0.6247	0.6247
3	0	158625	0	0	0	0	0
4	0	36274	122351	0	0	0.7712	0.7712
5	0	158625	0	0	0	0	0
6	0	158625	0	0	0	0	0
7	0	158625	0	0	0	0	0
8	0	158625	0	0	0	0	0
9	0	66878	91747	0	0	0.5784	0.5784
0	0	67631	90994	0	0	0.5736	0.5736

Tabela A.18 – Resultados com um descritor - Imagem 18

Descritor	VP	FP	VN	FN	Sensibilidade	Especificidade	Acurácia
10	0	81078	91787	0	0	0.5313	0.5313
11	0	172865	0	0	0	0	0
1	0	172865	0	0	0	0	0
2	0	73167	99698	0	0	0.5766	0.5766
3	0	172865	0	0	0	0	0
4	0	36463	136402	0	0	0.7891	0.7891
5	0	172865	0	0	0	0	0
6	0	172865	0	0	0	0	0
7	0	172865	0	0	0	0	0
8	0	172865	0	0	0	0	0
9	0	77019	95846	0	0	0.5544	0.5544
0	0	78200	94665	0	0	0.5475	0.5475

Tabela A.19 – Resultados com um descritor - Imagem 19

Descritor	VP	FP	VN	FN	Sensibilidade	Especificidade	Acurácia
10	0	77191	79264	0	0	0.5066	0.5066
11	0	156455	0	0	0	0	0
1	0	156455	0	0	0	0	0
2	0	67276	89179	0	0	0.5695	0.5695
3	0	156455	0	0	0	0	0
4	0	44336	112119	0	0	0.7166	0.7166
5	0	156455	0	0	0	0	0
6	0	156455	0	0	0	0	0
7	0	156455	0	0	0	0	0
8	0	156455	0	0	0	0	0
9	0	75467	80988	0	0	0.5175	0.5175
0	0	76268	80187	0	0	0.5124	0.5124

Tabela A.20 – Resultados com um descritor - Imagem 20

Descritor	VP	FP	VN	FN	Sensibilidade	Especificidade	Acurácia
10	0	67545	110851	0	0	0.6213	0.6213
11	0	178396	0	0	0	0	0
1	0	178396	0	0	0	0	0
2	0	62148	116248	0	0	0.6515	0.6515
3	0	178396	0	0	0	0	0
4	0	26015	152381	0	0	0.8541	0.8541
5	0	178396	0	0	0	0	0
6	0	178396	0	0	0	0	0
7	0	178396	0	0	0	0	0
8	0	178396	0	0	0	0	0
9	0	65887	112509	0	0	0.6307	0.6307
0	0	66316	112080	0	0	0.6282	0.6282

Tabela A.21 – Resultados com um descritor - Imagem 21

Descritor	VP	FP	VN	FN	Sensibilidade	Especificidade	Acurácia
10	0	65203	87614	0	0	0.5733	0.5733
11	0	152817	0	0	0	0	0
1	0	152817	0	0	0	0	0
2	0	57819	94998	0	0	0.6216	0.6216
3	0	152817	0	0	0	0	0
4	0	35574	117243	0	0	0.7671	0.7671
5	0	152817	0	0	0	0	0
6	0	152817	0	0	0	0	0
7	0	152817	0	0	0	0	0
8	0	152817	0	0	0	0	0
9	0	152817	0	0	0	0	0
0	0	64683	88134	0	0	0.5766	0.5766

Tabela A.22 – Resultados com um descritor - Imagem 22

Descritor	VP	FP	VN	FN	Sensibilidade	Especificidade	Acurácia
10	0	77166	94735	0	0	0.5511	0.5511
11	0	171901	0	0	0	0	0
1	0	171901	0	0	0	0	0
2	0	68909	102992	0	0	0.5990	0.5990
3	0	171901	0	0	0	0	0
4	0	24674	147227	0	0	0.8565	0.8565
5	0	171901	0	0	0	0	0
6	0	75811	96090	0	0	0.5595	0.5595
7	0	171901	0	0	0	0	0
8	0	171901	0	0	0	0	0
9	0	74008	97893	0	0	0.5695	0.5695
0	0	74589	97312	0	0	0.5661	0.5661

Tabela A.23 – Resultados com um descritor - Imagem 23

Descritor	VP	FP	VN	FN	Sensibilidade	Especificidade	Acurácia
10	0	68951	98420	0	0	0.5877	0.5877
11	0	167371	0	0	0	0	0
1	0	167371	0	0	0	0	0
2	0	60081	107290	0	0	0.6411	0.6411
3	0	167371	0	0	0	0	0
4	0	47742	119629	0	0	0.7147	0.7147
5	0	167371	0	0	0	0	0
6	0	167371	0	0	0	0	0
7	0	167371	0	0	0	0	0
8	0	167371	0	0	0	0	0
9	0	67501	99870	0	0	0.5967	0.5967
0	0	68176	99195	0	0	0.5927	0.5927

Tabela A.24 – Resultados com um descritor - Imagem 24

Descritor	VP	FP	VN	FN	Sensibilidade	Especificidade	Acurácia
10	0	68361	109602	0	0	0.6159	0.6159
11	0	177963	0	0	0	0	0
1	0	177963	0	0	0	0	0
2	0	59616	118347	0	0	0.6654	0.6654
3	0	177963	0	0	0	0	0
4	0	34121	143842	0	0	0.8083	0.8083
5	0	177963	0	0	0	0	0
6	0	177963	0	0	0	0	0
7	0	177963	0	0	0	0	0
8	0	177963	0	0	0	0	0
9	0	65344	112619	0	0	0.6328	0.6328
0	0	66204	111759	0	0	0.628	0.628

Tabela A.25 – Resultados com um descritor - Imagem 25

Descritor	VP	FP	VN	FN	Sensibilidade	Especificidade	Acurácia
10	0	72695	111330	0	0	0.6048	0.6048
11	0	184025	0	0	0	0	0
1	0	184025	0	0	0	0	0
2	0	67686	116339	0	0	0.6321	0.6321
3	0	184025	0	0	0	0	0
4	0	17989	166036	0	0	0.9022	0.9022
5	0	184025	0	0	0	0	0
6	0	184025	0	0	0	0	0
7	0	184025	0	0	0	0	0
8	0	184025	0	0	0	0	0
9	0	70481	113544	0	0	0.6169	0.6169
0	0	70977	113048	0	0	0.6142	0.6142

Tabela A.26 – Resultados com um descritor - Imagem 26

Descritor	VP	FP	VN	FN	Sensibilidade	Especificidade	Acurácia
10	0	74390	91178	0	0	0.5506	0.5506
11	0	165568	0	0	0	0	0
1	0	165568	0	0	0	0	0
2	0	65969	99599	0	0	0.6016	0.6016
3	0	165568	0	0	0	0	0
4	0	32690	132878	0	0	0.8025	0.8025
5	0	165568	0	0	0	0	0
6	0	165568	0	0	0	0	0
7	0	165568	0	0	0	0	0
8	0	165568	0	0	0	0	0
9	0	71864	93704	0	0	0.5655	0.5655
0	0	73219	92349	0	0	0.5577	0.5577

Tabela A.27 – Resultados com um descritor - Imagem 27

Descritor	VP	FP	VN	FN	Sensibilidade	Especificidade	Acurácia
10	0	74390	91178	0	0	0.5506	0.5506
11	0	165568	0	0	0	0	0
1	0	165568	0	0	0	0	0
2	0	65969	99599	0	0	0.6016	0.6016
3	0	165568	0	0	0	0	0
4	0	32690	132878	0	0	0.8025	0.8025
5	0	165568	0	0	0	0	0
6	0	165568	0	0	0	0	0
7	0	165568	0	0	0	0	0
8	0	165568	0	0	0	0	0
9	0	71864	93704	0	0	0.5655	0.5655
0	0	73219	92349	0	0	0.5577	0.5577

Tabela A.28 – Resultados com um descritor - Imagem 28

Descritor	VP	FP	VN	FN	Sensibilidade	Especificidade	Acurácia
10	0	78467	97204	0	0	0.5533	0.5533
11	0	175671	0	0	0	0	0
1	0	175671	0	0	0	0	0
2	0	71291	104380	0	0	0.5941	0.5941
3	0	175671	0	0	0	0	0
4	0	32576	143095	0	0	0.8145	0.8145
5	0	175671	0	0	0	0	0
6	0	175671	0	0	0	0	0
7	0	175671	0	0	0	0	0
8	0	175671	0	0	0	0	0
9	0	76261	99410	0	0	0.5658	0.5658
0	0	77083	98588	0	0	0.5612	0.5612

Tabela A.29 – Resultados com um descritor - Imagem 29

Descritor	VP	FP	VN	FN	Sensibilidade	Especificidade	Acurácia
10	0	73942	89354	0	0	0.5472	0.5472
11	0	163296	0	0	0	0	0
1	0	163296	0	0	0	0	0
2	0	63327	99969	0	0	0.6121	0.6121
3	0	163296	0	0	0	0	0
4	0	43632	119664	0	0	0.7328	0.7328
5	0	163296	0	0	0	0	0
6	0	163296	0	0	0	0	0
7	0	163296	0	0	0	0	0
8	0	163296	0	0	0	0	0
9	0	70826	92470	0	0	0.5663	0.5663
0	0	72769	90527	0	0	0.5544	0.5544

Tabela A.30 – Resultados com um descritor - Imagem 30

Descritor	VP	FP	VN	FN	Sensibilidade	Especificidade	Acurácia
10	0	66417	82927	0	0	0.5553	0.5553
11	0	149344	0	0	0	0	0
1	0	149344	0	0	0	0	0
2	0	58698	90646	0	0	0.6068	0.6068
3	0	149344	0	0	0	0	0
4	0	32286	117058	0	0	0.7838	0.7838
5	0	149344	0	0	0	0	0
6	0	65139	84205	0	0	0.5637	0.5637
7	0	149344	0	0	0	0	0
8	0	149344	0	0	0	0	0
9	0	63132	86212	0	0	0.5773	0.5773
0	0	64586	84758	0	0	0.5675	0.5675

Resultados Numéricos com Dois Descritores

Tabela B.1 – Resultados com dois descritores - Imagem 1

Descritor	VP	FP	VN	FN	Sensibilidade	Especificidade	Acurácia
0-11	18364	75840	81491	75	0.9959	0.5182	0.5681
0-1	18439	157331	0	0	1	0	0.1048
0-2	14624	58154	99177	3815	0.7931	0.6303	0.6473
0-3	18329	78045	79286	110	0.9939	0.5039	0.5554
0-4	712	3804	153527	17727	3.862E-2	0.9758	0.8774
0-5	18439	157331	0	0	1	0	0.1048
0-6	18358	74250	83081	81	0.9956	0.5281	0.5770
0-7	18273	69684	87647	166	0.9909	0.5571	0.6026
0-8	18439	157331	0	0	1	0	0.1048
0-9	17903	67677	89654	536	0.9708	0.5697	0.6119
10-11	18363	75761	81570	76	0.9959	0.5184	0.5685
1-10	18439	157331	0	0	1	0	0.1048
1-11	18439	157331	0	0	1	0	0.1048
1-2	18439	157331	0	0	1	0	0.1048
1-3	18439	157331	0	0	1	0	0.1048
1-4	18439	157331	0	0	1	0	0.1048
1-5	16121	42901	114430	2318	0.8742	0.7272	0.7427
1-6	18439	157331	0	0	1	0	0.1048
1-7	18439	157331	0	0	1	0	0.1048
1-8	18439	157331	0	0	1	0	0.1048
1-9	18439	157331	0	0	1	0	0.1048
2-10	13115	57648	99683	5324	0.7113	0.6336	0.6417
2-11	15694	60945	96386	2745	0.8510	0.6126	0.6377
2-3	17892	77393	79938	547	0.9703	0.5081	0.5565
2-4	3069	11639	145692	15370	0.1663	0.9265	0.8463
2-5	18439	157331	0	0	1	0	0.1048

2-6	18355	75004	82327	84	0.9953	0.5232	0.5727
2-7	18350	74431	82900	89	0.9951	0.5269	0.5756
2-8	18439	157331	0	0	1	0	0.1048
2-9	18100	73070	84261	339	0.9816	0.5355	0.5824
3-10	18053	77622	79709	386	0.9790	0.5066	0.5562
3-11	18439	157331	0	0	1	0	0.1048
3-4	0	49574	107757	18439	0	0.6848	0.6130
3-5	18363	78497	78834	76	0.9959	0.5010	0.5535
3-6	17996	77686	79645	443	0.9758	0.5061	0.5554
3-7	18439	157331	0	0	1	0	0.1048
3-8	18439	157331	0	0	1	0	0.1048
3-9	18439	157331	0	0	1	0	0.1048
4-10	633	3324	154007	17806	3.427E-2	0.9788	0.8798
4-11	656	3878	153453	17783	3.56E-2	0.9754	0.8768
4-5	18439	157331	0	0	1	0	0.1048
4-6	18203	68073	89258	236	0.9871	0.5673	0.6114
4-7	18439	157331	0	0	1	0	0.1048
4-8	18439	157331	0	0	1	0	0.1048
4-9	17932	68658	88673	507	0.9725	0.5635	0.6065
5-10	18439	157331	0	0	1	0	0.1048
5-10	18439	157331	0	0	1	0	0.1048
5-11	18439	157331	0	0	1	0	0.1048
5-6	18439	157331	0	0	1	0	0.1048
5-7	18439	157331	0	0	1	0	0.1048
5-8	18439	157331	0	0	1	0	0.1048
5-9	18439	157331	0	0	1	0	0.1048
6-10	18359	75007	82324	80	0.9957	0.5232	0.5727
6-11	18358	74133	83198	81	0.9956	0.5288	0.5777
6-7	18357	74084	83247	82	0.9956	0.5291	0.5780
6-8	18439	157331	0	0	1	0	0.1048
6-9	18184	73218	84113	255	0.9861	0.5345	0.5816
7-10	0	0	157331	18439	0	1	0.8951
7-11	18359	74832	82499	80	0.9957	0.5243	0.5737
7-8	18439	157331	0	0	1	0	0.1048
7-9	14763	43888	113443	3676	0.8005	0.7207	0.7294
8-10	18439	157331	0	0	1	0	0.1048
8-11	17863	77545	79786	576	0.9687	0.5071	0.5554

8-9	18439	157331	0	0	1	0	0.1048
8-9	18439	157331	0	0	1	0	0.1048
9-10	17974	68060	89271	465	0.9748	0.5674	0.6100
9-11	17829	67007	90324	610	0.9668	0.5741	0.6152

Tabela B.2 – Resultados com dois descritores - Imagem 2

Descritor	VP	FP	VN	FN	Sensibilidade	Especificidade	Acurácia
0-11	3526	58997	89214	163	0.9557	0.6018	0.6105
0-1	3689	148211	0	0	1	0	2.429E-2
0-2	2411	39744	108467	1278	0.6535	0.7318	0.7298
0-3	3382	61028	87183	307	0.9167	0.5881	0.5961
0-4	445	2006	146205	3244	0.1206	0.9865	0.9654
0-5	3689	148211	0	0	1	0	2.429E-2
0-6	3689	148211	0	0	1	0	2.429E-2
0-7	3292	55765	92446	397	0.8923	0.6237	0.6302
0-8	3689	148211	0	0	1	0	2.429E-2
0-9	3047	54424	93787	642	0.8256	0.6328	0.6374
10-11	3543	59343	88868	146	0.9604	0.5996	0.6084
1-10	3689	148211	0	0	1	0	2.429E-2
1-11	3689	148211	0	0	1	0	2.429E-2
1-2	3689	148211	0	0	1	0	2.429E-2
1-3	3689	148211	0	0	1	0	2.429E-2
1-4	3689	148211	0	0	1	0	2.429E-2
1-5	3324	30785	117426	365	0.9011	0.7923	0.7949
1-6	3689	148211	0	0	1	0	2.429E-2
1-7	3689	148211	0	0	1	0	2.429E-2
1-8	3689	148211	0	0	1	0	2.429E-2
1-9	3263	60539	87672	426	0.8844	0.5915	0.5987
2-10	2110	37862	110349	1579	0.5715	0.7445	0.7402
2-11	2781	43746	104465	908	0.7539	0.7047	0.7056
2-3	3260	60413	87798	429	0.8837	0.5924	0.5995
2-4	684	7938	140273	3005	0.1854	0.9464	0.9285
2-5	3689	148211	0	0	1	0	2.429E-2
2-6	3689	148211	0	0	1	0	2.429E-2
2-7	3689	148211	0	0	1	0	2.429E-2
2-8	3231	58392	89819	458	0.8758	0.6058	0.6126

2-9	3145	57012	91199	544	0.8525	0.6152	0.6210
3-10	3293	60753	87458	396	0.8927	0.5900	0.5974
3-11	3689	148211	0	0	1	0	2.429E-2
3-4	99	70236	77975	3590	2.681E-2	0.5261	0.5141
3-5	3535	61224	86987	154	0.9583	0.5868	0.5958
3-6	3300	60701	87510	389	0.8945	0.5904	0.5978
3-7	3689	148211	0	0	1	0	2.429E-2
3-8	3689	148211	0	0	1	0	2.429E-2
3-9	3689	148211	0	0	1	0	2.429E-2
4-10	410	1762	146449	3279	0.1111	0.9880	0.9667
4-11	420	1951	146260	3269	0.1139	0.9868	0.9656
4-5	3689	148211	0	0	1	0	2.429E-2
4-6	3232	55411	92800	457	0.8760	0.6260	0.6321
4-7	3689	148211	0	0	1	0	2.429E-2
4-8	3212	58299	89912	477	0.8707	0.6066	0.6130
4-9	3157	53465	94746	532	0.8558	0.6392	0.6444
5-10	3689	148211	0	0	1	0	2.429E-2
5-11	3689	148211	0	0	1	0	2.429E-2
5-6	3689	148211	0	0	1	0	2.429E-2
5-7	3689	148211	0	0	1	0	2.429E-2
5-8	3689	148211	0	0	1	0	2.429E-2
5-9	3689	148211	0	0	1	0	2.429E-2
6-0	3689	148211	0	0	1	0	2.429E-2
6-10	3689	148211	0	0	1	0	2.429E-2
6-11	3689	148211	0	0	1	0	2.429E-2
6-7	3689	148211	0	0	1	0	2.429E-2
6-8	3689	148211	0	0	1	0	2.429E-2
6-9	3333	56177	92034	356	0.9034	0.621	0.6278
7-10	3689	148211	0	0	1	0	2.429E-2
7-11	3458	58275	89936	231	0.9374	0.6068	0.6148
7-8	3689	148211	0	0	1	0	2.429E-2
7-9	3275	55611	92600	414	0.8878	0.6248	0.6311
8-10	3217	58146	90065	472	0.8720	0.6077	0.6140
8-11	3208	58010	90201	481	0.8696	0.6086	0.6149
8-9	3689	148211	0	0	1	0	2.429E-2
9-10	3055	54745	93466	634	0.8280	0.6306	0.6353
9-11	2987	53978	94233	702	0.8096	0.6358	0.64

Tabela B.3 – Resultados com dois descritores - Imagem 3

Descritor	VP	FP	VN	FN	Sensibilidade	Especificidade	Acurácia
0-11	10342	89842	78839	257	0.9758	0.4673	0.4974
0-1	10599	168681	0	0	1	0	5.91E-2
0-2	8326	69851	98830	2273	0.7854	0.5858	0.5977
0-3	10312	91801	76880	287	0.9728	0.4557	0.4863
0-4	770	6832	161849	9829	7.258E-2	0.9595	0.9071
0-5	10599	168681	0	0	1	0	5.91E-2
0-6	10342	88037	80644	257	0.9758	0.4781	0.5074
0-7	10259	83868	84813	340	0.9678	0.5028	0.5302
0-8	10599	168681	0	0	1	0	5.91E-2
0-9	9963	82295	86386	636	0.94	0.5121	0.5373
10-11	10342	89444	79237	257	0.9758	0.4697	0.4996
1-10	10599	168681	0	0	1	0	5.91E-2
1-11	10599	168681	0	0	1	0	5.91E-2
1-2	10599	168681	0	0	1	0	5.91E-2
1-3	10599	168681	0	0	1	0	5.91E-2
1-4	10599	168681	0	0	1	0	5.91E-2
1-5	9308	68422	100259	1291	0.8781	0.5944	0.6111
1-6	10599	168681	0	0	1	0	5.91E-2
1-7	10599	168681	0	0	1	0	5.91E-2
1-8	10599	168681	0	0	1	0	5.91E-2
1-9	10599	168681	0	0	1	0	5.91E-2
2-10	7248	68523	100158	3351	0.6837	0.5937	0.5990
2-11	8820	72027	96654	1779	0.8322	0.5725	0.5883
2-3	10130	91022	77659	469	0.9557	0.4603	0.4897
2-4	1533	14078	154603	9066	0.1446	0.9164	0.8709
2-5	10599	168681	0	0	1	0	5.91E-2
2-6	10342	89479	79202	257	0.9758	0.4694	0.4995
2-7	10338	88240	80441	261	0.9754	0.4768	0.5063
2-8	10599	168681	0	0	1	0	5.91E-2
2-9	10131	88174	80507	468	0.9557	0.4773	0.5056
3-10	10192	91255	77426	407	0.9616	0.4592	0.4887
3-11	10599	168681	0	0	1	0	5.91E-2
3-4	0	49731	118950	10599	0	0.7052	0.6634
3-5	10342	92393	76288	257	0.9758	0.4522	0.4832
3-6	10202	91402	77279	397	0.9625	0.4581	0.4879

3-7	10599	168681	0	0	1	0	5.91E-2
3-8	10599	168681	0	0	1	0	5.91E-2
3-9	10599	168681	0	0	1	0	5.91E-2
4-10	725	6047	162634	9874	6.842E-2	0.9641	0.9112
4-11	741	6821	161860	9858	6.994E-2	0.9596	0.9073
4-5	10599	168681	0	0	1	0	5.91E-2
4-6	880	6151	162530	9719	8.304E-2	0.9635	0.9114
4-7	10317	86486	82195	282	0.9734	0.4873	0.5161
4-8	10599	168681	0	0	1	0	5.91E-2
4-9	10146	83298	85383	453	0.9573	0.5061	0.5328
5-10	10599	168681	0	0	1	0	5.91E-2
5-11	10599	168681	0	0	1	0	5.91E-2
5-6	10599	168681	0	0	1	0	5.91E-2
5-7	10599	168681	0	0	1	0	5.91E-2
5-8	10599	168681	0	0	1	0	5.91E-2
5-9	10599	168681	0	0	1	0	5.91E-2
6-10	10342	89559	79122	257	0.9758	0.4691	0.499
6-11	10342	88603	80078	257	0.9758	0.4747	0.5043
6-7	10341	87835	80846	258	0.9757	0.4793	0.5086
6-8	10599	168681	0	0	1	0	5.91E-2
6-9	10310	87756	80925	289	0.9727	0.4798	0.5089
7-10	10341	87961	80720	258	0.9757	0.4784	0.5079
7-11	10342	88988	79693	257	0.9758	0.4723	0.5021
7-8	10599	168681	0	0	1	0	5.91E-2
7-9	10289	86953	81728	310	0.9708	0.4844	0.5132
8-10	10599	168681	0	0	1	0	5.91E-2
8-11	10599	168681	0	0	1	0	5.91E-2
8-9	10599	168681	0	0	1	0	5.91E-2
9-10	9959	82487	86194	640	0.9395	0.5111	0.5363
9-11	9887	81449	87232	712	0.9327	0.5171	0.5416

Tabela B.4 – Resultados com dois descritores - Imagem 4

Descritor	VP	FP	VN	FN	Sensibilidade	Especificidade	Acurácia
0-11	2372	177368	0	0	1	0	1.32E-2
0-1	2372	177368	0	0	1	0	1.32E-2
0-2	2073	58569	118799	299	0.8739	0.6697	0.6724

0-3	2351	77076	100292	21	0.9910	0.5654	0.5711
0-4	0	1668	175700	2372	0	0.9906	0.9775
0-5	2372	177368	0	0	1	0	1.32E-2
0-6	2372	177368	0	0	1	0	1.32E-2
0-7	2351	69223	108145	21	0.9910	0.6097	0.6148
0-8	2372	177368	0	0	1	0	1.32E-2
0-9	2340	68058	109310	32	0.9865	0.6162	0.6211
10-11	2351	74916	102452	21	0.9910	0.5776	0.5830
1-10	2372	177368	0	0	1	0	1.32E-2
1-11	2372	177368	0	0	1	0	1.32E-2
1-2	2372	177368	0	0	1	0	1.32E-2
1-3	2372	177368	0	0	1	0	1.32E-2
1-4	2372	177368	0	0	1	0	1.32E-2
1-5	1864	35012	142356	508	0.7858	0.8025	0.8024
1-6	2372	177368	0	0	1	0	1.32E-2
1-7	2372	177368	0	0	1	0	1.32E-2
1-8	2372	177368	0	0	1	0	1.32E-2
1-9	2372	177368	0	0	1	0	1.32E-2
2-10	1989	57146	120222	383	0.8385	0.6777	0.6798
2-11	2168	63178	114190	204	0.9143	0.6438	0.6473
2-3	2351	76083	101285	21	0.9910	0.5705	0.5766
2-4	310	11055	166313	2062	0.1307	0.9376	0.9275
2-5	2372	177368	0	0	1	0	1.32E-2
2-6	2372	177368	0	0	1	0	1.32E-2
2-7	2372	177368	0	0	1	0	1.32E-2
2-8	2372	177368	0	0	1	0	1.32E-2
2-9	2351	72931	104437	21	0.9910	0.5887	0.5940
3-10	2351	76459	100909	21	0.9910	0.5688	0.5745
3-11	2372	177368	0	0	1	0	1.32E-2
3-4	0	68245	109123	2372	0	0.6151	0.6070
3-5	2351	77790	99578	21	0.9910	0.5614	0.5671
3-6	2351	76513	100855	21	0.9910	0.5685	0.5742
3-7	2372	177368	0	0	1	0	1.32E-2
3-8	2372	177368	0	0	1	0	1.32E-2
3-9	2372	177368	0	0	1	0	1.32E-2
4-10	2351	69238	108130	21	0.9910	0.6096	0.6147
4-11	0	1665	175703	2372	0	0.9906	0.9775

4-5	2372	177368	0	0	1	0	1.32E-2
4-6	2351	68545	108823	21	0.9910	0.6135	0.6185
4-7	2372	177368	0	0	1	0	1.32E-2
4-8	2275	75602	101766	97	0.9590	0.5737	0.5787
4-9	2295	67783	109585	77	0.9675	0.6178	0.6225
5-10	2372	177368	0	0	1	0	1.32E-2
5-11	2372	177368	0	0	1	0	1.32E-2
5-6	2372	177368	0	0	1	0	1.32E-2
5-7	2372	177368	0	0	1	0	1.32E-2
5-8	2372	177368	0	0	1	0	1.32E-2
5-9	2372	177368	0	0	1	0	1.32E-2
6-10	2372	177368	0	0	1	0	1.32E-2
6-11	2372	177368	0	0	1	0	1.32E-2
6-7	2372	177368	0	0	1	0	1.32E-2
6-8	2372	177368	0	0	1	0	1.32E-2
6-9	2340	71839	105529	32	0.9865	0.5947	0.6000
7-10	2372	177368	0	0	1	0	1.32E-2
7-11	2372	177368	0	0	1	0	1.32E-2
7-8	2372	177368	0	0	1	0	1.32E-2
7-9	2322	70639	106729	50	0.9788	0.6017	0.6067
8-10	2372	177368	0	0	1	0	1.32E-2
8-11	2275	75636	101732	97	0.9590	0.5736	0.5786
8-9	2372	177368	0	0	1	0	1.32E-2
9-10	2344	68369	108999	28	0.9881	0.6145	0.6195
9-11	2338	67674	109694	34	0.9857	0.6185	0.6232

Tabela B.5 – Resultados com dois descritores - Imagem 5

Descritor	VP	FP	VN	FN	Sensibilidade	Especificidade	Acurácia
0-11	2345	65921	110489	2223	0.5133	0.6262	0.6235
0-1	4568	176410	0	0	1	0	2.52E-2
0-2	1907	55078	121332	2661	0.4174	0.6877	0.6815
0-3	3331	80690	95720	1237	0.7291	0.5425	0.5473
0-4	800	11229	165181	3768	0.1751	0.9363	0.9171
0-5	4568	176410	0	0	1	0	2.52E-2
0-6	2452	67631	108779	2116	0.5368	0.6166	0.6146
0-7	2101	65753	110657	2467	0.4598	0.6272	0.623

0-8	4568	176410	0	0	1	0	2.52E-2
0-9	535	13476	162934	4033	0.1171	0.9235	0.9032
10-11	2830	71479	104931	1738	0.6195	0.5948	0.5954
1-10	4568	176410	0	0	1	0	2.52E-2
1-11	4568	176410	0	0	1	0	2.52E-2
1-2	4568	176410	0	0	1	0	2.52E-2
1-3	4568	176410	0	0	1	0	2.52E-2
1-4	4568	176410	0	0	1	0	2.52E-2
1-5	4061	55986	120424	507	0.8891	0.6825	0.6877
1-6	4568	176410	0	0	1	0	2.52E-2
1-7	4568	176410	0	0	1	0	2.52E-2
1-8	4568	176410	0	0	1	0	2.52E-2
1-9	4568	176410	0	0	1	0	2.52E-2
2-10	1310	53368	123042	3258	0.2868	0.6975	0.6871
2-11	2983	61555	114855	1585	0.6532	0.6511	0.6511
2-3	2835	79517	96893	1733	0.6206	0.5492	0.5511
2-4	1126	24049	152361	3442	0.2465	0.8637	0.8480
2-5	3230	78934	97476	1338	0.7070	0.5525	0.5564
2-6	2674	69247	107163	1894	0.5854	0.6075	0.6069
2-7	2279	67225	109185	2289	0.4989	0.6189	0.6159
2-8	4568	176410	0	0	1	0	2.52E-2
2-9	839	32592	143818	3729	0.1837	0.8152	0.7993
3-10	2983	79928	96482	1585	0.6532	0.5469	0.5495
3-11	4568	176410	0	0	1	0	2.52E-2
3-4	589	62529	113881	3979	0.1288	0.6454	0.6324
3-5	3940	81939	94471	628	0.8625	0.5354	0.5437
3-6	3111	80360	96050	1457	0.6815	0.5444	0.5479
3-7	4568	176410	0	0	1	0	2.52E-2
3-8	4568	176410	0	0	1	0	2.52E-2
3-9	4568	176410	0	0	1	0	2.52E-2
4-10	751	9540	166870	3817	0.1643	0.9458	0.9262
4-11	812	10364	166046	3756	0.1778	0.9413	0.9224
4-5	4568	176410	0	0	1	0	2.52E-2
4-6	1132	30314	146096	3436	0.2477	0.8282	0.8135
4-7	2422	67540	108870	2146	0.5302	0.6170	0.6149
4-8	4568	176410	0	0	1	0	2.52E-2
4-9	73	2220	174190	4495	1.6E-2	0.9874	0.9628

5-10	3208	78300	98110	1360	0.7023	0.5561	0.5597
5-11	4568	176410	0	0	1	0	2.52E-2
5-6	3724	81451	94959	844	0.8152	0.5383	0.5453
5-7	3635	81203	95207	933	0.7957	0.5396	0.5462
5-8	4568	176410	0	0	1	0	2.52E-2
5-9	3534	80900	95510	1034	0.7735	0.5413	0.5473
6-10	2781	69237	107173	1787	0.6088	0.6075	0.6076
6-11	2508	68063	108347	2060	0.5494	0.6141	0.6125
6-7	2420	67584	108826	2148	0.5298	0.6169	0.6147
6-8	4568	176410	0	0	1	0	2.52E-2
6-9	968	24768	151642	3600	0.2119	0.8596	0.8433
7-10	2562	68117	108293	2006	0.5608	0.6139	0.6125
7-11	2627	68484	107926	1941	0.5750	0.6118	0.6109
7-8	4568	176410	0	0	1	0	2.52E-2
7-9	1009	24872	151538	3559	0.2209	0.8589	0.8428
8-10	4568	176410	0	0	1	0	2.52E-2
8-11	4568	176410	0	0	1	0	2.52E-2
8-9	4568	176410	0	0	1	0	2.52E-2
9-10	501	12456	163954	4067	0.1097	0.9294	0.9086
9-11	452	9613	166797	4116	9.892E-2	0.9455	0.9241

Tabela B.6 – Resultados com dois descritores - Imagem 6

Descritor	VP	FP	VN	FN	Sensibilidade	Especificidade	Acurácia
0-11	3328	75412	94785	181	0.9484	0.5568	0.5647
0-1	3509	170197	0	0	1	0	2.019E-2
0-2	1720	54527	115670	1789	0.4902	0.6795	0.6757
0-3	3362	77921	92276	147	0.9580	0.5422	0.5505
0-4	798	5962	164235	2711	0.2273	0.9647	0.9500
0-5	3509	170197	0	0	1	0	2.019E-2
0-6	3290	74092	96105	219	0.9375	0.5646	0.5722
0-7	3124	70486	99711	385	0.8902	0.5858	0.5917
0-8	3509	170197	0	0	1	0	2.019E-2
0-9	2796	68096	102101	713	0.7967	0.5998	0.6038
10-11	3411	76340	93857	98	0.9720	0.5514	0.5605
1-10	3509	170197	0	0	1	0	2.019E-2
1-11	3509	170197	0	0	1	0	2.019E-2

1-2	3509	170197	0	0	1	0	2.019E-2
1-3	3509	170197	0	0	1	0	2.019E-2
1-4	3509	170197	0	0	1	0	2.019E-2
1-5	3250	53931	116266	259	0.9262	0.6831	0.6874
1-6	3509	170197	0	0	1	0	2.019E-2
1-7	3509	170197	0	0	1	0	2.019E-2
1-8	3509	170197	0	0	1	0	2.019E-2
1-9	3509	170197	0	0	1	0	2.019E-2
2-10	1123	51138	119059	2386	0.32	0.6995	0.6918
2-11	1871	59773	110424	1638	0.5332	0.6488	0.6464
2-3	3250	76334	93863	259	0.9262	0.5514	0.5591
2-4	520	10130	160067	2989	0.1482	0.9405	0.9244
2-5	3509	170197	0	0	1	0	2.019E-2
2-6	3280	74442	95755	229	0.9346	0.5625	0.5701
2-7	3251	73825	96372	258	0.9264	0.5662	0.5735
2-8	3509	170197	0	0	1	0	2.019E-2
2-9	2801	72009	98188	708	0.7982	0.5768	0.5814
3-10	3286	76695	93502	223	0.9364	0.5494	0.5572
3-11	3509	170197	0	0	1	0	2.019E-2
3-4	63	66862	103335	3446	1.799E-2	0.6070	0.5951
3-5	3441	79256	90941	68	0.9806	0.5343	0.5433
3-6	3303	76941	93256	206	0.9413	0.5479	0.5558
3-7	3509	170197	0	0	1	0	2.019E-2
3-8	3509	170197	0	0	1	0	2.019E-2
3-9	3509	170197	0	0	1	0	2.019E-2
4-10	772	5543	164654	2737	0.22	0.9674	0.9523
4-11	753	5916	164281	2756	0.2146	0.9651	0.9500
4-5	3509	170197	0	0	1	0	2.019E-2
4-6	854	5489	164708	2655	0.2434	0.9677	0.9530
4-7	3220	72659	97538	289	0.9175	0.5731	0.5796
4-8	3509	170197	0	0	1	0	2.019E-2
4-9	3002	69202	100995	507	0.8555	0.5934	0.5987
5-10	3509	170197	0	0	1	0	2.019E-2
5-11	3509	170197	0	0	1	0	2.019E-2
5-6	3509	170197	0	0	1	0	2.019E-2
5-7	3509	170197	0	0	1	0	2.019E-2
5-8	3509	170197	0	0	1	0	2.019E-2

5-9	3509	170197	0	0	1	0	2.019E-2
6-10	3305	74592	95605	204	0.9418	0.5616	0.5694
6-11	3291	74016	96181	218	0.9378	0.5651	0.5726
6-7	3287	73934	96263	222	0.9366	0.5655	0.5731
6-8	3509	170197	0	0	1	0	2.019E-2
6-9	3195	73447	96750	314	0.9104	0.5685	0.5754
7-10	3271	73769	96428	238	0.9322	0.5665	0.5735
7-11	3314	74810	95387	195	0.9444	0.5605	0.5682
7-8	3509	170197	0	0	1	0	2.019E-2
7-9	3190	72941	97256	319	0.9091	0.5714	0.5783
8-10	3509	170197	0	0	1	0	2.019E-2
8-11	3509	170197	0	0	1	0	2.019E-2
8-9	3509	170197	0	0	1	0	2.019E-2
9-10	2782	68247	101950	727	0.7927	0.5988	0.6028
9-11	2700	67295	102902	809	0.7693	0.6046	0.6079

Tabela B.7 – Resultados com dois descritores - Imagem 7

Descritor	VP	FP	VN	FN	Sensibilidade	Especificidade	Acurácia
0-11	0	0	137964	10191	0	1	0.9312
0-1	0	0	137964	10191	0	1	0.9312
0-2	8276	43383	94581	1915	0.8121	0.6855	0.6943
0-3	10069	58605	79359	122	0.9879	0.5752	0.6036
0-4	740	1402	136562	9451	7.258E-2	0.9898	0.9266
0-5	0	0	137964	10191	0	1	0.9312
0-6	0	0	137964	10191	0	1	0.9312
0-7	10075	53244	84720	116	0.9886	0.6140	0.6398
0-8	0	0	137964	10191	0	1	0.9312
0-9	9484	51912	86052	707	0.9305	0.6237	0.6448
10-11	10083	56983	80981	108	0.9893	0.5867	0.6147
1-10	0	0	137964	10191	0	1	0.9312
1-11	0	0	137964	10191	0	1	0.9312
1-2	0	0	137964	10191	0	1	0.9312
1-3	0	0	137964	10191	0	1	0.9312
1-4	0	0	137964	10191	0	1	0.9312
1-5	8517	28645	109319	1674	0.8357	0.7923	0.7954
1-6	0	0	137964	10191	0	1	0.9312

1-7	0	0	137964	10191	0	1	0.9312
1-8	0	0	137964	10191	0	1	0.9312
1-9	9676	58093	79871	515	0.9495	0.5788	0.6044
2-10	7685	41222	96742	2506	0.7540	0.7012	0.7047
2-11	8681	47042	90922	1510	0.8518	0.6593	0.6723
2-3	10083	116957	21007	108	0.9893	0.1522	0.2097
2-4	2484	8911	129053	7707	0.2437	0.9354	0.8878
2-5	0	0	137964	10191	0	1	0.9312
2-6	0	0	137964	10191	0	1	0.9312
2-7	0	0	137964	10191	0	1	0.9312
2-8	9424	56942	81022	767	0.9246	0.5873	0.6105
2-9	9810	54678	83286	381	0.9626	0.6037	0.6283
3-10	9864	58059	79905	327	0.9678	0.5792	0.6058
3-11	0	0	137964	10191	0	1	0.9312
3-4	0	57779	80185	10191	0	0.5812	0.5412
3-5	10083	59146	78818	108	0.9893	0.5713	0.6000
3-6	9804	58085	79879	387	0.9617	0.5786	0.6052
3-7	0	0	137964	10191	0	1	0.9312
3-8	0	0	137964	10191	0	1	0.9312
3-9	0	0	137964	10191	0	1	0.9312
4-10	642	1222	136742	9549	6.3E-2	0.9910	0.9273
4-11	685	1331	136633	9506	6.716E-2	0.9903	0.9268
4-5	0	0	137964	10191	0	1	0.9312
4-6	10013	52864	85100	178	0.9825	0.6168	0.6422
4-7	0	0	137964	10191	0	1	0.9312
4-8	9325	56746	81218	866	0.9154	0.5887	0.6110
4-9	9462	51511	86453	729	0.9284	0.6266	0.6473
5-10	0	0	137964	10191	0	1	0.9312
5-11	0	0	137964	10191	0	1	0.9312
5-6	0	0	137964	10191	0	1	0.9312
5-7	0	0	137964	10191	0	1	0.9312
5-8	0	0	137964	10191	0	1	0.9312
5-9	0	0	137964	10191	0	1	0.9312
6-10	0	0	137964	10191	0	1	0.9312
6-11	0	0	137964	10191	0	1	0.9312
6-7	0	0	137964	10191	0	1	0.9312
6-8	0	0	137964	10191	0	1	0.9312

6-9	9850	54090	83874	341	0.9665	0.6079	0.6326
7-10	0	0	137964	10191	0	1	0.9312
7-11	0	0	137964	10191	0	1	0.9312
7-8	0	0	137964	10191	0	1	0.9312
7-9	9694	53162	84802	497	0.9512	0.6147	0.6378
8-10	9319	56742	81222	872	0.9143	0.5887	0.6110
8-11	9282	56592	81372	909	0.9108	0.5897	0.6119
8-9	0	0	137964	10191	0	1	0.9312
9-10	9662	52204	85760	529	0.9481	0.6216	0.6441
9-11	9395	51644	86320	796	0.9219	0.6257	0.6462

Tabela B.8 – Resultados com dois descritores - Imagem 8

Descritor	VP	FP	VN	FN	Sensibilidade	Especificidade	Acurácia
0-11	3997	80588	79451	1096	0.7848	0.4964	0.5052
0-1	5093	160039	0	0	1	0	3.081E-2
0-2	2168	56654	103385	2925	0.4257	0.6462	0.6391
0-3	3473	82274	77765	1620	0.6818	0.4859	0.4919
0-4	1086	4188	155851	4007	0.2132	0.9738	0.9504
0-5	5093	160039	0	0	1	0	3.081E-2
0-5	5093	160039	0	0	1	0	3.081E-2
0-6	3366	78028	82011	1727	0.6609	0.5123	0.5172
0-6	5045	69305	90734	48	0.9906	0.5668	0.5796
0-7	2621	72590	87449	2472	0.5145	0.5464	0.5454
0-8	5093	160039	0	0	1	0	3.081E-2
0-9	1925	70425	89614	3168	0.378	0.5605	0.5543
10-11	4006	79796	80243	1087	0.7865	0.5013	0.5101
1-10	5093	160039	0	0	1	0	3.081E-2
1-11	5093	160039	0	0	1	0	3.081E-2
1-2	5093	160039	0	0	1	0	3.081E-2
1-3	5093	160039	0	0	1	0	3.081E-2
1-4	5093	160039	0	0	1	0	3.081E-2
1-5	4162	51723	108316	931	0.8172	0.6767	0.6811
1-6	5093	160039	0	0	1	0	3.081E-2
1-7	5093	160039	0	0	1	0	3.081E-2
1-8	5093	160039	0	0	1	0	3.081E-2
1-9	5093	160039	0	0	1	0	3.081E-2

2-10	1660	52778	107261	3433	0.3259	0.6702	0.6595
2-11	2703	60538	99501	2390	0.5306	0.6217	0.6189
2-3	2722	80565	79474	2371	0.5344	0.4965	0.4978
2-4	1063	12096	147943	4030	0.2087	0.9244	0.9022
2-5	5093	160039	0	0	1	0	3.081E-2
2-6	3354	78877	81162	1739	0.6585	0.5071	0.5118
2-7	3285	78230	81809	1808	0.6452	0.5111	0.5152
2-8	5093	160039	0	0	1	0	3.081E-2
2-9	2288	75984	84055	2805	0.4491	0.5252	0.5229
3-10	2887	81070	78969	2206	0.5668	0.4934	0.4956
3-11	5093	160039	0	0	1	0	3.081E-2
3-4	933	55449	104590	4160	0.1832	0.6534	0.6391
3-5	4112	83323	76716	981	0.8074	0.4793	0.4894
3-6	2982	81270	78769	2111	0.5855	0.4922	0.4950
3-7	5093	160039	0	0	1	0	3.081E-2
3-8	5093	160039	0	0	1	0	3.081E-2
3-9	5093	160039	0	0	1	0	3.081E-2
4-10	1091	3781	156258	4002	0.2142	0.9764	0.9528
4-11	1046	4132	155907	4047	0.2054	0.9741	0.9505
4-5	5093	160039	0	0	1	0	3.081E-2
4-6	1139	3728	156311	3954	0.2235	0.9767	0.9535
4-7	5093	160039	0	0	1	0	3.081E-2
4-8	3075	81016	79023	2018	0.6038	0.4938	0.4971
4-9	2329	70881	89158	2764	0.4572	0.5571	0.5545
5-10	5093	160039	0	0	1	0	3.081E-2
5-11	5093	160039	0	0	1	0	3.081E-2
5-6	5093	160039	0	0	1	0	3.081E-2
5-7	5093	160039	0	0	1	0	3.081E-2
5-8	5093	160039	0	0	1	0	3.081E-2
5-9	5093	160039	0	0	1	0	3.081E-2
6-10	3459	79033	81006	1634	0.6792	0.5061	0.5114
6-11	3341	77689	82350	1752	0.6563	0.5145	0.5189
6-7	3330	77753	82286	1763	0.6538	0.5141	0.5184
6-8	5093	160039	0	0	1	0	3.081E-2
6-9	2982	76005	84034	2111	0.5855	0.5251	0.5269
7-10	3298	77810	82229	1795	0.6475	0.5138	0.5179
7-11	3529	78912	81127	1564	0.6928	0.5069	0.5127

7-8	5093	160039	0	0	1	0	3.081E-2
7-9	2846	74874	85165	2247	0.5587	0.5322	0.5333
8-10	5093	160039	0	0	1	0	3.081E-2
8-11	3151	81121	78918	1942	0.6187	0.4930	0.497
8-9	5093	160039	0	0	1	0	3.081E-2
9-10	1924	70607	89432	3169	0.3778	0.5587	0.5532
9-11	1799	69837	90202	3294	0.3532	0.5635	0.5571

Tabela B.9 – Resultados com dois descritores - Imagem 9

Descritor	VP	FP	VN	FN	Sensibilidade	Especificidade	Acurácia
0-11	4362	72637	100344	1107	0.7975	0.5800	0.5867
0-1	5469	172981	0	0	1	0	3.059E-2
0-2	2603	51743	121238	2866	0.4758	0.7008	0.6935
0-3	4242	74682	98299	1227	0.7755	0.5683	0.5746
0-4	1075	3527	169454	4394	0.1966	0.9796	0.9556
0-7	3662	65813	107168	1807	0.6695	0.6195	0.6210
0-8	5469	172981	0	0	1	0	3.059E-2
0-9	3029	63938	109043	2440	0.5537	0.6303	0.628
10-11	4562	72373	100608	907	0.8342	0.5816	0.5894
1-10	5469	172981	0	0	1	0	3.059E-2
1-11	5469	172981	0	0	1	0	3.059E-2
1-2	5469	172981	0	0	1	0	3.059E-2
1-3	5469	172981	0	0	1	0	3.059E-2
1-4	5469	172981	0	0	1	0	3.059E-2
1-5	4623	42975	130006	846	0.8453	0.7516	0.7543
1-6	5469	172981	0	0	1	0	3.059E-2
1-7	5469	172981	0	0	1	0	3.059E-2
1-8	5469	172981	0	0	1	0	3.059E-2
1-9	5469	172981	0	0	1	0	3.059E-2
2-10	2115	48126	124855	3354	0.3866	0.7218	0.7115
2-11	3218	56559	116422	2251	0.5884	0.6734	0.6704
2-3	3706	73521	99460	1763	0.6775	0.5746	0.5780
2-4	1094	11432	161549	4375	0.2	0.9338	0.9113
2-5	5469	172981	0	0	1	0	3.059E-2
2-6	4172	70970	102011	1297	0.7628	0.5897	0.5947
2-7	4076	70331	102650	1393	0.7452	0.5934	0.5980

2-8	5469	172981	0	0	1	0	3.059E-2
2-9	3368	68306	104675	2101	0.6158	0.6050	0.6055
3-10	3822	73986	98995	1647	0.6987	0.5723	0.5762
3-11	5469	172981	0	0	1	0	3.059E-2
3-4	768	71646	101335	4701	0.1404	0.5857	0.5722
3-5	4662	75489	97492	807	0.8524	0.5635	0.5725
3-6	3873	74053	98928	1596	0.7082	0.5718	0.5760
3-7	5469	172981	0	0	1	0	3.059E-2
3-8	5469	172981	0	0	1	0	3.059E-2
3-9	5469	172981	0	0	1	0	3.059E-2
4-10	1071	3289	169692	4398	0.1958	0.9808	0.9568
4-11	1053	3415	169566	4416	0.1925	0.9802	0.9560
4-5	5469	172981	0	0	1	0	3.059E-2
4-6	3445	64968	108013	2024	0.6299	0.6243	0.6246
4-7	5469	172981	0	0	1	0	3.059E-2
4-8	3958	73153	99828	1511	0.7237	0.5770	0.5816
4-9	3412	63954	109027	2057	0.6239	0.6302	0.6300
5-10	5469	172981	0	0	1	0	3.059E-2
5-11	5469	172981	0	0	1	0	3.059E-2
5-6	5469	172981	0	0	1	0	3.059E-2
5-7	5469	172981	0	0	1	0	3.059E-2
5-8	5469	172981	0	0	1	0	3.059E-2
5-9	5469	172981	0	0	1	0	3.059E-2
6-10	4221	71159	101822	1248	0.7718	0.5886	0.5941
6-11	4174	70005	102976	1295	0.7631	0.5953	0.6004
6-7	4157	70029	102952	1312	0.7601	0.5951	0.6001
6-8	5469	172981	0	0	1	0	3.059E-2
6-9	3927	68306	104675	1542	0.7177	0.6050	0.6086
7-11	4223	71040	101941	1246	0.7722	0.5893	0.5948
7-8	5469	172981	0	0	1	0	3.059E-2
7-9	3837	67220	105761	1632	0.7016	0.6114	0.6141
8-10	5469	172981	0	0	1	0	3.059E-2
8-11	4001	73232	99749	1468	0.7316	0.5766	0.5814
8-9	5469	172981	0	0	1	0	3.059E-2
9-10	3044	64083	108898	2425	0.5565	0.6294	0.6272
9-11	2909	63392	109589	2560	0.5319	0.6334	0.6303

Tabela B.10 – Resultados com dois descritores - Imagem 10

Descritor	VP	FP	VN	FN	Sensibilidade	Especificidade	Acurácia
0-11	4902	59748	77387	1183	0.8055	0.5643	0.5746
0-1	6085	137135	0	0	1	0	4.253E-2
0-2	3124	44108	93027	2961	0.5133	0.6784	0.6714
0-3	4502	60996	76139	1583	0.7399	0.5552	0.5631
0-4	1113	1907	135228	4972	0.1829	0.9860	0.9516
0-5	6085	137135	0	0	1	0	4.253E-2
0-6	4651	58705	78430	1434	0.7642	0.5718	0.5800
0-7	4032	56521	80614	2053	0.6625	0.5877	0.5907
0-8	6085	137135	0	0	1	0	4.253E-2
0-9	3143	55455	81680	2942	0.5164	0.5956	0.5923
10-11	5130	60226	76909	955	0.8430	0.5607	0.5727
1-10	6085	137135	0	0	1	0	4.253E-2
1-11	6085	137135	0	0	1	0	4.253E-2
1-2	6085	137135	0	0	1	0	4.253E-2
1-3	6085	137135	0	0	1	0	4.253E-2
1-4	6085	137135	0	0	1	0	4.253E-2
1-5	4794	33901	103234	1291	0.7877	0.7528	0.7542
1-6	6085	137135	0	0	1	0	4.253E-2
1-7	6085	137135	0	0	1	0	4.253E-2
1-8	6085	137135	0	0	1	0	4.253E-2
1-9	3935	60647	76488	2150	0.6467	0.5577	0.5615
2-10	3200	40931	96204	2885	0.5259	0.7015	0.6941
2-11	3684	48730	88405	2401	0.6054	0.6447	0.6432
2-3	3499	60139	76996	2586	0.5746	0.5615	0.5626
2-4	1491	7841	129294	4594	0.245	0.9427	0.9132
2-5	6085	137135	0	0	1	0	4.253E-2
2-6	6085	137135	0	0	1	0	4.253E-2
2-7	6085	137135	0	0	1	0	4.253E-2
2-8	4141	59862	77273	1944	0.6804	0.5635	0.5685
2-9	3773	57773	79362	2312	0.62	0.5786	0.5805
3-10	3723	60397	76738	2362	0.6118	0.5595	0.5617
3-11	6085	137135	0	0	1	0	4.253E-2
3-4	874	56747	80388	5211	0.1436	0.5862	0.5674
3-5	5143	61677	75458	942	0.8451	0.5502	0.5627
3-6	3753	60452	76683	2332	0.6168	0.5592	0.5615

3-7	6085	137135	0	0	1	0	4.253E-2
3-8	6085	137135	0	0	1	0	4.253E-2
3-9	6085	137135	0	0	1	0	4.253E-2
4-10	1069	1777	135358	5016	0.1757	0.9869	0.9526
4-11	1069	1874	135261	5016	0.1757	0.9862	0.9518
4-5	6085	137135	0	0	1	0	4.253E-2
4-6	3757	56138	80997	2328	0.6173	0.5906	0.5917
4-7	6085	137135	0	0	1	0	4.253E-2
4-8	3958	59686	77449	2127	0.6504	0.5647	0.5684
4-9	3561	55206	81929	2524	0.5852	0.5974	0.5968
5-10	6085	137135	0	0	1	0	4.253E-2
5-11	6085	137135	0	0	1	0	4.253E-2
5-6	6085	137135	0	0	1	0	4.253E-2
5-7	6085	137135	0	0	1	0	4.253E-2
5-8	6085	137135	0	0	1	0	4.253E-2
5-9	6085	137135	0	0	1	0	4.253E-2
6-10	6085	137135	0	0	1	0	4.253E-2
6-11	6085	137135	0	0	1	0	4.253E-2
6-7	6085	137135	0	0	1	0	4.253E-2
6-8	6085	137135	0	0	1	0	4.253E-2
6-9	4195	57657	79478	1890	0.6894	0.5796	0.5842
7-10	6085	137135	0	0	1	0	4.253E-2
7-10	5644	66249	70886	441	0.9274	0.5169	0.5343
7-11	4745	59085	78050	1340	0.7798	0.5691	0.5780
7-8	6085	137135	0	0	1	0	4.253E-2
7-9	4048	57108	80027	2037	0.6652	0.5836	0.5867
8-10	4079	59662	77473	2006	0.6703	0.5648	0.5694
8-11	4044	59724	77411	2041	0.6645	0.5645	0.5686
8-9	6085	137135	0	0	1	0	4.253E-2
9-10	3195	55510	81625	2890	0.5251	0.5951	0.5921
9-11	2987	55157	81978	3098	0.4909	0.5978	0.5931

Tabela B.11 – Resultados com dois descritores - Imagem 11

Descritor	VP	FP	VN	Fn	Sensibilidade	Especificidade	Acurácia
0-10	0	0	172800	0	0	1	1
0-10	0	0	172800	0	0	1	1

0-11	0	87662	85138	0	0	0.4927	0.4927
0-1	0	93325	79475	0	0	0.4598	0.4598
0-2	0	52703	120097	0	0	0.6945	0.6945
0-3	0	94349	78451	0	0	0.4541	0.4541
0-4	0	77990	94810	0	0	0.5486	0.5486
0-5	0	92644	80156	0	0	0.4638	0.4638
0-6	0	0	172800	0	0	1	1
0-7	0	0	172800	0	0	1	1
0-8	0	94321	78479	0	0	0.4541	0.4541
0-9	0	7281	165519	0	0	0.9578	0.9578
10-11	0	84918	87882	0	0	0.5086	0.5086
1-10	0	94403	78397	0	0	0.4536	0.4536
1-11	0	93597	79203	0	0	0.4583	0.4583
1-2	0	93297	79503	0	0	0.4601	0.4601
1-3	0	93408	79392	0	0	0.4593	0.4593
1-4	0	93154	79646	0	0	0.4608	0.4608
1-5	0	79286	93514	0	0	0.5412	0.5412
1-6	0	93664	79136	0	0	0.4582	0.4582
1-7	0	93933	78867	0	0	0.4563	0.4563
1-8	0	94349	78451	0	0	0.4541	0.4541
1-9	0	93095	79705	0	0	0.4612	0.4612
2-10	0	89175	83625	0	0	0.4839	0.4839
2-11	0	132334	40466	0	0	0.2341	0.2341
2-3	0	93697	79103	0	0	0.4577	0.4577
2-4	0	51914	120886	0	0	0.6996	0.6996
2-5	0	0	172800	0	0	1	1
2-6	0	0	172800	0	0	1	1
2-7	0	83483	89317	0	0	0.5169	0.5169
2-8	0	93936	78864	0	0	0.4563	0.4563
2-9	0	6036	166764	0	0	0.9650	0.9650
3-10	0	92958	79842	0	0	0.4622	0.4622
3-11	0	93074	79726	0	0	0.4613	0.4613
3-4	0	91617	81183	0	0	0.4698	0.4698
3-5	0	0	172800	0	0	1	1
3-6	0	92941	79859	0	0	0.4621	0.4621
3-7	0	92871	79929	0	0	0.4626	0.4626
3-8	0	83403	89397	0	0	0.5172	0.5172

3-9	0	92185	80615	0	0	0.4665	0.4665
4-10	0	75195	97605	0	0	0.5647	0.5647
4-11	0	79341	93459	0	0	0.5409	0.5409
4-5	0	83782	89018	0	0	0.5151	0.5151
4-6	0	0	172800	0	0	1	1
4-7	0	80956	91844	0	0	0.5314	0.5314
4-8	0	94012	78788	0	0	0.4559	0.4559
4-9	0	28424	144376	0	0	0.8355	0.8355
5-10	0	80405	92395	0	0	0.5346	0.5346
5-11	0	54220	118580	0	0	0.6862	0.6862
5-6	0	0	172800	0	0	1	1
5-7	0	53485	119315	0	0	0.6905	0.6905
5-8	0	93279	79521	0	0	0.4602	0.4602
5-9	0	55949	116851	0	0	0.6762	0.6762
6-10	0	0	172800	0	0	1	1
6-11	0	74257	98543	0	0	0.5703	0.5703
6-7	0	0	172800	0	0	1	1
6-8	0	93861	78939	0	0	0.4567	0.4567
6-9	0	7749	165051	0	0	0.9552	0.9552
7-10	0	0	172800	0	0	1	1
7-11	0	0	172800	0	0	1	1
7-8	0	93383	79417	0	0	0.4596	0.4596
7-9	0	9009	163791	0	0	0.9478	0.9478
8-10	0	93861	78939	0	0	0.4567	0.4567
8-11	0	93853	78947	0	0	0.4568	0.4568
9-10	0	5975	166825	0	0	0.9654	0.9654
9-11	0	7189	165611	0	0	0.9584	0.9584

Tabela B.12 – Resultados com dois descritores - Imagem 12

Descritor	VP	FP	VN	FN	Sensibilidade	Especificidade	Acurácia
0-10	0	0	184900	0	0	1	1
0-11	0	0	184900	0	0	1	1
0-1	0	75423	109477	0	0	0.5920	0.5920
0-2	0	10944	173956	0	0	0.9407	0.9407
0-3	0	75512	109388	0	0	0.5916	0.5916
0-4	0	66601	118299	0	0	0.6398	0.6398

0-5	0	153004	31896	0	0	0.1724	0.1724
0-6	0	0	184900	0	0	1	1
0-7	0	0	184900	0	0	1	1
0-8	0	0	184900	0	0	1	1
0-9	0	73777	111123	0	0	0.6008	0.6008
10-11	0	0	184900	0	0	1	1
1-10	0	75412	109488	0	0	0.5920	0.5920
1-11	0	75428	109472	0	0	0.5920	0.5920
1-2	0	75413	109487	0	0	0.5920	0.5920
1-3	0	70897	114003	0	0	0.6166	0.6166
1-4	0	75431	109469	0	0	0.5917	0.5917
1-5	0	0	184900	0	0	1	1
1-6	0	75487	109413	0	0	0.5917	0.5917
1-7	0	75493	109407	0	0	0.5917	0.5917
1-8	0	68282	116618	0	0	0.6307	0.6307
1-9	0	75478	109422	0	0	0.5917	0.5917
2-10	0	15078	169822	0	0	0.9184	0.9184
2-11	0	145627	39273	0	0	0.2124	0.2124
2-3	0	75005	109895	0	0	0.5943	0.5943
2-4	0	5788	179112	0	0	0.9687	0.9687
2-5	0	0	184900	0	0	1	1
2-6	0	10360	174540	0	0	0.9435	0.9435
2-7	0	5738	179162	0	0	0.9687	0.9687
2-8	0	75434	109466	0	0	0.5917	0.5917
2-9	0	72872	112028	0	0	0.6058	0.6058
3-10	0	0	184900	0	0	1	1
3-11	0	0	184900	0	0	1	1
3-4	0	75236	109664	0	0	0.5930	0.5930
3-5	0	75187	109713	0	0	0.5934	0.5934
3-6	0	75309	109591	0	0	0.5927	0.5927
3-7	0	75029	109871	0	0	0.5941	0.5941
3-8	0	66905	117995	0	0	0.6381	0.6381
3-9	0	75051	109849	0	0	0.5940	0.5940
4-10	0	67280	117620	0	0	0.6361	0.6361
4-11	0	66659	118241	0	0	0.6394	0.6394
4-5	0	78196	106704	0	0	0.5770	0.5770
4-6	0	0	184900	0	0	1	1

4-7	0	73515	111385	0	0	0.6024	0.6024
4-8	0	0	184900	0	0	1	1
4-9	0	51284	133616	0	0	0.7226	0.7226
5-10	0	0	184900	0	0	1	1
5-11	0	78105	106795	0	0	0.5776	0.5776
5-6	0	153047	31853	0	0	0.1723	0.1723
5-7	0	70018	114882	0	0	0.6212	0.6212
5-8	0	75531	109369	0	0	0.5915	0.5915
5-9	0	0	184900	0	0	1	1
6-10	0	2917	181983	0	0	0.9841	0.9841
6-11	0	3548	181352	0	0	0.9808	0.9808
6-7	0	0	184900	0	0	1	1
6-8	0	0	184900	0	0	1	1
6-9	0	67645	117255	0	0	0.6341	0.6341
7-10	0	74283	110617	0	0	0.5983	0.5983
7-11	0	73940	110960	0	0	0.6000	0.6000
7-8	0	0	184900	0	0	1	1
7-9	0	0	184900	0	0	1	1
8-10	0	0	184900	0	0	1	1
8-11	0	0	184900	0	0	1	1
8-9	0	0	184900	0	0	1	1
9-10	0	58265	126635	0	0	0.6848	0.6848
9-11	0	54739	130161	0	0	0.7036	0.7036

Tabela B.13 – Resultados com dois descritores - Imagem 13

Descritor	VP	FP	VN	FN	Sensibilidade	Especificidade	Acurácia
0-10	0	61561	115127	0	0	0.6515	0.6515
0-11	0	63287	113401	0	0	0.6418	0.6418
0-1	0	0	176688	0	0	1	1
0-2	0	52169	124519	0	0	0.7046	0.7046
0-3	0	77007	99681	0	0	0.5642	0.5642
0-4	0	66622	110066	0	0	0.6229	0.6229
0-5	0	144174	32514	0	0	0.184	0.184
0-6	0	56912	119776	0	0	0.6778	0.6778
0-7	0	55732	120956	0	0	0.6845	0.6845
0-8	0	74873	101815	0	0	0.5762	0.5762

0-9	0	66187	110501	0	0	0.6253	0.6253
10-11	0	0	176688	0	0	1	1
1-10	0	71188	105500	0	0	0.5970	0.5970
1-11	0	71145	105543	0	0	0.5973	0.5973
1-2	0	70684	106004	0	0	0.6	0.6
1-3	0	71346	105342	0	0	0.5961	0.5961
1-4	0	76780	99908	0	0	0.5654	0.5654
1-5	0	133781	42907	0	0	0.2427	0.2427
1-6	0	68048	108640	0	0	0.6149	0.6149
1-7	0	71273	105415	0	0	0.5966	0.5966
1-8	0	71224	105464	0	0	0.5968	0.5968
1-9	0	69758	106930	0	0	0.6051	0.6051
2-10	0	67289	109399	0	0	0.6191	0.6191
2-11	0	67288	109400	0	0	0.6191	0.6191
2-3	0	67328	109360	0	0	0.6189	0.6189
2-4	0	59740	116948	0	0	0.6619	0.6619
2-5	0	67288	109400	0	0	0.6191	0.6191
2-6	0	110666	66022	0	0	0.3736	0.3736
2-7	0	123398	53290	0	0	0.3015	0.3015
2-8	0	71271	105417	0	0	0.5966	0.5966
2-9	0	67288	109400	0	0	0.6191	0.6191
3-10	0	71195	105493	0	0	0.5970	0.5970
3-11	0	71323	105365	0	0	0.5963	0.5963
3-4	0	71320	105368	0	0	0.5964	0.5964
3-5	0	71236	105452	0	0	0.5968	0.5968
3-6	0	71419	105269	0	0	0.5958	0.5958
3-7	0	71402	105286	0	0	0.5958	0.5958
3-8	0	71201	105487	0	0	0.5968	0.5968
3-9	0	71216	105472	0	0	0.5968	0.5968
4-10	0	62507	114181	0	0	0.6462	0.6462
4-11	0	65238	111450	0	0	0.6308	0.6308
4-5	0	0	176688	0	0	1	1
4-6	0	61601	115087	0	0	0.6513	0.6513
4-7	0	66428	110260	0	0	0.624	0.624
4-8	0	72324	104364	0	0	0.5907	0.5907
4-9	0	61945	114743	0	0	0.6493	0.6493
5-10	0	70676	106012	0	0	0.6	0.6

5-11	0	71148	105540	0	0	0.5973	0.5973
5-6	0	70901	105787	0	0	0.5987	0.5987
5-7	0	71120	105568	0	0	0.5975	0.5975
5-8	0	68043	108645	0	0	0.6149	0.6149
5-9	0	71095	105593	0	0	0.5976	0.5976
6-10	0	121783	54905	0	0	0.3106	0.3106
6-11	0	119837	56851	0	0	0.3217	0.3217
6-7	0	74768	101920	0	0	0.5767	0.5767
6-8	0	71148	105540	0	0	0.5973	0.5973
6-9	0	98954	77734	0	0	0.44	0.44
7-10	0	79300	97388	0	0	0.5512	0.5512
7-11	0	68047	108641	0	0	0.6149	0.6149
7-8	0	70152	106536	0	0	0.6028	0.6028
7-9	0	96102	80586	0	0	0.4561	0.4561
8-10	0	71185	105503	0	0	0.5970	0.5970
8-11	0	71188	105500	0	0	0.5970	0.5970
8-9	0	71258	105430	0	0	0.5967	0.5967
9-10	0	68770	107918	0	0	0.6108	0.6108
9-11	0	67861	108827	0	0	0.6159	0.6159

Tabela B.14 – Resultados com dois descritores - Imagem 15

Descritor	VP	FP	VN	FN	Sensibilidade	Especificidade	Acurácia
0-10	0	3412	157168	0	0	0.9788	0.9788
0-11	0	0	160580	0	0	1	1
0-1	0	66871	93709	0	0	0.5836	0.5836
0-2	0	7355	153225	0	0	0.9542	0.9542
0-3	0	67135	93445	0	0	0.5818	0.5818
0-4	0	1273	159307	0	0	0.9920	0.9920
0-5	0	0	160580	0	0	1	1
0-6	0	1438	159142	0	0	0.9909	0.9909
0-7	0	1212	159368	0	0	0.9925	0.9925
0-8	0	67766	92814	0	0	0.5776	0.5776
0-9	0	49619	110961	0	0	0.6905	0.6905
10-11	0	0	160580	0	0	1	1
1-10	0	62344	98236	0	0	0.6118	0.6118
1-11	0	64277	96303	0	0	0.5997	0.5997

1-2	0	61764	98816	0	0	0.6153	0.6153
1-3	0	64376	96204	0	0	0.5990	0.5990
1-4	0	67769	92811	0	0	0.5776	0.5776
1-5	0	62341	98239	0	0	0.6118	0.6118
1-6	0	62341	98239	0	0	0.6118	0.6118
1-7	0	62330	98250	0	0	0.6118	0.6118
1-8	0	62378	98202	0	0	0.6115	0.6115
1-9	0	62357	98223	0	0	0.6117	0.6117
2-10	0	4953	155627	0	0	0.9691	0.9691
2-11	0	0	160580	0	0	1	1
2-3	0	61716	98864	0	0	0.6157	0.6157
2-4	0	2812	157768	0	0	0.9825	0.9825
2-5	0	61716	98864	0	0	0.6157	0.6157
2-6	0	66010	94570	0	0	0.5888	0.5888
2-7	0	65477	95103	0	0	0.5921	0.5921
2-8	0	61764	98816	0	0	0.6153	0.6153
2-9	0	66319	94261	0	0	0.5867	0.5867
3-10	0	62369	98211	0	0	0.6116	0.6116
3-11	0	0	160580	0	0	1	1
3-4	0	67222	93358	0	0	0.5814	0.5814
3-5	0	62373	98207	0	0	0.6116	0.6116
3-6	0	62341	98239	0	0	0.6118	0.6118
3-7	0	61707	98873	0	0	0.6157	0.6157
3-8	0	131981	28599	0	0	0.1781	0.1781
3-9	0	62330	98250	0	0	0.6118	0.6118
4-10	0	59889	100691	0	0	0.627	0.627
4-11	0	1683	158897	0	0	0.9895	0.9895
4-5	0	67189	93391	0	0	0.5816	0.5816
4-6	0	60293	100287	0	0	0.6245	0.6245
4-7	0	51515	109065	0	0	0.6792	0.6792
4-8	0	67488	93092	0	0	0.5796	0.5796
4-9	0	16817	143763	0	0	0.8952	0.8952
5-10	0	62330	98250	0	0	0.6118	0.6118
5-11	0	64777	95803	0	0	0.5966	0.5966
5-6	0	62330	98250	0	0	0.6118	0.6118
5-7	0	62330	98250	0	0	0.6118	0.6118
5-8	0	62341	98239	0	0	0.6118	0.6118

5-9	0	62341	98239	0	0	0.6118	0.6118
6-10	0	89573	71007	0	0	0.4421	0.4421
6-11	0	1510	159070	0	0	0.9906	0.9906
6-7	0	63714	96866	0	0	0.6031	0.6031
6-8	0	62341	98239	0	0	0.6118	0.6118
6-9	0	7294	153286	0	0	0.9546	0.9546
7-10	0	64075	96505	0	0	0.6008	0.6008
7-11	0	1704	158876	0	0	0.9893	0.9893
7-8	0	61700	98880	0	0	0.6158	0.6158
7-9	0	106322	54258	0	0	0.3378	0.3378
8-10	0	62385	98195	0	0	0.6115	0.6115
8-11	0	64701	95879	0	0	0.5970	0.5970
8-9	0	62369	98211	0	0	0.6116	0.6116
9-10	0	79197	81383	0	0	0.5068	0.5068

Tabela B.15 – Resultados com dois descritores - Imagem 16

Descritor	VP	FP	VN	FN	Sensibilidade	Especificidade	Acurácia
0-10	0	64417	96163	0	0	0.5988	0.5988
0-11	0	68711	91869	0	0	0.5721	0.5721
0-1	0	0	160580	0	0	1	1
0-2	0	64424	96156	0	0	0.5988	0.5988
0-3	0	0	160580	0	0	1	1
0-4	0	64475	96105	0	0	0.5985	0.5985
0-5	0	71475	89105	0	0	0.5548	0.5548
0-6	0	25328	135252	0	0	0.8423	0.8423
0-7	0	51771	108809	0	0	0.6775	0.6775
0-8	0	72388	88192	0	0	0.5492	0.5492
0-9	0	26662	133918	0	0	0.8336	0.8336
10-11	0	67484	93096	0	0	0.5796	0.5796
1-10	0	0	160580	0	0	1	1
1-11	0	72170	88410	0	0	0.5505	0.5505
1-2	0	0	160580	0	0	1	1
1-3	0	0	160580	0	0	1	1
1-4	0	0	160580	0	0	1	1
1-5	0	0	160580	0	0	1	1
1-6	0	72116	88464	0	0	0.5508	0.5508

1-7	0	72172	88408	0	0	0.5505	0.5505
1-8	0	72354	88226	0	0	0.5494	0.5494
1-9	0	0	160580	0	0	1	1
2-10	0	13032	147548	0	0	0.9187	0.9187
2-11	0	126380	34200	0	0	0.2129	0.2129
2-3	0	72319	88261	0	0	0.5495	0.5495
2-4	0	64527	96053	0	0	0.5981	0.5981
2-5	0	70656	89924	0	0	0.5605	0.5605
2-6	0	26132	134448	0	0	0.8373	0.8373
2-7	0	25250	135330	0	0	0.8427	0.8427
2-8	0	72418	88162	0	0	0.5494	0.5494
2-9	0	32722	127858	0	0	0.7962	0.7962
3-10	0	72065	88515	0	0	0.5512	0.5512
3-11	0	72131	88449	0	0	0.5507	0.5507
3-4	0	0	160580	0	0	1	1
3-5	0	0	160580	0	0	1	1
3-6	0	0	160580	0	0	1	1
3-7	0	72261	88319	0	0	0.5504	0.5504
3-8	0	72319	88261	0	0	0.5495	0.5495
3-9	0	72019	88561	0	0	0.5514	0.5514
4-10	0	67862	92718	0	0	0.5774	0.5774
4-11	0	68258	92322	0	0	0.5748	0.5748
4-5	0	69850	90730	0	0	0.5645	0.5645
4-6	0	25985	134595	0	0	0.8381	0.8381
4-7	0	21476	139104	0	0	0.8662	0.8662
4-8	0	0	160580	0	0	1	1
4-9	0	22465	138115	0	0	0.8600	0.8600
5-10	0	71189	89391	0	0	0.5566	0.5566
5-11	0	71275	89305	0	0	0.5561	0.5561
5-6	0	0	160580	0	0	1	1
5-7	0	71158	89422	0	0	0.5568	0.5568
5-8	0	0	160580	0	0	1	1
5-9	0	70967	89613	0	0	0.5581	0.5581
6-10	0	25757	134823	0	0	0.8396	0.8396
6-11	0	24811	135769	0	0	0.8455	0.8455
6-7	0	28798	131782	0	0	0.8206	0.8206
6-8	0	72320	88260	0	0	0.5495	0.5495

6-9	0	15934	144646	0	0	0.9008	0.9008
7-10	0	36373	124207	0	0	0.7734	0.7734
7-11	0	43974	116606	0	0	0.7261	0.7261
7-8	0	72427	88153	0	0	0.5494	0.5494
7-9	0	35951	124629	0	0	0.7761	0.7761
8-10	0	0	160580	0	0	1	1
8-11	0	72254	88326	0	0	0.5504	0.5504
8-9	0	72321	88259	0	0	0.5495	0.5495
9-10	0	27446	133134	0	0	0.8290	0.8290
9-11	0	25362	135218	0	0	0.8420	0.8420

Tabela B.16 – Resultados com dois descritores - Imagem 17

Descritor	VP	FP	VN	FN	Sensibilidade	Especificidade	Acurácia
0-10	0	74812	83813	0	0	0.5283	0.5283
0-11	0	75404	83221	0	0	0.5245	0.5245
0-1	0	0	158625	0	0	1	1
0-2	0	76509	82116	0	0	0.5177	0.5177
0-3	0	85239	73386	0	0	0.4626	0.4626
0-4	0	69342	89283	0	0	0.5628	0.5628
0-5	0	0	158625	0	0	1	1
0-6	0	80460	78165	0	0	0.4928	0.4928
0-7	0	75710	82915	0	0	0.5227	0.5227
0-8	0	0	158625	0	0	1	1
0-9	0	78225	80400	0	0	0.5069	0.5069
10-11	0	0	158625	0	0	1	1
1-10	0	0	158625	0	0	1	1
1-11	0	0	158625	0	0	1	1
1-2	0	0	158625	0	0	1	1
1-3	0	85233	73392	0	0	0.4627	0.4627
1-4	0	0	158625	0	0	1	1
1-5	0	85239	73386	0	0	0.4626	0.4626
1-6	0	85239	73386	0	0	0.4626	0.4626
1-7	0	85232	73393	0	0	0.4627	0.4627
1-8	0	85290	73335	0	0	0.4622	0.4622
1-9	0	0	158625	0	0	1	1
2-10	0	77665	80960	0	0	0.5103	0.5103

2-11	0	123090	35535	0	0	0.224	0.224
2-3	0	85125	73500	0	0	0.4633	0.4633
2-4	0	76596	82029	0	0	0.5171	0.5171
2-5	0	0	158625	0	0	1	1
2-6	0	76176	82449	0	0	0.5198	0.5198
2-7	0	68837	89788	0	0	0.5655	0.5655
2-8	0	85216	73409	0	0	0.4627	0.4627
2-9	0	82694	75931	0	0	0.4787	0.4787
3-10	0	85067	73558	0	0	0.4637	0.4637
3-11	0	85156	73469	0	0	0.4632	0.4632
3-4	0	85296	73329	0	0	0.4622	0.4622
3-5	0	85231	73394	0	0	0.4627	0.4627
3-6	0	83581	75044	0	0	0.4731	0.4731
3-7	0	85319	73306	0	0	0.4621	0.4621
3-8	0	0	158625	0	0	1	1
3-9	0	85031	73594	0	0	0.4638	0.4638
4-10	0	75354	83271	0	0	0.5252	0.5252
4-11	0	77291	81334	0	0	0.5127	0.5127
4-5	0	134039	24586	0	0	0.155	0.155
4-6	0	0	158625	0	0	1	1
4-7	0	75920	82705	0	0	0.5213	0.5213
4-8	0	0	158625	0	0	1	1
4-9	0	9932	148693	0	0	0.9374	0.9374
5-11	0	0	158625	0	0	1	1
5-6	0	49402	109223	0	0	0.6885	0.6885
5-7	0	73863	84762	0	0	0.5343	0.5343
5-8	0	0	158625	0	0	1	1
5-9	0	84186	74439	0	0	0.4692	0.4692
6-10	0	75791	82834	0	0	0.5222	0.5222
6-11	0	0	158625	0	0	1	1
6-7	0	79893	78732	0	0	0.4963	0.4963
6-8	0	84934	73691	0	0	0.4646	0.4646
6-9	0	68432	90193	0	0	0.5685	0.5685
7-10	0	68764	89861	0	0	0.5665	0.5665
7-11	0	0	158625	0	0	1	1
7-8	0	0	158625	0	0	1	1
7-9	0	68835	89790	0	0	0.5661	0.5661

8-10	0	85219	73406	0	0	0.4627	0.4627
8-11	0	85160	73465	0	0	0.4631	0.4631
8-9	0	0	158625	0	0	1	1
9-10	0	0	158625	0	0	1	1

Tabela B.17 – Resultados com dois descritores - Imagem 19

Descritor	VP	FP	VN	FN	Sensibilidade	Especificidade	Acurácia
0-10	0	65951	90504	0	0	0.5785	0.5785
0-11	0	65597	90858	0	0	0.5806	0.5806
0-1	0	156455	0	0	0	0	0
0-2	0	57754	98701	0	0	0.6309	0.6309
0-3	0	72676	83779	0	0	0.5354	0.5354
0-4	0	10801	145654	0	0	0.9315	0.9315
0-5	0	156455	0	0	0	0	0
0-6	0	65739	90716	0	0	0.5797	0.5797
0-7	0	65410	91045	0	0	0.5818	0.5818
0-8	0	156455	0	0	0	0	0
0-9	0	10523	145932	0	0	0.9326	0.9326
10-11	0	156455	0	0	0	0	0
1-10	0	156455	0	0	0	0	0
1-11	0	156455	0	0	0	0	0
1-2	0	156455	0	0	0	0	0
1-3	0	156455	0	0	0	0	0
1-4	0	156455	0	0	0	0	0
1-5	0	51825	104630	0	0	0.6687	0.6687
1-6	0	156455	0	0	0	0	0
1-7	0	156455	0	0	0	0	0
1-8	0	156455	0	0	0	0	0
1-9	0	156455	0	0	0	0	0
2-10	0	52479	103976	0	0	0.6645	0.6645
2-11	0	60992	95463	0	0	0.6101	0.6101
2-3	0	71894	84561	0	0	0.5404	0.5404
2-4	0	24596	131859	0	0	0.8427	0.8427
2-5	0	156455	0	0	0	0	0
2-6	0	66019	90436	0	0	0.5776	0.5776
2-7	0	65613	90842	0	0	0.5806	0.5806

2-8	0	156455	0	0	0	0	0
2-9	0	27066	129389	0	0	0.8266	0.8266
3-10	0	72151	84304	0	0	0.5387	0.5387
3-11	0	156455	0	0	0	0	0
3-4	0	68302	88153	0	0	0.5634	0.5634
3-5	0	73396	83059	0	0	0.5309	0.5309
3-6	0	72430	84025	0	0	0.5371	0.5371
3-7	0	156455	0	0	0	0	0
3-8	0	156455	0	0	0	0	0
3-9	0	156455	0	0	0	0	0
4-10	0	9223	147232	0	0	0.9411	0.9411
4-11	0	9633	146822	0	0	0.9384	0.9384
4-5	0	156455	0	0	0	0	0
4-6	0	31288	125167	0	0	0.8	0.8
4-7	0	156455	0	0	0	0	0
4-8	0	156455	0	0	0	0	0
4-9	0	5794	150661	0	0	0.9627	0.9627
5-10	0	156455	0	0	0	0	0
5-11	0	156455	0	0	0	0	0
5-6	0	73087	83368	0	0	0.5329	0.5329
5-7	0	72947	83508	0	0	0.5338	0.5338
5-8	0	156455	0	0	0	0	0
5-9	0	72755	83700	0	0	0.5353	0.5353
6-10	0	66073	90382	0	0	0.5776	0.5776
6-11	0	65787	90668	0	0	0.5795	0.5795
6-7	0	65717	90738	0	0	0.5796	0.5796
6-8	0	156455	0	0	0	0	0
6-9	0	18596	137859	0	0	0.8810	0.8810
7-10	0	65902	90553	0	0	0.5787	0.5787
7-11	0	65890	90565	0	0	0.5788	0.5788
7-8	0	156455	0	0	0	0	0
7-9	0	16962	139493	0	0	0.8915	0.8915
8-10	0	156455	0	0	0	0	0
8-11	0	156455	0	0	0	0	0
8-9	0	156455	0	0	0	0	0
9-10	0	8813	147642	0	0	0.9436	0.9436

Tabela B.18 – Resultados com dois descritores - imagem 21

Descritor	VP	FP	VN	FN	Sensibilidade	Especificidade	Acurácia
0-11	0	70855	81962	0	0	0.5363	0.5363
0-1	0	152817	0	0	0	0	0
0-2	0	62776	90041	0	0	0.5891	0.5891
0-3	0	80394	72423	0	0	0.4738	0.4738
0-4	0	9652	143165	0	0	0.9367	0.9367
0-5	0	152817	0	0	0	0	0
0-6	0	71986	80831	0	0	0.5289	0.5289
0-7	0	70498	82319	0	0	0.5386	0.5386
0-8	0	152817	0	0	0	0	0
0-9	0	16259	136558	0	0	0.8935	0.8935
10-11	0	74705	78112	0	0	0.5111	0.5111
1-10	0	152817	0	0	0	0	0
1-11	0	152817	0	0	0	0	0
1-2	0	152817	0	0	0	0	0
1-3	0	152817	0	0	0	0	0
1-4	0	152817	0	0	0	0	0
1-5	0	61366	91451	0	0	0.5984	0.5984
1-6	0	152817	0	0	0	0	0
1-7	0	152817	0	0	0	0	0
1-8	0	152817	0	0	0	0	0
1-9	0	152817	0	0	0	0	0
2-10	0	62652	90165	0	0	0.59	0.59
2-11	0	66763	86054	0	0	0.5631	0.5631
2-3	0	80003	72814	0	0	0.4764	0.4764
2-4	0	29934	122883	0	0	0.8041	0.8041
2-5	0	152817	0	0	0	0	0
2-6	0	73805	79012	0	0	0.5172	0.5172
2-7	0	71923	80894	0	0	0.5293	0.5293
2-8	0	152817	0	0	0	0	0
2-9	0	41008	111809	0	0	0.7317	0.7317
3-10	0	80177	72640	0	0	0.4753	0.4753
3-11	0	152817	0	0	0	0	0
3-4	0	46132	106685	0	0	0.6981	0.6981
3-5	0	80693	72124	0	0	0.4718	0.4718
3-6	0	80312	72505	0	0	0.4744	0.4744

3-7	0	152817	0	0	0	0	0
3-8	0	152817	0	0	0	0	0
3-9	0	152817	0	0	0	0	0
4-10	0	8596	144221	0	0	0.9436	0.9436
4-11	0	8961	143856	0	0	0.9414	0.9414
4-5	0	152817	0	0	0	0	0
4-6	0	30370	122447	0	0	0.8013	0.8013
4-7	0	152817	0	0	0	0	0
4-8	0	152817	0	0	0	0	0
4-9	0	9242	143575	0	0	0.9395	0.9395
5-10	0	152817	0	0	0	0	0
5-11	0	152817	0	0	0	0	0
5-6	0	152817	0	0	0	0	0
5-7	0	152817	0	0	0	0	0
5-8	0	152817	0	0	0	0	0
5-9	0	152817	0	0	0	0	0
6-10	0	73722	79095	0	0	0.5175	0.5175
6-11	0	72394	80423	0	0	0.5262	0.5262
6-7	0	72045	80772	0	0	0.5285	0.5285
6-8	0	152817	0	0	0	0	0
6-9	0	29506	123311	0	0	0.8068	0.8068
7-10	0	72787	80030	0	0	0.5237	0.5237
7-11	0	72729	80088	0	0	0.5241	0.5241
7-8	0	152817	0	0	0	0	0
7-9	0	28051	124766	0	0	0.8164	0.8164
8-10	0	152817	0	0	0	0	0
8-11	0	152817	0	0	0	0	0
8-9	0	152817	0	0	0	0	0
9-10	0	15901	136916	0	0	0.8959	0.8959
9-11	0	11810	141007	0	0	0.9226	0.9226

Tabela B.19 – Resultados com dois descritores - Imagem 22

Descritor	VP	FP	VN	FN	Sensibilidade	Especificidade	Acurácia
0-10	0	67916	99455	0	0	0.5941	0.5941
0-11	0	67813	99558	0	0	0.5948	0.5948
0-1	0	167371	0	0	0	0	0

0-2	0	56137	111234	0	0	0.6645	0.6645
0-3	0	74862	92509	0	0	0.5526	0.5526
0-4	0	34578	132793	0	0	0.7933	0.7933
0-5	0	167371	0	0	0	0	0
0-6	0	67864	99507	0	0	0.5945	0.5945
0-7	0	67809	99562	0	0	0.5948	0.5948
0-8	0	167371	0	0	0	0	0
0-9	0	1175	166196	0	0	0.9929	0.9929
10-11	0	67920	99451	0	0	0.5941	0.5941
1-10	0	167371	0	0	0	0	0
1-11	0	167371	0	0	0	0	0
1-2	0	167371	0	0	0	0	0
1-3	0	167371	0	0	0	0	0
1-4	0	167371	0	0	0	0	0
1-5	0	18755	148616	0	0	0.8879	0.8879
1-6	0	167371	0	0	0	0	0
1-7	0	167371	0	0	0	0	0
1-8	0	167371	0	0	0	0	0
1-9	0	75292	92079	0	0	0.5501	0.5501
2-10	0	49114	118257	0	0	0.7066	0.7066
2-11	0	58873	108498	0	0	0.6482	0.6482
2-3	0	75260	92111	0	0	0.5503	0.5503
2-4	0	34835	132536	0	0	0.7919	0.7919
2-5	0	167371	0	0	0	0	0
2-6	0	67894	99477	0	0	0.5944	0.5944
2-7	0	67805	99566	0	0	0.5948	0.5948
2-8	0	73860	93511	0	0	0.5586	0.5586
2-9	0	6648	160723	0	0	0.9603	0.9603
3-10	0	74329	93042	0	0	0.5558	0.5558
3-11	0	167371	0	0	0	0	0
3-4	0	68740	98631	0	0	0.5893	0.5893
3-5	0	75325	92046	0	0	0.5504	0.5504
3-6	0	74537	92834	0	0	0.5546	0.5546
3-7	0	167371	0	0	0	0	0
3-8	0	167371	0	0	0	0	0
3-9	0	167371	0	0	0	0	0
4-10	0	29977	137394	0	0	0.8208	0.8208

4-11	0	31065	136306	0	0	0.8144	0.8144
4-5	0	167371	0	0	0	0	0
4-6	0	58558	108813	0	0	0.6501	0.6501
4-7	0	67837	99534	0	0	0.5947	0.5947
4-8	0	72979	94392	0	0	0.5635	0.5635
4-9	0	563	166808	0	0	0.9966	0.9966
5-10	0	167371	0	0	0	0	0
5-11	0	167371	0	0	0	0	0
5-6	0	75083	92288	0	0	0.5514	0.5514
5-7	0	74949	92422	0	0	0.5522	0.5522
5-8	0	167371	0	0	0	0	0
5-9	0	167371	0	0	0	0	0
6-10	0	67910	99461	0	0	0.5943	0.5943
6-11	0	67877	99494	0	0	0.5945	0.5945
6-7	0	67860	99511	0	0	0.5946	0.5946
6-8	0	167371	0	0	0	0	0
6-9	0	3690	163681	0	0	0.9778	0.9778
7-10	0	67864	99507	0	0	0.5945	0.5945
7-11	0	67880	99491	0	0	0.5944	0.5944
7-8	0	167371	0	0	0	0	0
7-9	0	3381	163990	0	0	0.9798	0.9798
8-10	0	73856	93515	0	0	0.5586	0.5586
8-11	0	73414	93957	0	0	0.5614	0.5614
8-9	0	167371	0	0	0	0	0
9-10	0	945	166426	0	0	0.9943	0.9943
9-11	0	681	166690	0	0	0.9959	0.9959

Tabela B.20 – Resultados com dois descritores - Imagem 23

Descritor	VP	FP	VN	FN	Sensibilidade	Especificidade	Acurácia
0-10	0	63950	114013	0	0	0.6407	0.6407
0-11	0	63249	114714	0	0	0.6445	0.6445
0-1	0	177963	0	0	0	0	0
0-2	0	55506	122457	0	0	0.6881	0.6881
0-3	0	74489	103474	0	0	0.5814	0.5814
0-4	0	20395	157568	0	0	0.8853	0.8853
0-5	0	177963	0	0	0	0	0

0-6	0	63589	114374	0	0	0.6427	0.6427
0-7	0	63267	114696	0	0	0.6444	0.6444
0-8	0	177963	0	0	0	0	0
0-9	0	4831	173132	0	0	0.9728	0.9728
10-11	0	64712	113251	0	0	0.6363	0.6363
1-10	0	177963	0	0	0	0	0
1-11	0	177963	0	0	0	0	0
1-2	0	177963	0	0	0	0	0
1-3	0	177963	0	0	0	0	0
1-4	0	177963	0	0	0	0	0
1-5	0	32481	145482	0	0	0.8175	0.8175
1-6	0	177963	0	0	0	0	0
1-7	0	177963	0	0	0	0	0
1-8	0	177963	0	0	0	0	0
1-9	0	177963	0	0	0	0	0
2-10	0	52262	125701	0	0	0.7063	0.7063
2-11	0	58445	119518	0	0	0.6715	0.6715
2-3	0	73674	104289	0	0	0.5857	0.5857
2-4	0	29515	148448	0	0	0.8342	0.8342
2-5	0	72854	105109	0	0	0.5906	0.5906
2-6	0	64901	113062	0	0	0.6352	0.6352
2-7	0	63591	114372	0	0	0.6427	0.6427
2-8	0	177963	0	0	0	0	0
2-9	0	18439	159524	0	0	0.8963	0.8963
3-10	0	74060	103903	0	0	0.5837	0.5837
3-11	0	177963	0	0	0	0	0
3-4	0	71667	106296	0	0	0.5973	0.5973
3-5	0	75267	102696	0	0	0.5770	0.5770
3-6	0	74306	103657	0	0	0.5825	0.5825
3-7	0	177963	0	0	0	0	0
3-8	0	177963	0	0	0	0	0
3-9	0	177963	0	0	0	0	0
4-10	0	17258	160705	0	0	0.9032	0.9032
4-11	0	18169	159794	0	0	0.8979	0.8979
4-5	0	177963	0	0	0	0	0
4-6	0	44553	133410	0	0	0.7497	0.7497
4-7	0	63661	114302	0	0	0.6422	0.6422

4-8	0	177963	0	0	0	0	0
4-9	0	2311	175652	0	0	0.9869	0.9869
5-10	0	72167	105796	0	0	0.5945	0.5945
5-11	0	177963	0	0	0	0	0
5-6	0	74948	103015	0	0	0.5788	0.5788
5-7	0	74762	103201	0	0	0.5798	0.5798
5-8	0	177963	0	0	0	0	0
5-9	0	74585	103378	0	0	0.5808	0.5808
6-10	0	64686	113277	0	0	0.6364	0.6364
6-11	0	63781	114182	0	0	0.6415	0.6415
6-7	0	63572	114391	0	0	0.6428	0.6428
6-8	0	177963	0	0	0	0	0
6-9	0	10999	166964	0	0	0.9382	0.9382
7-10	0	63761	114202	0	0	0.6417	0.6417
7-11	0	63927	114036	0	0	0.6408	0.6408
7-8	0	177963	0	0	0	0	0
7-9	0	10513	167450	0	0	0.9408	0.9408
8-10	0	177963	0	0	0	0	0
8-11	0	177963	0	0	0	0	0
8-9	0	177963	0	0	0	0	0
9-10	0	3938	174025	0	0	0.9778	0.9778
9-11	0	2774	175189	0	0	0.9844	0.9844

Tabela B.21 – Resultados com dois descritores - Imagem 24

Descritor	VP	FP	VN	FN	Sensibilidade	Especificidade	Acurácia
0-10	0	83013	88725	0	0	0.5165	0.5165
0-11	0	81406	90332	0	0	0.5262	0.5262
0-1	0	171738	0	0	0	0	0
0-2	0	71784	99954	0	0	0.5816	0.5816
0-3	0	89120	82618	0	0	0.4811	0.4811
0-4	0	15601	156137	0	0	0.9092	0.9092
0-5	0	171738	0	0	0	0	0
0-6	0	82276	89462	0	0	0.5209	0.5209
0-7	0	81231	90507	0	0	0.5272	0.5272
0-8	0	171738	0	0	0	0	0
0-9	0	13120	158618	0	0	0.9235	0.9235

10-11	0	83845	87893	0	0	0.5118	0.5118
1-10	0	171738	0	0	0	0	0
1-11	0	171738	0	0	0	0	0
1-2	0	171738	0	0	0	0	0
1-3	0	171738	0	0	0	0	0
1-4	0	171738	0	0	0	0	0
1-5	0	54637	117101	0	0	0.6818	0.6818
1-6	0	171738	0	0	0	0	0
1-7	0	171738	0	0	0	0	0
1-8	0	171738	0	0	0	0	0
1-9	0	171738	0	0	0	0	0
2-10	0	66133	105605	0	0	0.6149	0.6149
2-11	0	76046	95692	0	0	0.5572	0.5572
2-3	0	88499	83239	0	0	0.4847	0.4847
2-4	0	32521	139217	0	0	0.8105	0.8105
2-5	0	171738	0	0	0	0	0
2-6	0	83358	88380	0	0	0.5145	0.5145
2-7	0	82203	89535	0	0	0.5212	0.5212
2-8	0	171738	0	0	0	0	0
2-9	0	35296	136442	0	0	0.7944	0.7944
3-10	0	88775	82963	0	0	0.4830	0.4830
3-11	0	171738	0	0	0	0	0
3-4	0	55089	116649	0	0	0.6792	0.6792
3-5	0	89645	82093	0	0	0.4778	0.4778
3-6	0	88970	82768	0	0	0.4819	0.4819
3-7	0	171738	0	0	0	0	0
3-8	0	171738	0	0	0	0	0
3-9	0	171738	0	0	0	0	0
4-10	0	13070	158668	0	0	0.9239	0.9239
4-11	0	14358	157380	0	0	0.9163	0.9163
4-5	0	171738	0	0	0	0	0
4-6	0	42481	129257	0	0	0.7526	0.7526
4-7	0	82297	89441	0	0	0.5208	0.5208
4-8	0	171738	0	0	0	0	0
4-9	0	5648	166090	0	0	0.9670	0.9670
5-10	0	171738	0	0	0	0	0
5-11	0	171738	0	0	0	0	0

5-6	0	171738	0	0	0	0	0
5-7	0	171738	0	0	0	0	0
5-8	0	171738	0	0	0	0	0
5-9	0	171738	0	0	0	0	0
6-10	0	83371	88367	0	0	0.5144	0.5144
6-11	0	82563	89175	0	0	0.5192	0.5192
6-7	0	82224	89514	0	0	0.5212	0.5212
6-8	0	171738	0	0	0	0	0
6-9	0	25104	146634	0	0	0.8538	0.8538
7-10	0	82712	89026	0	0	0.5183	0.5183
7-11	0	82858	88880	0	0	0.5174	0.5174
7-8	0	171738	0	0	0	0	0
7-9	0	23684	148054	0	0	0.8620	0.8620
8-10	0	171738	0	0	0	0	0
8-11	0	171738	0	0	0	0	0
8-9	0	171738	0	0	0	0	0
9-10	0	12574	159164	0	0	0.9267	0.9267
9-11	0	9212	162526	0	0	0.9464	0.9464

Tabela B.22 – Resultados com dois descritores - Imagem 25

Descritor	VP	FP	VN	FN	Sensibilidade	Especificidade	Acurácia
0-10	0	70663	113362	0	0	0.6159	0.6159
0-11	0	70015	114010	0	0	0.6195	0.6195
0-1	0	184025	0	0	0	0	0
0-2	0	63496	120529	0	0	0.6553	0.6553
0-3	0	78987	105038	0	0	0.5707	0.5707
0-4	0	6414	177611	0	0	0.9650	0.9650
0-5	0	184025	0	0	0	0	0
0-6	0	70253	113772	0	0	0.6181	0.6181
0-7	0	69709	114316	0	0	0.6211	0.6211
0-8	0	184025	0	0	0	0	0
0-9	0	23205	160820	0	0	0.8739	0.8739
10-11	0	184025	0	0	0	0	0
1-10	0	184025	0	0	0	0	0
1-11	0	184025	0	0	0	0	0
1-2	0	184025	0	0	0	0	0

1-3	0	184025	0	0	0	0	0
1-4	0	184025	0	0	0	0	0
1-5	0	69696	114329	0	0	0.6212	0.6212
1-6	0	184025	0	0	0	0	0
1-7	0	184025	0	0	0	0	0
1-8	0	184025	0	0	0	0	0
1-9	0	184025	0	0	0	0	0
2-10	0	59207	124818	0	0	0.6783	0.6783
2-11	0	66376	117649	0	0	0.6392	0.6392
2-3	0	78236	105789	0	0	0.5748	0.5748
2-4	0	24295	159730	0	0	0.8679	0.8679
2-5	0	184025	0	0	0	0	0
2-6	0	184025	0	0	0	0	0
2-7	0	70122	113903	0	0	0.6189	0.6189
2-8	0	184025	0	0	0	0	0
2-9	0	45222	138803	0	0	0.7542	0.7542
3-10	0	78515	105510	0	0	0.5733	0.5733
3-11	0	184025	0	0	0	0	0
3-4	0	86164	97861	0	0	0.5318	0.5318
3-5	0	79987	104038	0	0	0.5653	0.5653
3-6	0	78836	105189	0	0	0.5716	0.5716
3-7	0	184025	0	0	0	0	0
3-8	0	184025	0	0	0	0	0
3-9	0	184025	0	0	0	0	0
4-10	0	5791	178234	0	0	0.9685	0.9685
4-11	0	5891	178134	0	0	0.9677	0.9677
4-5	0	184025	0	0	0	0	0
4-6	0	20642	163383	0	0	0.8878	0.8878
4-7	0	184025	0	0	0	0	0
4-8	0	184025	0	0	0	0	0
4-9	0	15439	168586	0	0	0.9161	0.9161
5-10	0	184025	0	0	0	0	0
5-11	0	184025	0	0	0	0	0
5-6	0	79606	104419	0	0	0.5674	0.5674
5-7	0	79393	104632	0	0	0.5685	0.5685
5-8	0	184025	0	0	0	0	0
5-9	0	79173	104852	0	0	0.5697	0.5697

6-10	0	184025	0	0	0	0	0
6-11	0	70343	113682	0	0	0.6178	0.6178
6-7	0	70265	113760	0	0	0.6181	0.6181
6-8	0	184025	0	0	0	0	0
6-9	0	35651	148374	0	0	0.8063	0.8063
7-10	0	70421	113604	0	0	0.6172	0.6172
7-11	0	70483	113542	0	0	0.6169	0.6169
7-8	0	184025	0	0	0	0	0
7-9	0	33189	150836	0	0	0.8196	0.8196
8-10	0	184025	0	0	0	0	0
8-11	0	184025	0	0	0	0	0
8-9	0	184025	0	0	0	0	0
9-10	0	22390	161635	0	0	0.8782	0.8782
9-11	0	70343	113682	0	0	0.6178	0.6178

Tabela B.23 – Resultados com dois descritores - Imagem 26

Descritor	VP	FP	VN	FN	Sensibilidade	Especificidade	Acurácia
0-10	0	72186	93382	0	0	0.5635	0.5635
0-11	0	71088	94480	0	0	0.5706	0.5706
0-1	0	165568	0	0	0	0	0
0-2	0	59945	105623	0	0	0.6379	0.6379
0-3	0	80080	85488	0	0	0.5162	0.5162
0-4	0	17726	147842	0	0	0.8929	0.8929
0-5	0	165568	0	0	0	0	0
0-6	0	71490	94078	0	0	0.5682	0.5682
0-7	0	70701	94867	0	0	0.5725	0.5725
0-8	0	165568	0	0	0	0	0
0-9	0	8698	156870	0	0	0.9475	0.9475
10-11	0	72536	93032	0	0	0.5618	0.5618
1-10	0	165568	0	0	0	0	0
1-11	0	165568	0	0	0	0	0
1-2	0	165568	0	0	0	0	0
1-3	0	165568	0	0	0	0	0
1-4	0	165568	0	0	0	0	0
1-5	0	49513	116055	0	0	0.7006	0.7006
1-6	0	165568	0	0	0	0	0

1-7	0	165568	0	0	0	0	0
1-8	0	165568	0	0	0	0	0
1-9	0	165568	0	0	0	0	0
2-10	0	53513	112055	0	0	0.6767	0.6767
2-11	0	64505	101063	0	0	0.6104	0.6104
2-3	0	78621	86947	0	0	0.5251	0.5251
2-4	0	28199	137369	0	0	0.8296	0.8296
2-5	0	165568	0	0	0	0	0
2-6	0	72094	93474	0	0	0.5645	0.5645
2-7	0	71110	94458	0	0	0.5705	0.5705
2-8	0	165568	0	0	0	0	0
2-9	0	23445	142123	0	0	0.8584	0.8584
3-10	0	79130	86438	0	0	0.5221	0.5221
3-11	0	165568	0	0	0	0	0
3-4	0	57518	108050	0	0	0.6525	0.6525
3-5	0	81501	84067	0	0	0.5077	0.5077
3-6	0	79609	85959	0	0	0.5191	0.5191
3-7	0	165568	0	0	0	0	0
3-8	0	165568	0	0	0	0	0
3-9	0	165568	0	0	0	0	0
4-10	0	15274	150294	0	0	0.9076	0.9076
4-11	0	15926	149642	0	0	0.9038	0.9038
4-5	0	165568	0	0	0	0	0
4-6	0	41089	124479	0	0	0.7518	0.7518
4-7	0	71483	94085	0	0	0.5683	0.5683
4-8	0	165568	0	0	0	0	0
4-9	0	4791	160777	0	0	0.9710	0.9710
5-10	0	165568	0	0	0	0	0
5-11	0	165568	0	0	0	0	0
5-6	0	80906	84662	0	0	0.5112	0.5112
5-7	0	80600	84968	0	0	0.5131	0.5131
5-8	0	165568	0	0	0	0	0
5-9	0	80297	85271	0	0	0.5151	0.5151
6-10	0	72283	93285	0	0	0.5634	0.5634
6-11	0	71643	93925	0	0	0.5673	0.5673
6-7	0	71434	94134	0	0	0.5685	0.5685
6-8	0	165568	0	0	0	0	0

6-9	0	16341	149227	0	0	0.9012	0.9012
7-10	0	71677	93891	0	0	0.5671	0.5671
7-11	0	71864	93704	0	0	0.5655	0.5655
7-8	0	165568	0	0	0	0	0
7-9	0	15617	149951	0	0	0.9056	0.9056
8-10	0	165568	0	0	0	0	0
8-11	0	165568	0	0	0	0	0
8-9	0	165568	0	0	0	0	0
9-10	0	7976	157592	0	0	0.9517	0.9517
9-11	0	6033	159535	0	0	0.9636	0.9636

Tabela B.24 – Resultados com dois descritores - Imagem 27

Descritor	VP	FP	VN	FN	Sensibilidade	Especificidade	Acurácia
0-10	0	76165	99506	0	0	0.5664	0.5664
0-11	0	75164	100507	0	0	0.5721	0.5721
0-1	0	175671	0	0	0	0	0
0-2	0	65770	109901	0	0	0.6256	0.6256
0-3	0	82663	93008	0	0	0.5293	0.5293
0-4	0	14862	160809	0	0	0.9153	0.9153
0-5	0	175671	0	0	0	0	0
0-6	0	75453	100218	0	0	0.5705	0.5705
0-7	0	74990	100681	0	0	0.5731	0.5731
0-8	0	175671	0	0	0	0	0
0-9	0	10769	164902	0	0	0.9386	0.9386
10-11	0	76710	98961	0	0	0.5633	0.5633
1-10	0	175671	0	0	0	0	0
1-11	0	175671	0	0	0	0	0
1-2	0	175671	0	0	0	0	0
1-3	0	175671	0	0	0	0	0
1-4	0	175671	0	0	0	0	0
1-5	0	50893	124778	0	0	0.7103	0.7103
1-6	0	175671	0	0	0	0	0
1-7	0	175671	0	0	0	0	0
1-8	0	175671	0	0	0	0	0
1-9	0	175671	0	0	0	0	0
2-10	0	60743	114928	0	0	0.6542	0.6542

2-11	0	69781	105890	0	0	0.6028	0.6028
2-3	0	81750	93921	0	0	0.5345	0.5345
2-4	0	32201	143470	0	0	0.8166	0.8166
2-5	0	175671	0	0	0	0	0
2-6	0	76153	99518	0	0	0.5665	0.5665
2-7	0	75283	100388	0	0	0.5715	0.5715
2-8	0	175671	0	0	0	0	0
2-9	0	30866	144805	0	0	0.8243	0.8243
3-10	0	82141	93530	0	0	0.5323	0.5323
3-11	0	175671	0	0	0	0	0
3-4	0	65269	110402	0	0	0.6284	0.6284
3-5	0	83617	92054	0	0	0.5242	0.5242
3-6	0	82422	93249	0	0	0.5308	0.5308
3-7	0	175671	0	0	0	0	0
3-8	0	175671	0	0	0	0	0
3-9	0	175671	0	0	0	0	0
4-10	0	12630	163041	0	0	0.9281	0.9281
4-11	0	13148	162523	0	0	0.9252	0.9252
4-5	0	175671	0	0	0	0	0
4-6	0	42322	133349	0	0	0.7591	0.7591
4-7	0	75518	100153	0	0	0.5701	0.5701
4-8	0	175671	0	0	0	0	0
4-9	0	5018	170653	0	0	0.9714	0.9714
5-10	0	175671	0	0	0	0	0
5-11	0	175671	0	0	0	0	0
5-6	0	175671	0	0	0	0	0
5-7	0	175671	0	0	0	0	0
5-8	0	175671	0	0	0	0	0
5-9	0	175671	0	0	0	0	0
6-10	0	76172	99499	0	0	0.5664	0.5664
6-11	0	75603	100068	0	0	0.5696	0.5696
6-7	0	75450	100221	0	0	0.5705	0.5705
6-8	0	175671	0	0	0	0	0
6-9	0	20407	155264	0	0	0.8838	0.8838
7-10	0	75748	99923	0	0	0.5687	0.5687
7-11	0	75785	99886	0	0	0.5685	0.5685
7-8	0	175671	0	0	0	0	0

7-9	0	18537	157134	0	0	0.8944	0.8944
8-10	0	175671	0	0	0	0	0
8-11	0	175671	0	0	0	0	0
8-9	0	175671	0	0	0	0	0
9-10	0	9586	166085	0	0	0.9454	0.9454
9-11	0	6953	168718	0	0	0.9604	0.9604

Tabela B.25 – Resultados com dois descritores - Imagem 28

Descritor	VP	FP	VN	FN	Sensibilidade	Especificidade	Acurácia
0-11	0	70091	105580	0	0	0.6008	0.6008
0-1	0	175671	0	0	0	0	0
0-2	0	57290	118381	0	0	0.6739	0.6739
0-3	0	80317	95354	0	0	0.5427	0.5427
0-4	0	29150	146521	0	0	0.8340	0.8340
0-5	0	175671	0	0	0	0	0
0-6	0	70421	105250	0	0	0.5990	0.5990
0-7	0	69927	105744	0	0	0.6018	0.6018
0-8	0	175671	0	0	0	0	0
0-9	0	4146	171525	0	0	0.9764	0.9764
1-10	0	175671	0	0	0	0	0
1-11	0	175671	0	0	0	0	0
1-2	0	175671	0	0	0	0	0
1-3	0	175671	0	0	0	0	0
1-4	0	175671	0	0	0	0	0
1-5	0	34315	141356	0	0	0.8046	0.8046
1-6	0	175671	0	0	0	0	0
1-7	0	175671	0	0	0	0	0
1-8	0	175671	0	0	0	0	0
1-9	0	175671	0	0	0	0	0
2-10	0	51246	124425	0	0	0.7083	0.7083
2-11	0	62667	113004	0	0	0.6432	0.6432
2-3	0	150602	25069	0	0	0.1426	0.1426
2-4	0	31919	143752	0	0	0.8183	0.8183
2-5	0	78698	96973	0	0	0.5525	0.5525
2-6	0	71035	104636	0	0	0.5956	0.5956
2-7	0	70079	105592	0	0	0.6010	0.6010

2-8	0	175671	0	0	0	0	0
2-9	0	13139	162532	0	0	0.9252	0.9252
3-10	0	79302	96369	0	0	0.5485	0.5485
3-11	0	175671	0	0	0	0	0
3-4	0	68595	107076	0	0	0.6095	0.6095
3-5	0	81848	93823	0	0	0.5341	0.5341
3-6	0	79708	95963	0	0	0.5463	0.5463
3-7	0	175671	0	0	0	0	0
3-8	0	175671	0	0	0	0	0
3-9	0	175671	0	0	0	0	0
4-11	0	26257	149414	0	0	0.8505	0.8505
4-5	0	175671	0	0	0	0	0
4-6	0	53259	122412	0	0	0.6967	0.6967
4-7	0	70240	105431	0	0	0.6001	0.6001
4-8	0	79343	96328	0	0	0.5483	0.5483
4-9	0	2420	173251	0	0	0.9861	0.9861
5-10	0	78083	97588	0	0	0.5554	0.5554
5-11	0	175671	0	0	0	0	0
5-6	0	81250	94421	0	0	0.5374	0.5374
5-7	0	80908	94763	0	0	0.5393	0.5393
5-8	0	175671	0	0	0	0	0
5-9	0	175671	0	0	0	0	0
6-10	0	71148	104523	0	0	0.5947	0.5947
6-11	0	70517	105154	0	0	0.5986	0.5986
6-7	0	70380	105291	0	0	0.5994	0.5994
6-8	0	175671	0	0	0	0	0
6-9	0	8952	166719	0	0	0.9485	0.9485
7-8	0	175671	0	0	0	0	0
7-9	0	8839	166832	0	0	0.9496	0.9496

Tabela B.26 – Resultados com dois descritores - Imagem 29

Descritor	VP	FP	VN	FN	Sensibilidade	Especificidade	Acurácia
0-10	0	62701	100595	0	0	0.6159	0.6159
0-11	0	60195	103101	0	0	0.6313	0.6313
0-1	0	163296	0	0	0	0	0
0-2	0	53039	110257	0	0	0.6752	0.6752

0-3	0	71601	91695	0	0	0.5615	0.5615
0-4	0	19464	143832	0	0	0.8808	0.8808
0-5	0	163296	0	0	0	0	0
0-6	0	61459	101837	0	0	0.6236	0.6236
0-7	0	60141	103155	0	0	0.6317	0.6317
0-8	0	163296	0	0	0	0	0
0-9	0	6111	157185	0	0	0.9626	0.9626
10-11	0	64154	99142	0	0	0.6070	0.6070
1-10	0	163296	0	0	0	0	0
1-11	0	163296	0	0	0	0	0
1-2	0	163296	0	0	0	0	0
1-3	0	163296	0	0	0	0	0
1-4	0	163296	0	0	0	0	0
1-5	0	36287	127009	0	0	0.7778	0.7778
1-6	0	163296	0	0	0	0	0
1-7	0	163296	0	0	0	0	0
1-8	0	163296	0	0	0	0	0
1-9	0	163296	0	0	0	0	0
2-10	0	48201	115095	0	0	0.7047	0.7047
2-11	0	57278	106018	0	0	0.6492	0.6492
2-3	0	70330	92966	0	0	0.5693	0.5693
2-4	0	28295	135001	0	0	0.8266	0.8266
2-5	0	163296	0	0	0	0	0
2-6	0	62696	100600	0	0	0.6160	0.6160
2-7	0	61080	102216	0	0	0.626	0.626
2-8	0	163296	0	0	0	0	0
2-9	0	19010	144286	0	0	0.8836	0.8836
3-10	0	70883	92413	0	0	0.5658	0.5658
3-11	0	163296	0	0	0	0	0
3-4	0	67936	95360	0	0	0.5836	0.5836
3-5	0	72691	90605	0	0	0.5548	0.5548
3-6	0	71160	92136	0	0	0.5642	0.5642
3-7	0	163296	0	0	0	0	0
3-8	0	163296	0	0	0	0	0
3-9	0	163296	0	0	0	0	0
4-10	0	16671	146625	0	0	0.8979	0.8979
4-11	0	17495	145801	0	0	0.8929	0.8929

4-5	0	163296	0	0	0	0	0
4-6	0	42030	121266	0	0	0.7426	0.7426
4-7	0	61240	102056	0	0	0.625	0.625
4-8	0	163296	0	0	0	0	0
4-9	0	1071	162225	0	0	0.9933	0.9933
5-10	0	163296	0	0	0	0	0
5-11	0	163296	0	0	0	0	0
5-6	0	72274	91022	0	0	0.5574	0.5574
5-7	0	72001	91295	0	0	0.5591	0.5591
5-8	0	163296	0	0	0	0	0
5-9	0	163296	0	0	0	0	0
6-10	0	62746	100550	0	0	0.6158	0.6158
6-11	0	61802	101494	0	0	0.6215	0.6215
6-7	0	61391	101905	0	0	0.6240	0.6240
6-8	0	163296	0	0	0	0	0
6-9	0	13300	149996	0	0	0.9185	0.9185
7-10	0	61669	101627	0	0	0.6222	0.6222
7-11	0	61982	101314	0	0	0.6203	0.6203
7-8	0	163296	0	0	0	0	0
7-9	0	13439	149857	0	0	0.9176	0.9176
8-10	0	163296	0	0	0	0	0
8-11	0	71703	91593	0	0	0.5608	0.5608
8-9	0	163296	0	0	0	0	0
9-10	0	4986	158310	0	0	0.9695	0.9695
9-11	0	3679	159617	0	0	0.9775	0.9775

Tabela B.27 – Resultados com dois descritores - Imagem 30

Descritor	VP	FP	VN	FN	Sensibilidade	Especificidade	Acurácia
0-10	0	65280	84064	0	0	0.5628	0.5628
0-11	0	64989	84355	0	0	0.5647	0.5647
0-1	0	149344	0	0	0	0	0
0-2	0	52671	96673	0	0	0.6472	0.6472
0-3	0	72293	77051	0	0	0.5159	0.5159
0-4	0	25237	124107	0	0	0.8306	0.8306
0-5	0	149344	0	0	0	0	0
0-6	0	65091	84253	0	0	0.5642	0.5642

0-7	0	64966	84378	0	0	0.5645	0.5645
0-8	0	149344	0	0	0	0	0
0-9	0	3627	145717	0	0	0.9757	0.9757
10-11	0	149344	0	0	0	0	0
1-10	0	149344	0	0	0	0	0
1-11	0	149344	0	0	0	0	0
1-2	0	149344	0	0	0	0	0
1-3	0	149344	0	0	0	0	0
1-4	0	149344	0	0	0	0	0
1-5	0	24225	125119	0	0	0.8377	0.8377
1-6	0	149344	0	0	0	0	0
1-7	0	149344	0	0	0	0	0
1-8	0	149344	0	0	0	0	0
1-9	0	149344	0	0	0	0	0
2-10	0	45737	103607	0	0	0.6936	0.6936
2-11	0	55278	94066	0	0	0.6299	0.6299
2-3	0	71241	78103	0	0	0.5232	0.5232
2-4	0	28942	120402	0	0	0.8062	0.8062
2-5	0	149344	0	0	0	0	0
2-6	0	65723	83621	0	0	0.5598	0.5598
2-7	0	65007	84337	0	0	0.5646	0.5646
2-8	0	149344	0	0	0	0	0
2-9	0	12880	136464	0	0	0.9137	0.9137
3-10	0	71735	77609	0	0	0.5197	0.5197
3-11	0	149344	0	0	0	0	0
3-4	0	56588	92756	0	0	0.6210	0.6210
3-5	0	73074	76270	0	0	0.5107	0.5107
3-6	0	72004	77340	0	0	0.5179	0.5179
3-7	0	149344	0	0	0	0	0
3-8	0	149344	0	0	0	0	0
3-9	0	149344	0	0	0	0	0
4-10	0	20825	128519	0	0	0.8606	0.8606
4-11	0	22582	126762	0	0	0.8488	0.8488
4-5	0	149344	0	0	0	0	0
4-6	0	48724	100620	0	0	0.6736	0.6736
4-7	0	65062	84282	0	0	0.5643	0.5643
4-8	0	72105	77239	0	0	0.5171	0.5171

4-9	0	2647	146697	0	0	0.9822	0.9822
5-10	0	149344	0	0	0	0	0
5-11	0	149344	0	0	0	0	0
5-6	0	72783	76561	0	0	0.5125	0.5125
5-7	0	72640	76704	0	0	0.5135	0.5135
5-8	0	149344	0	0	0	0	0
5-9	0	149344	0	0	0	0	0
6-10	0	65685	83659	0	0	0.5602	0.5602
6-11	0	65142	84202	0	0	0.5637	0.5637
6-7	0	65078	84266	0	0	0.5642	0.5642
6-8	0	149344	0	0	0	0	0
6-9	0	8038	141306	0	0	0.9462	0.9462
7-10	0	65123	84221	0	0	0.5638	0.5638
7-11	0	65177	84167	0	0	0.5635	0.5635
7-8	0	149344	0	0	0	0	0
7-9	0	7868	141476	0	0	0.9473	0.9473
8-10	0	149344	0	0	0	0	0
8-11	0	72302	77042	0	0	0.5159	0.5159
8-9	0	149344	0	0	0	0	0
9-10	0	149344	0	0	0	0	0

Resultados Numéricos com Três Descritores

Tabela C.1 – Resultados Numéricos com Três Descritores

Nome da Imagem	VP	FP	VN	FN	Sensibilidade	Especificidade	Acurácia
0-2-5	7537	4239	133725	2654	0,7396	0,9693	0,9535
0-4-5	7459	4281	133683	2732	0,7319	0,969	0,9527
2-4-5	7114	4456	133508	3077	0,6981	0,9677	0,9492
0-1-10	0	0	137964	10191	0	1	0,9312
0-1-11	0	0	137964	10191	0	1	0,9312
0-1-2	0	0	137964	10191	0	1	0,9312
0-1-4	0	0	137964	10191	0	1	0,9312
0-1-5	0	0	137964	10191	0	1	0,9312
0-1-6	0	0	137964	10191	0	1	0,9312
0-1-7	0	0	137964	10191	0	1	0,9312
0-1-8	0	0	137964	10191	0	1	0,9312
0-1-9	0	0	137964	10191	0	1	0,9312
0-3-10	0	0	137964	10191	0	1	0,9312
0-3-7	0	0	137964	10191	0	1	0,9312
0-3-9	0	0	137964	10191	0	1	0,9312
0-5-10	0	0	137964	10191	0	1	0,9312
0-5-11	0	0	137964	10191	0	1	0,9312
0-5-6	0	0	137964	10191	0	1	0,9312
0-5-7	0	0	137964	10191	0	1	0,9312
0-5-8	0	0	137964	10191	0	1	0,9312
0-5-9	0	0	137964	10191	0	1	0,9312
0-6-10	0	0	137964	10191	0	1	0,9312
0-6-8	0	0	137964	10191	0	1	0,9312
0-6-9	0	0	137964	10191	0	1	0,9312
0-7-10	0	0	137964	10191	0	1	0,9312
0-7-11	0	0	137964	10191	0	1	0,9312

0-78	0	0	137964	10191	0	1	0,9312
0-79	0	0	137964	10191	0	1	0,9312
0-911	0	0	137964	10191	0	1	0,9312
1-10-11	0	0	137964	10191	0	1	0,9312
1-2-11	0	0	137964	10191	0	1	0,9312
1-2-4	0	0	137964	10191	0	1	0,9312
1-2-5	0	0	137964	10191	0	1	0,9312
1-2-6	0	0	137964	10191	0	1	0,9312
1-2-7	0	0	137964	10191	0	1	0,9312
1-2-8	0	0	137964	10191	0	1	0,9312
1-2-9	0	0	137964	10191	0	1	0,9312
1-3-5	0	0	137964	10191	0	1	0,9312
1-3-7	0	0	137964	10191	0	1	0,9312
1-3-8	0	0	137964	10191	0	1	0,9312
1-3-9	0	0	137964	10191	0	1	0,9312
1-4-10	0	0	137964	10191	0	1	0,9312
1-4-11	0	0	137964	10191	0	1	0,9312
1-4-1	0	0	137964	10191	0	1	0,9312
1-4-5	0	0	137964	10191	0	1	0,9312
1-4-6	0	0	137964	10191	0	1	0,9312
1-4-7	0	0	137964	10191	0	1	0,9312
1-4-8	0	0	137964	10191	0	1	0,9312
1-4-9	0	0	137964	10191	0	1	0,9312
1-5-10	0	0	137964	10191	0	1	0,9312
1-6-10	0	0	137964	10191	0	1	0,9312
1-6-11	0	0	137964	10191	0	1	0,9312
1-6-7	0	0	137964	10191	0	1	0,9312
1-6-8	0	0	137964	10191	0	1	0,9312
1-6-9	0	0	137964	10191	0	1	0,9312
1-7-10	0	0	137964	10191	0	1	0,9312
1-7-11	0	0	137964	10191	0	1	0,9312
1-7-8	0	0	137964	10191	0	1	0,9312
1-7-9	0	0	137964	10191	0	1	0,9312
1-8-10	0	0	137964	10191	0	1	0,9312
1-9-10	0	0	137964	10191	0	1	0,9312
1-9-11	0	0	137964	10191	0	1	0,9312
2-3-5	0	0	137964	10191	0	1	0,9312

2-5-11	0	0	137964	10191	0	1	0,9312
2-5-6	0	0	137964	10191	0	1	0,9312
2-5-7	0	0	137964	10191	0	1	0,9312
2-5-8	0	0	137964	10191	0	1	0,9312
2-6-10	0	0	137964	10191	0	1	0,9312
2-6-11	0	0	137964	10191	0	1	0,9312
2-6-8	0	0	137964	10191	0	1	0,9312
2-6-9	0	0	137964	10191	0	1	0,9312
2-7-10	0	0	137964	10191	0	1	0,9312
2-7-11	0	0	137964	10191	0	1	0,9312
2-7-8	0	0	137964	10191	0	1	0,9312
2-7-9	0	0	137964	10191	0	1	0,9312
3-1-011	0	0	137964	10191	0	1	0,9312
3-4-10	0	0	137964	10191	0	1	0,9312
3-4-5	0	0	137964	10191	0	1	0,9312
3-4-6	0	0	137964	10191	0	1	0,9312
3-5-11	0	0	137964	10191	0	1	0,9312
3-5-1	0	0	137964	10191	0	1	0,9312
3-5-6	0	0	137964	10191	0	1	0,9312
3-5-7	0	0	137964	10191	0	1	0,9312
3-5-8	0	0	137964	10191	0	1	0,9312
3-7-10	0	0	137964	10191	0	1	0,9312
3-7-8	0	0	137964	10191	0	1	0,9312
3-8-10	0	0	137964	10191	0	1	0,9312
3-8-9	0	0	137964	10191	0	1	0,9312
4-5-10	0	0	137964	10191	0	1	0,9312
4-5-11	0	0	137964	10191	0	1	0,9312
4-5-6	0	0	137964	10191	0	1	0,9312
4-5-7	0	0	137964	10191	0	1	0,9312
4-5-8	0	0	137964	10191	0	1	0,9312
4-5-9	0	0	137964	10191	0	1	0,9312
4-6-10	0	0	137964	10191	0	1	0,9312
4-6-7	0	0	137964	10191	0	1	0,9312
4-6-8	0	0	137964	10191	0	1	0,9312
4-6-9	0	0	137964	10191	0	1	0,9312
4-7-10	0	0	137964	10191	0	1	0,9312
4-7-8	0	0	137964	10191	0	1	0,9312

4-7-9	0	0	137964	10191	0	1	0,9312
4-9-10	0	0	137964	10191	0	1	0,9312
5-10-11	0	0	137964	10191	0	1	0,9312
5-6-10	0	0	137964	10191	0	1	0,9312
5-6-11	0	0	137964	10191	0	1	0,9312
5-6-7	0	0	137964	10191	0	1	0,9312
5-6-8	0	0	137964	10191	0	1	0,9312
5-6-9	0	0	137964	10191	0	1	0,9312
5-7-10	0	0	137964	10191	0	1	0,9312
5-7-11	0	0	137964	10191	0	1	0,9312
5-7-8	0	0	137964	10191	0	1	0,9312
5-7-9	0	0	137964	10191	0	1	0,9312
5-8-10	0	0	137964	10191	0	1	0,9312
5-9-10	0	0	137964	10191	0	1	0,9312
5-9-11	0	0	137964	10191	0	1	0,9312
6-10-11	0	0	137964	10191	0	1	0,9312
6-7-10	0	0	137964	10191	0	1	0,9312
6-7-11	0	0	137964	10191	0	1	0,9312
6-7-8	0	0	137964	10191	0	1	0,9312
6-7-9	0	0	137964	10191	0	1	0,9312
6-9-10	0	0	137964	10191	0	1	0,9312
7-10-11	0	0	137964	10191	0	1	0,9312
7-8-9	0	0	137964	10191	0	1	0,9312
7-9-10	0	0	137964	10191	0	1	0,9312
7-9-11	0	0	137964	10191	0	1	0,9312
0-2-7	1062	1928	136036	9129	0,1042	0,986	0,9254
0-2-8	2291	4114	133850	7900	0,2248	0,9702	0,9189
0-2-3	4359	15276	122688	5832	0,4277	0,8893	0,8575
2-6-7	6726	22138	115826	3465	0,66	0,8395	0,8272
0-4-7	7581	25664	112300	2610	0,7439	0,814	0,8092
4-9-11	7479	25606	112358	2712	0,7339	0,8144	0,8089
0-4-10	7847	26941	111023	2344	0,77	0,8047	0,8023
0-4-11	8026	28457	109507	2165	0,7876	0,7937	0,7933
0-4-9	8078	28921	109043	2113	0,7927	0,7904	0,7905
4-7-11	8185	29354	108610	2006	0,8032	0,7872	0,7883
0-4-6	8062	29397	108567	2129	0,7911	0,7869	0,7872
2-4-9	7796	30070	107894	2395	0,765	0,782	0,7809

2-4-10	7821	30318	107646	2370	0,7674	0,7802	0,7794
2-4-6	7827	30415	107549	2364	0,768	0,7795	0,7788
2-4-8	7504	30432	107532	2687	0,7363	0,7794	0,7765
4-10-11	8357	31566	106398	1834	0,82	0,7712	0,7746
2-4-7	7964	31566	106398	2227	0,7815	0,7712	0,7719
2-4-11	8071	32462	105502	2120	0,792	0,7647	0,7666
4-6-11	8560	33317	104647	1631	0,84	0,7585	0,7641
2-9-10	8257	37419	100545	1934	0,8102	0,7288	0,7344
0-4-8	8406	40209	97755	1785	0,8248	0,7086	0,7166
1-5-9	9714	44400	93564	477	0,9532	0,6782	0,6971
9-10-11	9613	51175	86789	578	0,9433	0,6291	0,6507
0-2-4	9946	51702	86262	245	0,976	0,6253	0,6494
0-9-10	9798	51641	86323	393	0,9614	0,6257	0,6488
0-2-9	9987	52151	85813	204	0,98	0,622	0,6466
1-5-8	10011	52804	85160	180	0,9823	0,6173	0,6424
0-6-11	10016	52876	85088	175	0,9828	0,6167	0,6419
0-10-11	10037	52930	85034	154	0,9849	0,6163	0,6417
0-6-7	10027	52939	85025	164	0,9839	0,6163	0,6416
6-9-11	9963	52963	85001	228	0,9776	0,6161	0,641
0-2-10	10054	53056	84908	137	0,9866	0,6154	0,641
2-9-11	9981	53115	84849	210	0,9794	0,615	0,6401
0-2-11	10080	53463	84501	111	0,9891	0,6125	0,6384
1-5-11	10010	53914	84050	181	0,9822	0,6092	0,6349
2-10-11	10083	54354	83610	108	0,9894	0,606	0,6324
2-5-9	10020	54997	82967	171	0,9832	0,6014	0,6276
2-5-10	10049	55534	82430	142	0,9861	0,5975	0,6242
8-9-10	9688	57052	80912	503	0,9506	0,5865	0,6115
8-9-11	9782	57345	80619	409	0,9599	0,5843	0,6102
3-9-11	9787	57394	80570	404	0,9604	0,584	0,6099
7-8-10	9806	57428	80536	385	0,9622	0,5837	0,6098
3-6-10	9740	57365	80599	451	0,9557	0,5842	0,6098
3-6-8	9726	57358	80606	465	0,9544	0,5843	0,6097
2-8-10	9759	57405	80559	432	0,9576	0,5839	0,6096
2-8-9	9776	57458	80506	415	0,9593	0,5835	0,6094
2-8-11	9778	57463	80501	413	0,9595	0,5835	0,6094
6-8-11	9830	57549	80415	361	0,9646	0,5829	0,6091
7-8-11	9847	57569	80395	344	0,9662	0,5827	0,6091

6-8-10	9838	57576	80388	353	0,9654	0,5827	0,609
6-8-9	9857	57640	80324	334	0,9672	0,5822	0,6087
0-8-9	9891	57684	80280	300	0,9706	0,5819	0,6086
0-8-11	9882	57680	80284	309	0,9697	0,5819	0,6086
0-1-3	10005	57842	80122	186	0,9817	0,5807	0,6083
8-10-11	9866	57732	80232	325	0,9681	0,5815	0,6081
4-8-10	9951	57871	80093	240	0,9764	0,5805	0,6078
0-8-10	9982	57946	80018	209	0,9795	0,58	0,6075
1-2-3	10003	57972	79992	188	0,9816	0,5798	0,6074
4-8-11	10037	58204	79760	154	0,9849	0,5781	0,6061
4-8-9	10037	58210	79754	154	0,9849	0,5781	0,6061
5-8-9	10076	58319	79645	115	0,9887	0,5773	0,6056
2-3-8	10083	58629	79335	108	0,9894	0,575	0,6035
3-4-11	10083	58640	79324	108	0,9894	0,575	0,6035
3-4-9	10083	58656	79308	108	0,9894	0,5748	0,6034
1-3-4	10083	58680	79284	108	0,9894	0,5747	0,6032
1-5-7	10083	58681	79283	108	0,9894	0,5747	0,6032
3-5-2	10083	58700	79264	108	0,9894	0,5745	0,6031
2-3-6	10083	58704	79260	108	0,9894	0,5745	0,603
0-3-8	10083	58706	79258	108	0,9894	0,5745	0,603
3-8-11	10083	58706	79258	108	0,9894	0,5745	0,603
2-3-11	10083	58708	79256	108	0,9894	0,5745	0,603
0-3-5	10083	58719	79245	108	0,9894	0,5744	0,6029
2-3-4	10083	58728	79236	108	0,9894	0,5743	0,6029
1-3-11	10083	58743	79221	108	0,9894	0,5742	0,6028
0-3-4	10083	58755	79209	108	0,9894	0,5741	0,6027
3-5-4	10083	58756	79208	108	0,9894	0,5741	0,6027
3-6-9	10083	58756	79208	108	0,9894	0,5741	0,6027
3-5-5	10083	58758	79206	108	0,9894	0,5741	0,6027
0-3-6	10083	58760	79204	108	0,9894	0,5741	0,6027
3-5-3	10083	58760	79204	108	0,9894	0,5741	0,6027
1-5-6	10083	58770	79194	108	0,9894	0,574	0,6026
1-2-10	10083	58782	79182	108	0,9894	0,5739	0,6025
5-8-11	10083	58798	79166	108	0,9894	0,5738	0,6024
3-6-7	10083	58801	79163	108	0,9894	0,5738	0,6024
1-3-6	10083	58808	79156	108	0,9894	0,5737	0,6023
3-6-11	10083	58817	79147	108	0,9894	0,5737	0,6023

3-5-10	10083	58820	79144	108	0,9894	0,5737	0,6023
3-7-11	10083	58824	79140	108	0,9894	0,5736	0,6022
0-3-11	10083	58827	79137	108	0,9894	0,5736	0,6022
2-3-10	10083	58829	79135	108	0,9894	0,5736	0,6022
3-5-9	10083	58829	79135	108	0,9894	0,5736	0,6022
2-3-7	10083	58830	79134	108	0,9894	0,5736	0,6022
3-4-7	10083	58835	79129	108	0,9894	0,5735	0,6022
3-4-8	10083	58842	79122	108	0,9894	0,5735	0,6021
3-7-9	10083	58849	79115	108	0,9894	0,5734	0,6021
3-9-10	10083	58856	79108	108	0,9894	0,5734	0,602
2-3-9	10083	58859	79105	108	0,9894	0,5734	0,602
1-3-10	10083	58860	79104	108	0,9894	0,5734	0,602
1-8-11	10083	58915	79049	108	0,9894	0,573	0,6016
1-8-9	10083	58926	79038	108	0,9894	0,5729	0,6015