



Universidade de Brasília – UnB
Campus Gama – FGA
Programa de Pós-Graduação em Engenharia Biomédica

**SEGMENTAÇÃO AUTOMÁTICA DE IMAGENS DE RESSONÂNCIA
MAGNÉTICA CEREBRAL PARA AUXÍLIO AO DIAGNÓSTICO
DE ESQUIZOFRENIA**

EVERTON KLYSNNEY MOREIRA NUNES

Orientador: DR. MARCUS VINÍCIUS CHAFFIM COSTA, FGA, UNB.

Coorientador: DR. RENAN UTIDA FERREIRA, FGA, UNB.



UNB – UNIVERSIDADE DE BRASÍLIA

FGA – FACULDADE GAMA



**SEGMENTAÇÃO AUTOMÁTICA DE IMAGENS DE RESSONÂNCIA
MAGNÉTICA CEREBRAL PARA AUXÍLIO AO DIAGNÓSTICO DE
ESQUIZOFRENIA**

EVERTON KLYSNNEY MOREIRA NUNES

ORIENTADOR: DR. MARCUS VINÍCIUS CHAFFIM COSTA, FGA, UNB.

CO-ORIENTADOR: DR. RENAN UTIDA FERREIRA, FGA, UNB.

DISSERTAÇÃO DE MESTRADO EM
ENGENHARIA BIOMÉDICA

PUBLICAÇÃO: 134A/2020

BRASÍLIA/DF, NOVEMBRO DE 2020

UNB – UNIVERSIDADE DE BRASÍLIA
FGA – FACULDADE GAMA
PROGRAMA DE PÓS-GRADUAÇÃO

SEGMENTAÇÃO AUTOMÁTICA DE IMAGENS DE RESSONÂNCIA
MAGNÉTICA CEREBRAL PARA AUXÍLIO AO DIAGNÓSTICO DE
ESQUIZOFRENIA

EVERTON KLYSNNEY MOREIRA NUNES

DISSERTAÇÃO DE MESTRADO SUBMETIDA AO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA BIOMÉDICA DA UNIVERSIDADE DE BRASÍLIA, COMO PARTE DOS REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE MESTRE EM ENGENHARIA BIOMÉDICA

APROVADA POR:



Dr. Marcus Vinícius Chaffim Costa, FGA, UnB.

(Orientador)



Dr. Cristiano Jacques Miosso, FGA, UnB.

(Examinador interno)



Dra. Neysa Aparecida Tinoco Regattieri, FMD, UnB.

(Examinador externo)

Dr. Vinícius de Carvalho Rispoli, FGA, UnB.

(Examinador suplente)

FICHA CATALOGRÁFICA

NUNES, EVERTON

Segmentação Automática de Imagens de Ressonância Magnética Cerebral para Auxílio ao Diagnóstico de Esquizofrenia

[Distrito Federal], 2020.

76p., 210 × 297 mm (FGA/UnB Gama, Mestrado em Engenharia Biomédica, 2020).

Dissertação de Mestrado em Engenharia Biomédica, Faculdade UnB Gama, Programa de Pós-Graduação em Engenharia Biomédica. Publicação: 134A/2020

- | | |
|---------------------------|-----------------------------------|
| 1. Esquizofrenia | 2. Transformada <i>Contourlet</i> |
| 3. Auxílio ao Diagnóstico | 4. Sistema Ventricular |
| I. FGA UnB/UnB. | II. Título (série) |

REFERÊNCIA

NUNES, EVERTON (2020). Segmentação Automática de Imagens de Ressonância Magnética Cerebral para Auxílio ao Diagnóstico de Esquizofrenia. Dissertação de mestrado em engenharia biomédica, Publicação 134A/2020, Programa de Pós-Graduação, Faculdade UnB Gama, Universidade de Brasília, Brasília, DF, 76p.

CESSÃO DE DIREITOS

AUTOR: Everton Klysnney Moreira Nunes

TÍTULO: Segmentação Automática de Imagens de Ressonância Magnética Cerebral para Auxílio ao Diagnóstico de Esquizofrenia

GRAU: Mestre

ANO: 2020

É concedida à Universidade de Brasília permissão para reproduzir cópias desta dissertação de mestrado e para emprestar ou vender tais cópias somente para propósitos acadêmicos e científicos. O autor reserva outros direitos de publicação e nenhuma parte desta dissertação de mestrado pode ser reproduzida sem a autorização por escrito do autor.

klysnney@gmail.com

Brasília, DF – Brasil

RESUMO

O termo esquizofrenia (*esquizo*=divisão, *phrenia*=mente) foi cunhado por Bleuler (1857-1939) e caracteriza um transtorno mental, geralmente de início insidioso, cujos principais aspectos observados são: alucinações e delírios, transtornos de pensamento e fala, perturbação das emoções, afeto e déficits cognitivos. Seus primeiros sinais e sintomas, via de regra, ocorrem no início da adolescência ou da vida adulta, afetando sobremaneira a qualidade de vida do paciente e de seus familiares. A doença é envolvida de muitos tabus, possuindo muitas lacunas a serem preenchidas. Uma dessas lacunas está relacionada ao diagnóstico. Atualmente, o diagnóstico da doença é fundamentado no quadro clínico apresentado pelo próprio paciente por meio de uma entrevista padronizada baseada no DSM-V- Manual de Diagnóstico e Estatístico de Transtornos Mentais. Todavia, esta entrevista torna-se subjetiva devido a uma possível inconsistência das informações fornecidas por pacientes que sofrem de delírio e alucinação. Outro ponto importante é que o quadro clínico apresentado se sobrepõe ao de outros transtornos, dificultando seu diagnóstico e, conseqüentemente, a vida dos portadores de esquizofrenia. Ademais, nas últimas décadas, pesquisadores afirmam que existem desvios anatômicos da normalidade que podem ou não estar ligadas à doença como, por exemplo, a dilatação do sistema ventricular. Todas estas informações foram obtidas por meio de análise de imagens de ressonância magnética.

Diante deste contexto, com as imagens adquiridas por meio da ressonância magnética fornecidas pela *Biomedical Informatics Research Network*, BIRN, que é um banco de dados projetado para fins de compartilhamento de dados biomédicos, foi possível desenvolver um algoritmo que serve de auxílio ao diagnóstico que extrai parâmetros, de forma automática, do sistema ventricular cerebral com o intuito de verificar alterações anatômicas que possam estar correlacionadas com a presença ou não da esquizofrenia. Desta forma, foi viável a utilização de ferramentas na área de processamento de imagens como a DWT (do inglês, *Discrete Wavelet Transform*), a DT-CWT (do inglês, *Dual-Tree Complex Wavelet Transform*) e a Transformada *Contourlet* com a finalidade de se obter o contorno do sistema ventricular. Este será nosso objeto de interesse. Esta região, como dito anteriormente, foi escolhida com a intenção de se analisar uma possível ligação entre a doença e sua dilatação. Em seguida, uma segmentação baseada em GLCM, Matriz de Coocorrência de Níveis de Cinza, foi aplicada objetivando delinear o sistema ventricular. Esta etapa do projeto foi de fundamental importância, já que era essencial uma demarcação coerente para que, na classificação, os parâmetros extraídos fossem fidedignos e confirmassem se a averiguação da presença da doença por meio do sistema ventricular era válida. Além disso, a classificação, que usou 70% dos parâmetros para treinamento e 30% para validação, serviu também para validar a segmentação. Outras ferramentas utilizadas no processo foram a morfologia matemática e os superpixels.

Após a classificação, foram obtidos resultados como a confirmação diagnóstica dos paci-

entes portadores de esquizofrenia com especificidade de 75% e precisão de 71%. Além disso, é reduzida a chance de falso-negativo, haja vista a acurácia de 70%. Com estes resultados foi possível validar a segmentação por meio da GLCM, pois a dilatação do sistema ventricular se mostrou uma característica que distingue o grupo de controle do grupo de portadores de esquizofrenia. Por fim, as imagens segmentadas foram reconstruídas, buscando apresentar os cortes axiais, coronais e sagitais, que também ratificam a segmentação das imagens ao apresentar o sistema ventricular realçado.

ABSTRACT

The term schizophrenia (*esquizo* = division, *phrenia* = mind) was coined by Bleuler (1857-1939) and characterizes a mental disorder, usually of insidious onset, whose main aspects observed are: hallucinations and delusions, thought and speech disorders, disturbed emotions, affect and cognitive deficits. Its first signs and symptoms, as a rule, occur in early adolescence or adulthood, greatly affecting the quality of life of the patient and his family. The disease is involved in many taboos, with many gaps to be filled. One of these gaps is related to the diagnosis. Currently, the diagnosis of the disease is based on the clinical picture presented by the patient himself through a standardized interview based on the DSM-V - Diagnostic and Statistical Manual of Mental Disorders. However, this interview becomes subjective due to a possible inconsistency in the information provided by patients suffering from delirium and hallucination. Another important point is that the clinical picture presented overlaps with that of other disorders, making it difficult to diagnose and, consequently, the lives of people with schizophrenia. In addition, in recent decades, researchers claim that there are anatomical deviations from normality that may or may not be linked to the disease, such as dilation of the ventricular system. All this information was obtained through the analysis of magnetic resonance images.

In this context, with the images acquired through the magnetic resonance provided by the textit Biomedical Informatics Research Network, BIRN, which is the database designed for the purpose of sharing biomedical data, it was possible to develop an algorithm that will serve as an aid to the diagnosis that automatically extracts parameters from the cerebral ventricular system in order to check for the presence or absence of schizophrenia. Thus, it was possible to use tools in the area of image processing such as DWT (*Discrete Wavelet Transform*), DT-CWT (*Dual- Tree Complex Wavelet Transform*) and *Contourlet Transform* in order to obtain the contour of the ventricular system. This will be our object of interest. This region, as previously mentioned, was chosen with the intention of analyzing a possible link between the disease and its dilation. Then, a segmentation based on GLCM, Gray Levels Cooccurrence Matrix, was applied in order to outline the ventricular system. This stage of the project was of fundamental importance, since a coherent demarcation was essential so that, in the classification, the extracted parameters were reliable and confirmed whether the presence of the disease through the ventricular system was valid. In addition, the classification that used 70 % of the parameters for training and 30 % for validation, also served to validate the segmentation. Other tools used in the process were mathematical morphology and superpixels.

After classification, results were obtained, such as the diagnostic confirmation of schizophrenic patients with specificity of 75 % and precision of 71 %. In addition, the chance

of false negative with an accuracy of 70 % is reduced. With these results it was possible to validate the segmentation through GLCM, because the dilation of the ventricular system proved to be a characteristic that distinguishes the control group from the group of schizophrenia patients. Finally, the segmented images were reconstructed, seeking to present the axial, coronal and sagittal sections, which also ratify the segmentation of the images when presenting the enhanced ventricular system.

SUMÁRIO

1	Introdução	1
1.1	Contextualização	1
1.2	Definição do Problema Científico	2
1.3	Justificativa	2
1.4	Objeto de Estudo	3
1.5	Objetivo	3
1.5.1	Objetivo Geral	3
1.5.2	Objetivos Específicos	3
2	Fundamentação Teórica	4
2.1	Esquizofrenia	4
2.1.1	Definição e Histórico	4
2.1.2	Diagnóstico e Sintomas	4
2.1.3	Críticas Relacionadas ao Diagnóstico	5
2.1.4	Alterações Cerebrais em Portadores de Esquizofrenia	6
2.1.5	Sistema Ventricular	7
2.2	Ressonância Magnética	8
2.2.1	Princípio Físico	8
2.2.2	Tipos de Corte	12
2.3	Transformada <i>Wavelet</i>	13
2.3.1	A Transformada de <i>Fourier</i> - FT	13
2.3.2	Transformada <i>Wavelet</i> Contínua - CWT	13
2.3.3	Transformada <i>Wavelet</i> Discreta - DWT	15
2.3.4	Transformada <i>Wavelet</i> em Imagens	16

2.4	Transformada <i>Wavelet</i> Complexa de Árvore Dupla	18
2.4.1	Transformada <i>Wavelet</i> Complexa de Árvore Dupla Unidimensional	18
2.4.2	Transformada <i>Wavelet</i> Complexa de Árvore Dupla Bidimensional	21
2.5	Transformada <i>Contourlet</i>	24
2.6	Matriz de Coocorrência de Níveis de Cinza	27
2.7	Morfologia Matemática	29
2.7.1	Erosão e Dilatação Morfológica	30
2.7.2	Abertura e Fechamento Morfológico	32
2.7.3	Transformada <i>Top-Hat</i> e <i>Bottom-Hat</i>	32
2.7.4	Complemento e Diferença	33
2.8	Superpixels	33
2.9	Descritores	34
2.10	Máquinas de Vetor de Suporte	34
2.10.1	SVM e sua aplicação em dados lineares	34
2.10.2	Vetor de Suporte	35
2.10.3	O Hiperplano de separação	35
2.10.4	SVM e sua aplicação em dados não lineares	36
2.10.5	Funções <i>Kernel</i>	37
3	Materiais e Métodos	38
3.1	Diagrama Geral do Sistema	38
3.2	Experimentos Computacionais	39
3.3	Transformada <i>Wavelet</i> , DT-CWT e Transformada <i>Contourlet</i> Para a Extração de Bordas ou Contornos	40
3.3.1	Processamento com DWT - Transformada <i>Wavelet</i>	40
3.3.2	Processamento com DT-CWT - Transformada <i>Wavelet</i> Complexa de Árvore Dupla	40
3.3.3	Processamento com Transformada <i>Contourlet</i>	40
3.4	GLCM - Matriz de Coocorrência de Níveis de Cinza	41
3.5	Máscara de SuperPixels	41

3.6	Máscara Morfológica	41
3.7	Estimativa da Área do Cérebro	42
3.8	Descritores Para Classificação	43
3.9	Classificação de Padrões Utilizando SVM	43
4	Resultados e Discussões	45
4.1	Resultados da Aplicação das Transformadas	45
4.1.1	Resultado da Transformada <i>Wavelet</i>	45
4.1.2	Resultado da DT-CWT	48
4.1.3	Resultado da Transformada <i>Contourlet</i>	51
4.2	Inserção dos Contornos para Cálculo da GLCM e Segmentação	54
4.3	Criação de Máscara Automática Utilizando SuperPixels e Morfologia Matemática	56
4.4	Área do Cérebro	60
4.5	Extração de Parâmetros e Classificação Utilizando SVM	61
4.6	Cortes Transversal, Sagital e Coronal	63
4.6.1	Corte Transversal	63
4.6.2	Corte Sagital	65
4.6.3	Corte Coronal	66
5	Conclusão	69
	Lista de Referências	70

LISTA DE TABELAS

2.1	Tempo de relaxação de T_1 e T_2 para um campo magnético de 1,5T. . . .	11
3.1	Adaptação da matriz confusão utilizada na avaliação de classificadores . .	43
4.1	Os parâmetros extraídos das GLCM's.	54
4.2	Resultado da Segmentação GLCM para cada Transformada.	55
4.3	Resultado da Segmentação Baseada em Superpixels do Retângulo Selecionado.	57
4.4	Imagens com exemplos de resultados do processamento aplicado para obtenção da Máscara Morfológica.	58
4.5	Imagens com exemplos de resultados do processamento aplicado para obtenção dos ventrículos isolados.	59
4.6	Imagens com exemplos de resultados do processamento aplicado para obtenção da estimativa da área do cérebro.	60

LISTA DE FIGURAS

2.1	Ventrículo de um paciente saudável, à esquerda, e de um portadores de esquizofrenia, à direita.	7
2.2	Estrutura ventricular	7
2.3	Estrutura ventricular tendo como base o crânio	8
2.4	Momento magnético em x em resposta a um campo magnético de perturbação em radiofrequência e em sentido perpendicular ao campo estático.	10
2.5	Momento magnético em y em resposta a um campo magnético de perturbação em radiofrequência e em sentido perpendicular ao campo estático.	10
2.6	Constante de decaimento FID em resposta a um campo magnético de perturbação em radiofrequência e em sentido perpendicular ao campo estático.	11
2.7	Planos anatômicos.	12
2.8	Tipos de cortes: à esquerda, corte transversal, ao centro, corte coronal e, à direita, corte sagital.	12
2.9	Representação tempo-frequência da WTF.	14
2.10	Fator de escala de uma função <i>wavelet</i>	15
2.11	Fator de deslocamento. Acima, uma função <i>wavelet</i> e, abaixo, a mesma função deslocada.	16
2.12	Plano tempo-frequência e as representações das caixas para a Transformada <i>wavelet</i>	17
2.13	Árvore de decomposição <i>wavelet</i>	18
2.14	Árvore de decomposição <i>wavelet</i>	18

2.15	Decomposição em dois níveis. A imagem HH corresponde a utilização de filtros passa-altas nas linhas e colunas, oferecendo detalhes diagonais da imagem. A imagem LH corresponde a utilização dos filtros passa-baixas e passa-altas nas linhas e colunas, respectivamente, concendendo detalhes horizontais. A imagem HL corresponde a utilização dos filtros passa-altas e passa-baixas nas linhas e colunas, conferindo detalhes verticais. Por fim, a imagem LL é decomposta, passando por mais um processo de decomposição, gerando as imagens LLLL, LLHL, LLLH e LLHH, que representa a aproximação, os detalhes horizontais, os detalhes verticais e os detalhes diagonais.	19
2.16	Esquema de decomposição da DT-CWT usando árvore dupla.	21
2.17	O espectro <i>wavelet</i> complexa.	22
2.18	Espectro da parte real da <i>wavelet</i>	22
2.19	Orientação da parte real da DT-CWT. (a) <i>wavelets</i> no domínio do espaço. (b) espectro idealizado para as <i>wavelets</i> no dompinio da frequência . . .	23
2.20	Respostas impulsivas das transformadas DT-CWT, com seis orientações, e DWT, com três orientações.	24
2.21	Banco de Filtros de Contorno: Primeiramente, ocorre a decomposição em múltiplas escalas em bandas de oitavas pela pirâmide laplaciana e, em seguida, o banco de filtros direcionais é aplicado.	25
2.22	Decomposição gerada pelo filtro <i>Quincunx</i>	26
2.23	Partições de frequências gerada para l-3, isto é, oito partições.	26
2.24	Esquerda: Imagem original. Direita: Imagem rotacionada e subamostrada.	26
2.25	Como gerar uma matriz de coocorrência.	28
2.26	Orientação dos ângulos da GLCM.	28
2.27	(a) Conjunto A. (b) Elemento Estruturante. (c) Erosão A por B. (d) Elemento estruturante alongado. (e) Erosão A por B utilizando o elemento estruturante alongado.	30
2.28	(a) Conjunto A. (b) Elemento Estruturante. (c) Dilatação de A por B. (d) Elemento estruturante alongado. (e) Dilatação de A por B utilizando o elemento estruturante alongado.	31
2.29	À esquerda, o complemento. À direita, a diferença	33
2.30	Segmentação utilizando superpixel.	34

2.31	Exemplo de classificação SVM, separando duas classes.	35
2.32	Dois separadores de classes e suas margens com vetores de suporte. Estes são vetores do espaço amostral mais próximo da função de separação. . .	35
2.33	Espaço amostral em ambiente tridimensional possui função de separação 2D.	36
2.34	Redistribuição dos dados de entrada, que, coletados em espaço 2D, foram redistribuídos em espaço 3D por aplicação de uma função Kernel.	36
2.35	Espaço amostral inicial onde as classes se distribuem de maneira não-linear à esquerda. À direita, a função Kernel aplicada para se tornar possível a delimitação do hiperplano de separação.	37
3.1	Estrutura geral do método implementado.	38
3.2	Exemplo de uma imagem de RM fornecida pela BIRN.	39
3.3	Método para a máscara de superpixels.	41
3.4	Método morfológico para isolamento do ventrículo.	42
3.5	Método utilizado para encontrar a área do cérebro.	42
4.1	Processamento de imagem de RM com a DWT. A imagem no canto superior esquerdo indica a aproximação com resolução 32x32. As três imagens que a cerca indicam os detalhes horizontais (baixo), verticais (lado), diagonais (diagonal), sendo todos com uma resolução de 32x32. Da mesma forma, as imagens ao lado indicam suas respectivas imagens de detalhes com uma resolução de 64x64 e 128x128.	46
4.2	Imagem de RM reconstruída após três níveis de decomposição DWT e a eliminação dos coeficientes de aproximação	47
4.3	Perspectiva tridimensional dos contornos destacados da imagem de RM após processamento com a DWT. Entretanto, os contornos externos igualmente presentes.	48
4.4	Processamento de imagem de RM com a DT-CWT. A imagem mostra a decomposição em três níveis da parte complexa.	49
4.5	Contornos destacados da imagem de RM após processamento com a DT-CWT. Entretanto, os contornos externos mostram-se igualmente presentes.	49
4.6	Imagem de RM reconstruída após a aplicação da DT-CWT evidenciando os contornos.	50

4.7	Perspetiva tridimensional dos contornos destacados da imagem de RM após o processamento com a DT-CWT.	51
4.8	Processamento de imagem de RM com a Transformada <i>Contourlet</i> . Nesta imagem, pequenos coeficientes são mostrados em preto, enquanto grandes coeficientes são mostrados em branco.	52
4.9	Contornos destacados da imagem de RM reconstruída após a aplicação da Transformada <i>Contourlet</i>	53
4.10	Perspectiva tridimensional dos contornos destacados da imagem de RM após o processamento da Transformada <i>Contourlet</i>	53
4.11	Histograma de Acurácia.	61
4.12	Histograma de Precisão.	62
4.13	Histograma de Sensibilidade.	62
4.14	Histograma de Especificidade.	63
4.15	Corte Transversal: à esquerda, grupo de controle; à direita, grupo de portadores de esquizofrenia.	64
4.16	Corte Transversal com Ventrículo: à esquerda, grupo de controle; à direita, grupo de portadores de esquizofrenia.	64
4.17	Corte Transversal com Ventrículo Segmentado: à esquerda, grupo de controle; à direita, grupo de portadores de esquizofrenia.	65
4.18	Corte Sagital: à esquerda, grupo de controle; à direita, grupo de portadores de esquizofrenia.	65
4.19	Corte Sagital com Ventrículo do Grupo de Controle: à esquerda, as imagens de RM; à direita, as imagens de RM segmentadas.	66
4.20	Corte Sagital com Ventrículo do Grupo de portadores de esquizofrenia: à esquerda, as imagens de RM; à direita, as imagens de RM segmentadas.	66
4.21	Corte Coronal: à esquerda, grupo de controle; à direita, grupo de portadores de esquizofrenia.	67
4.22	Corte Coronal com Ventrículo Segmentado do Grupo de Controle: à esquerda, as imagens de RM; à direita, as imagens de RM segmentadas.	67
4.23	Corte Coronal com Ventrículo Segmentado do Grupo de portadores de esquizofrenia: à esquerda, as imagens de RM; à direita, as imagens de RM segmentadas.	68

LISTA DE NOMENCLATURAS E ABREVIACOES

- B* – *Campo Magnético*
- CT* – *Contourlet Transform (Transformada de Contourlet)*
- CWT* – *Continuous Wavelet Transform (Transformada Wavelet Contínua)*
- DFB* – *Directional Filter Bank (Banco de Filtros Direcionais)*
- DSM* – *Diagnostic and Statistical Manual of Mental Disorders*
(Manual Diagnóstico e Estatístico de Transtornos Mentais)
- DT-CWT* – *Dual-tree Wavelet Transform (Transformada Wavelet Complexa de Árvore Dupla)*
- DWT* – *Discrete Wavelet Transform (Transformada Wavelet Discreta)*
- ES* – *Structuring element (Elemento Estruturante)*
- FB* – *Filter Banks (Banco de Filtros)*
- FID* – *Free Induction Decay (Sinal de Decaimento Livre)*
- FN* – *False Negative (Falso Negativo)*
- FP* – *False Positive (Falso Positivo)*
- GLCM* – *Gray-Level Co-Occurrence Matrix (Matriz de co-ocorrência de níveis de cinza)*
- LP* – *Laplacian Pyramid (Pirâmide Laplaciana)*
- RBF* – *Radial Basis Function (Função de Base Radial)*
- RF* – *Radiofrequency (Rádio Frequência)*
- RM* – *Magnetic Resonance (Ressonância Magnética)*
- ROI* – *Region of Interest (Região de Interesse)*
- RP* – *Perfect Reconstruction (Reconstrução Perfeita)*
- SVM* – *Support Vector Machine (Máquina de Vetores de Suporte)*
- TF* – *Fourier Transform (Transformada de Fourier)*
- T1* – *Return of the Magnetization Vector (Retorno do Vetor Magnetização)*
- T2* – *Magnetization Reduction Time in the Transversal Plane*
(Tempo de redução da magnetização no plano transversal.)
- V* – *Magnetization Vector (Vetor Magnetização)*
- VN* – *True Negative (Verdadeiro Negativo)*
- VP* – *True Positive (Verdadeiro Positivo)*
- WFT* – *Windowed Fourier Transform (Transformada de Fourier por Janelas)*

LISTA DE SÍMBOLOS

γ	–	<i>Razão Giromagnética</i>
Ω	–	<i>Frequência</i>
ψ	–	<i>Wavelet</i>
ξ	–	<i>Deslocamento de janela no sinal</i>
a	–	<i>Parâmetro de escala</i>
b	–	<i>Parâmetro de deslocamento</i>
ζ	–	<i>Diferentes larguras em wavelets</i>
η	–	<i>Coefficientes de escala</i>
ϕ	–	<i>Funções de escala</i>
ϑ	–	<i>Tonalidade de cinza</i>
κ	–	<i>Tonalidade de cinza</i>
ι	–	<i>Acurácia</i>
ϖ	–	<i>Precisão</i>
ρ	–	<i>Sensibilidade</i>
δ	–	<i>Especificidade</i>
τ	–	<i>Kernel Linear</i>
Γ	–	<i>Kernel Polinomial</i>
Φ	–	<i>Kernel RBF</i>
Υ	–	<i>Kernel Sigmóide</i>

1 INTRODUÇÃO

1.1 CONTEXTUALIZAÇÃO

A esquizofrenia é um dos principais e mais complexos transtornos mentais, afetando significativamente a qualidade de vida do paciente [17]. A doença é caracterizada por uma variedade de sintomas como delírios, alucinações, fala e comportamento desorganizados ou capacidade cognitiva prejudicada, interferindo na capacidade do portador de participar de eventos sociais e de estabelecer relacionamentos [34]. Mesmo diante desse impacto social, continua sendo uma doença envolvida de muitos tabus e discriminação [5]. Atualmente, é uma doença mental sem perspectiva de cura, mas o tratamento terapêutico torna os quadros mais estáveis e pode proporcionar uma melhora na qualidade de vida [17].

Atualmente, o diagnóstico é realizado com base nas manifestações clínicas da doença. Exames laboratoriais ainda não permitem o reconhecimento, servindo apenas para exclusão de outras alterações que possuem características semelhantes à esquizofrenia. A doença é um alvo cada vez maior de estudo. Apesar dos exames laboratoriais não diagnosticarem a presença ou a ausência da doença, pesquisas recentes apontam que existem anormalidades estruturais no cérebro do portador. Estas informações, das diferenças estruturais cerebrais, foram adquiridas por meio de imagens por ressonância magnética [36].

A ressonância magnética (RM) revolucionou o estudo da morfologia do encéfalo. A possibilidade de se realizar cortes em qualquer orientação pretendida e a diferenciação entre as substâncias branca e cinzenta proporcionaram, por meio da RM, a capacidade de se gerar imagens de encéfalo, aproximando-se à de um corte de peça anatômica [20].

As imagens de RM obtidas, a partir de encéfalos de pacientes portadores de esquizofrenia, demonstraram diferenças estruturais em relação a grupos de controle [48]. Desta maneira, a área de processamento de imagens pode ser utilizada como ferramenta auxiliar na análise destas alterações. O interesse no campo do processamento de imagens provém de duas áreas fundamentais: uma melhor interpretação visual humana e o processamento de dados de imagens. Nesta pesquisa, a primeira parte irá ser analisada por meio da segmentação e a separação do sistema ventricular, enquanto a segunda será aplicada por meio de uma análise dos dados extraídos da região de interesse. Este trabalho visa uma contribuição para a detecção da doença, auxiliando profissionais da saúde.

1.2 DEFINIÇÃO DO PROBLEMA CIENTÍFICO

Atualmente, o diagnóstico da esquizofrenia se baseia no quadro clínico apresentado pelo paciente [34]. Quanto à sua etiologia, quantidades crescentes de dados apontam para sobreposições de fatores tais como neurobiológicos, genéticos e ambientais, gerando dificuldades no diagnóstico. Portanto, as evidências apontam que classificações futuras dos distúrbios psicóticos, afetivos e de desenvolvimento deverão ser embasadas, principalmente, em bases biológicas [14]. Além disso, é fundamental ressaltar que o diagnóstico é baseado em uma entrevista minuciosa com pacientes e familiares, fundamentado no DSM-V, que é o *Diagnostic and Statistical Manual of Mental Disorders*, que torna o processo subjetivo e complexo [14].

Por ser ainda uma doença de difícil detecção, a esquizofrenia traz, aos pacientes e familiares, impactos sociais e econômicos [2]. Então, o estudo da doença é de extrema importância. A esquizofrenia é uma desordem mental que ainda possui lacunas a serem preenchidas no campo do conhecimento. A ciência busca algumas soluções. Um exemplo é o próprio diagnóstico da doença [13]. Logo, o desenvolvimento de um algoritmo que isole o sistema ventricular cerebral de imagens de RM, segmentando-o de forma precisa a fim de extrair características que possam validar a presença ou não da doença se faz necessário. Esta ferramenta servirá de auxílio aos profissionais de saúde.

1.3 JUSTIFICATIVA

O diagnóstico é realizado clinicamente com base na história e no exame do estado mental, não possuindo testes diagnósticos ou biomarcadores a fim de fornecer uma segurança para a tomada de decisões ou para pesquisas biológicas e epidemiológicas [46] [8]. Todavia, pesquisas apontam déficits estruturais nos portadores de esquizofrenia como o aumento do ventrículo cerebral, volume reduzido da substância cinzenta e perturbação da integridade da substância branca e redução da espessura do córtex cerebral [32] [12] [26].

O auxílio no diagnóstico de esquizofrenia vem sendo alvo de estudos na Universidade de Brasília. Nos últimos anos, os alunos estiveram estudando maneiras de avançar no tema. Em sua pesquisa, Siqueira e Vergara buscaram desenvolver uma ferramenta semiautomática na qual a seleção de cortes era fundamental para o funcionamento [25]. Já Cruz fez uma seleção de cortes axiais e extraiu manualmente as características cerebrais [9]. O terceiro trabalho que procurou avançar no tema foi de Marcella Nunes. Foi desenvolvida uma ferramenta que propõe realizar a extração de medidas de imagens de diversos cortes, utilizando cada informação em um estudo de associação com a ocorrência ou não da esquizofrenia [42].

Diante desse contexto, onde há dificuldades de verificação da doença e a confirmação de alterações anatômicas no sistema ventricular cerebral, esta pesquisa busca desenvolver um algoritmo que extraia parâmetros automaticamente dos ventrículos laterais de portadores da esquizofrenia e de pessoas saudáveis com o objetivo de averiguar a ocorrência ou não da doença por meio de RM fornecidas pela BIRN, *Biomedical Research Network*, que é um banco de dados biomédicos.

1.4 OBJETO DE ESTUDO

A esquizofrenia é considerada uma doença de grande impacto social, pois causa comportamentos psicóticos e diversas dificuldades ligadas aos relacionamentos interpessoais, ao processamento de informações, soluções de problemas e outras capacidades mentais. A doença tem o seu início na adolescência e no início da vida adulta, com grande prejuízo na adequação social [40].

Diante dos obstáculos encontrados para o diagnóstico da esquizofrenia, é plausível a busca por ferramentas que auxiliem no reconhecimento desta doença. Assim, as técnicas na área de processamento de imagens podem ser utilizadas objetivando contribuir de maneira significativa no processo do desenvolvimento de um diagnóstico mais preciso.

1.5 OBJETIVO

1.5.1 Objetivo Geral

A pesquisa busca desenvolver um algoritmo que auxilie no aprimoramento de um diagnóstico mais confiável. As diversas etapas que este trabalho possui têm como meta contribuir no processo de melhoria tanto por meio de uma segmentação que descreva o sistema ventricular de forma mais lúdica quanto na extração de características e, consequentemente, em sua classificação com a intenção de validar a presença da doença. Além disso, o trabalho servirá como apoio a futuras pesquisas que pretendam colaborar no estudo na área de esquizofrenia.

1.5.2 Objetivos Específicos

1. Desenvolvimento de um algoritmo que isole o sistema ventricular.
2. Extração de características.
3. Classificação das imagens segundo presença ou não da doença.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 ESQUIZOFRENIA

2.1.1 Definição e Histórico

A esquizofrenia é um transtorno mental complexo. Configura-se como uma dissociação da ação e do pensamento, sendo suas principais manifestações os sintomas negativos ou déficits cognitivos, delírios e alucinações [38]. Dado todo o estigma que as doenças psiquiátricas possuem e o comportamento social fora dos padrões da normalidade, o portador da esquizofrenia, juntamente com os seus familiares, sofrem um forte impacto social negativo por conta dos sintomas da doença e, além disso, do preconceito [35].

Historicamente, há uma construção do conceito de esquizofrenia. No final do século XIX, Emil Kraepelin fez uma descrição, até então definida, como demência precoce. Para ele, as principais particularidades se davam devido ao enfraquecimento das atividades emocionais e a perda da unidade interna do intelecto. Outro cientista de grande destaque foi Eugen Bleuler, que, assim como Kraepelin, influenciou o conceito atual da esquizofrenia [17]. Ademais, uma nova explicação foi dada quando ele passou a explicar o distúrbio por meio da psicologia e identificou a patologia mediante quatro sintomas essenciais: afrouxamento de associações, afeto, ambivalência e autismo. Estes sinais associados aos delírios e alucinações são características da esquizofrenia [39].

2.1.2 Diagnóstico e Sintomas

Atualmente, o diagnóstico da doença é baseado em uma entrevista padronizada com a utilização de alguns critérios como deficiência cognitiva, discurso desorganizado, comportamento inadequado, deterioração da aparência pessoal, pensamento suicida e atividade motora anormal [30].

O diagnóstico realizado para assegurar a presença da doença no paciente é feito por meio da confirmação de algumas características determinadas pelo Manual Diagnóstico e Estatísticos de Transtornos Mentais V, conhecido como DSM-V. Os critérios estabelecidos são:

- a) Dois dos itens a seguir devem se manifestar significativamente durante um mês, sendo que pelo menos um deles deve ser o delírio, a alucinação ou o discurso desorganizado.
1. Delírios: Estes são crenças que não são passíveis de alterações mesmo diante de evidências.
 2. Alucinações: Perceber a presença de um objeto ou indivíduo sem a presença dele. A mais comum no caso da esquizofrenia é a auditiva.
 3. Discurso Desorganizado: Quando o indivíduo transita de assunto não dando sentido algum ao conteúdo expresso.
 4. Comportamento Grosseiramente Desorganizado ou Catatônico: A pessoa é imatura e apática, possui dificuldades para tarefas diárias simples, torna-se desleixada, grita e insulta pessoas, além de mais características inerentes à doença.
 5. Sintomas Negativos: Ocorre o desinteresse da vida, a interação com as outras pessoas diminuem, existe dificuldade de iniciar e continuar tarefas planejadas. Tais sintomas estão ligados às emoções e comportamentos.
- b) Por um período após o surgimento da perturbação, deve haver uma queda acentuada no nível de relações interpessoais, no trabalho e no autocuidado.
- c) Sinais contínuos de perturbação persistem durante, no mínimo, seis meses. Dentro desse período, deve estar incluso pelo menos um mês de sintomas que satisfazem o critério A.
- d) Transtorno Esquizoafetivo, depressivo ou transtorno bipolar são descartados, já que não há episódio depressivo ou maníaco concomitantemente aos sintomas de fase ativo e, além disso, em casos de momento de humor na fase ativa, seria por pouco tempo.
- e) Se existe histórico de transtorno de espectro autista ou transtorno da comunicação iniciado na infância, o diagnóstico adicional de esquizofrenia deve ser feito somente se houver delírios ou alucinações [3].

2.1.3 Críticas Relacionadas ao Diagnóstico

Alguns pesquisadores criticam a forma de diagnóstico da doença devido à subjetividade dos dados fornecidos pelos pacientes. Stephen Wong, em seu artigo intitulado *A critique of the Diagnostic Construct Schizophrenia*, relata sobre alguns tópicos do DSM-V como as alucinações, por exemplo, que são de difícil detecção. Para o autor, a alucinação

é uma sensação conhecida apenas pelo paciente, não podendo ser verificada por um observador externo. Logo, este sintoma é evento privado, não podendo ser associado a condições físicas como a dor, citando caso análogo. Na melhor das hipóteses, é possível averiguar as alucinações devido ao comportamento verbal ou motor aberto, isto é, a gesticulação ou conversas no espaço vazio. Mesmo em tais circunstância, a única aferição possível são os atos observados.

Outra crítica feita pelo autor é relacionada ao tempo de manifestação das características da patologia. Os sintomas da esquizofrenia devem se manifestar durante um mês e os sinais contínuos do distúrbio precisam persistir por seis meses. Quando o assunto é o transtorno esquizofreniforme, as características precisam se manifestar durante o período de um mês, assim como a esquizofrenia, mas os sinais contínuos devem ser menores que seis meses. O problema está na não explicação da diferenciação entre seis meses exatos que separam os dois diagnósticos. Além disso, a única informação dada para diferenciar as duas patologias encontra-se no fato de que o delírio acentuado no nível de funcionamento de áreas como trabalho, relações interpessoais e autocuidado está presente apenas na esquizofrenia e não no transtorno esquizofreniforme [60].

2.1.4 Alterações Cerebrais em Portadores de Esquizofrenia

Diante deste contexto, onde se pretende investigar critérios e métodos objetivos, é necessário que as próximas etapas no avanço de investigação da doença seja fundamentada em categorias e dimensões biológicas [14]. Nos últimos anos, pesquisadores detectaram anormalidades cerebrais que podem estar ligadas à doença, como redução no volume do encéfalo, além de substâncias cinzentas e brancas anômalas [26]. Entretanto, os achados mais consistentes encontram-se no aumento dos ventrículos e da perda da substância cinzenta, retomando os conceitos sobre degeneração neuronal estabelecida por Kraepelin [59]. Tais alterações converteram-se significativamente em psicose [32]. A Figura 2.1 apresenta uma RM cerebral que compara os ventrículos de portadores de esquizofrenia e de um paciente saudável.

Em uma pesquisa realizada pela Universidade de Califórnia, uma comparação entre os ventrículos do grupo de portadores de esquizofrenia com o de controle resultou em uma diferença significativa entre as categorias. O primeiro obteve o resultado de 6,35, enquanto o segundo 4,77. Estes números referem-se à razão entre a área do ventrículo e a área total do cérebro. O aumento do ventrículo permanece como biomarcador neurológico e um dos mais frequentes da doença [49].

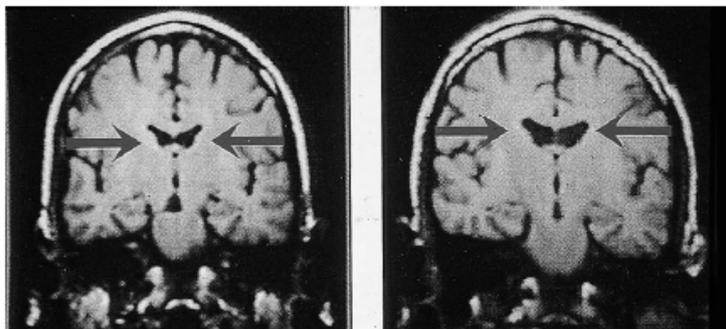


Figura 2.1. Ventrículo de um paciente saudável, à esquerda, e de um portador de esquizofrenia, à direita. Figura adaptada de [38].

2.1.5 Sistema Ventricular

O sistema ventricular é uma estrutura de comunicação de cavidades revestidas de epêndima e preenchida por líquido cefalorraquidiano, que é um líquido que serve para fornecer nutrientes. Este sistema é composto por dois ventrículos laterais, o terceiro ventrículo, o aqueduto cerebral e o quarto ventrículo, conforme exibido na Figura 2.2 e 2.3 [58].

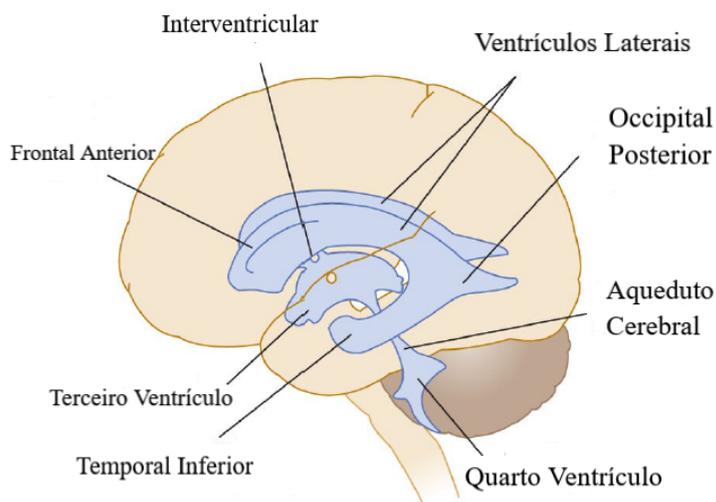


Figura 2.2. Estrutura ventricular. Figura adaptada de [58].

Estas informações cerebrais obtidas para o avanço da pesquisa são o resultado da revolução trazida pela implementação da ressonância magnética, que possibilitou a realização de cortes em diversas orientações. Essa ferramenta viabilizou a análise de detalhes que aproximaram-se da estrutura anatômica [20].

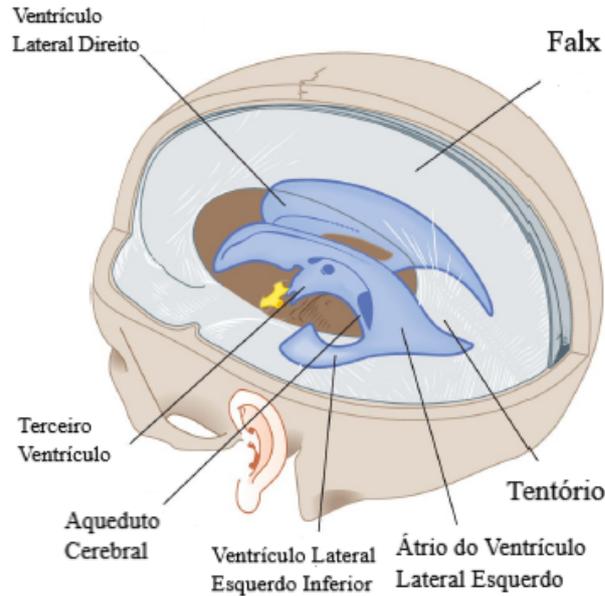


Figura 2.3. Estrutura ventricular tendo como base o crânio. Figura adaptada de [58].

Essa interação cria situações para o envio de pulsos da radiofrequência (RF), que é modificado e, posteriormente, captado por um receptor que, neste caso, é uma antena o bobina.

2.2 RESSONÂNCIA MAGNÉTICA

A ressonância magnética foi proposta pelo pesquisador C.J. Gorter e aplicadas por Bloch e Purcell, após a segunda guerra mundial, objetivando o estudo das propriedades físico-químicas da matéria. Os primeiros experimentos eram de proporções pequenas, usando ímãs pequenos e feixes de partículas atômicas que atravessavam uma câmara a vácuo. Logo, após o prosseguimento das pesquisas, alguns tecidos humanos e de animais foram aplicados na RM. Todavia, o seu uso clínico na geração de imagens ocorreu a partir de 1973. Este avanço ocorreu devido à sugestão Paul Lauterbur na utilização de gradientes de campo magnético, gerando a codificação do posicionamento espacial do sinal de RM detectado por conta das associações desses gradientes, resultando na obtenção anatômica em plano transversal [57].

2.2.1 Princípio Físico

A técnica de mapeamento usa as propriedades magnéticas do hidrogênio, que é o menor núcleo existente possuindo apenas um próton. A ferramenta principal que envolve a

ressonância magnética é o spin. Basicamente, quando os prótons não estão sob a ação de um campo magnético externo, os spins apontam para direções aleatórias, mas com a soma vetorial resultante sendo zero. Porém, quando o campo magnético estático uniforme B_0 é inserido, os momentos magnéticos nucleares, μ , são alinhados e um macroscópico momento magnético, denominado magnetização \mathbf{M} , é criado. Então, um campo magnético de radiofrequência polarizada, B_1 , referenciada como frequência de Lamor por $\omega = \gamma B_0$, é aplicada ortogonalmente ao campo magnético estático, gerando uma reflexão de \mathbf{M} em um plano transversal ao campo magnético estático, induzindo uma tensão na bobina [61] [25].

A equação de Bloch, que é a base da RM, afirma que

$$\frac{dM(t)}{dt} = M(t) \times \gamma B(t) - \frac{M_x(t)i + M_y(t)j}{T_2} - \frac{(M_z(t) - M_0)k}{T_1}, \quad (2.1)$$

em que \mathbf{B} é o campo magnético total, γ a taxa giromagnética e T_1 e T_2 são, respectivamente, os tempos de relaxação para componentes longitudinal e transversal de magnetização.

Na Equação 2.1, na qual $M_{xy} = M_x + iM_y$ e impondo as condições de $M_{xy}=0$, tem-se

$$M_{xy}(t) = M_0 e^{it\omega_0} e^{-\frac{t}{T_2}}. \quad (2.2)$$

Os campos magnéticos reais e imaginários de M_{xy} são funções de senos e cossenos amortecidos. Logo, o sinal M_{xy} decairá exponencialmente a uma taxa de T_2 , chamada tempo de relaxação transversal. Este é o sinal de decaimento livre da indução ou FID (do inglês, *Free Induction Decay*)

A Equação 2.1 para T e assumindo $M_z=0$, tem-se

$$M_z(t) = M_0(1 - e^{-\frac{t}{T_1}}). \quad (2.3)$$

As Figuras 2.4, 2.5 e 2.6 representam os comportamentos de M_x , M_y , M_{xy} desde $t=0$.

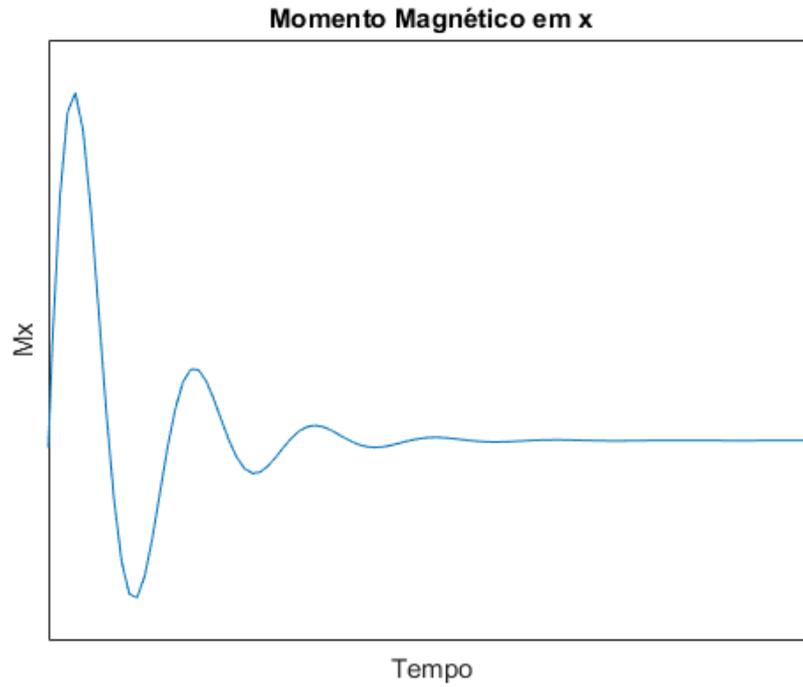


Figura 2.4. Momento magnético em x em resposta a um campo magnético de perturbação em radiofrequência e em sentido perpendicular ao campo estático.

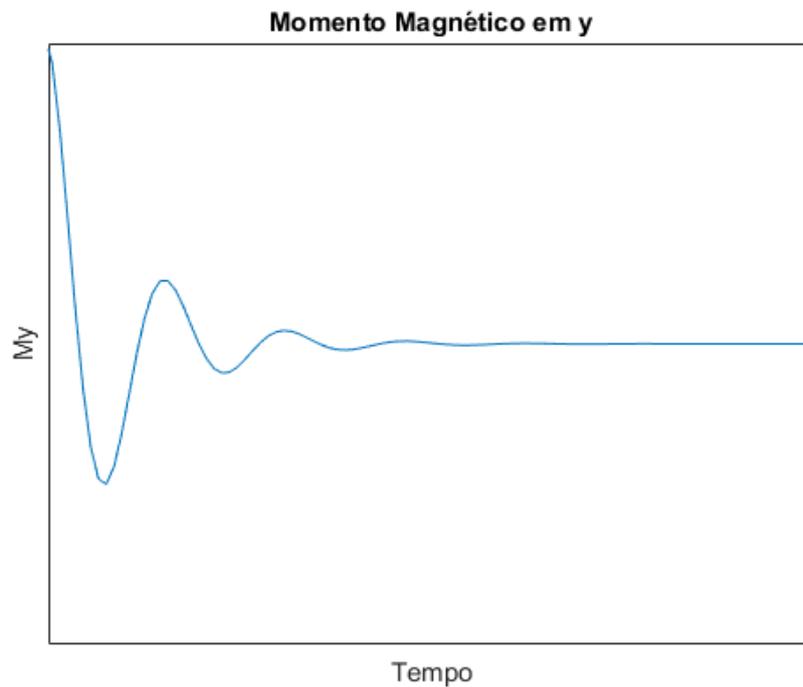


Figura 2.5. Momento magnético em y em resposta a um campo magnético de perturbação em radiofrequência e em sentido perpendicular ao campo estático.

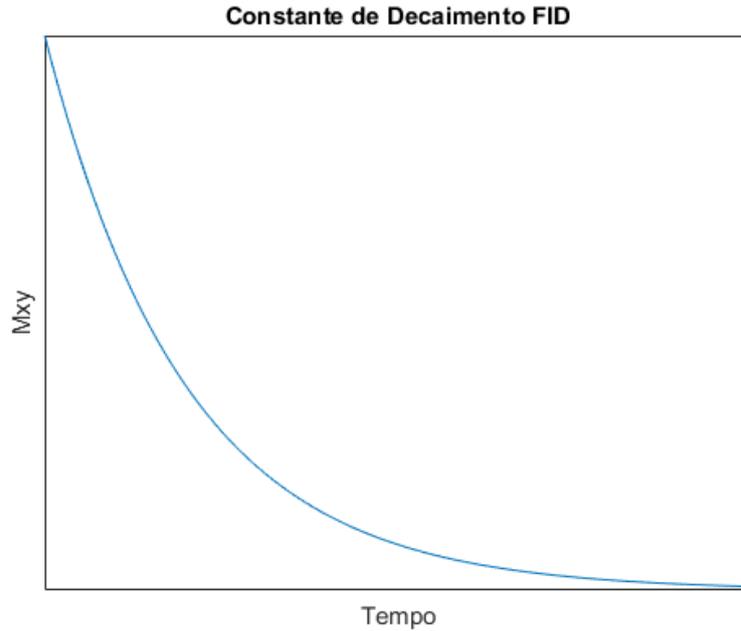


Figura 2.6. Constante de decaimento FID em resposta a um campo magnético de perturbação em radiofrequência e em sentido perpendicular ao campo estático.

Por fim, o contraste é definido pela diferença nos tempos de relaxação T_1 e T_2 entre os diferentes tecidos. A Tabela 2.1 apresenta alguns exemplos [47].

Tabela 2.1. Tempo de relaxação de T_1 e T_2 para um campo magnético de 1,5T. Fonte: [22].

Tecido	T1 (ms)	T2 (ms)
Susbstância Branca	790	90
Substância Cinzenta	920	100
Líquido (Líquor)	4000	2000
Sangue (Arterial)	1200	50
Parênquima Hepático	490	40
Miocárdio	870	60
Músculo	870	50
Lipídios	260	80

2.2.2 Tipos de Corte

Resumidamente, existem três tipos de cortes anatômicos: transversal (axial), sagital e coronal, conforme a Figura 2.7. A ressonância permite a reconstrução desses três tipos de imagens. Basicamente, é feito um imageamento volumétrico e, por computação gráfica, é feita a visualização dos diferentes cortes.

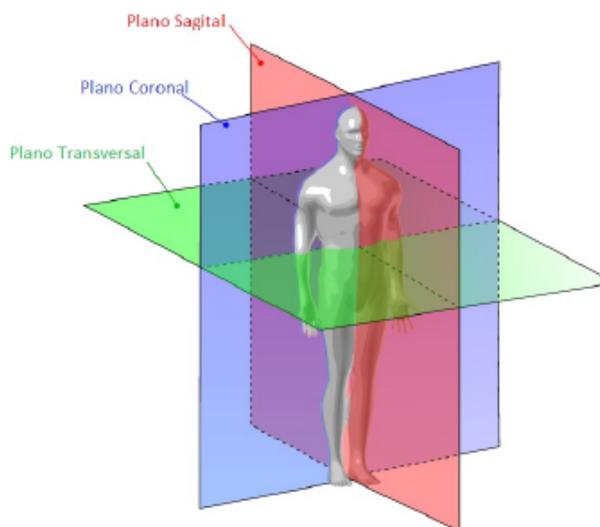


Figura 2.7. Planos anatômicos. Figura retirada de [42].

- Corte Transversal: Fraciona o corpo em partes: superior e inferior.
- Corte Sagital: Fraciona o corpo em dois lados: direito e esquerdo.
- Corte Coronal: Fraciona o corpo em duas partes: anterior e inferior.

Todos esses cortes de imagens de RM são apresentados na Figura 2.8.



Figura 2.8. Tipos de cortes: à esquerda, corte transversal, ao centro, corte coronal e, à direita, corte sagital. Figura adaptada de [44]

2.3 TRANSFORMADA *Wavelet*

2.3.1 A Transformada de *Fourier* - FT

A Transformada de Fourier (FT, do inglês *Fourier Transform*) tem como objetivo levar um sinal $f(t)$ do domínio do tempo para o domínio da frequência $\mathcal{F}(\Omega)$, tendo como funções de base senoides [48], utilizando a Equação 2.4:

$$\mathcal{F}(\Omega) = \int_{-\infty}^{\infty} f(t)e^{-j\Omega t} dt. \quad (2.4)$$

Todavia, essa transformada de sinal contínuo não relaciona intervalos de tempo com suas respectivas frequências. Logo, a fim de solucionar o problema, Dennis Gabor propôs um ajustamento na FT com a finalidade de analisar pedaços de um sinal no tempo. Esse método recebeu o nome de Transformada de Fourier por Janelas (WFT, do inglês *Windowed Fourier Transform*) e tem como principal característica o deslocamento da janela no domínio do tempo com o propósito de calcular a FT na região desejada. Então, considerando $\mathcal{J}(t)$ como uma função que corresponde a janela mencionada [10] [28], WTF é definida pela Equação 2.5:

$$\mathcal{F}(\Omega, \xi) = \int_{-\infty}^{\infty} \mathcal{J}(t - \xi)f(t)e^{-j\Omega t}, \quad (2.5)$$

em que ξ representa o deslocamento da janela no sinal. Porém, alguns problemas contínuam por conta do tamanho da janela, que permanece constante para todas as frequências, não podendo ser alterada durante análise, limitando a resolução tempo-frequência, conforme indicado na Figura 2.9.

A solução deste problema se encontra na Transformada *Wavelet*, que permite a análise multiresolução, que consiste em separar um sinal original em duas partes, por meio de ondas de diferentes escalas, que equivalem às frequências. Estas ondas são definidas a partir de uma onda fundamental chamada *Wavelet* mãe.

2.3.2 Transformada *Wavelet* Contínua - CWT

A Transformada *Wavelet* é dividida em duas categorias: a contínua e a discreta. A primeira, a Transformada *Wavelet* Contínua (*CWT*, do inglês *Continuous Wavelet Transform*), é definida pelo produto da soma, ao longo do tempo, do sinal $f(t)$ com a *wavelet* $\Psi_{a,b}(t)$ na escala e no deslocamento desejados, culminando em coeficientes de

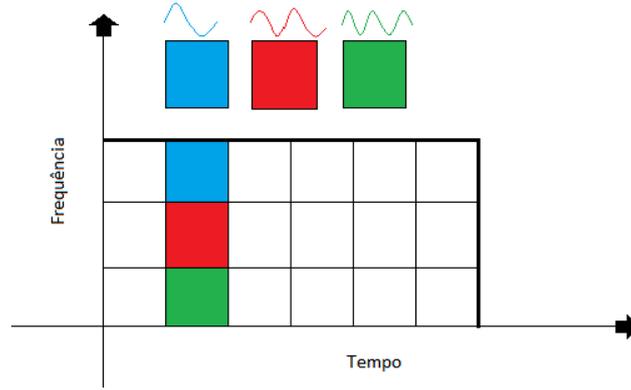


Figura 2.9. Representação tempo-frequência da WTF.

wavelets que são funções de escala e posição [6]. A Transformada é definida por

$$W(a, b) = \int_{-\infty}^{\infty} f(t) \Psi_{a,b}(t) dt, \quad (2.6)$$

na qual a é um parâmetro de escala (contração ou dilatação) e b é um parâmetro de posição (deslocamento). A função $\Psi_{a,b}(t)$ é definida como

$$\Psi_{a,b}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right), a \neq 0, b \in \mathbb{R}, \quad (2.7)$$

em que $\psi(t)$ é a *wavelet*-mãe.

Além disso, a *wavelet*-mãe precisa satisfazer a seguinte propriedade:

$$\int_{-\infty}^{\infty} \psi(t) dt = 0. \quad (2.8)$$

As variações tanto na escala quanto no deslocamento podem ser observadas nas Figuras 2.10 e 2.11, respectivamente. O parâmetro da escala mostra sua ligação com a frequência, apontando que para valores menores de a , os detalhes modificam-se rapidamente (alta frequência), enquanto para valores maiores, os valores globais modificam-se lentamente (baixa frequência) [23]. Além disso, é apresentado a influência do fator b , deslocando a *wavelet*.

Por fim, a título de comparação, as *wavelets* têm variâncias, tendo pequenas funções de base para altas frequências e funções de bases maiores para baixas frequências com

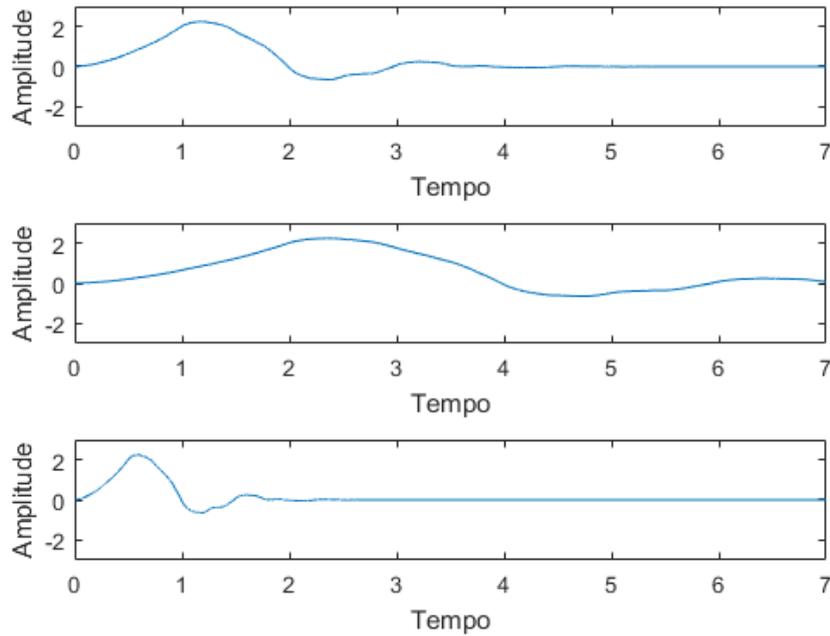


Figura 2.10. Fator de escala de uma função *wavelet*.

a finalidade de transformar um sinal para o espaço de tempo-escala, conforme a Figura abaixo.

2.3.3 Transformada *Wavelet* Discreta - DWT

Na Transformada *Wavelet* Discreta (DWT, do inglês *Discrete Wavelet Transform*), os parâmetros a , que corresponde à escala, e b , que corresponde à posição, assumem valores discretos. Para a , é preciso escolher valores inteiros positivos ou negativos, sendo este potência de um parâmetro fixo a_0 elevado a ζ , que corresponde a diferentes larguras [23].

$$a = a_0^{-\zeta} \quad a_0 > 1, \zeta \in \mathbb{R}. \quad (2.9)$$

A respeito do parâmetro b , este depende de ζ , pois as wavelets menores (altas frequências) são deslocadas por distâncias pequenas como o objetivo de ocupar o domínio do tempo, enquanto as largas (baixa frequências) por distâncias grandes. Logo,

$$b = kb_0 a_0^{-\zeta} \quad b_0 > 0, \zeta, k \in \mathbb{R}. \quad (2.10)$$

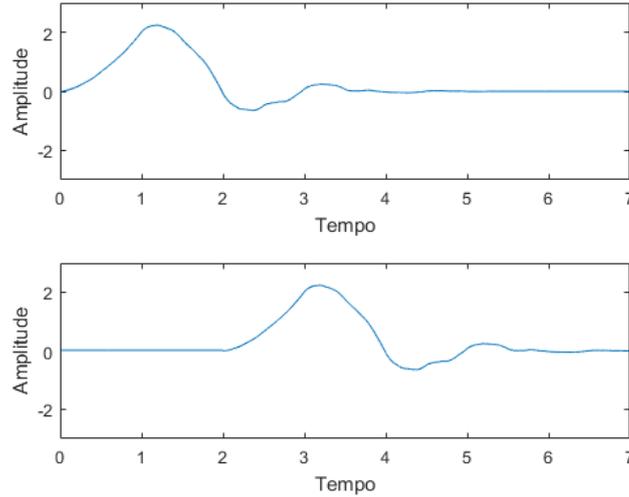


Figura 2.11. Fator de deslocamento. Acima, uma função *wavelet* e, abaixo, a mesma função deslocada.

Então, a *wavelet* discreta é apresentada na Equação 2.11

$$\Psi_{\zeta,k} = a_0^{\frac{\zeta}{2}} \Psi(a_0^{\zeta} t - kb_0), \quad (2.11)$$

e a transformada para sinais discretos

$$W_{m,n}(a,b) = a_0^{-\frac{\zeta}{2}} \int f(t) \Psi(a_0^{-\zeta} t - nb_0). \quad (2.12)$$

2.3.4 Transformada *Wavelet* em Imagens

A DWT, considerando o caso de funções de base separáveis, pode ser estendida para mais dimensões. Uma maneira de compreender o uso desta ferramenta é por meio do produto sensorial. Neste caso, ocorre o aparecimento de três tipos de funções *wavelets*: As *wavelets* horizontais, verticais e diagonais. Estas recebem este nome a fim de evidenciar a maneira com que os detalhes são obtidos, considerando as possíveis direções de variação nos dados bidimensionais.

O algoritmo bidimensional para a Transformada *Wavelet* explora a propriedade de separabilidade oriunda do produto tensorial. Dessa maneira, ocorre tanto a decomposição da imagem, conforme indicado na Figura 2.13, denominada análise, quanto sua reconstrução, exibida na Figura 2.14, chamada síntese. A DWT é aplicada nas dimensões, linhas e colunas, da imagem por meio de algoritmos unidimensionais [23].

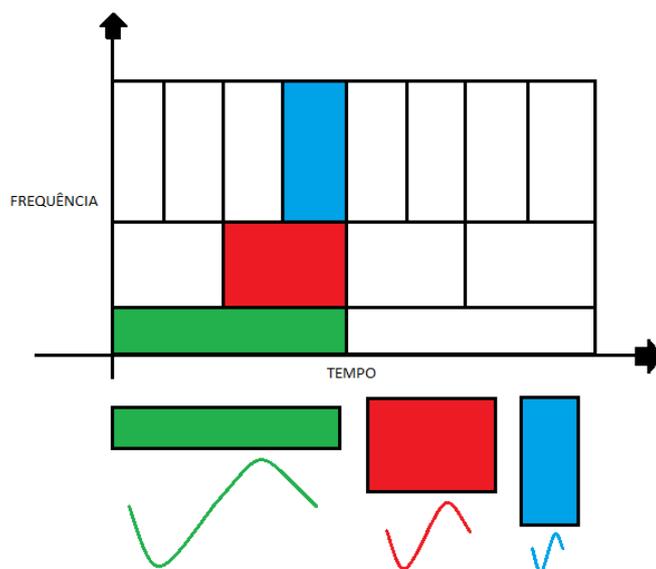


Figura 2.12. Plano tempo-frequência e as representações das caixas para a Transformada *wavelet*.

Na análise *wavelet*, a imagem é decomposta gerando novas imagens chamadas de aproximação e detalhes. A primeira consiste em coeficientes de baixa frequência, enquanto os detalhes referem-se aos coeficientes de alta frequência. No caso da Figura 2.13, juntamente com a Figura 2.15, as imagens LH, HL e HH correspondem aos detalhes após serem inseridos em filtros passa-baixas, representado por L, e passa-altas, indicado por H. Os coeficientes dos filtros passa-baixas são determinados pela função *wavelet*, enquanto os coeficientes passa-alta pela função escala. Como observado, ocorre em seguida, uma subamostragem resultando em imagens de menor resolução no fim da primeira decomposição.

Por ser um processo recursivo, é possível decompor a imagem em mais níveis. No caso da Figura 2.13, a imagem LL, que corresponde a aproximação, é decomposta nas imagens LLLL, LLLH, LLHL e LLHH, passando pelo mesmo processo citado no parágrafo anterior [41] [45].

Finalmente, a reconstrução do sinal pode ser realizada utilizando os coeficientes de aproximação e detalhes por meio do uso de uma superamostragem seguido de filtros passa-baixas e passa-altas, conforme a Figura 2.14.

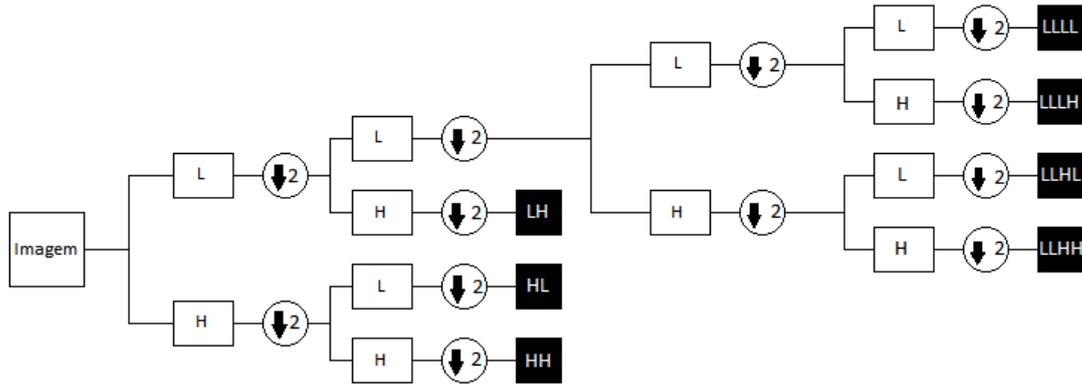


Figura 2.13. Árvore de decomposição *wavelet*.

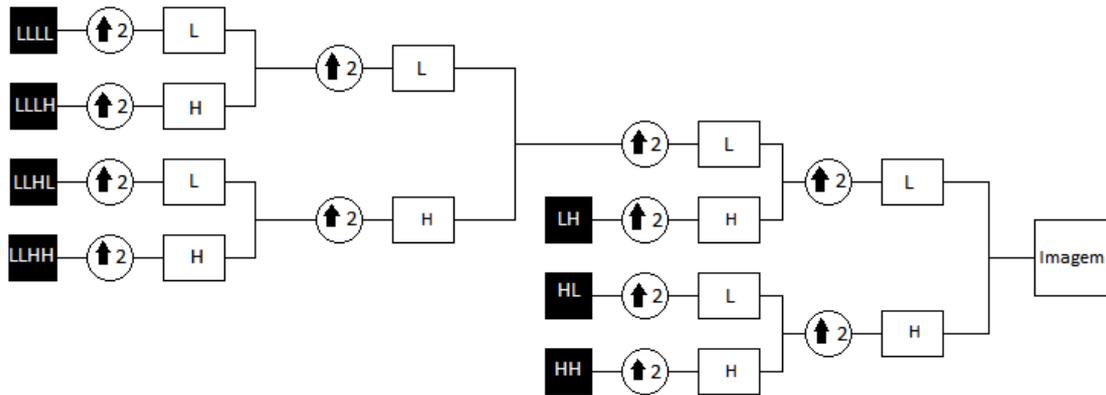


Figura 2.14. Árvore de reconstrução *wavelet*.

2.4 TRANSFORMADA *Wavelet* COMPLEXA DE ÁRVORE DUPLA

A Transformada *Wavelet* contém quatro deficiências: oscilação, variação ao deslocamento, *aliasing* e pobre direcionalidade. Logo, diante desse contexto, surge a Transformada *Wavelet* Complexa (CWT, do inglês *Complex Wavelet Transform*) a fim de suprir estes problemas.

2.4.1 Transformada *Wavelet* Complexa de Árvore Dupla Unidimensional

Todos os sinais $f(t)$ de energia finita podem ser decompostos por meio de *wavelets* e funções de escala como indicado na Equação 2.13:

$$f(t) = \sum_{-\infty}^{\infty} c(\eta)\phi(t - \eta) + \sum_{i=0}^{\infty} \sum_{\eta=-\infty}^{\infty} d(i, \eta)2^{\frac{i}{2}}\psi(2^i t - \eta), \quad (2.13)$$

LLLL	LLHL	HL
LLLH	LLHH	
LH		HH

Figura 2.15. Decomposição em dois níveis. A imagem HH corresponde a utilização de filtros passa-altas nas linhas e colunas, oferecendo detalhes diagonais da imagem. A imagem LH corresponde a utilização dos filtros passa-baixas e passa-altas nas linhas e colunas, respectivamente, concendendo detalhes horizontais. A imagem HL corresponde a utilização dos filtros passa-altas e passa-baixas nas linhas e colunas, conferindo detalhes verticais. Por fim, a imagem LL, chamada de aproximação, resultado dos filtros passa-baixas nas linhas e colunas, passa por mais um processo de decomposição, gerando as imagens LLLL, LLHL, LLLH e LLHH, que representam a aproximação, os detalhes horizontais, os verticais e os diagonais, respectivamente, com uma resolução menor por conta da subamostragem inerente ao processo.

em que $c(\eta)$ indica os coeficientes de escala, enquanto $d(i, \eta)$ representa os coeficientes *wavelets* e ambos são definidos pela Equações 2.14 e 2.15:

$$c(\eta) = \int_{-\infty}^{\infty} f(t)\phi(t - \eta)dt \quad (2.14)$$

$$d(i, \eta) = 2^{\frac{i}{2}} \int_{-\infty}^{\infty} f(t)\psi(2^i - \eta)dt, \quad (2.15)$$

lembrando que $\phi(t)$ e $\psi(t)$ são funções de escala e *wavelet*, respectivamente.

Essa ferramenta é influenciada pela TF, que tem como base sinais oscilatórios com valores complexos, possuindo, conseqüentemente, funções de escala e *wavelet* com valores complexos, conforme indicado na Equação 2.16:

$$\psi_a(t) = \psi_r(t) + j\psi_i(t), \quad (2.16)$$

no qual $\psi_r(t)$ e $\psi_i(t)$ correspondem às partes real (componente par) e imaginária (componente ímpar), respectivamente.

Os coeficientes *wavelet* complexos são definidos por:

$$d_c(i, \eta) = d_r(i, \eta) + jd_i(i, \eta), \quad (2.17)$$

com valores de magnitude e fase definidos nas Equações 2.18 e 2.19:

$$|d_c(i, \eta)| = \sqrt{d_r(i, \eta)^2 + d_i(i, \eta)^2}, \quad (2.18)$$

$$\angle d_c(i, \eta) = \arctan\left(\frac{d_i(i, \eta)}{d_r(i, \eta)}\right). \quad (2.19)$$

Porém, a CWT não possui propriedades analíticas, sendo inviável a redução das limitações citadas anteriormente. Logo, a Transformada *Wavelet* Complexa de Árvore Dupla (DT-CWT, do inglês *Dual-tree Complex Wavelet Transform*), desenvolvida por Kingsbury [33], reduz essas limitações por meio de uma árvore dupla de filtros distintos, possibilitando obter uma representação com coeficientes complexos, gerando dados de magnitude e fase. Os benefícios trazidos pela nova ferramenta são a redundância limitada, a reconstrução perfeita, invariância ao deslocamento no primeiro nível, invariância aproximada para os demais níveis e boa seletividade direcional para sinais acima de duas dimensões, gerando seis direções para cada decomposição $\pm 15^\circ$, $\pm 45^\circ$ e $\pm 75^\circ$ [50].

A Figura 2.16 apresenta um esquema com três níveis de decomposição, na qual h_0 e g_0 indicam os filtros passa-baixas e h_1 e g_1 denotam os filtros passa-altas por meio de duas árvores: a e b . Após a decomposição, ocorre a operação de subamostragem, igualmente a DWT. Essa transformada pode ser decomposta em mais níveis.

Então, a Equação 2.16 pode ser expressa como:

$$\psi(t) = \psi_h(t) + j\psi_g(t), \quad (2.20)$$

na qual $\psi_h(t)$ e $\psi_g(t)$ representam as árvores a e b , respectivamente. A $\psi_g(t)$ corresponde aproximadamente à Transformada de Hilbert de $\psi_h(t)$, tornando $\psi(t)$ aproximadamente analítica [54].

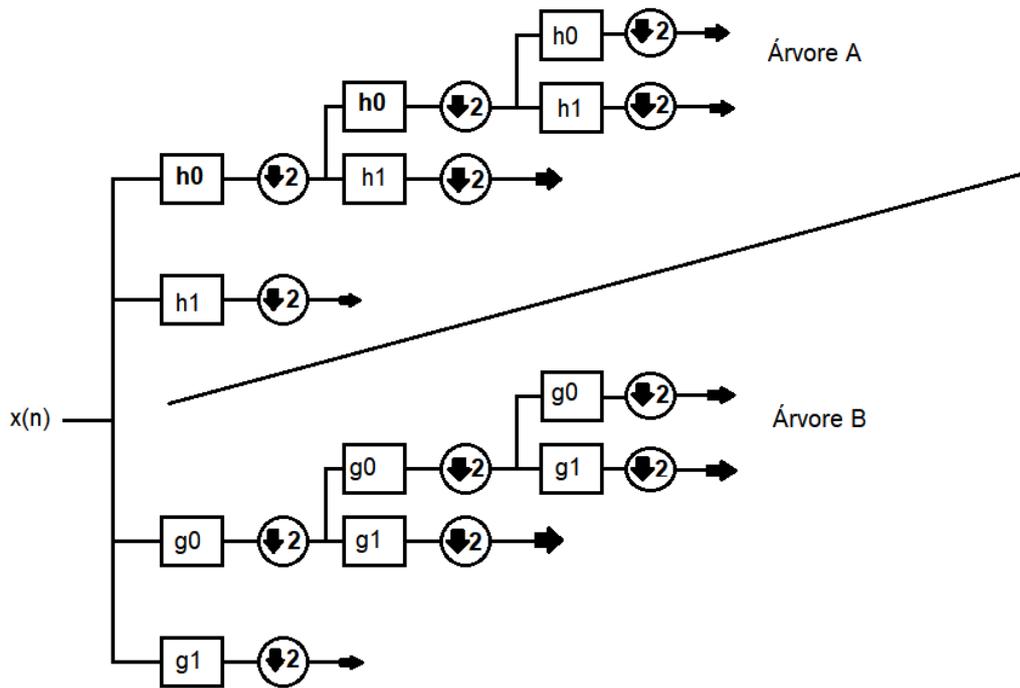


Figura 2.16. Esquema de decomposição da DT-CWT usando árvore dupla.

2.4.2 Transformada *Wavelet* Complexa de Árvore Dupla Bidimensional

Em sinais bidimensionais, o processo de filtragem é semelhante à DWT, ocorrendo por toda a extensão das linhas e colunas. Todavia, um dos fatores diferenciais da DT-CWT consiste na decomposição em mais direções. Essa ferramenta fornece subimagens em dois quadrantes espectrais adjacentes para cada nível.

A DT-CWT aplica seis *wavelets* complexas, $\phi(x)\psi(y)$, $\psi(x)\phi(y)$, $\psi(x)\psi(y)$, $\phi(x)\overline{\psi(y)}$, $\psi(x)\overline{\phi(y)}$ e $\psi(x)\overline{\psi(y)}$, a fim de decompor a imagem em seis distintas direções, sendo $\phi(x)$ e $\psi(x)$ dadas pelas seguintes equações:

$$\phi(x) = \phi_h(x) + j\phi_g(x), \quad (2.21)$$

$$\psi(x) = \psi_h(x) + j\psi_g(x), \quad (2.22)$$

sendo que $\overline{\psi(y)}$ e $\overline{\phi(y)}$ são os conjugados complexos de $\psi(y)$ e $\phi(y)$, nessa ordem. Além disso, x e y correspondem às linhas e colunas, respectivamente [54].

Objetivando uma melhor apresentação, a *wavelet* complexa $\psi(x)\psi(y)$, que corresponde à direção de -45° será utilizada como exemplo a fim de mostrar a decomposição e a forma de obtenção das orientações. A partir da Equação 2.22 e estendendo a duas dimensões:

$$\psi(x, y) = \psi_h(x)\psi_h(y) - \psi_g(x)\psi_g(y) + j[\psi_g(x)\psi_h(y) + \psi_h(x)\psi_g(y)] \quad (2.23)$$

Como apresentado na Equação 2.23 acima, a parte real da *wavelet* complexa é mostrada por duas *wavelets* separáveis com o espectro da função real simétrico em relação à origem. O espectro de Fourier da *wavelet* complexa é exibida na Figura 2.17, enquanto o espectro para a parte real é apresentada na Figura 2.18.

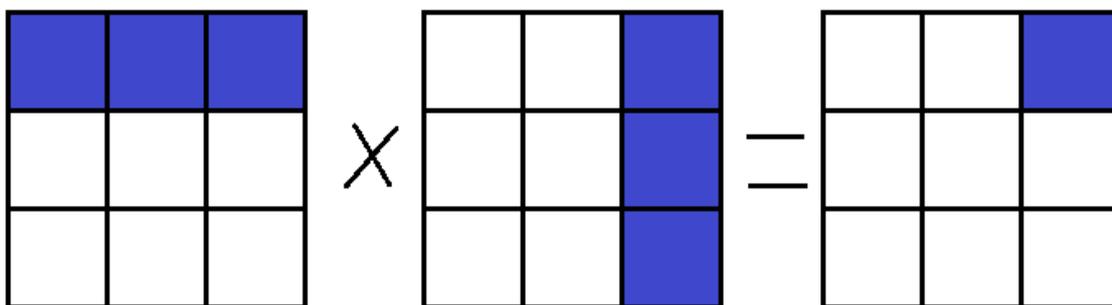


Figura 2.17. O espectro *wavelet* complexa.

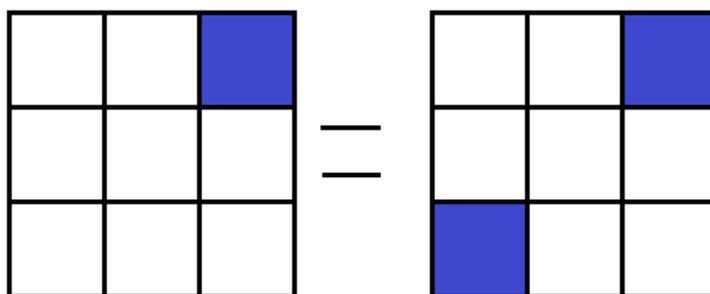


Figura 2.18. Espectro da parte real da *wavelet*.

Na Equação 2.23, o primeiro termo da parte real corresponde à orientação HH (horizontal) da *wavelet* separável dada pelo filtro h_0 e h_1 , nas linhas e colunas, enquanto o segundo termo corresponde à orientação HH dado pelo filtro g_0 e g_1 nas linhas e colunas, em que h_0 e h_1 representa os filtros passa-baixas da árvore a e g_0 e g_1 indica os filtros passa-altas da árvore b . Na parte imaginária, o primeiro termo é a orientação HH (horizontal) na *wavelet* separável 2D dado pelos filtros g_0 e g_1 nas linhas e h_0 e h_1 nas colunas, enquanto o segundo termo da parte imaginário é a orientação HH dada pelo filtro h_0 e h_1 nas linhas e colunas.

As seis orientações da parte real da DT-CWT são dadas pelas seguintes Equações:

$$\begin{aligned}
 \psi_1(x, y) &= \frac{1}{\sqrt{2}}(\phi_h(x)\psi_h(y) - \phi_g(x)\psi_g(y)), \text{ LH} \\
 \psi_2(x, y) &= \frac{1}{\sqrt{2}}(\psi_h(x)\phi_h(y) - \psi_g(x)\phi_g(y)), \text{ HL} \\
 \psi_3(x, y) &= \frac{1}{\sqrt{2}}(\psi_h(x)\psi_h(y) - \psi_g(x)\psi_g(y)), \text{ HH} \\
 \psi_4(x, y) &= \frac{1}{\sqrt{2}}(\phi_h(x)\psi_h(y) + \phi_g(x)\psi_g(y)), \text{ LH} \\
 \psi_5(x, y) &= \frac{1}{\sqrt{2}}(\psi_h(x)\phi_h(y) + \psi_g(x)\phi_g(y)), \text{ HL} \\
 \psi_6(x, y) &= \frac{1}{\sqrt{2}}(\psi_h(x)\psi_h(y) + \psi_g(x)\psi_g(y)), \text{ HH}
 \end{aligned} \tag{2.24}$$

em que $\frac{1}{\sqrt{2}}$ é usado como fator de normalização, ψ_1 , ψ_2 e ψ_3 são as orientações LH, HL e HH, e ψ_4 , ψ_5 e ψ_6 são as orientações LH, HL e HH, das árvores a e b , respectivamente. Na Figura 2.19 são apresentadas no domínio do espaço (a) e em espectros idealizados para as seis orientações da parte real no domínio da frequência (b).

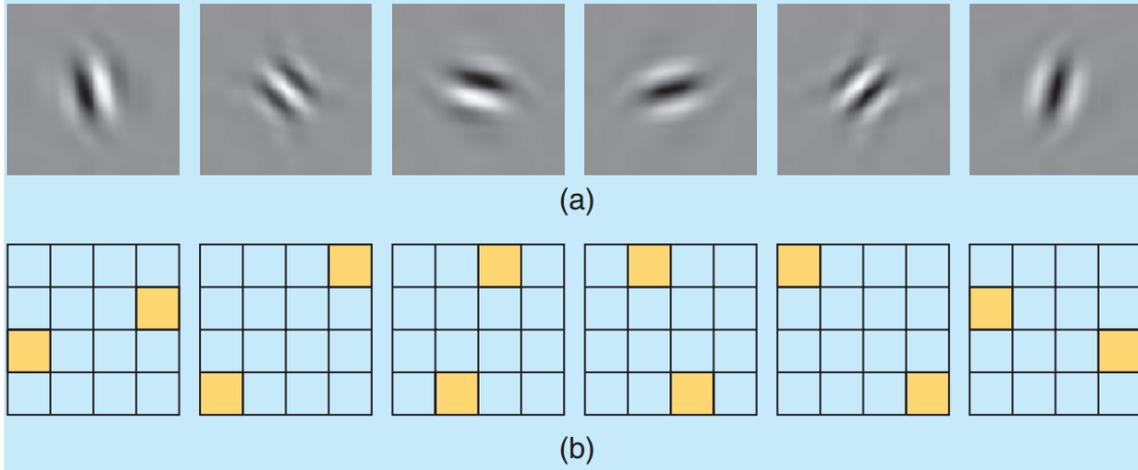


Figura 2.19. Orientação da parte real da DT-CWT. (a) *wavelets* no domínio do espaço. (b) espectro idealizado para as *wavelets* no domínio da frequência. Figura retirada de [31].

As seis orientações imaginárias da DT-CWT são:

$$\begin{aligned}
\psi_1(x, y) &= \frac{1}{\sqrt{2}}(\phi_g(x)\psi_h(y) + \phi_h(x)\psi_g(y)), \quad LH \\
\psi_2(x, y) &= \frac{1}{\sqrt{2}}(\psi_g(x)\phi_h(y) + \psi_h(x)\phi_g(y)), \quad HL \\
\psi_3(x, y) &= \frac{1}{\sqrt{2}}(\psi_g(x)\psi_h(y) + \psi_h(x)\psi_g(y)), \quad HH \\
\psi_4(x, y) &= \frac{1}{\sqrt{2}}(\phi_g(x)\psi_h(y) - \phi_h(x)\psi_g(y)), \quad LH \\
\psi_5(x, y) &= \frac{1}{\sqrt{2}}(\psi_g(x)\phi_h(y) - \psi_h(x)\phi_g(y)), \quad HL \\
\psi_6(x, y) &= \frac{1}{\sqrt{2}}(\psi_g(x)\psi_h(y) - \psi_h(x)\psi_g(y)), \quad HH
\end{aligned} \tag{2.25}$$

A Figura 2.20 apresenta as respostas impulsivas da DT-CWT e DWT. Como é possível observar, devido às características de direcionalidade, a DT-CWT não apresenta a aparência de tabuleiro de xadrez (*checkerboard*) como acontece na DWT na orientação de $\pm 45^\circ$ [54].

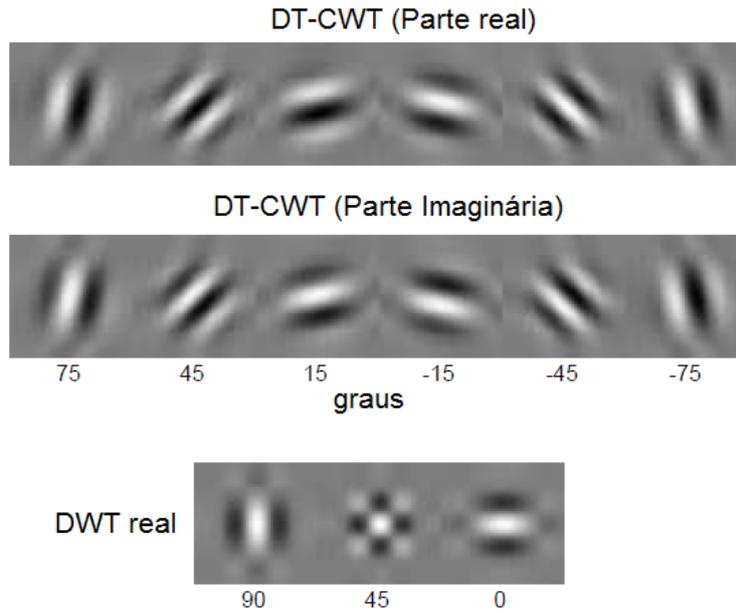


Figura 2.20. Respostas impulsivas das transformadas DT-CWT, com seis orientações, e DWT, com três orientações. Figura retirada de [31].

2.5 TRANSFORMADA *Contourlet*

A Transformada *Contourlet* (CT, do inglês *Contourlet Transform*) é uma ferramenta fundamentada em duas técnicas: o banco de filtros direcionais (*DFB*, do inglês *Directional Filter Bank*) e a pirâmide laplaciana (LP, do inglês *Laplacian Pyramid*). A primeira consiste na geração de uma estrutura capaz de extrair contornos, enquanto a segunda

separa as altas e as baixas frequências da imagem [51] [1]. Resumidamente, uma imagem \mathbf{I} entra na LP e passa por um filtros g passa-baixas gerando uma saída I_B reduzida pela metade da resolução da imagem \mathbf{I} . Em seguida, após o processo de sobreamostragem de I_B , a LP fornece uma imagem com os coeficientes de aproximação da imagem \mathbf{I} original e, por fim, a imagem laplaciana $\mathbf{L1}$ é definida pela Equação 2.28. Esta nova imagem $\mathbf{L1}$ contém as altas frequências da imagem original.

$$L1 = I - I_B \quad (2.26)$$

Esse processo pode ser repetido em I_B , gerando I_{B2} e, a partir desse ponto, gerando uma nova imagem $\mathbf{L2}$ por meio da subtração entre I_B e I_{B2} . Enfim, LP pode atuar em n-níveis, possuindo uma imagem passa-baixas e um conjunto de imagens de alta frequência. Esse grupo irá passar pelo DFB para a detecção de bordas [56] [16]. Todo o processo é exibido na Figura 2.21.

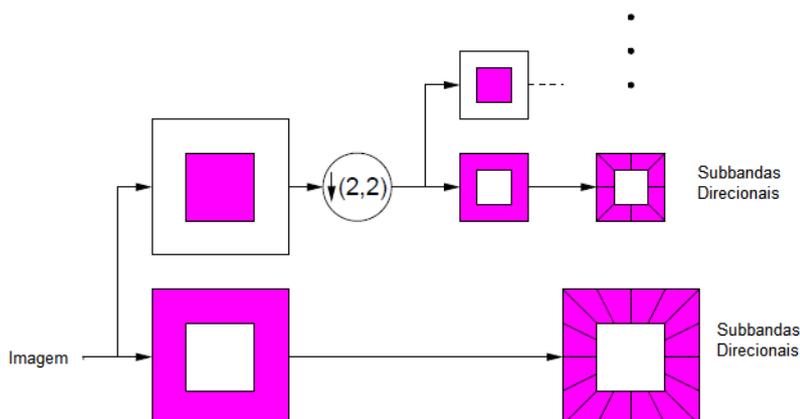


Figura 2.21. Banco de Filtros de Contorno: Primeiramente, ocorre a decomposição em múltiplas escalas em bandas de oitavas pela pirâmide laplaciana e, em seguida, o banco de filtros direcionais é aplicado.. Figura retirada de [56].

A segunda etapa consiste na aplicação no DFB tanto nos espectros horizontais quanto nos verticais das imagens de alta frequência por meio de um Banco de Filtros *Quincunx*, conforme a Figura 2.22.

Nesses filtros, para que exista a decomposição nas duas direções, as seguintes matrizes de rotação é utilizada junto com a subamostragem $S_k(l)$,

$$\begin{bmatrix} 2^{t-1} & 0 \\ 0 & 2 \end{bmatrix} \quad 0 \leq k \leq 2^{t-1} \quad (2.27)$$

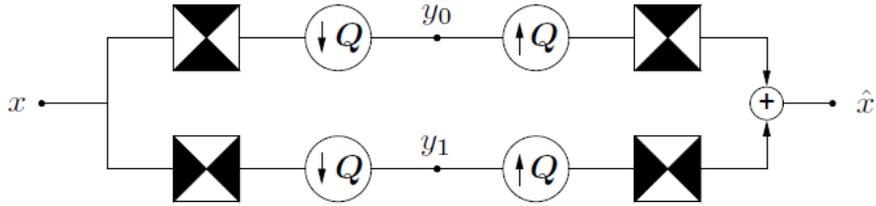


Figura 2.22. Decomposição gerada pelo filtro *Quincunx*. Figura retirada de [56].

na qual

$$\begin{bmatrix} 2 & 0 \\ 0 & 2^{t-1} \end{bmatrix} \quad 2^{t-1} \leq k \leq 2^t, \quad (2.28)$$

sendo que l representa o nível a ser decomposto em 2^l participações como pode ser visto na Figura 2.23.

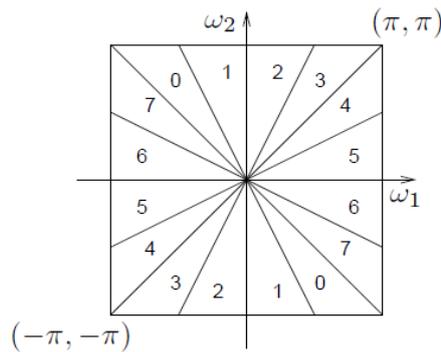


Figura 2.23. Partições de frequências gerada para $l=3$, isto é, oito partições. Figura retirada de [56].

A fim de exemplificação, a Figura 2.24 apresenta uma imagem rotacionada pelas matrizes $S_k(l)$. Nesse caso, a imagem contém apenas as altas frequências da imagem original e após a rotação é aplicado o DFB em cada partição.



Figura 2.24. Esquerda: Imagem original. Direita: Imagem rotacionada e submostrada. Figura retirada de [56].

Por fim, a Transformada *Contourlet* irá apresentar uma imagem passa-baixas, que representa uma aproximação da imagem original gerada pela LP e um conjunto de imagens passa-altas em diferentes escalas e direções, representando o contorno da imagem [56] [16].

2.6 MATRIZ DE COCORRÊNCIA DE NÍVEIS DE CINZA

A matriz de coocorrência de níveis de cinza (GLCM, do inglês *Gray-Level Co-Occurrence Matrix*) foi sugerida por Haralick [21] a fim de analisar texturas baseadas nas posições dos pixels em uma imagem em níveis de cinza. Resumidamente, ocorre a extração de dados estruturais sobre o padrão de textura existente em diferentes escalas e orientações. No fim, o GLCM fornece uma tabela com a quantidade de combinações de valores de intensidades de pixels que ocorrem na imagem [21] [53]. Sua equação é dada por:

$$P(\vartheta, \kappa) = [(i, j), (k, l)] \subset V | f(i, j) = \vartheta \quad e \quad f(l, k) = \kappa, \quad (2.29)$$

em que $P(\vartheta, \kappa)$ é todo elemento da matriz de coocorrência responsável por armazenar o número de translação de um pixel com tonalidade de ϑ para um com tonalidade κ . Para executar tal tarefa, é preciso definir um conjunto V de par ordenados de cada pixel. A fim de exemplificação, observe a seguinte matriz, apresentada em 2.30, que inserida na Equação 2.29, resulta na GLCM expressa em 2.31.

$$\begin{bmatrix} 3 & 4 & 3 & 8 \\ 8 & 4 & 3 & 7 \\ 7 & 4 & 7 & 8 \\ 4 & 7 & 4 & 3 \end{bmatrix} \quad (2.30)$$

$$\begin{bmatrix} 0 & 1 & 1 & 1 \\ 3 & 0 & 2 & 0 \\ 0 & 2 & 0 & 1 \\ 0 & 1 & 0 & 0 \end{bmatrix} \quad (2.31)$$

Essa nova matriz representa o número de ocorrências das transições, exemplificadas na Figura 2.25

Em seguida, ocorre o processo de normalização definida pela Equação 2.32

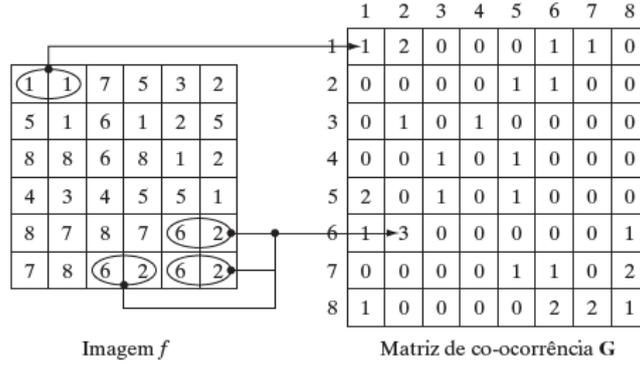


Figura 2.25. Como gerar uma matriz de coocorrência. Figura retirada de [48].

$$p_{m,n} = \frac{P(m,n)}{\sum_{i=0}^{H_g} \sum_{j=0}^{H_g} P(i,j)}, \quad (2.32)$$

culminando na matriz:

$$\begin{bmatrix} 0,00 & 0,08 & 0,08 & 0,08 \\ 0,25 & 0,00 & 0,17 & 0,00 \\ 0,00 & 0,17 & 0,00 & 0,08 \\ 0,00 & 0,08 & 0,00 & 0,00 \end{bmatrix} \quad (2.33)$$

Além disso, um ponto de fundamental importância diz respeito aos fatores no cálculo da GLCM. O primeiro é o ângulo θ , que consiste na direção em que será calculada a ocorrência entre os pixels, e que pode tomar os valores de 0° , 45° , 90° e 135° , conforme indicado na Figura 2.26. O outro ponto é a distância d , que representa o intervalo entre os pixels. No exemplo acima, utilizou-se $\theta=0$ e $d=1$.

É importante ressaltar que a quantidade de GLCM é definida pelo produto da quantidade de ângulos com a quantidade de distância, isto é, em caso de dois ângulos e duas distâncias haverá quatro matrizes.

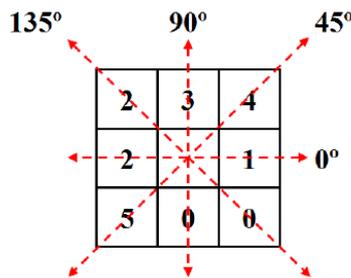


Figura 2.26. Orientação dos ângulos da GLCM. Figura retirada de [29]

Por fim, encontrada a matriz de coocorrência, o próximo passo está baseado na extração de informações. Abaixo, são apresentados alguns parâmetros bastante utilizados nessas aplicações.

A **Energia** determina uniformidade da textura. Em texturas ásperas, poucos elementos da matriz são diferentes de zero:

$$Energia = \sum_{i,j=0}^{N-1} P_{i,j}(i,j)^2 \quad (2.34)$$

O **Contraste** apresenta a diferença dos tons de cinza. Um baixo contraste apresenta uma baixa diferença entre os pixels:

$$Contraste = \sum_{i,j} (i-j)^2 * P(i,j) \quad (2.35)$$

A **Homogeneidade** assume altos valores quando ocorre pequenas variações em níveis de cinza:

$$Homogeneidade = \sum_{i,j} \frac{P(i,j)}{1 + (i-j)^2}. \quad (2.36)$$

A **Correlação** é a medida da dependência entre níveis de cinza e uma textura. Valores elevados indicam regiões com elevadas similiaridades entre os níveis de cinza, conforme a expressão:

$$Correlacao = \sum_{i,j=0}^{N-1} \frac{P_{i,j}(1 - \mu)}{\sigma^2}, \quad (2.37)$$

na qual μ é a média de $P(m, n)$ e σ é o desvio-padrão [52] [29].

2.7 MORFOLOGIA MATEMÁTICA

A morfologia matemática é uma ferramenta fundamentada na teoria dos conjuntos, sendo sua principal aplicação o estudo de estruturas ou formas. O tema principal desta técnica está baseado no denominado elemento estruturante (ES), que é um pequeno conjunto ou subimagem que percorre toda a imagem analisada, modificando-a a fim de obter os dados de interesse. Por este motivo, percebe-se a importância da escolha do ES

correto em morfologia matemática.

Os próximos tópicos abordarão as operações morfológicas e a relevância do elemento estruturante em cada uma.

2.7.1 Erosão e Dilatação Morfológica

A erosão de uma determinada imagem A com um elemento estruturante B é definida pela Equação 2.38. Essencialmente, a erosão de A por B é o conjunto de todos os pontos de z de forma que B, transladado por z, esteja contido em A.

$$A \ominus B = \{z | (B)_z \subseteq A\}. \quad (2.38)$$

A Figura 2.27 apresenta o resultado da erosão do conjunto A com dois tipos de ES, um quadrado e outro alongado. Em ambos os casos, o ES desliza sobre a imagem, retirando as informações de interesse. As principais aplicações dessa ferramenta são a separação de objetos e a remoção de extrusões.

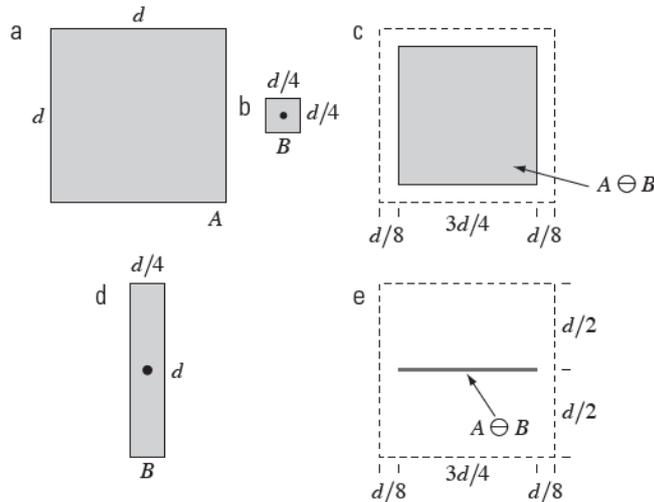


Figura 2.27. (a) Conjunto A. (b) Elemento Estruturante. (c) Erosão A por B. (d) Elemento estruturante alongado. (e) Erosão A por B utilizando o elemento estruturante alongado. Figura retirada de [48].

Com relação à dilatação, a Equação 2.39 é definida por:

$$A \oplus B = z | (\hat{B}_z \cap A) \subseteq A. \quad (2.39)$$

Nesta operação, a dilatação de A por B é o conjunto de todos os deslocamentos z

de forma que \hat{B}_z e A se sobreponham pelo elemento. A Figura 2.28 mostra o resultado de uma operação de dilatação com dois elementos estruturantes distintos. As aplicações desta ferramenta são a reparação de quebras e intrusões [15].

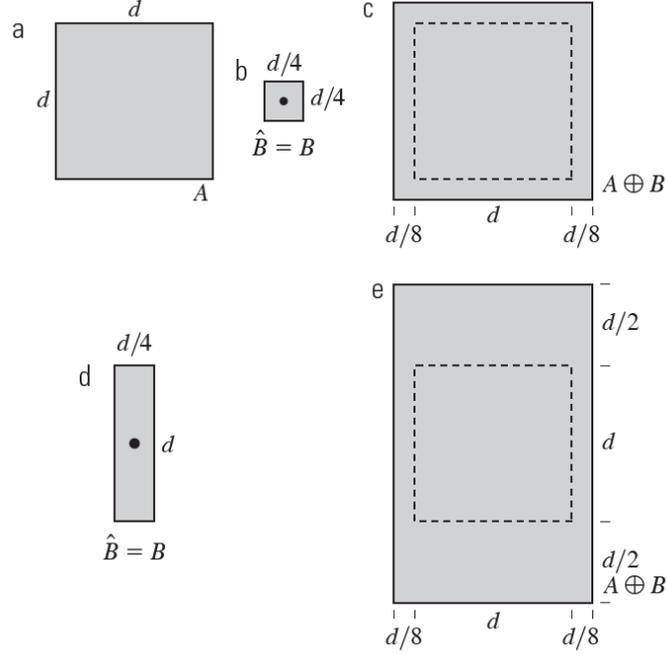


Figura 2.28. (a) Conjunto A. (b) Elemento Estruturante. (c) Dilatação de A por B. (d) Elemento estruturante alongado. (e) Dilatação de A por B utilizando o elemento estruturante alongado. Figura retirada de [48].

Quando a imagem tratada está em níveis de cinza, as operações morfológicas fornecem outras informações. A erosão é determinada pelos valores mínimos de f contidos na região que coincide com B, resultando no aumento do domínio das regiões escuras. A Equação 2.40 define a operação de erosão morfológica, denotada pelo símbolo \ominus .

$$[f \ominus b] = \min_{s,t \in b} f(x + s, y + t). \quad (2.40)$$

Diferentemente, a dilatação busca o valor máximo, evidenciando as regiões mais claras. A Equação 2.41 define a dilatação morfológica, representada pelo símbolo \oplus .

$$[f \oplus b] = \max_{s,t \in b} f(x - s, y - t). \quad (2.41)$$

2.7.2 Abertura e Fechamento Morfológico

A terceira operação morfológica chama-se abertura, definida pela Equação 2.42, que consiste em uma erosão seguida de uma dilatação. Essa técnica é empregada no rompimento de istmos e eliminação de saliências finas e pequenos pontos isolados [48].

$$A \circ B = (A \ominus B) \oplus B. \quad (2.42)$$

Enfim, a última operação é o fechamento, indicado na Equação 2.43, que consiste na dilatação seguida de uma erosão. Essa ferramenta é utilizada em suavizações de contorno, fundição de discontinuidades estreitas, eliminação de pequenos buracos e o preenchimento de lacunas [48].

$$A \cdot B = (A \oplus B) \ominus B. \quad (2.43)$$

2.7.3 Transformada *Top-Hat* e *Bottom-Hat*

As Transformadas *Top-Hat* e *Bottom-Hat* são baseadas em operações morfológicas, possuindo características complementares. A primeira consiste na extração dos elementos claros, enquanto a segunda na obtenção dos elementos escuros. A Equação 2.44 mostra que a Transformada *Top-Hat* é definida pela subtração da imagem original pela sua abertura, ao passo que a Equação 2.45 indica que a Transformada *Bottom-Hat* baseia-se na diferença do fechamento pela imagem original [62].

$$A - (A \circ B), \quad (2.44)$$

$$(A \cdot B) - A. \quad (2.45)$$

2.7.4 Complemento e Diferença

O complemento consiste no conjunto de pontos que não pertencem a \mathbf{A} , conforme indicado pela Equação 2.46. A diferença é o conjunto de pontos que pertencem a \mathbf{A} , mas não a \mathbf{B} , conforme indicado na Equação 2.47. Ambas as operações são exibidas na Figura 2.29.

$$A^C = w | w \notin A. \quad (2.46)$$

$$A - B = w | w \in A, w \notin B = A \cap B^C. \quad (2.47)$$

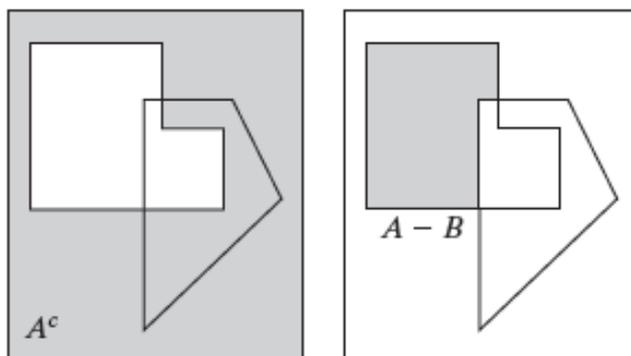


Figura 2.29. À esquerda, o complemento. À direita, a diferença. Figura retirada de [48].

2.8 SUPERPIXELS

Desde as primeiras pesquisas na área de processamento de sinais, os pixels são vistos como os elementos mais básicos de uma imagem. Todavia, um pixel não possui nenhum valor semântico em si. Logo, com a finalidade de executar uma segmentação, o método de superpixels foi introduzido. Esta nova ferramenta supersegmenta uma imagem, realizando um agrupamento de pixels que compartilham propriedades em comum, como, por exemplo, a homogeneidade. Neste caso, um superpixel pode ser definido como uma estrutura homogênea espacialmente coerente. Além disso, há maiores vantagens quanto às informações e os limites naturais da imagem serem mais precisamente definidores [24] [43]. A Figura 2.30 exibe uma segmentação por superpixel.

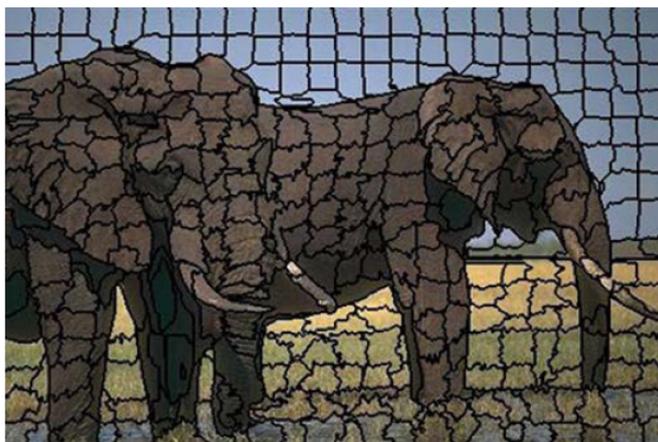


Figura 2.30. Segmentação utilizando superpixels. Figura retirada de [43].

2.9 DESCRITORES

Os descritores são valores numéricos que retratam características da imagem analisada, sendo utilizados, geralmente, após a segmentação. Esses atributos são divididos em categorias, sendo suas principais os descritores de fronteira e de região.

Os descritores de fronteiras são:

- Descritores simples: comprimento de contorno e curvatura.
- Código de cadeia: baseado em conectividade de quatro e oito.

Enquanto os descritores de região são:

- Área, perímetro e compacidade.
- Descritores topológicos: números de buracos, números de componentes convexos, contrastes, homogeneidade, correlação e energia [19].

2.10 MÁQUINAS DE VETOR DE SUPORTE

2.10.1 SVM e sua aplicação em dados lineares

A Máquina de Vetor de Suporte (SVM, do inglês *Support Vector Machine*) é uma ferramenta que tem como finalidade analisar os dados e reconhecer padrões, executando uma separação automática entre duas classes. Resumidamente, é obtido um conjunto de características pertencentes a dois grupos diferentes como exemplo de treino de máquina, com a finalidade de encontrar uma separação entre classes a partir das características de entrada. Assim sendo, as novas características submetidas no algoritmo da análise

poderão pertencer a um dos dois grupos que foram separados [11]. Então, diante de uma amostragem de duas classes distintas, a classificação SVM permite a obtenção de diversas funções de um separador das mesmas, conforme a Figura 2.31. Diante disto, deve avaliar a função que melhor distingue as duas classes [18].

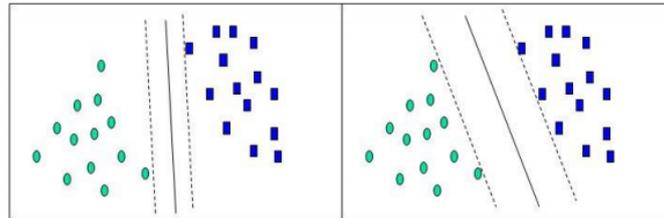


Figura 2.31. Exemplo de classificação SVM, separando duas classes. Figura retirada de [18].

A função que possui maior margem entre as duas classes é a escolhida. Basicamente, a distância é calculada entre os pontos limítrofes pertencentes a classes distintas.

2.10.2 Vetor de Suporte

Os vetores de suportes são os pontos de ambas as classes que estão mais próximos do separador de classes. A Figura 2.32 apresenta dois exemplos de classificação SVM para os mesmos dados de entrada.

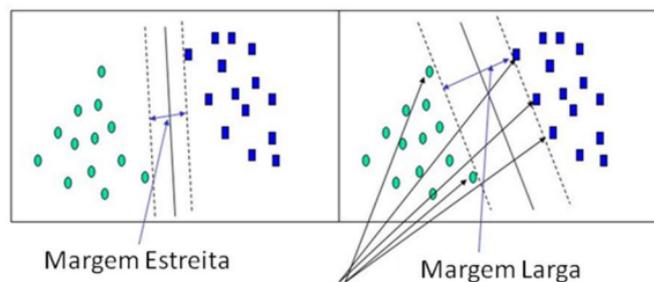


Figura 2.32. Dois separadores de classes e suas margens com vetores de suporte. Estes são vetores do espaço amostral mais próximo da função de separação. Figura retirada de [18].

Neste caso, o classificador à direita é o mais adequado, já que a margem que separa as duas classes é a maior.

2.10.3 O Hiperplano de separação

O hiperplano é uma função de separação. No caso de um espaço bidimensional, o hiperplano é uma reta, conforme a Figura 2.31 e 2.32. Porém, em uma dimensão maior, como na Figura 2.33, a função de separação deve ser um plano.

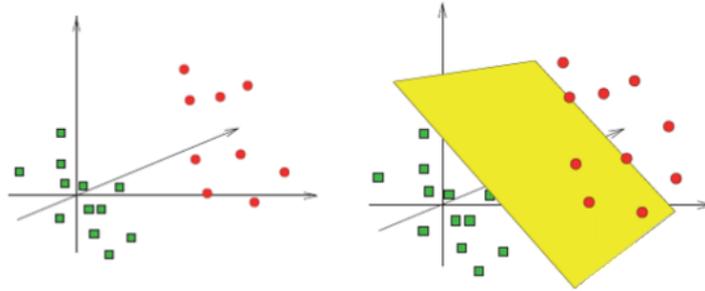


Figura 2.33. Espaço amostral em ambiente tridimensional possui função de separação 2D. Figura adaptada de [18].

A Equação 2.48 mostra a margem a ser maximizada que demonstram as propriedades dos vetores de suporte:

$$L(\alpha) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j} \alpha_i \alpha_j y_i y_j x_i^T x_j, \quad (2.48)$$

em que x_i é um conjunto de treinamento, y_i seus rótulos, x_j os dados não classificados, y_j seus respectivos rótulos e α os multiplicadores de Lagrange dos dados de treinamento $\mathbf{i}(\alpha_i)$ e os dados a serem classificados $\mathbf{j}(\alpha_j)$.

2.10.4 SVM e sua aplicação em dados não lineares

Geralmente, os dados não ficam distribuídos de forma linear, como mostrado nos exemplos anteriores. Logo, a fim de resolver problemas não lineares, Hofmann, Scholkopf e Smola (2008) propuseram uma reprojeção dos dados amostrais em um espaço dimensional maior através de funções de Kernel (ϕ), sendo que a partir desse caso o algoritmo de classificação SVM é aplicado. Na Figura 2.34, é exibida uma função Kernel.

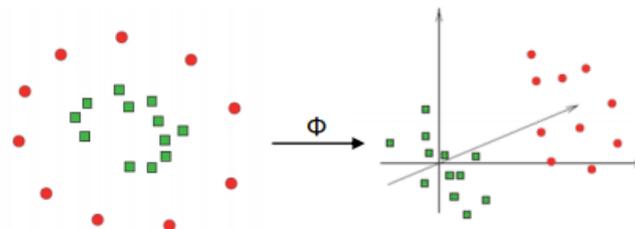


Figura 2.34. Redistribuição dos dados de entrada, que, coletados em espaço 2D, foram redistribuídos em espaço 3D por aplicação de uma função Kernel. Figura retirada de [18].

2.10.5 Funções *Kernel*

Um Kernel corresponde a um produto escalar que normalmente encontra-se em um espaço dimensional superior a qual os atributos foram inseridos. Neste novo espaço, os métodos de modelagem são lineares. A fim de exemplificação, na Figura 2.35, os dados coletados no espaço bidimensional necessitaram de ser reamostrados em um espaço tridimensional para que a separação das classes pudesse ser executada.

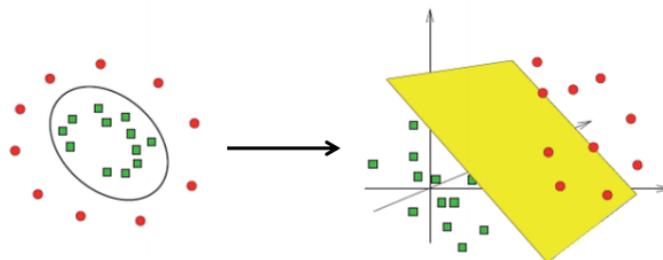


Figura 2.35. Espaço amostral inicial onde as classes se distribuem de maneira não-linear à esquerda. À direita, a função Kernel aplicada para se tornar possível a delimitação do hiperplano de separação. Figura adaptada de [18].

O SVM não linear depende da função Kernel, expressa pelas fórmulas de 2.49 até 2.52, a ser implementada.

$$\tau(x_i; x_j) = x_i^T x_j, \quad (2.49)$$

$$\Gamma(x_i; x_j) = (Y x_i^T x_j + r)^d, Y > 0, \quad (2.50)$$

$$\Phi(x_i; x_j) = \exp(-Y \|x_i - x_j\|^2), Y > 0, \quad (2.51)$$

$$\Upsilon(x_i; x_j) = \tanh(Y x_i^T x_j + r), \quad (2.52)$$

onde τ , Γ , Φ e Υ representam a forma linear, polinomial, RBF (do inglês, *Radial Basis Function* ou Função de Base Radial) e a sigmóide, respectivamente.

Nesta pesquisa, o kernel utilizado será o RBF.

3 MATERIAIS E MÉTODOS

3.1 DIAGRAMA GERAL DO SISTEMA

Baseado em pesquisas científicas que apontam anormalidades no ventrículo de portadores da patologia, a proposta do trabalho consiste no desenvolvimento de um algoritmo que isole e segmente essa região cerebral de um banco de imagens a fim de classificá-lo no grupo de portadores de esquizofrenia ou de controle, servindo como auxílio ao diagnóstico clínico.

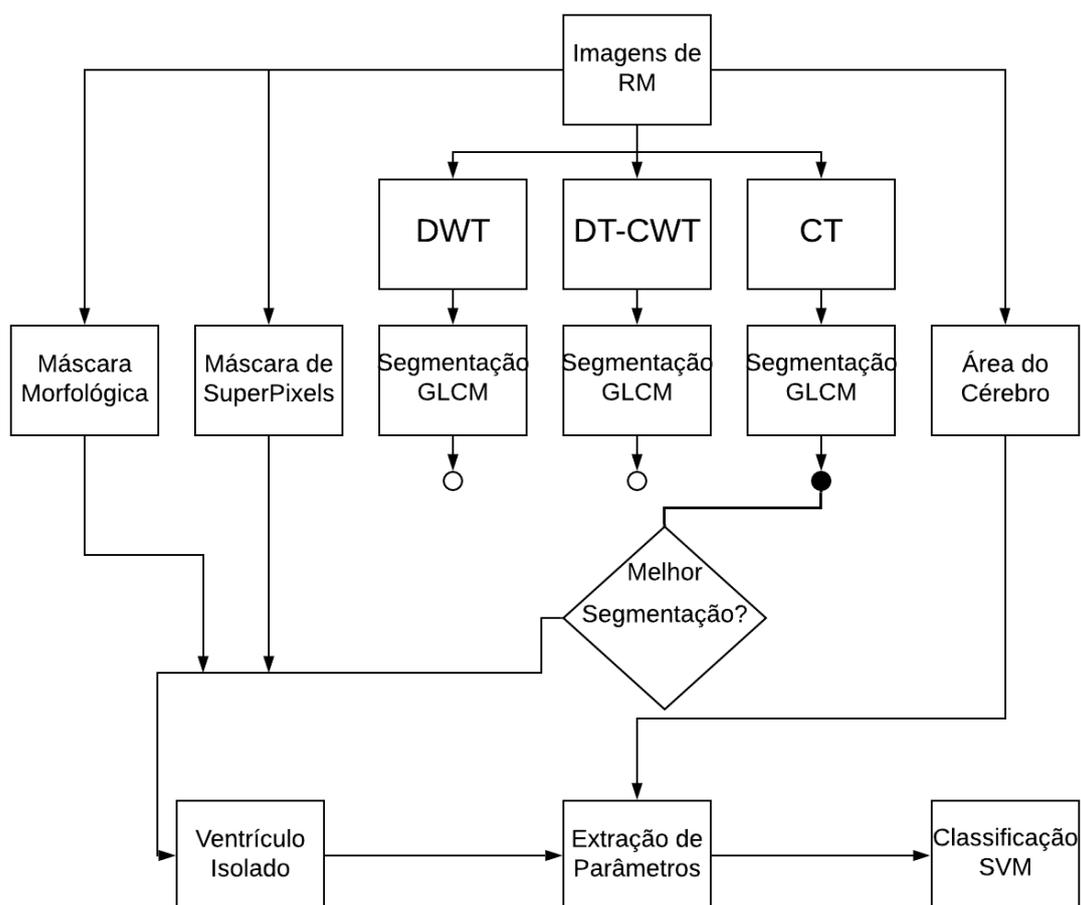


Figura 3.1. Estrutura geral do método implementado.

Basicamente, as imagens de RM, que possuem os ventrículos laterais em evidências,

serão inseridas em três transformadas em paralelo: a DWT, a DT-CWT e Transformada *Contourlet* a fim de se obter os contornos dessa região de interesse. Em seguida, será realizada uma segmentação baseada na textura das imagens utilizando a GLCM e a segmentação que melhor delinear o sistema ventricular é escolhida para avançar na aplicação do método proposto. Além disso, duas máscaras, morfológica e de superpixels, serão desenvolvidas com o propósito de isolar o sistema ventricular. Desta forma, tanto características da região de interesse como da área do cérebro, que também é encontrada, serão utilizadas para classificação. Esta consistiu numa escolha randômica onde 70% das características foram usados para treino, enquanto 30% para validação.

3.2 EXPERIMENTOS COMPUTACIONAIS

As imagens de ressonância magnética empregadas neste trabalho foram obtidas do BIRN, *Biomedical Informatics Research Network*, banco de dados projetados para fins de compartilhamento de dados biomédicos. Uma das subdivisões deste banco chama-se fBIRN em que imagens, dados comportamentais e avaliações clínicas de pessoas com ou sem esquizofrenia estão disponíveis. A Figura 3.2 apresenta uma das imagens do banco de dados.

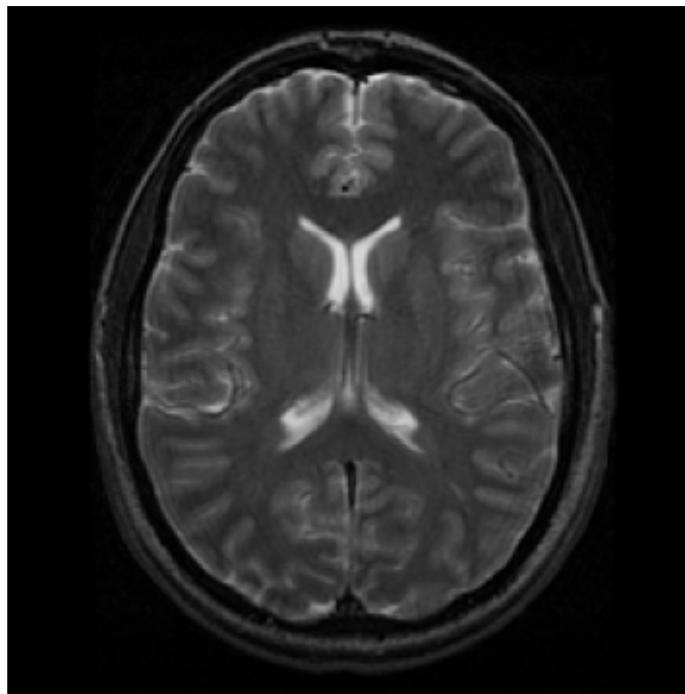


Figura 3.2. Exemplo de uma imagem de RM fornecida pela BIRN.

Além disso, para a realização do experimento, algumas imagens foram selecionadas. Por conta das alterações nos ventrículos laterais, as imagens que contêm essa região foram escolhidas para passarem pelo processo descrito na Figura 3.1. O banco de dados contém 155 imagens volumétricas com 79 cortes do grupo de controle e 76 do grupo de portadores de esquizofrenia.

3.3 TRANSFORMADA *Wavelet*, DT-CWT E TRANSFORMADA *Contourlet* PARA A EXTRAÇÃO DE BORDAS OU CONTORNOS

3.3.1 Processamento com DWT - Transformada *Wavelet*

A Transformada *Wavelet* será aplicada nas imagens a fim de separá-las em sub-bandas. Nesta caso, a imagem de RM será decomposta em três níveis com o objetivo de extrair os coeficientes de alta frequência onde estão inseridos os coeficientes de contorno da imagem. Logo, a imagem de aproximação será descartada, enquanto os detalhes serão reconstruídos.

3.3.2 Processamento com DT-CWT - Transformada *Wavelet* Complexa de Árvore Dupla

A DT-CWT é utilizada para preservar as componentes de alta frequência da imagem, possuindo maior seletividade e invariância quando comparada a DWT. A imagem será decomposta em três sub-bandas, gerando componentes reais e complexas. Essa ferramenta é usada para analisar bordas da imagem e, para alcançar êxito, é necessário reconstruir a imagem retendo as componentes de alta frequência (detalhes) e excluindo as de baixa-frequência (aproximação). Por se tratar de uma transformada mais eficiente na discriminação angular que a DWT, é esperado que os contornos sejam mais evidentes do que na ferramenta anterior.

3.3.3 Processamento com Transformada *Contourlet*

A última ferramenta que será utilizada para a extração de contornos é a Transformada *Contourlet*. Essa ferramenta captura contornos de forma eficaz com alguns coeficientes. A imagem irá ser decomposta em sub-bandas direcionais de passa-bandas usando DFB. Essa ferramenta é mais eficaz do que a Transformada *Wavelet* para extração de bordas e texturas, pois é sensível à direção da textura da imagem.

3.4 GLCM - MATRIZ DE COCORRÊNCIA DE NÍVEIS DE CINZA

A textura é uma das características mais significativas na identificação de objetos ou regiões de uma imagem. O GLCM é um método de análise estatística que representa a distribuição espacial dos valores de cinza na imagem de textura, podendo obter parâmetros de características texturais. Nessa pesquisa, será utilizada a GLCM para analisar o contraste, a correlação, a energia e a homogeneidade. Em seguida, usando a GLCM, a imagem será segmentada. Nessa etapa, com a segmentação GLCM, a transformada, dentre as três anteriores testadas, que melhor isolar o ventrículo cerebral será escolhida para o prosseguimento da metodologia.

3.5 MÁSCARA DE SUPERPIXELS

Os superpixels são utilizados com a finalidade de contribuir no isolamento do ventrículo cerebral. Basicamente, é levado em consideração o potencial da ferramenta em respeitar os contornos da imagem. Nessa aplicação, os superpixels são encontrados e a média de cada um é calculada. Em seguida, ocorre a inserção de um quadrilátero no centro da imagem com a finalidade de manter apenas os superpixels onde o ventrículo está contido. Por fim, esse quadrilátero é binarizado e usado como máscara, conforme a Figura 3.3. Nessa circunstância, uma parcela considerável de sulco cerebral e da calota craniana devem ser descartadas, culminando em uma região de interesse (ROI, do inglês *Region of Interest*) quase isolada.

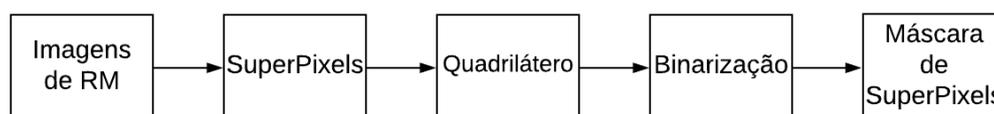


Figura 3.3. Método para a máscara de superpixels.

3.6 MÁSCARA MORFOLÓGICA

A morfologia matemática é inserida na imagem de RM com a finalidade de isolar o ventrículo cerebral e, em seguida, ser utilizada como máscara juntamente com os superpixels. Dessa forma, baseado na pesquisa [7], que isola o tumor cerebral usando morfologia, a soma das Transformadas *Top-Hat* e *Bottom-Hat* foram realizadas. A primeira fornece uma imagem em que os elementos mais claros são extraídos, ao mesmo tempo em que a segunda concede uma imagem com os elementos escuros [63]. A fusão dessas imagens fornece uma saída onde as informações pertinentes, para esta pesquisa, da imagem original

são enfatizadas [4]. Por fim, segmentação é feita após a definição de um limiar empírico. Finalmente, pequenos objetos são retirados da imagem e uma dilatação é realizada, restando, na maioria das imagens, apenas o ventrículo cerebral, de acordo com a Figura 3.4. A imagem resultante, juntamente com a imagem de superpixels, servirão como máscara para o isolamento do ventrículo na segmentação GLCM.

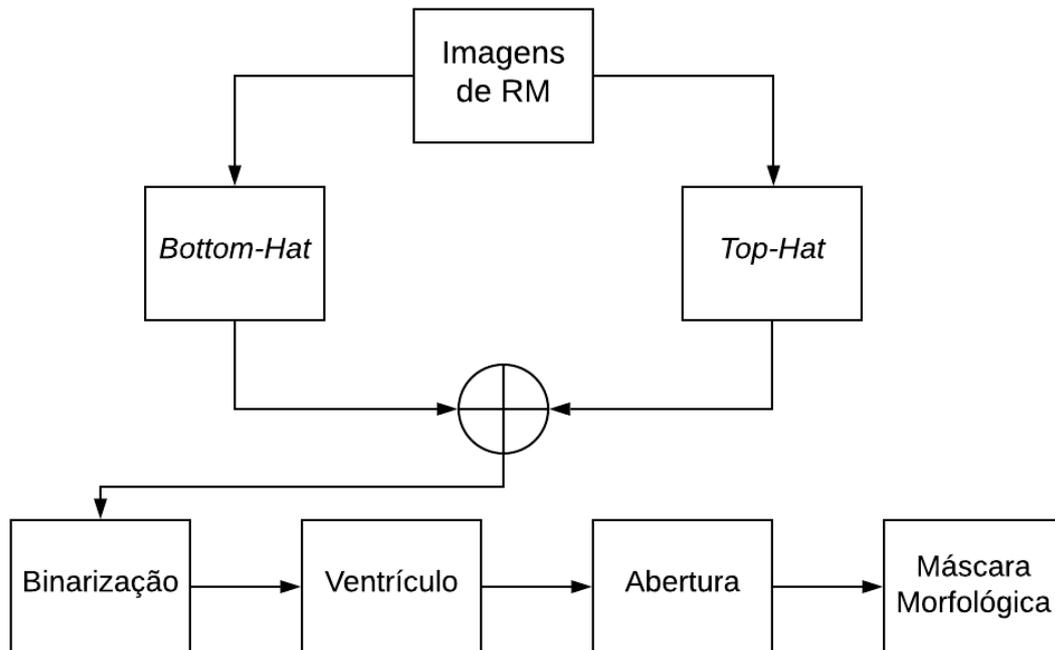


Figura 3.4. Método morfológico para isolamento do ventrículo.

3.7 ESTIMATIVA DA ÁREA DO CÉREBRO

A imagem de RM é binarizada baseada em Otsu, que escolhe um valor limite para minimizar a variação entre as classes dos pixels preto e branco. Em seguida, ocorre a remoção de objetos que não pertencem à área por meio das operações morfológicas de dilatação e erosão, como explicitado na Figura 3.5

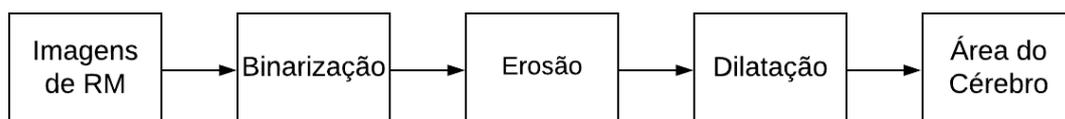


Figura 3.5. Método utilizado para encontrar a área do cérebro.

3.8 DESCRITORES PARA CLASSIFICAÇÃO

Assim sendo, a extração de parâmetros torna-se essencial para que a separação dos grupos possa ser realizada. Dessa forma, medidas como área, v , e perímetro, χ , do ventrículo e do cérebro são estimadas, a fim de calcular a razão associada a cada imagem, conforme as Equações 3.1 e 3.2.

$$v = \frac{\text{Área do Ventrículo}}{\text{Área do Cérebro}}, \quad (3.1)$$

$$\chi = \frac{\text{Contorno do Ventrículo}}{\text{Contorno do Cérebro}}. \quad (3.2)$$

3.9 CLASSIFICAÇÃO DE PADRÕES UTILIZANDO SVM

Nessa etapa, os parâmetros obtidos são inseridos no classificador SVM a fim de separar o grupo de controle do grupo de portadores de esquizofrenia. A escolha para a classificação foi randômica, sendo 70% para treinamento e 30% para validação.

Após a validação, medições de desempenho foram obtidas com o objetivo de contribuir na análise dos resultados. As medições são o percentual de erros de entrada de treino e validação, falsos positivos, falsos negativos, verdadeiros positivos, verdadeiros negativos, sensibilidade e especificidade.

Diante desse contexto, uma matriz de confusão adaptada é usada para avaliar o classificador baseado nos parâmetros do tipo ROC (do inglês *Receiver Operating Characteristics*) [27], conforme a Tabela 3.1. No caso dessa pesquisa, o grupo de portadores de esquizofrenia é o dos positivos, enquanto o grupo de controle estão associados aos negativos.

Tabela 3.1. Adaptação da matriz confusão utilizada na avaliação de classificadores

	Positivos	Negativos
Positivos	Verdadeiro Positivo - VP	Falso Positivo - FP
Negativos	Falso Negativo - FN	Verdadeiro Negativo - VN

- Verdadeiro Positivo (VP) - Indica os casos em que os indivíduos foram detectados corretamente com a esquizofrenia.

- Falso Positivo (FP) - Indica os casos em que os indivíduos foram diagnosticados como do grupo de controle, mas possuem a patologia.
- Verdadeiro Negativo (VN) - Indica os casos em que os indivíduos foram classificados como do grupo de controle e, realmente, não são portadores de esquizofrenia.
- Falso Negativo (FN) - Indica os casos em que os indivíduos foram diagnosticados como do grupo de controle, mas possuem a doença.

A partir dessas informações, os cálculos de acurácia, precisão, sensibilidade e especificidade podem ser executados.

A acurácia irá exibir a proporção de acertos, isto é, o total de verdadeiros positivos e verdadeiros negativos quando comparados a toda a amostra.

$$\iota = \frac{VP + VN}{VP + VN + FP + FN}. \quad (3.3)$$

A precisão irá mostrar os resultados considerados positivos e que são de fato positivos.

$$\varpi = \frac{VP}{VP + FP}. \quad (3.4)$$

A sensibilidade irá averiguar a capacidade de diagnosticar os verdadeiros positivos em indivíduos doentes. Quanto mais sensível for o teste mais raramente deixa de encontrar pessoas portadoras da patologia.

$$\varrho = \frac{VP}{VP + FN}. \quad (3.5)$$

Por fim, a especificidade apresenta os verdadeiros negativos nos pacientes verdadeiramente saudáveis. Quanto mais específico for o teste, mais dificilmente uma pessoa saudável será inserida no grupo de portadores de esquizofrenia [27] [55].

$$\delta = \frac{VP}{VN + FP}. \quad (3.6)$$

4 RESULTADOS E DISCUSSÕES

O primeiro passo, como mencionado na metodologia, consiste na aplicação dos exames de RM em cada uma das transformadas a fim de obter os contornos que irão evidenciar o ventrículo cerebral. As próximas seções apresentarão, de maneira detalhada, cada uma das etapas.

4.1 RESULTADOS DA APLICAÇÃO DAS TRANSFORMADAS

4.1.1 Resultado da Transformada *Wavelet*

A Transformada Wavelet tem como uma das suas principais aplicações a detecção de bordas, que serve como base para uma futura segmentação ou para reconhecimento de objetos, por exemplo. No contexto dessa pesquisa, essa ferramenta é utilizada para obter o contorno ventricular além de, posteriormente, segmentá-lo.

Nessa aplicação, a imagem de RM é inserida, executando a transformada em três níveis de decomposição. Obviamente, conforme já explicada nas seções anteriores, em cada decomposição há uma diminuição da resolução pela metade e o fornecimento de quatro novas imagens, conforme exibido na Figura 4.1. Uma das imagens contém os coeficientes de aproximação, enquanto as outras três (diagonal, horizontal e vertical) possuem os coeficientes de detalhes. Por se tratar de um processo recursivo, a imagem com os coeficientes de aproximação pode ser reinserida na função para gerar outras quatro imagens, porém com a metade da resolução.

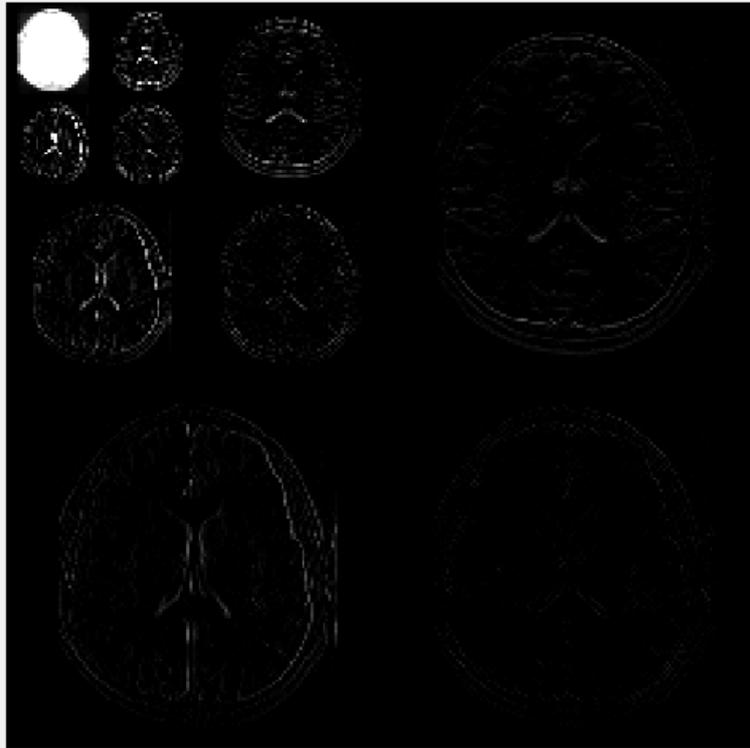


Figura 4.1. Processamento de imagem de RM com a DWT. A imagem no canto superior esquerdo indica a aproximação com resolução 32x32. As três imagens que a cerca indicam os detalhes horizontais (baixo), verticais (lado), diagonais (diagonal), sendo todos com uma resolução de 32x32. Da mesma forma, as imagens ao lado indicam suas respectivas imagens de detalhes com uma resolução de 64x64 e 128x128.

A imagem de aproximação possui informações sobre as propriedades globais e sua remoção culmina em grandes distorções. A sub-banda que representa a imagem de detalhes vertical possui dados ligados às linhas horizontais ocultas na imagem e sua remoção resultará na exclusão dos contornos horizontais. A sub-banda que representa a imagem de detalhes horizontal possui dados ligados às linhas verticais ocultas na imagem e sua eliminação resultará na diminuição dos contornos verticais. Por fim, a imagem diagonal expõe contornos escondidos na diagonal e sua dispensa gera pequenas distorções.

O objetivo é conseguir o contorno ventricular e, para tal tarefa, é necessário reconstruir a imagem, excluindo os coeficientes de aproximação a fim de obter os contornos do estudo por RM, que são características das altas frequências. Estes contornos, apresentados na Figura 4.1, são reconstruídos e apresentados na Figura 4.2.

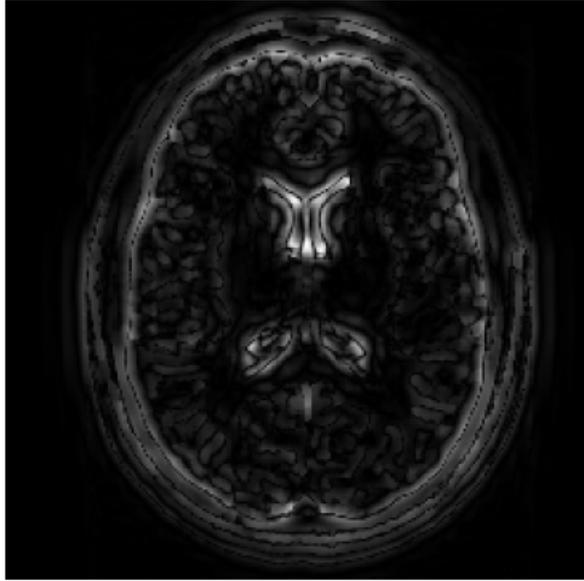


Figura 4.2. Imagem de RM reconstruída após três níveis de decomposição DWT e a eliminação dos coeficientes de aproximação.

A imagem de RM reconstruída consegue gerar os contornos do ventrículo, mas fica evidente que alguns detalhes estão ausentes e as singularidades de linha e curva não estão reproduzidas fidedignamente como, por exemplo, a parte inferior da ROI.

Ademais, para melhorar a visualização, é apresentada, na Figura 4.3, um exemplo em perspectiva tridimensional (os valores dos níveis de cinza são diretamente proporcionais às alturas representadas), onde o ventrículo recebe seu destaque no centro da imagem. Todavia, como esperado, os contornos externos também ficaram em destaque.

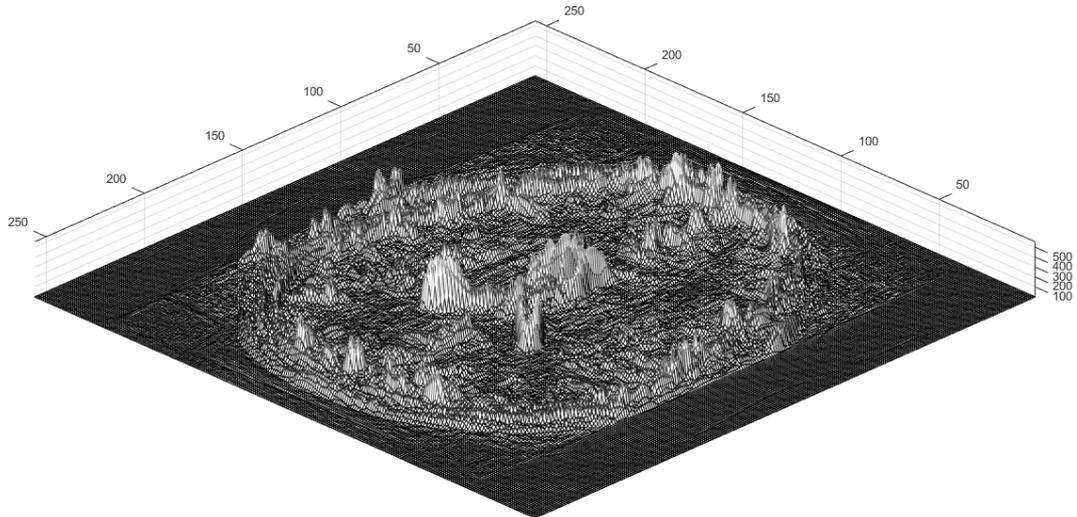


Figura 4.3. Perspectiva tridimensional dos contornos destacados da imagem de RM após processamento com a DWT. Entretanto, os contornos externos igualmente presentes.

4.1.2 Resultado da DT-CWT

A inserção da imagem de RM na DT-CWT, é baseada em duas árvores de decomposição DWT, uma com coeficientes reais e a outra com os imaginários. Como esperado, a DT-CWT deve ser superior a DWT por conta da invariância ao deslocamento e a seletividade direcional. Logo, os coeficientes da *wavelet* complexa deve fornecer uma medida precisa da energia espectral em um local específico no espaço, escala e orientação. Essas características reduzem os artefatos presentes na DWT.

Inicialmente, é introduzida no algoritmo a imagem de RM a fim de obter os contornos assim como na DWT anterior. Dessa maneira, os filtros e as decomposições são escolhidas e o processo se inicia. No caso dessa pesquisa, ocorre uma decomposição em três níveis, gerando, nas duas árvores, dois tipos de coeficientes, o real e o imaginário, presentes nas Figuras 4.4 e 4.5, respectivamente.

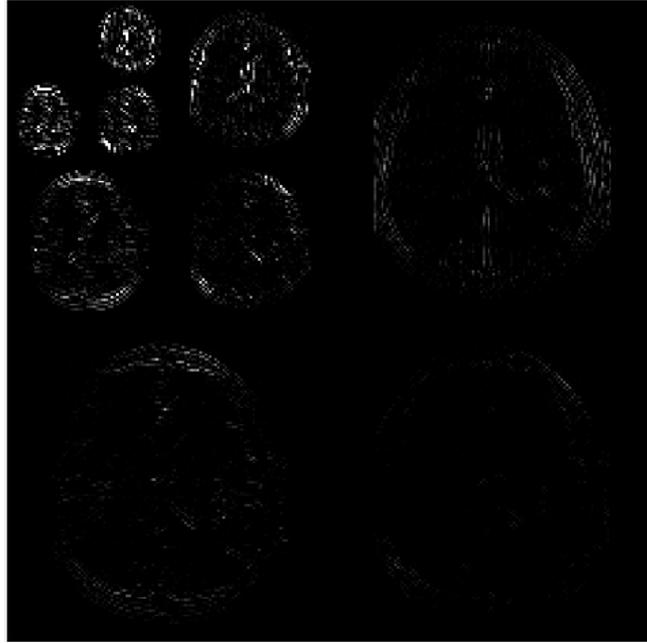


Figura 4.4. Processamento de imagem de RM com a DT-CWT. A imagem mostra a decomposição em três níveis da parte complexa.

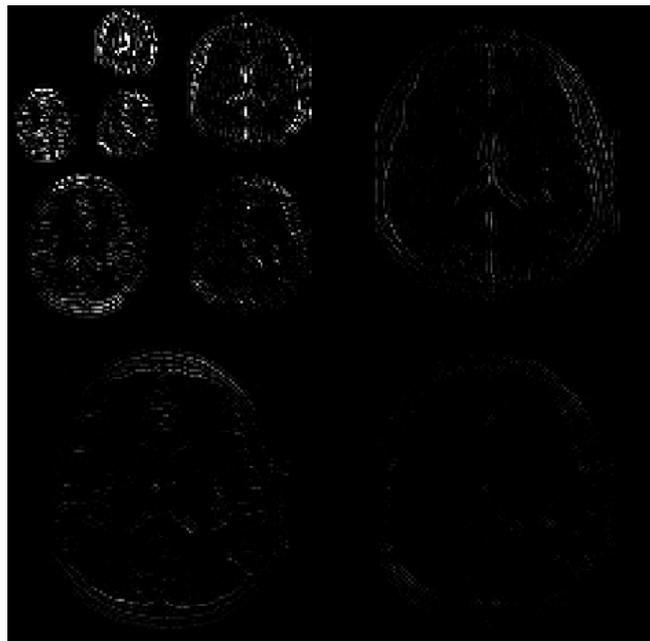


Figura 4.5. Contornos destacados da imagem de RM após processamento com a DT-CWT. Entretanto, os contornos externos mostram-se igualmente presentes.

Assim como na DWT, ocorre a reconstrução da imagem, excluindo tanto na parte real quanto na imaginária os coeficientes de aproximação com a finalidade de extrair os contornos do ventrículo cerebral. É importante ressaltar que, de forma análoga à DWT, há a redução da resolução a cada decomposição, conforme as Figuras 4.4 e 4.5.

A reconstrução é realizada com as imagens denominadas detalhes, destacando as

altas frequências, conforme a Figura 4.6., onde é possível observar o contorno ventricular, assim como as bordas dos sulcos cerebrais. Quando comparada à Figura 4.2, apesar da diferença esperada por conta da sofisticação inerente à DT-CWT, a semelhança com a DWT é notável.

Além disso, para melhorar a visualização é apresentada na Figura 4.7 uma perspectiva tridimensional, onde o ventrículo recebe seu destaque, juntamente com as bordas externas.

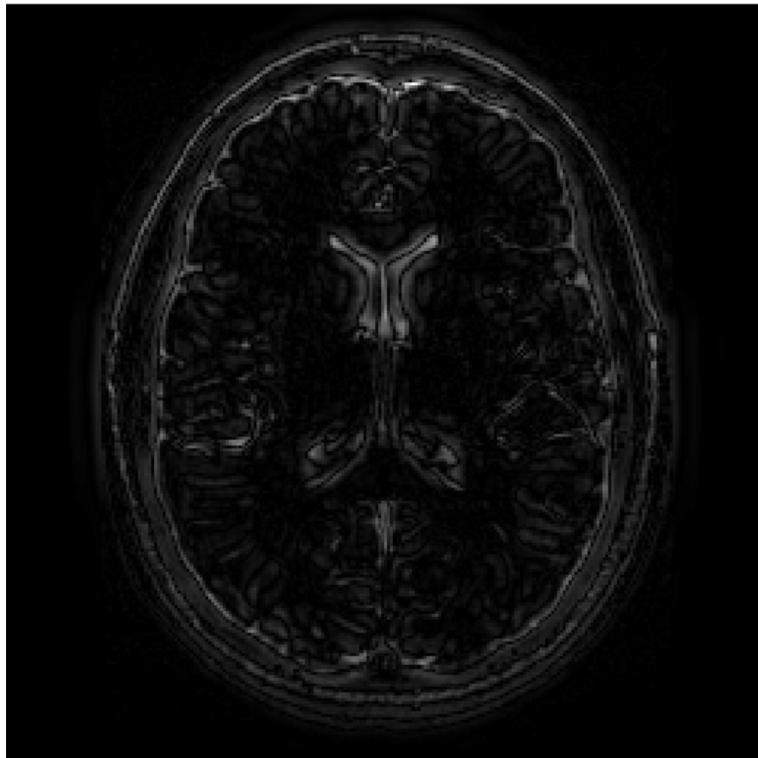


Figura 4.6. Imagem de RM reconstruída após a aplicação da DT-CWT evidenciando os contornos.

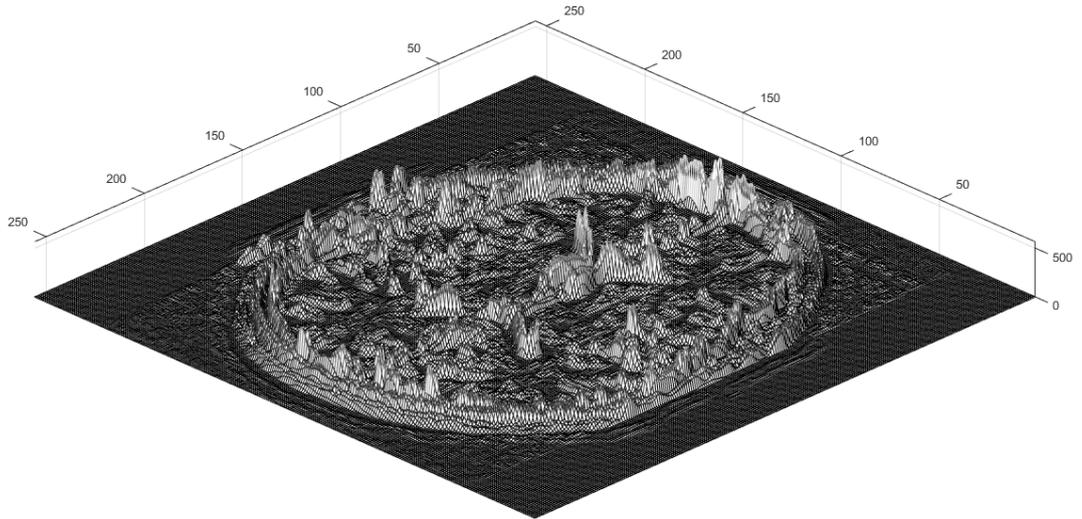


Figura 4.7. Perspetiva tridimensional dos contornos destacados da imagem de RM após o processamento com a DT-CWT.

4.1.3 Resultado da Transformada *Contourlet*

Na Transformada *Contourlet*, a etapa inicial é a seleção dos filtros piramidal e direcional além dos níveis de decomposição. Os filtros utilizados, tanto direcional quanto piramidal são o 9-7 e a Figura 4.8 apresenta as imagens de RM decompostas em quatro níveis piramidais, que são então decompostas em dois, quatro, oito e dezesseis sub-bandas direcionais.

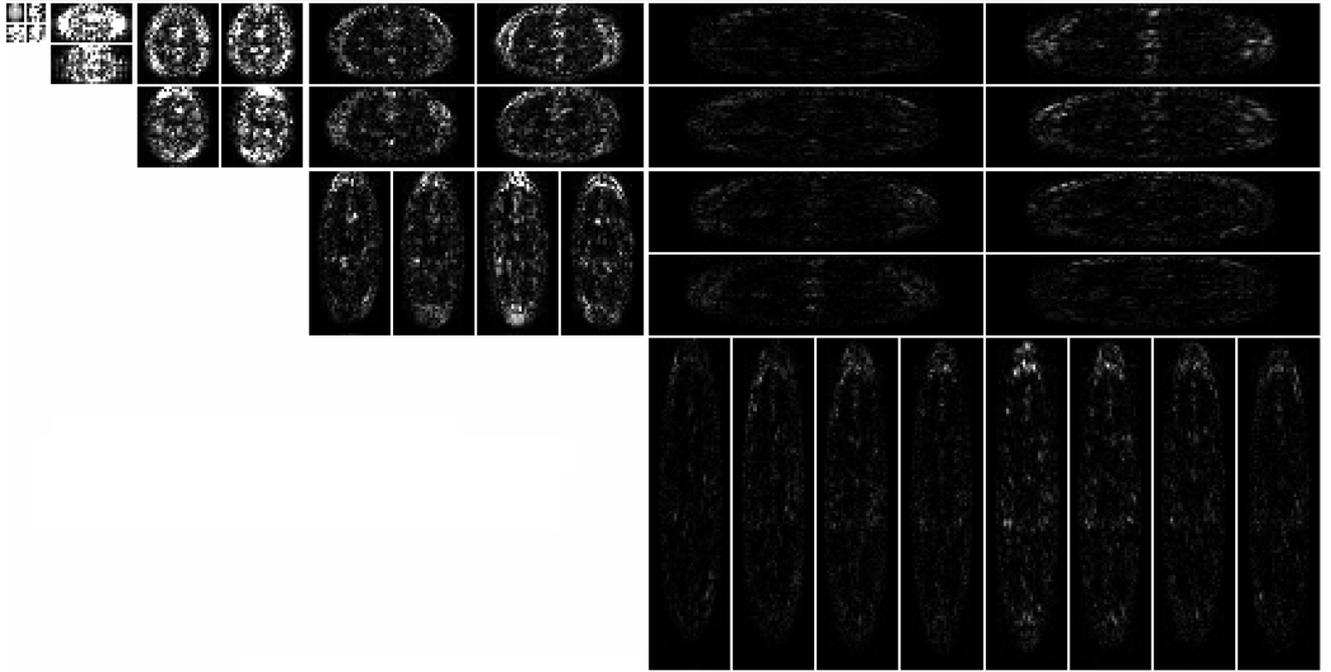


Figura 4.8. Processamento de imagem de RM com a Transformada *Contourlet*. Nesta imagem, pequenos coeficientes são mostrados em preto, enquanto grandes coeficientes são mostrados em branco.

Em seguida, a imagem de RM é reconstruída com a utilização dos mesmos filtros e excluindo a sub-banda passa-baixas, resultando em uma imagem onde as altas frequências, isto é, os contornos ficam destacados, conforme a Figura 4.9. Como esperado, as bordas na Transformada *Contourlet* são melhores preservadas do que na DWT, fazendo com que seu desempenho para essa aplicação seja mais eficaz por conta de duas características que são mais aprimoradas na ferramenta como a direcionalidade e anisotropia [37]. A primeira indica que a representação deve conter elementos de base orientados em uma variedade de direções, muito mais do que as poucas direções das *Wavelets*, enquanto a segunda captura os contornos suaves das imagens com os elementos de base usando uma variedade de formas alongadas com diferentes proporções.

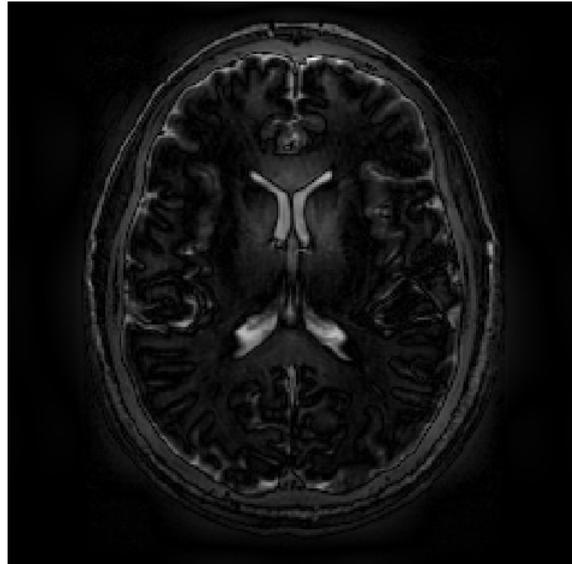


Figura 4.9. Contornos destacados da imagem de RM reconstruída após a aplicação da Transformada *Contourlet*.

Porém, de acordo na Figura 4.10, o contorno ventricular ficou acentuado, mas alguns contornos indesejados ficaram presentes, principalmente perto das bordas da imagem. Quando comparado com as Figuras 4.2 e 4.6, há uma melhoria na captura do contorno do ventrículo.

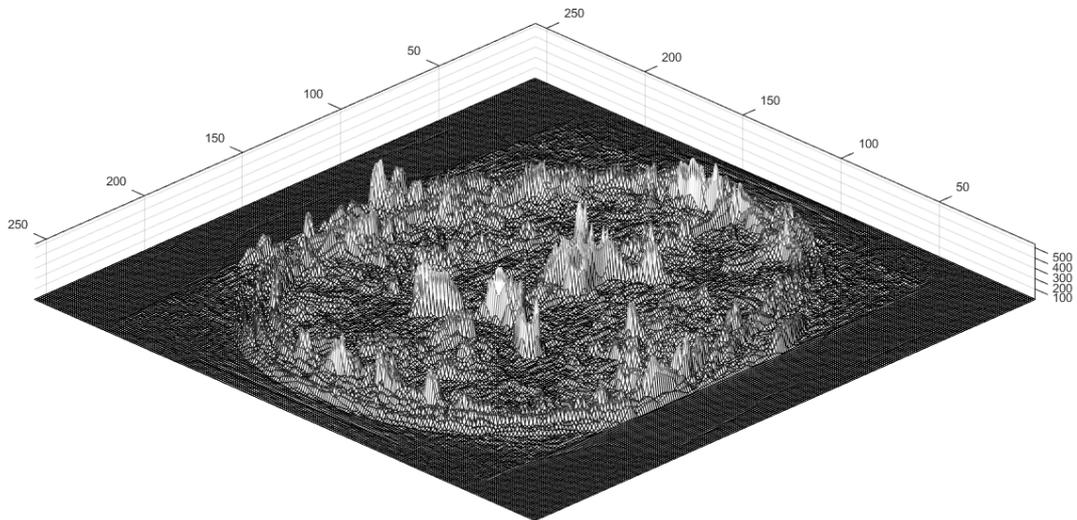


Figura 4.10. Perspectiva tridimensional dos contornos destacados da imagem de RM após o processamento da Transformada *Contourlet*.

4.2 INSERÇÃO DOS CONTORNOS PARA CÁLCULO DA GLCM E SEGMENTAÇÃO

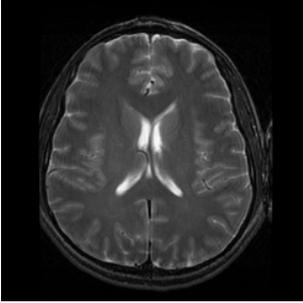
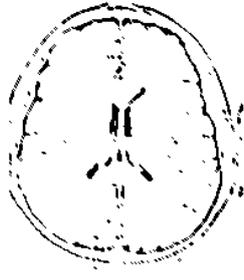
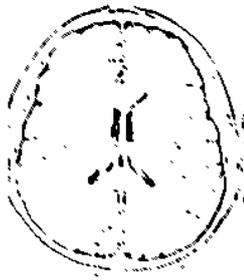
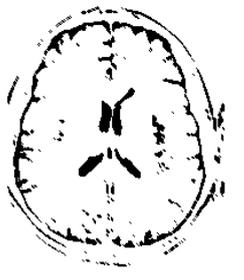
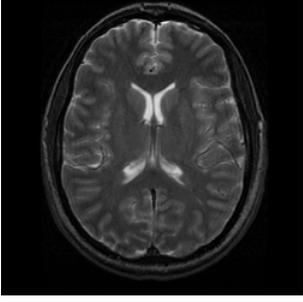
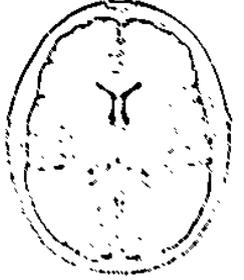
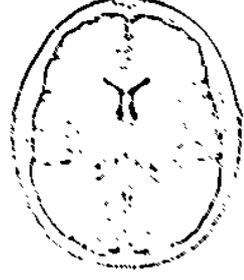
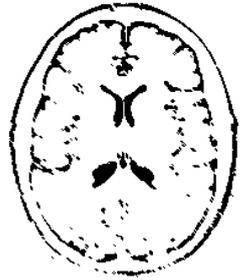
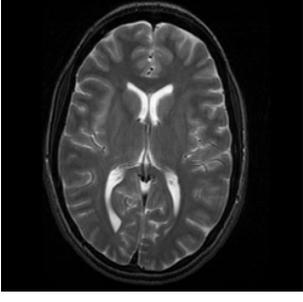
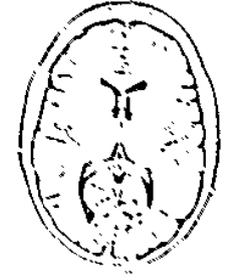
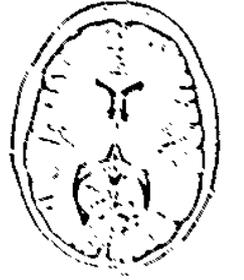
Com a obtenção dos contornos por meio das três transformadas, a GLCM de cada imagem é calculada a fim de extrair os parâmetros de contraste, homogeneidade, energia e correlação, exibidos na Tabela 4.1. Utilizando uma distância $d=1$ e um $\theta =0$, os resultados a seguir, Tabela 4.1, indicam características importantes a respeito das imagens. Os valores de contraste da DWT e da DT-CWT são maiores por conta da menor definição dos contornos e, conseqüentemente, a maior presença de buracos, culminando também em uma menor homogeneidade. Com relação à homogeneidade, que é basicamente o oposto do contraste, a Transformada *Contourlet* possui o maior valor, mesmo de maneira discreta. Isso ocorre por efeito da melhor aquisição do contorno, diminuindo consideravelmente o número de buracos, deixando a imagem mais homogênea. A energia está ligada à uniformidade da textura, ou seja, à repetição de padrões. Haja vista a explanação anterior, os valores deste parâmetro contidos na *Contourlet* são menores devido ao destaque dado ao contorno. Por fim, a correlação indica a similaridade maior entre os pixels da Transformada *Contourlet*.

Tabela 4.1. Os parâmetros extraídos das GLCM's.

	Contraste	Homogeneidade	Energia	Correlação
DWT	251.2608	0.2097	0.00120	0.3179
DT-CWT	202.2075	0.2135	0.00130	0.2972
Transformada <i>Contourlet</i>	169.9312	0.2214	0.00088	0.6653

Além disso, uma imagem em escala reduzida é sintetizada, contendo apenas a quantidade de níveis preenchidos. No caso desta pesquisa, as imagens possuem oito níveis, por terem tamanho de 256x256 pixels. Todavia, há ocorrências em apenas cinco níveis, gerando uma imagem em escala que é usada para a segmentação. Com a imagem redimensionada, criando uma função que converta os valores de pixels iguais a 1 em branco e os outros (2, 3, 4 e 5) em preto por meio de uma função que utiliza um bloco deslizante de [1,1], seguida de limiarização, alcança-se uma segmentação baseada em GLCM, conforme a Tabela 4.2.

Tabela 4.2. Resultado da Segmentação GLCM para cada Transformada.

Imagem Original	DWT	DT-CWT	Transformada <i>Contourlet</i>
			
			
			

A segmentação de cada uma das transformadas apresentou algumas características esperadas e outras não. O primeiro assunto está relacionado com a proximidade das imagens segmentadas da DWT e da DT-CWT. Este ponto não era previsto por conta das sofisticações inerentes da DT-CWT quando comparada com a DWT. Desta maneira, era aguardado um maior número de detalhes na DT-CWT. Outro ponto consiste na diferença entre a Transformada *Contourlet* e as outras ferramentas, onde é nítida a diferença de detalhes segmentados. A Tabela 4.2 mostra as diferenças. A superioridade da textura da Transformada *Contourlet* ocorre por conta da melhor extração dos contornos da imagem de RM. Consequentemente, a segmentação por textura possui resultados melhores, já que há mais homogeneidade e o contraste tem um valor consideravelmente alto, mesmo sendo inferior às demais transformadas. Então, como o sistema ventricular ficou melhor delineado em relação às outras transformadas, a segmentação GLCM da Transformada *Contourlet* foi priorizada em detrimento das outras duas funções, antes de prosseguir com as demais etapas do método proposto, também para concentrar os

esforços computacionais.

Devido a este fator e por ser a transformada que manteve o maior número de informações ventriculares, a Transformada *Contourlet* foi escolhida para as próximas etapas.

4.3 CRIAÇÃO DE MÁSCARA AUTOMÁTICA UTILIZANDO SUPERPIXELS E MORFOLOGIA MATEMÁTICA

Ao analisar os cortes axiais do cérebro em que o ventrículo encontra-se, é possível aplicar a ferramenta de superpixels, que respeita os limites reais da imagem a fim de isolar a ROI. Além disso, devido à localização central do ventrículo, foi estabelecido um quadrilátero posicionado ao centro da imagem de RM com a finalidade de excluir todo parênquima cerebral circundante aos ventrículos laterais. Obviamente, apenas os superpixels contidos no quadrilátero são mantidos e, adiante, binarizados, conforme a Tabela 4.3.

Ademais, a utilização da morfologia matemática para a aquisição de uma segunda máscara que consiga isolar definitivamente os ventrículos se fez necessária. Apesar de que um número razoável de imagens resultaram no isolamento satisfatório da imagem de RM somente com os superpixels, algumas outras imagens de RM ainda possuíam informações que não faziam parte da ROI. Logo, com a soma das transformadas *Top-Hat* e *Bottom-Hat* das imagens originais seguida de uma binarização, com um limiar de 122, foi exequível isolar a ROI. Assim sendo, alguns objetos pequenos foram retirados utilizando a operação de abertura morfológica. Os resultados, a fim de exemplificação, são mostrados na Tabela 4.4. Em ambas as transformadas foram utilizados um elemento estruturante de disco 1, enquanto a dilatação final um disco de 8 se fez mais apropriado.

Tabela 4.3. Resultado da Segmentação Baseada em Superpixels do Retângulo Selecionado.

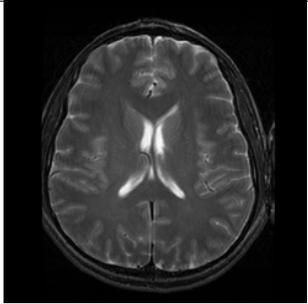
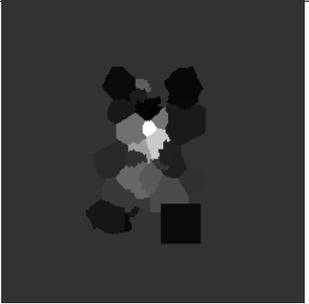
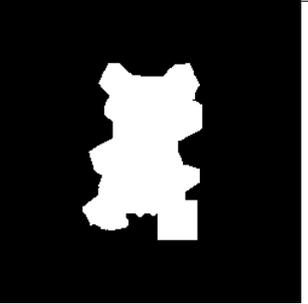
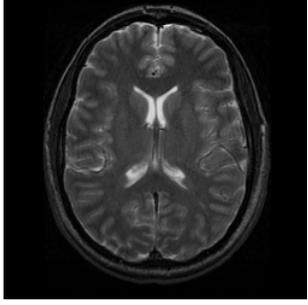
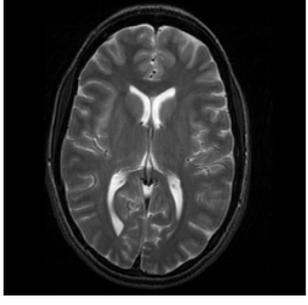
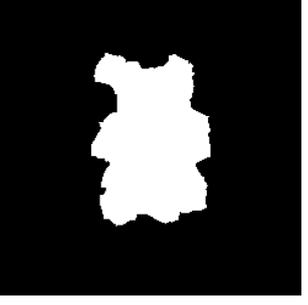
Imagem Original	Transformada <i>Contourlet</i>	Binarização
		
		
		

Tabela 4.4. Imagens com exemplos de resultados do processamento aplicado para obtenção da Máscara Morfológica.

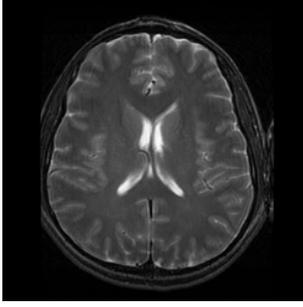
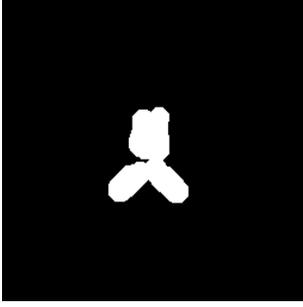
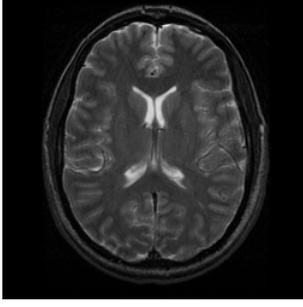
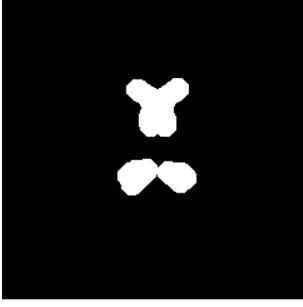
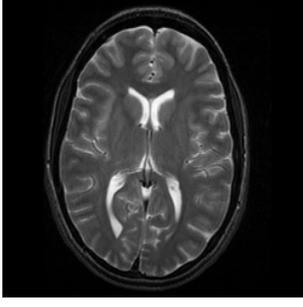
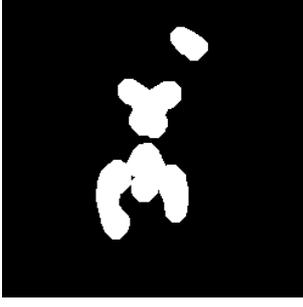
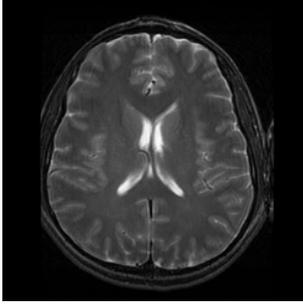
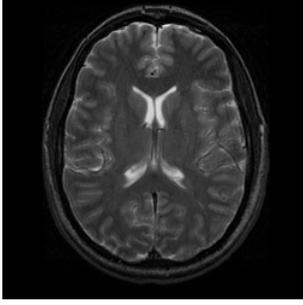
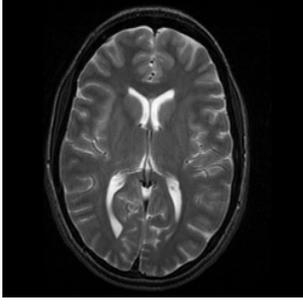
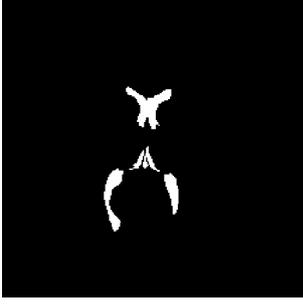
Imagem Original	<i>Morfologia Matemática</i>
	
	
	

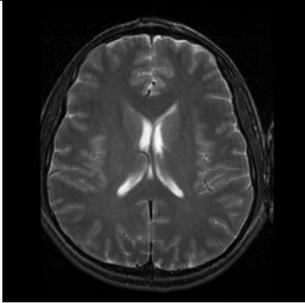
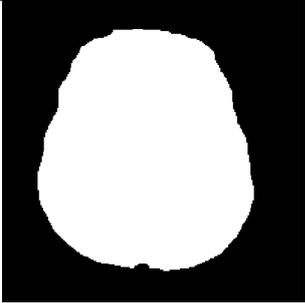
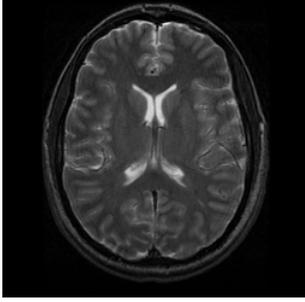
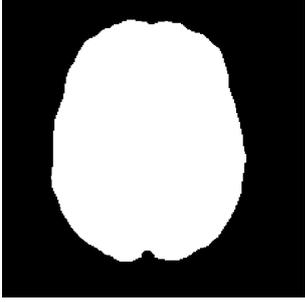
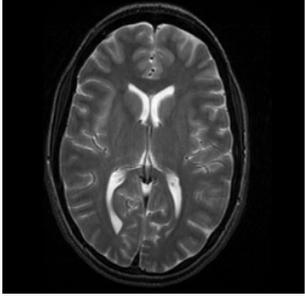
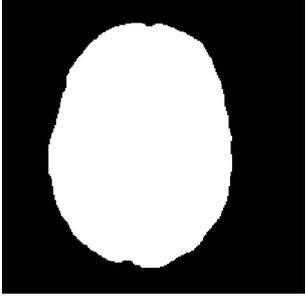
Tabela 4.5. Imagens com exemplos de resultados do processamento aplicado para obtenção dos ventrículos isolados.

Imagem Original	Ventrículo Isolado
	
	
	

4.4 ÁREA DO CÉREBRO

A área total do cérebro é obtida por meio da binarização da imagem de RM seguida da retirada de pequenos objetos utilizando a abertura morfológica, seguida da operação de fechamento morfológico com disco de raio 5, objetivando excluir objetos indesejados que não fazem parte da região, de acordo com a Tabela 4.6.

Tabela 4.6. Imagens com exemplos de resultados do processamento aplicado para obtenção da estimativa da área do cérebro.

Imagem Original	Área do Cérebro
	
	
	

4.5 EXTRAÇÃO DE PARÂMETROS E CLASSIFICAÇÃO UTILIZANDO SVM

Com o ventrículo isolado e a área total do cérebro, os parâmetros extraídos foram a razão da área do ventrículo pela área do cérebro e a razão do contorno do ventrículo com o contorno do cérebro. Com esses dados obtidos, eles são inseridos no classificador SVM com a finalidade de classificação, fornecendo os histogramas de acurácia, precisão, sensibilidade e especificidade. Os histogramas exibirão os resultados percentuais de desempenho para as entradas de desempenho de validação e treinamento.

Nessa pesquisa, foram realizadas mil testes para validar o desempenho do classificador. Os histogramas que serão exibidos a seguir estão organizados da seguinte forma: o eixo x é o percentual de erros para as entradas (treinamento e validação), enquanto o eixo y é dado o número de ocorrências, que, neste caso, foi de mil repetições.

A acurácia, indicada na Figura 4.11, diz que a possibilidade de um paciente verdadeiramente portador de esquizofrenia, ou verdadeiramente sadio, ser diagnosticado corretamente é de cerca de 70%.

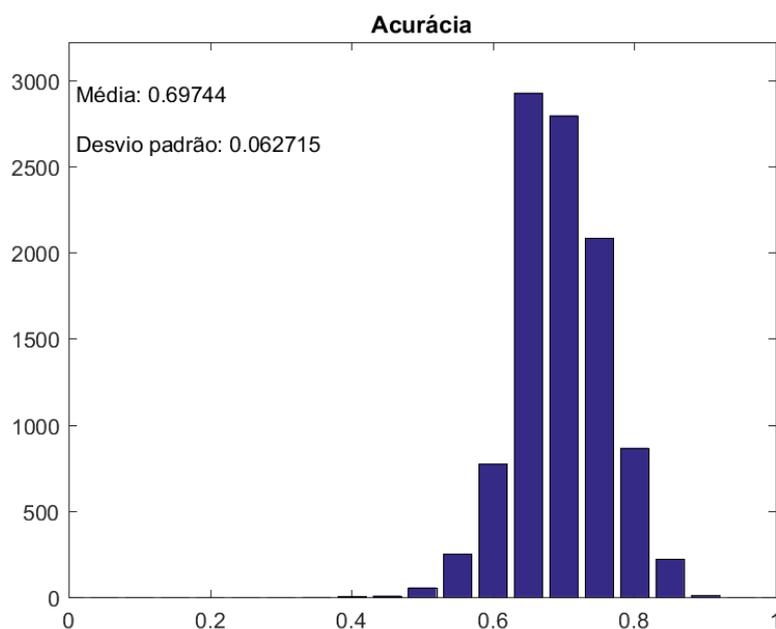


Figura 4.11. Histograma de Acurácia.

A precisão, mostrada na Figura 4.12, avalia a quantidade de acertos na classificação de indivíduos portadores de esquizofrenia que, nesta pesquisa, é de 71%.

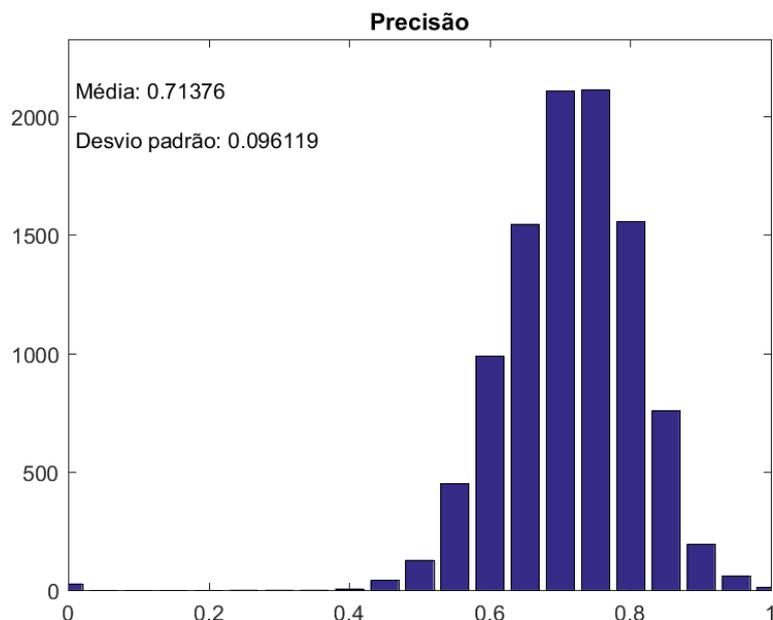


Figura 4.12. Histograma de Precisão.

A capacidade de diagnosticar os verdadeiros positivos nos indivíduos que, de fato, estão doentes é chamada sensibilidade, representada na Figura 4.13. Quando o teste é sensível, raramente deixa de encontrar pessoas com a doença. O maior número de ocorrências é por volta dos 64%, ou seja, há cerca de 64% de probabilidade de um indivíduo que é considerado do grupo de portadores de esquizofrenia ser, de fato, portador.

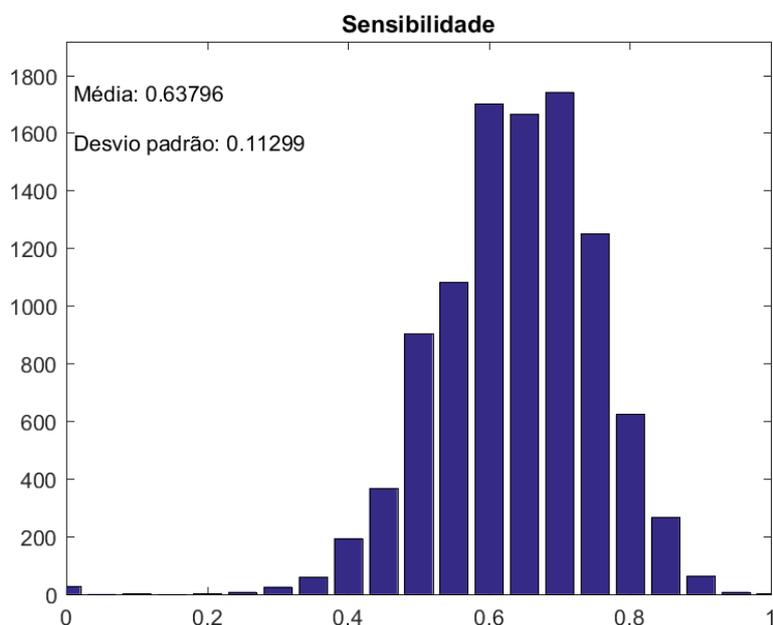


Figura 4.13. Histograma de Sensibilidade.

O teste que vai diagnosticar os verdadeiros negativos nos indivíduos verdadeiramente saudios é a especificidade, exibida na Figura 4.14. Um teste específico dificilmente comete o erro de dizer que uma pessoa sadia é doente. Esse é o teste com maior número de

ocorrências, aproximadamente 75%. Existe cerca de 75% de chance de um paciente que não é portador de esquizofrenia ser diagnosticado como sadio.

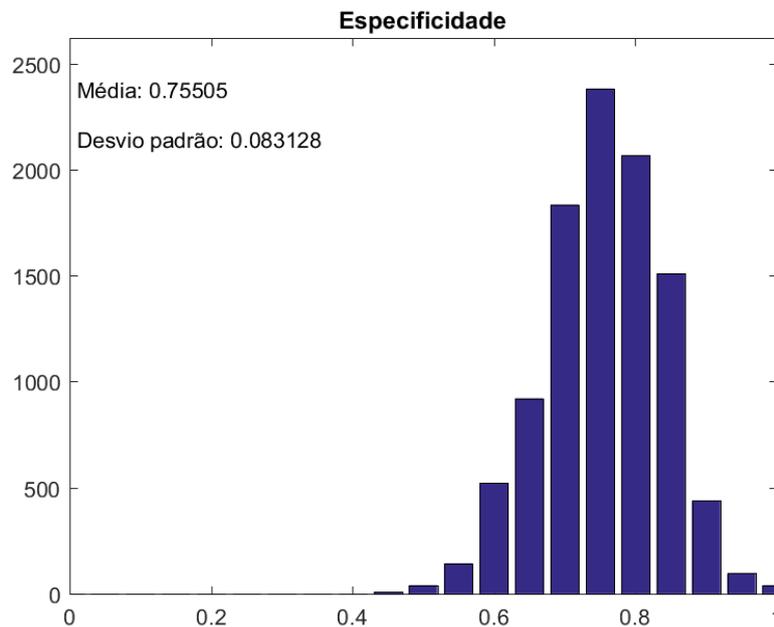


Figura 4.14. Histograma de Especificidade.

4.6 CORTES TRANSVERSAL, SAGITAL E CORONAL

No intuito de apresentar diferentes tipos de corte, tanto da imagem de RM original como da imagem segmentada, esta seção irá apresentar os cortes transversais, sagitais e coronais de todo o processo, objetivando demonstrar, mesmo de forma visual, a diferença do ventrículo cerebral do grupo de controle e do grupo de portadores de esquizofrenia. No caso dos cortes coronal e sagital não houve uma nova classificação, sendo esta utilizada apenas no corte axial.

4.6.1 Corte Transversal

A Figura 4.15 apresenta os cortes transversais das vinte e sete fatias do cérebro de um paciente saudável, à esquerda, e um paciente portador da doença, à direita. Como o foco da pesquisa é aferir a dilatação do sistema ventricular cerebral, as imagens de RM que contêm esse fragmento do cérebro serão separadas a fim de comparação, conforme a Figura 4.16.

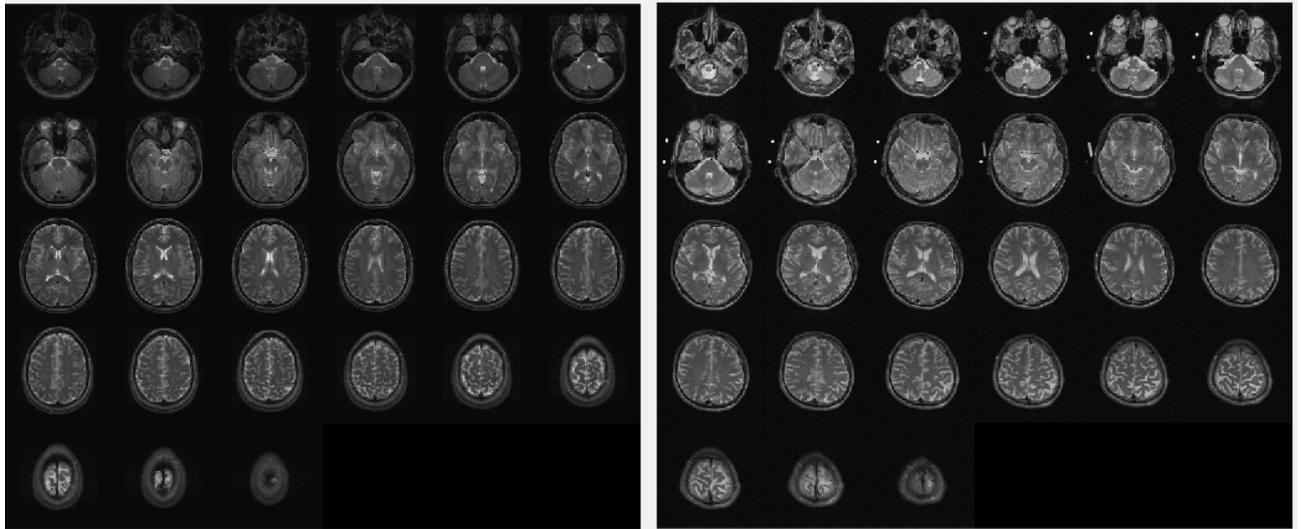


Figura 4.15. Corte Transversal: à esquerda, grupo de controle; à direita, grupo de portadores de esquizofrenia.

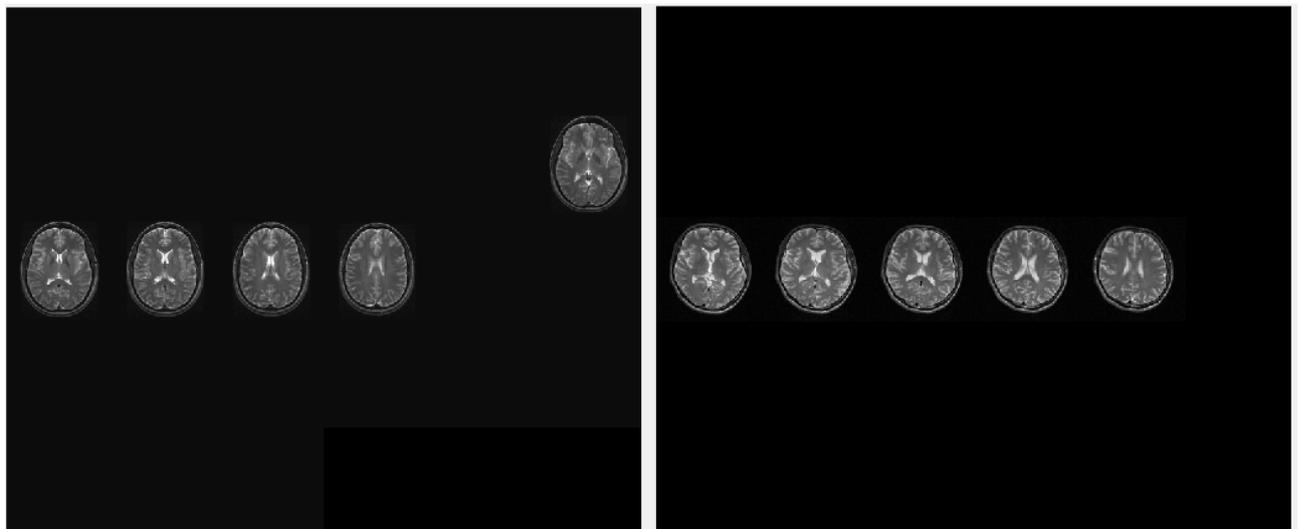


Figura 4.16. Corte Transversal com Ventrículo: à esquerda, grupo de controle; à direita, grupo de portadores de esquizofrenia.

Percebe-se, na Figura 4.17, que os ventrículos estão mais dilatados no grupo de portadores de esquizofrenia do que no grupo de controle, como indicam as pesquisas acerca das alterações cerebrais e também como essa pesquisa apresentou na seção anterior, podendo ser um fator importante no diagnóstico clínico.

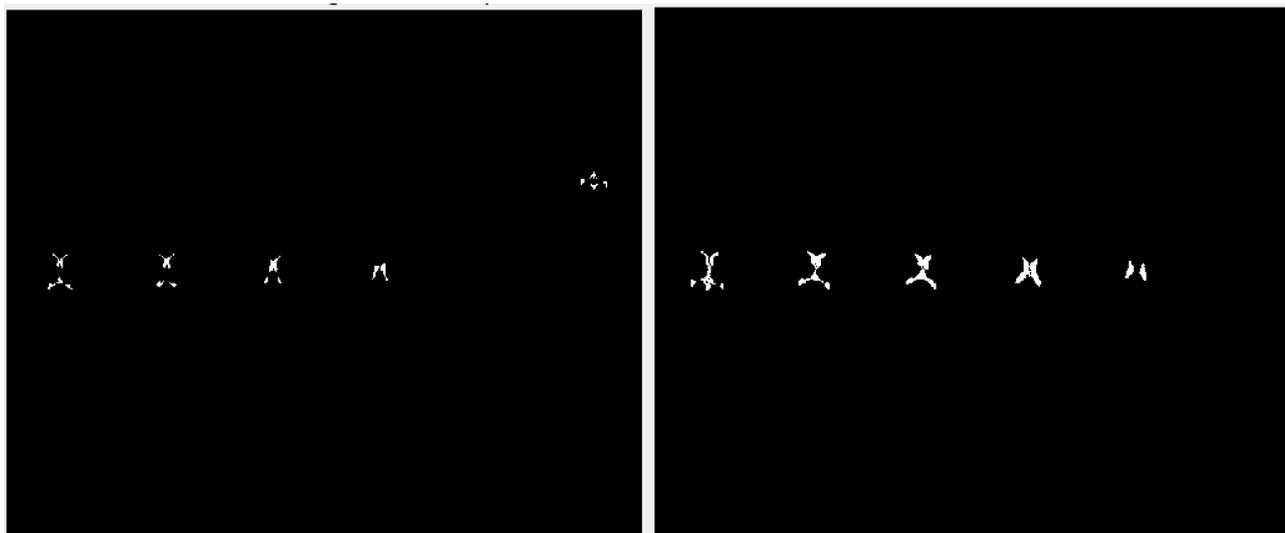


Figura 4.17. Corte Transversal com Ventrículo Segmentado: à esquerda, grupo de controle; à direita, grupo de portadores de esquizofrenia.

4.6.2 Corte Sagital

Nesta subseção, serão apresentados os cortes sagitais de ambos os grupos, conforme a Figura 4.18, que indica, à esquerda, o grupo de controle e, à direita, o grupo de portadores de esquizofrenia.

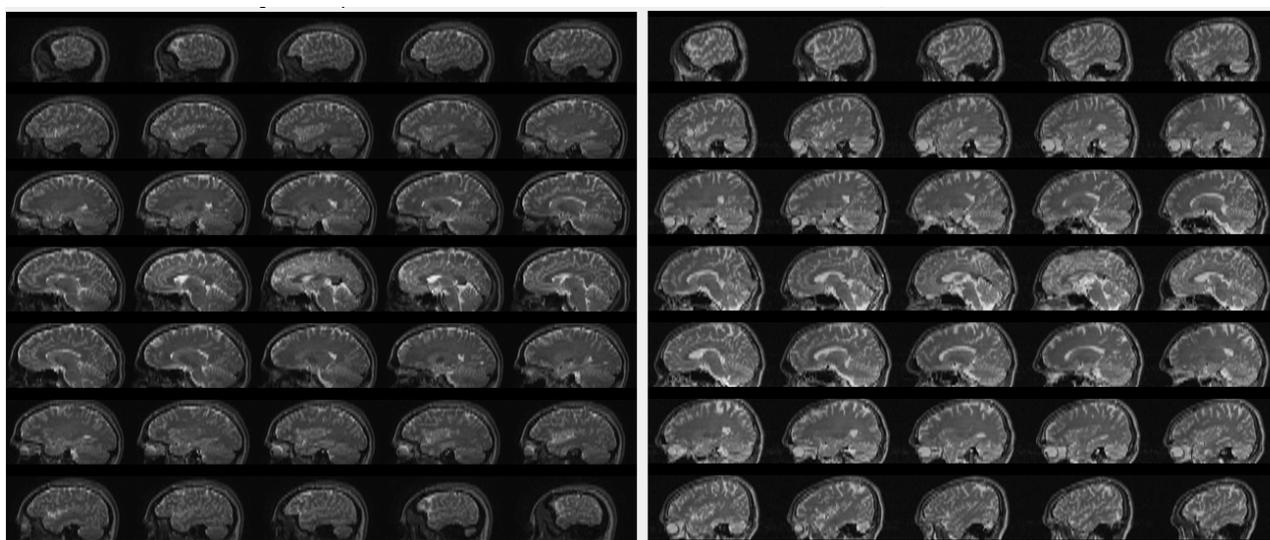


Figura 4.18. Corte Sagital: à esquerda, grupo de controle; à direita, grupo de portadores de esquizofrenia.

Entretanto, para a construção do ventrículo nas imagens sagitais, apenas as imagens de RM axiais que continham o ventrículo foram utilizadas. Logo, esperava-se que a segmentação do ventrículo lateral dos portadores de esquizofrenia estivesse aumentada quando comparada ao ventrículo do grupo de controle. As Figuras 4.19 e 4.20 mostram

como os ventrículos laterais dos portadores de esquizofrenia estendem-se por mais imagens e são mais dilatados. Outro fator importante é que os ventrículos segmentados possuem o formato esperado, conforme a Figura 2.8. Além disso, é fundamental ressaltar que a segmentação dos cortes coronais e sagitais foi realizada de forma indireta, ou seja, a partir da segmentação das imagens de RM axiais.

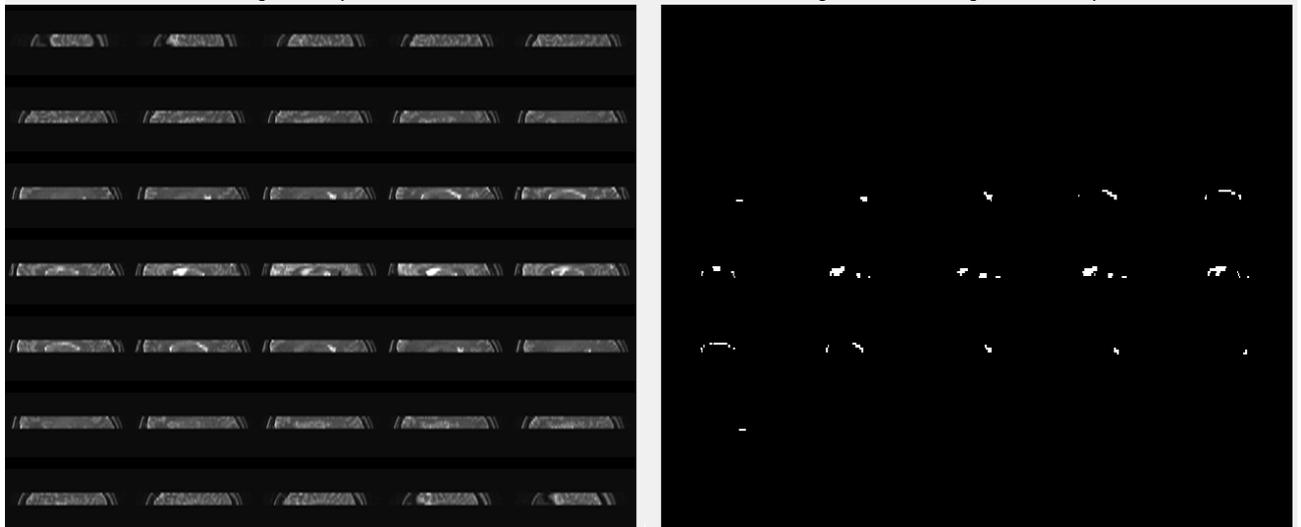


Figura 4.19. Corte Sagital com Ventrículo do Grupo de Controle: à esquerda, as imagens de RM; à direita, as imagens de RM segmentadas.

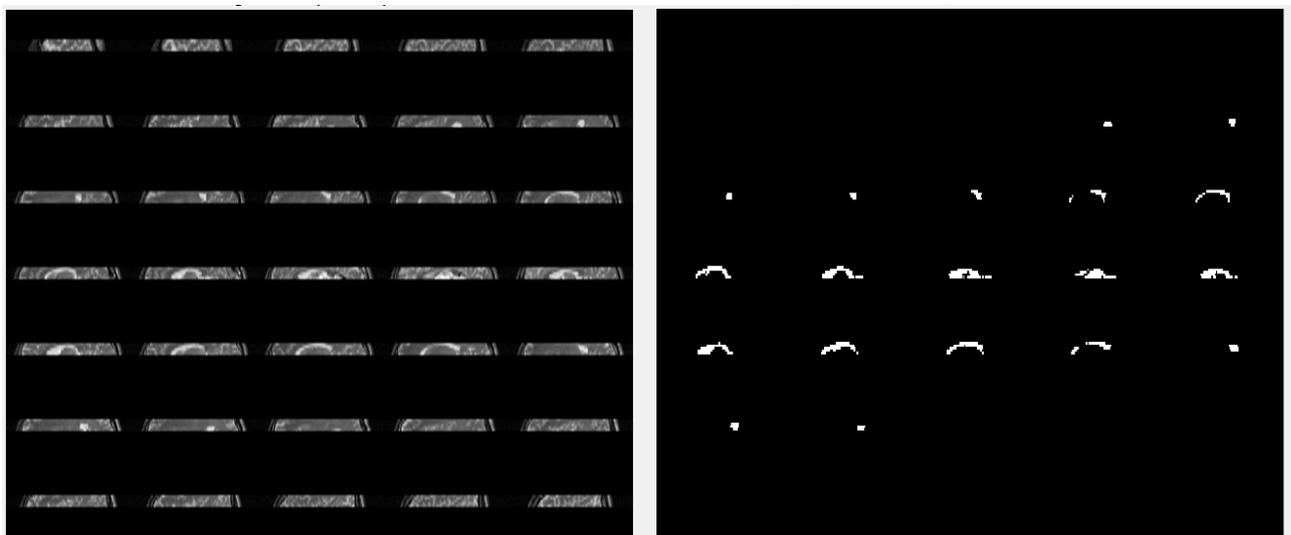


Figura 4.20. Corte Sagital com Ventrículo do Grupo de portadores de esquizofrenia: à esquerda, as imagens de RM; à direita, as imagens de RM segmentadas.

4.6.3 Corte Coronal

As imagens de RM dos cortes coronais estão exibidas na Figura 4.21 e, assim como na Figura 4.18, apresentam os grupos de controle e de portadores de esquizofrenia.

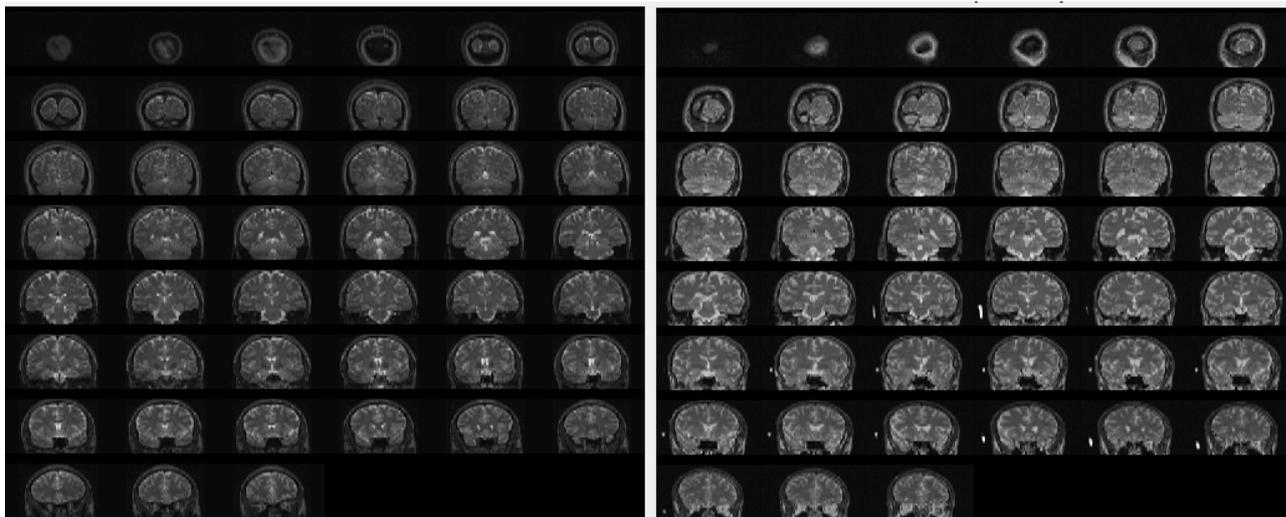


Figura 4.21. Corte Coronal: à esquerda, grupo de controle; à direita, grupo de portadores de esquizofrenia.

Ademais, também é notável os ventrículos alargados no grupo de portadores de esquizofrenia nas Figuras 4.22 e 4.23 e o formato semelhante ao da Figura 2.8, como esperado.



Figura 4.22. Corte Coronal com Ventrículo Segmentado do Grupo de Controle: à esquerda, as imagens de RM; à direita, as imagens de RM segmentadas.



Figura 4.23. Corte Coronal com Ventrículo Segmentado do Grupo de portadores de esquizofrenia: à esquerda, as imagens de RM; à direita, as imagens de RM segmentadas.

5 CONCLUSÃO

A esquizofrenia é uma doença ainda desconhecida em muitos aspectos. Este trabalho buscou desenvolver uma ferramenta que auxiliasse o diagnóstico da doença por meio da detecção de mudanças anatômicas cerebrais. Com as pesquisas que apontam alterações nos ventrículos laterais cerebrais dos portadores de esquizofrenia e as imagens de RM fornecidas pelo banco de dados BIRN, foi possível processar as imagens e extrair parâmetros a fim de classificar os grupos de controle e dos portadores de esquizofrenia

Direcionado pela metodologia proposta, as imagens de RM passam pelas transformadas *Wavelet* Discreta, DT-CWT e *Contourlet*, além da morfologia matemática e dos superpixels, com a finalidade de segmentar e isolar o ventrículo cerebral de forma eficiente. O delineamento dessa região de interesse é de fundamental importância, já que poderá ser realizada, de forma mais fidedigna, uma extração de parâmetros que pode associar as alterações anatômicas a manifestações de sintomas, promovendo, assim, uma ferramenta de auxílio ao diagnóstico.

Desta forma, por meio da obtenção dos contornos do sistema ventricular cerebral obtidas nas transformadas, a segmentação baseada na textura da imagem por GLCM foi executada e a região de interesse foi obtida. Logo, a segmentação que melhor preservou as estruturas dos ventrículos laterais foi escolhida para a aplicação do restante da metodologia. Em seguida, os parâmetros foram extraídos e inseridos em um classificador SVM objetivando separar o grupo de controle do grupo de portadores de esquizofrenia. Como apresentado no trabalho, os resultados baseados na acurácia, precisão, sensibilidade e especificidade ofereceram uma margem de acerto em torno de 70%, 71%, 64% e 75%, respectivamente. Diante desses dados, o resultado foi satisfatório, pois o número de acertos foi considerável. Todavia, a ressalva é que é necessário aprimorar a ferramenta computacional com a finalidade de melhorar as estimativas.

Com relação à acurácia, que é a chance dos verdadeiros positivos e verdadeiros negativos estarem corretos, e à precisão, que é a chance dos positivos serem, de fato, positivos, são de sete a cada dez indivíduos. A sensibilidade, que alcançou cerca de 64%, analisa a capacidade de diagnosticar os verdadeiros positivos em indivíduos doentes. Este foi o menor valor dos dados parâmetros obtidos. Por fim, a especificidade mostra os verdadeiros negativos em pacientes, de fato, saudáveis. Este foi o maior valor, alcançando 75% de

acertos.

Portanto, devido à segmentação, que preserva as estruturas dos ventrículos laterais, é possível afirmar, a partir das evidências obtidas, que os resultados em relação à especificidade, à precisão, à acurácia e à sensibilidade apontam na direção de que a ferramenta desenvolvida traz auxílio nos seguintes pontos:

- Possibilidade de auxílio objetivo, por meio de técnicas de Processamento Digital de Imagens e Aprendizagem de Máquina, à confirmação diagnóstica dos pacientes portadores de esquizofrenia (especificidade de 75% e precisão de 71%).
- Evita potenciais efeitos deletérios no uso de medicação em pacientes verdadeiramente sadios (reduz a chance de falso-positivo) e reduz os agravos da doença nos pacientes verdadeiramente portadores de esquizofrenia, ao serem corretamente medicados, reduzindo a chance de falso-negativos (acurácia de 70%).
- A sensibilidade de 64% demonstra que a ferramenta como auxílio na triagem de pacientes portadores de esquizofrenia requer maior aprimoramento.

Como sugestões para trabalhos futuros, a obtenção de uma quantidade maior de parâmetros, juntamente com uma segmentação mais sofisticada, podem resultar em melhores resultados. Além disso, a reconstrução de um sistema ventricular tridimensional, a fim de adquirir informações volumétricas que possam correlacionar a dilatação do sistema ventricular à esquizofrenia, será um passo fundamental no auxílio ao diagnóstico.

LISTA DE REFERÊNCIAS

- [1] P. Burt ; E. Adelson. The Laplacian Pyramid as a Compact Image Code. *IEEE Transactions on Communications*, 31(4):532–540, Apr 1983.
- [2] Fernanda Meizi Miron Nathalia Pedroza Miguel Celine de Carvalho Furtado Ana Isabel Sobral Bellemo Amanda Mendes Silva, Cláudio Alexandre dos Santos. ESQUIZOFRENIA: UMA REVISÃO BIBLIOGRÁFICA. *UNILUS Ensino e Pesquisa*, 13(30):18–25, Mar de 2016.
- [3] American Psychiatric Association. *Diagnostic and statistical manual of mental disorders: DSM-5*. APA, Washington, DC, 5th ed. edição, 2013.
- [4] N. Aishwarya ; Y. Asnath Vicky Phamila ; R. Amutha. Multi-focus image fusion using multi-structure top-hat transform and image variance . *International Conference on Communication and Signal Processing*, páginas 352–356, Apr 2013.
- [5] Karin Lisiany de Pontes André Luiz Souza Domingues de Matos e Álaba Cristina Pereira. REVISÃO TEÓRICA DA ESQUIZOFRENIA E IMPLICAÇÕES CAUSADAS PELA DOENÇA NA VIDA DO PORTADOR E DOS FAMILIARES. *III Congresso Nacional de Pesquisa em Ciências Sociais Aplicadas*, Oct de 2014.
- [6] Boanerges Victor Soares de Araújo. Estudo de famílias wavelets para aplicação na análise em doas. Master's thesis, Universidade Federal do Rio Grande do Norte, Rio Grande do Norte, 2015.
- [7] Rekha Vig e Vaishali Kulkarni Ashwini Gade. Segmentation of Tumor Region in MRI Images of Brain using Mathematical Morphology. *International Journal of Image Processing (IJIP)*, 8(3):95–102, 2014.
- [8] MD Assen Jablensky. The diagnostic concept of schizophrenia: its history, evolution, and future prospects. *Dialogues Clin Neurosci*, 12(3):271–287, Sep de 2010.
- [9] B.F.Cruz. Classificação de esquizofrenia com base em máquinas de suporte vetorial aplicadas a características de imagens de ressonância magnética. Master's thesis, Universidade de Brasília, Gama, 2015.

- [10] Marcelo Franceschi de Bianchi. Extração de características de imagens de faces humanas através de wavelets, pca e impca. Master's thesis, Escola de Engenharia de São Carlos- USP, São Carlos, 2006.
- [11] Ricardo J. G. B. Campello. Support vector machine - svm, 2018. <http://www.facom.ufu.br/backes/pgc204/Aula08-SVM.pdf>.
- [12] Department of Psychiatry University of Maryland School of Medicine Baltimore Md Carol A. Tamminga, Maryland Psychiatric Research Center. The biology of schizophrenia. *Dialogues Clin Neurosci*, 2(4):339—348, Dec de 2000.
- [13] Shao-Long Cao Chen Qiao, Dong-Dong Lin e Yu-Ping Wang. The effective diagnosis of schizophrenia by using multi-layer rbms deep networks. *2015 IEEE International Conference on Bioinformatics and Biomedicine (BIBM)*, páginas 603—606, Nov of 2015.
- [14] Paulo Lizano John Torous Chiara S. Haller, Jaya L. Padmanabhan e Matcheri Keshavan. Recent advances in understanding schizophrenia. *F1000Prime Reports*, 6(57):1—11, Jul de 2014.
- [15] Toby Breckon Chris Solomon. *Fundamentals of Digital Image Processing: A Practical Approach with Examples in Matlab*. Wiley-Blackwell, 1th ed. edição, 2011.
- [16] Daniel Moura Martins da Costa. *Emsemble* baseado em métodos de *kernel* para reconhecimento biométrico multimodal. Master's thesis, Universidade de São Paulo, São Paulo – SP, 2016.
- [17] Regina Cláudia Barbosa da Silva. Esquizofrenia: uma revisão. *Psicol. USP*, 17(4):263–285, Nov de 2006.
- [18] Rafael Walter de Albuquerque. Monitoramento da cobertura do solo no entorno de hidrelétricas utilizando o classificador svm (support vector machines). Master's thesis, Universidade de São Paulo, Escola Politécnica, 2012.
- [19] Marco Antônio Garcia de Carvalho. Processamento digital de imagens- st061. Master's thesis, Universidade Federal de Campinas, Campinas – SP, 2004.
- [20] Cláudio Campi de Castro. Ressonância magnética na esquizofrenia: Um estudo morfométrico. *Radiol Bras*, 34(3):141—144, May/Jun de 2001.
- [21] Robert M. Haralick ; K. Shanmugam ; Its'Hak Dinstein. Textural Features for Image Classification. *IEEE Transactions on Systems, Man, and Cybernetics*, SMC-3(6):610–621, Nov 1973.

- [22] Martin J. Graves Martin R. Prince Donald W. McRobbie, Elizabeth A. Moore. *MRI from Picture to Proton*. Cambridge University Press, 2th ed. edição, 2006.
- [23] Nilvana dos Santos Reigota. Comparação da transformada wavelet discreta e da transformada do cosseno, para compressão de imagens de impressão digital. Master's thesis, Escola de Engenharia de São Carlos- USP, São Carlos, 2007.
- [24] Jyotsana Mehra e Nirvair Neeru. A Brief Review: Super-Pixel Based Image Segmentation Methods. *Imperial Journal of Interdisciplinary Research*, 2(9):8–12, 2016.
- [25] R.F. Siqueira e P.G. Vergara. Análise de Imagens Anatômicas de Ressonância Magnética Segmentação e Parametrização de Imagens de Ressonância Magnética do Cérebro: Método Semi-Automático de Extração de Características para Apoio a Diagnóstico de Pacientes com Esquizofrenia., 2015. Monografia (Bacharel em Engenharia Eletrônica), UnB (Universidade de Brasília), Brasília, Brazil.
- [26] Olga Małolepsza Nikodem Skoczeń Ewelina Dziwota, Agnieszka Łaba-Stefanek e Marcin Olajossy. Anatomiczne zmiany mózgu w schizofrenii. 17(3-4):121–128, 2015.
- [27] Tom Fawcett. An introduction to ROC analysis. *Pattern Recognition Letters*, 27(8):861–874, Jun 2006.
- [28] C. G.; SUAZO C. A. T. GAROFANO, G. J. R.; VENANCIO e P. I. ALMEIDA. Application of the wavelet image analysis technique to monitor cell concentration in bioprocesses. *Brazilian Journal of Chemical Engineering*, 22(4):573–583, 2005.
- [29] Kauê Tartarotti Maruturi Haribabu. Contribuições em análise de textura para fins de segmentação de imagens digitais. Master's thesis, Universidade Estadual de Campinas, Campinas – SP, 2017.
- [30] Carpenter WT Jr Green MF Gold JM Schoenbaum M Harvey PD, Heaton RK. Diagnosis of schizophrenia: consistency across information sources and stability of the condition. *Schizophrenia Research*, páginas 9–14, Sep de 2012.
- [31] Richard G. Baraniuk Ivan W. Selesnick e Nick G. Kingsbury. The dual-tree complex wavelet transform: a new technique for shift invariance and directional filters. *The Dual-Tree Complex Wavelet Transform*, 22(6):123–151, Nov 2005.
- [32] Daqiang Sun Katherine H. Karlsgodt e Tyrone D. Cannon. Structural and functional brain abnormalities in schizophrenia. *Curr Dir Psychol Sci*, 19(4):226—231, Aug de 2010.
- [33] N. KINGSBURY. The dual-tree complex wavelet transform: a new technique for shift invariance and directional filters. *Proceedings of the 8th IEEE Digital Signal Processing Workshop*, páginas 86–89, 1998.

- [34] RPh; Jessica Cherian PharmD RPh; Kunj Gohil PharmD RPh; Krishna R. Patel, PharmD e Dylan Atkinson. Schizophrenia: Overview and Treatment Options. *Pharmacy and Therapeutics*, 39(9):638–645, Sep de 2014.
- [35] Evandro Silva Freire Coutinho Leonardo Araújo de Souza. Fatores associados à qualidade de vida de pacientes com esquizofrenia. *Rev. Bras. Psiquiatr*, 28(1):50–58, Mar de 2006.
- [36] Mário Rodrigues Louzã. Detecção precoce: é possível prevenir a esquizofrenia? *Rev. psiquiatr.*, 34(2):169—173, 2007.
- [37] Srinivasa Rao Chalamala ; Krishna Rao Kakkirala ; Rao G Bala Mallikarjuna. Analysis of wavelet and contourlet transform based image watermarking techniques . *IEEE International Advance Computing Conference (IACC)*, páginas 1122–1126, Feb 2014.
- [38] Mike Travis Martin Stefan e Robin Murray. *An Atlas of Schizophrenia*. Informa Healthcare, New York, USA, 2ª edição, 2002.
- [39] William D. Spaulding Ming Li. *The Neuropsychopathology of Schizophrenia: Molecules, Brain Systems, Motivation, and Cognition*. Springer International Publishing, Lincoln , NE , USA, 1ª edição, 2016.
- [40] Marciana Fernandes MOLL e Toyoko SAEKI. A vida social de pessoas com diagnóstico de esquizofrenia, usuárias de um centro de atenção psicossocial. *Rev. Latino-Am. Enfermagem*, 17(6):995–1000, 2009.
- [41] Fonseca M.S. Um estudo sobre influência das famílias *wavelets* na compressão de imagens. Master’s thesis, Universidade Federal Fluminense de Niterói, Rio Grande do Norte, 2004.
- [42] Marcella Nunes. Análise de Imagens Anatômicas de Ressonância Magnética Para a Extração de Características do Cérebro Usadas em Ferramentas de Apoio a Diagnóstico de Esquizofrenia, 2015. Monografia (Bacharel em Engenharia Eletrônica), UnB (Universidade de Brasília), Brasília, Brazil.
- [43] Emre Celebi Olivier Lézoray, Cyril Meurie. Superpixels for Image Processing and Computer Vision. *Journal of Electronic Imaging, SPIE and IS e T.*, páginas 8–12, Oct 2017.
- [44] M. Thirumalaiselvi S.T. Padmapriya S. Ramkumar P. Sriramakrishnan, T. Kalaiselvi. A Role of Medical Imaging Techniques in Human Brain Tumor Treatment, volume = 8, year = 2019. *International Journal of Recent Technology and Engineering*, páginas 565—568, Dec de.

- [45] Maruturi Haribabu ; Ch. Hima Bindu ; K. Satya Prasad. Multimodal Medical Image Fusion of MRI-PET Using Wavelet Transform . *International Conference on Advances in Mobile Network, Communication and Its Applications*, páginas 127–130, Aug 2012.
- [46] Prof. Akira Sawa MD Prof. Michael J Owen, PhD e PhD Prof. Preben B Mortensen. Schizophrenia. *UNILUS Ensino e Pesquisa*, 288(10039):86–97, Jan de 2016.
- [47] Editor R. Nick Bryan. *Introduction to the Science of Medical Imaging*. Cambridge University Press, 1 edição, 2009.
- [48] Richard E. Woods Rafael C. Gonzalez. *Digital Image Processing*. Prentice Hall, Upper Saddle River, N.J, 2th ed. edição, 2002.
- [49] Jennings RG Sayo A e Van Horn JD. Study factors influencing ventricular enlargement in schizophrenia: a 20 year follow-up meta-analysis. *Elsevier NeuroImage*, 59(1):156—167, Jan de 2012.
- [50] R.; KINGSBURY N. SELESNICK, I.; BARANIUK. The dual-tree complex wavelet transform. *IEEE Signal Processing Magazine*, 22(6):123–151, 2005.
- [51] R.H. Bamberger ; M.J.T. Smith. A filter bank for the directional decomposition of images: theory and design. *IEEE Transactions on Signal Processing*, 40(4):882–893, Apr 1992.
- [52] G. Preethi ; V. Sornagopal. MRI image classification using GLCM texture features. *2014 International Conference on Green Computing Communication and Electrical Engineering (ICGCCCE)*, páginas –, Oct 2014.
- [53] G. Arockia Selva Saroja ; C. Helen Sulochana. Texture analysis of non-uniform images using GLCM. *2013 IEEE Conference on Information e Communication Technologies*, páginas 1319–1322, Jul 2013.
- [54] AMANDIA DE OLIVEIRA SÁ. Detecção de agrupamento de microcalcificações em imagens de mamogramas digitalizados usando a transformada wavelet complexa de Árvore dupla. Master’s thesis, UNIVERSIDADE FEDERAL DE SÃO CARLOS, São Carlos – SP, 2016.
- [55] Robert Trevethan. Sensitivity, Specificity, and Predictive Values: Foundations, Plabilities, and Pitfalls in Research and Practice. *Front Public Health*, 5(5):1–7, Nov 2017.
- [56] M.N. Do ; M. Vetterli. The contourlet transform: an efficient directional multiresolution image representation. *IEEE Transactions on Image Processing*, 14(12):2091–2106, Dec 2005.

- [57] Scott W. *Magnetic Resonance Imaging of the Brain and Spine*. Wolters Kluwer, Philadelphia., PA 19106.
- [58] Stephen G. Waxman. *Clinical Neuroanatomy*. MC Graw Hill Education, 28th ed. edição, 2016.
- [59] Peter Williamson. *Mind, brain, and schizophrenia*. Oxford University Press, New York, Oxford, 1th ed. edição, 2006.
- [60] Stephen E. Wong. A critique of the diagnostic construct schizophrenia. *Research on Social Work Practice*, 24(1):132–141, Oct de 2014.
- [61] G.A. Wright. Magnetic resonance imaging. *IEEE Signal Processing Magazine*, 14(1):56—66, Jan de 1997.
- [62] Fugen Zhou e Bindang Xue Xiangzhi Bai. Image fusion through local feature extraction by using multi-scale top-hat by reconstruction operators. *Journal of Electronic Imaging, SPIE and IS e T,*, 52(16):3198–3203, 2013.
- [63] Xiangzhi Bai ; Fugen Zhou. Multi structuring element top-hat transform to detect linear features . *IEEE 10th INTERNATIONAL CONFERENCE ON SIGNAL PROCESSING PROCEEDINGS*, páginas 877–880, Dec 2014.