

PONTIFÍCIA UNIVERSIDADE CATÓLICA DO RIO
GRANDE DO SUL
FACULDADE DE INFORMÁTICA

**GERAÇÃO DE IMAGENS PARA A QUANTIFICAÇÃO DAS LESÕES DE
ESCLEROSE MÚLTIPLA COM EXAMES DE RESSONÂNCIA
MAGNÉTICA DO CÉREBRO HUMANO UTILIZADO NO PROTOCOLO
DE ROTINA DA PRÁTICA CLÍNICA**

FABIANO RICARDO FARIAS

PORTO ALEGRE
2014

PONTIFÍCIA UNIVERSIDADE CATÓLICA DO RIO GRANDE DO SUL
FACULDADE DE INFORMÁTICA

**GERAÇÃO DE IMAGENS PARA A
QUANTIFICAÇÃO DAS LESÕES DE ESCLEROSE
MÚLTIPLA COM EXAMES DE RESSONÂNCIA
MAGNÉTICA DO CÉREBRO HUMANO UTILIZADO
NO PROTOCOLO DE ROTINA DA PRÁTICA
CLÍNICA**

FABIANO RICARDO FARIAS

Dissertação apresentada como requisito parcial
à obtenção do grau de Mestre em Ciência da
Computação na Pontifícia Universidade
Católica do Rio Grande do Sul.

Orientador: Prof. Dr. Márcio Sarroglia Pinho

Porto Alegre
2014

Dados Internacionais de Catalogação na Publicação (CIP)

F224g Farias, Fabiano Ricardo

Geração de imagens para a quantificação das lesões de esclerose múltipla com exames de ressonância magnética do cérebro humano utilizado no protocolo de rotina da prática clínica / Fabiano Ricardo Farias. – Porto Alegre, 2014.

161 f.

Dissertação (Mestrado) – Faculdade de Informática, PUCRS.
Orientador: Prof. Dr. Márcio Sarroglia Pinho

1. Informática. 2. Processamento de Imagens.
3. Esclerose Múltipla. 4. Diagnóstico por Imagem. I. Pinho, Márcio Sarroglia. II. Título.

CDD 006.61

**Ficha Catalográfica elaborada pelo
Setor de Tratamento da Informação da BC-PUCRS**



Pontifícia Universidade Católica do Rio Grande do Sul
FACULDADE DE INFORMÁTICA
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

TERMO DE APRESENTAÇÃO DE DISSERTAÇÃO DE MESTRADO

Dissertação intitulada "Geração de Imagens para a Quantificação das Lesões de Esclerose Múltipla com Exames de Ressonância Magnética do Cérebro Humano Utilizado no Protocolo de Rotina da Prática Clínica" apresentada por Fabiano Ricardo Farias como parte dos requisitos para obtenção do grau de Mestre em Ciência da Computação, aprovada em 23/04/2014 pela Comissão Examinadora:

Prof. Dr. Márcio Sarroglia Pinho –
Orientador

PPGCC/PUCRS

Profa. Dra. Soraia Raupp Musse –

PPGCC/PUCRS

Prof. Dr. Alexandre Rosa Franco –

FENG/PUCRS

Homologada em 06/11/2014, conforme Ata No. 021 pela Comissão Coordenadora.

Prof. Dr. Luiz Gustavo Leão Fernandes
Coordenador.

PUCRS

Campus Central

Av. Ipiranga, 6681 – P32– sala 507 – CEP: 90619-900
Fone: (51) 3320-3611 – Fax (51) 3320-3621
E-mail: ppgcc@pucrs.br
www.pucrs.br/facin/pos

AGRADECIMENTOS

Muitas pessoas contribuíram para a realização desta dissertação de mestrado e não poderia deixar de manifestar meu profundo agradecimento a todas elas. À minha mãe pelo apoio financeiro e emocional em todos os momentos. Ao meu padrinho Adirlei pelo apoio prestado à família enquanto morei em Porto Alegre para concluir o Mestrado. Ao CNPq (Conselho Nacional de Desenvolvimento Científico e Tecnológico) pelo apoio financeiro para a realização deste trabalho possibilitando minha dedicação exclusiva ao mesmo. Ao meu orientador Márcio Pinho pelos apoios financeiros conquistados, pela oportunidade, permitindo ampliar meu conhecimento. Aos colegas e amigos do GRV pela ótima convivência me proporcionaram durante os anos que faço parte deste grupo. Aos médicos Ricardo Soder e Jefferson Becker pelo apoio ao trabalho e pela obtenção das imagens.

DEDICATÓRIA

Dedico este trabalho à minha mãe, meu maior exemplo e inspiração, que sempre me apoiou e me mostrou como não desistir diante de todos os problemas enfrentados e ao meu cachorrinho Jhoey que deixou a gente depois de 15 anos e que sempre vai me fazer sentir saudade.

GERAÇÃO DE IMAGENS PARA A QUANTIFICAÇÃO DAS LESÕES DE ESCLEROSE MÚLTIPLA COM EXAMES DE RESSONÂNCIA MAGNÉTICA DO CÉREBRO HUMANO UTILIZADO NO PROTOCOLO DE ROTINA DA PRÁTICA CLÍNICA

RESUMO

As imagens, que correspondem à cortes em exames de ressonância magnética, fazem parte dos protocolos utilizados para o auxílio no diagnóstico da esclerose múltipla e apresentam as lesões que caracterizam a doença. Dentre os protocolos existentes, estão o protocolo de rotina e o protocolo específico para a doença que está sendo avaliada. O exame de ressonância magnética do protocolo específico é um exame caro e demorado, porém apresenta uma quantificação mais precisa da volumetria das lesões no cérebro. O exame de ressonância magnética do protocolo de rotina é um exame barato, entretanto, sua precisão é menor para a quantificação do volume de lesões de esclerose múltipla, devido ao fato de possuir uma quantidade inferior de dados. Dentro desse contexto, o presente trabalho apresenta a aplicação de métodos de interpolação para gerar imagens artificiais, através das imagens presentes no exame de ressonância magnética do protocolo de rotina com o objetivo de simular as imagens contidas no exame do protocolo específico para a esclerose múltipla. Ao final, é apresentada uma abordagem que visa melhorar a precisão obtida com as técnicas de interpolação utilizadas, visando aumentar a confiabilidade da volumetria de lesões geradas pelas interpolações.

PALAVRAS CHAVE: Imagens de Ressonância Magnética, Lesões de Esclerose Múltipla, Protocolo de Rotina, Protocolo Específico, Técnicas de Interpolação

**IMAGE GENERATION FOR QUANTIFICATION OF MULTIPLE SCLEROSIS
LESIONS WITH MAGNETIC RESONANCE IMAGING OF THE HUMAN BRAIN
USED IN THE ROUTINE PROTOCOL ON CLINICAL PRACTICE**

ABSTRACT

The images, which correspond to slices in MRIs are part of the protocols used to aid in the diagnosis of multiple sclerosis and have lesions that characterize the disease. Among existing protocols, are the routine protocol and protocol specific for the disease being evaluated. The MRI scan of the specific protocol is an expensive and time-consuming test, but presents a more accurate quantification of volumetric lesion in the brain. The MRI scan of the routine protocol is an inexpensive routine examination; however, its accuracy is lower for quantifying the volume of multiple sclerosis lesions, due to the fact that it has a lower amount of data. Within this context, this dissertation presents the application of interpolation methods to generate artificial images through the images on the MRI scan of the routine protocol in order to simulate the images of the specific protocol for multiple sclerosis. At the end, an approach is presented that aims to improve the precision obtained with the interpolation techniques used to increase the reliability of volumetric lesion generated by interpolations.

KEYWORDS: *MRI, Multiple Sclerosis Lesions, Routine Protocol, Specific Protocol, Interpolation Techniques*

LISTA DE FIGURAS

Figura 1 - Exemplos de IRM do Cérebro e da Medula Espinhal	16
Figura 2 - Lesão de EM em Cortes Axiais nas Diferentes Sequências de Aquisição.....	17
Figura 3 - Exemplos de Sequências de Aquisição.....	19
Figura 4 - Diferença entre os Protocolos de Aquisição.....	20
Figura 5 - Diferenças de Intensidades dos Tecidos Cerebrais em cada Sequência de Aquisição	23
Figura 6 - Cortes Axiais das Diferentes Sequências de Aquisição com Lesões Segmentadas	25
Figura 7 - Etapa de Pré-Processamento das Imagens.....	28
Figura 8 - Mapas de Possíveis Lesões	29
Figura 9 – Exemplos de Discrepâncias na Substância Branca de um Corte FLAIR	29
Figura 10 - Verificação de Lesões de Substância Branca	30
Figura 11 - Cortes de dois Exames FLAIR com Lesões de EM	36
Figura 12 - Cortes de dois Exames T1 com Lesões de EM	37
Figura 13 – Interface do Simulador do BrainWeb	38
Figura 14 – Cortes de dois Exames FLAIR com Lesões EM Gerados com o <i>BrainWeb</i>	40
Figura 15 – Cortes de dois Exames T1 com Lesões EM Gerados com <i>BrainWeb</i>	40
Figura 16 - Resultado Qualitativo da Segmentação do PE de um Exame A do InsCer	41
Figura 17 - Resultado Qualitativo da Segmentação do PR de um Exame A do InsCer	42

Figura 18 - Resultado Qualitativo da Segmentação do PE de um Exame B do InsCer	43
Figura 19 - Resultado Qualitativo da Segmentação do PR de um Exame B do InsCer	44
Figura 20 - Resultado Qualitativo da Segmentação do PE de um Exame C com EM do BrainWeb	45
Figura 21 - Resultado Qualitativo da Segmentação do PR de um Exame C com EM do BrainWeb	46
Figura 22 - Resultado Qualitativo da Segmentação do PE de um Exame D com EM do BrainWeb	47
Figura 23 - Resultado Qualitativo da Segmentação do PR de um Exame D com EM do BrainWeb	48
Figura 24 – Exemplo de Geração de Cortes em Exames de IRM	53
Figura 25 - Exemplo de Interpolação Linear para Geração de Cortes Ausentes	54
Figura 26 - Exemplo de Imagens Sagitais de um Exame do InsCer Geradas com a Interpolação Linear	55
Figura 27 – Exemplo de Imagens Axiais de um Exame do <i>BrainWeb</i> Geradas com a Interpolação Linear	56
Figura 28 - Exemplo de Imagens Sagitais de um Exame do InsCer Geradas com a Interpolação <i>Nearest-Neighbor</i>	57
Figura 29 – Exemplo de Imagens Axiais do <i>BrainWeb</i> Geradas com a Interpolação <i>Nearest-Neighbor</i>	58
Figura 30 – Exemplo de Imagens Sagitais de um Exame do InsCer Geradas com a Interpolação por Área	59
Figura 31 – Exemplo de Imagens Axiais do <i>BrainWeb</i> Geradas com a Interpolação por Área	60
Figura 32 - Exemplo de uma Imagem Gerada com a Interpolação Cúbica a partir de Imagens de um Exame do InsCer	61

Figura 33 – Exemplo de uma Imagem Gerada com a Interpolação Cúbica a partir de Imagens de um Exame do <i>BrainWeb</i>	62
Figura 34 - Exemplo de Imagem Gerada com a Interpolação Lanczos a partir de Imagens de um Exame do InsCer.....	64
Figura 35 - Exemplo de Imagem Gerada com a Interpolação Lanczos a partir de Imagens de um Exame do <i>BrainWeb</i>	65
Figura 36 - Imagens Geradas com os Métodos de Interpolação do Corte de um Exame do InsCer	74
Figura 37 - Lesões Segmentadas dos Cortes de um Exame do InsCer Gerados com os Métodos de Interpolação	75
Figura 38 - Imagens Geradas com os Métodos de Interpolação do Corte de um Exame do BrainWeb	76
Figura 39 - Lesões Segmentadas dos Cortes do <i>BrainWeb</i> Gerados com os Métodos de Interpolação	77
Figura 40 - Exemplo de Sobreposição de Região Desalinhada.....	78
Figura 41 - Geração de Falsos Positivos nos Cortes Interpolados do InsCer ...	80
Figura 42 – Geração de Falsos Positivos nos Cortes Interpolados do <i>BrainWeb</i>	81
Figura 43 - Lesões Válidas que não foram Geradas pelo Método de Interpolação em um Exame do InsCer.....	82
Figura 44 - Lesões Válidas que não foram Geradas pelo Método de Interpolação em um Exame do <i>BrainWeb</i>	83
Figura 45 - Exemplo do Mapa de Lesões para as Imagens do InsCer	84
Figura 46 – Exemplo do Mapa de Lesões para as Imagens do BrainWeb.....	85
Figura 47 - Imagens do InsCer e Segmentadas Geradas com a Interpolação <i>Nearest-Neighbor</i>	94
Figura 48 – Imagens do <i>BrainWeb</i> e Segmentadas Geradas com a Interpolação <i>Nearest-Neighbor</i>	94

Figura 49 – Imagens do InsCer Segmentadas e Geradas com a Interpolação por Área.....	94
Figura 50 – Imagens do <i>BrainWeb</i> e Segmentadas Geradas com a Interpolação por Área.....	95
Figura 51 - Imagens do InsCer Segmentadas e Geradas com a Interpolação Linear.....	95
Figura 52 – Imagens do <i>BrainWeb</i> Segmentadas e Geradas com a Interpolação Linear	96
Figura 53 - Imagens do InsCer Segmentadas e Geradas com a Interpolação Cúbica	96
Figura 54 – Imagens do <i>BrainWeb</i> Segmentadas e Geradas com a Interpolação Cúbica	97
Figura 55 - Imagens do InsCer Segmentadas e Geradas com a Interpolação Lanczos	97
Figura 56 – Imagens do <i>BrainWeb</i> segmentadas geradas e com a Interpolação Lanczos	98
Figura 57 - Exemplo da Utilização de uma Malha no <i>Morphing</i> de Imagens ..	109
Figura 58 - Exemplo de Malha Associada às Bordas das Lesões	111
Figura 59 - Pontos de Controle nas Lesões	112
Figura 60 - Pontos de Controle em duas Imagens Adjacentes	113
Figura 61 - Imagens Geradas pelo <i>Morphing</i> por Malha	114
Figura 62 - Geração de falsos positivos no exame segmentado do PR	116
Figura 63 - Esquema do problema encontrado.....	117
Figura 64 - Imagem Artificial Construída com a Operação AND entre os Cortes Reais Adjacentes	118
Figura 65 - Esquema do Modelo Proposto.....	118
Figura 66 - Exemplo da Geração de um Falso Positivo na Imagem FLAIR	132

Figura 67 - Esquema do Problema de Geração das Falsos Positivos nas Imagens FLAIR	133
Figura 68 - Geração da Imagem Artificial no Método Proposto	134
Figura 69 - União das Regiões Hiperintensas	135
Figura 70 - União das Lesões com a Operação OR	135
Figura 71 - Geração da Máscara Final	136
Figura 72 - Geração das Imagens Artificiais do PR	136
Figura 73 - Esquema do Modelo Proposto.....	137
Figura 74 - Resultado da Interpolação do PR com os Cortes Artificiais Inseridos no Exame FLAIR.....	138
Figura 75 - Esquema Geral do Método da Geração de Cortes Artificiais no Exame FLAIR do PR.....	139

SUMÁRIO

1	INTRODUÇÃO	13
2	IMAGENS DE RESSONÂNCIA MAGNÉTICA COM ESCLEROSE MÚLTIPLA....	16
3	SEGMENTAÇÃO DE LESÕES DE ESCLEROSE MÚLTIPLA EM IRM	21
3.1	CONCEITOS BÁSICOS.....	21
3.2	MÉTODOS DE SEGMENTAÇÃO AUTOMÁTICA	23
3.3	DESAFIOS NA DETECÇÃO DE LESÕES DE SUBSTÂNCIA BRANCA	25
3.4	MÉTODO DE SEGMENTAÇÃO UTILIZANDO O ALGORITMO DE CRESCIMENTO DE LESÃO	27
4	TRABALHOS RELACIONADOS	31
5	SEGMENTAÇÃO E QUANTIFICAÇÃO DA VOLUMETRIA DE LESÕES DE EM .	34
5.1	OBTENÇÃO DOS EXAMES DE IRM COM EM.....	34
5.1.1	<i>EXAMES DE IRM COM EM DO INSCER.....</i>	<i>34</i>
5.1.2	<i>EXAMES DE IRM COM EM DO BRAINWEB</i>	<i>38</i>
5.2	SEGMENTAÇÃO DOS EXAMES DE IRM COM EM	40
5.3	QUANTIFICAÇÃO DAS LESÕES DE EM.....	49
6	INTERPOLAÇÃO DE IMAGENS PARA A GERAÇÃO DE CORTES INTERMEDIÁRIOS.....	52
6.1	INTERPOLAÇÃO LINEAR.....	53
6.2	INTERPOLAÇÃO <i>NEAREST-NEIGHBOR</i>	56
6.3	INTERPOLAÇÃO POR ÁREA.....	58
6.4	INTERPOLAÇÃO CÚBICA	60
6.5	INTERPOLAÇÃO LANCZOS COM OITO VIZINHOS.....	63
7	AVALIAÇÃO DE MÉTODOS DE INTERPOLAÇÃO PARA CÁLCULO DE VOLUMETRIA DE LESÕES	66

7.1	CÁLCULO DA VOLUMETRIA DAS IMAGENS FLAIR E T1 INTERPOLADAS	66
7.1.1	ANÁLISE VISUAL DAS IMAGENS INTERPOLADAS	73
7.1.2	RESULTADOS QUANTITATIVOS E ANÁLISE DO POSICIONAMENTO DAS LESÕES GERADAS	79
7.2	CÁLCULO DA VOLUMETRIA NAS IMAGENS SEGMENTADAS E INTERPOLADAS	93
7.2.1	ANÁLISE VISUAL DAS IMAGENS SEGMENTADAS E INTERPOLADAS	93
7.2.2	RESULTADOS QUANTITATIVOS OBTIDOS COM AS IMAGENS SEGMENTADAS E INTERPOLADAS	99
8	MÉTODOS PARA REMOÇÃO DE FALSOS POSITIVOS	107
8.1	GERAÇÃO DE IMAGENS COM MORPHING	108
8.1.1	MORPHING POR MALHA	109
8.1.2	APLICAÇÃO DO MORPHING POR MALHA NOS EXAMES COM EM DO PR	110
8.1.3	RESULTADOS QUANTITATIVOS OBTIDOS COM O MORPHING POR MALHA	114
8.2	MÉTODO DE INSERÇÃO DE CORTES ARTIFICIAIS NO PR SEGMENTADO	115
8.2.1	RESULTADOS QUANTITATIVOS OBTIDOS COM O MÉTODO DE INSERÇÃO DE CORTES ARTIFICIAIS NO PR SEGMENTADO	119
8.3	MÉTODO DE INSERÇÃO DE CORTES ARTIFICIAIS NO EXAME FLAIR DO PR	130
8.3.1	RESULTADOS QUANTITATIVOS OBTIDOS COM O MÉTODO DE INSERÇÃO DE CORTES ARTIFICIAIS NO EXAME FLAIR DO PR	140
9	CONSIDERAÇÕES FINAIS	153
10	REFERÊNCIAS	155

1 INTRODUÇÃO

A esclerose múltipla (EM) é uma doença inflamatória que afeta o cérebro e a medula espinhal atingindo as fibras nervosas responsáveis pela transmissão de comandos do cérebro a várias partes do corpo (Alastair Compston, 2002). Na EM, o sistema imunológico ataca uma substância chamada mielina que envolve filamentos do neurônio chamados axônios¹. Isso ocorre quando os indivíduos possuem uma desordem no sistema nervoso central que é resultado de uma interação entre fatores ambientais ainda não identificados e genes de suscetibilidade. Com isso, a percepção, o raciocínio e o controle do corpo pelo cérebro são prejudicados. Entre os principais sintomas estão, a fraqueza ou dormência de um membro do corpo, descoordenação motora, vertigem ou disfunção visual (García-Lorenzo, Francis, Narayanan, Arnold, & Louis Collins, 2012).

Existem várias formas de diagnóstico para a EM, entre elas a interpretação dos sintomas e a análise de exames complementares. Entre alguns dos principais exames estão a punção lombar para análise do líquido cefalorraquidiano² (Stroke, 2011), o teste de potencial evocado para a avaliação da resposta do organismo a pequenos choques elétricos (Stroke, 2011) e as imagens de ressonância magnética (*IRM*) do sistema nervoso central, que permitem identificar visualmente áreas com variações de sinal conhecidas como áreas hiperintensas na chamada substância branca³ do cérebro (Anitha, Selvy, & Palanisamy). Para classificar a doença através da análise da *IRM*, é preciso identificar e quantificar visualmente as áreas hiperintensas na substância branca que também são conhecidas como lesões de esclerose múltipla. Um dos métodos que auxilia este processo é a

¹ Estruturas responsáveis pela condução dos pulsos elétricos usados na comunicação entre as células nervosas (Alastair Compston, 2002)

² É um fluido corporal localizado entre o crânio e o córtex cerebral que age como um amortecedor para o córtex e a medula espinhal.

³ Consiste em milhões de cabos que conectam os neurônios individuais (substância cinzenta) em diferentes regiões do cérebro e ocupam quase metade do cérebro. (Fields, 2008)

segmentação⁴ da IRM. Atualmente, na prática clínica, a segmentação é realizada por especialistas através de procedimentos manuais para identificar e categorizar a lesão de EM de acordo com a disseminação da mesma no espaço e no tempo, mas existem casos em que a segmentação automática é realizada usando configurações muito específicas para o equipamento de ressonância magnética utilizado. Embora os algoritmos automáticos estejam se desenvolvendo, ainda não foi encontrada uma solução satisfatória para todos os tipos de aquisições e para todos os tipos de lesões. (García-Lorenzo, Francis, Narayanan, Arnold, & Louis Collins, 2012)

Os exames de ressonância magnética estão inseridos em dois protocolos de aquisição relevantes para esta dissertação. Um deles é o Protocolo de Rotina (PR). O outro é o Protocolo Específico (PE) dedicado à doença que está sendo avaliada e contém um exame de IRM mais detalhado que o Protocolo de Rotina, permitindo quantificar as lesões com mais precisão, porém é mais demorado e caro.

Considerando esse contexto, esta dissertação apresenta um estudo sobre métodos de geração de imagens artificiais para permitir a quantificação das lesões de substância branca utilizando o PR de IRM, ao invés do PE, para auxiliar no diagnóstico da EM. O método proposto utiliza técnicas tradicionais em processamento de imagens, com o objetivo de gerar cortes adicionais ao PR, simulando a aquisição obtida com o PE. No entanto, os métodos apresentados vão além da simples aplicação das técnicas de interpolação, visando diminuir o erro causado pela aplicação destas.

No capítulo 2 apresentam-se conceitos sobre IRM, assim como uma visão geral sobre os fatores relacionados ao auxílio no diagnóstico da EM através da ressonância magnética. No capítulo 3 é feito um apanhado geral sobre métodos de segmentação de imagens para EM, assim como uma revisão

⁴A segmentação é o processo pelo qual uma imagem é dividida em várias regiões, sem sobreposição e homogêneas com relação a alguma característica, como intensidade de cor ou textura. (Haralick & Shapiro, 1985).

sobre alguns métodos existentes na área e uma explicação sobre o método de segmentação utilizado neste trabalho. O capítulo 4 apresenta alguns trabalhos relacionados na área de geração de imagens artificiais com técnicas de interpolação. O capítulo 5 apresenta o processo utilizado para segmentação e quantificação dos exames de IRM no PE e no PR. O capítulo 6 apresenta as técnicas de interpolação que foram utilizadas para a gerar os cortes de IRM ao longo desta dissertação. No capítulo 7 são apresentados os resultados gerados com a aplicação das técnicas de interpolação e a avaliação dos métodos utilizados. O capítulo 8 apresenta estratégias para buscar melhorar o desempenho dos métodos de interpolação utilizados. No capítulo 9 são apresentadas as considerações finais com conclusões sobre os resultados obtidos pela aplicação das interpolações e das estratégias propostas.

2 IMAGENS DE RESSONÂNCIA MAGNÉTICA COM ESCLEROSE MÚLTIPLA

O exame de IRM é o tipo de exame utilizado nesta dissertação, pois se trata de uma modalidade de imagem que apresenta, segundo Wilson (Wilson, 2012), um valor preditivo positivo muito maior do que em outros testes, para pacientes com EM. A Figura 1 apresenta um exemplo de IRM com lesões de EM destacadas no cérebro de um homem de 35 anos, e um exemplo de IRM da medula espinhal com uma lesão de EM destacada de uma mulher de 27 anos. Em face disto, este capítulo apresenta conceitos, exemplos e considerações gerais sobre a IRM para lesões de EM, os diferentes protocolos de aquisição da IRM, os diferentes tipos de **sequências de imagens** ou **sequências de aquisição**, como cada sequência impacta no diagnóstico da EM e alguns problemas típicos da IRM.




Figura 1 - Exemplos de IRM do Cérebro e da Medula Espinhal

Fonte: http://www.medicinenet.com/multiple_sclerosis_pictures_slideshow/article.htm

A quantificação do volume e do número de lesões é usada para avaliar o impacto e a progressão da doença. Com essa modalidade é possível determinar a disseminação no tempo e no espaço para lesões de EM (McDonald, et al., 2001).

A IRM usada para análise do impacto da EM possui algumas particularidades conforme os parâmetros escolhidos para a execução do exame. Esses parâmetros determinam a chamada **sequência de aquisição** da IRM. Cada sequência de aquisição permite observar uma característica específica, como anatomia do cérebro e manifestações patológicas, entre outras características.

A configuração de cada sequência de imagem pode ser alterada através da escolha de parâmetros físicos específicos do equipamento de ressonância magnética no momento da aquisição, a fim de realçar regiões que permitem uma análise mais clara de lesões, ou da anatomia do cérebro, conforme a necessidade da análise, sendo fundamentais no diagnóstico de EM. A Figura 2 apresenta um exemplo da mesma lesão de EM nas diferentes sequências de aquisição.



Figura 2 - Lesão de EM em Cortes Axiais nas Diferentes Sequências de Aquisição

Fonte: (García-Lorenzo, Francis, Narayanan, Arnold, & Louis Collins, 2012)

Na IRM níveis de contraste variam dependendo do conteúdo do tecido. Por exemplo, gordura e água, possuem contrastes diferentes e suas informações têm características particulares em cada tipo de sequência. Para auxiliar no diagnóstico de EM, as sequências de aquisição mais comuns são a sequência ponderada em T1, sequência ponderada em T2, sequência ponderada em Densidade de Protons (DP) e Fluid Attenuated Inversion Recovery (FLAIR).

Segundo Trip (Trip, 2005) a sequência **ponderada em T2** identifica lesões de EM com um sinal alto em áreas hiperintensas, em contrapartida com o sinal baixo em tecidos mais escuros também conhecidos como áreas hipointensas, que correspondem à substância branca saudável. A gordura fica

disposta em tons mais escuros enquanto a água possui tons mais claros. Entretanto, lesões na região periventricular do cérebro podem ser indistinguíveis devido ao líquido cefalorraquidiano que também tem um sinal alto na sequência ponderada em T2. Uma alternativa para este problema é a sequência **ponderada em DP** que pode melhorar o contraste das lesões, pois o líquido cefalorraquidiano tem um sinal baixo nessa sequência. As imagens A e B da Figura 3 apresentam respectivamente, um exemplo da sequência T2 e DP.

Já a sequência **FLAIR** possui características parecidas com a sequência T2 e a sequência DP, porém consegue eliminar o sinal do líquido cefalorraquidiano. Com isso ela atinge níveis de contraste satisfatórios para a detecção de lesões, sendo a sequência mais utilizada no diagnóstico da EM. A sequência FLAIR só é desvantajosa em relação à sequência T2 e a sequência DP na detecção de lesões em algumas regiões da fossa posterior e na medula espinhal. A imagem C da Figura 3 apresenta um exemplo da sequência FLAIR.

A sequência **ponderada em T1** possui um sinal alto na substância branca saudável e um sinal baixo nas lesões. Com isso as lesões possuem tons mais escuros conhecidos como “black holes”. Essa sequência é favorável para ver a anatomia das regiões do cérebro. Outra opção para a sequência T1 é uma injeção no paciente de um elemento químico chamado Gadolínio (Gd) que faz com que o contraste das imagens seja melhorado permitindo detectar alguma ruptura da barreira hematoencefálica⁵ que esteja associada à inflamação. A letra D da Figura 3 apresenta um exemplo desta sequência de aquisição.

⁵ A barreira hematoencefálica é uma barreira formada por células endoteliais que revestem microvasos cerebrais e tem um papel importante na manutenção de um microambiente precisamente regulado para a sinalização neuronal confiável. (Abbott, Ronnback, & Hansson, 2006)




Figura 3 - Exemplos de Sequências de Aquisição

Fonte: (Trip, 2005)

Na prática clínica do Instituto do Cérebro da PUCRS (InsCer) as sequências de imagens fazem parte de protocolos de aquisição, conhecidos como Protocolo de Rotina (PR) e Protocolo Específico (PE) para a uma determinada doença que se deseja avaliar. O PR demanda menos tempo de aquisição e é mais barato, porém possui uma quantidade inferior dados, como uma sequências de imagens menor que o PE. Cada sequência do PR também possui uma quantidade menor de cortes. O PE, por sua vez, é um protocolo mais caro e demorado, por possuir uma quantidade maior de dados, que incluem mais sequências de imagens e cada sequência possui mais cortes que o PR. Outra diferença significativa entre os protocolos é as propriedades dos cortes contidos nas sequências de imagens, por exemplo, o PR possui intervalos (gaps) entre os cortes e estes possuem uma espessura maior que os cortes do PE. As imagens representam a informação destes cortes, portanto, uma imagem referente à um corte do PR irá representar uma região maior do cérebro do que uma imagem referente à um corte do PE. A Figura 4 apresenta um exemplo da diferença entre os protocolos de aquisição.




Figura 4 - Diferença entre os Protocolos de Aquisição

Fonte: O autor

3 SEGMENTAÇÃO DE LESÕES DE ESCLEROSE MÚLTIPLA EM IRM

Esse capítulo apresenta a fundamentação teórica sobre as principais questões relacionadas à segmentação de lesões de EM na IRM. São mostrados conceitos sobre segmentação de imagem e técnicas de segmentação automática para detectar lesões de EM.

3.1 CONCEITOS BÁSICOS

A segmentação pode ser definida como um problema de subdivisão de um espaço. Se o domínio da imagem inteira é Ω e S_k é cada uma destas regiões, a união de todas elas deve ser igual a Ω . Assim é possível definir a segmentação tradicional:

$$\Omega = \bigcup_{k=1}^K S_k$$

Onde cada S_k é uma região conectada⁶. É possível que nem toda a imagem seja coberta por estas regiões, neste caso tem-se uma região S_k especial que é a região de fundo. (Shapiro & Stockman, 2001).

Segundo García-Lorenzo (García-Lorenzo, Francis, Narayanan, Arnold, & Louis Collins, 2012), a segmentação é o processo que decide qual voxel pertence à lesão e qual não pertence. De acordo com a histologia, as lesões podem ser nítidas ou imprecisas (García-Lorenzo, Francis, Narayanan, Arnold, & Louis Collins, 2012). Delinear a lesão é um processo complicado, pois diversos tipos de tecidos contribuem para a intensidade da imagem em pixels que pertencem à borda. Se a região que cerca a lesão for uma região de substância branca saudável, o contraste é mais convincente ainda, da mesma forma que duas regiões separadas por um limite nítido são mais fáceis de identificar do que duas regiões separadas difusamente. Em IRM um conjunto de cortes torna a segmentação mais desafiadora porque o leitor define um

⁶ Região da imagem em que cada pixel que pertence a ela deve ter como vizinho ao menos outro pixel da mesma região (Shapiro & Stockman, 2001)

contraste global, que acaba influenciando a aparência relativa dos tecidos ao longo das imagens pertencentes à sequência de aquisição.

Para realizar a segmentação é preciso entender algumas características dos tecidos do cérebro, e com isto poder separar o tecido saudável das lesões. Considerando esta afirmação e baseado no fato que diferentes tecidos do cérebro têm diferentes intensidades de tons de cinza, a característica mais comum usada para segmentação de lesões é a intensidade do voxel (Cuadra, Cammoun, Butz, Cuisenaire, & Thiran, 2005). Além disso, a aparência do tecido e das lesões depende da sequência de IRM utilizada. Por exemplo, conforme Lladó et al. (Lladó, et al., 2011) a substância branca saudável aparece em áreas hiperintensas nas imagens T1, em áreas hipointensas nas imagens T2 e em tecidos com um tom de cinza intermediário nas imagens FLAIR. Por outro lado, o líquido cefalorraquidiano aparece em áreas hiperintensas nas imagens T2, e em áreas hipointensas em imagens T1 e FLAIR. A substância cinzenta do cérebro aparece em tecidos com um tom de cinza intermediário nas imagens T1 e T2, enquanto aparecem levemente mais claras que a substância branca saudável nas imagens FLAIR. Lesões aparecem em áreas hiperintensas nas imagens DP, T2 e FLAIR, e em áreas hipointensas nas imagens T1. A Figura 5 apresenta as diferenças de intensidades dos tecidos cerebrais em cada tipo de sequência, sendo que os losangos mostram exemplos de uma parte da substância branca saudável em cada imagem, os triângulos mostram uma parte da substância cinzenta, os quadrados uma parte do líquido cefalorraquidiano e os círculos algumas das lesões .




Figura 5 - Diferenças de Intensidades dos Tecidos Cerebrais em cada Sequência de Aquisição

Fonte: (Lladó, et al., 2011)

3.2 MÉTODOS DE SEGMENTAÇÃO AUTOMÁTICA

O processo de identificar lesões de EM e classificá-las ainda sofre uma alta variabilidade devido ao procedimento manual realizado por diferentes especialistas. Tendo isso em vista, vários autores tem proposto métodos automáticos de segmentação que visam otimizar e unificar o processo para possibilitar o uso em centenas ou milhares de imagens. Contudo, apesar dos resultados promissores, nenhum método automático é amplamente utilizado (García-Lorenzo, Francis, Narayanan, Arnold, & Louis Collins, 2012), pois além de exigirem um complexo processo de validação dos resultados, sofrem da heterogeneidade das lesões e da grande variabilidade de aquisições.

Os métodos automáticos utilizam algoritmos capazes de identificar e quantificar as lesões usando alguma técnica de acordo com sua especificação. Conforme apresentado por García-Lorenzo et al. (Garcia-Lorenzo, Francis, Narayanan, Arnold, & Louis Collins, 2012), é possível classificar os métodos automáticos em duas classes: métodos de aprendizado supervisionados e métodos sem supervisão.

Os métodos de aprendizado supervisionados “aprendem” a definição da lesão se baseando em um conjunto de imagens que já foram segmentadas, por um processo anterior. Este método é muito eficiente e amplamente empregado em tarefas que o conjunto de imagens usadas para treinar os algoritmos

satisfaz todos os casos possíveis de lesões. Entretanto, exigem um cuidado especial na escolha das imagens de treino além de serem dependentes de uma segmentação prévia do mesmo conjunto, que pode ser manual, e com isso sofrem da variabilidade de segmentação entre os especialistas além de consumirem muito tempo.

Os métodos sem supervisão não precisam de um conjunto de imagens para aprender sobre o padrão das lesões para identificá-las. A maioria destes métodos emprega técnicas de agrupamento que separa os voxels em diferentes classes usando métricas como, por exemplo, a intensidade do voxel. Eles exigem informações *a priori* para atribuir os voxels às determinadas classes (Substância Branca, Substância Cinzenta, Líquido Cefalorraquidiano, Lesões de Substância Branca), estas informações são adquiridas a partir do conhecimento de especialistas e combinadas com algoritmos de classificação, concentrando sua complexidade na reprodução do conhecimento em um algoritmo que possa ser implementado.

A Figura 6 apresenta as lesões de EM segmentadas nas diferentes sequências de aquisição, de um mesmo cérebro. As lesões realçadas aparecem circuladas em azul sendo visíveis em áreas hiperintensas em todas as imagens com exceção da imagem T1 que aparece em áreas hipointensas. A lesão circulada em verde é mais nítida na imagem T2, mostrando o benefício desta sequência para visualizar lesões em determinadas regiões do cérebro. As lesões circuladas em vermelho são as lesões visíveis em T1 (áreas hipointensas) que também podem ser vistas em áreas hiperintensas nas imagens FLAIR, DP e T2. Na imagem FLAIR é possível observar todas as lesões constatadas nas outras imagens, por isso é vantajosa em relação às demais sequências. Entretanto, tanto nas imagens FLAIR como T1 com gadolínio, por exemplo, várias áreas hiperintensas podem ser confundidas com lesões, por este motivo existe a necessidade de observar as diferentes sequências de aquisição.




Figura 6 - Cortes Axiais das Diferentes Sequências de Aquisição com Lesões Segmentadas

Fonte: (García-Lorenzo, Francis, Narayanan, Arnold, & Louis Collins, 2012)

3.3 DESAFIOS NA DETECÇÃO DE LESÕES DE SUBSTÂNCIA BRANCA

A segmentação automática das lesões de substância branca e a posterior quantificação das mesmas têm por objetivo auxiliar no diagnóstico de EM. Entretanto, ainda existem desafios em aberto, que ao serem resolvidos nos próximos anos podem consolidar a segmentação automática como uma alternativa automatizada para a quantificação de lesões. Os desafios atuais no processo de segmentação são apresentados por Garcia-Lorenzo et. al. (García-Lorenzo, Francis, Narayanan, Arnold, & Louis Collins, 2012):

- Mesmo havendo uma grande quantidade trabalhos na literatura sobre segmentação automática das lesões de substância branca, ainda não há um método preciso e completamente automático que possa ser utilizado

na prática clínica que sirva da mesma forma para centenas ou milhares de imagens;

- Ainda é necessária informação de diferentes tipos de sequências para confirmar o resultado da identificação das lesões, pois apesar de algumas lesões serem óbvias em apenas uma sequência, como a FLAIR, é preciso confirmar as lesões em outras sequências para evitar resultados falsos positivos;
- Apenas a informação de intensidade não é suficiente para uma boa segmentação, pois alguns tecidos podem ter intensidades semelhantes e o ruído pode prejudicar o desempenho do algoritmo. Para melhorar a precisão dos resultados é necessário incluir informações espaciais dos voxels vizinhos ou informações anatômicas de modelos específicos com lesões;
- A criação de um banco de dados público que cubra todos os casos de lesões para a utilização de métodos supervisionados de segmentação automática ainda é complicada pela dificuldade de obter imagens de pessoas que sofrem de esclerose múltipla;
- Métodos sem supervisão são baseados em técnicas de agrupamento global como Modelo de Mistura Gaussiana e média-C Fuzzy, mas ainda possuem problemas de sensibilidade em algumas regiões do cérebro, como alguns tecidos e lesões, devido à variação de intensidade que os voxels de determinadas regiões possuem por toda a imagem;
- A maioria dos métodos de segmentação propostos não é disponibilizada publicamente, o que dificulta sua utilização por outras pessoas, além de dificultar as comparações e seu aperfeiçoamento;
- Imagens do mesmo tipo adquiridas por equipamentos de ressonância magnética diferentes podem ter intensidades e contrastes diferentes. Os métodos existentes não lidam com essas variações, ou seja, eles não podem ser utilizados em imagens de todos os equipamentos da mesma maneira;
- Há pouco esforço para o desenvolvimento de métodos que trabalhem com imagens de ressonância magnética da medula espinhal para a detecção de lesões de substância branca;

- Métodos automáticos têm se concentrado em lesões focais, mas em alguns casos, quando a borda é difusa, é complicado encontrá-la entre as lesões e sua vizinhança. Essa questão precisa ser melhor tratada;
- Os métodos atuais de segmentação automática de lesões de esclerose múltipla não têm considerado efeitos de volume parcial⁷. Ao considerar os efeitos de volume parcial, a validação e reprodução do método são mais complicadas.

3.4 MÉTODO DE SEGMENTAÇÃO UTILIZANDO O ALGORITMO DE CRESCIMENTO DE LESÃO

O algoritmo de crescimento de lesão proposto por Schmidt P. et al. (Schmidt P. , et al., 2012) tem o objetivo de segmentar lesões de EM em exames de IRM através de etapas que envolvem o pré-processamento das imagens, a geração de mapas com as possíveis lesões e a aplicação do algoritmo que confirma as lesões dos mapas gerados. O algoritmo de crescimento de lesão foi avaliado com 53 pacientes com EM e com diferentes volumetrias de lesões, 10 pacientes com lesões na fossa posterior e 18 sujeitos que foram escaneados com o mesmo aparelho de ressonância magnética, obtendo a taxa de acerto maior que 0.93.

O pré-processamento das imagens tem como objetivo identificar as regiões do cérebro no exame FLAIR utilizando as informações do exame T1. Conforme foi mencionado no capítulo 2, para a análise da anatomia do cérebro, o tipo de imagem mais adequado é o T1. Por isto, o algoritmo inicia-se classificando os voxels deste exame nas classes de tecido, substância branca, substância cinzenta e líquido cefalorraquidiano. A classificação dos voxels no exame T1 é realizada através de sua intensidade, pois cada uma das três classes possui uma faixa de valores de intensidade própria que as representam.

⁷ O efeito de volume parcial refere-se ao fato de que o valor do tom de cinza contido no voxel representa apenas o valor médio da radiação absorvida durante o escaneamento do objeto de interesse, resultando em imagens com limites indefinidos, os quais são difíceis de selecionar na segmentação. (Ferraz, 2009)

A seguir, o corte FLAIR é então registrado com o corte T1 para que as regiões de ambos estejam alinhadas. Com esse processo é possível saber a localização da substância branca no corte FLAIR registrado com o exame T1, aumentando a precisão da localização espacial dessa classe. Além disto, para melhorar a precisão da classificação é utilizado um *mapa de probabilidade da substância branca*, criado por Mazziotta & Toga (Mazziotta & Toga, 2005) a partir de 452 exames. Isso é feito apenas para a substância branca, pois esta classe de tecido possui a maior probabilidade para ocorrência de lesões.

A segmentação final é realizada com o corte FLAIR, pois este exame é mais indicado para a identificação de lesões devido ao seu contraste bem definido das regiões hiperintensas do cérebro. A Figura 7 apresenta o esquema que resume a etapa de pré-processamento.

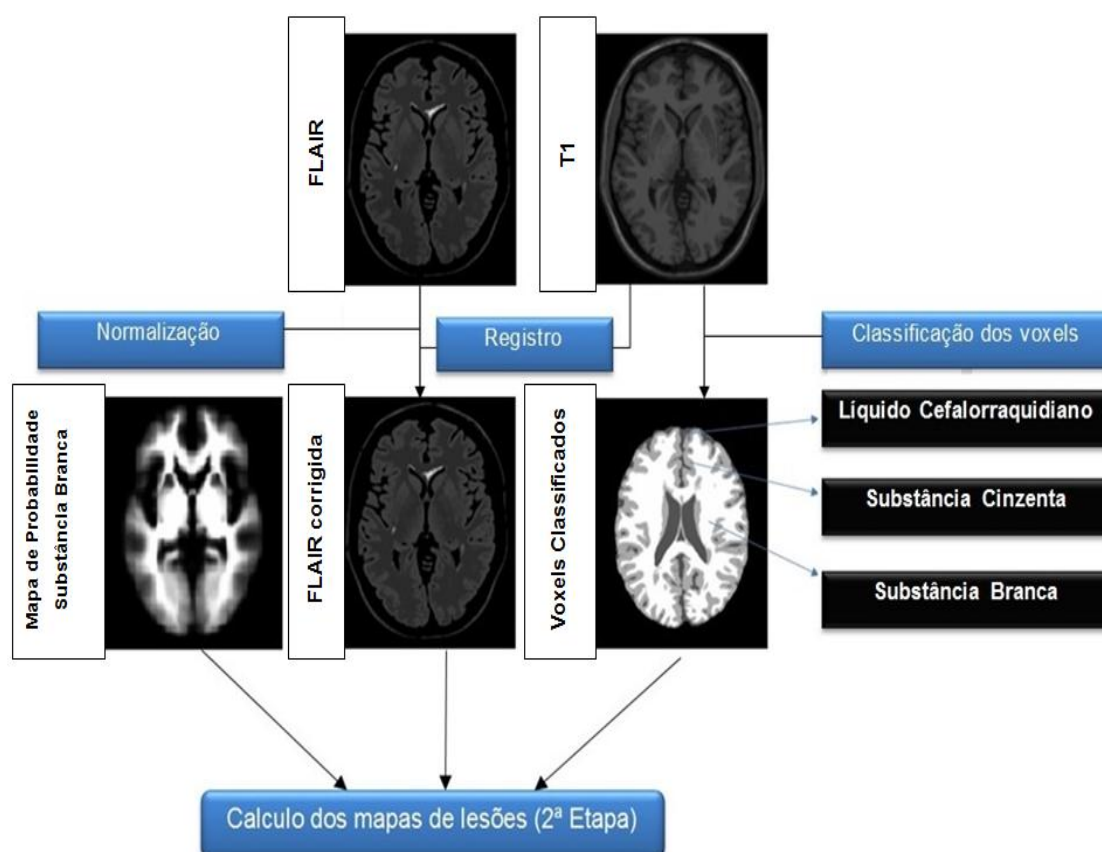


Figura 7 - Etapa de Pré-Processamento das Imagens

Fonte: O autor

Na segunda etapa são identificadas, para cada classe de tecido, voxels que tenham intensidades discrepantes daquelas esperadas para o tecido nas imagens FLAIR, com o objetivo de identificar possíveis lesões como mostram

as regiões circuladas no exemplo da Figura 9. Com todas as discrepâncias encontradas, é possível construir três mapas de possíveis lesões, um na substância branca, na substância cinzenta e outro no líquido cefalorraquidiano, conforme o exemplo da Figura 8.




Figura 8 - Mapas de Possíveis Lesões

Fonte: (Schmidt P. , et al., 2011)




Figura 9 – Exemplos de Discrepâncias na Substância Branca de um Corte FLAIR

Fonte: O autor

Embora se esteja buscando apenas lesões de substância branca, os mapas são construídos para todas as três regiões. Isto é feito desta forma, para aumentar a precisão do algoritmo na terceira etapa, pois para cada mapa é usado um critério diferente na escolha da lesão. Além disso, devido aos

processos de deformação da fase de pré-processamento, pode ocorrer que lesões identificadas em áreas limítrofes entre duas classes fiquem divididas entre duas ou três classes, como mostra a Figura 10, o que pode reduzir o volume final da lesão se for considerado apenas o volume identificado nos voxels classificados como substância branca. Para evitar este problema, a solução adotada no algoritmo soma os três mapas em uma única representação, que será usada na terceira etapa do algoritmo.

A terceira etapa aplica um método que avalia as possíveis lesões na soma dos mapas, conforme sua vizinhança. Aquelas possíveis lesões que não tiverem voxels adjacentes à substância branca ou a voxels oriundos de lesões previamente classificadas, são descartados, como as áreas hiperintensas marcadas com o número 2 da Figura 10. Por outro lado, os voxels que forem adjacentes à substância branca ou aos voxels já classificados como lesões são contabilizados, como as áreas marcadas com o número 1 da Figura 10.

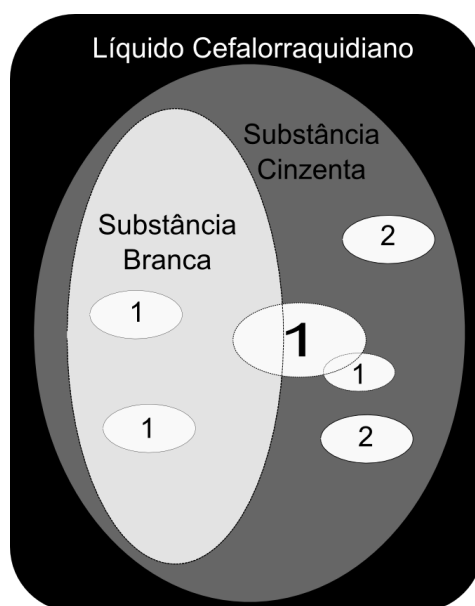


Figura 10 - Verificação de Lesões de Substância Branca

Fonte: O autor

Esta etapa gera uma sequência de imagens segmentadas com todas as lesões encontradas, em que cada voxel contém uma intensidade que representa a probabilidade deste pertencer a uma lesão. Por exemplo, uma região hiperintensa no exame FLAIR e um “*black hole*” no exame T1, ambas localizadas no mesmo lugar na substância branca, irá possuir intensidade que corresponda a 100% de chance desta ser uma lesão na imagem segmentada.

4 TRABALHOS RELACIONADOS

A geração de imagens artificiais como solução para o problema de exames de IRM que não fazem uma aquisição completa de imagens, como exames do PR, pode tornar-se uma alternativa na prática clínica para evitar a necessidade de realizar o exame do PE, que é mais demorado e caro. Entretanto, para que isso seja possível, os dados gerados devem possuir a precisão adequada para substituir as imagens obtidas com o exame do PE.

Para aplicar um método que gere imagens com a precisão exigida é preciso avaliar as técnicas existentes na literatura, visando encontrar uma solução disponível ou referências para o desenvolvimento de um novo método. Sendo assim, o presente capítulo apresenta alguns trabalhos relacionados à geração de imagens médicas através da interpolação de dados existentes.

A aplicação mais comum para a geração de imagens intermediárias é a criação de volumes isotrópicos 3D⁸. Exemplos de trabalhos nesta área são os de Goshtasby et. al. (Goshtasby, Turner, & Ackerman, 1992), Miranda et. al. (Miranda, Prado, & Traina, 1996), Atoui et. al (Atoui, Miguet, Sarrut, & others, 2006) e Boydev et. al (Boydev, Pasquier, Derraz, Peyrodie, Taleb-Ahmed, & Thiran, 2012).

O primeiro gera imagens através de um método que aplica uma interpolação linear entre a intensidade dos pontos correspondentes em duas imagens (origem e destino) de ressonância magnética ou tomografia computadorizada (TC) distintas. Para determinar quais pontos são correspondentes, é calculada a magnitude e a direção do gradiente dos tons de cinza e, através da semelhança destas informações, atribui-se a correspondência dos pixels. Estabelecendo a correspondência, o método gera uma reta entre os dois pontos, e sua intersecção com o corte que irá ser gerado determina a posição e a intensidade do novo pixel. Para os pixels que possuíram incompatibilidades na correspondência, são buscados os quatro pontos mais próximos na imagem de origem e sua posição na imagem de destino é dada pela média da posição destes. Permanecendo a

⁸ Volume de dados que têm as resoluções espaciais iguais nos três eixos coordenados.

incompatibilidade, o método realiza os mesmos processos invertendo as imagens de origem e destino. Se ainda sim a incompatibilidade existir, é estimado o deslocamento do ponto na imagem de destino fazendo uma interpolação bilinear dos quatro pontos mais próximos e que já possuem sua correspondência com outro ponto.

Já Miranda et. al. adaptaram a ideia proposta por Goshtasby na etapa que realiza a correspondência entre os pixels. A geração das imagens também é realizada pela interpolação linear entre a intensidade dos pixels correspondentes em duas imagens de ressonância magnética ou TC. O primeiro passo é estabelecer a correspondência para pixels com um valor de gradiente alto, que é o caso das fronteiras entre os tecidos do cérebro. Para essas regiões da imagem de origem é realizada uma pesquisa na imagem de destino, procurando localizar a correspondência de cada pixel pela maior semelhança encontrada. Neste caso, a semelhança é dada pela diferença das posições entre eles e pelas diferenças de densidade e gradiente. Para os pontos com um valor de gradiente baixo, que pertencem a regiões homogêneas nas imagens, utilizam-se os pontos que já possuem a correspondência estabelecida no primeiro passo como vértices, para construir uma triangulação de Delaunay (Delaunay, 1934). A triangulação define o fecho convexo desses pontos que passam por uma rotina de interpolação linear entre os pixels pertencentes aos triângulos, para definir as posições de cada ponto na outra imagem, estabelecendo suas correspondências. Para os pixels que estão fora do fecho convexo, as correspondências são definidas através de uma rotina de extrapolação que encontra as posições desses na outra imagem.

Já o trabalho de Atoui et. al gera imagens intermediárias entre duas imagens de TC através da aplicação do método de *morphing* por malha deformadas (Wolberg, 1998), com a deformação das malhas sendo feita pelo algoritmo de Catmull-Rom (Catmull & Rom, 1974). Como a técnica de *morphing* por malha só pode ser aplicada se houver regiões correspondentes entre as imagens, o trabalho utiliza um algoritmo que encontra a correspondência em blocos nas imagens. Inicialmente, as imagens de origem e destino são divididas em blocos, com um tamanho de área pré-definido. Através dos

valores de gradientes de cada pixel contido nos blocos procura-se o bloco correspondente na outra imagem verificando se este atende a um critério de semelhança de um valor X maior que um limiar T . O critério de semelhança é dado por uma equação que considera a intensidade do pixel, a magnitude do gradiente e a sua direção.

Por fim, o trabalho de Boydev et. al. gera imagens interpolando a forma das estruturas a partir de cortes binários gerados por segmentação. Os cortes são interpolados com a informação de um único corte, e não em mais de uma imagem como os outros métodos apresentados. O primeiro passo aplica, em todos os cortes da sequência, o algoritmo de Danielsson (Danielsson, 1980), que gera para cada pixel um valor correspondente à distância Euclidiana deste até a borda mais próxima. Pela segmentação das imagens utilizadas define-se a borda, sendo que por convenção, valores internos dos objetos definidos pela borda possuem valores negativos e valores externos recebem valores positivos. O segundo passo cria novos cortes que possuem os valores de intensidade correspondentes à interpolação, que pode ser linear ou outra, entre as distâncias euclidianas geradas pelo primeiro passo. O último passo transforma as novas imagens geradas em binárias aplicando um limiar com o valor 0, ou seja, todo valor interno ao objeto que foi gerado pela interpolação será transformado em 1. Assim, é gerada uma nova sequência de imagens, com uma quantidade maior de cortes que a original, em que as imagens geradas contém forma interpolada dos objetos contidos na imagem real utilizada.

5 SEGMENTAÇÃO E QUANTIFICAÇÃO DA VOLUMETRIA DE LESÕES DE EM

O presente capítulo descreve uma abordagem geral da metodologia utilizada para quantificar a volumetria das lesões, apresentando o processo utilizado, desde a obtenção dos exames de IRM com EM, passando pela segmentação das áreas hiperintensas, até a quantificação dos dados segmentados.

Além disto, o capítulo tem por objetivo mensurar o erro gerado no cálculo da volumetria, quando se utilizam exames do PR, se comparado ao cálculo feito com o exame do PE.

O capítulo está dividido em três seções. A seção 5.1 apresenta os processos utilizados para adquirir os exames de IRM que são utilizados para a aplicação dos métodos ao longo desta dissertação. A seção 5.2 descreve o processo de segmentação destes exames e por fim, a seção 5.3 apresenta a quantificação das lesões nos exames segmentados nos dois protocolos.

5.1 OBTENÇÃO DOS EXAMES DE IRM COM EM

Como foi apresentado na seção 3.3 o desafio de encontrar dados públicos com lesões de EM ainda permanece, pois não há bancos de dados públicos disponíveis com exames de IRM que envolvam casos variados de EM, como lesões de gravidades diferentes, localizadas em mais de uma região do cérebro, entre outros fatores que podem alterar a maneira como as lesões são apresentadas nos exames de IRM com EM.

Diante a esta dificuldade, o InsCer forneceu um conjunto de exames com as características necessárias para aplicar os testes, conforme será apresentado na seção 5.1.1. A segunda alternativa encontrada foi utilizar o simulador online *BrainWeb* que contém um pequeno número de exames de IRM com EM, em seu banco de dados (seção 5.1.2).

5.1.1 EXAMES DE IRM COM EM DO INSCER

O InsCer forneceu 10 pares de exames (T1 e FLAIR) de pacientes com EM, que já haviam liberado suas imagens para a realização de estudos.

Conforme foi mencionado na seção 3.4, para a aplicação do algoritmo de crescimento de lesão, é necessário ter-se as sequências FLAIR e T1 do mesmo paciente. Além disso, para permitir a comparação dos resultados, os pares de sequências deveriam ter sido realizados no PE e no PR.

No entanto, a aquisição das imagens FLAIR nos exames do InsCer foram realizadas apenas com o PE, com cortes sagitais de, no máximo, 1mm de espessura. Já a aquisição das imagens T1 foi realizada apenas nas aquisições do PR, em que os cortes eram sagitais, possuíam cerca de 5mm de espessura e apresentavam gaps (intervalos) entre os cortes de aproximadamente 6mm.

Em face disto, foi necessário construir um exame FLAIR do PR e um exame T1 do PE, para cada paciente cujos exames foram fornecidos. O FLAIR do PR foi gerado retirando-se cortes de 1mm do PE para criar os gaps e unindo-se a informação de 5 cortes em uma única imagem. A construção do exame T1 do PE foi realizada com uma interpolação linear para gerar cortes adicionais, utilizando o método apresentado na seção 6.1.

Essa abordagem, apesar de reduzir a qualidade das imagens, não causou falhas significativas na determinação das lesões, pois no algoritmo de crescimento de lesão o exame T1 é usado para confirmar algumas lesões, para determinar a anatomia do cérebro e para classificar as substâncias. As lesões em si, são obtidas com o exame FLAIR.

A Figura 11 apresenta alguns cortes FLAIR dos exames fornecidos pelo InsCer e a Figura 12 apresenta os cortes T1 dos mesmos pacientes.




Figura 11 - Cortes de dois Exames FLAIR com Lesões de EM
Fonte: O autor




Figura 12 - Cortes de dois Exames T1 com Lesões de EM
Fonte: O autor

5.1.2 EXAMES DE IRM COM EM DO *BRAINWEB*

Além das imagens do InsCer, este trabalho utilizou imagens geradas com o simulador da ferramenta online *BrainWeb* (Kwan, Evans, & Pike, 1999) mostrada na Figura 13. Esta mesma abordagem já foi utilizada nos trabalhos de Ait-Ali et. al. (Ait-Ali, Prima, Hellier, Carsin, Edan, & Barillot, 2005) e Garcia-Lorenzo et. al. (Garcia-Lorenzo, Lecoecur, Arnold, Collins, & Barillot, 2009).

O *BrainWeb* possui três exames com lesões de EM no seu banco de dados, sendo que há um exame para cada categoria de lesão: graves, moderadas e leves

Com os três exames disponíveis foram possíveis gerar imagens semelhantes às utilizadas na prática clínica nos formatos T1 e FLAIR. A ferramenta pode simular diferentes aquisições através da alteração de parâmetros que modificam elementos como a distribuição e a intensidade do ruído, a espessura dos cortes, a técnica de scan, etc.

BrainWeb: custom MRI simulations request

Please choose the parameters for your simulation:

Simulation model (phantom)	
Phantom	normal
MR pulse sequence	
[Set all parameters] from template: T1 [] pulse sequence, and [CBM] [] protocol. and/or customize the individual parameters below:	
Slice thickness [mm]	1 <small>this also specifies the amount of partial volume artifact; note that the in-plane pixel size is always 1x1mm range: 1...10</small>
Scan technique	SFLASH (spoiled FLASH) [] <small>type of pulse sequence</small>
Repetition time (TR) [ms]	18
Inversion time (TI) [ms]	[] <small>only used for the inversion recovery (IR) pulse sequence</small>
Flip angle [deg]	30 <small>ignored for all SE, DSE* and IR sequences (these use a fixed excitation flip angle of 90 deg) range: 1...150</small>
Echo time(s) (TE) [ms]	10 <small>all pulse sequences use only one echo time, except the DSE_EARLY and DSE_LATE sequences which need two echo times separated by a comma (,)</small>
Image Type	magnitude [] <small>type of reconstructed output image</small>
Imaging artifacts	
Noise reference tissue	(brightest_tissue) [] <small>tissue that is to be used as a reference for the percent noise calculation (see below)</small>
Noise level [%]	3 <small>the standard deviation of the gaussian noise that is to be added to the real and imaginary channels is given by the noise percent multiplied by the reference tissue intensity range: 0...100</small>
Random generator seed	0 <small>seed used to initialize the random number generator used for noise simulations; if zero, a new pseudo-random seed will be generated everytime range: 0...2147483647</small>
INU field	field A [] <small>choice of a synthetic INU field shape; all of them are based on fields observed in real MR scans</small>
INU ("RF") level [%]	20 <small>specifies the intensity non-uniformity level (a negative value inverts the field) range: -100...100</small>
Your email:	[] <small>When the requested simulation is completed, you will be notified at this address. NOTE: it is very important to correctly enter a valid email address, otherwise you won't be able to retrieve the data that you requested!</small>
[Done] [Undo changes]	

BrainWeb | MeBICAM
Interface version: 1.3 (2004/08/17 20:52:51 UTC)
Comments/Bugs to B.I.C. (bicr+bw@bic.mni.mcgill.ca)

Figura 13 – Interface do Simulador do BrainWeb

Fonte: http://brainweb.bic.mni.mcgill.ca/cgi/bw/submit_request

É importante ressaltar que existe apenas um modelo de cérebro com EM para cada categoria de lesão, ou seja, as lesões são as mesmas nos exames apresentados, a menos que a categoria da lesão seja alterada.

O fato que determina a diferença entre os exames da mesma categoria de lesão é a variação dos parâmetros do simulador. A alteração destes simula diferentes aquisições do mesmo paciente, influenciando na qualidade das imagens, alterando a precisão do cálculo da volumetria das lesões.

Nos exemplos do *BrainWeb* apresentados nesta dissertação foram utilizados cortes axiais com 1mm de espessura simulando um exame de IRM para o PE, e exames com 5mm de espessura e 6mm de gap, que simulam exames realizados no PR. Os exames T1 e FLAIR do PR foram construídos retirando os cortes de 1mm do PE relativos ao gap e unindo a informação de 5 cortes em uma única imagem.

Considerando que são três modelos de cérebro, dois protocolos, e que foram simulados três níveis de ruído, de 0%, 3% e 6%, ao todo foram gerados 18 pares de exames (T1 e FLAIR). A Tabela 1 apresenta os parâmetros gerais de aquisição usados para a geração de todos os exames FLAIR.

Tabela 1 – Parâmetros de aquisição

Espessura do corte (mm)	1 mm para PE/5mm para PR
Técnica de Scan	Recuperação da inversão (IR)
Tempo de repetição (ms)	10000
Tempo de inversão (ms)	1750
Tempo de eco (ms)	140
Ângulo de Inclinação (graus)	90
Número de ecos	1
Tipo de imagem	Magnitude

A Figura 14 apresenta alguns cortes gerados com *BrainWeb*. À esquerda pode-se observar um exame FLAIR de um paciente com lesões graves de EM, já à direita observa-se um exame FLAIR de um paciente com lesões moderadas de EM. A Figura 15 mostra cortes T1 dos mesmos pacientes da Figura 14.




Figura 14 – Cortes de dois Exames FLAIR com Lesões EM Gerados com o *BrainWeb*

Fonte: O autor




Figura 15 – Cortes de dois Exames T1 com Lesões EM Gerados com *BrainWeb*

Fonte: O autor

Para certificar que estes exames simulados representam pacientes realistas na prática clínica, os exames foram validados por um profissional do InsCer.

5.2 SEGMENTAÇÃO DOS EXAMES DE IRM COM EM

Para realizar a quantificação da volumetria das lesões de EM inicialmente se faz a segmentação das lesões dentro dos cortes. Os cortes dos exames fornecidos pelo InsCer e os cortes dos exames gerados pelo *BrainWeb*

foram submetidos ao método de segmentação automática contido no algoritmo proposto por Schmidt et al. (Schmidt P. , et al., 2012) descrito na seção 3.4.

A Figura 16 e a Figura 17 apresentam os resultados da segmentação de um exame de IRM com EM, chamado de exame A, fornecido pelo InsCer, utilizando as imagens do PE e do PR, respectivamente. Em ambas as figuras, as lesões aparecem em verde nas imagens inferiores de cada exame. As imagens superiores mostram os cortes sem as lesões segmentadas. Da mesma forma a Figura 18 e a Figura 19 mostram outro exemplo com um exame de IRM com EM do InsCer, chamado de exame B.

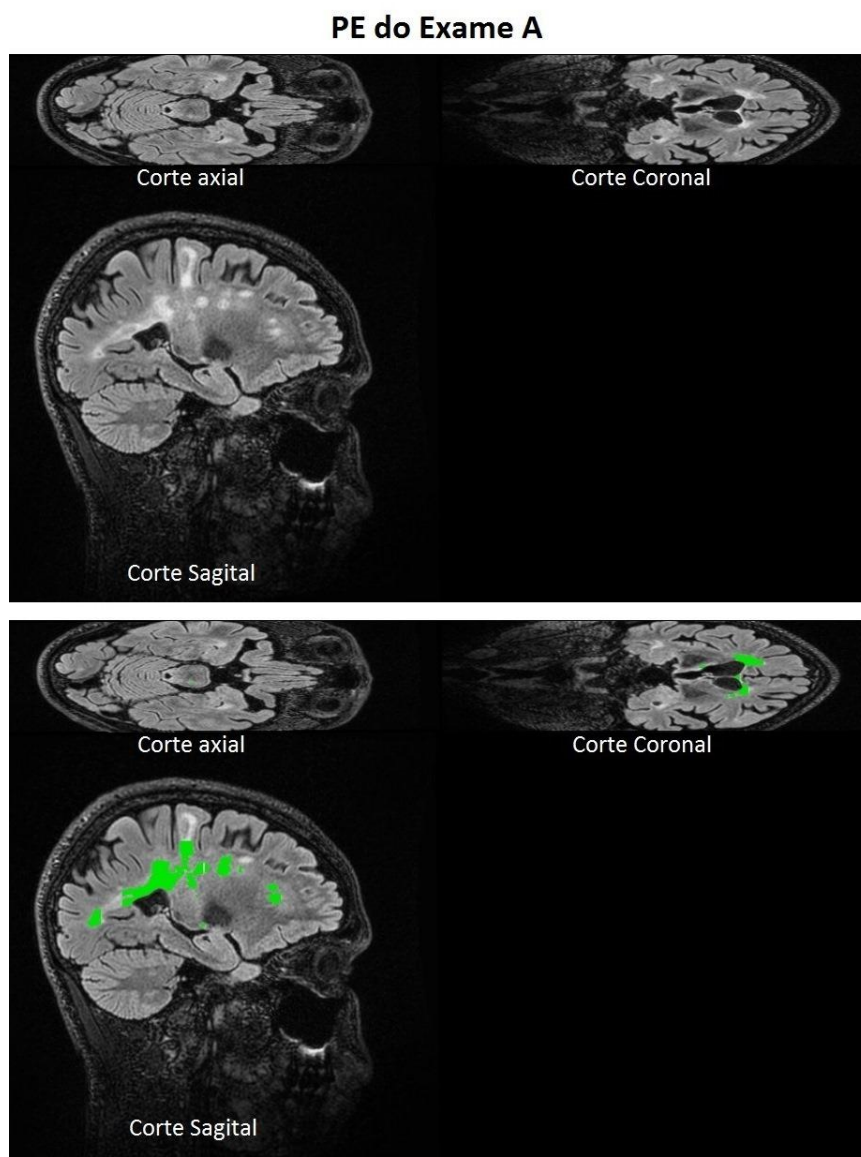


Figura 16 - Resultado Qualitativo da Segmentação do PE de um Exame A do InsCer

Fonte: O autor

PR do Exame A




Figura 17 - Resultado Qualitativo da Segmentação do PR de um Exame A do InsCer

Fonte: O autor


PE do Exame B

Figura 18 - Resultado Qualitativo da Segmentação do PE de um Exame B do InsCer

Fonte: O autor




Figura 19 - Resultado Qualitativo da Segmentação do PR de um Exame B do InsCer

Fonte: O autor

Os exemplos com exames do BrainWeb são apresentados nas figuras a seguir. A Figura 20 e na Figura 21 para o exame com lesões graves chamado de exame C. A Figura 22 e Figura 23 mostram um exame com lesões moderadas chamado de exame D.

PE do Exame C




Figura 20 - Resultado Qualitativo da Segmentação do PE de um Exame C com EM do BrainWeb

Fonte: O autor

PR do Exame C

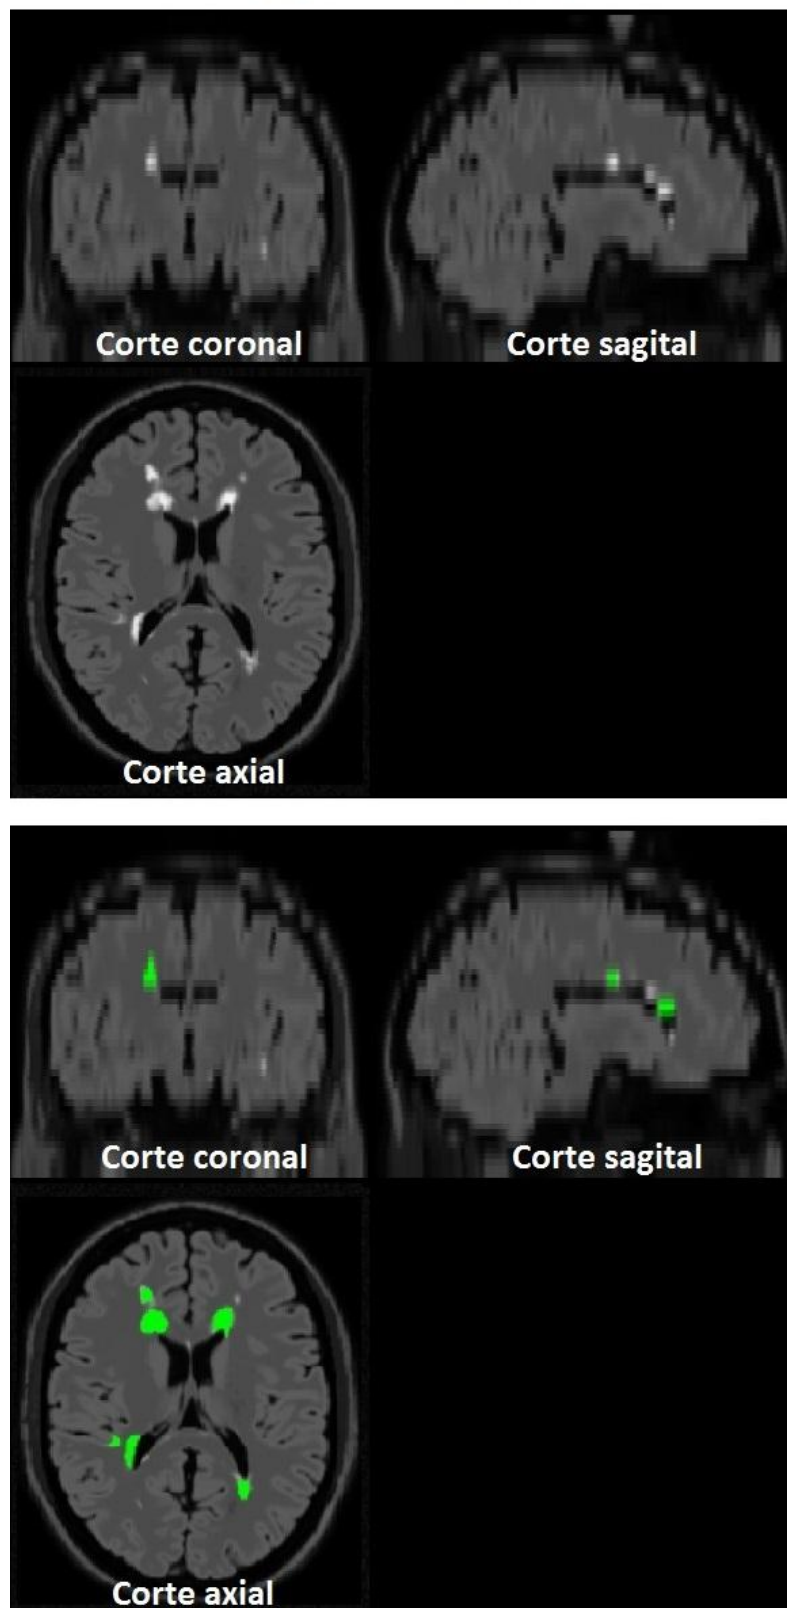


Figura 21 - Resultado Qualitativo da Segmentação do PR de um Exame C com EM do BrainWeb

Fonte: O autor

PE do Exame D




Figura 22 - Resultado Qualitativo da Segmentação do PE de um Exame D com EM do BrainWeb

Fonte: O autor

PR do Exame D

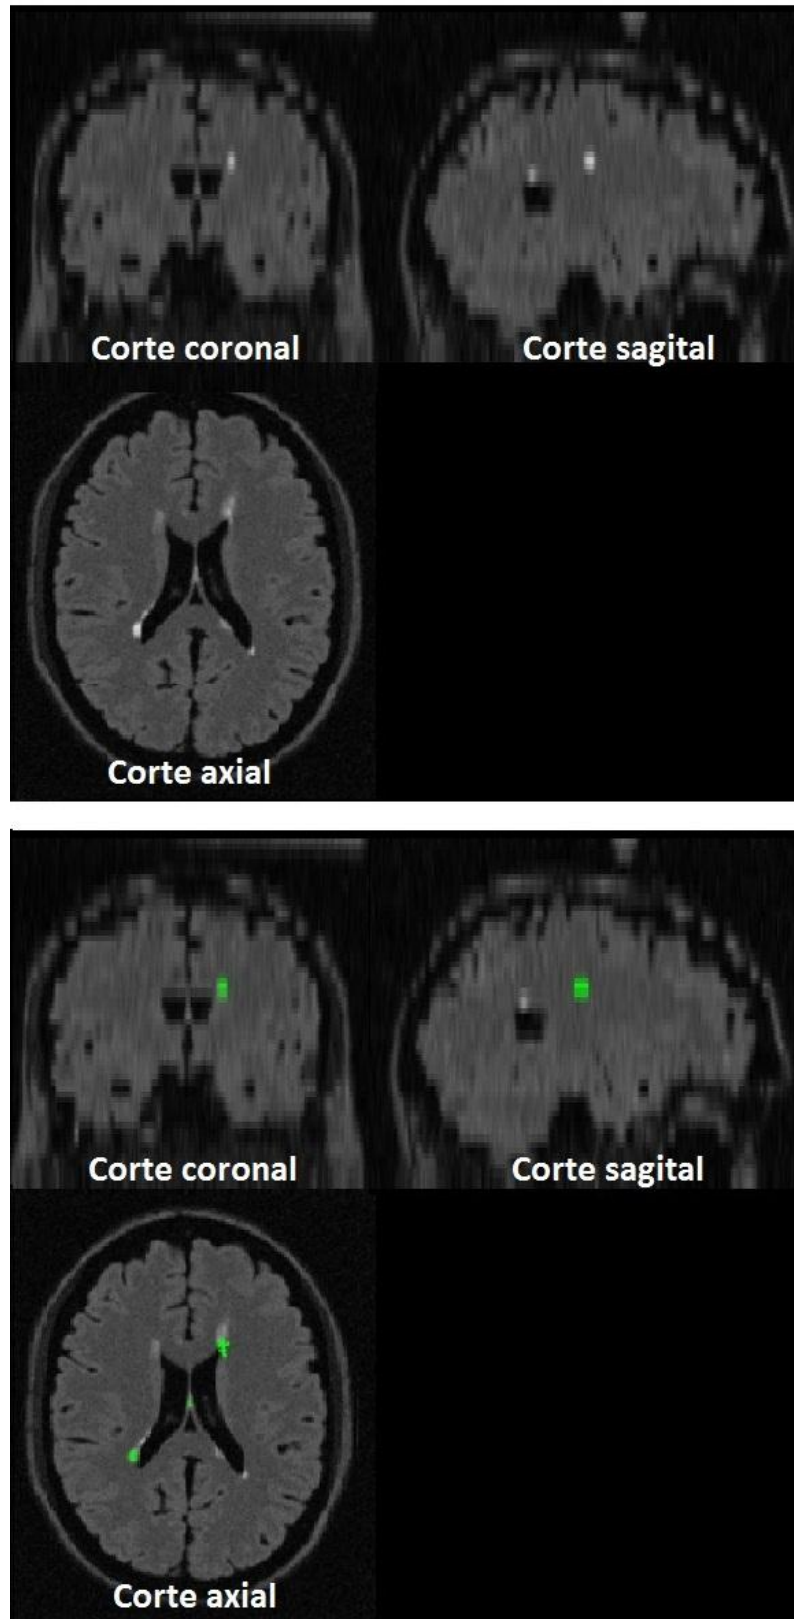


Figura 23 - Resultado Qualitativo da Segmentação do PR de um Exame D com EM do BrainWeb

Fonte: O autor

A Figura 17 e a Figura 19, que possuem os exames do InsCer no PR, é possível visualizar a baixa resolução que o PR apresenta nas estruturas dos cortes axiais e coronais das imagens, pois estes foram criados a partir dos cortes sagitais. Essa questão fica mais evidente ao comparar-se com os cortes do PE. O mesmo fenômeno acontece com os exames do *BrainWeb* na Figura 21 e na Figura 23, porém nos cortes coronais e sagitais, os quais são criados a partir dos cortes axiais para estes exames. Esta baixa resolução é causada pela ausência de dados no PR e isto acaba afetando a precisão do cálculo da volumetria de EM. Isso é possível ser visualizado nas manchas verdes em todas as tabelas apresentadas nesta seção. Percebe-se visualmente uma quantidade inferior de lesões nos exames do PR quando comparada ao PE. A seção 5.3 irá apresentar essa questão através de resultados quantitativos.

5.3 QUANTIFICAÇÃO DAS LESÕES DE EM

A quantificação da volumetria das lesões de EM é realizada através da soma dos voxels correspondentes às lesões segmentadas e posterior multiplicação pela unidade de volume que cada voxel representa. Nesta seção são apresentados os resultados da quantificação utilizando os dados dos exames do InsCer e dos exames produzidos pelo *BrainWeb*, conforme apresentados na seção 5.1.

Através dos resultados apresentados, é possível fazer uma análise comparativa entre a quantificação das lesões do exame do PR e do exame do PE. Para calcular o erro que os exames do PR geram no cálculo das lesões, o exame do PE foi utilizado como *ground truth* para seu respectivo exame do PR. Com a comparação da quantificação de lesões dos dois protocolos, é possível obter uma referência quantitativa do erro que o exame do PR acarreta no cálculo da volumetria das lesões. Em todos os resultados quantitativos que serão apresentados nesta dissertação, os dados do InsCer e do *BrainWeb* serão tratados de forma separada, pois a aquisição de seus exames não foi realizada da mesma forma.

A Tabela 2 apresenta o resultado da quantificação das lesões para os exames de IRM com EM fornecidos pelo InsCer, informando também o

percentual correspondente ao erro que a volumetria do PR possui em relação à volumetria do PE e a média dos valores apresentados.

Tabela 2 - Comparação da quantificação do volume de lesões entre o PE e o PR para os pacientes com EM do InsCer

Exames	Volumetria das lesões		Percentual de Erro
	PE (ground truth)	PR	
Exame 1	15,046	0,994	93%
Exame 2	2,377	0,255	89%
Exame 3	31,332	1,61	95%
Exame 4	22,624	3,595	84%
Exame 5	0,983	0,059	94%
Exame 6	3,261	0,369	89%
Exame 7	80,268	25,248	69%
Exame 8	3,995	1,454	64%
Exame 9	1,685	0,18	89%
Exame 10	5,471	0,436	92%
Média Total	16,704	3,420	86%

A Tabela 3 apresenta o resultado da quantificação das lesões para os exames do *BrainWeb*, informando também o percentual de erro do volume obtido com o PR em relação ao exame do PE. Nas tabelas referentes aos exames do *BrainWeb* que serão apresentadas nesta dissertação, os exames 1, 2 e 3 irão sempre corresponder a categoria de lesões graves, os exames 4, 5 e 6 irão corresponder a lesões moderadas e os exames 7, 8 e 9 às lesões leves.

Tabela 3 - Comparação da quantificação do volume dos exames de lesões do PE e do PR para os exames do *BrainWeb*

Exames	Volumetria das lesões		Percentual de Erro
	PE (ground truth)	PR	
Exame 1	20,853 ml	8,850 ml	58%
Exame 2	19,537 ml	6,373ml	67%
Exame 3	17,087 ml	5,120 ml	70%
Exame 4	7,016 ml	2,240 ml	68%
Exame 5	6,204 ml	1,457 ml	77%
Exame 6	5,374 ml	0,829 ml	85%
Exame 7	0,855 ml	0,175 ml	80%
Exame 8	0,611 ml	0,117 ml	81%
Exame 9	0,403 ml	0,055 ml	86%
Média Total	8,660 ml	2,802 ml	75%

Os resultados apresentados nesta seção mostram que para os exames do InsCer o PR obtém um erro médio de 86% para o volume quantificado com o PE. Para os exames do *BrainWeb* esse é de 75%. Com isso, confirma-se a imprecisão do PR em relação ao PE para quantificar as lesões de EM e percebe-se a necessidade de melhorar a precisão do PR para evitar a realização do PE na prática clínica. Para isto o PR precisa “simular” o PE, de modo que sua volumetria se aproximasse da volumetria obtida com o PE e o erro médio seja diminuído.

6 INTERPOLAÇÃO DE IMAGENS PARA A GERAÇÃO DE CORTES INTERMEDIÁRIOS

A precisão da quantificação das lesões é um fator importante no auxílio do diagnóstico da EM. Para tanto, é fundamental que as imagens tenham a qualidade suficiente para que o algoritmo de segmentação identifique corretamente os tecidos e as lesões.

Com o exame do PR é possível reduzir o tempo de exame em relação ao PE, pois o PR possui uma quantidade menor de cortes mais espessos e gaps entre eles. Ao utilizar o PR, entretanto, a qualidade das imagens é comprometida pelo fato de possuir uma quantidade menor de dados dificultando a análise detalhada dos tecidos cerebrais e a quantificação precisa das lesões, como foi visto nos resultados apresentados na seção 5.3.

Por esta razão, este capítulo apresenta uma metodologia para geração de imagens artificiais buscando aprimorar a quantificação de lesões com imagens do PR. A abordagem adotada pretende criar cortes intermediários aos cortes existentes e com eles chegar a um resultado mais próximo daquele obtido com o PE. Para a geração dos cortes intermediários a metodologia mais comum é a utilização de uma técnica de interpolação nas intensidades das imagens existentes, na qual a intensidade do pixel (x,y) da imagem A é interpolada com o pixel (x,y) da imagem B.

De forma genérica, a interpolação é o processo que utiliza dados conhecidos para estimar valores desconhecidos, sendo muito utilizada em métodos de reamostragem de imagens, em tarefas como ampliação, redução, rotação e correções geométricas de imagens (Gonzalez & Woods, 2007).

Nos exames de IRM a informação dos cortes presentes é utilizada para estimar os dados perdidos como mostra o exemplo da Figura 24, em que o Corte Gerado AB representa o corte que deveria ser gerado na posição sinalizada.




Figura 24 – Exemplo de Geração de Cortes em Exames de IRM

Fonte: O autor

Existem diversos métodos de interpolação de imagens, que variam no desempenho computacional, conforme a complexidade de cada técnica empregada, e produzem resultados com diferentes qualidades.

As próximas seções explicarão o comportamento, vantagens e desvantagens de cada técnica utilizada nos exemplos deste capítulo. A seção 6.1 apresenta o método de Interpolação Linear. A seção 6.2 explica o funcionamento da Interpolação *Nearest-Neighbor*. A seção 6.3 apresenta a Interpolação por Área. A seção 6.4 explica a Interpolação Cúbica e seção 6.5 mostra o funcionamento da Interpolação Lanczos com Oito Vizinhos.

6.1 INTERPOLAÇÃO LINEAR

A Interpolação Linear é uma técnica que possui baixo custo computacional (Lin, Sheu, Chiang, Liaw, Wu, & Tsai, 2010) além de ser simples de implementar. Contudo, a interpolação linear pode gerar uma atenuação dos componentes de alta-frequência e o *aliasing*⁹ dos dados (Lehmann, Gonner, & Spitzer, 1999). Dessa forma a interpolação linear pode comprometer a qualidade das imagens diminuindo a precisão da estimativa. O seu uso é indicado quando a aplicação necessita de um método veloz e sua perda de qualidade não seja suficiente para comprometer a confiabilidade dos dados gerados.

⁹ É o processo que alguns componentes de alta frequência de uma função são amostrados como componentes de baixa frequência. Quando a função representa uma imagem, o *aliasing* causa uma aparência serrilhada dos dados e reduz seus detalhes.

O método de interpolação linear gera novos dados entre dois pontos existentes através de uma estimativa obtida com uma média ponderada, que utiliza a distância da posição desejada até a posição dos pontos existentes para determinar os valores dos pesos (Dougherty, 2009). Dessa forma, é possível traçar uma reta entre pontos consecutivos e estimar os valores intermediários entre esses pontos.

No caso de uma IRM, tendo-se dois pixels de imagens que correspondem à cortes adjacentes e sabendo-se que eles representam pontos correspondentes nestes dois cortes, a aplicação do método de interpolação linear na intensidade entre esses voxels pode ser representada pelo esquema da Figura 25, na qual são estimados quatro pontos intermediários.




Figura 25 - Exemplo de Interpolação Linear para Geração de Cortes Ausentes

Fonte: O autor

Os pesos usados na estimativa de valores da Figura 25 são mostrados na Tabela 4. A fórmula geral de interpolação linear pode ser definida conforme a Equação 1 onde p_1 e p_2 são os valores dos pontos existentes i_1 e i_2 , e w é o peso de cada ponto em relação à distância de i' para p_1 , com $0 < w < 1$.

A Figura 26 apresenta uma sequência de imagens do plano sagital geradas com a interpolação linear a partir de imagens reais do PR fornecidas pelo InsCer. A Figura 27 apresenta uma sequência de imagens do plano axial geradas com a interpolação linear a partir de imagens reais do PR obtidas com o *BrainWeb*.

$$f(i') = w \cdot p1 + (1 - w) \cdot p2$$

Equação 1 – Interpolação Linear

Tabela 4 - Pesos Usados nos Cálculos de Interpolação linear da Figura 25

		Ponto Existente	
		i_1	i_2
Ponto Interpolado	i'_1	80%	20%
	i'_2	60%	40%
	i'_3	40%	60%
	i'_4	20%	80%




Figura 26 - Exemplo de Imagens Sagitais de um Exame do InsCer Geradas com a Interpolação Linear

Fonte: O autor




Figura 27 – Exemplo de Imagens Axiais de um Exame do *BrainWeb* Geradas com a Interpolação Linear

Fonte: O autor

6.2 INTERPOLAÇÃO *NEAREST-NEIGHBOR*

A interpolação *Nearest-Neighbor* é a interpolação mais simples dentre as técnicas apresentadas neste capítulo. É um método veloz e trivial que apenas replica o valor dos pixels existentes para os pixels que se deseja gerar, sendo que estes recebem o valor do pixel mais próximo (Burger & Burge, 2009). A Figura 28 apresenta um exemplo de imagens sagitais geradas com esse método, mostrando que são apenas cópias das imagens reais mais próximas do PR fornecidas pelo InsCer. Da mesma forma, as cópias das imagens reais são mostradas na Figura 29, em que as imagens axiais são geradas com a interpolação *Nearest-Neighbor* a partir das imagens reais do PR obtidas pelo *BrainWeb*.




Figura 28 - Exemplo de Imagens Sagitais de um Exame do InsCer Geradas com a Interpolação *Nearest-Neighbor*

Fonte: O autor




Figura 29 – Exemplo de Imagens Axiais do *BrainWeb* Geradas com a Interpolação *Nearest-Neighbor*

Fonte: O autor

6.3 INTERPOLAÇÃO POR ÁREA

A interpolação por área é muito parecida com a Interpolação *Nearest-Neighbor*, pois atribui ao pixel o valor de intensidade do pixel existente mais próximo. A diferença ocorre quando o pixel a ser gerado possui a mesma

distância para os dois vizinhos mais próximos. Nesse caso é atribuído um valor correspondente a uma média ponderada em relação a uma área de pixels reais, que pode considerar quatro, oito ou até um número maior de vizinhos mais próximos. A Figura 30 apresenta um exemplo das imagens geradas com a interpolação por área a partir das imagens sagitais reais do PR fornecidas pelo InsCer, em que é possível verificar que a imagem central se enquadra no caso em que a distância para as duas imagens reais é a mesma, e por isso é gerada pela média ponderada. A Figura 31 apresenta o mesmo caso, porém as imagens reais do PR obtidas com o *BrainWeb* e estão no plano axial.

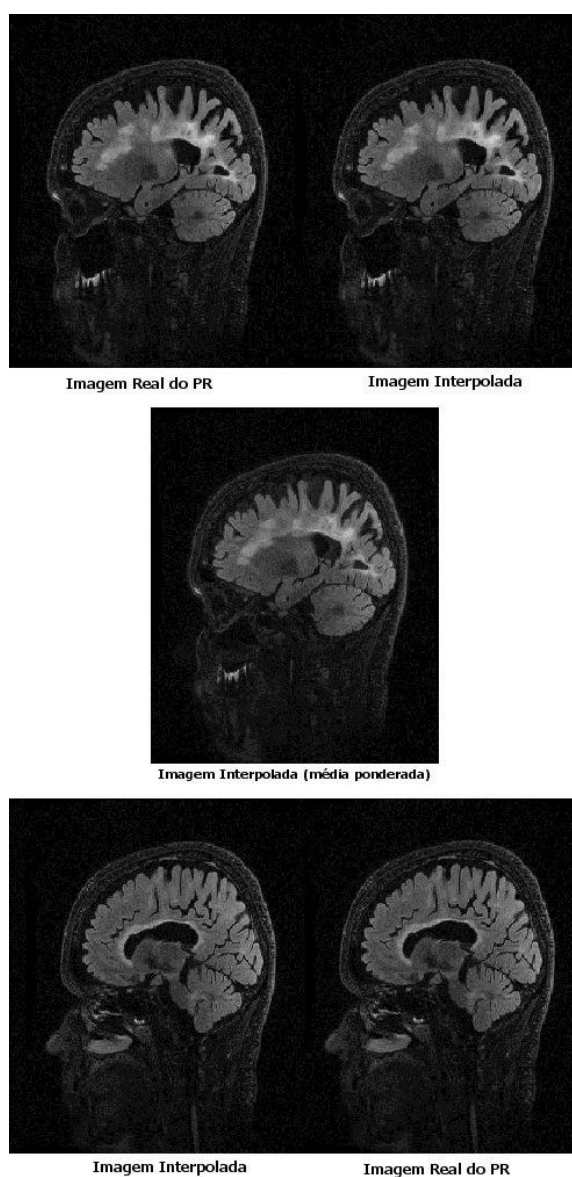


Figura 30 – Exemplo de Imagens Sagitais de um Exame do InsCer Geradas com a Interpolação por Área

Fonte: O autor

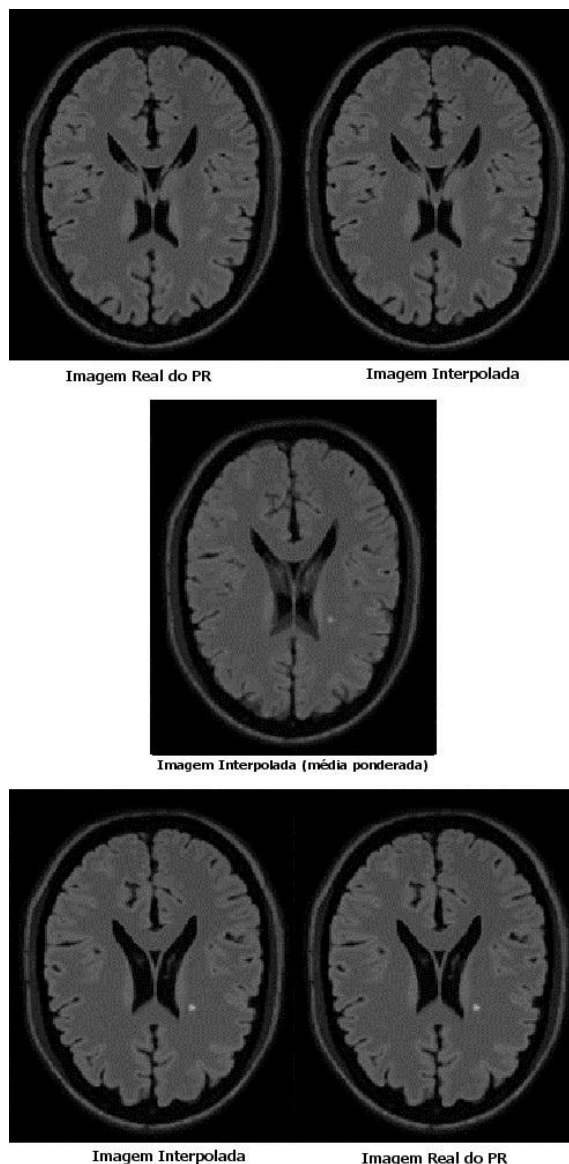


Figura 31 – Exemplo de Imagens Axiais do *BrainWeb* Geradas com a Interpolação por Área

Fonte: O autor

6.4 INTERPOLAÇÃO CÚBICA

Na interpolação cúbica, o valor do pixel (x,y) na imagem que será gerada é obtido a partir da aplicação de uma função polinomial cúbica para cada ponto (Burger & Burge, 2009) dentre os quatro vizinhos (x,y) mais próximos do pixel que se deseja gerar a intensidade. Com os valores conhecidos dos quatro pixels reais é possível montar uma matriz com as quatro equações polinomiais da qual é extraído os coeficientes da função polinomial cúbica utilizada. Finalmente, o valor interpolado é gerado com a aplicação do mesmo polinômio cúbico, mas dessa vez utilizando os valores dos coeficientes.

A Figura 32 apresenta uma imagem sagital gerada com a interpolação cúbica a partir das quatro imagens do PR, do InsCer, mais próximas da imagem que se deseja gerar. A Figura 33 apresenta o mesmo caso, porém com imagens reais obtidas pelo *BrainWeb*, no plano axial.

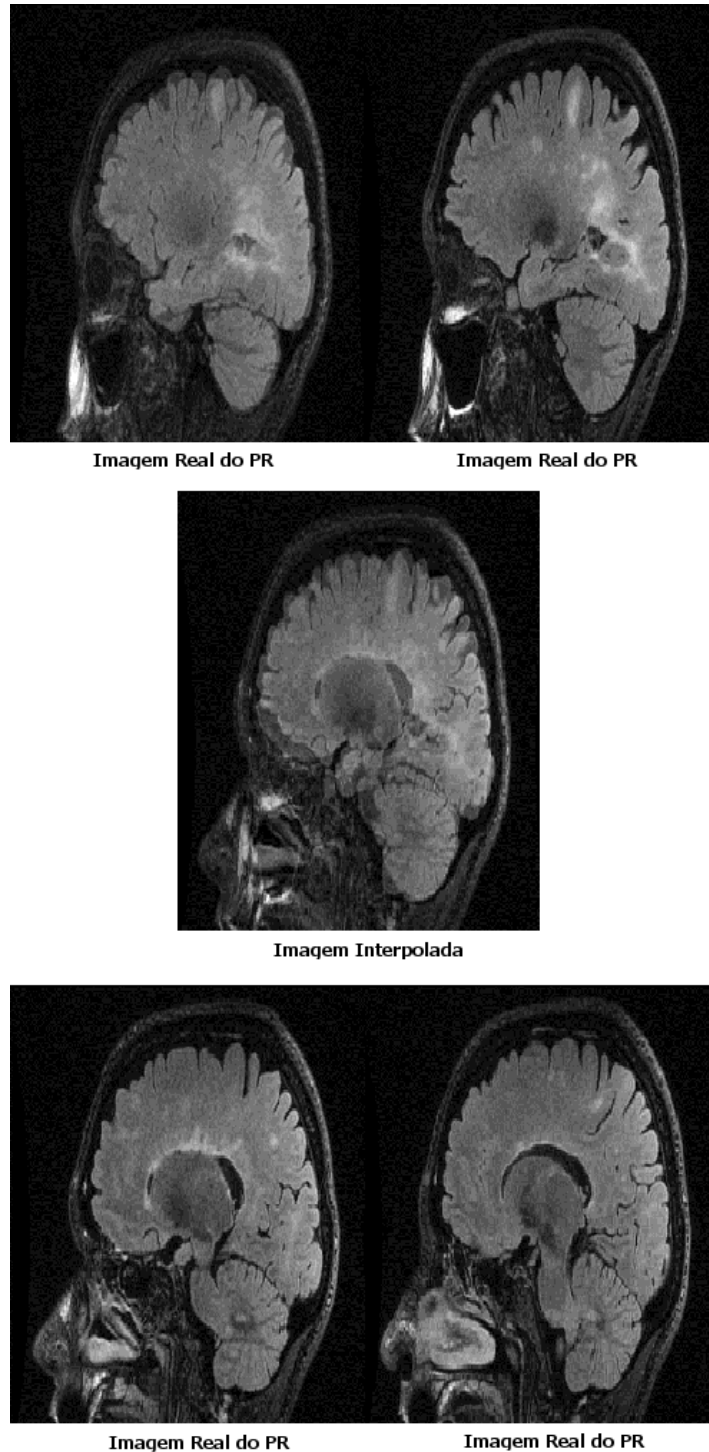


Figura 32 - Exemplo de uma Imagem Gerada com a Interpolação Cúbica a partir de Imagens de um Exame do InsCer

Fonte: O autor

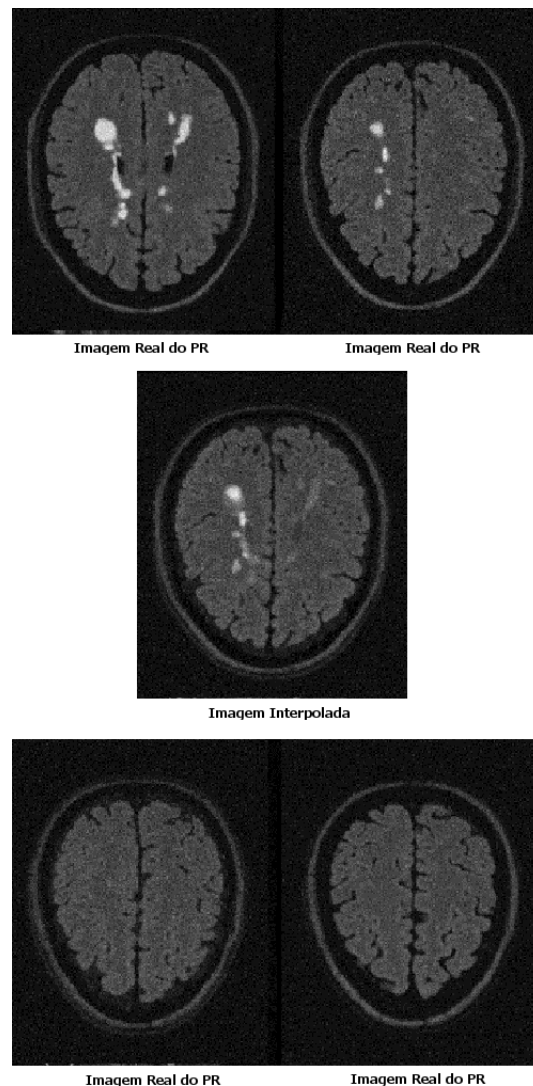


Figura 33 – Exemplo de uma Imagem Gerada com a Interpolação Cúbica a partir de Imagens de um Exame do *BrainWeb*

Fonte: O autor

Essa técnica utiliza os quatro vizinhos mais próximos quando trabalha com apenas uma dimensão, que é o caso da geração das imagens tratadas neste capítulo, porém ao aumentar o número de dimensões os vizinhos utilizados pela interpolação cúbica crescem exponencialmente.

A interpolação cúbica é um método mais lento do que os métodos apresentados até aqui pelo fato de realizar uma maior quantidade de cálculos e considerar os quatro pixels vizinhos mais próximos do ponto que se deseja gerar o valor da intensidade.

6.5 INTERPOLAÇÃO LANCZOS COM OITO VIZINHOS

A interpolação Lanczos com Oito Vizinhos (Bradski & Kaehler, 2008) é um método que gera imagens com menos *aliasing* do que as técnicas apresentadas nas seções anteriores, além de preservar mais estruturas pequenas, por exemplo, como é o caso de algumas lesões de EM.

O objetivo do método é obter os coeficientes através de uma função sinc^{10} multiplicada pelo Kernel de Lanczos¹¹ (Burger & Burge, 2009), e aplicar os coeficientes obtidos em uma função que interpola os valores considerando oito pixels reais mais próximos. Essa técnica é mais lenta que as outras técnicas apresentadas. A Figura 34 apresenta uma imagem no plano sagital interpolada a partir das oito imagens reais do PR fornecidas pelo InsCer, em que as estruturas interpoladas se assemelham visualmente com os resultados da interpolação cúbica. A Figura 35 mostra uma imagem no plano axial interpolada a partir de oito imagens reais obtidas com o *BranWeb*. Embora utilizou-se oito vizinhos com esta técnica, ao longo dissertação esta Interpolação será sempre referenciada apenas como Interpolação Lanczos.

¹⁰ A função sinc é uma função matemática utilizada para a reconstrução de sinais originais a partir de amostras uniformemente espaçadas desse sinal (Camargo & Santos, 2006).

¹¹ É um template de imagem que representa a multiplicação de duas funções sinc, que utilizam valores dentro de um determinado intervalo definido pelo tamanho do kernel.

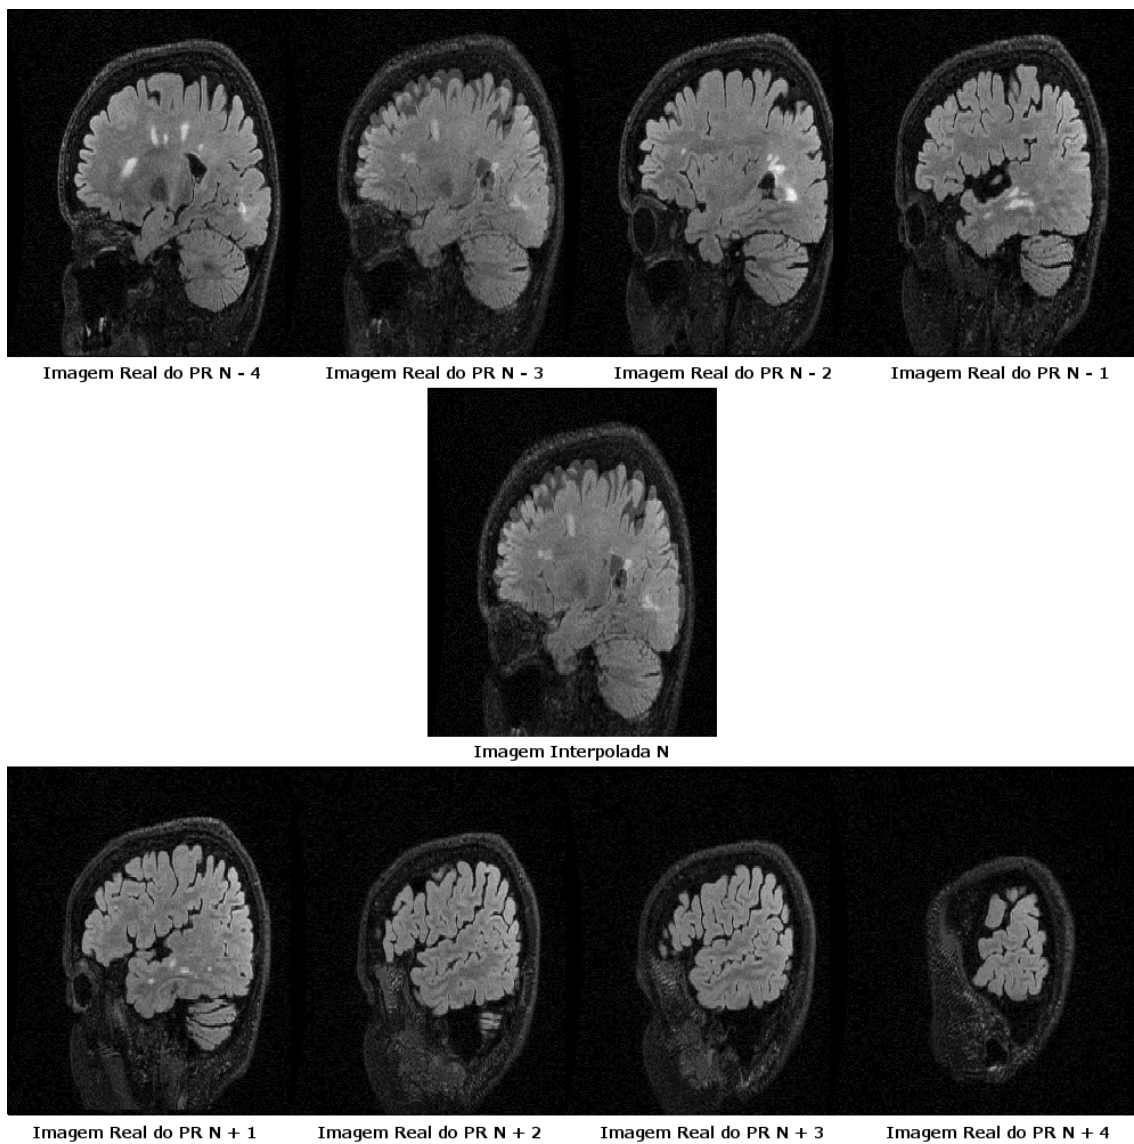


Figura 34 - Exemplo de Imagem Gerada com a Interpolação Lanczos a partir de Imagens de um Exame do InsCer

Fonte: O autor




Figura 35 - Exemplo de Imagem Gerada com a Interpolação Lanczos a partir de Imagens de um Exame do *BrainWeb*

Fonte: O autor

7 AVALIAÇÃO DE MÉTODOS DE INTERPOLAÇÃO PARA CÁLCULO DE VOLUMETRIA DE LESÕES

A partir dos métodos de interpolação apresentados no capítulo 6, foram realizados testes para avaliar o efeito destes no cálculo de volumetria de lesões de EM.

Foram aplicadas duas abordagens para testar as técnicas de interpolação. A primeira interpola as imagens FLAIR e T1 antes de serem aplicadas ao algoritmo da seção 3.4, e a segunda, interpola imagens já segmentadas, geradas pelo mesmo algoritmo. O objetivo dos testes apresentados neste capítulo é determinar qual abordagem obtém o melhor desempenho dos métodos de interpolação.

Inicialmente, as imagens interpoladas FLAIR e T1 foram segmentadas e foi calculado o volume das lesões destas, conforme é apresentado na seção 7.1. A seguir foram feitas análises da localização das lesões geradas com as interpolações nestas imagens, que foram divididas em duas seções, a seção 7.1.1 mostra a análise visual e a seção 7.1.2 a análise quantitativa. O mesmo processo é aplicado após a interpolação das imagens segmentadas. A seção 7.2 apresenta o cálculo de volume das lesões nas imagens segmentadas após terem sido interpoladas. A seção 7.2.1 mostra a análise visual das imagens geradas e a seção 7.2.2 apresenta a análise quantitativa das lesões.

7.1 CÁLCULO DA VOLUMETRIA DAS IMAGENS FLAIR e T1 INTERPOLADAS

Com a aplicação das técnicas descritas no capítulo 6 sobre as imagens do PR, foram geradas cinco sequências de imagens para cada exame com a mesma quantidade de cortes que o PE, sendo uma sequência com cada método de interpolação.

As sequências de cada par de exames (T1 e FLAIR), obtidas com a aplicação dos métodos de interpolação, foram utilizadas no algoritmo de segmentação, descrito na seção 3.4. Com isso, foram geradas as novas sequências de imagens segmentadas, que permitem o cálculo da volumetria

das lesões, através do mesmo processo descrito na seção 5.3. Com isto, para cada par de exames gerados com as técnicas de interpolação foi obtido o seu respectivo volume de lesões e os resultados são apresentados na presente seção para uma avaliação do desempenho das técnicas apresentadas através da comparação com a volumetria do PE. A Tabela 5 apresenta os dados referentes à aplicação dos métodos de interpolação para os exames de IRM com EM fornecidos pelo InsCer. A Tabela 6 apresenta a aplicação dos métodos de interpolação nos exames do *BrainWeb*.

Em cada uma destas tabelas, a primeira coluna especifica o exame que foi utilizado, a segunda e a terceira coluna mostram a volumetria do PE e do PR respectivamente. A quarta especifica o método de interpolação utilizado nas imagens do PR para simular o PE, a quinta coluna apresenta o resultado da volumetria de lesões gerada com as imagens interpoladas e a sexta coluna apresenta a relação deste volume com o volume obtido pelas imagens do PE.

Tabela 5 - Quantificação do volume de lesões gerado pelos métodos de Interpolação com exames do InsCer

Exames	PE (ml)	PR (ml)	Interpolação	Quantificação total (ml)	Relação do volume gerado
Exame 1	15,046	0,994	Nearest-Neighbor	12,059	80%
			Area	12,198	81%
			Linear	20,071	133%
			Cubica	25,960	173%
			Lanczos	26,548	176%
Exame 2	2,377	0,255	Nearest-Neighbor	2,567	108%
			Area	2,198	92%
			Linear	3,612	152%
			Cubica	4,064	171%
			Lanczos	4,528	190%
Exame 3	31,332	1,610	Nearest-Neighbor	19,907	64%
			Area	23,861	76%
			Linear	26,345	84%
			Cubica	30,703	98%
			Lanczos	33,759	108%
Exame 4	22,624	3,595	Nearest-Neighbor	14,941	66%
			Area	14,898	66%
			Linear	22,397	99%
			Cubica	29,767	132%
			Lanczos	30,888	137%
Exame 5	0,983	0,059	Nearest-Neighbor	0,786	80%
			Area	0,692	70%
			Linear	0,491	50%
			Cubica	0,964	98%

Exames	PE (ml)	PR (ml)	Interpolação	Quantificação total (ml)	Relação do volume gerado
			Lanczos	1,277	130%
Exame 6	3,261	0,369	Nearest-Neighbor	3,463	106%
			Area	4,261	131%
			Linear	2,819	86%
			Cubica	6,367	195%
			Lanczos	3,217	99%
Exame 7	80,268	25,248	Nearest-Neighbor	61,200	76%
			Area	59,292	74%
			Linear	74,350	93%
			Cubica	87,505	109%
			Lanczos	74,090	92%
Exame 8	3,995	1,454	Nearest-Neighbor	5,119	128%
			Area	5,815	146%
			Linear	5,567	139%
			Cubica	7,347	184%
			Lanczos	7,583	190%
Exame 9	1,685	0,180	Nearest-Neighbor	3,892	231%
			Area	4,141	246%
			Linear	1,804	107%
			Cubica	4,636	275%
			Lanczos	2,285	136%
Exame 10	5,471	0,436	Nearest-Neighbor	4,169	76%
			Area	5,380	98%
			Linear	5,575	102%
			Cubica	5,558	102%
			Lanczos	6,481	118%
Média Total	16,704	3,420	-	16,348	121%

Tabela 6 – Quantificação do volume de lesões gerados pelos métodos de Interpolação com os exames do *BrainWeb*

Exames	PE (ml)	PR (ml)	Interpolação	Quantificação total (ml)	Relação do volume gerado
Exame 1	20,853	6,709	Nearest-Neighbor	17,542	84%
			Area	18,176	87%
			Linear	22,139	106%
			Cubica	23,227	111%
			Lanczos	23,262	112%
Exame 2	19,537	6,373	Nearest-Neighbor	18,486	95%
			Area	19,123	98%
			Linear	22,490	115%
			Cubica	23,083	118%
			Lanczos	23,456	120%
Exame 3	17,087	5,120	Nearest-Neighbor	18,618	109%
			Area	19,318	113%
			Linear	22,131	130%

Exames	PE (ml)	PR (ml)	Interpolação	Quantificação total (ml)	Relação do volume gerado
			Cubica	22,545	132%
			Lanczos	22,636	132%
Exame 4	7,016	1,622	Nearest-Neighbor	5,765	82%
			Area	5,969	85%
			Linear	6,870	98%
			Cubica	7,465	106%
			Lanczos	7,380	105%
Exame 5	6,204	1,457	Nearest-Neighbor	6,138	99%
			Area	6,365	103%
			Linear	7,128	115%
			Cubica	7,459	120%
			Lanczos	7,523	121%
Exame 6	5,374	0,829	Nearest-Neighbor	6,326	118%
			Area	6,575	122%
			Linear	7,402	138%
			Cubica	8,208	153%
			Lanczos	8,526	159%
Exame 7	0,855	0,124	Nearest-Neighbor	0,845	99%
			Area	0,794	93%
			Linear	0,774	91%
			Cubica	0,850	99%
			Lanczos	0,898	105%
Exame 8	0,611	0,117	Nearest-Neighbor	0,932	153%
			Area	0,888	145%
			Linear	0,766	125%
			Cubica	0,855	140%
			Lanczos	0,940	154%
Exame 9	0,403	0,055	Nearest-Neighbor	0,858	213%
			Area	0,873	217%
			Linear	0,708	176%
			Cubica	0,955	237%
			Lanczos	0,938	233%
Média Total	8,660	2,490	-	9,649	126%

Os resultados obtidos na Tabela 5 permitem observar que a volumetria de lesões das sequências de imagens geradas a partir dos cortes do PR do InsCer possui uma média de 121% em relação à volumetria de lesões obtida com os exames do PE. Para os exames do *BrainWeb* percentual médio foi de 126% conforme é apresentado na Tabela 6.

Como esses dados são referentes à aplicação de todas as técnicas, é necessário analisar de forma mais detalhada o desempenho de cada interpolação, pois algum método pode estar gerando um erro maior e prejudicando volume médio.

A Tabela 7 apresenta o desempenho de cada técnica na geração de volume para os exames do InsCer. A Tabela 8 apresenta o desempenho para os exames do BrainWeb. Em ambas as tabelas são mostradas a média do percentual correspondente à volumetria das lesões geradas, o desvio padrão obtido em cada interpolação e o erro absoluto médio de cada método. Este erro é calculado através da média do erro, o qual representa em valores absolutos a diferença para a volumetria de lesões do PE.

Tabela 7 - Desempenho médio das interpolações na geração de volume dos exames do InsCer

Interpolação	Exame	Relação do volume gerado
Nearest-Neighbor	1	80%
	2	108%
	3	64%
	4	66%
	5	80%
	6	106%
	7	76%
	8	128%
	9	231%
	10	76%
	Média	102%
	Desvio Padrão	0,499
	Erro Absoluto Médio	33%
Área	1	81%
	2	92%
	3	76%
	4	66%
	5	70%
	6	131%
	7	74%
	8	146%
	9	246%
	10	98%
	Média	108%
	Desvio Padrão	0,553
	Erro Absoluto Médio	37%
Linear	1	133%
	2	152%
	3	84%

Interpolação	Exame	Relação do volume gerado
	4	99%
	5	50%
	6	86%
	7	93%
	8	139%
	9	107%
	10	102%
	Média	105%
	Desvio Padrão	0,301
	Erro Absouto Médio	22%
Cúbica	1	173%
	2	171%
	3	98%
	4	132%
	5	98%
	6	195%
	7	109%
	8	184%
	9	275%
	10	102%
Média	154%	
Desvio Padrão	0,571	
Erro Absouto Médio	55%	
Lanzos	1	176%
	2	190%
	3	108%
	4	137%
	5	130%
	6	99%
	7	92%
	8	190%
	9	136%
	10	118%
Média	138%	
Desvio Padrão	0,363	
Erro Absoluto Médio	39%	

Tabela 8 - Desempenho médio das interpolações na geração de volume dos exames do *BrainWeb*

Interpolação	Exame	Relação do volume gerado
Nearest-Neighbor	1	84%
	2	95%
	3	109%
	4	82%
	5	99%
	6	118%
	7	99%
	8	153%

Interpolação	Exame	Relação do volume gerado
	9	213%
	Média	117%
	Desvio Padrão	0,419
	Erro Absoluto Médio	26%
Area	1	87%
	2	98%
	3	113%
	4	85%
	5	103%
	6	122%
	7	93%
	8	145%
	9	217%
	Média	118%
	Desvio Padrão	0,416
	Erro Absoluto Médio	26%
	Linear	1
2		115%
3		130%
4		98%
5		115%
6		138%
7		91%
8		125%
9		176%
Média		122%
Desvio Padrão		0,253
Erro Absoluto Médio		24%
Cúbica		1
	2	118%
	3	132%
	4	106%
	5	120%
	6	153%
	7	99%
	8	140%
	9	237%
	Média	135%
	Desvio Padrão	0,418
	Erro Absoluto Médio	35%
	Lanczos	1
2		120%
3		132%
4		105%
5		121%
6		159%
7		105%
8		154%

Interpolação	Exame	Relação do volume gerado
	9	233%
	Média	138%
	Desvio Padrão	0,407
	Erro Absoluto Médio	38%

A Tabela 7 permite observar o desempenho dos métodos de interpolação aplicados aos exames do PR do InsCer. Analisando os resultados obtidos, a técnica que obteve o menor erro absoluto médio em relação à volumetria de lesões do PE foi a Interpolação Linear com um percentual de 22%, sendo que gerou em média 105% do volume de lesões. Para os exames do InsCer, a Interpolação Linear também mostrou ser a técnica com a menor variabilidade em relação a média, pois obteve o menor desvio padrão (0,301).


A Tabela 8 apresenta a volumetria média das lesões geradas pelas técnicas de interpolação quando aplicadas aos exames do PR do *BrainWeb*. Para estes exames a técnica que obteve o menor erro médio também foi a Interpolação Linear com um percentual de 24%, o menor desvio padrão (0,253) e uma média de 122% de volume gerado.

Como existem volumes gerados que estão excedendo os 100%, percebe-se que há lesões inexistentes sendo geradas. Por isto, é necessário confirmar a precisão dos volumes gerados com as técnicas de interpolação através de outras análises. A seção 7.1.1 apresenta uma análise visual das imagens geradas, enquanto a seção 7.1.2 mostra os resultados quantitativos de um cálculo que considera apenas lesões válidas e uma análise do posicionamento das lesões geradas nas imagens.


7.1.1 ANÁLISE VISUAL DAS IMAGENS INTERPOLADAS

Para permitir uma comparação visual dos resultados, a Figura 36 apresenta alguns exemplos de imagens do InsCer geradas com cada método de interpolação e seu respectivo PE, enquanto a Figura 37 mostra as lesões destas mesmas imagens após terem sido segmentadas. Da mesma forma a Figura 38 mostra as imagens interpoladas e o corte do PE relativo ao exame de

lesões moderadas do *BrainWeb* e a Figura 39 apresenta suas respectivas lesões.




Corte do PE



Interpolação Nearest-Neighbor

Interpolação por Área




Interpolação Linear

Interpolação Cúbica

Interpolação Lanczos

Figura 36 - Imagens Geradas com os Métodos de Interpolação do Corte de um Exame do InsCer

Fonte: O autor



Corte do PE



Interpolação Nearest-Neighbor

Interpolação por Área




Interpolação Linear

Interpolação Cúbica


Interpolação Lanczos

Figura 37 - Lesões Segmentadas dos Cortes de um Exame do InsCer Gerados com os Métodos de Interpolação

Fonte: O autor




Corte do PE



Interpolação Nearest-Neighbor

Interpolação por Área




Interpolação Linear

Interpolação Cúbica


Interpolação Lanczos

Figura 38 - Imagens Geradas com os Métodos de Interpolação do Corte de um Exame do BrainWeb

Fonte: O autor




Corte do PE



Interpolação Nearest-Neighbor

Interpolação por Área



Interpolação Linear

Interpolação Cúbica

Interpolação Lanczos

Figura 39 - Lesões Segmentadas dos Cortes do *BrainWeb* Gerados com os Métodos de Interpolação

Fonte: O autor

A Figura 37 e Figura 39 mostram que há lesões nas imagens interpoladas que não estão no PE e que há lesões do PE que não estão nas imagens interpoladas. Essa questão será melhor abordada na seção 7.1.2.

Com isto, percebe-se que o cálculo de volume está considerando lesões inválidas na quantificação.

Para buscar entender os motivos que causaram os falsos positivos nos cortes interpolados analisaram-se visualmente os cortes gerados por cada técnica. Um dos problemas encontrados na maioria das imagens interpoladas que foram analisadas foi a **sobreposição de regiões desalinhadas**, que é mencionada por Wolberg (Wolberg, 1998). Este problema surge, por exemplo, quando duas imagens reais vão ser interpoladas e suas regiões correspondentes estão em posições diferentes, ou quando as regiões correspondentes entre as imagens reais não tem formas semelhantes. Essas situações acabam gerando, nas imagens interpoladas, um efeito visual que permite visualizar as estruturas das imagens reais sobrepostas como mostra o exemplo da Figura 40.




Figura 40 - Exemplo de Sobreposição de Região Desalinhada

Fonte: O autor

7.1.2 RESULTADOS QUANTITATIVOS E ANÁLISE DO POSICIONAMENTO DAS LESÕES GERADAS

Além da análise visual nas imagens geradas pelos métodos de interpolação e em suas lesões segmentadas, é preciso validar as lesões de uma maneira mais precisa.

Embora o erro absoluto médio obtido pelas técnicas de interpolação, apresentado na Tabela 5 e na Tabela 6, tenha um valor menor que o erro absoluto médio obtido com o PR, apresentado na Tabela 2 e na Tabela 3, é necessário saber-se a localização das lesões geradas, para concluir se esta é uma lesão válida, tendo como base a localização das lesões no exame PE, que é utilizado como *ground truth*. Por esta razão, esta seção apresenta uma análise do posicionamento das lesões geradas com as técnicas de interpolação.

Conforme foi apresentado na seção 7.1, a volumetria de lesões criadas pelas técnicas de interpolação está sendo maior do que a volumetria de lesões do PE. Isso está acontecendo porque as interpolações estão gerando falsos positivos que acabam sendo contabilizadas no cálculo da volumetria. Consideram-se falsos positivos as lesões que foram geradas em posições incorretas, ou seja, em lugares que o PE não possui lesões e por isso elas não podem ser consideradas válidas. Exemplos deste problema podem ser observados na Figura 41, em que os falsos positivos são mostradas em vermelho e foram geradas na Interpolação Linear de um exame do InsCer. As lesões do PE são mostradas em azul. A Figura 42 mostra os falsos positivos em um exame com lesões graves do *BrainWeb* também gerados pela Interpolação Linear.

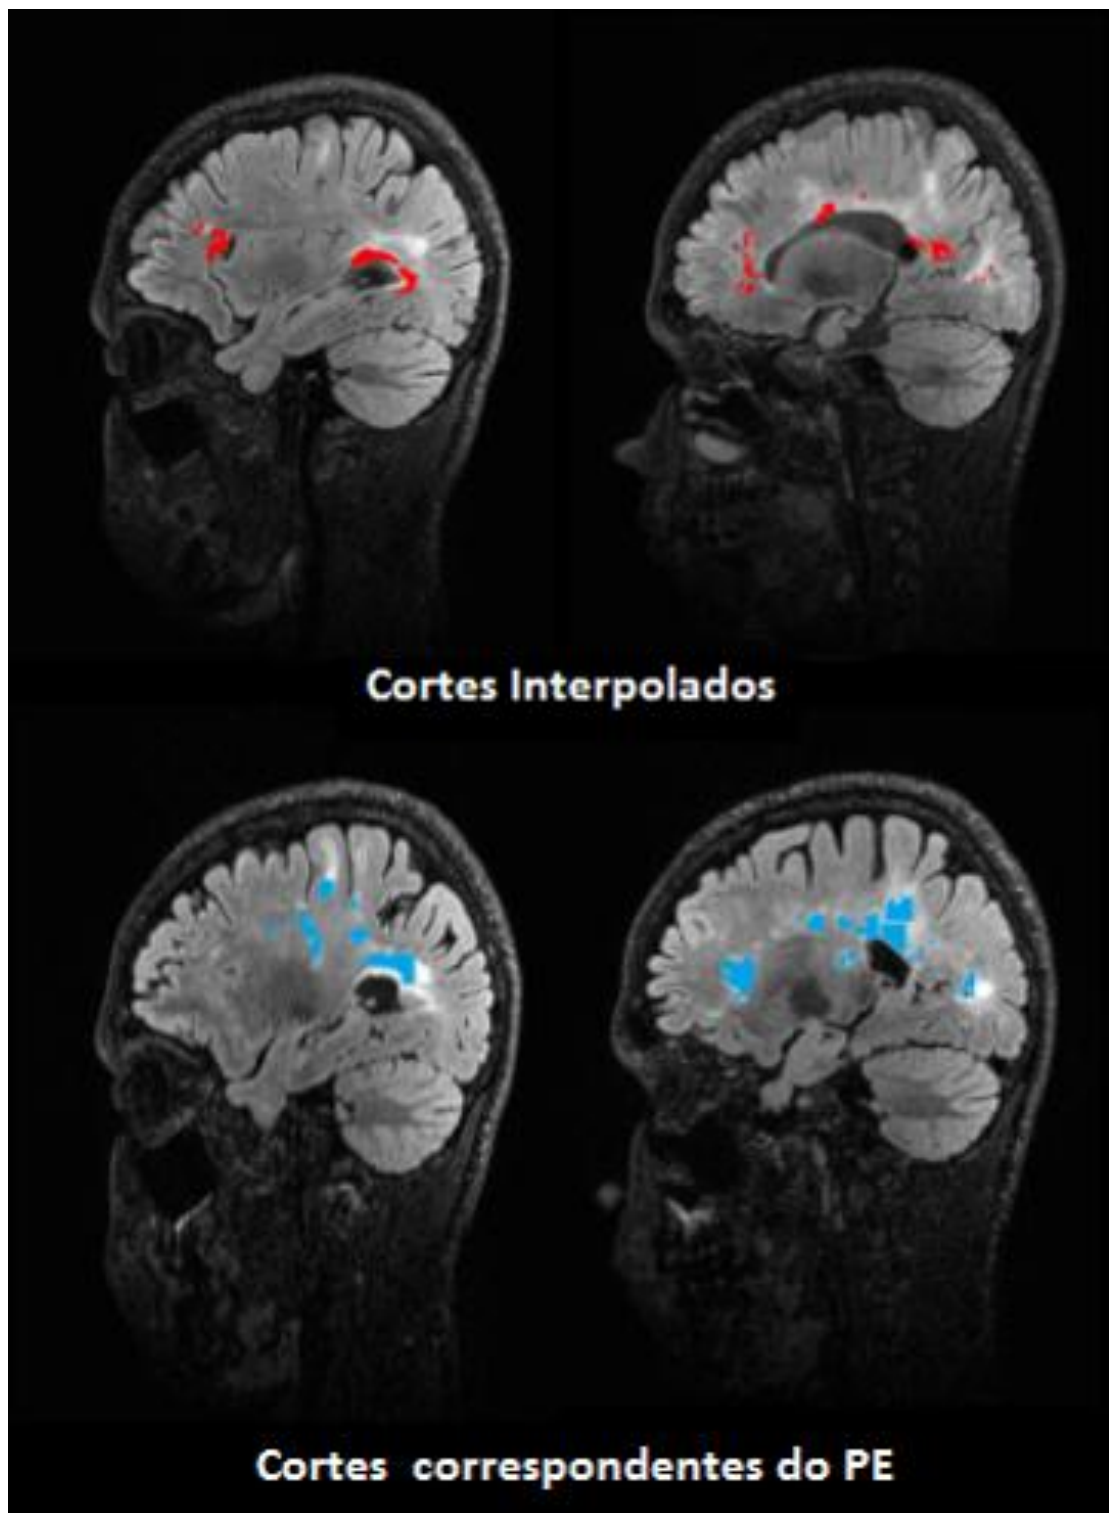


Figura 41 - Geração de Falsos Positivos nos Cortes Interpolados do InsCer

Fonte: O autor

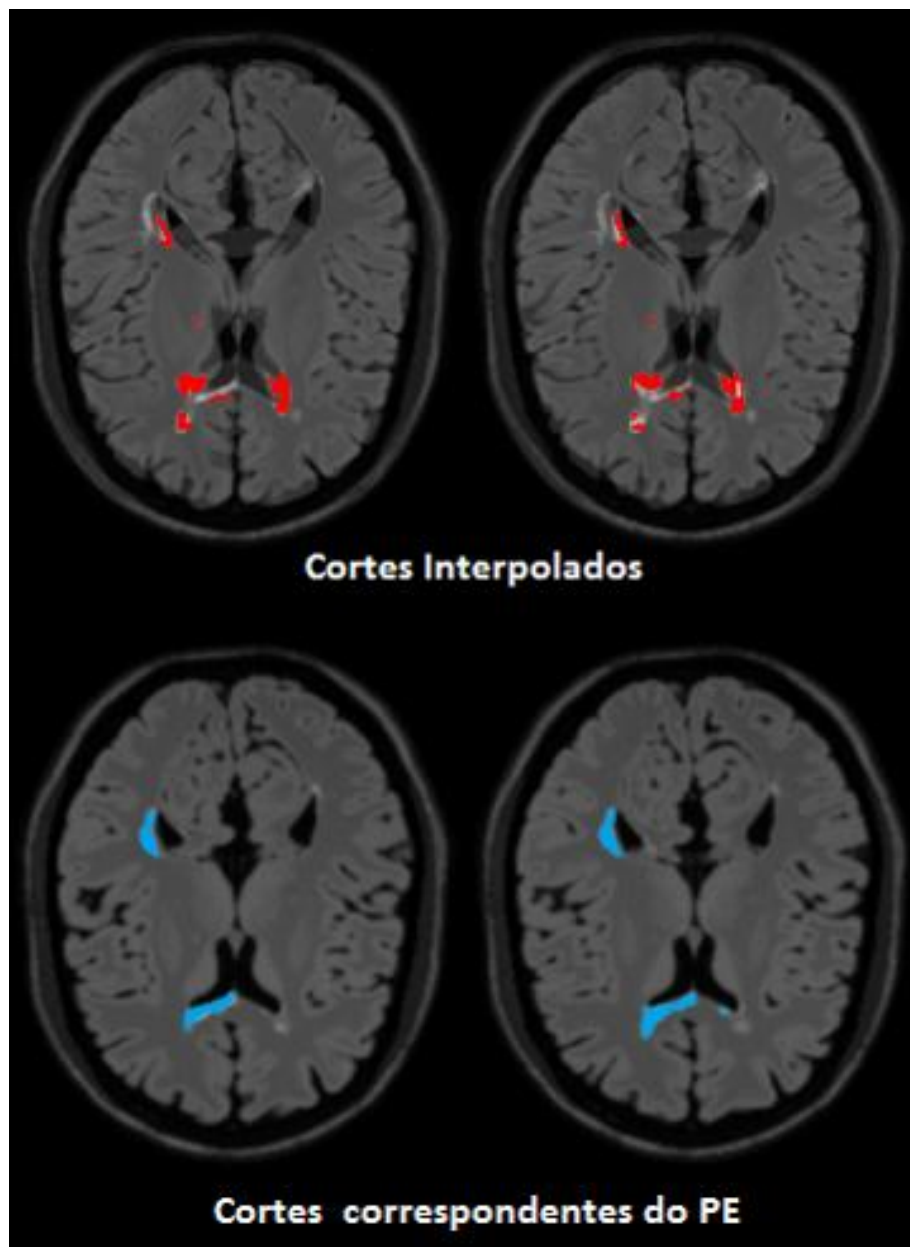


Figura 42 – Geração de Falsos Positivos nos Cortes Interpolados do *BrainWeb*

Fonte: O autor

Além dos falsos positivos, a análise do posicionamento das lesões permite identificar também os falsos negativos, ou seja, as lesões que existem no exame do PE e que as técnicas de interpolação não conseguiram gerar, como no exemplo apresentado na Figura 43. Neste exemplo, as lesões mostradas em amarelo nos cortes inferiores, são as lesões do PE, que o método de Interpolação Linear não gerou nas imagens interpoladas de um exame do InsCer. A Figura 44 apresenta o mesmo caso com imagens do

BrainWeb. Em ambas as figuras todas as lesões geradas são marcadas em verde nos cortes superiores.

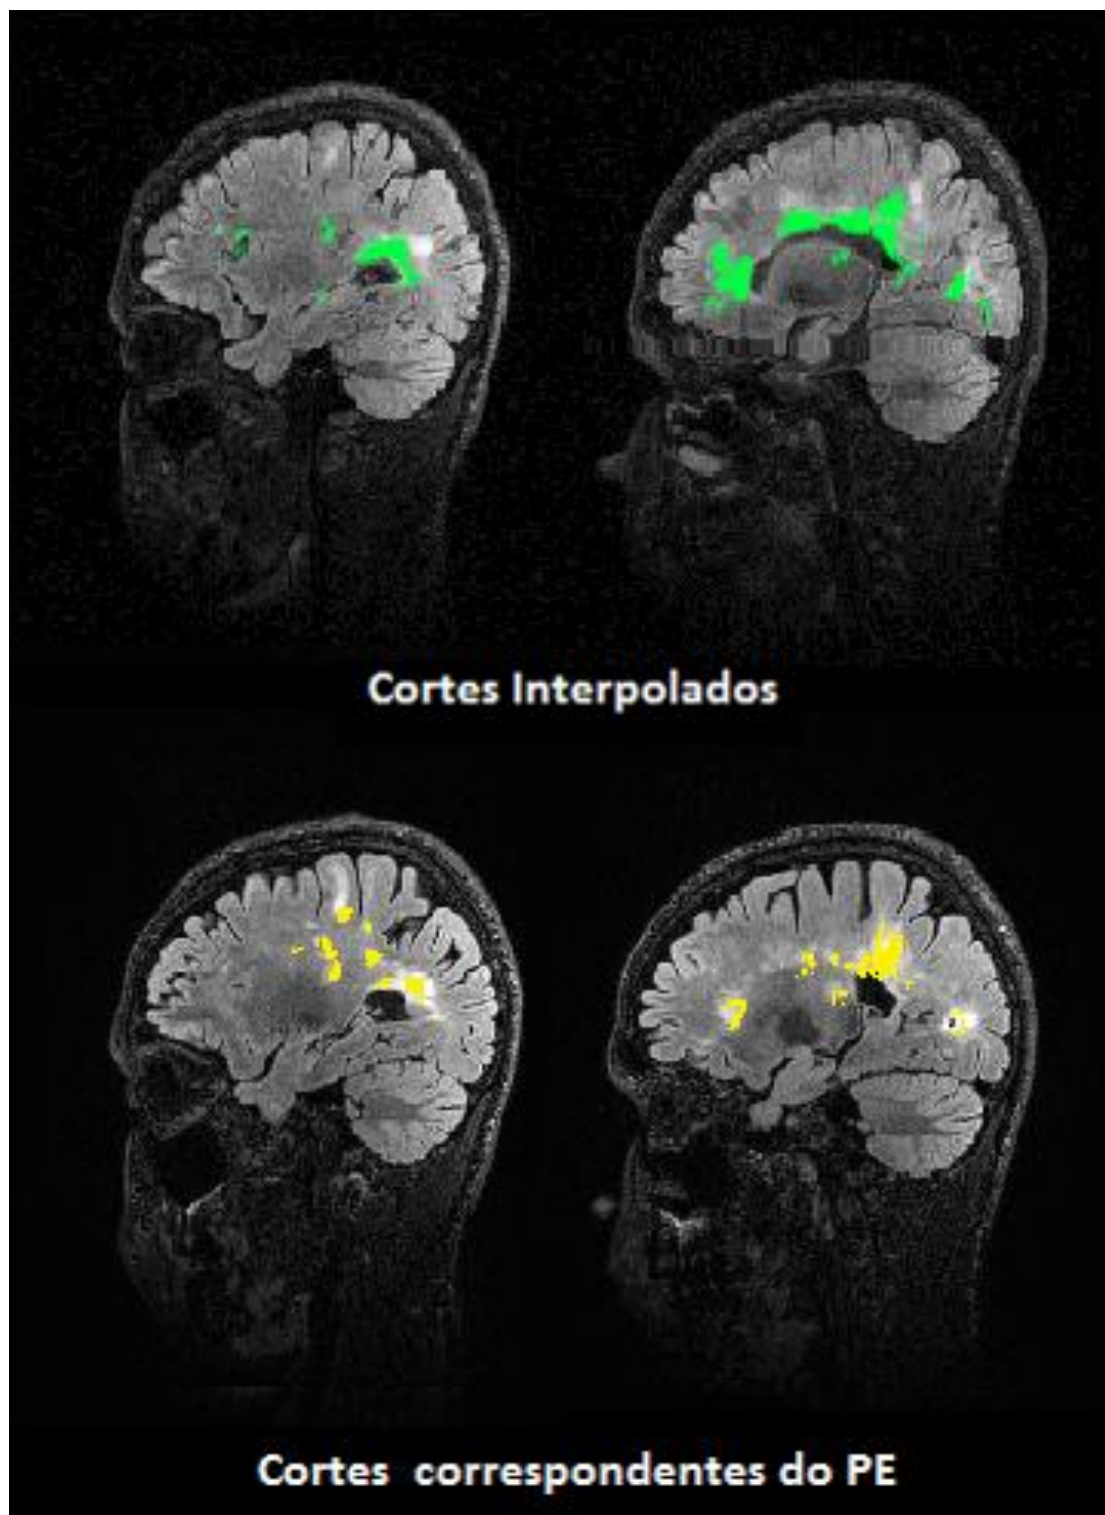


Figura 43 - Lesões Válidas que não foram Geradas pelo Método de Interpolação em um Exame do InsCer

Fonte: O autor

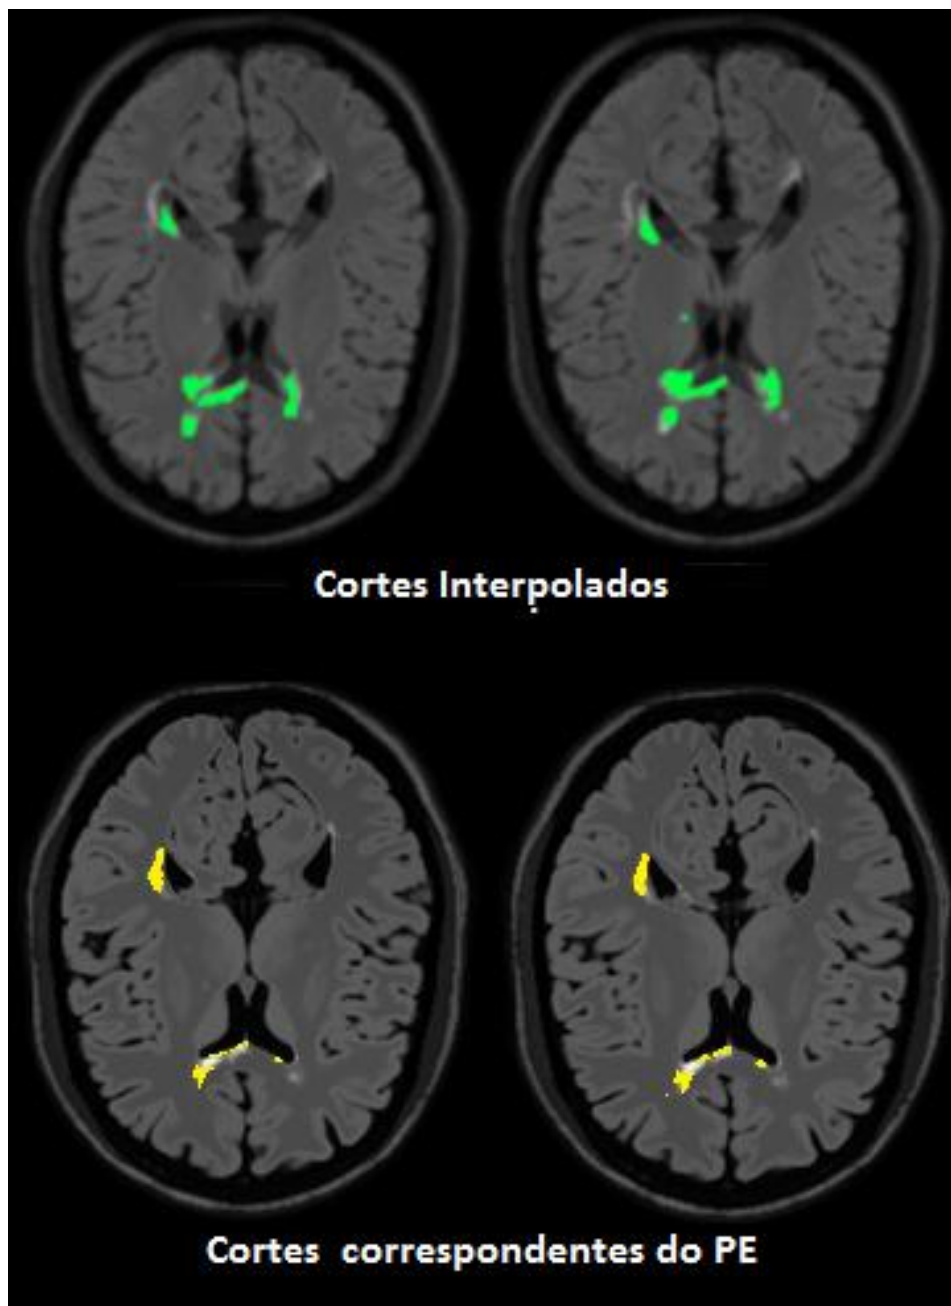


Figura 44 - Lesões Válidas que não foram Geradas pelo Método de Interpolação em um Exame do *BrainWeb*

Fonte: O autor

Para exemplificar melhor o o problema, a Figura 45 e a Figura 46 mostram um mapa das lesões geradas que permite analisar os as lesões geradas de forma correta e os falsos positivos. A Figura 45 mostra um exemplo de uma imagem do InsCer gerada com a Interpolação Cúbica e seu mapa de lesões, criado a partir da comparação entre as lesões identificadas na imagem interpolada e as lesões do exame do PE, utilizado como *ground truth*. No mapa de lesões, a cor azul representa as lesões corretas, ou seja, as lesões geradas

na mesma posição das lesões no PE. A cor amarela representa os falsos negativos e a cor vermelha os falsos positivos que surgiram durante a interpolação, mas que não existem no PE. A Figura 46, mostra o mesmo modelo de exemplo, mas com uma imagem do *BrainWeb*. Em ambas as figuras também são apresentadas a quantidade de pixels de cada grupo nos mapas de lesões, para uma análise quantitativa do mapa.




Figura 45 - Exemplo do Mapa de Lesões para as Imagens do InsCer
Fonte: O autor




Figura 46 – Exemplo do Mapa de Lesões para as Imagens do BrainWeb
 Fonte: O autor

Com a Figura 45 nota-se que 29% das lesões geradas são falsos positivos e que 71% são lesões corretas, pois foram geradas na mesma posição que lesões existentes no PE. A Figura 45 mostra 58% são falsos positivos e que 42% são lesões corretas. O número de falsos positivos e lesões corretas varia de uma imagem para outra da sequência, assim como o número de falsos negativos.

Por esta análise, percebe-se que o volume contabilizado até agora continha um elevado número de falsos positivos, fazendo com que a volumetria

estimada seja imprecisa. Por isso, é importante calcular novamente o volume das lesões, contabilizando apenas as lesões geradas na mesma posição que as lesões existentes no PE.

Dessa forma, calculou-se outra vez a volumetria dos exames, excluindo-se os falsos positivos e considerando apenas as lesões válidas, conforme é apresentado na Tabela 9 e na Tabela 10. Essas tabelas contém, respectivamente, a quantificação do volume válido de lesões para os exames gerados com as imagens do *InsCer* e para os exames gerados com as imagens do *BrainWeb*. Nota-se que nessas tabelas, a sétima coluna contém um percentual de erro. Este percentual corresponde ao valor absoluto obtido com a diferença entre 100%, equivalentente à quantificação total, e o percentual obtido com a relação entre a quantificação sem os falsos positivos (sexta coluna) e a quantificação do volume total gerado pelo método de interpolação (quinta coluna). Com isso é possível analisar dentre o total de lesões geradas, o percentual relativo à quantidade de lesões válidas.

Tabela 9 - Quantificação do volume válido nos exames do InsCer

Exames	PE (ml)	PR (ml)	Interpolação	Quantificação original (ml)	Quantificação do volume sem falsos positivos (ml)	Percentual de erro
Exame 1	15,046	0,994	Nearest-Neighbor	12,059	5,518	54%
			Area	12,198	5,482	55%
			Linear	20,071	8,586	57%
			Cubica	25,96	9,355	64%
			Lanczos	26,548	9,293	65%
Exame 2	2,377	0,255	Nearest-Neighbor	2,567	1,413	45%
			Area	2,198	1,257	43%
			Linear	3,612	1,56	57%
			Cubica	4,064	1,614	60%
			Lanczos	4,528	1,673	63%
Exame 3	31,332	1,61	Nearest-Neighbor	19,907	10,255	48%
			Area	23,861	12,23	49%
			Linear	26,345	13,806	48%
			Cubica	30,703	15,738	49%
			Lanczos	33,759	14,754	56%
Exame 4	22,624	3,595	Nearest-Neighbor	14,941	7,185	52%
			Area	14,898	7,681	48%
			Linear	22,397	13,5	40%

Exames	PE (ml)	PR (ml)	Interpolação	Quantificação original (ml)	Quantificação do volume sem falsos positivos (ml)	Percentual de erro
			Cubica	29,767	15,662	47%
			Lanczos	30,888	15,898	49%
Exame 5	0,983	0,059	Nearest-Neighbor	0,786	0,262	67%
			Area	0,692	0,262	62%
			Linear	0,491	0,206	58%
			Cubica	0,964	0,3	69%
			Lanczos	1,277	0,334	74%
Exame 6	3,261	0,369	Nearest-Neighbor	3,463	0,547	84%
			Area	4,261	0,622	85%
			Linear	2,819	0,36	87%
			Cubica	6,367	0,68	89%
			Lanczos	3,217	0,353	89%
Exame 7	80,268	25,248	Nearest-Neighbor	61,2	36,587	40%
			Area	59,292	35,324	40%
			Linear	74,35	43,578	41%
			Cubica	87,505	44,413	49%
			Lanczos	74,09	41,949	43%
Exame 8	3,995	1,454	Nearest-Neighbor	5,119	1,992	61%
			Area	5,815	2,077	64%
			Linear	5,567	1,876	66%
			Cubica	7,347	2,357	68%
			Lanczos	7,583	2,419	68%
Exame 9	1,685	0,18	Nearest-Neighbor	3,892	0,373	90%
			Area	4,141	0,353	91%
			Linear	1,804	0,535	70%
			Cubica	4,636	0,425	91%
			Lanczos	2,285	0,535	77%
Exame 10	5,471	0,436	Nearest-Neighbor	4,169	1,519	64%
			Area	5,38	1,971	63%
			Linear	5,575	1,19	79%
			Cubica	5,558	2,18	61%
			Lanczos	6,481	1,871	71%
Média Total	16,704	3,42	-	16,348	7,998	62%

Tabela 10 - Quantificação do volume válido nos exames do *BrainWeb*

Exames	PE (ml)	PR (ml)	Interpolação	Quantificação original (ml)	Quantificação do volume sem os falsos positivos (ml)	Percentual de Erro
Exame 1	20,853	6,709	Nearest-Neighbor	17,542	13,389	24%
			Area	18,176	13,927	23%
			Linear	22,139	15,697	29%
			Cubica	23,227	16,214	30%
			Lanczos	23,262	16,143	31%
Exame 2	19,537	6,373	Nearest-Neighbor	18,486	13,473	27%
			Area	19,123	14,058	26%
			Linear	22,49	15,458	31%
			Cubica	23,083	15,729	32%
			Lanczos	23,456	15,706	33%
Exame 3	17,087	5,12	Nearest-Neighbor	18,618	12,435	33%
			Area	19,318	12,804	34%
			Linear	22,131	13,76	38%
			Cubica	22,545	13,933	38%
			Lanczos	22,636	13,905	39%
Exame 4	7,016	1,622	Nearest-Neighbor	5,765	3,803	34%
			Area	5,969	3,937	34%
			Linear	6,87	4,204	39%
			Cubica	7,465	4,565	39%
			Lanczos	7,38	4,524	39%
Exame 5	6,204	1,457	Nearest-Neighbor	6,138	3,785	38%
			Area	6,365	3,896	39%
			Linear	7,128	4,136	42%
			Cubica	7,459	4,261	43%
			Lanczos	7,523	4,295	43%
Exame 6	5,374	0,829	Nearest-Neighbor	6,326	3,398	46%
			Area	6,575	3,528	46%
			Linear	7,402	3,714	50%
			Cubica	8,208	3,959	52%
			Lanczos	8,526	3,973	53%
Exame 7	0,855	0,124	Nearest-Neighbor	0,845	0,52	38%
			Area	0,794	0,371	53%
			Linear	0,774	0,418	46%
			Cubica	0,85	0,381	55%
			Lanczos	0,898	0,436	51%
Exame 8	0,611	0,117	Nearest-Neighbor	0,932	0,352	62%
			Area	0,888	0,351	60%
			Linear	0,766	0,302	61%
			Cubica	0,855	0,359	58%
			Lanczos	0,94	0,371	61%
Exame 9	0,403	0,055	Nearest-	0,858	0,221	74%

Exames	PE (ml)	PR (ml)	Interpolação	Quantificação original (ml)	Quantificação do volume sem os falsos positivos (ml)	Percentual de Erro
			Neighbor			
			Area	0,873	0,226	74%
			Linear	0,708	0,225	68%
			Cubica	0,955	0,237	75%
			Lanczos	0,938	0,227	76%
Média total	8,66	2,49	-	9,649	6,258	45%

Com os resultados apresentados na Tabela 9 e na Tabela 10, é possível observar através da comparação entre a sexta e terceira coluna que, mesmo desconsiderando os falsos positivos, os métodos conseguem obter um volume de lesões maior do que a quantificação original obtida com o PR em todos os exames.

A Tabela 11 e a Tabela 12 mostram, para os exames do InsCer e do *BrainWeb* respectivamente, o desempenho de cada técnica de interpolação, considerando o percentual de erro obtido em cada exame e o erro médio de cada técnica, ao considerar apenas o volume válido. O erro absoluto médio é uma média em valores absolutos dos percentuais de erro em cada técnica.

Tabela 11 - Desempenho médio das interpolações na geração de volume válido com os exames do InsCer

Interpolação	Exame	Percentual de Erro
Nearest-Neighbor	1	54%
	2	45%
	3	48%
	4	52%
	5	67%
	6	84%
	7	40%
	8	61%
	9	90%
	10	64%
	Desvio Padrão	0,164
	Erro Absoluto Médio	61%
Área	1	55%
	2	43%
	3	49%
	4	48%
	5	62%

Interpolação	Exame	Percentual de Erro
	6	85%
	7	40%
	8	64%
	9	91%
	10	63%
	Desvio Padrão	0,171
	Erro Absoluto Médio	60%
Linear	1	57%
	2	57%
	3	48%
	4	40%
	5	58%
	6	87%
	7	41%
	8	66%
	9	70%
	10	79%
	Desvio Padrão	0,155
	Erro Absoluto Médio	60%
Cúbica	1	64%
	2	60%
	3	49%
	4	47%
	5	69%
	6	89%
	7	49%
	8	68%
	9	91%
	10	61%
	Desvio Padrão	0,154
	Erro Absoluto Médio	65%
Lanzos	1	65%
	2	63%
	3	56%
	4	49%
	5	74%
	6	89%
	7	43%
	8	68%
	9	77%
	10	71%
	Desvio Padrão	0,136
	Erro Absoluto Médio	65%

Tabela 12 - Desempenho médio das interpolações na geração de volume válido com os exames do *BrainWeb*

Interpolação	Exame	Percentual de Erro
Nearest-Neighbor	1	24%
	2	27%
	3	33%
	4	34%
	5	38%
	6	46%
	7	38%
	8	62%
	9	74%
	Desvio Padrão	0,166
	Erro Absoluto Médio	42%
Area	1	23%
	2	26%
	3	34%
	4	34%
	5	39%
	6	46%
	7	53%
	8	60%
	9	74%
	Desvio Padrão	0,167
	Erro Absoluto Médio	43%
Linear	1	29%
	2	31%
	3	38%
	4	39%
	5	42%
	6	50%
	7	46%
	8	61%
	9	68%
	Desvio Padrão	0,130
	Erro Absoluto Médio	45%
Cúbica	1	30%
	2	32%
	3	38%
	4	39%
	5	43%
	6	52%
	7	55%
	8	58%
	9	75%
	Desvio Padrão	0,145

Interpolação	Exame	Percentual de Erro
	Erro Absoluto Médio	47%
Lanczos	1	31%
	2	33%
	3	39%
	4	39%
	5	43%
	6	53%
	7	51%
	8	61%
	9	76%
	Desvio Padrão	0,145
Erro Absoluto Médio	47%	

Com a Tabela 11, tem-se agora o erro absoluto médio correspondente ao percentual de acerto dos métodos de interpolação aplicados aos exames do InsCer, sendo que o melhor desempenho foi da Interpolação Linear e da Interpolação por Área, ambos com um erro médio de 60%, no entanto, a Interpolação Linear obteve um desvio padrão de 0,155 que é menor que o desvio padrão de 0,171 da Interpolação por Área. Pela Tabela 12, percebe-se que o menor erro absoluto médio foi de 42% da Interpolação *Neighbor-Nearest* com um desvio padrão de 0,166. O menor desvio padrão para estes exames foi 0,130 da Interpolação Linear, que obteve um erro médio de 45%.

Como os falsos positivos só foram identificadas empregando-se o PE, que não estaria disponível na prática clínica, a utilização do PR com as técnicas de interpolação para quantificar as lesões precisaria obter um erro médio menor. Isso faria a precisão das técnicas aumentar, gerando uma quantidade menor de falsos positivos. Tendo esse objetivo em vista os outros métodos apresentados ao longo da dissertação buscam diminuir o erro absoluto médio obtido com as técnicas, ao considerar somente o volume válido.

7.2 CÁLCULO DA VOLUMETRIA NAS IMAGENS SEGMENTADAS E INTERPOLADAS

Conforme foi apresentado na seção 7.1.2, na prática clínica é importante minimizar o erro causado pelos métodos na geração de imagens, por isso cresce a necessidade de testar outras estratégias para melhorar a precisão dos resultados obtidos com as técnicas tradicionais de interpolação. Como se identificou o problema da sobreposição de áreas desalinhadas adotou-se uma nova estratégia para evitar este efeito. A estratégia escolhida segmenta as lesões das imagens do PR com o algoritmo descrito na seção 3.4 **antes** de aplicar os métodos de interpolação, ou seja, as imagens utilizadas na interpolação foram imagens do PR geradas pela terceira etapa do algoritmo de crescimento de lesão.

O motivo da utilização dessa estratégia foi tentar garantir que apenas as regiões com lesões obtidas com a aplicação do algoritmo de crescimento de lesão, fossem interpoladas. Com isto os métodos de interpolação geraram novas imagens que são apresentadas na seção 7.2.1. A seção 7.2.2 apresenta os resultados quantitativos do volume válido após a aplicação das técnicas de interpolação nas imagens segmentadas, permitindo analisar se o erro absoluto médio causado pelas técnicas apresentadas diminuiu.

7.2.1 ANÁLISE VISUAL DAS IMAGENS SEGMENTADAS E INTERPOLADAS

Para permitir uma comparação visual dos resultados, esta seção apresenta algumas imagens segmentadas que foram interpoladas com as técnicas apresentadas no capítulo 6. Como os cortes segmentados são imagens que contém em cada pixel uma intensidade que corresponde à probabilidade deste ser uma lesão, os dados interpolados são as probabilidades dos pixels serem lesões.

A Figura 47 e a Figura 48 apresentam alguns exemplos de imagens geradas com a Interpolação *Nearest-Neighbor*, para as imagens segmentadas do InsCer e do *BrainWeb*, respectivamente. Da mesma forma, a Figura 49 e a Figura 50 mostram algumas imagens geradas com a Interpolação por Área, a Figura 51 e a Figura 52 apresentam algumas imagens geradas com a

Interpolação Linear, a Figura 53 e a Figura 54 para algumas imagens geradas com a Interpolação Cúbica, a Figura 55 e a Figura 56 mostram algumas imagens geradas com a Interpolação Lanczos.




Figura 47 - Imagens do InsCer e Segmentadas Geradas com a Interpolação *Nearest-Neighbor*

Fonte: O autor




Figura 48 – Imagens do *BrainWeb* e Segmentadas Geradas com a Interpolação *Nearest-Neighbor*

Fonte: O autor




Figura 49 – Imagens do InsCer Segmentadas e Geradas com a Interpolação por Área

Fonte: O autor




Figura 50 – Imagens do *BrainWeb* e Segmentadas Geradas com a Interpolação por Área

Fonte: O autor



Imagem Real do PR

Imagem Interpolada 1

Imagem Interpolada 2




Imagem Interpolada 3

Imagem Interpolada 4

Imagem Real do PR

Figura 51 - Imagens do *InsCer* Segmentadas e Geradas com a Interpolação Linear

Fonte: O autor

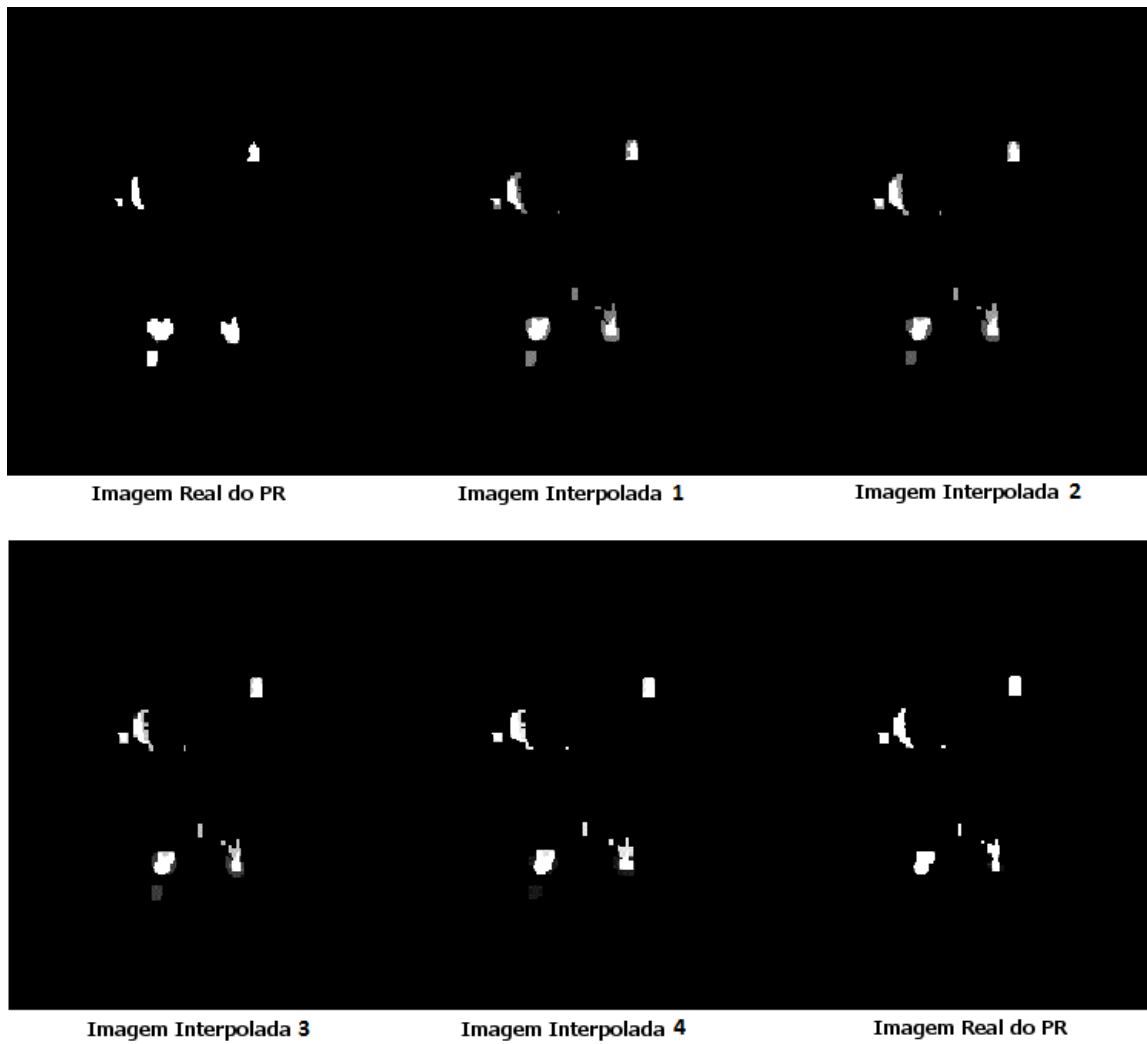


Figura 52 – Imagens do *BrainWeb* Segmentadas e Geradas com a Interpolação Linear

Fonte: O autor




Figura 53 - Imagens do *InsCer* Segmentadas e Geradas com a Interpolação Cúbica

Fonte: O autor




Figura 54 – Imagens do *BrainWeb* Segmentadas e Geradas com a Interpolação Cúbica

Fonte: O autor




Imagem Real do PR N - 4

Imagem Real do PR N - 3

Imagem Real do PR N - 2

Imagem Real do PR N - 1




Imagem Interpolada N




Imagem Real do PR N + 1

Imagem Real do PR N + 2

Imagem Real do PR N + 3

Imagem Real do PR N + 4

Figura 55 - Imagens do *InsCer* Segmentadas e Geradas com a Interpolação Lanczos

Fonte: O autor

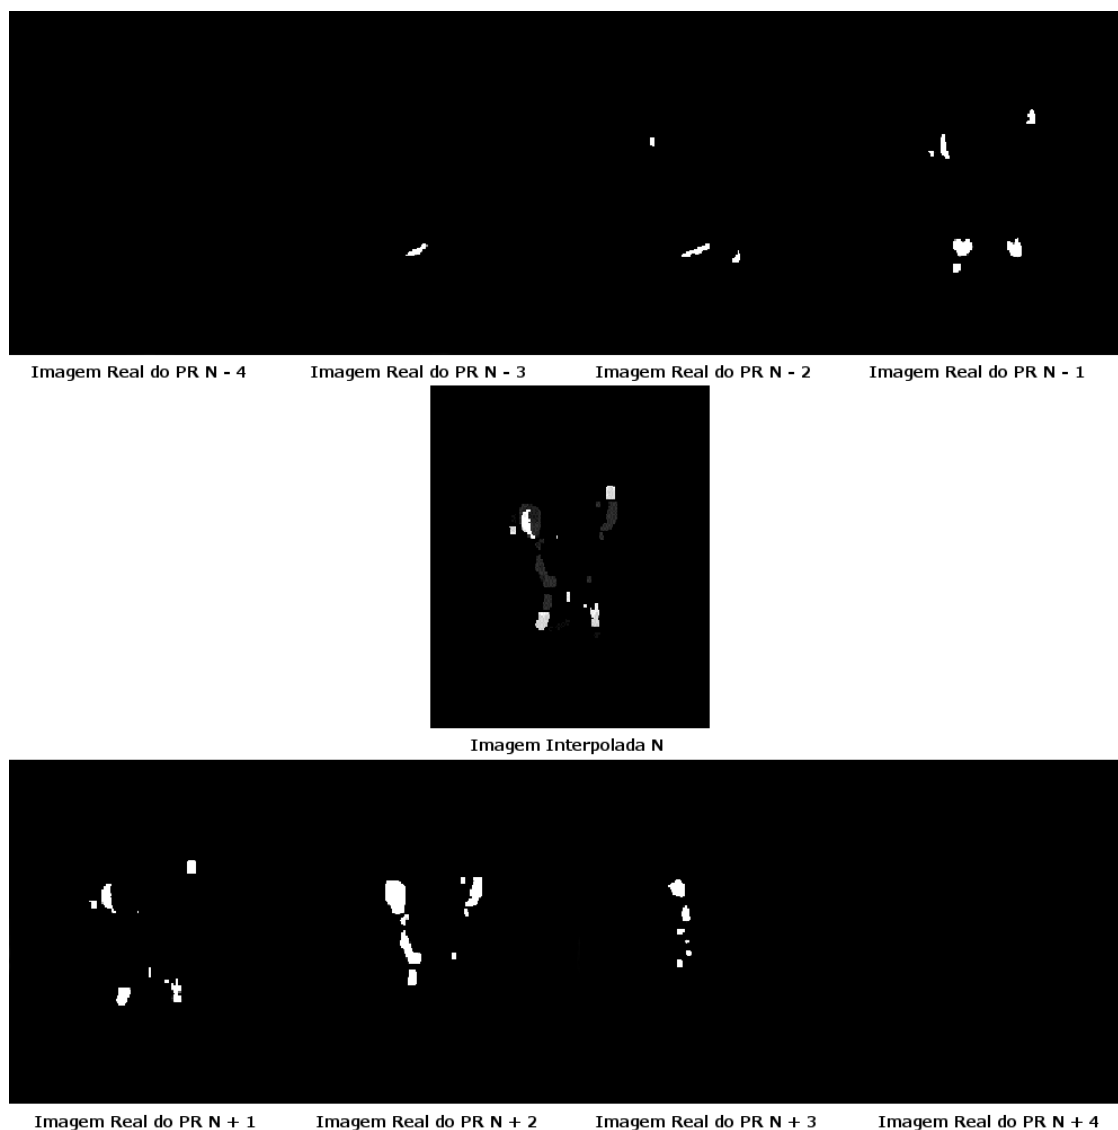


Figura 56 – Imagens do *BrainWeb* segmentadas geradas e com a Interpolação Lanczos

Fonte: O autor

Com as figuras apresentadas nesta seção notam-se que as imagens interpoladas possuem tons de cinza intermediários, ou seja, valores menores que o valor máximo (255) e maiores que 0. Visando facilitar os cálculos que não consideram os falsos positivos, houve a transformação das imagens geradas em binárias com um limiar em 0, ou seja, qualquer pixel com um valor maior que 0 acaba sendo considerado como lesão. Os resultados quantitativos obtidos com as imagens segmentadas são apresentados na seção 7.2.2.

7.2.2 RESULTADOS QUANTITATIVOS OBTIDOS COM AS IMAGENS SEGMENTADAS E INTERPOLADAS

Nesta seção são apresentados os resultados quantitativos que permitem avaliar se a metodologia de interpolar as imagens segmentadas conseguiu diminuir o erro absoluto médio causado pelos métodos de interpolação com as imagens FLAIR e T1, conforme foi apresentado na seção 7.1.2. A Tabela 13 apresenta a quantificação do volume válido referentes aos exames segmentados do InsCer. A Tabela 14, mostra os dados referentes aos exames segmentados do *BrainWeb*.

Tabela 13 - Quantificação do volume válido de lesões nos exames segmentados do InsCer

Exames	PE (ml)	PR (ml)	Interpolação	Quantificação original (ml)	Quantificação do volume sem os falsos positivos (ml)	Percentual de Erro
Exame 1	15,046	0,994	Nearest-Neighbor	1,034	0,591	43%
			Area	1,098	0,608	45%
			Linear	1,630	0,733	55%
			Cubica	1,558	0,715	54%
			Lanczos	2,680	0,751	72%
Exame 2	2,377	0,255	Nearest-Neighbor	0,678	0,131	81%
			Area	0,751	0,132	82%
			Linear	1,082	0,137	87%
			Cubica	1,078	0,137	87%
			Lanczos	1,922	0,137	93%
Exame 3	31,332	1,610	Nearest-Neighbor	1,726	0,581	66%
			Area	1,939	0,647	67%
			Linear	3,012	0,891	70%
			Cubica	2,892	0,864	70%
			Lanczos	5,096	1,009	80%
Exame 4	22,624	3,595	Nearest-Neighbor	3,700	1,907	48%
			Area	4,115	2,142	48%
			Linear	5,845	2,580	56%
			Cubica	5,653	2,569	55%
			Lanczos	9,987	2,574	74%
Exame 5	0,983	0,059	Nearest-Neighbor	0,082	0,005	94%
			Area	0,082	0,005	94%
			Linear	0,139	0,006	96%
			Cubica	0,139	0,006	96%
			Lanczos	0,274	0,006	98%
Exame 6	3,261	0,369	Nearest-Neighbor	0,412	0,023	94%
			Area	0,426	0,023	95%

Exames	PE (ml)	PR (ml)	Interpolação	Quantificação original (ml)	Quantificação do volume sem os falsos positivos (ml)	Percentual de Erro
			Linear	0,718	0,028	96%
			Cubica	0,695	0,028	96%
			Lanczos	1,302	0,028	98%
Exame 7	80,268	25,248	Nearest-Neighbor	41,285	18,551	55%
			Area	43,933	19,205	56%
			Linear	57,274	21,122	63%
			Cubica	50,109	20,229	60%
			Lanczos	77,810	21,285	73%
Exame 8	3,995	1,454	Nearest-Neighbor	1,724	0,554	68%
			Area	1,939	0,629	68%
			Linear	2,969	0,797	73%
			Cubica	2,780	0,784	72%
			Lanczos	5,209	0,801	85%
Exame 9	1,685	0,180	Nearest-Neighbor	0,214	0,025	88%
			Area	0,218	0,025	89%
			Linear	0,356	0,043	88%
			Cubica	0,336	0,043	87%
			Lanczos	0,587	0,043	93%
Exame 10	5,471	0,436	Nearest-Neighbor	0,523	0,101	81%
			Area	0,588	0,128	78%
			Linear	0,903	0,166	82%
			Cubica	0,844	0,157	81%
			Lanczos	1,584	0,157	90%
Média Total	16,704	3,420	-	7,059	2,497	76%

Tabela 14 - Quantificação do volume válido de lesões nos exames segmentados do *BrainWeb*

Exames	PE (ml)	PR (ml)	Interpolação	Quantificação original (ml)	Quantificação do volume sem os falsos positivos (ml)	Percentual de Erro
Exame 1	20,853	6,709	Nearest-Neighbor	13,856	11,193	19%
			Area	15,048	11,750	22%
			Linear	23,144	13,424	42%
			Cubica	22,550	13,594	40%
			Lanczos	40,632	13,723	66%
Exame 2	19,537	6,373	Nearest-Neighbor	13,162	10,586	20%
			Area	14,265	11,070	22%
			Linear	21,733	12,820	41%
			Cubica	21,155	12,686	40%
			Lanczos	37,857	12,841	66%
Exame 3	17,087	5,120	Nearest-Neighbor	10,554	8,570	19%

Exames	PE (ml)	PR (ml)	Interpolação	Quantificação original (ml)	Quantificação do volume sem os falsos positivos (ml)	Percentual de Erro
			Area	11,469	8,948	22%
			Linear	17,662	10,484	41%
			Cubica	17,314	10,402	40%
			Lanczos	31,244	10,499	66%
Exame 4	7,016	1,622	Nearest-Neighbor	3,257	2,637	19%
			Area	3,661	2,795	24%
			Linear	6,325	3,390	46%
			Cubica	6,292	3,375	46%
			Lanczos	12,203	3,421	72%
Exame 5	6,204	1,457	Nearest-Neighbor	2,922	2,255	23%
			Area	3,296	2,398	27%
			Linear	5,761	2,855	50%
			Cubica	5,737	2,852	50%
			Lanczos	11,173	2,875	74%
Exame 6	5,374	0,829	Nearest-Neighbor	1,636	1,198	27%
			Area	1,854	1,275	31%
			Linear	3,306	1,562	53%
			Cubica	3,300	1,562	53%
			Lanczos	6,478	1,563	76%
Exame 7	0,855	0,124	Nearest-Neighbor	0,268	0,184	31%
			Area	0,300	0,213	29%
			Linear	0,501	0,301	40%
			Cubica	0,502	0,302	40%
			Lanczos	0,983	0,302	69%
Exame 8	0,611	0,117	Nearest-Neighbor	0,248	0,125	50%
			Area	0,275	0,150	45%
			Linear	0,439	0,212	52%
			Cubica	0,428	0,212	50%
			Lanczos	0,794	0,213	73%
Exame 9	0,403	0,055	Nearest-Neighbor	0,120	0,077	36%
			Area	0,135	0,092	32%
			Linear	0,225	0,120	47%
			Cubica	0,225	0,120	47%
			Lanczos	0,449	0,120	73%
Média total	8,660	2,490	-	8,772	4,697	43%

Com os resultados apresentados na quinta coluna das tabelas, é possível perceber que para todos os exames, a estratégia de interpolar imagens segmentadas gerou uma quantidade menor de lesões, fazendo com

que o volume total gerado tenha um desempenho inferior em relação à estratégia da seção 7.1, no quesito de gerar um volume próximo ao PE.

No entanto, para realizar a comparação dos percentuais de erro que consideram o volume válido, como já foi feito na seção 7.1.2, foi analisado qual método de interpolação aplicado as imagens segmentadas gerou o menor erro absoluto médio em relação ao volume sem os falsos positivos. Para isso, a Tabela 15 e a Tabela 16 apresentam, para os exames do InsCer e do BrainWeb respectivamente, o erro absoluto médio causado pelas técnicas que interpolam as imagens segmentadas. Além disso, essas tabelas possuem os erros médios da abordagem que interpola as imagens FLAIR e T1, permitindo uma comparação entre os erros absolutos médios obtidos pelas duas estratégias adotadas, ou seja, a estratégia apresentada na seção 7.1., que interpola as imagens FLAIR e T1 e a estratégia mostrada na seção 7.2 que segmenta as imagens com o algoritmo descrito na seção 3.4 **antes** de serem interpoladas. Essa comparação possibilita analisar com qual abordagem adotada, as interpolações são mais precisas para gerar o volume válido de lesões.

Tabela 15 - Comparação do percentual de acerto entre as estratégias adotadas para os exames do InsCer

Interpolação	Exame	Percentual de Erro Interpolação FLAIR e T1	Percentual de Erro Interpolação Imagens Segmentadas
Nearest-Neighbor	1	54%	43%
	2	45%	81%
	3	48%	66%
	4	52%	48%
	5	67%	94%
	6	84%	94%
	7	40%	55%
	8	61%	68%
	9	90%	88%
	10	64%	81%
		Desvio Padrão	0,164
	Erro Absoluto Médio	61%	72%
Área	1	55%	45%
	2	43%	82%
	3	49%	67%
	4	48%	48%
	5	62%	94%
	6	85%	95%
	7	40%	56%
	8	64%	68%

Interpolação	Exame	Percentual de Erro Interpolação FLAIR e T1	Percentual de Erro Interpolação Imagens Segmentadas
	9	91%	89%
	10	63%	78%
	Desvio Padrão	0,171	0,184
	Erro Absoluto Médio	60%	72%
Linear	1	57%	55%
	2	57%	87%
	3	48%	70%
	4	40%	56%
	5	58%	96%
	6	87%	96%
	7	41%	63%
	8	66%	73%
	9	70%	88%
	10	79%	82%
	Desvio Padrão	0,155	0,154
	Erro Absoluto Médio	60%	77%
Cúbica	1	64%	54%
	2	60%	87%
	3	49%	70%
	4	47%	55%
	5	69%	96%
	6	89%	96%
	7	49%	60%
	8	68%	72%
	9	91%	87%
	10	61%	81%
	Desvio Padrão	0,154	0,161
	Erro Absoluto Médio	65%	76%
Lanzos	1	65%	72%
	2	63%	93%
	3	56%	80%
	4	49%	74%
	5	74%	98%
	6	89%	98%
	7	43%	73%
	8	68%	85%
	9	77%	93%
	10	71%	90%
	Desvio Padrão	0,136	0,102
	Erro Absoluto Médio	66%	86%

Tabela 16 - Comparação do percentual de acerto entre as estratégias adotadas para os exames do *BrainWeb*

Interpolação	Exame	Percentual de Erro Interpolação FLAIR e T1	Percentual de Erro Interpolação Imagens Segmentadas
Nearest-Neighbor	1	24%	19%
	2	27%	20%
	3	33%	19%
	4	34%	19%
	5	38%	23%
	6	46%	27%
	7	38%	31%
	8	62%	50%
	9	74%	36%
	Desvio Padrão	0,166	0,104
	Erro Absoluto Médio	42%	27%
Área	1	23%	22%
	2	26%	22%
	3	34%	22%
	4	34%	24%
	5	39%	27%
	6	46%	31%
	7	53%	29%
	8	60%	45%
	9	74%	32%
	Desvio Padrão	0,167	0,075
	Erro Absoluto Médio	43%	28%
Linear	1	29%	42%
	2	31%	41%
	3	38%	41%
	4	39%	46%
	5	42%	50%
	6	50%	53%
	7	46%	40%
	8	61%	52%
	9	68%	47%
	Desvio Padrão	0,130	0,051
	Erro Absoluto Médio	45%	46%
Cúbica	1	30%	40%
	2	32%	40%
	3	38%	40%
	4	39%	46%
	5	43%	50%
	6	52%	53%
	7	55%	40%
	8	58%	50%
	9	75%	47%
	Desvio Padrão	0,145	0,053
	Erro Absoluto Médio	47%	45%
Lanzos	1	31%	66%

Interpolação	Exame	Percentual de Erro Interpolação FLAIR e T1	Percentual de Erro Interpolação Imagens Segmentadas
	2	33%	66%
	3	39%	66%
	4	39%	72%
	5	43%	74%
	6	53%	76%
	7	51%	69%
	8	61%	73%
	9	76%	73%
	Desvio Padrão	0,145	0,038
	Erro Absoluto Médio	47%	71%

Através Tabela 15, que apresenta os dados obtidos com exames do InsCer, nota-se visualizando a quarta coluna que as técnicas que obtiveram o melhor desempenho utilizando a abordagem de interpolar as imagens segmentadas foram as Interpolações *Nearest-Neighbor* e a Interpolação por Área, ambas com um erro médio de 72%. A Interpolação por Área obteve um desvio padrão menor (0,184) do que Interpolação *Nearest-Neighbor* (0,187) e por isso mostra uma variabilidade menor dos dados em relação à média. O menor desvio padrão obtido foi da Interpolação Lanczos (0,102) que gerou um erro médio de 86%.

Com a Tabela 15 também se percebe que para os exames do InsCer a estratégia que interpola as imagens FLAIR e T1 possui um erro absoluto médio menor em todos os métodos de interpolação comparados a estratégia que interpola as imagens segmentadas, sendo que a maior diferença foi de 20% com Interpolação Lanczos.

A Tabela 16 mostra, que para os exames do *BrainWeb*, o método de interpolação que obteve o melhor desempenho utilizando a estratégia com as imagens segmentadas foi a Interpolação *Nearest-Neighbor* que obteve um erro médio de 27%, com um desvio padrão de 0,104. Seu desvio padrão, no entanto, foi o maior dentre os outros métodos sendo que o menor desvio padrão foi da Interpolação Lanczos (0,038) cujo erro médio foi de 71%.

Na Tabela 16 nota-se que para a Interpolação *Nearest-Neighbor*, a Interpolação por Área e a Interpolação Cúbica, a estratégia de interpolar as

imagens segmentadas gerou um erro menor do que a estratégia que interpola as imagens FLAIR e T1, sendo que as comparações foram de 27% contra 42%, 28% contra 43% e 45% contra 47%, respectivamente. Entretanto, para a Interpolação Linear e para a Interpolação Lanczos o erro médio obtido com as imagens segmentadas foi maior, sendo 46% contra 45% e 71% contra 47%, respectivamente.

Pelas análises realizadas percebe-se que a estratégia de segmentar as imagens **antes** de interpolar não conseguiu diminuir o erro absoluto médio obtido com a primeira estratégia para os exames do InsCer, porém conseguiu diminuir o erro em 3 das 5 técnicas de interpolação nas imagens do *BrainWeb*.

Com isso, observou-se que a segunda estratégia não diminuiu o erro absoluto médio calculado pelo volume válido gerado na primeira abordagem para todos os casos, principalmente com os exames reais do InsCer.

Sendo assim, o capítulo 8 apresenta novos métodos com objetivo de diminuir a quantidade de falsos positivos, diminuindo os erros médios obtidos em cada técnica.

8 MÉTODOS PARA REMOÇÃO DE FALSOS POSITIVOS

Com a aplicação das técnicas de interpolação percebeu-se que, mesmo obtendo um erro absoluto médio menor que o PR na aproximação da volumetria de lesões obtidas com o PE, há uma grande quantidade de falsos positivos sendo gerados. Devido a esse fato procurou-se aplicar outras técnicas para tentar diminuir o número desses falsos positivos, melhorando a precisão dos resultados obtidos com os métodos de interpolação, em termos da localização das lesões geradas e com isso diminuir o erro absoluto médio relacionado ao volume de lesões válidas.

Ao analisar os resultados apresentados na seção 7.1.2 percebeu-se que uma grande quantidade dos falsos positivos surgia nas imagens FLAIR interpoladas em regiões que, apesar de hiperintensas no exame do PR, não haviam sido classificadas como lesões nos cortes reais.

Em outra análise, desta vez com os resultados do método que aplica as técnicas de interpolação ao exame segmentado do PR (seção 7.2.2), constatou-se que as regiões que mais geravam falsos positivos eram áreas que, apesar de hiperintensas, não possuíam lesões, nas mesmas posições, em cortes reais adjacentes.

Baseado nessas características que geravam os erros, o presente capítulo apresenta três abordagens que visam reduzir os falsos positivos gerados pelas técnicas tradicionais de interpolação. A primeira aplica uma técnica tradicional de *morphing* de imagens, que tem a ideia de identificar as mesmas lesões em cortes adjacentes e transformar a forma das mesmas ao longo das imagens artificiais geradas. A técnica de *morphing* é apresentada na seção 8.1. A segunda abordagem, apresentada na seção 8.2, tem a ideia de eliminar as regiões hiperintensas do PR segmentado que não possuem as mesmas posições nos cortes adjacentes. O objetivo neste caso é eliminar dessas imagens as regiões com maiores chances de gerarem falsos positivos, antes de aplicar as técnicas de interpolação. Na terceira abordagem a ideia é eliminar as regiões hiperintensas do exame FLAIR do PR que o algoritmo de crescimento de lesão não classificou como lesão, também visando retirar as

áreas com maiores chances de gerarem falsos positivos antes de aplicar as técnicas de interpolação. Esta técnica é apresentada na seção 8.3.

8.1 GERAÇÃO DE IMAGENS COM MORPHING

A primeira alternativa testada para gerar imagens interpoladas com uma quantidade menor de falsos positivos foi a aplicação de uma técnica de *morphing* de imagens. Optou-se por usar esta abordagem, buscando-se interpolar a forma das lesões, e com isto diminuir os efeitos de sobreposição das áreas desalinhadas.

Conforme Wolberg (Wolberg, 1998) e Atoui et. al. (Atoui, Miguet, Sarrut, & others, 2006), o *morphing* de imagens é uma técnica utilizada para gerar uma imagem artificial através da aplicação de uma série de deformações entre regiões correspondentes, seguidas da interpolação de intensidades nas regiões deformadas.

As técnicas de *morphing* são muito utilizadas na indústria de entretenimento, por exemplo, para aplicar efeitos visuais em vídeos, e já se mostraram uma alternativa viável em aplicações médicas (MSIV & Les Folio, 2007), como a geração de imagens ausentes em exames de IRM. Weber et. al. (Weber, Keerl, Jaspersen, Huppmann, Schick, & Draf, 1996) utilizaram o *morphing* para reconstruir o processo de cicatrização do nariz e do esôfago. D'Haese et. al. (D'Haese, Cetinkaya, Konrad, Kao, & Dawant, 2005) utilizaram o *morphing* de imagens para desenvolver um sistema de orientação que auxilia na colocação de estimuladores cerebrais com o objetivo de tratar distúrbios de movimentos como, por exemplo, mal de Parkinson.

Existem diversas técnicas tradicionais de *morphing* aplicadas a imagens como é apresentado por Wolberg (Wolberg, 1998), todas aplicando procedimentos semelhantes, porém variando na velocidade de processamento, na eficiência e na confiabilidade dos dados gerados.

Nesta dissertação foi utilizado o método de *morphing* por malha disponibilizado pelo software *Morpheus* (Morpheus Software, 1999) pelo fato de ser uma técnica conhecida na literatura e com softwares disponíveis para sua aplicação. A seção 8.1.1 apresenta a fundamentação teórica do método, a

seção 8.1.2 mostra o método aplicado para as imagens com EM e a seção 8.1.3 apresenta uma avaliação dos seus resultados.

8.1.1 MORPHING POR MALHA

O *morphing* por malha é uma técnica que gera imagens através da interpolação da forma e da intensidade das estruturas em um processo que utiliza duas malhas relacionadas. Estas malhas definem áreas correspondentes entre uma imagem de origem e uma imagem de destino e são divididas em pequenas regiões que são associadas por conjuntos de pontos de controle para serem deformadas (Wolberg, 1998).

A Figura 57 mostra um exemplo de uma malha sendo utilizada no *morphing* de um rosto canino para o rosto de uma menina.

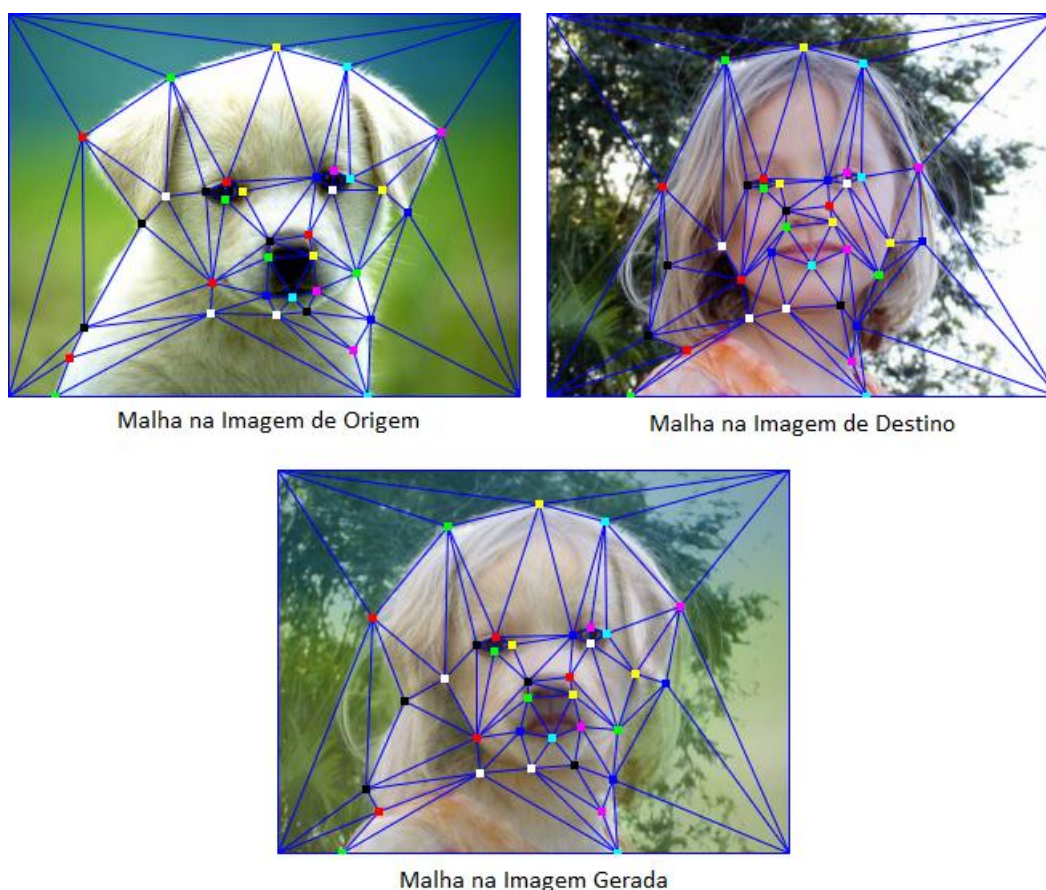


Figura 57 - Exemplo da Utilização de uma Malha no *Morphing* de Imagens

Fonte: O autor

Os pontos de controle são as coordenadas das regiões associadas e devem ser colocados de forma que o pixel marcado pelo ponto X na imagem de origem corresponda ao pixel marcado pelo ponto X na imagem de destino,

gerando dois conjuntos de pontos, uma para cada imagem. Nas imagens da Figura 57, por exemplo, é possível identificar os pontos correspondentes pela cor e pela localização.

A partir dos pontos de controle especificados, tem-se o conjunto de coordenadas das regiões associadas em cada imagem e é possível, então, gerar uma malha para cada conjunto. Esta malha tem a função de definir a transformação espacial que os pontos da imagem de origem sofreram em relação aos pontos da imagem de destino (Wolberg, 1998). Através da interpolação linear entre as duas malhas gera-se uma malha M que deformada gera as posições dos pixels nas imagens intermediárias. Esta deformação corresponde a um alinhamento das regiões nas imagens de origem e destino seguido de uma interpolação de intensidade das mesmas. Conforme Wolberg, o alinhamento é feito interpolando-se as coordenadas do conjunto de pontos entre a imagem de origem e a malha M, e entre o conjunto de pontos da imagem de destino e a malha M. Por fim é realizada uma interpolação de intensidade das imagens alinhadas.

8.1.2 APLICAÇÃO DO *MORPHING* POR MALHA NOS EXAMES COM EM DO PR

A ideia da aplicação de *morphing* para gerar as imagens interpoladas é transformar as estruturas correspondentes ao longo dos cortes. Isto é feito através da criação de malhas tendo como pontos de controle, pontos localizados nas bordas das lesões correspondentes, como mostra o exemplo de malha da Figura 58.

Esta foi a metodologia escolhida pelo fato das imagens adjacentes do PR possuírem poucas estruturas semelhantes devido à existência de gaps entre os cortes no momento da aquisição, dificultando o relacionamento entre elas. Com os pontos especificados nas lesões correspondentes busca-se que a deformação destas regiões reduza o efeito de sobreposição das mesmas e por consequência gere um número menor de falsos positivos nas áreas deformadas.

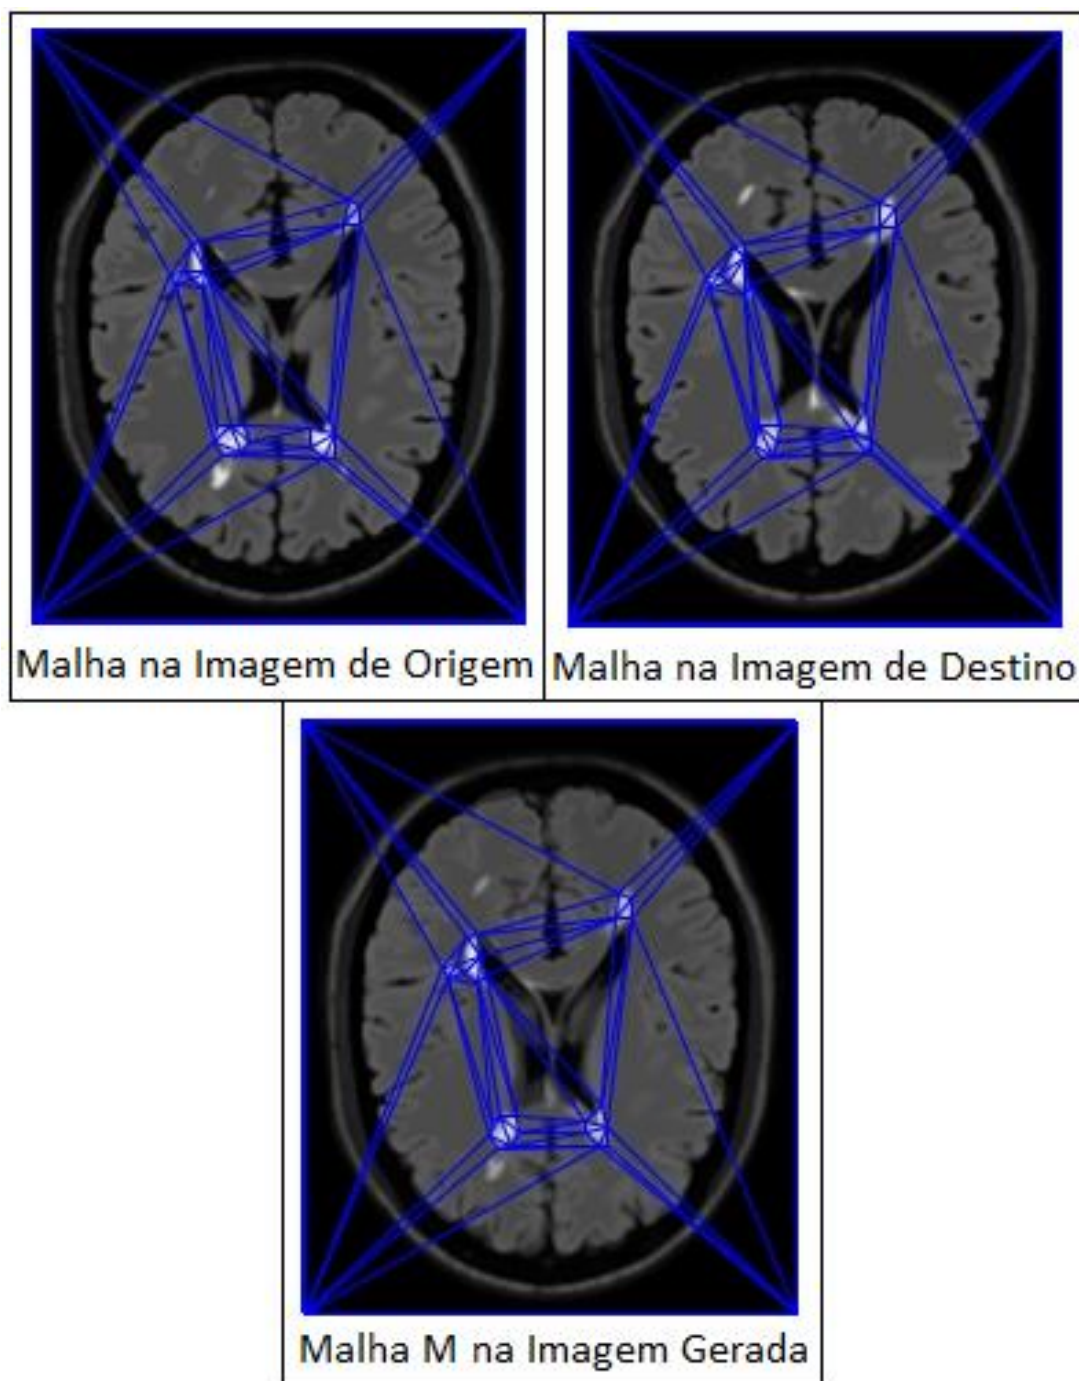


Figura 58 - Exemplo de Malha Associada às Bordas das Lesões

Fonte: O autor

A especificação dos pontos de controle e a associação destes entre as imagens adjacentes, o que demanda tempo e precisão, se esta tarefa for realizada de forma manual, ou exige a utilização de um algoritmo automático complexo que seja capaz de encontrar as áreas semelhantes em imagens adjacentes e associar os pontos nessas regiões.

Para os resultados apresentados na seção 8.1.3, optou-se por colocar os pontos de controle de forma manual. A Figura 59 apresenta os pontos de controle colocados na mesma lesão apresentada em imagens adjacentes com dois arcos mostrando dois dos pontos correspondentes.

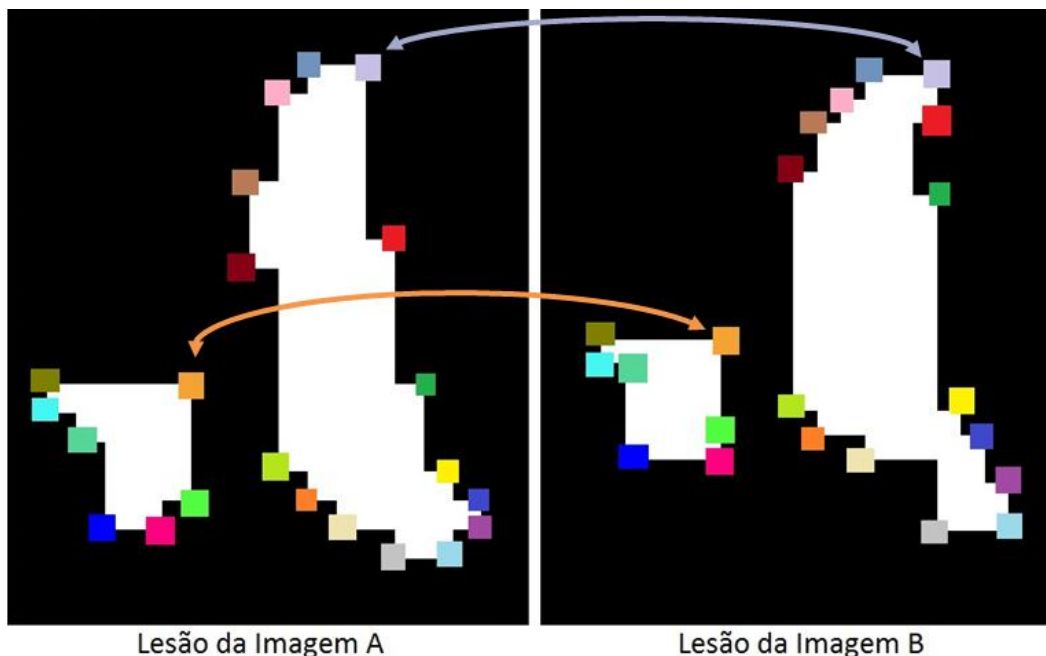


Figura 59 - Pontos de Controle nas Lesões

Fonte: O autor

A Figura 60 apresenta um exemplo de como os pontos de controle correspondentes ficam nas imagens FLAIR adjacentes ao utilizarem-se as posições das lesões segmentadas. A Figura 61 mostra uma sequência de imagens do exame de lesões graves do *BrainWeb* geradas com o *morphing* por malha.




Figura 60 - Pontos de Controle em duas Imagens Adjacentes

Fonte: O autor




Figura 61 - Imagens Geradas pelo *Morphing* por Malha

Fonte: O autor

8.1.3 RESULTADOS QUANTITATIVOS OBTIDOS COM O *MORPHING* POR MALHA

Decidiu-se, em primeiro lugar, aplicar o método de *morphing* aos exames do *BrainWeb*. A técnica foi aplicada em exames gerados pelo *BrainWeb* com 0% de ruído, visando facilitar a inserção dos pontos de controle. Aplicou-se o *morphing* por malha em um exame com lesões graves e em um exame com lesões moderadas, que são os exames 1 e 4 do *BrainWeb* respectivamente. Escolheram-se esses dois exames para testar esta técnica pelo fato de possuírem lesões correspondentes em cortes adjacentes permitindo a inserção dos pontos de controle de acordo com as posições das lesões segmentadas. A Tabela 17 apresenta os resultados da aplicação do método de *morphing* por malha nos dois exames.

Tabela 17 - Quantificação do volume no exame de lesões graves e moderadas

Exame	Quantificação original	Quantificação do volume sem os falsos positivos	Percentual de erro
Lesões Graves	21,313 ml	14,683 ml	31 %
Lesões Moderadas	7,057 ml	4,213 ml	40 %

Os resultados mostram que o *morphing por malha* não reduziu a quantidade de falsos positivos, tendo em vista que o percentual de erro do exame com lesões graves foi de 31% e este desempenho é semelhante ao pior percentual obtido com as interpolações para o mesmo exame, que foi de 31% com a Interpolação Lanczos. Da mesma forma, para o exame com lesões moderadas, o erro de 40% foi maior que a interpolação de pior desempenho para o mesmo exame, que foi da interpolações Linear, Cúbica e Lanczos, que erraram 39% das lesões geradas. Os dados comparados são os exames 1 e 4 da Tabela 10, que contém os dados do *BrainWeb* gerados com a abordagem de que interpola as imagens FLAIR e T1.

Devido à dificuldade de realizar a correspondência entre os dados de imagens diferentes e percebendo que através metodologia adotada para inserir os pontos de controle, o *morphing por malha* não poderia ser aplicado em exames que não tivessem as lesões correspondentes nas imagens adjacentes, não se continuou empregando esse método para os exames reais disponibilizados pelo InsCer.

8.2 MÉTODO DE INSERÇÃO DE CORTES ARTIFICIAIS NO PR SEGMENTADO

Conforme apresentado na seção 8.1, a técnica de *morphing* mostrou-se inadequada para aplicação em exames que não possuíam lesões correspondentes nos cortes adjacentes. Além disso, para aplicar as técnicas de *morphing* é necessário associar pontos nas regiões correspondentes em imagens adjacentes, o que demanda tempo e precisão, se esta tarefa for realizada de forma manual, ou exige a utilização de um algoritmo automático complexo que seja capaz de encontrar a correspondência das regiões em imagens adjacentes.

Em face disto, buscou-se outra forma de diminuir a quantidade de falsos positivos gerados pelas interpolações. Como primeira abordagem, optou-se pela proposta de um método que fosse aplicado ao exame segmentado, pelo fato deste exame possuir apenas as lesões, permitindo uma identificação mais simples da causa que gerava os falsos positivos.

Analisando a localização destes falsos positivos nas imagens geradas na seção 7.2, constatou-se que a principal causa do problema, era que as áreas que não possuíam lesões correspondentes na mesma posição em cortes adjacentes, ao serem interpoladas geravam regiões hiperintensas. Estas regiões, ao passarem pelo algoritmo de crescimento de lesão, acabavam por gerar falsos positivos, em especial nos cortes situados na porção central da interpolação ou em cortes mais distantes da imagem que possui a lesão. Na Figura 62, por exemplo, pode-se observar nas regiões apontadas pelas setas, que mesmo não existindo uma lesão com a mesma posição na imagem A e na imagem B, foi gerada uma lesão na imagem interpolada.




Figura 62 - Geração de falsos positivos no exame segmentado do PR

Fonte: O autor

Ainda na mesma análise, percebeu-se que lesões que possuíam as mesmas posições em cortes adjacentes apresentavam uma quantidade alta de lesões geradas de forma correta, em termos de localização, até mesmo nos cortes centrais de uma sequência gerada entre duas imagens reais do PR e nos cortes distantes das áreas reais com lesão.

A Figura 63 mostra uma visão esquemática do problema, na qual se pode observar a geração de falsos positivos sinalizados pelos círculos.




Figura 63 - Esquema do problema encontrado

Fonte: O autor

Buscando solucionar este problema, o método proposto **insere imagens artificiais no PR já segmentado** pelo algoritmo de crescimento de lesão da seção 3.4. A função da imagem artificial inserida é dividir a região interpolada, de modo que a interpolação que simula o PE seja realizada entre uma imagem real e uma artificial e não entre duas imagens reais.

A imagem artificial foi então construída de forma que as regiões com maior probabilidade de gerar falsos positivos estivessem sem lesões, reduzindo a propagação das mesmas entre os cortes. Em outras palavras, uma lesão que antes iniciava em um corte real e, pela interpolação, iria terminar próxima do corte adjacente, agora passa a terminar próxima do corte central das imagens interpoladas.

Para efeitos de implementação, os cortes artificiais são imagens binárias que possuem apenas as lesões que se encontram na mesma posição em imagens reais adjacentes. A geração destas imagens, em si, é feita com uma operação AND entre as versões binárias dos cortes do exame segmentado do PR, como mostra o exemplo da Figura 64. Nesta imagem o corte artificial AB é

gerado com uma operação AND entre as imagens adjacentes A e B. Por fim a imagem AB é inserida no exame segmentado do PR entre os mesmos cortes A e B antes de aplicar os métodos de interpolação para simular o PE como mostra o esquema da Figura 65.




Figura 64 - Imagem Artificial Construída com a Operação AND entre os Cortes Reais Adjacentes

Fonte: O autor

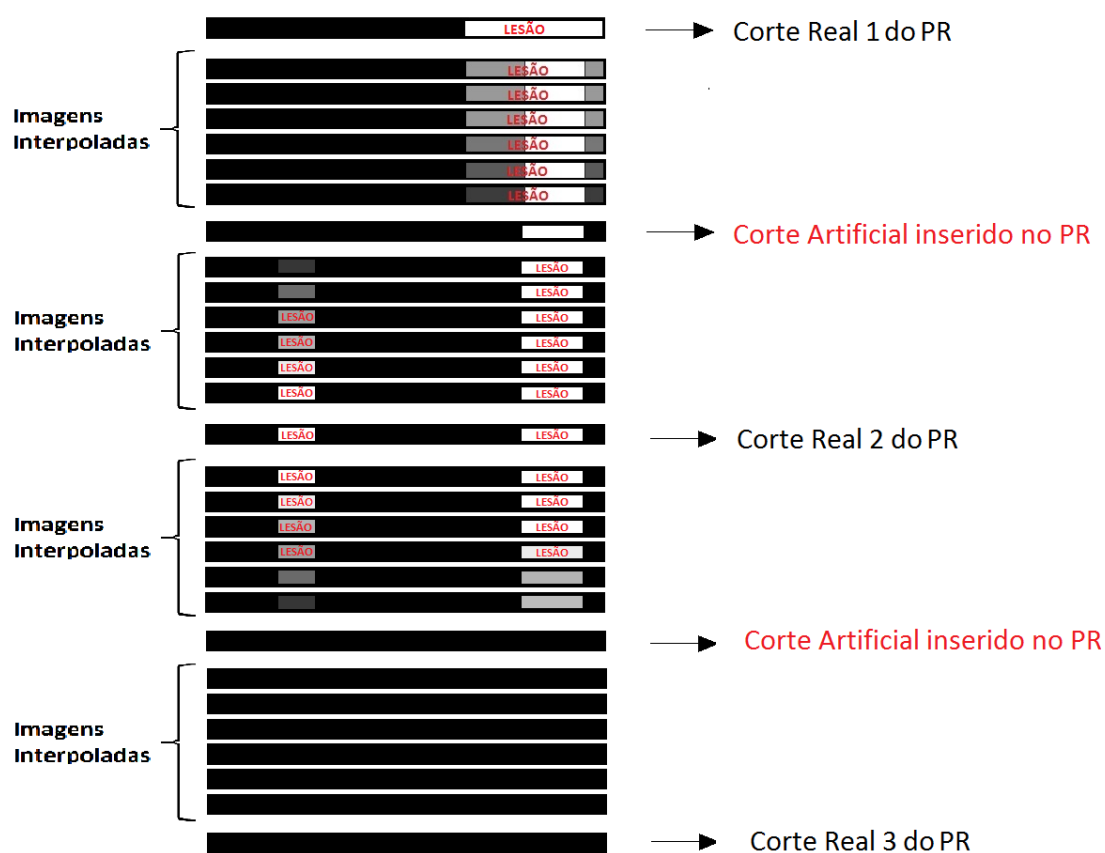


Figura 65 - Esquema do Modelo Proposto

Fonte: O autor

8.2.1 RESULTADOS QUANTITATIVOS OBTIDOS COM O MÉTODO DE INTERÇÃO DE CORTES ARTIFICIAIS NO PR SEGMENTADO

Com os novos exames do PR, gerados através do método apresentado na 8.2, foram aplicados os métodos de interpolação para gerar os novos exames interpolados com as imagens segmentadas. Para estes exames foi calculada a volumetria das lesões de EM para analisar a quantidade de falsos positivos que o método conseguiu reduzir em cada técnica de interpolação através da avaliação do erro médio.

Esta seção apresenta os resultados quantitativos e também uma comparação dos métodos de interpolação com as diferentes abordagens para a geração de volume válido. A Tabela 18 apresenta os resultados da aplicação das técnicas de interpolação nos exames do InsCer com o Método de Inserção de Cortes Artificiais no PR Segmentado. Da mesma forma, a Tabela 19 apresenta os resultados dos exames do *BrainWeb*.

Tabela 18 - Quantificação do volume válido nos exames do InsCer com o Método de Inserção de Cortes Artificiais no PR Segmentado

Exames	PE (ml)	PR (ml)	Interpolação	Quantificação original (ml)	Quantificação do volume sem os falsos positivos(ml)	Percentual de erro
Exame 1	15,046	0,994	Nearest-Neighbor	0,735	0,448	39%
			Area	0,843	0,492	42%
			Linear	1,026	0,580	43%
			Cubica	0,978	0,564	42%
			Lanczos	1,567	0,600	62%
Exame 2	2,377	0,255	Nearest-Neighbor	0,453	0,129	72%
			Area	0,506	0,129	75%
			Linear	0,675	0,132	80%
			Cubica	0,671	0,132	80%
			Lanczos	1,104	0,136	88%
Exame 3	31,332	1,61	Nearest-Neighbor	1,181	0,380	68%
			Area	1,392	0,466	67%
			Linear	1,801	0,585	68%
			Cubica	1,724	0,553	68%
			Lanczos	2,929	0,722	75%
Exame 4	22,624	3,595	Nearest-Neighbor	2,282	1,480	35%
			Area	2,996	1,757	41%
			Linear	3,734	2,070	45%
			Cubica	3,629	2,058	43%
			Lanczos	5,786	2,135	63%

Exames	PE (ml)	PR (ml)	Interpolação	Quantificação original (ml)	Quantificação do volume sem os falsos positivos(ml)	Percentual de erro
Exame 5	0,983	0,059	Nearest-Neighbor	0,035	0,003	91%
			Area	0,047	0,003	94%
			Linear	0,069	0,004	94%
			Cubica	0,070	0,004	94%
			Lanczos	0,137	0,006	96%
Exame 6	3,261	0,369	Nearest-Neighbor	0,238	0,007	97%
			Area	0,294	0,016	95%
			Linear	0,405	0,024	94%
			Cubica	0,391	0,024	94%
			Lanczos	0,712	0,024	97%
Exame 7	80,268	25,248	Nearest-Neighbor	27,005	13,219	51%
			Area	31,287	14,981	52%
			Linear	40,233	18,192	55%
			Cubica	36,841	17,046	54%
			Lanczos	48,620	17,847	63%
Exame 8	3,995	1,454	Nearest-Neighbor	1,048	0,348	67%
			Area	1,265	0,451	64%
			Linear	1,681	0,580	65%
			Cubica	1,580	0,573	64%
			Lanczos	2,889	0,613	79%
Exame 9	1,685	0,18	Nearest-Neighbor	0,138	0,016	88%
			Area	0,164	0,025	85%
			Linear	0,211	0,034	84%
			Cubica	0,199	0,034	83%
			Lanczos	0,347	0,034	90%
Exame 10	5,471	0,436	Nearest-Neighbor	0,327	0,070	79%
			Area	0,391	0,091	77%
			Linear	0,519	0,113	78%
			Cubica	0,508	0,107	79%
			Lanczos	0,889	0,113	87%
Média Total	16,704	3,420	-	4,691	2,003	72%

Tabela 19 - Quantificação do volume válido nos exames do *BrainWeb* com o Método de Inserção de Cortes Artificiais no PR Segmentado

Exames	PE (ml)	PR (ml)	Interpolação	Quantificação original (ml)	Quantificação do volume sem os falsos positivos (ml)	Percentual de erro
Exame 1	20,853	6,709	Nearest-Neighbor	18,714	12,410	34%
			Area	19,596	12,541	36%
			Linear	23,243	13,276	43%
			Cubica	22,981	13,174	43%
			Lanczos	35,337	13,292	62%

Exames	PE (ml)	PR (ml)	Interpolação	Quantificação original (ml)	Quantificação do volume sem os falsos positivos (ml)	Percentual de erro
Exame 2	19,537	6,373	Nearest-Neighbor	8,485	7,437	12%
			Area	9,643	8,344	13%
			Linear	13,318	10,805	19%
			Cubica	13,021	10,699	18%
			Lanczos	21,27	10,9	49%
Exame 3	17,087	5,12	Nearest-Neighbor	6,723	5,916	12%
			Area	7,668	6,671	13%
			Linear	10,752	8,734	19%
			Cubica	10,58	8,664	18%
			Lanczos	17,418	8,877	49%
Exame 4	7,016	1,622	Nearest-Neighbor	4,724	3,106	34%
			Area	5,116	3,160	38%
			Linear	5,973	3,354	44%
			Cubica	5,938	3,335	44%
			Lanczos	10,475	3,351	68%
Exame 5	6,204	1,457	Nearest-Neighbor	1,432	1,247	13%
			Area	1,806	1,527	15%
			Linear	3,074	2,314	25%
			Cubica	3,062	2,310	25%
			Lanczos	5,725	2,319	59%
Exame 6	5,374	0,829	Nearest-Neighbor	0,775	0,667	14%
			Area	0,994	0,817	18%
			Linear	1,743	1,236	29%
			Cubica	1,740	1,236	29%
			Lanczos	3,271	1,252	62%
Exame 7	0,855	0,124	Nearest-Neighbor	0,340	0,195	43%
			Area	0,373	0,225	40%
			Linear	0,466	0,245	47%
			Cubica	0,466	0,245	47%
			Lanczos	1,016	0,254	75%
Exame 8	0,611	0,117	Nearest-Neighbor	0,136	0,068	50%
			Area	0,164	0,095	42%
			Linear	0,248	0,145	42%
			Cubica	0,243	0,145	40%
			Lanczos	0,430	0,145	66%
Exame 9	0,403	0,055	Nearest-Neighbor	0,060	0,042	30%
			Area	0,075	0,057	24%
			Linear	0,120	0,091	24%
			Cubica	0,120	0,091	24%
			Lanczos	0,239	0,091	62%
Média total	8,660	2,490	-	6,647	4,113	36%

Com os resultados apresentados nas quintas colunas da Tabela 18 e da Tabela 19 constatou-se que a volumetria de lesões gerada ficou distante do PE. A Tabela 20 e a Tabela 21 ajudam a entender melhor esse problema. Essas tabelas contêm os percentuais correspondentes à relação entre o volume gerado por cada técnica e o volume do PE, além de conter o erro absoluto médio obtido a partir dos mesmos.

Tabela 20 - Comparação entre as abordagens para a aproximação do PE nos exames do InsCer

Interpolação	Exame	Relação com o PE utilizando a Interpolação FLAIR e T1	Relação com o PE utilizando a Interpolação Imagens Segmentadas	Relação com o PE utilizando o Método Inserção Imagens Segmentadas
Nearest-Neighbor	1	80%	7%	5%
	2	108%	29%	19%
	3	64%	6%	4%
	4	66%	16%	10%
	5	80%	8%	4%
	6	106%	13%	7%
	7	76%	51%	34%
	8	128%	43%	26%
	9	231%	13%	8%
	10	76%	10%	6%
	Média	102%	20%	12%
	Desvio Padrão	0,499	0,160	0,105
	Erro Absoluto Médio	33%	80%	88%
Área	1	81%	7%	6%
	2	92%	32%	21%
	3	76%	6%	4%
	4	66%	18%	13%
	5	70%	8%	5%
	6	131%	13%	9%
	7	74%	55%	39%
	8	146%	49%	32%
	9	246%	13%	10%
	10	98%	11%	7%
	Média	108%	21%	15%
	Desvio Padrão	0,553	0,179	0,122
	Erro Absoluto Médio	37%	79%	85%
Linear	1	133%	11%	7%
	2	152%	46%	28%
	3	84%	10%	6%
	4	99%	26%	17%
	5	50%	14%	7%
	6	86%	22%	12%

Interpolação	Exame	Relação com o PE utilizando a Interpolação FLAIR e T1	Relação com o PE utilizando a Interpolação Imagens Segmentadas	Relação com o PE utilizando o Método Inserção Imagens Segmentadas
	7	93%	71%	50%
	8	139%	74%	42%
	9	107%	21%	13%
	10	102%	17%	9%
	Média	105%	31%	19%
	Desvio Padrão	0,301	0,240	0,157
	Erro Absoluto Médio	22%	69%	81%
Cúbica	1	173%	10%	7%
	2	171%	45%	28%
	3	98%	9%	6%
	4	132%	25%	16%
	5	98%	14%	7%
	6	195%	21%	12%
	7	109%	62%	46%
	8	184%	70%	40%
	9	275%	20%	12%
	10	102%	15%	9%
	Média	154%	29%	18%
	Desvio Padrão	0,571	0,220	0,146
	Erro Absoluto Médio	55%	71%	82%
Lanzos	1	176%	18%	10%
	2	190%	81%	46%
	3	108%	16%	9%
	4	137%	44%	26%
	5	130%	28%	14%
	6	99%	40%	22%
	7	92%	97%	61%
	8	190%	130%	72%
	9	136%	35%	21%
	10	118%	29%	16%
	Média	138%	52%	30%
	Desvio Padrão	0,363	0,380	0,222
	Erro Absoluto Médio	39%	54%	70%

Tabela 21 - Comparação entre as abordagens para a aproximação do PE nos exames do *BrainWeb*

Interpolação	Exame	Relação com o PE utilizando a Interpolação FLAIR e T1	Relação com o PE utilizando a Interpolação Imagens Segmentadas	Relação com o PE utilizando o Método Inserção Imagens Segmentadas
Nearest-Neighbor	1	84%	66%	90%
	2	95%	67%	43%
	3	109%	62%	39%
	4	82%	46%	67%
	5	99%	47%	23%
	6	118%	30%	14%
	7	99%	31%	40%
	8	153%	41%	22%
	9	213%	30%	15%
	Média	117%	47%	39%
	Desvio Padrão	0,419	0,152	0,254
	Erro Absoluto Médio	26%	53%	61%
Área	1	87%	72%	94%
	2	98%	73%	49%
	3	113%	67%	45%
	4	85%	52%	73%
	5	103%	53%	29%
	6	122%	34%	18%
	7	93%	35%	44%
	8	145%	45%	27%
	9	217%	33%	19%
	Média	118%	52%	44%
	Desvio Padrão	0,416	0,162	0,254
	Erro Absoluto Médio	26%	48%	56%
Linear	1	106%	111%	111%
	2	115%	111%	68%
	3	130%	103%	63%
	4	98%	90%	85%
	5	115%	93%	50%
	6	138%	62%	32%
	7	91%	59%	55%
	8	125%	72%	41%
	9	176%	56%	30%
	Média	122%	84%	59%
	Desvio Padrão	0,253	0,223	0,261
	Erro Absoluto Médio	24%	21%	43%
Cúbica	1	111%	108%	110%
	2	118%	108%	67%
	3	132%	101%	62%

Interpolação	Exame	Relação com o PE utilizando a Interpolação FLAIR e T1	Relação com o PE utilizando a Interpolação Imagens Segmentadas	Relação com o PE utilizando o Método Inserção Imagens Segmentadas
	4	106%	90%	85%
	5	120%	92%	49%
	6	153%	61%	32%
	7	99%	59%	55%
	8	140%	70%	40%
	9	237%	56%	30%
	Média	135%	83%	59%
	Desvio Padrão	0,418	0,214	0,260
	Erro Absoluto Médio	35%	21%	43%
Lanzos	1	112%	195%	169%
	2	120%	194%	109%
	3	132%	183%	102%
	4	105%	174%	149%
	5	121%	180%	92%
	6	159%	121%	61%
	7	105%	115%	119%
	8	154%	130%	70%
	9	233%	111%	59%
	Média	138%	156%	103%
	Desvio Padrão	0,407	0,357	0,382
	Erro Absoluto Médio	38%	56%	30%

Com a comparação entre as abordagens utilizadas na Tabela 20 e na Tabela 21, pode-se ver que quando a abordagem de inserção de cortes artificiais no PR segmentado é utilizada, o erro absoluto médio é o maior em cada técnica de interpolação, com exceção da Interpolação Lanczos nos exames do *BrainWeb*. Isso significa que a estratégia apresentada nesta seção não está diminuindo somente a quantidade de falsos positivos, mas também está diminuindo a quantidade de lesões corretas. Com isto, aproximação da volumetria gerada com cada interpolação está mais distante do PE comparada às outras estratégias já apresentadas.

A Tabela 22 mostra a análise comparativa, para os exames do InsCer, do erro absoluto médio, em relação ao cálculo sem os falsos positivos, gerado pelas técnicas com as três abordagens utilizadas, a interpolação das imagens FLAIR e T1, a interpolação das imagens segmentadas e a interpolação das

imagens após a aplicação do Método de Inserção de Cortes Artificiais com o PR Segmentado. Da mesma forma a Tabela 23 compara as abordagens com os exames do *BrainWeb*.

Tabela 22 - Comparação do percentual de acerto entre as estratégias adotadas para os exames do InsCer

Interpolação	Exame	Percentual de Erro Interpolação FLAIR e T1	Percentual de Erro Interpolação Imagens Segmentadas	Percentual de Erro Método Inserção Imagens Segmentadas	
Nearest-Neighbor	1	54%	43%	39%	
	2	45%	81%	72%	
	3	48%	66%	68%	
	4	52%	48%	35%	
	5	67%	94%	91%	
	6	84%	94%	97%	
	7	40%	55%	51%	
	8	61%	68%	67%	
	9	90%	88%	88%	
	10	64%	81%	79%	
		Desvio Padrão	0,164	0,187	0,214
		Erro Absoluto Médio	61%	72%	69%
Área	1	55%	45%	42%	
	2	43%	82%	75%	
	3	49%	67%	67%	
	4	48%	48%	41%	
	5	62%	94%	94%	
	6	85%	95%	95%	
	7	40%	56%	52%	
	8	64%	68%	64%	
	9	91%	89%	85%	
	10	63%	78%	77%	
		Desvio Padrão	0,171	0,184	0,195
		Erro Absoluto Médio	60%	72%	69%
Linear	1	57%	55%	43%	
	2	57%	87%	80%	
	3	48%	70%	68%	
	4	40%	56%	45%	
	5	58%	96%	94%	
	6	87%	96%	94%	
	7	41%	63%	55%	
	8	66%	73%	65%	
	9	70%	88%	84%	
	10	79%	82%	78%	

Interpolação	Exame	Percentual de Erro Interpolação FLAIR e T1	Percentual de Erro Interpolação Imagens Segmentadas	Percentual de Erro Método Inserção Imagens Segmentadas
	Desvio Padrão	0,155	0,154	0,187
	Erro Absoluto Médio	60%	77%	71%
Cúbica	1	64%	54%	42%
	2	60%	87%	80%
	3	49%	70%	68%
	4	47%	55%	43%
	5	69%	96%	94%
	6	89%	96%	94%
	7	49%	60%	54%
	8	68%	72%	64%
	9	91%	87%	83%
	10	61%	81%	79%
	Desvio Padrão	0,154	0,161	0,191
	Erro Absoluto Médio	65%	76%	70%
Lanzos	1	65%	72%	62%
	2	63%	93%	88%
	3	56%	80%	75%
	4	49%	74%	63%
	5	74%	98%	96%
	6	89%	98%	97%
	7	43%	73%	63%
	8	68%	85%	79%
	9	77%	93%	90%
	10	71%	90%	87%
	Desvio Padrão	0,136	0,102	0,136
	Erro Absoluto Médio	66%	86%	80%

Tabela 23 - Comparação do percentual de acerto entre as estratégias adotadas para os exames do *BrainWeb*

Interpolação	Exame	Percentual de Erro Interpolação FLAIR e T1	Percentual de Erro Interpolação Imagens Segmentadas	Percentual de Erro Método Inserção Imagens Segmentadas
Nearest-Neighbor	1	24%	19%	34%
	2	27%	20%	12%
	3	33%	19%	12%
	4	34%	19%	34%
	5	38%	23%	13%
	6	46%	27%	14%
	7	38%	31%	43%
	8	62%	50%	50%

Interpolação	Exame	Percentual de Erro Interpolação FLAIR e T1	Percentual de Erro Interpolação Imagens Segmentadas	Percentual de Erro Método Inserção Imagens Segmentadas
	9	74%	36%	30%
	Desvio Padrão	0,166	0,104	0,145
	Erro Absoluto Médio	42%	27%	27%
Área	1	23%	22%	36%
	2	26%	22%	13%
	3	34%	22%	13%
	4	34%	24%	38%
	5	39%	27%	15%
	6	46%	31%	18%
	7	53%	29%	40%
	8	60%	45%	42%
	9	74%	32%	24%
	Desvio Padrão	0,167	0,075	0,122
	Erro Absoluto Médio	43%	28%	27%
Linear	1	29%	42%	43%
	2	31%	41%	19%
	3	38%	41%	19%
	4	39%	46%	44%
	5	42%	50%	25%
	6	50%	53%	29%
	7	46%	40%	47%
	8	61%	52%	42%
	9	68%	47%	24%
	Desvio Padrão	0,130	0,051	0,115
	Erro Absoluto Médio	45%	46%	32%
Cúbica	1	30%	40%	43%
	2	32%	40%	18%
	3	38%	40%	18%
	4	39%	46%	44%
	5	43%	50%	25%
	6	52%	53%	29%
	7	55%	40%	47%
	8	58%	50%	40%
	9	75%	47%	24%
	Desvio Padrão	0,145	0,053	0,116
	Erro Absoluto Médio	47%	45%	32%
Lanzos	1	31%	66%	62%
	2	33%	66%	49%
	3	39%	66%	49%

Interpolação	Exame	Percentual de Erro Interpolação FLAIR e T1	Percentual de Erro Interpolação Imagens Segmentadas	Percentual de Erro Método Inserção Imagens Segmentadas
	4	39%	72%	68%
	5	43%	74%	59%
	6	53%	76%	62%
	7	51%	69%	75%
	8	61%	73%	66%
	9	76%	73%	62%
	Desvio Padrão	0,145	0,038	0,084
	Erro Absoluto Médio	47%	71%	61%

Para os exames do InsCer, primeiro analisou-se a quinta coluna Tabela 22 para identificar qual foi a técnica de interpolação que obteve o menor erro médio dentre as que utilizaram o Método de Inserção de Cortes Artificiais no PR Segmentado. Os menores erros absolutos médios obtidos na primeira análise foram da Interpolação *Nearest-Neighbor* e da Interpolação por Área, ambos com 69%, sendo que o menor desvio padrão entre as duas foi da Interpolação por Área (0,195) contra 0,214 da Interpolação *Nearest-Neighbor*. O menor desvio padrão obtido com o método de inserção no PR segmentado foi 0,136 da Interpolação Lanczos que obteve um erro médio de 80%.

Na segunda análise, compararam-se as estratégias adotadas e constatou-se que o método de inserção no PR segmentado obteve um erro absoluto médio menor que a abordagem de interpolação das imagens segmentadas para todas as interpolações. Este método, entretanto, não conseguiu diminuir o erro gerado pelas interpolações quando estas são aplicadas com a primeira abordagem, que interpola as imagens FLAIR e T1.

Com isso percebe-se que a primeira metodologia ainda é a que gera o menor erro absoluto médio para todas as interpolações no cálculo da volumetria sem os falsos positivos.

Da mesma forma, para os exames do *BrainWeb*, analisou-se a quinta coluna da Tabela 23. Os menores erros absolutos médios dentre as técnicas que utilizaram o Método de Inserção de Cortes Artificiais no PR Segmentado foram da Interpolação *Nearest-Neighbor* e da Interpolação por Área, ambos

com 27%, sendo que o menor desvio padrão entre as duas foi da Interpolação por Área (0,122) contra 0,145 da Interpolação *Nearest-Neighbor*. O menor desvio padrão obtido com o método de inserção no PR segmentado foi 0,084 da Interpolação Lanczos que obteve um erro médio de 61%. Na segunda análise, compararam-se as estratégias adotadas e constatou-se que o método de inserção no PR segmentado obteve um erro absoluto médio menor que a segunda abordagem, que interpola as imagens segmentadas, para todas as interpolações com exceção da Interpolação *Nearest-Neighbor* em que tiveram um percentual igual (27%). Comparando o erro absoluto médio obtido pelas interpolações do método de inserção no PR segmentado com as interpolações da primeira estratégia, o erro médio da última abordagem foi menor em todas as técnicas com exceção da Interpolação Lanczos, que foi de 61% contra 47%.

De um modo geral, o Método de Inserção de Cortes Artificiais no PR Segmentado só conseguiu diminuir o erro médio na maioria das técnicas de interpolação aplicadas nos exames do *BrainWeb*. Para as imagens reais do InsCer a abordagem não funcionou.

Além disso, conforme foi mostrado na Tabela 20 e na Tabela 21, ao utilizar essa abordagem ocorreu uma perda significativa do volume total gerado, piorando a aproximação com a volumetria obtida com PE, em relação às outras duas abordagens.

Com isso, uma nova abordagem foi proposta para diminuir a quantidade de falsos positivos, conforme é apresentada na seção a seguir.

8.3 MÉTODO DE INSERÇÃO DE CORTES ARTIFICIAIS NO EXAME FLAIR DO PR

Embora o método apresentado na seção 8.2 tenha conseguido o objetivo de diminuir os falsos positivos de modo que o erro médio fosse diminuído em todas as interpolações nos exames *BrainWeb*, o método não funcionou da mesma forma para as imagens do InsCer. Conforme foi mostrado na seção 8.2.1, a abordagem ainda reduziu a volumetria das lesões a ponto de piorar a aproximação do PE em relação às outras abordagens apresentadas

nas seções 7.1 e 7.2. Por esta razão, buscou-se outra maneira para eliminar os falsos positivos, sem afetar a volumetria.

A alternativa escolhida foi utilizar as imagens FLAIR **antes de serem segmentadas pelo algoritmo de crescimento de lesão** da seção 3.4. Essa escolha se deu, pois no método anterior, ao criar um corte artificial que é inserido entre as imagens segmentadas, as únicas regiões que tinham a possibilidade de serem removidas neste corte eram áreas já classificadas como lesões no PR, conforme o método apresentado na seção 8.2. Os resultados da seção 8.2.1 mostram que essa ideia evitou a propagação dos falsos positivos para alguns casos, entretanto impediu que uma grande quantidade de lesões corretas fosse gerada, fazendo a volumetria ficar muito abaixo do PE.

Utilizando as imagens FLAIR, pretende-se que seja possível criar um corte artificial para ser inserido entre estas imagens, com a função de impedir que os falsos positivos sejam propagados na interpolação destas, mas que permita manter **todas** as áreas classificadas como lesões no PR, dentro deste corte artificial.

Em face desta abordagem, foram analisados os cortes gerados pela estratégia da seção 7.1 e os resultados da seção 7.1.2 de modo que fosse identificada a causa da geração dos falsos positivos nestas imagens.

Pela análise, percebeu-se que uma das causas dos falsos positivos na interpolação, acontecia quando as regiões da imagem FLAIR do PR que, apesar de hiperintensas, não eram consideradas lesões pelo algoritmo de crescimento de lesão. Estas mesmas áreas, ao serem interpoladas nas imagens FLAIR, ganhavam características que faziam com que passassem a ser consideradas lesões. A Figura 66 mostra um exemplo deste problema. Nesta figura, a região sinalizada pelo círculo mostra uma área hiperintensa que não era lesão antes da interpolação, mas passou a ser lesão após ter sido interpolada.

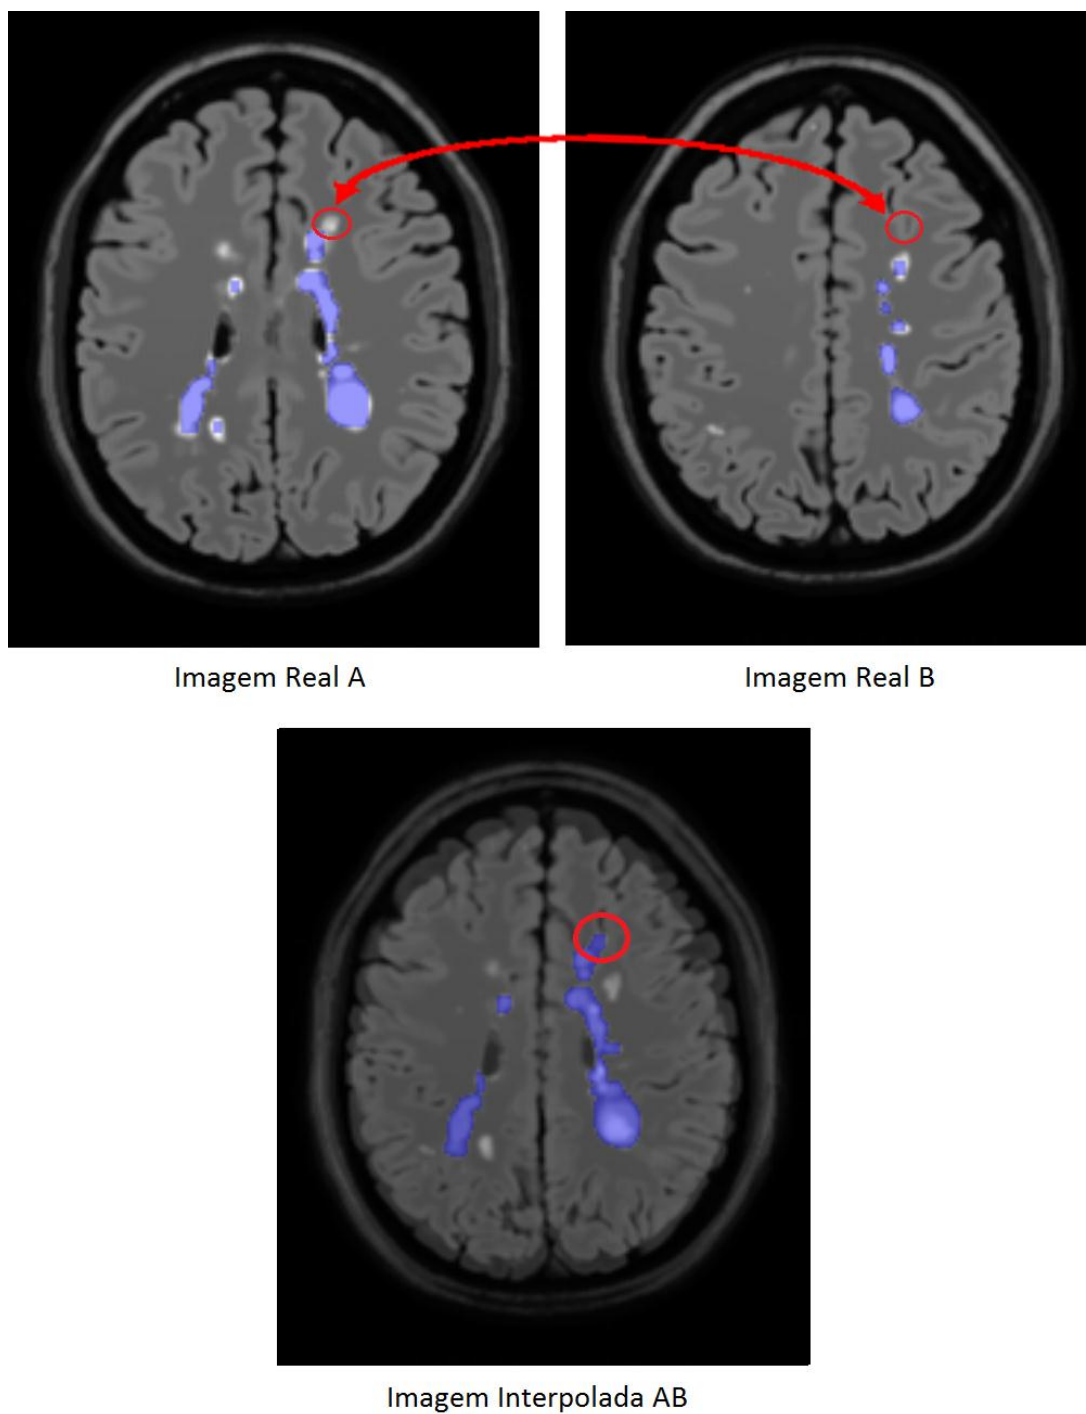


Figura 66 - Exemplo da Geração de um Falso Positivo na Imagem FLAIR

Fonte: O autor

A Figura 67 apresenta outra maneira de visualizar o que acontece na Figura 66. No caso, o corte real 2 do PR contém uma região hiperintensa que não é uma lesão, no entanto, as mesmas posições nos cortes interpolados se transformaram em lesões.




Figura 67 - Esquema do Problema de Geração das Falsos Positivos nas Imagens FLAIR

Fonte: O autor

Após as análises realizadas, decidiu-se que o método proposto utilizaria a ideia de inserir cortes artificiais no exame FLAIR do PR entre as imagens reais adjacentes, antes de aplicar a interpolação. Os cortes artificiais possuem as regiões hiperintensas, com chances de gerar falsos positivos, removidas.

Os cortes artificiais inseridos no exame FLAIR do PR resultam da interpolação linear entre cortes adjacentes, seguida da aplicação de uma máscara. Esta máscara remove da imagem artificial áreas que podem gerar falsos positivos conforme a análise realizada, como mostra o exemplo da Figura 68. A imagem AB é gerada com a interpolação linear entre os cortes reais A e B. Em seguida a imagem AB tem as regiões removidas, utilizando as posições das áreas brancas da máscara. Com isto, gera-se a imagem artificial AB que é a imagem inserida no exame FLAIR do PR.

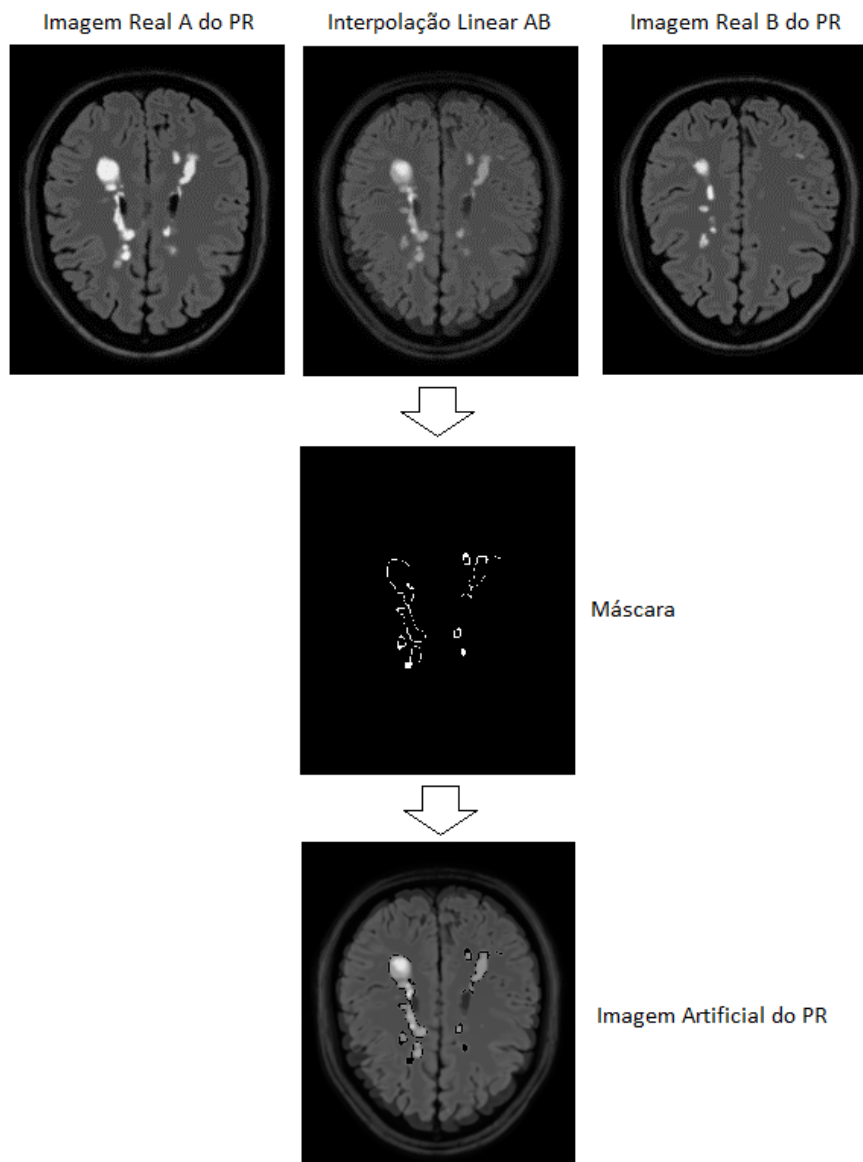


Figura 68 - Geração da Imagem Artificial no Método Proposto

Fonte: O autor

A primeira etapa para a construção da máscara é obter, para cada corte, uma imagem binária contendo as regiões hiperintensas das imagens FLAIR. Neste caso, são consideradas as regiões com tons de cinza maiores do que um valor L , que é usado no algoritmo de crescimento de leão como valor inicial para a determinação das lesões.

A seguir, é realizada uma operação lógica OR entre duas imagens binárias e adjacentes, para unir as regiões segmentadas em apenas uma imagem como mostra a Figura 69.



Figura 69 - União das Regiões Hiperintensas

Fonte: O autor

Além do conjunto de máscaras com todas as regiões hiperintensas é preciso determinar quais destas regiões são lesões. Para isso aplica-se sobre as imagens FLAIR e T1, do PR, o algoritmo de crescimento de lesão, gerando uma máscara que determina a posição dessas lesões. Nesse conjunto de imagens, contendo somente lesões, também é aplicada uma operação lógica OR para unir as imagens adjacentes duas a duas, conforme o exemplo da Figura 70.




Figura 70 - União das Lesões com a Operação OR

Fonte: O autor

Desta forma, passa-se a ter dois conjuntos de imagens, C_{HIPER} com todas as regiões hiperintensas e $C_{LESIONS}$, com todas as regiões consideradas como lesões.

A partir destes conjuntos, determinam-se as regiões hiperintensas que não são consideradas lesões através de uma subtração na forma mostrada na Equação 2. O resultado desta operação pode ser observado na Figura 71.

$C_{NOT_LESIONS} = C_{HIPER} - C_{LESIONS}$

Equação 2 - Operação para Remoção de Hiperintensidades que não são Lesões

$$C_NOT_LESIONS [A] = C_HIPER [A] - C_LESIONS [A]$$



Figura 71 - Geração da Máscara Final

Fonte: O autor

Este novo conjunto de imagens contém as máscaras finais utilizadas para remover aquelas regiões hiperintensivas que não são lesões, das imagens da sequência FLAIR geradas com a interpolação linear.

Isto é realizado por uma subtração, implementada através de uma operação OR seguida de uma operação XOR entre a imagem FLAIR interpolada e a máscara, como é apresentado na Figura 72.




Figura 72 - Geração das Imagens Artificiais do PR

Fonte: O autor

Após a aplicação deste algoritmo, obtém-se um novo conjunto de imagens FLAIR do PR, contendo imagens inseridas que foram geradas artificialmente sem as regiões hiperintensas que não devem ser consideradas lesões pelo algoritmo de crescimento de lesão. A Figura 73 apresenta um esquema de funcionamento do método sobre um conjunto de imagens.

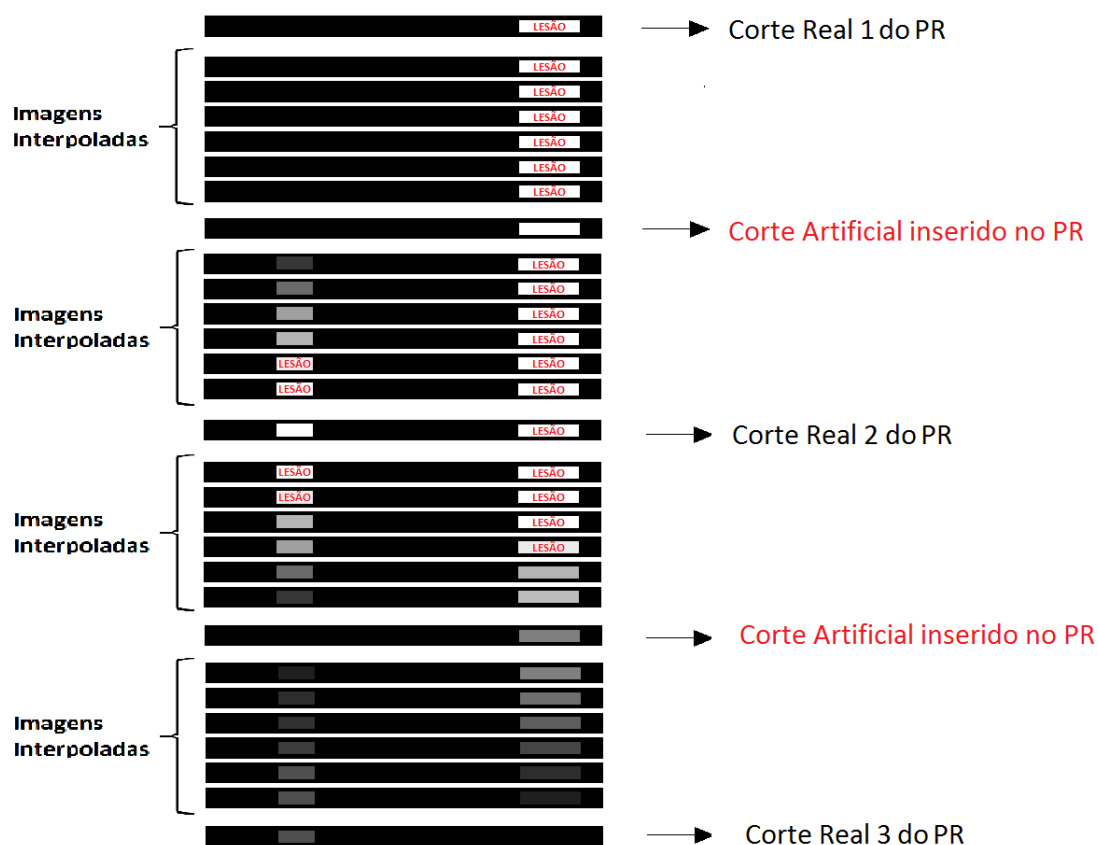


Figura 73 - Esquema do Modelo Proposto

Fonte: O autor

A partir disto, este novo exame FLAIR do PR com os cortes artificiais inseridos pode ser submetido aos métodos de interpolação para simular o PE. A Figura 74 mostra o resultado do algoritmo proposto aplicado à mesma imagem da Figura 66. Percebe-se que a área do círculo desta vez não se transformou em uma falsa lesão, a lesão marcada com o quadrado que havia crescido na interpolação entre os cortes reais não foi gerada com o método proposto. A Figura 75 apresenta o esquema geral do método de geração de cortes adicionais no PR.




Figura 74 - Resultado da Interpolação do PR com os Cortes Artificiais Inseridos no Exame FLAIR

Fonte: O autor

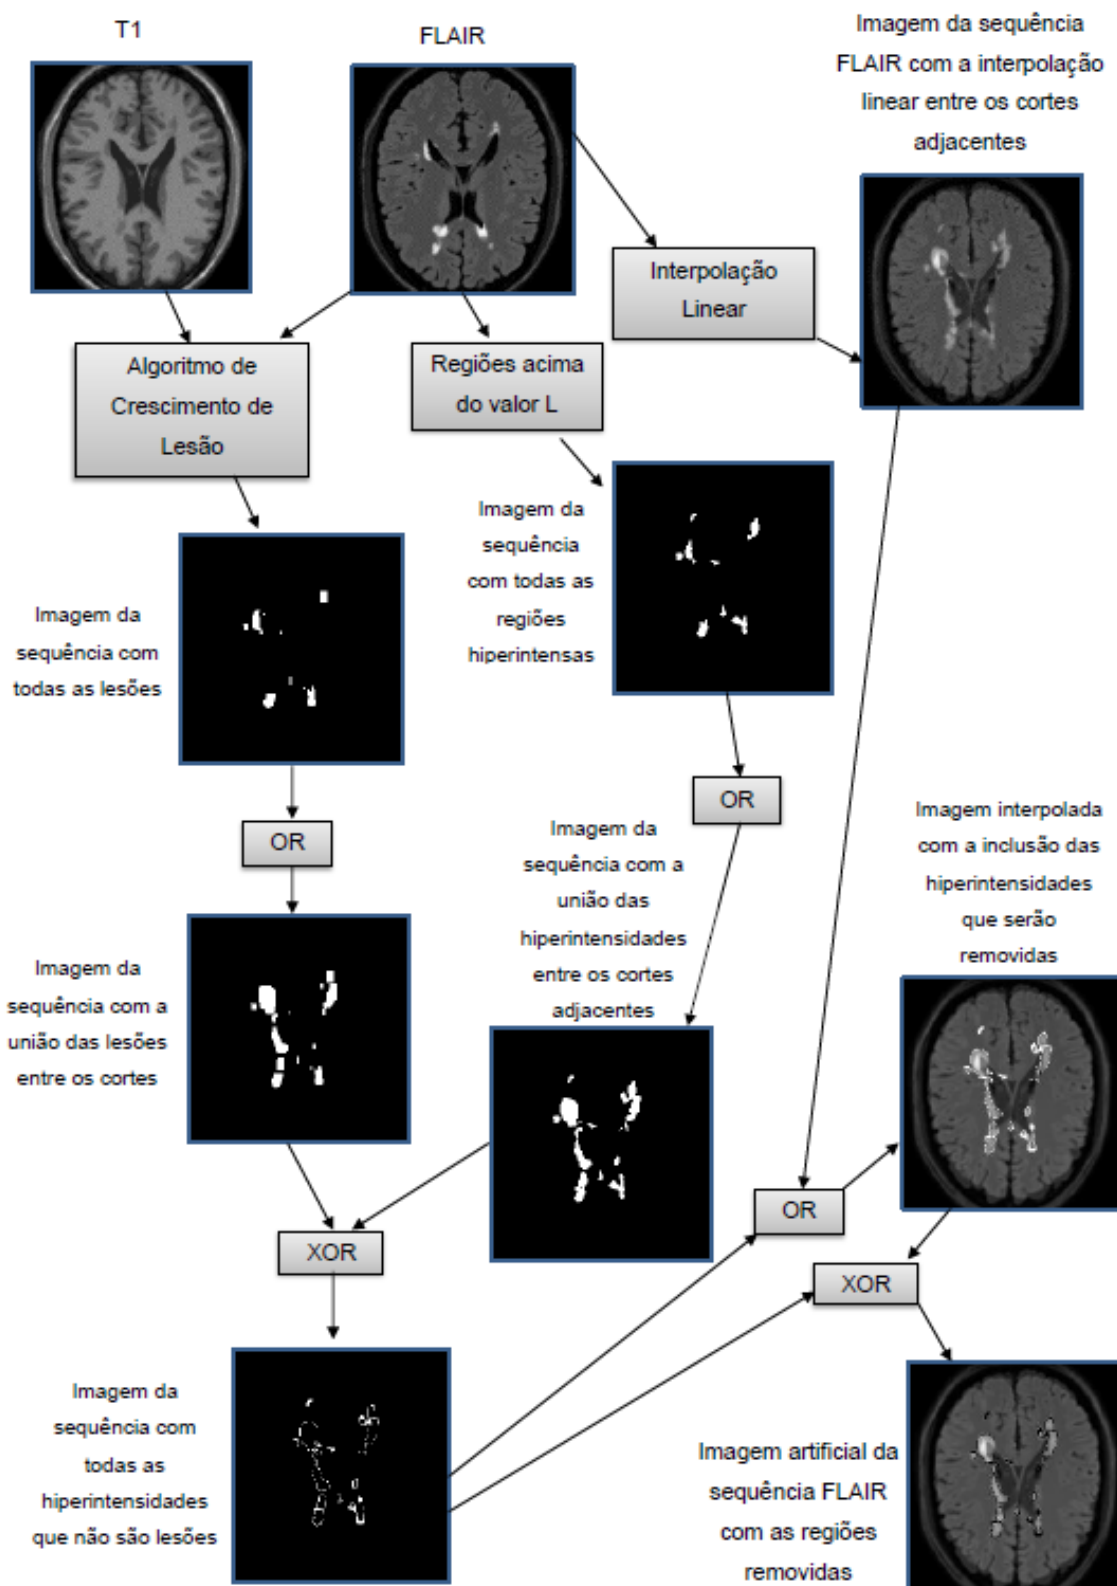


Figura 75 - Esquema Geral do Método da Geração de Cortes Artificiais no Exame FLAIR do PR

Fonte: O autor

Para a sequência T1 o método de geração de cortes artificiais ao PR não é aplicado, pois ao remover as lesões nessa sequência criaria mais lesões,

tendo em vista que elas aparecem como “black holes” nas imagens T1. Além disso, nem todas as lesões aparecem, portanto cortes artificiais com regiões removidas nas imagens T1 podem levar a uma perda de precisão quando esta sequência é utilizada pelo algoritmo de crescimento de lesão. Para a sequência T1 é aplicado apenas o mesmo método de interpolação utilizado na sequência FLAIR, antes de submeter as duas sequências para o algoritmo de crescimento de lesão.

8.3.1 RESULTADOS QUANTITATIVOS OBTIDOS COM O MÉTODO DE INSERÇÃO DE CORTES ARTIFICIAIS NO EXAME FLAIR DO PR

Com os novos exames do PR, gerados através do método apresentado na seção 8.3, foram aplicados os métodos de interpolação para gerar os novos exames FLAIR interpolados. Para estes exames foi calculada a volumetria das lesões de EM para analisar a quantidade de falsos positivos que o Método de Inserção de Cortes Artificiais no Exame FLAIR do PR conseguiu reduzir em cada técnica de interpolação através da avaliação do erro absoluto médio obtido pela relação entre o volume válido e volume total gerado.

Esta seção apresenta os resultados quantitativos e também uma comparação dos métodos de interpolação com as diferentes estratégias utilizadas para a geração de volume válido.

A Tabela 24 apresenta os resultados da aplicação das técnicas de interpolação nos exames do InsCer com o Método de Inserção de Cortes Artificiais no Exame FLAIR do PR. Da mesma forma, a Tabela 25 apresenta os resultados dos exames do *BrainWeb*.

Tabela 24 - Quantificação do volume válido nos exames do InsCer com o Método de Inserção de Cortes Artificiais no exame FLAIR do PR

Exames	PE (ml)	PR (ml)	Interpolação	Quantificação original (ml)	Quantificação do volume sem os falsos positivos (ml)	Percentual de erro
Exame 1	15,046	0,994	Nearest-Neighbor	7,485	4,099	45%
			Area	7,413	3,901	47%
			Linear	15,683	7,525	52%
			Cubica	17,615	7,99	55%
			Lanczos	17,615	8,038	54%
Exame 2	2,377	0,255	Nearest-	1,143	0,721	37%

Exames	PE (ml)	PR (ml)	Interpolação	Quantificação original (ml)	Quantificação do volume sem os falsos positivos (ml)	Percentual de erro
			Neighbor			
			Area	0,948	0,616	35%
			Linear	0,796	0,569	29%
			Cubica	0,956	0,623	35%
			Lanczos	1,342	0,755	44%
Exame 3	31,332	1,61	Nearest-Neighbor	18,442	9,22	50%
			Area	22,618	11,534	49%
			Linear	28,211	14,276	49%
			Cubica	29,381	14,848	49%
			Lanczos	31,164	13,663	56%
Exame 4	22,624	3,595	Nearest-Neighbor	10,508	5,42	48%
			Area	9,713	4,98	49%
			Linear	13,929	7,811	44%
			Cubica	18,79	9,583	49%
			Lanczos	19,668	9,911	50%
Exame 5	0,983	0,059	Nearest-Neighbor	0,302	0,137	55%
			Area	0,265	0,131	51%
			Linear	0,208	0,088	58%
			Cubica	0,258	0,109	58%
			Lanczos	0,541	0,2	63%
Exame 6	3,261	0,369	Nearest-Neighbor	2,676	0,48	82%
			Area	2,659	0,467	82%
			Linear	2,636	0,338	87%
			Cubica	4,564	0,609	87%
			Lanczos	3,676	0,45	88%
Exame 7	80,268	25,248	Nearest-Neighbor	42,679	25,598	40%
			Area	45,246	26,894	41%
			Linear	62,684	37,022	41%
			Cubica	69,822	35,937	49%
			Lanczos	56,175	32,536	42%
Exame 8	3,995	1,454	Nearest-Neighbor	4,799	1,813	62%
			Area	4,454	1,755	61%
			Linear	4,631	1,543	67%
			Cubica	4,693	1,722	63%
			Lanczos	5,104	1,958	62%
Exame 9	1,685	0,18	Nearest-Neighbor	1,03	0,159	85%
			Area	0,965	0,156	84%
			Linear	0,661	0,123	81%
			Cubica	0,908	0,144	84%
			Lanczos	0,696	0,099	86%
Exame 10	5,471	0,436	Nearest-Neighbor	3,292	1,431	57%
			Area	4,613	1,861	60%
			Linear	3,918	0,88	78%

Exames	PE (ml)	PR (ml)	Interpolação	Quantificação original (ml)	Quantificação do volume sem os falsos positivos (ml)	Percentual de erro
			Cubica	4,006	1,727	57%
			Lanczos	4,572	1,648	64%
Média Total	16,704	3,420	-	12,323	6,282	58%

Tabela 25 - Quantificação do volume válido nos exames do *BrainWeb* com o Método de Inserção de Cortes Artificiais no exame FLAIR do PR

Exames	PE (ml)	PR (ml)	Interpolação	Quantificação original (ml)	Quantificação do volume sem os falsos positivos (ml)	Percentual de erro
Exame 1	20,853	6,709	Nearest-Neighbor	17,288	13,193	24%
			Area	16,821	12,687	25%
			Linear	16,631	12,819	23%
			Cubica	17,317	13,387	23%
			Lanczos	17,315	13,261	23%
Exame 2	19,537	6,373	Nearest-Neighbor	17,472	13,127	25%
			Area	17,289	12,783	26%
			Linear	16,218	12,388	24%
			Cubica	16,682	12,631	24%
			Lanczos	16,808	12,652	25%
Exame 3	17,087	5,12	Nearest-Neighbor	16,488	11,62	30%
			Area	16,421	11,385	31%
			Linear	16,032	11,288	30%
			Cubica	16,381	11,458	30%
			Lanczos	16,389	11,416	30%
Exame 4	7,016	1,622	Nearest-Neighbor	4,934	3,256	34%
			Area	4,714	3,114	34%
			Linear	4,620	3,166	31%
			Cubica	4,970	3,363	32%
			Lanczos	5,152	3,445	33%
Exame 5	6,204	1,457	Nearest-Neighbor	5,237	3,289	37%
			Area	5,195	3,223	38%
			Linear	4,897	3,114	36%
			Cubica	5,142	3,266	36%
			Lanczos	5,230	3,286	37%
Exame 6	5,374	0,829	Nearest-Neighbor	2,557	0,803	69%
			Area	3,318	1,059	68%
			Linear	3,478	1,599	54%
			Cubica	4,149	1,585	62%
			Lanczos	4,227	1,564	63%
Exame 7	0,855	0,124	Nearest-Neighbor	0,497	0,255	49%
			Area	0,436	0,257	41%

Exames	PE (ml)	PR (ml)	Interpolação	Quantificação original (ml)	Quantificação do volume sem os falsos positivos (ml)	Percentual de erro
			Linear	0,330	0,210	36%
			Cubica	0,397	0,205	48%
			Lanczos	0,449	0,236	47%
Exame 8	0,611	0,117	Nearest-Neighbor	0,472	0,205	57%
			Area	0,435	0,201	54%
			Linear	0,766	0,302	61%
			Cubica	0,384	0,188	51%
			Lanczos	0,398	0,196	51%
Exame 9	0,403	0,055	Nearest-Neighbor	0,420	0,151	64%
			Area	0,459	0,164	64%
			Linear	0,273	0,148	46%
			Cubica	0,357	0,155	57%
			Lanczos	0,381	0,146	62%
Média total	8,660	2,490	-	7,241	5,072	41%

A quinta coluna da Tabela 24 e da Tabela 25 permitem observar a quantidade total da volumetria de lesões gerada para analisar a quantidade perdida por cada método de interpolação ao utilizar a estratégia de inserção no exame FLAIR do PR.

Para melhorar a análise, a Tabela 26 e a Tabela 27 apresentam a comparação entre as abordagens utilizadas, mostrando os percentuais correspondentes à relação entre o volume gerado com cada técnica e o volume do PE, assim como o erro absoluto obtido em cada interpolação.

Tabela 26 - Comparação entre as abordagens para a aproximação do PE nos exames do InsCer

Interpolação	Exame	Relação com o PE utilizando a Interpolação FLAIR e T1	Relação com o PE utilizando a Interpolação Imagens Segmentadas	Relação com o PE utilizando o Método Inserção Imagens Segmentadas	Relação com o PE utilizando o Método Inserção Exame FLAIR
Nearest-Neighbor	1	80%	7%	5%	50%
	2	108%	29%	19%	48%
	3	64%	6%	4%	59%
	4	66%	16%	10%	46%
	5	80%	8%	4%	31%
	6	106%	13%	7%	82%
	7	76%	51%	34%	53%
	8	128%	43%	26%	120%
	9	231%	13%	8%	61%

Interpolação	Exame	Relação com o PE utilizando a Interpolação FLAIR e T1	Relação com o PE utilizando a Interpolação Imagens Segmentadas	Relação com o PE utilizando o Método Inserção Imagens Segmentadas	Relação com o PE utilizando o Método Inserção Exame FLAIR
	10	76%	10%	6%	60%
	Média	102%	20%	12%	61%
	Desvio Padrão	0,499	0,160	0,105	0,245
	Erro Absoluto Médio	33%	80%	88%	43%
Área	1	81%	7%	6%	49%
	2	92%	32%	21%	40%
	3	76%	6%	4%	72%
	4	66%	18%	13%	43%
	5	70%	8%	5%	27%
	6	131%	13%	9%	82%
	7	74%	55%	39%	56%
	8	146%	49%	32%	111%
	9	246%	13%	10%	57%
	10	98%	11%	7%	84%
	Média	108%	21%	15%	62%
	Desvio Padrão	0,553	0,179	0,122	0,251
	Erro Absoluto Médio	37%	79%	85%	40%
Linear	1	133%	11%	7%	104%
	2	152%	46%	28%	33%
	3	84%	10%	6%	90%
	4	99%	26%	17%	62%
	5	50%	14%	7%	21%
	6	86%	22%	12%	81%
	7	93%	71%	50%	78%
	8	139%	74%	42%	116%
	9	107%	21%	13%	39%
	10	102%	17%	9%	72%
	Média	105%	31%	19%	70%
	Desvio Padrão	0,301	0,240	0,157	0,310
	Erro Absoluto Médio	22%	69%	81%	34%
Cúbica	1	173%	10%	7%	117%
	2	171%	45%	28%	40%
	3	98%	9%	6%	94%
	4	132%	25%	16%	83%
	5	98%	14%	7%	26%
	6	195%	21%	12%	140%
	7	109%	62%	46%	87%
	8	184%	70%	40%	117%
	9	275%	20%	12%	54%

Interpolação	Exame	Relação com o PE utilizando a Interpolação FLAIR e T1	Relação com o PE utilizando a Interpolação Imagens Segmentadas	Relação com o PE utilizando o Método Inserção Imagens Segmentadas	Relação com o PE utilizando o Método Inserção Exame FLAIR
	10	102%	15%	9%	73%
	Média	154%	29%	18%	83%
	Desvio Padrão	0,571	0,220	0,146	0,361
	Erro Absoluto Médio	55%	71%	82%	32%
Lanzos	1	176%	18%	10%	117%
	2	190%	81%	46%	56%
	3	108%	16%	9%	99%
	4	137%	44%	26%	87%
	5	130%	28%	14%	55%
	6	99%	40%	22%	113%
	7	92%	97%	61%	70%
	8	190%	130%	72%	128%
	9	136%	35%	21%	41%
	10	118%	29%	16%	84%
	Média	138%	52%	30%	85%
	Desvio Padrão	0,363	0,380	0,222	0,294
	Erro Absoluto Médio	39%	54%	70%	27%

Tabela 27 - Comparação entre as abordagens para a aproximação do PE nos exames do *BrainWeb*

Interpolação	Exame	Relação com o PE utilizando a Interpolação FLAIR e T1	Relação com o PE utilizando a Interpolação Imagens Segmentadas	Relação com o PE utilizando o Método Inserção Imagens Segmentadas	Relação com o PE utilizando o Método Inserção Exame FLAIR
Nearest-Neighbor	1	84%	66%	90%	83%
	2	95%	67%	43%	89%
	3	109%	62%	39%	96%
	4	82%	46%	67%	70%
	5	99%	47%	23%	84%
	6	118%	30%	14%	48%
	7	99%	31%	40%	58%
	8	153%	41%	22%	77%
	9	213%	30%	15%	104%
	Média	117%	47%	39%	79%
	Desvio Padrão	0,419	0,152	0,254	0,178
	Erro Médio	26%	53%	61%	22%

Interpolação	Exame	Relação com o PE utilizando a Interpolação FLAIR e T1	Relação com o PE utilizando a Interpolação Imagens Segmentadas	Relação com o PE utilizando o Método Inserção Imagens Segmentadas	Relação com o PE utilizando o Método Inserção Exame FLAIR
Área	1	87%	72%	94%	81%
	2	98%	73%	49%	88%
	3	113%	67%	45%	96%
	4	85%	52%	73%	67%
	5	103%	53%	29%	84%
	6	122%	34%	18%	62%
	7	93%	35%	44%	51%
	8	145%	45%	27%	71%
	9	217%	33%	19%	114%
	Média	118%	52%	44%	79%
	Desvio Padrão	0,416	0,162	0,254	0,191
Erro Médio	26%	48%	56%	24%	
Linear	1	106%	111%	111%	80%
	2	115%	111%	68%	83%
	3	130%	103%	63%	94%
	4	98%	90%	85%	66%
	5	115%	93%	50%	79%
	6	138%	62%	32%	65%
	7	91%	59%	55%	39%
	8	125%	72%	41%	125%
	9	176%	56%	30%	68%
	Média	122%	84%	59%	78%
	Desvio Padrão	0,253	0,223	0,261	0,235
Erro Médio	24%	21%	43%	28%	
Cúbica	1	111%	108%	110%	83%
	2	118%	108%	67%	85%
	3	132%	101%	62%	96%
	4	106%	90%	85%	71%
	5	120%	92%	49%	83%
	6	153%	61%	32%	77%
	7	99%	59%	55%	46%
	8	140%	70%	40%	63%
	9	237%	56%	30%	89%
	Média	135%	83%	59%	77%
	Desvio Padrão	0,418	0,214	0,260	0,151
Erro Médio	35%	21%	43%	23%	
Lanzos	1	112%	195%	169%	83%
	2	120%	194%	109%	86%
	3	132%	183%	102%	96%

Interpolação	Exame	Relação com o PE utilizando a Interpolação FLAIR e T1	Relação com o PE utilizando a Interpolação Imagens Segmentadas	Relação com o PE utilizando o Método Inserção Imagens Segmentadas	Relação com o PE utilizando o Método Inserção Exame FLAIR
	4	105%	174%	149%	73%
	5	121%	180%	92%	84%
	6	159%	121%	61%	79%
	7	105%	115%	119%	53%
	8	154%	130%	70%	65%
	9	233%	111%	59%	95%
	Média	138%	156%	103%	79%
Desvio Padrão	0,407	0,357	0,382	0,139	
Erro Médio	38%	56%	30%	21%	

Com a comparação entre as abordagens utilizadas na Tabela 26 e na Tabela 27, pode-se observar que quando a abordagem de inserção de cortes artificiais no exame FLAIR do PR é utilizada nos exames do InsCer, o erro médio é menor do que a segunda e a terceira abordagens para cada técnica de interpolação.

Com relação à primeira estratégia, o erro médio do método de inserção no exame FLAIR do PR foi menor também para a Interpolação Cúbica e para a Interpolação Lanczos. Mesmo que a primeira estratégia ainda possua o menor erro médio menor no restante das interpolações, a maior diferença foi de apenas 12% para a Interpolação Linear. Nos exames do *BrainWeb* a única interpolação da primeira abordagem que teve um erro menor que foi a Interpolação Linear (diferença de 4%).

A Tabela 28 mostra a análise comparativa, para os exames do InsCer, do erro absoluto médio obtido pelos percentuais de acerto, que consideram a volumetria sem os falsos positivos. Da mesma forma a Tabela 29 compara as estratégias com os exames do *BrainWeb*.

Tabela 28 - Comparação do percentual de acerto entre as estratégias adotadas para os exames do InsCer

Interpolação	Exame	Percentual de Acerto Interpolação FLAIR e T1	Percentual de Acerto Interpolação Imagens Segmentadas	Percentual de Acerto Método Inserção Imagens Segmentadas	Percentual de Erro Método Inserção Exame FLAIR	
Nearest-Neighbor	1	54%	43%	39%	45%	
	2	45%	81%	72%	37%	
	3	48%	66%	68%	50%	
	4	52%	48%	35%	48%	
	5	67%	94%	91%	55%	
	6	84%	94%	97%	82%	
	7	40%	55%	51%	40%	
	8	61%	68%	67%	62%	
	9	90%	88%	88%	85%	
	10	64%	81%	79%	57%	
		Desvio Padrão	0,164	0,187	0,214	0,162
		Erro Médio	61%	72%	69%	56%
Área	1	55%	45%	42%	47%	
	2	43%	82%	75%	35%	
	3	49%	67%	67%	49%	
	4	48%	48%	41%	49%	
	5	62%	94%	94%	51%	
	6	85%	95%	95%	82%	
	7	40%	56%	52%	41%	
	8	64%	68%	64%	61%	
	9	91%	89%	85%	84%	
	10	63%	78%	77%	60%	
		Desvio Padrão	0,171	0,184	0,195	0,163
		Erro Médio	60%	72%	69%	56%
Linear	1	57%	55%	43%	52%	
	2	57%	87%	80%	29%	
	3	48%	70%	68%	49%	
	4	40%	56%	45%	44%	
	5	58%	96%	94%	58%	
	6	87%	96%	94%	87%	
	7	41%	63%	55%	41%	
	8	66%	73%	65%	67%	
	9	70%	88%	84%	81%	
	10	79%	82%	78%	78%	
		Desvio Padrão	0,155	0,154	0,187	0,192
		Erro Médio	60%	77%	71%	59%
Cúbica	1	64%	54%	42%	55%	
	2	60%	87%	80%	35%	
	3	49%	70%	68%	49%	
	4	47%	55%	43%	49%	

Interpolação	Exame	Percentual de Acerto Interpolação FLAIR e T1	Percentual de Acerto Interpolação Imagens Segmentadas	Percentual de Acerto Método Inserção Imagens Segmentadas	Percentual de Erro Método Inserção Exame FLAIR
	5	69%	96%	94%	58%
	6	89%	96%	94%	87%
	7	49%	60%	54%	49%
	8	68%	72%	64%	63%
	9	91%	87%	83%	84%
	10	61%	81%	79%	57%
	Desvio Padrão	0,154	0,161	0,191	0,161
Erro Médio	65%	76%	70%	59%	
Lanzos	1	65%	72%	62%	54%
	2	63%	93%	88%	44%
	3	56%	80%	75%	56%
	4	49%	74%	63%	50%
	5	74%	98%	96%	63%
	6	89%	98%	97%	88%
	7	43%	73%	63%	42%
	8	68%	85%	79%	62%
	9	77%	93%	90%	86%
	10	71%	90%	87%	64%
	Desvio Padrão	0,136	0,102	0,136	0,156
	Erro Médio	66%	86%	80%	62%

Tabela 29 - Comparação do percentual de acerto entre as estratégias adotadas para os exames do *BrainWeb*

Interpolação	Exame	Percentual de Erro Interpolação FLAIR e T1	Percentual de Erro Interpolação Imagens Segmentadas	Percentual de Erro Método Inserção Imagens Segmentadas	Percentual de Erro Método Inserção Exame FLAIR
Nearest-Neighbor	1	24%	19%	34%	24%
	2	27%	20%	12%	25%
	3	33%	19%	12%	30%
	4	34%	19%	34%	34%
	5	38%	23%	13%	37%
	6	46%	27%	14%	69%
	7	38%	31%	43%	49%
	8	62%	50%	50%	57%
	9	74%	36%	30%	64%
	Desvio Padrão	0,166	0,104	0,145	0,170
Erro Médio	42%	27%	27%	43%	
Área	1	23%	22%	36%	25%

Interpolação	Exame	Percentual de Erro Interpolação FLAIR e T1	Percentual de Erro Interpolação Imagens Segmentadas	Percentual de Erro Método Inserção Imagens Segmentadas	Percentual de Erro Método Inserção Exame FLAIR
	2	26%	22%	13%	26%
	3	34%	22%	13%	31%
	4	34%	24%	38%	34%
	5	39%	27%	15%	38%
	6	46%	31%	18%	68%
	7	53%	29%	40%	41%
	8	60%	45%	42%	54%
	9	74%	32%	24%	64%
	Desvio Padrão	0,167	0,075	0,122	0,161
	Erro Médio	43%	28%	27%	42%
Linear	1	29%	42%	43%	23%
	2	31%	41%	19%	24%
	3	38%	41%	19%	30%
	4	39%	46%	44%	31%
	5	42%	50%	25%	36%
	6	50%	53%	29%	54%
	7	46%	40%	47%	36%
	8	61%	52%	42%	61%
	9	68%	47%	24%	46%
	Desvio Padrão	0,130	0,051	0,115	0,131
Erro Médio	45%	46%	32%	38%	
Cúbica	1	30%	40%	43%	23%
	2	32%	40%	18%	24%
	3	38%	40%	18%	30%
	4	39%	46%	44%	32%
	5	43%	50%	25%	36%
	6	52%	53%	29%	62%
	7	55%	40%	47%	48%
	8	58%	50%	40%	51%
	9	75%	47%	24%	57%
	Desvio Padrão	0,145	0,053	0,116	0,144
Erro Médio	47%	45%	32%	40%	
Lanzos	1	31%	66%	62%	23%
	2	33%	66%	49%	25%
	3	39%	66%	49%	30%
	4	39%	72%	68%	33%
	5	43%	74%	59%	37%
	6	53%	76%	62%	63%
	7	51%	69%	75%	47%
	8	61%	73%	66%	51%
	9	76%	73%	62%	62%
	Desvio Padrão	0,145	0,038	0,084	0,150

Interpolação	Exame	Percentual de Erro Interpolação FLAIR e T1	Percentual de Erro Interpolação Imagens Segmentadas	Percentual de Erro Método Inserção Imagens Segmentadas	Percentual de Erro Método Inserção Exame FLAIR
	Erro Médio	47%	71%	61%	41%

Para os exames do InsCer, primeiro analisou-se a sexta coluna Tabela 28 para identificar qual foi a técnica de interpolação que obteve o menor erro médio dentre as que utilizaram o Método de Inserção de Cortes Artificiais no Exame FLAIR do PR. Os menores erros médios obtidos na primeira análise foram da Interpolação *Nearest-Neighbor* e da Interpolação por Área, ambos com 56%, sendo que o menor desvio padrão entre as duas foi da Interpolação *Nearest-Neighbor* (0,162) contra 0,163 da Interpolação *Area*. O menor desvio padrão obtido com o Método de Inserção no PR Segmentado foi 0,156 da Interpolação Lanczos que obteve um erro médio de 62%.

Na segunda análise, compararam-se as abordagens adotadas e constatou-se que o **Método de Inserção de Cortes Artificiais no Exame FLAIR do PR** obteve um erro absoluto médio menor do que todas as abordagens testadas, para todas as técnicas de interpolações.

Da mesma forma, para os exames do *BrainWeb*, analisou-se a sexta coluna da Tabela 29. O menor erro médio dentre as técnicas que utilizaram a estratégia de inserção de cortes artificiais no exame FLAIR do PR foi da Interpolação Linear (38%), assim como foi o menor desvio padrão obtido (0,131). Na segunda análise, compararam-se as abordagens adotadas e constatou-se que o Método de Inserção no Exame FLAIR do PR obteve um erro médio menor do que todas as técnicas de interpolação da primeira abordagem, que interpola os exames FLAIR e T1, com exceção da Interpolação *Nearest-Neighbor*, no entanto, a diferença para essa última foi de apenas 1%. Comparando com a segunda estratégia, o Método de Inserção no Exame FLAIR do PR teve um erro médio menor na Interpolação Linear, 38% contra 46%, e na Interpolação Lanczos, 41% contra 71%. Comparando com o Método de Inserção no PR Segmentado, o Método de Inserção no Exame

FLAIR do PR só obteve um erro médio menor na Interpolação Lanczos, 41% contra 61%.

Como nas seções anteriores foi concluído que a segunda e a terceira estratégia possuíam um desempenho inferior em relação à primeira, O Método de Inserção de Cortes Artificiais no Exame FLAIR do PR foi comparado apenas com a primeira abordagem,. Assim, de um modo geral, percebe-se que o Método de Inserção de Cortes Artificiais no Exame FLAIR do PR conseguiu diminuir o erro médio que considera apenas o volume válido, portanto diminuiu a quantidade de falsos positivos geradas em cada método de interpolação.

9 CONSIDERAÇÕES FINAIS

A quantificação do volume de lesões com exames do PR é uma alternativa desejável do ponto de vista clínico, pois é um exame mais barato e rápido que o PE. No entanto, a precisão da volumetria obtida com o PR é muito inferior ao PE.

Em face disto, este trabalho desenvolveu algumas estratégias visando interpolar imagens reais de modo que fossem geradas imagens artificiais capazes de reproduzir as lesões contidas nos exames do PE.

Foram apresentadas e comparadas quatro estratégias: Interpolação das Imagens FLAIR e T1, Interpolação das Imagens Segmentadas, Método de Inserção de Cortes Artificiais no PR Segmentado e o Método de Inserção de Cortes Artificiais no Exame FLAIR do PR. Para cada uma dessas abordagens foram utilizadas cinco técnicas de interpolação para simular o exame do PE, a Interpolação *Nearest-Neighbor*, a Interpolação por Área, a Interpolação Linear, a Interpolação Cúbica e a Interpolação Lanczos, permitindo avaliar com qual estratégia as técnicas de interpolação obtêm o melhor desempenho.

O desempenho foi avaliado através do menor erro médio causado pelos métodos em dois critérios: volumetria total com a melhor aproximação da quantificação obtida com o PE e a melhor volumetria quantificada sem os falsos positivos.

Conforme os resultados apresentados, concluiu-se que a Interpolação das Imagens Segmentadas e o Método de Inserção de Cortes Artificiais no PR Segmentado não conseguiram melhorar o desempenho das técnicas de interpolação, apresentadas na primeira abordagem, nos dois critérios avaliados.

A primeira estratégia, que aplica as técnicas de interpolação tradicionais nas imagens FLAIR e T1, obteve o menor erro absoluto médio com relação a aproximação da volumetria do PE nos exames do InsCer para a Interpolação *Nearest-Neighbor*, para Interpolação por Área e para a Interpolação Linear, quando comparada com o Método de Inserção de Cortes Artificiais no Exame FLAIR do PR.

Na mesma comparação, para os exames do *BrainWeb*, a única técnica da primeira estratégia que obteve o menor erro médio foi a Interpolação Linear. Entretanto, para todas essas interpolações a diferença entre os erros médios foram pequenas, sendo que a maior foi 12% com a Interpolação Linear nos exames do InsCer.

Em todas as demais técnicas, o Método de Inserção de Cortes Artificiais do Exame FLAIR do PR obteve o menor erro absoluto médio. Isso significa que este método, ao tentar diminuir a quantidade de falsos positivos, não causou uma perda significativa do volume total, como as técnicas que utilizaram as imagens segmentadas, sendo que em alguns casos o erro diminuiu.

Para o segundo critério, que considera a relação entre a volumetria sem os falsos positivos e a volumetria total gerada, o Método de Inserção de Cortes Artificiais no Exame FLAIR do PR obteve um erro médio menor para todas as técnicas de interpolações nos exames do InsCer. Para os exames do *BrainWeb*, o erro médio foi menor em todas as técnicas de interpolação, com exceção da Interpolação *Nearest-Neighbor*, sendo que para esta a diferença foi de apenas 1%.

Desta análise percebeu-se que o Método de Inserção de Cortes Artificiais no Exame FLAIR do PR diminuiu erro causado pelas técnicas de interpolação tradicionais, que foram aplicadas na primeira estratégia, ao diminuir a quantidade de falsos positivos.

Sendo assim, o Método de Inserção de Cortes Artificiais no Exame FLAIR do PR mostrou evidências de que pode melhorar a precisão das técnicas tradicionais de interpolação ao buscar simular a quantificação da volumetria de lesões obtida com o exame do PE, diminuindo a quantidade de falsos positivos sem causar uma perda significativa no volume total.

A confirmação dessa evidência, entretanto requer, como trabalho futuro, a aplicação dos testes em uma amostra maior de exames com EM.

10 REFERÊNCIAS

- Abbott, N., Ronnback, L., & Hansson, E. (2006). Astrocyte-endothelial interactions at the blood-brain barrier. *Nature Reviews Neuroscience*, 7(1), 41-53.
- Ait-Ali, L. S., Prima, S., Hellier, P., Carsin, B., Edan, G., & Barillot, C. (2005). STREM: a robust multidimensional parametric method to segment MS lesions in MRI. In: *Medical Image Computing and Computer-Assisted Intervention--MICCAI 2005* (pp. 409-416). Springer.
- Alastair Compston, A. C. (2002). Multiple sclerosis. In: A. C. Alastair Compston, *The Lancet* (pp. 1221-1231). Cambridge: The Lancet.
- Anitha, M., Selvy, P., & Palanisamy, V. (s.d.). Automated Detection Of White Matter Lesions In MRI Brain Images Using Spatio-Fuzzy And Spatio-Possibilistic Clustering Models.
- Atoui, H., Miguet, S., Sarrut, D., & others. (2006). A fast morphing-based interpolation for medical images: application to conformal radiotherapy. *Image Anal Stereol*, 25(2), 95-103.
- Bay, H., Ess, A., Tuytelaars, T., & Van Gool, L. (2008). Speeded-up robust features (SURF). *Computer vision and image understanding*, 110(3), 346-359.
- Bay, H., Tuytelaars, T., & Van Gool, L. (2006). Surf: Speeded up robust features. In: *Computer Vision--ECCV 2006* (pp. 404-417). Springer.
- Bazin, P., & Pham, D. (2008). Homeomorphic brain image segmentation with topological and statistical atlases. *Medical image analysis*, 12(5), 616.
- Borman, S. (2009). The Expectation Maximization Algorithm-A short tutorial. *The Expectation Maximization Algorithm-A short tutorial*.
- Boydev, C., Pasquier, D., Derraz, F., Peyrodie, L., Taleb-Ahmed, A., & Thiran, J. (10 de 2012). Shape-based Interpolation of a Set of 2D Slices.
- Bradski, G., & Kaehler, A. (2008). *Learning OpenCV: Computer vision with the OpenCV library*. O'reilly.

- Burger, W., & Burge, M. J. (2009). *Principles of digital image processing: core algorithms* (Vol. 2). Springer.
- Camargo, A. C., & Santos, L. T. (2006). Reamostragem uniforme utilizando a função SINC.
- Catmull, E., & Rom, R. (1974). A class of local interpolating splines. *Computer aided geometric design*, 74, 317-326.
- Cocosco, C. A., Kollokian, V., Kwan, R. K.-S., Pike, G. B., & Evans, A. C. (1997). Brainweb: Online interface to a 3D MRI simulated brain database. *NeuroImage*.
- Collins, D. L., Zijdenbos, A. P., Kollokian, V., Sled, J. G., Kabani, N. J., Holmes, C. J., et al. (1998). Design and construction of a realistic digital brain phantom. *Medical Imaging, IEEE Transactions on*, 17(3), 463-468.
- Cuadra, M., Cammoun, L., Butz, T., Cuisenaire, O., & Thiran, J. (2005). Comparison and validation of tissue modelization and statistical classification methods in T1-weighted MR brain images. *Medical Imaging, IEEE Transactions on*, 24(12), 1548-1565.
- da Silva, B. C. (1994). Deformação e metamorfose de imagens digitais.
- Danielsson, P.-E. (1980). Euclidean distance mapping. *Computer Graphics and image processing*, 14(3), 227-248.
- Delaunay, B. (1934). {Sur la sphère vide}. *Izvestia Akademii Nauk SSSR, Otdelenie Matematicheskikh i Estestvennykh Nauk*, 6, 793-800.
- D'Haese, P.-F., Cetinkaya, E., Konrad, P. E., Kao, C., & Dawant, B. M. (2005). Computer-aided placement of deep brain stimulators: from planning to intraoperative guidance. *Medical Imaging, IEEE Transactions on*, 24(11), 1469-1478.
- Dougherty, G. (2009). *Digital image processing for medical applications* (Vol. 1). Cambridge University Press New York.
- Evans, C. A.-S. (1997). *BrainWeb: Simulated Brain Database*. Acesso em 28 de 05 de 2013, disponível em BrainWeb: Simulated Brain Database: <http://www.bic.mni.mcgill.ca/brainweb/>

- Ferraz, E. G. (2009). *Efeito do Processamento de Reconstruções Tridimensionais Virtuais para Confecção de Biomodelos de Prototipagem Rápida: Estudo*. Ph.D. dissertation, Universidade Federal da Bahia. Faculdade de Odontologia.
- Fields, R. (2008). White matter matters. *Scientific American*, 298(3), 54-61.
- Garcia-Lorenzo, D., Francis, S., Narayanan, S., Arnold, D. L., & Louis Collins, D. (2012). Review of automatic segmentation methods of multiple sclerosis white matter lesions on conventional magnetic resonance imaging. *Medical image analysis*.
- García-Lorenzo, D., Francis, S., Narayanan, S., Arnold, D., & Louis Collins, D. (2012). Review of automatic segmentation methods of multiple sclerosis white matter lesions on conventional magnetic resonance imaging. *Medical Image Analysis*.
- Garcia-Lorenzo, D., Lecoeur, J., Arnold, D. L., Collins, D. L., & Barillot, C. (2009). Multiple sclerosis lesion segmentation using an automatic multimodal graph cuts. In: *Medical Image Computing and Computer-Assisted Intervention--MICCAI 2009* (pp. 584-591). Springer.
- Garcia-Lorenzo, D., Prima, S., Arnold, D., Collins, D., & Barillot, C. (2011). Trimmed-Likelihood Estimation for Focal Lesions and Tissue Segmentation in Multisequence MRI for Multiple Sclerosis. *Medical Imaging, IEEE Transactions on*, 30(8), 1455-1467.
- Gonzalez, R. C., & Woods, R. E. (2007). *Digital Image Processing, 3-rd Edition*. Prentice Hall.
- Goshtasby, A., Turner, D. A., & Ackerman, L. V. (1992). Matching of tomographic slices for interpolation. *Medical Imaging, IEEE Transactions on*, 11(4), 507-516.
- Group, S. B. (09 de 08 de 2010). *VBM8*. Acesso em 28 de 05 de 2013, disponível em VBM8: <http://dbm.neuro.uni-jena.de/vbm8/>
- Haralick, R. M., & Shapiro, L. G. (1985). Image segmentation techniques. *Computer Vision, Graphics, and Image Processing*, 29(1), 100-132.

- Kwan, R. K.-S., Evans, A. C., & Pike, G. B. (1996). An extensible MRI simulator for post-processing evaluation. *Visualization in Biomedical Computing*, (pp. 135-140).
- Kwan, R.-S., Evans, A. C., & Pike, G. B. (1999). MRI simulation-based evaluation of image-processing and classification methods. *Medical Imaging, IEEE Transactions on*, 18(11), 1085-1097.
- Lee, S.-Y., Chwa, K.-Y., Hahn, J. K., & Shin, S. Y. (1996). Image morphing using deformation techniques. *Journal of Visualization and Computer Animation*, 7(1), 3-23.
- Lehmann, T. M., Gonner, C., & Spitzer, K. (1999). Survey: Interpolation methods in medical image processing. *Medical Imaging, IEEE Transactions on*, 18(11), 1049-1075.
- Lin, C.-c., Sheu, M.-h., Chiang, H.-K., Liaw, C., Wu, Z.-C., & Tsai, W.-K. (2010). An Efficient Architecture of Extended Linear Interpolation for Image Processing. *Journal of Information Science and Engineering*, 26(2), 631-648.
- Lladó, X., Oliver, A., Cabezas, M., Freixenet, J., Vilanova, J., Quiles, A., et al. (2011). Segmentation of multiple sclerosis lesions in brain MRI: A review of automated approaches. *Information Sciences*.
- Mazziotta, J. C., & Toga, A. W. (2005). *ICBM Probabilistic Atlases - LONI*. Acesso em 25 de 06 de 2013, disponível em International Consortium for Brain Mapping: http://www.loni.ucla.edu/ICBM/Downloads/Downloads_ICBMprobabilistic.shtml
- Mazzola, A. (2009). Ressonância magnética: princípios de formação da imagem e aplicações em imagem funcional. *Revista Brasileira de Física Médica*, 3(1), 117-29.
- McDonald, W., Compston, A., Edan, G., Goodkin, D., Hartung, H., Lublin, F., et al. (2001). Recommended diagnostic criteria for multiple sclerosis:

- guidelines from the International Panel on the diagnosis of multiple sclerosis. *Annals of neurology*, 50(1), 121-127.
- Miklos, P. (2004). Image interpolation techniques. *2nd Siberian-Hungarian Joint Symposium On Intelligent Systems*.
- Miranda, A. H., Prado, A., & Traina, A. J. (1996). Interpolação de Imagens Tomográficas através de Matching usando Triangulação de Delaunay.
- Morpheus Software*. (1999). Acesso em 15 de 04 de 2014, disponível em Morpheus Photo Morpher - Premiere Photo Morphing Software: <http://www.morpheussoftware.net/>
- MSIV, K. P., & Les Folio, D. (2007). Medical applications of digital image morphing. *Journal of Digital Imaging*, 20(3), 279-283.
- Neuroimaging, W. T. (Abril de 2009). *SPM8*. Acesso em 2013 de 05 de 28, disponível em Statistical Parametric Mapping: <http://www.fil.ion.ucl.ac.uk/spm/>
- Ni, K., Nguyen, T., & Vasconcelos, N. (2003). Statistical Based Image Interpolation.
- Raya, S. P., & Udupa, J. K. (1990). Shape-based interpolation of multidimensional objects. *Medical Imaging, IEEE Transactions on*, 9(1), 32-42.
- Schmidt, P., Gaser, C., Arsic, M., Buck, D., Forschler, A., Berthele, A., et al. (2011). An automated tool for detection of FLAIR-hyperintense white-matter lesions in Multiple Sclerosis. *NeuroImage*.
- Schmidt, P., Gaser, C., Arsic, M., Buck, D., Förschler, A., Berthele, A., et al. (2012). An automated tool for detection of FLAIR-hyperintense white-matter lesions in Multiple Sclerosis. *NeuroImage*, 59(4), 3774-3783.
- Schmidt, P., Mühlau, M., Gaser, C., & Wink, L. (23 de 12 de 2011). *LST: A Lesion Segmentation Tool For SPM*. Acesso em 28 de 05 de 2013, disponível em LST: A Lesion Segmentation Tool For SPM: <http://www.applied-statistics.de/lst.html>

- Schumacher, G., Beebe, G., Kibler, R., Kurland, L., Kurtzke, J., McDowell, F., et al. (1965). Problems of experimental trials of therapy in multiple sclerosis: report by the panel on the evaluation of experimental trials of therapy in multiple sclerosis. *Annals of the New York Academy of Sciences*, 122(1), 552-568.
- Shapiro, L. G., & Stockman, G. C. (2001). *Computer vision*. Prentice Hall.
- Shiee, N., Bazin, P., Ozturk, A., Reich, D., Calabresi, P., & Pham, D. (2010). A topology-preserving approach to the segmentation of brain images with multiple sclerosis lesions. *Neuroimage*, 49(2), 1524.
- Souplet, J., Lebrun, C., Ayache, N., Malandain, G., & others. (2008). An automatic segmentation of T2-FLAIR multiple sclerosis lesions. *Grand Challenge Work.: Mult. Scler. Lesion Segm. Challenge*, 1-11.
- Stroke, N. I. (04 de 08 de 2011). *Neurological diagnostic tests and procedures*. Acesso em 20 de 12 de 2012, disponível em [www.ninds.nih.gov: http://www.ninds.nih.gov/about_ninds/addresses.htm](http://www.ninds.nih.gov/about_ninds/addresses.htm)
- TANG, X., WANG, L., & LIU, W. (2011). A Comprehensive Interpolation for Medical Slices Based on Combination of Linear and Matching Interpolation. *Chinese Journal of Electronics*, 20(1).
- Trip, S. A. (2005). Imaging in multiple sclerosis. *Journal of Neurology, Neurosurgery \& Psychiatry*, iii11-iii18.
- Van Leemput, K., Maes, F., Vandermeulen, D., & Suetens, P. (1999). Automated model-based bias field correction of MR images of the brain. *Medical Imaging, IEEE Transactions on*, 18(10), 885-896.
- Weber, R., Keerl, R., Jaspersen, D., Huppmann, A., Schick, B., & Draf, W. (1996). Computer-assisted documentation and analysis of wound healing of the nasal and oesophageal mucosa. *The Journal of Laryngology \& Otology*, 110(11), 1017-1021.
- Wilson, J. A. (03 de 02 de 2012). *Diseases & Conditions - Medscape Reference*. Acesso em 20 de 12 de 2012, disponível em Medscape: <http://emedicine.medscape.com/article/342254-overview>

Wolberg, G. (1998). Image morphing: a survey. *The visual computer*, 14(8), 360-372.