



Universidade Federal
do Rio de Janeiro

Escola Politécnica

TÉCNICAS DE ENTROPIA APLICADAS À ESTIMATIVA DA PERIODICIDADE DE TECIDOS BIOLÓGICOS

Alberto Jorge Silva de Lima

Projeto de Graduação apresentado ao Curso de Engenharia Eletrônica e de Computação da Escola Politécnica, Universidade Federal do Rio de Janeiro, como parte dos requisitos necessários à obtenção do título de Engenheiro.

Orientadores: Wagner Coelho de Albuquerque Pereira e Mariane Rembold Petraglia

RIO DE JANEIRO
DEZEMBRO de 2009

TÉCNICAS DE ENTROPIA APLICADAS À ESTIMATIVA DA
PERIODICIDADE DE TECIDOS BIOLÓGICOS

Alberto Jorge Silva de Lima

PROJETO DE GRADUAÇÃO SUBMETIDO AO CORPO DOCENTE DO CURSO DE ENGENHARIA ELETRÔNICA E DE COMPUTAÇÃO DA ESCOLA POLITÉCNICA DA UNIVERSIDADE FEDERAL DO RIO DE JANEIRO COMO PARTE DOS REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE ENGENHEIRO ELETRÔNICO E DE COMPUTAÇÃO.

Examinado por:

Prof. Wagner Coelho de Albuquerque Pereira, D. Sc.

Prof^a. Mariane Rembold Petraglia, Ph. D.

Prof. José Gabriel Rodríguez Carneiro Gomes, Ph. D.

RIO DE JANEIRO, RJ - BRASIL

DEZEMBRO de 2009

Lima, Alberto Jorge Silva de

Técnicas de Entropia Aplicadas à Estimativa da Periodicidade de Tecidos Biológicos/ Alberto Jorge Silva de Lima. – Rio de Janeiro: UFRJ/ Escola Politécnica, 2009.

XIII, 49 p.: il.; 29,7 cm.

Orientadores: Wagner Coelho de Albuquerque Pereira e Mariane Rembold Petraglia

Projeto de Graduação – UFRJ/ Escola Politécnica/ Curso de Engenharia Eletrônica e de Computação, 2009.

Referencias Bibliográficas: p. 48-49.

1. MSS. 2. Tecido hepático. 3. Periodicidade. 4.Ultrassom. 5.Entropia. I. Pereira, Wagner *et al.* II. Universidade Federal do Rio de Janeiro, Escola Politécnica, Curso de Engenharia Eletrônica e de Computação. III. Título.

DEDICATÓRIA

*A meus queridos pais, Marizete Soares da Silva e
Manuel Nunes de Lima Filho e a minha querida
irmã, Clotildes, a Clo, com amor e gratidão.*

AGRADECIMENTOS

Agradeço primeiramente a Wagner Pereira e Christiano Machado, pela orientação, que teve início, na verdade, há quatro anos, quando comecei a caminhada neste terreno tão incerto que é a pesquisa. Devo muito a vocês pelo aprendizado recebido nestes anos. Agradeço, em segundo lugar, à minha orientadora no Departamento de Engenharia Eletrônica e de Computação, Mariane Petraglia, pelo desafio de aceitar a orientação de um projeto que já tinha certo percurso quando a procurei. Ao CNPq, que apoiou este projeto durante os anos em que o desenvolvi como bolsista de iniciação científica.

Eu não poderia deixar de citar também uma série de nomes que foram muito importantes nestes cinco anos e meio de graduação. Sem eles, eu não estaria terminando este projeto e talvez nem estivesse na Universidade. Peço desculpas se esqueci alguém.

A Pedro Brito, Leticia Lemos, Alberto Wagner, Alexandre Guazzi, Isabel Sant'Anna, Ana Fernanda, Amanda Alves, Rennan Roig, Julia Simões, Pedro Coelho, Saulo Nunes, Anderson Frazão, agradeço não só pelas horas de estudo conjunto e apoio nas horas difíceis, mas também, e principalmente, pelos churrascos, chopadas, trilhas, sorrisos e abraços. A vida não vale nada sem a amizade.

Aos professores Jomar Gozzi, Antonio Claudio, Heloísa Helena e Osvaldo Pereira, também amigos, agradeço pela presença sempre marcante dentro e fora da sala de aula, sempre com muito carinho, respeito e fé na profissão que escolheram; vocês são uma inspiração para mim e reforçaram ainda mais o desejo antigo de me tornar professor.

Agradeço ao pessoal do Roxinho, pela organização de eventos culturais, ao pessoal do SOLTEC, pela oportunidade de ver a engenharia sob um ponto de vista menos técnico e pensar a tecnologia sob uma perspectiva mais integrada ao ser humano e ao planeta e menos alinhada a interesses elitistas e degradantes da vida.

Agradeço a meus pais, nordestinos, como tantos outros que para o sul vieram construir suas vidas, que na sua simplicidade me ensinaram o valor da dedicação, da honestidade e da educação, e que essas palavras não valem nada sem amor. A minha irmã, pela alegria de todos os dias e porque minha vida não teria sentido sem ela.

Agradeço também a Barbara, que entrou em minha vida há tão pouco tempo e já marcou sua presença para sempre. Obrigado, querida, pelas horas de compreensão em minha ausência, pelos papos regados a bom vinho (bom porque compartilhado contigo), pelas trilhas e pelo amor.

Por fim, ao povo brasileiro, que mesmo sem saber, ou talvez sem se dar conta, mantém as

universidades e escolas públicas do país. Este trabalho deve muito a essa gente, sobretudo aos que mais sofrem, meus irmãos.

Obrigado...

Memória

*Amar o perdido
deixa confundido
este coração.*

*Nada pode o olvido
contra o sem sentido
apelo do Não.*

*As coisas tangíveis
tornam-se insensíveis
à palma da mão.*

*Mas as coisas findas,
muito mais que lindas,
essas ficarão.*

Carlos Drummond de Andrade

Resumo do Projeto de Graduação apresentado à Escola Politécnica/UFRJ como parte dos requisitos necessários para a obtenção do grau de Engenheiro Eletrônico e de Computação.

TÉCNICAS DE ENTROPIA APLICADAS À ESTIMATIVA DA PERIODICIDADE DE TECIDOS BIOLÓGICOS

Alberto Jorge Silva de Lima

Dezembro/2009

Orientadores: Wagner Coelho de Albuquerque Pereira e Mariane Rembold Petraglia

Curso: Engenharia Eletrônica e de Computação

Este trabalho teve como principal objetivo estudar o comportamento de uma nova forma de se estimar a periodicidade de sinais de ultrassom (US), baseada na entropia relativa. Como parâmetro para caracterizar a periodicidade escolheu-se o MSS (*Mean Scatterer Spacing*). O método foi aplicado a sinais de US simulados, a sinais reais provenientes da reflexão em *phantoms* e a sinais reais provenientes da reflexão em amostras de tecido hepático humano *in vitro* saudáveis (fibrose grau 0) e cirróticas (fibrose grau 4). As estimativas de MSS foram satisfatórias (erro médio abaixo de 8 %) nos sinais simulados com pouca contribuição de espalhamento gerado por partículas difusas (*Ad* igual a 1 % e a 5 %). Em relação aos sinais de *phantoms* e de tecido hepático, as estimativas ficaram muito dependentes dos sinais de varredura utilizados pelo método. Em particular, a análise estatística realizada sobre as estimativas de MSS dos sinais de tecido hepático diferenciaram não só as amostras saudáveis das cirróticas, como também amostras com mesmo grau de fibrose.

Palavras-Chave: MSS, tecido hepático, periodicidade, ultrassom, entropia.

Abstract of Undergraduate Project presented to POLI/UFRJ as a partial fulfillment of the requirements for the degree of Engineer.

ENTROPY TECHNIQUES APPLIED TO PERIODICITY ESTIMATION OF
BIOLOGICAL TISSUES

Alberto Jorge Silva de Lima

December/2009

Advisors: Wagner Coelho de Albuquerque Pereira e Mariane Rembold Petraglia

Course: Electronic and Computer Engineering

The main goal of this project was the study of a new way of ultrasound signal periodicity estimation, based on relative entropy. MSS (Mean Scatterer Spacing) was the chosen parameter to characterize periodicity. The method was applied to simulated US signals, to real signals collected from *phantoms*, and to real signals collected from *in vitro* human hepatic tissue (healthy and pathological samples). The MSS estimates presented mean error below 8 % in simulated signals with low diffuse reflection (A_d equals 1 and 5 %). To *phantoms* and hepatic tissue signals, estimates were very dependent on sweeping signals used by the method. Particularly, the statistical analysis made on hepatic signals estimates differentiated the healthy from pathological samples, as also as samples from the same fibrosis degree.

Key-words: MSS, hepatic tissue, periodicity, ultrasound, entropy.

Sumário

Capítulo 1 - Introdução.....	1
1.1 – Tema.....	1
1.2 – Contextualização.....	1
1.3 – Justificativa.....	2
1.4 – Objetivos.....	2
1.5 – Metodologia.....	3
1.6 – Descrição.....	3
Capítulo 2 - Revisão Bibliográfica – MSS.....	4
2.1 – Ultrassom e caracterização tecidual.....	4
2.2 – Técnicas de estimativa da periodicidade de tecidos.....	5
Capítulo 3 - Entropia.....	6
3.1 – Entropia e termodinâmica.....	6
3.2 – Entropia e teoria da informação.....	7
3.3 – Entropia e caracterização tecidual.....	12
Capítulo 4 - Materiais e Métodos	16
4.1 – Estudos com sinais simulados.....	16
4.2 – Estudos com sinais de phantoms.....	19
4.3 – Estudos com sinais de fígado.....	22
Capítulo 5 - Resultados	26
5.1 – Estudos com sinais simulados.....	26
5.2 – Estudos com sinais de phantoms.....	33
5.3 – Estudos com sinais de fígado.....	34
Capítulo 6 - Discussão.....	43
6.1 – Estudos com sinais simulados.....	43
6.2 – Estudos com sinais de phantoms.....	44
6.3 – Estudos com sinais de fígado.....	44
Capítulo 7 - Conclusão.....	46
Bibliografia.....	48

Lista de Figuras

Figura 1: Onda de US se propagando em um meio com espalhadores regulares e difusos [incluir fonte/cortesia].....	19
Figura 2: Esquema da aquisição dos sinais de nylon (Fonte: Machado [1]).....	22
Figura 3: Típico sinal do <i>phantom</i> de nylon de 0,8 mm.....	24
Figura 4: Típico sinal do <i>phantom</i> de nylon de 1,2 mm.....	24
Figura 5: Esquema da aquisição dos sinais de amostras de fígado (Fonte: Machado [1]).....	25
Figura 6: Típico sinal da amostra de fígado N1 (normal).....	28
Figura 7: Típico sinal da amostra de fígado F5 (grau 4 de fibrose).....	28
Figura 8: Desenho esquemático do tecido hepático, com destaque para a estrutura lobular hexagonal (Fonte: Machado [1]).....	29
Figura 9: Pulso de US utilizado pelo simulador ($f_a = 500$ MHz, $B = 12$ MHz e $f_0 = 20$ MHz).....	31
Figura 10: Eco de US simulado ($A_d = 1$ %, jitter = 1 % e $c = 1498$ m/s).....	32
Figura 11: Eco de US simulado ($A_d = 60$ %, jitter = 1 % e $c = 1498$ m/s).....	32
Figura 12: MSS médio estimado em função da periodicidade simulada, para diferentes valores de A_d (cada estimativa foi repetida 25 vezes).....	33
Figura 13: Erro de estimativa para cada periodicidade simulada, para diferentes valores de A_d	34
Figura 14: Curva de entropia versus MSS do estudo com sinais simulados. O sinal em teste tem periodicidade igual a 1 mm e A_d igual a 1 %.....	36
Figura 15: Curva de entropia versus MSS do estudo com sinais simulados. O sinal em teste tem periodicidade igual a 0,5 mm e A_d igual a 1 %.....	37
Figura 16: Curva de entropia versus MSS do estudo com sinais simulados. O sinal em teste tem periodicidade igual a 1 mm e A_d igual a 60 %.....	37
Figura 17: Curva de entropia versus MSS do estudo com sinais simulados. O sinal em teste tem periodicidade igual a 0,5 mm e A_d igual a 60 %.....	38
Figura 18: Histograma com as distribuições das estimativas de MSS, com diferentes escolhas de largura de banda (<i>phantom</i> de 08 mm).....	39
Figura 19: Histograma com as distribuições das estimativas de MSS, com diferentes escolhas de largura de banda (<i>phantom</i> de 0,8 mm).....	39
Figura 20: Histograma das 300 estimativas de MSS da amostra N1 (25 classes).....	41
Figura 21: Histograma das 300 estimativas de MSS da amostra N2 (25 classes).....	41
Figura 22: Histograma das 300 estimativas de MSS da amostra N3 (25 classes).....	42

Figura 23: Histograma das 300 estimativas de MSS da amostra N4 (25 classes).....	42
Figura 24: Histograma das 300 estimativas de MSS da amostra N5 (25 classes).....	43
Figura 25: Histograma das 300 estimativas de MSS da amostra F1 (25 classes).....	44
Figura 26: Histograma das 300 estimativas de MSS da amostra F2 (25 classes).....	44
Figura 27: Histograma das 300 estimativas de MSS da amostra F3 (25 classes).....	45
Figura 28: Histograma das 300 estimativas de MSS da amostra F4 (25 classes).....	45
Figura 29: Histograma das 300 estimativas de MSS da amostra F5 (25 classes).....	46

Lista de Tabelas

Tabela 1: Descrição dos parâmetros configuráveis do simulador de sinais de US.....	20
Tabela 2: Sinais cuja periodicidade foi estimada.....	20
Tabela 3: Parâmetros dos sinais de varredura utilizados na estimativa.....	20
Tabela 4: Parâmetros dos sinais de varredura utilizados no estudo com sinais de nylon.....	22
Tabela 5: Parâmetros dos sinais das amostras de fígado.....	27
Tabela 6: Parâmetros dos sinais de varredura utilizados no estudo com sinais de fígado.....	27
Tabela 7: Médias das estimativas de MSS, com respectivos valores de desvio padrão, para cada valor de Ad.....	32
Tabela 8: Resultado das estimativas de MSS dos sinais de <i>phantom</i> , com diferentes escolhas de largura de banda para os sinais de varredura (valores em mm).....	35
Tabela 9: Resultados das estimativas médias de MSS de cada amostra de tecido hepático normal..	37
Tabela 10: Resultados das estimativas médias de MSS da amostra de tecido hepático com grau 4 de fibrose.....	40
Tabela 11: Resultado do teste KS do grupo de amostras normais.....	44
Tabela 12: Resultado do teste KS do grupo de amostras com fibrose grau 4.....	44
Tabela 13: Resultado do teste KS entre os grupos de amostras normais e de amostras com fibrose grau 4.....	44

Capítulo 1

Introdução

1.1 – Tema

Este trabalho está inserido na área da caracterização de tecidos biológicos por meio do ultrassom (US).

1.2 – Contextualização

Este trabalho tem como enfoque o processamento digital de sinais de US provenientes de tecidos biológicos como forma de se determinar parâmetros relativos à periodicidade do meio em estudo.

Em particular, foi desenvolvida uma técnica de estimativa da periodicidade baseada em entropia.

O ultrassom (US) apresenta diversas aplicações na área médica. O uso desta tecnologia é difundido tanto na área terapêutica, comum, por exemplo, em fisioterapia, quanto na área diagnóstica. Nesta última, encontra-se, por exemplo, o uso do ultrassom para a visualização de estruturas biológicas, por meio da formação de imagens (ultrassonografia).

Outro uso comum do US voltado para o diagnóstico é a caracterização de estruturas por meio da análise quantitativa do sinal de radiofrequência (RF). O sinal em questão é proveniente da reflexão e espalhamento da onda de US nas estruturas do meio que se quer estudar.

Nos últimos anos, diversos estudos foram desenvolvidos na busca de se extrair parâmetros quantitativos do sinal de RF. Dentre esses parâmetros, encontram-se, por exemplo, os coeficientes de espalhamento e de atenuação e a velocidade de propagação.

Em sinais provenientes de meios com estrutura quase-periódica, i. e., com espalhadores mais ou menos igualmente espaçados entre si, um parâmetro de interesse é o espaçamento médio entre espalhadores – em inglês, *Mean Scatterer Spacing* (MSS).

Este trabalho está inserido entre aqueles que procuram desenvolver técnicas para se obter uma estimativa do MSS.

1.3 – Justificativa

Embora seja uma técnica já difundida e consolidada na área médica, o diagnóstico por ultrassonografia ainda apresenta um elevado grau de subjetividade, uma vez que a análise da imagem é, em geral, baseada somente na experiência do especialista [1].

Considerando-se esta questão, surge a necessidade de se desenvolver técnicas de processamento que permitam extrair parâmetros quantitativos do sinal, não como uma forma de substituir a experiência do especialista, mas procurando agregar informação ao processo de análise.

Quanto à escolha do MSS como parâmetro a ser estimado, cabe ressaltar que tecidos que apresentam uma estrutura quasi-periódica tendem a perdê-la na presença de certas doenças [1]. Assim, identificar esta perda de periodicidade precocemente aporta uma maior probabilidade de cura, além de menores custos psicológicos para o paciente e financeiros para o sistema de saúde.

Nos últimos anos, foram desenvolvidas diversas técnicas de estimativa do MSS, baseadas, sobretudo, em análise espectral [2]. Como a periodicidade está intimamente associada ao nível de organização do sistema (tecido), a entropia pode ser um mecanismo interessante na estimativa do MSS [3,4].

1.4 – Objetivos

O objetivo geral deste trabalho foi desenvolver um método de estimativa do MSS, baseado em entropia, aplicado a sinais de US de tecidos biológicos. Como objetivos específicos, pretendeu-se:

1. utilizar o método entrópico para se estimar a periodicidade de sinais provenientes de meios que simulam tecidos biológicos e a periodicidade de sinais de tecidos biológicos reais;
2. diferenciar, a partir dos resultados, tecidos saudáveis de doentes.

1.5 – Metodologia

Este trabalho utiliza técnicas de entropia para estimar a periodicidade de sinais de US. Primeiramente, será apresentada uma revisão bibliográfica que busque na literatura as diversas técnicas existentes para a estimativa do MSS e as técnicas de entropia existentes no âmbito da teoria da informação. Em segundo lugar, será proposto um método entrópico de estimativa do MSS. O método será então aplicado a sinais de US provenientes de meios que simulam tecidos biológicos com estruturas periódicas (*phantoms*) e, depois, a sinais provenientes de tecidos biológicos reais, com e sem a presença de doenças. Para finalizar, será realizado um teste estatístico, a partir dos resultados, tendo como objetivo verificar a significância das diferenças encontradas entre os valores estimados de MSS entre tecidos biológicos saudáveis e enfermos.

Este trabalho utiliza um banco de sinais coletados previamente, no âmbito de uma colaboração entre o *Centre National de la Recherche Scientifique* (CNRS), da França, e o Laboratório de Ultrassom do Programa de Engenharia Biomédica da COPPE/UFRJ. Os sinais são provenientes de *phantoms* de nylon e fígado normal e cirrótico. Os sinais foram todos coletados *in vitro*, usando um transdutor ultrassônico de 20 MHz de frequência central conectado a um sistema XYZ de varredura automática, controlado por computador. Os sinais de ultrassom (radio-frequência) foram coletados seqüencialmente e armazenados em arquivos digitais para posterior processamento. Para a realização do processamento foi utilizado o software MATLAB R2008a.

1.6 – Descrição

No Capítulo 2 são apresentados os resultados de uma breve revisão bibliográfica a respeito das principais técnicas de estimativa de MSS.

No Capítulo 3 é introduzido o conceito de entropia em diversos contextos: na termodinâmica, na teoria da informação e na estimativa de periodicidade de sinais. Neste capítulo também é apresentado o algoritmo de estimativa de MSS utilizado neste trabalho.

No Capítulo 4 são apresentados os diversos estudos realizados, caracterizando-se os sinais e os métodos de estimativa de MSS aplicados a cada um.

O Capítulo 5 traz os principais resultados dos estudos descritos no Capítulo 4, através de gráficos e tabelas. Tais resultados são discutidos detalhadamente no Capítulo 6.

Por fim, o Capítulo 7 traz a conclusão, com a avaliação dos resultados e sugestões para a continuação do trabalho.

Capítulo 2

Revisão Bibliográfica – MSS

2.1 – Ultrassom e caracterização tecidual

Ondas de som e de ultrassom são distúrbios mecânicos que se propagam em um meio, associados a variações de pressão e de densidade neste meio, em torno de um determinado valor de equilíbrio [5,9]. As ondas sonoras são aquelas audíveis pelos seres humanos e estão na faixa de frequências que vai de aproximadamente 20 Hz até 20 kHz. Ondas acima de 20 kHz, em particular, são chamadas de ondas de ultrassom.

Quando utilizadas para a formação de imagens (ultrassonografia), as ondas de ultrassom costumam estar na faixa de frequências que vai de 2 a 100 MHz [3]. O processo de formação da imagem, por sua vez, é realizado através da técnica de pulso-eco, na qual pulsos de US se propagam pelo tecido em uma dada direção e os ecos provenientes da reflexão e do espalhamento no tecido são captados pelo transdutor. Tal processo gera um sinal de RF que descreve a intensidade dos ecos em função da profundidade das respectivas estruturas de onde se originaram [9].

Como já mencionado na introdução deste trabalho, a análise do sinal de RF se faz, sobretudo, através da observação de imagens. Entretanto, a reflexão/espalhamento resultante da interação entre o tecido e a onda de US traz consigo outras informações que podem ser quantificadas e analisadas em conjunto com informações clínicas, tais como a presença ou a evolução de doenças. De fato, a interação do US com a microestrutura do tecido gera níveis de espalhamento que podem tornar difícil a separação visual entre este e as reflexões [10].

Dentre os diversos parâmetros relativos à microestrutura do tecido que podem ser extraídos do sinal de RF, o MSS vem sendo proposto por diversos autores como um estimador da periodicidade de tecidos. Tecidos com estruturas quasi-periódicas compreendem, por exemplo, o tecido hepático e o osso trabecular.

2.2 – Técnicas de estimativa da periodicidade de tecidos

Em sua tese de doutorado, Kauati [3] realizou uma revisão bibliográfica dos principais métodos de obtenção do MSS. A maior parte dos trabalhos por ela relatados descreve métodos baseados na análise do espectro do sinal de RF. Kauati destacou os trabalhos de Fellingham e Sommer [11], Landini e Verrazzani [12], Wear *et al.* [13], Varghese e Donohue [14,15,16], Abeyratne e Petropulu [17], Narayanan [18], Cohen *et al.* [19], Simon *et al.* [20] e de Pereira e Maciel [21]. Em particular, na linha destes trabalhos, ela implementou o método de autocorrelação espectral – ou SAC, na sigla em inglês, de *Spectral Autocorrelation* –, descrito por Varghese e Donohue; o método de SIMON, descrito por Simon *et al.*; e o método da análise do espectro singular – ou SSA, na sigla em inglês, de *Singular Spectrum Analysis* –, descrito por Pereira e Maciel. Adicionalmente, ela implementou também métodos paramétricos de estimativa do MSS. Tais métodos foram aplicados a sinais que simulam tecidos com estruturas periódicas e a sinais reais, provenientes de *phantoms* e de tecidos hepáticos *in vitro* (normais e com graus 1 e 3 de fibrose).

A análise teórica realizada por Kauati apontou a possibilidade de se estimar a periodicidade através da análise do maior valor de amplitude no espectro da envoltória do sinal de RF, supondo um modelo linear de reflexão, com espalhadores regulares e difusos. Entretanto, os resultados por ela obtidos demonstraram que a aplicação do método de estimativa em sinais reais não é trivial. Em relação aos sinais de *phantom*, por exemplo, o método SSA foi sensível ao aumento do tamanho dos poros (em esponjas de plástico), mas nenhum método conseguiu diferenciar tecidos normais de tecidos com fibrose. Assim, ela propôs, em trabalhos futuros, a utilização do MSS junto a outros parâmetros teciduais.

Em uma linha semelhante ao trabalho de Kauati, Machado [1] desenvolveu uma dissertação na qual aplica os métodos SAC, SIMON e SSA em sinais de tecido hepático humano *in vitro*, normais e patológicos. A inovação do trabalho de Machado, em relação a outros, foi realizar a estimativa conjuntamente a uma análise histopatológica das amostras. Para tal, ele utilizou o sistema METAVIR, que classifica amostras de fígado quanto à atividade e ao estágio da fibrose. Os resultados obtidos por Machado, aplicando-se os três métodos a sinais de tecidos com quatro graus de fibrose, indicaram que não foi possível discriminar tecidos com diferentes classificações utilizando-se apenas as médias das estimativas de MSS. Assim, ele acrescentou à média de MSS o desvio padrão das estimativas e a velocidade da onda de US no tecido, o que permitiu um aumento na capacidade discriminatória dos métodos, embora este aumento não tenha sido grande o suficiente a ponto de garantir que tais métodos dêem resultados idênticos à classificação METAVIR.

Capítulo 3

Entropia

3.1 – Entropia e termodinâmica

A palavra entropia, do grego “transformação”, foi introduzida por Clausius¹ para designar uma função de estado associada a um sistema em equilíbrio termodinâmico. Tal função é correspondente à 2ª lei da termodinâmica [5].

A 2ª lei da termodinâmica está intimamente ligada à questão da reversibilidade dos processos termodinâmicos e uma de suas principais consequências está no fato de que sistemas termicamente isolados² tem o seu estado de equilíbrio associado a estados de entropia máxima. Em outras palavras, quando um sistema termicamente isolado muda de estado, sua entropia jamais decresce, permanece constante se o processo for reversível e aumenta se o processo for irreversível.

Como processo irreversível, entenda-se aquele que ocorre espontaneamente somente em um sentido, ou seja, não ocorre espontaneamente no sentido reverso. Exemplos de processos irreversíveis são a expansão livre de um gás e a passagem de calor de um corpo mais quente para outro mais frio. A experiência mostra que um gás outrora confinado e que esteja ocupando homogeneamente um espaço jamais voltará à situação inicial; da mesma forma, sabe-se que não é possível passar energia espontaneamente de um corpo mais frio para outro mais quente.

Os primeiros trabalhos sobre termodinâmica lidavam, em geral, com grandezas macroscópicas dos sistemas (temperatura, volume, pressão, dentre outras). Entretanto, é possível realizar uma ponte entre os níveis microscópico e macroscópico do sistema através da Mecânica Estatística, uma área da física que procura descrever a natureza da matéria e sua interação através de métodos estatísticos [5].

No contexto da Mecânica Estatística, destaca-se o trabalho de Boltzmann³. Segundo ele, a entropia de um sistema, em um dado macroestado, pode ser definida por:

$$S_n = k \ln(W_n) \tag{3.1}$$

1 Clausius, Rudolf Julius Emmanuel (1822-1888); físico alemão.

2 Sistemas termicamente isolados são aqueles onde não existem trocas de energia com o meio externo.

3 Boltzmann, Ludwig Eduard (1844-1906); físico austríaco.

onde:

S_n → Entropia do sistema correspondente ao macroestado n ;

k → Constante de Boltzmann;

W_n → Número total de microestados associados ao macroestado n ;

Da equação (3.1), chega-se à conclusão de que a entropia é máxima para o macroestado n que possui o maior número possível de microestados a ele associados, ou seja, a entropia é máxima para o macroestado que possui maior probabilidade de ocorrência. Assim, voltando aos exemplos de processos irreversíveis, pode-se dizer que, do ponto de vista de Mecânica Estatística, não é impossível que o gás passe espontaneamente ao confinamento, mas que a probabilidade de que isto ocorra é extremamente baixa, o que corresponde a estados de entropia muito baixos.

A termodinâmica e as implicações dela decorrentes constituem um campo de estudo fascinante, com o poder de lançar luzes em questões relativas à origem e ao fim do universo, por exemplo. Para maiores informações, o leitor interessado pode consultar [5].

3.2 – Entropia e teoria da informação

Em 1948, Claude Shannon⁴ publicou um trabalho [6] que se tornou a pedra fundamental da área de estudos conhecida como Teoria da Informação. O grande desenvolvimento desta área durante o século XX se deu em virtude da necessidade de construção de sistemas de comunicações eficientes e confiáveis [7].

O ponto de partida para se introduzir a teoria da informação é discutir como mensurar a informação.

Assim, considere-se uma fonte de informação F que emite símbolos s_k de forma discreta. Estes símbolos estão restritos a um conjunto finito e constante A denominado alfabeto.

$$A = \{s_1, s_2, \dots, s_K\} \quad (3.2)$$

Cada símbolo s_k possui uma probabilidade p_k de ser emitido pela fonte, tal que

4 Shannon, Claude Elwood (1916-2001); matemático americano.

$$\sum_{k=1}^K p_k = 1 \quad (3.3)$$

onde K é o número de símbolos do alfabeto A .

Imagine-se agora como um observador dos símbolos que a fonte está emitindo. Antes do símbolo ser emitido, tudo o que você tem é a probabilidade de emissão de cada símbolo, o que constitui uma incerteza. Uma vez que o símbolo seja emitido, a incerteza desaparece e há um ganho de informação.

Pensando-se de uma maneira diferente, se a probabilidade de emissão de um símbolo é alta, a incerteza quanto à sua ocorrência é menor, logo, uma vez que este símbolo ocorra, o ganho de informação não será tão grande quanto no caso em que há a ocorrência de um símbolo de baixa probabilidade. Para que o conceito fique mais claro ainda, considere-se o caso em que um dos símbolos tem probabilidade de ocorrência igual a 1 (100 %); neste caso, a incerteza quanto a emissão da fonte é igual a zero e, por conseguinte, a ocorrência deste símbolo não agrega nenhuma informação ao processo.

Desta forma, intuitivamente, percebe-se que a função que quantifica a grandeza informação, neste processo, deve ter um comportamento inversamente proporcional em relação à probabilidade de ocorrência de um símbolo. Assim, o ganho de informação associado à ocorrência de um símbolo s_k com probabilidade p_k pode ser definido como

$$I(s_k) = \log\left(\frac{1}{p_k}\right) \quad (3.4)$$

O ganho de informação definido na equação (3.4) possui as seguintes propriedades:

1. $I(s_k) = 0$ para $p_k = 1$;
2. $I(s_k) \geq 0$ para $0 \leq p_k \leq 1$;
3. $I(s_k) > I(s_j)$ para $p_k \leq p_j$.

A propriedade 1 indica que um evento cuja probabilidade de ocorrência é de 100 % (fonte que emite sempre o mesmo símbolo) não traz nenhum ganho de informação. A propriedade 2, por sua vez, nos diz que a ocorrência de um evento jamais leva à perda de informação. Por fim, a

propriedade 3 indica que o ganho de informação é tanto maior quanto menor for a probabilidade de ocorrência do evento [7].

Seja $I(s_k)$ uma variável aleatória discreta cuja densidade de probabilidade é dada por

$$P[I(s_k)] = p_k, \text{ com } k = 1, 2, \dots, K \quad (3.5)$$

Desta forma, o valor médio de $I(s_k)$ sobre o alfabeto da fonte F é definido como

$$E[I(s_k)] = \sum_{k=1}^K p_k I(s_k) \quad (3.6)$$

que nos leva a

$$E[I(s_k)] = \sum_{k=1}^K p_k \log\left(\frac{1}{p_k}\right) = H[F] \quad (3.7)$$

ou, em uma forma mais usual

$$E[I(s_k)] = - \sum_{k=1}^K p_k \log(p_k) = H[F] \quad (3.8)$$

$H[F]$ é definida como a entropia da fonte F e pode ser interpretada como uma medida do conteúdo médio de informação por símbolo da fonte.

A entropia, tal como definido na equação (3.8), apresenta as seguintes propriedades [6]:

1. $H[F] = 0$, se e somente se um dos símbolos emitidos por F tiver probabilidade igual a 1, respeitando-se a condição de normalização descrita na equação (3.3);
2. Se todos os símbolos tiverem a mesma probabilidade de emissão, isto é, se $p_k = \frac{1}{K}$, para todo k , então $H[F]$ é máximo e seu valor é $\log(K)$;
3. Suponha a emissão conjunta de símbolos por duas fontes, F e G . A entropia conjunta das fontes é dada por

$$H[F, G] = - \sum_{k,j} p_{k,j} \log(p_{k,j}) \quad (3.9)$$

onde os índices k e j são relativos às fontes F e G , respectivamente, e $p_{k,j}$ é a probabilidade de emissão conjunta dos símbolos s_k e s_j .

As entropias individuais das fontes são dadas por

$$H[F] = - \sum_{k,j} p_{k,j} \log(p_k) \quad (3.10)$$

$$H[G] = - \sum_{k,j} p_{k,j} \log(p_j) \quad (3.11)$$

Assim, tem-se a seguinte relação

$$H[F, G] \leq H[F] + H[G] \quad (3.12)$$

Em particular, se as fontes tem emissões independentes entre si, isto é, $p_{k,j} = p_k p_j$, tem-se que

$$H[F, G] = H[F] + H[G] \quad (3.12)$$

4. Há um crescimento de $H[F]$ ao se realizar um processo de média sobre o vetor de probabilidade da forma

$$p'_j = \sum_{k=1}^K a_{jk} p_k \quad (3.13)$$

onde $\sum_k a_{jk} = \sum_j a_{jk} = 1$ e $a_{jk} \geq 0$, para todos j e k .

5. Suponha a emissão conjunta de símbolos por duas fontes F e G , tal como descrito na propriedade 3. A probabilidade de que a fonte G emita o símbolo s_j uma vez que a fonte F tenha emitido o símbolo s_k é chamada de probabilidade condicional e é definida como

$$p_k(j) = \frac{P_{k,j}}{\sum_j P_{k,j}} \quad (3.14)$$

A entropia condicional de G , $H_F[G]$, é definida como a média da entropia de G para cada símbolo de F , ponderada de acordo com a probabilidade de emissão daquele símbolo particular de F , ou seja,

$$H_F[G] = -\sum_{k,j} p_{k,j} \log(p_k(j)) \quad (3.15)$$

Portanto, $H_F[G]$ é uma medida da incerteza média quanto à emissão de G uma vez que a emissão de F seja conhecida.

Substituindo-se a equação 3.14 na 3.15, obtém-se

$$H_F[G] = -\sum_{k,j} p_{k,j} \log(p_{k,j}) + \sum_{k,j} p_{k,j} \log \sum_j (p_{k,j})$$

$$H_F[G] = H[F, G] - H[F]$$

$$H[F, G] = H[F] + H_F[G] \quad (3.16)$$

A equação (3.16) diz que a incerteza quanto à emissão conjunta das fontes F e G é igual à incerteza quanto à emissão de F mais a incerteza quanto à emissão de G quando a emissão de F é conhecida.

6. Das propriedades 3 e 5, chega-se a

$$H[F] + H[G] \geq H[F, G] = H[F] + H_F[G]$$

Logo,

$$H[G] \geq H_F[G] \quad (3.17)$$

A inequação (3.17) diz que a entropia de G jamais cresce com o conhecimento de F . Ela decresce a menos que F e G sejam fontes independentes, caso no qual $H[G]$ permanece constante.

Outro conceito importante para este trabalho é o de entropia relativa, definida como [8]

$$D[p:q] = \sum_k p_k \log \left(\frac{p_k}{q_k} \right) \quad (3.18)$$

A entropia relativa, também chamada distância Kullback-Leibler, é uma medida da ineficiência em assumir que a distribuição dos símbolos da fonte é q , quando na verdade ela é p . Em outras palavras, quanto maior a entropia relativa, maior é a distância⁵ entre a distribuição real e a arbitrada. As funções de probabilidade tem que satisfazer à condição de normalização definida na equação (3.3) e adicionalmente a

$$\sum_{k=1}^K q_k = 1 \quad (3.19)$$

3.3 – Entropia e caracterização tecidual.

Em sua tese de doutorado, Kauati [3] dedicou especial atenção ao método SSA. Tal método, conforme descrito por Pereira e Maciel [21], é baseado na técnica de análise de componentes principais e tem como objetivo separar do sinal de RF as partes periódica e não-periódica. Para tal, o sinal é decomposto em autovetores. Em seguida, adicionam-se os autovetores em ordem decrescente, em pares definidos pela correlação entre os respectivos autovalores (autovalores próximos definem um par de autovetores relativos à uma certa periodicidade). Define-se, em seguida, um limiar heurístico para determinar a interrupção da adição de autovetores. Tal limiar está relacionado com a variância total dos autovalores somados.

⁵ A palavra distância aqui não deve ser entendida como uma distância euclidiana.

Kauati, em particular, concentrou esforços para desenvolver um critério automático de interrupção da adição de autovetores. Tal critério foi baseado em entropia, em vez da variância. Assim, a cada par de autovetores adicionados, ela calculou o espectro do sinal residual (diferença entre o sinal original e o reconstruído) e obteve a entropia relativa deste sinal, tal como definido na equação (3.18), tomando como referência o espectro do sinal original. O resultado deste processo é uma curva que relaciona entropia e número de pares de autovetores. O valor mínimo de entropia nesta curva define o número de autovetores a serem utilizados na reconstrução do sinal original.

Este projeto é fortemente inspirado no trabalho de Kauati, uma vez que seus resultados mostraram que a entropia pode funcionar como um critério para a determinação do número de autovetores necessários para representar satisfatoriamente a periodicidade de um sinal de RF [22]. Entretanto, o método de estimativa de MSS aqui apresentado difere do desenvolvido por Kauati, por não possuir uma conexão com métodos de separação de sub-espacos, tais como o método SSA.

Retornando à definição de entropia expressa na equação (3.18), vê-se que há a necessidade de se definir duas funções de probabilidade associadas à fonte de símbolos: sendo uma arbitrada (q) e outra desconhecida (p).

Fazendo uma conexão com esta definição de entropia, a entropia relativa de um sinal discreto $x[n]$, em relação a um outro sinal discreto $y[n]$, pode ser definida como

$$D[x : y] = \sum_{k=1}^K p_k(x) \log \left(\frac{p_k(x)}{p_k(y)} \right) \quad (3.20)$$

onde $p_k(x)$ e $p_k(y)$ são, respectivamente, as distribuições de amplitudes dos sinais $x[n]$ e $y[n]$ e K é o número de classes das funções de distribuição. As condições de normalização definidas em (3.3) e (3.19) devem ser respeitadas, com $p_k = p_k(x)$ e $q_k = p_k(y)$.

Nesta definição de entropia relativa, a fonte de informação corresponde ao processo que está gerando as amostras $x[n]$ e $y[n]$. Se o padrão de distribuição dessas emissões for semelhante, a entropia tende a zero. Este resultado, entretanto, não é suficiente para dizer que os sinais $x[n]$ e $y[n]$ são iguais entre si, uma vez que distribuições iguais não implicam em sinais iguais. Apesar disso, se for verdade que mudanças na periodicidade de um sinal influem na distribuição de amplitudes deste, a entropia relativa passa a ser uma técnica potencial de estimativa de periodicidades. Assim, com o intuito de testar o alcance desta proposição, foi desenvolvido um método de estimativa de MSS baseado na busca pelo mínimo de entropia. A idéia básica é estimar o MSS de um determinado sinal pela comparação deste com um banco de sinais periódicos

conhecidos (com valores que cobrem uma faixa de MSS). A comparação se dá por meio da entropia relativa entre o sinal cujo MSS se quer estimar e os sinais de referência. A seguir está apresentada a estrutura do algoritmo proposto (Algoritmo 1).

Algoritmo 1: Estimativa de MSS por mínimo de entropia.

```

N ← tamanho_de(x[n])
K ← numero_de_classes(N)
x[n] ← normalizar(x[n])
env_x ← envoltoria(x[n])
prob_x ← distribuição_de_amplitudes(env_x, K)
MSS_faixa ← [MSS_min .. MSS_max]
{Define faixa de valores onde se espera encontrar o MSS de x[n]}
para MSS_y variando de MSS_min até MSS_max faça
    y[n] ← gerar_sinal_y(MSS_y)
    y[n] ← normalizar(y[n])
    env_y ← envoltoria(y[n])
    prob_y ← distribuição_de_amplitudes(env_y, K)
    ent(MSS_y) ← entropia_relativa(prob_x, prob_y) {Eq. 3.20}
fim para
[min_ent, MSS_y_min] ← mínimo(ent)
{Define a entropia mínima e o MSS da faixa de varredura a ela relativo}
MSS_estimado ← MSS_y_min
{O MSS de x[n] corresponde ao MSS da faixa de varredura que gerou o mínimo de entropia}

```

O Algoritmo 1 requer a definição de uma faixa de valores onde se espera encontrar o MSS e também a definição de uma função que gere sinais de varredura (**gerar_sinal_y**) semelhantes ao sinal $x[n]$. Esta função deve gerar, para cada valor da faixa de valores MSS, um sinal $y[n]$ que deverá ser comparado ao sinal $x[n]$ pelo cálculo da entropia relativa. O MSS de $x[n]$ será, em hipótese, igual ao do sinal $y[n]$ que gerou a menor entropia.

A envoltória dos sinais é obtida através da transformada de Hilbert [7].

$$a(t) = |s(t) + j\hat{s}(t)| \quad (3.21)$$

onde $\hat{s}(t)$ é a transformada de Hilbert do sinal $s(t)$ e $a(t)$ é a envoltória.

Os sinais tem que ser normalizados, de maneira que a média seja zero e a máxima amplitude seja igual a um (função **normalizar**).

A função que gera o sinal de varredura está baseada em um modelo de sinal RF que será descrito posteriormente.

Uma vez definido o algoritmo de estimativa de MSS, foi necessário garantir sua funcionalidade. Assim, foram realizados diversos estudos com sinais simulados, sinais reais provenientes de *phantoms*⁶ e sinais reais provenientes de tecidos biológicos.

O Capítulo 4 dará destaque a esses diversos estudos.

⁶ *Phantoms*, neste contexto, são estruturas artificiais que procuram mimetizar tecidos biológicos, quanto às diversas propriedades acústicas.

Capítulo 4

Materiais e Métodos

4.1 – Estudos com sinais simulados

Os estudos descritos nesta seção tiveram como principal objetivo testar a capacidade do Algoritmo 1 em estimar a periodicidade de sinais de US provenientes de estruturas periódicas, a partir de sinais simulados. Para tal, foi utilizado o mesmo modelo desenvolvido por Maciel *apud* Kauati [3] e utilizado em diversos trabalhos [3,4].

Segundo este modelo, um meio formado por partículas com distribuição espacial periódica e distribuição não-periódica (difusa) tem a seguinte resposta impulsiva:

$$g(t) = \sum_{i=1}^N a_i \delta(t - \tau_i) + \sum_{j=1}^M b_j \delta(t - \theta_j) \quad (3.22)$$

onde $g(t)$ é a resposta impulsiva do meio;

N é o número total de partículas regulares;

M é o número total de partículas difusas;

a_i é a amplitude do sinal referente à partícula regular i ;

b_j é a amplitude do sinal referente à partícula difusa j ;

τ_i é o atraso, relativo à posição, da partícula regular i ;

θ_j é o atraso, relativo à posição, da partícula regular j ;

$\delta(t)$ é a função impulso de Dirac.

O pulso de US gerado pelo transdutor pode ser modelado pela seguinte equação

$$p(t) = -t \exp(-4 B^2 t^2) \sin(2 \pi f_0 t) \quad (3.23)$$

onde $p(t)$ é o pulso de US;

B é a largura de banda do transdutor, em Hertz;
 f_0 é a frequência central do transdutor, em Hertz.

Assim, o sinal RF do eco de US pode ser obtido realizando-se a convolução entre o pulso de US incidente e a resposta impulsiva do meio, como descreve a equação (3.24).

$$r(t) = p(t) * g(t) \quad (3.24)$$

A Figura 1 ilustra um modelo de propagação de um pulso de US em um meio semelhante ao descrito anteriormente.

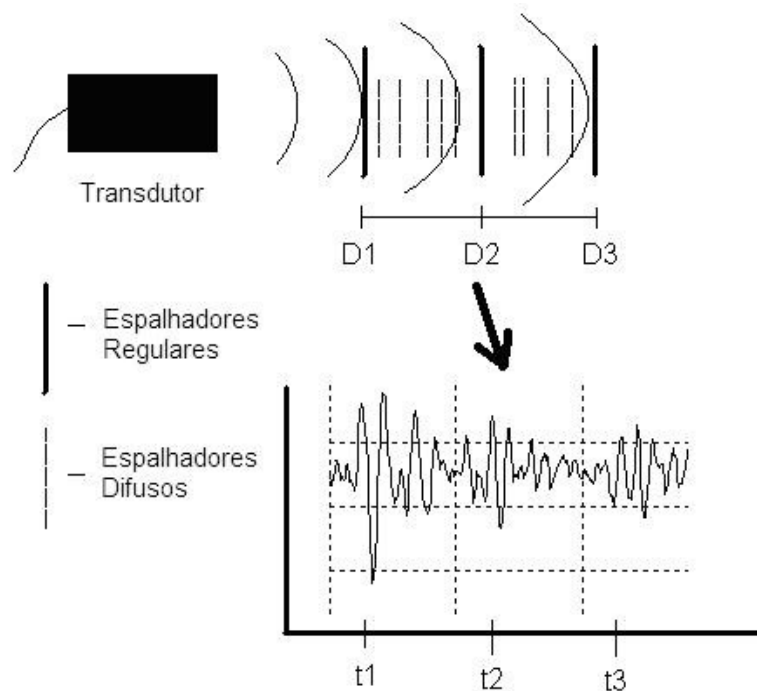


Figura 1: Onda de US se propagando em um meio com espalhadores regulares e difusos [cortesia: Machado].

O programa utilizado para gerar os sinais simulados foi adaptado para o presente trabalho. A Tabela 1 apresenta as variáveis que podem ser configuradas no programa.

Tabela 1: Descrição dos parâmetros configuráveis do simulador de sinais de US.

Variável	Descrição
MSS	Espaçamento médio entre espalhadores (mm)
c	Velocidade do pulso de US no meio (m/s)
<i>Jitter</i>	Variância na função de distribuição espacial das partículas regulares (%)
Ad	Máxima amplitude das partículas difusas, em relação à amplitude das partículas regulares (%)
f_a	Frequência de amostragem (Hz)
f_0	Frequência central do transdutor (Hz)
B	Largura de banda do transdutor (Hz)

A primeira bateria de testes do Algoritmo 1 teve como principal objetivo verificar se o mesmo seria capaz de estimar corretamente a periodicidade (parâmetro MSS) de sinais simulados. A criação dos sinais de varredura também foi realizada a partir do simulador.

A Tabela 2 descreve as características dos sinais cuja periodicidade será estimada. Para verificar o efeito do espalhamento nas partículas difusas sobre a estimativa de MSS, os sinais em teste foram divididos em 7 grupos, cada um com os parâmetros descritos na Tabela 2, mas com diferentes valores de Ad (1, 10 15, 30 45 e 60 %). Assim, para cada valor de Ad , há 21 representando uma variação linear na periodicidade. A estimativa de cada sinal foi repetida 25 vezes (em cada repetição os sinais foram gerados novamente, com os mesmos parâmetros).

A Tabela 3 descreve as características dos sinais de varredura utilizados na estimativa dos sinais de cada um dos 7 grupos.

Tabela 2: Sinais cuja periodicidade foi estimada.

Parâmetros	<i>Jitter</i> (%)	f_a (MHz)	f_0 (MHz)	B (MHz)	c (m/s)	MSS mínimo (mm)	MSS máximo (mm)	Passo de MSS (mm)	Número de sinais
Valores	0,1	500	20	12	1498	0,5	1,5	0,05	21

Tabela 3: Parâmetros dos sinais de varredura utilizados na estimativa.

Parâmetros	<i>Jitter</i> (%)	Ad (%)	f_a (MHz)	f_0 (MHz)	B (MHz)	c (m/s)	MSS mínimo (mm)	MSS máximo (mm)	Passo de MSS (mm)	Número de sinais
Valores	0,1	0,1	500	20	12	1498	0,2	2	0,01	181

Ao gerar os sinais, há a necessidade de se determinar um trecho de análise (janelamento). Este janelamento se justifica porque, na prática, a capacidade de penetração do pulso de US é limitada (o pulso vai sofrendo atenuação durante a passagem no meio) e inversamente proporcional à frequência central do transdutor. Neste estudo, em particular, definiu-se uma janela de 2670 pontos, o que equivale a uma capacidade de penetração de aproximadamente 4 mm, levando-se em conta a velocidade do pulso no meio e a frequência de amostragem, ou seja:

$$P = (J - 1)R \quad (3.25)$$

onde P é o tamanho da janela (em mm), J é o tamanho da janela (em número de amostras) e R é a distância (em mm) entre uma amostra do sinal e outra. O parâmetro R , por sua vez, pode ser calculado a partir da equação 3.26.

$$R = \frac{c}{2f_a} \quad (3.26)$$

Os resultados referentes a este teste serão apresentados adiante, no Capítulo “Resultados”.

4.2 – Estudos com sinais de *phantoms*

Neste estudo foram utilizados sinais provenientes de dois *phantoms*: um com fios de *nylon* espaçados entre si de 0,8 mm e outro com fios de *nylon* espaçados em 1,2 mm. O principal objetivo foi verificar a capacidade do Algoritmo 1 em estimar o MSS em sinais reais, com periodicidade conhecida.

Os sinais foram coletados no *Laboratoire d’Imagerie Paramétrique*, Universidade de Paris VI, França [1].

De acordo com Machado [1], os *phantoms* foram imersos em uma tanque acústico contendo água para a realização da aquisição dos sinais. O transdutor utilizado (Panametrics® M316, USA), de 20 MHz de frequência central, foi deslocado paralelamente ao longo do comprimento dos fios, em um plano modo-B (o *phantom* foi posicionado de uma forma tal que seu eixo vertical e o eixo do transdutor fizessem um ângulo entre 10-15°; isto garantiu que todos os fios fossem atingidos pelo pulso). Em cada posição foi realizada uma aquisição. Os sinais RF adquiridos foram então

amplificados e digitalizados (152 linhas, modo-A, com 100 MHz de frequência de amostragem) com um osciloscópio de 8 bits (LeCroy 9350AL) . A Figura 2 mostra um esquema do experimento.




Figura 2: Esquema da aquisição dos sinais de nylon (Fonte: Machado [1])

Para a realização das estimativas, foram selecionados de cada grupo (0,8 e 1,2 mm) 100 sinais. Para a realização da varredura, foram criados com o simulador 151 sinais, com MSS variando entre 0,5 e 2 mm. A Tabela 4 resume os parâmetros dos sinais de varredura.

Tabela 4: Parâmetros dos sinais de varredura utilizados no estudo com sinais de nylon.

Parâmetros	$Jitter$ (%)	Ad (%)	f_a (MHz)	f_0 (MHz)	c (m/s)	MSS mínimo (mm)	MSS máximo (mm)	Passo de MSS (mm)	Número de sinais
Valores	0,1	0,1	500	20	1498	0,5	2	0,01	151

Para verificar o efeito da largura de banda dos sinais de varredura sobre a estimativa, o teste foi repetido 5 vezes, mantendo constantes os valores da Tabela 4, mas mudando, em cada repetição, a largura de banda (B). Para tal foram escolhidos os seguintes valores para B : 1,5; 3; 4;; 5 e 6 MHz.

A janela escolhida foi de 5500 amostras, o que equivale a uma profundidade de 8,24 mm, aproximadamente.

As Figuras 3 e 4 ilustram típicos sinais retro-espalhados dos *phantoms* de nylon de 0,8 e 1,2 mm, respectivamente.




Figura 3: Típico sinal do *phantom* de nylon de 0,8 mm.




Figura 4: Típico sinal do *phantom* de nylon de 1,2 mm.

4.3 – Estudos com sinais de fígado

Uma vez realizados estudos com sinais simulados (onde todos os parâmetros são controlados) e com sinais de *phantoms* (onde não há controle sobre os parâmetros, mas a periodicidade é conhecida), o próximo passo foi realizar estudos com sinais reais de tecidos biológicos (onde não há controle sobre nenhum parâmetro e a periodicidade exata não é conhecida).

Os sinais escolhidos são provenientes de amostras de fígado humano, *in vitro*, com dois graus de fibrose. Estes sinais foram coletados no mesmo âmbito da colaboração citada na Seção 4.2.

As amostras de tecido receberam um tratamento especial (maiores detalhes em [1]) e foram colocadas em um recipiente contendo solução salina fisiológica. Acima da amostra foi colocada uma fina membrana plástica e abaixo, uma placa de aço polida. O recipiente contendo a amostra foi então colocado em um tanque acústico para a realização do experimento.

O transdutor utilizado possui frequência central de 20 MHz (Panametrics® M316 USA; 0,125” de diâmetro; 0,75” de distância focal; largura de banda de 6 a 30 MHz a 6 dB). O transdutor foi posicionado acima do refletor plano, de forma que seu feixe ficasse perpendicular a este. Os sinais foram coletados movendo-se o transdutor em passos de 1 mm (cada posição correspondendo à coleta de um sinal), para então serem amplificados (Sofranel 5052 PRX, França), amostrados a 100 MHz – ou 250 MHz – por um osciloscópio (LeCroy 9350, 500 MHz) e armazenados em um computador. A velocidade dos sinais foi estimada a partir do método da substituição. Para maiores detalhes, ver [1]. A Figura 5 ilustra a aquisição dos sinais.




Figura 5: Esquema da aquisição dos sinais de amostras de fígado (Fonte: Machado [1]).

Para a realização das estimativas, foram selecionados sinais provenientes de 5 amostras classificadas como normais (grau 0 de fibrose) e 5 classificadas como cirróticas (grau 4 de fibrose). A Figura 6 ilustra uma amostra do primeiro grupo e a Figura 7, uma amostra do segundo grupo.




Figura 6: Típico sinal da amostra de fígado N1 (normal).




Figura 7: Típico sinal da amostra de fígado F5 (grau 4 de fibrose).

A escolha do tecido hepático se deve porque este possui, em condições normais, uma estrutura hexagonal periódica, tal como ilustrado na Figura 8. A presença de fibrose no tecido pode, em teoria, modificar esta estrutura e influenciar na periodicidade dos espalhadores hexagonais. Um tratamento rigoroso sobre a histologia do tecido hepático e os efeitos da fibrose sobre este pode ser encontrado em [1].

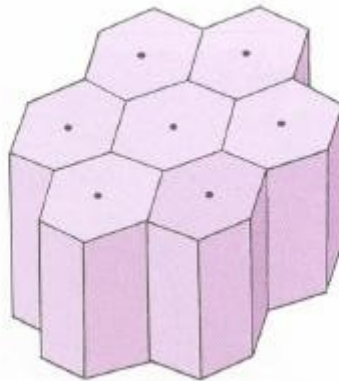


Figura 8: Desenho esquemático do tecido hepático, com destaque para a estrutura lobular hexagonal (Fonte: Machado [1]).

Em cada amostra, foram selecionados 300 sinais para a realização da estimativa de MSS. Para a varredura, utilizou-se uma faixa de MSS entre 0,2 e 2 mm, com passo de 0,01 mm, totalizando 151 sinais. A Tabela 5 traz os detalhes dos sinais de figado e a Tabela 6 os detalhes dos sinais de varredura.

Tabela 5: Parâmetros dos sinais das amostras de fígado.

Amostra	c Média (m/s)	Janela	Número de sinais
N1	1550	2560	300
N2	1460	2560	300
N3	1430	2560	300
N4	1460	2560	300
N5	1580	2560	300
F1	1540	2560	300
F2	1550	1900	300
F3	1590	2560	300
F4	1560	2560	300
F5	1560	2560	300

Tabela 6: Parâmetros dos sinais de varredura utilizados no estudo com sinais de fígado.

Parâmetros	<i>Jitter</i> (%)	<i>Ad</i> (%)	f_a (MHz)	f_o (MHz)	c (m/s)	MSS mínimo (mm)	MSS máximo (mm)	Passo de MSS (mm)	Número de sinais
Valores	0,1	0,1	500	20	Média da amostra	0,5	2	0,01	151

Capítulo 5

Resultados

5.1 – Estudos com sinais simulados

Os resultados apresentados nesta seção se referem ao estudo descrito na Seção 4.1. Mas antes, serão apresentados alguns gráficos relativos ao simulador.

A Figura 9 ilustra um pulso de US gerado pelo simulador, com $f_a = 500$ MHz, $B = 12$ MHz e $f_0 = 20$ MHz, e as Figuras 10 e 11 ilustram o resultado da reflexão/espalhamento do pulso no meio modelado, com $jitter = 1\%$ e $c = 1498$ m/s, sendo $Ad = 1\%$ na primeira figura e $Ad = 60\%$ na segunda.

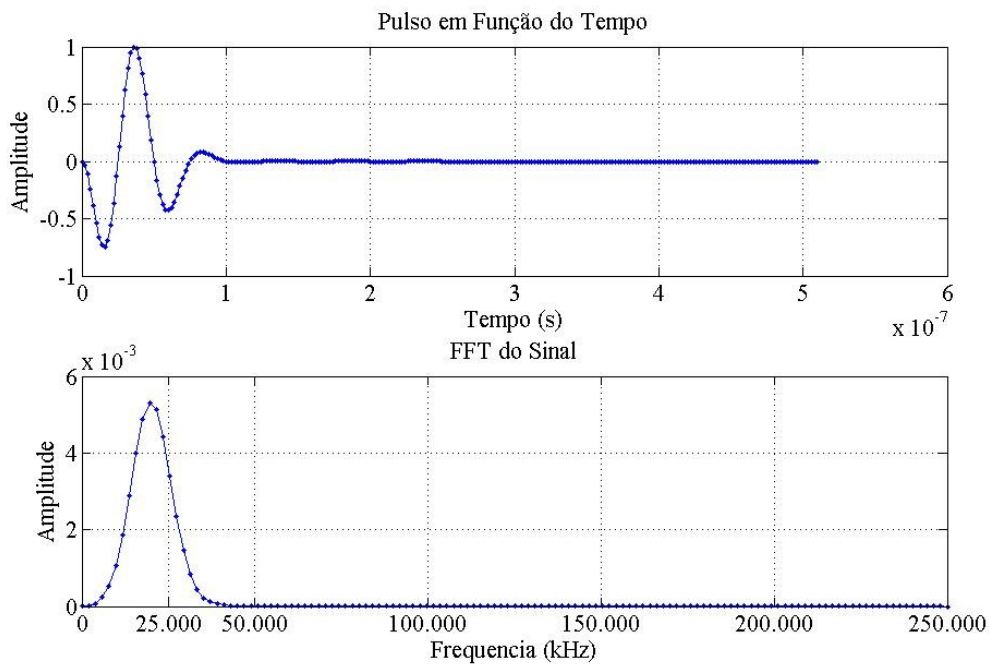


Figura 9: Pulso de US utilizado pelo simulador ($f_a = 500$ MHz, $B = 12$ MHz e $f_0 = 20$ MHz).

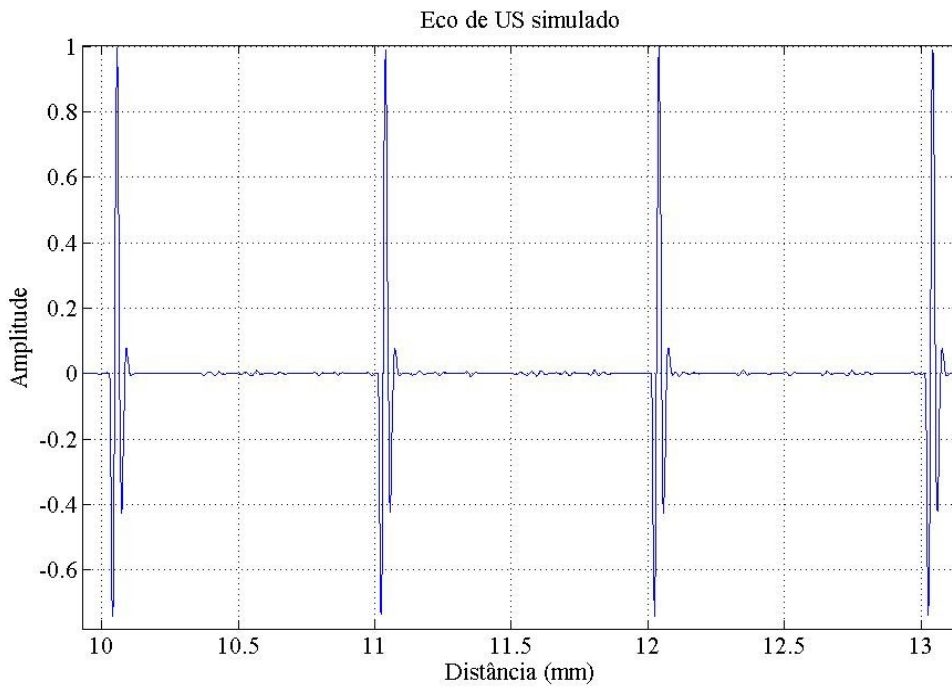


Figura 10: Eco de US simulado ($A_d = 1\%$, $jitter = 1\%$ e $c = 1498$ m/s)

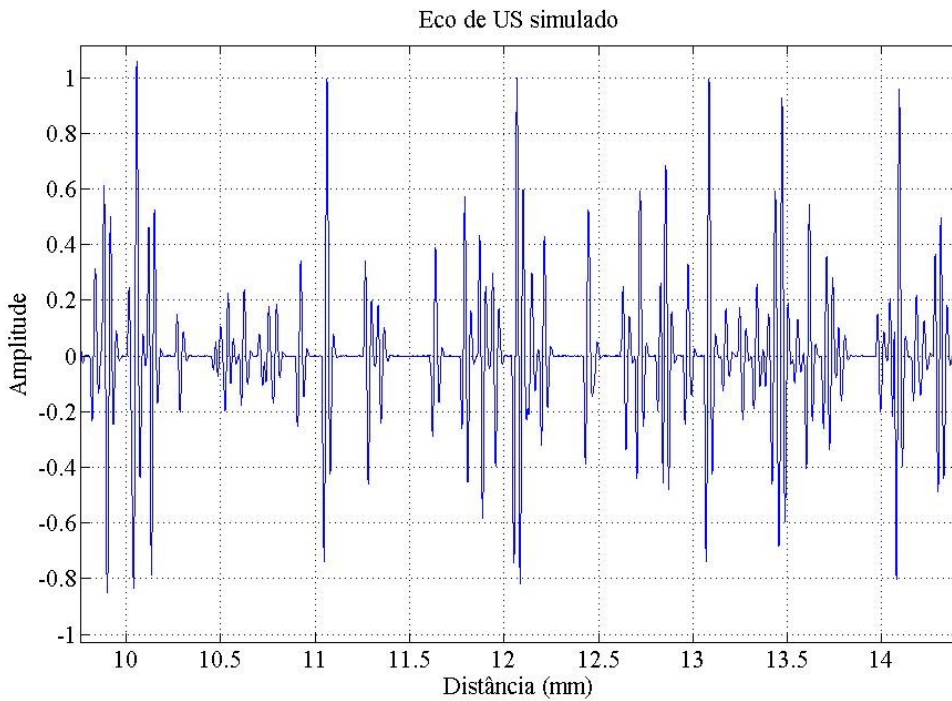


Figura 11: Eco de US simulado ($A_d = 60\%$, $jitter = 1\%$ e $c = 1498$ m/s)

Apresentados alguns resultados especificamente ligados ao simulador, apresentam-se, em seguida, resultados do estudo de estimativa de MSS em sinais com periodicidades conhecidas, com diferentes valores de Ad , tal como descrito na Seção 4.1.

A Figura 12 ilustra as estimativas de MSS em função da periodicidade simulada, para cada valor de Ad . Cada estimativa representa o valor médio de 25 repetições da varredura. A Figura 13, por sua vez, ilustra o erro das estimativas, em relação ao valor esperado (diferença absoluta entre a estimativa e o valor esperado), para cada valor de Ad .

A Tabela 7 mostra as mesmas estimativas da Figura 12, incluindo os respectivos valores de desvio-padrão.

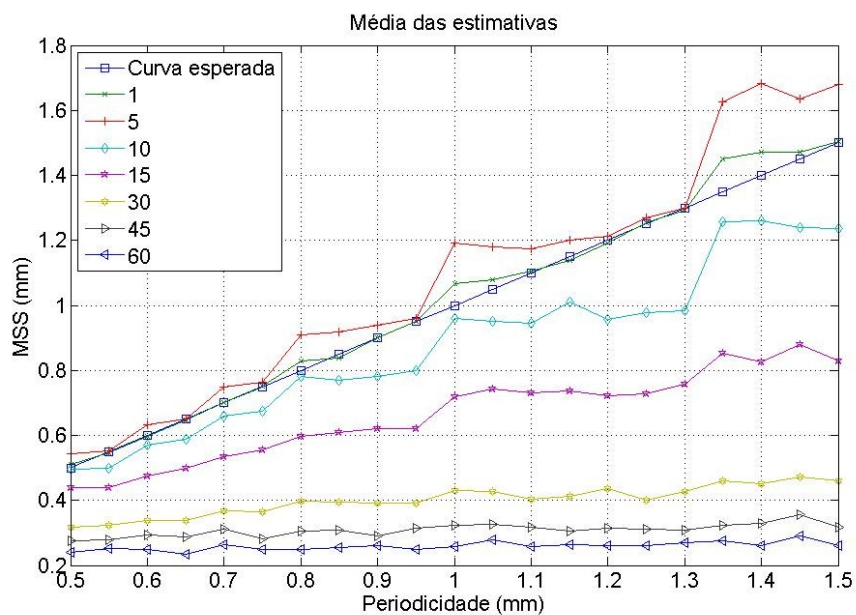


Figura 12: MSS médio estimado em função da periodicidade simulada, para diferentes valores de Ad (cada estimativa foi repetida 25 vezes).

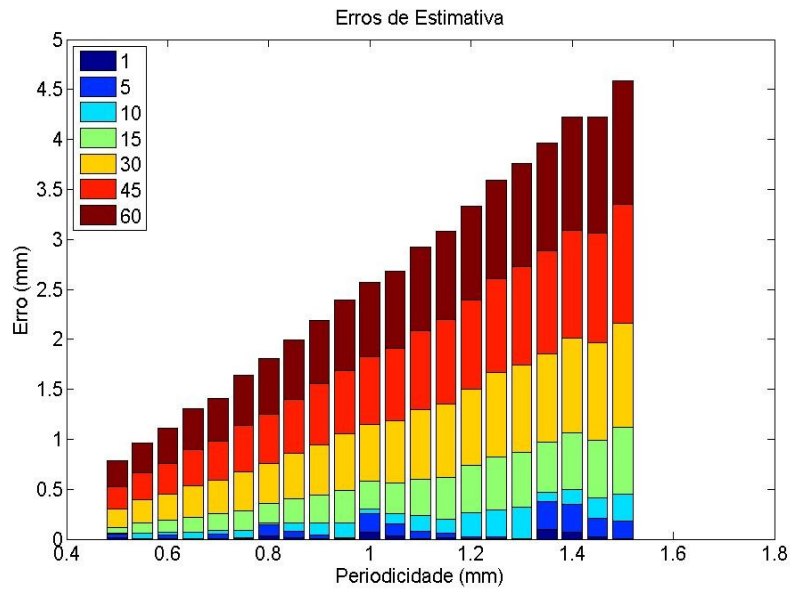


Figura 13: Erro de estimativa para cada periodicidade simulada, para diferentes valores de Ad .

Tabela 7: Médias das estimativas de MSS, com respectivos valores de desvio padrão, para cada valor de Ad .

$Ad (%) =$	1		5		10		15		30		45		60	
Periodicidade	MSS	DP	MSS	DP	MSS	DP	MSS	DP	MSS	DP	MSS	DP	MSS	DP
0,5	0,51	0,01	0,54	0,01	0,5	0,03	0,44	0,03	0,32	0,03	0,28	0,04	0,24	0,04
0,55	0,55	0,01	0,55	0,01	0,5	0,04	0,44	0,03	0,32	0,04	0,28	0,04	0,25	0,04
0,6	0,6	0,02	0,63	0,02	0,57	0,04	0,47	0,03	0,34	0,04	0,29	0,04	0,25	0,04
0,65	0,65	0,01	0,65	0	0,59	0,04	0,5	0,04	0,34	0,03	0,29	0,04	0,23	0,03
0,7	0,7	0,01	0,75	0,03	0,66	0,04	0,53	0,05	0,37	0,05	0,31	0,05	0,26	0,05
0,75	0,75	0,01	0,76	0,02	0,68	0,05	0,55	0,06	0,37	0,04	0,28	0,03	0,25	0,04
0,8	0,83	0,02	0,91	0,05	0,78	0,08	0,6	0,05	0,4	0,04	0,31	0,04	0,25	0,05
0,85	0,84	0,02	0,92	0,04	0,77	0,02	0,61	0,05	0,39	0,03	0,31	0,05	0,26	0,04
0,9	0,9	0,02	0,94	0,03	0,78	0,02	0,62	0,06	0,39	0,06	0,29	0,04	0,26	0,04
0,95	0,95	0,01	0,96	0,01	0,8	0,07	0,62	0,07	0,39	0,05	0,31	0,06	0,25	0,04
1	1,07	0,04	1,19	0,08	0,96	0,12	0,72	0,08	0,43	0,04	0,32	0,04	0,26	0,04
1,05	1,08	0,05	1,18	0,08	0,95	0,09	0,74	0,08	0,43	0,05	0,33	0,06	0,28	0,05
1,1	1,1	0,04	1,17	0,07	0,95	0,07	0,73	0,09	0,4	0,05	0,32	0,04	0,26	0,04
1,15	1,14	0,05	1,2	0,08	1,01	0,13	0,74	0,08	0,41	0,06	0,31	0,03	0,26	0,04
1,2	1,19	0,03	1,21	0,06	0,96	0,06	0,72	0,06	0,44	0,07	0,31	0,04	0,26	0,05
1,25	1,25	0,02	1,27	0,03	0,98	0,08	0,73	0,1	0,4	0,05	0,31	0,05	0,26	0,05
1,3	1,29	0,03	1,3	0,01	0,98	0,09	0,76	0,09	0,43	0,05	0,31	0,05	0,27	0,04
1,35	1,45	0,1	1,63	0,15	1,26	0,12	0,85	0,14	0,46	0,05	0,32	0,05	0,27	0,05
1,4	1,47	0,11	1,68	0,14	1,26	0,12	0,83	0,09	0,45	0,08	0,33	0,05	0,26	0,05
1,45	1,47	0,11	1,64	0,11	1,24	0,13	0,88	0,14	0,47	0,06	0,35	0,06	0,29	0,07
1,5	1,5	0,07	1,68	0,18	1,24	0,17	0,83	0,13	0,46	0,05	0,32	0,05	0,26	0,03

Para melhor entender os resultados apresentados anteriormente, pode-se observar, nas Figuras 14 e 15, típicas curvas de varredura (entropia em relação ao MSS), das quais é obtido o mínimo de entropia e estimado o MSS. A primeira curva apresenta a varredura para um sinal de periodicidade igual a 1 mm e a segunda, para um sinal de 0,5 mm. Em ambos, o Ad é igual a 1%. Curvas semelhantes são apresentadas nas Figuras 16 e 17, com a diferença de que o Ad dos sinais em teste é igual a 60 %.




Figura 14: Curva de entropia versus MSS do estudo com sinais simulados. O sinal em teste tem periodicidade igual a 1 mm e Ad igual a 1 %.

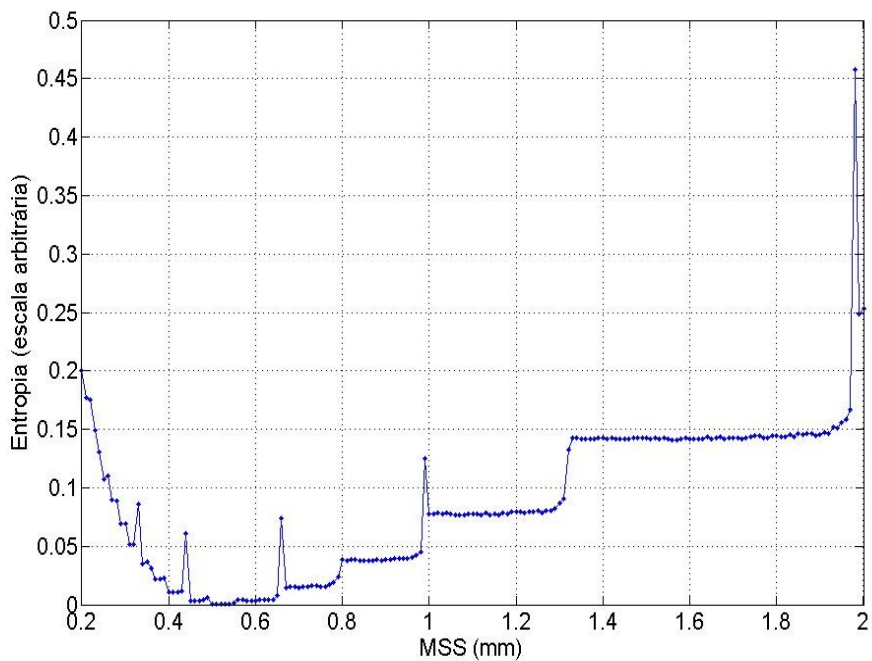


Figura 15: Curva de entropia versus MSS do estudo com sinais simulados. O sinal em teste tem periodicidade igual a 0,5 mm e Ad igual a 1 %.




Figura 16: Curva de entropia versus MSS do estudo com sinais simulados. O sinal em teste tem periodicidade igual a 1 mm e Ad igual a 60 %.




Figura 17: Curva de entropia versus MSS do estudo com sinais simulados. O sinal em teste tem periodicidade igual a 0,5 mm e Ad igual a 60 %.

5.2 – Estudos com sinais de *phantoms*

Os resultados apresentados a seguir se referem ao estudo descrito na Seção 4.2.

A Tabela 8 mostra os valores de estimativa (média das estimativas de 100 sinais) para cada *phantom*, com diferentes escolhas de largura de banda para os sinais de varredura.

Tabela 8: Resultado das estimativas de MSS dos sinais de *phantom*, com diferentes escolhas de largura de banda para os sinais de varredura (valores em mm).

B (MHz)	1,5		3		4		5		6	
Espaçamento	MSS	DP	MSS	DP	MSS	DP	MSS	DP	MSS	DP
0,8	1,74	0,235	1,125	0,231	0,843	0,203	0,694	0,139	0,591	0,102
1,2	1,964	0,03	1,943	0,056	1,494	0,192	1,361	0,159	1,113	0,174

As Figuras 18 e 19 mostram os histogramas com as distribuições das estimativas para, respectivamente, os *phantoms* de 0,8 e 1,2 mm. Observa-se que cada figura traz uma comparação entre as estimativas com diferentes escolhas de largura de banda.

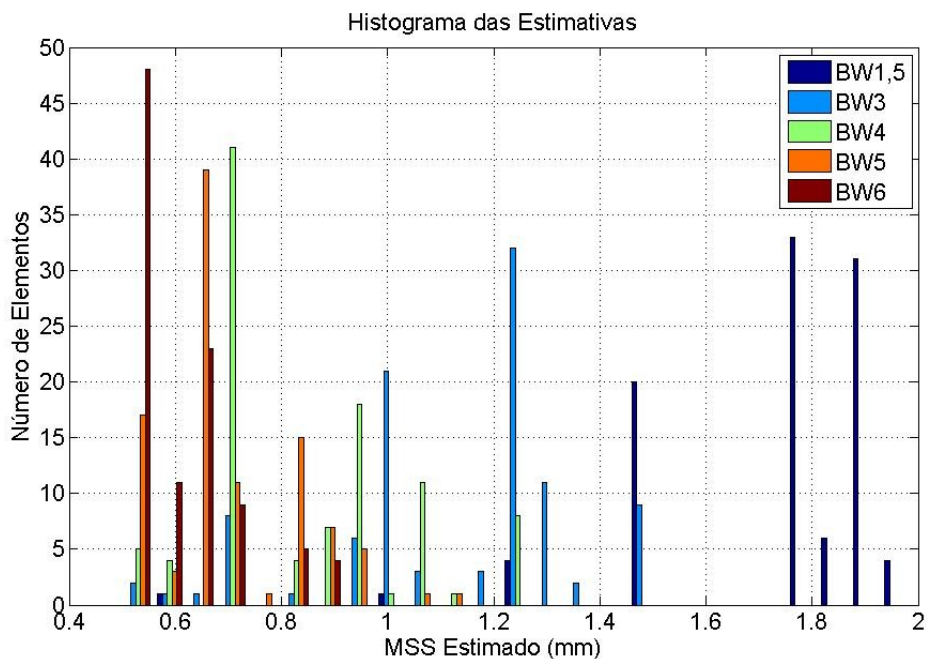


Figura 18: Histograma com as distribuições das estimativas de MSS, com diferentes escolhas de largura de banda (*phantom* de 08 mm).

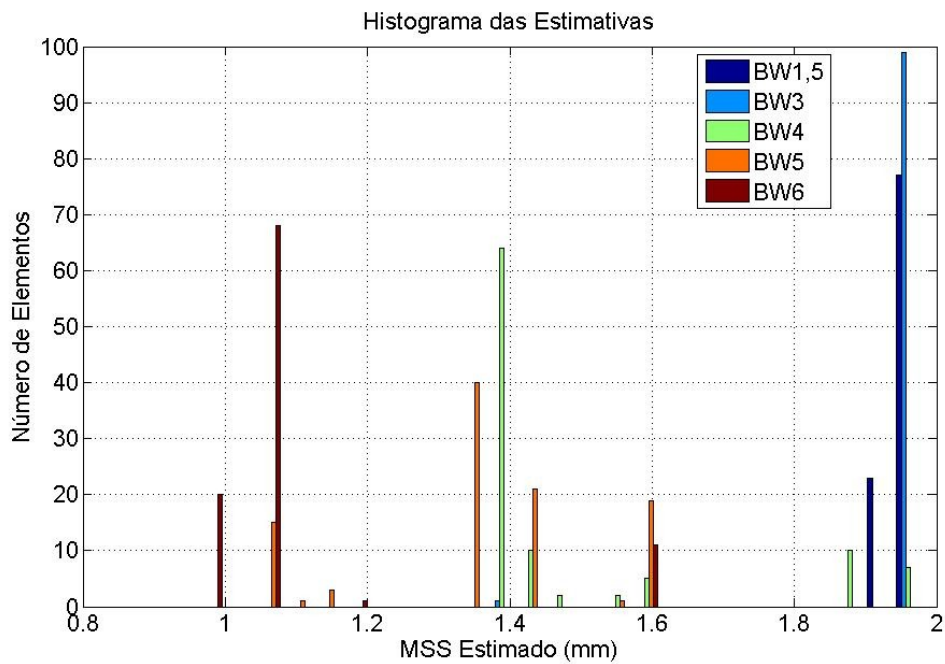


Figura 19: Histograma com as distribuições das estimativas de MSS, com diferentes escolhas de largura de banda (*phantom* de 0,8 mm).

5.3 – Estudos com sinais de fígado

Nesta seção são apresentados os resultados do estudo descrito na Seção 4.3.

A Tabela 9 traz os resultados das estimativas de MSS de cada amostra de tecido hepático normal. Cada estimativa representa a média de 300 sinais coletados da amostra em consideração. As Figuras 20, 21, 22, 23 e 24 mostram as distribuições das estimativas de MSS dos 300 sinais de cada amostra.

Tabela 9: Resultados das estimativas médias de MSS de cada amostra de tecido hepático normal.

Amostra	MSS Médio (mm)	D.P. (mm)	Modas (mm)
N1	1,2	0,388	0,825 e 1,125
N2	1,479	0,142	1,438 e 1,5
N3	1,462	0,28	1,313
N4	1,179	0,366	0,875
N5	1,281	0,373	0,813

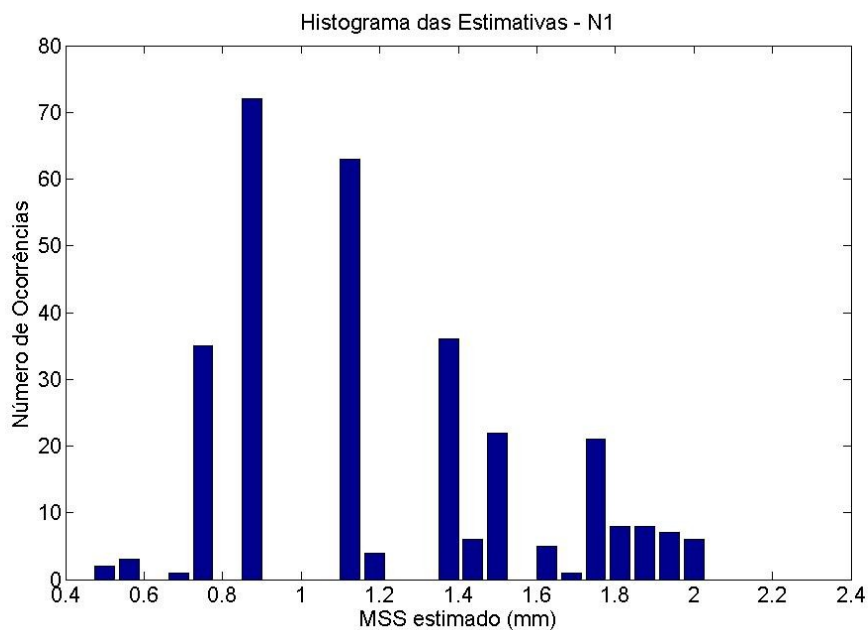


Figura 20: Histograma das 300 estimativas de MSS da amostra N1 (25 classes).




Figura 21: Histograma das 300 estimativas de MSS da amostra N2 (25 classes).

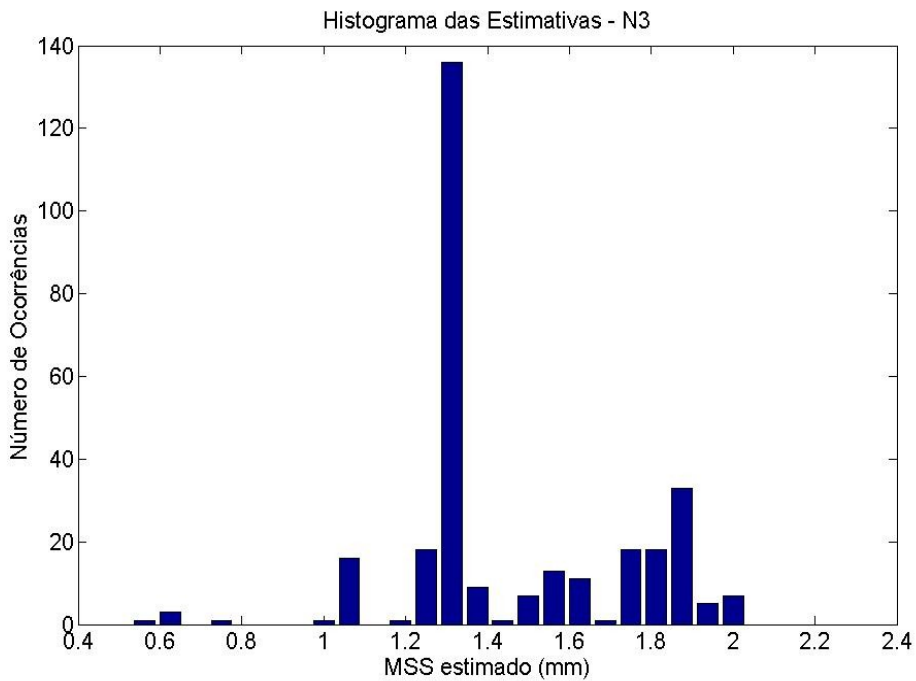


Figura 22: Histograma das 300 estimativas de MSS da amostra N3 (25 classes).




Figura 23: Histograma das 300 estimativas de MSS da amostra N4 (25 classes).




Figura 24: Histograma das 300 estimativas de MSS da amostra N5 (25 classes).

A Tabela 10 mostra os resultados das estimativas de MSS das amostras com grau de fibrose 4. As Figuras 25, 26, 27, 28 e 29 mostram a distribuição das estimativas dos 300 sinais de cada amostra.

Tabela 10: Resultados das estimativas médias de MSS da amostra de tecido hepático com grau 4 de fibrose.

Amostra	MSS Médio (mm)	D.P. (mm)	Modas (mm)
F1	1,289	0,404	1,0625
F2	1,4	0,501	0,8125 e 2,000
F3	1,438	0,309	1,1875 e 1,500
F4	1,204	0,288	1,0625
F5	1,329	0,273	1.125 e 1,375

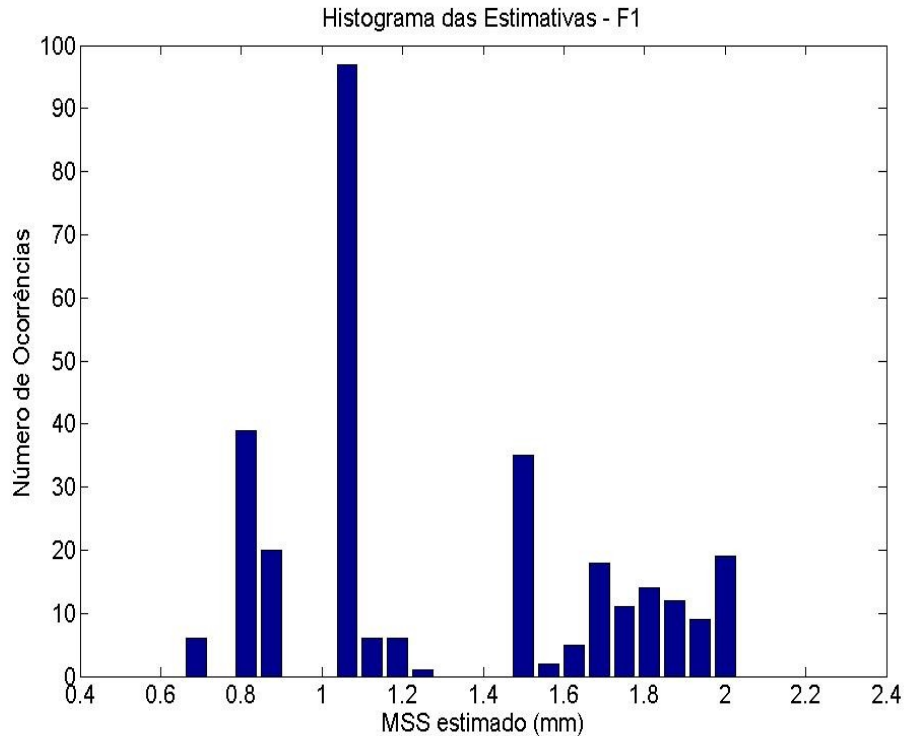


Figura 25: Histograma das 300 estimativas de MSS da amostra F1 (25 classes).




Figura 26: Histograma das 300 estimativas de MSS da amostra F2 (25 classes).




Figura 27: Histograma das 300 estimativas de MSS da amostra F3 (25 classes).

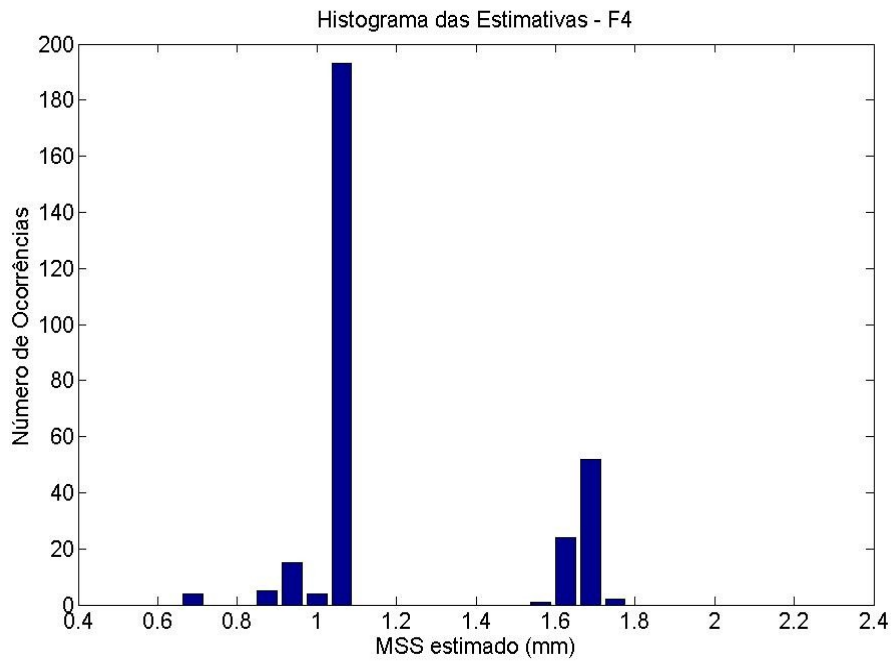


Figura 28: Histograma das 300 estimativas de MSS da amostra F4 (25 classes).

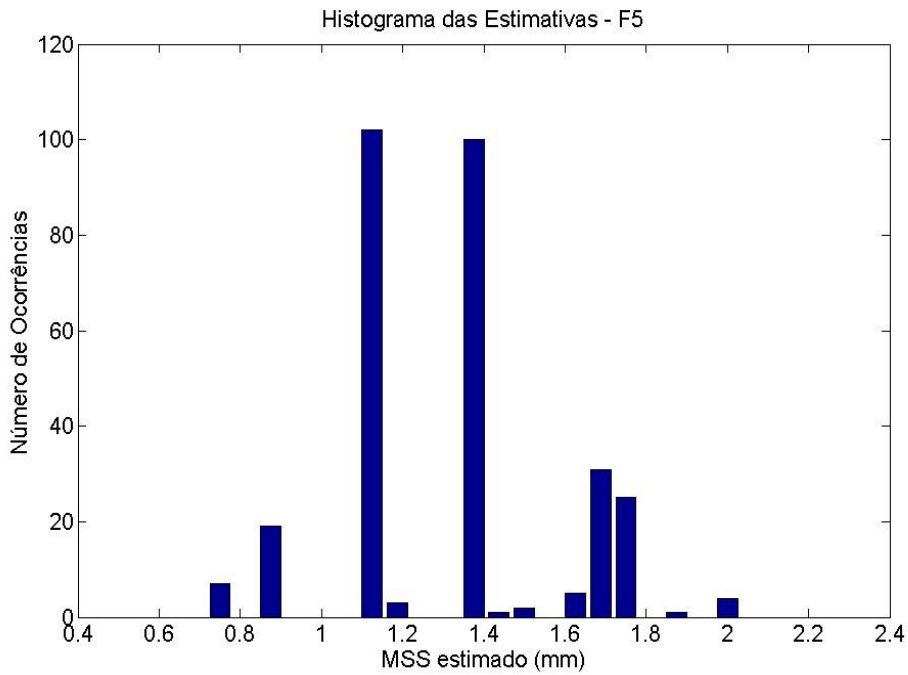


Figura 29: Histograma das 300 estimativas de MSS da amostra F5 (25 classes).

Na introdução foi colocada a idéia de se tentar fazer a diferenciação entre tecidos com diferentes graus de fibrose, a partir das estimativas de MSS. Embora Machado [1] não tenha conseguido fazer esta diferenciação trabalhando apenas com as estimativas de MSS (ele apontou para a necessidade de se realizar um estudo multi-paramétrico), este trabalho procurou realizar testes semelhantes, com o mesmo objetivo.

Utilizou-se o teste de Kolmogorov-Smirnov (KS), que é não-paramétrico e pode ser usado para se verificar a hipótese de que dois conjuntos de dados tem mesma distribuição (hipótese nula), em um certo nível de significância (5 %).

Foram realizados basicamente três testes: o primeiro procurou testar a diferenciação entre as amostras normais; o segundo, entre as amostras com grau 4 de fibrose; e o terceiro, a diferenciação entre as amostras normais e as com fibrose.

As Tabela 11 e 12 trazem os resultados dos testes intra-grupo e a Tabela 13, do teste inter-grupos. A palavra “*False*” indica que a hipótese nula, de mesma distribuição, não pode ser descartada. Por outro lado, a palavra “*True*” indica que a hipótese nula pode ser descartada.

Tabela 11: Resultado do teste KS do grupo de amostras normais.

	N1	N2	N3	N4	N5
N1	False	True	True	True	True
N2	True	False	True	True	True
N3	True	True	False	True	True
N4	True	True	True	False	True
N5	True	True	True	True	False

Tabela 12: Resultado do teste KS do grupo de amostras com fibrose grau 4.

	F1	F2	F3	F4	F5
F1	False	True	True	True	True
F2	True	False	True	True	True
F3	True	True	False	True	True
F4	True	True	True	False	True
F5	True	True	True	True	False

Tabela 13: Resultado do teste KS entre os grupos de amostras normais e de amostras com fibrose grau 4.

		Amostras Fibrose Grau 4				
		F1	F2	F3	F4	F5
Amostras Normais	N1	True	True	True	True	True
	N2	True	True	True	True	True
	N3	True	True	True	True	True
	N4	True	True	True	True	True
	N5	True	True	True	True	True

Capítulo 6

Discussão

6.1 – Estudos com sinais simulados

Os resultados referentes aos estudos com sinais simulados, apresentados na Seção 5.1, mostram claramente uma degradação do método de estimativa com o aumento contribuição das partículas difusas (vide Figuras 12 e 13).

Da Figura 13, em particular, que traz os erros de estimativa, vê-se que, para um mesmo Ad o erro das estimativas aumenta proporcionalmente à periodicidade que se está procurando estimar, o que é provavelmente uma característica intrínseca do método. Observando-se as Figuras 14 a 17, verifica-se que o valor de entropia varia pouco em alguns segmentos do eixo de MSS, com variações bruscas de entropia na transição de um desses segmentos para outro. O tamanho dos segmentos em que a entropia sofre pouca variação também muda de acordo com a região do eixo de MSS em que se está; os segmentos tendem a ser maiores quanto maior for o valor de MSS.

Deve ser lembrado que a função de entropia relativa – tal como utilizada neste trabalho – é uma espécie de comparação de distribuições de amplitude. A característica do método levantada no parágrafo anterior está indicando que as distribuições de amplitude dos sinais não se modificam muito quando se está em uma região de alto MSS. De fato, se a periodicidade é de pequeno tamanho, então há muitos ecos na janela de análise. Se, por outro lado, a periodicidade tem dimensões maiores, há pouco ecos em uma janela de mesmo tamanho. Provavelmente, mudanças de periodicidade nestes dois cenários (alta ou baixa periodicidade) tem efeitos diferentes nas distribuições de amplitudes dos respectivos sinais. No primeiro, em hipótese, precisa-se de poucos passos de aumento do MSS para retirar um eco da janela de análise. No segundo, também em hipótese, o aumento de MSS para retirar um eco da janela tem que ser muito maior, e enquanto o eco não “sai” da janela, as distribuições de amplitudes pouco mudam. As variações bruscas de entropia entre um segmento e outro podem indicam a saída de um eco da janela de análise.

6.2 – Estudos com sinais de *phantoms*

Os resultados do estudo com sinais de *phantoms*, apresentados na Seção 5.2, indicam uma dependência forte da estimativa com a largura de banda escolhida para gerar os sinais de varredura (vide Figuras 18 e 19 e a Tabela 8). Quanto maior a largura de banda, menor é a estimativa de MSS, para ambos os *phantoms*.

Em princípio, o valor mais adequado para a largura de banda dos sinais de varredura deveria ser o valor nominal do transdutor (12 MHz). Entretanto, o valor que garantiu uma estimativa de MSS mais próxima do esperado foi 4 MHz para o *phantom* de 0,8 mm e 6 MHz para o *phantom* de 1,2 mm.

Esta dependência da estimativa com o valor da largura de banda levanta um questionamento: como saber qual o valor de largura de banda mais adequado para se gerar os sinais de varredura? Esta questão não é problema quando se está trabalhando com sinais de periodicidade conhecida (como no caso dos *phantoms*), entretanto, é necessário ser cauteloso quando se está trabalhando com sinais cuja periodicidade não é conhecida (objetivo final de aplicação do método).

Esta limitação imposta pela escolha da largura de banda pode ser uma limitação do modelo de sinal considerado pelo simulador. De fato, observando as figuras que representam típicos sinais de *phantoms* (Figuras 3 e 4) observa-se que eles são relativamente diferentes dos sinais gerados pelo simulador (Figuras 10 e 11). A melhora da estimativa de MSS ao se alterar a largura de banda deve-se provavelmente a uma coincidência, no sentido de que sinais com largura de banda menor tem ecos com maior duração, o que acaba se assemelhando a reflexões/espalhamentos em outras estruturas, não modeladas, no sinal real.

6.3 – Estudos com sinais de fígado

Os resultados das estimativas de MSS dos sinais de fígado foram apresentados na Seção 5.3. Observando-se as Tabelas 9 e 10, percebe-se que as estimativas médias ficaram entre 1,1 e 1,5 mm, em ambos os grupos de sinais (amostras normais e amostras com fibrose grau 4). Vale a pena observar também as modas nos histogramas das estimativas.

Em termos gerais, não foi possível inferir algum comportamento claro, a partir das médias das estimativas de MSS, que possa garantir a diferenciação entre os dois grupos de amostras. De fato, as estimativas parecem semelhantes, embora as distribuições não pareçam ser.

Os testes estatísticos apresentados nas Tabelas 11, 12 e 13 indicaram que a hipótese de mesma distribuição pode ser descartada, no nível de significância de 5 %, seja na comparação intra-grupos (amostras normais entre si e amostras com fibrose entre si), seja na comparação inter-grupos (amostras normais com amostras cirróticas). Este resultado indica que a distribuição das estimativas de MSS, pelo método de entropia aqui apresentado, não é uma boa escolha para se realizar a separação das amostras, pelo menos não para estas amostras em particular.

A escolha de um outro valor de largura de banda poderia alterar as estimativas, mas não seria possível saber qual o valor mais adequado, tal como discutido na seção anterior. A escolha de 1,5 MHz se deu porque ela possibilitou estimativas de MSS mais próximas das relatadas na literatura [1].

A estimativa de MSS do grupo de amostras normais foi realizada em trabalho publicado [4], utilizando-se este mesmo método, porém, sem a realização da interpolação (aumento da frequência de amostragem). Os valores obtidos naquela ocasião foram um pouco menores (mais próximos de 1 mm), porém, o padrão de estimativas entre as amostras foi mantido.

A diferenciação de amostras com mesmo grau de fibrose se deve, provavelmente, à grande variabilidade entre amostras de indivíduos diferentes. Esta é uma dificuldade grande em sinais biológicos, relatada em outros trabalhos [1].

Capítulo 7

Conclusão

Este trabalho teve como principal objetivo estudar técnicas de entropia aplicadas à estimativa de MSS de sinais de US, como alternativas aos métodos baseados em análise espectral.

O método proposto possibilitou estimativas de baixo erro em sinais simulados com pouca contribuição de partículas difusas. Observou-se, entretanto, um erro elevado e crescente em sinais com contribuição difusa acima de 5 %. No caso destes sinais, uma solução seria realizar um pré-processamento no sinal; por exemplo, decompor o sinal em sub-espacos diferentes (parte periódica, parte difusa e ruído) e reconstruí-lo utilizando-se apenas a parte periódica (como proposto pelo método SSA).

Em sinais reais (*phantoms* e tecido hepático), o método apresentou algumas limitações, sendo a maior delas o modelo utilizado para gerar os sinais de varredura. O ideal seria gerar um modelo específico para o tipo de sinal que se está trabalhando. No caso dos *phantoms*, esta não seria uma tarefa muito difícil, pois os parâmetros deles podem ser controlados durante sua construção. Entretanto, no caso dos sinais de fígado, esta tarefa seria mais dispendiosa, pois haveria a necessidade de se ter um banco de sinais maior e diverso (com vários graus de fibrose e provenientes de muitos indivíduos diferentes) para caracterizar de forma adequada cada tipo de meio.

Uma segunda limitação do método é a diminuição da capacidade de discriminar sinais com periodicidades diferentes em certas faixas de MSS (vide Seção 6.1), o que aumenta o erro de estimativa, sobretudo para valores elevados de MSS. Sendo esta uma característica do método, uma solução seria encontrar uma outra função de probabilidade associada ao sinal, através da qual seja possível se estimar a periodicidade. O trabalho de Kauati [3], no qual a entropia foi utilizada como critério de reconstrução do sinal periódico para a posterior análise, pode ser uma opção interessante.

Como sugestão para trabalhos futuros, pode-se utilizar outras definições de entropia, como a entropia de Tsallis e a entropia de Kolmogorov. A primeira tem origem em problemas de não-extensividade e vem sendo utilizada com sucesso em diversas áreas, inclusive no processamento de sinais [23]. A segunda, por sua vez, tem grande aplicação em estudos sobre o caos em sistemas físicos e há trabalhos aplicando-a, inclusive, em sinais biológicos [24,25].

Este trabalho procurou estudar uma nova abordagem relacionando entropia e periodicidade de sinais de US de tecidos biológicos. Como uma abordagem incipiente, os resultados aqui representam estudos ainda básicos, mas que apontam caminhos possíveis a seguir, sendo esta, talvez, a principal contribuição do trabalho para a área de estimativa de MSS.

Bibliografia

- [1] MACHADO, C. B., *Caracterização da Periodicidade de Fígado Humano Sadio e Patológico Usando Sinais de Ultra-Som*. Dissertação de Mestrado, Programa de Engenharia Biomédica, COPPE/UFRJ, Rio de Janeiro, Maio 2005.
- [2] MACHADO, C. B.; PEREIRA, W. C. A.; MEZIRI, M.; LAUGIER, P., “Characterization of in vitro healthy and pathological human liver tissue periodicity using backscattered ultrasound signals” *Ultrasound in Medicine and Biology*, USA, v. 32, n. 5, pp. 649-657, 2006.
- [3] KAUATI, Adriana T., *Avaliação da detecção automática do espaçamento médio de espalhadores utilizando sinais ultra-sônicos*. Tese de Doutorado, Programa de Engenharia Biomédica, COPPE/UFRJ, Rio de Janeiro, Outubro 2003.
- [4] LIMA, A. J. S., MACHADO, C. B., LAUGIER, P., PEREIRA, W. C. A., “Entropia de shannon na estimativa da periodicidade de sinais de ultra-som de tecido hepático in vitro”. In: *Anais do XXI Congresso Brasileiro de Engenharia Biomédica*, pp. 1070-1073, Salvador, 2008.
- [5] NUSSENZVEIG, H. M., *Curso de Física Básica, 2*. São Paulo, Edgard Blücher, 2004.
- [6] SHANNON, C. E., “A Mathematical Theory of Communication”, *The Bell System Technical Journal*, v. 27, pp. 379–423, 623–656, 1948.
- [7] HAYKIN, S., *Communication Systems*, 4 ed., New York, John Wiley & Sons, 2001.
- [8] COVER, T. M., THOMAS, J. A., *Elements of information theory*, 1 ed., New York, John Wiley & Sons, 1991.
- [9] FISH, P., *Physics and instrumentation of diagnostic medical ultrasound*, 1 ed., Chichester, England, John Wiley & Sons, 1990.
- [10] PEREIRA, W. C. A., BRIDAL, S. L., CORON, A., LAUGIER, P., “Singular spectrum analysis is applied to backscattered ultrasound signals from *in vitro* human cancellous bone specimens”, *IEEE Transactions on Ultrasonics, Ferroelectrics, and Frequency Control*, v. 51, n. 3, pp. 302-312, 2004.
- [11] FELLINGHAM, L., SOMMER, F., “Ultrasonic characterization of tissue structure in the human liver and spleen”, *IEEE Transactions on Sonics and Ultrasonics*, v. SU-31, n. 4, pp. 418-428, 1984.
- [12] LANDINI, L., VERRAZZANI, L., “Spectral characterization of tissue microstructure by ultrasound: a stochastic approach”, *IEEE Transactions on Ultrasonics, Ferroelectrics, and Frequency Control*, v. 37, n. 5, pp. 448-456, 1990.
- [13] WEAR, K. A., WAGNER, R. F., INSANA, M. F., HALL, T. J., “Application of autoregressive spectral analysis to cepstral estimation of mean scatterer spacing”, *IEEE Transactions on Ultrasonics, Ferroelectrics, and Frequency Control*, v. 40, n. 1, pp. 50-58, 1993.

- [14] VARGHESE, T., DONOHUE, K. D., “Characterization of tissue microstructure scatterer distribution with spectral correlation”, *Ultrasonic Imaging*, v. 15, pp. 238-254, 1993.
- [15] VARGHESE, T., DONOHUE, K. D., “Mean scatterer spacing estimates with spectral correlation”, *Journal of The Acoustical Society of America*, v. 96, n. 6, pp. 3504-3515, 1994.
- [16] VARGHESE, T., DONOHUE, K. D., “Estimating mean scatterer spacing with the frequency-smoothed spectral autocorrelation function”, *IEEE Transactions on Ultrasonics, Ferroelectrics, and Frequency Control*, v. 42, n. 3, pp. 451-463, 1995.
- [17] ABEYRATNE, U. R., PETROPULU, A. P., “On modeling the tissue response from ultrasonic B-scan images”, *IEEE Transactions on Medical Imaging*, v. 15, n. 4, pp. 479-490, 1996.
- [18] NARAYANAN, V. M., MOLTHEN, R. C., SHANKAR, P. M., VERGARA, L. J., REID, M., “Studies on ultrasonic scattering from quasi-periodic structures”, *IEEE Transactions on Ultrasonics, Ferroelectrics, and Frequency Control*, v. 44, n. 1, pp. 114-124, 1997.
- [19] COHEN, F. S., GEORGIU, G., HALPERN, J., “WOLD decomposition of the backscatter echo tissue of tissue in ultrasound images of tissue organs”, *IEEE Transactions on Ultrasonics, Ferroelectrics, and Frequency Control*, v. 44, n. 1, pp. 460-472, 1997.
- [20] SIMON, C., SHEN, J., SEIP, R., EBBINI, E. S., “A robust and computationally efficient algorithm for mean scatterer spacing estimation”, *IEEE Transactions on Ultrasonics, Ferroelectrics, and Frequency Control*, v. 44, n. 4, pp. 882-894, 1997.
- [21] PEREIRA, W. C. A., MACIEL, C. D., “Performance of ultrasound echo decomposition using singular spectrum analysis”, *Ultrasound in Medicine & Biology*, v. 27, n. 9, pp. 1231-1238, 2001.
- [22] KAUATI, A. T., MACIEL, C. D., PEREIRA, W. C. A., “Ultrasonic Tissue Characterization Using Singular Spectral Analysis and Entropy: Simulated Results”. In: *25th Symposium on Acoustical Imaging. Acoustical Imaging, 2000*, v. 25, pp. 351-356, Bristol, 2000.
- [23] TSALLIS, C., “Nonextensive Statistics: Theoretical, Experimental and Computational Evidences and Connections”, *Brazilian Journal of Physics*, v. 29, n. 1, pp. 1-35, 1999.
- [24] RICHMAN, J. S., MOORMAN, J. R., “Physiological time-series analysis using approximate entropy and sample entropy”, *Am J Physiol Heart Circ Physiol*, n. 278, pp. 2039-2049, 2000.
- [25] ABOY, M., CUESTA-FRAU, D., AUSTIN, D., MICÓ-TORMOS, P. “Characterization of Sample Entropy in the Context of Biomedical Signal Analysis”, In: *Proceedings of the 29th Annual International Conference of the IEEE EMBS*, pp. 5942-5945, Lyon, 2007.