

UNIVERSIDADE DE SÃO PAULO
FFCLRP - DEPARTAMENTO DE FÍSICA E MATEMÁTICA
PROGRAMA DE PÓS-GRADUAÇÃO EM FÍSICA APLICADA À MEDICINA E
BIOLOGIA

“Método de análise de componentes dependentes para o processamento, caracterização e extração de componentes de sinais biomédicos”

Carlos Alberto Estombelo Montesco

Tese apresentada à Faculdade de Filosofia, Ciências e Letras de Ribeirão Preto da USP, como parte das exigências para a obtenção do título de Doutor em Ciências, Área: Física Aplicada à Medicina e Biologia.

RIBEIRÃO PRETO -SP

2007

Livros Grátis

<http://www.livrosgratis.com.br>

Milhares de livros grátis para download.

CARLOS ALBERTO ESTOMBELO MONTESCO

“Método de análise de componentes dependentes para o processamento, caracterização e extração de componentes de sinais biomédicos”

Tese apresentada à Faculdade de Filosofia, Ciências e Letras de Ribeirão Preto da USP, como parte das exigências para a obtenção do título de Doutor em Ciências, Área: Física Aplicada à Medicina e Biologia.

Orientador: Prof. Antônio Carlos Roque da Silva Filho

Assessor: Prof. Dráulio Barros de Araújo

RIBEIRÃO PRETO -SP

2007

FICHA CATALOGRÁFICA

Estombelo-Montesco, Carlos Alberto

Método de análise de componentes dependentes para o processamento, caracterização e extração de componentes de sinais biomédicos. Ribeirão Preto, 2007.

74 p. : il. ; 30cm

Tese de Doutorado, apresentada à Faculdade de Filosofia, Ciências e Letras de Ribeirão Preto da USP. Área de concentração: Física Aplicada à Medicina e Biologia.

Orientador: Antônio Carlos Roque da Silva Filho.

1. Extração de componentes. 2. MCGf. 3. MGG. 4. fMRI. 5. Processamento de sinais biomédicos.

*Dedico este trabalho a Eliana e Thiago, meus grandes
amores, por sua compreensão, seu amor, seu carinho, sua
presença e apoio durante todo este tempo.*

AGRADECIMENTOS

Ao Prof. Antônio Carlos Roque pela oportunidade de realização do meu doutorado e acreditar no meu trabalho no Departamento de Física e Matemática da Faculdade de Filosofia Ciências e Letras de Ribeirão Preto da USP. Esta oportunidade contribuiu para meu crescimento científico e intelectual.

Ao Prof. Dráulio Barros de Araújo pela assessoria durante todo este tempo, discussões, atenção e apoio científico durante o desenvolvimento do trabalho.

Ao Prof. Oswaldo Baffa e ao Prof. Eder Rezende Moraes pelas contínuas discussões e contribuições realizadas durante o trabalho com o objetivo de aprimorar este trabalho de pesquisa.

Ao Prof. Allan Kardec Barros, da Universidade Federal do Maranhão, por sua disposição em colaborar com o trabalho e mostrar sua experiência científica.

A minha família, Eliana e Thiago, minhas maiores alegrias, pelo apoio, amor e compreensão.

A minha família que esta longe, meu pai Andrés, minha mãe Eufemia, meu irmão Richard, Eduardo, Renata, meu sogro Albino, e a mãe da minha esposa Isabel, que sempre me apoiaram e acreditaram na realização deste Doutorado.

A todos os amigos do Departamento de Física e Matemática que proporcionaram momentos agradáveis e produtivos.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela concessão da bolsa de Doutorado.

RESUMO

Um objetivo importante na área de processamento de sinais biomédicos é a extração de informação baseada em um conjunto de medidas feitas ao longo do tempo. Em boa parte dos casos, sinais biomédicos são medidas eletromagnéticas. Essas medidas (geralmente feitas com aparelhos multicanais) são registradas usando sensores distribuídos espacialmente pelo corpo humano, dando origem a um conjunto de dados correlacionados no tempo e/ou no espaço. Os sinais de interesse raramente são registrados de forma isolada, mas observados como uma mistura de outros sinais (sobrepostos) espúrios, de ruído e artefatos fisiológicos ou ambientais. Além do mais, a relação sinal-ruído é geralmente baixa. Em várias aplicações um grande número de sensores está disponível, mas somente algumas das fontes são de interesse, o restante pode ser considerado ruído. Para esse tipo de aplicações é necessário desenvolver algoritmos de aprendizagem confiáveis, robustos e efetivos que permitam extrair somente um pequeno número de fontes que sejam potencialmente de interesse e que contenham informações úteis. A estratégia aqui utilizada para extração é aplicado em três importantes problemas da área de processamento de sinais biomédicos: (1) detecção do sinal do feto em magnetocardiografia fetal (MCGf); (2) detecção da atividade de resposta elétrica do estômago em magnetogastrografia (MGG); e (3) detecção de regiões ativas do cérebro em experimentos de imagens por ressonância magnética funcional (*Functional Magnetic Resonance Imaging*, fMRI). Os resultados, nos três casos estudados, mostraram que o método utilizado como estratégia é efetivo e computacionalmente eficiente na extração dos sinais desejados.

ABSTRACT

An important goal in biomedical signal processing is the extraction of information based on a set of physiological measurements made along time. Generally, biomedical signals are electromagnetic measurements. Those measurements (usually made with multichannel equipment) are registered using spatially distributed sensors around some areas of the human body, originating a set of time and/or space correlated data. The signals of interest are rarely registered alone, being usually observed as a mixture of other spurious, noisy signals (sometimes superimposed) and environmental or physiological artifacts. More over, the signal-to-noise ratio is generally low. In many applications, a big number of sensors are available, but just a few sources are of interest and the remainder can be considered noise. For such kind of applications, it is necessary to develop trustful, robust and effective learning algorithms that allow the extraction of only a few sources potentially of interest and that hold useful information. The strategy used here for extraction of sources is applied in three important problems in biomedical signal processing: (1) detection of the fetal magnetocardiogram signal (fMCG); (2) detection of the electrical activity of the stomach in magnetogastrograms (MGG); and (3) detection of active regions of the brain in experiments in functional Magnetic Resonance Imaging (fMRI). The results, within the three cases of study, showed that the DCA method used as strategy is effective and computationally efficient on extraction of desired signals.

ÍNDICE GERAL

CAPÍTULO 1. INTRODUÇÃO	13
1.1. CONTEXTUAIZAÇÃO E MOTIVAÇÃO	13
1.2. OBJETIVOS.....	15
1.3. ORGANIZAÇÃO.....	15
CAPÍTULO 2. REFERENCIAL TEÓRICO	17
2.1. BIOMAGNETISMO E SINAIS BIOMAGNÉTICOS.....	17
2.2. MAGNETOCARDIOGRAFIA FETAL	18
2.3. MAGNETOGASTROGRAFIA.....	19
2.4. IMAGEM FUNCIONAL POR RESSONÂNCIA MAGNÉTICA (fMRI)	20
CAPÍTULO 3. ANÁLISE DE COMPONENTES.....	22
3.1. ANÁLISE DE COMPONENTES INDEPENDENTES	22
3.1.1. <i>Modelo estatístico e definição</i>	22
3.1.2. <i>Ambigüidades do modelo</i>	26
3.1.3. <i>Separação cega de fontes</i>	27
3.1.4. <i>Limitações da ACI</i>	30
3.1.5. <i>Necessidade de pré-processamento</i>	30
3.2. ANÁLISE DE COMPONENTES DEPENDENTES	33
3.2.1. <i>Separação da fonte pela ACD</i>	34
3.2.2. <i>Algoritmo de aprendizagem</i>	36
3.2.3. <i>Evitando o problema da Permutação</i>	37
3.2.4. <i>Evitando o problema de escalamento</i>	37
3.3. MODELO AUTO-REGRESSIVO.....	39
3.3.1. <i>Escolha da ordem do modelo</i>	40
3.4. TRANSFORMADA DE WAVELET	41
3.4.1. <i>Transformada de Morlet</i>	43
CAPÍTULO 4. COMPONENTE FETAL A PARTIR DE MAGNETOCARDIOGRAMAS.....	47
4.1. MATERIAL E MÉTODOS	47
4.2. RESULTADOS.....	47
CAPÍTULO 5. COMPONENTES GÁSTRICOS A PARTIR DE MAGNETOGASTROGRAMAS.....	51
5.1. MATERIALES E MÉTODOS	51
5.2. RESULTADOS.....	57
CAPÍTULO 6. COMPONENTE AUDITIVO A PARTIR DE DADOS DE fMRI	64
6.1. MATERIAL E MÉTODOS	64
6.2. RESULTADOS.....	69
CAPÍTULO 7. DISCUSSÃO E CONCLUSÕES	71

LISTA DE FIGURAS

FIGURA 1 : DIAGRAMA DE BLOCOS DA ESTIMAÇÃO DA ACI.....	24
FIGURA 2 : APLICAÇÃO DO SISTEMA DE MISTURA A E DO SEU INVERSO W (FERREIRA 2002).....	25
FIGURA 3 : APLICAÇÃO DA ACI AO PROBLEMA DA SCF. A FIGURA MOSTRA OS SINAIS NO DOMÍNIO DO TEMPO E SUAS CONCRETIZAÇÕES CONJUNTAS. NO TOPO MOSTRAM-SE AS DUAS COMPONENTES INDEPENDENTES s_1 E s_2 ; NO MEIO, CONSTAM AS DUAS OBSERVAÇÕES x_1 E x_2 , CUJAS CONCRETIZAÇÕES CONJUNTAS FORMAM UM PARALELOGRAMO DE ARESTAS PARALELAS ÀS RETAS DEFINIDAS PELAS COLUNAS DA MATRIZ A ; EM BAIXO, MOSTRAM-SE AS COMPOENNETES ESTIMADAS \hat{s}_1 E \hat{s}_2	29
FIGURA 4 : DIAGRAMA DE BLOCOS DA ACI; DETALHE SOBRE O PRÉ-PROCESSAMENTO.....	33
FIGURA 5 : MODELO PARA O NEURÔNIO QUE INCLUI UMA REFERENCIA INTERNA (OU PADRÃO)(BARROS AND CICHOCKI 2002).	34
FIGURA 6 : QUATRO <i>WAVELETS</i> DE MORLET DIFERENTES. AS <i>WAVELETS</i> MOSTRADAS EM A), B) E C) SÃO AS QUE TÊM A MESMA “LARGURA”, \tilde{W} , NO CASO IGUAL A 7. A LARGURA DA BANDA ESPECTRAL SE AMPLIA QUANDO AS FREQUÊNCIAS SÃO AUMENTADAS. ISTO TAMBÉM PODE SER OBSERVADO QUANDO O ENVELOPE DA <i>WAVELET</i> SE TORNA MAIS AGUDO. POR OUTRO LADO, QUANDO \tilde{W} É DIVIDA PELA METADE O NÚMERO DE OSCILAÇÕES DA <i>WAVELET</i> TAMBÉM É DIVIDIDO PELA METADE, O QUE PODE SER OBSERVADO EM D). A LINHA SÓLIDA É A PARTE REAL DA <i>WAVELET</i> COMPLEXA, E A LINHA TRACEJADA É A PARTE IMAGINARIA.	45
FIGURA 7 : DEZ SEGUNDOS DE DADOS OBSERVADOS, PARA 5 DOS 37 CANAIS DE MCGF REGISTRADOS. OS REGISTROS MOSTRAM OS SINAIS DA MÃE E DO FETO SUPERPOSTOS.	48
FIGURA 8 : ESPECTRO DE POTÊNCIA DE UM REGISTRO SIMPLES. DOIS PICOS CORRESPONDENTES À COMPONENTE FETAL E À COMPONENTE DA MÃE SÕ OBSERVADOS.	49
FIGURA 9 : COMPONENTES SEPARADAS DO MCG DA MÃE (A) E DO MCG FETAL (B), OBTIDAS POR FASTICA, E DO MCG FETAL (C) EXTRAÍDO POR ACD BASEADO NA ANÁLISE ESPECTRAL AUTO-REGRESSIVA.	50
FIGURA 10 : DIAGRAMA ILUSTRATIVO DO MÉTODO APLICADO. (A) CADA FONTE (ESTÔMAGO, CORAÇÃO, TECIDO, ARTEFATOS, ETC) PRODUZ UM SINAL MAGNÉTICO, NA PRÁTICA NÃO OBSERVADOS DIRETAMENTE. (B) OS SINAIS DE CADA FONTE SÃO MISTURADOS (LINEARMENTE, POR HIPÓTESE) COM OS DAS OUTRAS FONTES E A MISTURA É REPRESENTADA PELO BLOCO DENOMINADO “PROCESSO DE MISTURA”. (C) OS SINAIS ADQUIRIDOS POR CADA CANAL DO MAGNETÔMETRO SÃO, NA VERDADE, MISTURAS DOS SINAIS ORIGINAIS. (D) APÓS A AQUISIÇÃO DOS SINAIS MISTURADOS REALIZA-SE A SEPARAÇÃO/EXTRAÇÃO DA FONTE DE INTERESSE ATRAVÉS DO PROCESSO DE ACD. (E) FINALMENTE, NA SAÍDA HÁ UMA ÚNICA SÉRIE TEMPORAL DETERMINADA A MENOS DE UM FATOR DE ESCALA QUE PRECISA SER CALCULADO PARA SE ESTIMAR SUA AMPLITUDE RELATIVA. ESTES PASSOS FORAM APLICADOS PARA AS TRÊS ÉPOCAS MEDIDAS: A PRÉ-PRANDIAL E AS DUAS PÓS-PRANDIAIS.	52
FIGURA 11 : O PAINEL SUPERIOR MOSTRA O SINAL CORRESPONDENTE AO REB OBSERVADO ORIGINALMENTE APÓS A DECIMAÇÃO, SEM QUALQUER OUTRO TIPO DE PROCESSAMENTO. O PAINEL INFERIOR MOSTRA O ESPECTRO DE POTÊNCIA DO SINAL DO PAINEL SUPERIOR, INDICANDO CLARAMENTE O SINAL REB EM 0,05 Hz (3 CPM.).....	53
FIGURA 12 : O PAINEL SUPERIOR MOSTRA A SÉRIE TEMPORAL ORIGINAL DA ÉPOCA PRÉ-PRANDIAL APÓS DECIMAÇÃO E FILTRAGEM DAS FREQUENCIAS BAIXAS. O PAINEL INFERIOR MOSTRA O ESPECTRO DE POTENCIA DA AER DOS REGISTROS DA ÉPOCA PRÉ-PRANDIAL MOSTRADOS NO PAINEL ACIMA. O SINAL AER TEM UMA FRACA ENERGIA COMPARADO À COMPONENTE DO CORAÇÃO NAS ALTAS FREQUENCIAS.	54
FIGURA 13 : O PAINEL SUPERIOR MOSTRA O SINAL ORIGINAL DA PRIMEIRA ÉPOCA PÓS-PRANDIAL, APÓS DECIMAÇÃO E FILTRAGEM DAS FREQUENCIAS BAIXAS. O PAINEL INFERIOR MOSTRA O ESPECTRO DE POTÊNCIA DESTA SINAL, COM UM FORTE PICO EM TORNO DE 1,5 Hz ASSOCIADO AO RITMO CARDÍACO E COM O PICO DA ARE EM TORNO DE 0,8 Hz, MUITO MAIS INTENSO DO QUE NO CASO PRÉ-PRANDIAL.....	55
FIGURA 14 : SINAIS DO REB (LINHA PONTILHADA) E DA ARE (LINHA SÓLIDA) EXTRAÍDOS USANDO A ACD. (A) COMPONENTES EXTRAÍDAS NA ÉPOCA PRÉ-PRANDIAL, (B) E (C) COMPONENTES EXTRAÍDAS PARA A PRIMEIRA ÉPOCA PÓS-PRANDIAL E PARA A SEGUNDA ÉPOCA PÓS-PRANDIAL, RESPECTIVAMENTE. DO LADO DIREITO MOSTRA-SE A ESCALA USADA PARA O SINAL DO REB E, DO LADO ESQUERDO, MOSTRA-SE A ESCALA USADA PARA O SINAL DA ARE. O	

SINAL DO REB CONSISTE DE UM <i>UPSTROKE</i> SEGUIDO POR UM PLATÔ E, POSTERIORMENTE, PELA FASE DE DESPOLARIZAÇÃO LENTA COM UMA FREQUÊNCIA APROXIMADA DE 3 CPM. NOTE A DIFERENCIA DE AMPLITUDE ENTRE O SINAL DO REB NA ÉPOCA PRÉ-PRANDIAL E O SINAL DA ARE NAS DUAS ÉPOCAS PÓS-PRANDIAIS. A ESCALA DO EIXO <i>x</i> ESTÁ EM SEGUNDOS.	58
FIGURA 15: CONTRIBUIÇÕES DOS CANAIS PARA O SINAL DO REB EXTRAÍDO PELA ACD. (A) MAPA DE CONTORNO DO SINAL DO REB NA ÉPOCA PRE-PRANDIAL. (B) MAPA DE CONTORNO DO SINAL DO REB DE UMA ÉPOCA PÓS-PRANDIAL. NESSAS ÉPOCAS, A ENERGIA INTENSA DA ONDA LENTA ESTÁ PRESENTE O TEMPO TODO.	59
FIGURA 16: CONTRIBUIÇÕES DOS CANAIS PARA O SINAL DA ARE EXTRAÍDA POR ACD. (A) MAPA DE CONTORNO PARA O SINAL DA ARE NA ÉPOCA PRE-PRANDIAL. NESSA ÉPOCA É ESPERADO QUE A ARE NÃO APRESENTE CONTRIBUIÇÃO, POIS NA ÉPOCA PRE-PRANDIAL NÃO HÁ CONTRAÇÕES. (B) MAPA DE CONTORNO PARA O SINAL DA ARE NA PRIMEIRA ÉPOCA PÓS-PRANDIAL, MOSTRANDO CLARAMENTE UMA MUDANÇA NO PADRÃO ESPACIAL.	59
FIGURA 17: INTERVALO DE TEMPO DURANTE A ÉPOCA PRÉ-PRANDIAL, COM AS COMPONENTES DO REB E DA ARE NO PAINEL SUPERIOR E A RTF DA COMPONENTE DA ARE NO PAINEL INFERIOR. A LINHA BRANCA CONTÍNUA SOBREPOSTA À RTF DO PAINEL INFERIOR É A SOMA DAS COMPONENTES DO REB E DA ARE. A ESCALA DO LADO ESQUERDO CORRESPONDE À COMPONENTE DA ARE E A ESCALA DO LADO DIREITO CORRESPONDE À COMPONENTE DO REB.	60
FIGURA 18: INTERVALO DE TEMPO DURANTE A PRIMEIRA ÉPOCA PÓS-PRANDIAL MOSTRANDO AS COMPONENTES DO REB E DA ARE. PODE-SE OBSERVAR OS POTENCIAIS DE AÇÃO ASSOCIADOS À COMPONENTE DA ARE NO PAINEL SUPERIOR, CORRESPONDENTES COM OS PONTOS LUMINOSOS NA RTF DO PAINEL INFERIOR, QUE ESTÃO EM FASE COM A COMPONENTE DO REB. A FREQUÊNCIA DA COMPONENTE DA ARE NA RTF VARIA DE 0,6 HZ. A 1,0 HZ. AS ESCALAS DESTA FIGURA SÃO SIMILARES ÀS DA FIGURA	61
FIGURA 19: INTERVALO DE TEMPO DURANTE A SEGUNDA ÉPOCA PÓS-PRANDIAL MOSTRANDO AS COMPONENTES DO REB E DA ARE. NOTE-SE QUE O SINAL DA ARE ESTÁ MAIS DISTRIBUIDO, TANTO NO TEMPO COMO NA FREQUÊNCIA, EMBORA MANTENHA-SE EM FASE COM A COMPONENTE DO REB.	61
FIGURA 20: ESPECTRO DE POTÊNCIA AUTO-REGRESSIVO DA COMPONENTE DA ARE DURANTE A ÉPOCA PRÉ-PRANDIAL E AS DUAS ÉPOCAS PÓS-PRANDIAIS, APÓS SUA EXTRAÇÃO PELO MÉTODO DA ACD. OS DADOS REFEREM-SE A UM SUJEITO. A INSERÇÃO MOSTRA O ÍNDICE CALCULADO PARA CADA ÉPOCA.	62
FIGURA 211: ESQUEMA DO PROTOCOLO EM BLOCOS USADO NO EXPERIMENTO. OS 64 PONTOS DO EIXO HORIZONTAL EQUIVALEM A 289,8 SEGUNDOS. OS PRIMEIROS 12,7 S FORAM UTILIZADOS PARA A CALIBRAÇÃO DO APARELHO.	65

LISTA DE TABELAS

TABELA 1: EFEITO DA "LARGURA", \tilde{W} , DA <i>WAVELET</i> DE MORLET NO SEU DESEMPENHO EM DIFERENTES FREQUÊNCIAS f_0 . $2\sigma_t$ É A DURAÇÃO DA <i>WAVELET</i> E $2\sigma_f$ É A LARGURA DA BANDA ESPECTRAL DA <i>WAVELET</i> NA FREQUÊNCIA EXISTENTE NA TABELA. DESSA FORMA, ESSES VALORES DETERMINAM O DESEMPENHO ÓTIMO DA <i>WAVELET</i>	46
TABELA 2: NO CASO DO REB (3 CPM), A TABELA MOSTRA O EFEITO DE \tilde{W} NA <i>WAVELET</i> DE MORLET PARA DIFERENTES FREQUÊNCIAS f_0 . NO PRESENTE TRABALHO, PARA O REB, O PARÂMETRO FOI CONFIGURADO COM O VALOR DE $\tilde{W} = 3,5$	56
TABELA 3 : PARA O CASO DA ARE A TABELA MOSTRA VÁRIOS CONFIGURAÇÕES DE VALORES DE \tilde{W} E f_0 PARA A <i>WAVELET</i> DE MORLET. NO CASO DA ARE, O PARÂMETRO FOI CONFIGURADO COM O VALOR DE $\tilde{W} = 21$	57
TABELA 4 : ÍNDICE PARA CADA ÉPOCA (ENTRE 0,5 Hz E 1,33 Hz) $\times 10^{51}$	63

CAPÍTULO 1. INTRODUÇÃO

1.1. CONTEXTUAIZAÇÃO E MOTIVAÇÃO

Um objetivo importante na área de processamento de sinais biomédicos é a extração de informação baseada em um conjunto de medidas feitas ao longo do tempo (**James and Hesse 2005**). Em boa parte dos casos, sinais biomédicos são medidas eletromagnéticas, embora outras quantidades físicas ou químicas possam também ser avaliadas. Essas medidas (geralmente feitas com aparelhos multicanais) são registradas usando sensores distribuídos espacialmente pelo corpo humano, dando origem a um conjunto de dados correlacionados no tempo e/ou no espaço.

Sabe-se que a informação inerente às medidas depende, geralmente, do domínio de aplicação (em que se devem considerar o número de sensores e suas posições). Os sinais de interesse raramente são registrados de forma isolada, mas observados como uma mistura de outros sinais espúrios, de ruído e artefatos fisiológicos ou ambientais. Além do mais, a relação sinal-ruído é geralmente baixa. Ainda, os dados contêm medidas, algumas vezes sobrepostas, que são geradas por fontes localizadas em diferentes partes do corpo humano.

Por outro lado, quando médicos e/ou especialistas observam sinais biomédicos (após um treinamento e pela própria experiência) eles procuram por diferentes padrões de atividade com alguma distribuição espacial (localização) em particular. Em outras palavras, poder-se-ia dizer que os médicos tentam descobrir e/ou desfazer a mistura observada, de forma visual. Seria, portanto, de grande benefício para os especialistas se fosse possível automatizar a análise de sinais biomédicos para realizar o seguinte:

- reverter a mistura e isolar um conjunto de sinais biomédicos em suas componentes constituintes, chamadas também de fontes;

- fornecer a informação sobre o número de fontes distintas que estão sendo observadas;
- fornecer uma distribuição espacial de acordo com a série temporal pertencente à fonte;
- rastrear as mudanças no número de fontes identificadas, suas distribuições espaciais assim como sua morfologia no transcurso do tempo.

Considerando o contexto relatado anteriormente, de forma geral este problema é conhecido como separação cega de fontes (*Blind Source Separation*, BSS), onde um tipo de solução é denominada na literatura como análise de componentes independentes (*Independent Component Analysis*, ICA), sendo esta, uma ferramenta que poderia oferecer soluções aos requerimentos listados acima. A ICA é uma técnica que, essencialmente, extrai um conjunto de fontes subjacentes ou componentes (independentes) a partir de um conjunto de variáveis aleatórias, medidas ou sinais. A técnica tipicamente utiliza grandes conjuntos de dados multivariados para definir um modelo para os dados observados. Essa técnica considera que as componentes são desconhecidas e estão misturadas linearmente, e tenta reverter o processo de mistura separando todas as fontes explorando a propriedade de sua independência.

Em várias aplicações um grande número de sensores está disponível, mas somente algumas das fontes são de interesse, o restante pode ser considerado ruído. Para esse tipo de aplicações é necessário desenvolver algoritmos de aprendizagem confiáveis, robustos e efetivos que permitam extrair somente um pequeno número de fontes que sejam potencialmente de interesse e que contenham informações úteis (**Barros et al. 2000**).

Barros e Cichoki (2001) propuseram um algoritmo alternativo à ICA para extrair apenas fontes de interesse em uma dada aplicação, deixando de lado os demais sinais. Para tanto, o método utiliza uma informação *a priori*, ligada aos componentes de frequência dos sinais de interesse.

1.2. OBJETIVOS

Nesta tese, o método proposto por Barros e Cichoki foi adaptado, recebendo o nome de análise de componentes dependentes (Dependent Component Analysis, DCA), e aplicado ao caso de separação de fontes em três importantes problemas da área de processamento de sinais biomédicos: (1) detecção do sinal do feto em magnetocardiografia fetal (MCGf) (**de Araujo et al. 2005**); (2) detecção da atividade de resposta elétrica do estômago em magnetogastrografia (MGG) (**Estombelo-Montesco et al. 2007a**); e (3) detecção de regiões ativas do cérebro em experimentos de imagens por ressonância magnética funcional (*Functional Magnetic Resonance Imaging*, fMRI) (**Estombelo-Montesco et al. 2007b**).

Em resumo, os objetivos deste trabalho são os seguintes:

- Propor o método de análise de componentes dependentes para auxiliar na extração das componentes de interesse a partir de medidas multivariadas;
- Caracterizar as componentes extraídas através de representações em termos de tempo e de frequência e do espectro de potência;
- Aplicar o método e avaliar as componentes de interesse extraídas no contexto real da MCGf;
- Aplicar o método e avaliar as componentes de interesse extraídas no contexto real da MGG;
- Aplicar o método e avaliar as componentes de interesse extraídas no contexto real de fMRI.

Os resultados das aplicações feitas indicam que o método aqui proposto é eficaz nas aplicações feitas, o que indica seu potencial para aplicações clínicas.

1.3. ORGANIZAÇÃO

Esta tese está organizada de forma a apresentar o contexto teórico no qual está inserida, bem como resultados obtidos e suas contribuições para a comunidade acadêmica.

No **Capítulo 2** é mostrado um referencial teórico de biomagnetismo e sinais biomagnéticos, assim como brevemente é descrito a magnetocardiografia fetal, a magnetogastrografia e a imagem funcional por ressonância magnética

No **Capítulo 3** são apresentados os conceitos de análise de componentes independentes, análise de componentes dependentes (método estartégico dessa tese) e outros métodos que auxiliaram na caracterização e processamento dos sinais como são o modelo autoregressivo e a representação tempo-frequencia.

No **Capítulo 4** é mostrada uma aplicação do método proposto na área de magnetocardiograma fetal. Aqui a aplicação se concentra na extração da componente fetal considerando a componente materna e o ruído existente no ambiente ou outros artefatos originados de outros órgãos.

No **Capítulo 5** é mostrada uma segunda aplicação na área de magnetogastrografia. Onde a existência de componentes (obtidas como uma mistura de componentes), uma de baixa freqüência e outra de alta freqüência tem caraterísticas em comum quando é medida a atividade elétrica no pré e pós prandial.

No **Capítulo 6** é mostrada uma aplicação na área de imagens por ressonância magnética funcional, onde é os dados são obtidos de um voluntário após realizar uma tarefa auditiva, aqui também se concentra na extração de somente a componente relacionada com a tarefa auditiva e sua localização no cérebro, indicando quais áreas se ativam na realização dessa tarefa.

Finalmente, no **Capítulo 7**, são apresentadas as conclusões desta tese.

CAPÍTULO 2. REFERENCIAL TEÓRICO

2.1. BIOMAGNETISMO E SINAIS BIOMAGNÉTICOS

O biomagnetismo é a área de pesquisa que procura medir e analisar os campos magnéticos produzidos pelos órgãos do corpo humano (**Carneiro et al. 2000**). De maneira geral, os seus objetivos consistem em buscar um maior entendimento sobre os processos fisiológicos dos diversos órgãos do corpo humano e em desenvolver e aprimorar técnicas de diagnóstico não-invasivas e eficientes.

Os campos magnéticos produzidos pelo corpo humano são muito fracos e estão na faixa de 10^{-9} a 10^{-14} T. Para comparação, o campo magnético da Terra é da ordem de 10^{-4} T. A faixa de frequência desses campos vai de zero (DC) a alguns KHz (**Carneiro et al. 2000**).

O corpo produz campos magnéticos associados às correntes elétricas iônicas geradas pela atividade de despolarização de suas células ou por partículas ferromagnéticas ou paramagnéticas localizadas em seus órgãos. Substâncias magnéticas (marcadores magnéticos) ingeridas ou injetadas no corpo também produzem campos magnéticos. A partir de medições desses campos pode-se localizar com precisão a região que os produz e determinar as características das fontes associadas, isto é, a intensidade de corrente ou a concentração de materiais paramagnéticos ou ferromagnéticos (**Carneiro et al. 2000**).

Os campos magnéticos de maior intensidade produzidos pelo corpo podem ser medidos por um dispositivo chamado de magnetômetro de fluxo saturado, ou *fluxgate* em inglês. A maior parte dos campos, no entanto, por serem de baixíssima intensidade, são medidos com um dispositivo criogênico extremamente sensível denominado dispositivo superconductor de interferência quântica, ou SQUID da sigla em inglês (**Carneiro et al. 2000**).

2.2. MAGNETOCARDIOGRAFIA FETAL

Dentre as aplicações do biomagnetismo, a magnetocardiografia (MCG) – ou seja, a que se interessa por medir os campos magnéticos gerados pelo coração – é uma das mais importantes em virtude da grande incidência de doenças cardiovasculares na população (**Comani et al. 2004**). Os sinais do coração (da ordem de alguns picoteslas) são medidos por sensores SQUID posicionados acima da pele e fornecem informações sobre as fontes de atividade elétrica cardíaca sem a necessidade de fixação de eletrodos na pele do paciente como no caso de medidas eletrofisiológicas convencionais (**Carneiro et al. 2000**).

A magnetocardiografia fetal (MCGf) é a sub-área da MCG voltada para a medida dos campos magnéticos gerados pelo coração do feto. Neste caso, os sensores SQUID são posicionados sobre o abdômen da mãe. A MCGf apresenta grandes vantagens em comparação à eletrocardiografia fetal (ECGf) devido aos seguintes fatos: os sinais obtidos por eletrodos sofrem muita interferência do coração da mãe; os sinais elétricos têm uma baixa relação sinal/ruído; e a pele do feto passa a ser envolvida, a partir da vigésima quinta semana de gestação, por uma substância de baixa condutividade elétrica, denominada *vernix caseosa*, que atua como isolante elétrico (**de Araujo et al. 2005**).

Os campos magnéticos produzidos pelo coração de um feto são mais fracos que os de sua mãe e estão sujeitos a diferentes tipos de interferência, desde o sinal cardíaco da mãe até os gerados pela respiração da mãe e pelos movimentos do próprio feto. Além disso, devido ao pequeno volume do coração fetal e de seu distanciamento dos sensores, as medidas dos sinais magnéticos fetais exigem uma ótima relação sinal-ruído. A MCGf apresenta uma boa relação sinal-ruído durante todo o período de gestação e permite uma ótima definição da forma de onda, o que a torna excelente para acompanhar a atividade cardíaca de fetos (**Baffa et al. 1995**).

Outra vantagem da MCGf é que ela pode ser usada a partir da décima quinta semana de gestação, muito antes da ECGf (**de Araujo et al. 2005**), o que permite a detecção precoce de anomalias congênitas e, graças aos modernos procedimentos cirúrgicos, torna possível uma intervenção antes mesmo do nascimento do feto (**Carneiro et al. 2000**).

2.3. MAGNETOGASTROGRAFIA

Assim como no caso do coração, as contrações dos músculos da parede do estômago durante a digestão produzem campos elétricos que podem ser medidos por eletrodos posicionados sobre a pele. A técnica associada a essas medidas é conhecida como eletrogastrografia (EGG) (**Carneiro et al. 2000**). Ainda de maneira similar ao caso do coração, a atividade elétrica estomacal também produz campos magnéticos que podem ser medidos, por exemplo, por sensores SQUID, resultando na técnica denominada de magnetogastrografia (MGG) (**Carneiro et al. 2000**).

O uso da MGG pode vir a oferecer mais informações sobre a atividade do estômago do que a EGG. Os sinais magnéticos são menos afetados pela condutividade elétrica do tecido do que os sinais elétricos e dependem mais fortemente da distância entre a fonte e o detector do que os sinais elétricos (**Andrä and Nowak 2006**). Isso faz com que a MGG forneça uma melhor resolução espacial do que a EGG (**Carneiro et al. 2000**).

A atividade elétrica gástrica é constituída por duas componentes: um ritmo elétrico de base, não necessariamente associado aos movimentos de contração estomacal, que se manifesta como uma onda elétrica lenta (com frequência de três ciclos por minuto em humanos) e uma atividade de resposta elétrica, que ocorre em conjunção com os movimentos de contração estomacal e que é caracterizada por potenciais de ação durante a fase de platô do ritmo elétrico de base (**Irimia et al. 2006**).

A detecção e a caracterização da atividade de resposta elétrica são consideradas de grande importância em gastroenterologia e a MGG tem potencial para oferecer uma importante

contribuição nesta área, por ser uma técnica não-invasiva. Os principais problemas para a detecção da atividade de resposta elétrica por MGG decorrem do fato de que o sinal da atividade de resposta elétrica possui amplitude relativamente baixa e está sujeito a interferências de outros sinais corporais, por exemplo, cardíacos e respiratórios.

2.4. IMAGEM FUNCIONAL POR RESSONÂNCIA MAGNÉTICA (fMRI)

O campo das neuroimagens funcionais tem sofrido um enorme progresso nos últimos anos. Imagens com resolução anatômica milimétrica e resolução temporal da ordem de milisegundos possibilitam, de forma não-invasiva, a caracterização espaço-temporal de uma gama de processos cognitivos, bem como a sua utilização em algumas rotinas clínicas (**de Araujo 2002**).

O princípio da imagem funcional por ressonância magnética (fMRI)¹ para o mapeamento de regiões cerebrais ativas é relativamente simples. As informações de interesse clínico obtidas através da fMRI são, geralmente, alcançadas através da diferença entre imagens que refletem dois estados de atividade cerebral distintos: de atividade e de repouso. Quando as células nervosas do cérebro estão ativas, elas consomem o oxigênio presente nas moléculas de hemoglobina dos glóbulos vermelhos do sangue. Por causa disso, quando ocorre um aumento de atividade em uma dada região do cérebro ocorre também um aumento do fluxo sanguíneo para essa região, com um correspondente aumento local no consumo de oxigênio. Isso causa alterações ao longo do tempo nas concentrações relativas de oxihemoglobina e deoxi-hemoglobina (respectivamente, as formas oxigenada e a não-oxigenada da molécula de hemoglobina) no local do aumento de atividade cerebral. A oxihemoglobina é diamagnética e a deoxi-hemoglobina é paramagnética e essa diferença faz com que elas possuam susceptibilidades magnéticas distintas. Quando ocorre uma alteração na susceptibilidade magnética em uma dada região do cérebro, o tempo de relaxação

característico do tecido em resposta a uma seqüência apropriada de pulsos de rádio-freqüência também se altera. Isso provoca uma alteração no contraste das imagens denominada de efeito BOLD (*blood oxygen level dependent*)². Técnicas de aquisição rápida de imagens permitem explorar o efeito BOLD para se obter uma visualização de muitos padrões de atividade cerebral (**de Araujo 2002**).

Devido ao fato de as alterações nos contrastes das imagens serem tênues, nos exames de fMRI costuma-se obter imagens repetidas de uma mesma região cerebral. Por causa disso, é essencial que se consiga fazer uma aquisição rápida das imagens, o que reduz a duração do exame e minimiza a possibilidade de movimentos involuntários do paciente durante sua execução. Além disso, uma alta amostragem das condições de atividade e de repouso aumenta as chances de detecção do sinal relativo à tarefa específica. É, portanto, importante que os exames sejam efetuados por seqüências rápidas de pulsos.

¹ Por ser de uso já consagrado em nosso idioma, adota-se aqui a sigla em inglês para representar o termo “imagem funcional por ressonância magnética”.

² Este é mais um dos poucos casos nesta tese em que se usa a sigla em inglês para denotar um termo que, em português, seria contraste “dependente no nível de oxigênio no sangue” (DNOS).

CAPÍTULO 3. ANÁLISE DE COMPONENTES

3.1. ANÁLISE DE COMPONENTES INDEPENDENTES

O presente capítulo introduz o conceito de análise de componentes independentes (ACI), fornecendo o suporte teórico e a terminologia utilizada ao longo do texto. Mostra-se o modelo estatístico, sobre o qual a ACI se baseia, juntamente com a sua definição, respectivas ambigüidades e suas conseqüências. Por fim, mostra-se um exemplo de aplicação da ACI a sinais unidimensionais na resolução do problema da separação cega de fontes (SCF), que é usado para se identificar as restrições da ACI.

A notação matemática utilizada é a seguinte:

- Variáveis aleatórias são representadas por letras maiúsculas e as suas concretizações por letras minúsculas.
- Vetores aleatórios são representados por letras maiúsculas em negrito e as suas respectivas concretizações por letras minúsculas em negrito.

Dado que as matrizes também são representadas por letras maiúsculas em negrito, a notação adotada é ambígua com relação às representações de matrizes e vetores aleatórios. Esta ambigüidade é resolvida por indicação expressa no texto.

3.1.1. Modelo estatístico e definição

Seja $\mathbf{S} = [S_1, S_2, \dots, S_M]^T$ um vetor aleatório com M componentes/fontes estatisticamente independentes entre si. Por este motivo, as fontes S_i serão chamadas de componentes independentes (**Ferreira 2002**). Nesta situação, a função densidade de probabilidade (fdp) multivariada do vetor \mathbf{S} é dada pelo produto das M fdps marginais $p(S_i)$, de todas as componentes independentes:

$$p(\mathbf{S}) = \prod_{i=1}^M p(S_i) = p(S_1)p(S_2)\dots p(S_M). \quad (1)$$

Suponha que sobre o vetor \mathbf{S} seja aplicada uma transformação linear \mathbf{A} (sendo \mathbf{A} uma matriz de dimensão $N \times M$), obtendo-se o vetor aleatório $\mathbf{X} = [X_1, X_2, \dots, X_N]^T$ com N componentes X_i , designadas aqui de observações:

$$\mathbf{X} = \mathbf{AS}. \quad (2)$$

O processo de mistura das fontes primárias S_i pode ter diferentes modelos físicos ou matemáticos, dependendo das aplicações específicas. Para o presente trabalho, se considerará uma abordagem do tipo mistura linear como a definida pela Equação (2). Para simplificar a apresentação considera-se, por ora, que $N = M$, ou seja, que o número de observações é igual ao número de fontes (portanto, a matriz \mathbf{A} é quadrada). Nestas condições, a Equação (2) pode ser escrita na forma (**James and Hesse 2005**):

$$\mathbf{X} = \begin{bmatrix} X_1 \\ X_2 \\ \vdots \\ X_M \end{bmatrix} = \begin{bmatrix} a_{11}S_1 + a_{12}S_2 + \dots + a_{1M}S_M \\ a_{21}S_1 + a_{22}S_2 + \dots + a_{2M}S_M \\ \vdots \\ a_{M1}S_1 + a_{M2}S_2 + \dots + a_{MM}S_M \end{bmatrix}. \quad (3)$$

Verifica-se que cada observação X_i é uma combinação linear das M componentes independentes S_j . Analisando as combinações lineares que formam as observações X_i , verifica-se que estas não são estatisticamente independentes entre si. Por seu turno, as componentes independentes S_j não são diretamente observáveis. De fato, tanto a matriz de mistura \mathbf{A} como as componentes independentes S_j são desconhecidas; apenas se conhece as observações X_i .

Os coeficientes da combinação linear que produz X_i constituem a linha i da matriz

\mathbf{A} :

$$X_i = a_{i1}S_1 + a_{i2}S_2 + \dots + a_{iM}S_M = \sum_{j=1}^M a_{ij}S_j, \quad \forall i \in \{1, \dots, M\}. \quad (4)$$

Seja $\mathbf{a}_i = [a_{i1}, \dots, a_{iM}]^T$ o vetor que contém os elementos da linha i da matriz \mathbf{A} . Desta forma, a observação X_i resulta do produto interno de \mathbf{a}_i por \mathbf{S} ,

$$X_i = \mathbf{a}_i^T \mathbf{S}. \quad (5)$$

Considerando o modelo descrito pela Equação anterior, que representa de fato a Equação (2), e dado que apenas se observam amostras do vetor \mathbf{X} , a estimação das componentes independentes \mathbf{S} , e/ou da matriz de mistura \mathbf{A} , é denominada de análise de componentes independentes (ACI). O problema que a ACI procura resolver é o de realizar essa estimação no caso mais geral possível: a independência estatística entre todas as fontes é a única condição imposta desde o início da sua formulação. A Figura 1 esquematiza o processo de estimação da ACI (Ferreira 2002).

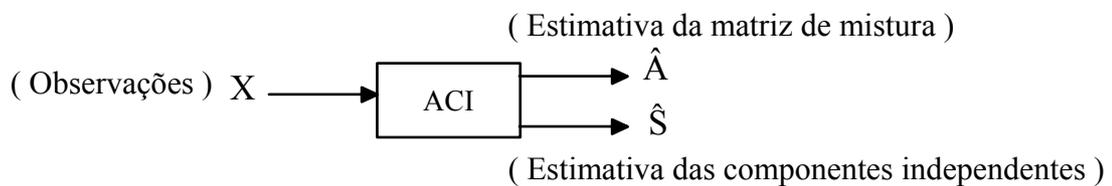


Figura 1 : Diagrama de blocos da estimação da ACI.

Analicamente, a ACI consiste em estimar a transformação linear \mathbf{W} que, quando aplicada às observações \mathbf{X} , produz componentes estatisticamente independentes:

$$\hat{\mathbf{S}} = \mathbf{W}\mathbf{X} = \mathbf{W}\mathbf{A}\mathbf{S} \quad (6)$$

Analisando-se a Equação (6), pode-se escrever uma outra definição para a ACI: “Encontrar um sistema linear de coordenadas não ortogonais \mathbf{W} que represente dados multivariados tal que a representação desses dados pelo sistema \mathbf{W} seja realizada por coeficientes estatisticamente independentes”. Após a estimação de \mathbf{W} obtém-se a matriz de

3.1.2. Ambigüidades do modelo

Analisando a Equação (3), onde se evidencia que cada observação X_i é uma combinação linear das componentes independentes, verifica-se que a mesma pode ser expressa na forma:

$$\mathbf{X} = \begin{bmatrix} X_1 \\ X_2 \\ \vdots \\ X_M \end{bmatrix} = \begin{bmatrix} a_{11} \\ a_{21} \\ \vdots \\ a_{M1} \end{bmatrix} S_1 + \begin{bmatrix} a_{12} \\ a_{22} \\ \vdots \\ a_{M2} \end{bmatrix} S_2 + \dots + \begin{bmatrix} a_{1M} \\ a_{2M} \\ \vdots \\ a_{MM} \end{bmatrix} S_M \quad (8)$$

A Equação (8) permite a constatação de duas ambigüidades sobre o modelo da ACI (**Comon 1994**):

1. Escalamento: as variâncias das componentes independentes não podem ser estimadas; de fato, efetuar a multiplicação das componentes independentes S_j por uma constante k e simultaneamente efetuar a divisão da respectiva coluna da matriz \mathbf{A} pela mesma constante, não altera nenhuma observação X_i ;
2. Permutação: a ordem das componentes independentes não pode ser estimada, dado que a troca da ordem dos termos da equação (8) não altera nenhuma observação X_i .

Combinando estas duas ambigüidades, pode-se então definir que as componentes independentes são estimadas a menos de um escalamento \mathbf{T} e de uma permutação \mathbf{R} ,

$$\mathbf{S} = \mathbf{TRWX} \quad (9)$$

Na Equação (9), \mathbf{R} é uma matriz de permutação, ou seja, para cada linha/coluna, existe apenas um elemento que vale 1 e não existem duas linhas/colunas iguais e \mathbf{T} é uma matriz de escalamento, com elementos diferentes de zero apenas ao longo da diagonal principal.

A chamada matriz de desempenho $\mathbf{P} = \mathbf{TR}$ traduz a qualidade de separação das componentes independentes. Essa matriz reflete as ambigüidades da estimação por ACI. Após uma reordenação e uma normalização, quanto mais próxima \mathbf{P} estiver da matriz identidade

\mathbf{I}_M , maior será a qualidade da separação. No caso em que se verifica $\mathbf{P} = \mathbf{I}_M$, sem reordenação nem normalização, tem-se a separação ideal (sem ambigüidades) das componentes de \mathbf{S} , ou seja, seguindo a ordem pela qual foram combinadas e sem fatores de escala.

Combinando-se as equações (2) e (9) tem-se:

$$\mathbf{S} = \mathbf{TRWAS} = \mathbf{PWAS}. \quad (10)$$

No caso ideal de separação, tem-se que $\mathbf{P} = \mathbf{I}_M$ implicando que a matriz estimada \mathbf{W} é exatamente a inversa de \mathbf{A} . Em termos gerais, as duas ambigüidades da ACI não têm grande impacto em suas aplicações atuais. O escalamento (multiplicação por constante) preserva o formato dos sinais. A ordem com que as componentes independentes (fontes) são estimadas não é importante porque o objetivo é recuperar as fontes.

3.1.3. Separação cega de fontes

As equações (6) e (7) e a Figura 2 estabelecem a ligação da ACI com o problema da separação cega de fontes (SCF) (**Ferreira 2002**). Por separação entende-se o processo de obter as fontes originais \mathbf{S} a partir do conjunto de observações \mathbf{X} . A separação é classificada como cega por dois motivos: não se assume conhecimento sobre as distribuições de probabilidade das fontes \mathbf{S} e a matriz de mistura \mathbf{A} também é desconhecida. A ACI é o método mais utilizado para realizar SCF, de tal forma que em alguns contextos da literatura estes termos são sinônimos. O desenvolvimento inicial da ACI tinha como objetivo resolver o problema da SCF.

Mostra-se agora um exemplo de SCF baseado no problema habitualmente designado por problema *cocktail-party*, cujo enunciado é o seguinte: “Em um salão existem pessoas conversando simultaneamente com uma música de fundo tocando. O som da sala é captado

por dois microfones em locais diferentes. Pretende-se separar os sinais de fala e música a partir das misturas captadas pelos dois microfones.” (Comon 1994)

Tendo em conta o modelo ACI, o problema *cocktail-party* é representado por:

$$\mathbf{X} = \begin{bmatrix} X_1 \\ X_2 \end{bmatrix} = \begin{bmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{bmatrix} \begin{bmatrix} S_1 \\ S_2 \end{bmatrix} = \begin{bmatrix} a_{11}S_1 + a_{12}S_2 \\ a_{21}S_1 + a_{22}S_2 \end{bmatrix}. \quad (6)$$

As constantes a_{ij} representam a atenuação/amplificação aplicada sobre as fontes S_1 e S_2 . A Figura 3, utilizando sinais artificiais, ilustra a aplicação da ACI na resolução deste problema e exemplifica as suas ambigüidades. Os sinais são mostrados no domínio do tempo, juntamente com suas concretizações conjuntas. Utilizou-se a seguinte matriz de mistura original:

$$\mathbf{A} = \begin{bmatrix} -1 & 1/2 \\ 1 & 1 \end{bmatrix} \quad (7)$$

Analisando a Figura 3 constata-se que S_1 e S_2 são independentes e que X_1 e X_2 não são independentes. As componentes são estimadas com exatidão, a menos de um fator de escala, devido às ambigüidades discutidas anteriormente. Nestas condições, a matriz de mistura estimada é:

$$\hat{\mathbf{A}} = \begin{bmatrix} -0.5003 & -0.9999 \\ -0.9996 & 1.0001 \end{bmatrix} \quad (8)$$

Comparando com a matriz de mistura original da equação (7), nota-se que as colunas estão trocadas, e que a primeira coluna da matriz $\hat{\mathbf{A}}$ está multiplicada por -1 , ou seja, a primeira componente estimada \hat{S}_1 sofreu inversão de fase, como se pode constatar pela observação dos sinais estimados na Figura 3.

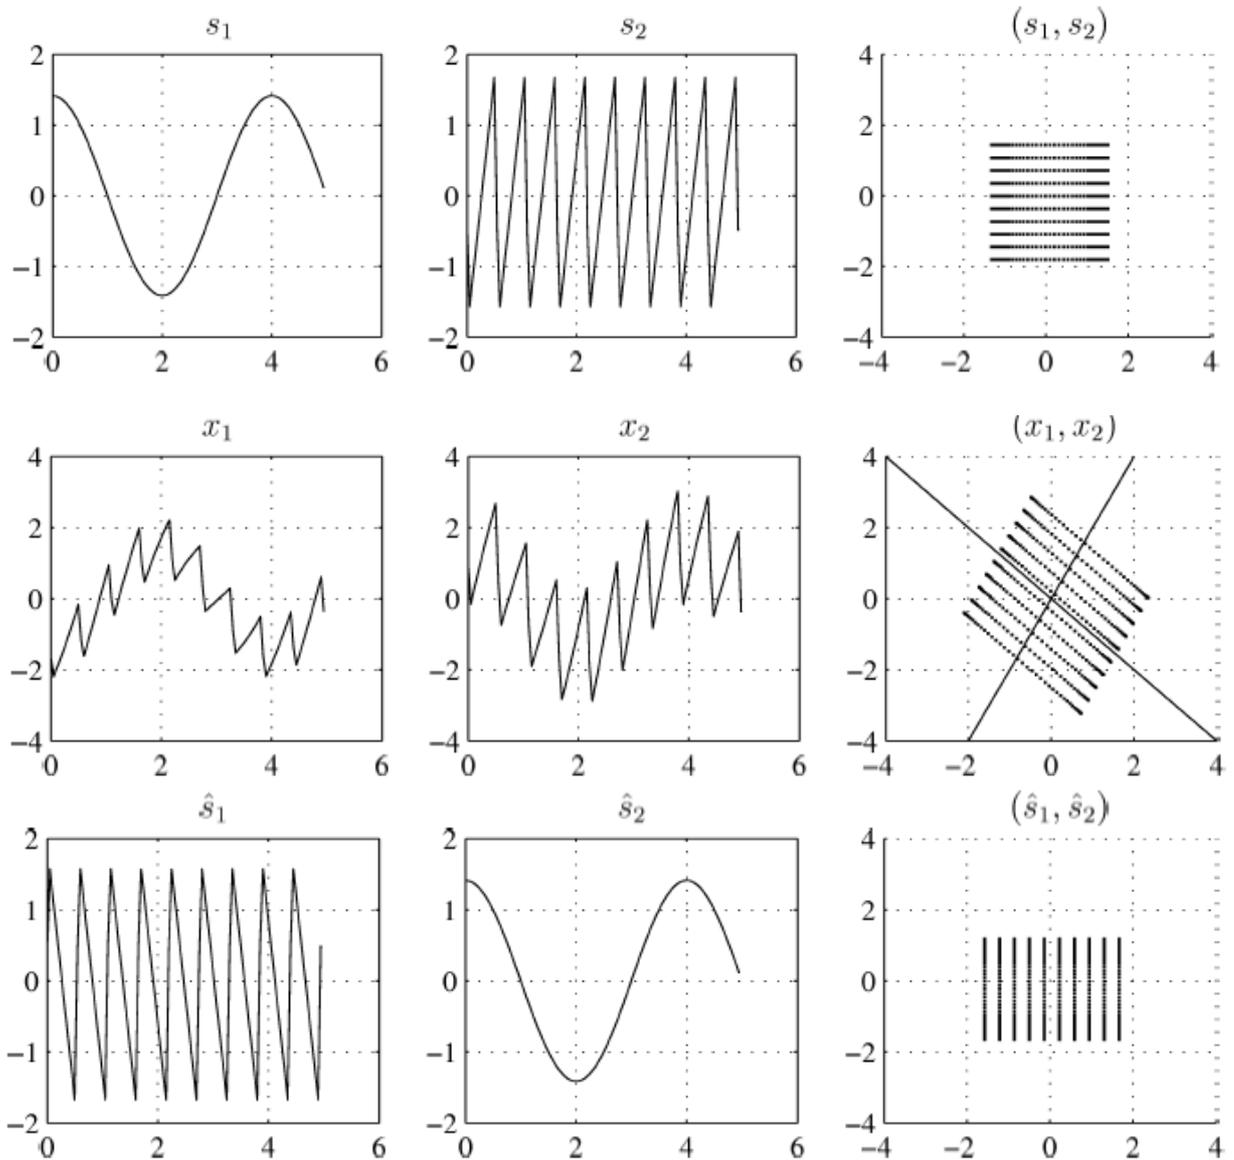


Figura 3 : Aplicação da ACI ao problema da SCF. A figura mostra os sinais no domínio do tempo e suas concretizações conjuntas. No topo mostram-se as duas componentes independentes s_1 e s_2 ; no meio, constam as duas observações x_1 e x_2 , cujas concretizações conjuntas formam um paralelogramo de arestas paralelas às retas definidas pelas colunas da matriz A ; em baixo, mostram-se as componentes estimadas \hat{s}_1 e \hat{s}_2 .

Em termos de separação de sinais de áudio, estas ambigüidades não constituem problema. A informação sobre a amplitude original perdeu-se, mas reconhecem-se ambos os sinais. Por outro lado, a inversão de fase não é notada pelo ouvido humano. A ordem de estimação não influencia o objetivo de obter os sinais separados. A matriz de desempenho \mathbf{P} , estimada nesta situação é:

$$\mathbf{P} = \begin{bmatrix} 0.0003 & 0.9999 \\ -0.9999 & 0.0002 \end{bmatrix} \approx \begin{bmatrix} 0 & 1 \\ -1 & 0 \end{bmatrix}. \quad (9)$$

Isso atesta que as duas componentes foram estimadas na ordem contrária àquela com que foram sobrepostas, além disso, a primeira está multiplicada por -1 .

3.1.4. Limitações da ACI

Na ACI procura-se, a partir de observações que não são independentes, estimar as componentes independentes que lhes deram origem e/ou a respectiva matriz de mistura. Estimadas as componentes independentes, a sua distribuição conjunta é fatorizada. No entanto, existem situações em que não é possível estimar as componentes independentes. No caso de as distribuições conjuntas das observações serem simétricas é impossível inferir informação sobre a matriz de mistura \mathbf{A} . Por exemplo, no caso dos exemplos anteriores as observações têm concretizações conjuntas na forma de paralelogramo cujas arestas são paralelas às retas definidas pelas colunas da matriz \mathbf{A} . Caso as observações não traduzam informação sobre a matriz de mistura é impossível estimá-la. Outra limitação da ACI está relacionada com a distribuição estatística das componentes independentes. No máximo, apenas uma componente independente pode ter distribuição normal.

3.1.5. Necessidade de pré-processamento

Em geral, a estimação das componentes independentes é simplificada (os algoritmos convergem mais rapidamente) se as observações \mathbf{X} possuírem média nula e estiverem branqueadas, isto é (Hyvarinen and Oja 2000):

- $E\{\mathbf{X}\} = 0$;
- $\mathbf{C}_X = \text{cov}(\mathbf{X}) = E\{\mathbf{X}\mathbf{X}^T\} = \mathbf{I}$

Na prática, o valor médio também pode ser estimado como uma componente independente. Ao transformar as observações para que tenham média nula, tem-se que as

componentes independentes também têm média nula, como se pode observar pelo modelo ACI da equação (2). Centrar as observações \mathbf{X} em torno do vetor valor médio $\mathbf{m}_x = E\{\mathbf{X}\}$ consiste em obter as novas observações:

$$\tilde{\mathbf{X}} = \mathbf{X} - \mathbf{m}_x \quad (10)$$

A imposição de média nula não afeta a matriz de mistura. Após a estimação da matriz de mistura \mathbf{A} e das componentes independentes \mathbf{S} com os dados centrados, repõe-se o valor médio das mesmas: $\mathbf{m}_s = \mathbf{A}^{-1}\mathbf{m}_x$.

Para realizar o branqueamento dos dados aplica-se uma transformação linear invertível \mathbf{V} , de forma que as observações $\mathbf{Z} = \mathbf{V}\tilde{\mathbf{X}}$ tenham matriz de covariância identidade, isto é, sejam incorrelacionadas com variância unitária:

$$\mathbf{C}_z = \text{cov}(\mathbf{Z}) = E\{\mathbf{Z}\mathbf{Z}^T\} = E\{\mathbf{V}\tilde{\mathbf{X}}(\mathbf{V}\tilde{\mathbf{X}})^T\} = \mathbf{V}E\{\tilde{\mathbf{X}}\tilde{\mathbf{X}}^T\}\mathbf{V}^T = \mathbf{I} \quad (11)$$

A matriz de covariância das observações $\tilde{\mathbf{X}}$, designada por $\mathbf{C}_{\tilde{\mathbf{X}}}$, é simétrica, de maneira que os seus autovetores são ortogonais entre si e os seus autovalores são reais. Assim, pode se escrever:

$$\mathbf{C}_{\tilde{\mathbf{X}}} = E\{\tilde{\mathbf{X}}\tilde{\mathbf{X}}^T\} = \mathbf{E}\mathbf{D}\mathbf{E}^T \quad (12)$$

Onde \mathbf{E} é uma matriz ortogonal cujas colunas são os autovetores normalizados de $E\{\tilde{\mathbf{X}}\tilde{\mathbf{X}}^T\}$ e $\mathbf{D} = \text{diag}(d_1, \dots, d_n)$ é matriz diagonal com os autovalores de $\mathbf{C}_{\tilde{\mathbf{X}}}$. O branqueamento é realizado através da transformação linear invertível não ortogonal:

$$\mathbf{V} = \mathbf{D}^{-\frac{1}{2}}\mathbf{E}^T \quad (13)$$

Tendo em conta a definição de \mathbf{V} e a decomposição em autovalores, apresentada na equação (12), tem-se:

$$\begin{aligned}
\mathbf{C}_Z &= \text{cov}(\mathbf{Z}) = E\{\mathbf{Z}\mathbf{Z}^T\} = E\{\mathbf{V}\tilde{\mathbf{X}}(\mathbf{V}\tilde{\mathbf{X}})^T\} = E\{\mathbf{V}\tilde{\mathbf{X}}\tilde{\mathbf{X}}^T\mathbf{V}^T\} \\
&= \mathbf{V}E\{\tilde{\mathbf{X}}\tilde{\mathbf{X}}^T\}\mathbf{V}^T = (\mathbf{D}^{-\frac{1}{2}}\mathbf{E}^T)(\mathbf{E}\mathbf{D}\mathbf{E}^T)(\mathbf{D}^{-\frac{1}{2}}\mathbf{E}^T)^T \\
&= \mathbf{D}^{-\frac{1}{2}}\underbrace{\mathbf{E}^T\mathbf{E}}_{\mathbf{I}}\underbrace{\mathbf{E}\mathbf{D}\mathbf{E}^T}_{\mathbf{I}}\mathbf{D}^{-\frac{1}{2}} = \mathbf{D}^{-\frac{1}{2}}\mathbf{D}\mathbf{D}^{-\frac{1}{2}} = \mathbf{I}
\end{aligned} \tag{14}$$

Contudo, \mathbf{V} não é a única matriz de branqueamento; qualquer matriz \mathbf{UV} em que \mathbf{U} seja ortogonal conduz ao mesmo resultado.

A utilidade da operação de branqueamento consiste na transformação da matriz de mistura \mathbf{A} , na matriz $\tilde{\mathbf{A}}$. Juntando as equações (2) e (13) e considerando que as observações têm média nula tem-se:

$$\mathbf{Z} = \mathbf{V}\tilde{\mathbf{X}} = \underbrace{\mathbf{V}\mathbf{A}}_{\tilde{\mathbf{A}}}\mathbf{S} = \mathbf{D}^{-\frac{1}{2}}\mathbf{E}^T\mathbf{A}\mathbf{S} = \tilde{\mathbf{A}}\mathbf{S}. \tag{15}$$

Dado que $\mathbf{C}_Z = \mathbf{I}$, temos:

$$\mathbf{I} = E\{\mathbf{Z}\mathbf{Z}^T\} = E\{\tilde{\mathbf{A}}\mathbf{S}(\tilde{\mathbf{A}}\mathbf{S})^T\} = \tilde{\mathbf{A}}E\{\mathbf{S}\mathbf{S}^T\}\tilde{\mathbf{A}}^T = \tilde{\mathbf{A}}\tilde{\mathbf{A}}^T = \mathbf{I}. \tag{16}$$

Ou seja, a nova matriz de mistura $\tilde{\mathbf{A}}$ é ortogonal. Desta forma, o branqueamento reduz o número de parâmetros a estimar, reduzindo o espaço de pesquisa às matrizes ortogonais. Em vez de estimar os n^2 parâmetros (elementos) de uma matriz de mistura genérica $n \times n$, é necessário estimar $\frac{n(n-1)}{2}$ parâmetros, dado que este é o número de graus de liberdade de uma matriz ortogonal. Para valores elevados de n , constata-se que se tem cerca de metade dos graus de liberdade dos de uma matriz arbitrária.

O branqueamento é uma forma adequada de reduzir a complexidade do problema da estimação das componentes independentes. Dado que, após o branqueamento, a matriz de covariância dos dados é diagonal, as estatísticas de segunda ordem ficam removidas, permitindo que o operador de ACI foque a sua análise nas estatísticas de ordem superior.

A Figura 4 ilustra as fases de pré-processamento e aplicação do operador de ACI, através de diagramas de blocos de todo o processo de estimação (Ferreira 2002).

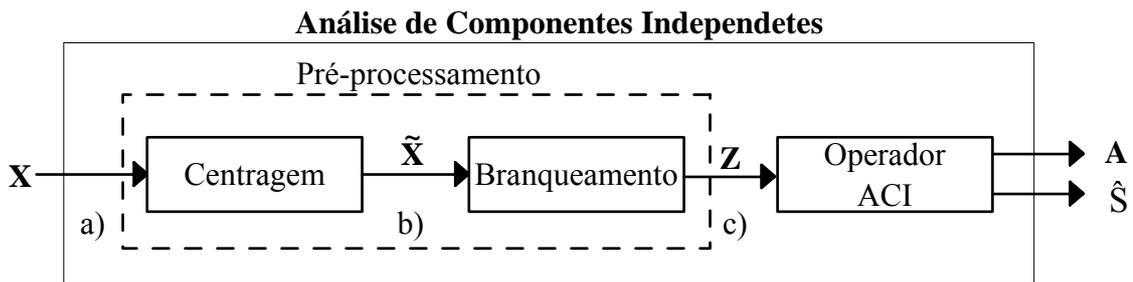


Figura 4 : Diagrama de blocos da ACI; detalhe sobre o pré-processamento.

De acordo com a notação introduzida na Figura 4 temos:

- a) As observações: \mathbf{X} .
- b) As observações centradas, com média nula e correlacionadas: $\tilde{\mathbf{X}} = \mathbf{X} - \mathbf{m}_x$.
- c) As observações branqueadas (centradas e incorrelacionadas com variância unitária):

$$\mathbf{Z} = \mathbf{V}\tilde{\mathbf{X}}.$$

3.2. ANÁLISE DE COMPONENTES DEPENDENTES

Neste trabalho, procura-se trabalhar com um algoritmo para SCF que incorpore estratégias para evitar os problemas de permutação e de ambigüidade possuídos pela ACI. Uma das características desejadas para o novo algoritmo é a de que ele também trabalhe com sinais não ortogonais (**Barros and Cichocki 2002**). Isto significa que se deve relaxar a suposição de independência estatística entre as fontes e sugere uma estratégia para diminuir a redundância, onde os sinais de saída devem ter uma medida de correlação cruzada mínima.

Para diferenciar o novo método da ACI, ele será chamado de análise de componentes dependentes (ACD) (**Barros and Cichocki 2002; de Araujo et al. 2005; Estombelo-Montesco et al. 2007b; Estombelo-Montesco et al. 2007a**).

Alguns algoritmos propostos na literatura usam a chamada aprendizagem do tipo ponto-fixo, em que se extrai um sinal de cada vez. O método de aprendizagem utilizado nesse trabalho segue esta idéia, sendo que a diferença está dada pela informação a priori requerida e

na extração da componente (função base) de forma direta em uma varredura dos dados. Isto é realizado através da entrada de uma referência interna, que como hipótese, assume-se ser da própria unidade processadora, ou neurônio, como é mostrado na Figura 5. Biologicamente falando, a entrada dessa referência pode ser um padrão que pertenceu previamente ao neurônio, devido a sua adaptação ao ambiente ou a características genéticas.

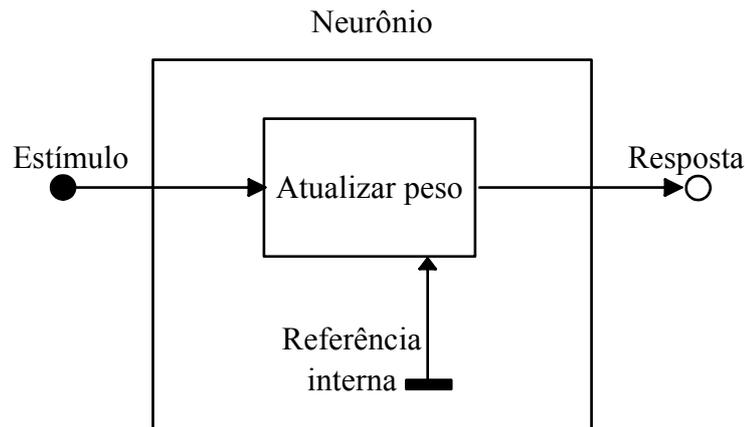


Figura 5 : Modelo para o neurônio que inclui uma referencia interna (ou padrão)(Barros and Cichocki 2002).

3.2.1. Separação da fonte pela ACD

Considerando que somente o vetor \mathbf{X} está disponível, assim como a necessidade de desenvolver algoritmos que consigam estimar as fontes primárias e/ou identificar a matriz de mistura \mathbf{A} com algumas ambigüidades intrínsecas (fatores de escalamento e permutação), pode-se observar na literatura duas abordagens principais para resolver o problema.

A primeira abordagem é a separação simultânea de todas as fontes primárias. Na segunda abordagem se considera a extração das fontes primárias uma a uma, sequencialmente, em vez de se extrair todas simultaneamente (Cichocki et al. 2002).

Em várias aplicações, um grande número de sensores está disponível, mas somente alguns dos sinais fonte são de interesse, o restante pode ser considerados como ruído de interferência. Um outro exemplo é o problema *cocktail-party*, onde usualmente é essencial extrair especificamente a voz de uma única pessoa, ao invés de separar todos os sinais fonte disponíveis a partir do vetor de sinais dos microfones. Para esse tipo de aplicações é

necessário desenvolver algoritmos de aprendizagem confiáveis, robustos e efetivos que permitam extrair somente um pequeno número de sinais fonte que sejam potencialmente de interesse e que contenham informação úteis (**Barros et al. 2000**).

Esse é o tipo de problema a ser trabalhado nesta tese: extrair somente um ou alguns sinais desejados (sinais de interesse), com determinadas características, em vez de extrair todas as fontes. Na continuação, descreve-se a estratégia proposta baseada no algoritmo de (**Barros and Cichocki 2001**). Este algoritmo constitui a base para o resto do trabalho, assim como para as aplicações a dados reais e em diferentes contextos analisadas na tese (**de Araujo et al. 2005; Estombelo-Montesco et al. 2007b; Estombelo-Montesco et al. 2007a**).

Considere n fontes dispostas em um vetor de sinal fonte como $\mathbf{S}(k) = [s_1(k), \dots, s_n(k)]^T$. No modelo, o vetor observado $\mathbf{X}(k) = [x_1(k), \dots, x_n(k)]^T$ é o resultado da mistura linear dos sinais fonte. Dessa forma, essa mistura pode ser escrita como $\mathbf{X}(k) = \mathbf{A}\mathbf{S}(k)$, onde \mathbf{A} é uma matriz $n \times n$ não singular (invertível). Aqui o objetivo é encontrar a componente de \mathbf{X} que surja a partir das fontes de interesse, $s_i(k)$. De forma geral, como foi mostrado no capítulo anterior, o número de componentes independentes pode ser tão grande como a dimensão do vetor \mathbf{X} .

Assume-se nesta abordagem que os sinais fonte têm uma estrutura temporal e funções de autocorrelação diferentes, mas não necessariamente eles tenham que ser estatisticamente independentes. Deve-se observar que essa decorrelação mútua por um período de tempo é suficiente (mas não necessária) para se extrair a fonte com sucesso. Dados atrasos temporais específicos para cada sinal, τ_i , o algoritmo garante a extração de forma cega de qualquer um dos sinais fonte s_i que satisfaça as seguintes relações:

$$E[s_i(k)s_i(k - \tau_i)] \neq 0$$

$$E[s_i(k)s_j(k - \tau_i)] = 0 \forall i \neq j. \quad (17)$$

Como se quer extrair somente um sinal fonte, pode-se usar uma unidade de processamento simples descrita por $y(k) = \mathbf{w}^T \mathbf{x}(k)$, onde $y(k)$ é o sinal de saída (que é uma estimativa do sinal fonte específico s_i), k é o número da amostragem, e \mathbf{w} é o vetor de pesos. Em seguida, com o propósito de desenvolver o algoritmo, deve-se definir a seguinte medida de erro: $\varepsilon(k) = y(k) - y(k-p)$.

3.2.2. Algoritmo de aprendizagem

A idéia principal é realizar a minimização do erro quadrático médio (EQM) $\xi(\mathbf{w}) = E[\varepsilon^2]$.

Para simplificar a notação, seja $y_p = y(k-p)$, onde o índice p é usado para representar o atraso temporal e, de forma geral, daqui em diante omite-se o índice k por conveniência.

Dessa forma após algumas manipulações matemáticas se tem:

$$\xi(\mathbf{w}) = \mathbf{w}^T E[\mathbf{xx}^T] \mathbf{w} - 2E[y_p \mathbf{w}^T \mathbf{x}] + E[y_p^2]. \quad (18)$$

Essa função de custo alcança o mínimo quando seu gradiente em relação a \mathbf{w} chega a zero. Logo, para alcançar o mínimo se aplica a seguinte condição:

$$\frac{\partial \xi(\mathbf{w})}{\partial \mathbf{w}} = 2E[\mathbf{xx}^T] \mathbf{w} - 2E[y_p \mathbf{x}] + 2E[\mathbf{x}_p \mathbf{x}_p] \mathbf{w} = 0. \quad (19)$$

Isso resulta na seguinte regra de atualização:

$$\mathbf{w} = \frac{1}{2} E[\mathbf{xx}^T]^{-1} E[y_p \mathbf{x}]. \quad (20)$$

Sem perda de generalidade, pode-se assumir que os dados foram pré-branqueados, onde se considera $E[\mathbf{xx}^T] = \mathbf{I}$. Dessa forma, a realização da normalização do vetor a cada iteração, na forma $\mathbf{w}_* = \mathbf{w} / \|\mathbf{w}\|$, leva à seguinte regra de aprendizado (**Barros and Cichocki 2001**):

$$\mathbf{w} = E[\mathbf{x}y_p]. \quad (21)$$

Neste ponto surge um problema prático: como estimar o atraso temporal mais eficiente? Uma simples solução é calcular a função de correlação dos sinais do sensor como uma função do atraso e encontrar o atributo correspondente, em nosso caso um pico com o atraso apropriado, que corresponda ao sinal de interesse. Para efetuar isso o sistema será modelado usando-se auto-regressão, que será descrita em seções seguintes.

3.2.3. Evitando o problema da Permutação

Como visto no capítulo anterior, algoritmos que realizam a estimativa de todas as componentes de forma cega, usando a matriz de $n \times n$ componentes \mathbf{W} e obtendo na saída o vetor $\mathbf{Y} = \mathbf{W}\mathbf{X} = \mathbf{W}\mathbf{A}\mathbf{S}$, possuem uma ambigüidade de escala e de ordem que pode ser representada por $\mathbf{Y} = \mathbf{D}\mathbf{P}\mathbf{S}$, onde \mathbf{D} e \mathbf{P} são a matriz diagonal e a matriz de permutação, respectivamente (**Comon 1994**).

Pelo raciocínio anterior e na tentativa de estimar somente uma componente a cada vez, a ambigüidade mencionada pode ser escrita da forma: $y = \alpha \mathbf{P}^T \mathbf{S}$, onde \mathbf{P} é qualquer coluna da matriz de permutação e α é um fator de escalamento. Portanto, não se pode predizer qual componente será estimada primeiro.

No entanto, acredita-se que a permutação pode ocorrer somente se a intenção é recuperar as fontes de forma cega. De fato, o teorema mostrado em (**Barros and Cichocki 2001**) prova que o algoritmo da equação (21) soluciona o problema de permutação e conduz à extração da componente desejada.

3.2.4. Evitando o problema de escalamento

A estimativa do sinal extraído pelo método ACD pode estar multiplicada por um fator de escala no momento final da extração. No entanto, caso a estimativa do sinal não dependa de medidas prévias para ser avaliada, o escalamento do sinal não é considerado um problema, porque obter o sinal fonte e seu comportamento tem maior relevância. Por outro lado, quando

existem medidas de controle, com o propósito de avaliar o sinal extraído antes e após algum evento (ou tarefa), para uma posterior comparação, o problema de escalamento se torna relevante. Em consequência, se não tratarmos o problema de escalamento adequadamente o resultado final, da comparação, pode levar a uma avaliação errônea.

Considerando a formulação feita na seção anterior do problema de permutação temos $y = \alpha \mathbf{P}^T \mathbf{S}$, onde α é um fator de escalamento que precisa ser estimado. Simplificaremos a formulação deixando de lado \mathbf{P} , de forma a iniciarmos com a seguinte formulação $\mathbf{Y} = \alpha \mathbf{S}$.

Após a extração da componente desejada pelo método ACD, procede-se da seguinte forma para se estimar o fator de escalamento α . Sendo y a componente extraída esta pode ser projetada de volta no conjunto origem de sinais observados. Para tal, primeiro definimos o seguinte erro:

$$\varepsilon_b = x_i - \alpha_i y. \quad (22)$$

Nesta definição, x_i é o sinal observado e que contem a escala original e y é a componente obtida pelo método ACD. Em seguida, minimizamos o erro quadrático médio do erro definido $\xi(\alpha_i) = E[\varepsilon_b^2]$, obtendo $\xi(\alpha_i) = x_i^2 - 2x_i\alpha_i y + (\alpha_i y)^2$. O mínimo será alcançado fornecendo os seguintes pesos na expressão:

$$\alpha_i = E[y^2]^{-1} E[xy]. \quad (23)$$

A formulação apresentada fornece dois tipos de informação importantes. A primeira é: se escolhermos o maior valor absoluto de α teremos o fator de escalamento para aquela componente extraída pelo ACD. Portanto, agora existe uma forma de realizar uma comparação das amplitudes relativas do sinal medido antes e após algum evento (ou tarefa), no domínio do tempo ou no domínio da frequência do sinal. A segunda é: se forem considerados todos os valores de α pode-se obter a contribuição de cada canal para o sinal

fonte extraído, permitindo realizar um mapa espacial da distribuição e localização da contribuição do sinal fonte estimado.

3.3. MODELO AUTO-REGRESSIVO

O modelo auto-regressivo (AR) é uma das mais importantes técnicas de modelagem matemática, sendo muito utilizado para a análise de sinais de natureza fisiológica (**Spyers-Ashby et al. 1998**).

O modelo AR consiste no cálculo de pesos multiplicados às entradas anteriores de um dado ponto do sinal. Conhecendo-se esses pesos e a variância do ruído é possível calcular o espectro de potência do ponto. No modelo AR estima-se o valor de um ponto $x(n)$ de uma série em função de pontos passados $x(n-k)$, onde $1 < k < p$ e $p < n$, por isto o nome auto-regressivo. Os estimadores auto-regressivos têm sido bastante utilizados atualmente, principalmente pelo fato de fornecerem um espectro de potência de alta resolução dos pontos estimados da série em função dos parâmetros calculados.

O modelo AR para estimar o ponto $\tilde{x}(n)$ é formulado da seguinte forma:

$$x(n) = \hat{x}(n) + e(n), \quad \text{onde } \hat{x}(n) = -\sum_{k=1}^p a_k x(n-k). \quad (24)$$

Nesta equação, $x(n)$ é o sinal observado, $\hat{x}(n)$ é o sinal estimado e $e(n)$ representa o ruído, que é considerado como tendo média zero e variância σ^2 . A ordem do estimador, ou ordem do modelo, é o valor de p na equação anterior.

O processo da estimativa consiste, portanto, em determinar os coeficientes a_k do modelo AR a partir dos dados disponíveis ou observados. Estes podem ser determinados, por exemplo, pelo método de minimização do erro utilizando o método de Yule-Walker, que será usado no presente trabalho (**Marple 2005**). Este modelo é usualmente abreviado na literatura

como AR(p). Análise adicional, tal como a estimativa do espectro, é feita usando os parâmetros do modelo em vez de usar os dados originais.

O espectro de potência da estimativa auto-regressiva é dado por (**Madisetti and Williams 1998; Moraes et al. 2003**):

$$\hat{P}_m(\omega) = \sigma^2 \left| 1 + \sum_{k=1}^p a_{pk} \exp(-i\omega k) \right|^{-2}. \quad (25)$$

Nesta equação, $\hat{P}_m(\omega)$ é a potência espectral para a frequência ω do ponto estimado $x(m)$ e a_{mk} são os coeficientes AR. No método AR, a resolução no espaço de frequências não depende da ordem da estimativa e, portanto, não depende do número de pontos a serem utilizados para a determinação do espectro. Dessa forma, os espectros de potência obtidos pelo método AR fornecem melhor resolução na frequência do que os obtidos pela FFT (transformada rápida de Fourier).

Deve-se observar que a estimativa é uma função da frequência e está na faixa de frequência: $0 < f < 1/2 f_{\text{amostragem}}$. Além disso, é necessário tomar cuidado quando se interpreta a estimativa do espectro de potência do sinal. Em métodos baseados na FFT a altura do pico no espectro é proporcional à potência da correspondente componente nos dados. Por outro lado, para métodos baseado em AR a área abaixo do pico é proporcional à potência da componente (**Marple 2005**).

3.3.1. Escolha da ordem do modelo

A importância da escolha da ordem do modelo (não conhecida *a priori*) é fundamental para o modelo AR representar os dados originais. De forma geral, na prática costuma-se postular várias ordens para o modelo e, baseado nelas, se escolhe aquela que permita calcular algum critério de erro que indique qual o melhor modelo a ser usado (**Marple 2005**). De forma específica, pode-se ressaltar que valores muito altos na ordem do modelo, embora propiciem

um ganho na resolução do espectro, podem causar o fenômeno denominado separação da linha espectral. Este é caracterizado pelo aparecimento de dois picos espaçados no espectro quando somente um deveria aparecer (falsos picos). Por outro lado, valores muito baixos podem resultar em uma estimativa do espectro com uma forma muito lisa, carecendo de detalhes e podendo, também, perder picos no espectro.

Vários métodos foram desenvolvidos para auxiliar na escolha de uma ordem de modelo ótimo e um estudo exaustivo sobre as ordens do modelo AR pode ser encontrado em (Boardman et al. 2002). Uma das técnicas habitualmente usadas é o critério de informação de Akaike ou AIC (Akaike 1974; Marple 2005). O AIC determina a ordem do modelo minimizando a função da teoria da informação definida da seguinte forma:

$$AIC(p) = N \ln(E_p) + 2p. \quad (26)$$

Nesta equação, N é o número dados amostrados e E_p é a potencia do erro predito (produzida anteriormente na estimativa dos parâmetros). Segundo o AIC, o valor de p que minimiza a função acima (em um gráfico de AIC versus p) representa a ordem desejada para o modelo (Spyers-Ashby et al. 1998).

3.4. TRANSFORMADA DE WAVELET

A transformada de *wavelet* (também chamada, em português, de ondaleta) de um sinal permite uma análise nos domínios do tempo e da frequência do sinal. Basicamente, ela consiste em uma representação do sinal construída por translações e dilatações de uma *wavelet* de base Ψ . A transformada de *wavelet* contínua de um sinal u é calculada a partir do produto interno do sinal com o conjugado complexo da *wavelet* de base Ψ (Aldroubi and Unser 1996):

$$U(b,a) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} u(t) \Psi^* \left(\frac{t-b}{a} \right) dt. \quad (27)$$

Nesta equação, $a, b \in \mathfrak{R}$ e $a > 0$ é o coeficiente de escala que permite a compressão ou a expansão da função *wavelet*, b é o coeficiente de translação no eixo do tempo e $\Psi(t)$ é a função da *wavelet* de base. O termo $\frac{1}{\sqrt{a}}$ é um fator de normalização.

Para sinais discretos, a transformada de *wavelet* do sinal u é definida como:

$$U(b, a) = 2^{\frac{a}{2}} \sum_k u(k) \Psi(2^{-a} k - b). \quad (28)$$

Nesta equação, a e b são versões discretas dos coeficientes de escala e de translação, respectivamente, e a função discreta Ψ pode ser tomada como uma versão amostrada da sua contraparte contínua.

A *wavelet* de base Ψ é geralmente escolhida de forma a ser bem localizada nos domínios do tempo e da frequência. Esta função pode ser real ou complexa, resultando também em uma transformada real ou complexa. Na análise do sinal, nenhuma escala é privilegiada, pois a mesma função Ψ é utilizada em diversas escalas. Portanto, a transformada mantém uma resposta fortemente dependente da função Ψ (**Rioul and Vetterli 1991**).

A transformada de *wavelet* permite calcular os coeficientes dos espectros de frequência para cada frequência de um sinal específico, isto é, a energia em função da frequência. O diagrama resultante é denominado espectrograma. Analogamente ao espectrograma, as magnitudes da transformada de *wavelet* definem o escalograma da função (**Aldroubi and Unser 1996; Rioul and Vetterli 1991**). Esse tipo de representação será chamado aqui de representação tempo-frequência (RTF).

3.4.1. Transformada de Morlet

A primeira *wavelet* de base estudada, e ainda hoje muito usada, no contexto da teoria das *wavelets* foi a *wavelet* de Morlet, também chamada de gaussiana modulada. Ela é particularmente apropriada para a análise de padrões periódicos locais, pois é bem localizada nos domínios do tempo e da frequência (Tallon-Baudry et al. 1997).

A *wavelet* de Morlet complexa $w(t, f_0)$ tem a forma de uma gaussiana, tanto no domínio do tempo (com desvio padrão σ_t) como no domínio da frequência (com desvio padrão σ_f), centrada na sua frequência central f_0 . Ela é definida pela seguinte expressão (Tallon-Baudry et al. 1997):

$$w(t, f_0) = A \exp(-t^2/2\sigma_t^2) \exp(2i\pi f_0 t). \quad (29)$$

Nesta equação, o fator de normalização A é igual a $(\sigma_t \sqrt{\pi})^{-1/2}$. O desvio padrão no domínio da frequência é dado por $\sigma_f = 1/2\pi \sigma_t$.

A família da *wavelet* de Morlet é caracterizada pela razão constante $\tilde{w} = f_0/\sigma_f$, onde \tilde{w} é denominada de “largura” da *wavelet*. Em aplicações em magnetogastrografia, por exemplo, a família *wavelet* é definida por $\tilde{w} = f_0/\sigma_f = 3.5$, com f_0 variando desde 0.02 Hz até 0.09 Hz em passos de 0.001 Hz. Para 0.02 Hz, a duração da *wavelet* ($2\sigma_t$) é determinada como sendo de 55.70 s e a largura de banda espectral ($2\sigma_f$) como sendo de 0.01 Hz; já para 0.09 Hz, a duração é de 12.38 s e a largura de banda espectral é de 0.05 Hz. Este exemplo ilustra uma propriedade da transformada de Morlet: a resolução temporal aumenta com a frequência f_0 , enquanto que a resolução na frequência decresce.

O vetor t (de t_{Inicio} até t_{Fim}) é a faixa de tempo para a *wavelet*, cujo intervalo de amostragem é Δt , de onde se define a frequência de amostragem f_s como $f_s = 1/\Delta t$. De fato,

a “largura” da *wavelet* não é literalmente uma largura, mas sim o número de oscilações da *wavelet*.

Além do mais, $2\sigma_t$ é igual ao comprimento ou duração da *wavelet* e $2\sigma_f$ é igual à largura de banda espectral da *wavelet* para uma frequência específica. Considerando que a frequência a ser examinada, f_0 , determina algumas propriedades da *wavelet*, surge a importância de se saber o que caracteriza a constante $\tilde{\omega}$. Na Figura 6 se observa que se $\tilde{\omega}$ é dividido por dois, o número de oscilações da função de base é também dividido e a largura da *wavelet* se torna mais estreita. Além disso, quanto menor $\tilde{\omega}$, maior será a largura de banda espectral da *wavelet*, o que significa que a *wavelet* processará atividade de uma banda de maior largura. Por outro lado, para maiores valores de $\tilde{\omega}$, a resolução temporal da *wavelet* será de várias centenas de milisegundos para as frequências abaixo de 20 Hz, o que significa que componentes de frequências baixas requerem longas épocas para serem analisadas por este método.

Grandes valores de $\tilde{\omega}$ fornecem uma excelente banda larga espectral, mas a resolução temporal não é suficientemente boa, podendo ser várias centenas de milisegundos especialmente para baixas frequências.

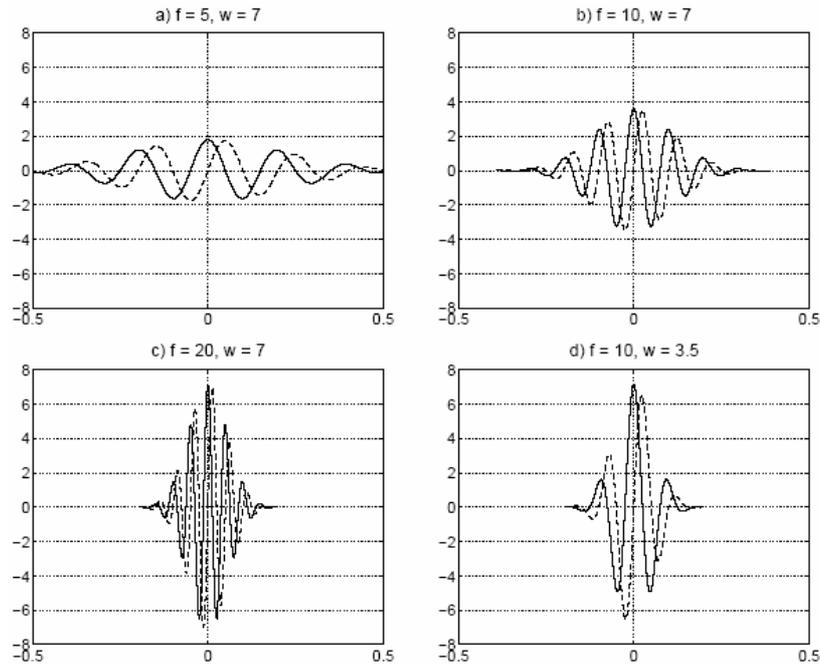


Figura 6 : Quatro *wavelets* de Morlet diferentes. As *wavelets* mostradas em a), b) e c) são as que têm a mesma “largura”, \tilde{W} , no caso igual a 7. A largura da banda espectral se amplia quando as frequências são aumentadas. Isto também pode ser observado quando o envelope da *wavelet* se torna mais agudo. Por outro lado, quando \tilde{W} é dividida pela metade o número de oscilações da *wavelet* também é dividido pela metade, o que pode ser observado em d). A linha sólida é a parte real da *wavelet* complexa, e a linha tracejada é a parte imaginária.

Algumas propriedades de diferentes *wavelets* de Morlet são mostradas na Tabela 1. A resolução temporal deste método aumenta com a frequência f_0 , enquanto que a resolução na frequência decresce, o que pode ser observado claramente pela Tabela 1 (Auranen 2002).

w	f_0	$2\sigma_t$ (ms)	$2\sigma_f$ (Hz)
1	5	64	10
1	10	32	20
1	20	16	40
5	5	318	2
5	10	159	4
5	20	80	8

7	5	446	1.4
7	10	223	2.9
7	20	111	5.7
10	5	637	1
10	10	318	2
10	20	159	4

Tabela 1: Efeito da "largura", \tilde{w} , da *wavelet* de Morlet no seu desempenho em diferentes frequências f_0 . $2\sigma_t$ é a duração da *wavelet* e $2\sigma_f$ é a largura da banda espectral da *wavelet* na frequência existente na tabela. Dessa forma, esses valores determinam o desempenho ótimo da *wavelet*.

Finalmente, podemos mencionar que a literatura indica que em varias aplicações são usadas versões modificadas da *wavelet* de Morlet, que poderiam ser chamadas de pseudo *wavelets* de Morlet. Embora estas não sejam necessariamente úteis para reconstruir o sinal a partir da sua transformada de *wavelet* (Sadowsky 1996), elas são muito úteis para mostrar a RTF do sinal, porque as características relevantes do sinal aparecem como padrões na superfície, além de que as pseudo *wavelets* de Morlet são muito mais simples para serem usada na prática computacional (Sadowsky 1996).

CAPÍTULO 4. COMPONENTE FETAL A PARTIR DE MAGNETOCARDIOGRAMAS

Neste capítulo, descreve-se uma aplicação do algoritmo de ACD proposto anteriormente a um caso de MCGf, onde o sinal de interesse é extraído usando-se um atraso temporal τ_i obtido da modelagem do sistema por AR e identificando-se a componente de interesse do sinal. Mostra-se que o método é efetivo na remoção do sinal materno e observa-se sua eficiência computacional. Finalmente, compara-se os resultados obtidos com os de um dos métodos já estabelecidos na literatura, conhecido como FastICA (**Hyvarinen and Oja 1997**).

4.1. MATERIAL E MÉTODOS

Os dados de MCGf foram coletados de dois fetos assintomáticos com idades de gestação iguais a 29 e 32 semanas, respectivamente. Os registros foram realizados com um biomagnetômetro de 37 canais (Magne II, 4D Neuroimaging), que coletava os sinais do feto e da mãe misturados. Os sinais foram digitalizados a 520,8 Hz e foram filtrados com um filtro passa-banda de 1 a 80 Hz. A filtragem de sinais magnéticos do coração entre 1 e 80 Hz é uma prática comum em MCGf e não compromete a qualidade dos registros (**Wakai et al. 2003**). Finalmente, para serem trabalhados os dados foram re-amostrados de forma a ficar digitalizados com uma frequência 4 vezes menor de 130,2 Hz.

4.2. RESULTADOS

Para se ter uma idéia dos dados, a Figura 7 mostra 5 dos 37 canais registrados pelo biomagnetômetro. A figura mostra 10 segundos de dados típicos. Deve-se observar que o MCG da mãe e o MCG fetal se sobrepõem no tempo.

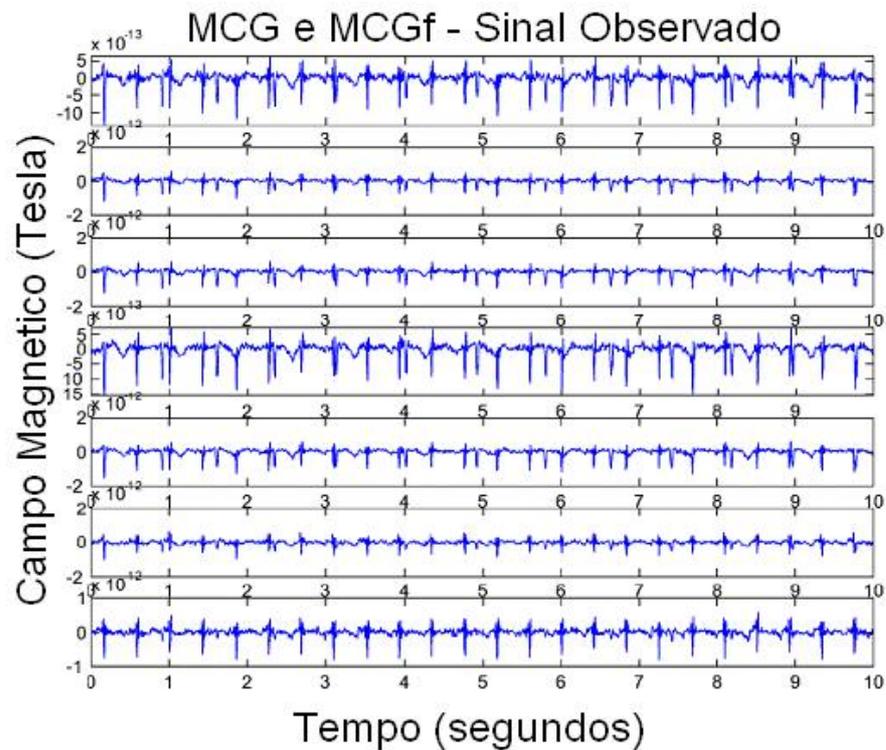


Figura 7 : Dez segundos de dados observados, para 5 dos 37 canais de MCGf registrados. Os registros mostram os sinais da mãe e do feto superpostos.

O algoritmo proposto no capítulo anterior foi aplicado para extrair o MCGf a partir dos sinais observados. O primeiro passo foi o cálculo dos coeficientes auto-regressivos pelo método de Yule-Waker e a obtenção das raízes correspondentes aos seus pólos (Figura 8). A complexidade dos dados de MCGf se deve ao fato de que os sinais cardíacos materno e fetal são quase-periódicos e têm uma forma similar.

No entanto, pode-se demonstrar, com o modelo proposto aqui, que os sinais cardíacos materno e fetal são caracterizados por valores diferentes de frequência e amplitude. Na Figura 8 mostra-se que o batimento cardíaco do feto tem uma frequência maior que a do batimento cardíaco da mãe, e que a amplitude do MCG da mãe é maior que a do feto.

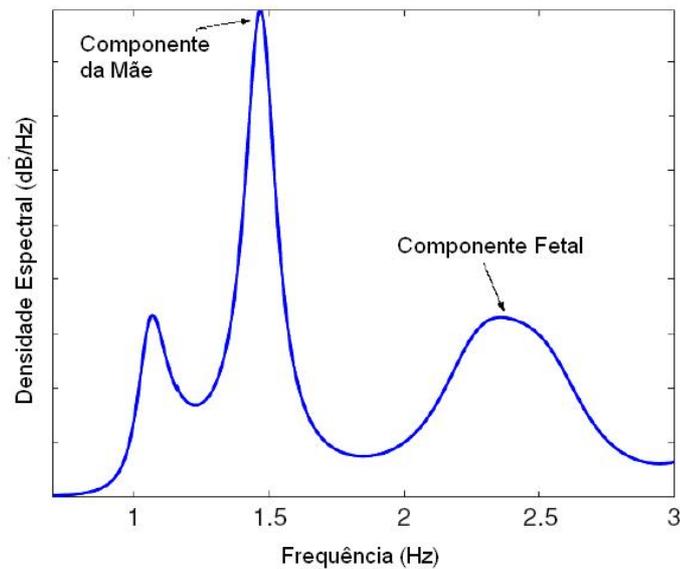


Figura 8 : Espectro de potência de um registro simples. Dois picos correspondentes à componente fetal e à componente da mãe são observados.

Depois de encontrar um pólo em 1,5 Hz, que é consistente com uma taxa de batimento cardíaco de um adulto, e um outro em 2,4 Hz, que é consistente com uma taxa de batimento cardíaco de um feto, foi aplicado o algoritmo de ACD conforme descrito no capítulo anterior. A Figura 9(c) mostra o sinal cardíaco do feto extraído pelo método de ACD. O MCGf é claramente preservado e a interferência materna é removida.

Para comparar o resultado do algoritmo proposto com o resultado obtido pelo método de FastICA, o método FastICA foi aplicado ao mesmo conjunto de dados, resultando na Figura 9(a) e Figura 9(b). De forma geral, o método FastICA tem vários passos que podem ser evitados com o algoritmo proposto. Por exemplo, para o FastICA é necessário encontrar a melhor combinação de sinais de entrada, formando agrupamentos específicos, para se obter um resultado estável.

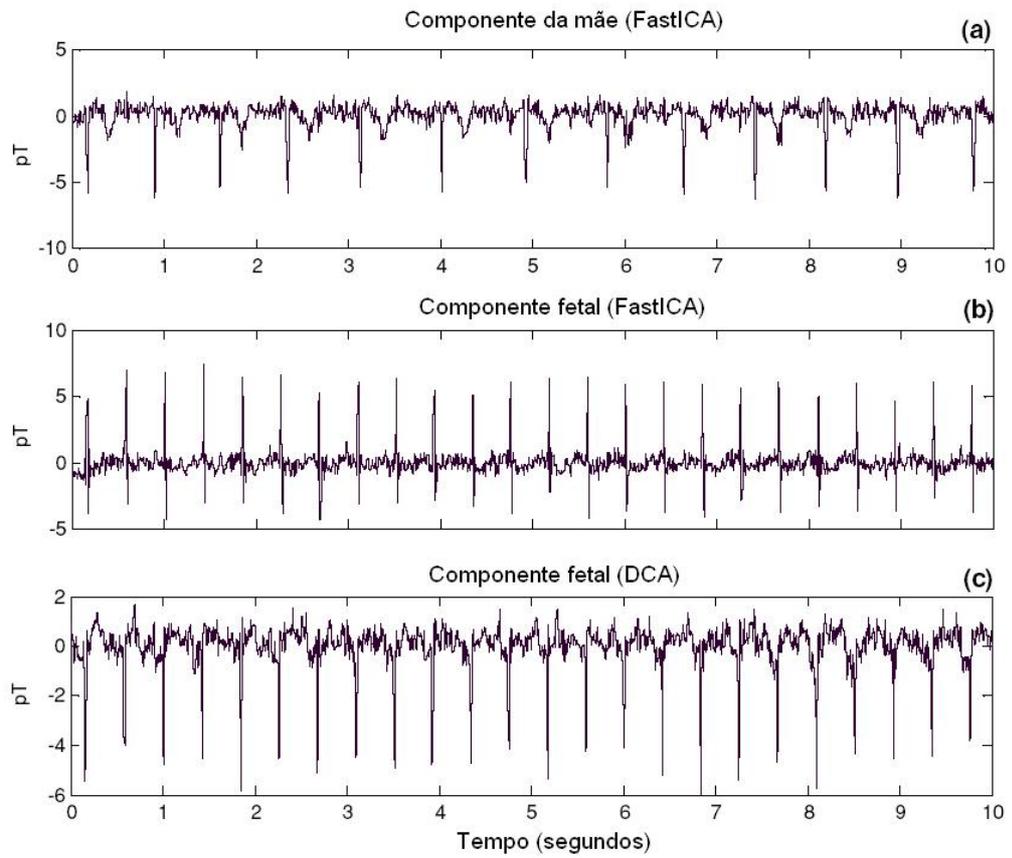


Figura 9 : Componentes separadas do MCG da mãe (a) e do MCG fetal (b), obtidas por fastICA, e do MCG fetal (c) extraído por ACD baseado na análise espectral auto-regressiva.

CAPÍTULO 5. COMPONENTES GÁSTRICOS A PARTIR DE MAGNETOGASTROGRAMAS

Este capítulo descreve uma aplicação do método de ACD à detecção das duas componentes da atividade elétrica gástrica após uma refeição, o ritmo elétrico de base (REB) e a atividade de resposta elétrica (ARE). Conforme mencionado no Capítulo 2, os sinais de MGG são altamente contaminadas pela respiração, movimento e artefatos cardíacos e, possivelmente, pela atividade mioelétrica originada em outros órgãos, o que confunde a interpretação e a análise do MGG (**Liang et al. 2000**). Em particular, a detecção da ARE é especialmente difícil porque ela tem um baixo nível de amplitude e possui sobreposição espectral com os sinais cardíacos, impossibilitando o uso dos métodos de análise existentes considerados como padrão.

O método de ACD é aplicado aqui para separar os sinais REB e ARE de outras fontes de interferência, mesmo em casos com baixas taxas da relação sinal-ruído. Além disto, utiliza-se uma representação tempo-frequência (RTF) das componentes extraídas, baseada em *wavelets*, para se examinar as características temporais da REB e da ARE.

5.1. MATERIALES E MÉTODOS

Os registros foram feitos com um sistema de gradiômetros de primeira ordem (*Magnes, Biomagnetic Technologies, Inc*) colocado no interior de uma sala blindada contra campos magnéticos de alta intensidade. O sistema consistiu de duas unidades de magnetômetros, A e B, cada uma contendo 37 canais uniformemente distribuídos sobre áreas circulares de diâmetros 13,7 cm e 14,4 cm, respectivamente. O ruído intrínseco por canal é de 5-10 fT (Hz)^{-1/2}.

Sete sujeitos voluntários assintomáticos participaram no estudo. Cada sujeito ficou deitado em uma cama especial, com o magnetômetro A posicionado sobre seu estomago e o

magnetômetro B posicionado sobre suas costas, de forma a ficar alinhado com o primeiro (Estombelo-Montesco et al. 2007a). Com esta disposição experimental foi possível adquirir simultaneamente os sinais das partes anterior e posterior do estômago; além disso, foi possível adquirir sinais do estômago à menor distância possível.

Três épocas de 10 minutos de duração foram adquiridas. A primeira (época pré-prandial) foi adquirida antes da ingestão do alimento teste. Depois, um alimento teste (um sanduíche de pão com queijo de 250 kcal) foi dado aos sujeitos imediatamente antes da segunda medida (primeira época pós-prandial). Posteriormente, mais 10 minutos de aquisição foram feitos (segunda época pós-prandial).

Os sinais de MGG foram amostrados a 73,1 Hz e armazenados para subseqüente análise. Os dados digitalizados foram decimados a 4 Hz para eliminar artefatos de altas frequências e interferências, resultando em um sinal com largura de banda de pouco menos de 1 ciclo/min.

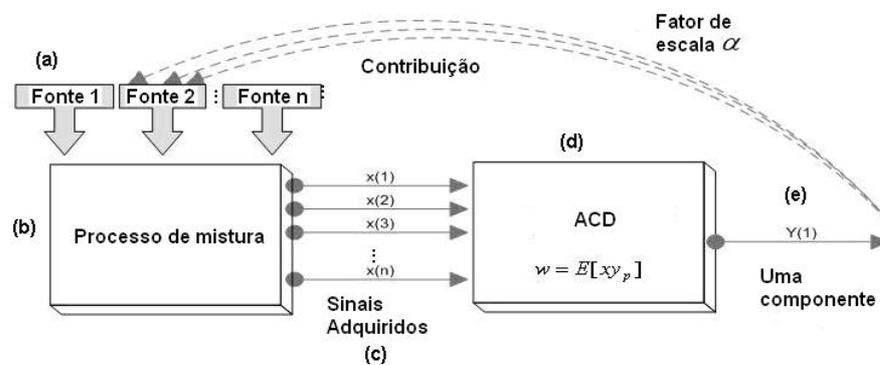


Figura 10 : Diagrama ilustrativo do método aplicado. (a) Cada fonte (estômago, coração, tecido, artefatos, etc) produz um sinal magnético, na prática não observados diretamente. (b) Os sinais de cada fonte são misturados (linearmente, por hipótese) com os das outras fontes e a mistura é representada pelo bloco denominado “processo de mistura”. (c) Os sinais adquiridos por cada canal do magnetômetro são, na verdade, misturas dos sinais originais. (d) Após a aquisição dos sinais misturados realiza-se a separação/extração da fonte de interesse através do processo de ACD. (e) Finalmente, na saída há uma única série temporal determinada a menos de um fator de escala que precisa ser calculado para se estimar sua amplitude relativa. Estes passos foram aplicados para as três épocas medidas: a pré-prandial e as duas pós-prandiais.

O diagrama da Figura 10 ilustra a estratégia utilizada para a extração das componentes REB e ARE, segundo o método de ACD. Lembramos aqui que o método ACD depende da

estimação *a priori* do atraso temporal ótimo para cada sinal (REB e ARE) e que isso é feito a partir da função de autocorrelação dos sinais, cujas séries temporais são modeladas por AR.

A Figura 11 mostra o espectro de potência representativo de segmentos do sinal registrado (observado e sem processar) para a época pré-prandial. A partir do modelo AR pode-se estimar um atraso temporal apropriado ao sinal de interesse a ser extraído. A Figura 11 mostra o espectro de potência do sinal do REB com um pico em 0,05 Hz (ou 3 cpm). Esta é a informação *a priori* usada para estimar o atraso temporal para o método de ACD.

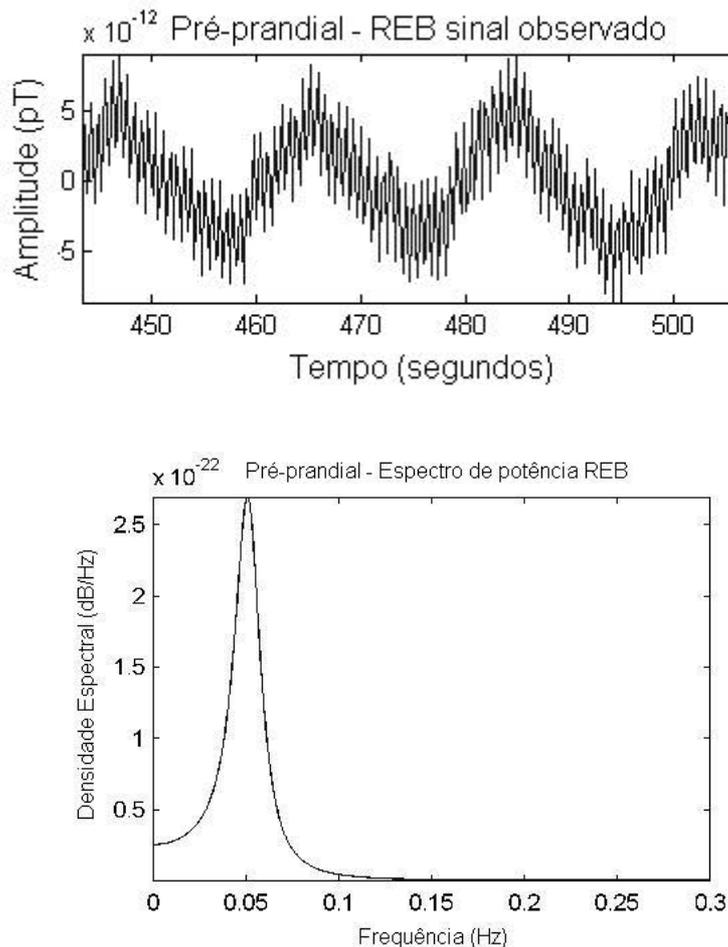


Figura 11 : O painel superior mostra o sinal correspondente ao REB observado originalmente após a decimação, sem qualquer outro tipo de processamento. O painel inferior mostra o espectro de potência do sinal do painel superior, indicando claramente o sinal REB em 0,05 Hz (3 cpm.).

O espectro de potência dos sinais do coração e da ARE em um registro pré-prandial único está mostrado na Figura 12. Pode-se observar que a componente do coração (1,5 Hz) é muito mais forte que a componente da ARE (0,8 Hz).

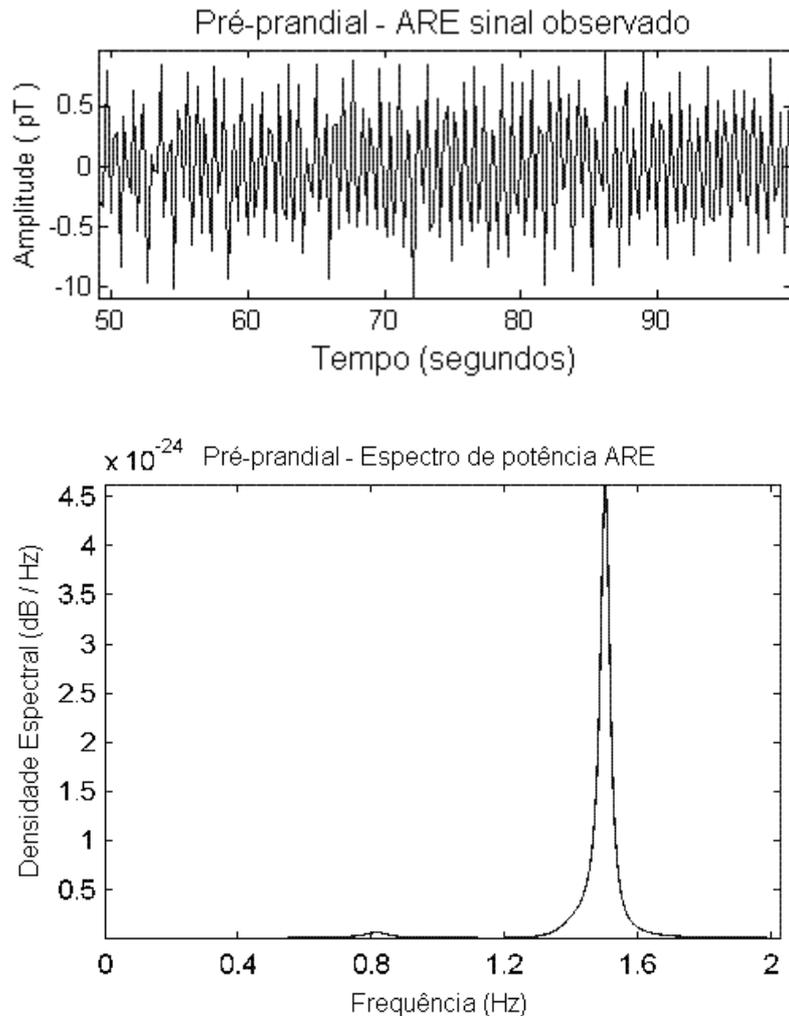


Figura 12 : O painel superior mostra a serie temporal original da época pre-prandial após decimação e filtragem das frequencias baixas. O painel inferior mostra o espectro de potencia da AER dos registros da época pre-prandial mostrados no painel acima. O sinal AER tem uma fraca energia comparado à componente do coração nas altas frequencias.

Comparando-se com o espectro de potência dos registros da primeira época pós-prandial, mostrado na Figura 13, vê-se que este último mostra uma diferença significativa perto de 0,8 Hz, indicando um estado diferente em relação ao caso da época pré-prandial da Figura 12. Além disso, a potencia associada à ARE na época pós-prandial é muito maior que a da época pré-prandial para a mesma frequência.

A estimação do sinal extraído pela ACD pode ter uma escala diferente da do sinal original. Isso pode levar a comparações erradas entre as energias das épocas pré-prandial e pós-prandial, o que faz com que a determinação de um fator de escala apropriado seja fundamental. O fator de escala é determinado aqui pela Equação (23).

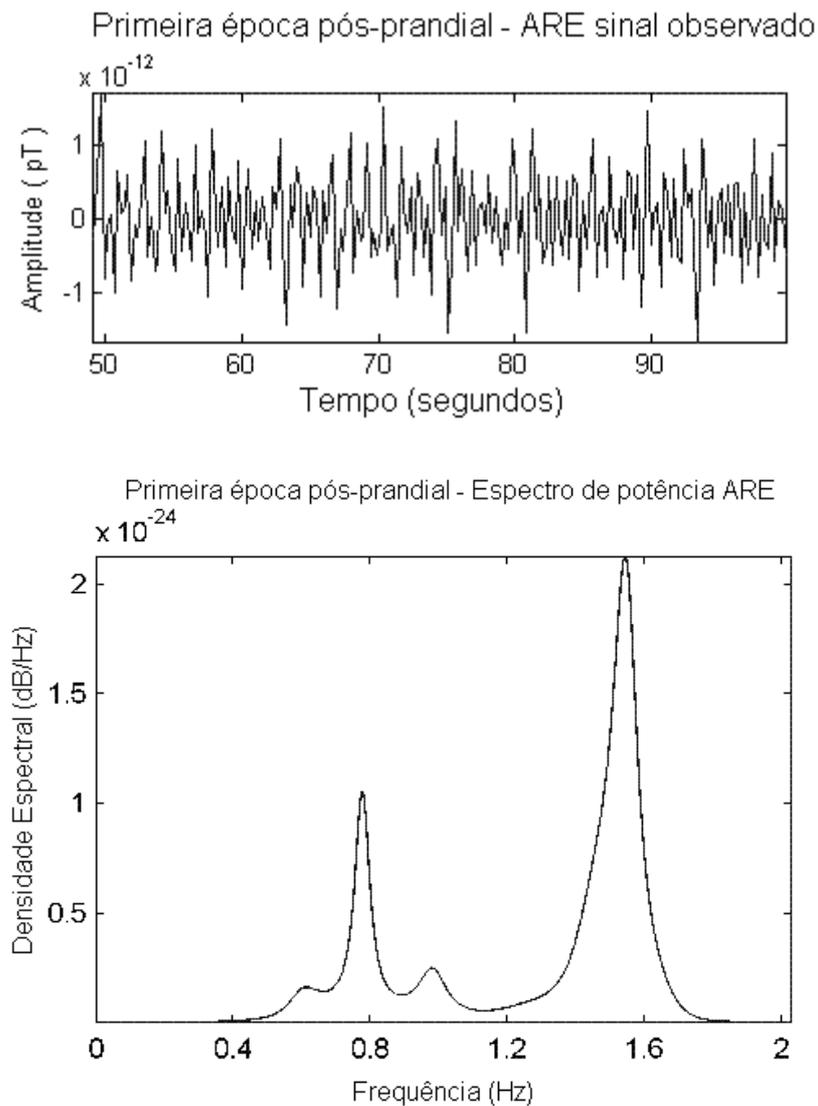


Figura 13 : O painel superior mostra o sinal original da primeira época pós-prandial, após decimação e filtragem das frequências baixas. O painel inferior mostra o espectro de potência deste sinal, com um forte pico em torno de 1,5 Hz associado ao ritmo cardíaco e com o pico da ARE em torno de 0,8 Hz, muito mais intenso do que no caso pré-prandial.

O fator de escala fornece duas informações valiosas. Em primeiro lugar, se tomarmos o maior valor absoluto de α teremos o fator de escala para a componente extraída pela ACD. Realizando este procedimento para cada uma das épocas teremos seus respectivos fatores de

escala. Dessa forma, pode-se comparar suas amplitudes relativas para serem analisadas, no domínio da frequência ou no domínio do tempo, e detectar o sinal da ARE assim como sua intensidade e localização no domínio da frequência.

A segunda informação está relacionada com todos os valores contidos no vetor α , pois como cada componente deste vetor pertence a um sensor (ou canal) estes permitirão uma representação espacial em que se poderá observar a contribuição de cada canal para o sinal fonte. Esse mapa espacial do sinal fonte estimado, montado a partir dos sinais dos 37 canais, será mostrado na seção seguinte.

A caracterização dos sinais do REB e da ARE foi feita por RTF em termos de *wavelets*. A *wavelet* utilizada neste estudo é a *wavelet* de Morlet definida e descrita anteriormente. Para o caso específico da MGG, os valores dos parâmetros da *wavelet* de Morlet dada pela Equação (29) utilizados para a RTF do sinal do REB estão dados na Tabela 2 e os valores dos parâmetros utilizados para a RTF da ARE estão dados na Tabela 3.

\tilde{w}	f_0	$2\sigma_t$ (seg)	$2\sigma_f$ (Hz)
10	0,05	63,66	0,010
7	0,05	44,56	0,014
2	0,05	12,73	0,050
3,5	0,02	55,7	0,011
3,5	0,05	22,3	0,029
3,5	0,09	12,4	0,051

Tabela 2: No caso do REB (3 cpm), a tabela mostra o efeito de \tilde{w} na *wavelet* de Morlet para diferentes frequências f_0 . No presente trabalho, para o REB, o parâmetro foi configurado com o valor de $\tilde{w} = 3,5$.

\tilde{w}	f_0	$2\sigma_t$ (seg)	$2\sigma_f$ (Hz)
16	0,6	8,49	0,08

16	0,8	6,37	0,10
16	1,0	5,09	0,13
21	0,6	11,14	0,06
21	0,8	8,36	0,08
21	1,0	6,68	0,10
26	0,6	13,79	0,05
26	0,8	10,35	0,06
26	1,0	8,28	0,08

Tabela 3 : Para o caso da ARE a tabela mostra várias configurações de valores de \tilde{W} e f_0 para a *wavelet* de Morlet. No caso da ARE, o parâmetro foi configurado com o valor de $\tilde{W} = 21$.

5.2. RESULTADOS

A Figura 14 mostra as três épocas (uma em cada painel) com as componentes do sinal gástrico associadas ao REB e à ARE extraídas pela ACD. Geralmente, no domínio temporal a componente do REB tem a maior amplitude que a componente da ARE. Para melhor visualização é mais conveniente mostrar as duas componentes (REB e ARE) sobrepostas, cada uma com sua própria escala.

A Figura 14(b) e (c) mostram que a componente da ARE está sempre presente no estômago. Pode-se notar que o sinal da ARE pós-prandial tem maior amplitude que o sinal pré-prandial (Figura 14(a), especialmente durante a fase do platô do REB perto de 50 seg., 70 seg., 90 seg. e 110 seg. da Figura 14(b)).

A contribuição de energia de cada canal pode ser usada para a construção de mapas de contorno das contribuições. Esses mapas mostram uma representação espacial da área de onde o sinal fonte surge. A representação do arranjo dos 37 canais para a componente do REB (das épocas pré-prandial e pós-prandial) está mostrada na **Figura 15**.

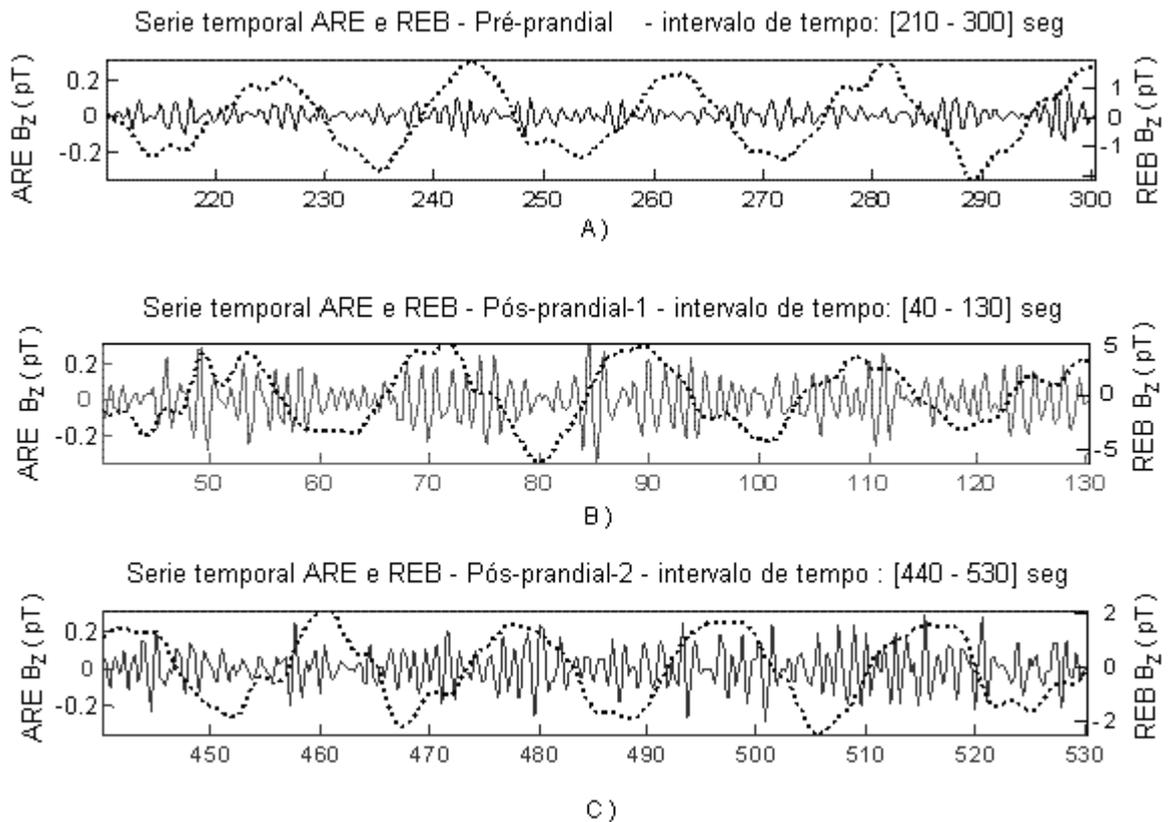


Figura 14 : Sinais do REB (linha pontilhada) e da ARE (linha sólida) extraídos usando a ACD. (a) componentes extraídas na época pre-prandial, (b) e (c) componentes extraídas para a primeira época pós-prandial e para a segunda época pós-prandial, respectivamente. Do lado direito mostra-se a escala usada para o sinal do REB e, do lado esquerdo, mostra-se a escala usada para o sinal da ARE. O sinal do REB consiste de um *upstroke* seguido por um platô e, posteriormente, pela fase de despolarização lenta com uma frequência aproximada de 3 cpm. Note a diferença de amplitude entre o sinal do REB na época pré-prandial e o sinal da ARE nas duas épocas pós-prandiais. A escala do eixo x está em segundos.

A Figura 16(a) mostra a contribuição de cada canal após a aplicação da ACD para extrair o sinal da ARE na época pré-prandial. Observa-se uma baixa energia associada ao ritmo da ARE. A pequena quantidade de energia observada no canto superior direito é devida ao sinal cardíaco restante após o processo de extração.

A Figura 16(b) mostra o mapa com as contribuições do sinal da ARE na época pós-prandial após a extração por ACD. Aqui se observa um aumento da energia em alguns canais do lado direito do mapa que tinham baixas energias no caso anterior (época pré-prandial).

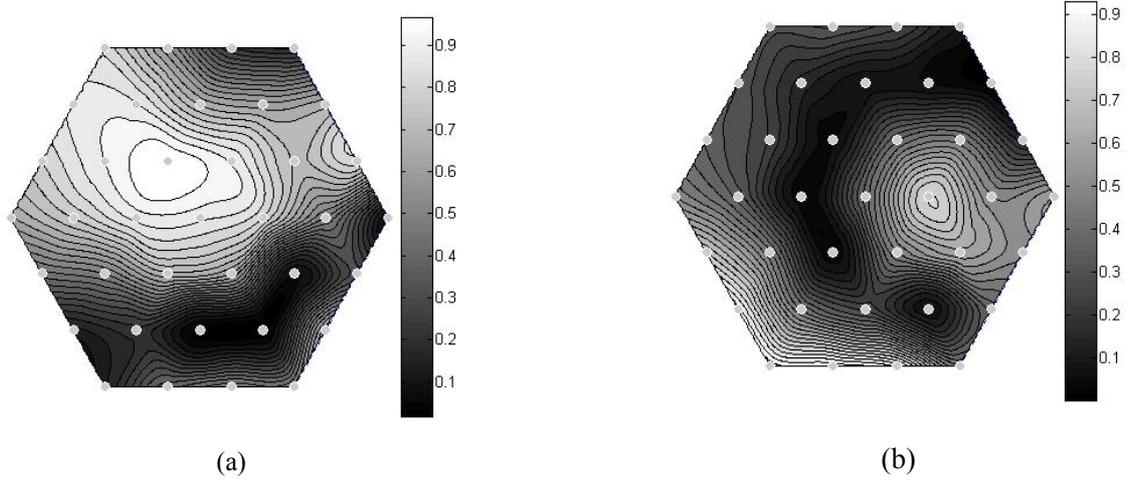


Figura 15: Contribuições dos canais para o sinal do REB extraído pela ACD. (a) Mapa de contorno do sinal do REB na época pre-prandial. (b) Mapa de contorno do sinal do REB de uma época pós-prandial. Nessas épocas, a energia intensa da onda lenta está presente o tempo todo.

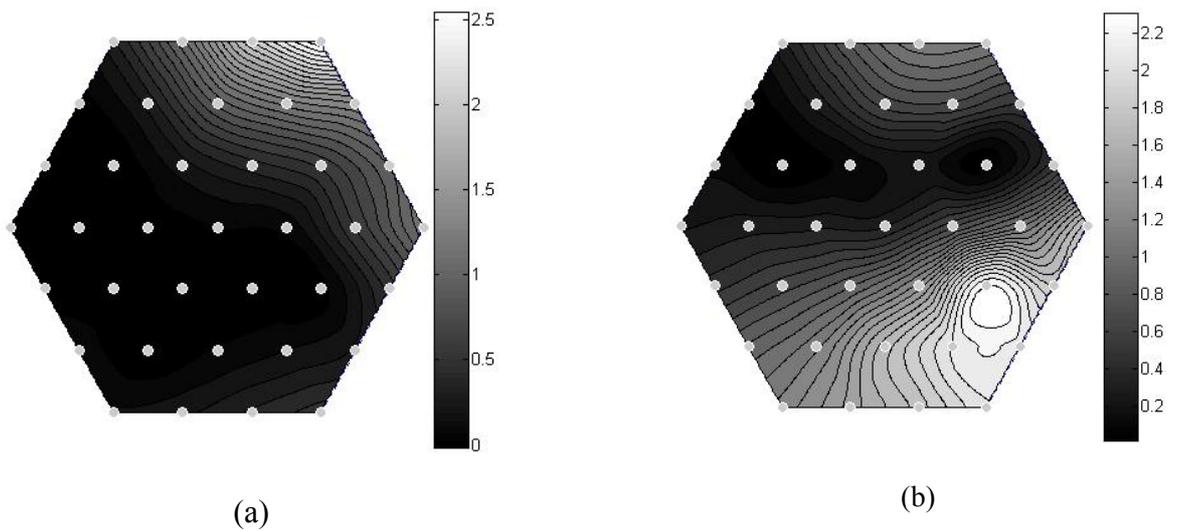


Figura 16: Contribuições dos canais para o sinal da ARE extraída por ACD. (a) Mapa de contorno para o sinal da ARE na época pre-prandial. Nessa época é esperado que a ARE não apresente contribuição, pois na época pre-prandial não há contrações. (b) Mapa de contorno para o sinal da ARE na primeira época pós-prandial, mostrando claramente uma mudança no padrão espacial.

Empregando outra representação, no caso a RTF, e combinando com os resultados obtidos no domínio temporal (Figura 14) mostrado anteriormente, obtém-se a Figura 17, onde, no painel superior, pode-se observar novamente os sinais do REB e da ARE durante a época pré-prandial. No painel inferior da Figura 17 mostra-se uma linha branca contínua, obtida pela soma das séries temporais do REB e da ARE, sobreposta à representação tempo-frequência do

signal da ARE obtida pela transformada de *wavelet*. O eixo vertical da RTF vai de 0,5 Hz a 1,3 Hz. Pode-se observar algumas (poucas) regiões localizadas de alta energia, mas elas não estão consistentemente em fase com a componente do REB.

Na Figura 18, no painel superior, mostram-se os sinais do REB e da ARE durante a primeira época pós-prandial. A amplitude do sinal da ARE é maior neste caso do que da época pré-prandial. Agora, na RTF do painel inferior pode-se notar pontos de alta energia da componente da ARE em fase com a componente do REB. Esta característica é muito importante para ratificar a existência da componente da ARE. Uma outra característica que se deve observar é que a frequência fundamental da componente da ARE, embora esteja concentrada em 0,8 Hz, pode variar no tempo, aumentando até 1,30 Hz, mas mantendo-se em fase com a componente do REB no platô.

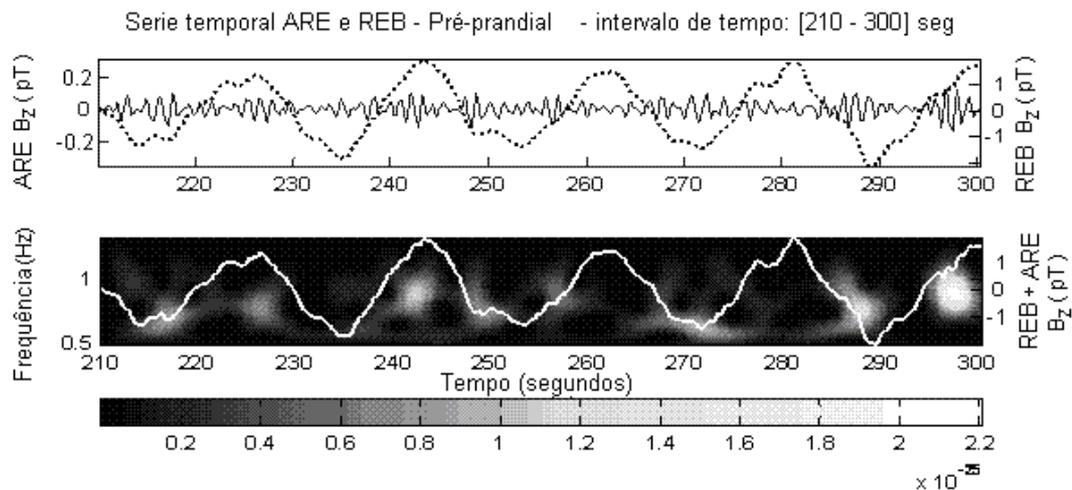


Figura 17: Intervalo de tempo durante a época pré-prandial, com as componentes do REB e da ARE no painel superior e a RTF da componente da ARE no painel inferior. A linha branca contínua sobreposta à RTF do painel inferior é a soma das componentes do REB e da ARE. A escala do lado esquerdo corresponde à componente da ARE e a escala do lado direito corresponde à componente do REB.

Na Figura 19, no painel superior, mostra-se os sinais do REB e da ARE durante a segunda época pós-prandial. Pode-se observar que a amplitude do sinal da ARE continua alta como na primeira época pós-prandial. No painel inferior da Figura 19 pode-se ver que a RTF da componente da ARE tem uma distribuição de energia mais difusa que na época anterior.

No entanto, ela ainda se mantém em fase com o sinal do REB, apesar da diminuição na energia.

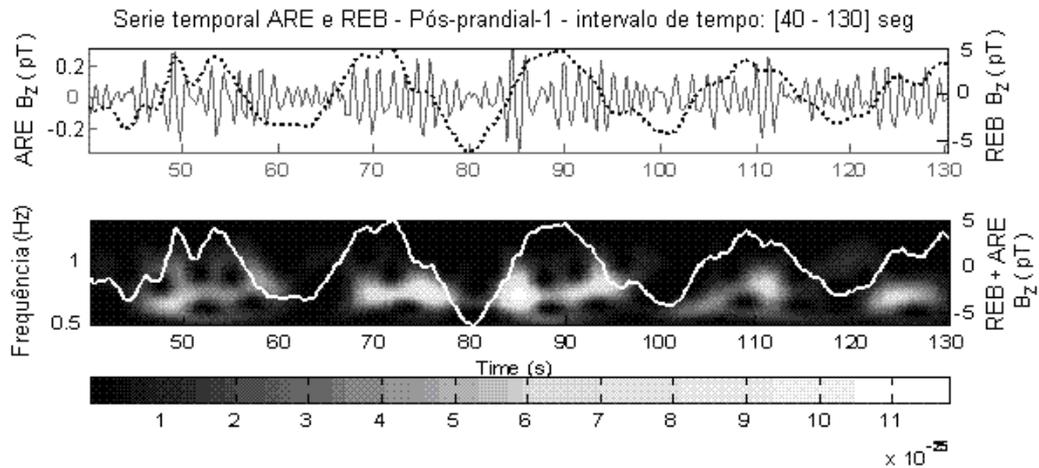


Figura 18: Intervalo de tempo durante a primeira época pós-prandial mostrando as componentes do REB e da ARE. Pode-se observar os potenciais de ação associados à componente da ARE no painel superior, correspondentes com os pontos luminosos na RTF do painel inferior, que estão em fase com a componente do REB. A frequência da componente da ARE na RTF varia de 0,6 Hz. a 1,0 Hz. As escalas desta figura são similares às da **Figura** .

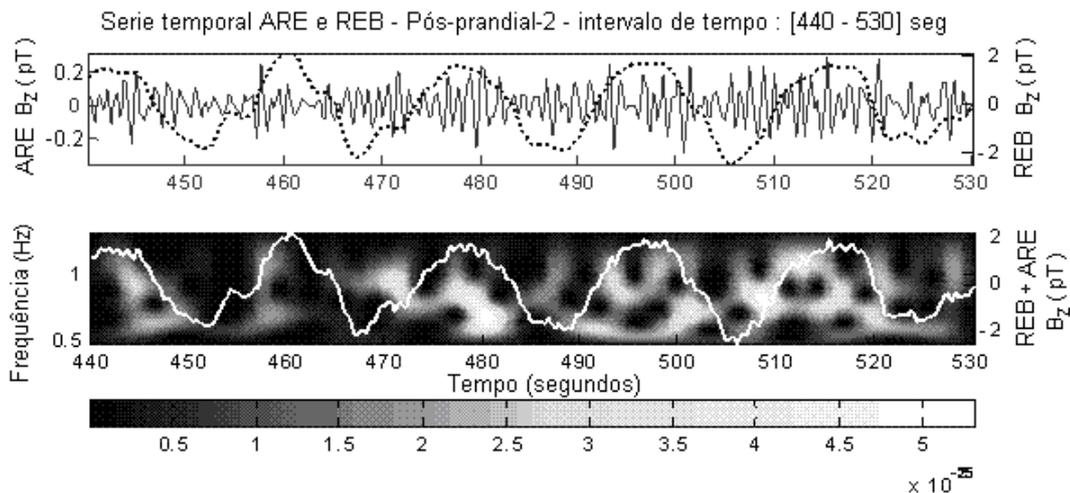


Figura 19: Intervalo de tempo durante a segunda época pós-prandial mostrando as componentes do REB e da ARE. Note-se que o sinal da ARE está mais distribuído, tanto no tempo como na frequência, embora mantenha-se em fase com a componente do REB.

Após a extração dos sinais desejados pelo método de ACD e de se estimar o fator de escala, pode-se calcular o espectro de potência para se determinar a energia da componente da ARE em cada época usando-se o método AR. Os resultados (Figura 20) mostram um aumento na amplitude do sinal na faixa de 0,6 Hz a 1,0 Hz. A frequência dominante nesta faixa é a de 0,8 Hz, em geral, correlacionada com a maior intensidade do REB. O centro da banda da frequência e sua largura variam de um sujeito para outro, mostrando a importância da aquisição pré-prandial como controle.

Uma forma de sintetizar essas diferenças encontradas no espectro de potência auto-regressivo e de permitir comparações entre elas é gerar uma variável, designada aqui de índice, para representar cada espectro de potência de cada componente de ARE. Este índice é gerado integrando-se a área abaixo da curva do espectro de potência entre as frequências 0,5 Hz e 1,33 Hz. Os valores do índice para cada curva estão mostrados na inserção da Figura 20.

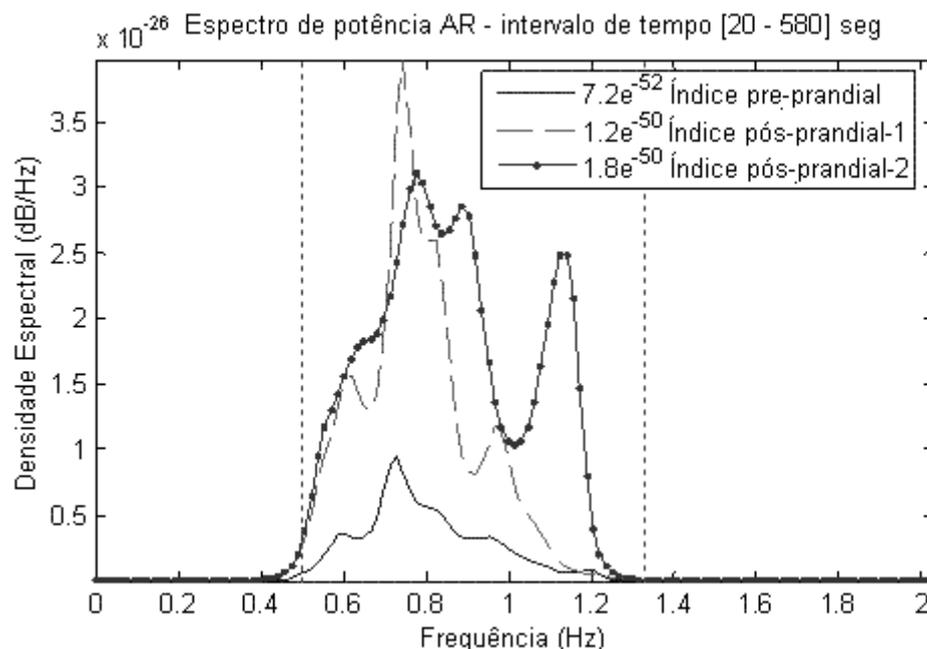


Figura 20: Espectro de potência auto-regressivo da componente da ARE durante a época pré-prandial e as duas épocas pós-prandiais, após sua extração pelo método da ACD. Os dados referem-se a um sujeito. A inserção mostra o índice calculado para cada época.

Os sinais adquiridos para todos os 7 sujeitos mostram um aumento nos índices das épocas pós-prandiais em comparação com os das épocas pré-prandiais. Esses resultados estão mostrados na Tabela 4. As grandes variações no índice observadas entre épocas (pré- e pós-prandial) e indivíduos diferentes são devidas a diversos fatores, como diferenças no tônus do músculo do estômago, na forma do corpo e na camada de gordura, por exemplo.

Tabela 4 : Índice para cada época (entre 0,5 Hz e 1,33 Hz) $\times 10^{51}$.

	Pré-prandial	Pós-prandial (1)	Pós-prandial (2)
Voluntário – 1	8.0	1100	930
Voluntário – 2	0.72	12	18
Voluntário – 3	9.0	91	120
Voluntário – 4	27	29	44
Voluntário – 5	16	300	83
Voluntário – 6	4.2	2800	5100
Voluntário – 7	8.6	99	180

CAPÍTULO 6. COMPONENTE AUDITIVO A PARTIR DE DADOS DE FMRI

Trabalhos recentes sugerem que o potencial dos métodos de separação cega de fontes (como a ACI) para a análise de dados de fMRI cresce quando informação *a priori*, quando disponível, é incorporada à estimativa das componentes (Suzuki et al. 2002).

Com inspiração nesses trabalhos, propõe-se aqui o uso da ACD para analisar dados de fMRI. Nos exemplos citados, baseados em ACI, utiliza-se informação *a priori* sobre o protocolo experimental adotado, mas, no caso da ACD, a informação *a priori* está contida no próprio conjunto de dados. Além do mais, a abordagem de ACD proposta aqui para fMRI mantém a idéia de se extrair somente a componente de interesse baseada na estrutura dos próprios dados. Isto pode ser considerado um avanço em relação aos trabalhos anteriores (Calhoun et al. 2005), pois deixa-se de precisar de informação *a priori* sobre o paradigma experimental e passa-se a precisar apenas de informação *a priori* contida no próprio conjunto de dados.

6.1. MATERIAL E MÉTODOS

O problema considerado nesta tese refere-se à determinação de fonte de estímulo auditivo a partir de medidas de fMRI. O paradigma experimental consistiu de uma escuta passiva de uma história complexa com uma estrutura narrativa padrão. Cada experimento estava composto por seis blocos de controle de 27,5 s, em que o indivíduo permanecia em repouso, alternados com cinco blocos durante os quais o indivíduo recebia o estímulo.

Os dados de fMRI foram adquiridos com um scanner (*Siemens 1.5 T, Magnetom vision scanner*). As medidas foram executadas em uma sessão contendo 64 volumes de 16 fatias cada um, usando seqüências rápidas de pulsos do tipo eco-planar (EPI). Imagens de alta

resolução espacial foram adquiridas também para que os mapas funcionais (obtidos no final do processamento) fossem sobrepostos a elas.

O protocolo utilizado pode ser observado na Figura 21. O eixo horizontal, graduado em termos do número de pontos amostrados, mostra a duração de cada bloco, de repouso ou de estímulo. Deve-se observar que o primeiro bloco (repouso) tem uma duração menor, pois seus pontos fazem parte do período durante o qual o equipamento foi calibrado.

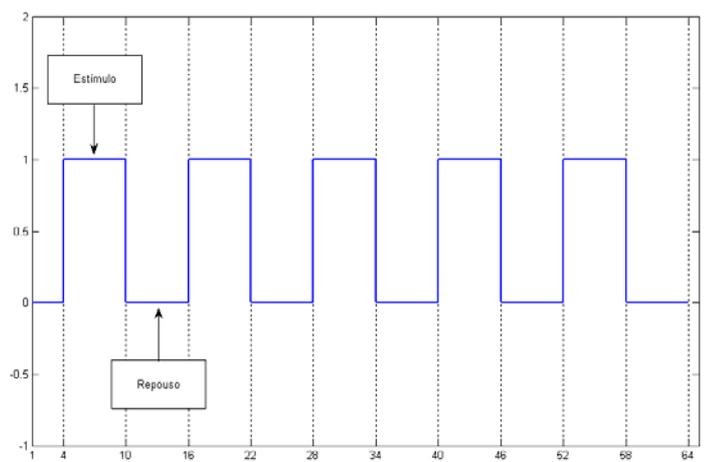


Figura 21: Esquema do protocolo em blocos usado no experimento. Os 64 pontos do eixo horizontal equivalem a 289,8 segundos. Os primeiros 12,7 s foram utilizados para a calibração do aparelho.

Na Figura 22 se observa uma amostra dos dados observados, sem a aplicação de qualquer processo de extração. De forma específica, essa imagem tem 128x128 pixels, pertence à fatia 12 do total de 16 fatias, e corresponde ao instante do ponto 32.

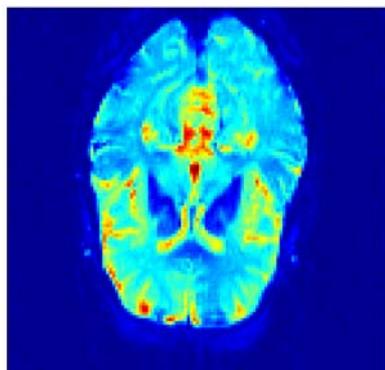


Figura 22: Exemplo de medida de fMRI sem processamento de extração. Matriz original de 128x128 pixels, fatia 12, amostragem 32 de 64 pontos.

Considerando que o mecanismo de contraste BOLD, aliado às técnicas de aquisição rápida, permite a visualização direta de um grande número de processos cerebrais, deve-se procurar passar as séries temporais obtidas por algumas etapas de pré-processamento para auxiliar na eliminação de alguns artefatos conhecidos, antes de analisá-las com ferramentas estatísticas ou algoritmos de extração. Os seguintes tipos de pré-processamento foram feitos sobre os dados: pré-processamento para a correção temporal entre fatias; pré-processamento para a correção de movimento; e pré-processamento para a redução da dimensão dos dados.

A avaliação do desempenho de um método é importante para se saber a eficácia do mesmo. Na maioria das técnicas isso é realizado por comparação com outros métodos, considerados padrões. Entretanto, diante da dificuldade de se obter um teste padrão para a fMRI, é comum estudar seu desempenho por meio de dados simulados (**Sturzbecher 2006**).

Para tanto, neste trabalho foram gerados artificialmente conjuntos de dados 3-D, de 64x64 voxels com séries temporais da função de resposta hemodinâmica (FRH) modelada analiticamente por (**Glover 1999**):

$$h(t) = \left(\frac{t}{d}\right)^a \exp\left(-\frac{t-d}{b}\right) - c \left(\frac{t}{d'}\right)^{a'} \exp\left(-\frac{t-d'}{b'}\right).$$

Neste modelo, $d = ab$ é o instante em que ocorre o pico da FRH e $d' = a'b'$ é o instante em que ocorre o *undershoot* da FRH. Os valores usados para os parâmetros são: $a = 6$, $a' = 12$, $b = b' = 0,9$ e $c = 0,35$. Na Figura se observa o comportamento desta função para estes parâmetros.

Nas colunas de 1 a 32 estão os voxels com padrão de ativação, ou seja, contendo um sinal BOLD, enquanto que as colunas de 32 a 64 somente contêm ruído, modelado por um padrão gaussiano uniforme.

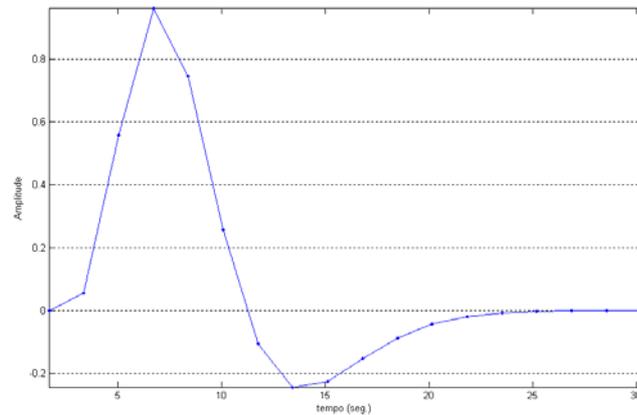


Figura 23 : Modelo da função hemodinâmica utilizada nos dados simulados.

Na Figura se observa uma série temporal baseada no modelo da FRH mostrada anteriormente.

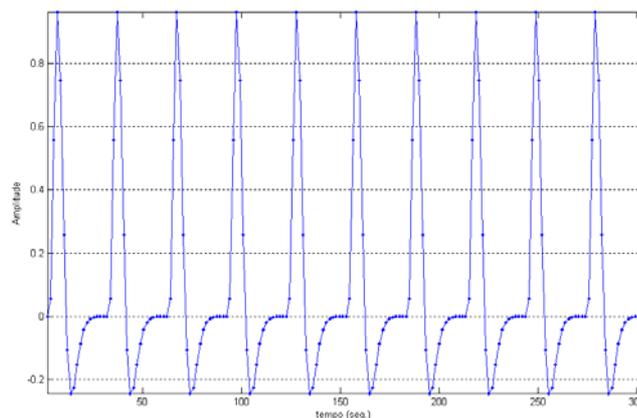


Figura 24: Série temporal de funções de resposta hemodinâmicas baseadas no modelo da **Figura** .

Antes de processar os dados de fMRI com as 16 fatias, é interessante fazer primeiro a análise da fatia que contém a maior quantidade de atividade neural. E como não se sabe em qual fatia o cérebro produz a maior quantidade de ativações devido ao experimento auditivo, tem-se que escolher empiricamente a melhor fatia. Uma das formas mais simples é realizar uma correlação cruzada de cada fatia com um sinal variável no tempo, criado artificialmente, formado por impulsos dos tipos ativado-desativado como ocorre no protocolo experimental.

Este teste empírico sugeriu que a fatia 12 pode conter a maior intensidade do sinal que se procura. A partir deste ponto foi possível a aplicação do método de ACD, considerando que ele pode ter o melhor desempenho com os dados da fatia 12.

Uma outra consideração é a quantidade de séries temporais processadas. Considerando que cada fatia é composta por 128x128 pixels e que cada pixel gera uma série temporal, a quantidade de dados é enorme. No caso deste experimento tem-se uma boa resolução espacial (128x128 pixels), em contraste com a resolução temporal que é menor (64 pontos de referência amostrados), mas suficiente para que a função de resposta hemodinâmica seja reconhecida. A questão é que precisa-se trabalhar somente com os pixels que sejam relevantes ou, pelo menos, que estejam dentro da área do cérebro. Para tal fim, aplica-se uma máscara sobre a fatia selecionada e esta detecta a região do cérebro que contém os pixels. Em consequência, somente as séries temporais desses pixels são utilizadas no processo de extração.

Após os diferentes tipos de pré-processamento descritos acima deve-se identificar, com base na informação intrínseca dos dados, a informação *a priori* necessária para a determinação do atraso temporal a ser usado na modelagem AR. Isto é feito a partir do cálculo do espectro de potência do sinal e um resultado representativo é mostrado na Figura . Nesta figura observa-se claramente a componente, em 0,018 Hz, relacionada com o experimento. Para verificar este resultado, pode-se compará-lo com a frequência obtida a partir do período de uma oscilação ($2 \times 27,5 \text{ s} = 55 \text{ seg}$), que é igual a 0.01818 Hz.

Uma vez identificada a informação *a priori*, o próximo passo consistiu em realizar uma redução na dimensão (branqueamento) dos dados para se trabalhar com os dados mais significativos.

O procedimento de extração propriamente dito é feito por cada fatia, uma a uma. A matriz original de 3 dimensões, <pixel X, pixel Y, ponto amostrado no tempo>, foi

transformada em uma matriz bidimensional de número de pixels por número de pontos amostrados: <16384, 64>. Esta última matriz é a entrada para o método de ACD. Deve-se observar que existe uma relação mapeando cada posição do pixel (vetor linha) dessa matriz em sua posição na matriz original, que é usada para posterior localização e criação do mapa de ativação.

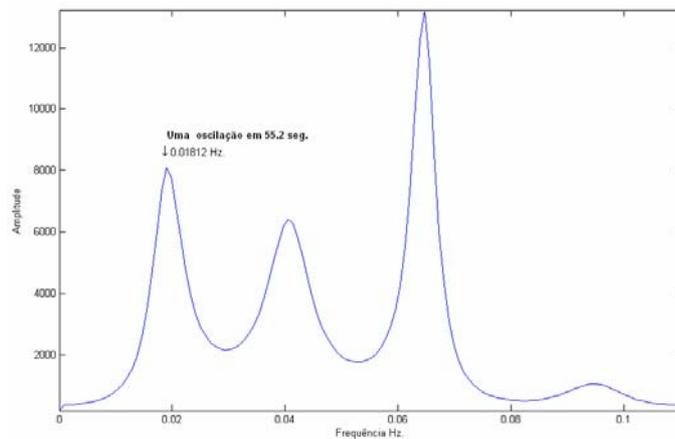


Figura 25: Espectro de potência AR de uma série temporal pertencente a um voxel. Observa-se a existência da componente em torno de 0,018 Hz.

6.2. RESULTADOS

Depois de processar os dados de fMRI com a ACD, a saída é a componente da fonte auditiva. Ela pode ser observada na Figura , com forte correlação com o protocolo e o paradigma usado no domínio do tempo mostrado na Figura 21.

Em consequência, tal componente foi correlacionada com as séries temporais das imagens obtendo-se como resultado os mapas de ativação, os quais foram sobrepostos às imagens utilizando-se o software de visualização MRIcro. As ativações detectadas foram localizadas na área do córtex correlacionada com o experimento auditivo deste trabalho (Figura 27).

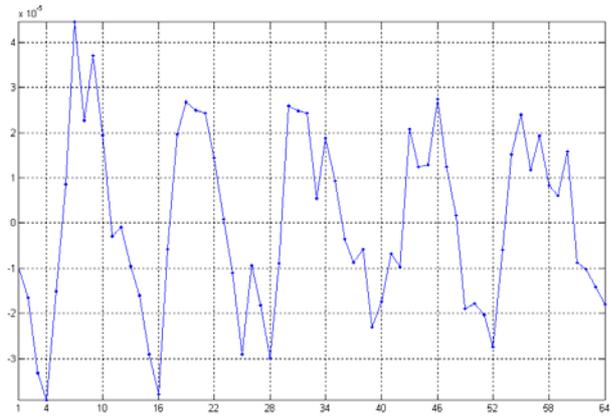


Figura 26: Componente auditiva extraída. Para um sinal quase-periodico, a ACD identifica a componente baseada no atraso temporal determinado a partir das características temporais da resposta hemodinâmica auditiva.

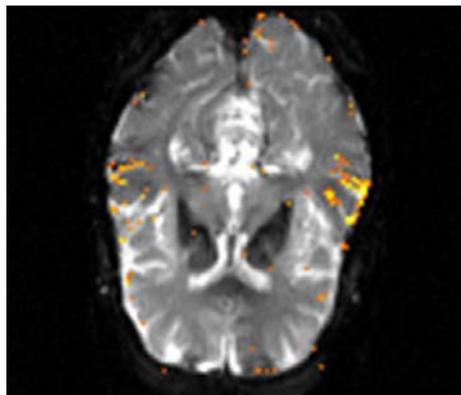


Figura 27: Área de atividade detectada no experimento de fMRI auditivo (fatia 12 do total de 16 fatias). Mapa de localização da atividade obtido por correlação cruzada entre a componente extraída (representando a função de resposta hemodinâmica auditiva) e o conjunto de dados originais (observações) obtidos por fMRI.

CAPÍTULO 7. DISCUSSÃO E CONCLUSÕES

O processamento de sinais biomédicos está composto de várias etapas a serem consideradas; ainda cada contexto de aplicação pode ter suas próprias características que de uma ou outra forma podem limitar o desempenho dos métodos. Dentro desse contexto a extração de fontes ainda é considerada, em muitas aplicações, uma tarefa difícil.

Na maioria dos casos, a extração de todas as fontes é desnecessária. A formulação deste método designado por ACD levou a uma simples regra de aprendizagem que pode obter resultados comparáveis com os de técnicas mais bem estabelecidas na área, onde a formulação pode ser bem mais complexa.

O método aqui proposto assume um sinal de interesse, com um *delay* específico escolhido a priori. No procedimento não requer a escolha de alguma configuração dos registros de entrada, além de que o algoritmo se desempenha consideravelmente eficiente. De fato este método não é afetado (não é sensível) à dimensão dos dados, como é o caso de dados fMRI.

A ACD teve um bom desempenho, na detecção e extração dos sinais desejados, em diferentes aplicações como MCG fetal e Magnetogastrografia, onde foram usados sinais biomagnéticos (37 canais), e por outro lado no mapeamento das atividades cerebrais através de fMRI onde se trabalharam com protocolos bem definidos. Esses resultados abrem possibilidades para outros tipos de aplicações em processamento de sinais biomédicos.

Referências

- Akaike, H. 1974, "New Look at Statistical-Model Identification 2", *Ieee Transactions on Automatic Control*, vol. AC19, no. 6, pp. 716-723.
- Aldroubi, A. & Unser, M. 1996, *Wavelets in medicine and biology* Boca Raton.
- Andrä, W. & Nowak, H. 2006, *Magnetism in Medicine : A Handbook* Wiley-vch.
- Auranen, T. 2002, *Nonparametric statistical analysis of time-frequency representations of magnetoencephalographic data*, **HELSINKI UNIVERSITY OF TECHNOLOGY**.
- Baffa, O., Wakai, R. T., Sousa, P. L., & Verzola, R. M. M. 1995, "Fetal Heart-Rate Monitoring by Magnetocardiograms 1", *Brazilian Journal of Medical and Biological Research*, vol. 28, no. 11-12, pp. 1333-1337.
- Barros, A. K. & Cichocki, A. 2001, "Extraction of specific signals with temporal structure", *Neural Computation*, vol. 13, no. 9, pp. 1995-2003.
- Barros, A. K. & Cichocki, A. "Neural Coding by Redundancy Reduction and Correlation", in *the VII Brazilian Symposium on Neural Networks (SBRN'02)*, pp. 223-226.
- Barros, A. K., Cichocki, A., & Ohnishi, N. "**Extraction of Statistically Dependent Sources with Temporal Structure**", in *VI Brazilian Symposium on Neural Networks (SBRN'00)*, pp. 61-65.
- Boardman, A., Schlindwein, F. S., Rocha, A. P., & Leite, A. 2002, "A study on the optimum order of autoregressive models for heart rate variability 1", *Physiological Measurement*, vol. 23, no. 2, pp. 325-336.
- Calhoun, V. D., Adali, T., Stevens, M. C., Kiehl, K. A., & Pekar, J. J. 2005, "Semi-blind ICA of fMRI: a method for utilizing hypothesis-derived time courses in a spatial ICA analysis", *Neuroimage*, vol. 25, no. 2, pp. 527-538.
- Carneiro, A. A. O., Ferreira, A., MoMoraes, E. R., de Araujo, D. B., Sosa, M., & Baffa, O. 2000, "Biomagnetismo: Aspectos Instrumentais e Aplicações", *Revista Brasileira de Ensino de Física*, vol. 22, pp. 324-338.
- Cichocki, A., Rutkowski, T., & Siwek, K. "Blind signal extraction of signals with specified frequency band", in *12th IEEE Workshop on Neural Networks for Signal Processing, 2002*, pp. 515-524.
- Comani, S., Mantini, D., Pennesi, P., Lagatta, A., & Cancellieri, G. 2004, "Independent component analysis: fetal signal reconstruction from magnetocardiographic recordings", *Computer Methods and Programs in Biomedicine*, vol. 75, no. 2, pp. 163-177.

- Comon, P. 1994, "Independent Component Analysis, A New Concept", *Signal Processing*, vol. 36, no. 3, pp. 287-314.
- de Araujo, D. B. 2002, ***SOBRE NEUROIMAGENS FUNCIONAIS POR MAGNETOENCEFALOGRAFIA E RESSONÂNCIA MAGNÉTICA: NOVOS MÉTODOS E APLICAÇÕES***, DFM.
- de Araujo, D. B., Barros, A. K., Estombelo-Montesco, C., Zhao, H., da Silva, A. C. R., Baffa, O., Wakai, R., & Ohnishi, N. 2005, "Fetal source extraction from magnetocardiographic recordings by dependent component analysis", *Physics in Medicine and Biology*, vol. 50, no. 19, pp. 4457-4464.
- Estombelo-Montesco, C. A., de Araujo, D. B., Silva Filho, A. C. R., Moraes, E. R., Barros, A. K., Wakai, R. T., & Baffa, O. Dependent component analysis for the magnetogastrographic detection of human electrical response activity. *Physiological Measurement* 28, 1-16. 2007a. Ref Type: Journal (Full)
- Estombelo-Montesco, C. A., Sturzbecher, M., Barros, A. K., Baffa, O., & de Araujo, D. B. "A new data-driven analysis for functional MRI", in *Workshop on Cerebral Perfusion and Brain Function: Novel Techniques and Applications*, Salvador, Bahia.
- Ferreira, A. J. 2002, *Aplicação da análise em componentes independentes na compressão de imagem*, Engenharia Electrotécnica e de Computadores, Univ. Técnica de Lisboa.
- Glover, G. H. 1999, "Deconvolution of impulse response in event-related BOLD fMRI", *Neuroimage*, vol. 9, no. 4, pp. 416-429.
- Hyvarinen, A. & Oja, E. 1997, "A fast fixed-point algorithm for independent component analysis 30", *Neural Computation*, vol. 9, no. 7, pp. 1483-1492.
- Hyvarinen, A. & Oja, E. 2000, "Independent component analysis: algorithms and applications 22", *Neural Networks*, vol. 13, no. 4-5, pp. 411-430.
- Irimia, A., Richards, W. O., & Bradshaw, L. A. 2006, "Magnetogastrographic detection of gastric electrical response activity in humans", *Physics in Medicine and Biology*, vol. 51, no. 5, pp. 1347-1360.
- James, C. J. & Hesse, C. W. 2005, "Independent component analysis for biomedical signals 1", *Physiological Measurement*, vol. 26, no. 1, p. R15-R39.
- Liang, H., Lin, Z., & McCallum, R. W. 2000, "Artifact reduction in electrogastrogram based on empirical mode decomposition method", *Medical & Biological Engineering & Computing*, vol. 38, no. 1, pp. 35-41.
- Madisetti, V. K. & Williams, D. B. 1998, ***The digital signal processing handbook***.
- Marple, L. S. 2005, *Digital Spectral Analysis with Applications in C, FORTRAN, and MATLAB* Pearson Higher Education.

- Moraes, E. R., Troncon, L. E. A., Baffa, O., Oba-Kunyioshi, A. S., Wakai, R., & Leuthold, A. 2003, "Adaptive, autoregressive spectral estimation for analysis of electrical signals of gastric origin", *Physiological Measurement*, vol. 24, no. 1, pp. 91-106.
- Rioul, O. & Vetterli, M. Wavelet and signal processing. *IEEE Signal Processing Magazine* 8[4], 14-38. 1991.
Ref Type: Magazine Article
- Sadowsky, J. 1996, "Investigation of signal characteristics using the continuous wavelet transform", *Johns Hopkins Apl Technical Digest*, vol. 17, no. 3, pp. 258-269.
- Spyers-Ashby, J. M., Bain, P. G., & Roberts, S. J. 1998, "A comparison of fast Fourier transform (FFT) and autoregressive (AR) spectral estimation techniques for the analysis of tremor data 3", *Journal of Neuroscience Methods*, vol. 83, no. 1, pp. 35-43.
- Sturzbecher, M. 2006, *Detecção e caracterização da resposta hemodinâmica pelo desenvolvimento de novos métodos de processamento de Imagens Funcionais por Ressonância Magnética*, Faculdade de Filosofia Ciências e Letras de Ribeirão Preto da Universidade de São Paulo – Área de Concentração: Física Aplicada a Medicina e Biologia.
- Suzuki, K., Kiryu, T., & Nakada, T. 2002, "Fast and precise independent component analysis for high field fMRI time series tailored using prior information on spatiotemporal structure 1", *Human Brain Mapping*, vol. 15, no. 1, pp. 54-66.
- Tallon-Baudry, C., Bertrand, O., Delpuech, C., & Pernier, J. **Oscillatory gamma-Band (30-70 Hz) Activity Induced by a Visual Search Task in Humans**. *The Journal of Neuroscience* 17[2], 722-734. 1997.
Ref Type: Journal (Full)
- Wakai, R. T., Strasburger, J. F., Li, Z., Deal, B. J., & Gotteiner, N. L. 2003, "Magnetocardiographic rhythm patterns at initiation and termination of fetal supraventricular tachycardia", *Circulation*, vol. 107, no. 2, pp. 307-312.

Livros Grátis

(<http://www.livrosgratis.com.br>)

Milhares de Livros para Download:

[Baixar livros de Administração](#)

[Baixar livros de Agronomia](#)

[Baixar livros de Arquitetura](#)

[Baixar livros de Artes](#)

[Baixar livros de Astronomia](#)

[Baixar livros de Biologia Geral](#)

[Baixar livros de Ciência da Computação](#)

[Baixar livros de Ciência da Informação](#)

[Baixar livros de Ciência Política](#)

[Baixar livros de Ciências da Saúde](#)

[Baixar livros de Comunicação](#)

[Baixar livros do Conselho Nacional de Educação - CNE](#)

[Baixar livros de Defesa civil](#)

[Baixar livros de Direito](#)

[Baixar livros de Direitos humanos](#)

[Baixar livros de Economia](#)

[Baixar livros de Economia Doméstica](#)

[Baixar livros de Educação](#)

[Baixar livros de Educação - Trânsito](#)

[Baixar livros de Educação Física](#)

[Baixar livros de Engenharia Aeroespacial](#)

[Baixar livros de Farmácia](#)

[Baixar livros de Filosofia](#)

[Baixar livros de Física](#)

[Baixar livros de Geociências](#)

[Baixar livros de Geografia](#)

[Baixar livros de História](#)

[Baixar livros de Línguas](#)

[Baixar livros de Literatura](#)
[Baixar livros de Literatura de Cordel](#)
[Baixar livros de Literatura Infantil](#)
[Baixar livros de Matemática](#)
[Baixar livros de Medicina](#)
[Baixar livros de Medicina Veterinária](#)
[Baixar livros de Meio Ambiente](#)
[Baixar livros de Meteorologia](#)
[Baixar Monografias e TCC](#)
[Baixar livros Multidisciplinar](#)
[Baixar livros de Música](#)
[Baixar livros de Psicologia](#)
[Baixar livros de Química](#)
[Baixar livros de Saúde Coletiva](#)
[Baixar livros de Serviço Social](#)
[Baixar livros de Sociologia](#)
[Baixar livros de Teologia](#)
[Baixar livros de Trabalho](#)
[Baixar livros de Turismo](#)