

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
FACULDADE DE MEDICINA
PROGRAMA DE PÓS-GRADUAÇÃO EM MEDICINA: CIÊNCIAS MÉDICAS

CLASSIFICAÇÃO DE FUSOS DE SONO POR MEIO DE TÉCNICAS NÃO-LINEARES

José Luiz Rybarczyk Filho

Orientadora: Prof. Dra. Márcia L.F. Chaves
Co-Orientador: Prof. Dr. Günther J. L. Gerhardt

Dissertação de Mestrado
2006

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
FACULDADE DE MEDICINA
PROGRAMA DE PÓS-GRADUAÇÃO EM MEDICINA: CIÊNCIAS MÉDICAS

CLASSIFICAÇÃO DE FUSOS DE SONO POR MEIO DE TÉCNICAS NÃO-LINEARES

José Luiz Rybarczyk Filho

Orientadora: Prof. Dra. Márcia L.F. Chaves

Co-Orientador: Prof. Dr. Günther J. L. Gerhardt

Dissertação de Mestrado apresentada
no Programa de Pós-graduação em Medicina:
Ciências Médicas para a obtenção do
título de Mestre em Ciências Médicas

Dissertação de Mestrado
Porto Alegre, 2006.

R989c Rybarczyk Filho, José Luiz

Classificação de fusos de sono por meio de técnicas não-lineares /
José Luiz Rybarczyk Filho ; orient. Márcia L. F. Chaves ; co-orient.
Günther J. L. Gerhardt. – 2009.
85 f. : il.

Dissertação (mestrado) - Universidade Federal do Rio Grande do
Sul. Faculdade de Medicina. Programa de Pós-Graduação em Medicina:
Ciências Médicas, Porto Alegre, BR-RS, 2009.

1. Fases do Sono 2. Classificação 3. Sono 4. Eletroencefalografia I.
Chaves, Márcia Lorena Fagundes II. Gerhardt, Günther J. L. III. Título.

NLM: WL 108

Agradecimentos

- A oportunidade que tive de desenvolver este trabalho no PPG ciências médicas.
- À Profa. Márcia Lorena Fagundes Chaves por ter aceitado me orientar.
- Ao Prof. Günther J. L. Gerhardt por ser meu orientador.
- À Dra. Suzana V. Schönwald.
- À todos os voluntários que dormiram para que pudéssemos trabalhar.
- À Minha mãe Eleonora , e aos meus avós Irma (*in memoriam*) e Oswaldo que sempre me apoiaram.

À minha mãe
Eleonora

Abreviaturas e Siglas

ECG	Eletrocardiograma
EEG	Eletroencefalograma
EMG	Eletromiograma
EOG	Eletrooculograma
FN	False Negative (Falso Negativo)
FP	False Positive (Falso Positivo)
FFT	Fast Fourier Transform (Transformada Rápida de Fourier)
FNE	False Positive Event (Evento Falso Negativo)
FPE	False Positive Event (Evento Falso Negativo)
HW	Half-Width (Meia Largura)
MP	Matching Pursuit
OS	Overlapping Structures (Estruturas Sobrepostas)
REM	Rapid Eyes Moviment (Rápido Movimento dos Olhos)
RK	Rechtschaffen e Kales
SS	Slep Spindle (Fusos de Sono)
TF	Transformada de Fourier
TG	Transformada de Gabor
TN	True Negative (Verdadeiro Negativo)
TP	True Positive (Verdadeiro Positivo)
TNE	True Negative Event (Evento Verdadeiro Negativo)
TPE	True Positive Event (Evento Verdadeiro Positivo)
WFT	Windowed Fourier Transforms (Transformada de Fourier Janelada)

Resumo

As performances² de duas metodologias para detecção de fusos de sono (SS) (Transformada de Gabor, GT e Matching Pursuit, MP) foram comparadas com a análise visual e entre si. O conjunto de dados compreendeu 160 segmentos de EEG pertencentes a 9 adultos jovens normais do sexo masculino, canal C3-A2, contendo 725 fusos detectados visualmente. Nesta amostra, ambas metodologias mostraram uma performance similar. GT localizou 2160 SS ao passo que MP detectou 2766. MP e GT concordam em 564 casos (77.8% dos fusos detectados visualmente). O número de concordâncias entre as metodologias foi 1716 SS, correspondendo a 79.4% dos eventos detectados por GT e a 67% dos detectados por MP. Uma proporção significativa de MP-SS foram reconstruídos como estruturas múltiplas sobrepostas.

²Este artigo foi originariamente escrito em inglês.

Neste trabalho optou-se por usar o termo em português "gorgeio" como sinônimo de "chirp" em inglês, sendo esta sua tradução literal. Mas cumpre salientar que esta expressão não é muito usada em análise de sinais (que prefere "chirp" ou "chirpante"), não existindo um termo definitivo técnico em português.

Abstract

Performance of two time-frequency methodologies for Sleep Spindle (SS) detection (Gabor Transform, GT; Matching Pursuit procedure, MP) were compared with each other and against visual scoring. Data set comprised 160 EEG intervals pertaining to 9 young male subjects, proportionally representative of normal sleep, containing 725 visually detected SS (C3-A2 EEG channel). In this sample, both methodologies showed similarly good performance against visual analysis. GT localized 2160 and MP, 2766 events. MP and GT agreed for 564 (77.8%) of visually detected SS. Overall agreement between automatic methodologies computed 1716 structures, corresponding to (79.4%) of GT-detected, and to (67%) of MP-detected events. A significant (23.8%) proportion of MP-SS atoms were reconstructed as multiple (two or more) overlapping structures.

Sumário

1	Revisão Bibliográfica	12
1.1	Introdução	12
1.2	As Frequências do EEG	13
1.3	O EEG e o Sono	15
1.4	A Macro e a Microestrutura do Sono	16
1.5	Estagiamento do Sono	18
1.6	Definição de Fusos de Sono	21
1.7	Relevância Clínica do Fuso de Sono	21
1.8	Métodos Matemáticos	23
1.8.1	Transformada de Gabor	24
1.8.2	Matching Pursuit	26
2	Objetivos	28
2.1	Objetivo Geral	28
2.2	Objetivos Específicos.	29
	Referências Bibliográficas	30
3	Artigo em Inglês	
	Comparison Between Two Spectral Methods for EEG Sleep Spindle De- tection	41
3.1	Introduction	43
3.2	Methods	46
3.2.1	Gabor Transform	46
3.2.2	Matching Pursuit	47
3.2.3	EEG and Visual Spindle Data Set	49
3.2.4	Method Comparison	49
3.3	Results	51
3.4	Discussion	57
3.4.1	Performance against visual analysis	57
3.4.2	Concordance between MP and GT	58
3.4.3	MP Overlapping Structures	59
3.5	Conclusions	60

4	Artigo em Português	
	Comparação de Dois Métodos Espectrais Para Detecção de Fusos de Sono	62
4.1	Introdução	64
4.2	Metodologia	67
4.2.1	Transformada Gabor	67
4.2.2	Matching Pursuit	68
4.2.3	EEG e Conjunto de Dados do Fuso Visual	70
4.2.4	Comparação Metodológica	71
4.3	Resultados	73
4.4	Discussão	76
4.4.1	Desempenho contra análise visual	76
4.4.2	Concordância entre MP e GT	81
4.4.3	Sobrepostas MP	82
4.5	Conclusões	83
5	Considerações finais e perspectivas	85

Lista de Figuras

1.1	a) Distribuição de freqüências para este mesmo sono usando-se uma Transformada de Fourier janelada em 30s. b)Exemplo de histograma de freqüências de uma noite de sono. Note que os estágios se alternam e acabam por se repetir formando uma ciclicidade durante o sono.	20
1.2	Escalograma mostrando uma região de 7s de sinal de EEG de sono com a presença de dois fusos. Mostra-se a utilização de uma Transformada de Gabor. os tons de cinza são os mesmos que foram usados na figura anterior. Os fusos de sono aparecem em 2s e em 5s. Estas elevações que caracterizam os blocos de frequência são os chamados "átomos de Heisenberg". Note a sobreposição de estruturas e a variação de frequência que estes elementos de curta duração podem apresentar. É um sinal da grande não-estacionariedade do sinal de EEG.	25
3.1	Sketch of benchmark procedure for SS identification. TP=True Positive, TN=True Negative, FP=False Positive and FN=False Negative regions. TPE=True Positive Events, FPE=False Positive Events. Here discrepancy was enhanced for demonstrative purposes. . . .	51
3.2	ROC curves showing Sensitivity/Specificity ratios for GT and MP as a function of voltage in the whole EEG sample. Cutoff threshold is indicated in figure and used in this work for direct comparison between methods.	52
3.3	Total events found by GT and MP relative to visual scoring. Circle size differences are merely illustrative and do not correspond exactly to real proportions in numbers.	54
3.4	Total MP-OS events (Overlapping Structures) relative to GT, MP and visual scoring. Circle size differences are merely illustrative and do not correspond exactly to real proportions in numbers. . . .	55
3.5	Two visual spindles (central portion on the time series) reconstructed as overlapping atoms by MP (MP-OS). On the GT plot one can see two chirping spindles, each of them overlapping a lower frequency structure. See text for details.	56

- 4.1 Procedimento de Benchmark para os SS. Regiões TP=Positivo Verdadeiro, TN=Negativo verdadeiro, FP=Positivo Falso e FN=Negativo Falso. TPE=Eventos Positivos Verdadeiros, FPE=Eventos Positivos Falso. Aqui a discrepância foi aumentada para propósitos demonstrativos. 73
- 4.2 Curva ROC, exibindo relações de Sensitividade/Especificidade para GT e MP como uma função de voltagem na amostra inteira de EEG. Limiar é indicado na figura e usado neste trabalho para comparação direta entre métodos. 74
- 4.3 Eventos totais achados por GT e MP relativo para contagem visual. Diferenças de tamanho de círculo são meramente ilustrativas e não correspondem exatamente a reais proporções em números. 77
- 4.4 Eventos totais de MP-OS (Estruturas Sobrepostas) relativo a GT, MP e contagem visual. Diferenças de tamanho de círculo são meramente ilustrativas e não correspondem exatamente a reais proporções em números. 78
- 4.5 Dois fusos visuais (porção central nas séries temporais) reconstruído como átomos sobrepostos por MP (MP-OS). No esquema de GT, pode-se ver dois fusos gorjeantes, cada um deles sobrepõem uma ou mais estruturas de frequência. Veja o texto para detalhes. 79

Capítulo 1

Revisão Bibliográfica

1.1 Introdução

Do ponto de vista tecnológico, o Eletroencefalograma (EEG) possui uma história fascinante e que se confunde com a própria evolução da captação de sinais. O EEG nasceu em 1929 com um trabalho pioneiro de Hans Berger [6] e desde então já era possível registrar as fracas correntes elétricas geradas no cérebro humano, sem a necessidade de abrir o crânio, e mostrá-las na forma de um registro em papel. Berger denominou esta nova forma de registro fisiológico de "eletroencefalograma", cunhando tal termo. Esta atividade mudava de características de acordo com o estado funcional do cérebro, tais como o sono, a anestesia, a hipóxia (falta de oxigênio) e certas doenças como a epilepsia.

De modo geral, o EEG é usado freqüentemente na experimentação porque o processo é não-invasivo. Além disso, o EEG é capaz de detectar mudanças na atividade elétrica no cérebro em um nível de milissegundos, sendo uma de poucas técnicas disponíveis que possuem tal definição temporal elevada. No EEG de superfície, a gravação é obtida colocando-se os eletrodos no escalpo, geralmente

após ter preparado a área pela abrasão leve e pela aplicação de um gel condutor para reduzir a impedância. Cada eletrodo é conectado a uma entrada de um amplificador diferencial (um amplificador por par de eletrodos), que amplifique a tensão entre eles (tipicamente 100.000 vezes ou 100 DB do ganho da tensão). O sinal resultante da tensão é filtrado por um filtro passa banda, ajustando-se tipicamente em 0.5Hz e em 35-70Hz, respectivamente. O filtro passa baixas (low-pass) filtra fora tipicamente sinais eletrolvânicos lentos, visto que o filtro passa altas (high-pass) filtra sinais eletromiográficos (ruído proveniente de atividade muscular). O sinal filtrado vai, então, para o papel (em sistemas mais antigos, analógicos), ou é indicado em uma tela de computador. A amplitude do EEG é aproximadamente $100 \mu V$ quando medida no escalpo, e aproximadamente $1-2 mV$ quando medida na superfície do cérebro (não trataremos aqui de medidas intracorticais) [52, 3].

1.2 As Frequências do EEG

No EEG de superfície em humanos, incluindo o EEG de sono, os potenciais elétricos captados variam, em amplitude, desde cerca de $\pm 0.1 \mu V$ até várias centenas de μV (com um limite prático freqüentemente estabelecido ao redor de $\pm 250 \mu V$). A maior parte da informação de EEG conhecida atualmente situa-se na faixa de freqüências entre 0.1Hz e 100Hz. Na prática, devido à aplicação de filtros, o limite superior de freqüências captadas sem atenuação significativa fica muitas vezes abaixo de 40Hz [42, 59, 52]. Esse intervalo de freqüências não é de

forma alguma absoluto, e provavelmente se deve a limitações dos equipamentos utilizados; existem, por exemplo, pesquisas envolvendo sinais de EEG de sono de alta frequência com muito baixa amplitude que procuram estabelecer a relação destas frequências com processamento de informação adquirida durante o dia [47, 14]. A seguir encontra-se a nomenclatura utilizada em neurofisiologia [52, 42] para subdivisões desse intervalo de frequências:

- Delta: Abaixo de 3.5 Hz
- Theta: 4 a 7.5 Hz
- Alfa: 8 a 13 Hz
- Sigma: 12 a 15 Hz
- Beta: acima de 13 Hz;
- Beta 1 entre 12.5 e 17.9 Hz
- Beta 2 entre 18 e 23.9 Hz
- Gama: geralmente acima de 35 Hz.

Algumas dessas denominações de bandas de frequências, como delta, theta, alfa e beta, vêm sendo classicamente utilizadas na análise visual do sinal de EEG. Outras, como a sigma, gama e subdivisões da banda beta, embora sejam termos cunhados pelos primeiros investigadores, só mais recentemente vêm sendo utilizadas de forma sistemática, no contexto das análises quantitativas. Provavelmente por esse motivo, encontra-se grande variabilidade nas suas definições.

Como veremos adiante, a informação obtida a partir do EEG de sono baseia-se fundamentalmente nas variações de seu conteúdo espectral [11].

1.3 O EEG e o Sono

Entre os diversos estados fisiológicos que podem ser tratados com o EEG, neste trabalho vamos nos dedicar ao EEG de sono, que possui algumas peculiaridades [42, 22, 41]. Com o surgimento de uma vida urbana cada vez mais independente do ciclo natural de dias e noites com a qual a espécie humana evoluiu, é natural pensar que o sono esteja começando a sofrer mudanças ou, pelo menos, uma pressão em uma direção anti-natural. Nas metrópoles modernas, onde vive uma parcela crescente da população, mais e mais pessoas são obrigadas a assumir padrões de sono e vigília que estão se distanciando dos velhos hábitos de seus ancestrais. Não é de se admirar portanto que o sono seja atualmente objeto de estudos intensivos; o que talvez pudesse causar surpresa é o fato de ser ainda o sono uma incógnita tão grande do ponto de vista fisiológico. Ainda não se sabe exatamente por que o ser humano (assim como outros animais) precisa dormir [52, 42, 41], nem se desvendaram completamente os mecanismos que governam o sono normal. Sabe-se que o sono é um estado fisiológico essencial para a manutenção homeostática do organismo [52]. Sabe-se também que, se o período de sono não for suficiente ou reparador, a vigília ficará comprometida [42, 46]. Ainda que as funções básicas do organismo sejam preservadas, qualidade de vida, produtividade e sensação geral de bem estar

serão prejudicadas.

O modelo atualmente melhor aceito para a regulação do sono humano normal considera-o como um acoplamento de dois processos [49]: sono REM, ainda relativamente pouco compreendido, mais dependente do marca-passo circadiano ("relógio biológico") e no qual ocorrem os sonhos; e sono não-REM (NREM), também chamado de sono quieto, aparentemente mais relacionado com variações homeostáticas (ou seja, da necessidade ou pressão para dormir) [9, 8, 16]. As diversas funções biológicas cumpridas pelo sono humano vêm sendo aos poucos desvendadas, com ênfase, nos últimos anos, nas propriedades locais de processamento cerebral de informação durante o sono [52, 17, 16].

1.4 A Macro e a Microestrutura do Sono

Em 1968 muitos trabalhos já haviam sido elaborados com registro de EEG em sono, assim como a evolução da técnica se mostrava evidente. Porém não havia uma padronização das nomenclaturas e nem dos critérios de avaliação. Neste sentido, um comitê formado de eminentes pesquisadores em fisiologia e distúrbios do sono reuniu-se e fez a primeira tentativa de padronização do estagiamento do sono. Estas reuniões resultaram num manual, conhecido como o *Manual de terminologias e técnicas para escoreamento de sono de Rechtschaffen e Kales* [59] (ou manual RK) e usado vastamente até os dias de hoje. Por um lado, este manual (que não foi aceito de forma imediata mas que se tornou popular a partir de meados da década de 1970) foi uma benção para a classificação e

para a homogeneização dos estudos com sono. Por outro lado, este manual foi elaborado em uma época quando toda a possibilidade de quantificação do sinal passava pelo crivo do olho humano e este detalhe acabou sendo passado adiante nas gerações seguintes de pesquisadores tornando muito difícil padronizar ferramentas analíticas sobre o sinal quando o *padrão ouro* não pode ser considerado com certeza absoluta [33, 42, 38, 46, 52, 20, 64, 53, para uma análise mais aprofundada deste problema].

Em outras palavras: o próprio manual prevê que haverá discrepâncias pequenas (de até 10%) entre peritos de forma que não se conseguirá nunca acordância absoluta entre nenhum método automático de análise e o manual *standard*. Com este manual se pode dar início ao estudo de duas ordens de grandeza distintas no sono: a macroestrutura e a microestrutura das quais tratar-se-á na seqüência. De qualquer forma o manual RK pode ser considerado um manual-ferramenta de análise de freqüência visual [59, 53, 19].

A macroestrutura consiste em decompor o sinal de EEG em estágios: W, I, II, III, IV, REM. A microestrutura está relacionada a grafoelementos como: Fusos de Sono, Complexos-K, ondas dente de serrote, ondas vertex, etc.

O manual RK é o ponto de partida de qualquer análise do sinal de EEG de sono. Ele define intervalos de frequência e amplitudes para vários estágios de sono e define canais próprios para o estagiamento. Nesta tentativa de padronização do sono aparecem as primeiras referências a duas ordens básicas de grandezas no estudo do EEG de sono: uma ordem de grandeza global, onde por várias *épocas*, ou seja, intervalos de 15 ou mais segundos os padrões das

ondas mantêm-se com frequências baixas ou mais altas e outra de ordem local, ou seja, de poucos segundos ou até mesmo menos de meio segundo de duração. Estes pequenos elementos (microestrutura) são indicativos de diferentes processos fisiológicos e são chamados de grafoelementos de sono, ou também de *eventos fásicos* [20, 64, 52, 42, 26, 21].

1.5 Estagiamento do Sono

O sono foi dividido em estágios a partir de RK (Figura 1.1), e aceitos de forma mais ou menos uniforme pela comunidade científica dentro dos critérios clássicos. Estes estágios de sono são assim definidos [42, 59]:

- Estágio W: estágio de vigília (Wakefulness). O EEG contém atividade alfa e/ou atividade de frequências mistas de baixa amplitude.
- Estágio I: É um estágio de frequências mistas de voltagem relativamente baixa, sem movimentos oculares rápidos. Este estágio é definido como uma transição de fases frente a outros estágios. Também possui muita presença de artefatos. (4 a 5% do sono total).
- Estágio II: Caracterizado por pequenas oscilações de 12Hz a 14Hz no traçado (chamadas de fusos de sono, ou *spindles*) e complexos K (oscilações muito amplas e lentas, bi ou polifásicas). Estas estruturas aparecem com frequência sobre um fundo de oscilações de baixa amplitude. (Este estágio é o mais freqüente, compondo cerca de 45% a 50% do tempo de uma noite

de sono).

- Estágio III: Quantidades moderadas (20% a 50%) de atividades de ondas lentas com amplitude alta (mínimo de 75 microvolts). Nesse estágio temos um aumento da atividade delta no intervalo de 0.5Hz-2.0Hz. Porém o limite de 2.0Hz é muitas vezes extendido até 4Hz. (4 a 6% do sono total)
- Estágio IV: Quantidades grandes (acima de 50%) de atividades de ondas lentas com alta amplitude (mínimo de 75 microvolts). (Este é considerado o estágio de sono mais profundo, no qual o limiar para despertar é mais alto) (12 a 15% do sono total).
- Estágio REM: EEG de frequências mistas com voltagem relativamente baixa, juntamente com movimentos oculares rápidos, episódicos, e amplitude baixa no eletromiograma. (Este é o estágio em que 95% dos sonhos acontecem). O escoreamento de tal estágio exige: presença de REMs, ausência de fusos de sono e complexos-K, baixo tônus muscular, respiração e Eletrocardiograma (ECG) irregulares. O estagiamento REM está fortemente ligado a presença de eventos fásicos envolvendo um alto grau de complexidade. (20 a 25% do sono total).

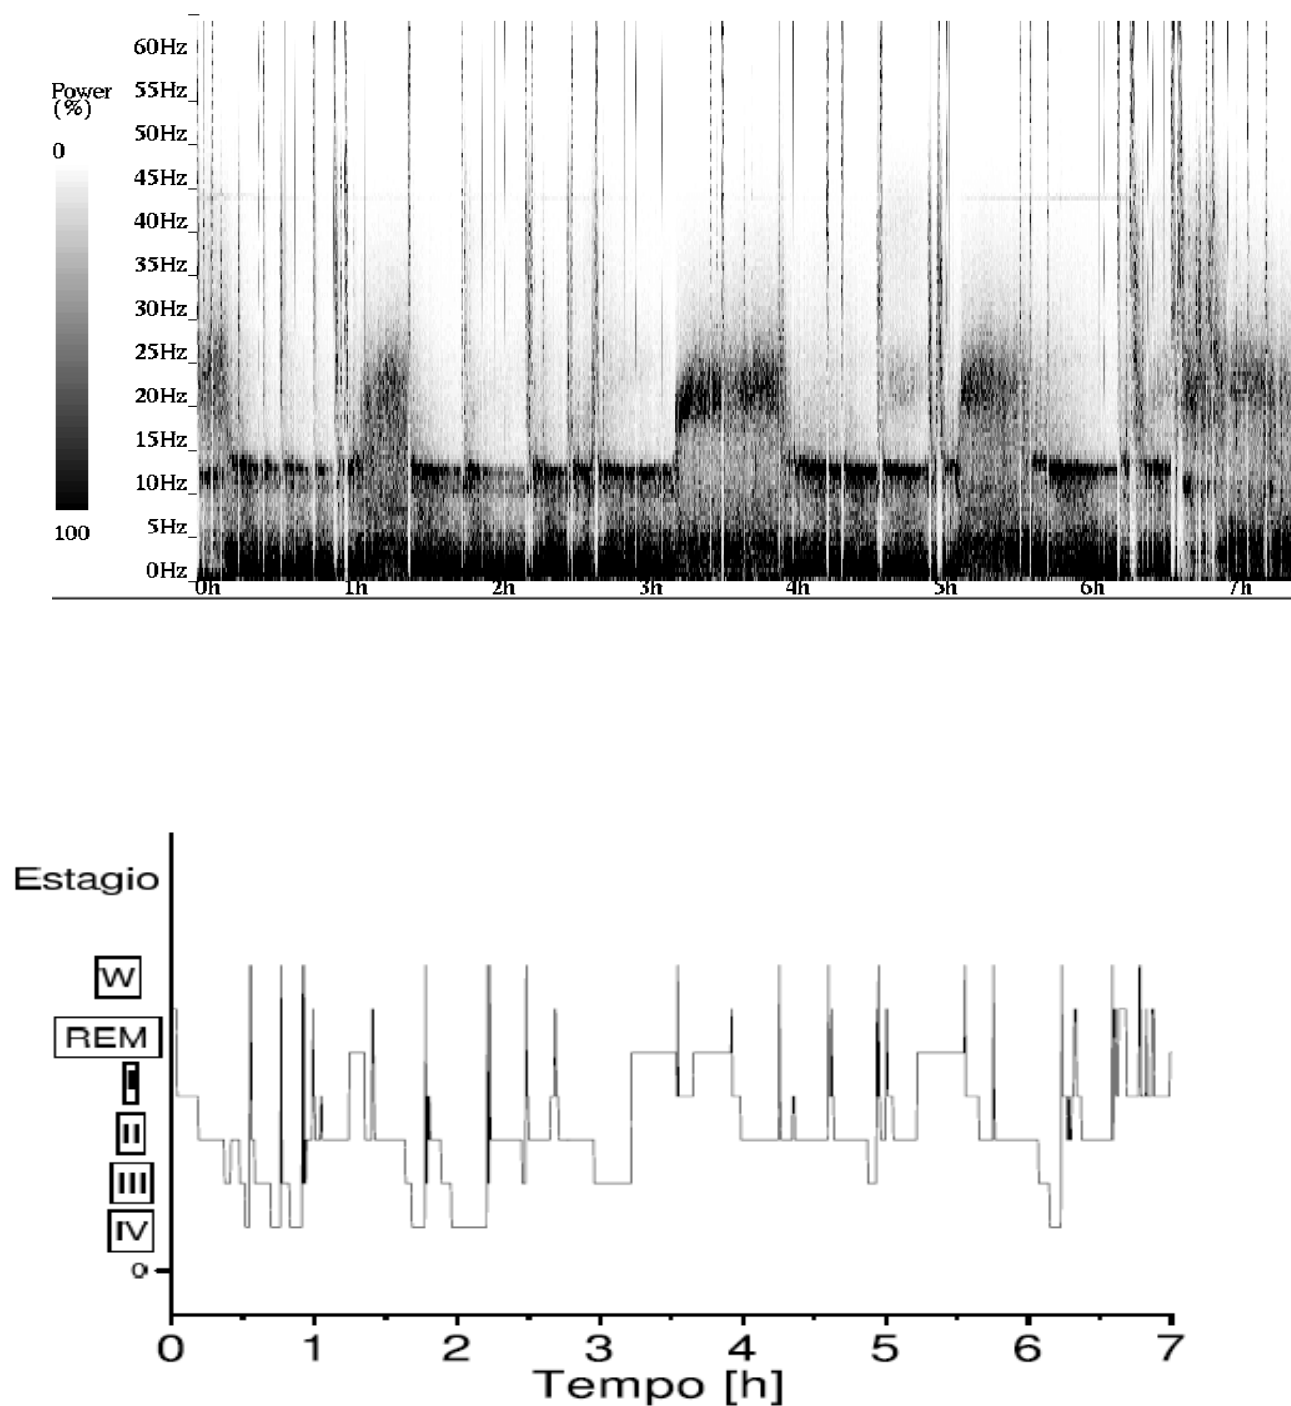


Figura 1.1: a) Distribuição de frequências para este mesmo sono usando-se uma Transformada de Fourier janelada em 30s. b) Exemplo de histograma de frequências de uma noite de sono. Note que os estágios se alternam e acabam por se repetir formando uma ciclicidade durante o sono.

1.6 Definição de Fusos de Sono

Desde o começo das gravações de EEG, varios tipos diferentes de oscilações foram observadas na atividade elétrica do cérebro. Entre eles, atenção especial foi dada a uma certa onda “ que aumentava e diminuía “ com freqüência ao redor 13 Hz. Aceita-se geralmente a definição dessa estrutura por Rechtschaffen e por Kales (1968): "a presença de um fuso de sono deve ser definida somente para aqueles com mais do que 0.5s de duração isto é, alguém deve ser capaz de contar 5 ou 7 ondas distintas dentro de meio segundo de período". Por isso o termo “Fuso de Sono“- No inglês é chamado de Sleep Spindle (SS)- tem sido largamente usado na pesquisa de sono, este termo deverá ser conservado. Este termo deve ser somente usado para descrever atividade entre 12Hz e 14Hz.

Esta definição de fuso foi complementada, mais tarde, por M. Steriade [46, 66]: "Fusos de sono são o epítome de sincronização do EEG para o início do sono. Estes dois tipos de oscilações (12Hz e 14Hz) são definidas pela associação de dois ritmos distintos: o comportamento oscilatório dos fusos para 7-14Hz com duração de 1.0-2.0 segundos, e recorrência periódica nos fusos com um ritmo lento de 0.1- 0.2Hz"

1.7 Relevância Clínica do Fuso de Sono

Este elemento particular é um epifenômeno originado em marcapassos talâmi-

cos [20], possivelmente associado com consolidação da memória [65] assim como habilidade mental [36]. A localização automática de fusos de sono para análise posterior é um ponto de partida para modelagem de oscilações rápidas globais do cérebro.

Os fusos de sono aparecem ao longo de toda a vida, desde o nascimento até a velhice. Sua morfologia muda um pouco com a idade. Eles aparecem em seres humanos a partir das 6 semanas e começam a mudar em amplitude e duração. Seu pico de duração ocorre em torno das 13 semanas (até 6s) e então decrescem até o final do primeiro ano de vida (em 1.5s) [55, 17, 44, 75]. Muitas destas mudanças observadas nos fusos podem estar relacionadas com o desenvolvimento da árvore dendrítica no núcleo reticular talâmico. O efeito mais pronunciado das modificações dos fusos com a idade ocorre na velhice, apresentando uma grande redução [55, 18, 73, 75].

Além disso existem relações entre os fusos de sono e certas patologias. Um exemplo é a epilepsia, onde a frequência dos fusos parece ser significativamente menor para pacientes com epilepsia generalizada do que para aqueles com crises parciais [75]. Pacientes com crises parciais complexas também possuem diferença nas frequências dos seus fusos se comparados com pacientes com crises parciais simples [72, 15, 75, 67]. Porém estes mecanismos não estão bem conhecidos nem estabelecidos ainda, podendo ser até mesmo efeito residual de medicamento [75, 66, 15] que poderia estar mascarando diferenças fisiológicas mais profundas na origem das crises epilepticas.

Os fusos de sono refletem, de alguma forma, a atividade de dormir- acordar e

o sistema de controle poderia relacionar os fusos com a hipersonia. Hipersonia pode ser definida como o sono excessivo de dia, ou sono prolongado, ou ambos. Relata-se [18, 75] que a densidade média de fusos do sono (o número de fusos de sono se alonga por toda uma unidade tempo) é mais elevada nos pacientes hipersonolentos, especialmente aqueles com o hipersônia idiopática. No começo e no fim do tempo noturno do sono, a densidade dos fusos de sono também é aumentada nos pacientes hipersonolentos se comparados aos normais [18].

1.8 Métodos Matemáticos

A primeira tentativa de quantificação de um sinal é com base nas informações que se tem visualmente deste sinal. Deste ponto de vista, pode-se considerar que o sono é uma área privilegiada pois as caracterizações e classificações das atividades foram feitas com base em frequências predominantes desde o início. Assim mesmo, somente na década de 1970 é que se iniciou o estudo do sinal via transformadas de Fourier [52], que é a primeira escolha quando se possui uma forma de gravar e analisar computacionalmente os dados.

Ainda assim cumpre salientar que estes estudos estão relacionados a centros de pesquisa e que, nesta época, uma gravação digital de um sinal não fazia parte do dia-a-dia do médico clínico e estudos envolvendo patologias e controles eram muito complexos. Somente na década de 1990, com a popularização dos microcomputadores, é que se começou a empregar ferramentas de análise quantitativa alternativas ao escoreamento visual (ou juntamente com ele) uma vez que

popularizou-se também a quantidade de aparelhos e *softwares* disponíveis para este fim. Nesta seção será descrito os métodos aqui aplicados na análise dos sinais de EEG: Transformada de Gabor e Matching Pursuit.

1.8.1 Transformada de Gabor

Uma Transformada de Gabor é um caso especial de uma Transformada de Fourier Janelada (WFT)(figura 1.2). Para um sinal $S(t)$ uma transformada janelada está definida como [48]

$$W\{S(t)\}(b, s) = \int_{-\infty}^{\infty} S(t)\Psi(t - b, s)dt, \quad (1.1)$$

onde $\Psi[(t - b), s]$ é uma base tempo-freqüência com localização temporal (b) e freqüência (s). No caso exato de uma GT, é a onda plana modulada por uma forma de curva Gaussiana.

$$\Psi[(t - b), s] = \frac{1}{\sqrt{2\pi\xi}} e^{-(t-b)^2/2\xi^2} e^{ist}, \quad (1.2)$$

que possui uma estrutura que maximiza a relação entre tempo e freqüência [48].

O Poder Espectral aqui está da mesma maneira definido como no espaço de Fourier como

$$P\{W(b, s)\} = |W(b, s)|^2. \quad (1.3)$$

Percorrendo 256-pontos (2s) foram aplicadas janelas deslocadas com passos de um ponto às séries de tempo, rendendo uma representação de tempo do espectro de (1.3). O valor de limiar da raiz quadrada de (1.3) será usado aqui como




Figura 1.2: Escalograma mostrando uma região de 7s de sinal de EEG de sono com a presença de dois fusos. Mostra-se a utilização de uma Transformada de Gabor. Os tons de cinza são os mesmos que foram usados na figura anterior. Os fusos de sono aparecem em 2s e em 5s. Estas elevações que caracterizam os blocos de frequência são os chamados "átomos de Heisenberg". Note a sobreposição de estruturas e a variação de frequência que estes elementos de curta duração podem apresentar. É um sinal da grande não-estacionariedade do sinal de EEG.

um parâmetro livre. Um candidato de SS corresponde à sucessão de passo para a qual a raiz quadrada do poder espectral é maior que este valor.

1.8.2 Matching Pursuit

Matching Pursuit não é uma transformada, é uma aproximação adaptável do sinal com um conjunto de funções fundamentais escolhidas de um dicionário. Descreve o sinal por meio de "átomos" fundamentais (as funções do dicionário, como palavras em uma língua). MP com dicionários de tempo-freqüência foram introduzidos em [45] e um esquema de correção para dados de tamanho grande, como EEG, foi complementado em [20]. Na aproximação de MP, um sinal $S(t)$ é obtido, e são feitos passos subseqüentes de adaptação na escritura $S(t)$ em termos de um dicionário básico e redundante de funções $D = \{g_{\gamma_i}\}$

$$S(t) \simeq \sum_{i=1}^M a_i g_{\gamma_i}, \quad (1.4)$$

onde γ_i representa um conjunto de parâmetros que caracterizam o dicionário de funções M é o número de passos e a_i é um termo de amplitude, o qual pode ser incorporado em g sem perda de generalidade. Para um sinal de tamanho N , $D = \{g_{\gamma_i}\}$ é um dicionário redundante de $i > N$ elementos que incluirão pelo menos N vetores linearmente independentes.

Como um filtro adaptável, o procedimento de MP combina o sinal com uma função g_{γ_i} a cada passo i , deixando um resíduo $R_{i+1}S(t)$ para ser combinado pelo mesmo procedimento em passo $i + 1$. Realmente MP projeta $S(t)$ em um

vetor g_γ e avalia o resíduo $R_1S(t)$:

$$S(t) = \langle S(t), g_\gamma \rangle g_\gamma + R_1S(t). \quad (1.5)$$

Se g_γ é uma base de ortogonal, pode-se escrever

$$\|S(t)\|^2 = |\langle S(t), g_\gamma \rangle|^2 + \|R_1S(t)\|^2. \quad (1.6)$$

Para minimizar $\|R_1S(t)\|$, g_γ é escolhido tal que $|\langle S(t), g_\gamma \rangle|$ é máximo ou pelo menos sub-ótimo. O procedimento é iterativamente continuado e substitui $R_1S(t)$ pelo original $S(t)$ até algum limiar de energia ou número de coeficiente de repetições seja alcançado. Generalizando o procedimento:

$$R_iS(t) = \langle R_iS(t), g_\gamma \rangle g_\gamma + R_{i+1}S(t), \quad (1.7)$$

para $0 < i < M$ onde $R_0S(t) \equiv S(t)$.

O dicionário usado para análise de tempo e freqüência é construído a partir de funções de Gabor reais, como

$$g_\gamma(t) = \alpha e^{-\pi((t-b)/s)^2} \sin(2\pi\omega(t-b)/N + \phi), \quad (1.8)$$

onde N é o tamanho do sinal, o conjunto $\gamma = \{\alpha, b, w, s, \phi\}$ representa parâmetros de funções do dicionário e α é escolhido tal que $\|g_\gamma\| = 1$. Um conjunto de deltas de Dirac e funções de Fourier é acrescentado a este dicionário para lidar com estruturas bem-localizadas em tempo e freqüência. Esta escolha não é singular; como explicado em [45], é importante adaptar o dicionário à classe de sinal que está sendo decomposto.

Capítulo 2

Objetivos

2.1 Objetivo Geral

O objetivo deste estudo é comparar duas metodologias de tempo e frequência - Matching Pursuit (MP) [45] e Transformada de Gabor (GT) [48] - para detecção de fusos em uma amostra de sono obtida de homens jovens saudáveis. GT é um caso especial de um janelamento em Transformada de Fourier que maximiza relação entre tempo e frequência, que foram usado em sinais de EEG, em [39] (em um procedimento matched-filtering) e [63] avaliando SS. Matching Pursuit são procedimentos gerais para computar representações adaptáveis confiando na recursividade, aproximação adaptável do sinal com funções escolhidas de um grande conjunto de formas de ondas. Isto inclui uma família de funções de Gabor como um jogo básico, com funções de Fourier e de Dirac delta somadas. MP foi empregado em vários estudos com características de SS nos últimos anos [64, 73, 21]. O foco central aqui é em como estes dois algoritmos se comparam, uma vez que seu desempenho foi aperfeiçoado para coincidir com a análise visual.

2.2 Objetivos Específicos.

- Elaborar programas para o cálculo da transformada de Gabor.
- Testar programas de domínio público "Matching Pursuit".
- Classificar os Fusos de Sono encontrado por ambas metodologias.

Referências Bibliográficas

- [1] Achermann, P., Borbély, A. A.; *Coherence analysis of the human sleep electroencephalogram*, **Neuroscience 85(4)** p.1195, 1998
- [2] A. Akin, T.Akgül; *Detection of sleep spindles by discrete wavelet transform*, **Proceedings of the IEEE 24th Annual Bioengineering Conference, Northeast,9-10 April** p.15, 1998
- [3] Armitage, R.; *The discrimination of EEG frequencies in NREM and NREM sleep stages in healthy young adults*, **Sleep 18(5)** p.334, 1995
- [4] ASDA, American Sleep Disorders Association; *ASDA Report on practice parameters for the indications for PSG and related procedures*, **Sleep 20(6)** p.406, 1997
- [5] T. Akgül, M. Sun, R.J. Scabassi, A.E. Cetin,; *Characterization of sleep spindles using higher order statistics and spectra*, **IEEE Transactions on Biomedical Engineering (47) 8** p.997, 2000
- [6] Berger, H.;*Über das Elektroenkephalogramm des Menschen*, **Archiv für Psychiatrie und Nervenkrankheiten 87** p.527, 1929

- [7] R. Bódizs, T. Kis, A.S. Lázár, L. Havrán, P. Rigó, Z. Clemens, P. Halász;; *Prediction of general mental ability based on neural oscillation measures of sleep*, **Journal of Sleep Research** **14** p.285, 2005
- [8] Borbély, A.; *A two process model of sleep regulation*, **Hum. Neurobiol.** **1 (3)** p.195 1982
- [9] Borbély, A., Achermann, P., Trachsel, L., Tobler, I.; *Initiation and initial sleep intensity: interactions of homeostatic and circadian mechanisms*, **J. Biol. Rhythms** **4 (2)** p.149, 1989
- [10] K. Campbell, A. Kumar, W. Hofman,;;*Human and automatic validation of a phase-locked loop spindle detection system*, **Electroencephalography and Clinical Neurophysiology** **48** p.602, 1980
- [11] Chatrian, G. E., Bergamini, L., Dondey, M., Klass, D. W., Lennox-Buchtall, M., Petersen, I.; *A glossary of terms most commonly used by clinical electroencephalographers*, **Electroencephalography and Clinical Neurophysiology** **37** p.538, 1974
- [12] Corsi-Cabrera, M., Arce, C., Ramos, J., GUEvara, M. A.; *Effect of spatial ability and sex on inter- and intrahemispheric correlation of EEG activity*, **Electroencephalography and Clinical Neurophysiology** **102** p.5, 1997
- [13] Da Rosa, A. C., Kemp, B., Paiva, T., Lopes da Silva, F. H., Kamphuisen, H. A. C.; *A model-based detector of vertex waves and K complexes in sleep electroencephalogram*, **Electroencephalography and Clinical Neurophysiology** **78** p.71, 1991

- [14] Draguhn A, Traub RD, Schmitz D, Jefferys JG; *Electrical coupling underlies high-frequency oscillations in the hippocampus in vitro*, **Nature** **394** p.189, 1998
- [15] M E Drake, DJ Dijk, E Werth, K Biederman, A Borbely; *Sleep Spindles in Epilepsy*, **Electroencephalography and Clinical Neurophysiology** **22 (3)** p.144, 1991
- [16] Dijk, D-J., Czeisler, C.A.; *Contribution of the Circadian Pacemaker and the Sleep Homeostat to Sleep Propensity, Sleep Structure, Electroencephalographic Slow Waves, and Sleep Spindle Activity in Humans*, **The Journal of Neuroscience** **15 (5)** p.3526, 1995
- [17] Dijk, D-J., Hayes, B., Czeisler, C.A.; *Dynamics of electroencephalographic sleep spindles and slow wave activity in men: effect of sleep deprivation*, **Brain Research** **626** p.190, 1993
- [18] Dijk D-J, Duffy JF, Riel E, Shanahan TL, Czeisler CA.; *Ageing and the circadian and homeostatic regulation of human sleep during forced desynchrony of rest, melatonin and temperature rhythms*, **J Physiol.** **516** p.611, 1999
- [19] Durka, P. J.; *Time frequency analysis of EEG*, **Institute of Experimental Physics, Warsaw University** Tese de Doutorado, 1996
- [20] Durka PJ, Ircha D, Blinowska KJ; *Stochastic time-frequency dictionaries for Matching Pursuit*, **IEEE Transactions on Signal Processing** **49 (3)** p.507, 2001

- [21] Durka PJ, Szelenberger W, Blinowska K, Androsiuk A, Myszka, W; *Adaptive time-frequency parametrization in pharmaco EEG*, **Journal of Neuroscience Methods** **117** p.65, 2002
- [22] Durka PJ, Malinowska U, Szelenberger W, Wakarow A, Blinowska K; *High resolution parametric description of slow wave sleep*, **Journal of Neuroscience Methods** 2005, in press.
- [23] Ehlers, C. L., Kupfer, D. J., Buysse, D. J., Cluss, P. A., Mirewald, J. M., Bisson, E. F., Grochocinski, V. J.; *The Pittsburgh study of normal sleep in young adults: focus on the relationship between waking and sleeping EEG spectral patterns*, **Electroencephalography and Clinical Neurophysiology** **106** p.199, 1998
- [24] Espa F, Ondze B, Deglise P, Billiard M, Besset A. *Sleep architecture, slow wave activity, and sleep spindles in adult patients with sleepwalking and sleep terrors*, **Clinical Neurophysiology** **111** p.929, 2000
- [25] Franaszczuk PJ, Bergey GK, Durka PJ, Eisenberg HM.; *Time-Frequency analysis using the matching pursuit algorithm applied to seizures originating from the mesial temporal lobe*, **Electroencephalography and Clinical Neurophysiology** **106** p.513, 1998
- [26] Gaillard JM, Blois R; *Spindle density in sleep of normal subjects*, **Sleep** **4 (4)** p.385, 1981
- [27] Gais S, Mölle M, Helms K, Born J.; *Learning-dependent increases in sleep spindle density*, **The Journal of Neuroscience** **22 (15)** p.6830, 2002

- [28] Guazzelli M, Feinberg I, Aminoff M, Fein G, Floyd TC, Maggini C.; *Sleep Spindles in Normal Elderly: Comparison with Young Adult Patterns and Relation to Nocturnal Awakening, Cognitive Function and Brain Atrophy*, **Electroencephalography and Clinical Neurophysiology** **63** p.526, 1986
- [29] R. Gribonval; *Fast Matching Pursuit with a Multiscale Dictionary of Gaussian Chirps*, **IEEE Transactions on Signal Processing** **49 (5)** p.994, 2001
- [30] J. Hasan,; *Past and Future of Computer-Assisted Sleep Analysis and Drowsiness Assessment*, **Journal of Clinical Neurophysiology** **13 (4)** p.295, 1996
- [31] Hassainia, F., Petit, D., Nielsen, T., Gauthier, S., Montplaisir, J.; *Quantitative EEG and statistical mapping of wakefulness and REM sleep in the evaluation of mild to moderate alzheimer's disease*, **European Neurology** **37** p.219, 1997
- [32] Himanen SL, Virkkala J, Huhtala H.; *Spindle frequencies in sleep EEG show U-shape within first four NREM sleep episodes*, **Journal of Sleep Research** **11** p.35, 2002
- [33] M. Hirschkowitz,; *Standing on the shoulders of giants: the Standardized Sleep Manual after 30 years*, **Sleep Medicine Reviews** **4 (2)** p.169, 2000
- [34] Hoey, G. van, Philips, W., Lemahieu, I.; *Time-frequency analysis of EEG signals*, **Proceedings of the ProRISC Workshop on Circuits, Systems and Signal Processing** 1997

- [35] Huupponen E, Värri A, Himanen SL, Hasan J, Lehtokangas M, Saarinen J; *Optimization of sigma amplitude threshold in sleep spindle detection*, **Journal of Sleep Research** **9** p.327, 2000
- [36] E.J. Huupponen, A.J. Saastamoinen, J.T. Virkkala, S.J. Himanen, J. Hasan, A.O. Värri, *Determination of EEG sleep spindle frequency with DFT and Matching Pursuit approaches*, **Proceedings of the IASTED International Conference on Biomedical Engineering, Innsbruck, Austria, 16-18 February** p.383, 2005
- [37] E. Huupponen, W. De Clercq, G. Gómez-Herrero, A. Saastamoinen, K. Egiazarian, A. Värri, B. Vanrumste, A. Vergult, S. Van Huffel, W. Van Paesschen, J. Hasan, S.L. Himanen, *Determination of dominant simulated spindle frequency with different methods*, **Journal of Neuroscience Methods** (to appear), 2006
- [38] Jankel WR and Niedermeyer E; *Sleep spindles*, **Journal of Clinical Neurophysiology** **2 (1)** p.1, 1985
- [39] Jobert M, Poiseau P, Jähnig P, Schultz S, Kubicki H. *Topographical analysis of sleep spindle activity*, **Neuropsychobiology** **26** p.210, 1992
- [40] M. Jobert, C. Tismer, E. Poiseau, H. Schulz, *Wavelets-a new tool in sleep biosignal analysis*, **Journal of Sleep Research** **3** p.223, 1994
- [41] Knoblauch V, Martens WLJ, Wirz-Justice A, Cajochen C.; *Human sleep spindle characteristics after sleep deprivation*, **Clinical Neurophysiology** **114** p.2258, 2003

- [42] Krieger, M. H., Roth, T., Dement, W. C.; *Principles and Practice of Sleep Medicine*, **W. B. Sanders Company** 2000
- [43] Kubicki S, Herrmann WM; *The future of computer-assisted investigation of the polysomnogram: Sleep microstructure*, **Journal of Clinical Neurophysiology** **13 (4)** p.285, 1996
- [44] Landolt HP, Dijk DJ, Achermann P, Borbely AA.; *Effect of age on the sleep EEG: slow-wave activity and spindle frequency activity in young and middle-aged men*, **Brain Res.** **738** p.205, 1996
- [45] Mallat S, Zhang Z; *Matching Pursuits with time-frequency dictionaries*, **IEEE Transactions on Signal Processing** **41 (12)** p.3397, 1993
- [46] Matsubayashi K, Ishiyama Y, Homma I, Ebe, M. *Some characteristics of sleep spindles derived from automatic analysis*, **Sleep** **4 (4)** p.392, 1981
- [47] McCornick, L., Nielsen, T., Nicolas, A., Ptito, M., Montplaisir, J.; *Topographical distribution of spindles and K-complexes in normal subjects*, **Sleep** **20 (11)** p.939, 1997
- [48] Meyer, Y.; *Wavelets: Algorithms and applications*, **Society for Industrial and Applied Mathematics** 1993
- [49] Mima, T., Hallett, M.; *Corticumuscular coherence: a review*, **Journal of Clinical Neurophysiology** **16 (6)** p.501, 1999
- [50] Nakamura M, Uchida S, Maehara T, Kawai K, Hirai N, Nakabayashi T.; *Sleep spindles in human prefrontal cortex: an electrocorticographic study*, **Neuroscience Research** **45** p.419, 2003

- [51] Nicolas, A., Petit, D., Rompre, S., Montplaisir, J.; *Sleep spindle characteristics in healthy subjects of different age groups*, **Clinical Neurophysiology** **112** p.521, 2001
- [52] Niedermeyer, E., Lopes da Silva, F.; *Eletroencephalography: basic principles, clinical applications and related topics 4^a ed.*, **Lippincott Williams & Wilkins** 1999
- [53] Nuwer, M.; *Assessing digital and quantitative EEG in clinical settings*, **Journal of Clinical Neurophysiology** **15 (6)** p.458, 1998
- [54] Ondze B, Espa F, Dauvilliers Y, Billiard M, Besset A.; *Sleep architecture, slow wave activity and sleep spindles in mild sleep disordered breathing*, **Clinical Neurophysiology** **114** p.867, 2003
- [55] Principe JC, Smith J; *Sleep spindle characteristics as a function of age*, **Sleep** **5 (1)** p.73, 1982
- [56] Pfurtscheller G, Woertz M, Krausz G, Neuper C; *Distinction of different fingers by the frequency of stimulus induced beta oscillations in the human EEG*, **Neuroscience Letters** **307** p.49, 2001
- [57] Quian Quiroga, R., Pirra, L., Podestá, C., Leiguarda, R., Rabinowitz, A.; *A time distribution of epileptic seizures during video-EEG monitoring. Implications for healthinsurance system in developing countries*, **Sizure** **6** p.475, 1996

- [58] R Development Core Team, *R: A language and environment for statistical computing*, **R Foundation for Statistical Computing, Vienna, Austria**, <http://www.R-project.org>, ISBN 3-900051-00-3, 2003
- [59] Rechtschaffen, A., Kales, A.; *A manual of standardized terminology, techniques and scoring systems for sleep stages in human subjects*, **Washington: US Government Printing Office** 1968
- [60] Roth, C., Achermann, P., Borbély, A. A.; *Alpha activity in the human REM sleep EEG: topography and effect of REM sleep deprivation*, **Clinical Neurophysiology** **110** p.632, 1999
- [61] O. A. Rosso, S. Blanco, A. Rabinowicz, *Wavelet analysis of generalized tonic-clonic epileptic seizures*, **Signal Processing** **83 (6)** p.1275, 2003
- [62] S. J. Schiff, D. Colella, G. M. Jacyna, E. Hughes, J. W. Creekmore, A. Marchal, M. Bozek-Kazmicki, G. Benke, W. D. Gaillard, J. Conry, S. R. Weinstein.; *Brain chirps: spectrographic signatures of epileptic seizures*, **Clinical Neurophysiology** **111 (2000)** p.953-958.
- [63] Schönwald SV, Gerhardt GJL, de Santa-Helena EL, Chaves MLF.; *Characteristics of human EEG sleep spindles assessed by Gabor transform*, **Physica A** **327** p.180, 2003
- [64] S.V. Schönwald, E. de Santa-Helena, R. Rossatto, M.L.F. Chaves, G.J.L. Gerhardt, *Benchmarking Matching Pursuit to find sleep spindles*, **Journal of Neuroscience Methods** **156 (1-2)** p.314, 2006

- [65] Steriade M. Brain Electrical Activity and Sensory Processing During Waking and Sleep States. in: M. H. Kryger, T. Roth, W. C. Dement; *Principles and Practice of Sleep Medicine*, **W. B. Saunders Company, Philadelphia,(third edition)**. Cap.VIII: p.93, 2000
- [66] Steriade, M.; *Sleep, epilepsy and thalamic reticular inhibitory neurons*, **Trends in Neuroscience 28 (6)** p.317, 2005
- [67] Senhadji, L., Dillenseger, J. L., Wending, F., Rocha, C., Linie, A.; *Wavelet analysis of EEG for three-dimensional mapping of epileptic events*, **Annals of Biomedical Engineering 23** p.543, 1995.
- [68] Smith JR and Karacan I.; *EEG sleep stage scoring by an automatic hybrid system*, **Electroencephalography and Clinical Neurophysiology 31 (3)** p.231, 1971
- [69] Tan X, Campbell IG, Feinberg I.; *Internight reliability and benchmark values for computer analyses of non-rapid eye movement (NREM) and REM EEG in normal young adult and elderly subjects*, **Clinical Neurophysiology 112** p.1540, 2001
- [70] M.G. Terzano, L. Parrino, A. Smerieri, R. Chervin, S. Chokroverty, C. Guilleminault, M. Hirshkowitz, M. Mahowald, H. Moldofsky, A. Rosa, R. Thonas, A. Walters, *Atlas, rules, and recording techniques for the scoring of cyclic alternating pattern (CAP) in human sleep*, **Sleep Medicine 3** p.187, 2001

- [71] E.M. Ventouras, E.A. Monoyiou, P.Y. Ktonas, T. Paparrigopoulos, D.G. Dikeos, N.K. Uzunoglu, C.R. Soldatos; *Sleep spindle detection using artificial neural networks trained with filtered time-domain EEG: A feasibility study*, **Computers Methods and Programs in Biomedicine** **78** p.191, 2005
- [72] Werth E, Achermann P, Dijk D-J, Borbély A.; *Spindle frequency activity in the sleep EEG: individual differences and topographic distribution*, **Clinical Neurophysiology** **103** p.535, 1997
- [73] Zygiereicz J, Blinowska KJ, Durka PJ, Szelenberger W, Niemcewicz S, Androsiuk W, *High resolution study of sleep spindles*, **Clinical Neurophysiology** **110** p.2136, 1999
- [74] J Zygiereicz, P. Suffczynski, K. Blinowska; *A model of Sleep Spindle Generation*, **Neurocomputing** **38-40** p.1619, 2001
- [75] Zygiereicz J; *Analysis of sleep spindles and models for their generations*, **Institute of Experimental Physics, Warsaw University Tese de Doutorado**, 1996

Capítulo 3

Artigo em Inglês Comparison Between Two Spectral Methods for EEG Sleep Spindle Detection

José L. Rybarczyk Filho, Günther J. L. Gerhardt, Suzana V. Schönwald
Emerson L. de Santa-Helena, Roberto Rossatto, Márcia L. F. Chaves

*HCPA Pós Graduação em Clínica Médica da Universidade Federal
do Rio Grande do Sul- Hospital de Clínicas de Porto Alegre,
Rua Ramiro Barcelos 2350 / sala 2040 / 90035-003 Porto Alegre Brazil.*

*UCS Departamento de Física e Química da Universidade de Caxias do Sul,
Rua Francisco Getúlio Vargas 1130 95001-970 Caxias do Sul Brazil*

*FURB Universidade Regional de Blumenau / Dep. de Física-Campus I
R. Antônio Veiga, 140-Vitor Kunder 89010-500 Blumenau SC Brazil*

Abstract

Performance of two time-frequency methodologies for Sleep Spindle (SS) detection (Gabor Transform, GT; Matching Pursuit procedure, MP) were compared with each other and against visual scoring. Data set comprised 160 EEG intervals pertaining to 9 young male subjects, proportionally representative of normal sleep, containing 725 visually detected SS (C3-A2 EEG channel). In this sample, both methodologies showed similarly good performance against visual analysis. GT localized 2160 and MP, 2766 events. MP and GT agreed for 564 (77.8%) of visually detected SS. Overall agreement between automatic methodologies computed 1716 structures, corresponding to (79.4%) of GT-detected, and to (67%) of MP-detected events. A significant (23.8%) proportion of MP-SS atoms were reconstructed as multiple (two or more) overlapping structures.

Key words:

Time Series; Matching Pursuit; EEG; sleep spindles

PACS: 87.19La; 87.19Vn; 06.30.Ft; 07.05.Rm

3.1 Introduction

Application of signal analysis to the study of human sleep - which comprises about one third of a lifetime - represents a special challenge. In this field, experts still spend the majority of their time making decisions (fundamented on quantitative criteria) while surveying large amounts of raw data, derived from a heterogeneous array of bio-signals [42]. For sleep macrostructure and single event analysis (arousals, respiratory disturbances, leg movements, etc.) their task has been rendered easier, in recent years, by the incorporation of automatic detection algorithms, despite the need for revision and editing (no "blind" scorings are accepted by clinicians [4]). Quantitative study of sleep microstructure, on the other hand, has remained experimental. The EEG signal shows very rich and nonstationary behaviour during sleep, with the presence of several transients (usually $0.5s$ to $2s$ long) related to information processing and/or sleep maintenance mechanisms, each occurring thousands of times along the night [52]. Sleep transients obtained during daytime sleep recordings (usually 20-40min samples) are visually scrutinized in the context of routine electroencephalography. Their general pattern of occurrence is taken into consideration for whole-night sleep stage classification [59, 70]. However, quantitative whole-night microstructure analysis has not thus far generated clinical implementation recommendations, possibly because it a) would be too time-consuming to be undertaken visually, b) lies within the very limit of visual discrimination capacity, c) has not been sufficiently investigated in clinical settings, or d) has not been successfully resolved by automated analysis.

The best-studied sleep EEG transient is a short-time oscillation between 11Hz

and 16Hz called Sleep Spindle (SS) [11]. This particular element is an epiphenomenon originated in thalamic pacemakers [66], possibly associated with memory consolidation [27] as well as mental ability [7]. SS automatic localization for posterior analysis is a starting point for modelling short-time brain global oscillations. Several methodologies have been developed and tested for automatic SS scoring [52, 38, 40, 73, 5, 2, 71]; indeed, methods for sleep spindle detection have so proliferated that almost every sleep laboratory has its own, whereas not many have been applied by more than one research group and few have been included in commercially available softwares. Most validation procedures are concerned with SS detection in sleep stage 2 only. Method specificity is seldom reported [35]. Spindle detection is often regarded as a long-solved problem in sleep analysis [30], but the clinician still has little information on how "visual"spindles relate to automatically scored spindles, and comparisons between reported results are hindered by a lack of automatic SS parameter (duration, frequency span, voltage distribution, etc.) standardization. Cross-comparisons between different automatic detection algorithms appear therefore to be necessary.

The fundamental approach to sleep spindle analysis is time-frequency decomposition, accomplished through several different transforms and methodologies (e.g. Wavelet, Discrete Fourier, Matching Pursuit) [61]. Converging results are expected from comparing different methods, but few attempts have been made in this direction. Campbell, Kumar and Hofman [10] compared a hybrid phase-locked loop system with a complex demodulation (related to FFT) hardware system, both against visual analysis. They found good agreement between automatic methods for well-defined spindles, lowered sensitivity for poorly-defined spindles

and less than 10 percent false-positives. Principe and Smith [55] tested a software (wave period discrimination after a 8-40Hz FIR digital filter had been applied to the signal) against a hybrid spindle detector (also relying on Fourier analysis) for which man-machine agreement had been calculated previously, and found very good agreement between both automatic systems, with few false-positives, provided that individual wave-frequency criteria were increased from 11.75-16Hz to 11.4-17.1Hz. More recently, the accuracy of spindle frequency determination through automatic methods has been investigated in simulated, as well as in visually selected human spindles [36, 37]. Similarly good results were found for two methods: Discrete Fourier Transform (DFT) and Matching Pursuit.

The aim of this study is to compare two time-frequency approaches - Matching Pursuit (MP) [45] and Gabor Transform (GT) [48] - for spindle detection in a sleep sample obtained from healthy young male subjects. GT is a special case of a Windowed Fourier Transform maximizing relationship between time and frequency, which has been used on EEG signals, for example, in [39] (on a matched-filtering procedure) and [63] assessing SS. Matching pursuits are general procedures to compute adaptive signal representations [45] relying on recursive, adaptive approximation of the signal with functions chosen from a large set of waveforms. These include a family of Gabor functions as a basic set with added Fourier and Dirac delta functions. MP has been employed in several studies of SS characteristics in recent years [37, 73, 21]. The central focus here is on how the output from these two algorithms compares once their performance has been optimized to meet visual analysis, rather than finding a best-performance method.

3.2 Methods

All analyses were carried out on EEG channel C3-A2, which is the classical sleep scoring channel [59]. For both methodologies the search was limited to SS candidates having a central frequency between 11Hz and 16Hz and a minimum duration of 0.5s.

3.2.1 Gabor Transform

A Gabor Transform is a special case of a Windowed Fourier Transform (WFT). For a signal $S(t)$ a windowed transform is defined as [48]

$$W\{S(t)\}(b, s) = \int_{-\infty}^{\infty} S(t)\Psi(t - b, s)dt, \quad (3.1)$$

where $\Psi[(t - b), s]$ has temporal (b) and frequency (s) localization. In the exact case of a GT, it is the plane wave modulated by a Gaussian curve in the form

$$\Psi[(t - b), s] = \frac{1}{\sqrt{2\pi\xi}} e^{-(t-b)^2/2\xi^2} e^{ist}, \quad (3.2)$$

which possesses a structure that maximizes relationship between time and frequency [48].

The Power Spectrum here is defined in the same way as in the Fourier space as

$$P\{W(b, s)\} = |W(b, s)|^2. \quad (3.3)$$

Sliding 256-point (2s) windows displaced with one-point steps were applied to the time series, yielding a time representation of the spectrum of (3.3). The threshold value of square root of (3.3) was used as a free parameter here (relative

power in μV in Fig. 2). An SS candidate corresponds to the step sequence for which the square root of power spectrum is greater than this threshold.

3.2.2 Matching Pursuit

Matching Pursuit is not a transform, it is an adaptive approximation of the signal with a set of fundamental functions chosen from a dictionary. It describes the signal through fundamental "atoms"(the dictionary functions). MP with time-frequency dictionaries were introduced in [45] and a correction scheme for large-size data like EEG was complemented in [20]. In the MP approach a signal $S(t)$ is taken and subsequent adaptation steps are made writing $S(t)$ in terms of a basic and redundant dictionary of functions $D = \{g_{\gamma_i}\}$

$$S(t) \simeq \sum_{i=1}^M a_i g_{\gamma_i}, \quad (3.4)$$

where γ_i represents a set of parameters that characterize the dictionary functions, M is the number of steps and a_i is an amplitude term. For a signal of size N , $D = \{g_{\gamma_i}\}$ is a redundant dictionary of $i > N$ elements which will include at least N linearly independent vectors.

As an adaptive filter, the MP procedure matches the signal with a function g_{γ_i} at each step i , leaving a residual $R_{i+1}S(t)$ to be matched by the same procedure in step $i + 1$. Indeed MP projects $S(t)$ on a vector g_{γ} and evaluates the residual $R_1S(t)$:

$$S(t) = \langle S(t), g_{\gamma} \rangle g_{\gamma} + R_1S(t). \quad (3.5)$$

If one takes g_{γ} to be an orthogonal basis one can write

$$\|S(t)\|^2 = |\langle S(t), g_{\gamma} \rangle|^2 + \|R_1S(t)\|^2. \quad (3.6)$$

In order to minimize $\|R_i S(t)\|$, g_γ is chosen such that $|\langle S(t), g_\gamma \rangle|$ is maximum or at least suboptimal. The procedure is continued iteratively replacing $R_i S(t)$ for the original $S(t)$ until some energy threshold or number of iterations coefficient is reached. Generalizing the procedure:

$$R_i S(t) = \langle R_i S(t), g_\gamma \rangle g_\gamma + R_{i+1} S(t), \quad (3.7)$$

for $0 < i < M$ where $R_0 S(t) \equiv S(t)$.

The dictionary used for time-frequency analysis is built from real Gabor functions as

$$g_\gamma(t) = \alpha e^{-\pi((t-b)/s)^2} \sin(2\pi\omega(t-b)/N + \phi), \quad (3.8)$$

where N is the size of the signal, the set $\gamma = \{\alpha, b, w, s, \phi\}$ represents parameters of dictionary functions and α is chosen such that $\|g_\gamma\| = 1$. A set of Dirac's delta and Fourier functions is added to this dictionary in order to deal with time and frequency well-localized structures. This choice is not unique; as explained in [45], it is important to adapt the dictionary to the class of signal that is being decomposed.

The free-version MP algorithm provided in <http://eeg.pl/mp> was used in this work, as it was made available aiming mostly EEG signal analysis [20]. Chosen total energy of reconstruction was 100%. MP decomposition was carried out in 16s (2048 points) juxtaposed windows over the time series obtained from EEG, with 96 iterations for each segment. A dictionary size of 10^6 Gabor atoms was used here. Atom amplitude (scale in MP algorithm) was used as a free parameter (amplitude of MP atom expressed in μV in Fig. 2).

3.2.3 EEG and Visual Spindle Data Set

This study makes use of a sample of 160 EEG segments proportionally representative of human sleep [59], with a total duration of 6.2h, collected for and described in more detail in a previous study [64]. Briefly, subjects (aged 20-34, average 24.6) were nine healthy male volunteers with regular sleep schedules. All polysomnograms were performed in an 18-channel analog NIHON-KOHDEN polygraph with 12 bit digital conversion (STELLATE RHYTHM V10.0), recorded with 128Hz resolution, with manufacturer's 0.5Hz high-pass filter, 0.3s time constant and -3dB IIR32 digital filter conditions applied to the signal. Two specialists scored all concordant spindles in these segments. Visual spindle prevalence (ratio between spindle time and sleep time) was 2.38%. This sample has 725 SS with the following characteristics: 18 SS in REM sleep (105min, 39 intervals), 513 SS in S2 sleep (161min, 35 intervals) and 194 SS in S3+S4 sleep (107min, 86 intervals).

3.2.4 Method Comparison

For cross-comparison between methods, 4-point steps (corresponding to $1/32s$ and estimated as smaller than visual discrimination capacity) were defined as minimal time units. True Positive (TP), True Negative (TN), False Positive (FP) and False Negative (FN) regions were defined considering time in seconds, as shown in Fig. 1, and used for the calculation of method sensitivity ($VP/VP+FN$) and specificity ($VN/VN+FP$) as a function of voltage (Fig. 2). In order to maximize agreement with visual analysis, SS duration in seconds was $[0.5, 3]$ for MP

and $[0.5, +\infty)$ for GT (in a post-hoc analysis, only 4% of GT SS candidates were longer than 3s and none longer than 6s). This procedure is necessary to avoid expurious sensitivity ratios for lower threshold values. Each atom obtained with MP has limits established by a half-width (HW) corresponding to $\pm\sigma$ on a gaussian curve. A value of 1.5HW was used here in order to increase sensitivity/specificity ratio. MP dictionary sizes up to 10^7 atoms were tested with the same parameters, reaching similar results at the expense of increased computational time. An additional test with 200 iterations did not significantly affect results.

For computation of isolated (single) SS, voltage cut-off points maximizing sensitivity/specificity ratio were taken from ROC curves built in the previous step (shown in Fig. 2). True Positive (TPE) and False Positive Events (FPE) were defined in relation to the presence of any degree of overlap with visual spindles and depicted in Fig.1, while False Negative Events (FNE) correspond to missed visual spindles.

Isolated EEG segments corresponding to events detected either by MP or GT only (MP- and GT-FPE) were analyzed by FFT so that frequency corresponding to the highest spectral power peak in 11-16Hz band was obtained. Duration and voltage amplitude were directly computed on these segments. All FPE were inspected as isolated events on a screen display, and experts were asked to issue a retrospective qualitative judgement on the correspondence between these events and visual spindles.

Considering that MP easily discriminates superimposed spindles [73], two or more MP atoms with any degree of overlap were computed here as single events,




Figura 3.1: Sketch of benchmark procedure for SS identification. TP=True Positive, TN=True Negative, FP=False Positive and FN=False Negative regions. TPE=True Positive Events, FPE=False Positive Events. Here discrepancy was enhanced for demonstrative purposes.

defined as Overlapping Structures (MP-OS) and analyzed further.

3.3 Results

Performance of GT and MP against visual analysis is shown in ROC curves (Fig. 2). Both methodologies displayed similarly good performance, as results are presented for collapsing data from all subjects and stages, and there is great

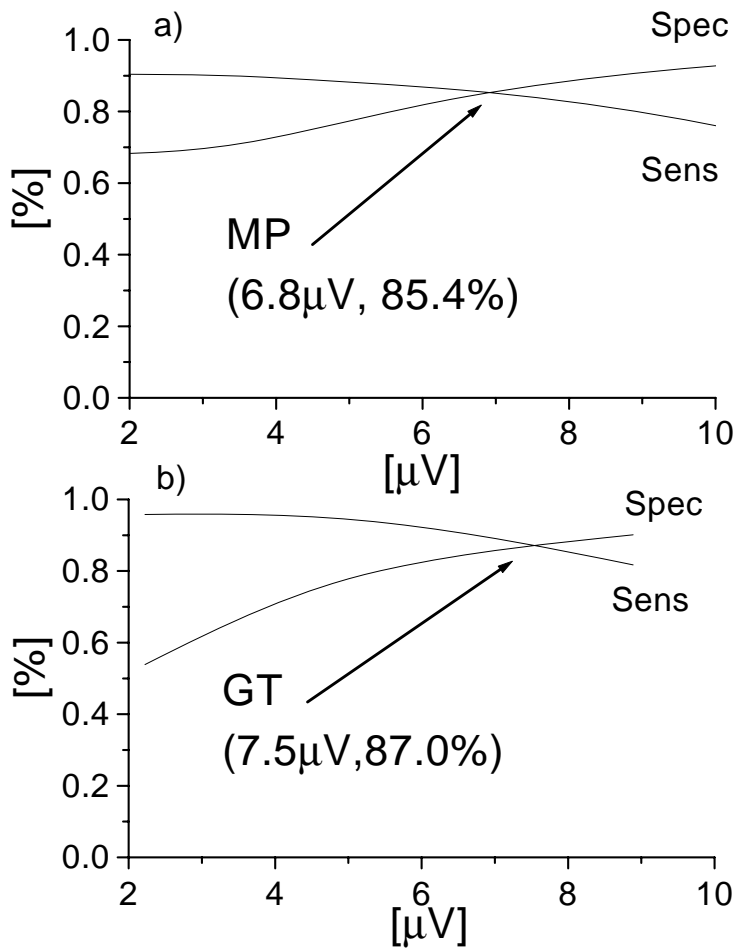


Figure 3.2: ROC curves showing Sensitivity/Specificity ratios for GT and MP as a function of voltage in the whole EEG sample. Cutoff threshold is indicated in figure and used in this work for direct comparison between methods.

threshold variability among subjects. In this sample, the GT cut-off point maximizing yield between sensitivity and specificity (87%) corresponded to $7.5\mu\text{V}$. For MP, this point was 85.4%, corresponding to $6.8\mu\text{V}$. A better discussion about this point is given at the end of section 4.1.

Fig. 3 shows a Venn diagram summarizing agreement among methods for single SS events. Whereas humans detected 725 SS in this sample, GT localized 2160 and MP, 2766 events. MP and GT agreed for 564 (77.8%) visually detected

SS. There were 68 and 64 visual SS respectively detected by MP and GT only. Twenty-nine SS were not found by any automatic method, 9 (1.7%) being in S2, 14 (7.2%) in S3+4 and 6 (33.3%) in REM sleep.

Overall agreement between automatic methods yielded 1716 structures, corresponding to (79.4%) of GT-detected, and to (62.0%) of MP-detected events. There were 982 and 380 events respectively detected by MP and GT only. These events had similar median duration (0.98s and 1s), while MP-FPE peak amplitude (computed directly over the time series) was $32.6\mu V$ and GT-FPE's, $41.5\mu V$. The frequency distribution curve (FFT directly computed over the time series) was different for MP- and GT-FPE, as MP picked up more FPE in the 14-15Hz band than GT did. Visual inspection showed GT-FPE to be noisier than MP-FPE. Distribution across stages did not show differences between MP- and GT-FPE characteristics. On visual retrospective analysis experts stated the vast of FPE could be accepted as poorly-defined spindles with shape distortion, low amplitude, short duration or embedded in slow activity.

Results for MP-OS (overlapping structures) are shown as the dashed region in Fig. 4. MP was able to find 645 such instances in this sample (521 double, 96 triple and 28 with four or more atoms), comprising 23.8% of MP-detected events. The region of MP concordance with either GT or the visual method included 576 (89.3%) of total MP-OS. MP-OS were 561 out of 1716 (32.7%) concordant events between MP and GT. Two-hundred and sixty nine (269, 37.1%) visual SS were classified as MP-OS, corresponding to 42.6% of the concordance between MP and the visual method. Thirty-one percent of double MP-OS had at least 2Hz central frequency difference between both atoms; these events corresponded to

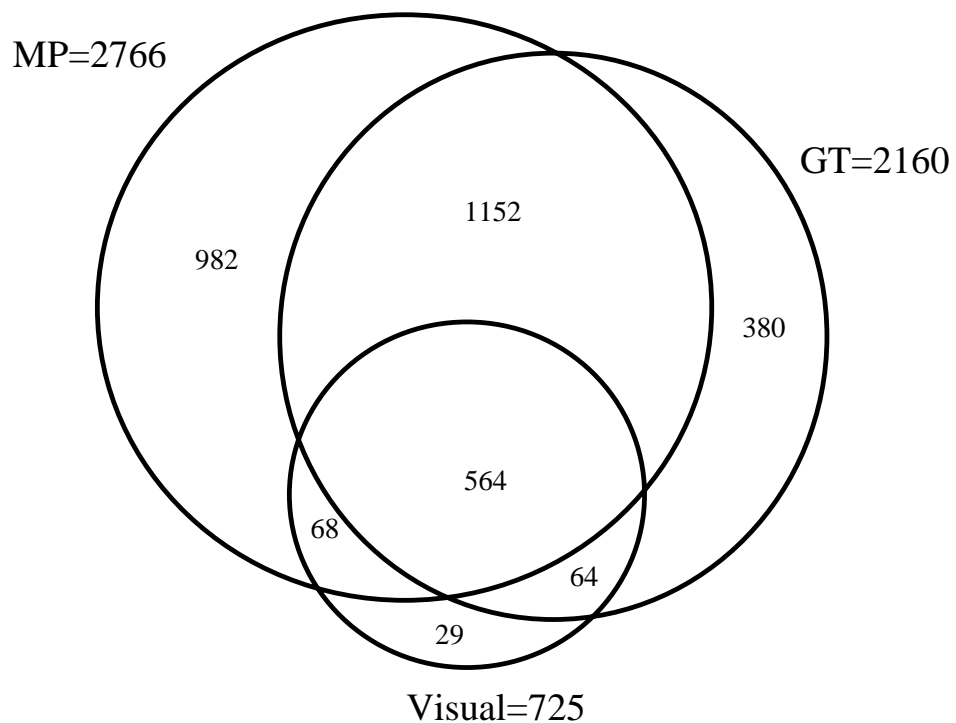


Figura 3.3: Total events found by GT and MP relative to visual scoring. Circle size differences are merely illustrative and do not correspond exactly to real proportions in numbers.

5.8% of total MP atoms.

The GT algorithm as implemented in this study did not allow quantification of superimposed structures. On visual inspection of GT Wigner plots corresponding to MP-OS it was possible to verify that GT often represented spindles as chirping structures, regardless of spindle superposition (exemplified in Fig. 5 and discussed below).




Figura 3.4: Total MP-OS events (Overlapping Structures) relative to GT, MP and visual scoring. Circle size differences are merely illustrative and do not correspond exactly to real proportions in numbers.

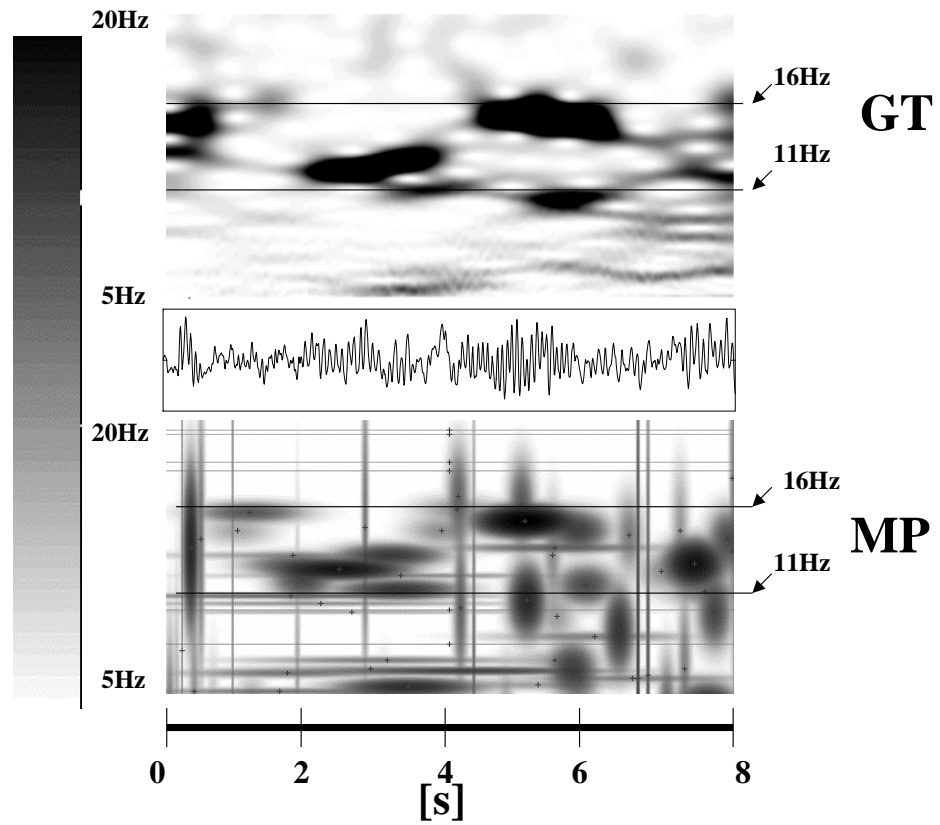


Figure 3.5: Two visual spindles (central portion on the time series) reconstructed as overlapping atoms by MP (MP-OS). On the GT plot one can see two chirping spindles, each of them overlapping a lower frequency structure. See text for details.

3.4 Discussion

The main purpose of this study was to compare two spectral decomposition methodologies for SS identification, once they had been optimized to meet visual analysis. The comparison procedure implemented made it necessary to analyze further MP-detected events reconstructed as two or more overlapping structures.

3.4.1 Performance against visual analysis

For both methods it was possible to reach very good (at least 85% sensitivity/specificity ratio against visual analysis. The voltage cut-off point maximizing yield between sensitivity and specificity was considered suitable, in this study, for single SS detection, because investigation of false positive events was targeted. With these thresholds, automatic spindle prevalence was 3 to 4 times higher than visual spindle prevalence. Higher voltage cut-off points yield less FPE and may be preferred for SS characterization in clinical settings, if specificity needs to be favored over sensitivity. However, it could be argued that visual spindle detection makes for an imperfect golden standard, since poorly-defined spindles are easily missed by humans [38]. In this study, visual retrospective analysis of FPE indicated the majority of these events could be accepted by clinicians as true spindles with shape distortion, low amplitude, short duration or embedded in slow activity, inasmuch the value of such retrospective judgement is limited. Combined prevalence of false negative events (visual SS not found by any automatic method), on the other hand, was very low (1.7%) in S2 and moderately increased (7.2%)

in S3+4, where SS are embedded in slow activity. FNE prevalence was high (33.3%) in REM sleep, where only 18 visual spindles were detected. Matching Pursuit concordance with visual analysis had already been investigated for different sleep stages in a previous study [64], and found to be lower in stages 3+4 and REM.

It should be remembered that MP and GT voltage parameter settings chosen in this study are related to, but not equivalent to spindle voltage directly measured over the EEG time series. Spindle voltage "seen" on EEG receives contribution from other frequency bands, especially lower frequencies, building up the visual spindle amplitude, whereas in the case of GT and MP, only activity in the spindle frequency band will contribute to atom voltage represented in the spectrogram.

3.4.2 Concordance between MP and GT

MP is not a transform in itself, but a rich spectral-based procedure to describe a signal. This description relies on the choice of elements from a large and redundant dictionary. Atoms are considered here as SS if they meet the limits of a frequency window, as well as duration and voltage minimum thresholds; it is statistically possible for MP to reconstruct some EEG activity classified by GT as an SS with an atom combination that does not meet all inclusion criteria to be classified as an MP-SS. In this study, good (although not optimal) concordance was seen between MP and GT, as overall agreement between automatic methods corresponded to at least two-thirds of detected events. It should be kept in mind that this performance was obtained with thresholds selected to maximize

agreement with visual analysis, and not between automatic methods. MP vs. GT discordance in this study therefore reflects parameter adjustment to accommodate visual analysis, as well as intrinsic differences between methodologies (for instance, 4% GT-SS were longer than 3s and would not be picked up by MP).

Characteristics of automatic spindles detected by MP and GT in this study could be summarized as follows. Prevalences were equally (3 to 4 times) higher than those obtained through visual analysis; the majority of false positive events were retrospectively accepted by experts as poorly defined spindles. Two-thirds of automatically - detected events were concordant between methods. MP and GT-discordant spindles were similar in duration; those obtained by MP only tended to be less noisy, slightly lower in amplitude and had greater contribution from higher (14-15Hz) frequencies than those obtained only by GT.

3.4.3 MP Overlapping Structures

A significant (23.8%) proportion of MP-SS atoms were reconstructed as multiple overlapping structures in this study, clearly higher than the 5% superimposed spindle prevalence reported by [73]. Because analysis here was limited to C3-A2 channel, which is expected to pick up low (around 12Hz) frontal as well as fast (around 14Hz) parietal spindles [39], and because superimposed spindles in [73] are not defined in terms of frequency difference or degree of overlap, it is not possible to ascertain here how many of these MP-OS correspond to superimposed spindles. However, prevalence of double MP-OS bearing at least 2Hz central frequency difference (best candidates for superimposed spindles) was 5.8%

of total MP-SS in this study, therefore similar to reported superimposed spindle prevalence. Understanding MP-OS seems to be relevant as the majority of these events lied in the region of MP concordance with GT and/or the visual method. The GT algorithm as implemented in this study did not enable quantification of superimposed structures. However, visual inspection of GT Wigner plots corresponding to MP-OS allowed the verification that GT often represented spindles as chirping structures, regardless of spindle superposition (as shown in Fig. 5). Could MP-OS be, at least in part, representations of chirping spindles? MP easily separates a chirp-like structure into two or more atoms [29]. As an additive, highly non-stationary physiological signal [52], EEG appears to intrinsically bear small frequency variations that can be described as chirping structures, for instance epileptic seizures [62]. Sleep spindles have been modelled as frequency packages occurring time to time [74], but some sleep spindles may be chirping along with their fluctuating power. MP appears to be a specially suitable sleep EEG descriptor, as it allows comparison of time evolution, topography and other characteristics of different signal structures, e.g. SS versus slow wave activity [74]. However, its description of the signal depends on function choice. MP implementation of chirping atoms as proposed by Gribonwal [29] may perhaps allow better insight into isolated sleep spindle frequency characteristics.

3.5 Conclusions

In conclusion, for this sleep EEG sample, two spectral decomposition me-

thodologies for automatic sleep spindle detection (Matching Pursuit and Gabor Transform) showed similarly good performance against visual analysis, and good (although not optimal) concordance between each other. Parameter adjustment to accommodate visual analysis, as well as intrinsic differences between methodologies, appear to account for discordance between these automatic methods. Automatic spindle prevalence was several (3 to 4) times higher than visual spindle prevalence; however, experts were retrospectively inclined to accept the majority of false positive events as poorly defined spindles. MP procedure yielded a significant proportion of overlapping structures, which may be in excess of expected superimposed spindle prevalence. It is suggested that these events may in part represent chirping spindles, which could be better analyzed through an MP implementation of chirping functions.

Acknowledgments

This work was partially supported by Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) and Fundação de Amparo a Pesquisa do Estado do Rio Grande do Sul (FAPERGS). The authors would also like to acknowledge A. C. da Rosa for fruitful discussions during the presentation of an old version of this work during the X Congresso Brasileiro de Sono (X Brazilian Sleep Congress) last year in Curitiba, Brazil as a poster communication. GG would also like to acknowledge Prof. Dr. C. Perottoni for useful technical help with HAL PC Cluster at UCS.

Capítulo 4

Artigo em Português Comparação de Dois Métodos Espectrais Para Detecção de Fusos de Sono

José L. Rybarczyk Filho, Günther J. L. Gerhardt, Suzana V. Schönwald,
Emerson L. de Santa-Helena, Roberto Rossatto, Márcia L. F. Chaves

*HCPA Pós Graduação em Clínica Médica da Universidade Federal
do Rio Grande do Sul- Hospital de Clínicas de Porto Alegre,
Rua Ramiro Barcelos 2350 / sala 2040 / 90035-003 Porto Alegre Brazil.*

*UCS Departamento de Física e Química da Universidade de Caxias do Sul,
Rua Francisco Getúlio Vargas 1130 95001-970 Caxias do Sul Brazil*

*FURB Universidade Regional de Blumenau / Dep. de Física-Campus I
R. Antônio Veiga, 140-Vitor Kunder 89010-500 Blumenau SC Brazil*

Resumo

As performances¹ de duas metodologias para detecção de fusos de sono (SS) (Transformada de Gabor, GT e Matching Pursuit, MP) foram comparadas com a análise visual e entre si. O conjunto de dados compreendeu 160 segmentos de EEG pertencentes a 9 adultos jovens normais do sexo masculino, canal C3-A2, contendo 725 fusos detectados visualmente. Nesta amostra, ambas metodologias mostraram uma performance similar. GT localizou 2160 SS ao passo que MP detectou 2766. MP e GT concordam em 564 casos (77.8% dos fusos detectados visualmente). O número de concordâncias entre as metodologias foi 1716 SS, correspondendo a 79.4% dos eventos detectados por GT e a 67% dos detectados por MP. Uma proporção significativa de MP-SS foram reconstruídos como estruturas múltiplas sobrepostas.

Key words:

Time Series; Matching Pursuit; EEG; sleep spindles

PACS:87.19La; 87.19Vn; 06.30.Ft; 07.05.Rm

¹Este artigo foi originariamente escrito em inglês.

Neste trabalho optou-se por usar o termo em português "gorgeio" como sinônimo de "chirp" em inglês, sendo esta sua tradução literal. Mas cumpre salientar que esta expressão não é muito usada em análise de sinais (que prefere "chirp" ou "chirpante"), não existindo um termo definitivo técnico em português.

4.1 Introdução

A aplicação de análise de sinais para o estudo de sono humano - que inclui aproximadamente um terço de uma vida - representa um desafio especial. Nesta área, peritos ainda gastam a maior parte de seu tempo tomando decisões (fundamentados em critérios quantitativos) enquanto estão inspecionando grandes quantidades de dados crus, derivados de um arranjo de bio-sinais heterogêneos [42]. Para macroestruturas do sono e análise de eventos únicos (estimulações perturbações respiratórias, movimentos de perna, etc.) a tarefa vem se tornando mais fácil, nos últimos anos, pela incorporação de algoritmos de detecção automática, apesar da necessidade de revisão e edição (nenhuma contagem "cega" é aceita por clínicos [4]). Por outro lado, o estudo quantitativo de microestruturas do sono permanece experimental. O sinal de EEG mostra-se muito variado e um comportamento não estacionário durante o sono, com a presença de várias flutuações (normalmente $0.5s$ para $2s$ de duração) relacionado ao processamento de informação e/ou aos mecanismos de manutenção do sono, ocorre milhares de vezes ao longo da noite [52]. Transientes de sono, "Sleep transients", obtidos em gravações de sono durante o dia (normalmente amostras de 20-40min) são examinado visualmente nas rotinas de eletroencefalografia. O padrão geral de ocorrência leva em conta uma noite inteira de sono como estágio classificatório [59, 70]. Porém, análise quantitativa de microestruturas de uma noite não gerou grandes recomendações de implementação clínicas, possivelmente porque isto: a) seria muito demorado de ser analisado visualmente,

b) remete ao mesmo limite da capacidade de discriminação visual, c) não foi investigado suficientemente em aplicações clínicas, ou d) não foi resolvido com sucesso pela análise automatizada.

O elemento mais estudado EEG de sono é uma oscilação de curto tempo, entre 11Hz e 16Hz, chamado de Fuso de Sono (SS) [11]. Este elemento particular é um epifenômeno originado em marcapassos talâmicos [66], possivelmente associado com consolidação da memória [27] assim como habilidade mental [7]. A localização automática de SS para análise posterior é um ponto de partida para modelagem de oscilações rápidas globais do cérebro. Foram desenvolvidas e testadas várias metodologias para quantificação automática de SS [52, 38, 40, 73, 5, 2, 71]; de fato, métodos para detecção de fuso de sono proliferaram tanto que quase todo laboratório de sono tem seu próprio, considerando que não muitos foram aplicados por mais de um grupo de pesquisa e poucos foram incluídos em softwares comercialmente disponíveis. A maioria dos procedimentos de validação só estão preocupados com detecção de SS na fase 2 do sono. A especificação do método raramente é informada [35]. Detecção de Fuso é considerada freqüentemente como um problema já resolvido em análise de sono [30], mas o clínico ainda tem pouca informação em como fusos "visuais" se relacionam a fusos automaticamente marcados, e comparações entre resultados informados são impedidas por uma falta de padronização no parâmetro de SS automático (duração, limites de freqüência, distribuição de voltagem, etc.). Comparações cruzadas entre diferentes algoritmos de detecção automática parecem ser necessárias.

A abordagem fundamental para análise do fuso de sono é decomposição de

tempo-freqüência, realizado por diferentes transformações e metodologias (por exemplo Wavelet, Fourier Discreto, Matching Pursuit) [61]. Resultados convergentes são esperados da comparação de métodos diferentes, mas foram feitas poucas tentativas nesta direção. Campbell, Kumar e Hofman [10] comparou um sistema cíclico híbrido de fase-fechada com uma demodulação complexa (relacionado a FFT) e sistema de hardware, ambos contra análise visual. Achando um bom acordo entre métodos automáticos para fusos bem definidos, abaixando a sensibilidade para fusos mal-definidos e menos de 10 por cento de falso-positivo. Principe e Smith [55] testaram um software (discriminação de período de onda depois de um 8-40Hz FIR, sendo que um filtro digital tinha sido aplicado ao sinal) contra um detector de fuso híbrido (também confiando em análise de Fourier) para o qual um acordo de homem-método previamente havia sido calculado, e se achou um bom acordo entre ambos sistemas automáticos, com poucos falsos-positivos, contanto que fossem aumentados os critérios de freqüência de onda individuais de 11.75-16Hz a 11.4-17.1Hz. Mais recentemente, a precisão na determinação de freqüência de fuso por métodos automáticos foi investigada de forma simulada, como também em fusos humanos visualmente selecionados [36, 37]. Semelhantemente bons resultados foram achados para dois métodos: Transformada de Fourier Discreta (DFT) e Matching Pursuit.

O objetivo deste estudo é comparar duas metodologias de tempo-freqüência - Matching Pursuit (MP) [45] e Transformada de Gabor (GT) [48] - para detecção de fusos em uma amostra de sono obtida de homens jovens saudáveis. GT é um caso especial de um janelamento em Transformada de Fourier que maximiza relação entre tempo e freqüência, que foram usado em sinais de EEG, em [39] (em

um procedimento matched-filtering) e [63] avaliando SS. Matching Pursuit são procedimentos gerais para computar representações adaptáveis [45] baseado na recursividade e aproximação adaptável do sinal com funções escolhidas de um grande conjunto de formas de ondas. Isto inclui uma família de funções de Gabor como um jogo básico, com funções de Fourier e de deltas de Dirac adicionadas. MP foi empregado em vários estudos com características de SS nos últimos anos [37, 73, 21]. O foco central aqui é em como estes dois algoritmos se comparam, uma vez que seu desempenho foi aperfeiçoado para coincidir com a análise visual.

4.2 Metodologia

Em todas as análises foram levadas em consideração o canal do EEG C3-A2, que é o canal clássico de estagiamento do sono [59]. Para ambas as metodologias, a procura foi limitada a candidatos a SS que tenham uma frequência central entre 11Hz e 16Hz e uma duração mínima de 0.5s.

4.2.1 Transformada Gabor

Uma Transformada de Gabor é um caso especial de uma Transformada de Fourier Janelada (WFT). Para um sinal $S(t)$ uma transformada janelada está definida como [48]

$$W\{S(t)\}(b, s) = \int_{-\infty}^{\infty} S(t)\Psi(t - b, s)dt, \quad (4.1)$$

onde $\Psi[(t - b), s]$ é uma base tempo-freqüência com localização temporal (b) e

freqüência (s). No caso exato de uma GT, é a onda plana modulada por uma forma de curva Gaussiana.

$$\Psi[(t - b), s] = \frac{1}{\sqrt{2\pi\xi}} e^{-(t-b)^2/2\xi^2} e^{ist}, \quad (4.2)$$

que possui uma estrutura que maximiza a relação entre tempo e freqüência [48].

O Poder Espectral aqui está da mesma maneira definido como no espaço de Fourier como

$$P\{W(b, s)\} = |W(b, s)|^2. \quad (4.3)$$

Percorrendo 256-ponto (2s) foram aplicadas janelas deslocadas com passos de um ponto às séries temporais, rendendo uma representação de tempo do espectro de (4.3). O valor de limiar da raiz quadrada de (4.3) era usado aqui como um parâmetro livre (poder relativo em μV na Fig. 2). Um candidato de SS corresponde à sucessão de passo para a qual a raiz quadrada do poder espectral é maior que este valor.

4.2.2 Matching Pursuit

Matching Pursuit não é uma transformada, é uma aproximação adaptável do sinal com um conjunto de funções fundamentais escolhidas de um dicionário. Descreve o sinal por meio de "átomos" fundamentais (as funções do dicionário, como palavras em uma língua). MP com dicionários de tempo-freqüência foram introduzidos em [45] e um esquema de correção para dados de tamanho grande, como EEG, foi complementado em [20]. Na aproximação de MP, um sinal $S(t)$

é obtido, e são feitos passos subseqüentes de adaptação na escritura $S(t)$ em termos de um dicionário básico e redundante de funções $D = \{g_{\gamma_i}\}$

$$S(t) \simeq \sum_{i=1}^M a_i g_{\gamma_i}, \quad (4.4)$$

onde γ_i representa um conjunto de parâmetros que caracterizam o dicionário de funções M é o número de passos e a_i é um termo de amplitude. Para um sinal de tamanho N , $D = \{g_{\gamma_i}\}$ é um dicionário redundante de $i > N$ elementos que incluirão pelo menos N vetores linearmente independentes.

Como um filtro adaptável, o procedimento de MP combina o sinal com uma função g_{γ_i} a cada passo i , deixando um resíduo $R_{i+1}S(t)$ para ser combinado pelo mesmo procedimento em passo $i + 1$. Realmente MP projeta $S(t)$ em um vetor g_{γ} e avalia o resíduo $R_1S(t)$:

$$S(t) = \langle S(t), g_{\gamma} \rangle g_{\gamma} + R_1S(t). \quad (4.5)$$

Se g_{γ} é uma base ortogonal, pode-se escrever

$$\|S(t)\|^2 = |\langle S(t), g_{\gamma} \rangle|^2 + \|R_1S(t)\|^2. \quad (4.6)$$

Para minimizar $\|R_1S(t)\|$, g_{γ} é escolhido tal que $|\langle S(t), g_{\gamma} \rangle|$ é máximo ou pelo menos sub-ótimo. O procedimento é iterativamente continuado e substitui $RS(t)$ pelo original $S(t)$ até algum limiar de energia ou número de coeficiente de repetições seja alcançado. Generalizando o procedimento:

$$R_iS(t) = \langle R_iS(t), g_{\gamma} \rangle g_{\gamma} + R_{i+1}S(t), \quad (4.7)$$

para $0 < i < M$ onde $R_0S(t) \equiv S(t)$.

O dicionário usado para análise de tempo-freqüência é construído a partir de funções de Gabor reais, como

$$g_\gamma(t) = \alpha e^{-\pi((t-b)/s)^2} \sin(2\pi\omega(t-b)/N + \phi), \quad (4.8)$$

onde N é o tamanho do sinal, o conjunto $\gamma = \{\alpha, b, w, s, \phi\}$ representa parâmetros de funções do dicionário e α é escolhido tal que $\|g_\gamma\| = 1$. Um conjunto de deltas de Dirac e funções de Fourier é acrescentado a este dicionário para lidar com estruturas bem-localizadas em tempo e freqüência. Esta escolha não é singular; como explicado em [45], é importante para adaptar o dicionário à classe de sinal que está sendo decomposto.

Uma versão livre do algoritmo Matching Pursuit disponível em <http://eeg.pl/mp> foi usado neste trabalho, já que o mesmo objetivava principalmente análise de sinal de EEG [20]. A energia total de reconstrução escolhida era 100%. Decomposição de MP foi resolvida em 16s (2048 pontos) justapondo janelas em cima das séries obtidas do EEG, com 96 interações para cada segmento. Um dicionário de tamanho de 10^6 átomos de Gabor foram usados aqui. Amplitude de átomo (escala em algoritmo de MP) foi usado como um parâmetro livre (amplitude de átomo de MP expresso em μV em Fig. 2).

4.2.3 EEG e Conjunto de Dados do Fuso Visual

Este estudo faz uso de uma amostra de 160 segmentos de EEG proporcionalmente representativa do sono humano [59], com uma duração total de 6.2h, coletados e descritos em mais detalhes em um estudo anterior [64]. Pacientes (idade

de 20-34 anos, com média 24.6), foram nove voluntários homens, saudáveis, com horários de sono regulares. Todos os polissonogramas foram executados em um polígrafo analógico de 18-canais, NIHON-KOHDEN, com 12 bits de conversão digital (STELLATE RHYTHM V10.0), gravado com 128Hz de resolução, com filtro de 0.5Hz do fabricante, 0.3s de tempo constante e filtro digital -3dB IIR32 aplicado ao sinal. Dois especialistas marcaram todos os fusos concordantes nestes segmentos. Prevalência de fuso visual (relação entre tempo de fuso e tempo de sono) era 2.38%. Esta amostra teve 725 SS com as características seguintes: 18 SS em sono REM (105min, 39 intervalos), 513 SS em sono S2 (161min, 35 intervalos) e 194 SS em sono S3+S4 (107min, 86 intervalos).

4.2.4 Comparação Metodológica

Para comparação cruzada entre métodos, passos de 4-pontos (correspondendo a $1/32s$ e estimado como menor que a capacidade de discriminação visual) foram definidos como unidades de tempo mínimas. Regiões Verdadeiro Positivo (TP), Verdadeiro Negativo (TN), Falso Positivo (FP) e Falso Negativo (FN) foram definidas considerando o tempo em segundos, como mostrado em Fig. 1, e usado para o cálculo do método de sensibilidade ($VP/VP + FN$) e especificidade ($VN/VN + FP$) como uma função de voltagem (Fig. 2). Para maximizar a combinação com a análise visual, o candidato a SS durava, em segundos, $[0.5, 3]$ para MP e $[0.5, +\infty)$ para GT (em uma análise post-hoc, só 4% de candidatos SS em GT eram mais longos que 3s e nenhum mais longo que 6s). Este procedimento é necessário evitar relações de sensibilidade expurios para

valores muito baixos do limiar em GT. Cada átomo obtido com MP tem limites estabelecidos por uma meia largura (HW) correspondendo a $\pm\sigma$ em uma curva gaussiana. Um valor de 1.5HW era usado aqui para aumentar a relação de sensibilidade/especificidade. Dicionários de MP de até 10^7 átomos foram testados com os mesmos parâmetros, alcançando resultados semelhantes às custas de um aumento no tempo computacional. Um teste adicional com 200 interações não afetaram significativamente os resultados.

Para computar SS isolado (único), foram levados limites de voltagem que maximizam a relação de sensibilidade/especificidade obtidas a partir de curvas ROC construídas no passo anterior (mostrado em Fig. 2). Verdadeiro Positivo (TPE) e Eventos de Falso Positivo (FPE) foram definidos em relação à presença de qualquer grau de sobreposição com fusos visuais e descritos na Fig.1, enquanto Eventos de Falso negativo (FNE) correspondiam a fusos visuais perdidos.

Segmentos isolados de EEG correspondendo a eventos detectados tanto por MP ou GT (MP - e GT-FPE) foram analisados por FFT de forma que a frequência que corresponde ao pico de poder espectral mais alto fosse obtida na faixa de 11-16Hz. Foram computadas duração e amplitude de voltagem diretamente nestes segmentos. Todos os FPE foram inspecionados como eventos isolados em uma exibição de tela, e foram pedidos para os peritos que emitissem um julgamento qualitativo retrospectivo na correspondência entre estes eventos e fusos visuais.

Considerando que MP separa fusos sobrepostos facilmente [73], dois ou mais átomos de MP com qualquer grau de sobreposição foram computados aqui como único evento, definido como Estrutura Sobreposta (MP-OS) e analisados mais

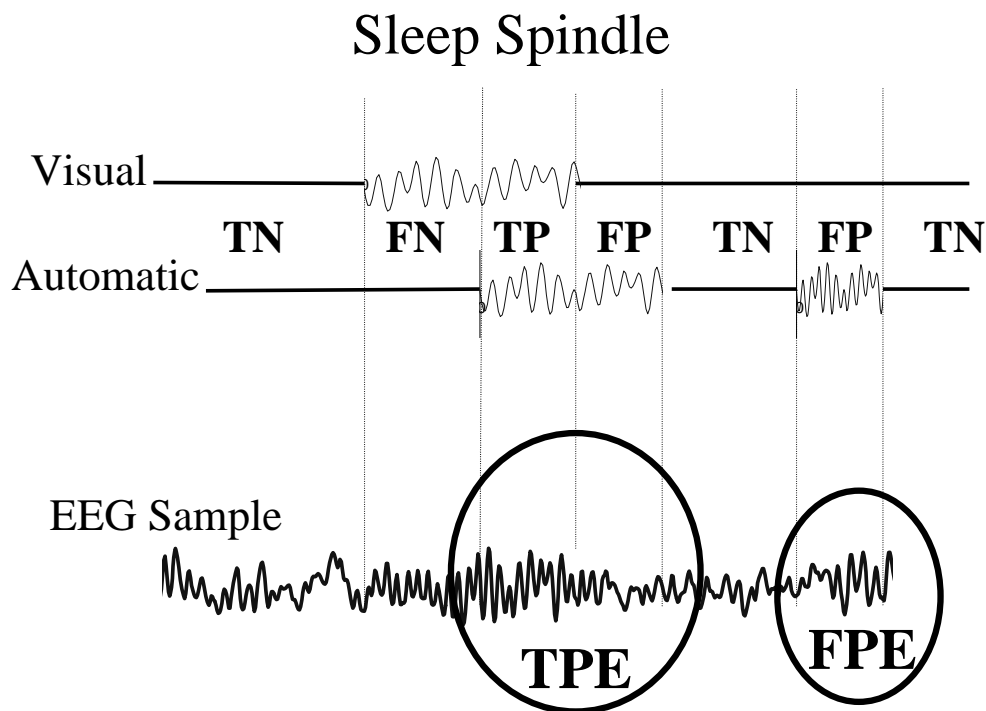


Figura 4.1: Procedimento de Benchmark para os SS. Regiões TP=Positivo Verdadeiro, TN=Negativo verdadeiro, FP=Positivo Falso e FN=Negativo Falso. TPE=Eventos Positivos Verdadeiros, FPE=Eventos Positivos Falso. Aqui a discrepância foi aumentada para propósitos demonstrativos.

adiante.

4.3 Resultados

Desempenho de GT e MP contra análise visual é mostrado em curvas de ROC (Fig. 2). Ambas as metodologias exibiram uma semelhança no desempenho, re-

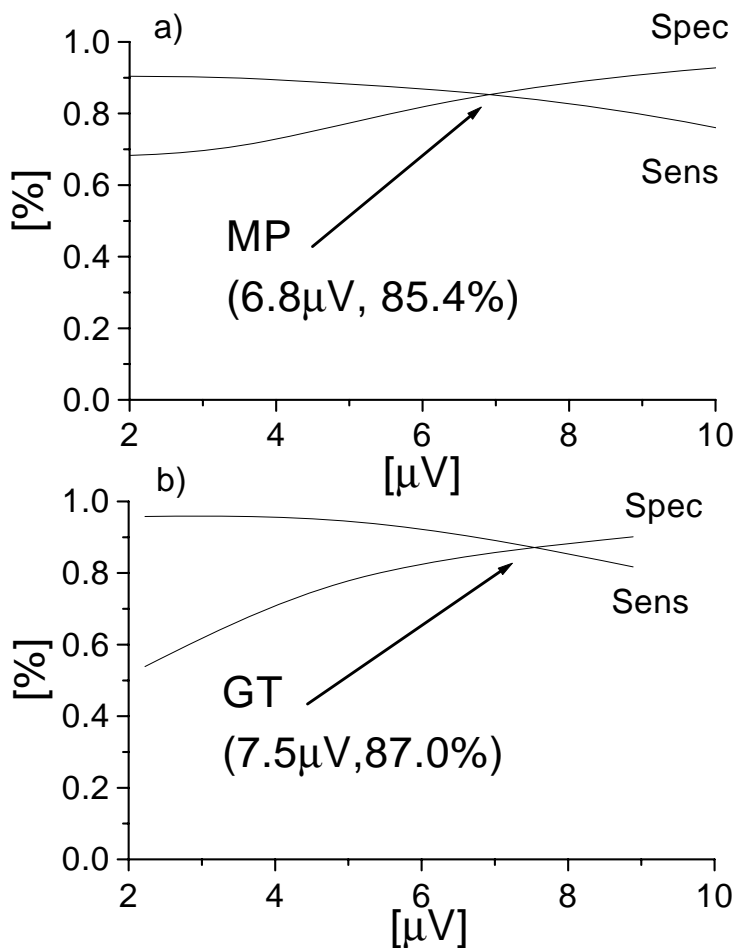


Figura 4.2: Curva ROC, exibindo relações de Sensibilidade/Especificidade para GT e MP como uma função de voltagem na amostra inteira de EEG. Limiar é indicado na figura e usado neste trabalho para comparação direta entre métodos.

sultados são apresentados para concatenação dos dados de todos os sujeitos e estágios existindo alguma variabilidade de limiar entre sujeitos. Nesta amostra, o limiar de GT que maximiza o rendimento entre sensibilidade e especificidade (87%) correspondeu a $7.5\mu V$. Para MP, este ponto era 85.4%, correspondendo a $6.8\mu V$. Uma melhor discussão sobre este ponto é mostrada ao término de seção 4.1.

A Fig. 3 mostra um diagrama de Venn que resume a concordância entre

métodos para eventos únicos (SS). Considerando que visualmente foram detectados 725 SS nesta amostra, GT localizou 2160 e MP 2766 eventos. MP e GT concordaram para 564 (77.8%) SS visualmente detectados. Havia 68 e 64 SS visuais, detectados respectivamente só por MP e GT. Vinte e nove SS não foram achados por qualquer método automático, 9 (1.7%) sendo em S2, 14 (7.2%) em S3+4 e 6 (33.3%) em sono REM.

Acordo global entre métodos automáticos rendeu 1716 estruturas, correspondendo a (79.4%) de SS detectados por GT, e para (62.0%) de eventos detectados por MP. Havia 982 e 380 eventos detectados por MP e GT respectivamente. Estes eventos tiveram uma duração mediana semelhante (0.98s e 1s), enquanto o pico de amplitude MP-FPE (computou diretamente em cima das séries temporais) era $32.6\mu V$ e GT-FPE, $41.5\mu V$. A curva de distribuição de frequência (FFT computou diretamente sobre as séries temporais) foi diferente para MP - e GT-FPE. Como MP encontrou mais FPE na faixa de 14-15Hz que GT, fez-se uma inspeção visual, o que mostrou GT-FPE eram mais ruidosos que MP-FPE. Distribuição por fases não mostrou diferenças entre MP - e características de GT-FPE. Em análise retrospectiva visual, peritos declararam que a maioria dos FPE poderia ser aceita como fusos mal definidos, com distorção de forma, baixa amplitude, duração curta ou embutido em atividade lenta.

Resultados para MP-OS (sobrepondo estruturas) são mostrados como a região sublinhada na Fig. 4. MP pôde achar 645 exemplos nesta amostra (521 duplos, 96 triplos e 28 com quatro ou mais átomos), perfazendo 23.8% de eventos MP-detectados. A região de concordância de MP com GT ou com o método visual incluiu 576 (89.3%) de MP-OS total. MP-OS onde 561 entre 1716 (32.7%) eventos

concordantes entre MP e GT. Duzentos e sessenta e nove (269, 37.1%) SS visual foram classificados como MP-OS, correspondendo a 42.6% da concordância entre MP e o método visual. Trinta e um por cento de duplos MP-OS teve 2Hz de diferença de frequência central, pelo menos entre ambos os átomos; estes eventos corresponderam a 5.8% de átomos totais de MP.

O algoritmo de GT como implementado neste estudo não permite quantificação de estruturas sobrepostas. Em inspeção visual do plot de Wigner para GT, correspondendo a MP-OS, foi possível verificar que freqüentemente GT representa fusos como estruturas gorjeantes (chirps), embora a superposição do fuso (exemplificado na Fig. 5 e discutido abaixo).

4.4 Discussão

O propósito principal deste estudo era comparar duas metodologias de decomposição espectral para identificação de SS, uma vez eles tinham sido aperfeiçoados para reconhecer a análise visual. O procedimento de comparação assim implementado torna necessário analisar eventos detectados por MP como duas ou mais estruturas sobrepostas em separado.

4.4.1 Desempenho contra análise visual

Para ambos os métodos era possível alcançar muito boas taxas de sensibilidade/especificidade contra análise visual (de 85%). O limite de voltagem que




Figura 4.3: Eventos totais achados por GT e MP relativo para contagem visual. Diferenças de tamanho de círculo são meramente ilustrativas e não correspondem exatamente a reais proporções em números.

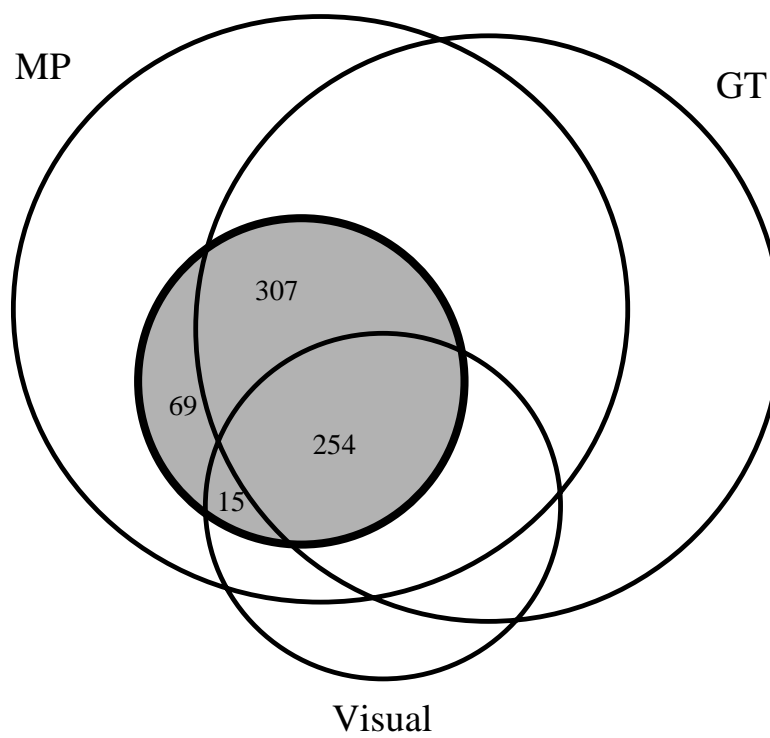


Figura 4.4: Eventos totais de MP-OS (Estruturas Sobrepostas) relativo a GT, MP e contagem visual. Diferenças de tamanho de círculo são meramente ilustrativas e não correspondem exatamente a reais proporções em números.




Figura 4.5: Dois fusos visuais (porção central nas séries temporais) reconstruído como átomos sobrepostos por MP (MP-OS). No esquema de GT, pode-se ver dois fusos gorgjeantes, cada um deles sobrepõem uma ou mais estruturas de frequência. Veja o texto para detalhes.

maximiza o rendimento entre sensibilidade e especificidade foi considerado satisfatório, neste estudo, para detecção simples de SS, porque o alvo da investigação foram eventos de falso positivo. Com estes limiares, a prevalência de fuso automática era de 3 a 4 vezes mais alta que prevalência de fuso visual. Limites de voltagem mais altos rendem menos FPE e podem ser preferido para a caracterização de SS em situações clínicas, se a especificidade precisa ser favorecida sobre a sensibilidade. Porém, poderia ser discutível se a detecção de fusos visual são um padrão ouro perfeito, desde que fusos mal-definidos são perdidos facilmente por humanos [38]. Neste estudo, a análise retrospectiva visual de FPE indicou que a maioria destes eventos poderiam ser aceitos por clínicos como verdadeiros fusos com distorção de forma, baixa amplitude, duração curta ou embutida em atividade lenta. A prevalência combinada de eventos de falso negativo (SS visual que não foi detectado por qualquer método automático), por outro lado, era muito baixo (1.7%) em S2 e moderadamente aumentado (7.2%) em S3+4, onde SS são embutidos em atividade lenta. Prevalência de FNE era alta (33.3%) em sono REM, onde só foram detectados 18 fusos visuais. A concordância de MP com análise visual já havia sido investigada em diferentes fases do sono em um estudo prévio [64] sendo mais baixo nas fases 3+4 e REM.

Assim deveria ainda ser lembrado que ajustes de parâmetro de voltagem MP e GT escolhidas neste estudo são relacionadas a, mas não equivalente a, voltagem de fuso medido diretamente em cima das séries temporais EEG. Voltagem de fuso "vista" em EEG recebe também contribuição de outras faixas de frequência, especialmente em frequências mais baixas, construindo a amplitude de fuso visual. Considerando que no caso de GT e MP, só a atividade na faixa de fre-

qüência de fuso contribuirá a voltagem de átomo representada no espectograma.

4.4.2 Concordância entre MP e GT

MP não é uma transformada em si mesma, mas um procedimento espectral rico para descrever um sinal. Esta descrição confia na escolha de elementos de um dicionário grande e redundante. Átomos são considerados aqui como SS se eles atingem os limites de uma janela de freqüência, como também os limites mínimos de duração e voltagem; é estatisticamente possível para MP reconstruir alguma atividade de EEG classificada por GT como um SS com uma combinação de átomo que não conhece todos os critérios de inclusão a ser classificados como um MP-SS. Neste estudo, boa concordância (embora não ótima) foi vista entre MP e GT, como acordo global entre métodos automáticos correspondendo a pelo menos dois terços de eventos detectados. Deveria ser também lembrado de que este desempenho foi obtido com limites selecionados para maximizar a concordância com análise visual, e não entre métodos automáticos. A discordância de GT com MP neste estudo reflete ajustes de parâmetro para adaptar à análise visual, como também diferenças intrínsecas entre metodologias (por exemplo, 4% GT-SS sendo mais longo que 3s e não seria apanhado por MP).

Poderiam ser resumidas características de fusos automáticos descobertas por MP e GT neste estudo como segue. Prevalências eram igualmente (3 a 4 vezes) mais altas que as obtidas por análise visual; a maioria dos eventos falso positivos foram retrospectivamente aceitos por peritos como fusos pobremente

definidos. Dois terços de eventos automaticamente detectados eram concordes entre métodos. MP e fusos GT discordantes eram semelhantes em duração; aqueles obtidos por MP tenderam apenas a ser menos ruidosos, ligeiramente mais baixos em amplitude e tendo maior contribuição vinda frequências mais altas (14-15Hz), que os provenientes de GT sozinhos.

4.4.3 Sobrepostas MP

Uma proporção significativa de átomos de MP-SS (23.8%), foi reconstruída como múltiplo de estruturas sobrepostas neste estudo, claramente mais alto que os 5% de prevalência de fusos sobrepostos informada por [73]. A análise aqui foi limitada aos canais C3-A2, que espera um apanhado frontal de baixa frequência (ao redor de 12Hz), como também rápido (ao redor 14Hz) parietal [39]. Os fusos sobrepostos presentes em [73], não foram definidos em termos de diferença de frequência ou grau de sobreposição, não sendo possível averiguar aqui quantos destes MP-OS correspondem aos fusos sobrepostos. Porém, prevalência de MP-OS que possui pelo menos 2Hz de diferença na frequência central (melhores candidatos para fusos sobrepostos) era 5.8% do total MP-SS neste estudo, assim sendo semelhante à prevalência informada de fusos sobrepostos. Compreender os MP-OS parece ser pertinente, pois a maioria destes eventos ligados à região de concordância de MP com de GT e/ou método visual. O algoritmo de GT como implementado neste estudo, não habilita quantificar estruturas sobrepostas. Porém, inspeção visual do plot de Wigner para GT correspondente a MP-OS, permite a verificação que GT representou frequentemente fusos como

sendo estruturas gorjeantes, embora a presença de um fuso sobreposto (como mostrado na Fig. 5). MP-OS poderia ser, pelo menos em parte, representações de fusos gorjeantes? MP separa facilmente uma estrutura gorjeante em dois ou mais átomos [29]. Além disso, o sinal fisiológico é altamente não-estacionário [52] e o EEG aparece possuir intrinsicamente variações pequenas de frequência, que podem ser descritas como estruturas gorjeantes. Um exemplo é apresentado para ataques epilépticos em [62]. Fusos de sono foram modelados como pacotes de frequência, acontecendo de tempos em tempos [74], mas alguns fusos de sono podem estar gorjeando junto com seu poder espectral. MP parece ser um descriptor de EEG de sono especialmente satisfatório, como permite comparação ao longo do tempo, topografia e outras características de diferentes estruturas do sinal (por exemplo SS contra atividade de onda lenta [74]). Porém, sua descrição do sinal depende da escolha da função do dicionário. Uma implementação de MP de átomos gorjeantes, como proposto por Gribonval [29], pode talvez permitir uma melhor visualização de características de frequência de fuso de sono isolados.

4.5 Conclusões

Em conclusão, para esta amostra de EEG de sono, duas metodologias de decomposição espectral para detecção automática de fuso de sono (Matching Pursuit e Transformada Gabor) mostraram bom desempenho e semelhança contra análise visual, e boa (embora não ótima) concordância entre um e outro. Ajuste

de parâmetro para acomodar análise visual, como também diferenças intrínsecas entre metodologias, parece responder por discordância entre estes métodos automáticos. Houve prevalências de fuso automático de 3 a 4 vezes mais alta que a prevalência de fuso visual; porém, os peritos foram inclinados retrospectivamente à aceitar a maioria dos eventos de falso positivo como fusos pobremente definidos. Procedimento de MP rendeu uma proporção significativa de estruturas sobrepostas. É sugerido que estes eventos possam representar fusos gorjeantes, fusos que poderiam ser analisados melhor por uma implementação de MP de funções gorjeantes.

Agradecimentos

Este trabalho foi apoiado parcialmente pelo Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e Fundação de Amparo a Pesquisa do Estado do Rio Grande do Sul (FAPERGS). Os autores também gostariam de agradecer a A. C. da Rosa pelas discussões frutíferas durante a apresentação de uma versão anterior deste trabalho durante o X Congresso Brasileiro do Sono no ano passado em Curitiba, Brasil, como uma apresentação em poster. GG também gostaria de agradecer ao Prof. Dr. C. Perottoni pela inestimável ajuda técnica com o Cluster HAL na UCS.

Capítulo 5

Considerações finais e perspectivas

Propusemos a comparação de duas metodologias de detecção de fusos de sono com a análise visual, constatou-se que ambas mostraram desempenho semelhante para encontrar tais grafos elementos e suas concordâncias foram boas, mas não ótimas. A identificação dos fusos foi feita buscando acomodar a análise visual e isto explica algumas discrepâncias. Houve uma prevalência de 3 a 4 vezes maior para os fusos encontrados automaticamente em comparação com os fusos visuais . A maioria dos fusos encontrados automaticamente foram aceitos a posteriori pelos peritos como possíveis "fusos distorcidos". Verificou-se que existe uma grande quantidade de estruturas chirpantes de curta duração no sinal de EEG, e parece haver uma frequência maior de recorrência para os chirps negativos do que positivo. A metodologia Matching Pursuit necessita de uma implementação de funções "Gabor chirpantes" para se fazer uma diferenciação dos fusos sobrepostos de estruturas meramente chirpantes.