

UNIVERSIDADE FEDERAL DO MARANHÃO
CENTRO DE CIÊNCIAS EXATAS E TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

Gustavo Henrique Batista Santos Oliveira

*Detecção automática de complexos-K no sinal EEG humano
baseada em análise espectral multitaper*

São Luís
2019

Gustavo Henrique Batista Santos Oliveira

*Detecção automática de complexos-K no sinal EEG humano
baseada em análise espectral multitaper*

Dissertação apresentada ao Programa de Pós-Graduação em Ciência da Computação da Universidade Federal do Maranhão como requisito parcial para a obtenção do grau de MESTRE em Ciência da Computação.

Orientador: Luciano Reis Coutinho

Doutor em Ciência da Computação – UFMA

São Luís

2019

Ficha gerada por meio do SIGAA/Biblioteca com dados fornecidos pelo(a) autor(a).
Núcleo Integrado de Bibliotecas/UFMA

Henrique Batista Santos Oliveira, Gustavo.

Detecção automática de complexos-K no sinal EEG humano baseada em análise espectral multitaper / Gustavo Henrique Batista Santos Oliveira. - 2019.

80 f.

Orientador(a): Luciano Reis Coutinho.

Dissertação (Mestrado) - Programa de Pós-graduação em Ciência da Computação/ccet, Universidade Federal do Maranhão, São Luís, 2019.

1. Análise espectral. 2. Complexo-K. 3. Eletroencefalograma. 4. Espectrograma multitaper. 5. Estudo do sono. I. Reis Coutinho, Luciano. II. Título.

Gustavo Henrique Batista Santos Oliveira

*Detecção automática de complexos-K no sinal EEG humano
baseada em análise espectral multitaper*

Este exemplar corresponde à redação da dissertação devidamente defendida por Gustavo Henrique Batista Santos Oliveira e aprovada pela banca examinadora.

Aprovada em 26 de Abril de 2019

BANCA EXAMINADORA

Luciano Reis Coutinho (orientador)

Doutor em Ciência da Computação – UFMA

Geraldo Braz Júnior

Doutor em Engenharia de Eletricidade – UFMA

Silmar Silva Teixeira

Doutor em Psiquiatria e Saúde Mental – UFPI

*À minha família, meus
amigos e meus professores.*

Resumo

Neste trabalho propõe-se um novo método para detecção automática de complexos-K (KCs) em eletroencefalograma (EEG) humano, denominado MT-KCD. De forma similar aos métodos existentes, o MT-KCD busca implementar algumas regras básicas da literatura médica tais como a caracterização do KC como uma onda bem-delineada e aguda que se sobressai do *background* iniciada por uma componente negativa e seguida imediatamente por uma componente positiva, possuindo faixa de frequência de 0-4 Hz, amplitude pico a pico $\geq 75 \mu\text{V}$ e duração ≤ 2 segundos. O que diferencia o MT-KCD dos outros métodos é a aplicação de análise espectral *multitaper* para realizar a caracterização do KC como ondas de 0-4 Hz que sobressaem do *background*. A análise espectral *multitaper* do EEG é uma técnica de estimação de potência de sinais estacionários que soluciona os problemas de alto *bias* e variância gerado pela técnicas mais simples e que recentemente tem sido utilizada por alguns pesquisadores como uma técnica complementar ao hipnograma tradicional para o estudo de macro e microestruturas do sono. O MT-KCD divide-se em três fases: pré-processamento, extração de candidatos e eliminação de candidatos. No pré-processamento, gera-se um espectrograma *multitaper* a partir do sinal de EEG de entrada. Na extração de candidatos, o espectrograma é usado para identificar regiões correspondentes a oscilações na faixa 0-4Hz e nelas marcar ondas que se sobressaem do *background* como possíveis ocorrências de KCs. Na eliminação de candidatos, ondas marcadas anteriormente que satisfazem critérios de duração e amplitude são classificadas como KCs. O MT-KCD foi avaliado utilizando uma base de dados pública de KCs, o DREAMS, que tem sido utilizada por grande parte dos trabalhos sobre identificação automática de KCs. Os resultados alcançados mostram, com relação ao *recall* e precisão, o MT-KCD é comparável aos métodos existentes, com a vantagem de apresentar uma melhor relação entre estas métricas (valores de F1 e F2), alcançando valores superiores a 75%, na maioria dos cenários, superando os demais métodos.

Palavras-chave: Eletroencefalograma, complexo-K, espectrograma *multitaper*, estudo do sono, análise espectral.

Abstract

In this work it is proposed a novel method for automatic k-complex (KC) detection in human sleep EEG, named MT-KCD. Like most methods, MT-KCD codifies some rules used by human experts such as KC characterization as 0-4 Hz waveform standing out from the background, with peak-to-peak amplitude $\geq 75 \mu V$ and duration ≤ 2 seconds. The MT-KCD novelty when compared to existing methods is the usage of multitaper spectral analysis to characterize the KC as 0-4 Hz waveform standing out from the background. The EEG multitaper spectral analysis is a recently proposed technique by researchers as a complement to the traditional hypnogram to sleep staging. The MT-KCD consists in three phases: pre-processing, candidates extraction and candidates elimination. In pre-processing phase, EEG multitaper spectrogram is computed. In sequence, the multitaper spectrogram is used to identify regions where possible have KCs occurrences. Lastly, candidates waveform which satisfy duration and peak-to-peak amplitude criterias are marked as KC. MT-KCD was evaluated using a public KC database known as DREAMS. Results have shown that MT-KCD improves detection metrics, especially F1 and F2 scores (harmonic averages of recall and precision), when compared to existing methods. F1 and F2 scores of MT-KCD on DREAMS were greater than 75%, in most of the evaluation scenarios, outperforming other methods. In regards to recall and precision, MT-KCD is comparable to existing methods in recall and precision, but presenting a more balanced relation between these metrics (F1 and F2 scores).

Keywords: Electroencephalogram, k-complex, multitaper spectrogram, sleep study, spectral analysis.

Agradecimentos

Ao meu orientador, Luciano Reis Coutinho, pelos ensinamentos, confiança e parceria.

Ao professor Josenildo Costa da Silva, que participou do desenvolvimento da pesquisa e contribuiu para o produto final deste trabalho.

Aos amigos e família que me incentivaram em todos momentos, tornando possível a produção deste trabalho.

Aos membros do Núcleo de Tecnologia da Informação - NTI do IFMA Campus São Luís Monte Castelo pelo apoio, compreensão e contribuição.

Aos membros do LSDi-UFMA, pelos ensinamentos, conselhos e estímulos.

A UFMA e ao PPGCC pela estrutura dada à execução deste trabalho.

Lista de Figuras

1.1	Estágios do sono e tipos de onda do sinal Electroencefalograma (EEG) (adaptado de [1]).	14
3.1	Comparação entre métodos de estimação espectral.	25
3.2	Comparação entre estimativas de espectro de potência utilizando janelas retangulares.	27
3.3	Comparação entre estimativas de espectro de potência utilizando janela de <i>Hann</i> e abordagem <i>multitaper</i>	28
4.1	Fases e etapas do <i>Multitaper-based KC detection</i> (MT-KCD).	31
4.2	Identificação de regiões candidatas no sinal filtrado.	37
4.3	Marcação de KCs candidatos no sinal filtrado.	37
4.4	Fases e principais etapas do MT-KCD.	40
6.1	Marcações do MT-KCD comparadas com as anotações dos especialistas.	52
A.1	Marcações do MT-KCD comparadas com as anotações dos especialistas para o paciente 01.	64
B.1	Marcações do MT-KCD comparadas com as anotações dos especialistas para o paciente 02.	68
C.1	Marcações do MT-KCD comparadas com as anotações dos especialistas para o paciente 03.	72
D.1	Marcações do MT-KCD comparadas com as anotações dos especialistas para o paciente 04.	76

E.1	Marcações do MT-KCD comparadas com as anotações dos especialistas para o paciente 05.	80
-----	---	----

Lista de Tabelas

2.1	Técnicas e resultados (%) baseados em classificação. Os resultados são dados em termos das seguintes métricas: $Recall = tp/(tp + fn)$, Precisão = $tp/(tp + fp)$ e Acurácia = $(tp + tn)/(tp + tn + fp + fn)$, onde tp são os verdadeiros positivos, tn são os verdadeiro negativos e fn são os falso negativos.	18
2.2	Técnicas e resultados (em porcentagem) dos métodos de identificação de Complexo-K (KC) baseado em detecção.	20
5.1	Anotações dos especialista na base de dados DREAMS.	44
5.2	Valores de parâmetros do MT-KCD ($F_s = 200$).	46
6.1	Resultados do cenário 1 (%).	50
6.2	Resultados do cenário 2 (%).	50
6.3	Resultados do cenário 3 (%).	50
6.4	Comparação entre os métodos, cenário 1.	54
6.5	Comparação entre os métodos, cenário 2.	54
6.6	Comparação entre os métodos, cenário 3.	54

Sumário

Lista de Figuras	v
Lista de Tabelas	vii
1 Introdução	13
1.1 O estudo do sono	13
1.1.1 Macroestruturas do sono	13
1.1.2 Microestruturas do sono	14
1.1.3 O complexo-K (KC)	15
1.2 Objetivo	16
1.3 Hipótese de pesquisa	16
1.4 Estrutura da dissertação	17
2 Identificação automática de KCs	18
2.1 Abordagens baseadas em classificação	18
2.2 Abordagens baseadas em detecção	19
2.3 Método proposto	21
3 Análise Espectral <i>Multitaper</i>	22
3.1 O sinal EEG	22
3.2 Espectro de potência de sinais finitos	23
3.3 Espectro de potência a longo prazo	24
3.4 Espectrograma baseado em periodograma	25
3.5 <i>Bias</i> e variância	26
3.6 Espectrograma <i>multitaper</i>	28

3.7	Parâmetros do espectrograma <i>multitaper</i>	29
4	Detector de KCs baseado em <i>Multitaper</i>	31
4.1	Visão geral do MT-KCD	31
4.2	Pré-processamento	32
4.3	Extração de candidatos	32
4.3.1	Identificação de regiões candidatas	33
4.3.2	Marcação de KCs candidatos	34
4.4	Eliminação de candidatos	38
4.4.1	Checagem de um candidato por região	38
4.4.2	Validação de amplitude e duração	39
4.5	Análise de complexidade	40
5	Avaliação Experimental	43
5.1	DREAMS	43
5.2	Cenários	43
5.3	Métricas	44
5.4	Parâmetros	45
6	Resultados da avaliação	48
6.1	Implementação	48
6.2	Cenário 1: cinco pacientes, anotações dos dois especialistas	48
6.3	Cenário 2: cinco pacientes, anotações do primeiro especialista	51
6.4	Cenário 3: cinco pacientes, anotações do segundo especialista	51
6.5	Comparação com os métodos existentes	53
7	Conclusão e Trabalhos Futuros	55
	Referências Bibliográficas	57

A	Marcações do MT-KCD para o paciente 01	61
B	Marcações do MT-KCD para o paciente 02	65
C	Marcações do MT-KCD para o paciente 03.	69
D	Marcações do MT-KCD para o paciente 04.	73
E	Marcações do MT-KCD para o paciente 05.	77

1 Introdução

A qualidade do sono influencia diretamente a performance mental e física do ser humano. Estudos comprovam que pessoas com uma má qualidade de sono ingerem uma maior quantidade de calorias, aumentando o risco de obesidade [2, 3]. Em relação à performance mental, o sono desempenha um papel fundamental em diversos processos cognitivos, tais como aprendizado, consolidação da memória e formação de *insigth* [4]. Atualmente, o sono insuficiente, a insônia e outros distúrbios do sono relacionados à rotina estressante do ser humano são os maiores obstáculos para manter a qualidade do sono [5].

1.1 O estudo do sono

A *polissonografia* (PSG) é um exame multiparamétrico utilizado para estudar a qualidade do sono e diagnosticar possíveis distúrbios. Na sua forma mais simples, a PSG envolve o registro de três sinais vitais durante uma noite de sono [6]: ondas cerebrais via *encefalograma* (EEG), movimentos dos olhos via *eletrooculograma* (EOG) e tonicidade muscular via *eletromiograma* (EMG). A partir da análise desses sinais, principalmente do EEG, os médicos especialistas em sono são capazes de identificar as macro e microestruturas do sono assim como distúrbios relacionados.

1.1.1 Macroestruturas do sono

As macroestruturas do sono representam os ciclos do sono, sendo divididas em cinco estágios: W, N1, N2, N3 e REM [6, 7]. O estágio W, estado de vigília, representa o período de sonolência antes do sono. O estágio N1, sono leve, é caracterizado por lentos movimentos dos olhos e por ondas cerebrais de baixa amplitude, com frequência variada. O estágio N2 ocorre quando o corpo entra no período de transição para o sono profundo. Neste estágio não há movimentos oculares e as ondas cerebrais se tornam mais lentas, com ocasionais ondas rápidas. O estágio N3, sono profundo, é caracterizado por ondas cerebrais extremamente lentas,

pela ausência de atividade muscular e por uma respiração mais lenta, profunda e cadenciada. Além destes estágios, tem-se o REM, estágio onde os sonhos ocorrem. No REM, os olhos movimentam-se rapidamente em várias direções, a respiração torna-se mais acelerada e as atividades musculares são paralisadas temporariamente. A Figura 1.1 sumariza os estágios do sono.

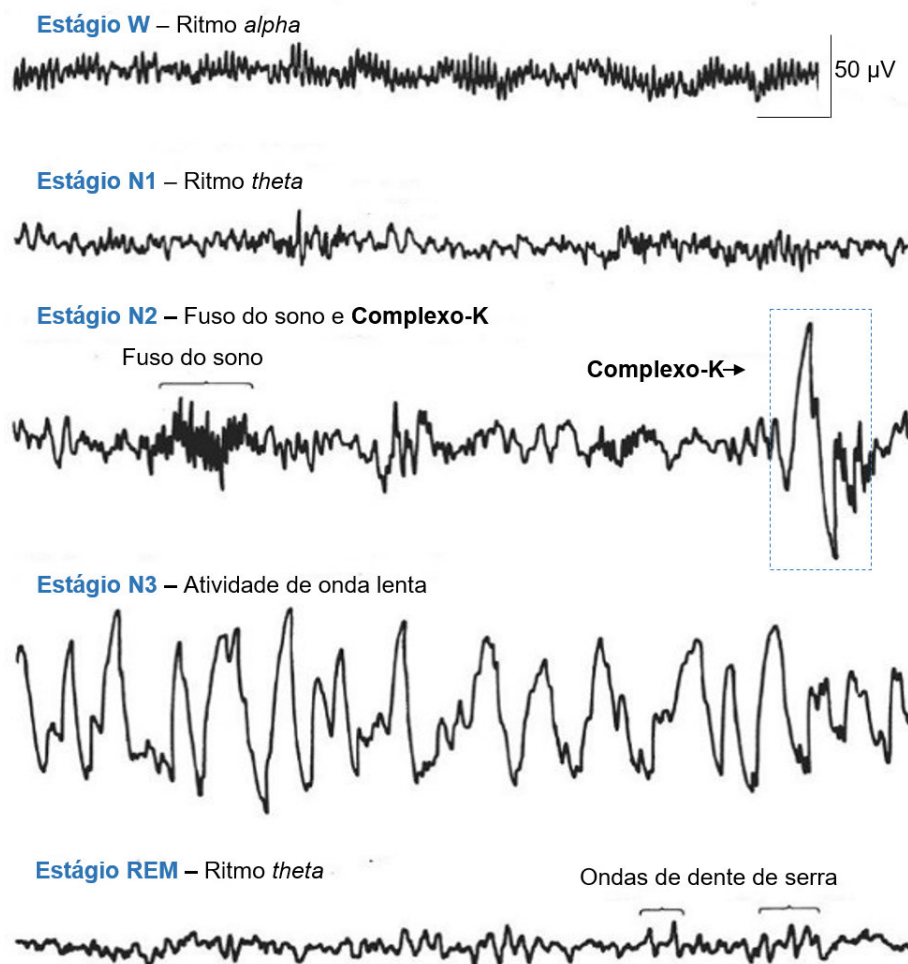


Figura 1.1: Estágios do sono e tipos de onda do sinal EEG (adaptado de [1]).

1.1.2 Microestruturas do sono

As microestruturas do sono correspondem às atividades oscilatórias mescladas com eventos transitórios, ocorrendo principalmente no sinal EEG [6,7]. Seis tipos de ondas do sinal EEG são particularmente importantes: ritmo *alpha*, ritmo *theta*, fusos do sono, complexos-K, atividade de ondas lentas e ondas de dentes de serra (Figura 1.1).

O ritmo *alpha* consiste em oscilações sinusoidais na faixa de 8-13 Hz e caracteriza o estágio W. O ritmo *theta* compreende as oscilações de baixa amplitude (4-8 Hz), ocorrendo, sobretudo, nos estágios N1 e REM. Os fusos do sono e complexos-K são eventos intermitentes que caracterizam o estágio N2. Os fusos do sono são definidos como cadeias de ondas distintas com frequência entre 11-16 Hz e duração ≥ 0.5 segundos. Os **complexos-K** são oscilações lentas caracterizadas por uma onda negativa¹, bem-delineada e aguda seguida imediatamente por uma componente positiva que se sobressai do *background*, apresentando uma alta amplitude e duração ≥ 0.5 segundos. A atividade de ondas lentas consiste em oscilações de frequência entre 0.5-2 Hz e amplitude pico a pico $\geq 75 \mu V$, sendo característica do estágio N3. Por fim, tem-se as ondas de dente de serra. As ondas de dente de serra possuem forma triangular aguda, geralmente serrilhadas, frequência de 2-6 Hz e ocorrem durante o estágio REM.

1.1.3 O complexo-K (KC)

Dentre os tipos de ondas do sinal EEG, o complexo-K (daqui em diante, KC) destaca-se como um importante grafoelemento da microestrutura do sono. Na Neurociência e Medicina do Sono, o KC é um tópico amplamente estudado. Pesquisadores vêm concentrando esforços a fim de compreender suas funções e relações com distúrbios do sono [8]. O ponto de vista mais aceito é que o KC é o precursor da atividade de onda lenta, e indica ocorrências de funções homeostáticas e reativas [9–12]. Os KCs representam estados corticais descendentes e refletem uma diminuição no aquecimento neural [13]. Estes estados são um modo fundamental da operação cortical e podem contribuir para o processo de proteção do sono e consolidação de memória [13, 14]. Além disso, alguns trabalhos reportam correlações entre a quantidade e forma dos KCs e distúrbios do sono, tais como insônia e apneia [15, 16]. Além do debate a cerca das funções fisiológicas, o KC é de grande importância durante o processo de estagiamento do sono: ele é utilizado como um dos marcadores do estágio N2. Desta forma, a correta identificação das ocorrências do KC é um pré-requisito tanto para o mapeamento confiável das macroestruturas do sono assim como para a posterior análise da qualidade do sono do paciente.

¹Por convenção, as voltagens negativas do sinal EEG são plotadas para cima.

Dada a importância fisiológica e prática do KC, e considerando o esforço necessário para especialistas humanos analisarem todo o sinal EEG — uma tarefa custosa, demorada e passível de erros [17]—, pesquisas recentes vêm propondo métodos para a identificação automática de KCs [18–29]. Em geral, os métodos de identificação de KCs propostos podem ser agrupados segundo dois pontos de vistas: classificação e detecção [27]. Os métodos baseados em classificação pressupõem uma segmentação do sinal de entrada em intervalos de tamanhos fixo. Isso implica em assumir que os KCs possuem uma duração fixa, o que não é o caso de acordo com a literatura médica [7]. Esses métodos apresentam valores de acurácia entre 69% e 96%, valores de *recall* entre 70% e 74% e de precisão variando entre 70% e 85% [27–32]. Os métodos baseados em detecção, por outro lado, não pressupõem a segmentação prévia do sinal em tamanhos fixos. Esses métodos apresentam valores de *recall* entre 60% e 84% e valores de precisão entre 56% e 80% [18–25]. Embora os métodos existentes apresentem índices de *recall* e precisão razoáveis, em geral a relação entre *recall* e precisão, F1 e F2, apresentam valores inferiores a 75%.

1.2 Objetivo

Motivado por esses fatos, o objetivo deste trabalho é apresentar um método para detecção automática de KC em sinal de EEG humano de tal forma a melhorar a relação entre *recall* e precisão, superando o valor médio de 75% alcançado pelos métodos existentes. Como hipótese de trabalho, propõe-se a utilização da análise espectral *multitaper* para a identificação de KCs. Assim, o objetivo deste trabalho pode também ser formulado como uma automatização da análise de espectrogramas *multitaper* do sinal EEG no que diz respeito à detecção de KCs.

1.3 Hipótese de pesquisa

Nos últimos anos, a análise espectral *multitaper* tem sido apontada como uma técnica vantajosa para a caracterização no domínio da frequência das macro e microestruturas do sono no sinal EEG [33–36]. Neste tipo de análise, o sinal EEG é caracterizado a partir do espectrograma *multitaper*. Nele, eventos intermitentes como

fusos do sono e KCs aparecem como áreas em que há concentração de energia. Devido aos diferentes padrões de frequência de cada evento, as áreas correspondentes estão localizadas em faixas de frequências específicas (0-4 Hz para KCs e 11-16 Hz para fusos do sono). Estas observações justificam a motivação para o uso da análise espectral *multitaper* e apontam para como ela pode ser utilizada na tarefa de detecção de KCs.

A partir do espectrograma *multitaper* do sinal EEG, a ideia geral é extrair KCs candidatos a partir da busca por áreas que possuam concentração de potência na faixa de 0-4 Hz (ritmo delta) e que se sobressaiam do *background* no domínio do tempo. Após a extração, antes de serem considerados instâncias de KCs, os KCs candidatos são submetidos à testes complementares de acordo com critérios de amplitude e duração. Essa ideia explora a resolução tempo-frequência mais refinada provida pelos espectrogramas *multitaper*, baseando-se diretamente nas principais características do KC (como por exemplo, precursora da onda lenta, onda de alta amplitude que se sobressai do *background*) como descrito na literatura [7, 10, 14, 33].

1.4 Estrutura da dissertação

O restante da dissertação está estruturado da seguinte forma. No Capítulo 2, apresenta-se uma análise dos métodos existentes para identificação de KCs. Conceitos básicos de análise espectral *multitaper* são revisados no Capítulo 3. O método proposto, MT-KCD, é detalhado no Capítulo 4. Em seguida, a metodologia de avaliação é descrita no Capítulo 5 e os resultados experimentais são discutidos no Capítulo 6. Por fim, no Capítulo 7, apresentam-se as conclusões e trabalhos futuros.

2 Identificação automática de KCs

O problema de identificação automática de KCs tem sido abordado sob dois pontos de vistas: classificação e detecção [27].

2.1 Abordagens baseadas em classificação

Na abordagem baseada em classificação, o sinal EEG é inicialmente dividido em segmentos de tamanhos fixos e, então, cada segmento é classificado como uma instância de KC ou não. Abordagens baseadas em classificação usualmente utilizam algoritmos de aprendizagem de máquina (AM), como regressão logística [27,28], redes neurais [27–31] e máquina de vetor de suporte [27,28,32]. Em geral, os algoritmos são treinados utilizando uma base de dados anotada por especialistas do sono e, a partir do treinamento, realiza as marcações na base de teste. Atualmente, o processo de anotação de instâncias de KC em um sinal EEG é um processo custoso, havendo poucas bases de treinamento disponíveis.

Método	Técnica de AM	Recall	Precisão	Acurácia
[27]	Rede neural (FNN)	—	—	91,40
[28]	Rede neural (RBF + MLP)	74,36	85,29	69,39
[29]	Rede neural (MELM-GRBF)	61,00	—	96,15
[30]	Rede neural (MLP)	—	—	—
[31]	Rede neural (MLP)	90,00	—	—
[32]	Máquina de Vetor Suporte	70,40	70,40	90,20

Tabela 2.1: Técnicas e resultados (%) baseados em classificação. Os resultados são dados em termos das seguintes métricas: $Recall = tp/(tp + fn)$, $Precisão = tp/(tp + fp)$ e $Acurácia = (tp + tn)/(tp + tn + fp + fn)$, onde tp são os verdadeiros positivos, tn são os verdadeiro negativos e fn são os falso negativos.

A Tabela 2.1 detalha os valores de *recall*, precisão e acurácia alcançados pela técnica de AM utilizada por cada método que apresentou melhores resultados.

Conforme mencionado no Capítulo 1, a principal limitação das abordagens baseadas em classificação é o fato de segmentar o sinal EEG em intervalos de tamanhos fixo, assumindo que os KCs possuem uma duração fixa, o que não é o caso conforme a literatura médica [7].

2.2 Abordagens baseadas em detecção

A identificação de KCs baseada em detecção recebe como entrada o sinal EEG completo (não-segmentado) e tem como saída o conjunto de segmentos, de tamanhos variados, identificados como instâncias de KC [18–25]. A partir da análise dos métodos existentes para detecção de KC, é possível perceber uma estrutura padrão. Essa estrutura consiste em três fases sequenciais: *pré-processamento*, *extração de candidatos* e *eliminação de candidatos*. Essas fases estão presentes explicitamente em alguns métodos enquanto que, em outros, estão presentes apenas de forma implícita, conforme sumarizado na Tabela 2.2.

Na fase de pré-processamento, o sinal EEG é filtrado ou transformado utilizando diferentes técnicas. Uma técnica comum é a aplicação de filtros de banda-passa no sinal de entrada, reduzindo o efeito de possíveis artefatos (movimentos do corpo, ruídos elétricos, etc.). Após a filtragem, muitos trabalhos convertem o sinal EEG para uma outra representação, seja no domínio do tempo ou frequência. Uma abordagem comumente utilizada é decompor o sinal em componentes de múltiplas frequências ou em escalas de tempo. Para isso, são utilizadas técnicas baseadas em *wavelets*, tais como a transformada discreta de *wavelet* [19, 24], transformada contínua de *wavelet* [22] e transformada de *wavelet Q-tunable* [21]. Outros trabalhos fazem uso da transformada discreta de curta duração de *Fourier* e redes Bayesianas [25]. Alternativamente, o sinal de entrada pode ser convertido para outra representação no domínio do tempo. Essa abordagem é utilizada em [23], onde o sinal de entrada é multiplicado por coeficientes de energia de curto e longo prazo, produzindo como saída um série temporal de energia relativa.

Na fase de extração de candidatos, o sinal pré-processado é analisado e um conjunto de instâncias de KCs candidatos é gerado. Nesta etapa, em geral, calculam-se características do sinal filtrado/transformado e, então, identifica-se KCs

Método	Pré-Processamento	Extração de candidatos	Eliminação de candidatos	Recall	Precisão
[18]	—	Amplitude pico a pico e voltagens do segmento e do <i>background</i>	Amplitude pico a pico do candidato	61,72	73,29
[19]	Transformada discreta de <i>wavelet</i>	Amplitude pico a pico, declive e duração do segmento	Amplitude, duração e potência relativa do <i>background</i> e amplitude pico a pico do candidato	56,10	72,90
[20]	—	Operador de energia Teager-Kaiser	Duração do candidato	83,31	63,69
[21]	Transformada de <i>wavelet</i> <i>Q-tunable</i>	Distância entre dois picos negativos de amplitude	—	61,00	56,00
[22]	Transformada contínua de <i>wavelet</i>	Duração da escala da <i>wavelet</i>	Quantidade de KCs dentro de um intervalo	84,00	62,00
[23]	Conversão para de série energia relativa	Valor do coeficiente ao série de energia relativa	Amplitude máxima, mínima e pico a pico, e duração do candidato	65,05	80,98
[24]	Transformada discreta de <i>wavelet</i>	Operador de energia Teager-Kaiser e duração do segmento	Amplitude, duração e declive do candidato	87,00	—
[25]	Transformada discreta de curta duração de Fourier e redes Bayesianas	Amplitude e duração do segmento	—	52,02	—

Tabela 2.2: Técnicas e resultados (em porcentagem) dos métodos de identificação de KC baseado em detecção.

candidatos. Exemplos de características computadas são a duração [19, 24, 25] e declive do segmento [19], amplitude pico a pico [18, 19, 22, 25], amplitude negativa, distância entre dois picos de amplitude [21], duração da escala de *wavelet* [22], valor do coeficiente do sinal [23], média e desvio padrão do segmento [26] e o operador de energia Teager-Kaiser [20, 24]. A extração dos candidatos é realizada a partir da comparação entre as características e limiares pré-definidos.

Por fim, na fase de eliminação de candidatos, KCs candidatos que não satisfaçam um conjunto de condições pré-estabelecido são rejeitados. Na maioria dos métodos, a eliminação de candidatos é baseado em características do domínio do tempo, tais como amplitude [18, 19, 23, 24], duração [19, 20, 24] e quantidade de KCs candidatos dentro de uma janela de n -segundos [22]. No domínio da frequência, um exemplo de característica utilizada é a potência relativa do sinal [19].

Diferentemente dos métodos baseados em classificação, os métodos baseados em detecção não empregam a acurácia como métrica de avaliação, mas apenas *recall* e precisão. Isso porque, como não há uma quantidade pré-definida de segmentos a ser classificada, não há como mensurar a quantidade de verdadeiros negativos (tn) dentro de um dado sinal EEG. Em geral, os métodos existentes não apresentam uma boa relação entre *recall* e precisão, alcançando valores abaixo de 75%, apresentando assim margem para evolução. Essa relação entre os valores do *recall* e precisão dos métodos detalhados na Tabela 2.2 é computada a partir do cálculo de médias harmônicas (F1 e F2).

2.3 Método proposto

Dado que o KC não possui uma duração pré-definida, dificultando a segmentação do EEG em intervalos de tamanhos fixos, o problema de identificação automática de KCs, neste trabalho, é abordado sob o ponto de vista de detecção. Em comparação com os métodos existentes na literatura, o método de detecção automática de KC proposto segue o mesmo padrão estrutural, apresentando as fases de pré-processamento, extração e eliminação de candidatos. A principal diferença está nas técnicas utilizadas nas fases de pré-processamento e extração de candidatos, onde se faz uso de uma abordagem baseada em análise espectral *multitaper*.

3 Análise Espectral *Multitaper*

A análise espectral *multitaper* é uma técnica utilizada para estimar o espectro de potência de sinais estacionários [37]. Ela surgiu com o objetivo de solucionar alguns problemas de técnicas mais simples [36]. Recentemente, a análise espectral *multitaper* vem sendo aplicada em áreas da bioengenharia, neurociência, e análise do sono. Neste último caso, a técnica tem sido utilizada para caracterizar as macro e microestruturas do sono no sinal EEG [33–36].

Neste capítulo são discutidos conceitos básicos da análise espectral aplicada ao sinal EEG, assim como as limitações das abordagens mais simples e as vantagens da abordagem *multitaper*. Inicialmente o sinal EEG é formalizado. Em seguida, discutem-se os conceitos de espectro de potência, espectro de potência a longo prazo, espectrogramas baseados em periodogramas, os problemas de *bias* e variação do periodograma, o espectrograma *multitaper* e suas vantagens. Ao final, caracterizam-se os parâmetros necessários para a estimação do espectrograma *multitaper*.

3.1 O sinal EEG

O EEG registra a atividade elétrica do cérebro: oscilação de voltagens, em μV , medida em diferentes regiões do escalpo, correspondentes aos lobos do cérebro (frontal, central e occipital). Em cada região, um ou mais eletrodos são posicionados, cada um dando origem a um canal de dados definido como derivação [7]. As medições ocorrem em uma taxa constante de amostras por segundo durante um tempo limitado. Nesse sentido, um registro EEG pode ser modelado como $\{x^{(1)}[n], x^{(2)}[n], \dots, x^{(D)}[n]\}$, onde cada $x^{(d)}[n]$, for $d = 1, \dots, D$, é uma sequência separada de dados de duração finita em tempo discreto (série temporal) representando uma derivação específica.

Tempo discreto significa que o tempo é medido em etapas de tempo $n = 0, \pm 1, \pm 2, \dots$ em que as amostras são registradas. Sendo T_s o *período de amostragem* e representando a voltagem medida pelo eletrodo e_d no momento nT_s por $e_d(nT_s)$, tem-se que $x^{(d)}[n] = e_d(nT_s)$. O inverso de T_s representa a *taxa de amostragem* $F_s = 1/T_s$.

Duração finita significa que existe um N tal que $x^{(d)}[n] = 0$ para todo $n < 0$ ou $n \geq N$. Esse N é a *duração* ou *tamanho* de $x^{(d)}[n]$. (Na sequência, para facilitar a notação, o sobrescrito (d) de $x^{(d)}[n]$ é omitido, escrevendo-se apenas $x[n]$ para denotar uma sequência de dados similares a $x^{(d)}[n]$.)

3.2 Espectro de potência de sinais finitos

Em muitos problemas, a informação contida no sinal pode ser analisada em termos da sua *densidade espectral de potência*, ou *espectro de potência*. O espectro de potência descreve como a potência média de um sinal é distribuída ao longo das faixas de componentes de frequência que compõem o sinal. Comumente, a *potência média* de um sinal de tempo discreto $x[n]$ sob um intervalo n_1 até n_2 é definido como a *energia* envolvida, dado por $\sum_{n=n_1}^{n_2} |x[n]|^2$, dividida pelo tamanho do intervalo, $n_2 - n_1 + 1$ [38]. Quando o sinal possui uma duração finita, N , sua energia total é finita e, a partir do teorema de Parseval, é possível mostrar que

$$\frac{1}{N} \sum_{n=0}^{N-1} |x[n]|^2 = \frac{1}{NF_s} \int_0^{F_s} |\text{FT}_x(f)|^2 df, \quad (3.1)$$

onde F_s é a taxa de amostragem e $\text{FT}_x(f)$ é a transformada de Fourier no tempo discreto de $x[n]$ dada pela fórmula

$$\text{FT}_x(f) = \sum_{n=-\infty}^{+\infty} x[n] e^{-i2\pi(f/F_s)n}, \quad f \in [0, F_s] \text{ Hz}. \quad (3.2)$$

A partir da (3.1), o *espectro de potência* de $x[n]$ limitado à uma duração finita N pode ser definido como

$$S_x^N(f) = \frac{1}{NF_s} |\text{FT}_x(f)|^2, \quad f \in [0, F_s] \text{ Hz}. \quad (3.3)$$

Integrando $S_x^N(f)$ de 0 a F_s , obtém-se a potência média $x[n]$ do intervalo de 0 a $N-1$; e, da frequência f_1 a f_2 , parte da potência média da faixa de frequência f_1 - f_2 Hz. Portanto, $S_x^N(f)$ descreve a distribuição da potência média (em um horizonte finito) de $x[n]$ para cada faixa de frequência.

3.3 Espectro de potência a longo prazo

Sinais como o EEG são obtidos através de amostragem limitada de processos de longa duração. Desta forma, eles podem ser vistos como segmentos relativamente pequenos de seqüências de dados mais longas.

Seja $\chi[m]$ uma seqüência de tempo discreto potencialmente infinita, i.e., uma seqüência de dados para a qual não há um M tal $x[m] = 0$ para todo $m \geq M$. A partir de $\chi[m]$, seqüências de dados de tamanho finito $x[n]$ podem ser obtidas através da *operação de janelamento*. Isso é, $x[n] = w_R^N[n]\chi[n]$ onde $w_R^N[n]$ é uma *janela retangular de dados* de tamanho N definida por

$$w_R^N[n] = \begin{cases} 1, & \text{se } 0 \leq n < N, \\ 0 & \text{caso contrário.} \end{cases} \quad (3.4)$$

Considerando $x[n] = w_R^N[n]\chi[n]$, o principal problema na análise espectral é como estimar o espectro de potência de $\chi[m]$ a partir de $x[n]$. Para tornar o problema mais significativo e analiticamente tratável, outras suposições são feitas. De forma geral, assume-se que $\chi[m]$ é resultado de um *processo estacionário* [36,37]. Isso significa que uma futura variação de $\chi[m]$ não pode ser exatamente conhecida, entretanto algumas medidas estatísticas como a média $\mu_\chi = \mathbb{E}\{\chi[m]\}$ e a variância $\sigma_\chi^2 = \mathbb{E}\{|\chi[m] - \mu_\chi|^2\}$, são constantes ao longo do tempo. Dado que a variância pode ser representada por $\sigma_\chi^2 = \mathbb{E}\{|\chi[m]|^2\} - |\mu_\chi|^2$, tem-se que a energia esperada por etapa de tempo (potência média), $\mathbb{E}\{|\chi[m]|^2\} = \sigma_\chi^2 + |\mu_\chi|^2$, é finita. Considerando essa suposição, o espectro de potência a longo prazo de $\chi[m]$ é então definido por

$$\phi_\chi(f) = \lim_{N \rightarrow \infty} \mathbb{E}\{S_x^N(f)\}, \quad f \in [0, F_s] \text{ Hz.} \quad (3.5)$$

Eq. (3.5) assume que a quantidade de amostras é infinita, logo, não pode ser utilizada para calcular $\phi_\chi(f)$ diretamente. Uma abordagem mais simples é ignorar a estimativa e a operação de limite descrita na Eq. (3.5) e considerar apenas $S_x^N(f)$ como um estimador de $\phi_\chi(f)$. Esse estimador, obtido através da Eq. (3.3), é conhecido como *periodograma* [36,37].

3.4 Espectrograma baseado em periodograma

Para sinais estacionários, o cálculo de um único periodograma, $S_x^N(f)$, é suficiente para a estimação do espectro de potência a longo prazo, $\phi_x(f)$. Quanto maior o tamanho de N , mais correta é a estimativa. Quando a estrutura da frequência do sinal varia ao longo do tempo (por exemplo, Figura 3.1(a)), a suposição de que o sinal é estacionário não é válida para longas sequências de dados. Nestes casos, uma alternativa é dividir $x[n]$ em sequências consecutivas, igualmente espaçadas e possivelmente sobrepostas $x_0[n], x_1[n], \dots, x_{J-1}[n]$, $J < N$, usando janelas retangulares de tamanho $L < N$ (Figura 3.1(b)). Isto é, $x_j[n] = w_R^L[n - j\Delta_j]x[n]$ para $j = 0, 1, \dots, J-1$, com $J = \lceil N/\Delta_j \rceil$ e $\Delta_j < N$ representando a separação entre duas subsequências consecutivas $x_j[n]$ e $x_{j+1}[n]$. Neste contexto, quanto menor for o tamanho da janela L , mais as subsequências $x_j[n]$ podem ser consideradas estacionárias. Desta forma, calculando $S_{x_0}^L(f), S_{x_1}^L(f), \dots, S_{x_{J-1}}^L(f)$, ao invés de um único periodograma $S_x^N(f)$, é possível representar o dinamismo do espectro de potência do sinal ao longo tempo. O conjunto de estimativas $\text{SG}_x^{L,\Delta_j} = (S_{x_0}^L(f), S_{x_1}^L(f), \dots, S_{x_{J-1}}^L(f))$ é chamado de *espectrograma baseado em periodograma* of $x[n]$ (Figura 3.1(c)).

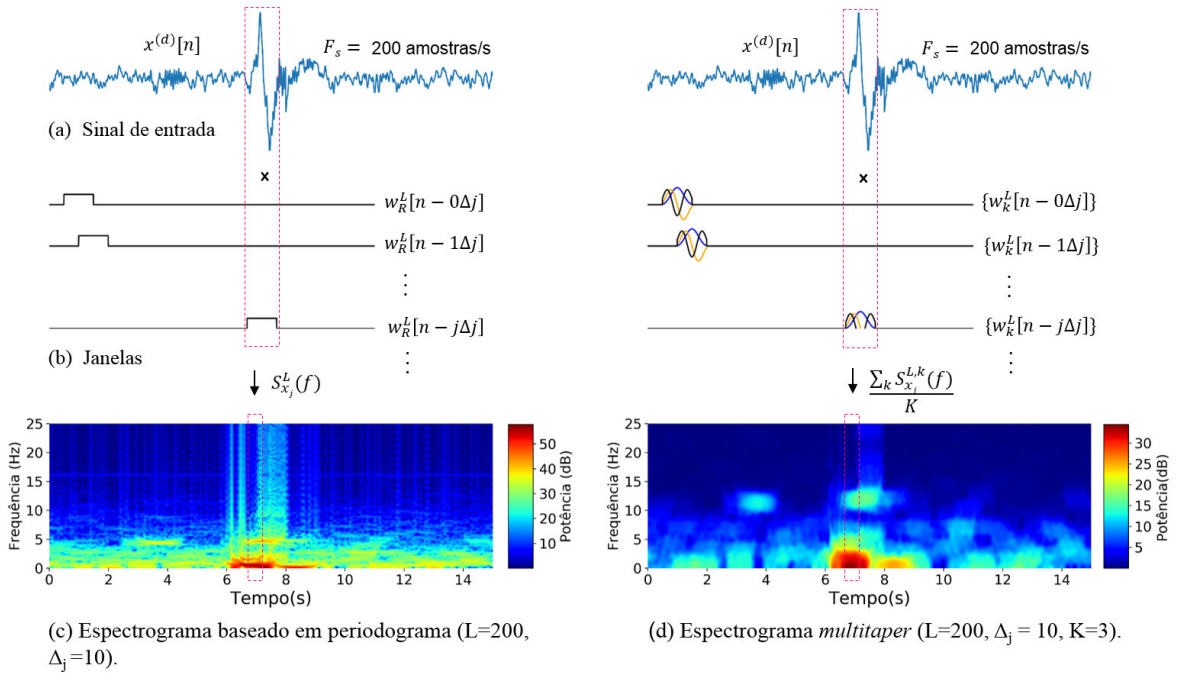


Figura 3.1: Comparação entre métodos de estimação espectral.

Os espectrogramas são exibidos como gráficos bidimensionais coloridos, onde o eixo-x representa o tempo, o eixo-y, a frequência, e as cores, a potência

(frequentemente na escala de dB, indo dos menores valores, representados pela cor azul, até os maiores valores, representados pela cor vermelha).

3.5 *Bias e variância*


O periodograma é considerado um estimador de espectro de potência impreciso [33, 36, 37]. Uma das razões é o fato de ser enviesado. Isso significa que $S_x^N(f)$ e $S_{x_j}^L(f)$ vão diferir significativamente do espectro de potência ideal a longo prazo a medida que N ou L fiquem menores. No caso dos espectrogramas baseados em periodograma, onde L deve ser o menor possível (em relação a N) para que as subsequências $x_j[n]$ possam ser consideradas estacionárias, isso torna-se um problema significativo.

A influência do *bias* pode ser visualizada na Figura 3.2. Na figura, considera-se um sinal x com 61560 pontos, gerado a partir de um processo autorregressivo de sexta ordem definido por

$$\begin{aligned} x_k = & 3.9515x_{k-1} - 7.8885x_{k-2} + 9.7340x_{k-3} \\ & - 7.7435x_{k-4} + 3.8078x_{k-5} - 0.9472x_{k-6} + v_k, \end{aligned} \quad (3.6)$$

onde v_k é *zero-mean independent* [36]. Foram então calculadas estimativas do espectro de potência utilizando diferentes tamanhos de L , com $L = 256$ e 3840 . Observando-se os resultados percebe-se que a diferença entre o espectro ideal $\phi_x(f)$ e a estimativa $S_x^L(f)$ aumenta a medida que o L diminui.

A segunda razão para a imprecisão do periodograma é a sua alta variância. Uma alta variância indica que a potência estimada vai ser incerta ao longo do eixo das frequências. Além disso, a alta variância indica que as potências do espectro variam muito em relação ao espectro de potência ideal. Na Figura 3.2 é possível visualizar o efeito da variância. Percebe-se que, ao contrário do *bias*, a variância diminui a medida que o tamanho L da janela aumenta. As limitações do *bias* e variância acarretam em espectrogramas com baixa resolução, sendo difícil determinar em qual faixa de frequência as concentrações de potência ocorrem.



(a) Sinal original




(b) Espectro potência ideal $\phi_x(f)$.(c) Estimativa de espectro potência, $S_x^L(f)$, utilizando janela retangular w_R^L , com $L = 256$.(d) Estimativa de espectro potência, $S_x^L(f)$, utilizando janela retangular w_R^L , com $L = 3840$.


Figura 3.2: Comparação entre estimativas de espectro de potência utilizando janelas retangulares.

3.6 Espectrograma *multitaper*


Para reduzir o problema do *bias* do periodograma, uma técnica básica é o uso de janelas não retangulares ou *tapers*. Um exemplo de *taper* é a janela Hann, que é uma curva em formato de sino definida por $w_H^L[n] = (1/2)(1 - \cos((2\pi n)/(L-1)))$, para $0 \leq n < L$, e $w_H^L[n] = 0$, caso contrário. Dado um *taper* específico $w_k^L[n]$, identificado pelo índice k , o periodograma da subsequência $x_j[n]$, correspondente à coluna j de um *espectrograma baseado em um único taper*, é calculado por

$$S_{x_j}^{L,k}(f) = \frac{1}{F_s} |\text{FT}_{w_k^L x_j}(f)|^2, \quad f \in [0, F_s] \text{ Hz}, \quad (3.7)$$

onde $w_k^L x_j[n] = w_k^L[n - j\Delta_j]x_j[n]$, e $\text{FT}_{w_k^L x_j}(f)$ é a transformada de Fourier $w_k^L x_j[n]$ obtida por (3.2).



(a) Estimativa de espectro potência $S_x^{L,k}(f)$ com $L = 256$, onde $w_k^L = w_H^L$ (janela de *Hann*).



(b) Estimativa de espectro potência $S_x^{L,k}(f)$ com $L = 256$ e $K = 3$, onde w_k^L pertence a uma classe funções denominada sequência discreta de prolate esférico (DPSS).

Figura 3.3: Comparação entre estimativas de espectro de potência utilizando janela de *Hann* e abordagem *multitaper*

Quando comparado com $S_{x_j}^L(f)$, é possível mostrar que o estimador $S_{x_j}^{L,k}(f)$ aproxima-se mais do espectro de potência a longo prazo, $\phi_{x_j}(f)$, da sequência $x_j[m]$,

mesmo com uma janela L pequena [36, 37]. Essa melhor aproximação é ilustrada na Figura 3.3(a). No entanto, o estimador $S_{x_j}^{L,k}(f)$ não resolve completamente o problema da variação do periodograma, conforme também ilustrado na Figura 3.3(a).

Em relação a esse problema, uma técnica que reduz tanto o *bias* quanto a variação do periodograma é o uso de múltiplos *tapers* [39], ilustrado na Figura 3.3(b). A partir da figura percebe-se que a estimativa do espectro de potência utilizando a abordagem *multitaper*, também com uma janela L pequena, assemelha-se ao espectro ideal ao passo que não possui alta variância. Sendo $\mathcal{W} = \{w_1^L, w_2^L, \dots, w_K^L\}$ o conjunto de K janelas *tapers*, todas com tamanho de tamanho L , o estimador espectral *multitaper* é definido por

$$S_{x_j}^{\mathcal{W}}(f) = \frac{\sum_{k=1}^K S_{x_j}^{L,k}(f)}{K}, \quad f \in [0, F_s] \text{ Hz.} \quad (3.8)$$

Assumindo que cada $x_j[n]$ seja uma subsequência de $x[n]$, de tamanho N , o conjunto $\text{SG}_x^{\mathcal{W}, \Delta_j} = (S_{x_0}^{\mathcal{W}}(f), S_{x_1}^{\mathcal{W}}(f), \dots, S_{x_{J-1}}^{\mathcal{W}}(f))$, com $J = \lceil N/\Delta_j \rceil$, forma o *espectrograma multitaper* de $x[n]$ (Figura 3.1(d)). Quando comparado com o espectrograma baseado em periodograma percebe-se que o espectrograma *multitaper* é menos ruidoso e mais preciso na caracterização das oscilações do sinal EEG.

3.7 Parâmetros do espectrograma *multitaper*

O conjunto \mathcal{W} de *tapers* vem de uma classe de funções chamada de *sequência discreta de prolatto esferoidal* (DPSS) [40]. O DPSS forma um conjunto de *tapers* ortonormais, $\mathcal{W} = \{w_1^L, w_2^L, \dots, w_K^L\}$, que não reduz apenas o *bias*, mas também produz estimativas não relacionadas *single-taper*, $S_{x_j}^{L,k}(f)$, a partir da mesma sequência de dados, $x_j[n]$, resultando em uma estimativa do espectro, $S_{x_j}^{\mathcal{W}}(f)$, com menor variação [36].

Para determinar a quantidade de *tapers*, K , alguns autores [33, 36] propõem um esquema baseado em dois parâmetros: tamanho do *taper*, L , e a resolução espectral do espectrograma, Δ_f . A resolução espectral (dada em Hz) representa a menor distância entre componentes de frequência que podem ser caracterizadas pelo espectrograma. Na prática, quando maior for o Δ_f , menos detalhada é a estimação espectral. A partir de L e Δ_f , é calculado o produto de meia largura de banda, TW , um valor necessário para a geração da DPSS. Este valor representa a relação entre o

tamanho da janela *taper* e a resolução espectral, dado por:

$$TW = \frac{L\Delta_f}{2F_s}. \quad (3.9)$$

Por fim, dado TW , o número de *tapers* K é obtido por:

$$K = \lfloor 2TW \rfloor - 1. \quad (3.10)$$

Além de \mathcal{W} , o cálculo do espectrograma depende de Δ_j . Conforme discutido no Seção 3.4, Δ_j determina a separação entre duas estimativas consecutivas, $S_{x_j}^{L,k}(f)$. Em comparação com Δ_f , os parâmetros Δ_j e L podem ser vistos como parâmetros que definem a resolução temporal do espectrograma (eixo-x).

4 Detector de KCs baseado em *Multitaper*

O Detector de KCs baseado em *Multitaper*, MT-KCD¹, é um método para identificação automática de KCs no sinal EEG. Tendo por base a análise espectral *multitaper*, ele recebe como entrada uma derivação EEG específica, $x^{(d)}[n]$, e produz como saída um conjunto de marcações, KC_{out} , onde cada marcação indica um intervalo de tempo do sinal original em que a ocorrência de KC foi detectada. Neste capítulo, inicialmente, é apresentando uma visão geral do método. Em seguida, são detalhadas cada fase do MT-KCD e é realizada a análise de complexidade do método.

4.1 Visão geral do MT-KCD

O MT-KCD é dividido em três fases: pré-processamento, extração de candidatos e eliminação de candidatos. Conforme representado na Figura 4.1, o método compreende seis etapas principais estratificadas nestas três fases: 1) filtragem do sinal de entrada, 2) cálculo do espectrograma *multitaper*, 3) identificação das regiões candidatas, 4) marcação dos KCs candidatos, 5) checagem de um candidato por região candidata, e 6) validação por amplitude e duração.

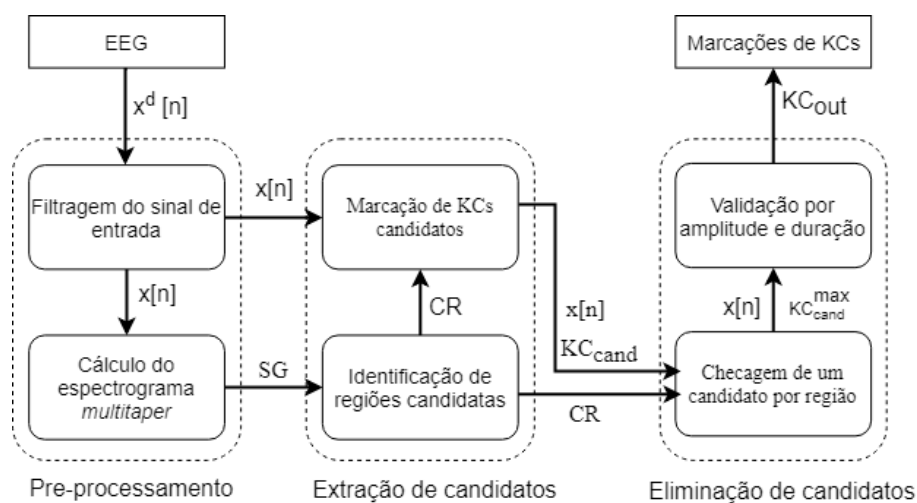


Figura 4.1: Fases e etapas do MT-KCD.

¹Multitaper-based KC detection

4.2 Pré-processamento

Inicialmente, o sinal EEG de entrada, $x^{(d)}[n]$, é filtrado por meio de um filtro de banda-passa de 0.3-35 Hz. Isso é realizado para reduzir o efeito de possíveis artefatos de baixa e alta potência, conforme recomendações da ASSM (*American Academy of Sleep Medicine*) [7].

O sinal EEG filtrado, denotado por $x[n]$, é usado para o cálculo do espectrograma *multitaper*, representado como uma matriz SG com J colunas e R linhas. O Algoritmo 1 especifica o procedimento. Em primeiro lugar, o conjunto de *tapers*, \mathcal{W} , é gerado (linhas 2-4); a função `dpss-windows(L, TW, K)`, na linha 4, realiza o cálculo das sequências discretas de prolato esferoidal, recebendo como entrada a quantidade K de *tapers*, o produto de meia largura de banda TW e o tamanho da janela L [41]. Em seguida, $x[n]$ é segmentado em subsequências sobrepostas, x_j , cada uma possuindo L pontos consecutivos de $x[n]$, iniciando em múltiplos de Δ_j (linha 9). Para cada x_j , a estimativa espectral *multitaper* correspondente é calculada e adicionada à SG como uma nova coluna (linhas 10-15). O cálculo reflete (3.7) e (3.8). A função `FFT($w_k^L * x_j, R$)`, na linha 12, em específico, representa a aplicação do algoritmo da transformada rápida de Fourier *radix-2 zero-padding* (implementação de (3.2)), sob a sequência obtida pela multiplicação ponto a ponto de $w_k^L[n]$ por $x_j[n]$, para $n = 0, 1, \dots, R - 1$. Neste caso, a faixa de frequências contínuas $f \in [0, F_s]$ Hz é reduzida para R valores discretos $\{f_r\}$, para $r = 0, 1, \dots, R - 1$. Dado r , a frequência correspondente é $f_r = r * (F_s/R)$ Hz. Por último, todos os valores de potência são convertidos para a escala de decibel (linha 17) e a matriz do espectrograma, SG, é retornada, junto com a quantidade de colunas, J , e de linhas, R (linha 18).

4.3 Extração de candidatos

A partir do sinal EEG filtrado, $x[n]$, e do espectrograma *multitaper*, SG, a próxima fase é a extração de candidatos. Em linhas gerais, é realizada a busca por concentrações de potência que ocorrem dentro da faixa de 0-4 Hz (ritmo *delta*) e que sobressaiam-se do *background* no domínio do tempo. De forma mais específica, a etapa de extração de candidatos é dividida em duas etapas: primeiro a identificação de regiões candidatas e, então, a marcação de KCs candidatos.

Algoritmo 1 Cálculo do espectrograma *multitaper*:

```

1: function CALCULAR-SG( $x, N, F_s; L, \Delta_j, \Delta_f$ )
2:    $TW \leftarrow (L * \Delta_f) / (2 * F_s)$  ▷ Eq. (3.9)
3:    $K \leftarrow \lfloor 2 * TW \rfloor - 1$  ▷ Eq. (3.10)
4:    $\mathcal{W} \leftarrow \text{dpss-windows}(L, TW, K)$ 
5:    $SG \leftarrow [[]]$ 
6:    $J \leftarrow \lceil N / \Delta_j \rceil$ 
7:    $R \leftarrow \min \{2^p \mid p \in \mathbb{N}, 2^p \geq L\}$ 
8:   for  $j = 0$  to  $J - 1$  do
9:      $x_j \leftarrow x[j * \Delta_j : j * \Delta_j + L - 1]$ 
10:     $S_{x_j}^{\mathcal{W}} \leftarrow []$ 
11:    for  $w_k^L \in \mathcal{W}$  do
12:       $S_{x_j}^{L,k} \leftarrow (1/F_s) * |\text{FFT}(w_k^L * x_j, R)|^2$  ▷ Eq. (3.7)
13:       $S_{x_j}^{\mathcal{W}} \leftarrow S_{x_j}^{\mathcal{W}} + S_{x_j}^{L,k} / K$  ▷ Eq. (3.8)
14:    end for
15:     $SG.append(S_{x_j}^{\mathcal{W}})$ 
16:  end for
17:   $SG \leftarrow 10 * \log_{10}(SG + 1)$  ▷ escala decibel (dB)
18:  return  $SG, J, R$ 
19: end function

```

4.3.1 Identificação de regiões candidatas

O conceito de concentração de potências dentro do ritmo *delta* é denotado a partir da soma dos valores de potência, $SG[j][r]$, de todas as frequências f_r abaixo de um dado limiar $f_{max} \leq 4$ Hz, para cada $j = 0, 1, \dots, J - 1$, formando a série temporal

$$C[j] = \sum_{f_r \leq f_{max}} SG[j][r], \quad (4.1)$$

onde $f_r = r * (F_s / R)$, para $r = 0, 1, \dots, R - 1$.

Em seguida, para caracterizar as concentrações de potências que se sobressaem do *background*, outras duas séries temporais são calculadas a partir de $C[j]$: nomeadas como, $C_{short}[j] = \text{CMA}_C^{I_{short}}[j]$ e $C_{backg}[j] = \text{CMA}_C^{I_{backg}}[j]$, onde $\text{CMA}_C^{I_*}[j]$ é a

média móvel central dos I_* -pontos obtida a partir de $C[j]$ por

$$\text{CMA}_C^{I_*}[j] = \frac{1}{I_*} \sum_{i=j-I_*/2}^{j+I_*/2-1} C[i]. \quad (4.2)$$

$C_{short}[j]$ e $C_{backg}[j]$ descrevem a concentração de potência sob uma quantidade fixa de pontos, I_{short} e I_{backg} respectivamente, com $I_{short} < I_{backg}$. $C_{backg}[j]$ representa a média da concentração de potência do *background* e $C_{short}[j]$ do curto prazo. Comparando $C_{short}[j]$ com $C_{backg}[j]$ é possível determinar regiões que se sobressaem do *background*. Esta comparação é realizada calculando

$$C_{diff}[j] = C_{short}[j] - C_{backg}[j]. \quad (4.3)$$

Os intervalos $j_1 \leq j \leq j_2$ onde a diferença entre as médias de concentração de potência do curto prazo e do *background*, $C_{diff}[j]$, é significativa, são selecionados como *regiões candidatas*. A diferença é considerada significativa quando é maior ou igual ao q -ésimo percentil de $C_{diff}[j]$. Para o cálculo do q -ésimo percentil, $C_{diff}[j]$ é colocada em ordem crescente e, então obtêm-se o valor do índice $\lfloor \frac{q}{100} J \rfloor$, onde J é a quantidade de colunas do espectrograma.

A etapa de identificação das regiões candidatas é resumida no Algoritmo 2 e ilustrada na Figura 4.2. Ela inicia com o cálculo do espectrograma *multitaper*, SG, do sinal EEG filtrado, $x[n]$, e termina como o conjunto de regiões candidatas, CR, consistindo em pares $(j_1, j_2), j_1 \leq j_2$. Cada par (j_1, j_2) representa um intervalo de tempo do espectrograma no qual a concentração de potência do ritmo *delta* se sobressai do *background*.

4.3.2 Marcação de KCs candidatos

Dentro de cada região candidata, ao menos uma ocorrência de KC é esperada. A próxima etapa é marcar tais ocorrências. A etapa de marcação de KCs candidatos recebe como entrada o sinal EEG filtrado, $x[n]$, e o conjunto de regiões candidatas, CR, produzindo como saída um conjunto de marcações candidatas de KCs, KC_{cand} . Um *KC candidato* é caracterizado como onda da região candidata onde a amplitude pico a pico se sobressai da amplitude do *background*. As *marcações* são pares $(n_1, n_2) \in \text{KC}_{cand}$ delimitando intervalos em $x[n]$ onde KCs possivelmente ocorrem.

Algoritmo 2 Identificação de regiões candidatas:

```

1: function IDENTIFICAR-CR(SG, J, R, Fs; fmax, Ishort, Ibackg, q)
2:   for j = 0 to J - 1 do
3:     C[j] ← ∑r*(Fs/R) ≤ fmax SG[j][r]           ▷ Eq. (4.1)
4:   end for
5:   for j = 0 to J - 1 do
6:     Cshort ← CMA(C, j, Ishort)           ▷ Eq. (4.2)
7:     Cbackg ← CMA(C, j, Ibackg)         ▷ Eq. (4.2)
8:     Cdiff[j] ← Cshort - Cbackg       ▷ Eq. (4.3)
9:   end for
10:  Cdifford ← order-ascending(Cdiff)
11:  qPerc ← Cdifford[[ (q/100) * J ]]
12:  CR ← { (j1, j2) | 0 ≤ j1 ≤ j2 ≤ J - 1 e
           Cdiff[j] ≥ qPerc for j1 ≤ j ≤ j2 e
           Cdiff[j] < qPerc for j = j1 - 1, j2 + 1 }
13:  return CR
14: end function

```

A caracterização do quão a amplitude pico a pico de uma onda se sobressai da amplitude do *background* é capturada da seguinte forma. Inicialmente, a *amplitude do background* é definida como a média móvel central $\bar{x}_{backg}[n] = \text{CMA}_x^{L_{backg}}[n]$, calculada por (4.2) substituindo por I_* por L_{backg} e C por x . Em seguida, duas bandas de amplitude média são definidas a partir de $\bar{x}_{backg}[n]$:

$$A_{inf}[n] = \bar{x}_{backg}[n] - \text{CMSD}_x^{L_{backg}}[n], \quad (4.4)$$

$$A_{sup}[n] = \bar{x}_{backg}[n] + \text{CMSD}_x^{L_{backg}}[n], \quad (4.5)$$

onde $\text{CMSD}_x^{L_*}[n]$ é o desvio padrão móvel central dos L_* -pontos calculado por

$$\text{CMSD}_x^{L_*}[n] = \sqrt{\frac{1}{L_*} \sum_{l=n-L_*/2}^{n+L_*/2-1} (x[l] - \text{CMA}_x^{L_*}[l])^2}. \quad (4.6)$$

$A_{inf}[n]$ e $A_{sup}[n]$ são as bandas de amplitude média acima e abaixo da amplitude do *background* $\bar{x}_{backg}[n]$, a uma distância de um desvio padrão variável no tempo $\text{CMSD}_x^{L_{backg}}[n]$. Assim, ondas que se sobressaem do *background* são aquelas em que

as amplitudes dos picos positivo e negativos estão abaixo e acima de $A_{inf}[n]$ e $A_{sup}[n]$, respectivamente. Quando ocorrem dentro dos limites da região candidata, tais ondas são marcadas como KCs candidatos.

Algoritmo 3 Marcação de KCs candidatos:

```


1: function MARCAR-KCcand( $x, N, CR; \Delta_j, L_{smth}, L_{backg}$ )
2:   for  $n = 0$  to  $N - 1$  do
3:      $\bar{x}_{smth}[n] \leftarrow \text{CMA}(x, n, L_{smth})$  ▷ Eq. (4.2)
4:      $\bar{x}_{backg}[n] \leftarrow \text{CMA}(x, n, L_{backg})$  ▷ Eq. (4.2)
5:      $\sigma_{backg} \leftarrow \text{CMSD}(x, n, L_{backg})$  ▷ Eq. (4.6)
6:      $A_{inf}[n] \leftarrow \bar{x}_{backg}[n] - \sigma_{backg}$  ▷ Eq. (4.4)
7:      $A_{sup}[n] \leftarrow \bar{x}_{backg}[n] + \sigma_{backg}$  ▷ Eq. (4.5)
8:   end for
9:    $WF \leftarrow \{(n_1, n_2) \mid$ 
       $0 \leq n_1 < n_2 \leq N - 1$  e
       $\bar{x}_{smth}[n] \succeq \bar{x}_{backg}[n]$  para  $n = n_1, n_2$  e
       $\bar{x}_{smth}[n] \not\prec \bar{x}_{backg}[n]$  para  $n_1 < n < n_2\}$ 
10:   $KC_{cand} \leftarrow \{(n_1, n_2) \in WF \mid$ 
       $\exists (j_1, j_2) \in CR \cdot j_1 \Delta_j \leq n_1 \leq j_2 \Delta_j$  e
       $\exists n_1 < n < n_2 \cdot \bar{x}_{smth}[n] \leq A_{inf}[n]$  e
       $\exists n_1 < n < n_2 \cdot \bar{x}_{smth}[n] \geq A_{sup}[n]\}$ 
11:  return  $KC_{cand}$ 
12: end function

```


Por sua vez, o conceito de onda dentro de uma região candidata é definido da seguinte forma. Sendo $\bar{x}_{smth}[n] = \text{CMA}_x^{L_{smth}}[n]$ uma versão suavizada de $x[n]$, calculada por (4.2) substituindo I_* por L_{smth} e C por x . Uma *onda* é então qualquer subsequência de $x[n]$ iniciando e finalizando em transições de amplitude $\bar{x}_{smth}[n]$ maior que $\bar{x}_{backg}[n]$ até uma amplitude $\bar{x}_{smth}[n+1]$ menor $\bar{x}_{backg}[n+1]$. Essas transições marcam o início e o término da onda caracterizada por um pico negativo (para cima) seguido de um pico positivo (para baixo) em relação à amplitude do *background* $\bar{x}_{backg}[n]$. Formalmente, o conjunto de ondas pode ser representado por $WF = \{(n_1, n_2)\}$ onde: (i) $0 \leq n_1 < n_2 \leq N - 1$; (ii) $\bar{x}_{smth}[n] \succeq \bar{x}_{backg}[n]$ para $n = n_1, n_2$; e (iii) $\bar{x}_{smth}[n] \not\prec \bar{x}_{backg}[n]$

for $n_1 < n < n_2$. A relação $\bar{x}_{smth}[n] \succeq \bar{x}_{backg}[n]$ significa que $\bar{x}_{smth}[n] \geq \bar{x}_{backg}[n]$ e $\bar{x}_{smth}[n+1] < \bar{x}_{backg}[n+1]$.






Por fim, o conjunto de *marcações de KCs candidatos* é o subconjunto $KC_{cand} \subseteq WF$ representando todas as ondas iniciando em uma região candidata e possuindo amplitudes abaixo e acima de $A_{inf}[n]$ e $A_{sup}[n]$, respectivamente. Formalmente, $(n_1, n_2) \in KC_{cand}$ se e somente se: (i) existir $(j_1, j_2) \in CR$ tal que $j_1\Delta_j \leq n_1 \leq j_2\Delta_j$, (ii) existir $n_1 < n < n_2$ tal que $\bar{x}_{smth}[n] \leq A_{inf}[n]$, e (iii) existir $n_1 < n < n_2$ tal que $\bar{x}_{smth}[n] \geq A_{sup}[n]$.





(a) Sinal filtrado (0, 3 – 35 Hz).




(a) Sinal filtrado (0, 3 – 35 Hz).

(b) Espectrograma multitaper ($L = 200$, $\Delta_j = 10$, $\Delta_f = 4$).(b) \bar{x}_{smth} e bandas A_{inf} , A_{sup} ($L_{smth} = 30$, $L_{backg} = 1000$).(c) Médias móveis ($I_{short} = 10$, $I_{backg} = 100$).(c) Intervalo de \bar{x}_{smth} correspondente a cr_1 .

(d) Diferença das médias e 95-ésimo percentil.

(d) Intervalo de \bar{x}_{smth} correspondente a cr_3 .

(e) Regiões candidatas identificadas.



(e) KCs candidatos marcados.

Figura 4.2: Identificação de regiões candidatas no sinal filtrado.

Figura 4.3: Marcação de KCs candidatos no sinal filtrado.

A etapa de marcação de KCs candidatas é especificada como um todo na Algoritmo 3 e ilustrada na Figura 4.3. A Figura 4.3(a) repete as regiões candidatas da Figura 4.2(e), aqui nomeadas como cr_1, cr_2, cr_3, cr_4 , por conveniência. A Figura 4.3(b) ilustra a média móvel, $\bar{x}_{smth}[n]$, e as bandas de amplitude média, $A_{inf}[n]$ e $A_{sup}[n]$, calculadas a partir de $x[n]$. Na Figura 4.3(c) e Figura 4.3(d), os segmentos de \bar{x}_{smth} correspondente às regiões cr_1 e cr_3 são amplificados. Na região candidata cr_1 (Figura 4.3(c)), nenhuma onda ultrapassa as bandas $A_{inf}[n]$ e $A_{sup}[n]$, logo nenhum KC candidato é marcado. É possível visualizar que uma onda ultrapassa as bandas próximo à região cr_1 . Entretanto, ela inicia após o término da região candidata cr_1 . Na região candidata cr_3 (Figura 4.3(d)), uma onda possui amplitudes menores que $A_{inf}[n]$ e outras maiores que $A_{sup}[n]$, logo é marcada como um KC candidato. Na Figura 4.3(e), o conjunto KC_{cand} retornado, sendo formado por três marcações, cr_2, cr_3 e cr_4 , é exibido sobre o sinal filtrado $x[n]$.

4.4 Eliminação de candidatos

Na última fase, alguns candidatos marcados em KC_{cand} são rejeitados e alguns são aceitos como instâncias verdadeiras de KC. As marcações aceitas compõem a saída final do método, KC_{out} . A eliminação de candidatos é dividida em duas etapas: a primeira, checagem de um candidato por região, e depois a validação de amplitude e duração.

4.4.1 Checagem de um candidato por região

Alguns trabalhos classificam o KC como um tipo de onda lenta [8], um ‘precursor’ de ondas *delta* [10]. Nesse sentido, KCs tendem a ocorrer isoladamente. Por esta razão, se mais de um KC candidato ocorrer dentro de uma região candidata, após esta etapa, apenas um é mantido, descartando os demais.

Para escolher qual KC deve ser mantido, segue-se a seguinte estratégia. Inicialmente, o conjunto KC_{cand} é particionado em classes equivalentes $KC_{cand}^{j_1, j_2}$, cada classe correspondendo a uma região candidata $(j_1, j_2) \in CR$. Em seguida, as amplitudes pico a pico de todos os KCs candidatos são calculadas. Por fim, para cada classe equivalente $KC_{cand}^{j_1, j_2}$, as marcações (n_1, n_2) correspondentes aos KCs candidatos

com maior amplitude pico a pico são mantidas. A saída desta etapa forma o conjunto KC_{cand}^{max} .

De forma mais precisa, $KC_{cand}^{j_1, j_2}$ é definido por:

$$KC_{cand}^{j_1, j_2} = \{(n_1, n_2) \in KC_{cand} \mid j_1 \Delta_j \leq n_1 \leq j_2 \Delta_j\} \quad (4.7)$$

A amplitude pico a pico de um KC candidato é representada por (n_1, n_2) e calculado por:

$$ppA_x(n_1, n_2) = \max(x[n_1 : n_2]) - \min(x[n_1 : n_2]), \quad (4.8)$$

onde $x[n_1 : n_2]$ denota a subsequência de $x[n]$ iniciando em n_1 e terminando em n_2 .

Para todos $(n_1, n_2) \in KC_{cand}^{j_1, j_2}$ o conjunto de amplitudes pico a pico é dado por:

$$ppA_x(KC_{cand}^{j_1, j_2}) = \{ppA_x(n_1, n_2) \mid (n_1, n_2) \in KC_{cand}^{j_1, j_2}\}. \quad (4.9)$$

Por fim, o conjunto KC_{cand}^{max} é definido por:

$$KC_{cand}^{max} = \{(n_1, n_2) \in KC_{cand}^{j_1, j_2} \mid (j_1, j_2) \in CR \text{ and } ppA_x(n_1, n_2) = \max(ppA_x(KC_{cand}^{j_1, j_2}))\} \quad (4.10)$$

4.4.2 Validação de amplitude e duração

Sabendo que o KC é um tipo de onda lenta, é esperado que possua amplitude e duração similar às oscilações *delta*. Posto isso, o objetivo desta última etapa é eliminar as ondas que não apresentem amplitude e duração características das ondas *delta*. Em relação à amplitude, ou mais especificamente, à amplitude pico a pico, esta deve ser superior ou igual a um valor mínimo, normalmente $75\mu V$ [7]. Em relação à duração, alguns trabalhos, tais como [7, 22], adotam 2 segundos como a duração máxima esperada.

De forma geral, considerando a amplitude pico a pico mínima, A_{min} , e a duração máxima, D_{max} (em pontos), a saída desta etapa e, conseqüentemente, da fase de eliminação de candidatos é definida como:

$$KC_{out} = \{(n_1, n_2) \in KC_{cand}^{max} \mid ppA_x(n_1, n_2) \geq A_{min} \text{ e } n_2 - n_1 < D_{max}\}. \quad (4.11)$$

O Algoritmo 4 especifica a fase de eliminação de candidatos. A Figura 4.4, também apresenta uma visão geral do método proposto, ilustrando o efeito da fase

de eliminação de candidatos em sua última linha. O KC candidato por volta dos 940s não possui uma amplitude pico a pico significativa, logo este é eliminado. Entre 960s e 980s, dois KC candidatos são marcados dentro de uma mesma região candidata. Nesse caso, a etapa de checagem de um candidato por região elimina o candidato com a menor amplitude pico a pico (o primeiro).

Algoritmo 4 Eliminação de candidatos:

- 1: **function** ELIMINAR-KC_{cand}(x , CR, KC_{cand}; A_{min} , D_{max})
 - 2: $KC_{cand}^{max} \leftarrow \{(n_1, n_2) \in KC_{cand}^{j_1, j_2} \mid$
 $(j_1, j_2) \in CR \text{ e } ppA_x(n_1, n_2) = \max(ppA_x(KC_{cand}^{j_1, j_2}))\} \triangleright$
 (4.10)
 - 3: $KC_{out} \leftarrow \{(n_1, n_2) \in KC_{cand}^{max} \mid$
 $ppA_x(n_1, n_2) \geq A_{min} \text{ and } n_2 - n_1 < D_{max}\} \triangleright \text{Eq. (4.11)}$
 - 4: **return** KC_{out}
 - 5: **end function**
-

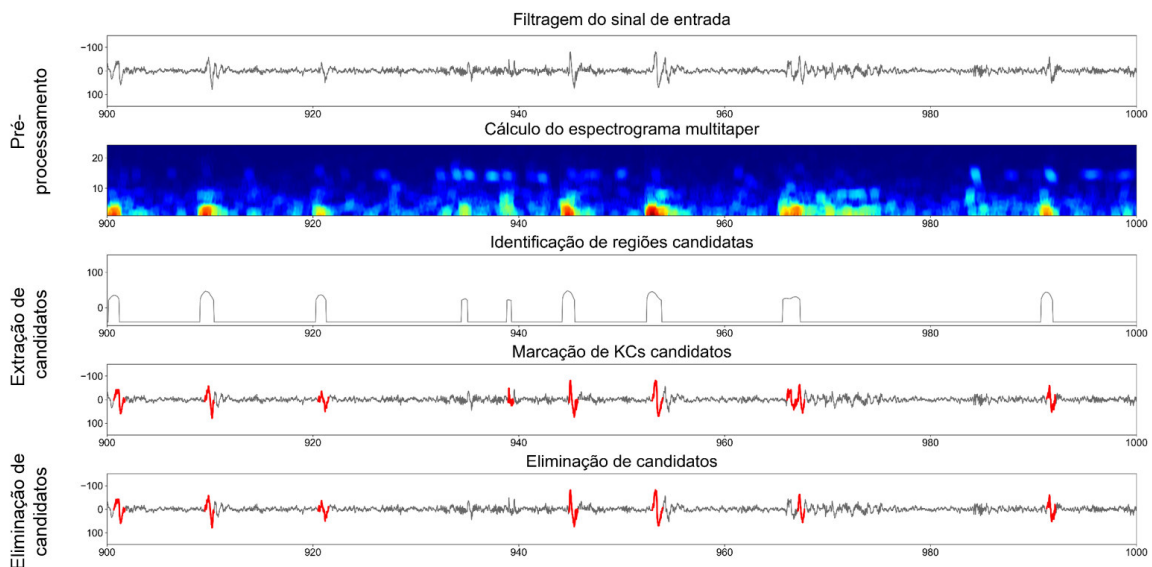


Figura 4.4: Fases e principais etapas do MT-KCD.

4.5 Análise de complexidade

A complexidade do MT-KCD pode ser dada em função da complexidade dos quatro principais algoritmos do método (Algoritmos 1 até 4).

O Algoritmo 1 é o calcular-SG($x, N, F_s; L, \Delta_j, \Delta_f$). A complexidade deste algoritmo é dada, sobretudo, em função da quantidade de colunas $J = \lceil N/\Delta_j \rceil$ do espectrograma e da quantidade de *tapers* K . Para cada coluna, realiza-se a convolução entre um segmento de tamanho L e um *taper* w_k^L e aplica-se a transformada de Fourier sob o sinal convalido (linhas 8-14). Considerando que o algoritmo de transformada rápida de Fourier (FFT) possui um custo computacional $\mathcal{O}(L \log L)$ [38], onde L é tamanho do segmento, tem-se que a complexidade pode ser representada por $\mathcal{O}(\lceil N/\Delta_j \rceil \cdot K \cdot (L \cdot \log L))$. Considerando que L, K e Δ_j são constantes e bem menores que a quantidade de pontos N do sinal de entrada, a complexidade pode ser simplificada por $\mathcal{O}(N)$.

O Algoritmo 2, identificar-CR(SG, $J, R, F_s; f_{max}, I_{short}, I_{backg}, q$), tem sua complexidade dada, principalmente, em função de $J = \lceil N/\Delta_j \rceil$. Primeiro, é gerada uma série temporal $C[j]$ para representar a concentração de potência dentro de uma determinada faixa de frequência. Para isso, os valores de potência $SG[j][r]$ de cada coluna do espectrograma abaixo de um dado limiar f_{max} são somados. No pior caso, tem-se a soma de todas as linhas R do espectrograma, levando a uma complexidade $\mathcal{O}(J \cdot R)$. Em seguida, são calculadas três séries temporais, $C_{short}, C_{backg}, C_{diff}$, a partir de $C[j]$. A complexidade desse processo (linhas 5-9) é dada por $\mathcal{O}(J \cdot (I_{short} + I_{backg}))$, onde I_{short} e I_{backg} representam o tamanho das janelas utilizadas para computar as séries C_{short}, C_{backg} , respectivamente. Após isso, ordena-se a série C_{diff} para que seja possível obter o q -ésimo percentil (linhas 10-11), resultando em uma complexidade, no pior caso, $\mathcal{O}(J \cdot \log(J))$. Por fim, identifica-se o conjunto de regiões candidatas a partir da iteração sobre a série C_{diff} , possuindo assim uma complexidade $\mathcal{O}(J)$. Posto isso, a complexidade geral deste algoritmo é $\mathcal{O}(J \cdot R + J \cdot (I_{short} + I_{backg}) + J \cdot \log(J) + J)$. Simplificando e colocando J em função de N , tem-se $\mathcal{O}(\lceil N/\Delta_j \rceil \cdot (R + (I_{short} + I_{backg}) + \log(\lceil N/\Delta_j \rceil) + 1))$. Assumindo que R, I_{short}, I_{backg} , e Δ_j são constantes e consideravelmente inferiores a N , a complexidade do algoritmo pode ser definida por $\mathcal{O}(N \cdot \log N)$.

O Algoritmo 3 é o marcar-KC_{cand}($x, N, CR; \Delta_j, L_{smth}, L_{backg}$). A complexidade é dada em função de N e CR . Inicialmente o algoritmo computa duas séries, $\bar{x}_{smth}, \bar{x}_{backg}$, calculadas a partir de $x[n]$. A partir de $\bar{x}_{smth}, \bar{x}_{backg}$, calcula-se duas bandas de amplitude, $A_{inf}[n]$ e $A_{sup}[n]$. A complexidade deste processo (linhas 2-8) é dada por $\mathcal{O}(N \cdot (L_{smth} + 2 \cdot L_{backg}))$, onde L_{smth} e L_{backg} representam o tamanho

das janelas utilizadas para calcular $\bar{x}_{smth}, \bar{x}_{backg}$, respectivamente. Após isso, itera-se todo sinal x afim de identificar um conjunto WF de ondas candidatas (linha 9). Por fim, é verificado se as ondas pertencentes ao conjunto WF inciam dentro uma região candidata $(j_1, j_2) \in CR$ e estão dentro das bandas de amplitude $A_{inf}[n]$ e $A_{sup}[n]$ (linha 10). Para implementar este processo, itera-se pelo conjunto de regiões candidatas. Para cada região candidata, marca-se ondas com formato de KC e verifica-se quais delas estão dentro das bandas de amplitude $A_{inf}[n]$ e $A_{sup}[n]$. No pior caso, a quantidade de regiões candidatas é igual a quantidade de pontos N , logo, a complexidade do processo de marcação de ondas candidatas é dada por $\mathcal{O}(N)$. Assim, a complexidade computacional do Algoritmo 3 é $\mathcal{O}(N \cdot (L_{smth} + 2 \cdot L_{backg}) + 2N)$, sendo simplificada por $\mathcal{O}(N)$.

O Algoritmo 4 é o eliminar-KC_{cand}($x, CR, KC_{cand}; A_{min}, D_{max}$). Nesta etapa, é verificado se cada elemento do conjunto KC_{cand} satisfaz um conjunto de restrições (linhas 2-3). No pior caso, a complexidade do algoritmo é $\mathcal{O}(N)$.

Uma vez realizada a análise de complexidade de todos os algoritmos que compõem o MT-KCD, tem-se que a complexidade geral do método pode ser representada por $\mathcal{O}((N) + (N \cdot \log N) + (N) + (N))$. Isto pode ser simplificado por $\mathcal{O}(N \cdot \log N)$.

5 Avaliação Experimental

Neste capítulo é apresentado o método utilizado para avaliação do MT-KCD. Inicialmente são descritos a base de dados de KCs assim como os cenários utilizados para realização dos experimentos. Em seguida, apresenta-se quais métricas são utilizadas para mensurar a eficácia do MT-KCD. Por fim, são discutidos os valores dos parâmetros do MT-KCD utilizados durante a bateria de experimentos.

5.1 DREAMS

Alguns trabalhos avaliam seus métodos de detecção de KCs usando base de dados privadas [24–26], tornando difícil a comparação com outros métodos. Uma alternativa para facilitar a comparação entre os métodos existentes de detecção de KCs é a base de dados DREAMS¹, uma base de dados de KCs comumente utilizada para ajustar e testar algoritmos de detecção automática [18–23]. Esta base de dados consiste em dez registros de polissonografia de pacientes saudáveis parcialmente anotado por dois especialistas. As anotações existentes correspondem a 30 minutos de um canal EEG para cada paciente (derivação CZ-A1, taxa de amostragem de $F_s = 200$). Além disso, apenas os canais EEG dos cinco primeiros pacientes são anotados pelo dois especialistas. Cada anotação apresenta o início e duração de uma ocorrência de KC. Dada a disponibilidade e o grande uso do DREAMS, ele foi escolhido como base de dados para avaliar o MT-KCD.

5.2 Cenários

Dado que apenas cinco dos dez pacientes da base de dados DREAMS tem o seu EEG anotado pelos dois especialistas, sendo os outros cinco anotados por apenas um, a maioria dos trabalhos que utilizam essa base de dados considera apenas as anotações relativas aos pacientes cujo EEG é anotado pelos dois especialistas. Dessa

¹<http://www.tcts.fpms.ac.be/~devuyst/Databases/DatabaseKcomplexes/>

forma, três diferentes cenários de avaliação podem ser identificados para realização dos experimentos. O primeiro consiste em realizar os experimentos utilizando a união das anotações dos dois especialistas para os cinco primeiros pacientes. Esse cenário é adotado por [20,22,23]. O segundo cenário de avaliação considera apenas as anotações realizadas pelo primeiro especialista para os cinco primeiros pacientes, sendo utilizado por [18, 19, 23]. Já o terceiro cenário considera apenas as anotações realizadas pelo segundo especialista, sendo utilizado em [18,23].

A escolha do cenário de avaliação a ser utilizado durante os experimentos influencia diretamente nos resultados. Isso acontece, sobretudo, devido a baixa concordância entre os especialistas. A Tabela 5.1 exibe a quantidade de anotações realizadas pelos especialistas para os cinco primeiros pacientes do DREAMS. A partir dos dados exibidos na tabela, percebe-se que a quantidade de anotações do primeiro especialista é aproximadamente três vezes maior que a quantidade de anotações do segundo especialista. Além disso, é possível visualizar que a concordância entre os especialistas (anotações em comum dividido por todas as anotações dos dois especialistas) é baixa, por volta de 16%.

Paciente	Especialista 01	Especialista 02	Concordância (%)
01	34	19	15,09
02	45	8	15,09
03	12	3	20,00
04	78	14	10,86
05	39	20	22,03
Média	41,60	12,80	16,61

Tabela 5.1: Anotações dos especialista na base de dados DREAMS.

5.3 Métricas

Quatro métricas de avaliação foram utilizadas para avaliar o MT-KCD: *recall* (taxa de verdadeiro positivo, *tpr*), *precisão* (valor de predição verdadeira, *ppv*), *F1 score* and *F2 score*. Tais métricas são calculadas a partir da quantidade de verdadeiros positivos, (*tp*), falso negativos (*fn*) e falso positivos (*fp*), conforme (5.1) até (5.4). Uma

marcação de KC é considerada um verdadeiro positivo se existir ao menos um ponto de interseção entre a marcação e as anotações do especialista.

$$tpr = \frac{tp}{tp + fn} \quad (5.1) \quad ppv = \frac{tp}{tp + fp} \quad (5.2)$$

$$F1 = 2 \cdot \frac{ppv \cdot tpr}{ppv + tpr} \quad (5.3) \quad F2 = 5 \cdot \frac{ppv \cdot tpr}{4 \cdot ppv + tpr} \quad (5.4)$$

5.4 Parâmetros

Em resumo, as principais etapas do MT-KCD são especificadas a partir de quatro algoritmos:

- calcular-SG($x, N, F_s; L, \Delta_j, \Delta_f$),
- identificar-CR(SG, $J, R, F_s; f_{max}, I_{short}, I_{backg}, q$),
- marcar-KC_{cand}($x, N, CR; \Delta_j, L_{smth}, L_{backg}$),
- eliminar-KC_{cand}($x, CR, KC_{cand}; A_{min}, D_{max}$).

As variáveis antes do ponto e vírgula representam os valores de entrada (o sinal EEG filtrado ou a saída da etapa anterior). As variáveis após o ponto e vírgula representam os parâmetros. Estes dependem, em parte das características do KC, em parte de alguns resultados da teoria e prática do espectrograma *multitaper* aplicado para a visualização do sinal EEG [33,36], e em parte de ajustes experimentais. A Tabela 5.2 resume os valores dos parâmetros utilizados durante a bateria de experimentos.

Os valores dos parâmetros de calcular-SG(\cdot) — $L = 200, \Delta_j = 10$, e $\Delta_f = 4$ — seguem as configurações sugeridas em [33] para a visualização de microestruturas do sinal EEG, com uma diferença. Aqui o valor de L utilizado é igual a $1F_s$ (1s), ao invés de $2,5F_s$ (2,5s), conforme sugerido em [33]. Essa alteração tem a ver com a necessidade de localizar de forma mais precisa possível as ocorrências de KC no eixo do tempo. Com um $L = 2,5F_s$, eventos oscilatórios são antecipados no eixo do tempo no espectrograma, causando defasagens consideráveis entre as estimativas de potência e os segmentos EEG correspondentes. Essas defasagens interferem na

Parâmetro	Valor	Valor relativo	Significado
L	200	$1F_s$	1s
Δ_j	10	$0,05F_s$	0,05s
Δ_f	4	—	4 Hz
f_{max}	3	—	3 Hz
I_{short}	10	$0,5F_s/\Delta_j$	0,5s
I_{backg}	100	$10I_{short}$	5s
q	95	—	Perc. <i>ranking</i> 95
L_{smth}	30	$0,15F_s$	0,15s
L_{backg}	1000	$\Delta_j I_{backg}$	5s
A_{min}	75	—	$75 \mu V$
D_{max}	400	$2F_s$	2s

Tabela 5.2: Valores de parâmetros do MT-KCD ($F_s = 200$).

correta identificação e marcação das regiões candidatas. Com um $L = 1F_s$, esse problema é minimizado mas não é completamente eliminado, conforme visto na Figura 4.3(a). Neste exemplo, a região candidata cr_1 é identificada 0,5s antes da região correspondente (a onda por volta dos 935s na Figura 4.3(b)), resultando em um KC candidato não marcado. Para L menor que $1F_s$, o tamanho e o número de *tapers* passa a ser muito pequeno, tendendo a um espectrograma com um único *taper*, com alto *bias* e *variança*. Utilizando um $L = 1F_s$ e resolução espectral $\Delta_f = 4$ Hz, o número de *tapers* correspondente é $K = 3$ (ver (3.10)).

Os valores dos parâmetros do algoritmo identificar-CR(\cdot) — $f_{max} = 3$, $I_{short} = 10$, $I_{backg} = 100$ e $q = 95$ — são baseados em resultados teóricos e práticos, conforme descrito a seguir. De acordo com [33, p.81], KCs “podem ser facilmente distinguidos de artefatos de movimento, com atenuação em 2-3Hz da potência espectral e menor duração.” Esse fato indica para o uso de um limiar de concentração de potência $f_{max} = 3$ Hz. Em relação ao $I_{short} = 10$ e $I_{backg} = 100$ (a quantidade de pontos do espectrograma utilizado para calcular as concentrações médias de curto prazo e do *background*, $C_{short}[j]$ e $C_{back}[j]$ respectivamente), eles seguem a seguinte relação: $I_{back} = 10I_{short}$. Assume-se, portanto, que a extensão do *background* deve ser necessariamente maior do que a extensão do curto prazo durante o processo de

cálculo da média e da comparação entre as concentrações de potência. Dessa forma, o valor $I_{short} = 10$ é escolhido baseado na duração mínima de 0,5s esperada para KC [7]. Por um lado, essa configuração aumenta a diferença $C_{short}[j] - C_{backg}[j]$ para ondas KC, contribuindo para a correta identificação das regiões candidatas. Esse aumento é obtido porque, sendo I_{short} a duração mínima do KC, nenhuma $C_{short}[j]$ é esperado capturar um KC completo com *background* formado por oscilações, o que reduziria $C_{short}[j]$ comparado ao $C_{backg}[j]$. Por outro lado, a influência sobre $C_{short}[j]$ de eventos de não KC de curta duração ($< 0,5s$) e alta amplitude, tais como *ondas agudas do vértice* [7]) é minimizada com I_{short} igual a 0,5s. O motivo é similar: espera-se que $C_{short}[j]$ capture sempre eventos $< 0.5s$ cercados por um *background* oscilante. Consequentemente, a diferença $C_{short}[j] - C_{backg}[j]$ diminui, contribuindo para evitar a identificação de regiões candidatas falsas. Por fim, o parâmetro do *ranking* do percentil, $q = 95$, foi escolhido experimentalmente, fixando os demais parâmetros.

Os parâmetros de $\text{marcar-KC}_{\text{cand}}(\cdot) - \Delta_j = 10, L_{smth} = 30$ e $L_{backg} = 1000$ — refletem as configurações anteriores. A quantidade de tempo por coluna do espectrograma, $\Delta_j = 10$, é obtido a partir das configurações utilizadas no cálculo do espectrograma. A quantidade de segundos utilizada no cálculo da amplitude do *background*, $L_{backg} = 1000$, é igual a I_{backg} pela relação $L_{backg} = \Delta_j I_{backg}$. A razão disto é que L_{backg} e I_{backg} desempenham funções similares em diferentes contextos: ambos os parâmetros representam a extensão do *background* em relação às variações de curto prazo a serem comparadas (concentração de potência no caso de I_{backg} , e amplitude para amplitude L_{backg}). A janela de suavização, $L_{smth} = 30$, por outro lado, não segue a mesma relação do I_{short} , pois apresenta um propósito diferente, apesar do aparente paralelismo. L_{smth} controla o grau de suavização aplicado ao sinal de entrada, com o intuito de eliminar ruídos que dificultam definir o início e término de uma onda dentro da região candidata. Assim como o parâmetro q da etapa anterior, L_{smth} foi setado experimentalmente, fixando os demais parâmetros.

Os parâmetros de $\text{eliminar-KC}_{\text{cand}}(\cdot) - A_{min} = 75$ e $D_{max} = 400$ — são baseados nos valores de referência encontrados na literatura: a amplitude mínima pico a pico, $75\mu V$, e a duração mínima esperada, $2s$, para ondas lentas [7].

6 Resultados da avaliação

Neste capítulo são apresentados e discutidos os resultados dos experimentos empíricos realizados a partir da base de dados, cenários, métricas e parâmetros descritos no capítulo anterior.

6.1 Implementação

O MT-KCD foi implementado em Python 3.6. A biblioteca NiTime (<http://nipy.org/nitime/>) foi utilizada para gerar o conjunto de *tapers* DPSS, elemento indispensável para o cálculo do espectrograma *multitaper*.

6.2 Cenário 1: cinco pacientes, anotações dos dois especialistas

No primeiro cenário de avaliação, foi considerado o sinal EEG dos cinco primeiros pacientes da base de dados DREAMS, e a união das anotações dos dois especialistas. Neste cenário, utilizando os parâmetros especificados na Tabela 5.2, o MT-KCD alcançou um *recall* médio de $81,34 \pm 8,23\%$, precisão média de $71,88 \pm 6,92\%$, F1 e F2 médio de $76 \pm 5,43\%$ e $79,02 \pm 6,50\%$, respectivamente. Esses valores detalhados por paciente são exibidos na Tabela 6.1.

Um alto valor de *recall* indica que o MT-KCD consegue identificar a maioria das instâncias de KC verdadeiros de acordo com as anotações dos especialistas. O alto *recall* alcançado é ilustrado na Figura 6.1, onde as marcações realizadas pelo MT-KCD são comparadas com as anotações realizadas pelos especialistas. Na Figuras 6.1(a) até 6.1(d), o método identifica corretamente quase todas as instâncias de KC anotadas pelos especialistas. A única anotação não marcada é a instância que ocorre entre 620-630s na Figura 6.1(c). Nesse intervalo, nenhuma região candidata é identificada, dado que a potência do sinal não se destaca significativamente do *background* (Algoritmo 2). Nas

Figuras 6.1(e) e 6.1(f), três das cinco instâncias de KCs anotadas pelos especialistas não são marcadas pelo MT-KCD. Duas delas, nos intervalos 110-120s e 200-210s, foram ignoradas porque ocorrem ligeiramente fora das regiões candidatas identificadas pelo método para os respectivos intervalos (Algoritmo 3). A terceira anotação, no intervalo 160-170s, foi identificada como um KC candidato, entretanto foi rejeitada pelo filtro de amplitude pico a pico (Algoritmo 4).

A precisão média por volta dos 70% alcançada indica que o MT-KCD marca algumas instâncias de KC não anotadas pelos especialistas, obtendo uma taxa de falsa descoberta de $\sim 30\%$. Nas Figuras 6.1(c) até 6.1(f) é possível visualizar exemplos de falsos positivos, os quais impactam diretamente no cálculo da precisão. Embora sejam falsos positivos, alguns destes apresentem características de KC e visualmente são similares a outras anotações realizadas pelos especialistas. Por exemplo, a instância marcada pelo método entre 560-570s na Figura 6.1(c), e não anotada pelos especialistas, é similar tanto em formato quanto em *background* à instância anotada pelos especialistas no intervalo 180-190s na Figura 6.1(f). O mesmo ocorre com: o falso positivo na Figura 6.1(d) entre 290-300s, que é comparável às anotações dos especialistas no intervalo entre 310-320 da mesma figura e no intervalo 540-550s da Figura 6.1(c); e o falso positivo na Figura 6.1(e) entre 140-150s, o qual se assemelha à anotação entre o intervalo 550-560s na Figura 6.1(c).

O falso positivo entre 110-120s na Figura 6.1(e) ocorre exatamente após uma anotação dos especialistas. Devido à proximidade com uma anotação, essa marcação pode não ser considerada como completamente errada. Os demais falsos positivos, localizados entre 330-340s na Figura 6.1(d), 120-130s na Figura 6.1(e) e 210-250s na Figura 6.1(f), ocorrem em um contexto de *background* de potência média. Nessa circunstância, observa-se que o método proposto tende a marcar as ondas que apresentem o formato de KC. Os especialistas, por outro lado, em algumas ocasiões anotam (200-210s na Figura 6.1(f)), em outras não (240-250s na Figura 6.1(f)).

As métricas F1 e F2 são médias harmônicas de precisão e *recall*. Valores altos de F1 e F2 indicam que o método apresenta uma boa relação entre os valores *recall* e precisão.

Paciente	<i>Recall (tpr)</i>	Precisão (<i>ppv</i>)	F1	F2
01	68,89	62,00	65,26	67,39
02	84,44	71,70	77,55	81,55
03	83,33	76,92	80,00	81,97
04	76,54	81,58	78,98	77,50
05	93,48	67,19	78,18	86,69
Média	81,34	71,88	76,00	79,02
Desv. Pad.	08,23	06,92	05,43	06,50

Tabela 6.1: Resultados do cenário 1 (%).

Paciente	<i>Recall (tpr)</i>	Precisão (<i>ppv</i>)	F1	F2
01	82,35	56,00	66,67	75,27
02	84,44	71,70	77,55	81,55
03	83,33	76,92	80,00	81,97
04	80,52	81,58	81,05	80,73
05	94,87	57,81	71,84	84,09
Média	85,10	68,80	75,42	80,72
Desv. Pad.	05,05	10,22	05,41	02,94

Tabela 6.2: Resultados do cenário 2 (%).

Paciente	<i>Recall (tpr)</i>	Precisão (<i>ppv</i>)	F1	F2
01	57,89	22,00	31,88	43,65
02	100,00	15,09	26,23	47,06
03	66,67	15,38	25,00	40,00
04	71,43	13,16	22,22	37,88
05	90,00	28,12	42,86	62,50
Média	77,20	18,75	29,64	46,22
Desv. Pad.	15,50	05,56	07,32	08,72

Tabela 6.3: Resultados do cenário 3 (%).


6.3 Cenário 2: cinco pacientes, anotações do primeiro especialista

O segundo cenário de avaliação considera o sinal EEG dos cinco primeiros pacientes da base DREAMS, levando em consideração as anotações do primeiro especialista apenas. Os experimentos foram realizados fazendo uso dos valores de parâmetros descritos na Tabela 5.2. Conforme visto na Tabela 6.2, os resultados alcançados são similares aos obtidos no primeiro cenário. Comparado ao cenário anterior, o *recall* médio é maior, atingindo $85,10 \pm 5,05\%$, e a precisão média é ligeiramente menor, atingindo $68,80 \pm 10,22\%$. Em relação à F1 e F2, os valores alcançados foram $75,43 \pm 5,41\%$ e $80,72 \pm 2,94\%$, respectivamente.


6.4 Cenário 3: cinco pacientes, anotações do segundo especialista

Em complemento, o terceiro cenário de avaliação considera apenas as anotações do segundo especialista, para os primeiros cinco pacientes, novamente fazendo uso dos valores de parâmetros descritos na Tabela 5.2. Comparado aos cenários 01 e 02, o *recall* médio diminui um pouco, passando de $81,34\%$ e $85,1\%$ para $77,2 \pm 15,50\%$, enquanto a precisão média diminui consideravelmente, indo de $71,88\%$ e $68,8\%$ para $18,75 \pm 5,56\%$, conforme descrito na Tabela 6.3. Conseqüentemente, os valores de F1 e F2 também desceram consideravelmente, alcançando valores médios de $29,64 \pm 7,32\%$ e $46,22 \pm 8,72\%$, respectivamente.


A queda no valor do *recall* está associada ao fato de que o segundo especialista anota algumas instâncias que não possuem as características de KC descritas na literatura. Isso é ilustrado na Figura 6.1(h). O intervalo EEG da figura corresponde ao estágio N3 do sono, o qual é caracterizado por cadeias de ondas lentas. A atividade de ondas lentas do estágio N3 é retratado no espectrograma como uma concentração de alta potência mais uniforme na faixa de 0-4 Hz. Mesmo assim, em desacordo com o primeiro especialista e com o MT-KCD, o segundo especialista anota algumas instâncias de KC que ocorrem neste intervalo EEG correspondente ao estágio N3.




(a) Paciente 02, EEG intervalo 270-360s.




(b) Patient 05, EEG intervalo 990-1080s.




(c) Patient 04, EEG intervalo 540-630s.




(d) Paciente 05, EEG intervalo 270-360s.




(e) Paciente 01, EEG intervalo 90-180s.



(f) Paciente 01, EEG intervalo 180-270s.



(g) Paciente 04, EEG intervalo 0-90s.



(h) Paciente 01, EEG intervalo 630-720s.

Figura 6.1: Marcações do MT-KCD comparadas com as anotações dos especialistas.

O baixo valor de precisão pode ser explicado pelo fato de que o segundo especialista realiza menos anotações quando comparado ao primeiro. Conforme detalhado na Tabela 5.1, a quantidade de anotações do segundo especialista é aproximadamente três vezes menor do que a do primeiro. A Figura 6.1(g) ilustra o fato. Nesta, o primeiro especialista realiza seis anotações e o segundo apenas uma. O MT-KCD marca cinco instâncias de KC que estão em consonância com as marcações do primeiro especialista. Dado que o segundo realizou apenas uma anotação, a quantidade de falsos positivos produzidos é alta, contribuindo assim para a baixa precisão do cenário 3. No cenário 01, a precisão não é afetada pois as anotações de ambos os especialistas são consideradas.

Os resultados comparando as marcações do MT-KCD e as anotações dos especialistas da bateria completa de experimentos realizados podem ser encontrados nos Apêndices A até E.

6.5 Comparação com os métodos existentes

Conforme mencionado anteriormente, a maioria dos métodos de detecção automática de KC tem sido avaliado utilizando a base de dados DREAMS. Nas Tabelas 6.4 até 6.6, MT-KCD é comparado com métodos existentes levando em conta os cenários discutidos. Considerando os cenários 1, 2 e 3, o MT-KCD tem melhor performance do que os demais métodos, na maioria dos casos, em relação aos valores de F1 e F2. Nestes cenários, o método com performance mais similar é o [23]. Comparado com [23], MT-KCD apresenta maiores valores de *recall*, F1 e F2, entretanto com uma menor precisão. Além de [23], outro método que merece menção é o proposto por [22], o qual apresenta um valor de *recall* maior que MT-KCD no cenário 1. Porém, embora apresenta um maior *recall*, este possui valores de precisão, F1 e F2 menores que o MT-KCD.

Método	<i>Recall</i>	Precisão	F1	F2
[20]	61,00	56,00	58,39	56,93
[22]	84,00	62,50	71,67	65,87
[23]	65,05	80,98	72,14	77,19
MT-KCD	81,34	71,88	76,00	79,02

Tabela 6.4: Comparação entre os métodos, cenário 1.

Método	<i>Recall</i>	Precisão	F1	F2
[18]	61,72	73,29	67,01	70,64
[19]	74,00	65,00	69,02	66,62
[23]	67,79	76,63	71,93	74,68
MT-KCD	85,10	68,80	75,42	80,72

Tabela 6.5: Comparação entre os métodos, cenário 2.

Método	<i>Recall</i>	Precisão	F1	F2
[18]	60,94	22,16	32,50	25,39
[23]	73,02	25,00	37,24	28,78
MT-KCD	77,20	18,75	29,64	46,22

Tabela 6.6: Comparação entre os métodos, cenário 3.

7 Conclusão e Trabalhos Futuros

Esta dissertação propõe um método baseado em análise espectral *multitaper* para detecção automática de KC em sinais EEG, denominado MT-KCD. Em linhas gerais, o MT-KCD utiliza espectrograma *multitaper* como técnica de pré-processamento. A partir do espectrograma *multitaper* do sinal EEG, regiões e KCs candidatos são identificados. Por fim, KCs candidatos que não satisfazem determinados critérios de amplitude e duração são eliminados.

O MT-KCD foi avaliado experimentalmente utilizando a base de dados DREAMS. O resultados obtidos mostram que o MT-KCD supera métodos existentes em termos de F1 e F2, alcançando valores médios acima de 75%, na maioria dos cenários de teste. Em relação ao *recall*, o MT-KCD apresenta melhores resultados do que a maioria dos métodos, atingindo valores médios acima de 80%. A métrica com resultados menos favoráveis é a precisão, alcançando um valor máximo de 71,88%, abaixo do valor de 80,98% alcançado por outro trabalho. A partir dos resultados conclui-se que o MT-KCD mostra-se comparável aos métodos existentes, possuindo uma relação mais balanceada entre *recall* e precisão. Em relação à complexidade computacional, tem-se que o MT-KCD é $\mathcal{O}(N \cdot \log N)$, onde N é a quantidade de pontos do sinal original.

Um das limitações do MT-KCD é a identificação de ocorrências de KCs em épocas compostas por longos trechos de ondas lentas, tipicamente o estágio N3. Em épocas com tais características, o espectrograma é caracterizado por seguidas concentrações de energias na faixa de frequência correspondente ao ritmo *delta*. Nesses casos, o método não consegue caracterizar de forma precisa o *background*, levando à marcação de falsos positivos. Essa limitação pode ser observada, por exemplo, na Figura A.1(a). Outra limitação do método é a identificação de artefatos que não foram eliminados na fase pré-processamento. Em alguns casos, o método não consegue identificar se uma onda é oriunda de algum tipo de ruído ou não, levando, em alguns casos, à marcação desta como uma ocorrência de KC, conforme ilustrado nas Figuras B.1(a) e E.1(s), contribuindo assim para um menor índice de precisão do método.

Como trabalhos futuros, planejamos realizar experimentos mais amplos a fim de avaliar, aperfeiçoar e estender o MT-KCD. Além do KC, a análise espectral *multitaper* do sinal EEG tem se mostrado eficiente para a identificação de outras microestruturas, como os fusos do sono. O fuso do sono é caracterizado visualmente no espectrograma *multitaper* como uma concentração de energia na faixa de frequência entre 11-16Hz, conforme ilustrado na Figura 6.1(d). Assim, a utilização do espectrograma *multitaper* para a marcação automática de ocorrências de fusos do sono mostra-se como um caminho promissor a ser explorado. A análise *multitaper* do sinal EEG pode ser utilizada também para identificação das macroestruturas do sono. O espectrograma *multitaper* consegue representar as oscilações do sinal equivalente a uma noite completa de sono em uma única visualização. A partir dessa visualização é possível perceber as diferentes assinaturas espectrais correspondentes a cada estágio do sono, apontando assim para outra possibilidade a ser estudada. Outra linha de pesquisar a ser explorada seria a automatização da marcação de eventos respiratórios que ocorrem durante o sono, como a apneia, a partir do espectrograma de um dado sinal EEG.

Referências Bibliográficas

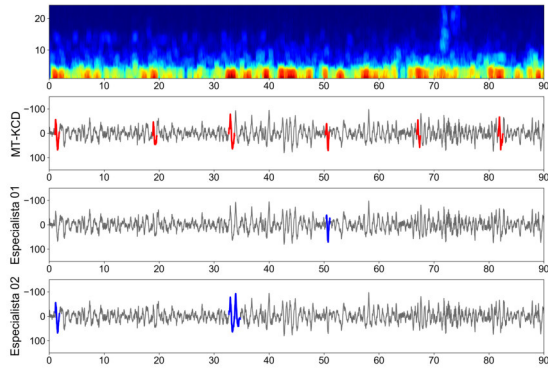
- [1] HAURI, P. *The sleep disorders*. 2nd. ed. Kalamazoo, MI: Upjohn, 1982. 5-62 p.
- [2] MARKWALD, R. R. et al. Impact of insufficient sleep on total daily energy expenditure, food intake, and weight gain. *Proc. Natl. Acad. Sci. U.S.A.*, v. 110, n. 14, p. 5695–5700, Apr 2013.
- [3] SPIEGEL, K. et al. Effects of poor and short sleep on glucose metabolism and obesity risk. *Nature Reviews Endocrinology*, Springer Nature America, Inc, v. 5, n. 5, p. 253–261, may 2009.
- [4] ELLENBOGEN, J. M. Cognitive benefits of sleep and their loss due to sleep deprivation. *Neurology*, v. 64, n. 7, p. E25–27, Apr 2005.
- [5] HIROTSU, C.; TUFIK, S.; ANDERSEN, M. L. Interactions between sleep, stress, and metabolism: From physiological to pathological conditions. *Sleep Science*, GN1 Genesis Network, v. 8, n. 3, p. 143–152, nov 2015.
- [6] KRYGER, M. H.; ROTH, T.; DEMENT, W. C. (Ed.). *Principles and practice of sleep medicine*. 6. ed. Philadelphia, PA: Elsevier, 2017.
- [7] BERRY, R. B. et al. *The AASM Manual for the Scoring of Sleep and Associated Events: Rules, Terminology and Technical Specifications*. [S.l.]: American Academy of Sleep Medicine, 2017.
- [8] HALÁSZ, P. The k-complex as a special reactive sleep slow wave – a theoretical update. *Sleep Medicine Reviews*, Elsevier BV, v. 29, p. 34–40, oct 2016.
- [9] WAUQUIER, A.; ALOE, L.; DECLERCK, A. K-complexes: are they signs of arousal or sleep protective? *Journal of Sleep Research*, Wiley, v. 4, n. 3, p. 138–143, sep 1995.
- [10] GENNARO, L. D.; FERRARA, M.; BERTINI, M. The spontaneous k-complex during stage 2 sleep: is it the ‘forerunner’ of delta waves? *Neuroscience Letters*, Elsevier BV, v. 291, n. 1, p. 41–43, sep 2000.

- [11] AMZICA, F.; STERIADE, M. The functional significance of k-complexes. *Sleep Medicine Reviews*, Elsevier BV, v. 6, n. 2, p. 139–149, may 2002.
- [12] HALÁSZ, P. K-complex, a reactive eeg graphoelement of nrem sleep: an old chap in a new garment. *Sleep Medicine Reviews*, v. 9, n. 5, p. 391 – 412, 2005. ISSN 1087-0792.
- [13] CASH, S. S. et al. The human k-complex represents an isolated cortical down-state. *Science*, American Association for the Advancement of Science (AAAS), v. 324, n. 5930, p. 1084–1087, may 2009.
- [14] WEIGENAND, A. et al. Characterization of k-complexes and slow wave activity in a neural mass model. *PLoS Computational Biology*, Public Library of Science (PLOS), v. 10, n. 11, p. e1003923, nov 2014.
- [15] FORGET, D.; MORIN, C. M.; BASTIEN, C. H. The role of the spontaneous and evoked k-complex in good-sleeper controls and in individuals with insomnia. *Sleep*, Oxford University Press (OUP), v. 34, n. 9, p. 1251–1260, sep 2011.
- [16] NGUYEN, C. D. et al. Mild airflow limitation during n2 sleep increases k-complex frequency and slows electroencephalographic activity. *Sleep*, Oxford University Press (OUP), v. 39, n. 3, p. 541–550, mar 2016.
- [17] YOUNES, M. The case for using digital EEG analysis in clinical sleep medicine. *Sleep Science and Practice*, Springer Nature, v. 1, n. 1, feb 2017.
- [18] DEVUYST, S. et al. Automatic k-complexes detection in sleep eeg recordings using likelihood thresholds. In: *2010 Annual International Conference of the IEEE Engineering in Medicine and Biology*. [S.l.: s.n.], 2010. p. 4658–4661. ISSN 1094-687X.
- [19] KROHNE, L. et al. Detection of k-complexes based on the wavelet transform. In: *2014 36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBC 2014*. [S.l.: s.n.], 2014. p. 5450–5453. Cited By 2.
- [20] PAREKH, A. et al. Detection of k-complexes and sleep spindles (detoks) using sparse optimization. *Journal of Neuroscience Methods*, v. 251, p. 37 – 46, 2015. ISSN 0165-0270.
- [21] LAJNEF, T. et al. Sleep spindle and k-complex detection using tunable q-factor wavelet transform and morphological component analysis. *Frontiers in human neuroscience*, v. 9, p. 414, 2015. ISSN 1662-5161.

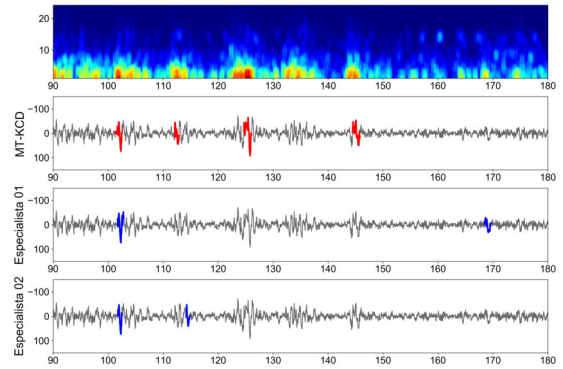
- [22] PATTI, C. R. et al. K-complex detection based on pattern matched wavelets. In: *2016 IEEE EMBS Conference on Biomedical Engineering and Sciences (IECBES)*. [S.l.: s.n.], 2016. p. 470–474.
- [23] YAZDANI, S.; FALLET, S.; VESIN, J. A novel short-term event extraction algorithm for biomedical signals. *IEEE Transactions on Biomedical Engineering*, v. 65, n. 4, p. 754–762, April 2018. ISSN 0018-9294.
- [24] ERDAMAR, A.; DUMAN, F.; YETKIN, S. A wavelet and teager energy operator based method for automatic detection of k-complex in sleep eeg. *Expert Systems with Applications*, v. 39, n. 1, p. 1284 – 1290, 2012.
- [25] CAMILLERI, T. A.; CAMILLERI, K. P.; FABRI, S. G. Automatic detection of spindles and k-complexes in sleep eeg using switching multiple models. *Biomedical Signal Processing and Control*, v. 10, p. 117 – 127, 2014.
- [26] YÜCELBAŞ, C. et al. A novel system for automatic detection of k-complexes in sleep eeg. *Neural Computing and Applications*, v. 29, n. 8, p. 137–157, Apr 2018.
- [27] HERNÁNDEZ-PEREIRA, E. et al. A comparison of performance of k-complex classification methods using feature selection. *Information Sciences*, v. 328, p. 1 – 14, 2016. ISSN 0020-0255.
- [28] MOLONEY, D. et al. Detecting k-complexes for sleep stage identification using nonsmooth optimization. *The ANZIAM Journal*, Cambridge University Press, v. 52, n. 4, p. 319–332, 2011.
- [29] NOORI, S. M. R. et al. K-complex identification in sleep eeg using melm-grbf classifier. In: *2014 21th Iranian Conference on Biomedical Engineering (ICBME)*. [S.l.: s.n.], 2014. p. 119–123.
- [30] JANSEN, B. H. Artificial neural nets for k-complex detection. *IEEE Engineering in Medicine and Biology Magazine*, v. 9, n. 3, p. 50–52, Sept 1990. ISSN 0739-5175.
- [31] BANKMAN, I. N. et al. Feature-based detection of the k-complex wave in the human electroencephalogram using neural networks. *IEEE Transactions on Biomedical Engineering*, v. 39, n. 12, p. 1305–1310, Dec 1992. ISSN 0018-9294.

- [32] VU, H. Q. et al. K-complex detection using a hybrid-synergic machine learning method. *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, v. 42, n. 6, p. 1478–1490, Nov 2012. ISSN 1094-6977.
- [33] PRERAU, M. J. et al. Sleep Neurophysiological Dynamics Through the Lens of Multitaper Spectral Analysis. *Physiology (Bethesda)*, v. 32, n. 1, p. 60–92, Jan 2017.
- [34] VILAMALA, A.; MADSEN, K.; HANSEN, L. K. Deep convolutional neural networks for interpretable analysis of eeg sleep stage scoring. In: *IEEE INTERNATIONAL WORKSHOP ON MACHINE LEARNING FOR SIGNAL PROCESSING, SEPT. 25–28, TOKYO, JAPAN*. [S.l.: s.n.], 2017. p. 1–6.
- [35] MELMAN, T.; VICTOR, J. D. Robust power spectral estimation for EEG data. *Journal of Neuroscience Methods*, Elsevier BV, v. 268, p. 14–22, aug 2016.
- [36] BABADI, B.; BROWN, E. N. A review of multitaper spectral analysis. *IEEE Transactions on Biomedical Engineering*, Institute of Electrical and Electronics Engineers (IEEE), v. 61, n. 5, p. 1555–1564, may 2014.
- [37] STOICA, P.; MOSES, R. L. *Spectral analysis of signals*. Upper Saddle River, N.J: Prentice Hall, 2005.
- [38] OPPENHEIM, A. V.; WILLSKY, A. S.; NAWAB, S. H. *Signals & systems*. 2nd ed. ed. Upper Saddle River, N.J: Prentice Hall, 1997. (Prentice-Hall signal processing series). ISBN 978-0-13-814757-0.
- [39] THOMSON, D. J. Spectrum estimation and harmonic analysis. *Proceedings of the IEEE*, v. 70, n. 9, p. 1055–1096, Sept 1982. ISSN 0018-9219.
- [40] SLEPIAN, D. Prolate spheroidal wave functions, fourier analysis, and uncertainty — v: the discrete case. *The Bell System Technical Journal*, v. 57, n. 5, p. 1371–1430, May 1978. ISSN 0005-8580.
- [41] LEES, J. M.; PARK, J. Multiple-taper spectral analysis: A stand-alone c-subroutine. *Computers & Geosciences*, Elsevier BV, v. 21, n. 2, p. 199–236, mar 1995.


A Marcações do MT-KCD para o paciente 01




(a) Paciente 01, intervalo 0-90 do EEG.



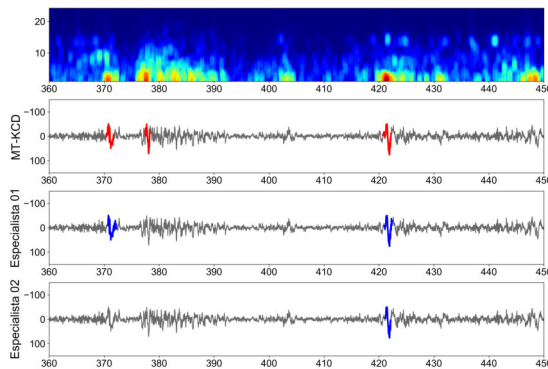
(b) Paciente 01, intervalo 90-180 do EEG.




(c) Paciente 01, intervalo 180-270 do EEG.




(d) Paciente 01, intervalo 270-360 do EEG.



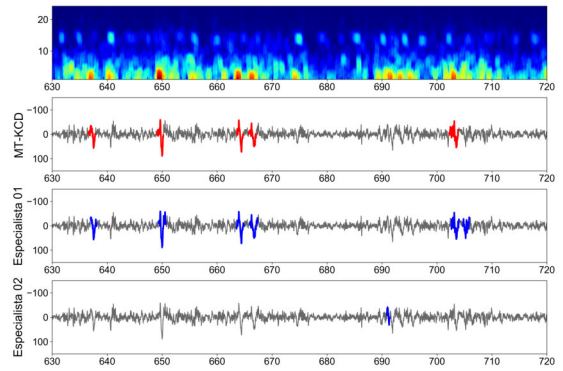
(e) Paciente 01, intervalo 360-450 do EEG.




(f) Paciente 01, intervalo 450-540 do EEG.




(g) Paciente 01, intervalo 540-630 do EEG.




(h) Paciente 01, intervalo 630-720 do EEG.




(i) Paciente 01, intervalo 720-810 do EEG.




(j) Paciente 01, intervalo 810-900 do EEG.




(k) Paciente 01, intervalo 900-990 do EEG.




(l) Paciente 01, intervalo 990-1080 do EEG.




(m) Paciente 01, intervalo 1080-1170 do EEG.




(n) Paciente 01, intervalo 1170-1260 do EEG.




(o) Paciente 01, intervalo 1260-1350 do EEG.




(p) Paciente 01, intervalo 1350-1440 do EEG.




(q) Paciente 01, intervalo 1440-1530 do EEG.



(r) Paciente 01, intervalo 1530-1620 do EEG.




(s) Paciente 01, intervalo 1620-1710 do EEG.




(t) Paciente 01, intervalo 1710-1800 do EEG.

Figura A.1: Marções do MT-KCD comparadas com as anotações dos especialistas para o paciente 01.


B Marcações do MT-KCD para o paciente 02




(a) Paciente 02, intervalo 0-90 do EEG.




(b) Paciente 02, intervalo 90-180 do EEG.




(c) Paciente 02, intervalo 180-270 do EEG.




(d) Paciente 02, intervalo 270-360 do EEG.



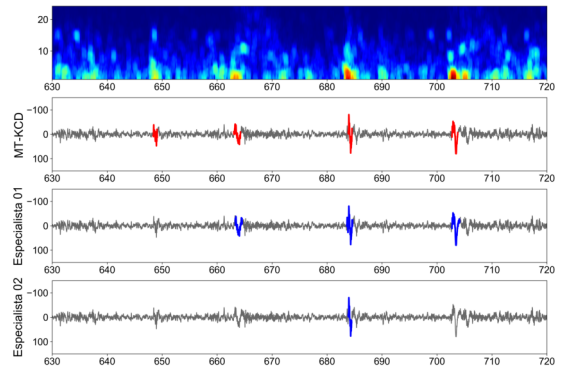
(e) Paciente 02, intervalo 360-450 do EEG.




(f) Paciente 02, intervalo 450-540 do EEG.




(g) Paciente 02, intervalo 540-630 do EEG.




(h) Paciente 02, intervalo 630-720 do EEG.




(i) Paciente 02, intervalo 720-810 do EEG.




(j) Paciente 02, intervalo 810-900 do EEG.




(k) Paciente 02, intervalo 900-990 do EEG.




(l) Paciente 02, intervalo 990-1080 do EEG.




(m) Paciente 02, intervalo 1080-1170 do EEG.




(n) Paciente 02, intervalo 1170-1260 do EEG.




(o) Paciente 02, intervalo 1260-1350 do EEG.




(p) Paciente 02, intervalo 1350-1440 do EEG.




(q) Paciente 02, intervalo 1440-1530 do EEG.



(r) Paciente 02, intervalo 1530-1620 do EEG.




(s) Paciente 02, intervalo 1620-1710 do EEG.




(t) Paciente 02, intervalo 1710-1800 do EEG.

Figura B.1: Marcações do MT-KCD comparadas com as anotações dos especialistas para o paciente 02.


C Marcações do MT-KCD para o paciente 03.




(a) Paciente 03, intervalo 0-90 do EEG.




(b) Paciente 03, intervalo 90-180 do EEG.




(c) Paciente 03, intervalo 180-270 do EEG.




(d) Paciente 03, intervalo 270-360 do EEG.




(e) Paciente 03, intervalo 360-450 do EEG.




(f) Paciente 03, intervalo 450-540 do EEG.




(g) Paciente 03, intervalo 540-630 do EEG.




(h) Paciente 03, intervalo 630-720 do EEG.




(i) Paciente 03, intervalo 720-810 do EEG.




(j) Paciente 03, intervalo 810-900 do EEG.




(k) Paciente 03, intervalo 900-990 do EEG.




(l) Paciente 03, intervalo 990-1080 do EEG.




(m) Paciente 03, intervalo 1080-1170 do EEG.




(n) Paciente 03, intervalo 1170-1260 do EEG.




(o) Paciente 03, intervalo 1260-1350 do EEG.




(p) Paciente 03, intervalo 1350-1440 do EEG.




(q) Paciente 03, intervalo 1440-1530 do EEG.



(r) Paciente 03, intervalo 1530-1620 do EEG.




(s) Paciente 03, intervalo 1620-1710 do EEG.




(t) Paciente 03, intervalo 1710-1800 do EEG.

Figura C.1: Marcações do MT-KCD comparadas com as anotações dos especialistas para o paciente 03.


D Marcações do MT-KCD para o paciente 04.




(a) Paciente 04, intervalo 0-90 do EEG.




(b) Paciente 04, intervalo 90-180 do EEG.




(c) Paciente 04, intervalo 180-270 do EEG.




(d) Paciente 04, intervalo 270-360 do EEG.




(e) Paciente 04, intervalo 360-450 do EEG.




(f) Paciente 04, intervalo 450-540 do EEG.




(g) Paciente 04, intervalo 540-630 do EEG.




(h) Paciente 04, intervalo 630-720 do EEG.




(i) Paciente 04, intervalo 720-810 do EEG.




(j) Paciente 04, intervalo 810-900 do EEG.




(k) Paciente 04, intervalo 900-990 do EEG.




(l) Paciente 04, intervalo 990-1080 do EEG.




(m) Paciente 04, intervalo 1080-1170 do EEG.




(n) Paciente 04, intervalo 1170-1260 do EEG.




(o) Paciente 04, intervalo 1260-1350 do EEG.




(p) Paciente 04, intervalo 1350-1440 do EEG.




(q) Paciente 04, intervalo 1440-1530 do EEG.



(r) Paciente 04, intervalo 1530-1620 do EEG.




(s) Paciente 04, intervalo 1620-1710 do EEG.




(t) Paciente 04, intervalo 1710-1800 do EEG.

Figura D.1: Marcações do MT-KCD comparadas com as anotações dos especialistas para o paciente 04.

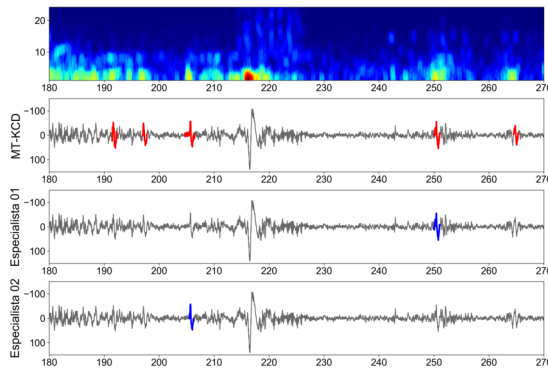
E Marcações do MT-KCD para o paciente 05.



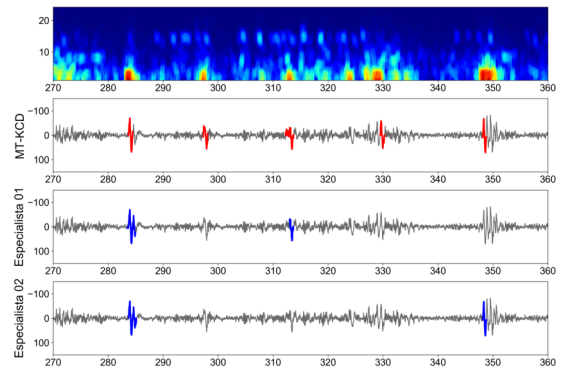
(a) Paciente 05, intervalo 0-90 do EEG.




(b) Paciente 05, intervalo 90-180 do EEG.




(c) Paciente 05, intervalo 180-270 do EEG.




(d) Paciente 05, intervalo 270-360 do EEG.




(e) Paciente 05, intervalo 360-450 do EEG.




(f) Paciente 05, intervalo 450-540 do EEG.



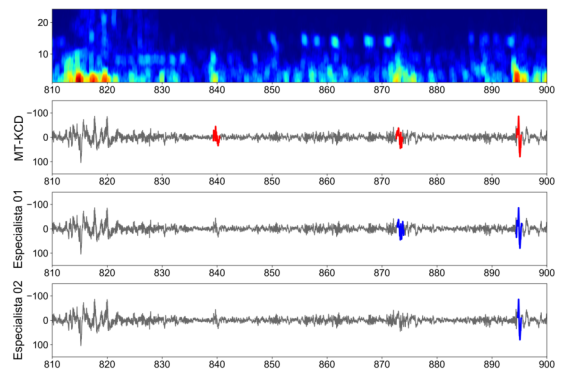
(g) Paciente 05, intervalo 540-630 do EEG.




(h) Paciente 05, intervalo 630-720 do EEG.




(i) Paciente 05, intervalo 720-810 do EEG.




(j) Paciente 05, intervalo 810-900 do EEG.




(k) Paciente 05, intervalo 900-990 do EEG.




(l) Paciente 05, intervalo 990-1080 do EEG.




(m) Paciente 05, intervalo 1080-1170 do EEG.




(n) Paciente 05, intervalo 1170-1260 do EEG.




(o) Paciente 05, intervalo 1260-1350 do EEG.




(p) Paciente 05, intervalo 1350-1440 do EEG.




(q) Paciente 05, intervalo 1440-1530 do EEG.



(r) Paciente 05, intervalo 1530-1620 do EEG.



(s) Paciente 05, intervalo 1620-1710 do EEG.



(t) Paciente 05, intervalo 1710-1800 do EEG.

Figura E.1: Marcações do MT-KCD comparadas com as anotações dos especialistas para o paciente 05.