

Fredson C. dos Santos

**Detecção de potenciais corticais antecipatórios
em sinais de eletroencefalografia (EEG) durante
a condução de carros**

Brasil

Março de 2015

Fredson C. dos Santos

Detecção de potenciais corticais antecipatórios em sinais de eletroencefalografia (EEG) durante a condução de carros

Dissertação apresentada como requisito parcial para obtenção do título de Mestre em Biotecnologia ao Programa de Pós Graduação em Biotecnologia, da Universidade Federal do Pará.

Universidade Federal do Pará - UFPa

Programa de Pós-Graduação em Biotecnologia - PPGBIOTEC

Orientador: Bruno Duarte Gomes

Coorientador: Schubert Ribeiro de Carvalho

Brasil

Março de 2015

Dados Internacionais de Catalogação-na-Publicação (CIP)
Sistema de Bibliotecas da UFPA

Santos, Fredson C. dos, 1989-

Detecção de potenciais corticais antecipatórios em
sinais de eletroencefalografia (EEG) durante a condução
de carros / Fredson C. dos Santos. - 2015.

Orientador: Bruno Duarte Gomes;
Coorientador: Schubert Ribeiro de
Carvalho.

Dissertação (Mestrado) - Universidade
Federal do Pará, Instituto de Ciências
Biológicas, Programa de Pós-Graduação em
Biotecnologia, Belém, 2015.

1. Interface cérebro-computador. 2.
Eletroencefalografia. 3. Cérebro. 4.
Biotecnologia. I. Título.

CDD 22. ed. 003.5

Fredson C. dos Santos

Deteccção de potenciais corticais antecipatórios em sinais de eletroencefalografia (EEG) durante a condução de carros

Dissertação apresentada como requisito parcial para obtenção do título de Mestre em Biotecnologia ao Programa de Pós Graduação em Biotecnologia, da Universidade Federal do Pará.

Trabalho apresentado. Brasil, 16 de março de 2015:

Bruno Duarte Gomes
Orientador

Luiz Guilherme Macedo
Orientador em Exercício

Schubert Ribeiro de Carvalho
Coorientador

Fernando Allan de Farias Rocha
Membro Avaliador

Anderson Manoel Herculano
Membro Avaliador

Chubert Bernardo Castro de Sena
Membro Avaliador

Brasil
Março de 2015

*Este trabalho é dedicado a todas as pessoas que participaram,
apoiaram ou mesmo só acreditaram que seria possível.*

Agradecimentos

Meus mais sinceros agradecimentos vão para Lorena Nascimento, a minha Lola que tanto tem me ajudado e me apoiado nestes momentos que precisam de concentração e dedicação, nunca tive em minha vida alguém tão compreensível, tá tem a mamãe, e tão importante para mim, fico muito feliz em saber que vais me acompanhar nesta e nas próximas etapas de nossas vidas, te amo.

Agradeço a minha família que me apoia muito, ao meu pai que sempre que pensei em trocar de rumo me orientou a prosseguir estudando, ele me ensinou a viver. Meu grande exemplo, a mamãe que cuida de mim me aconselha esta sim viveu e deixou ver como se vive. A meus irmãos só tenho a agradecer, mesmo que muitas vezes me perturbassem quando tinha de estudar, mesmo que aos atritos sabemos da admiração que temos entre-nos.

Aos professores que vem me ajudando e orientando não tenho como realmente agradecer por tudo que já fizeram por mim, pelos votos de confiança agradeço em especial aos professores Bruno, Givago, Schubert e Guilherme.

Agradeço aos meus colegas de convívio, Wallace, Alexandre, Iraquitan, Gustavo, Bruno, Lena, as Anas, Melina, podem estar faltando nomes, então obrigado a todos que me aturam, e que muitas vezes também colaboram com este trabalho.

*“Sem afobação
O pau pode estar quebrando
Você vai fazer tudo na calma.
(Capitão Nascimento
Por: Wagner Moura em Tropa de Elite)*

Resumo

O reconhecimento da intenção do condutor a partir de sinais de eletroencefalografia (EEG) pode ser útil no desenvolvimento de interfaces cérebro computador (BCI) para serem usadas em sinergia com veículos inteligentes. Isso pode ser benéfico para melhorar a qualidade de interação entre o motorista e o carro, por exemplo, fornecendo uma resposta do carro inteligente alinhada com a intenção do motorista. Neste estudo, considera-se a antecipação como sendo o estado cognitivo que leva a ações específicas durante a condução de um automóvel. Portanto, propomos investigar a presença de padrões antecipatórios em sinais EEG durante a condução de veículos para determinar duas ações específicas (1) virar à esquerda e (2) virar à direita, alguns milissegundos antes que tais ações aconteçam. Um protocolo experimental foi proposto para gravar sinais EEG de 5 indivíduos enquanto eles operam um simulador de realidade virtual não invasiva - que foi projetado para tal experimento - que simula a condução de um carro virtual. O protocolo experimental é uma variante do paradigma da variação negativa contingente (CNV) com condições Go e No-go no sistema de condução de realidade virtual. Os resultados apresentados neste estudo indicam a presença de padrões antecipatórios em potenciais corticais lentos observados no domínio do tempo (medias dos sinais EEG) e da frequência (Power Spectra e coerência de fase). Isso abre um leque de possibilidades no desenvolvimento de sistemas BCI - baseados em sinais antecipatórios - que conectem o motorista ao veículo inteligente favorecendo uma tomada de decisão que analise as intenções dos condutores podendo eventualmente evitar acidentes durante a condução.

Palavras-chaves: Interface Cérebro Computador. EEG. Sinais Antecipatórios.

Abstract

The recognition of the driver's intention from electroencephalographic signals (EEG) may be useful in the development of brain computer interface (BCI) to be used in synergy with intelligent vehicles. This can be beneficial to improve the quality of interaction between the driver and the car, for example, providing a response from the smart car aligned with the intention of the driver. In this study, the anticipation is considered as the cognitive state that leads to specific actions while driving a car. Therefore, we propose to investigate the presence of anticipatory patterns in EEG signals while driving vehicles to determine two specific actions (1) left and (2) turn right, a few milliseconds before such actions take place. An experimental protocol was proposed to record EEG signals of 5 individuals as they operate a virtual reality simulator non-invasive - it was designed for this experiment - which simulates driving a virtual car. The experimental protocol is a variant of the paradigm of contingent negative variation (CNV) with Go and No-go conditions in virtual reality training system. The results of this study indicate the presence of anticipatory patterns observed in slow cortical potentials in the time domain (medium EEG signal) and the frequency (Power Spectra and phase coherence). This opens a range of possibilities in the development of BCI systems - based on anticipatory signals - that connect the driver to the intelligent vehicle favoring a decision-making to assess the intentions of drivers may eventually prevent accidents while driving.

Key-words: Brain Computer Interface. EEG. Anticipatory Potentials.

Lista de ilustrações

Figura 1 – Referenciais anatômicos	17
Figura 2 – Potencial Visual Provocado de Estado Estacionário - SSVEP	20
Figura 3 – Decomposição tempo-frequência	33
Figura 4 – Análise da coerência de fase	34
Figura 5 – Exemplificação de classificadores	34
Figura 6 – EEG neuro-headset Emotiv Epoc	36
Figura 7 – Emotiv Painel de controle	37
Figura 8 – Interface do test Bench	38
Figura 9 – Visão do usuário do ambiente de simulação	39
Figura 10 – Tela do projeto no Xcode	40
Figura 11 – Interface da ferramenta de análise Edittool	41
Figura 12 – Estrutura do Ambiente de simulação	42
Figura 13 – Pista Completa do Ambiente de simulação	43
Figura 14 – Emotiv EPOC Headset disposição dos eletrodos	44
Figura 15 – Posicionamento do Emotiv neuro-headset	45
Figura 16 – Representação do córtex cerebral	46
Figura 17 – Representação dos eventos do experimento	46
Figura 18 – Grandes médias do EEG	49
Figura 19 – Mapa da decomposição tempo frequência	50
Figura 20 – Mapa da coerência de fase	51
Figura 21 – Mapa da coerência de fase	52
Figura 22 – Mapa da coerência de fase	53
Figura 23 – Desempenho de Classificação no Tempo	56
Figura 24 – Desempenho do Melhor Classificador	57
Figura 25 – Mapas de Cabeça Sujeito 1	59
Figura 26 – Mapas de Cabeça Sujeito 2	60
Figura 27 – Esquema genérico de sistemas BCI	63

Lista de abreviaturas e siglas

SNC	Sistema Nervoso Central
BCI	Brain–Computer Interface
WT	Wavelet Transform
DWT	Discrete Wavelet Transform
EEG	Eletroencefalograma
FC	Fisher Criterion
SSVEP	Steady State Visually Evoked Potential
MEG	Magnetoencefalografia
PET	Tomografia por emissão de pósitrons
fMRI	Ressonância magnética funcional
VEP	Visual Evoked Potential
ADAN	Anterior Directing Attention Negativity

Sumário

	Introdução	13
1	JUSTIFICATIVA	15
2	OBJETIVOS	16
2.1	Objetivo Geral	16
2.2	Objetivos Específicos	16
3	REFERENCIAIS TEÓRICOS	17
3.1	TIPOS DE SINAIS: MÉDIAS DA ATIVIDADE CEREBRAL	17
3.1.1	Referenciais Anatômicos	17
3.1.2	Técnicas Para Medir a Atividade Cerebral	18
3.1.3	Sinais Neurofisiológicos Utilizados em Sistema BCI	19
3.1.3.1	Potencias Provocados	19
3.1.3.2	Sinais Espontâneos	20
3.1.3.2.1	Ritmos Cerebrais	21
3.2	PROCESSAMENTO DO SINAL	22
3.2.1	Técnicas para filtragem do sinal	22
3.2.1.1	Filtro Temporal	23
3.2.1.2	Transformada Wavalet	23
3.2.2	Aplicação	25
3.3	DECOMPOSIÇÃO TEMPO-FREQUÊNCIA E ANÁLISE DE FASE	25
3.3.1	Análise no Domínio da Frequência	26
3.3.2	Análise da Coerência de Fase	27
3.4	PARADIGMAS RELACIONADOS AO BCI	28
3.4.1	Dessincronização e Sincronização Associada a Eventos	28
3.4.2	Paradigma <i>Go No-Go</i>	28
3.5	MODELOS DE APRENDIZADO PARA RECONHECIMENTO DE PADRÕES	29
3.5.1	Método de Validação	30
3.5.2	Validação Cruzada	30
3.5.3	<i>K-fold</i>	31
3.5.4	Acurácia da Classificação e Taxa de Erro	32
4	MATERIAIS E MÉTODOS	35
4.1	Sujeitos	35

4.2	Emotiv Headset	35
4.3	Softwares Utilizados	36
4.4	Detalhamento do Experimento	37
4.5	Parâmetros de Análise	39
5	RESULTADOS	47
5.1	Potenciais Relacionados à Antecipação de Eventos	47
5.2	Análises Dimensionais	47
5.3	Resultados de Classificação	54
5.4	Classificação em Varredura	54
5.5	Representação Topográfica do EEG	58
6	DISCUSSÃO	61
6.1	A variação do EEG em baixa frequência: Domínio do tempo	61
6.2	Informação fornecida pelo EEG sobre engajamento funcional: Domínio da frequência	61
6.3	Perspectivas	62
7	CONCLUSÃO	64
	Referências	65
	 APÊNDICES	 70
	APÊNDICE A – SUBMISSÃO AO COMITÊ DE ÉTICA	71
	APÊNDICE B – TERMO DE CONSENTIMENTO LIVRE E ESCLARECIDO (TCLE)	72
	APÊNDICE C – RESULTADOS DE CLASSIFICAÇÃO PARA TODOS OS SUJEITOS	74
	APÊNDICE D – GRÁFICOS DAS MÉDIAS DOS SINAIS	77
	APÊNDICE E – GRÁFICOS DAS DECOMPOSIÇÕES TEMPO-FREQUÊNCIA E COERÊNCIA DE FASE	118

Introdução

Acredita-se que a antecipação seja um processo cognitivo que acontece quando o sujeito se envolve ativamente em uma fase de preparação para a percepção de um estímulo e a execução de ações específicas após o aparecimento destes estímulos (WALTER *et al.*, 1964); por exemplo, o aparecimento de um sinal de luz vermelha quando o sinal de trânsito muda de verde para amarelo. Em paradigmas psicofísicos simples, uma negatividade central tem sido observada nos sinais de eletroencefalografia (EEG) durante o intervalo entre os estímulos preditivos e contingentes. Este potencial tem sido associado ao processamento preparatório para ações no momento da chegada de eventos futuros (KIRSCH; HENNIGHAUSEN, 2010; KROPP *et al.*, 2000). Este fato justifica a construção de sistemas inteligentes que possam antecipar a ação de motoristas durante a condução de veículos e provavelmente evitar acidentes, por exemplo, freando o carro ou simplesmente mudando a direção do mesmo. Neste contexto, desenvolver técnicas para acessar correlatos de estados cognitivos e detectar sinais antecipativos provenientes da intenção de sujeitos podem ajudar na melhoria de interfaces-cérebro computador (BCI) (MILLAN *et al.*, 2008). Isso pode ser benéfico para o desenvolvimento de sistemas BCI integrados a veículos que monitorem estados cerebrais do motorista durante a condução de veículos inteligentes. O principal conceito para a aplicação de sistemas BCI em veículos inteligentes se baseia em *shared control* (SC) ou controle compartilhado (FLEMISCH *et al.*, 2003), ou seja, o controle sobre o sistema é compartilhado entre o motorista e o carro. A implantação de um sistema deste tipo pode melhorar a interação através do alinhamento da resposta do carro inteligente com a intenção do motorista. Por exemplo, considere um trecho de estrada com curvas para esquerda e direita (como uma descida de serra) onde um motorista pode perceber a curva (i.e., tem a intenção de dobrar) mas não a faz por algum motivo de dúvida. Neste caso, o assistente do carro inteligente poderia detectar a intenção do motorista e seguramente realizar a manobra no momento mais adequado sem surpreendê-lo.

Eletroencefalografia da atividade cerebral tem sido muito utilizada para o diagnóstico clínico e na exploração do funcionamento do cérebro. Todavia, ao longo das últimas duas décadas, sistemas BCI baseados em EEG têm recebido maior atenção, principalmente, devido à facilidade de uso, alta resolução temporal, e o baixo custo em comparação com outros sistemas de medida não invasivos da atividade cerebral, como fMRI, MEG, escaneamento PET, etc (MCFARLAND; WOLPAW, 2011). Estudos anteriores que monitoraram estados mentais de motoristas, concentraram-se principalmente em detectar níveis de sonolência e excitação a partir de sinais de EEG e eletro-oculograma (EOG) (CHUANG *et al.*, 2010; LIN *et al.*, 2010). Além disso, sistemas baseados em EEG também

investigam a detecção de sobrecarga mental em condutores (LIN et al., 2010). Recentemente, Haufe et al. investigaram a detecção do freio de emergência antes do início da ação, ou seja, antes que o condutor realize a ação de freiar. Os resultados deste estudo indicam que a intenção do motorista pode ser detectada 130ms mais cedo do que as respostas dos pedais do carro usando EEG, ou seja, antes que a ação motora de pisar no pedal do freio aconteça (HAUFE et al., 2011). Neste estudo, estamos interessados em potenciais corticais antecipatórios codificados em sinais EEG durante a condução de veículos, associados a duas ações específicas de condução que são manobras para virar o carro à esquerda e à direita, pois acreditamos que alguns acidentes podem ser evitados produzindo uma mudança de direção no veículo.

Pelos motivos expostos acima, o presente trabalho utilizará o EEG como método de aquisição de informações originadas da atividade do cérebro. A coleta de dados foi feita utilizando o Emotiv EPOC, um equipamento desenvolvido especificamente para utilização em sistemas BCI onde os dados são transmitidos através de uma conexão sem fio, possibilitando uma maior liberdade de movimento do motorista durante a condução. O protocolo experimental para registro de dados é uma variante do paradigma da variação negativa contingente (CNV) com condições Go e No-go no sistema de condução de realidade virtual. Durante os experimentos, foram registrados sinais EEG de 5 (cinco) sujeitos usando uma variação do paradigma CNV em um experimento de condução simulado. Após a etapa de aquisição de informações, os dados coletados foram submetidos à técnicas de Processamento Digital de Sinais (PDS) para filtragem e seleção de bandas de frequência relevantes associadas a existência dos padrões antecipatórios no domínio do tempo e da frequência. O filtro Butterworth e a Transformada Discreta de Wavelet (DWT) foram utilizados para separação das bandas de frequência dos ritmos motores e do potencial cortical de ondas lentas, pois os ritmos sensoriais motores são potenciais associados à atividade motora e o potencial de ondas lentas contém informações relativas à antecipação da execução de uma ação motora (HINTERBERGER et al., 2004).

Os resultados apresentados neste estudo indicam a presença de padrões antecipatórios em potenciais corticais lentos observados no domínio do tempo (medias dos sinais EEG) e da frequência (Power Spectra e coerência de fase). Isso abre um leque de possibilidades no desenvolvimento de sistemas BCI - baseados em sinais antecipatórios - que conectem o motorista ao veículo inteligente favorecendo uma tomada de decisão que analise as intenções dos condutores podendo eventualmente evitar acidentes durante a condução através da mudança de direção do carro. Este projeto se encontra em avaliação do comitê de ética, ver Apêndice A.

1 Justificativa

Pesquisas relacionadas a BCI são importantes não apenas para pessoas com dificuldade motora, mas também para pessoas saudáveis, podendo ser utilizada em interfaces para comunicação, sistemas de imersão ou mesmo aplicações em entretenimento e segurança no trabalho. Este estudo apresenta uma forma de detectar e decodificar a intenção de manobras de condução de carros e classificar estas ações antes que elas ocorram, extraíndo informações prévias relevantes para a aplicação do sistema. Assim é possível prevenir que um motorista cometa ações indesejadas e que possam provocar acidentes, utilizando um sistema de controle inteligente funcionando no regime de tomada de decisões conjunta, onde caso ele reconheça que o motorista vai dobrar no momento errado, por exemplo, o sistema muda a direção do carro.

2 Objetivos

2.1 Objetivo Geral

Desenvolver uma metodologia para analisar a presença de potenciais corticais antecipatórios em sinais de eletroencefalografia (EEG) durante a condução de carros relacionadas a duas ações de mudança de direção, como virar a esquerda e a direita.

2.2 Objetivos Específicos

- A) Diferenciar com eficiência os intervalos de tempo do paradigma go no-go.
- B) Realizar testes de classificação utilizando janelas temporais.
- C) Desenvolver uma metodologia para classificação de potenciais antecipatórios.
- D) Validar a metodologia.

3 Referenciais Teóricos

3.1 TIPOS DE SINAIS: MÉDIAS DA ATIVIDADE CEREBRAL

3.1.1 Referenciais Anatômicos

O sistema nervoso central (SNC – toda parte do sistema nervoso que é protegida por ossos) é uma estrutura extremamente complexa, assim para facilitar seu estudo ele é subdividido. Porém, iremos apresentar aqui somente os referenciais anatômicos que serão utilizados neste trabalho. Podemos ver na [Figura 1](#) representada em diferentes cores a divisão do cérebro em lobos, os nomes desses lobos são definidos homonimamente aos ossos que os protegem, sendo o lobo frontal o de mais interesse neste trabalho, pois nele se encontra o córtex motor, na [seção 4.5](#) o córtex motor será abordado com mais detalhes. A divisão em lobos é uma divisão funcional do cérebro, pois cada uma destas áreas é responsável por específicas funções cerebrais, como por exemplo, o lobo frontal é o responsável pelo processamento das funções motoras.

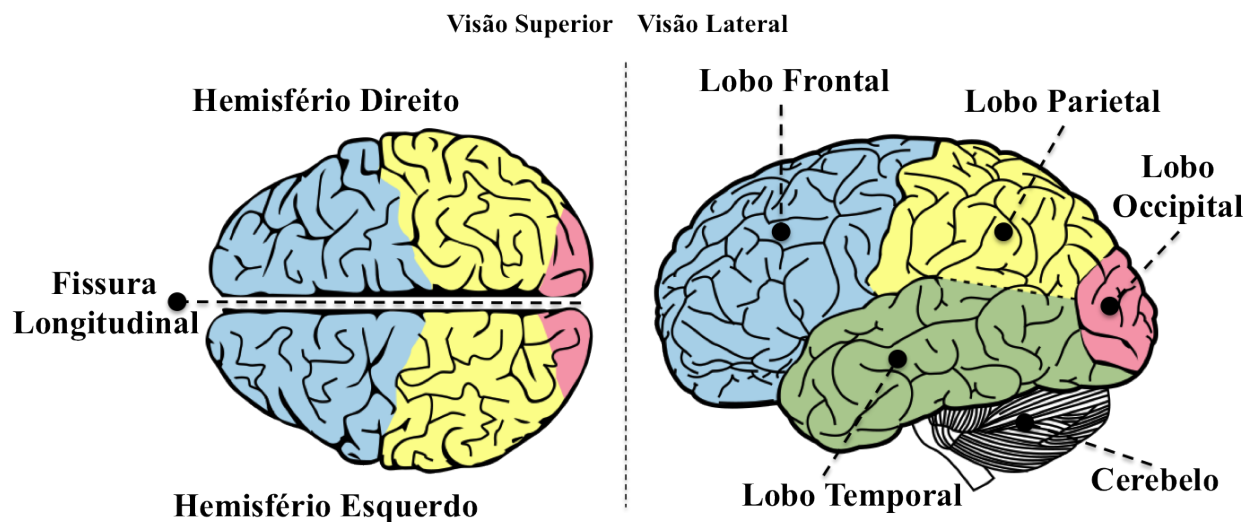


Figura 1 – Representação esquemática da divisão do cérebro em lobos, apresentando a visão lateral e superior, com indicações destacando os referenciais anatômicos mais relevantes para este trabalho.

O cérebro também se divide em dois hemisférios. Separados pela fissura longitudinal, os hemisférios direito e esquerdo praticamente não tem contato, unindo-se novamente apenas em sua base, próximo ao cerebelo. Esta divisão morfológica é de extrema importância pois o processamento de várias funções se dividem entre os hemisférios, como no caso da informação tátil que quando proveniente do lado direito do corpo é processada pelo hemisfério esquerdo do cérebro.

3.1.2 Técnicas Para Medir a Atividade Cerebral

Medir a atividade cerebral é o primeiro passo de um sistema BCI. Portanto, a maneira como isso é feito vai influenciar todo o resto do procedimento técnico. O EEG tem sido a técnica amplamente usada em aplicações BCI em humanos e será a aplicação usada no presente projeto. Por isso, é importante deixar claro porque o EEG foi a escolha para o primeiro trabalho do tipo na Amazônia. As aplicações modernas em BCI são muito recentes em comparação com outros procedimentos, mas é interessante notar que, de todas as técnicas mencionadas, o EEG é a mais antiga. De fato, a invenção do EEG por Hans Berger data de 1924.

A mencionada excelente resolução temporal não é vantagem exclusiva do EEG já que a MEG também possui resolução temporal similar. Ambos, EEG e MEG, refletem a produção de atividade pós-sináptica de grandes populações neurais, porém, ambas possuem baixa resolução espacial em comparação com a técnicas como fMRI e PET.

Por medir campos magnéticos e não potenciais elétricos, o MEG depende de orientação de dipólos e não da geometria do crânio do usuário, o que constitui uma vantagem sobre o EEG. Aplicações BCI importantes já foram implementadas usando MEG, como treino “mental” para indução mais rápida de plasticidade em pessoas que sofreram acidente vascular cerebral (BIRBAUMER; COHEN, 2007; MELLINGER et al., 2007). No entanto, assim como fMRI e PET, os equipamentos usados na MEG para medir os campos magnéticos atuam na escala de femtoteslas e são muito grandes. Por isso, são equipamentos sensíveis a interferência sendo necessário um ambiente controlado para seu devido funcionamento, são utilizadas salas especiais que dispõem de: umidade e temperatura controladas; isolamento contra interferência magnética, ou seja, a sala deve ser completamente coberta por uma blindagem de alumínio ou ligas de níquel-ferro, de forma a evitar interferências de campos magnéticos produzidos pela rede elétrica e transmissões de todo tipo. Essas características limitam o uso da MEG, inviabilizando sua utilização de forma portátil com qualquer portabilidade. Finalmente, o preço de um equipamento MEG é muito superior ao de qualquer equipamento para medição de EEG.

Em conclusão, o EEG é de baixo custo em comparação com outras técnicas. Pode ser usado com relativa portabilidade. Sua resolução temporal é uma das principais vantagens para sua aplicação em BCI, podendo reconhecer eventos com precisão em milissegundos, fator indispensável para aplicação em tempo real. Por ser um registro eletrofisiológico amostrado em computadores, o EEG pode ser processado por quaisquer técnicas de processamento digital de sinais implementados em rotinas computacionais como o filtros digitais FIR, IIF ou Butterworth (RABINER; GOLD; YUEN, 1978), bem como transformadas discretas Wavelet (DWT – discrete wavelet transform) ou de Fourier (SAMAR et al., 1999).

BCI's invasivos são sistemas baseados no registro do comportamento do cérebro de forma invasiva. O registro do potencial elétrico diretamente do cérebro, pode ser realizado através de eletrodos posicionados sobre o córtex cerebral, esta técnica chama-se eletrocorticograma (ECoG). O ECoG necessita da remoção de camadas de tecido para posicionar os eletrodos, eles podem ser posicionados sobre as meninges, o que requer a remoção de parte do couro cabeludo e do crânio, dessa forma são registrados potenciais elétricos associados a grupos de neurônios com uma relação sinal-ruído alta e uma boa resolução espacial. O registro desse tipo de potencial pode ainda ser mais preciso, caso os eletrodos penetrem o tecido cerebral registrando a atividade elétrica de grupos menores de neurônios próximos da ponta, acessando assim informações anteriormente indisponíveis. O ponto extremo desta técnica é o registro unitário, que coleta a atividade de apenas um neurônio, acessando os potenciais de ação de cada neurônio registrado. Na literatura os trabalhos envolvendo esta técnica se distinguem pelo número de neurônios registrados simultaneamente (IFFT et al., 2013).

3.1.3 Sinais Neurofisiológicos Utilizados em Sistema BCI

3.1.3.1 Potenciais Provocados

Considerado o significado direto do termo “potencial provocado”, poder-se-ia incluir virtualmente todos os potenciais produzidos mediante estimulação em condições experimentais. Inclusive, os medidos pela atividade de um neurônio ou grupos de neurônios. No entanto, o termo “potencial visual provocado” (VEP – *visual evoked potentials*) se refere comumente ao potencial elétrico medido através de eletrodos posicionados no couro cabeludo (ODOM et al., 2010; WANG et al., 2008), ou ainda sobre a dura-máter como é o caso do eletrocorticograma. Para nossa conveniência na discussão sobre BCI no presente projeto, trataremos apenas dos VEPs medidos com eletrodos posicionados no couro cabeludo.

Utilizando um sistema BCI provocado foi possível o reconhecimento de caracteres de um teclado QWERTY completo de forma dinâmica, eficiente e requerendo pouco ou nenhum treinamento para utilização do sistema (HWANG et al., 2012). O controle direcional também é possível utilizando o mesmo método (DIEZ et al., 2011), contudo a aplicação desta metodologia no controle do movimento de uma cadeira de rodas, por exemplo, iria requerer a adaptação do ambiente onde fosse acontecer esse deslocamento. A seguir são apresentados os principais VEPs utilizados em BCI.

Um dos componentes de onda provocados e importante em aplicações BCI é o P300, que recebe esta nomenclatura por se tratar de um sinal com o maior pico ocorrendo em torno de 300ms após o início de uma estimulação.

O P300 é uma resposta a uma novidade, muito utilizado em exames auditivos e

visuais. Em BCI, uma adaptação deste tipo de estimulação tem mostrado bons resultados. O usuário é orientado a focar um caractere em uma “tabela” formada por linhas e colunas de caracteres, normalmente letras e números, as linhas e colunas irão piscar de forma pseudo aleatória, gerando vários *flashes* que servem de estimulação para o P300. Assim, por questões associadas a critérios de atenção a resposta P300 mais intensa ocorrerá quando o caractere focalizado piscar. O sistema associa a posição temporal da resposta ao momento da estimulação e identifica o caractere focalizado.

O SSVEP é um fenômeno de ressonância onde uma estimulação constante gera uma resposta oscilatória estacionária, assim como pode ser visto na [Figura 2](#), o que origina a sigla “Steady-State Visual Evoked Potential” ou Potencial Visual Provocado de Estado Estacionário, como a frequência de resposta do SSVEP depende diretamente da frequência da estimulação pode-se realizar um procedimento muito semelhante ao utilizado com o P300, utilizando múltiplos estímulos com frequências diferentes, o aumento da atenção em um destes estímulos resulta no aumento da resposta associada a este estímulo, tal comportamento é convertido em comandos, tal metodologia está normalmente associada ao controle espacial ([VIALATTE et al., 2010](#)).




Figura 2 – Registro de estado estacionário (SSVEP), obtido através de estimulação Azul-Amarelo com 90% de contraste. As duas regiões destacadas, entre as linha pontilhadas, mostram o padrão de repetição que dá o nome ao SSVEP, esse padrão é formado pela estimulação repetitiva e é justamente a característica que facilita seu reconhecimento para utilização em sistemas BCI.

3.1.3.2 Sinais Espontâneos

Sinais espontâneos são gerados por diversas tarefas mentais, como movimento de membros, reforçando que estes sinais são gerados sem qualquer estimulação externa, mas

sim a partir de atividades do usuário, sejam elas atividades motoras propriamente ditas ou mesmo atividades imaginativas. É importante salientar que no caso do processamento realizado pelo córtex motor em sinais espontâneos a atividade neural gerada por imaginação motora ou atividade motora são extremamente semelhantes (GRAIMANN; ALLISON; PFURTSCHELLER, 2010), dessa forma a pessoa pode treinar para poder reproduzir esses padrões somente ao imaginar algo, esse fato ainda possibilita que pessoas portadoras de deficiências motoras possam utilizar sistemas desenvolvidos para pessoas saudáveis. Como os sinais espontâneos possuem padrões menos específicos que os gerados por sinais provocados, o treinamento se torna mais dispendioso, porém, se obtém mais liberdade nos comandos para controle, não dependendo de um ambiente adaptado. Um cuidado a ser tomado é o processamento, pois a interferência gerada por atividade muscular, como o movimento do pescoço e dos olhos, por exemplo, pode causar interferência e atrapalhar o funcionamento do sistema. Isso acontece com os dois tipos de sinais, porém, em maior intensidade em sinais espontâneos.

3.1.3.2.1 Ritmos Cerebrais

Mesmo que os sinais espontâneos não tenham um padrão definido existem especificidades que os separam, conhecidos como ritmos cerebrais. Os ritmos cerebrais separam os sinais cerebrais em faixas de frequência denominadas como ritmos *delta* (δ): $< 4\text{Hz}$, *teta* (θ): $4\text{--}8\text{Hz}$, *mi* (μ): $8\text{--}12\text{Hz}$, *beta* (β): $12\text{--}30\text{Hz}$ e *gama* (γ): $> 30\text{Hz}$ (GRAIMANN; ALLISON; PFURTSCHELLER, 2010).

Estas bandas de frequência não são perfeitamente determinadas, mesmo que as citadas acima sejam as mais utilizadas, alguns trabalhos utilizam intervalos diferentes. Como as bandas μ e β , utilizadas como $8\text{--}13\text{Hz}$ para μ e $14\text{--}30\text{Hz}$ para β em (WANG et al., 2010). Além das diferenças de bandas existem alguns detalhes de nomenclatura, neste trabalho utilizaremos o termo banda μ ao invés de α , mesmo se tratando da mesma faixa de frequência utiliza-se μ quando o registro é proveniente do córtex sensório-motor. Vários estudos utilizam estas faixas para classificação de sistemas BCI baseados em comandos por ações motoras imaginadas (BABILONI et al., 2000; WOLPAW; MCFARLAND, 2004).

As atividades motoras se encontram concentradas nos ritmos μ e β (*mi* e *beta*), também denominadas ritmos motores quando provenientes do cortex motor (WOLPAW; BOULAY, 2010), de forma que atividades motoras alteram o comportamento nesses ritmos específicos. Dessa forma, padrões gerados por ação ou imaginação motora se encontram dentro destes ritmos. Sistemas BCI que levam em conta os ritmos motores normalmente conseguem melhores resultados na classificação (MCFARLAND; WOLPAW, 2011).

A faixa *delta* (δ) também é conhecida como potenciais corticais lentos e são chamados desta forma por terem uma frequência muito baixa, $0.1\text{--}1\text{Hz}$ ou $0.1\text{--}4\text{Hz}$ dependendo

da fonte literária (HAMMON et al., 2008; KHALILIARDALI et al., 2012). Há indícios na literatura de que os potenciais dentro desta gama de frequência provenientes do córtex motor carregam informações quanto ao planejamento da execução de uma ação (GAN-GADHAR; CHAVARRIAGA; R.MILLAN, 2009). Isto possibilita identificar a intenção de realizar uma ação.

3.2 PROCESSAMENTO DO SINAL

Dentro da neurociência a filtragem dos dados é um procedimento padrão, consequentemente tem importância semelhante em BCI, onde comumente se utilizam dados eletroencefalográficos, contudo com aplicações e configurações ligeiramente diferentes.

A filtragem é indispensável em sistemas BCI que utilizam o EEG não invasivo, pois devido a quantidade de ruído contida neste tipo de registro a filtragem gera uma melhoria na qualidade do sinal. Um dos conceitos de filtragem é “remoção do ruído”, porém, o que é ruído ainda é relativo, desse modo podemos explicar a filtragem como uma maneira de separar a parte de interesse do sinal.

Em BCI muito do interesse está na análise da atividade motora que se encontra, segundo a literatura, em uma faixa de frequência entre 8Hz e 12Hz conhecida como ritmos cerebrais motores. Para analisar essa faixa de frequência de forma isolada, os filtros podem ser utilizados. Outras aplicações para os filtros são: remoção do ruído; filtragem espacial; remoção de artefatos e algumas outras, contudo estas são as principais.

3.2.1 Técnicas para filtragem do sinal

Existem várias metodologias de filtragem que podem funcionar separando ou suavizando o sinal. No geral, filtros são algoritmos que permitem eliminar componentes indesejáveis. Em BCI, os filtros são muito utilizados para analisar de forma mais específica a atividade cerebral, pois a intenção seria separar do EEG somente os potenciais relacionados à atividade motora. Contudo, essa tarefa não é simples devido à interferência comumente gerada por: potenciais musculares; a baixa resolução espacial dos dados; e o fato de que o EEG não invasivo coleta atividades de grandes grupos neurais. Os registros não são pontuais, pois os eletrodos e os grupos neurais sofrem interferência dos córtex vizinhos. Outros motivos da dificuldade nesta aplicação são: o fato dos córtex não serem claramente definidos (KANDEL; SCHWARTZ; JESSELL, 2000); as bandas dos ritmos cerebrais não são perfeitamente discretas. Os filtros são ferramentas utilizadas para tentar resolver tais problemas.

3.2.1.1 Filtro Temporal

Filtros que atuam em eventos distribuídos no tempo são chamados de filtros temporais, eles atuam em series de valores que são registrados a uma taxa de amostragem, ou seja, a cada determinado intervalo de tempo um valor é registrado, gerando uma sequencia temporal. Nesse momento é relevante observar que o ruído apresenta uma forma e frequência diferente do resto do sinal, dessa forma o sinal pode ser filtrado, removendo o ruído se aplicado às configurações de filtragem corretas.

Os filtros mais básicos são os passa-baixa, que só deixam passar componentes abaixo de uma frequência específica. A partir da inversão e combinação pode-se obter os passa-alta, passa-banda e nega-banda. O filtro Butterworth é um dos mais utilizados em BCI ([WALDETT et al., 2008](#); [AMIRI](#); [FAZEL-REZAI](#); [ASADPOUR, 2013](#)), comumente utilizado como passa-banda para selecionar um ritmo específico, o filtro Butterworth pode ser projetado a partir de sua função de transferência:

$$H(s) = \frac{b(1) + b(2)z^{-1} + \dots + b(n+1)z^{-n}}{1 + a(2)z^{-1} + \dots + a(n+1)z^{-n}} \quad (3.1)$$

Onde n é a ordem do filtro ([MATHWORKS, 2013](#)), quanto maior a ordem melhor a atenuação da curva do filtro e mais pesado computacionalmente a implementação do filtro se torna.

3.2.1.2 Transformada Wavalet

A transformada Wavelet (WT - Wavelet Transform) consiste em uma transformada de Kernel variável que permite uma análise multiresolução através de Wavelets de diferentes escalas. Essas Wavelets são originadas de uma função fundamental chamada de Wavelet mãe ([MISITI et al., 2012](#)) (mother Wavelet). A WT obtêm coeficientes de correlação das Wavelets com diferentes partes do sinal à medida que a Wavelet é transladada por toda extensão do sinal com uma dada extensão de deslocamento. Essa translação é feita em todo sinal para cada uma das escalas escolhidas, permitindo com que todo o sinal possa ser comparado com Wavelets em diferentes escalas. A funcionalidade da WT depende de devidas condições, para isso a Wavelet mãe, utilizada como Kernel de transformação, deve satisfazer alguns pressupostos matemáticos, ou seja, para considerar uma função como uma Wavelet ela tem de atender as seguintes condições ([VALENS, 1999](#)):

$$\int_{-\infty}^{\infty} |\psi(t)|^2 dt < \infty \quad e \quad \int_{-\infty}^{\infty} \psi(t) dt = 0 \quad (3.2)$$

Estas condições são equivalentes a dizer que $\psi(t)$ é de quadrado integrável. As propriedades acima sugerem que $\psi(t)$ tende a oscilar acima e abaixo do eixo t , e que tem sua energia localizada em certa região, já que ela é finita. O fato de que a energia esta

concentrada numa região finita é que possibilita a análise multidimensional com a WT, para isso as transformadas, direta e inversa são definidas como:

$$WT \rightarrow X(a, b) = \frac{1}{\sqrt{S}} \int_{-\infty}^{\infty} x(t) \psi * \left(\frac{t-a}{b} \right) dt \quad (3.3)$$

$$IWT \rightarrow x(t) = \frac{1}{C_{\psi}^2} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} X(a, b) \frac{1}{s^2} \psi * \left(\frac{t-a}{b} \right) da db \quad (3.4)$$

Onde b é o fator relacionado à translação da Wavelet em regiões do sinal e a é o fator de escala relacionado à frequência ($a^{-1} \sim \text{frequência}$). Podemos transladar a função $g_{ab}(t)$ ao longo do eixo do tempo variando o fator b e assim escolher a parte do sinal a ser analisada. A repetição deste processo chamamos de varredura, para a filtragem é realizada a reconstrução dos dados, porem excluindo os coeficientes a associados ao ruído, normalmente os associados as frequências mais altas (QUIROGA et al., 2001).

Para que a inversa seja factível a função Wavelet precisa também de outra característica que chamamos de condição de admissibilidade, ou seja, a Wavelet escolhida deve respeitar a condição abaixo:

$$C = \int_{-\infty}^{\infty} \frac{|\psi(\omega)|^2}{|\omega|} d\omega \quad (3.5)$$

Olhando para a integral acima podemos perceber que o parâmetro C precisa ser finito e positivo, o que mantém e garante a estrutura de reconstrução do sinal, alguns exemplos de funções Wavelet são as funções Haar e chapéu mexicano, respectivamente:

$$\psi(t) = \begin{cases} 1, 0 \leq t < 0.5 \\ -1, 0.5 \leq t < 1 \\ 0, \text{para outros valores de } t \end{cases} \quad (3.6)$$

$$\psi(t) = (1 - t^2)e^{-\frac{t^2}{2}} \quad (3.7)$$

A função Haar é formada por funções descontínuas já a chapéu mexicano trata-se da segunda derivada da função gaussiana, o nome é devido o formato do seu gráfico que lembra um chapéu mexicano. É muito importante lembrar que a Wavelet realiza um processo de comparação da função núcleo com um trecho do sinal, logo é fácil perceber que o seu desempenho depende fortemente do núcleo escolhida. Uma vantagem se utilizar a WT para se fazer a filtragem de sinais EEG é que a perda de informação torna-se algo contornável, permitindo afirmar com alguma segurança que foi removido somente o ruído do sinal.

3.2.2 Aplicação

O foco deste estudo é analisar padrões do EEG que representem a intenção de movimento do usuário e gerar classificadores capazes de reconhecer estes padrões neurais. A literatura indica que os padrões relacionados à intenção de ações motoras se encontram entre 0.1Hz e 1Hz e são conhecidos como *slow cortical potentials* que a banda delta (HAMMON et al., 2008). Já a banda alpha que vai de 8Hz a 12Hz, corresponde a atividade motora ativa. Para os estudos de tais bandas foram utilizados dois métodos de filtragem (RABINER; GOLD; YUEN, 1978; VALENS, 1999):

A) Filtro Butterworth: aplicado como passa-banda nas faixas de 0.1Hz a 1Hz e em 8Hz a 12Hz.

B) Transformada Wavelet: aplicada em uma decomposição de múltipla ordem, isolando as bandas de 0.1Hz a 1Hz e de 8Hz a 12Hz.

3.3 DECOMPOSIÇÃO TEMPO-FREQUÊNCIA E ANÁLISE DE FASE

Em vista que o alvo de estudo é um potencial eletrofisiológico que ocorre de forma localizada no tempo e em uma frequência baixa, ou seja, um evento de pouco menos de um segundo acontecendo na faixa de frequência abaixo de 2Hz, torna-se completamente relevante utilizar, para análise, ferramentas que forneçam informações mais detalhadas do sinal. Considerando estes fatores, foram utilizadas, além das já apresentadas, duas ferramentas de análise espectral. O termo espectral no contexto de processamento de sinais se refere a análise das frequências que compõem um sinal, ou no caso espectro de frequências.

As duas ferramentas escolhidas são metodologias que transportam um sinal bidimensional para um espaço tridimensional, ou seja, um sinal no espaço tempo-amplitude é representado em um espaço tempo-frequência-amplitude, justamente o que é gerado com a decomposição tempo-frequência. Como exemplos, temos os gráficos apresentados na Figura 3, em A o sinal está na forma como mais comumente é apresentado, espaço tempo-amplitude, em B temos a representação tempo-frequência do mesmo sinal apresentado em A, nesta representação, o eixo que antes era a amplitude representa a frequência e a amplitude é representada pelo esquema de cores.

O gráfico da Figura 3-A é a média de um conjunto de amostras (trials) para um único eletrodo, neste caso isto é relevante apenas para explicitar o tipo de sinal com o qual estamos trabalhando, sendo ele uma média bruta sem a aplicação de nenhum outro processamento, essa informação será de maior importância quando abordarmos o segundo método, aqui apresentado.

3.3.1 Análise no Domínio da Frequência

Há uma grande variedade de métodos empregados para a decomposição tempo-frequência. No presente trabalho, optamos pela decomposição tempo-frequência dos registros filtrados e brutos usando a convolução do registro eletrofisiológico com uma Wavelet do tipo Morlet complexa (CMW - Complex Morlet Wavelet). A *CMW* corresponde ao produto de uma função Gaussiana, parte I em destaque na [Equação 3.8](#), com uma senoide complexa parte II em destaque na [Equação 3.8](#).

$$CMW = A \overset{\text{(I)}}{\underset{\downarrow}{e^{-t^2/2s^2}}} \cdot \overset{\text{(II)}}{\underset{\downarrow}{e^{i2\pi ft}}} \quad (3.8)$$

onde

$$A = \frac{1}{(s\sqrt{\pi})^{\frac{1}{2}}} \quad (3.9)$$

De forma mais clara, cada ponto (tempo, frequência) no gráfico do Power Spectra é gerado pela convolução entre o sinal bruto e a [Equação 3.8](#), que estará ajustada para a frequência e tempo deste ponto, pois como poderemos ver a *CMW* é uma $f(t, f)$.

Os parâmetros de ajuste utilizados afetam diretamente o desempenho de qualquer metodologia de análise. De acordo com o tipo dos sinais analisados neste trabalho, foram utilizadas as seguintes especificações:

i. Número variável de ciclos da Wavelet indo de 3 a 10 ciclos em escala logarítmica. O número de ciclos é determinado pelo valor de S , na [Equação 3.10](#) temos as configuração utilizada no presente trabalho:

$$S = \frac{[\log(3)...\log(10)]}{2\pi f} \quad (3.10)$$

O número variável de ciclos corresponde é uma das vantagens em se usar a *CMW* em detrimento de outros métodos como transformada de Hilbert ou transformada de Fourier com janelamento. Com a variação do número de ciclos da Wavelet é possível obter uma boa precisão em ambos os domínios, tempo e frequência, com menor possibilidade de prejuízo na interpretação devido ao fenômeno de smoothing.

ii. As frequências usadas para a *CMW* corresponderam às frequências em que se decompuseram os registros. Como exemplo, na decomposição do registro bruto foram usadas Wavelets com frequência variando entre 0,2 e 50 Hz. Essa é mais uma vantagem da *CMW*. As frequências são totalmente inseridas no componente senoidal da expressão [Equação 3.8](#) (componente f). Com isso, não é sempre necessário filtrar os dados antes

da decomposição tempo-frequência, ainda sem ter um controle absoluto de quais frequências serão analisadas. Algo que é impossível em outros métodos como a transformada de Hilbert.

Após a obtenção dos dados espectrais por meio da decomposição tempo-frequência (Power Spectra), os valores foram normalizados em relação a um intervalo de tempo (linha de base) correspondente a variação de base dos potenciais em cada eletrodo, para cálculo dos valores espectrais em decibel (dB), de acordo com a relação:

$$db = 10 \log_{10} \left(\frac{\text{Valores}_{tf}}{\text{linhadabase}_f} \right) \quad (3.11)$$

Onde Valores_{tf} corresponde aos valores espectrais tempo-frequência e linha de base a média dos valores espectrais no intervalo de tempo da atividade de base. Isso é feito para que os níveis de atividade do mapa estejam nivelados em relação à linha de base, que no nosso caso deve ser selecionada a uma amostra do EEG onde não estejam ocorrendo ações ou estimulações. Assim, o mapa espectral irá representar a atividade de frequência referente ao comportamento diferente do estado de repouso do sujeito.

3.3.2 Análise da Coerência de Fase

A decomposição apresentada anteriormente é uma análise feita puramente na composição de frequências de sinais. Contudo, um sinal não é completamente expressado somente por sua frequência, existem outras características assim como a fase do sinal, que é justamente o foco na metodologia apresentada a seguir.

Conceitualmente, a fase de um sinal é o atraso do ciclo de repetição em relação à origem, um problema é que a origem pode ser definida em qualquer lugar, dessa forma, uma informação mais coerente é a diferença de fase entre dois sinais. A análise de coerência de fase representa o quão alinhadas estão as fases que compõem os múltiplos sinais.

Como os valores espectrais tempo-frequência são números complexos, possuindo uma parte real e uma parte imaginária, e correspondem a vetores no plano de Argand-Gauss, isso permite que seja calculado o ângulo de posicionamento de cada um desses vetores, ou seja, descobrir a fase de cada um dos valores espectrais. Como nesse procedimento o que interessa é o ângulo que o vetor faz com o eixo dos reais, cada vetor foi previamente normalizado para o valor unitário. O cálculo da coerência de fase (CF) é feito promediando os vetores através das amostras (trials). O cálculo pode ser expresso pela relação apresentada na [Equação 3.12](#).

$$CF = \left| n^{-1} \sum_{r=1}^n e^{i\theta(tf)} \right| \quad (3.12)$$

Onde, n é o número de trials e θ corresponde precisamente a fase do vetor. O cálculo é realizado para cada frequência a ser analisada. Ao analisar uma faixa de frequências, forma-se o gráfico apresentado na [Figura 4](#), que foi gerado pelos mesmos dados da [Figura 3](#), sendo analisada a banda de frequência de 0.2 Hz a 2Hz.

A coerência de fase é uma medida muito importante porque expressa um estado funcional que pode ser o produto de vários fenômenos. Se a coerência de fase é alta para um dado eletrodo através dos trials e em bandas específicas de frequência, isso significa que os sinais provenientes desse eletrodo mostram uma consistência temporal de atividade que pode estar sendo gerada por aferência de outras áreas e que por conseguinte são o produto de uma estado funcional estável. Saber se estado está relacionado com a tarefa a que o indivíduo está submetido dependerá da correspondência entre o intervalo de tempo que se está observando a coerência de fase e as características comportamentais. Como no presente trabalho pretendemos construir relações causais entre padrões de alteração do EEG e intenção no desempenho de uma dada tarefa, a coerência de fase foi analisada em intervalos de tempo na vizinhança do tempo em que ocorreu a tarefa.

3.4 PARADIGMAS RELACIONADOS AO BCI

3.4.1 Dessincronização e Sincronização Associada a Eventos

A Dessincronização Associada a Eventos, ou ERD (*Event-Related Desynchronization*), consiste em um dos comportamentos do cérebro ao se executar uma ação. O cérebro trabalha de forma que entre um estado de repouso e a execução de uma ação acontece uma dessincronização na região responsável pelo controle de tal ação. Exemplo, quando realizamos algum movimento com uma das mãos ocorre uma dessincronização no córtex motor primário contralateral e uma relativa sincronização no córtex motor ipsilateral, sincronização associada a evento ou ERS (*Event-Related Synchronization*). Tais efeitos acontecem principalmente nas bandas μ (8-12 Hz) e β (12-30 Hz), o condicionamento destes padrões de sincronização pode ser associado a eventos e a comandos, de forma que ao usuário basta reproduzir tais padrões, tarefa que pode ser realizada através de ações imaginativas.

3.4.2 Paradigma Go No-Go

O paradigma *go no-go* consiste em expor um sujeito a uma situação onde ele deverá realizar uma tarefa, mas somente quando lhe for autorizado ([GANGADHAR; CHAVARRIAGA; R.MILLAN, 2009](#)), gerando assim dois momentos ou épocas, uma onde o sujeito já saberá a ação a ser realizada, mas sem poder executar a mesma, e um segundo momento onde a ação deverá ser realizada, épocas *no-go* e *go* respectivamente, é importante sali-

entar que a época *go* é um período prévio a execução da ação, por isso, sua identificação fornece um ponto onde se sabe que uma ação será realizada.

Já foi mostrado ser possível à diferenciação das duas épocas (GARIPELLI; CHAVARRIAGA; MILLAN, 2011), o que pode ser uma ferramenta útil no desenvolvimento de sistemas BCI. Contudo existem outros contextos onde o paradigma pode ser explorado, com o propósito de analisar as possibilidades de diferenciação em outras situações, foi desenvolvida uma metodologia para a realização de experimentos onde o paradigma *go no-go* possa ser observado, mais detalhes na sessão matérias e métodos.

3.5 MODELOS DE APRENDIZADO PARA RECONHECIMENTO DE PADRÕES

Algoritmos de aprendizado supervisionado são ferramentas que buscam, a partir de amostras fornecidas, produzir modelos capazes de fazer previsões sobre casos futuros. Em outras palavras, o objetivo do aprendizado supervisionado é, de maneira concisa, gerar um modelo capaz de realizar o reconhecimento de classe, isso é feito a partir de amostras cuja as classes já são conhecidas, utilizadas para treinar o modelo, sendo capaz de fornecer uma classificação de novas amostras entre as classes do modelo, por isso também são conhecidos simplesmente como classificadores.

Foram utilizados neste trabalho duas metodologias para classificação, a análise discriminante linear ou LDA (*Linear Discriminant Analysis*) e a análise discriminante quadrática ou QDA (*Quadratic Discriminant Analysis*). A partir de uma base de treinamento, padrões que sejam de classes conhecidas, a análise de discriminante procura gerar uma métrica dentro do espaço onde a base de treinamento esta distribuída de forma a dividir as classes presentes da melhor maneira possível, contudo, os parâmetros necessários para uma classificação de qualidade podem mudar de acordo com a composição dos dados utilizados, para lidar com isso são utilizados diferentes critérios para gerar a métrica de divisão de classes. Em outras palavras a análise discriminante faz uma linha entre os membros de cada classe, de forma que ao ser apresentada uma nova amostra, ela é classificada conforme a área onde ficar posicionada; vejamos a [Figura 5](#) para entender melhor.

A figura ainda nos permite fazer duas observações, o LDA realiza uma divisão linear ou uma linha reta enquanto o QDA gera uma curva quadrática (FISHER, 1936), é importante observar que se invertêssemos os grupos apresentados na figura acima eles não seriam devidamente separados e ainda poderiam ocorrer erros, por esse motivo testamos os dois métodos, na intenção de encontrar os melhores resultados. Outros métodos foram testados, mas não serão apresentados por não terem obtido bons resultados neste trabalho.

A preparação dos algoritmos de aprendizado, para gerar um modelo classificador, é um procedimento comumente denominado de treinamento, que consiste basicamente em uma série de ajustes aplicados ao modelo, de forma a melhorar seu desempenho, já a melhora do modelo só pode ser acompanhada pela realização concomitante da validação. A validação é realizada aplicando o modelo gerado em um conjunto de dados já conhecido, dessa forma, pode-se contabilizar o percentual de acerto do modelo, dependendo deste resultado o próximo ajuste é definido, mais detalhes dos procedimento de validação serão apresentados nas seguintes sessões.

3.5.1 Método de Validação

Para poder fazer a seleção do “melhor” modelo, ou algoritmo de classificação, entre um conjunto de modelos competidores, é preciso avaliar alguns critérios. Uma abordagem comum e predominante é equilibrar a qualidade do ajuste do modelo com parcimônia¹. A qualidade do ajuste determina o quão bem o modelo descreve os dados. No entanto, com o aumento da complexidade dos modelos e o aumento da quantidade de características, esta-se sujeito a *overfitting*². Com o balanceamento da complexidade do modelo e a qualidade do ajuste do mesmo, é possível desenvolver modelos com menos erros de generalização (SYED, 2011).

Existem basicamente dois tipos de métodos de avaliação baseados no erro de generalização, erro por ressubstituição e erro por validação cruzada. O erro por ressubstituição é uma taxa de erro dos dados de treinamento, que é estimada pela diferença entre os valores de predição do modelo treinado e os valores observados nos dados de treinamento. Ou seja, os mesmos dados usados para treinar o modelo são usados para avaliar a precisão do mesmo. Por este motivo usaremos a validação cruzada que mensura o erro do modelo utilizando um conjunto diferente de amostras, algo mais semelhante ao que é realizado em sistemas BCI online.

3.5.2 Validação Cruzada

A validação cruzada é um método usado para medir o erro de generalização usando dados de validação ou controle. É uma técnica comumente utilizada para fazer seleção de modelos. Seu procedimento geral se dá pela partição dos dados em subconjuntos de treinamento e de teste. O treinamento é o processo de ajustar um modelo, enquanto que o teste é o processo de validar o modelo treinado através da medida do erro de predição. Os dados de treinamento e teste são disjuntos, portanto os dados de teste para a validação do modelo não são usados no treinamento, o que o diferencia do erro por ressubstituição.

¹ Parcimônia é o ato ou costume de economizar, de poupar; economia.

² O modelo descreve muito bem a base de treinamento, mas não consegue classificar com acurácia novas amostras.

Mais formalmente, a partir de um conjunto de dados $D = \{(X_i, y_i), \quad i = 1, \dots, n\}$ deseja-se avaliar um modelo M para a obtenção de um conjunto correspondente de valores de predição $\hat{y}_i, \quad i = 1, \dots, n$. É possível particionar o conjunto de dados D em dois subconjuntos: $D = D_1 \cup D_2$, com k dados em D_1 e $n - k$ dados em D_2 . O conjunto de dados em D_2 é usado para o treinamento do modelo M , portanto D_2 é chamado de *conjunto de treinamento*. Depois, o modelo treinado M é usado para se obter predições de observações \hat{y}_{D_1} dado X_{D_1} , portanto D_1 é chamado de *conjunto de teste*. Existem $\binom{n}{k}$ possíveis partições do conjunto de dados, e esse processo pode ser repetido várias vezes. A estimação do erro por validação cruzada é a média dos erros de predição dos conjuntos de teste usados, o que é uma estimação do erro de generalização do algoritmo de classificação usado em um conjunto de teste independente (CLARKE; FOKOUÉ; ZHANG, 2009).

3.5.3 *K-fold*

A validação cruzada *K-fold* é um procedimento alternativo, e visa diminuir o custo computacional do método *leave-one-out*. Este método se torna atraente pois ele equilibra o custo computacional com um aumento da estimação do viés ou tendenciosidade. Neste procedimento, o conjunto de dados D é dividido em K partições de tamanhos aproximadamente iguais, $D = \cup_{k=1}^K D_k$, e a cada partição é dado o nome de *fold* do conjunto de dados (portanto existem K *folds*). O modelo é treinado usando $K - 1$ *folds* para o treinamento, e o *fold* restante é usado para teste. Este procedimento é repetido K vezes de forma que cada *fold* é usado para teste apenas uma vez (CLARKE; FOKOUÉ; ZHANG, 2009). Quando $K = n$ obtemos a validação cruzada *leave-one-out*, ou seja, cada amostra do conjunto de dados é considerada um *fold* e utilizada para validação de um modelo que foi gerado utilizando todo o resto da base de dados no treinamento.

Uma função de indexação $\kappa : \{1, \dots, n\} \rightarrow \{1, \dots, K\}$ é definida como um esquema para a atribuição aleatória dos dados i para um *fold*. Deixando de fora o *fold* k e treinando o modelo com $k - 1$ *folds*, resulta na estimação da função do modelo $\hat{f}^{-\kappa(i)}$, isto é feito de forma que cada *fold* tenha uma boa representatividade³ da base. A estimação do erro da validação cruzada *K-fold* é dada por:

$$KCV = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}^{\kappa(i)})^2 \quad (3.13)$$

O método de validação cruzada *K-fold* é o método mais aplicado, por oferecer boa parte das vantagens do método *leave-one-out* mas com um custo computacional bem menor (SYED, 2011). Neste trabalho foi utilizado uma validação cruzada *4-fold*.

³ Do contrário um *fold* poderia conter mais amostras de um padrão, e conseqüentemente o modelo gerado seria tendencioso

3.5.4 Acurácia da Classificação e Taxa de Erro

A acurácia da classificação (ACC) ou a taxa de erro ($ERR = 1 - ACC$) são as métricas mais amplamente usadas em problemas de classificação. Um possível motivo para sua popularização é que ele pode ser facilmente calculado e interpretado. Porém, é importante notar que a acurácia de um classificador qualquer já é $100\%/M$, (e.g. para $M = 2$ classes 50% são corretamente classificadas por acaso). Se o valor de ACC é menor que este limite, algum erro ocorreu e é preciso investigar este erro. Por outro lado, a acurácia máxima não pode exceder 100%. A acurácia da classificação é calculada como:

$$ACC = p_0 = \frac{\sum_{i=1}^M n_{ii}}{N} \quad (3.14)$$

Algumas das limitações da acurácia da classificação como critério de avaliação estão baseadas nos fatos de que a acurácia da classificação para classes menos frequentes, nos casos de dados não balanceados, apresentam um peso menor (SCHOGL *et al.*, 2007), assim dependendo da base de dados este tipo de problema pode ser inevitável, contudo tais fatores foram levados em consideração, de forma a não termos esse tipo de problema nos dados coletados neste trabalho.

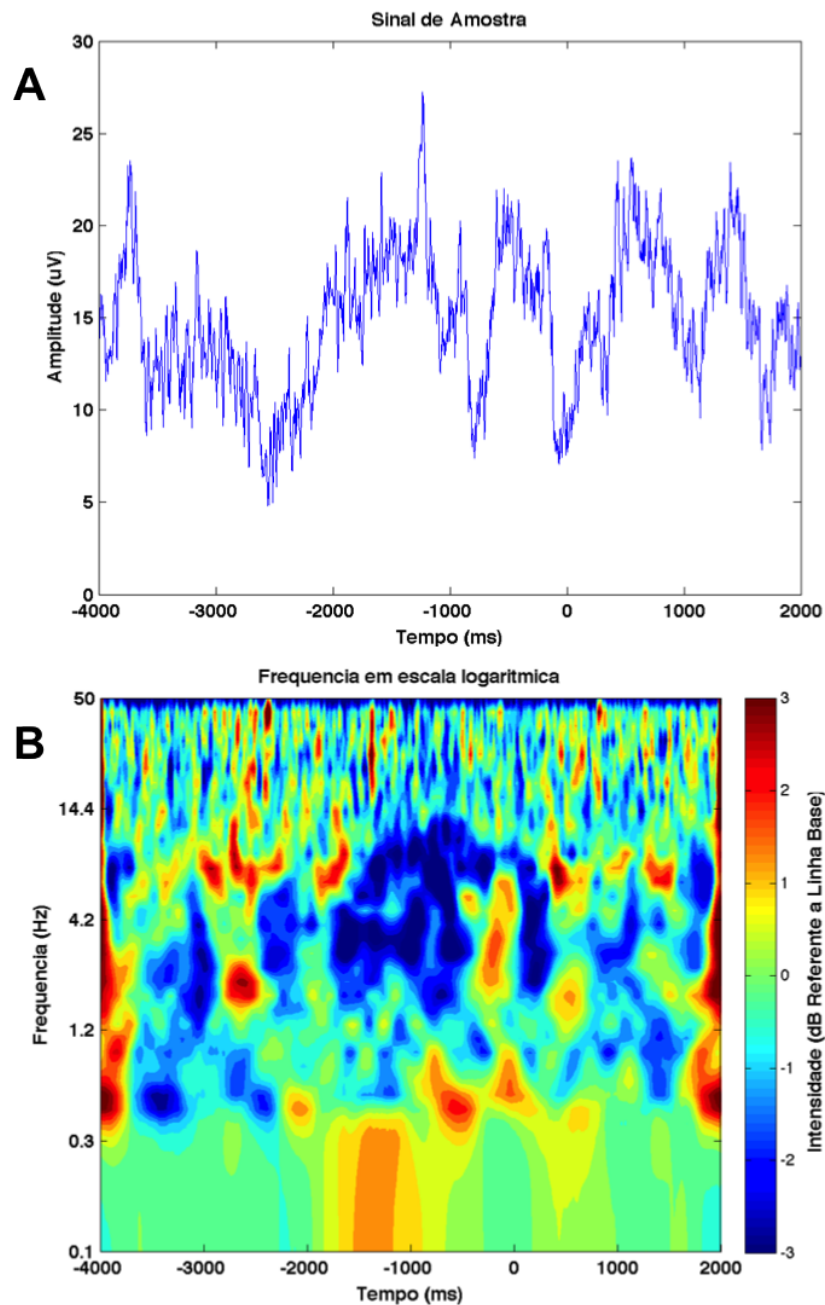


Figura 3 – A) Média dos dados brutos de um eletrodo e para uma sessão de amostras, estes dados são provenientes dos registros realizados para este trabalho, B) representação tempo-frequência dos dados apresentados em A, neste gráfico o eixo horizontal ainda representa o tempo, a variação de cores representa a variação de intensidade e o eixo vertical representa a faixa de frequência, que é a dimensão adicional obtida por este método, observando que esta informação é obtida de forma inteiramente adicional, sem se perder o eixo temporal e ainda com um ótimo nível de detalhe quanto a distribuição da intensidade das frequências.




Figura 4 – exemplo da análise de coerência de fase, tendo uma representação semelhante ao apresentado na [Figura 3](#), porém neste método, as cores representam a sincroniza das fases que compõem as múltiplos amostras analisadas, que para a elaboração deste gráfico foi utilizado o mesmo conjunto que para [Figura 3](#).



Figura 5 – Exemplificação do funcionamento e diferença entre dois tipos de classificadores, LDA e QDA, ambos estão dividindo perfeitamente diferentes grupos de duas classes, porém, é importante ressaltar que ao inverter essa situação dificilmente o LDA realizaria uma boa divisão no grupo que o QDA tem um melhor desempenho, o inverso também é válido.

4 MATERIAIS E MÉTODOS

4.1 Sujeitos

Este estudo teve a participação de cinco sujeitos saudáveis, com visão normal ou corrigida, dois deles dirigem com frequência e um destes é canhoto, todos do sexo masculino com idades entre 21 e 27 anos.

Critérios de inclusão: Ausência de queixa visuais; Ausência de deficiências motoras.

Critérios de exclusão: Presença de doenças sistêmicas. Presença de doenças oculares (Catarata, Conjuntivite, Dentre outras); Pessoas portadoras de epilepsia; Pessoas diagnosticadas com qualquer nível de autismo.

4.2 Emotiv Headset

Para aquisição do EEG foi utilizado o neuro-headset Emotiv Epoc, que pode ser visto na [Figura 6](#) dispondo de 14 eletrodos salinos, os eletrodos consistem de esponjas de feltro que quando humidificadas com uma solução salina fecha o contato entre o couro cabeludo e o *headset*. Os dados são enviados do capacete ao computador a uma taxa de amostragem de 128Hz através de uma conexão sem fio. Os 14 eletrodos são posicionados de acordo com o sistema 10-20, sendo todos fixos em posições predefinidas pelo fabricante (ODOM et al., 2010) ([Figura 14](#)). Informações mais detalhadas do *headset* podem ser vistas na [Tabela 1](#).

Emotiv Headset	
Numero de Canais	14 mais dois referências, CMS/DRL em P3/P4
Posição dos Canais (Sistema 10-20)	AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8, AF4
Método de amostragem	Amostragem sequencial
Taxa de amostragem	128 Hz (Frequência interna 2048 Hz)
Resolução	14 bits 1 LSB = $0.51\mu\text{V}$
Faixa de atuação	0.2 - 45Hz, filtro digital tipo not em 50Hz e 60Hz
Filtro interno	Filtro digital de quinta ordem
Alcance dinâmico (Referente a entrada)	$8400\mu\text{V}$ (pp)
Conexão	Wireless proprietario na banda 2.4GHz
Bateria	Bateria de polímero de lítio
Autonomia	12 hours
Medição da impedância	Monitoramento dos contatos em tempo real utilizando sistema patenteado

Tabela 1 – Especificações de funcionamento do *Emotiv headset*, equipamento desenvolvido com características voltadas para aplicação em BCI, fornecendo uma usabilidade prática e dinâmica.



Figura 6 – EEG *neuro-headset* *Emotiv EPOC*, desenvolvido para aplicação em BCI, foi adquirido para realização dos registros de dados neste trabalho, dispondo de 14 canais e transmissão sem fio.

4.3 Softwares Utilizados

Foram utilizadas duas ferramenteas fornecidas junto com o Emotiv Headset. A primeira consiste no Emotiv Control Panel, utilizado para monitorar o nível da bateria, a qualidade da conexão com o headset e a qualidade do posicionamento dos eletrodos, representada por um sistema de cores, ver [Figura 7](#). A segunda é o *Test Bench* que dispõe de uma janela que apresenta os últimos 10 segundos de registro, como na [Figura 8](#), permitindo identificar e marcar comportamentos anormais em tempo real.

O ambiente de simulação utilizado é o jogo de corrida “Trackmania Nations Forever[®]”. Este ambiente foi escolhido por possuir uma plataforma para construção de circuitos. Isto possibilita criar uma pista com curvas, obstáculos e *checkpoints* em locais específicos, minimizando eventos como presença de outros carros na pista, pedestres, sinalizações verticais, ou outras possíveis distrações visuais. Que são elementos indesejados durante o experimento, a [Figura 9](#) apresenta a visão que o sujeito tem durante o experimento. O ideal para este trabalho seria a construção de um ambiente virtual específico para nossas necessidades, permitindo a adaptação detalhadas do trajeto. O que não foi feito devido questões de prazos e orçamento do projeto. Sendo a plataforma selecionada a melhor dentre varias que foram testadas.

Para dar suporte ao funcionamento integrado destes componentes foi desenvolvido um projeto em C++ que realiza uma conexão com o Emotiv Headset para receber os

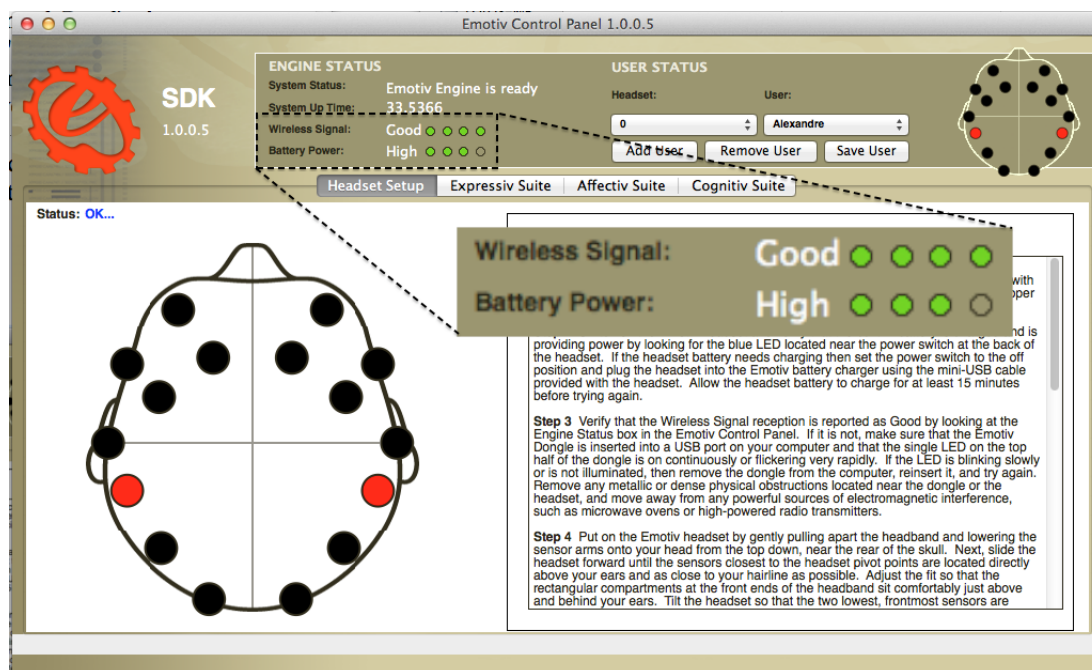


Figura 7 – Interface do Emotiv Control Panel, software que realiza a conexão do neuro-headset Emotiv Epoc com o computador, destacando o indicador de qualidade de sinal e de nível de bateria, região ampliada indicada pelas linhas tracejadas, ainda à esquerda da figura podemos ver a representação esquemática do posicionamento do eletrodos, aqui é representado por cores a qualidade dos sinais proveniente de cada eletrodo, este elemento é utilizado para monitoramento em tempo real da conectividade dos eletrodos.

dados do EEG de forma sincronizada com as marcações de eventos do experimento, ver Figura ??.

Também foi desenvolvida em Matlab a aplicação Edittool, Figura 11, que permite excluir amostras inválidas, análise visual dos dados, detecção de erros e seccionar o dados em amostras, remoção das amostras onde o sujeito tenha de movido (o que pode gerar interferência devido os potenciais musculares). Também são extraídas as janelas necessárias para a análise do paradigma *go no-go*.

4.4 Detalhamento do Experimento

O experimento consiste na realização de voltas em um circuito, onde o sujeito controla um carro em um ambiente virtual. Durante a direção será feito o resgistro do EEG junto com a marcação dos específicos eventos. Para isso, foi desenvolvido um circuito contendo curvas padronizadas de forma a gerar reprodutibilidade das amostras.

Cada amostra consiste na janela de dados do EEG registrada durante a realização de uma curva. Tais janelas são posicionadas com referência ao ponto de marcação do início da curva, mais detalhes do seccionamento dos dados serão apresentados a seguir.

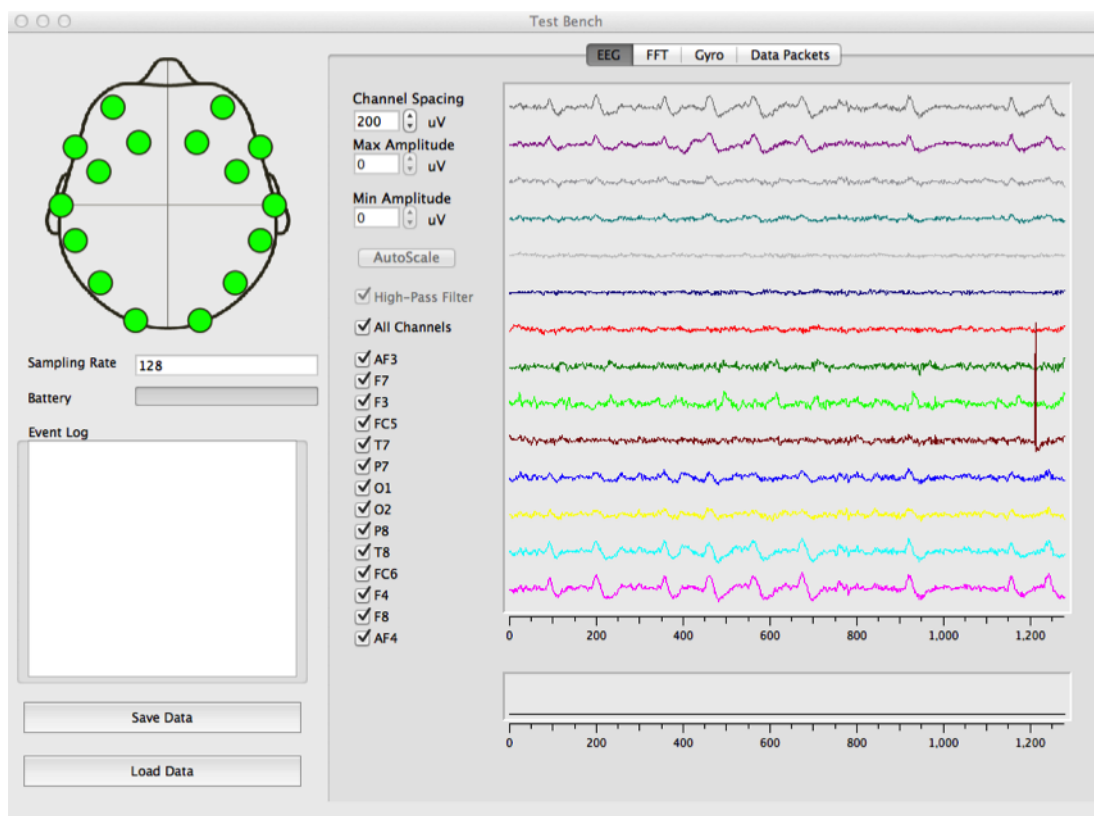


Figura 8 – Software que faz parte de conjunto de ferramentas que acompanham o neuro-headset Emotiv EPOC, o Test Bench pode funcionar em conjunto com o Control Panel, com ele é possível monitorar o EEG em tempo real de registro, os sensores giroscópios e a FFT em tempo real. Durante os registros o Test Bench foi utilizado para monitoramento do EEG para marcação e posterior remoção de comportamentos anômalos, como potenciais musculares provenientes de piscadelas, ranger de dentes ou mesmo movimentação do pescoço.

Na Figura 12 estão identificados os trechos e pontos principais que compõem a estrutura do circuito desenvolvido para o experimento. O sentido do trajeto vai de A para C, os marcadores indicados pelas setas azuis são *checkpoints* que precedem às curvas utilizadas como amostras, neste ponto será emitido o sinal sonoro. O trecho C evidencia uma das curvas não utilizadas como amostra. O trecho A é reservado para normalização do comportamento e ajuste do carro na pista. Finalmente, o trecho B, posicionado entre *checkpoints* e curvas, é onde o padrão de antecipação de movimento é buscado, este possui um tamanho fixo em todo o percurso. Na Figura 13 podemos ver o circuito completo contendo um número de curvas demarcadas, que seguem a métrica apresentada, igual para ambos os tipos de curvas, esquerda e direita. O circuito também é projetado a minimizar o efeito de aprendizado do circuito, de forma a evitar que o sujeito saiba para que lado é a próxima curva antes que ela chegue.

O controle do carro é realizado através de duas teclas, sendo que cada tecla é pressionada com a mão correspondente ao sentido da curva. Este método de controle foi



Figura 9 – Visão do usuário durante o experimento, o ambiente de simulação dispõe vários ângulos de visão, no experimento utilizamos a visão em terceira pessoa, que permite uma ampla visualização da posição do carro em relação a pista e da aproximação da curva.

escolhido para facilitar a diferenciação dos padrões esquerda e direita. Isso ocorre pois atividades motoras de cada mão são processadas pelo hemisfério contralateral do cérebro, gerando uma resposta lateralizada de modo que durante o experimento a atividade de cada mão resulta em respostas distribuídas de formas diferentes entre os eletrodos de cada hemisfério (PFURTSCHELLER; NEUPER, 2010).

Para que o sujeito realize apenas as ações de curva, foi inserido no experimento um sistema para o controle automático da aceleração, mantendo uma velocidade média de $99,2\text{Km/h} \pm 9,5\text{Km/h}$. Essa configuração foi a mais próxima possível à velocidade constante, pois o ambiente de simulação dispõe apenas os controles de aceleração total e frenagem.

O usuário é orientado a manter a direção no centro da pista, evitando manobras bruscas. Ao ouvir o sinal sonoro ele deve manter a direção em linha reta manobrando somente para fazer a curva. Antes de começar os registros é realizada uma volta no circuito para se familiarizar com o controle e direção do carro.

4.5 Parâmetros de Análise

Para cada amostra selecionada, foram analisados três segundos de registro prévios a cada curva. De acordo com (HAMMON et al., 2008) e (GARIPELLI; CHAVARRIAGA;

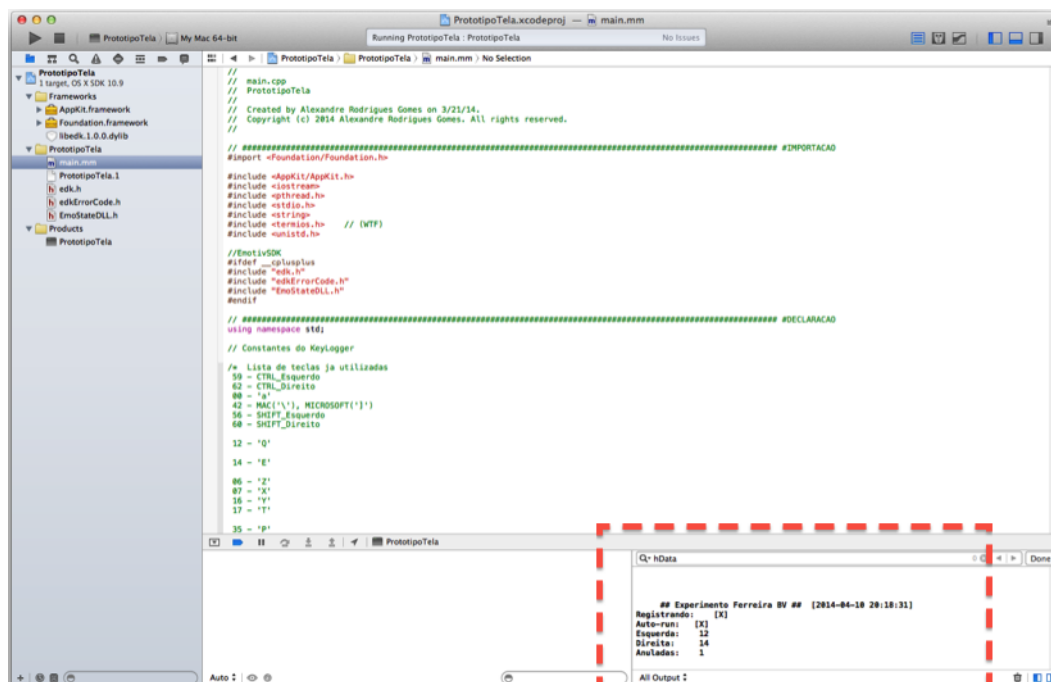


Figura 10 – Tela do projeto no IDE Xcode, a maior parte do que pode ser visto é apenas a IDE de desenvolvimento do Xcode, temos o destaque apenas do canto inferior direito, região dentro do tracejado em vermelho, onde durante os experimento temos um *feedback* informando o número de voltas realizadas para cada lado e o número de amostras anuladas, informações importantes para quem estiver aplicando o experimento.

MILLAN, 2011), janelas de um segundo são suficientemente grandes para a detecção dos potenciais corticais lentos. Por estarmos interessados na intenção da ação, posicionamos a amostra de modo que ela terminasse no ponto de inicio da curva.

A análise também foi realizada em dois grupos de eletrodos escolhidos por análise quantitativa visual. Utilizando a ferramenta Edittool, cada amostra escolhida foi inspecionada visualmente em busca dos padrões associados à atividade dos potenciais lentos. Os eletrodos que apresentavam com mais frequência os padrões relacionados aos potenciais corticais lentos foram utilizados nos testes de classificação. Foram selecionados os eletrodos mais internos ao topo da cabeça do usuário, conforme apresentado na Figura 14.

Os eletrodos AF3, AF4, F7 e F8, posicionados de acordo com o sistema 10-20 (ODOM et al., 2010), foram descartados por registrar uma grande ocorrência de interferência proveniente dos músculos da face, principalmente do movimento ocular e das sobrancelhas. Os eletrodos T7 e T8 foram excluídos por registrar quantitativamente uma baixa ocorrência de padrões corticais lentos. A Figura 15 é uma representação esquemática do posicionamento do *headset* em que pode ser visto a posição dos referidos eletrodos.

Os eletrodos foram divididos em dois grupos de acordo com seu posicionamento. O grupo frontal é formado pelos eletrodos que estão posicionados sobre o córtex motor (F3,




Figura 11 – Interface da aplicação Edittool desenvolvida em Matlab, para seleção de amostras e subdivisão do registro contínuo proveniente do experimento, com esta aplicação podemos visualizar o registro dos 14 eletrodos e as marcações de eventos, linha vertical vermelha representando o sinal sonoro e as azuis comandos de curva.

F4, FC5, FC6), enquanto o grupo occipital é formado pelos eletrodos posicionados sobre o córtex visual (P7, P8, O1, O2), como pode ser visto na [Figura 16](#). O córtex visual também processa informações referentes aos eventos, portanto, existe a relevância de estender este estudo ao conjunto occipital de eletrodos.

Para testar o paradigma *go no-go* é necessário subdividir o intervalo escolhido para a análise. Estas subdivisões são chamadas de janelas. Fica a cargo do sujeito a escolha do momento ideal para realizar a curva. Portanto, a última janela é associada ao parâmetro *go* enquanto as anteriores a essa são associadas ao parâmetro *no-go*.

Em outros trabalhos foram utilizados janelas de um e dois segundos ([HAMMON et al., 2008](#); [GARIPELLI](#); [CHAVARRIAGA](#); [MILLAN, 2011](#)). Porém, em nossos testes foram utilizadas janelas de meio e de um segundo, as quais serão referidas como janela curta e janela longa respectivamente, como mostrado na [Figura 17](#).

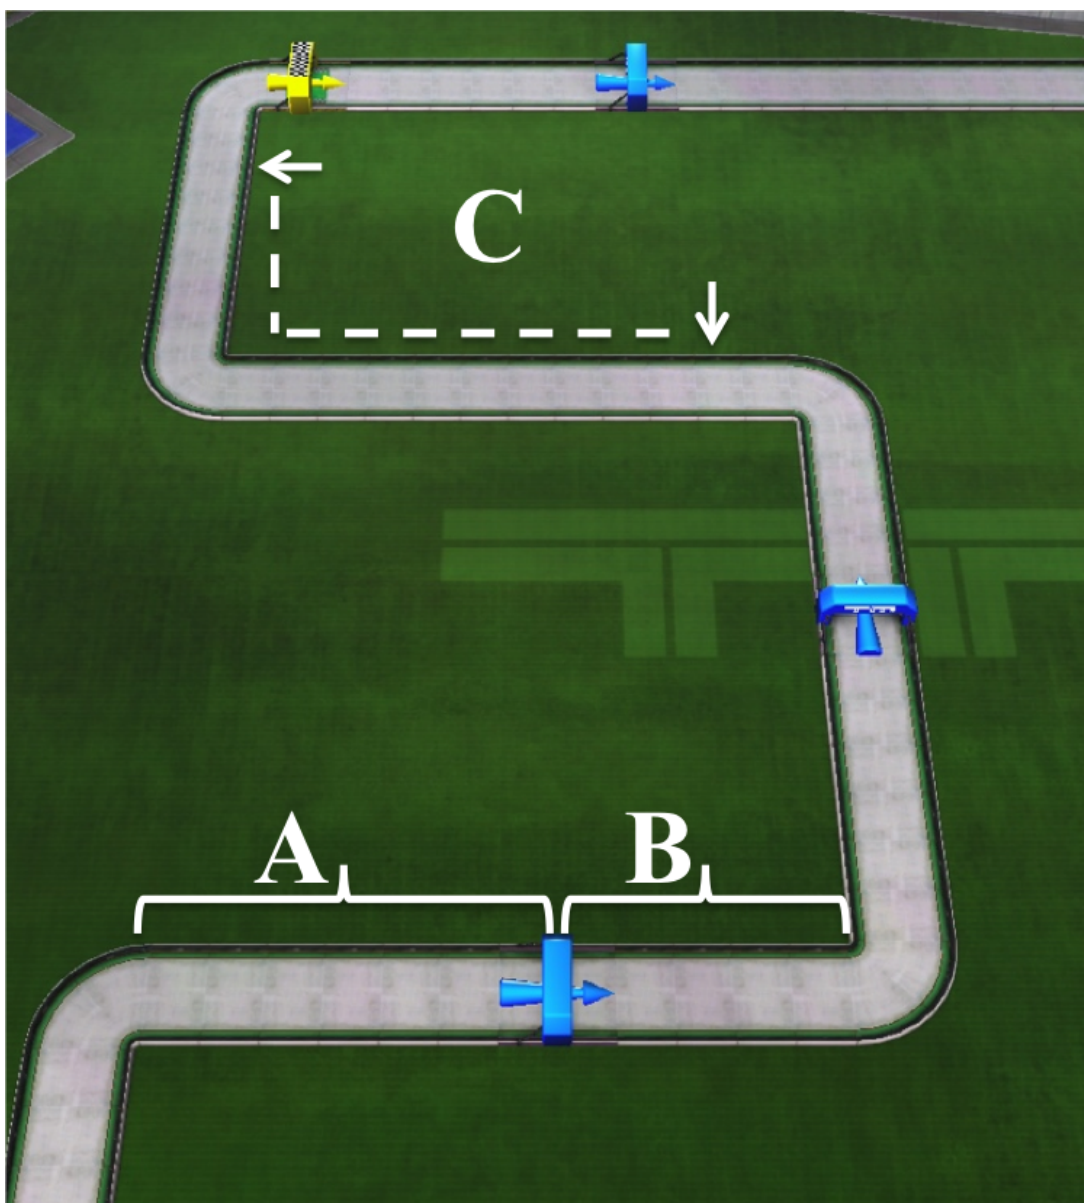


Figura 12 – Visão superior de um Trecho do circuito utilizado no experimento, o circuito é percorrido no sentido indicado pelas setas azuis, ou seja de A para C, as marcações A e B correspondem as métricas utilizadas em cada curva, sendo A) região prévia ao sinal sonoro, que tem um comprimento mínimo provendo espaço suficiente para o sujeito alinhar o carro antes do beep, B) região de busca dos padrões, esta tem um tamanho fixo de forma que as amostras sejam padronizadas e reproduzíveis e C) uma curva não utilizada para realização de registro, mesmo que o EEG seja registrado ao longo de todo o percurso esta curva não segue os padrões A e B, por isso ela não será utilizada como amostra.

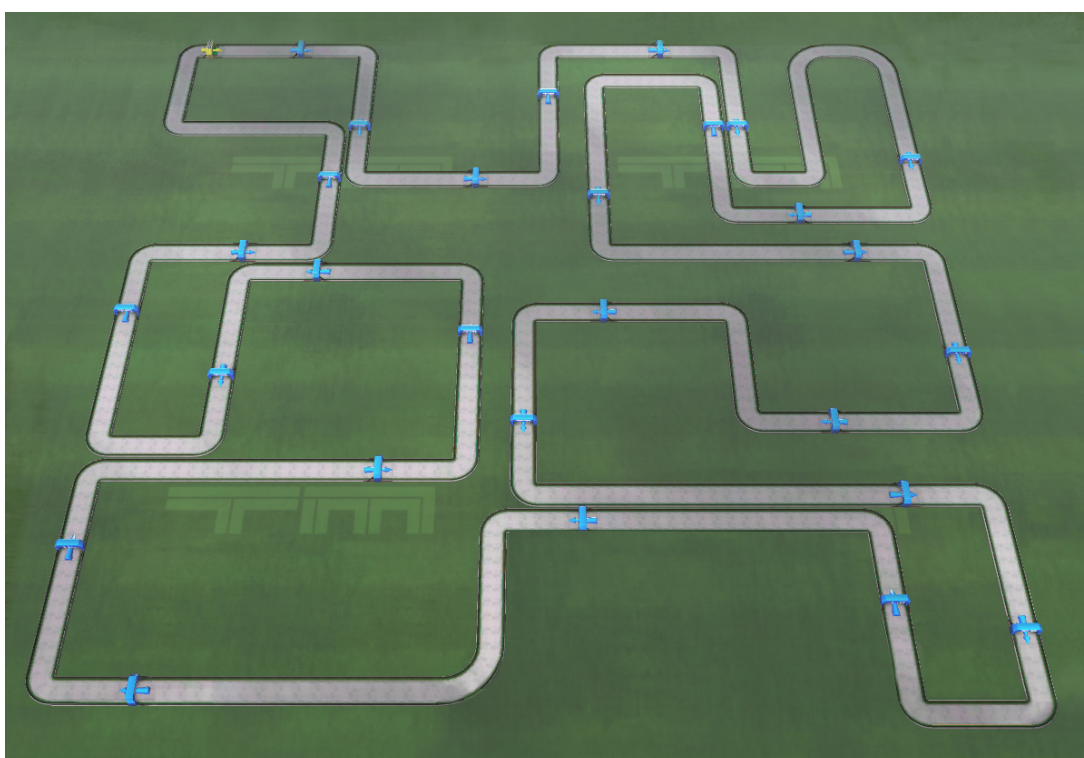


Figura 13 – Visão superior completa do circuito realizado no experimento, onde as curvas antecedidas pelas marcações azuis seguem uma métrica de padronização para gerar reprodutibilidade entre as amostras, o trajeto foi desenvolvido de forma a conter o mesmo número de curvas para cada lado, equilibrando assim o número de amostras obtidas para cada tipo de padrão. O formato do circuito foi projetado para minimizar o efeito de aprendizado, ou seja, dificulta que o sujeito decore as curvas.

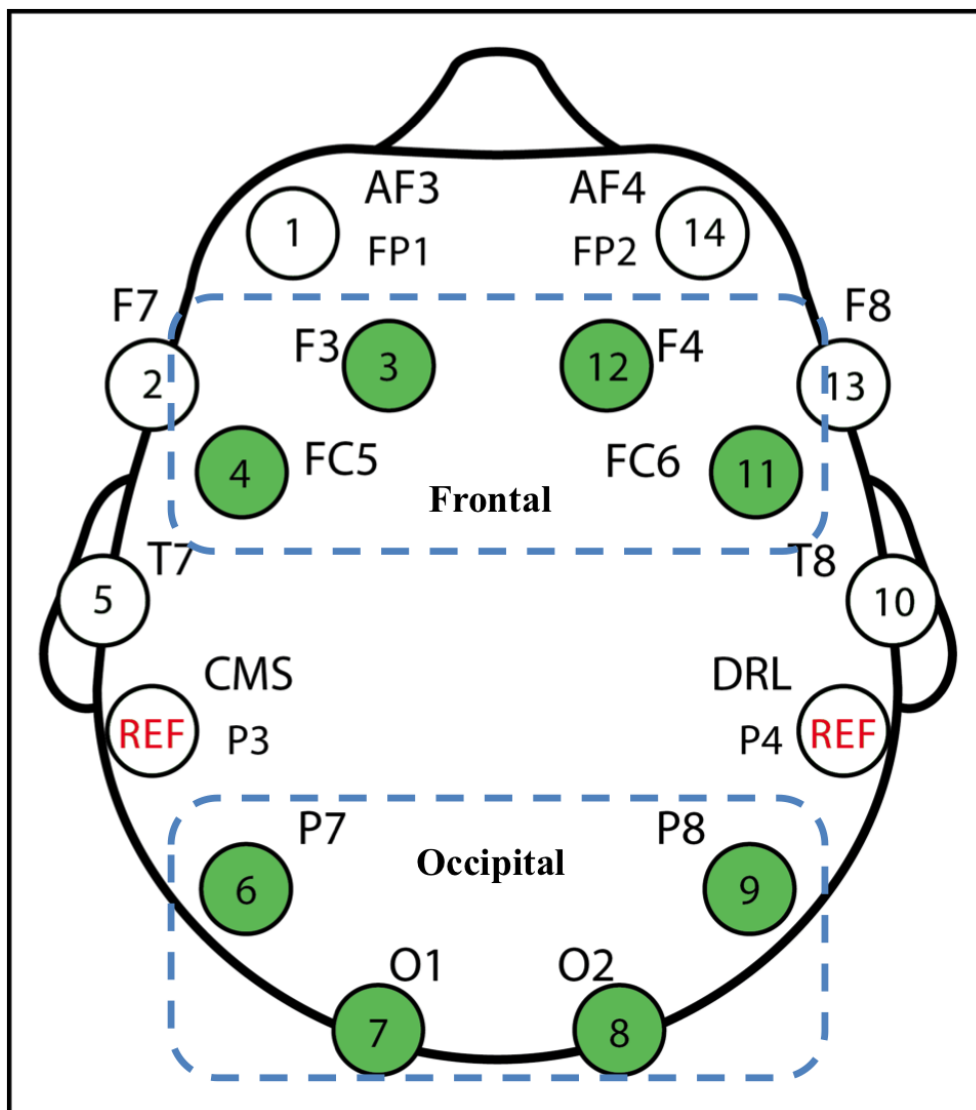


Figura 14 – Representação da localização dos eletrodos do EEG Emotiv EPOC Headset de acordo com o sistema 10-20 de posicionamento. Destacando os grupos utilizados na análise dos dados, frontal: F3, F4, FC5, FC6 e Grupo occipital: P7, P8, O1, O2. Os eletrodos são numerados e também estão identificados de acordo com o sistema 10-20.

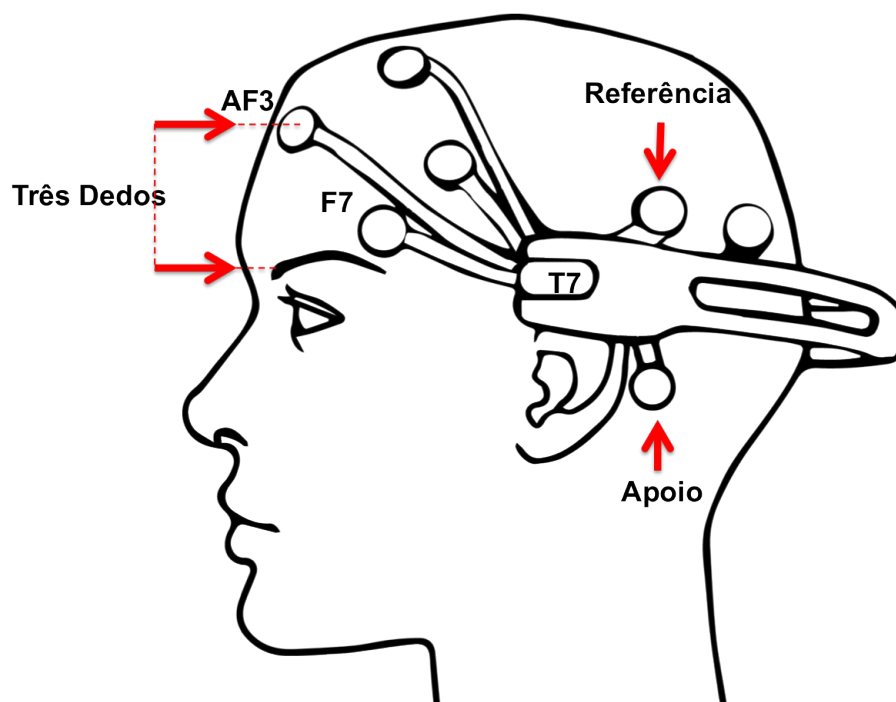


Figura 15 – Representação esquemática do posicionamento do Emotiv Headset. As duas setas vermelhas horizontais demarcam a distância entre os eletrodos mais frontais e as sobrancelhas, esta condição é importante pois determina a posição dos eletrodos F3, F4, FC5 e FC6 que devem estar sobre o córtex motor. Os apoios não são eletrodos, estão indicados devido suas posições, em relação as orelhas, ser importante, pois ajusta os eletrodos occipitais como O1 e O2.

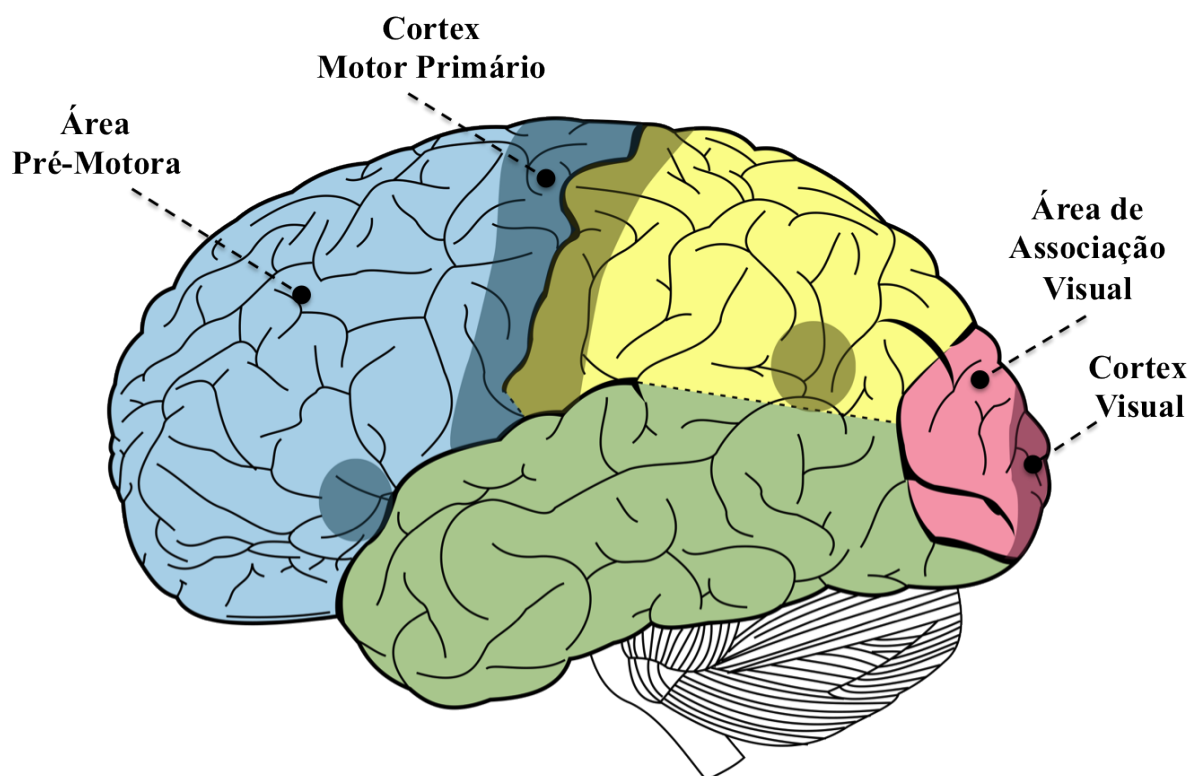


Figura 16 – Visão lateral de uma representação esquemática da distribuição do córtex cerebral. Destacadas as regiões do córtex motor primário e a área pré-motora, pontos de maior interesse neste trabalho. O córtex visual e a área de associação visual também foram destacadas, pois também serão analisadas.

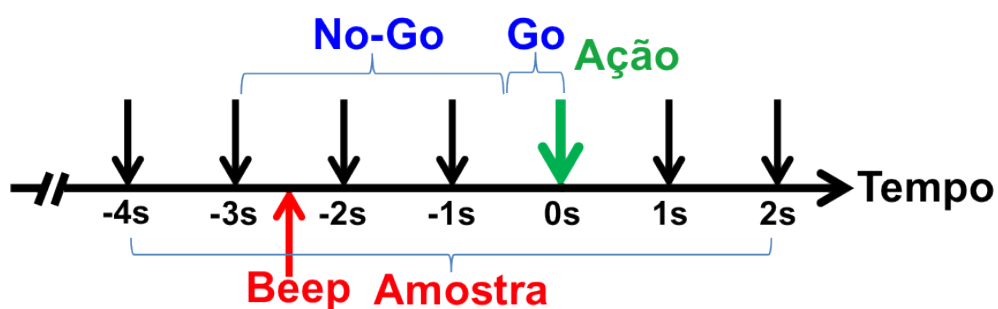


Figura 17 – Sequência dos eventos durante cada curva do experimento. A marcação temporal está de acordo com a divisão das janelas para a amostragem dos dados, por isso o ponto tempo igual a zero está alinhado com a ação. Dessa forma os eventos estão dispostos antes e depois da ação, com o período *Go* imediatamente anterior a ação que é antecedido pelo período *No-Go*, após a ação temos o período onde ocorre o potencial ativo, assim, todas as possíveis divisões dos dados se apresentam de acordo com o *pipeline* apresentado.

5 RESULTADOS

5.1 Potenciais Relacionados à Antecipação de Eventos

A [Figura 18](#) apresenta as médias do EEG de todas as amostras (os quatro dias de registro) para dois sujeitos, dos eletrodos F3 e F4, posicionados sobre cada uma dos hemisférios (esquerdo e direito respectivamente). Os gráficos apresentam duas curvas, uma para cada tipo de amostra, a média foi calculada separadamente para cada um dos tipos (esquerda curva verde pontilhada e direita linha contínua amarela). Em ambos pode ser visto um decaimento de potencial que inicia em torno de -2,8s, logo após o beep que acontece em torno de -3s (indicado pela linha azul contínua, as linhas azuis pontilhadas representam o desvio padrão). O decaimento é seguido de uma elevação não tão intensa do potencial e termina praticamente junto com a ação do sujeito (indicada pela linha vermelha), ou seja, o decaimento máximo ocorre em 0s, momento onde o sujeito realiza a ação de mudança de direção do veículo. É importante ressaltar que o padrão de decaimento mostrado pela [Figura 18](#) está de acordo com o apresentado em trabalhos anteriores ([WALTER et al., 1964](#); [KHALILIARDALI et al., 2012](#)).

A análise das grandes médias nos permite averiguar a existência de comportamentos que estão, segundo a literatura, de acordo com os padrões dos potenciais lentos. Contudo, uma análise mais detalhada para detectar a presença dos padrões do CNV também pode ser realizada no domínio da frequência.

5.2 Análises Dimensionais

A [Figura 19](#) apresenta a decomposição tempo-frequência feita com a CMW ([Equação 3.8](#)) para dois sujeitos diferentes. Estes dois gráficos possuem representatividade dentre os resultados obtidos na análise de frequência, onde poucos apresentaram atividade localizada na região do CNV, sendo em maioria gráficos dispersos, com alto nível de ruído e/ou que praticamente não tenham apresentado atividade.

A análise tempo-frequência nos permite verificar a composição de frequência de um sinal de forma simultânea, quanto a faixa de frequência mais ativa e o tempo onde tal atividade acontece, ainda que tenhamos obtidos resultados insatisfatórios com este método as vantagens na sua utilização, não são encontradas em outros métodos. Portanto, surge a necessidade de se realizar um estudo mais detalhado das causas deste comportamento, ou mesmo testar outros parâmetros de decomposição antes de descartar a decomposição utilizando a CWM.

A metodologia da coerência de fase nos permite analisar outros critérios do sinal, a [Figura 21](#) apresenta o resultado da coerência de fase para os mesmos dados utilizados na [Figura 19-A](#). Podemos ver a regiões em destaque, também de acordo com os parâmetros dos potenciais lentos. Coeficientes altos neste gráfico representam um alinhamento entre as amostras utilizadas na análise. Portanto, as regiões claras, coeficientes de maior valor, nas figuras [20](#) a [22](#), representam componentes que ocorreram de forma sincronizada entre as amostras, o que caracteriza componentes que devem ter a mesma causa e origem, reforçando a presença dos potenciais corticais lentos.

A [Figura 20](#) apresenta claramente uma região bem definida dentro dos padrões do CNV, mais acima próximo a margem do gráfico, pode-se observar a única área com atividade secundária. Contudo, podemos afirmar com firmeza que, devido sua localização temporal, a área secundária é consequente de potenciais ativos devido a execução da ação, não sendo assim, potenciais antecipatórios ou ruído do sinal.

O gráfico apresentado na [Figura 21](#) apresenta um comportamento promissor, criando base a futuras discussões e perguntas que podem ser vistas como pontos de futuras pesquisas. A [Figura 21](#) apresenta três áreas de forte intensidade para a coerência de fase, independente do pouco ruído presente no gráfico, sendo que todas estão de acordo com os parâmetros temporais do CNV e as duas mais abaixo estão claramente dentro dos parâmetros de frequência. Contudo a região mais acima reforça que os potenciais corticais lentos se estendem de 0.1Hz a 2Hz. Os resultados obtidos representam fortes indícios que esta faixa de frequência (0.1Hz a 2Hz) esteja correta, entretanto, ainda são necessários mais testes para confirmar tais indícios.

O gráfico apresentado na [Figura 22](#) apresenta atividade relacionada ao CNV, porém de forma dispersa e com mais ruído, comparativamente aos gráficos anteriores. Ainda assim a coerência de fase se apresenta predominantemente na região antes da ação. Estes três gráficos representam o que foi majoritariamente obtido a partir na análise da coerência de fase.

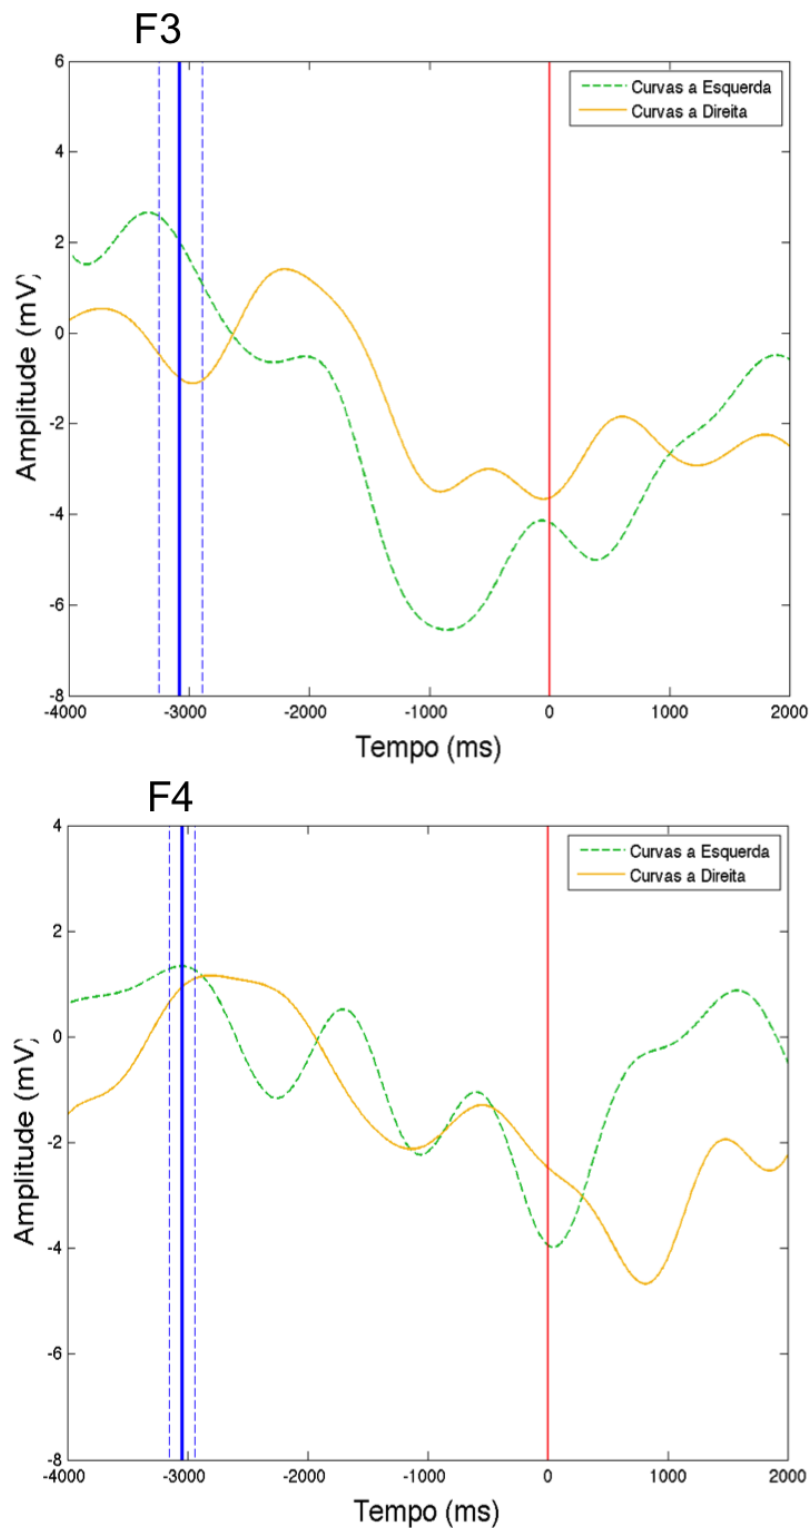


Figura 18 – As curvas representam as médias para cada tipo de amostra (curvas a direita e esquerda, linha amarela contínua e verde tracejada respectivamente) para os eletrodos F3 (sujeito 1) e F4 (sujeito 2). O gráfico representa a atividade entre -4s e 2s sendo que em 0s a ação de curva acontece (linha vertical vermelha), a linha azul representa onde acontece o beep (sendo a linha contínua a média e as pontilhadas o desvio padrão).




Figura 19 – Exemplos de mapas espectrais (*power spectra*) feitos utilizando a CWM, sendo o gráfico A para o sujeito 01 (eletrodo F8) e o gráfico B para o sujeito 04 (eletrodo F3). Este mapa representa os dados de um dia de registro para ambos sujeitos contendo todas as amostras.




Figura 20 – Mapa da coerência de fase para os dados de um dia de registro de um sujeito contendo todas as amostras. As regiões em destaque (círculos vermelhos) são pontos onde fases das amostras se alinham previamente à ação, $t = 0s$. Essa atividade se enquadra nos padrões antecipatórios dos potenciais corticais lentos, evidenciando um comportamento de componentes com a mesma causa e origem.




Figura 21 – Mapa da coerência de fase para os dados de um dia de registro de um sujeito contendo todas as amostras. As regiões em destaque (círculos vermelhos) são pontos onde fases das amostras se alinham previamente a ação, $t = 0s$. Essa atividade se enquadra nos padrões antecipatórios dos potenciais corticais lentos, evidenciando um comportamento de componentes com a mesma causa e origem.




Figura 22 – Mapa da coerência de fase para os dados de um dia de registro de um sujeito contendo todas as amostras. As regiões em destaque (círculos vermelhos) são pontos onde fases das amostras se alinham previamente a ação, $t = 0s$. Essa atividade se enquadra nos padrões antecipatórios dos potenciais corticais lentos, evidenciando um comportamento de componentes com a mesma causa e origem.

Sujeito 01		Grupo Frontal				Grupo Occipital			
		Janela Longa		Janela Curta		Janela Longa		Janela Curta	
		Filtro	Wavelet	Filtro	Wavelet	Filtro	Wavelet	Filtro	Wavelet
LDA	Ambos	65.9%	66.0%	83.3%	83.3%	66.3%	66.5%	83.3%	83.3%
	Direita	64.0%	64.3%	83.1%	83.3%	64.7%	65.7%	83.3%	83.3%
	Esquerda	66.0%	65.0%	83.3%	83.3%	66.3%	66.1%	83.4%	83.3%
QDA	Ambos	64.3%	58.0%	79.3%	83.3%	62.2%	64.6%	80.8%	83.3%
	Direita	63.8%	55.2%	79.7%	81.4%	62.7%	59.0%	82.7%	83.2%
	Esquerda	62.6%	57.8%	76.9%	83.3%	59.7%	60.6%	73.1%	83.3%

Tabela 2 – Os valores apresentados são percentuais de acerto obtidos através da validação cruzada para avaliação dos modelos de classificação para o sujeito 01, o procedimento foi realizado múltiplas vezes utilizando diferentes filtros, tamanhos de janelas, modelos de classificadores e grupamentos de eletrodos, os resultados específicos de cada combinação podem ser vistos nos cruzamentos da tabela.

5.3 Resultados de Classificação

Após o tratamento inicial dos dados (filtragem e divisão dos grupos frontal e occipital de eletrodos) realizou-se os testes de classificação. Que consistem em utilizar os algoritmos de classificação para diferenciar as janelas, [seção 4.5](#), para isso extraímos quatro pontos igualmente espaçados de cada janela, como foram utilizados quatro eletrodos o vetor de características fornecidos aos classificadores continha 16 valores.

Os percentuais de acerto em cada situação podem ser vistos na [Tabela 2](#) que subdivide os resultados de acordo com a metodologia utilizada, a saber: pelos grupos de eletrodos (grupo frontal e grupo occipital); pelo tamanho da janela (longa ou curta) e pelo filtro utilizado (filtro Butterworth ou transformada Wavelet). Por fim estão sobrepostos os métodos de classificação utilizados, LDA e QDA.

Os valores apresentados na [Tabela 2](#) são percentuais de acerto obtidos através da validação cruzada conforme descrito no [seção 3.5](#). Estão em destaque, em negrito, os melhores resultados dos testes de classificação, pode-se observar que os resultados da janela curta com o LDA são superiores aos demais e que o grupo occipital obteve uma média maior que o grupo frontal, o que pode se justificado pois os olhos acompanham os eventos do set-up experimental, gerando assim potenciais semelhantes o que consequentemente melhora o resultado do classificador, ainda assim os eletrodos do grupo occipital não registram informações dos potenciais corticais lentos por estarem muito distantes do cortex motor (KANDEL; SCHWARTZ; JESSELL, 2000).

5.4 Classificação em Varredura

Os resultados anteriores são referentes a testes de classificação quanto a diferenciação de janelas **go no-go**. A [Figura 23](#) apresenta o resultado de uma análise exploratória, onde os classificadores foram utilizados para reconhecimento dos padrões entre os diferen-

tes tipos de *trials*, curvas para a direita e para a esquerda, para várias janelas ao longo do tempo.

Este tipo de análise não foi realizada inicialmente por dois motivos:

Perguntar se há intenção e perguntar qual o tipo de intenção são questões diferentes, pois um classificador elaborado para diferenciar dois padrões irá sempre fornecer como saída um destes dois padrões mesmo ao classificar um sinal que não esteja associado a nenhum destes dois padrões, por isso, analisar separadamente as duas condições (existência e tipo de intenção) permite reduzir os falsos positivos.

Ainda, durante a análise para reconhecimento da intenção foram determinados os melhores parâmetros de processamento a serem utilizados nos potenciais corticais lentos. Estes parâmetros foram utilizados na classificação do tipo de ação, por isso a importância de realizar primeiramente os testes de classificação das janelas **go no-go**.

Neste procedimento, foi utilizada uma metodologia mais próxima ao que é feito em sistemas BCI online. Os dados foram filtrados entre 0.2 e 1Hz, utilizando um filtro Butterworth de quarta (4^a) ordem tipo passa-banda com fase zero. Então, foi realizado um *downsample*, reduzindo a taxa de amostragem do sinal de 128Hz para 16Hz, o que de acordo com o teorema de Nyquist (LYONS, 2010) não remove informações do sinal, devido as configurações de filtragem utilizadas. O modelo de classificação foi aplicado a cada conjunto de quatro pontos diretamente consecutivos, o que representa 250ms devido a taxa de amostragem de 16Hz. Por este motivo, o gráfico inicia em -3,75s e não em -4s, onde inicia nossa análise, já que o resultado de cada classificação fica associado à posição temporal do último ponto utilizado. Esta metodologia se assemelha ao que foi feito em (KHALILIARDALI et al., 2012), contudo, é uma abordagem que utiliza uma janela mais curta ainda e uma filtragem mais específica (LEW et al., 2014). O algoritmo de classificação utilizado foi o LDA, o vetor de características fornecido ao classificador consiste na concatenação dos mesmos quatro pontos de cada eletrodo utilizado, neste caso (F3, F4, FC5 e FC6) (WOLPAW; BOULAY, 2010) e para avaliação do desempenho de cada classificação foi utilizada uma validação cruzada 4-fold.

A Figura 23 apresenta os resultados de classificação (Linha verde) obtidos para os sujeitos 1 e 2. No gráfico a linha vertical preta, posicionada em $t = 0$ (tempo igual a zero), é onde a ação ocorre. A linha vertical azul é onde o processo de classificação obteve o melhor resultado prévio a ação, -250ms para ambos os sujeitos, o que permite verificar que é realmente possível diferenciar, com eficiência, qual ação será executada. Também, pode-se observar que a classificação tem uma curva de melhora intensa entre -1s e -0,5s para então assumir um comportamento estável, essa curva pode indicar que nesta janela de tempo o processo de planejamento da ação se inicia e chega a um ponto estável quando o sujeito está pronto a executar a curva, esta afirmação é cabível ao vermos a melhora na classificação da ação, é importante ressaltar que nosso grupo de pesquisa

possui um artigo aceito onde esta metodologia é apresentada (GOMES et al., 2015). Considerando que estamos utilizando sinais dentro dos parâmetros de frequência do CNV, essa curva de crescimento da classificação indica fortemente que este tipo de sinal contenha informações quanto ao tipo de ação que será executada. Mesmo que nossos resultados fossem insuficientes para poder fazer tais afirmações, este comportamento indica uma mudança convergente no estado cerebral, dessa forma, as outras análises realizadas neste estudo apoiam os resultados apresentados.

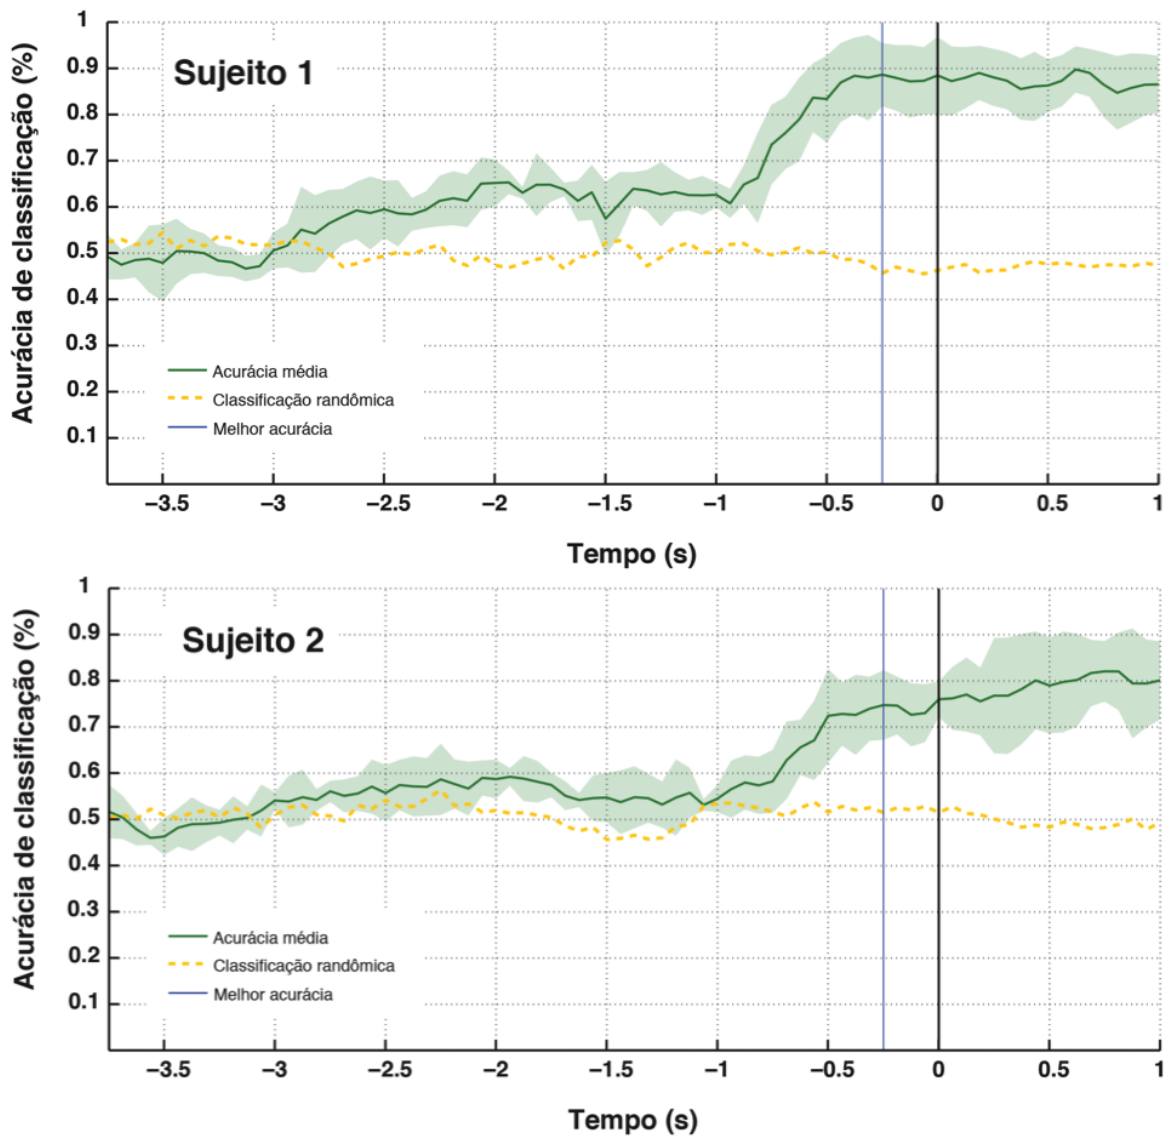


Figura 23 – Resultado de classificação utilizando os potenciais corticais lentos, filtragem entre 0.2Hz e 1Hz, sendo cada ponto da curva de desempenho gerado por uma classificador diferente, treinado para aquele conjunto de pontos.

A Figura 24 apresenta os resultados de classificação obtidos pela mesma metodologia utilizada na figura Figura 23, exceto pelo algoritmo de classificação. Neste caso, foi utilizado o melhor classificador gerado anteriormente, classificador que foi treinado para

os dados da linha azul vertical. A análise anterior apresenta a diferenciabilidade dos dados. Porém, mesmo que os resultados de classificação tenham sido constantemente altos, o treinamento do modelo de classificação a cada janela de dados é algo inviável em sistemas online, por isso a necessidade de ter um classificador fixo. Mesmo com essa alteração, ainda observamos a curva de crescimento prévia à ação, indicativo que o ponto onde acontece o máximo não está unicamente associado a diferenciabilidade dos dados, mas também a alguma característica presente nos dados. De acordo com os resultados obtidos na análise da coerência de fase e os parâmetros de filtragem utilizados, tal característica se trata dos potenciais corticais lentos.

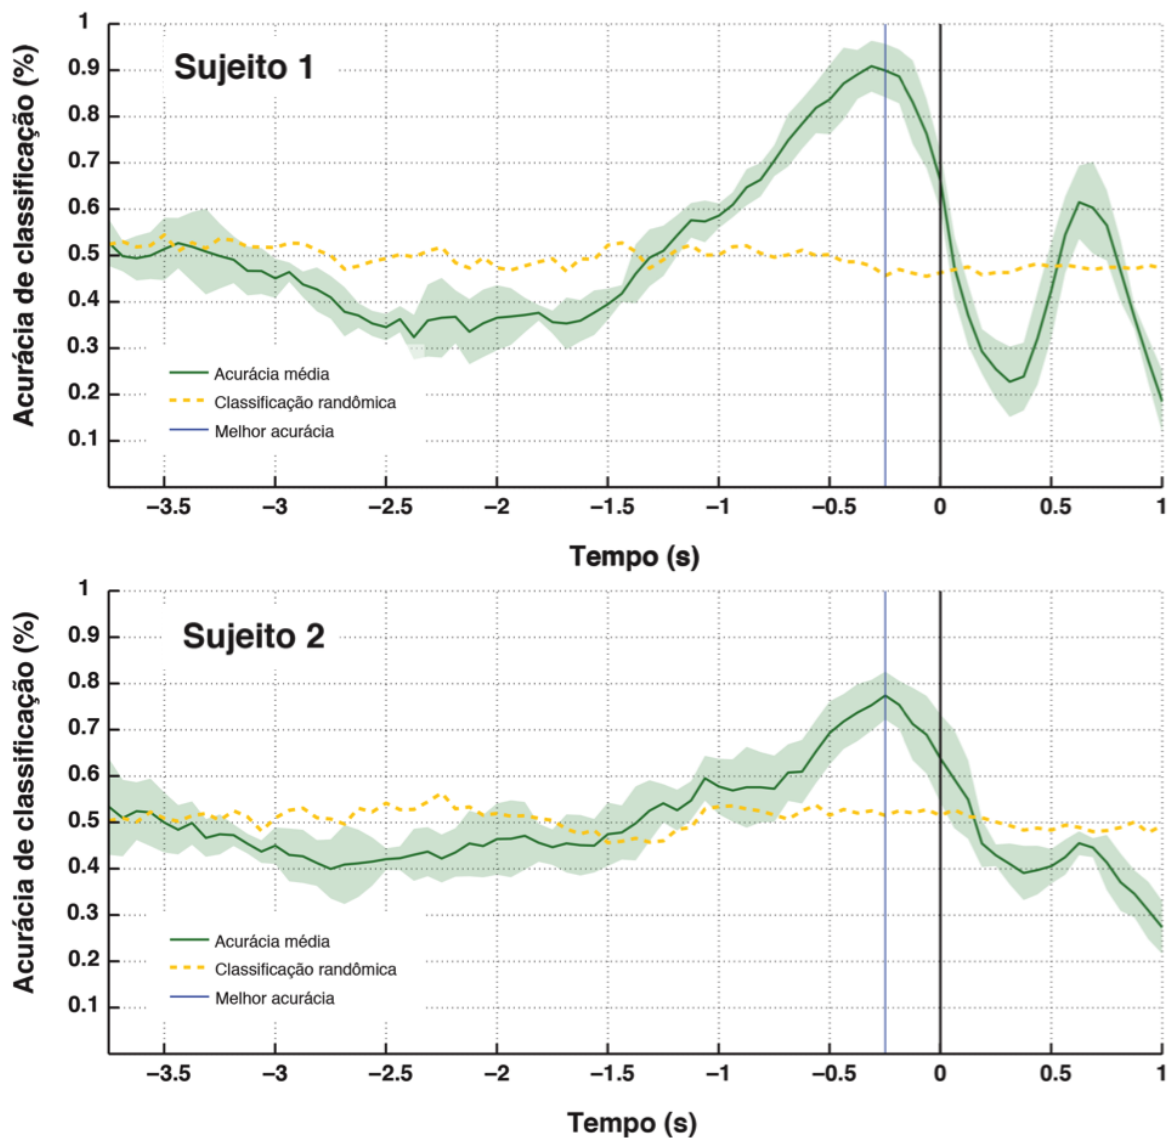


Figura 24 – Resultado de classificação utilizando os potenciais corticais lentos, filtragem entre 0.2Hz e 1Hz, sendo os pontos são resultados da aplicação do melhor classificador obtido anteriormente, classificador para -250ms (linha azul vertical).

5.5 Representação Topográfica do EEG

As etapas anteriores (médias do EEG, análise de fase e classificação em varredura) apresentaram resultados positivos de que o cérebro tende a um estado antecipatório em situações de planejamento, que tal estado é devido os potenciais corticais lentos. Os mapas de cabeça são a representação topográfica da distribuição da atividade elétrica registrada com o EEG, permitindo a análise visual das mudanças de estado que acontecem no cérebro durante o processo antecipatório.

Na [Figura 25](#) temos os mapas de cabeça que acompanham as medias apresentadas anteriormente ([Figura 18](#)), cada mapa é gerado pela média de todas as trials, estando distanciados em 1s (um segundo), dessa forma, podemos observar o comportamento geral do cérebro antes e depois da ação. Observando as médias encontramos o decaimento de potencial, que de acordo com os potenciais corticais lentos, ocorre antes da ação ser executada. Os mapas de cabeça apresentam o mesmo comportamento. As médias apresentadas foram feitas separadamente para cada tipo de amostra, entretanto, para os mapas de cabeça foram utilizadas todas as amostras. É relevante observar que ambos os casos, [figuras 25 e 26](#), pode-se observar uma decaimento no potencial da região central do mapa (cortex motor), surgindo logo antes da ação e se desfazendo após a ação.

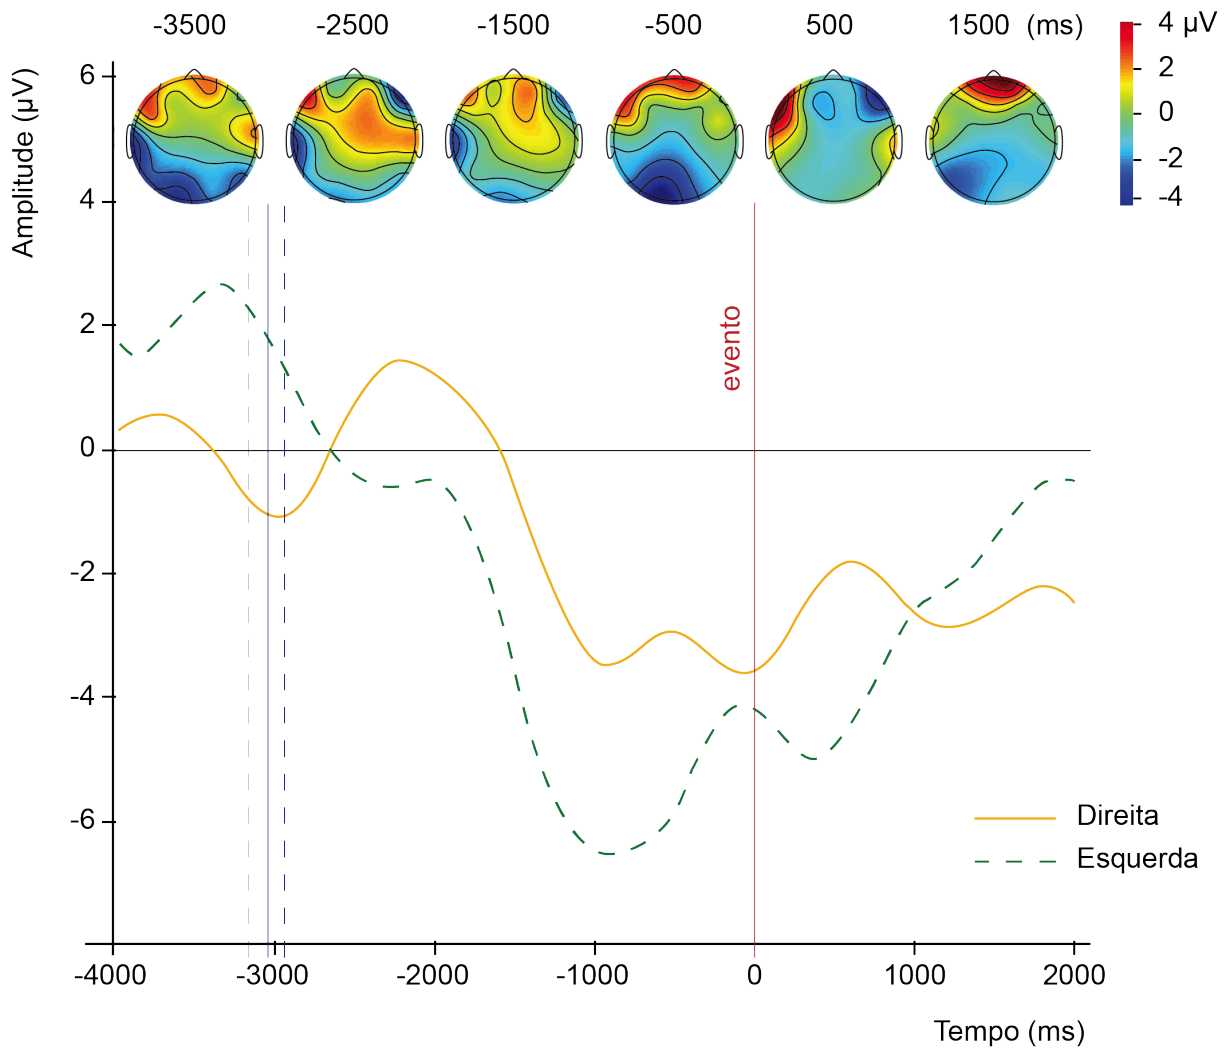


Figura 25 – Mapas de cabeça, para o sujeito 1, gerados pelas médias dos canais após a filtragem, 0.2Hz a 1Hz, sincronizados com a média do eletrodo F3 e a marcação de onde ocorrem o sinal sonoro (linhas verticais azuis contínua e pontilhadas, representando a média e a variância, respectivamente) e o evento (linha vertical vermelha, curva para a direita e curva para a esquerda).

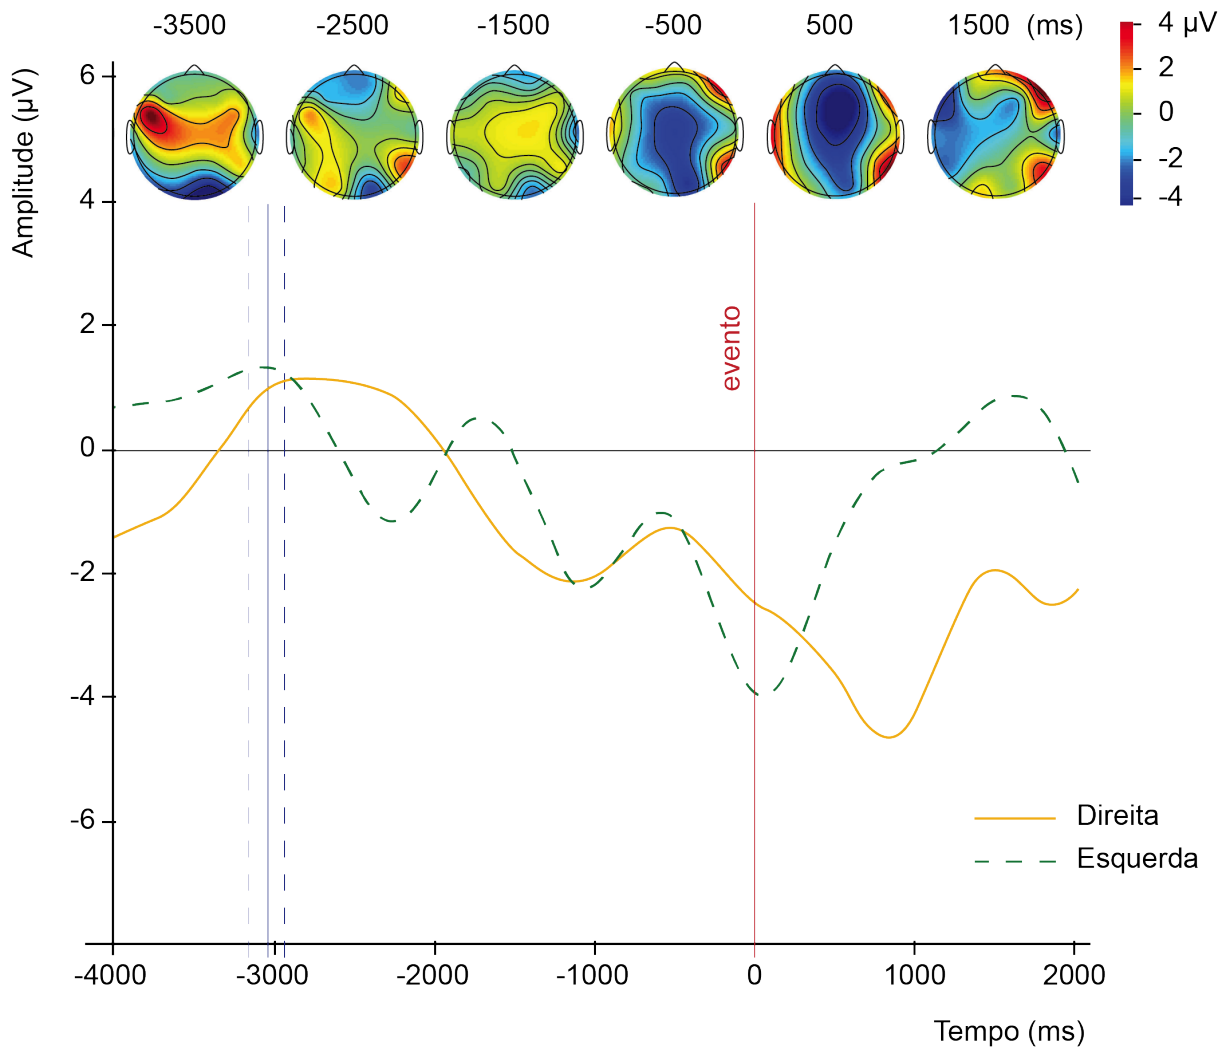


Figura 26 – Mapas de cabeça, para o sujeito 2, gerados pelas médias dos canais após a filtragem, 0.2Hz a 1Hz, sincronizados com a média do eletrodo F4 e a marcação de onde ocorrem o sinal sonoro (linhas verticais azuis contínua e pontilhadas, representando a média e a variância respectivamente) e o evento (linha vertical vermelha, curva para a direita e curva para a esquerda).

6 DISCUSSÃO

A partir dos resultados obtidos com a análise da coerência de fase, podemos observar a presença de potenciais corticais lentos e também caracterizá-los com maior riqueza de detalhes. Nossa análise mostrou fortes evidências de que os potenciais lentos se encontram entre -2,8s a -0,5s em relação ao evento e dentro de uma faixa de frequência que vai de 0,2Hz a 1,5Hz.

A literatura apresenta a utilização de janelas de 1 ou 2 segundos em procedimentos de reconhecimento como em (HAMMON *et al.*, 2008) e (GARIPELLI; CHAVARRIAGA; MILLAN, 2011). A metodologia apresentada neste trabalho testou janelas de 0,5s, Janela curta (ver seção 4.5). Nos testes de classificação foi obtido um acerto de 83%, 8% superior aos resultados obtidos por GARIPELLI; CHAVARRIAGA; MILLAN, 2011. Neste estudo, foi utilizada uma janela de meio segundo (0.5s), que é o tamanho mais comumente utilizado em janelas de varredura para classificação em sistema BCI. Um bom resultado com esse tamanho de janela é promissor para utilização desta metodologia em sistemas online.

6.1 A variação do EEG em baixa frequência: Domínio do tempo

Dois sujeitos apresentaram de forma clara um decaimento no potencial prévio a ação nas médias dos eletrodos frontais e fronto-centrais. Como as médias foram calculadas após a filtragem, entre 0.2 Hz e 1Hz, podemos afirmar que tal comportamento é devido os potenciais corticais lentos. Ou seja, analisando as médias no domínio do tempo pudemos observar os potenciais antecipatórios com certa clareza. Ainda durante a classificação exploratória, foi possível observar um máximo 250ms antes da ação, sendo que a curva de classificação estabiliza nesse ponto. No entanto, a curva inicia um crescimento intenso em -1s até chegar ao valor máximo. A curva de classificação indica a presença de fatores que aumentam a capacidade do classificador em diferenciar as classes, que de acordo com os parâmetros de processamento utilizados, significa que tais fatores diferenciados são os potenciais antecipatórios que nos trabalhos de KHALILIARDALI *et al.* corresponde ao CNV (*contingent negativity variation*).

6.2 Informação fornecida pelo EEG sobre engajamento funcional: Domínio da frequência

Usualmente, a informação relevante do EEG para aplicações em BCI, quando usadas no domínio da frequência, utilizam a amplitude espectral (power spectra). Isso é

particularmente claro no uso das ondas μ , ver em MCFARLAND et al. 1997. No presente trabalho, obtivemos um engajamento funcional através da análise de fase (*phase coherence*). Os resultados obtidos na análise de amplitude espectral foram inconclusivos. Os mapas espectrais (*power spectra*) não apresentaram resultados satisfatórios, pois na faixa de frequência analisada não consideramos as ondas μ (8-12 Hz), devido a tarefa não consistir em qualquer análise de movimento do indivíduo. Além disso, o *setup* experimental foi elaborado para gerar uma situação de planejamento sem movimentos bruscos. Em contraponto, os resultados observados na análise de fase apresentaram níveis elevados na faixa de frequência do CNV previamente a ação, tanto para eletrodos frontais e fronto-centrais quanto em eletrodos fronto-occipitais. Isso corrobora a presença do CNV, como também indica um comprometimento funcional das ondas que é similar aos padrões ADAN (anterior directing attention negativity) e LDAP (*late directing attention positivity*) (SIMPSON et al., 2011; CORBETTA; SHULMAN, 2002) que são indicativos de comportamento antecipatório em potenciais do EEG.

6.3 Perspectivas

A partir dos resultados apresentados, o próximo passo será o desenvolvimento de um sistema *Mult-Modal*, ou seja, um sistema que extrai informações de múltiplas regiões corticais. Neste trabalho, apresentamos metodologias para extrair múltiplas informações da banda delta de sinais provenientes de eletrodos frontais e fronto-centrais. A literatura mostra ser possível a extração de informações diferentes tanto da banda beta do córtex motor ou de outras bandas do córtex visual (ANDERSEN; MUSALLAM; PESARAN, 2004). Tais informações serão usadas para alimentar um sistema BCI na realização da tomada de decisões. Este seria um paradigma que expande o conceito da geração de comandos como atualmente é feito em sistemas BCI, possibilitando, através do mesmo sistema, uma maior liberdade de controle e escolhas, mudando a atual condição em que para um sujeito utilizar um sistema BCI, o mesmo tem que estar focado no controle para evitar comandos indesejados.

Uma forma de aprimoramento, a partir da metodologia apresentada neste trabalho, é apresentado a seguir. A utilização do paradigma go no-go com janelas curtas pode ser aplicado na detecção prévia de eventos em sistemas BCI online. A Figura 27 apresenta a sequência de funcionamento padrão utilizada em BCIs (Coluna A) e uma possível alteração proposta (Componentes dentro linha tracejada B). A alteração consiste em adicionar os componentes B e ignorar a seta tracejada do esquema padrão. O sistema passa a verificar se existe a intenção de realizar alguma ação antes de se aplicar a classificação para a tradução em comando, dessa forma, espera-se obter duas melhorias principais: uma redução no índice de erros e falsos positivos e uma redução no tempo de resposta do sistema.

Erros de classificação acontecem devido algoritmos não terem um desempenho satisfatório, assim, os erros devem ser tratados e minimizados. Os falsos positivos acontecem devido ao cérebro não entrar em “inércia” (atividade de fundo). Não há ausência de atividade mesmo quando não se tem a intenção de gerar um comando. Ainda assim, uma diminuição de falsos positivos é uma das metas mais almejadas na moderna pesquisa em BCI. Nossos resultados mostram um caminho promissor para análise precisa tanto no domínio do tempo quanto no da frequência, o que poderá fornecer alta precisão e confiabilidade.

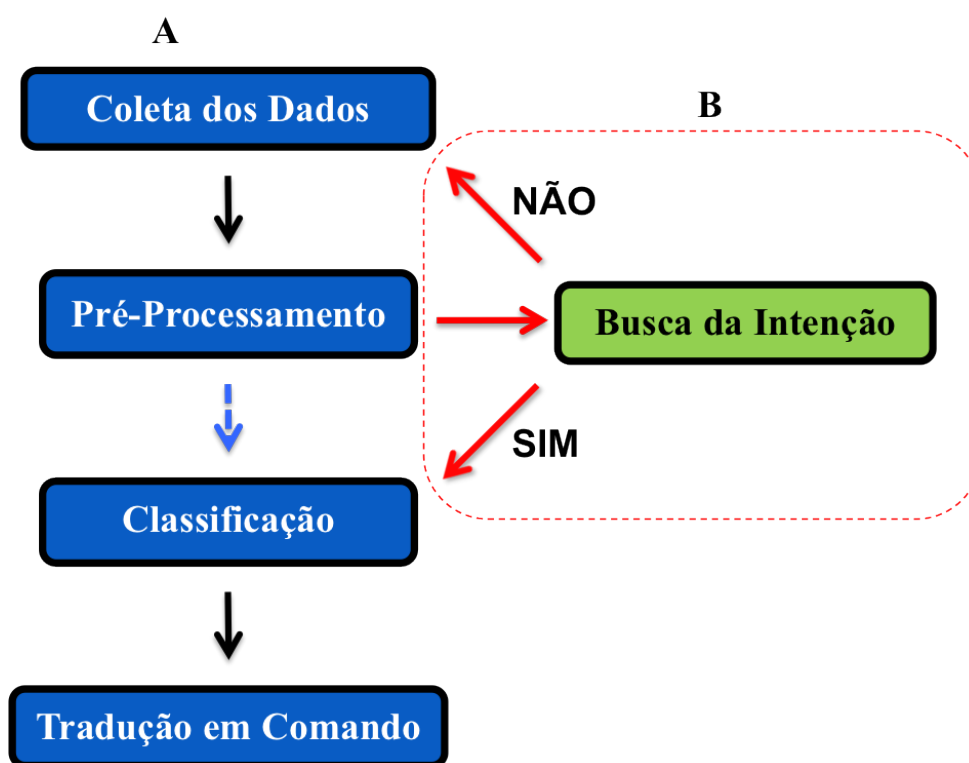


Figura 27 – Esquema genérico do funcionamento de sistemas BCI (Coluna A) e adaptação proposta (Componentes B), as aplicações BCI executam os procedimentos apresentados em A repetidamente conforme recebe dados, da mesma forma o ajuste B será executado de forma concomitante a A, de forma a tornar o sistema mais robusto a erros e mais rápido, por adicionar informações prévias à classificação, independentemente dos passos adicionais.

7 CONCLUSÃO E CONSIDERAÇÕES FINAIS

Neste trabalho foi investigado a presença de sinais EEG relacionados com a antecipação de eventos durante a condução de um carro virtual. Os eventos estudados foram manobras para produzir uma mudança de direção no carro, necessárias para realizar curvas à esquerda e à direita ao longo de uma estrada virtual. Os experimentos realizados com cinco sujeitos revelaram potenciais relacionados a evento consistentes com sinais CNV relatados na literatura (KIRSCH; HENNIGHAUSEN, 2010; GARIPELLI; CHAVARRIAGA; MILLAN, 2011).

Os resultados apresentados no presente trabalho são promissores, uma vez que observamos - com o uso de técnicas de análise temporal e espectral - nos resultados dos testes realizados em ambiente simulado, ser possível reconhecer e qualificar sinais antecipatórios em uma aplicação on-line.

A partir das metodologias apresentadas temos a necessidade de testes e ajustes para uma aplicação real, pois neste trabalho foi mostrado ser possível extrair do EEG um padrão antecipatório que possa ser usado em um sistema de predição de eventos/tomada de decisão real, para informar aos sensores do carro quando o condutor teve a intenção de realizar uma mudança de direção à esquerda ou à direita.

A detecção de potenciais cerebrais antecipatórios pode ser útil para avaliar a intenção do sujeito antes da execução de ações planejadas e permitir que um sistema inteligente avalie os sinais EEG associados a um evento que ainda não ocorreu, possibilitando assim que o sistema computacional tenha condições de tomar uma decisão de forma preventiva face a eventos que possam gerar riscos a segurança dos condutores e de outros pedestres na via de tráfego. Assim, acreditamos que sistemas BCI que funcionem com este tipo de sinal poderiam gerar um diferencial em sistemas de interação homem máquina ou, mais especificamente, em carros inteligentes. E por fim, mesmo que tenhamos conseguido detectar os potenciais antecipatórios, ainda existem mais desafios em sua aplicação, como a aplicação em tempo real e a adaptação para o ambiente real, desafios estes que devem ser superados com novos estudos para a aplicação das devidas melhorias em nossa metodologia que já se apresentou possível em ambiente de realidade virtual não invasivo.

Referências

- AMIRI, S.; FAZEL-REZAI, R.; ASADPOUR, V. A review of hybrid brain-computer interface systems. *Adv. in Hum.-Comp. Int.*, Hindawi Publishing Corp., New York, NY, United States, v. 2013, p. 1:1–1:1, jan. 2013. ISSN 1687-5893. Disponível em: <<http://dx.doi.org/10.1155/2013/187024>>. Citado na página 23.
- ANDERSEN, R. A.; MUSALLAM, S.; PESARAN, B. Selecting the signals for a brain-machine interface. *Current Opinion in Neurobiology*, v. 14, n. 6, p. 720 – 726, 2004. ISSN 0959-4388. Disponível em: <<http://npl.mcgill.ca/Papers/currentopinionselectingsignals.pdf>>. Citado na página 62.
- BABILONI, F. et al. Linear classification of low-resolution eeg patterns produced by imagined hand movements. *Rehabilitation Engineering, IEEE Transactions on*, v. 8, n. 2, p. 186–188, Jun 2000. ISSN 1063-6528. Citado na página 21.
- BIRBAUMER, N.; COHEN, L. G. Brain computer interfaces: communication and restoration of movement in paralysis. *The Journal of Physiology*, Blackwell Publishing Ltd, University of Tuebingen., n. 3, p. 621–636, mar 2007. ISSN 0022-3751. Citado na página 18.
- CHUANG, C.-H. et al. Driver’s cognitive state classification toward brain computer interface via using a generalized and supervised technology. In: *IJCNN*. [S.l.]: IEEE, 2010. p. 1–7. ISBN 978-1-4244-6916-1. Citado na página 13.
- CLARKE, B.; FOKOUÉ, E.; ZHANG, H. H. *Principles and Theory for Data mining and Machine Learning*. 2009. ed. [S.l.]: Springer, 2009. 781 p. ISBN 9780387981352. Citado na página 31.
- CORBETTA, M.; SHULMAN, G. L. Control of goal-directed and stimulus-driven attention in the brain. *Nat Rev Neurosci*, v. 3, n. 3, p. 201–215, 03 2002. Disponível em: <<http://dx.doi.org/10.1038/nrn755>>. Citado na página 62.
- DIEZ, P. et al. Asynchronous bci control using high-frequency ssvep. *Journal of NeuroEngineering and Rehabilitation*, v. 8, n. 1, p. 39, 2011. ISSN 1743-0003. Disponível em: <<http://www.jneuroengrehab.com/content/8/1/39>>. Citado na página 19.
- FISHER, R. A. The use of multiple measurements in taxonomic problems. *Annals of Eugenics*, 1936. Citado na página 29.
- FLEMISCH, O. et al. *NASA/TM2003-212672 The H-Metaphor as a Guideline for Vehicle Automation and Interaction*. 2003. Citado na página 13.
- GANGADHAR, G.; CHAVARRIAGA, R.; R.MILLAN, J. del. Fast recognition of anticipation-related potentials. *Biomedical Engineering, IEEE Transactions on*, v. 56, n. 4, p. 1257–1260, April 2009. ISSN 0018-9294. Citado 2 vezes nas páginas 22 e 28.
- GARIPELLI, G.; CHAVARRIAGA, R.; MILLAN, J. del R. Single trial recognition of anticipatory slow cortical potentials: The role of spatio-spectral filtering. In: *Neural Engineering (NER), 2011 5th International IEEE/EMBS Conference on*. [S.l.: s.n.], 2011. p. 408–411. ISSN 1948-3546. Citado 5 vezes nas páginas 29, 40, 41, 61 e 64.

- GOMES, A. et al. Anticipatory EEG Signals for Detecting and Classifying Game Interaction Onset. *Symposium on Virtual and Augmented Reality (SVR)*, p. 5, 2015. Citado na página 56.
- GRAIMANN, B.; ALLISON, B.; PFURTSCHELLER, G. Brain-computer interfaces: A gentle introduction. In: GRAIMANN, B.; PFURTSCHELLER, G.; ALLISON, B. (Ed.). *Brain-Computer Interfaces*. Springer Berlin Heidelberg, 2010, (The Frontiers Collection). p. 1–27. ISBN 978-3-642-02090-2. Disponível em: <http://dx.doi.org/10.1007/978-3-642-02091-9_1>. Citado na página 21.
- HAMMON, P. S. et al. Predicting reaching targets from human eeg. *Signal Processing Magazine, IEEE*, IEEE, v. 25, n. 1, p. 69–77, 2008. ISSN 1053-5888. Disponível em: <<http://dx.doi.org/10.1109/msp.2008.4408443>>. Citado 5 vezes nas páginas 22, 25, 39, 41 e 61.
- HAUFE, S. et al. Eeg potentials predict upcoming emergency brakings during simulated driving. *Journal of Neural Engineering*, v. 8, n. 5, p. 056001, 2011. Disponível em: <<http://stacks.iop.org/1741-2552/8/i=5/a=056001>>. Citado na página 14.
- HINTERBERGER, T. et al. Brain-computer communication and slow cortical potentials. *Biomedical Engineering, IEEE Transactions on*, v. 51, n. 6, p. 1011–1018, 2004. Disponível em: <<http://dx.doi.org/10.1109/tbme.2004.827067>>. Citado na página 14.
- HWANG, H.-J. et al. Development of an SSVEP-based BCI spelling system adopting a QWERTY-style LED keyboard. *Journal of Neuroscience Methods*, maio 2012. ISSN 01650270. Disponível em: <<http://dx.doi.org/10.1016/j.jneumeth.2012.04.011>>. Citado na página 19.
- IFFT, P. J. et al. A brain-machine interface enables bimanual arm movements in monkeys. *Science Translational Medicine*, v. 5, n. 210, p. 210ra154, 2013. Disponível em: <<http://stm.sciencemag.org/content/5/210/210ra154.abstract>>. Citado na página 19.
- KANDEL, E. R.; SCHWARTZ, J. H.; JESSELL, T. M. *Principles of Neural Science*. 4th. ed. [S.l.]: McGraw-Hill Medical, 2000. Hardcover. ISBN 0071120009. Citado 2 vezes nas páginas 22 e 54.
- KHALILIARDALI, Z. et al. Detection of anticipatory brain potentials during car driving. In: *Engineering in Medicine and Biology Society (EMBC), 2012 Annual International Conference of the IEEE*. [S.l.: s.n.], 2012. p. 3829–3832. ISSN 1557-170X. Citado 4 vezes nas páginas 22, 47, 55 e 61.
- KIRSCH, W.; HENNIGHAUSEN, E. Erp correlates of linear hand movements: Distance dependent changes. *Clinical Neurophysiology*, mar. 2010. ISSN 13882457. Disponível em: <<http://dx.doi.org/10.1016/j.clinph.2010.02.151>>. Citado 2 vezes nas páginas 13 e 64.
- KROPP, P. et al. Reliability and stability of contingent negative variation. *Applied Psychophysiology and Biofeedback*, Kluwer Academic Publishers-Plenum Publishers, v. 25, n. 1, p. 33–41, 2000. ISSN 1090-0586. Disponível em: <<http://dx.doi.org/10.1023/A%3A1009533405695>>. Citado na página 13.

- LEW, E. Y. L. et al. Single trial prediction of self-paced reaching directions from eeg signals. *Frontiers in Neuroscience*, v. 8, n. 222, 2014. ISSN 1662-453X. Disponível em: <<http://www.frontiersin.org/neuroprosthetics/10.3389/fnins.2014.00222/abstract>>. Citado na página 55.
- LIN, F.-C. et al. Eeg-based cognitive state monitoring and prediction by using the self-constructing neural fuzzy system. In: *Circuits and Systems (ISCAS), Proceedings of 2010 IEEE International Symposium on*. [S.l.: s.n.], 2010. p. 2287–2290. Citado 2 vezes nas páginas 13 e 14.
- LYONS, R. G. *Understanding Digital Signal Processing*. Third. Prentice Hall, 2010. 984 p. ISBN 9780137027415. Disponível em: <<http://book.douban.com/subject/4798355/>>. Citado na página 55.
- MATHWORKS, I. *Butterworth filter design*. 2013. Disponível em: <<http://www.mathworks.com/help/signal/ref/butter.html?searchHighlight=butter>>. Citado na página 23.
- MCFARLAND, D. et al. Spatial filter selection for eeg-based communication. *Electroencephalography and Clinical Neurophysiology*, v. 103, n. 3, p. 386–394, set. 1997. ISSN 00134694. Disponível em: <[http://dx.doi.org/10.1016/s0013-4694\(97\)00022-2](http://dx.doi.org/10.1016/s0013-4694(97)00022-2)>. Citado na página 62.
- MCFARLAND, D. J.; WOLPAW, J. R. Brain-computer interfaces for communication and control. *Commun. ACM*, ACM, New York, NY, USA, v. 54, n. 5, p. 60–66, maio 2011. ISSN 0001-0782. Disponível em: <<http://doi.acm.org/10.1145/1941487.1941506>>. Citado 2 vezes nas páginas 13 e 21.
- MELLINGER, J. et al. An meg-based brain-computer interface (bci). *NeuroImage*, v. 36, n. 3, p. 581 – 593, July 2007. ISSN 1053-8119. Disponível em: <<http://europepmc.org/articles/PMC2017111>>. Citado na página 18.
- MILLAN, J. d. R. et al. Non-invasive brain-machine interaction. *International Journal of Pattern Recognition and Artificial Intelligence*, 2008. Citado na página 13.
- MISITI, M. et al. *Wavelet Toolbox For Use with MATLAB*. [S.l.], 2012. Disponível em: <http://www.mathworks.com/help/pdf_doc/wavelet/wavelet_ug.pdf>. Citado na página 23.
- ODOM, J. et al. Iscev standard for clinical visual evoked potentials (2009 update). *Documenta Ophthalmologica*, Springer-Verlag, v. 120, n. 1, p. 111–119, 2010. ISSN 0012-4486. Disponível em: <<http://dx.doi.org/10.1007/s10633-009-9195-4>>. Citado 3 vezes nas páginas 19, 35 e 40.
- PFURTSCHELLER, G.; NEUPER, C. Dynamics of sensorimotor oscillations in a motor task//. In: GRAIMANN, B.; PFURTSCHELLER, G.; ALLISON, B. (Ed.). *Brain-Computer Interfaces*. Springer Berlin Heidelberg, 2010, (The Frontiers Collection). p. 47–64. ISBN 978-3-642-02090-2. Disponível em: <http://dx.doi.org/10.1007/978-3-642-02091-9_3>. Citado na página 39.
- QUIROGA, R. Q. et al. Wavelet transform in the analysis of the frequency composition of evoked potentials. *Brain Research Protocols*, v. 8, n. 1, p. 16 – 24, 2001. ISSN

1385-299X. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1385299X01000770>>. Citado na página 24.

RABINER, L. R.; GOLD, B.; YUEN, C. K. Theory and application of digital signal processing. *Systems, Man and Cybernetics, IEEE Transactions on*, v. 8, n. 2, p. 146–146, Feb 1978. ISSN 0018-9472. Citado 2 vezes nas páginas 18 e 25.

SAMAR, V. J. et al. Wavelet analysis of neuroelectric waveforms: A conceptual tutorial. *Brain and Language*, v. 66, n. 1, p. 7 – 60, 1999. ISSN 0093-934X. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0093934X98920247>>. Citado na página 18.

SCHOGL, A. et al. Evaluation criteria for bci research. In: *Toward Brain-computer Interfacing*. [S.l.]: MIT Press, 2007. cap. 19, p. 327–342. Citado na página 32.

SIMPSON, G. V. et al. Dynamic activation of frontal, parietal, and sensory regions underlying anticipatory visual spatial attention. *The Journal of neuroscience: the official journal of the Society for Neuroscience*, v. 31, n. 39, p. 13880–13889, September 2011. ISSN 0270-6474. Disponível em: <<http://europepmc.org/articles/PMC3672245>>. Citado na página 62.

SYED, A. R. *A Review of Cross Validation and Adaptive Model Selection*. Tese (Mathematics Theses) — Georgia State University, 2011. Citado 2 vezes nas páginas 30 e 31.

VALENS, C. *A Really Friendly Guide to Wavelets*. 1999. Disponível em: <<http://www.robots.ox.ac.uk/~parg/mlrg/papers/arfgtw.pdf>>. Citado 2 vezes nas páginas 23 e 25.

VIALATTE, F.-B. B. et al. Steady-state visually evoked potentials: focus on essential paradigms and future perspectives. *Progress in neurobiology*, v. 90, n. 4, p. 418–438, abr. 2010. ISSN 1873-5118. Disponível em: <<http://dx.doi.org/10.1016/j.pneurobio.2009.11.005>>. Citado na página 20.

WALDERT, S. et al. Hand movement direction decoded from meg and eeg. *The Journal of neuroscience : the official journal of the Society for Neuroscience*, Society for Neuroscience, Institute of Medical Psychology and Behavioral Neurobiology, University of Tübingen, 72076 Tübingen, Germany. waldert@bccn.uni-freiburg.de, v. 28, n. 4, p. 1000–1008, jan. 2008. ISSN 1529-2401. Disponível em: <<http://dx.doi.org/10.1523/jneurosci.5171-07.2008>>. Citado na página 23.

WALTER, W. G. et al. Contingent negative variation: An electric sign of sensorimotor association and expectancy in the human brain. *Nature*, v. 203, p. 380–384, jul. 1964. ISSN 0028-0836. Disponível em: <<http://view.ncbi.nlm.nih.gov/pubmed/14197376>>. Citado 2 vezes nas páginas 13 e 47.

WANG, Y. et al. Brain-computer interfaces based on visual evoked potentials. *Engineering in Medicine and Biology Magazine, IEEE*, v. 27, n. 5, p. 64–71, September 2008. ISSN 0739-5175. Citado na página 19.

WANG, Y. et al. Practical designs of brain-computer interfaces based on the modulation of eeg rhythms. In: GRAIMANN, B.; PFURTSCHELLER, G.; ALLISON, B. (Ed.). *Brain-Computer Interfaces*. Springer Berlin Heidelberg, 2010,

(The Frontiers Collection). p. 137–154. ISBN 978-3-642-02090-2. Disponível em: <http://dx.doi.org/10.1007/978-3-642-02091-9_8>. Citado na página 21.

WOLPAW, J.; BOULAY, C. Brain signals for brain-computer interfaces. In: GRAIMANN, B.; PFURTSCHELLER, G.; ALLISON, B. (Ed.). *Brain-Computer Interfaces*. Springer Berlin Heidelberg, 2010, (The Frontiers Collection). p. 29–46. ISBN 978-3-642-02090-2. Disponível em: <http://dx.doi.org/10.1007/978-3-642-02091-9_2>. Citado 2 vezes nas páginas 21 e 55.

WOLPAW, J. R.; MCFARLAND, D. J. Control of a two-dimensional movement signal by a noninvasive brain-computer interface in humans. *Proceedings of the National Academy of Sciences of the United States of America*, v. 101, n. 51, p. 17849–17854, 2004. Disponível em: <<http://www.pnas.org/content/101/51/17849.abstract>>. Citado na página 21.

Apêndices

APÊNDICE A – Submissão ao Comitê de Ética

Este projeto está sob avaliação do comitê de ética, segue o termo de submissão com número de protocolo.

	NÚCLEO DE MEDICINA TROPICAL-NMT/ UNIVERSIDADE FEDERAL DO	
COMPROVANTE DE ENVIO DO PROJETO		
DADOS DO PROJETO DE PESQUISA		
Título da Pesquisa:	Análise dos potenciais corticais lentos para predição de ações em sistemas de interface Cérebro Computador (BCI)	
Pesquisador:	Fredson Carmo dos Santos	
Versão:	1	
CAAE:	44068615.1.0000.5172	
Instituição Proponente:	Núcleo de Medicina Tropical-NMT/ Universidade Federal do Pará - UFPA	
DADOS DO COMPROVANTE		
Número do Comprovante:	031369/2015	
Patrocinador Principal:	ASSOCIACAO INSTITUTO TECNOLOGICO VALE - ITV	
Endereço: Av. Generalíssimo Deodoro, 92 Bairro: Umarizal CEP: 66.055-240 UF: PA Município: BELEM Telefone: (91)3201-0961 E-mail: cepbel@ufpa.br		

Figura 28 – Comprovante de envio de projeto a plataforma Brasil.

APÊNDICE B – Termo de Consentimento Livre e Esclarecido (TCLE)

INSTITUTO TECNOLÓGICO VALE DESENVOLVIMENTO SUSTENTÁVEL -
ITV-DS

Laboratório de Robótica

Rua Boa Ventura da Silva - Num. 1055 - Umarizal - Belém/Pa, 66055090

TERMO DE CONSENTIMENTO LIVRE E ESCLARECIDO

Título da Pesquisa: Análise dos Potenciais Corticais Lentos para Predição de Ações em Sistemas de Interface Cérebro Computador (BCI)

Responsável: Fredson Carmo dos Santos

Sistemas de interface cérebro-computador (BCI – Brain Computer Interface) geram comandos a partir de padrões de comportamento reconhecidos através da análise de dados provenientes de atividade cerebral. Neste estudo será utilizado o “EEG neuro-headset Emotiv Eporc”, equipamento que faz o registro dos potenciais elétricos provenientes do cérebro, utilizando eletrodos de feltro umidificados com solução salina. Ao posicionar o headset, os eletrodos ficam em contato com o couro cabeludo, transmitindo os dados para um computador através de uma conexão sem fio. O estudo consiste em realizar estes registros enquanto voluntários controlam um carro em um ambiente virtual, estes registros serão analisados para gerar uma metodologia capaz de prever manobras realizadas durante o experimento.

Nenhum outro equipamento ou substância será utilizada pelo voluntário, assim ele ficará exposto apenas ao monitor e ao ambiente onde será realizado o experimento. Dessa forma, os únicos riscos aos quais os voluntários serão expostos são: o contágio de alguma forma de doença de pele, como caspa, ou alguma alergia à solução salina. Não havendo existência de qualquer outro tipo de risco, em vista que os testes serão realizados utilizando um computador convencional com um monitor de alta qualidade, em uma sala climatizada contendo apenas os equipamentos utilizados e objetos convencionais de escritório.

Quanto aos inconvenientes relacionados ao uso do headset, será utilizada uma solução salina específica evitando assim possíveis alergias e contaminações. A solução consiste no mesmo produto utilizado para limpeza e manutenção de lentes de contato, esse tipo de material é desenvolvido para aplicação no globo ocular, o que minimiza o risco de qualquer alergia, principalmente em vista de que neste estudo a solução será utilizada

em contato com o couro cabeludo. Ainda assim, são realizados testes de alergia antes da colocação do headset, minimizando qualquer possível efeito colateral. Ainda é possível que o voluntário chegue a sentir dores de cabeça, provenientes da pressão dos eletrodos contra a cabeça. Porém, isso é semelhante a sensação de se utilizar um boné apertado, bastando apenas remover o headset. Quanto a isso deixamos claro que o voluntário poderá remover o equipamento, e mesmo abandonar o estudo, em qualquer momento, sem insistência por parte dos pesquisadores para sua permanência ou conclusão dos registros.

O posicionamento e utilização do headset não causará qualquer tipo de ferimento. O teste terá uma duração máxima de uma hora e meia, o que inclui o tempo de preparação e os intervalos de descanso. Os testes tem cerca de 25 minutos de registro efetivo. Todo o procedimento será realizado de forma a minimizar qualquer risco, por quaisquer motivos, para isso o tempo que o voluntário passará sentando, com as mão no controle do simulador ou utilizando o headset, com ampla margem de segurança, estão dentro dos padrões seguros de uso.

A participação neste estudo será voluntária, não sendo realizado nenhum tipo de pagamento em dinheiro, o que significa que nenhuma recompensa será dada, e que nenhum voluntário será obrigado a participar, tendo total liberdade de recusar a participação na pesquisa ou de deixar de participar durante a sua realização, sem dar maiores explicações aos pesquisadores, ou ser questionado quanto às causas da desistência. Este estudo destina-se a pesquisa. A identidade dos participantes será mantida em sigilo.

Assinatura do Pesquisador Responsável

Nome: Fredson Carmo dos Santos

Rua Boa Ventura da Silva – Nº 1055

Fone: 3213-5572

CONSENTIMENTO LIVRE E ESCLARECIDO

Declaro que li as informações acima sobre a pesquisa, que me sinto perfeitamente esclarecido sobre o conteúdo da mesma, assim como seus riscos e benefícios. Declaro ainda que, por minha livre vontade, aceito participar da pesquisa cooperando com a coleta de material para exame.

Belém, ____ / ____ / ____

Assinatura do sujeito da pesquisa ou do responsável

APÊNDICE C – Resultados de Classificação Para Todos os Sujeitos

Segue as tabelas dos resultados de classificação dos cinco sujeitos participantes dos testes.

Sujeito 02		Grupo Frontal				Grupo Occipital			
		Janela Longa		Janela Curta		Janela Longa		Janela Curta	
		Filtro	Wavelet	Filtro	Wavelet	Filtro	Wavelet	Filtro	Wavelet
LDA	Ambos	65.9%	66.5%	83.2%	83.3%	66.6%	65.9%	83.3%	83.3%
	Direita	65.0%	64.7%	82.9%	83.4%	65.0%	64.7%	82.8%	82.7%
	Esquerda	64.6%	63.6%	82.9%	83.1%	65.4%	64.5%	82.6%	83.2%
QDA	Ambos	63.5%	61.7%	83.4%	82.5%	61.9%	61.4%	83.2%	80.8%
	Direita	64.8%	58.5%	83.3%	82.2%	58.9%	60.5%	81.5%	78.2%
	Esquerda	57.7%	59.8%	82.8%	81.7%	63.8%	61.1%	80.2%	80.8%

Tabela 3 – Os valores apresentados são percentuais de acerto obtidos através da validação cruzada para avaliação dos modelos de classificação para o sujeito 02, o procedimento foi realizado múltiplas vezes utilizando diferentes filtros, tamanhos de janelas, modelos de classificadores e grupamentos de eletrodos, os resultados específicos de cada combinação podem ser vistos nos cruzamentos da tabela.

Sujeito 03		Grupo Frontal				Grupo Occipital			
		Janela Longa		Janela Curta		Janela Longa		Janela Curta	
		Filtro	Wavelet	Filtro	Wavelet	Filtro	Wavelet	Filtro	Wavelet
LDA	Ambos	65.6%	65.8%	83.3%	83.3%	65.7%	66.5%	83.3%	83.3%
	Direita	64.1%	63.9%	83.1%	83.3%	64.9%	64.7%	83.2%	83.3%
	Esquerda	65.9%	62.9%	83.3%	83.3%	64.0%	66.0%	83.4%	83.3%
QDA	Ambos	61.6%	59.7%	78.8%	81.9%	62.3%	62.4%	78.4%	83.3%
	Direita	61.9%	56.0%	79.1%	79.5%	60.7%	59.8%	82.2%	82.4%
	Esquerda	61.3%	58.5%	76.8%	81.7%	61.5%	65.0%	77.8%	81.0%

Tabela 4 – Os valores apresentados são percentuais de acerto obtidos através da validação cruzada para avaliação dos modelos de classificação para o sujeito 03, o procedimento foi realizado múltiplas vezes utilizando diferentes filtros, tamanhos de janelas, modelos de classificadores e grupamentos de eletrodos, os resultados específicos de cada combinação podem ser vistos nos cruzamentos da tabela.

Sujeito 04		Grupo Frontal				Grupo Occipital			
		Janela Longa		Janela Curta		Janela Longa		Janela Curta	
		Filtro	Wavelet	Filtro	Wavelet	Filtro	Wavelet	Filtro	Wavelet
LDA	Ambos	63.6%	66.3%	83.3%	83.3%	65.6%	66.1%	83.2%	83.3%
	Direita	61.8%	64.4%	83.3%	83.2%	62.6%	63.4%	83.2%	83.0%
	Esquerda	64.0%	65.8%	83.1%	83.1%	64.3%	64.7%	83.3%	83.3%
QDA	Ambos	58.0%	62.5%	83.1%	82.5%	65.2%	63.0%	78.7%	83.2%
	Direita	53.8%	61.7%	79.2%	79.1%	65.5%	62.3%	82.8%	83.0%
	Esquerda	61.5%	60.7%	81.4%	81.7%	64.4%	59.8%	76.2%	80.9%

Tabela 5 – Os valores apresentados são percentuais de acerto obtidos através da validação cruzada para avaliação dos modelos de classificação para o sujeito 04, o procedimento foi realizado múltiplas vezes utilizando diferentes filtros, tamanhos de janelas, modelos de classificadores e grupamentos de eletrodos, os resultados específicos de cada combinação podem ser vistos nos cruzamentos da tabela.

Sujeito 05		Grupo Frontal				Grupo Occipital			
		Janela Longa		Janela Curta		Janela Longa		Janela Curta	
		Filtro	Wavelet	Filtro	Wavelet	Filtro	Wavelet	Filtro	Wavelet
LDA	Ambos	66.2%	66.0%	83.3%	83.3%	65.7%	66.1%	83.3%	83.3%
	Direita	64.7%	64.0%	83.3%	83.3%	63.1%	65.6%	83.1%	83.3%
	Esquerda	66.4%	63.2%	83.4%	83.3%	65.6%	64.3%	83.7%	83.3%
QDA	Ambos	64.3%	61.7%	80.8%	81.6%	51.5%	61.8%	80.1%	83.1%
	Direita	60.2%	59.8%	75.4%	82.7%	61.0%	62.5%	77.4%	82.9%
	Esquerda	63.1%	58.4%	82.5%	81.8%	49.3%	57.3%	62.3%	83.0%

Tabela 6 – Os valores apresentados são percentuais de acerto obtidos através da validação cruzada para avaliação dos modelos de classificação para o sujeito 05, o procedimento foi realizado múltiplas vezes utilizando diferentes filtros, tamanhos de janelas, modelos de classificadores e grupamentos de eletrodos, os resultados específicos de cada combinação podem ser vistos nos cruzamentos da tabela.

APÊNDICE D – Gráficos das médias dos sinais

Gráficos das médias do EEG para todas as amostras e para todos os canais de todos os sujeitos:




Figura 29 – Média das amostras EEG do sujeito 01 eletrodo AF3, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.

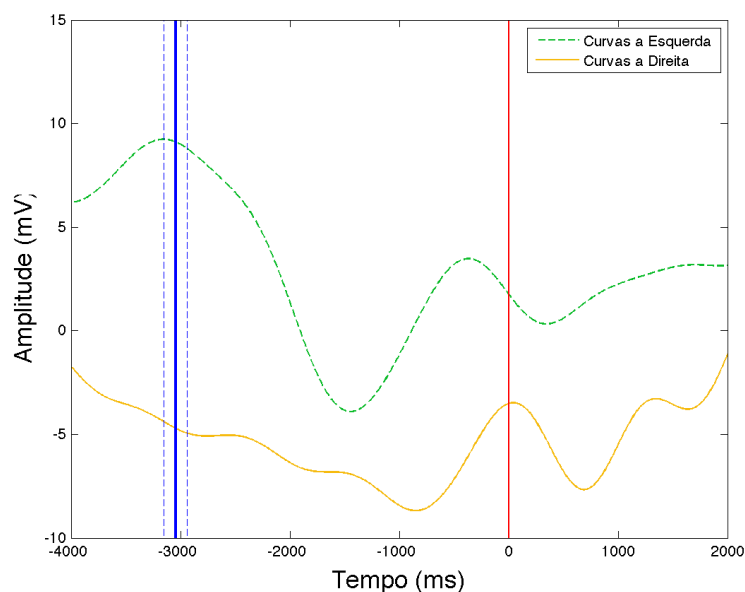


Figura 30 – Média das amostras EEG do sujeito 01 eletrodo AF4, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 31 – Média das amostras EEG do sujeito 01 eletrodo F3, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 32 – Média das amostras EEG do sujeito 01 eletrodo F4, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 33 – Média das amostras EEG do sujeito 01 eletrodo F7, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 34 – Média das amostras EEG do sujeito 01 eletrodo F8, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 35 – Média das amostras EEG do sujeito 01 eletrodo FC5, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 36 – Média das amostras EEG do sujeito 01 eletrodo FC6, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 37 – Média das amostras EEG do sujeito 01 eletrodo O1, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 38 – Média das amostras EEG do sujeito 01 eletrodo O2, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 39 – Média das amostras EEG do sujeito 01 eletrodo P7, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 40 – Média das amostras EEG do sujeito 01 eletrodo P8, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 41 – Média das amostras EEG do sujeito 01 eletrodo T7, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 42 – Média das amostras EEG do sujeito 01 eletrodo T8, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 43 – Média das amostras EEG do sujeito 02 eletrodo AF3, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 44 – Média das amostras EEG do sujeito 02 eletrodo AF4, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 45 – Média das amostras EEG do sujeito 01 eletrodo F3, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 46 – Média das amostras EEG do sujeito 01 eletrodo F4, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 47 – Média das amostras EEG do sujeito 01 eletrodo F7, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 48 – Média das amostras EEG do sujeito 01 eletrodo F8, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 49 – Média das amostras EEG do sujeito 01 eletrodo FC5, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 50 – Média das amostras EEG do sujeito 01 eletrodo FC6, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 51 – Média das amostras EEG do sujeito 01 eletrodo O1, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 52 – Média das amostras EEG do sujeito 01 eletrodo O2, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 53 – Média das amostras EEG do sujeito 01 eletrodo P7, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 54 – Média das amostras EEG do sujeito 01 eletrodo P8, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 55 – Média das amostras EEG do sujeito 01 eletrodo T7, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 56 – Média das amostras EEG do sujeito 01 eletrodo T8, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 57 – Média das amostras EEG do sujeito 03 eletrodo AF3, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 58 – Média das amostras EEG do sujeito 03 eletrodo AF4, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 59 – Média das amostras EEG do sujeito 03 eletrodo F3, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 60 – Média das amostras EEG do sujeito 03 eletrodo F4, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 61 – Média das amostras EEG do sujeito 03 eletrodo F7, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 62 – Média das amostras EEG do sujeito 03 eletrodo F8, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 63 – Média das amostras EEG do sujeito 03 eletrodo FC5, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 64 – Média das amostras EEG do sujeito 03 eletrodo FC6, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 65 – Média das amostras EEG do sujeito 03 eletrodo O1, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 66 – Média das amostras EEG do sujeito 03 eletrodo O2, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 67 – Média das amostras EEG do sujeito 03 eletrodo P7, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 68 – Média das amostras EEG do sujeito 03 eletrodo P8, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 69 – Média das amostras EEG do sujeito 03 eletrodo T7, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 70 – Média das amostras EEG do sujeito 03 eletrodo T8, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 71 – Média das amostras EEG do sujeito 04 eletrodo AF3, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 72 – Média das amostras EEG do sujeito 04 eletrodo AF4, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 73 – Média das amostras EEG do sujeito 04 eletrodo F3, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 74 – Média das amostras EEG do sujeito 04 eletrodo F4, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 75 – Média das amostras EEG do sujeito 04 eletrodo F7, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 76 – Média das amostras EEG do sujeito 04 eletrodo F8, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 77 – Média das amostras EEG do sujeito 04 eletrodo FC5, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 78 – Média das amostras EEG do sujeito 04 eletrodo FC6, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 79 – Média das amostras EEG do sujeito 04 eletrodo O1, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 80 – Média das amostras EEG do sujeito 04 eletrodo O2, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 81 – Média das amostras EEG do sujeito 04 eletrodo P7, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 82 – Média das amostras EEG do sujeito 04 eletrodo P8, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 83 – Média das amostras EEG do sujeito 04 eletrodo T7, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 84 – Média das amostras EEG do sujeito 04 eletrodo T8, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 85 – Média das amostras EEG do sujeito 05 eletrodo AF3, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 86 – Média das amostras EEG do sujeito 05 eletrodo AF4, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 87 – Média das amostras EEG do sujeito 05 eletrodo F3, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 88 – Média das amostras EEG do sujeito 05 eletrodo F4, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 89 – Média das amostras EEG do sujeito 05 eletrodo F7, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 90 – Média das amostras EEG do sujeito 05 eletrodo F8, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 91 – Média das amostras EEG do sujeito 05 eletrodo FC5, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 92 – Média das amostras EEG do sujeito 05 eletrodo FC6, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 93 – Média das amostras EEG do sujeito 05 eletrodo O1, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 94 – Média das amostras EEG do sujeito 05 eletrodo O2, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 95 – Média das amostras EEG do sujeito 05 eletrodo P7, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 96 – Média das amostras EEG do sujeito 05 eletrodo P8, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 97 – Média das amostras EEG do sujeito 05 eletrodo T7, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.




Figura 98 – Média das amostras EEG do sujeito 05 eletrodo T8, onde cada curva representa a média para um tipo de amostra, verde tracejada esquerda e amarela contínua direita.

APÊNDICE E – Gráficos das decomposições tempo-frequência e coerência de fase

Gráficos da decomposição tempo-frequência e da coerência de fase do EEG para todas os dias de registro e para todos os canais de todos os sujeitos:




Figura 99 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 01, dia 1, eletrodo AF3.





Figura 100 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 01, dia 1, eletrodo AF4.

Decomposição tempo-frequência



Coerência de fase




Figura 101 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 01, dia 1, eletrodo F3.

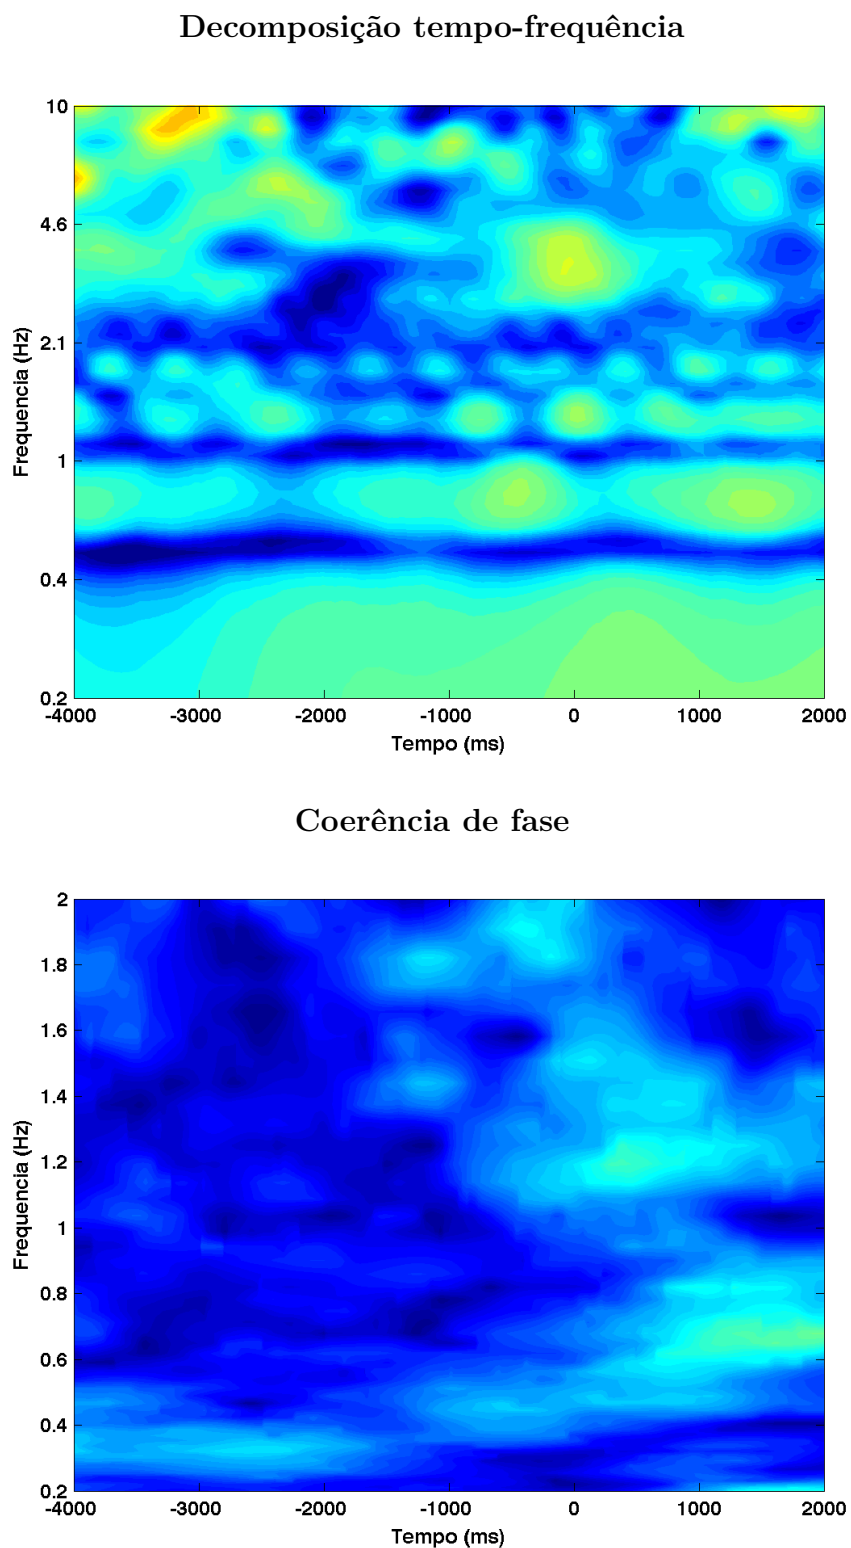



Figura 102 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 01, dia 1, eletrodo F4.

Decomposição tempo-frequência



Coerência de fase





Figura 103 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 01, dia 1, eletrodo F7.

Decomposição tempo-frequência



Coerência de fase





Figura 104 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 01, dia 1, eletrodo F8.

Decomposição tempo-frequência



Coerência de fase




Figura 105 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 01, dia 1, eletrodo FC5.





Figura 106 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 01, dia 1, eletrodo FC6.

Decomposição tempo-frequência



Coerência de fase




Figura 107 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 01, dia 1, eletrodo O1.





Figura 108 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 01, dia 1, eletrodo O2.

Decomposição tempo-frequência



Coerência de fase




Figura 109 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 01, dia 1, eletrodo P7.

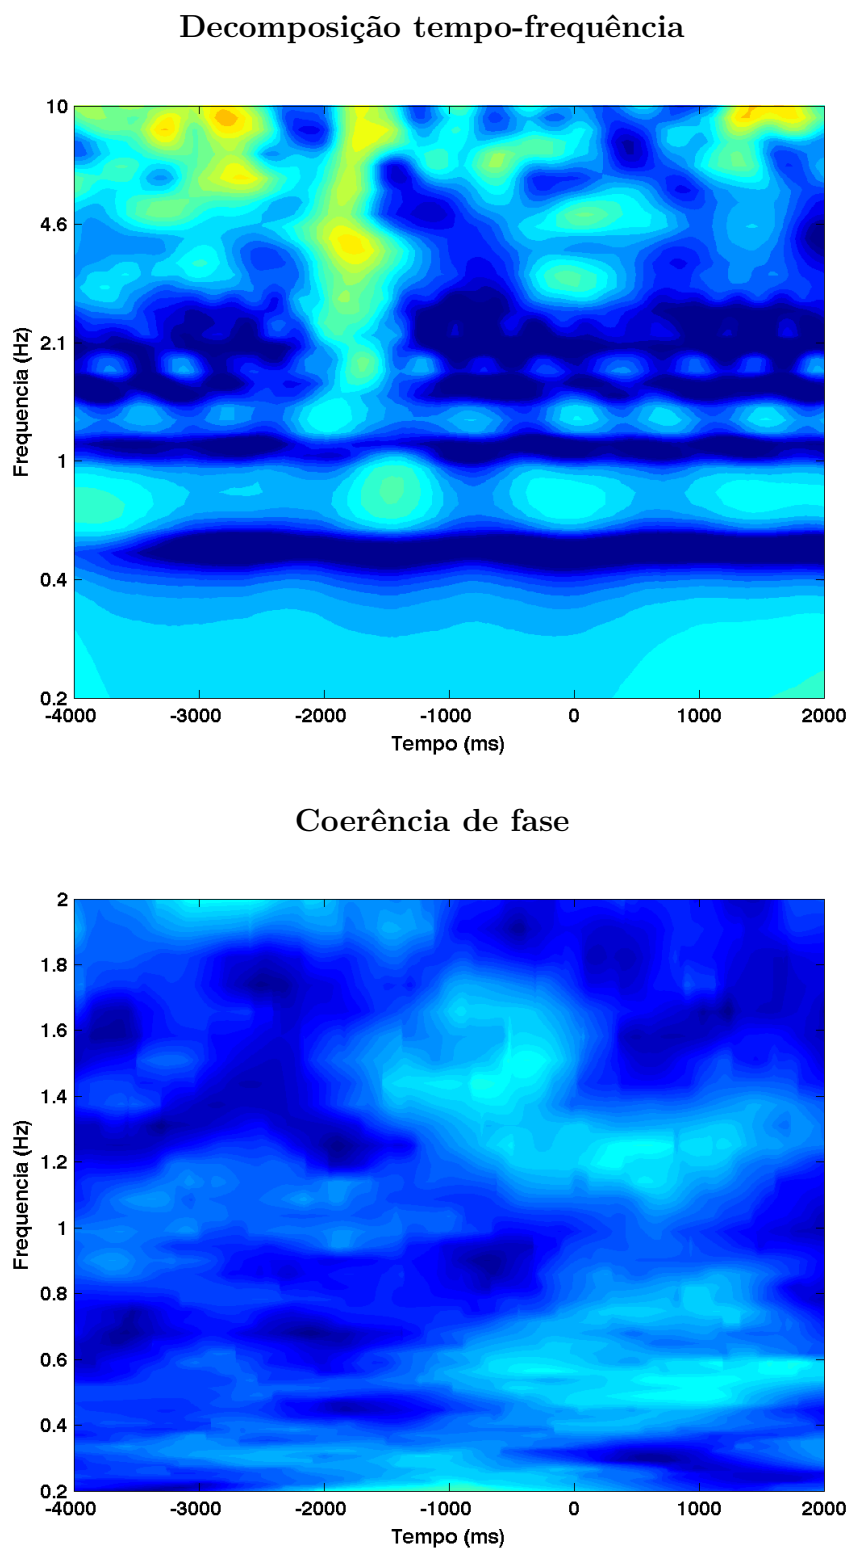



Figura 110 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 01, dia 1, eletrodo P8.

Decomposição tempo-frequência



Coerência de fase




Figura 111 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 01, dia 1, eletrodo T7.

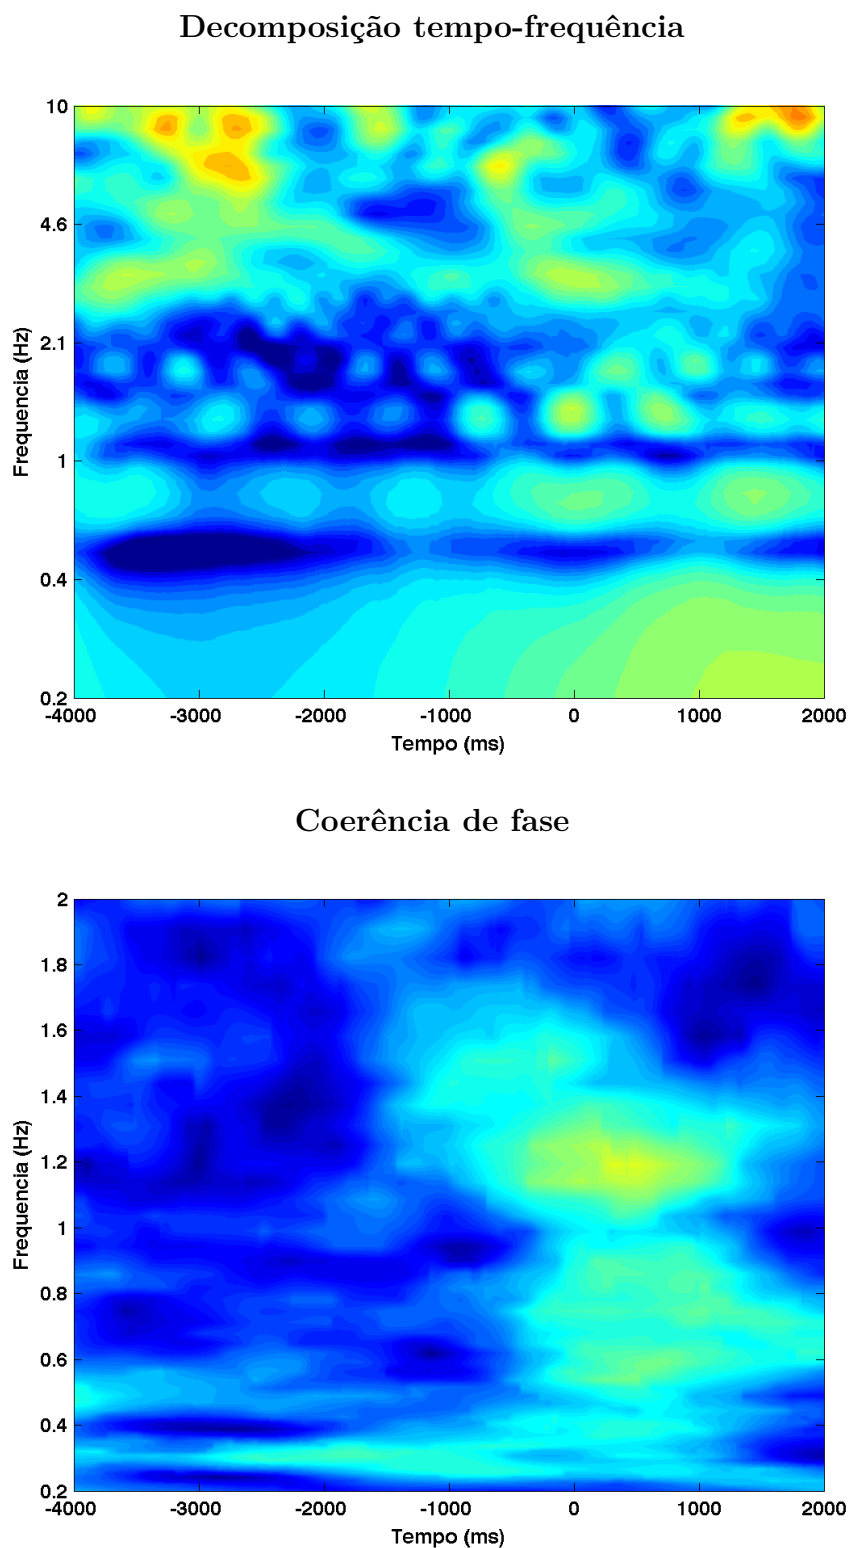


Figura 112 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 01, dia 1, eletrodo T8.





Figura 113 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 01, dia 2, eletrodo AF3.

Decomposição tempo-frequência



Coerência de fase




Figura 114 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 01, dia 2, eletrodo AF4.

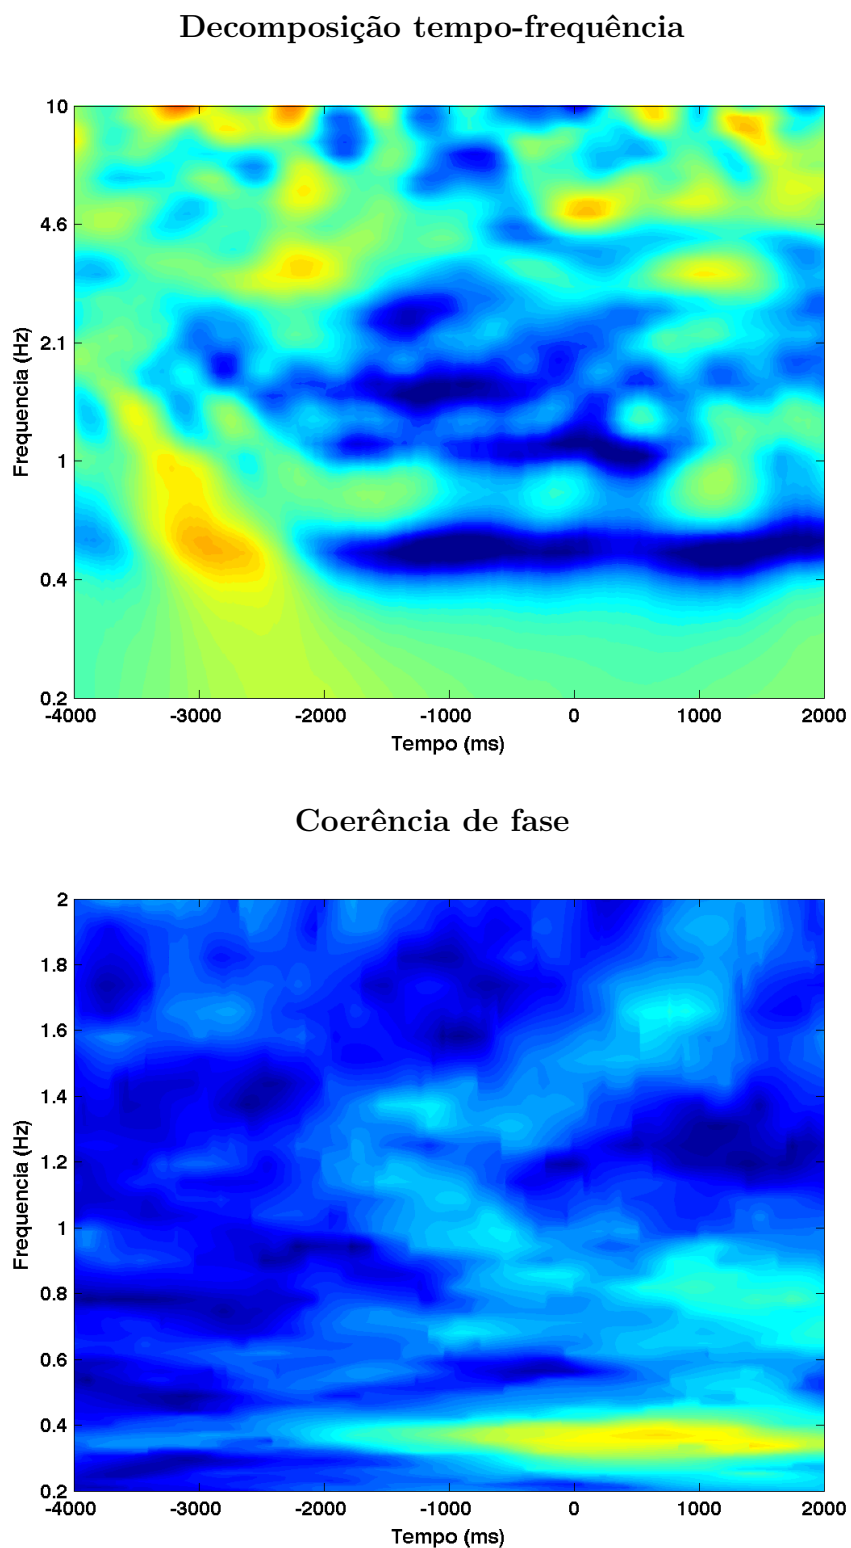



Figura 115 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 01, dia 2, eletrodo F3.

Decomposição tempo-frequência



Coerência de fase




Figura 116 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 01, dia 2, eletrodo F4.

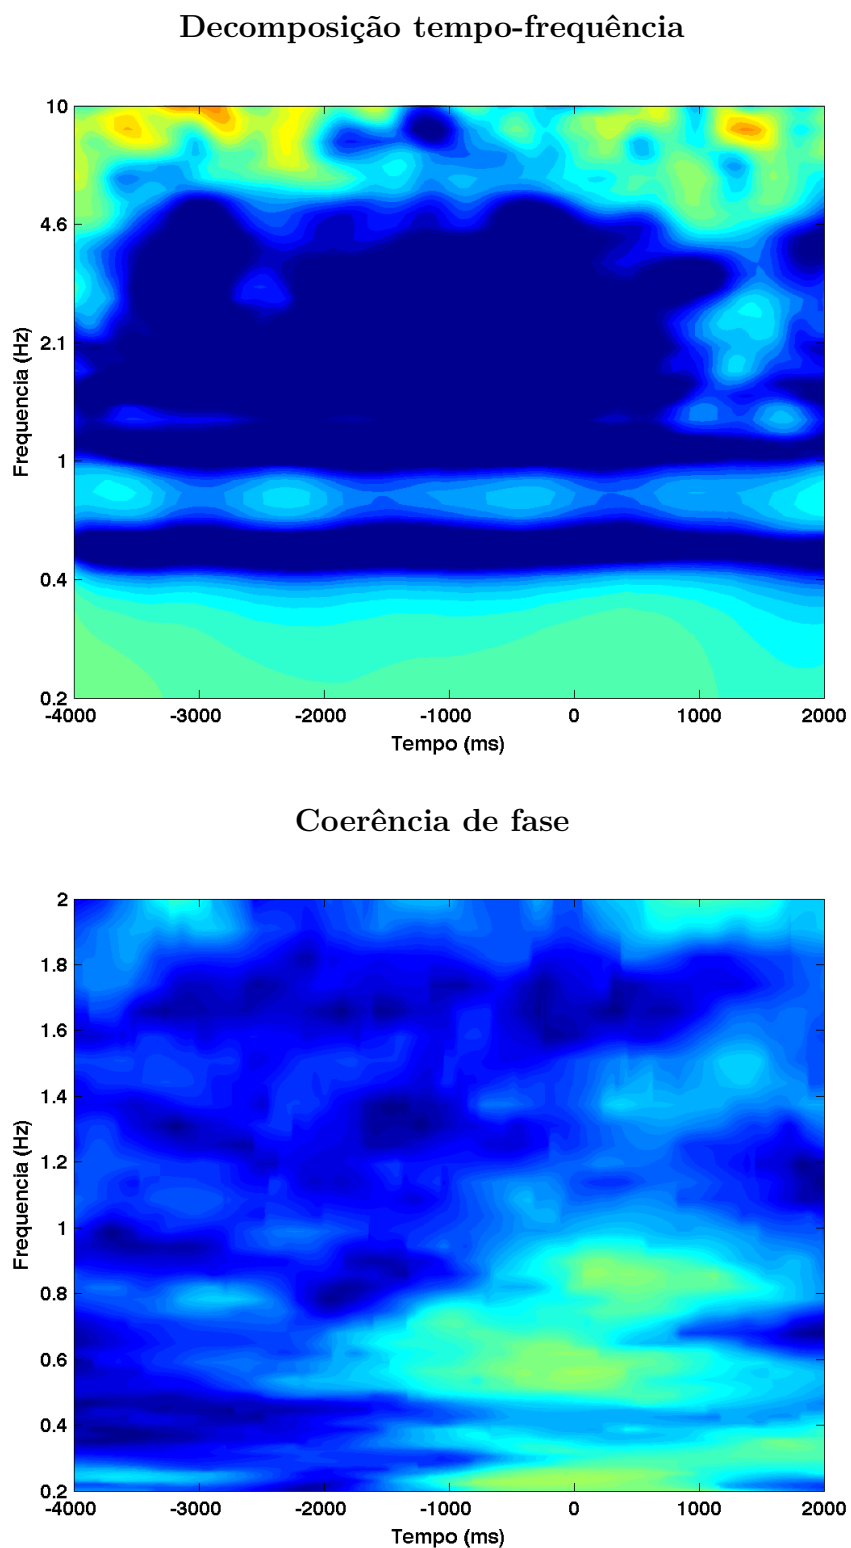


Figura 117 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 01, dia 2, eletrodo F7.

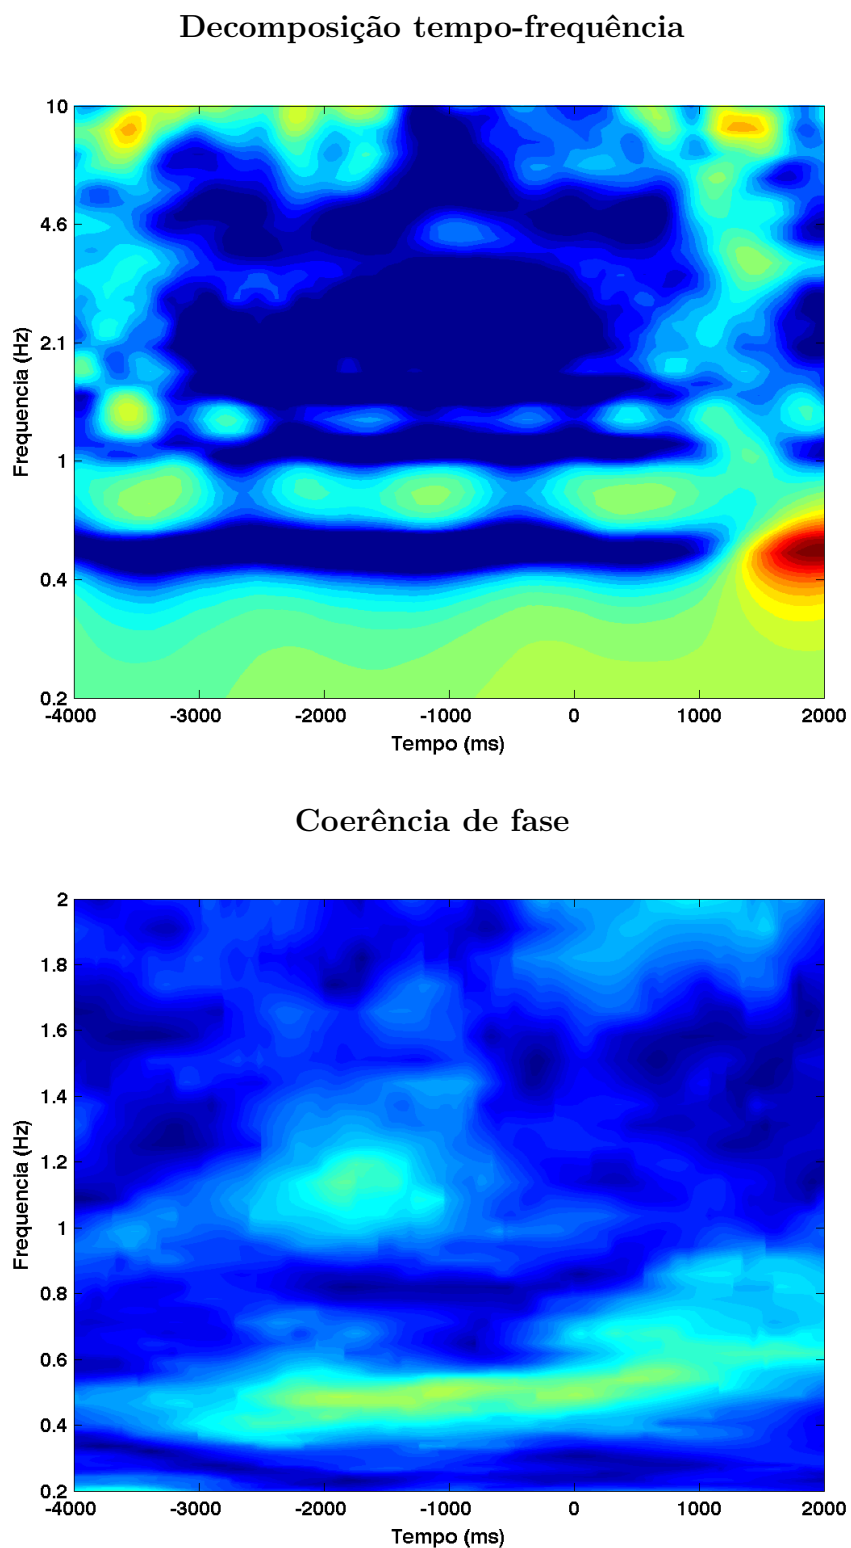


Figura 118 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 01, dia 2, eletrodo F8.

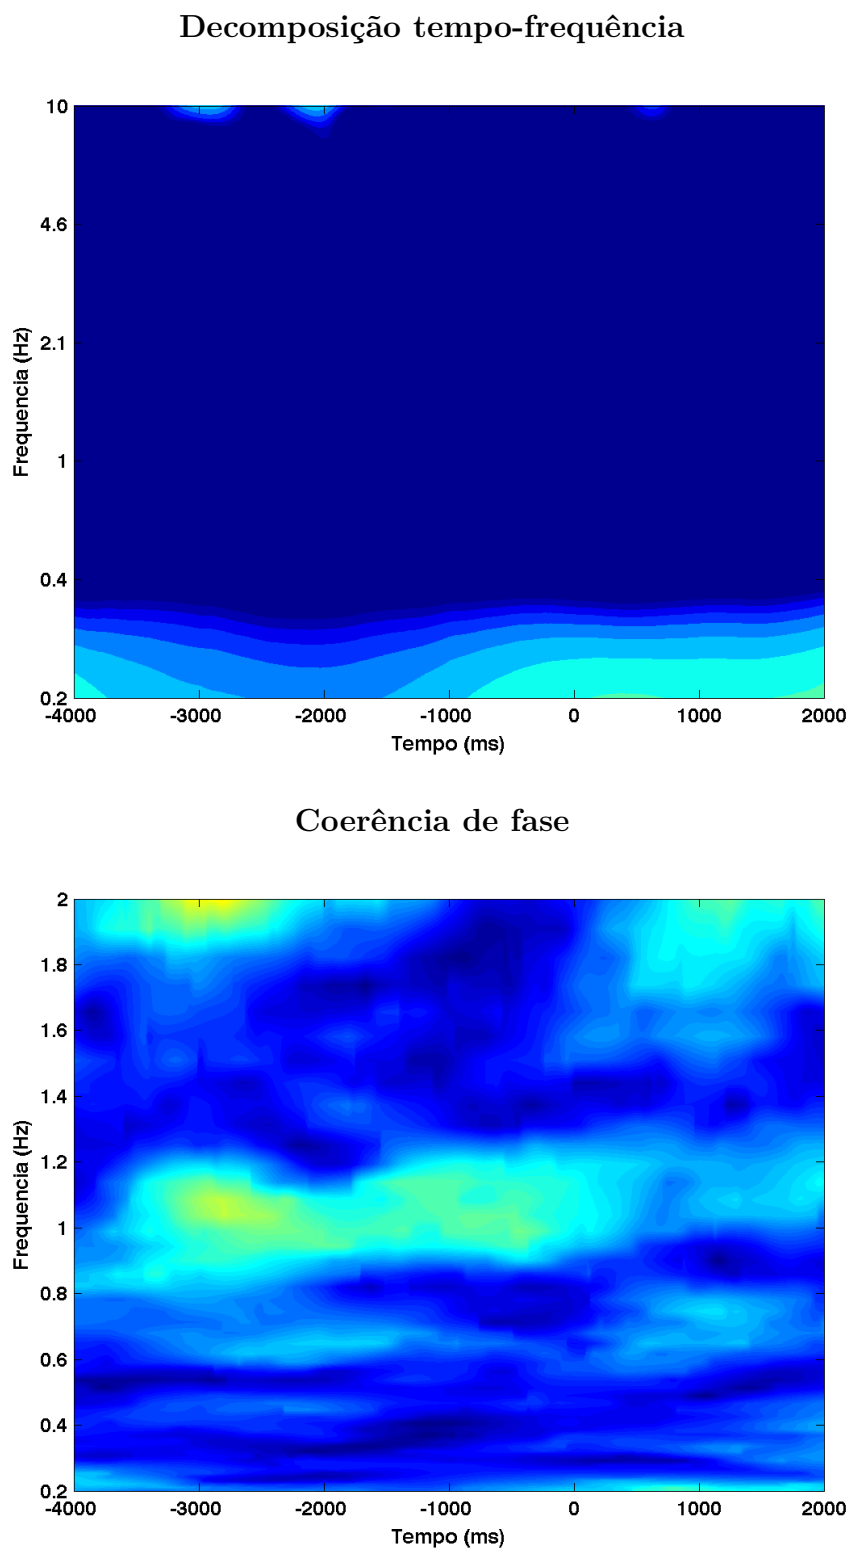


Figura 119 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 01, dia 2, eletrodo FC5.

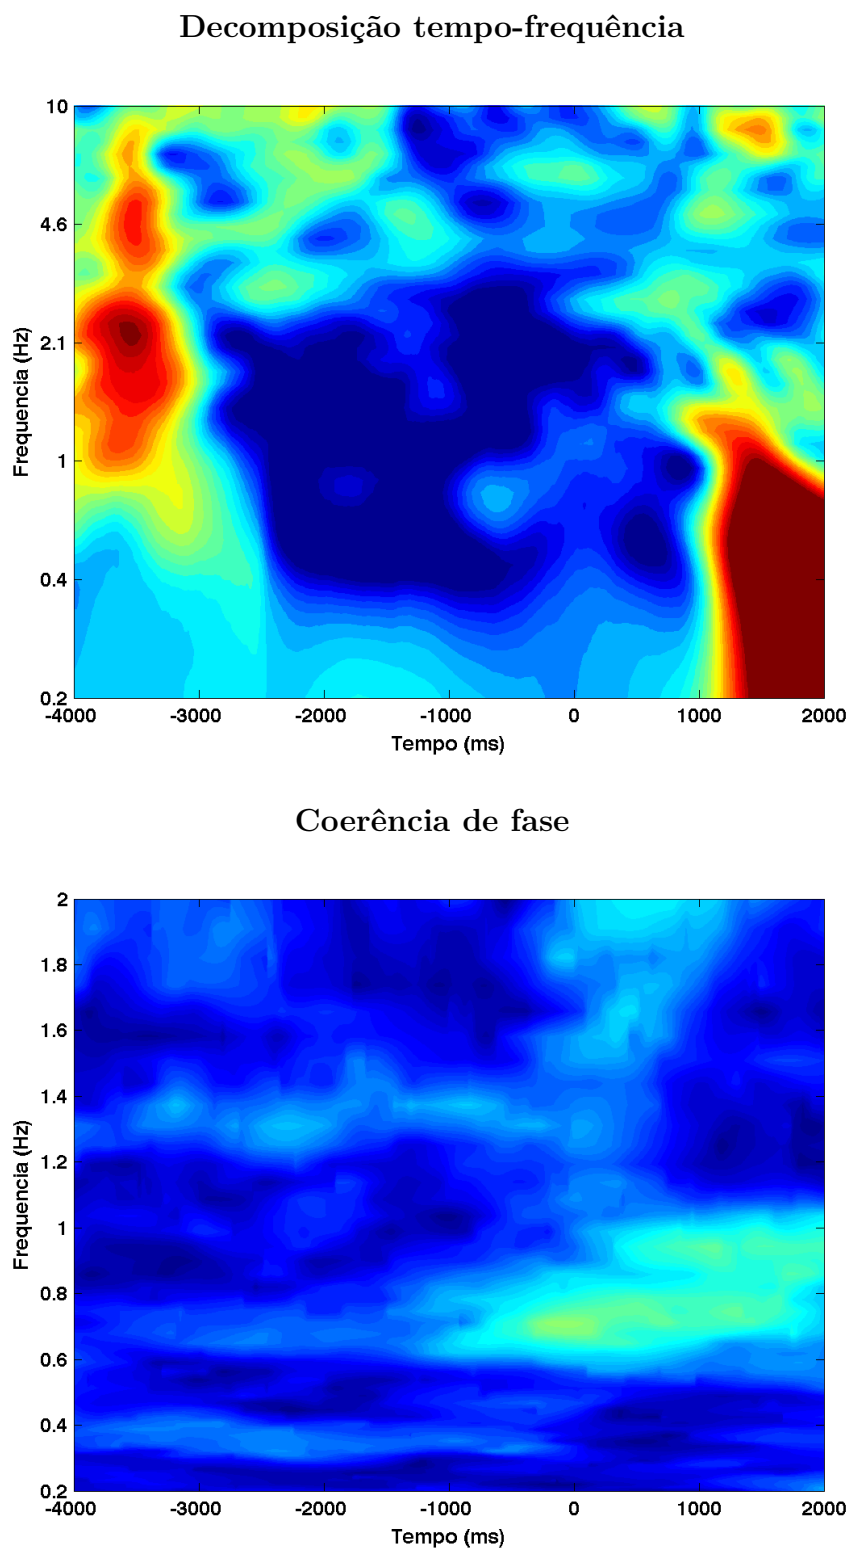



Figura 120 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 01, dia 2, eletrodo FC6.

Decomposição tempo-frequência



Coerência de fase





Figura 121 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 01, dia 2, eletrodo O1.

Decomposição tempo-frequência



Coerência de fase





Figura 122 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 01, dia 2, eletrodo O2.

Decomposição tempo-frequência



Coerência de fase





Figura 123 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 01, dia 2, eletrodo P7.

Decomposição tempo-frequência



Coerência de fase





Figura 124 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 01, dia 2, eletrodo P8.

Decomposição tempo-frequência



Coerência de fase





Figura 125 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 01, dia 2, eletrodo T7.

Decomposição tempo-frequência



Coerência de fase




Figura 126 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 01, dia 2, eletrodo T8.

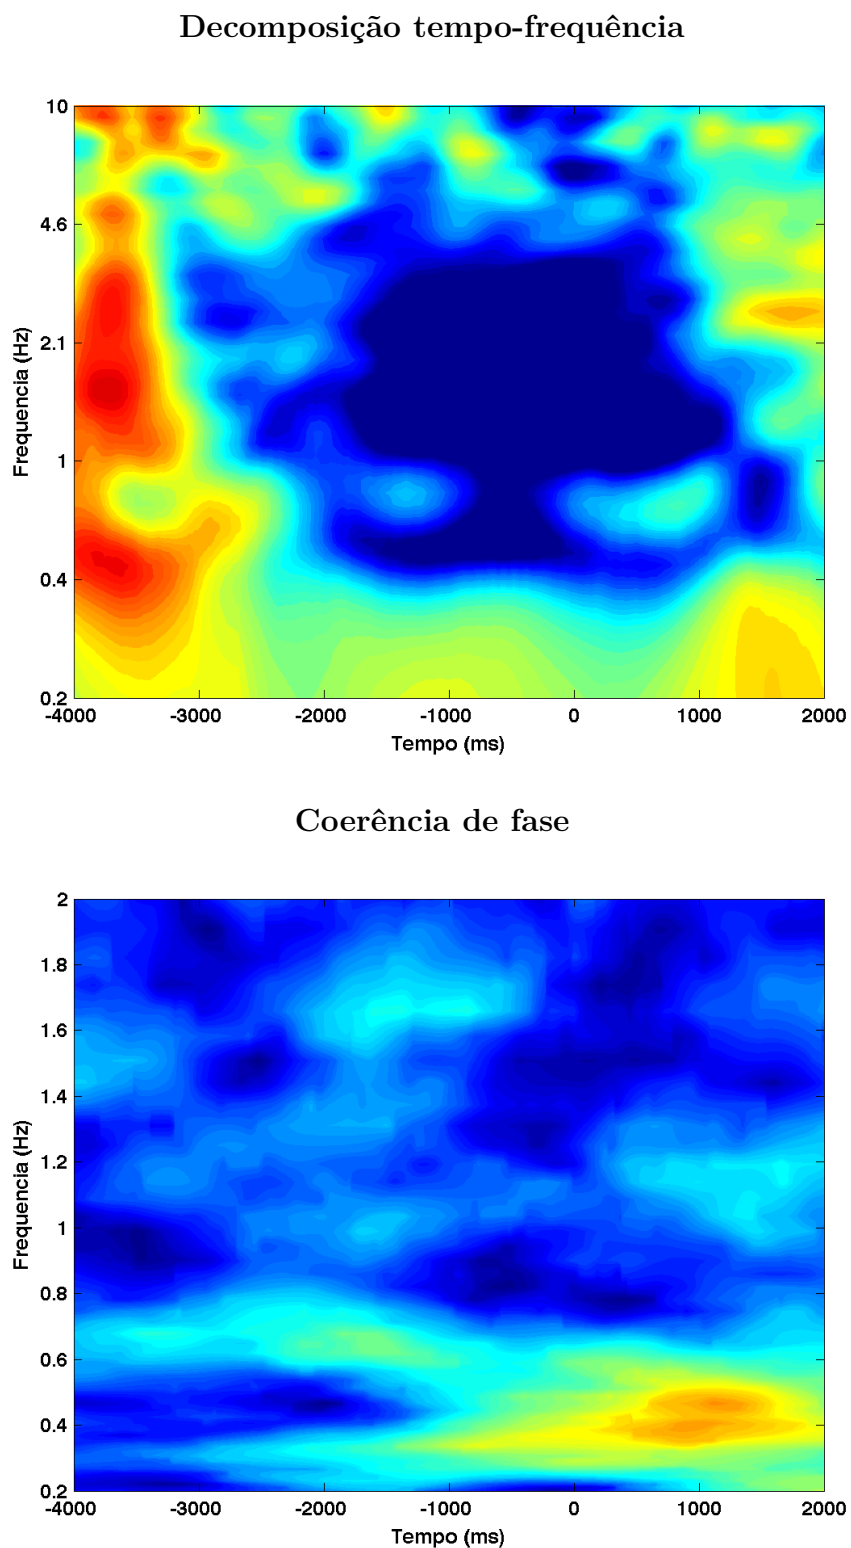


Figura 127 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 01, dia 3, eletrodo AF3.

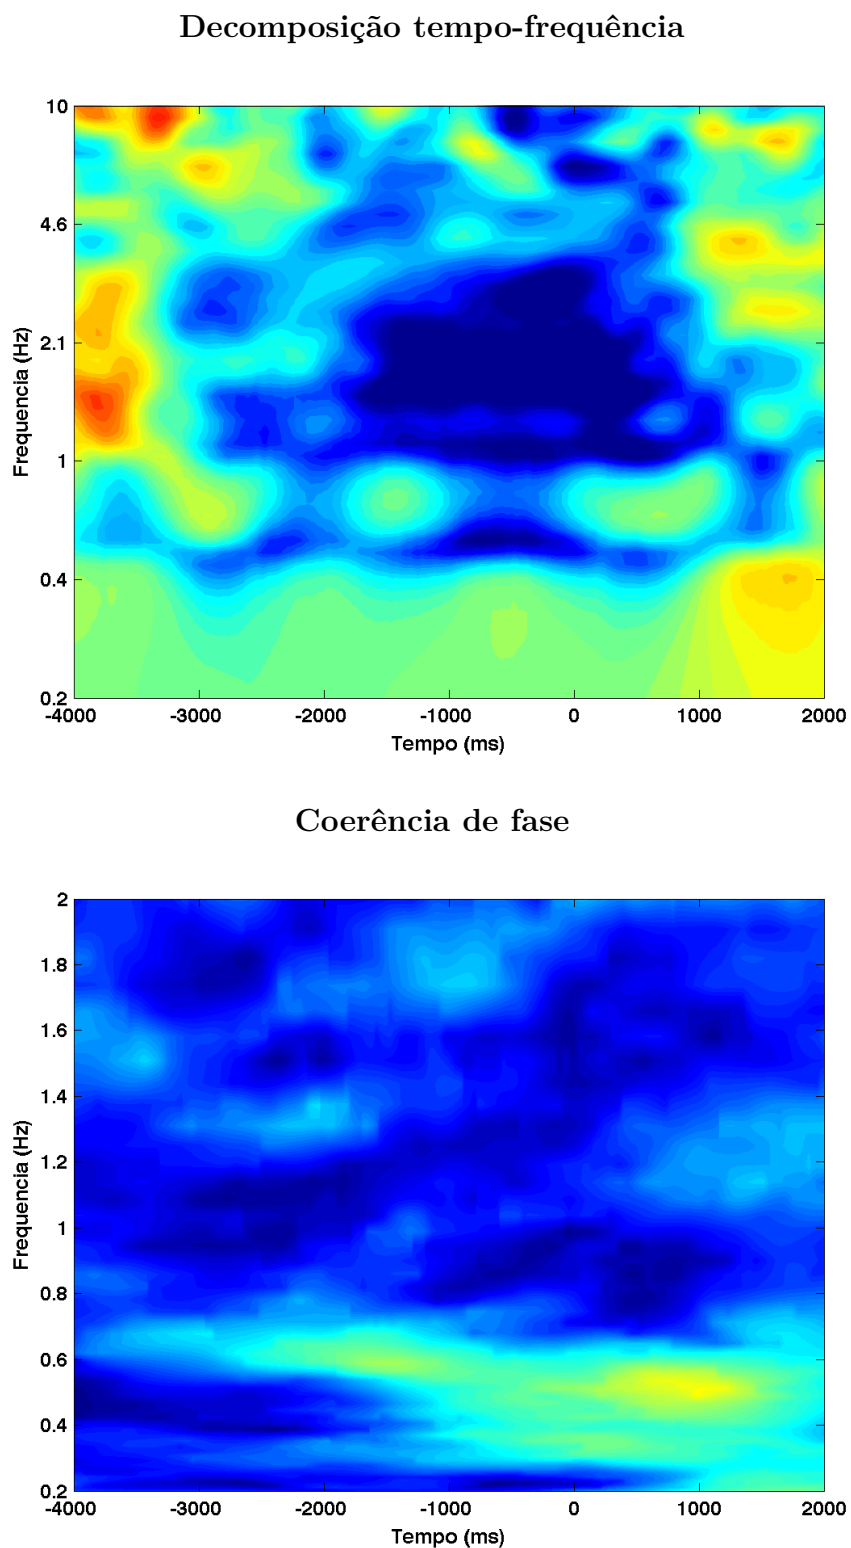



Figura 128 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 01, dia 3, eletrodo AF4.

Decomposição tempo-frequência



Coerência de fase





Figura 129 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 01, dia 3, eletrodo F3.

Decomposição tempo-frequência



Coerência de fase





Figura 130 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 01, dia 3, eletrodo F4.

Decomposição tempo-frequência



Coerência de fase




Figura 131 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 01, dia 3, eletrodo F7.




Figura 132 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 01, dia 3, eletrodo F8.

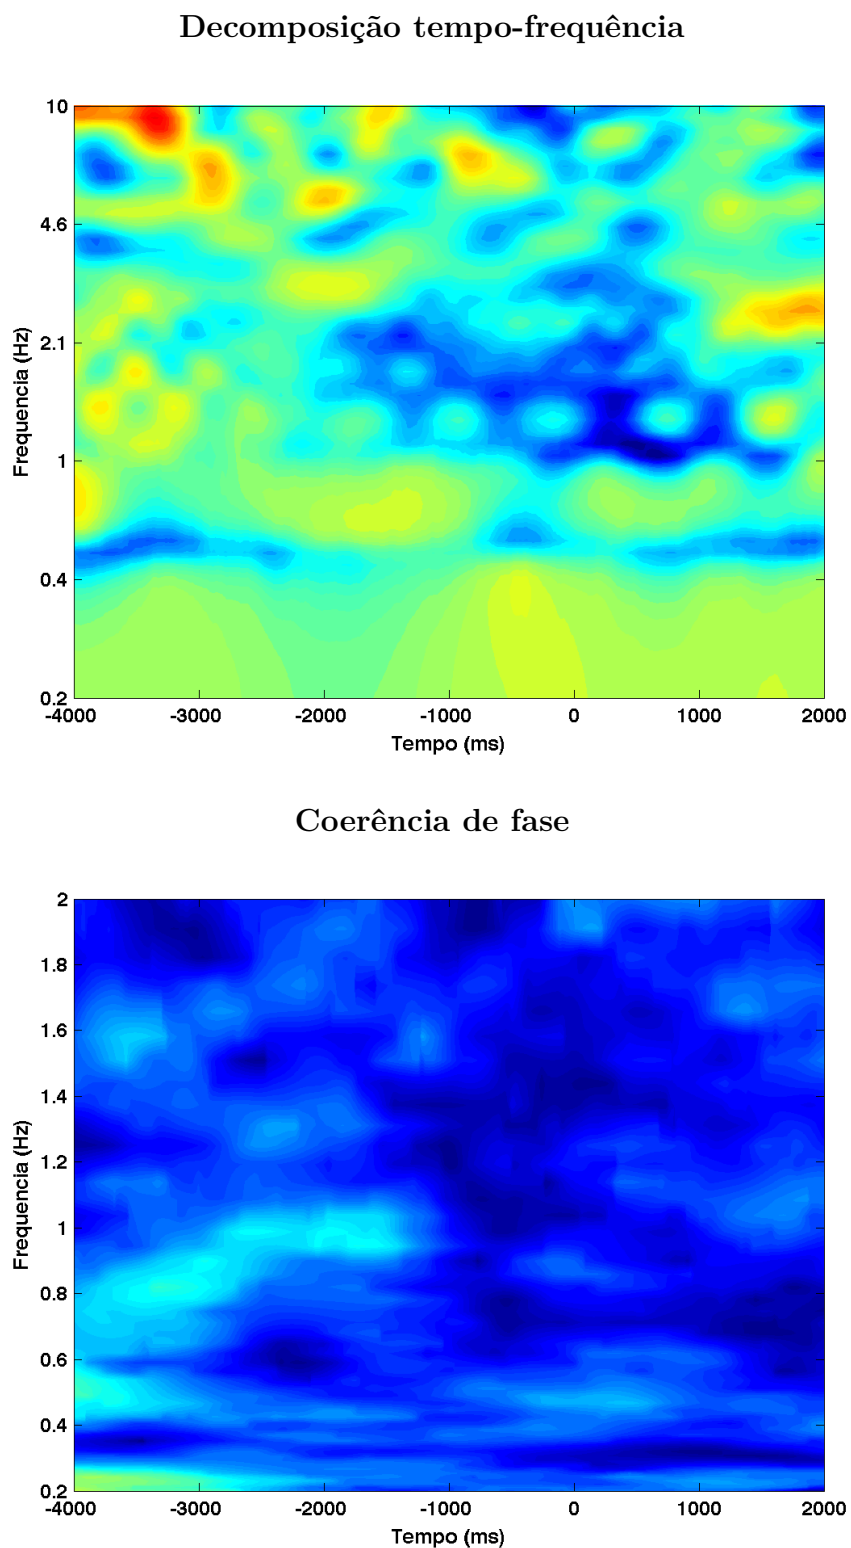


Figura 133 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 01, dia 3, eletrodo FC5.

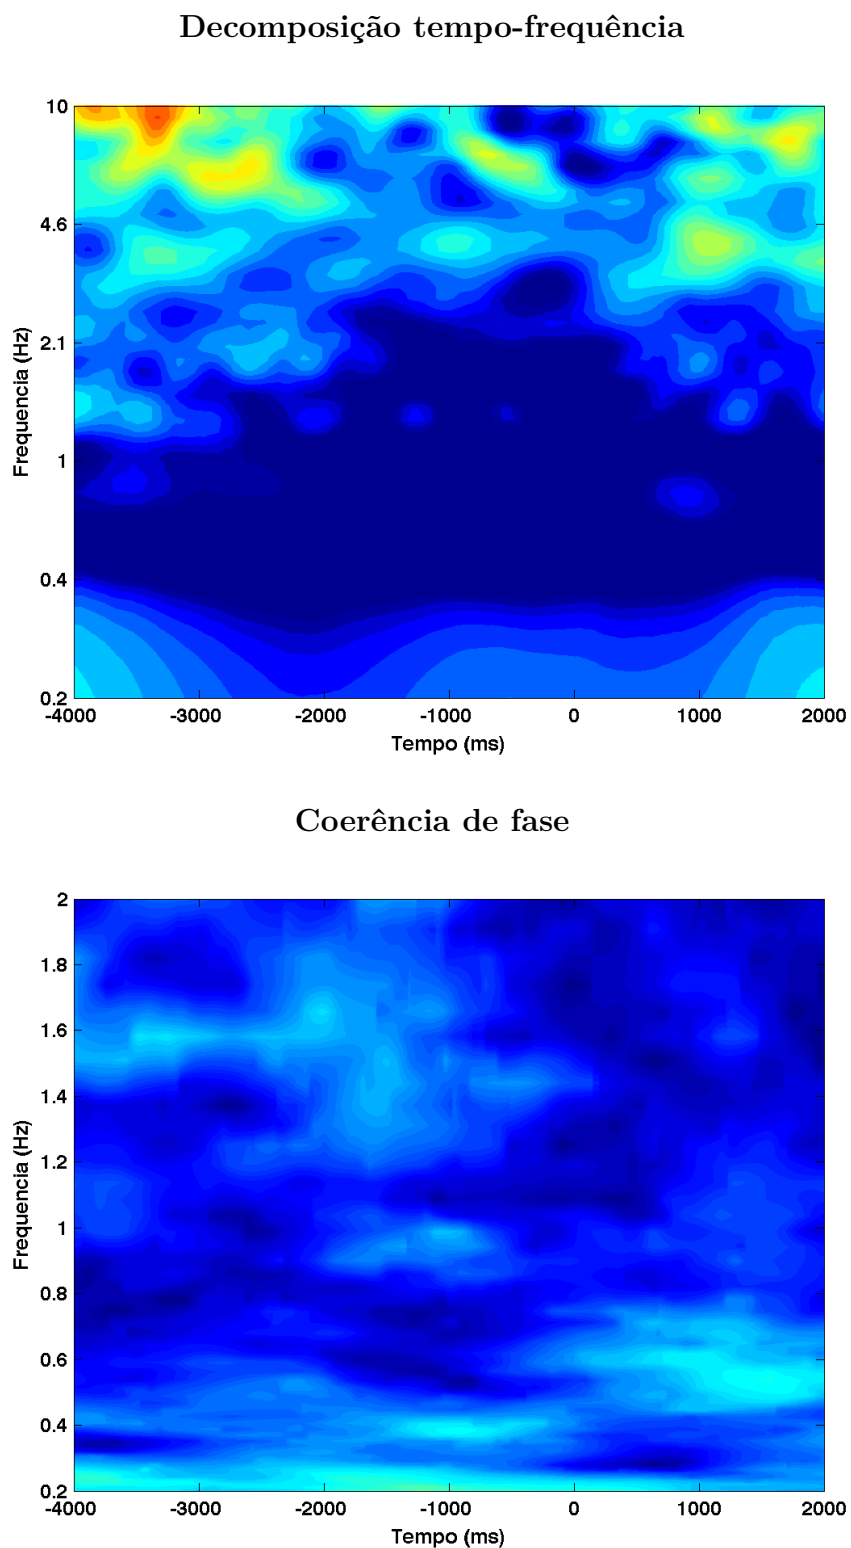



Figura 134 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 01, dia 3, eletrodo FC6.

Decomposição tempo-frequência



Coerência de fase





Figura 135 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 01, dia 3, eletrodo O1.

Decomposição tempo-frequência



Coerência de fase




Figura 136 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 01, dia 3, eletrodo O2.

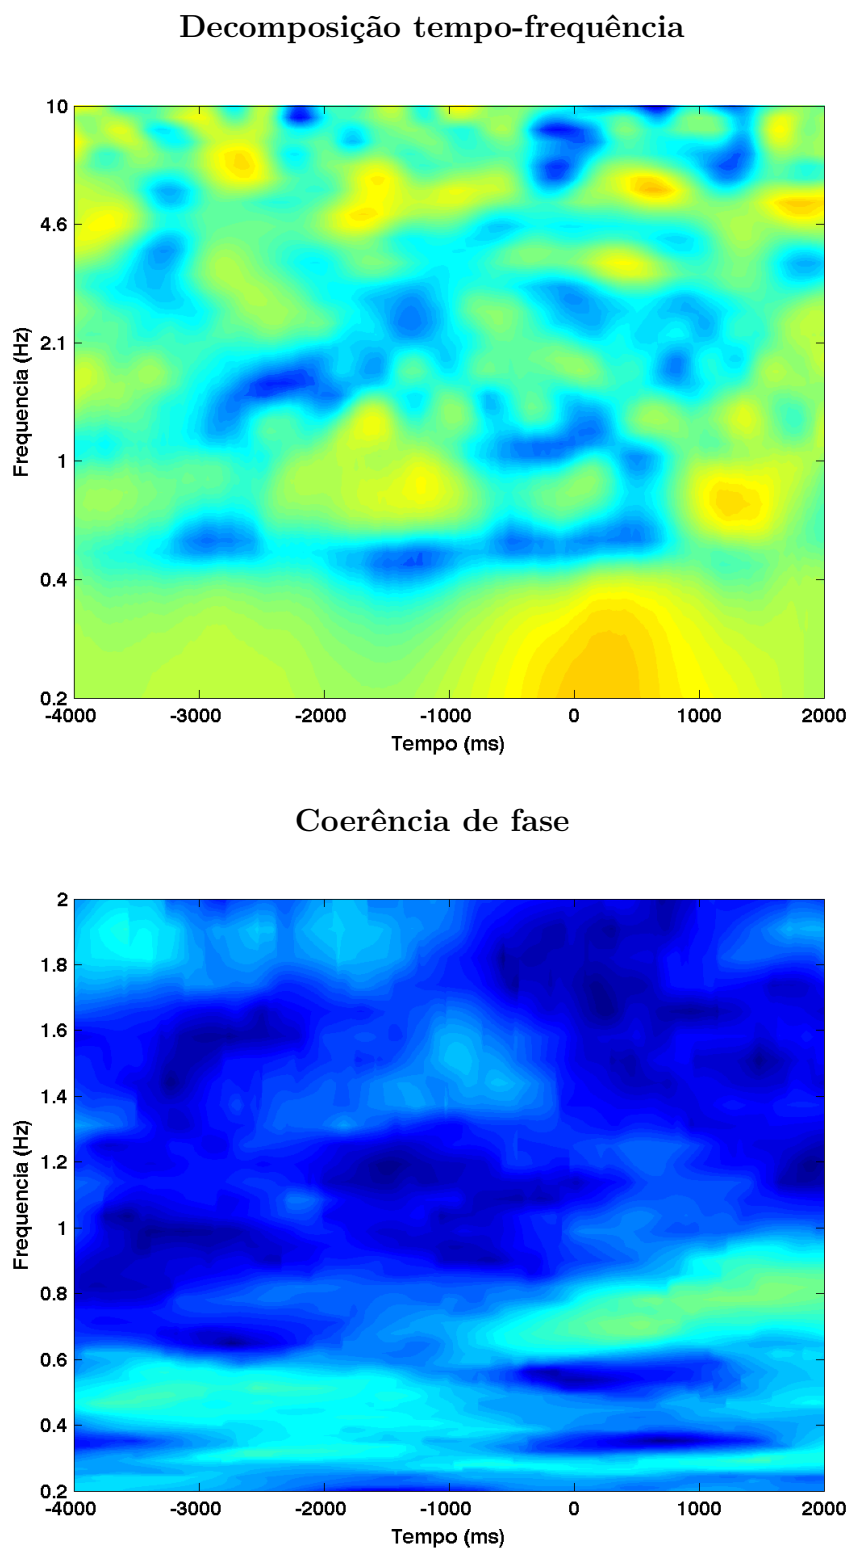



Figura 137 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 01, dia 3, eletrodo P7.

Decomposição tempo-frequência



Coerência de fase





Figura 138 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 01, dia 3, eletrodo P8.

Decomposição tempo-frequência



Coerência de fase





Figura 139 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 01, dia 3, eletrodo T7.

Decomposição tempo-frequência



Coerência de fase





Figura 140 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 01, dia 3, eletrodo T8.

Decomposição tempo-frequência



Coerência de fase





Figura 141 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 01, dia 4, eletrodo AF3.

Decomposição tempo-frequência



Coerência de fase




Figura 142 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 01, dia 4, eletrodo AF4.

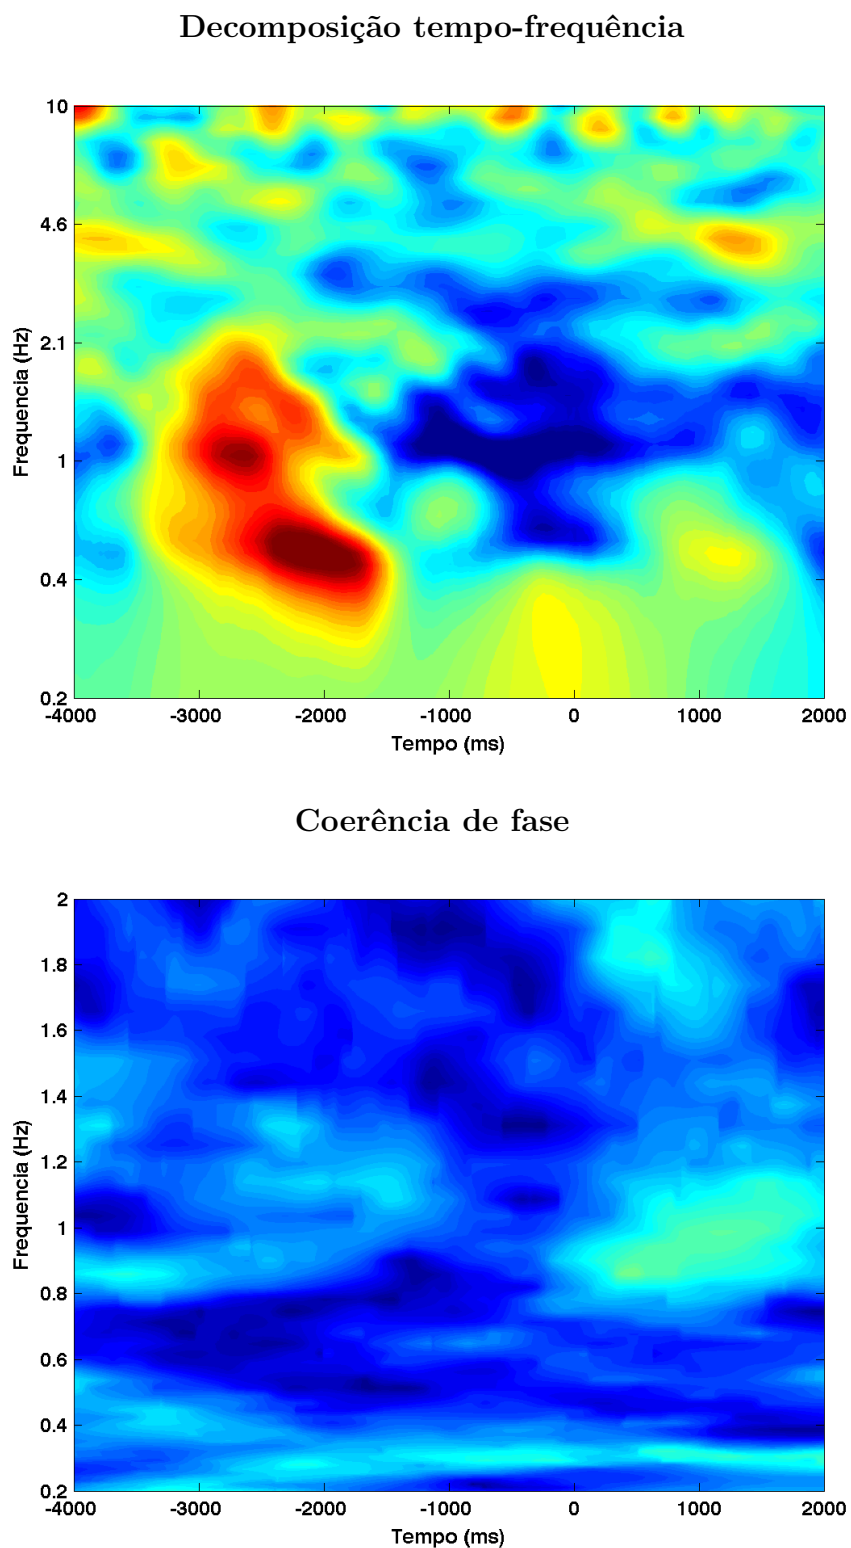



Figura 143 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 01, dia 4, eletrodo F3.

Decomposição tempo-frequência



Coerência de fase





Figura 144 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 01, dia 4, eletrodo F4.

Decomposição tempo-frequência



Coerência de fase





Figura 145 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 01, dia 4, eletrodo F7.

Decomposição tempo-frequência



Coerência de fase





Figura 146 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 01, dia 4, eletrodo F8.

Decomposição tempo-frequência



Coerência de fase





Figura 147 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 01, dia 4, eletrodo FC5.

Decomposição tempo-frequência



Coerência de fase




Figura 148 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 01, dia 4, eletrodo FC6.

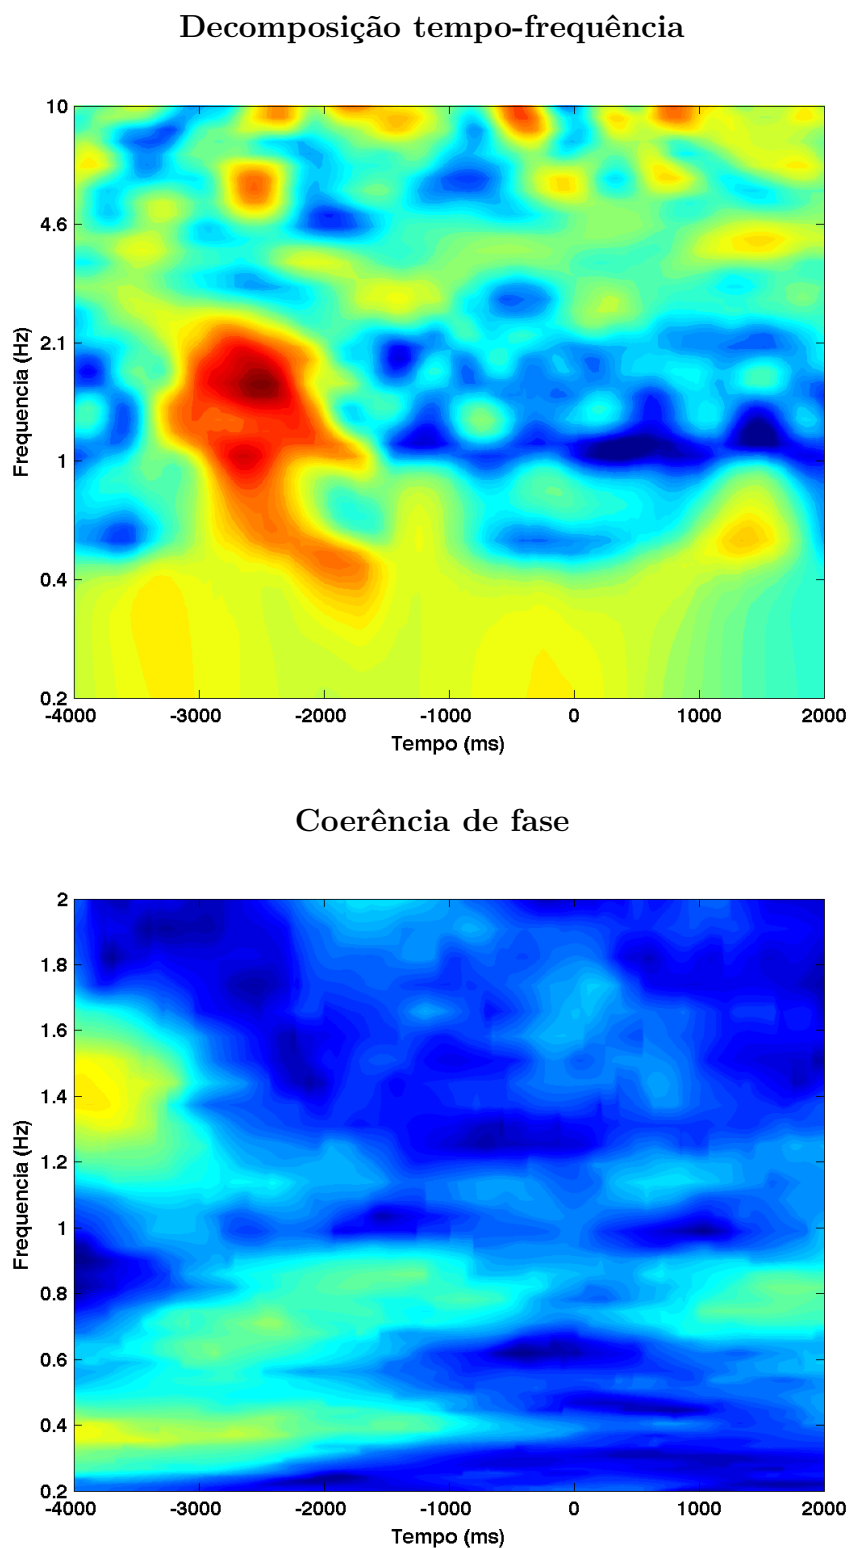



Figura 149 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 01, dia 4, eletrodo O1.

Decomposição tempo-frequência



Coerência de fase




Figura 150 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 01, dia 4, eletrodo O2.

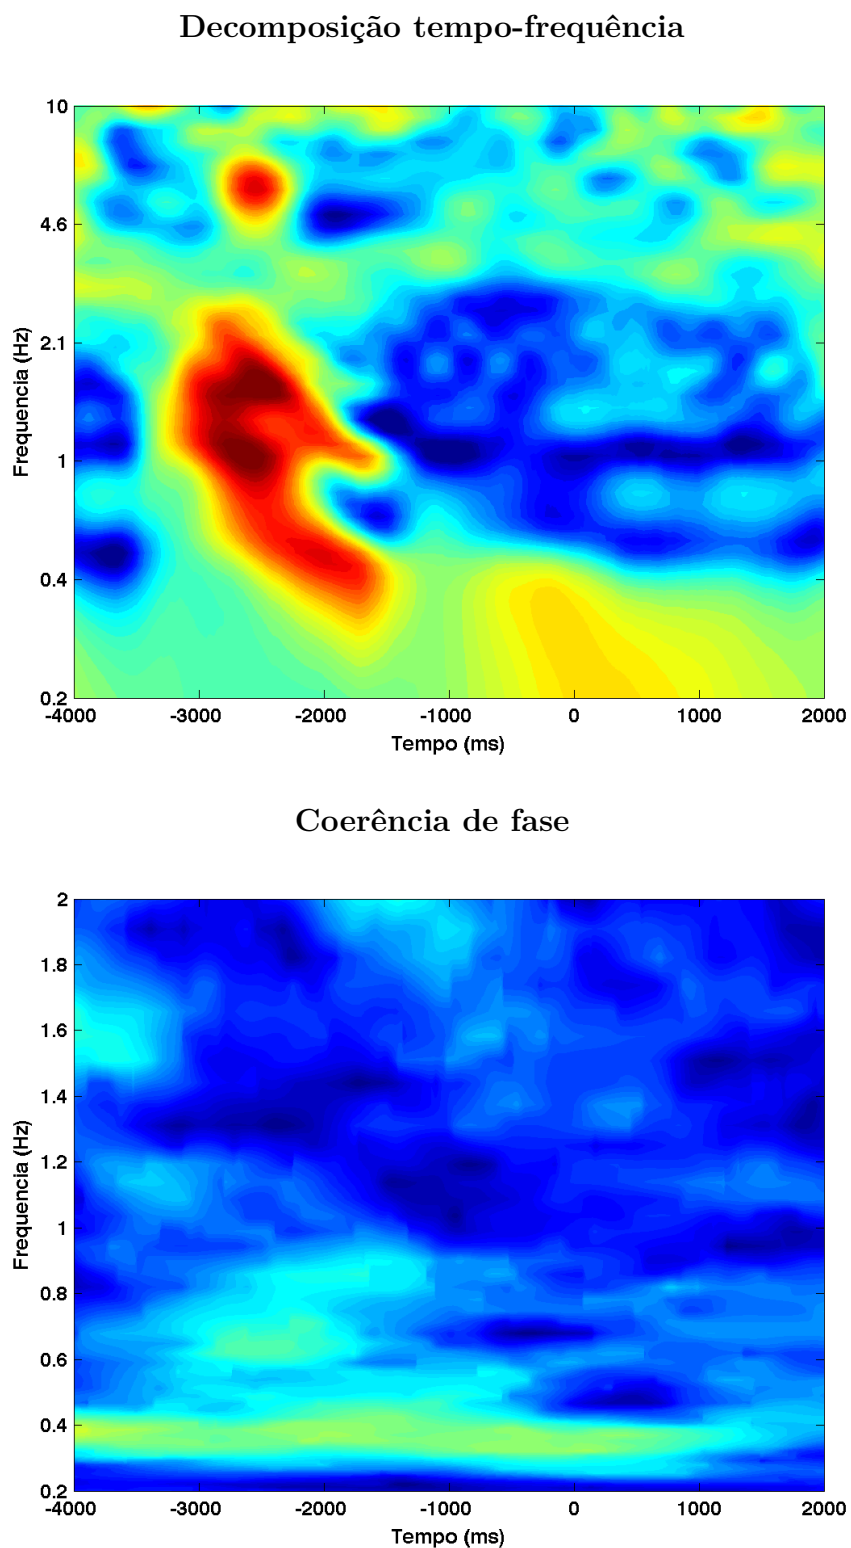



Figura 151 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 01, dia 4, eletrodo P7.

Decomposição tempo-frequência



Coerência de fase




Figura 152 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 01, dia 4, eletrodo P8.





Figura 153 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 01, dia 4, eletrodo T7.

Decomposição tempo-frequência



Coerência de fase




Figura 154 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 01, dia 4, eletrodo T8.

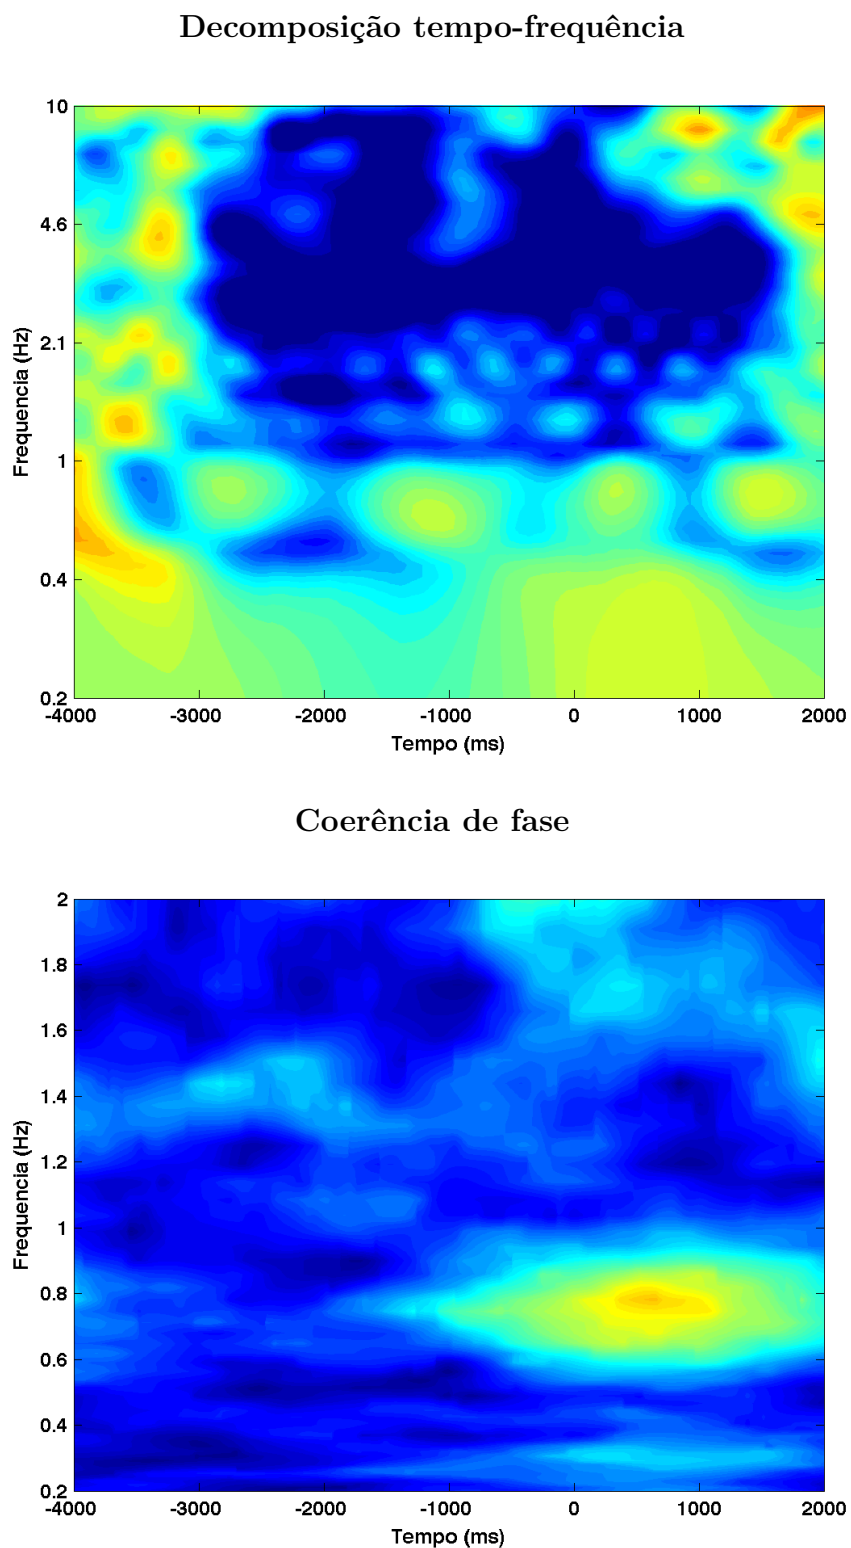


Figura 155 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 02, dia 1, eletrodo AF3.

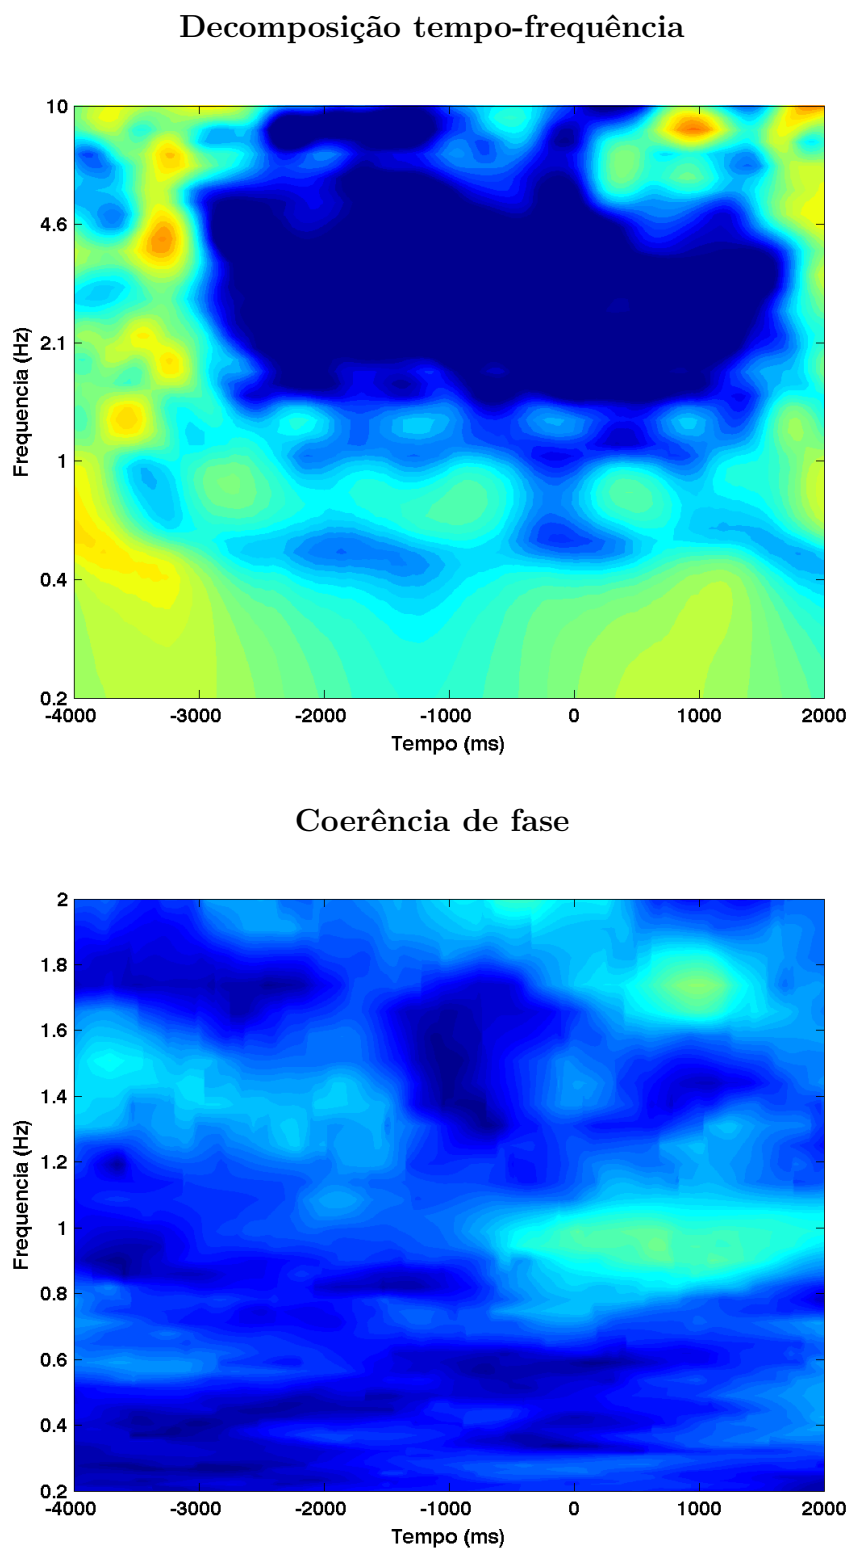


Figura 156 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 02, dia 1, eletrodo AF4.

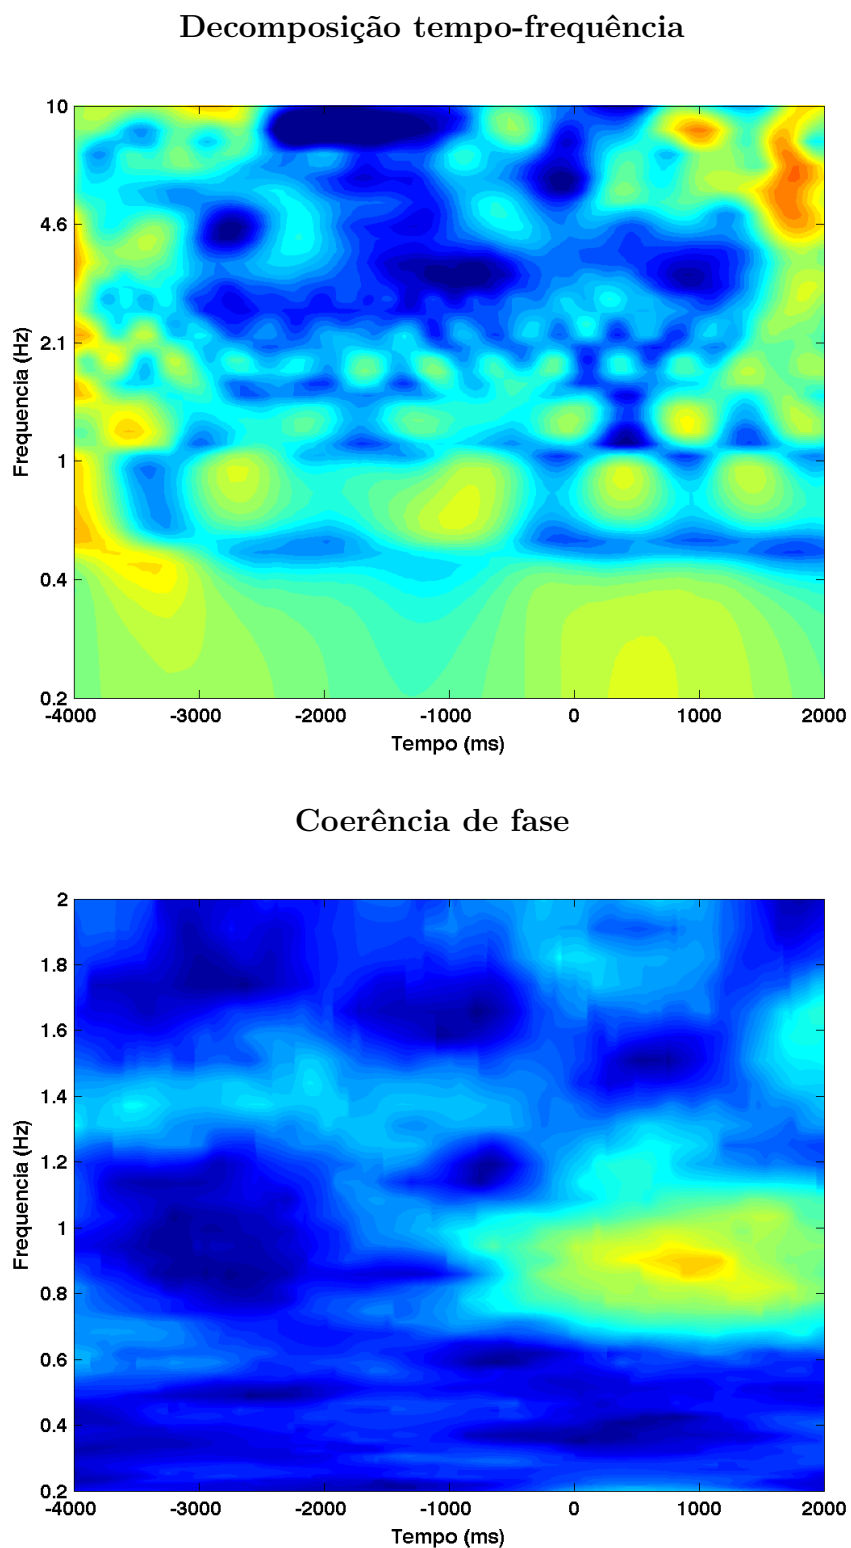



Figura 157 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 02, dia 1, eletrodo F3.

Decomposição tempo-frequência



Coerência de fase





Figura 158 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 02, dia 1, eletrodo F4.

Decomposição tempo-frequência



Coerência de fase





Figura 159 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 02, dia 1, eletrodo F7.

Decomposição tempo-frequência



Coerência de fase




Figura 160 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 02, dia 1, eletrodo F8.





Figura 161 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 02, dia 1, eletrodo FC5.

Decomposição tempo-frequência



Coerência de fase





Figura 162 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 02, dia 1, eletrodo FC6.

Decomposição tempo-frequência



Coerência de fase





Figura 163 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 02, dia 1, eletrodo O1.

Decomposição tempo-frequência



Coerência de fase





Figura 164 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 02, dia 1, eletrodo O2.

Decomposição tempo-frequência



Coerência de fase





Figura 165 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 02, dia 1, eletrodo P7.

Decomposição tempo-frequência



Coerência de fase




Figura 166 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 02, dia 1, eletrodo P8.

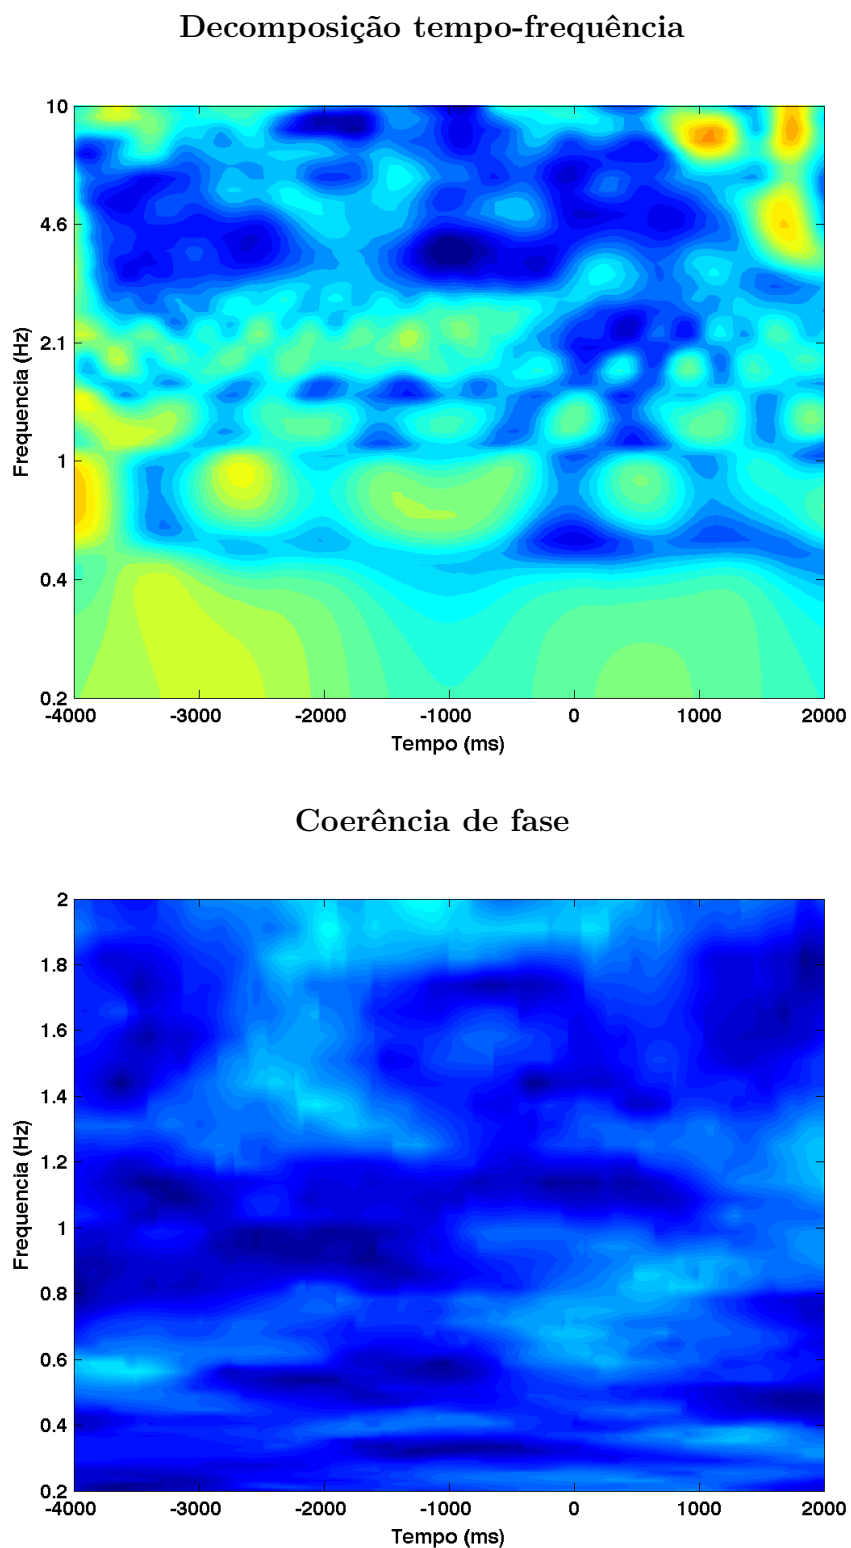



Figura 167 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 02, dia 1, eletrodo T7.

Decomposição tempo-frequência



Coerência de fase





Figura 168 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 02, dia 1, eletrodo T8.

Decomposição tempo-frequência



Coerência de fase





Figura 169 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 02, dia 2, eletrodo AF3.

Decomposição tempo-frequência



Coerência de fase




Figura 170 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 02, dia 2, eletrodo AF4.




Figura 171 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 02, dia 2, eletrodo F3.

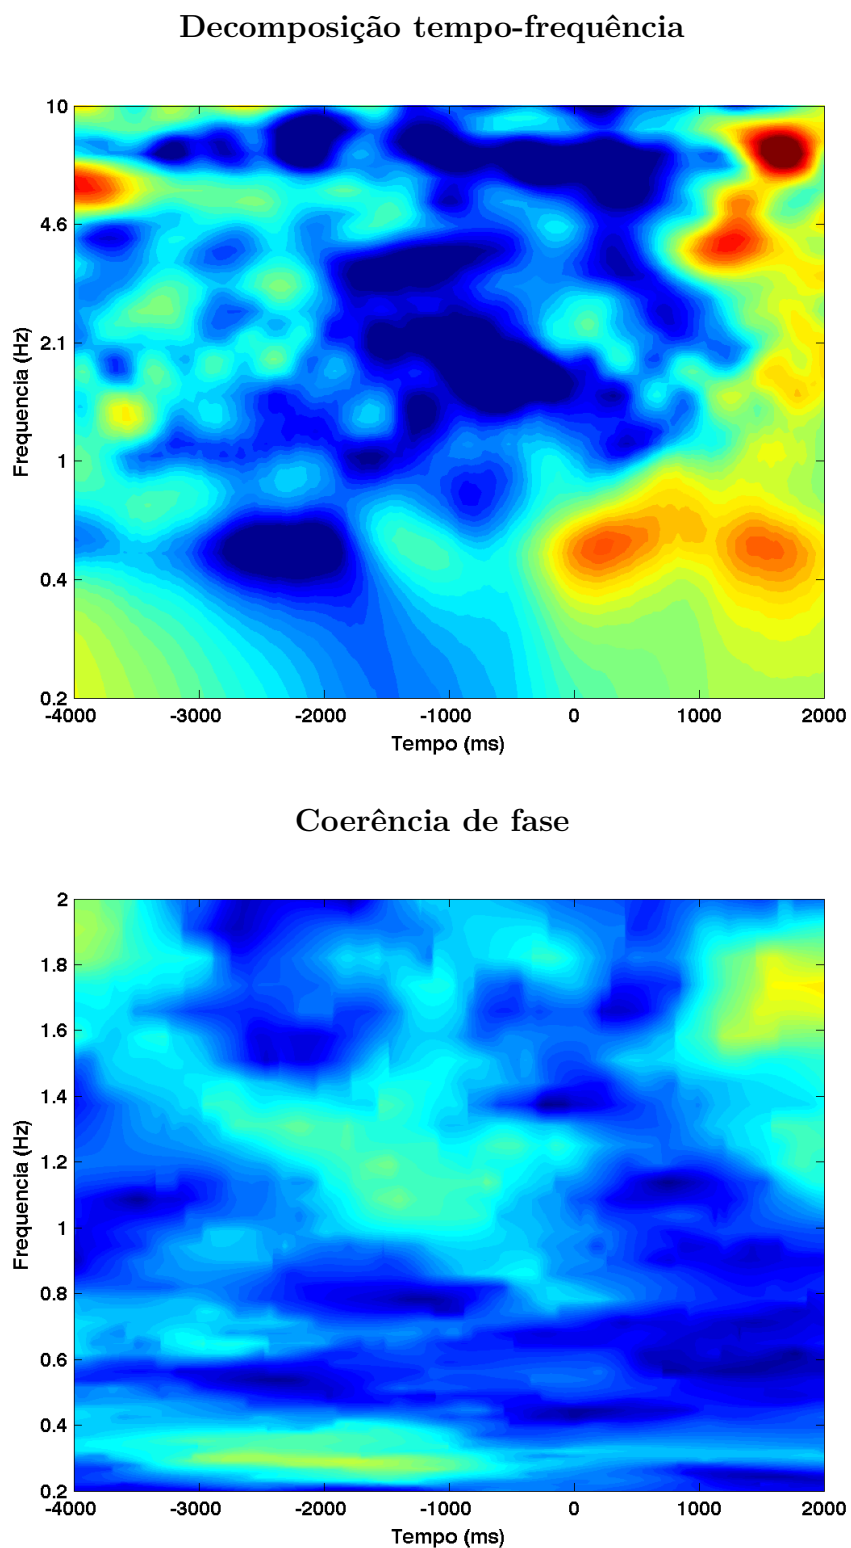



Figura 172 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 02, dia 2, eletrodo F4.

Decomposição tempo-frequência



Coerência de fase




Figura 173 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 02, dia 2, eletrodo F7.

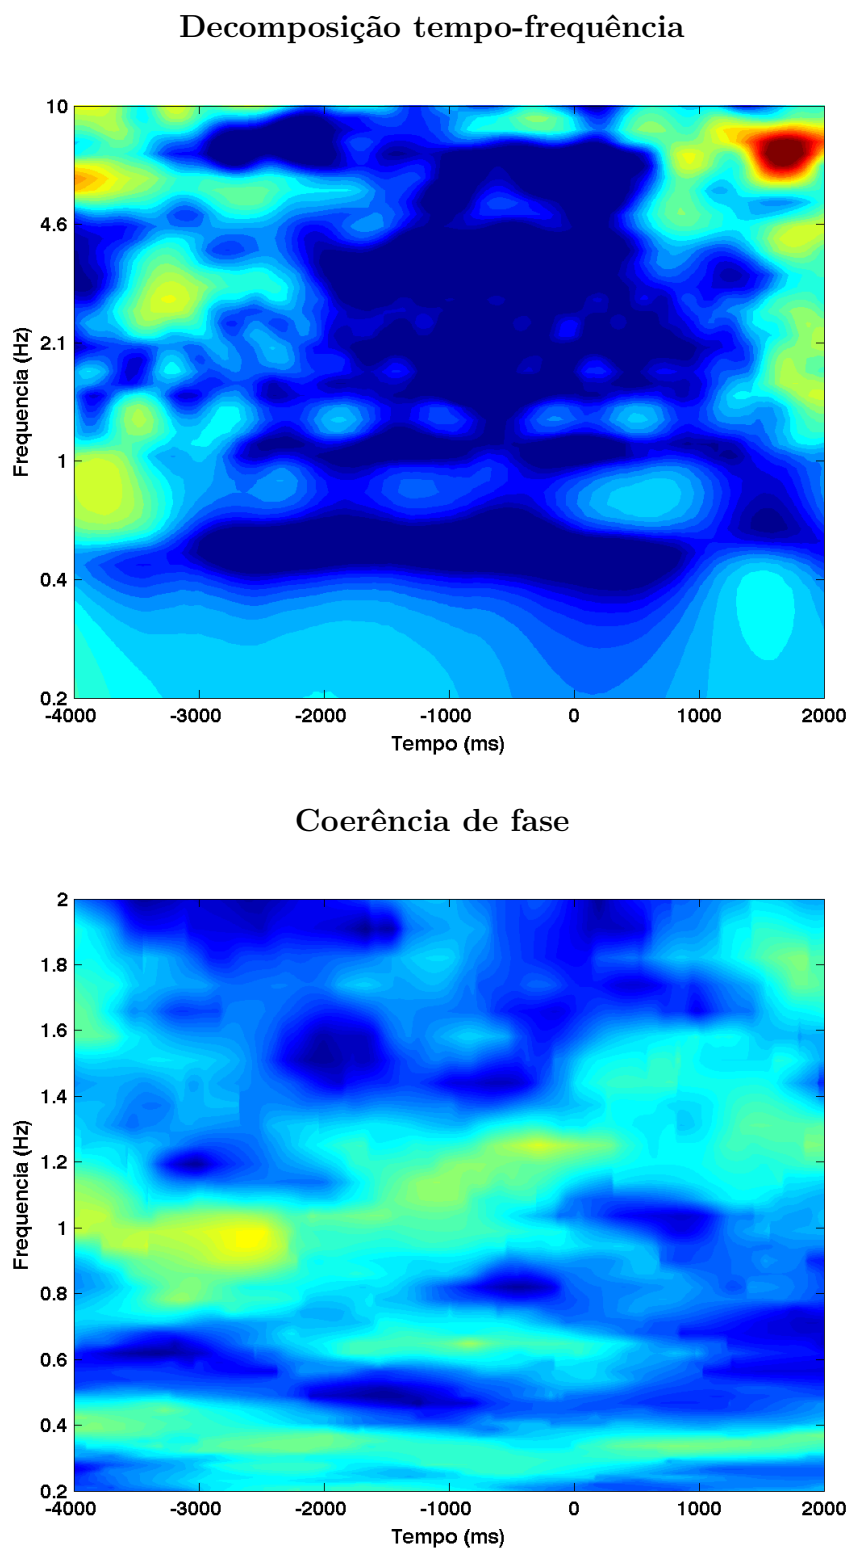



Figura 174 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 02, dia 2, eletrodo F8.

Decomposição tempo-frequência



Coerência de fase





Figura 175 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 02, dia 2, eletrodo FC5.

Decomposição tempo-frequência



Coerência de fase





Figura 176 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 02, dia 2, eletrodo FC6.

Decomposição tempo-frequência



Coerência de fase




Figura 177 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 02, dia 2, eletrodo O1.




Figura 178 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 02, dia 2, eletrodo O2.

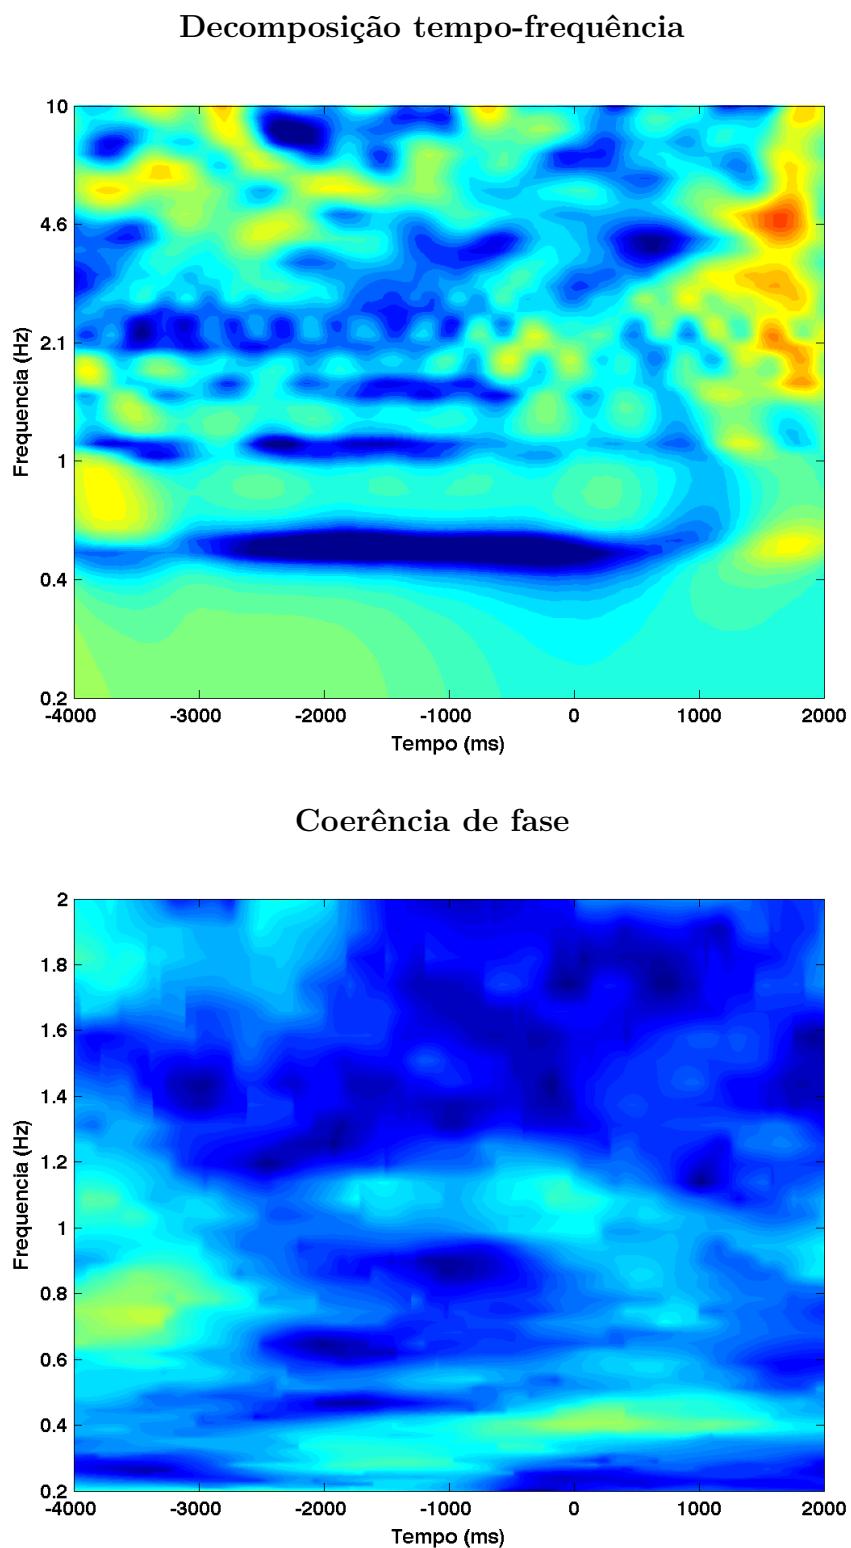



Figura 179 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 02, dia 2, eletrodo P7.

Decomposição tempo-frequência



Coerência de fase





Figura 180 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 02, dia 2, eletrodo P8.

Decomposição tempo-frequência



Coerência de fase





Figura 181 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 02, dia 2, eletrodo T7.

Decomposição tempo-frequência



Coerência de fase





Figura 182 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 02, dia 2, eletrodo T8.

Decomposição tempo-frequência



Coerência de fase





Figura 183 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 02, dia 3, eletrodo AF3.

Decomposição tempo-frequência



Coerência de fase





Figura 184 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 02, dia 3, eletrodo AF4.

Decomposição tempo-frequência



Coerência de fase





Figura 185 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 02, dia 3, eletrodo F3.

Decomposição tempo-frequência



Coerência de fase





Figura 186 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 02, dia 3, eletrodo F4.

Decomposição tempo-frequência



Coerência de fase





Figura 187 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 02, dia 3, eletrodo F7.

Decomposição tempo-frequência



Coerência de fase





Figura 188 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 02, dia 3, eletrodo F8.

Decomposição tempo-frequência



Coerência de fase





Figura 189 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 02, dia 3, eletrodo FC5.

Decomposição tempo-frequência



Coerência de fase





Figura 190 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 02, dia 3, eletrodo FC6.

Decomposição tempo-frequência



Coerência de fase





Figura 191 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 02, dia 3, eletrodo O1.

Decomposição tempo-frequência



Coerência de fase





Figura 192 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 02, dia 3, eletrodo O2.

Decomposição tempo-frequência



Coerência de fase





Figura 193 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 02, dia 3, eletrodo P7.

Decomposição tempo-frequência



Coerência de fase





Figura 194 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 02, dia 3, eletrodo P8.

Decomposição tempo-frequência



Coerência de fase





Figura 195 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 02, dia 3, eletrodo T7.

Decomposição tempo-frequência



Coerência de fase




Figura 196 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 02, dia 3, eletrodo T8.




Figura 197 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 02, dia 4, eletrodo AF3.




Figura 198 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 02, dia 4, eletrodo AF4.




Figura 199 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 02, dia 4, eletrodo F3.





Figura 200 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 02, dia 4, eletrodo F4.

Decomposição tempo-frequência



Coerência de fase




Figura 201 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 02, dia 4, eletrodo F7.





Figura 202 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 02, dia 4, eletrodo F8.

Decomposição tempo-frequência



Coerência de fase





Figura 203 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 02, dia 4, eletrodo FC5.

Decomposição tempo-frequência



Coerência de fase




Figura 204 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 02, dia 4, eletrodo FC6.

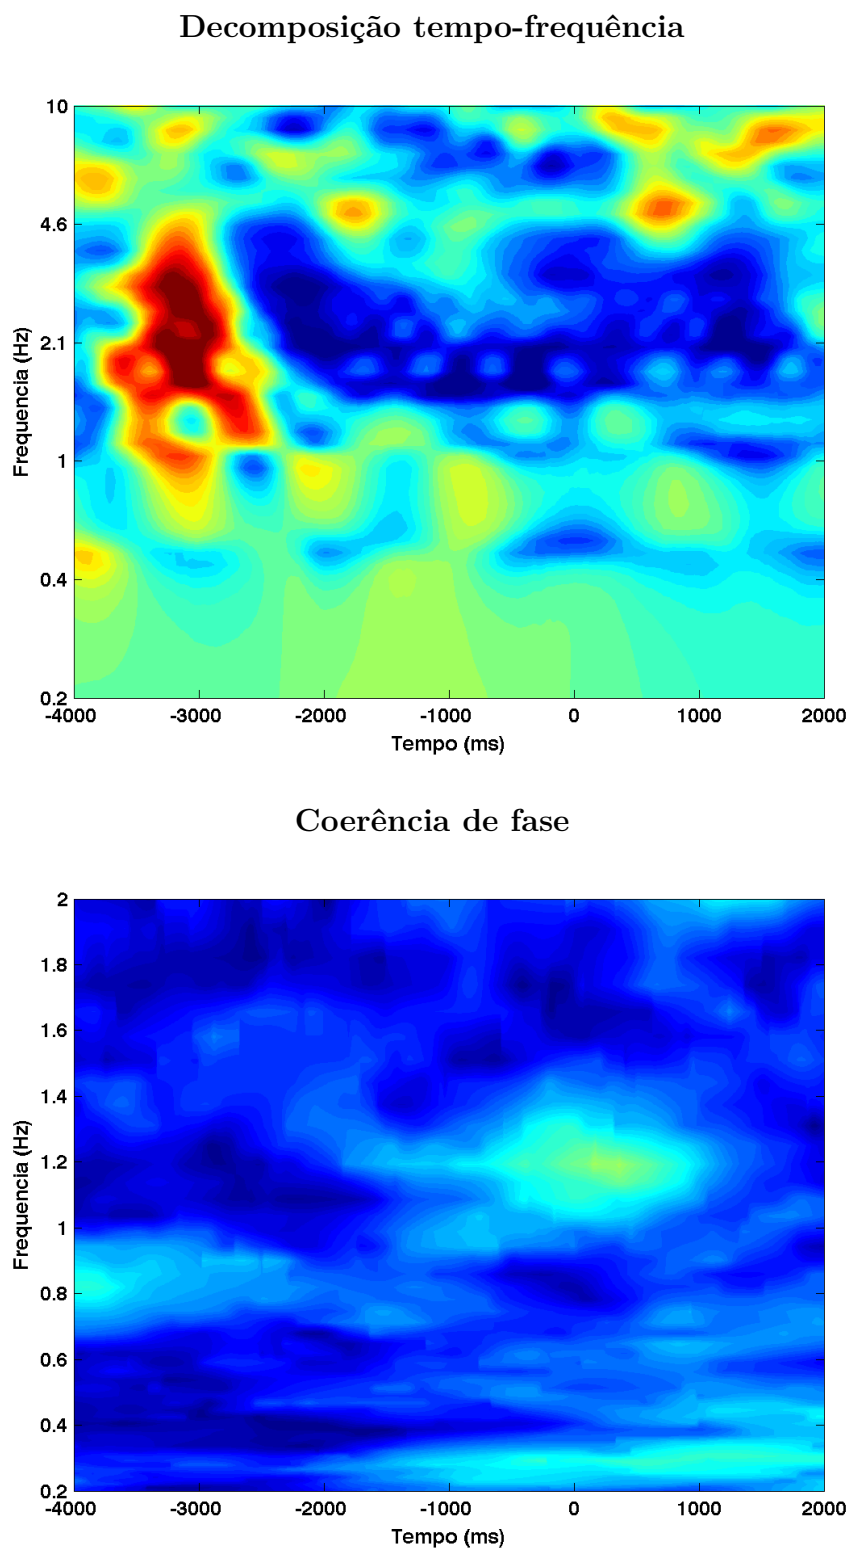


Figura 205 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 02, dia 4, eletrodo O1.

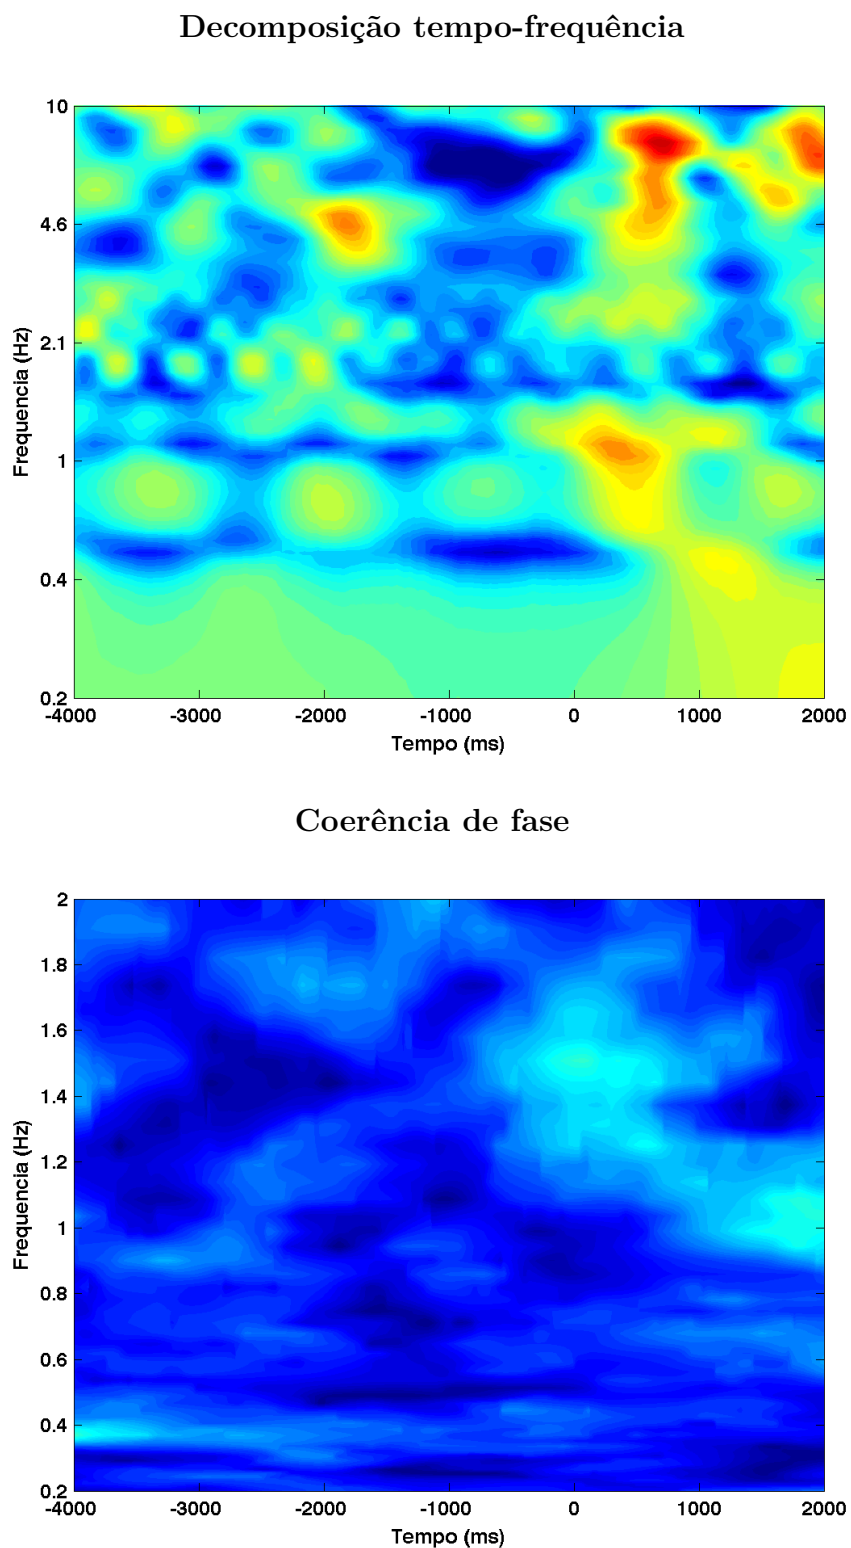


Figura 206 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 02, dia 4, eletrodo O2.

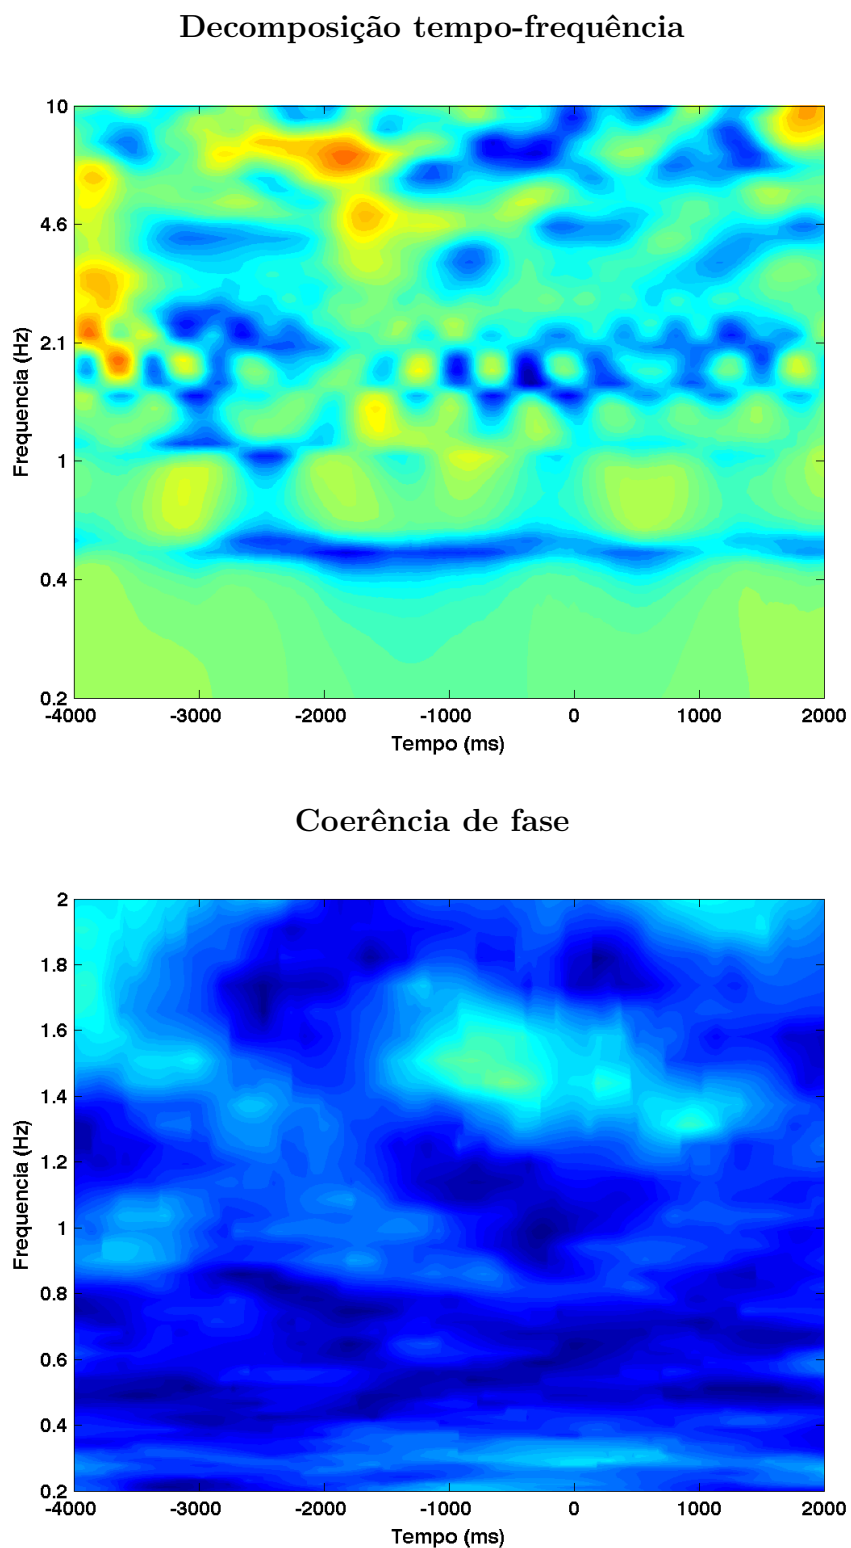


Figura 207 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 02, dia 4, eletrodo P7.




Figura 208 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 02, dia 4, eletrodo P8.




Figura 209 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 02, dia 4, eletrodo T7.

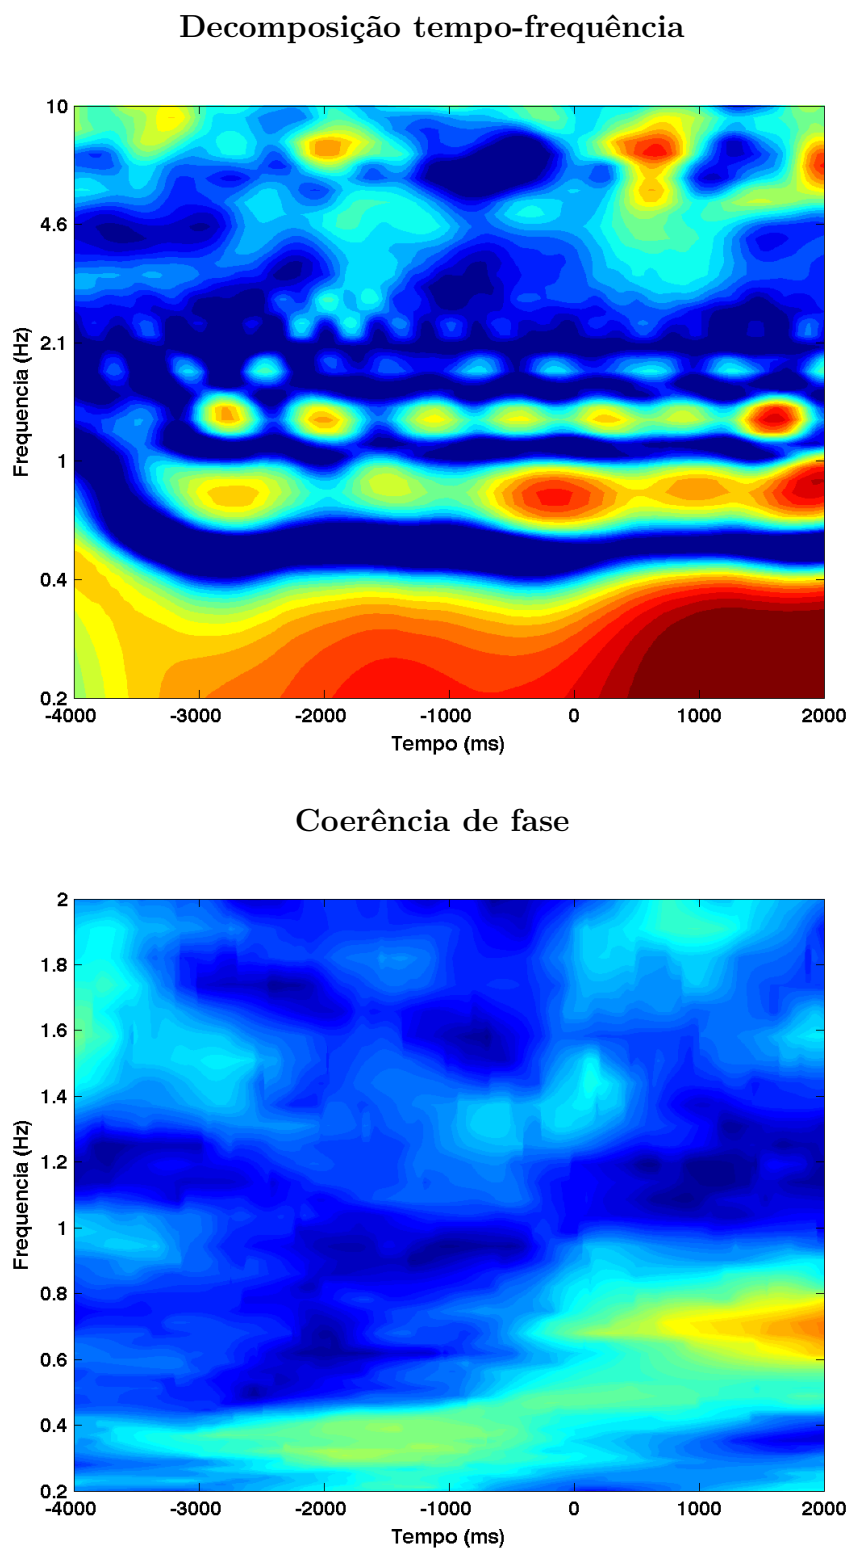


Figura 210 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 02, dia 4, eletrodo T8.




Figura 211 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 03, dia 1, eletrodo AF3.

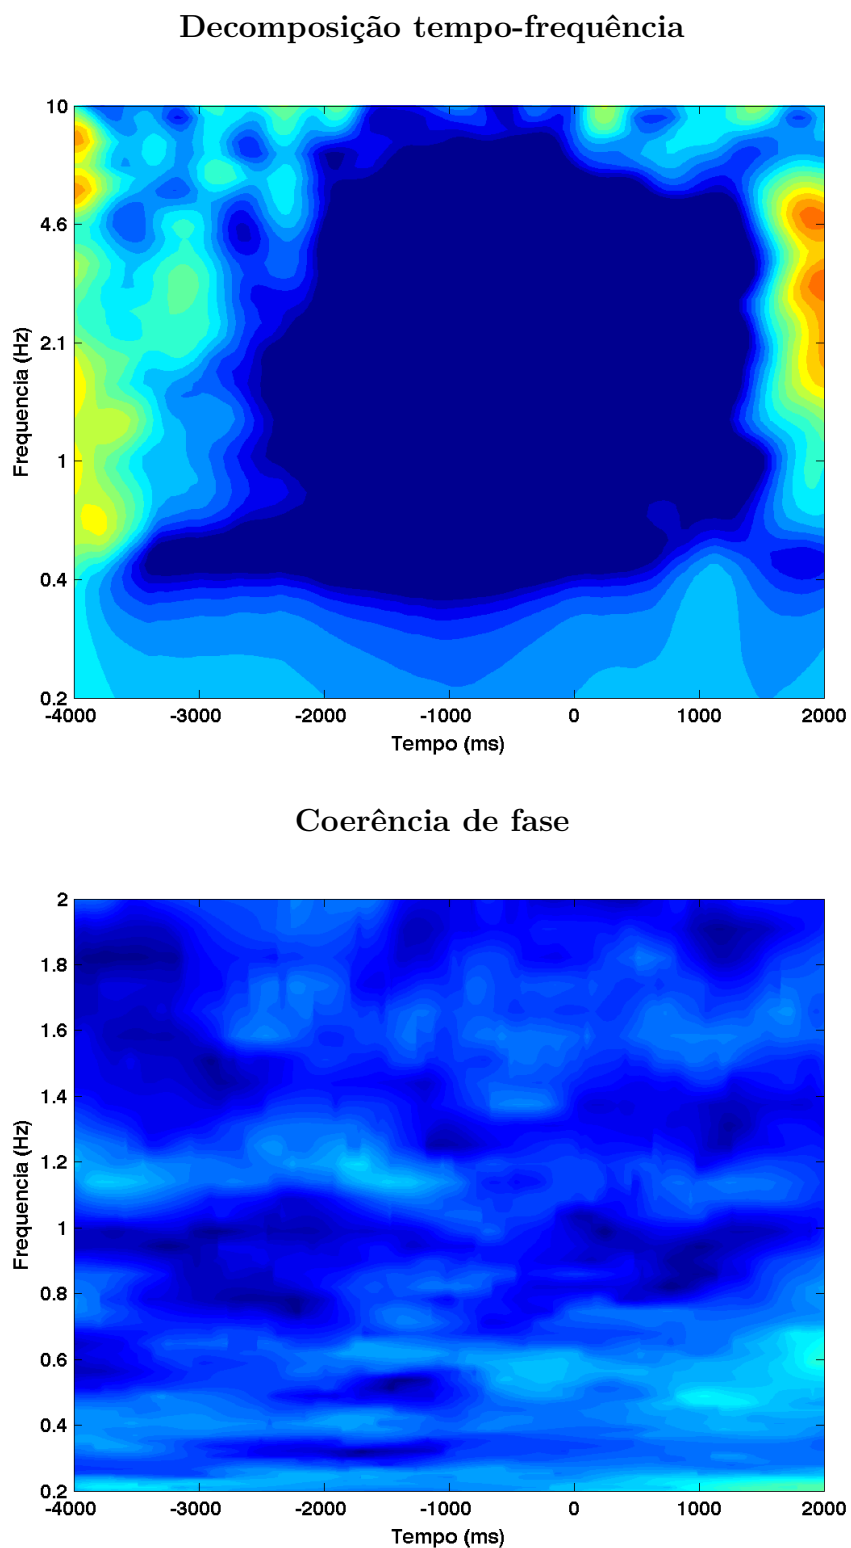


Figura 212 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 03, dia 1, eletrodo AF4.




Figura 213 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 03, dia 1, eletrodo F3.

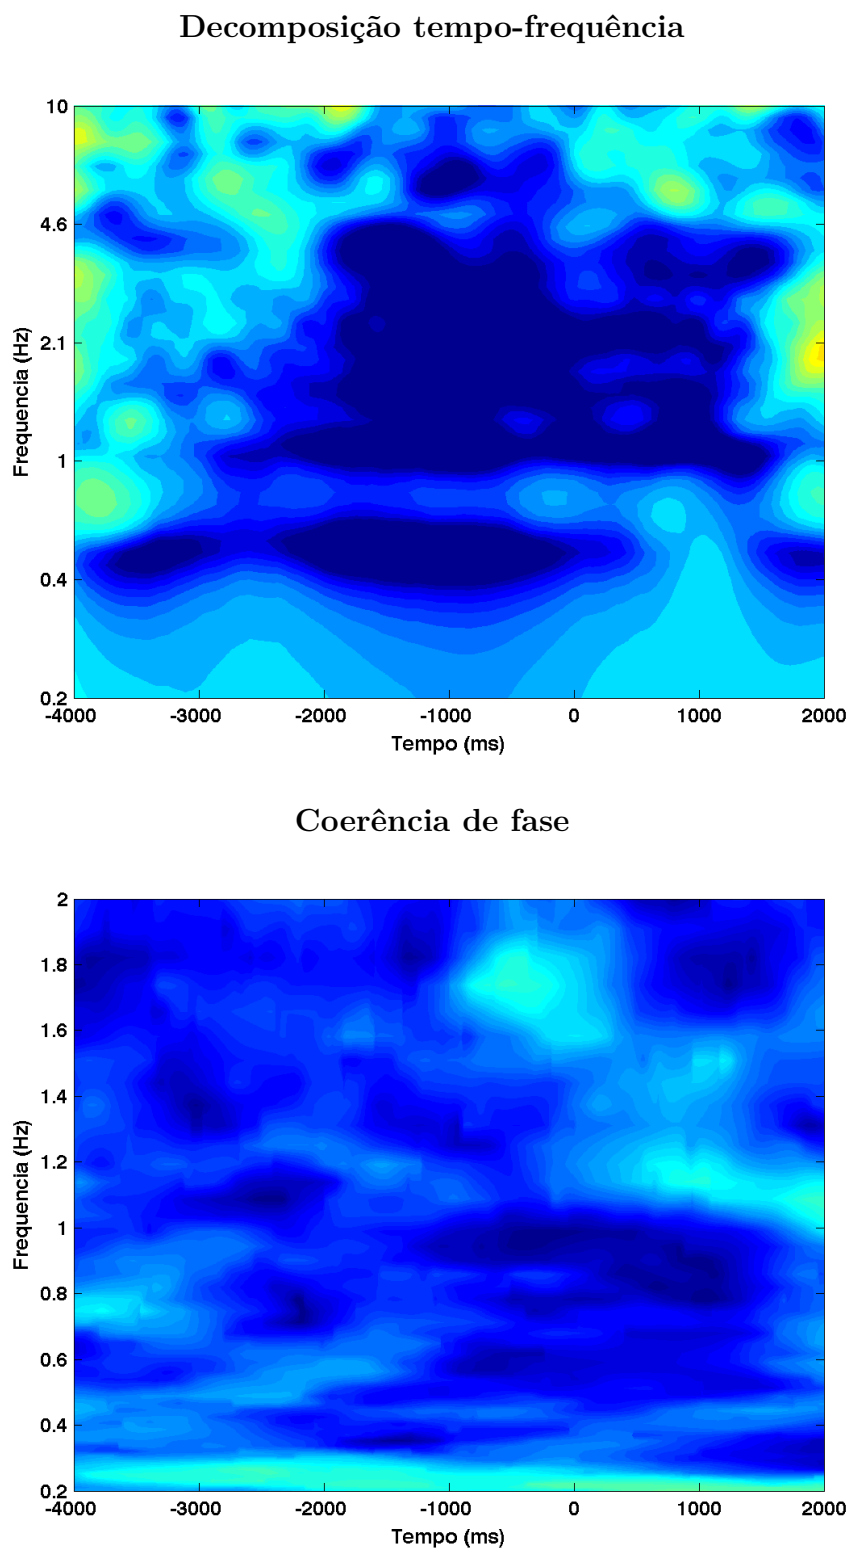



Figura 214 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 03, dia 1, eletrodo F4.

Decomposição tempo-frequência



Coerência de fase




Figura 215 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 03, dia 1, eletrodo F7.

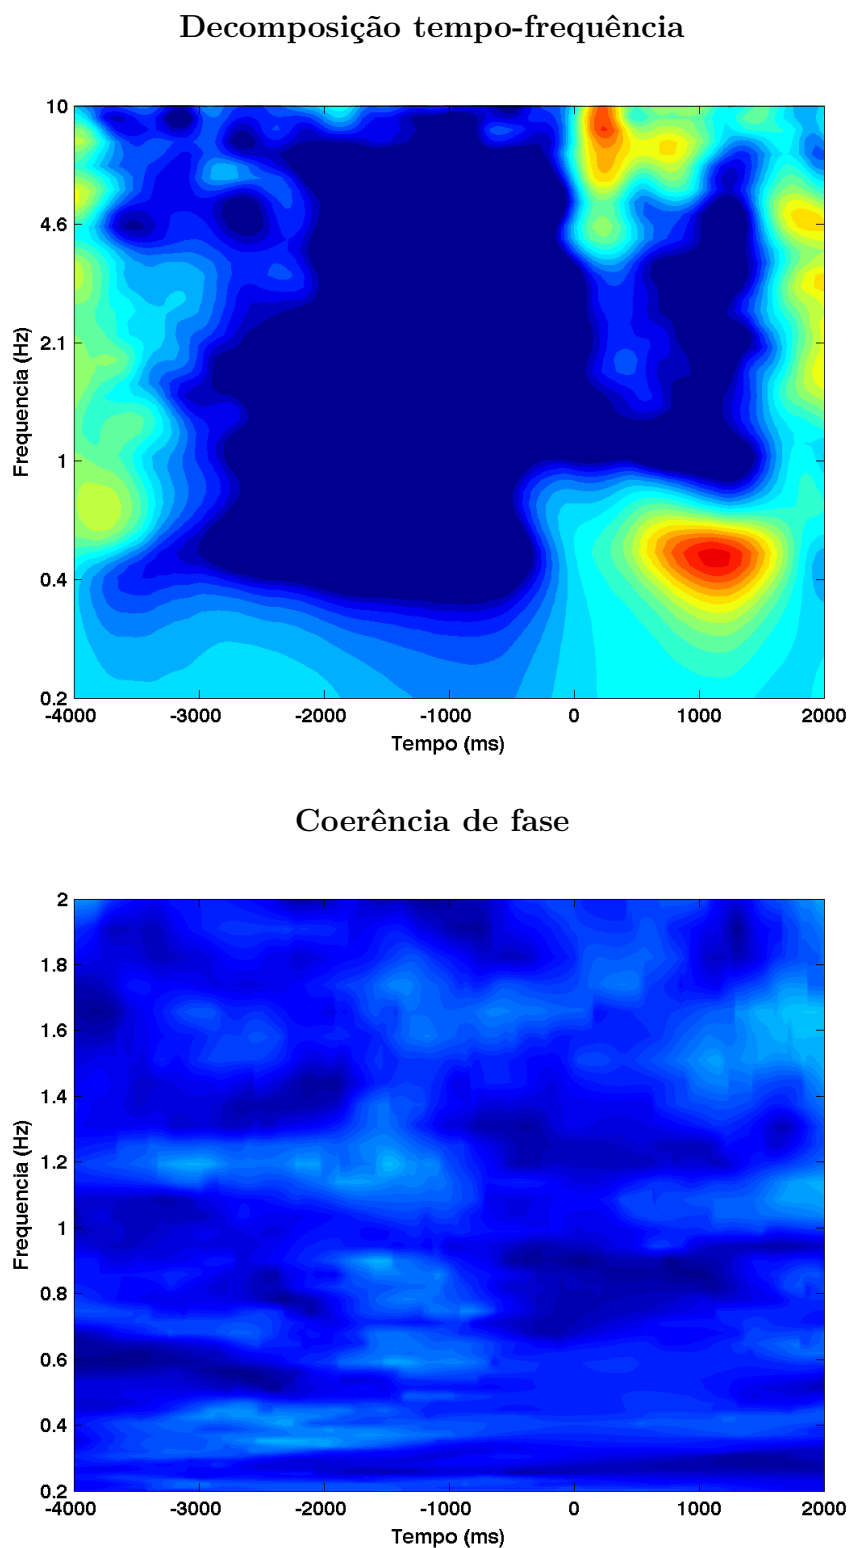



Figura 216 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 03, dia 1, eletrodo F8.

Decomposição tempo-frequência



Coerência de fase




Figura 217 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 03, dia 1, eletrodo FC5.

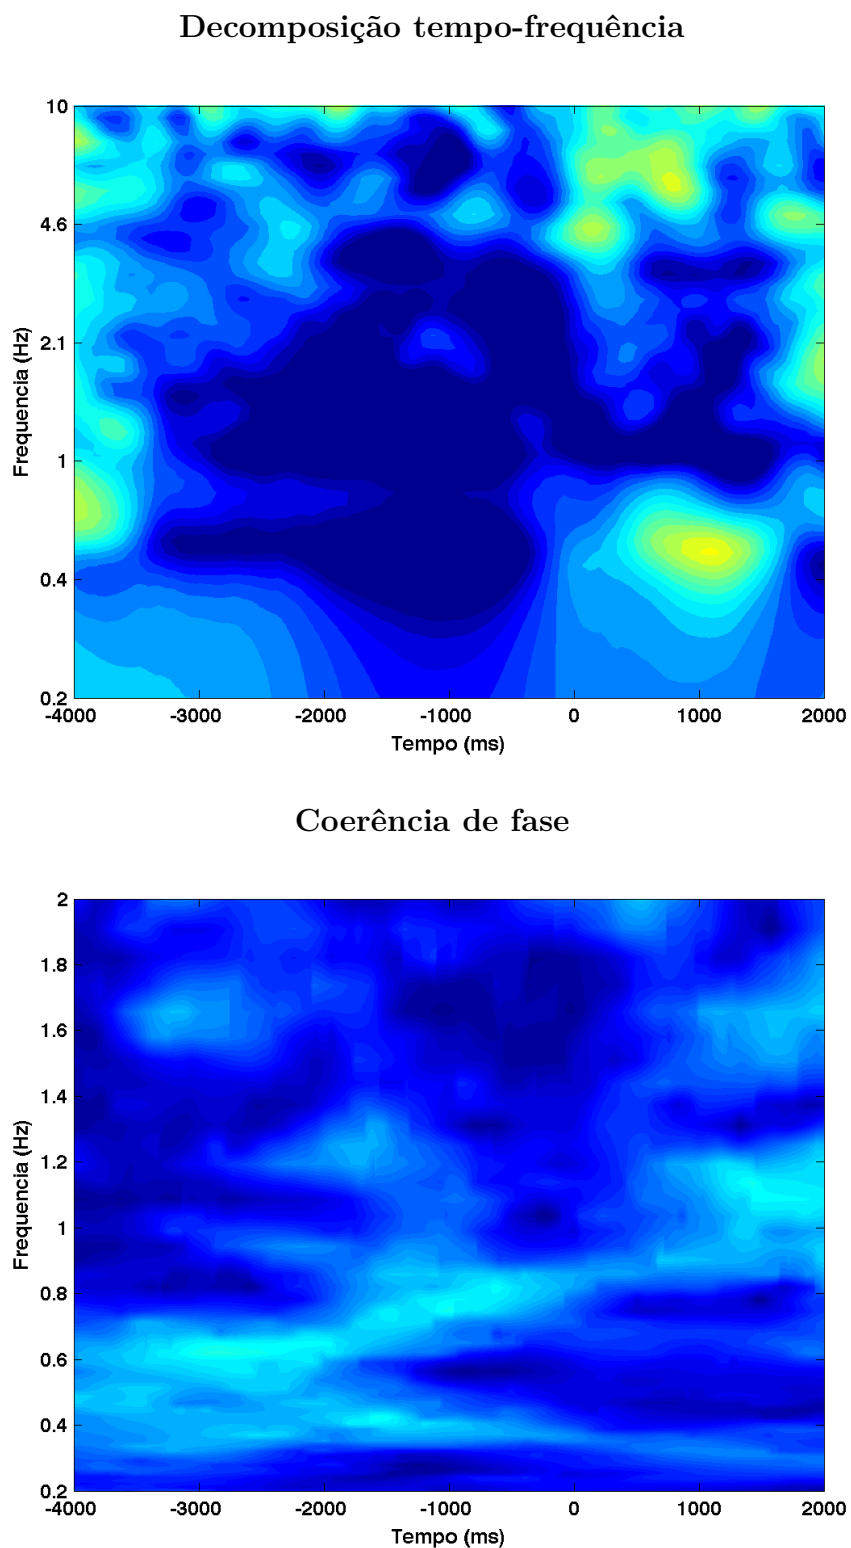



Figura 218 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 03, dia 1, eletrodo FC6.

Decomposição tempo-frequência



Coerência de fase




Figura 219 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 03, dia 1, eletrodo O1.

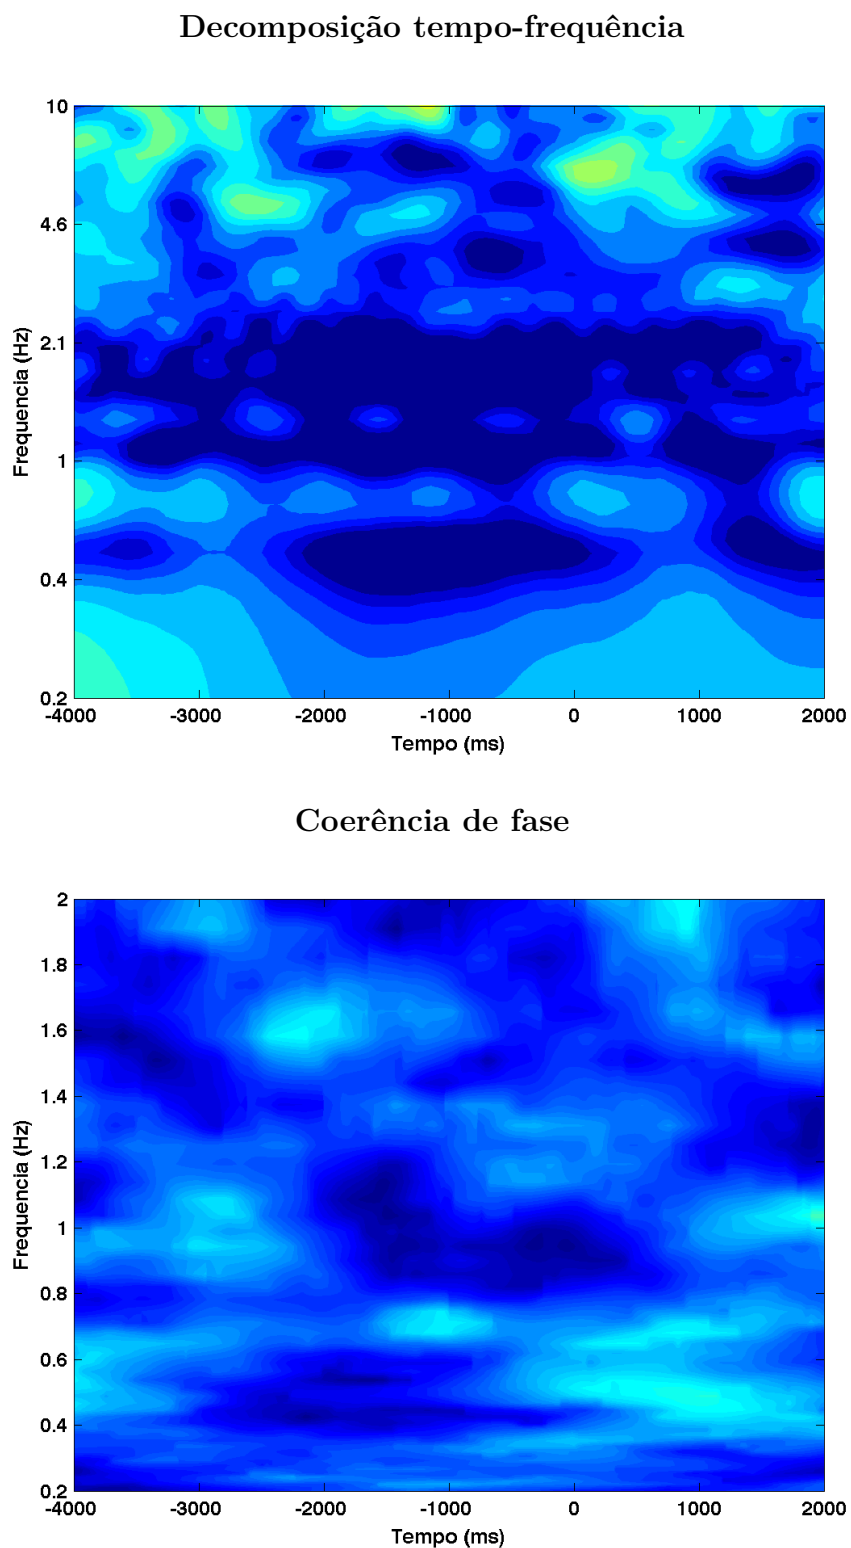


Figura 220 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 03, dia 1, eletrodo O2.

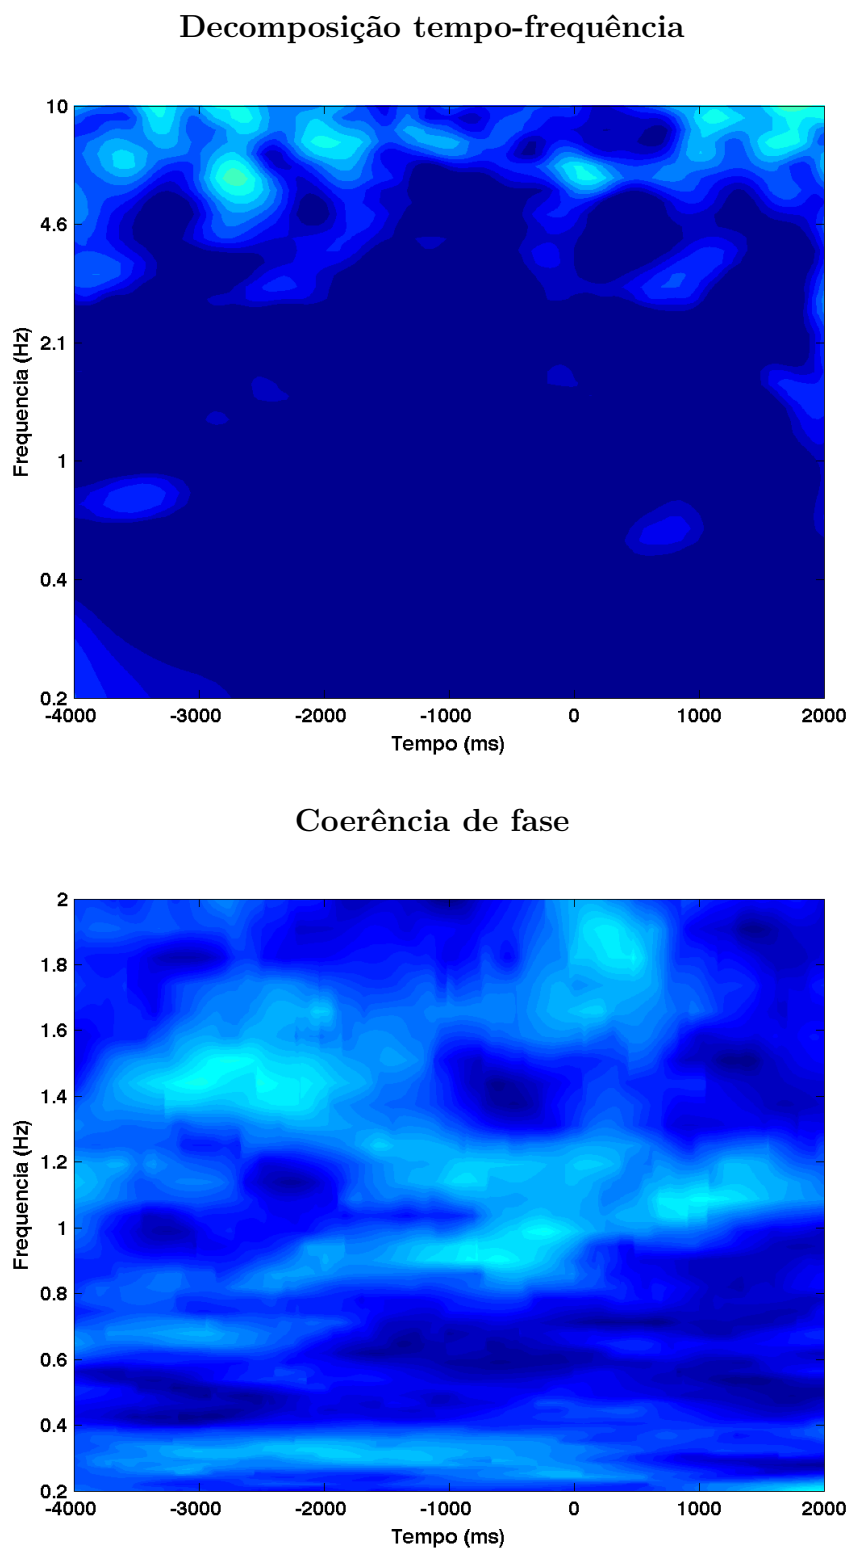



Figura 221 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 03, dia 1, eletrodo P7.

Decomposição tempo-frequência



Coerência de fase





Figura 222 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 03, dia 1, eletrodo P8.

Decomposição tempo-frequência



Coerência de fase





Figura 223 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 03, dia 1, eletrodo T7.

Decomposição tempo-frequência



Coerência de fase




Figura 224 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 03, dia 1, eletrodo T8.




Figura 225 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 03, dia 2, eletrodo AF3.

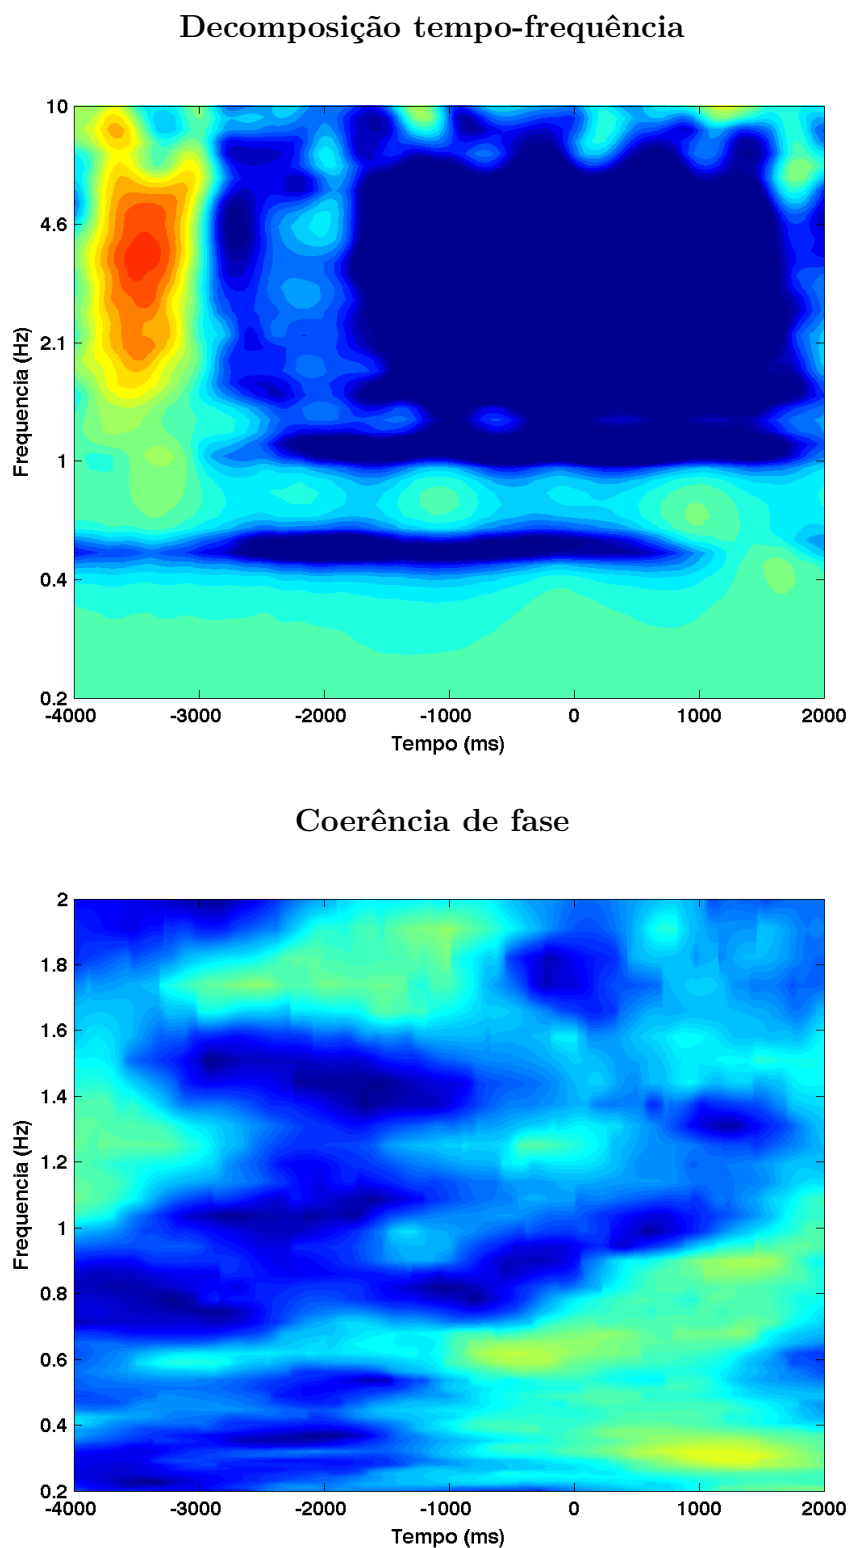


Figura 226 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 03, dia 2, eletrodo AF4.

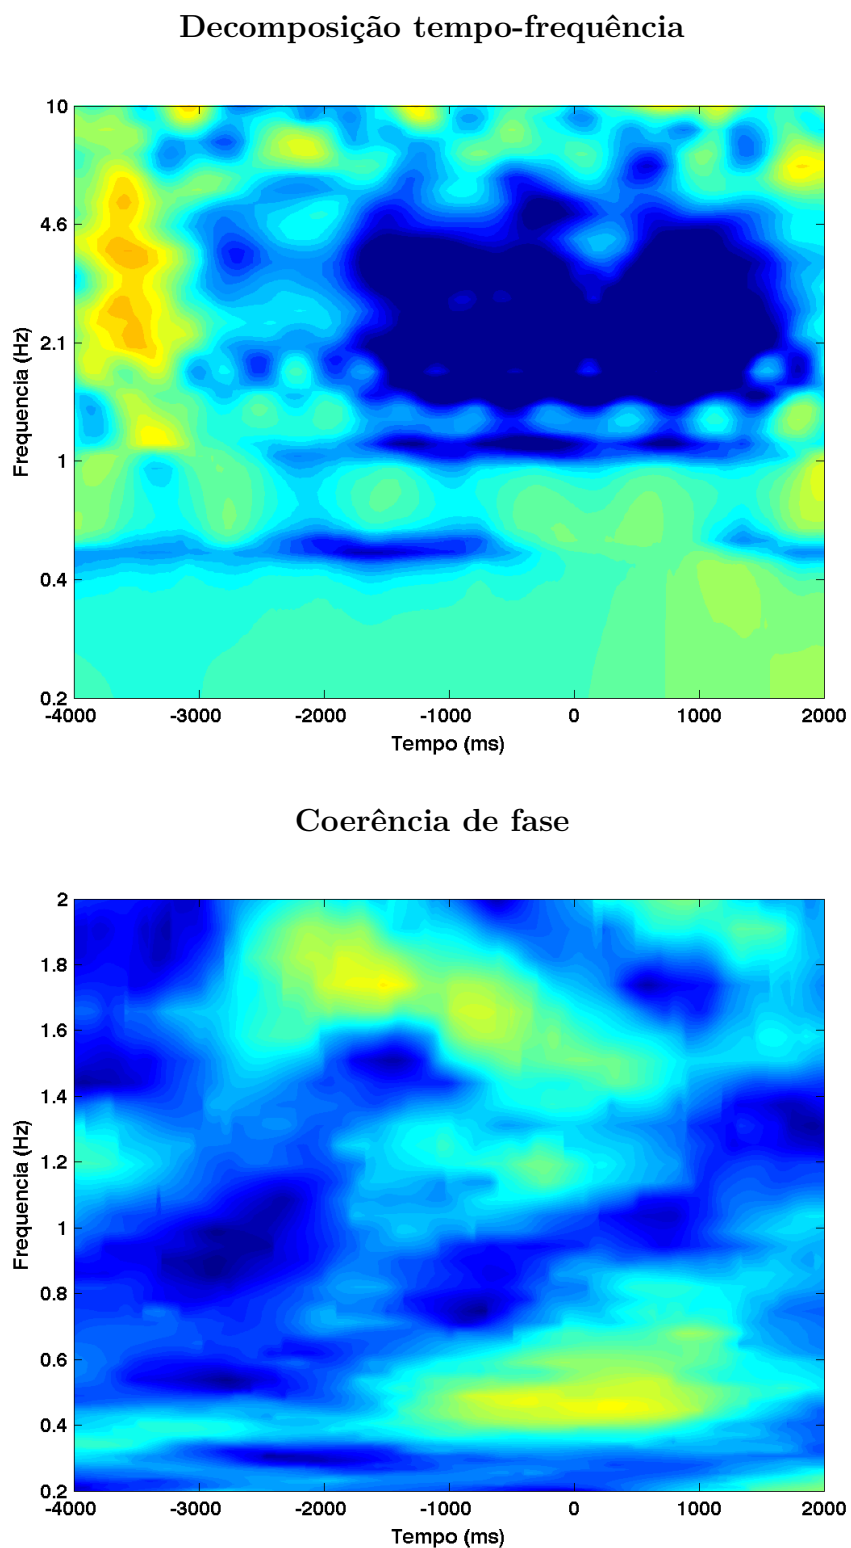


Figura 227 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 03, dia 2, eletrodo F3.

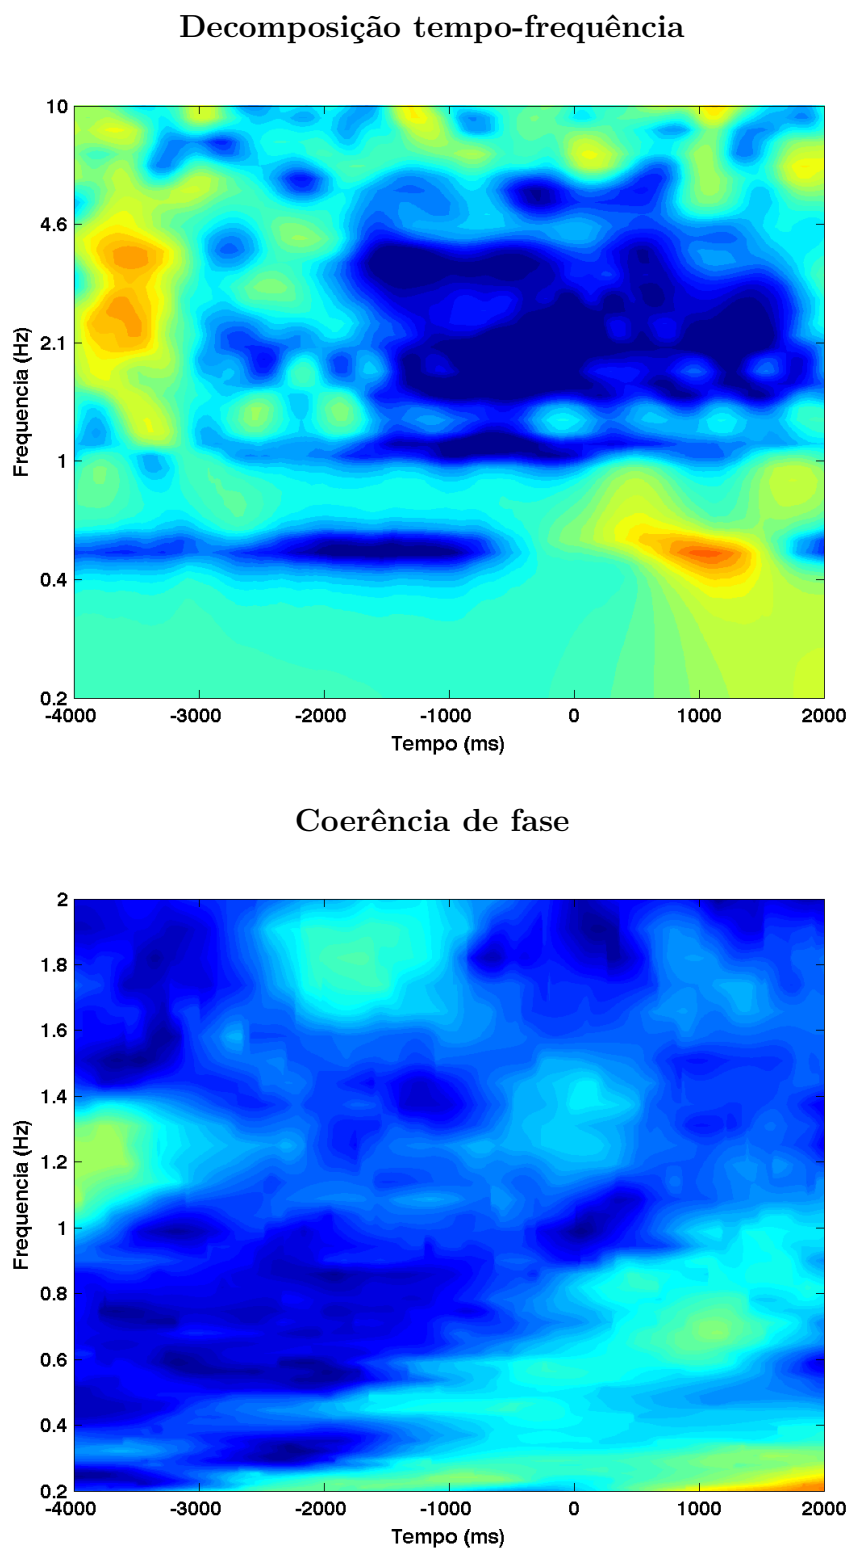


Figura 228 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 03, dia 2, eletrodo F4.

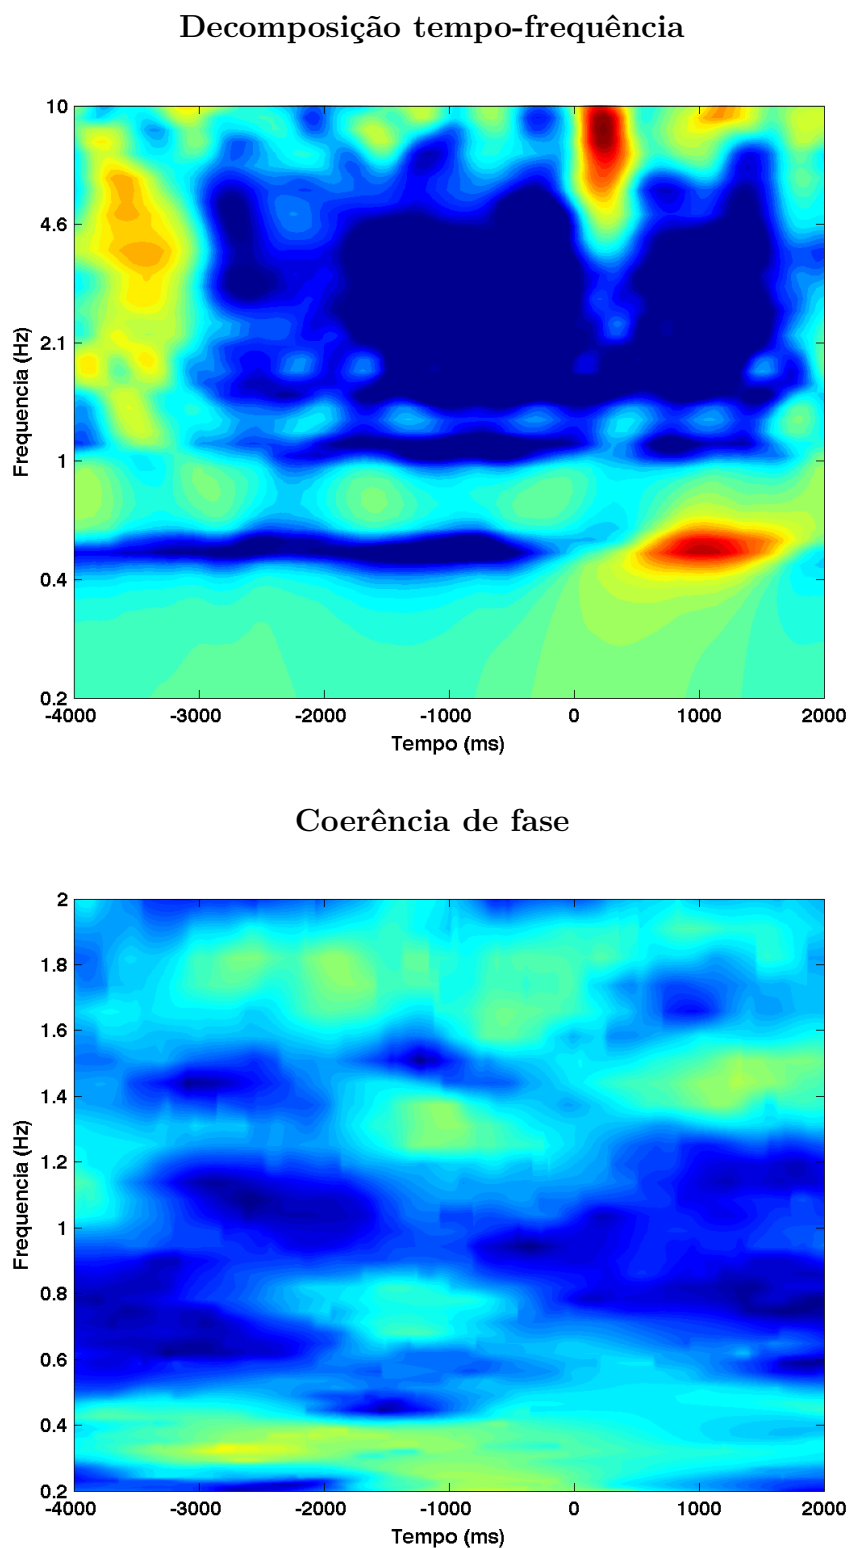


Figura 229 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 03, dia 2, eletrodo F7.

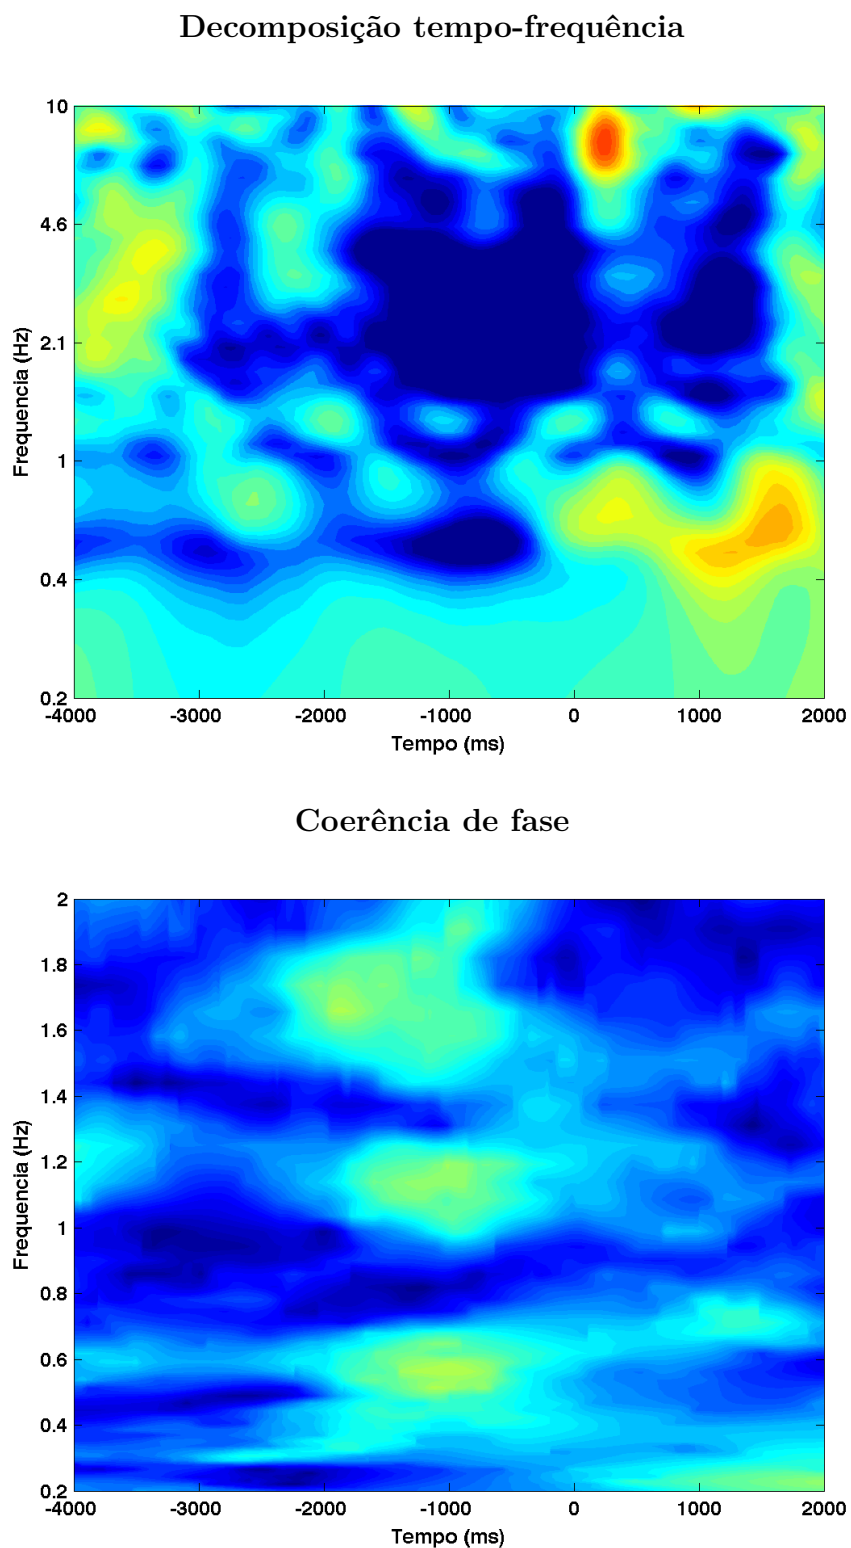


Figura 230 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 03, dia 2, eletrodo F8.

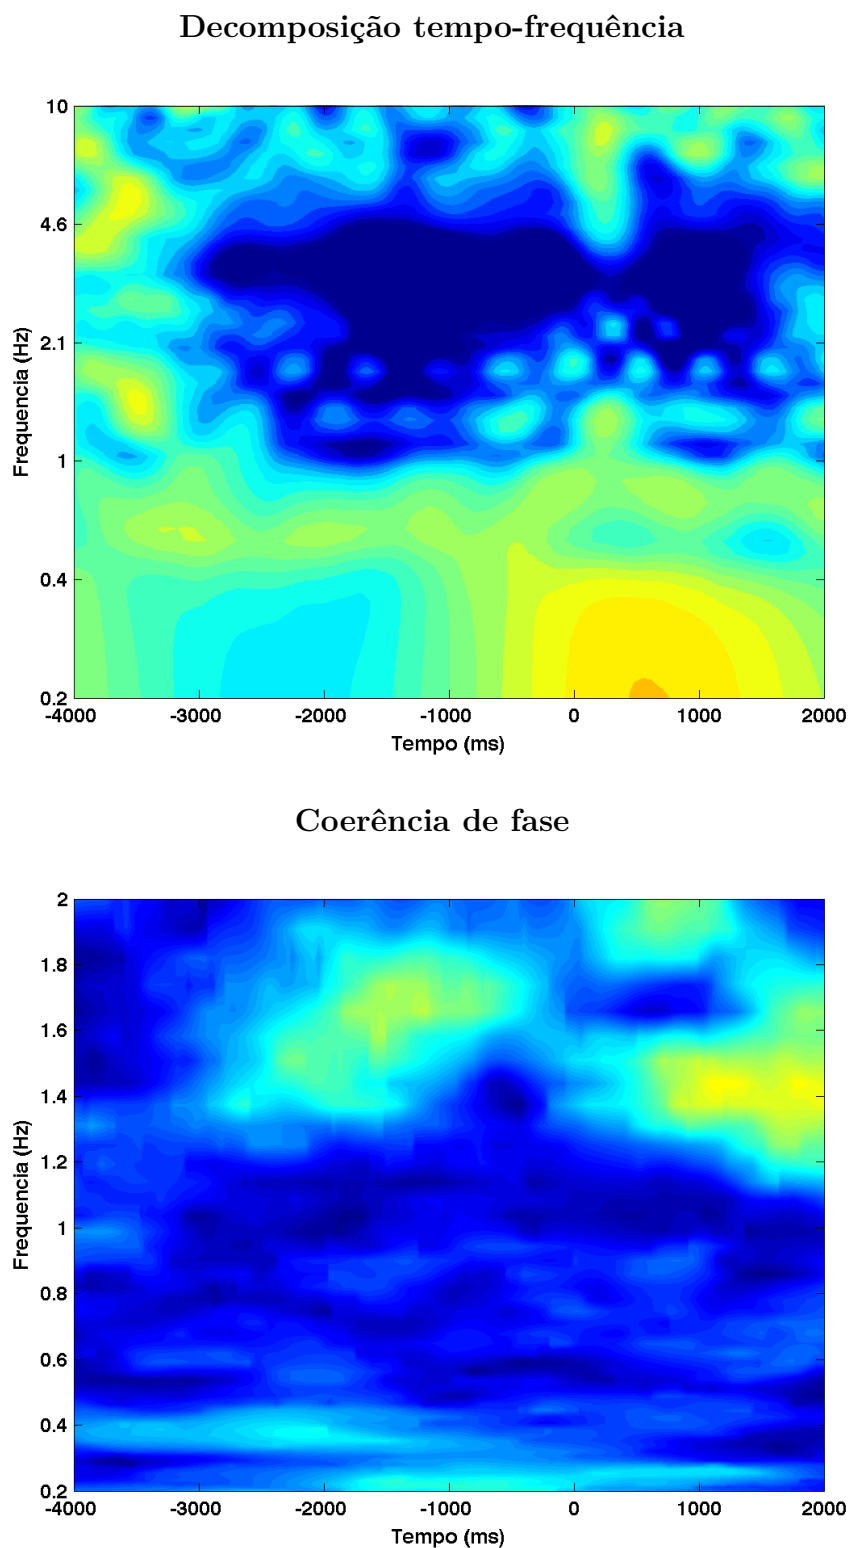


Figura 231 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 03, dia 2, eletrodo FC5.

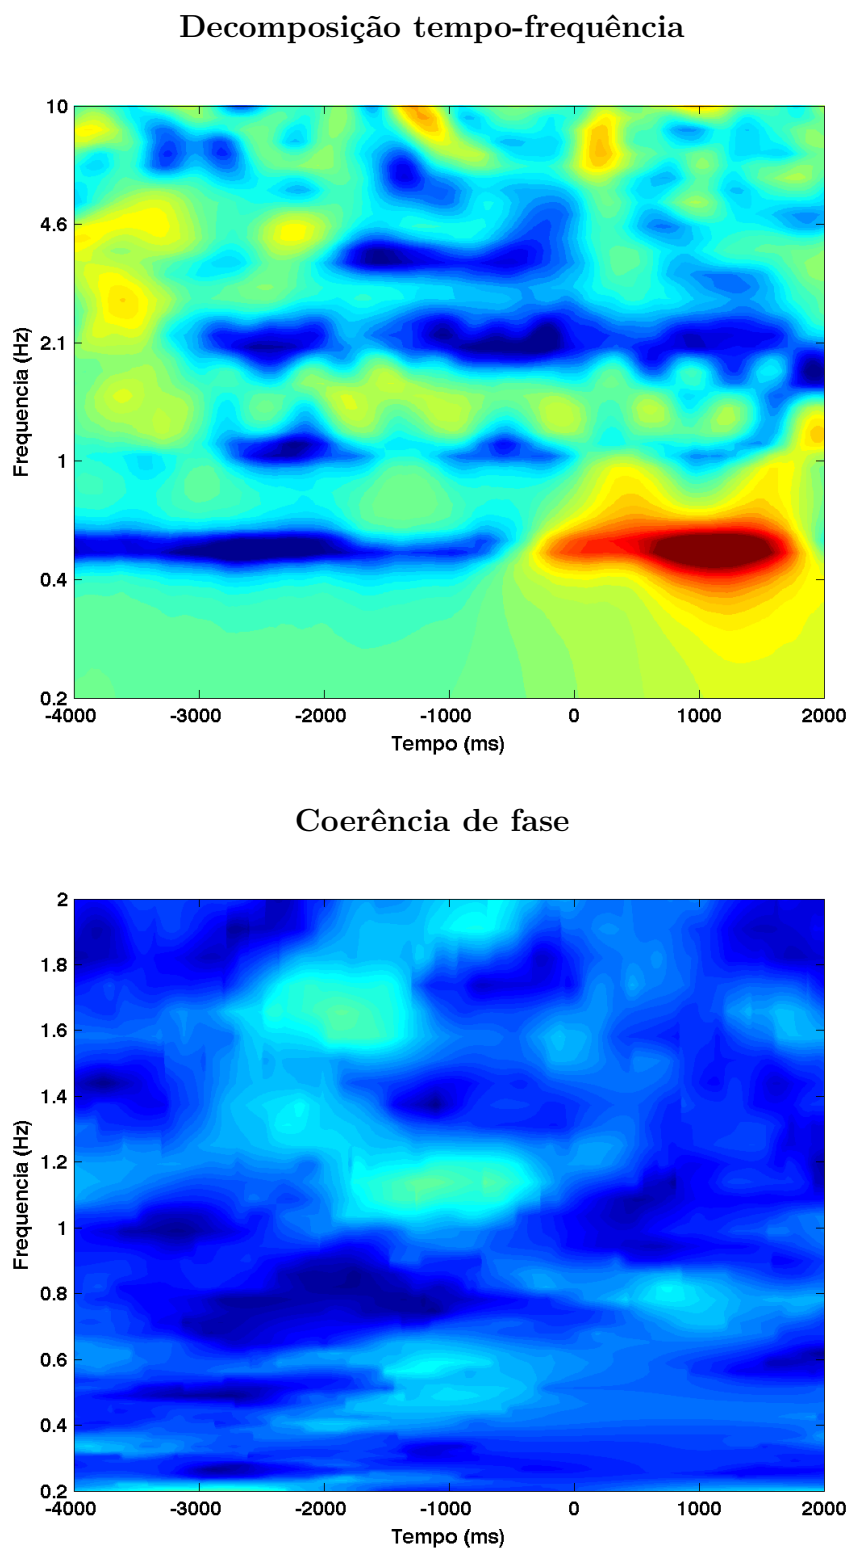



Figura 232 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 03, dia 2, eletrodo FC6.

Decomposição tempo-frequência



Coerência de fase





Figura 233 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 03, dia 2, eletrodo O1.

Decomposição tempo-frequência



Coerência de fase





Figura 234 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 03, dia 2, eletrodo O2.

Decomposição tempo-frequência



Coerência de fase




Figura 235 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 03, dia 2, eletrodo P7.

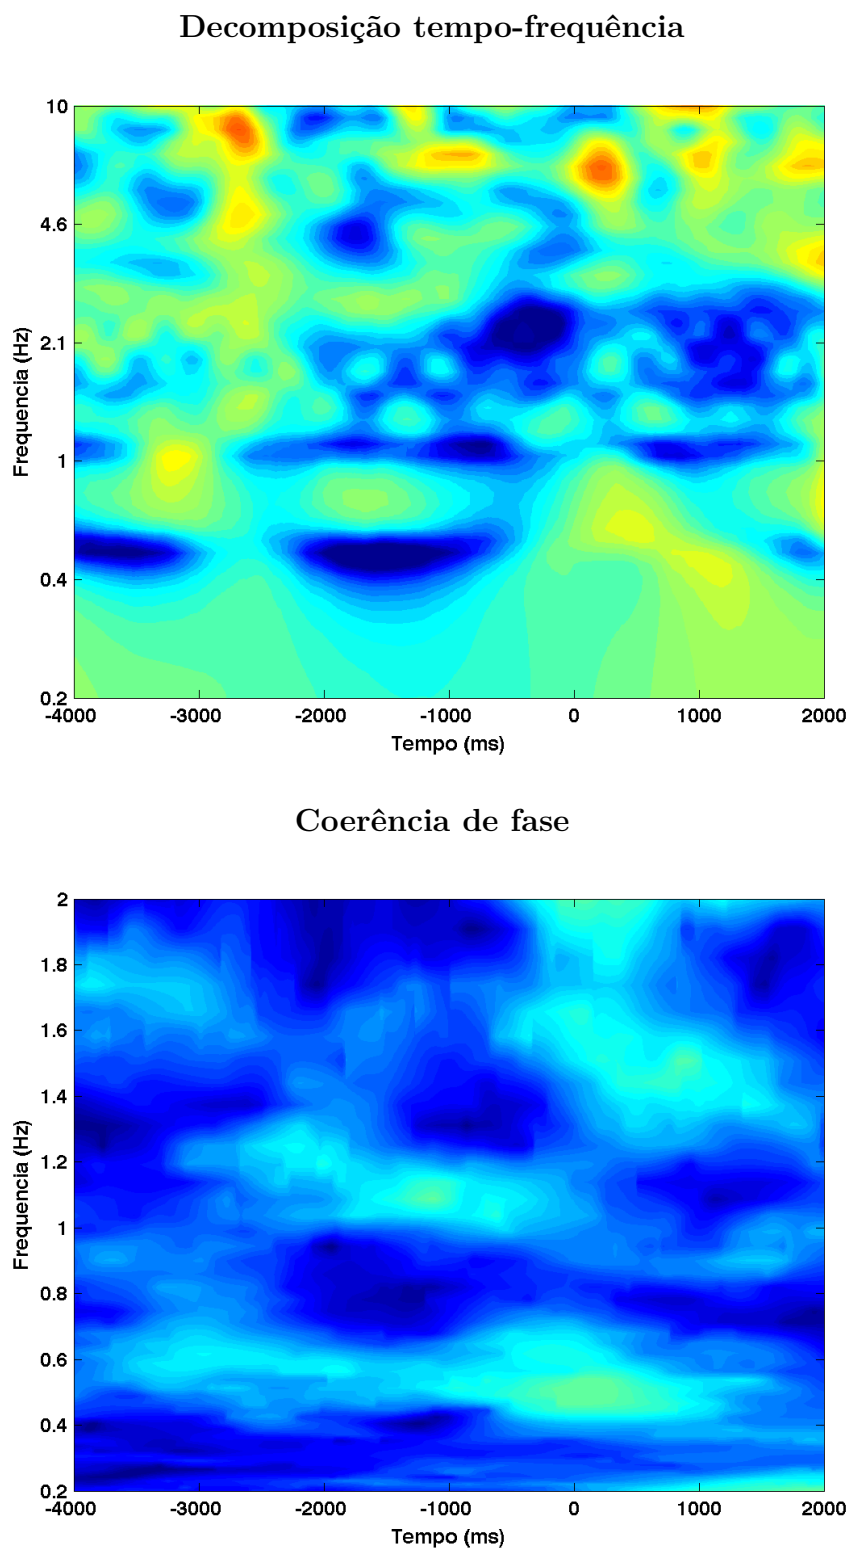


Figura 236 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 03, dia 2, eletrodo P8.




Figura 237 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 03, dia 2, eletrodo T7.

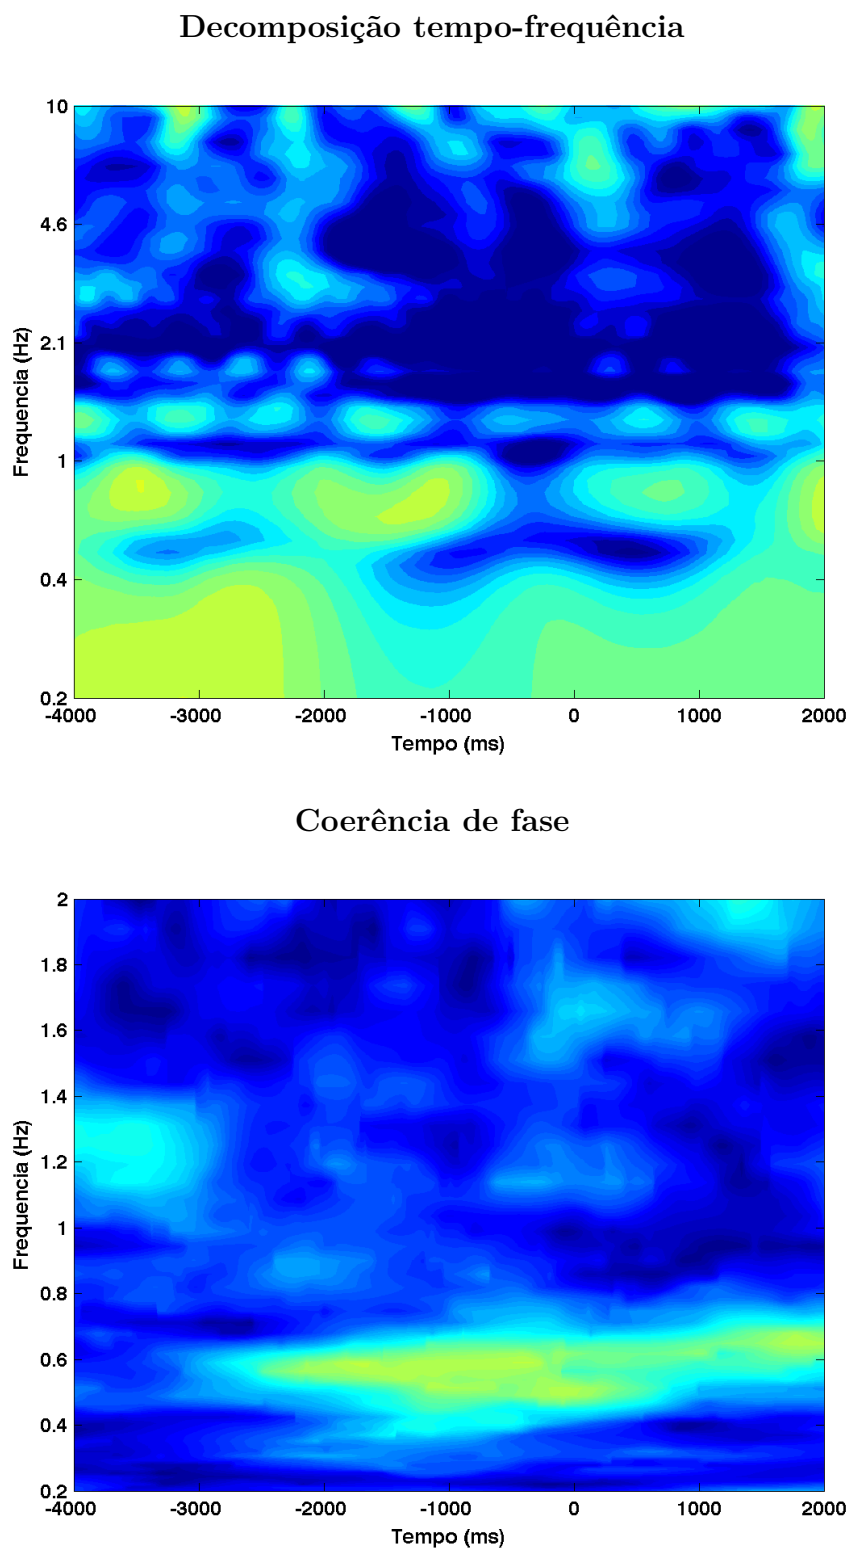



Figura 238 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 03, dia 2, eletrodo T8.

Decomposição tempo-frequência



Coerência de fase





Figura 239 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 03, dia 3, eletrodo AF3.

Decomposição tempo-frequência



Coerência de fase




Figura 240 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 03, dia 3, eletrodo AF4.

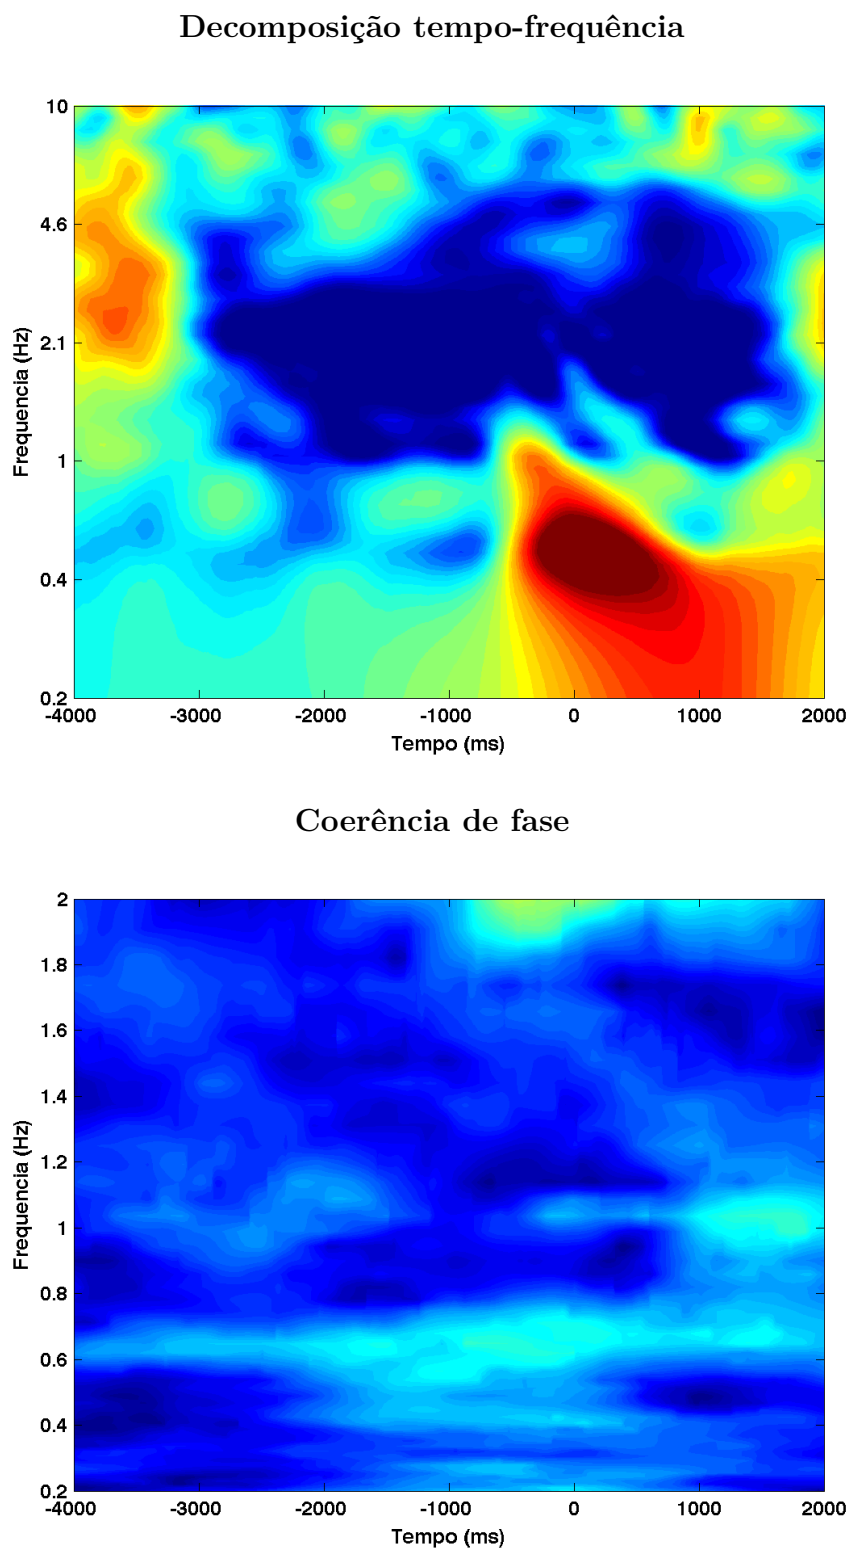


Figura 241 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 03, dia 3, eletrodo F3.

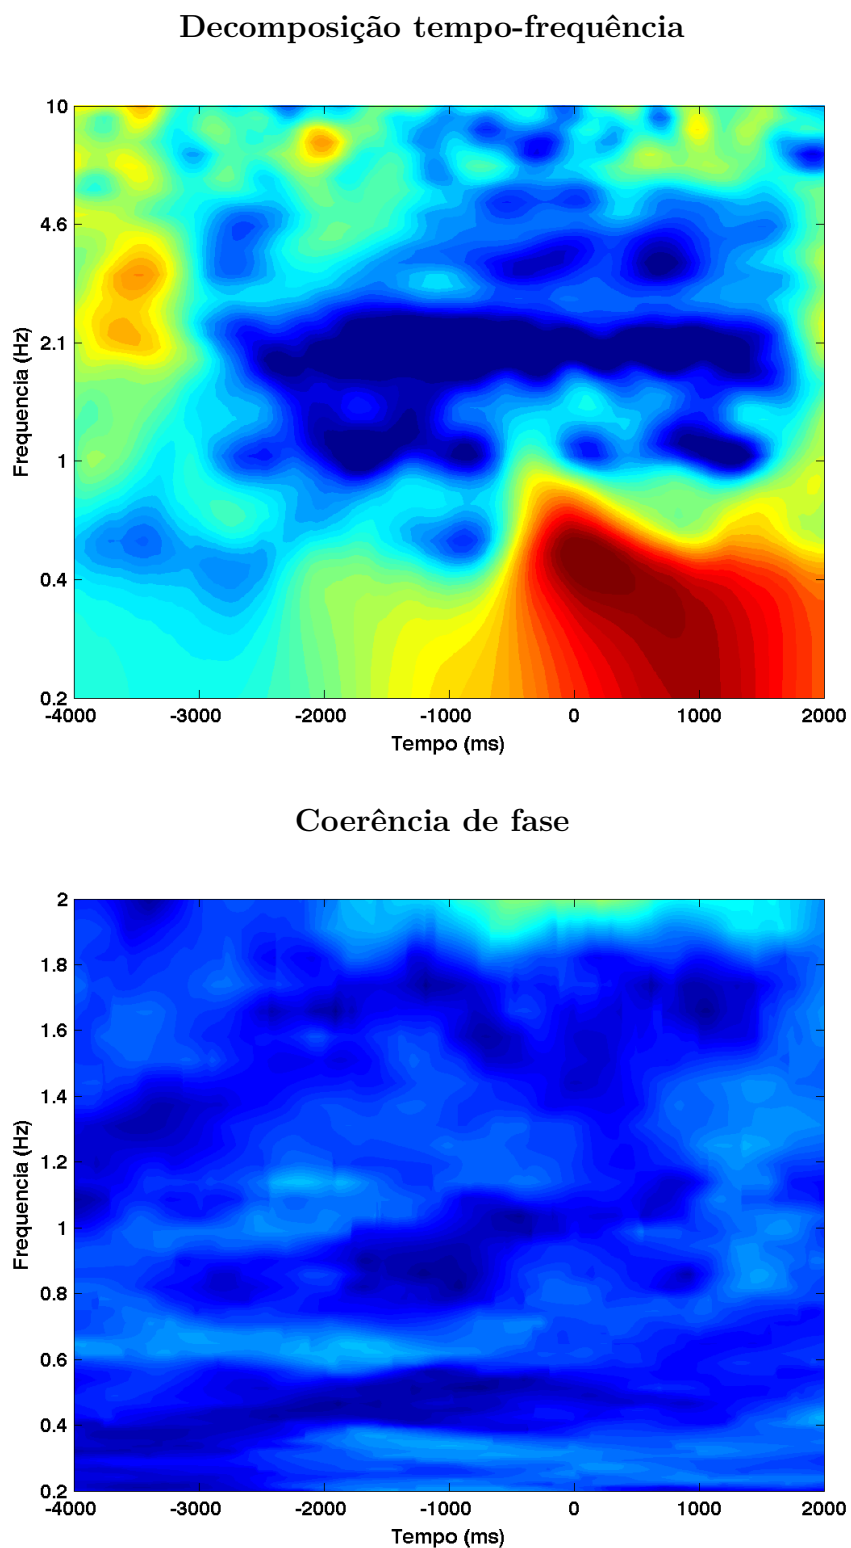


Figura 242 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 03, dia 3, eletrodo F4.

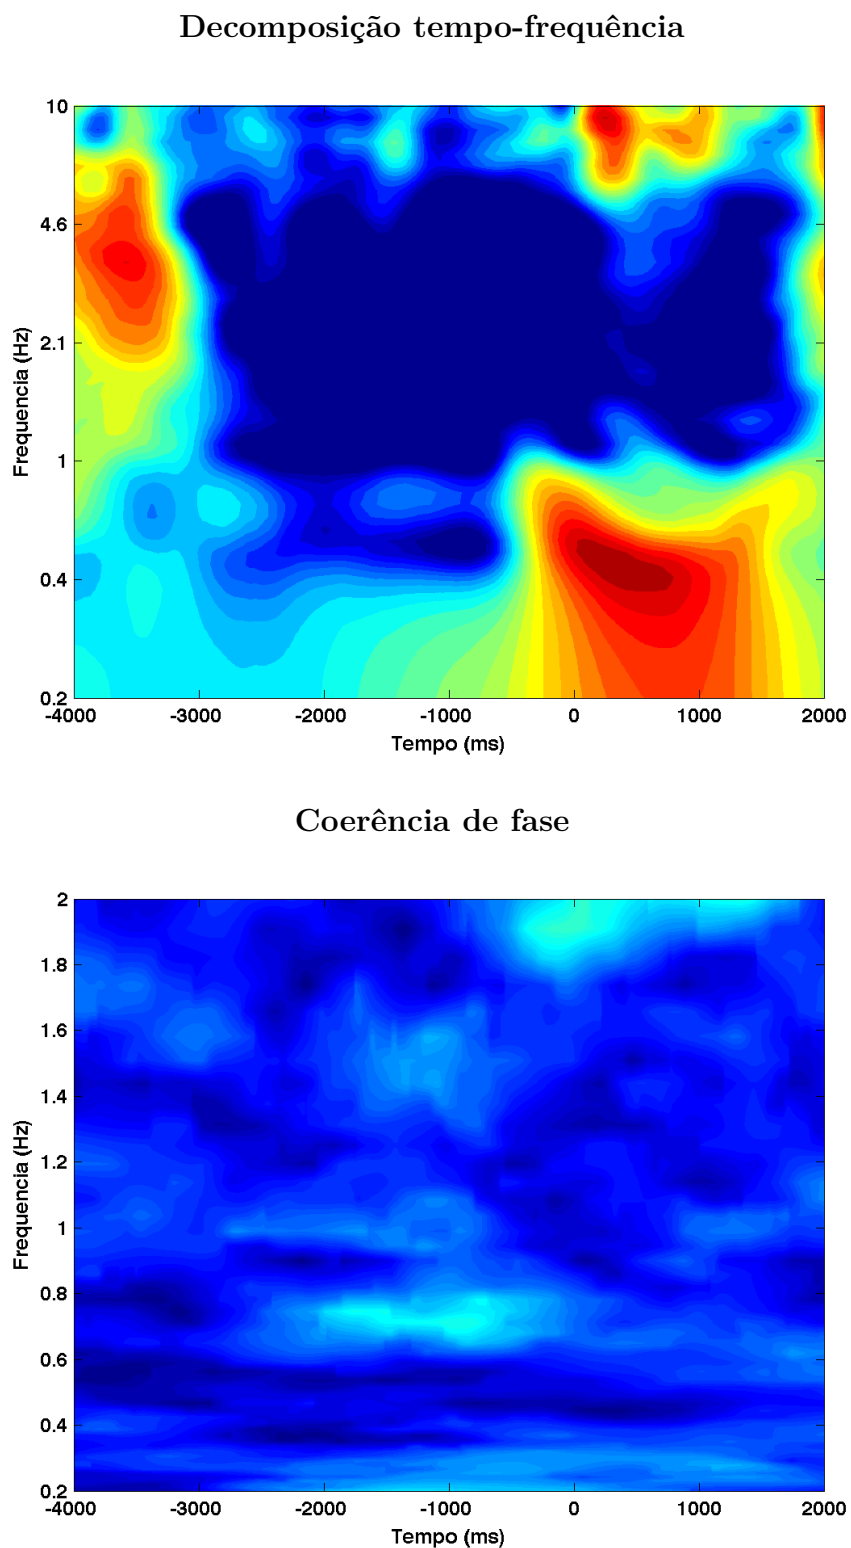


Figura 243 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 03, dia 3, eletrodo F7.





Figura 244 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 03, dia 3, eletrodo F8.

Decomposição tempo-frequência



Coerência de fase




Figura 245 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 03, dia 3, eletrodo FC5.

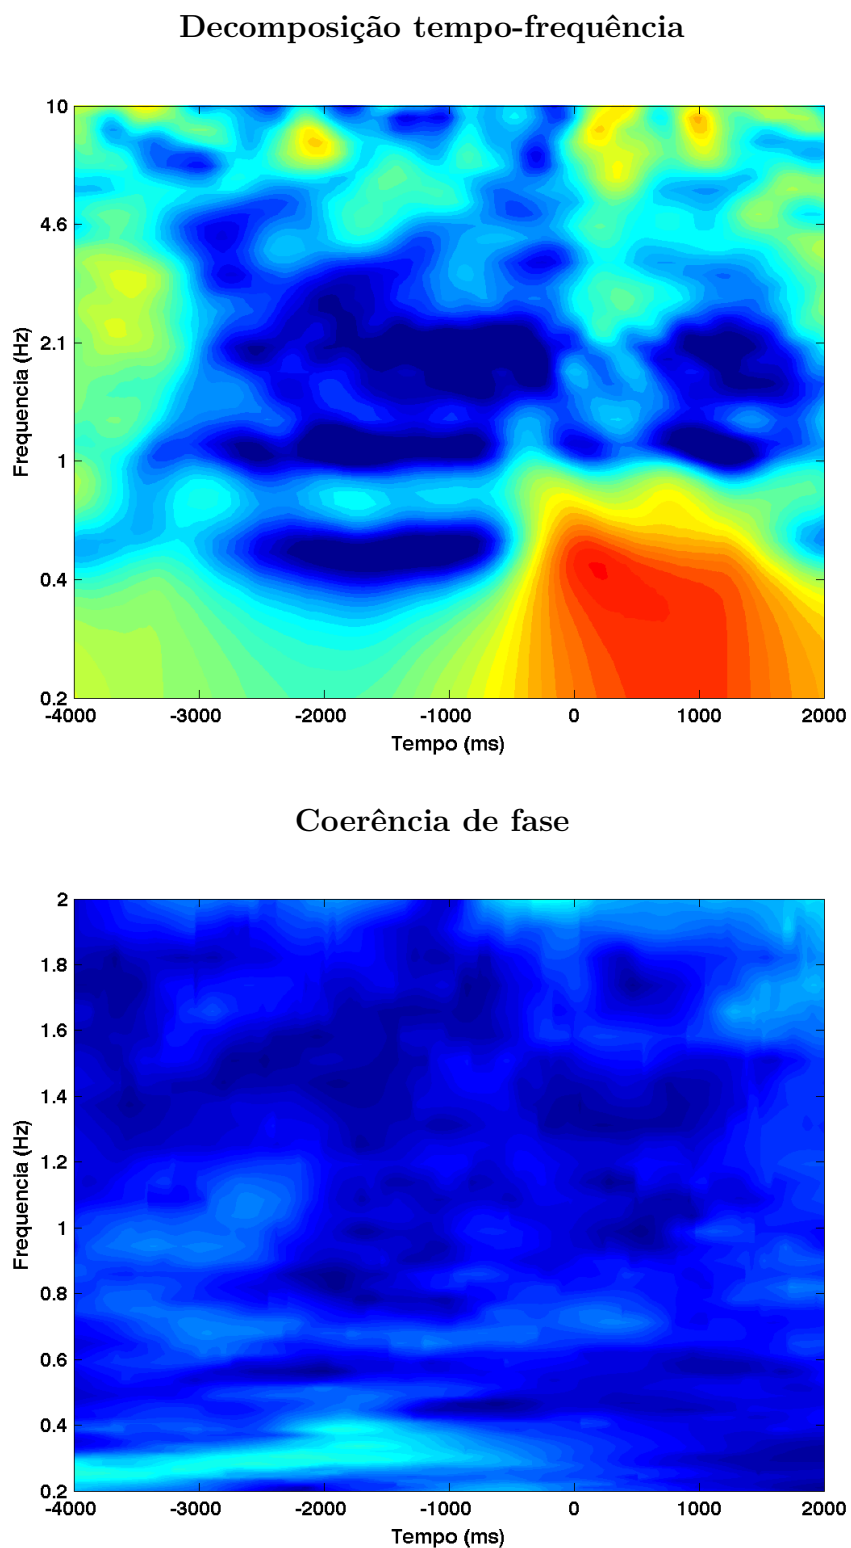


Figura 246 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 03, dia 3, eletrodo FC6.

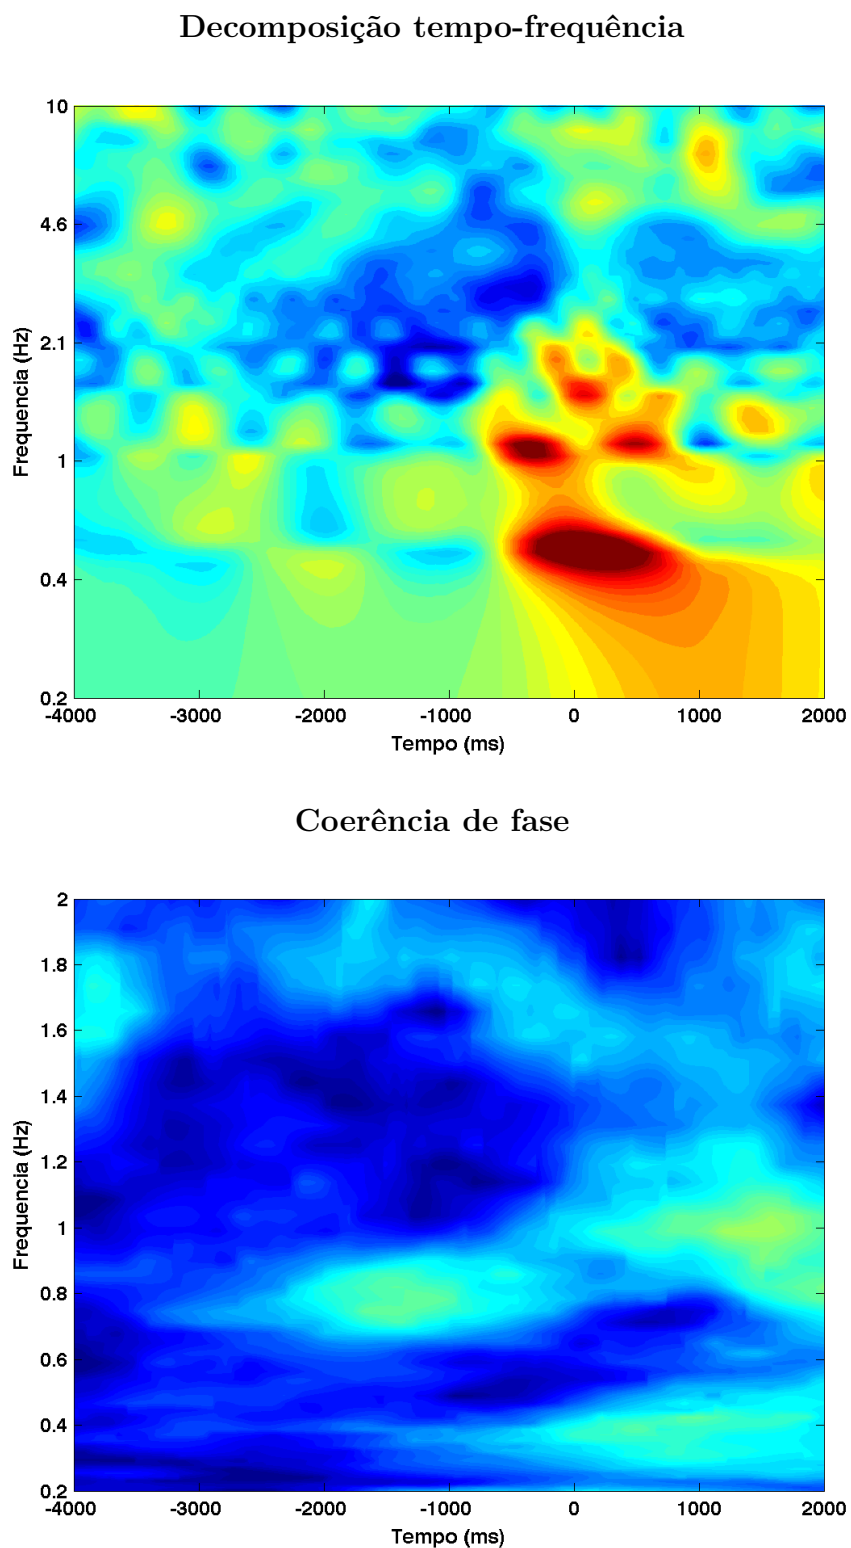


Figura 247 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 03, dia 3, eletrodo O1.

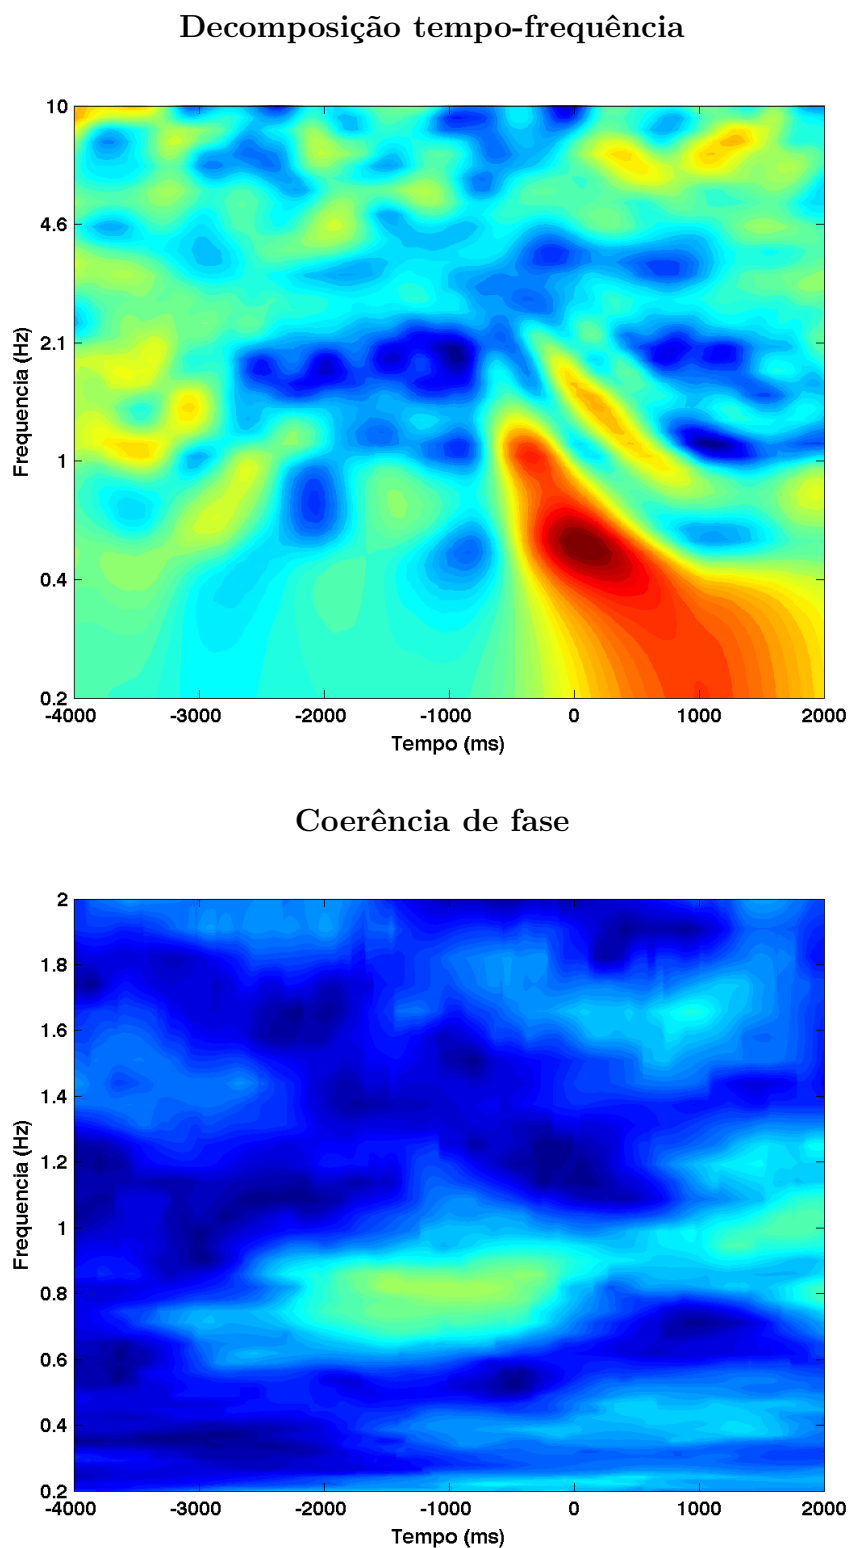



Figura 248 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 03, dia 3, eletrodo O2.

Decomposição tempo-frequência



Coerência de fase





Figura 249 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 03, dia 3, eletrodo P7.

Decomposição tempo-frequência



Coerência de fase





Figura 250 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 03, dia 3, eletrodo P8.

Decomposição tempo-frequência



Coerência de fase





Figura 251 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 03, dia 3, eletrodo T7.

Decomposição tempo-frequência



Coerência de fase





Figura 252 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 03, dia 3, eletrodo T8.

Decomposição tempo-frequência



Coerência de fase





Figura 253 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 03, dia 4, eletrodo AF3.

Decomposição tempo-frequência



Coerência de fase




Figura 254 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 03, dia 4, eletrodo AF4.

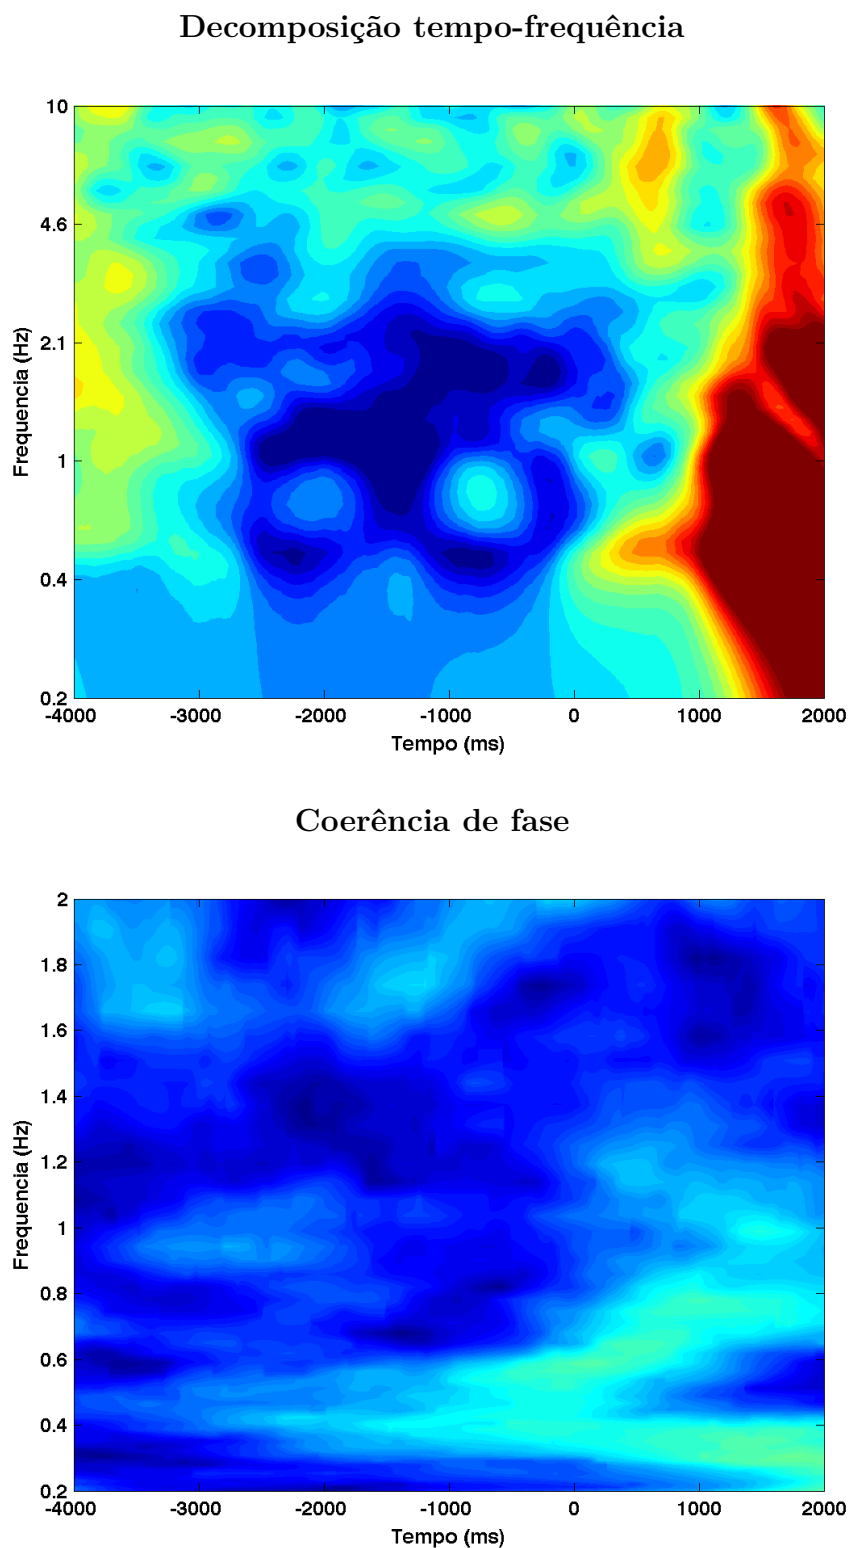


Figura 255 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 03, dia 4, eletrodo F3.




Figura 256 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 03, dia 4, eletrodo F4.




Figura 257 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 03, dia 4, eletrodo F7.

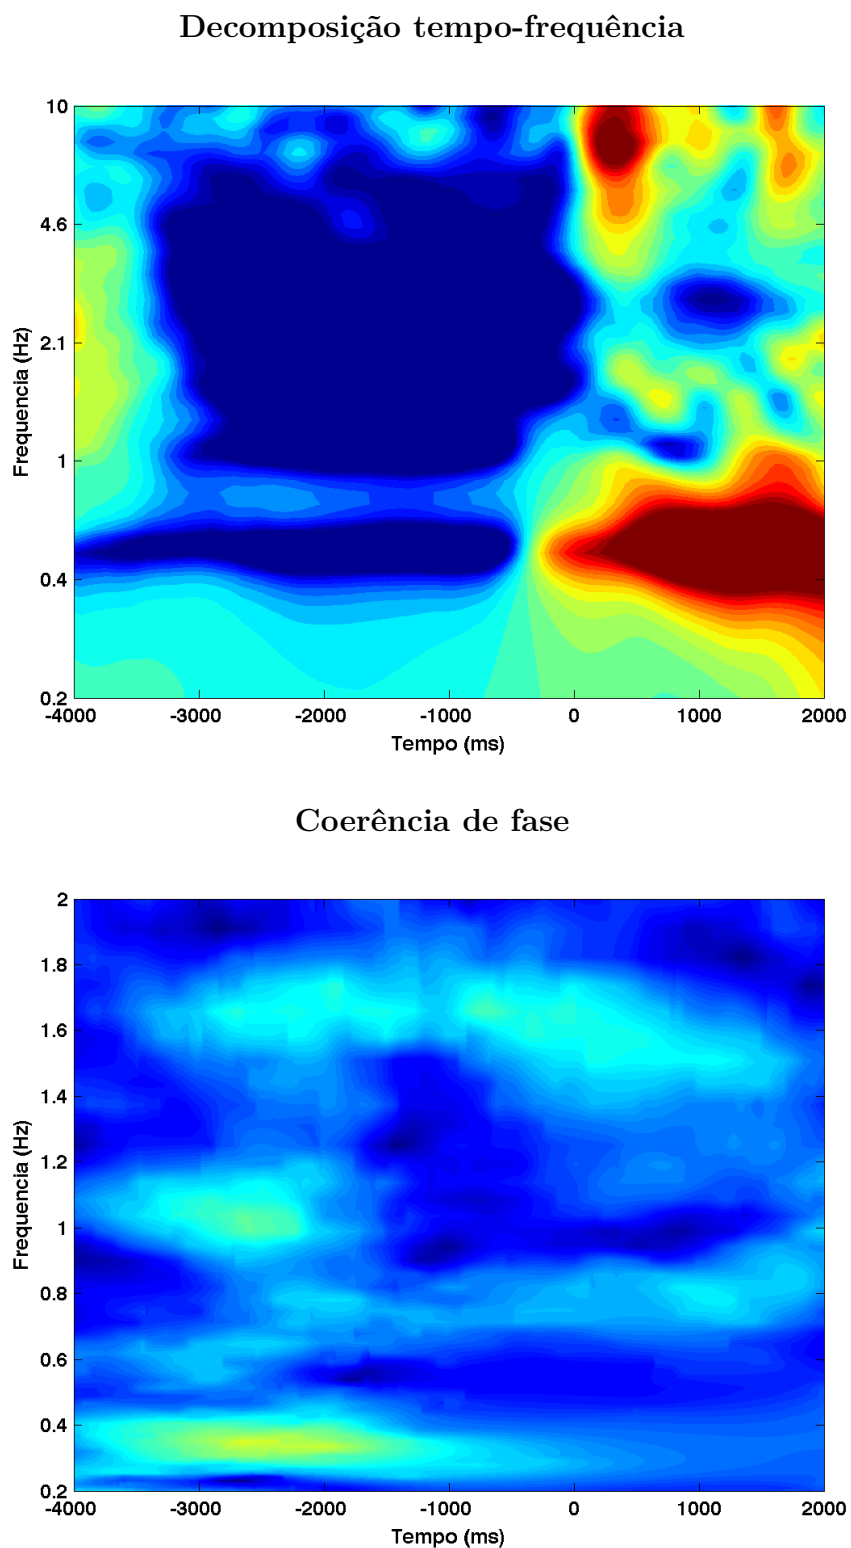


Figura 258 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 03, dia 4, eletrodo F8.




Figura 259 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 03, dia 4, eletrodo FC5.

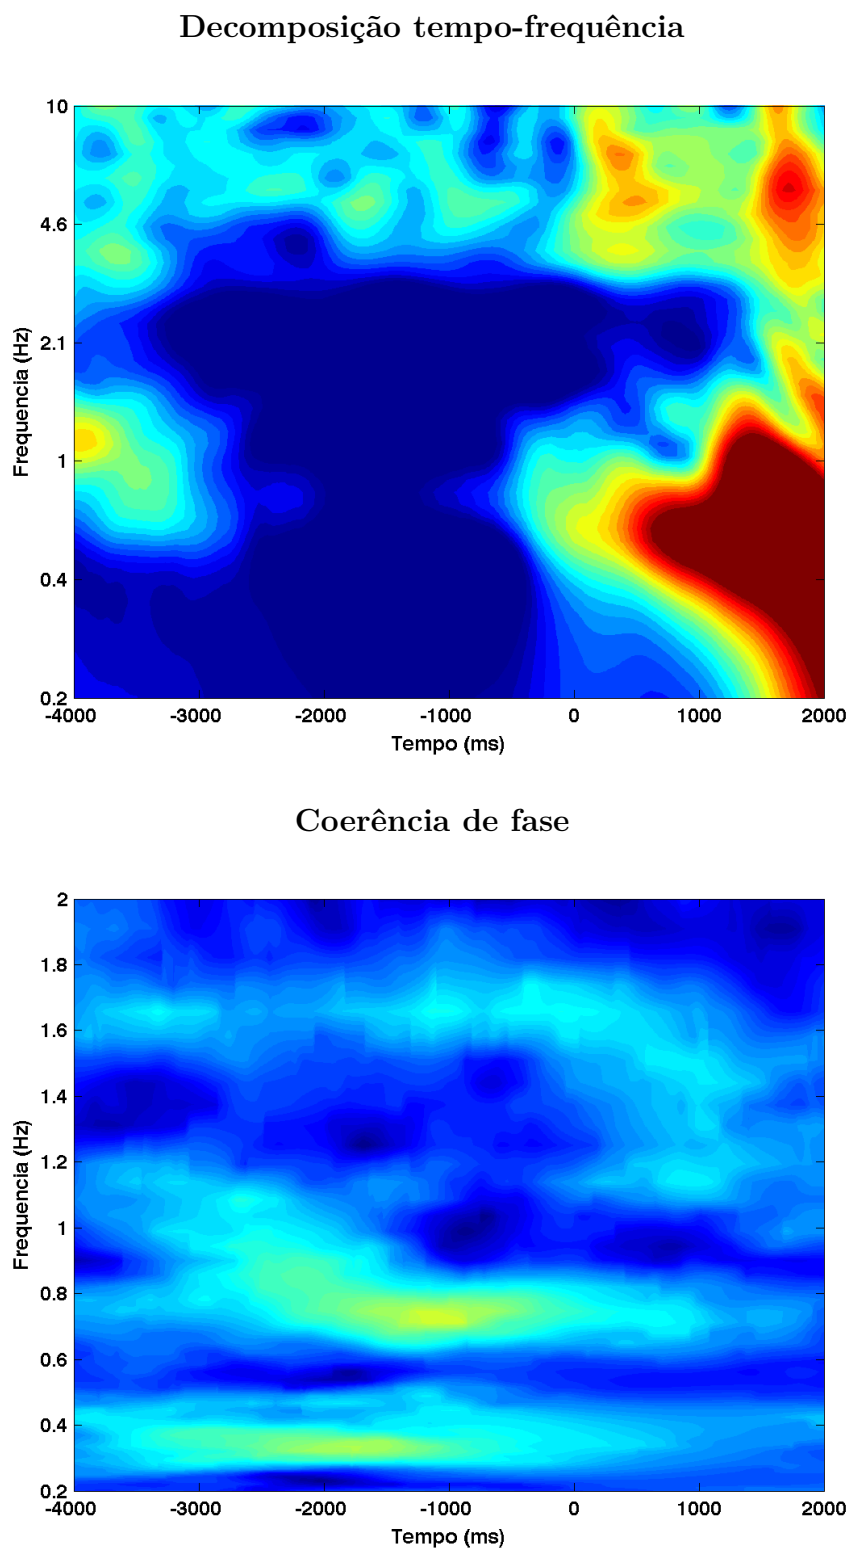



Figura 260 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 03, dia 4, eletrodo FC6.

Decomposição tempo-frequência



Coerência de fase





Figura 261 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 03, dia 4, eletrodo O1.

Decomposição tempo-frequência



Coerência de fase




Figura 262 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 03, dia 4, eletrodo O2.

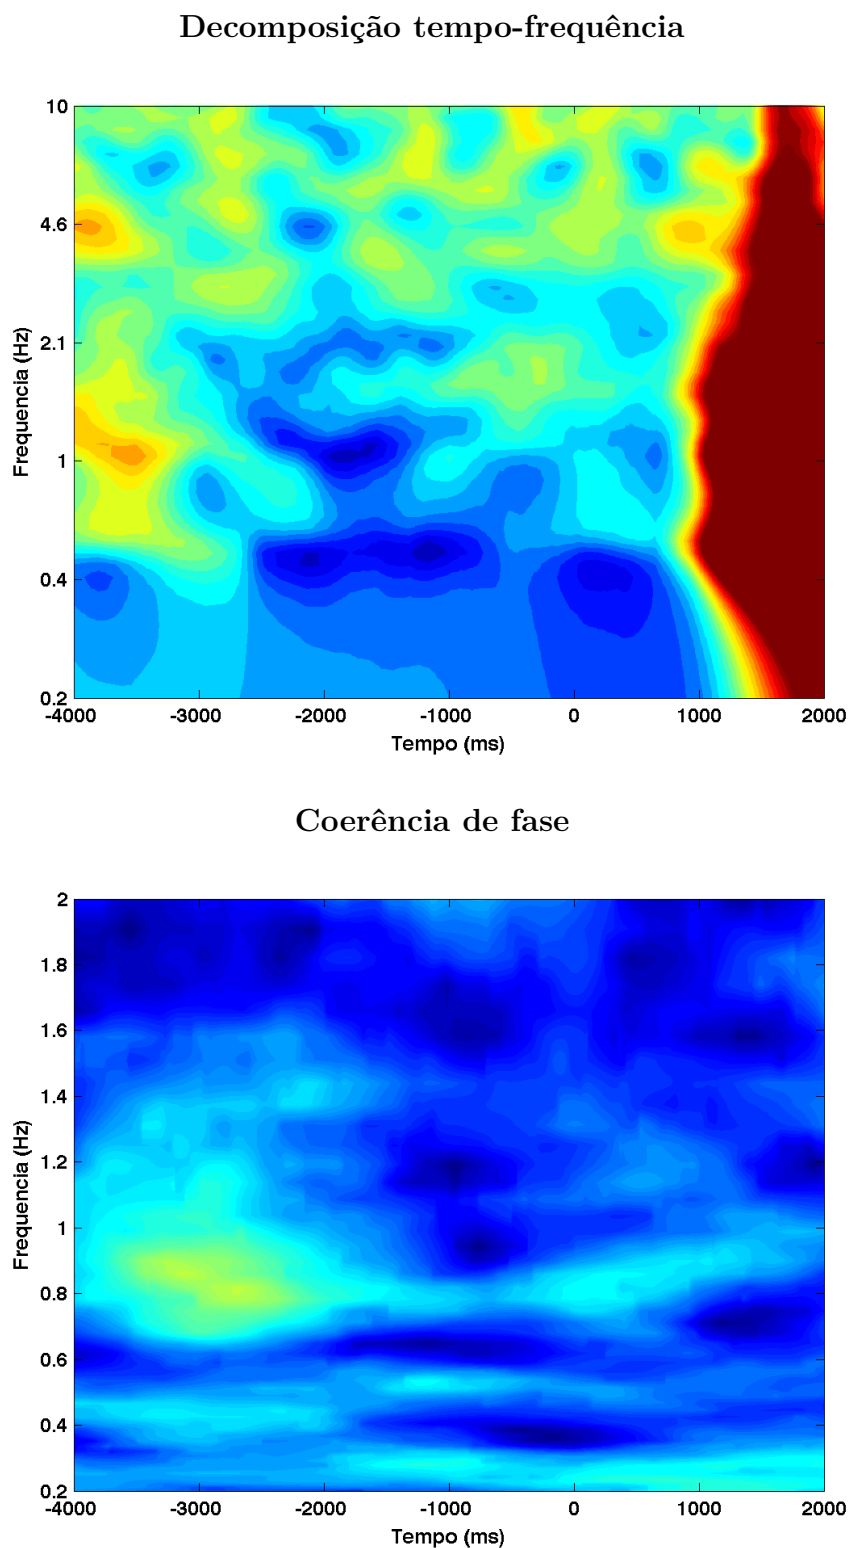


Figura 263 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 03, dia 4, eletrodo P7.

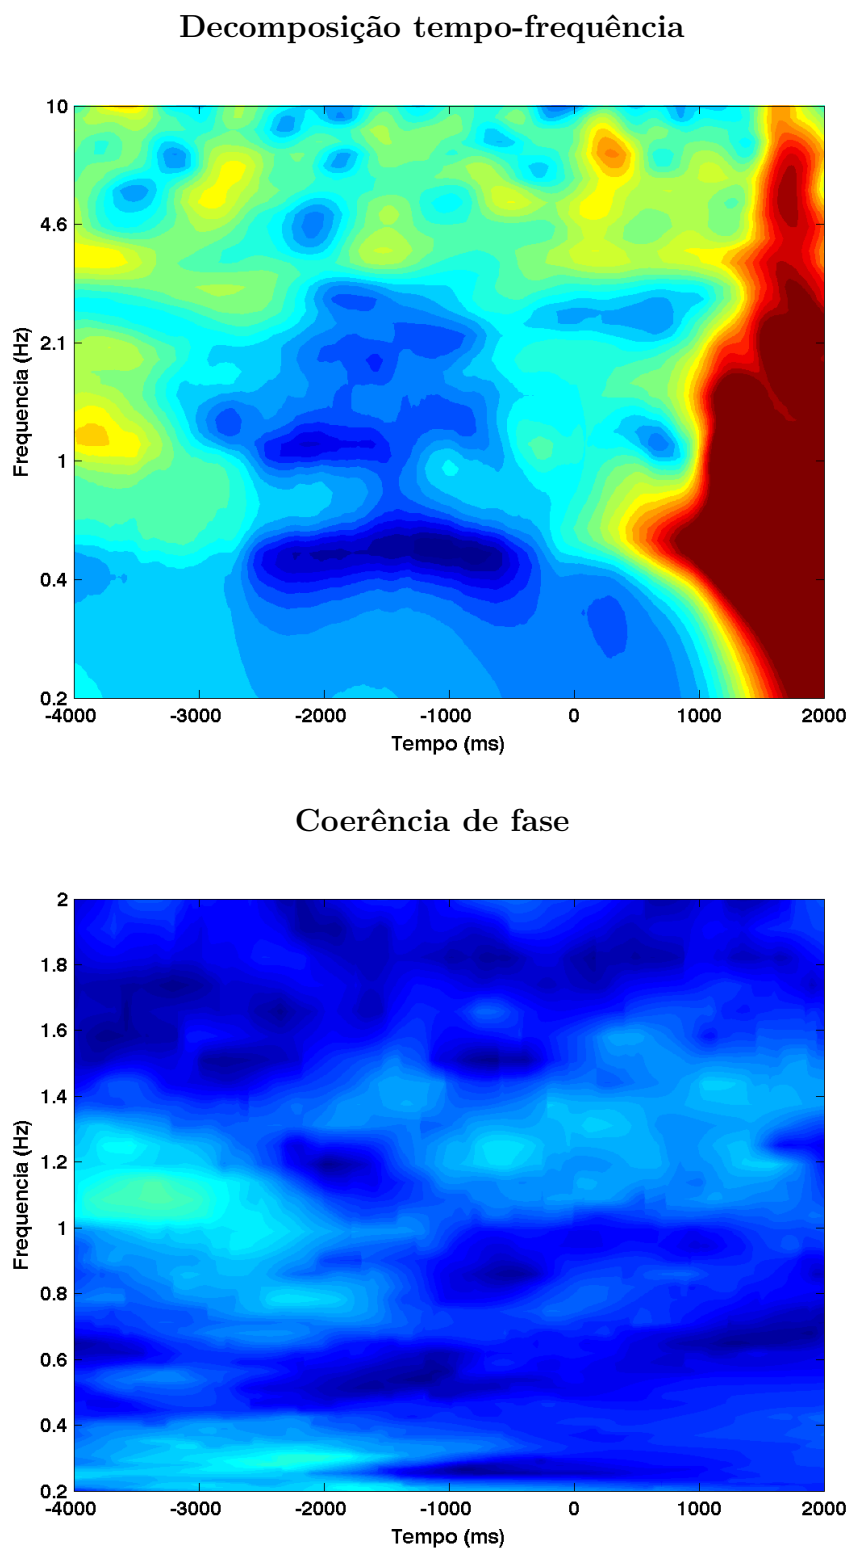



Figura 264 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 03, dia 4, eletrodo P8.

Decomposição tempo-frequência



Coerência de fase





Figura 265 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 03, dia 4, eletrodo T7.

Decomposição tempo-frequência



Coerência de fase




Figura 266 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 03, dia 4, eletrodo T8.




Figura 267 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 04, dia 1, eletrodo AF3.

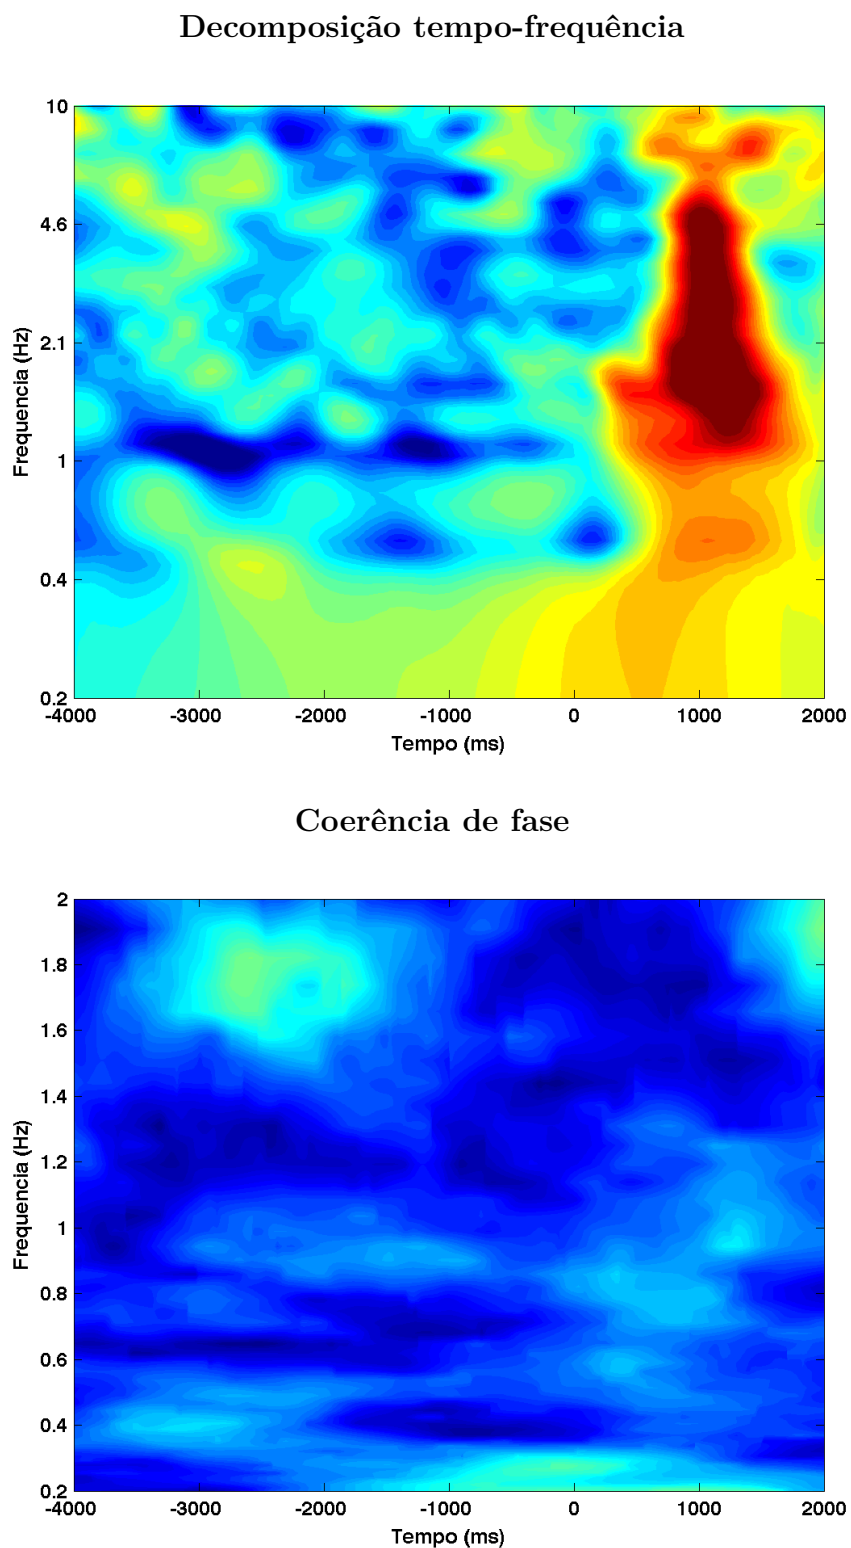


Figura 268 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 04, dia 1, eletrodo AF4.

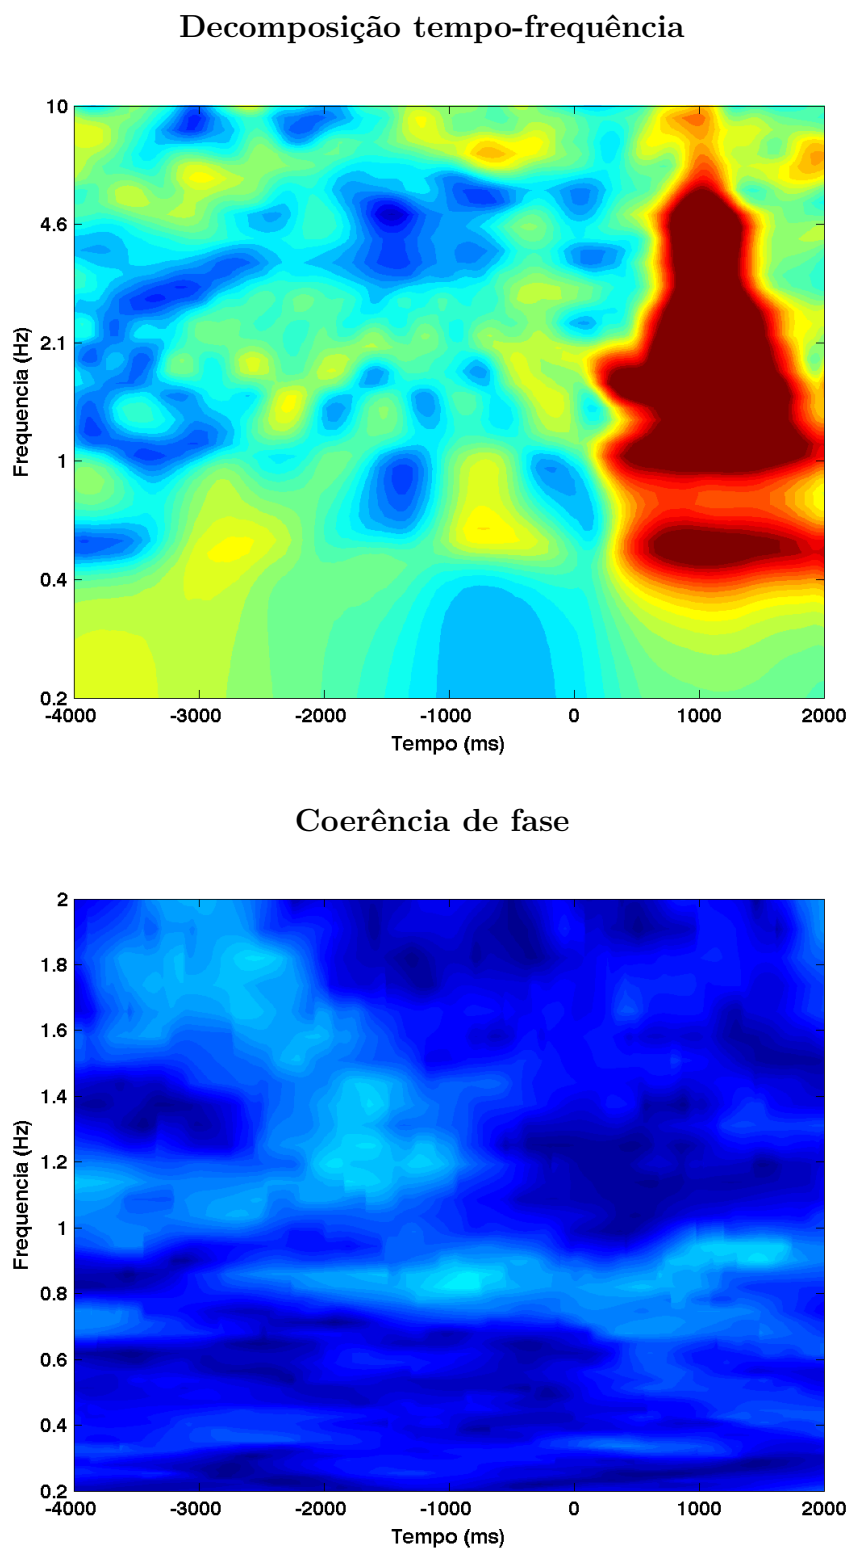


Figura 269 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 04, dia 1, eletrodo F3.

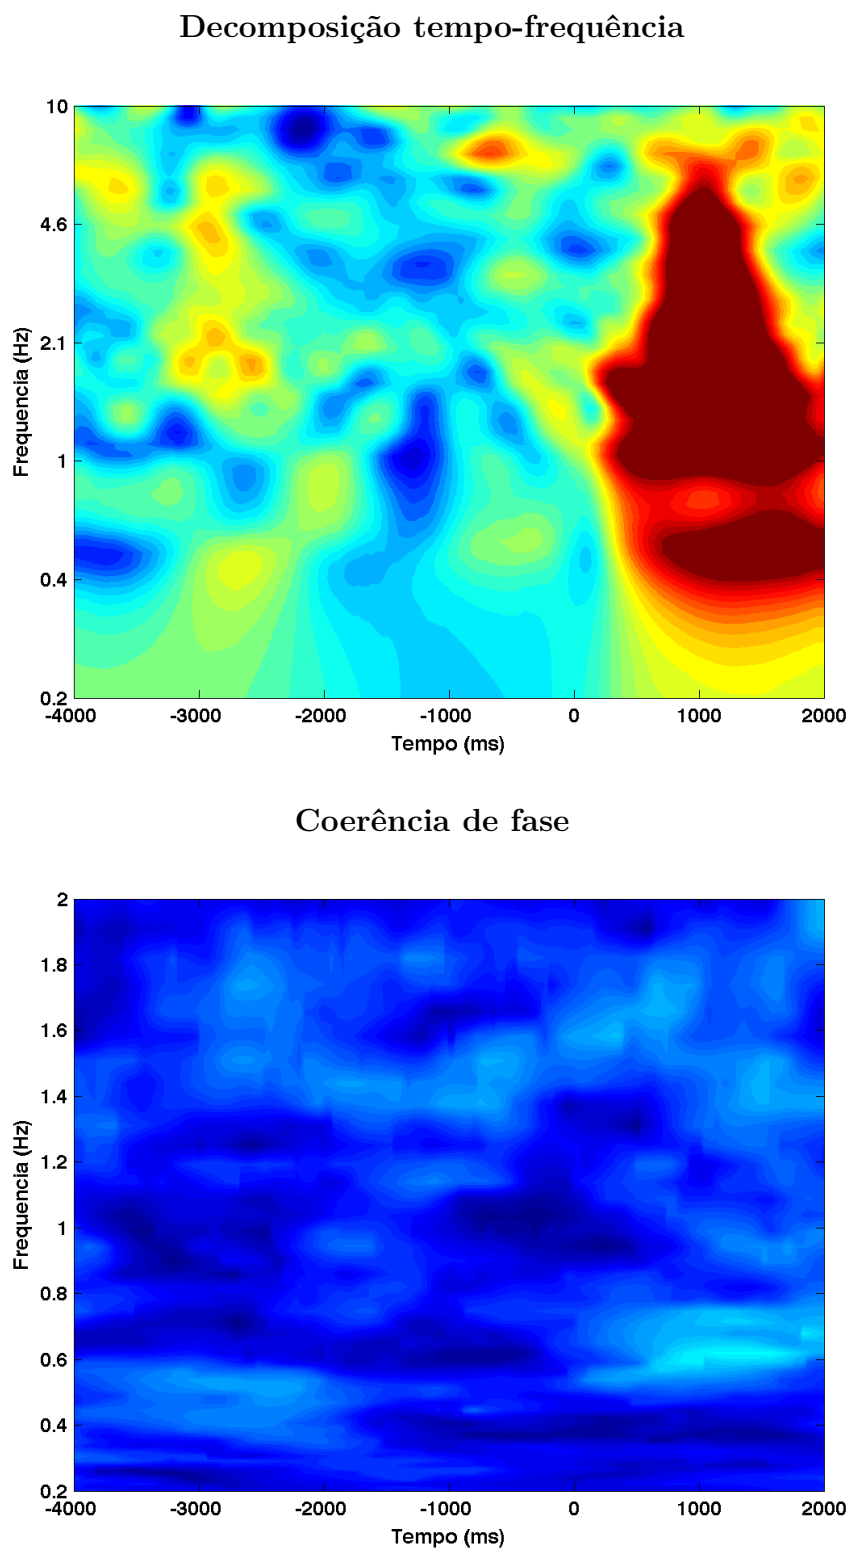


Figura 270 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 04, dia 1, eletrodo F4.





Figura 271 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 04, dia 1, eletrodo F7.

Decomposição tempo-frequência



Coerência de fase





Figura 272 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 04, dia 1, eletrodo F8.

Decomposição tempo-frequência



Coerência de fase




Figura 273 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 04, dia 1, eletrodo FC5.

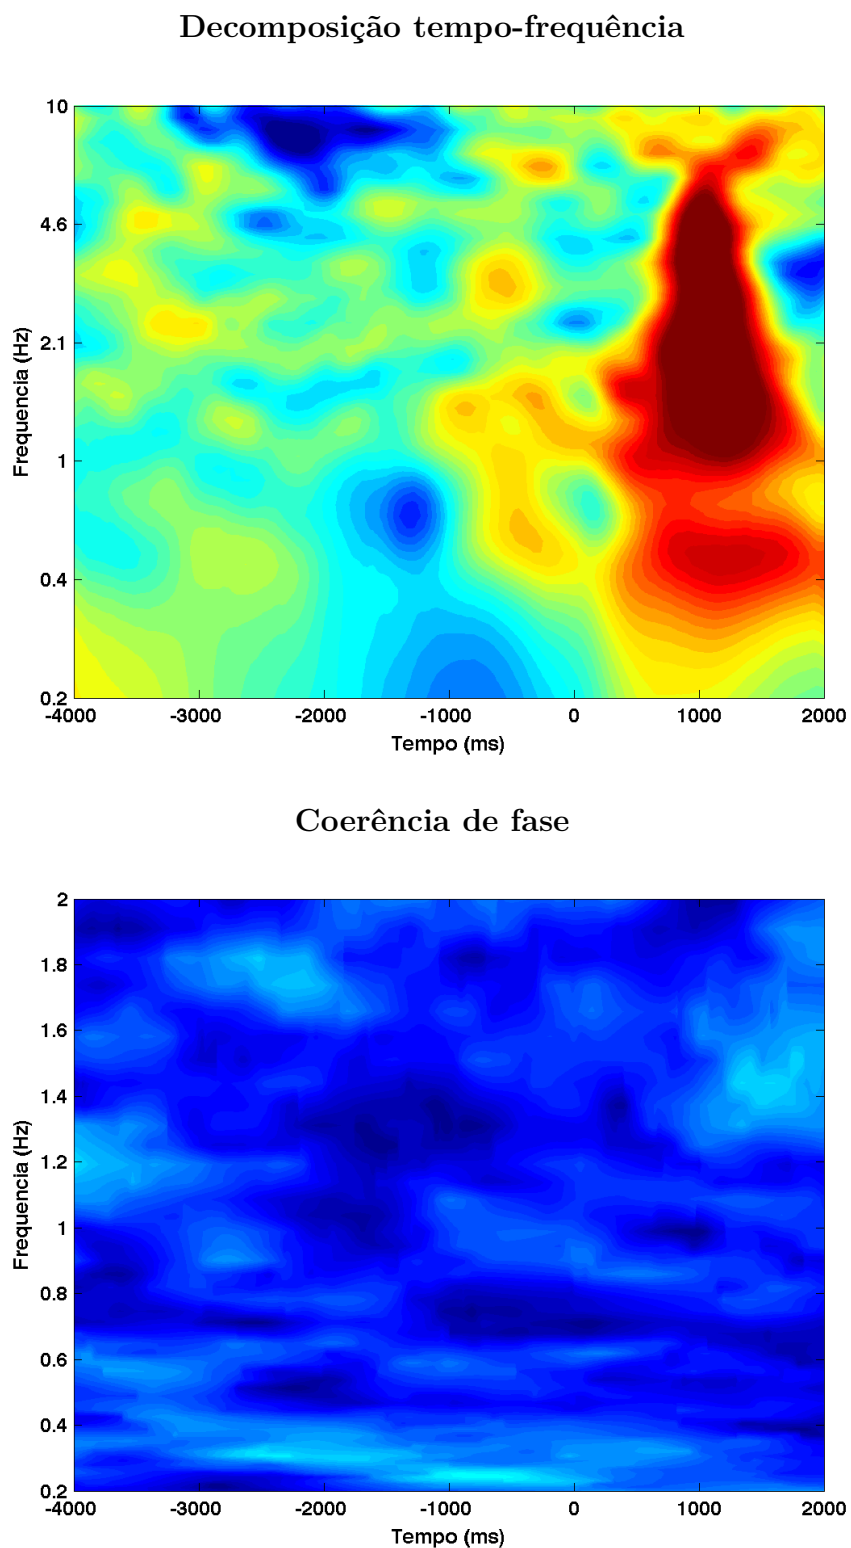


Figura 274 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 04, dia 1, eletrodo FC6.




Figura 275 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 04, dia 1, eletrodo O1.

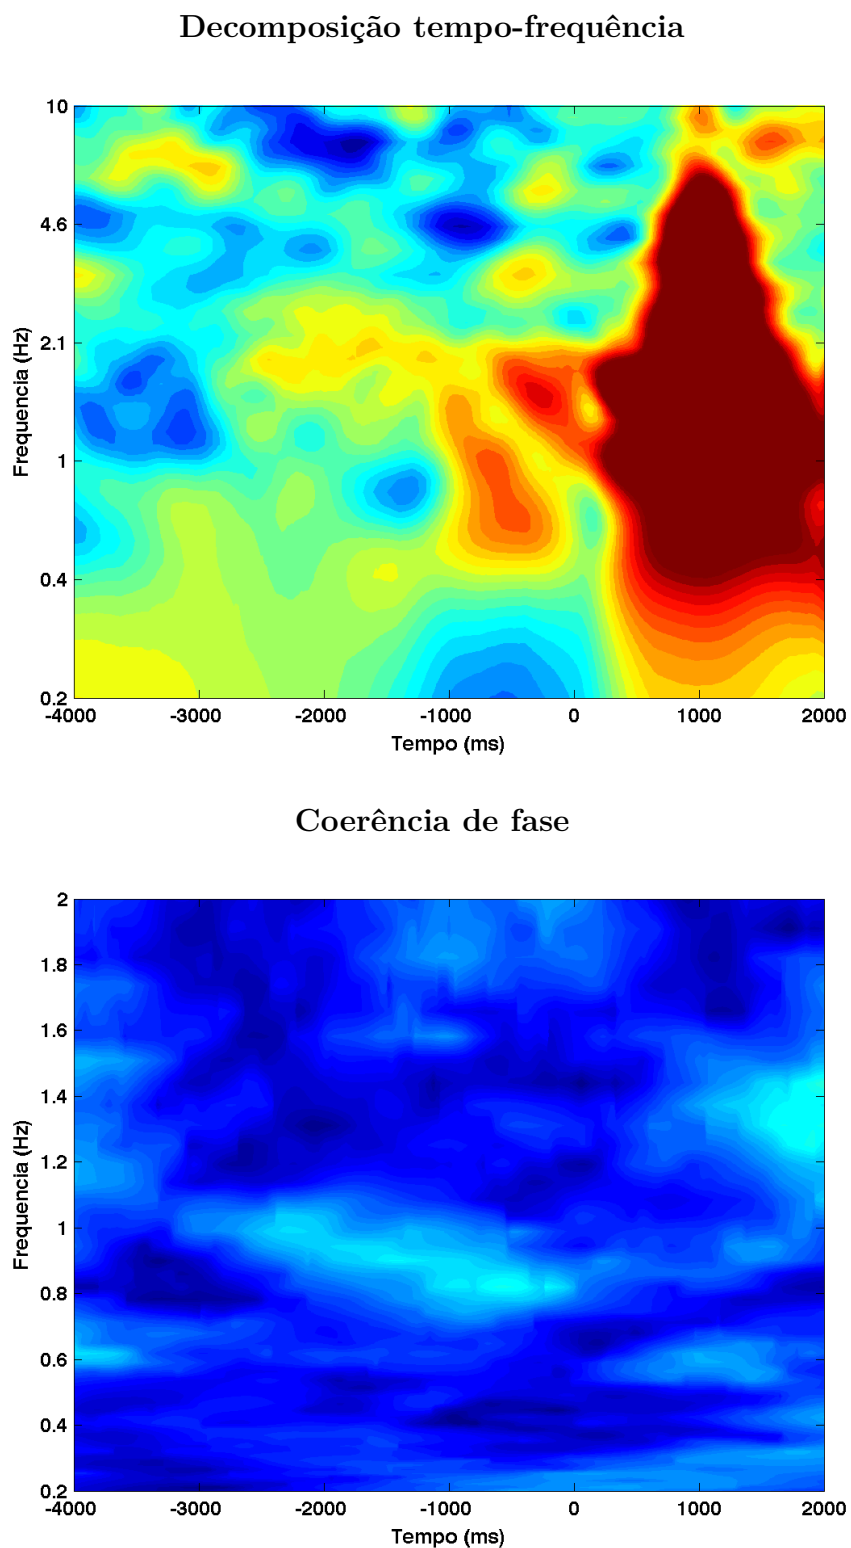


Figura 276 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 04, dia 1, eletrodo O2.

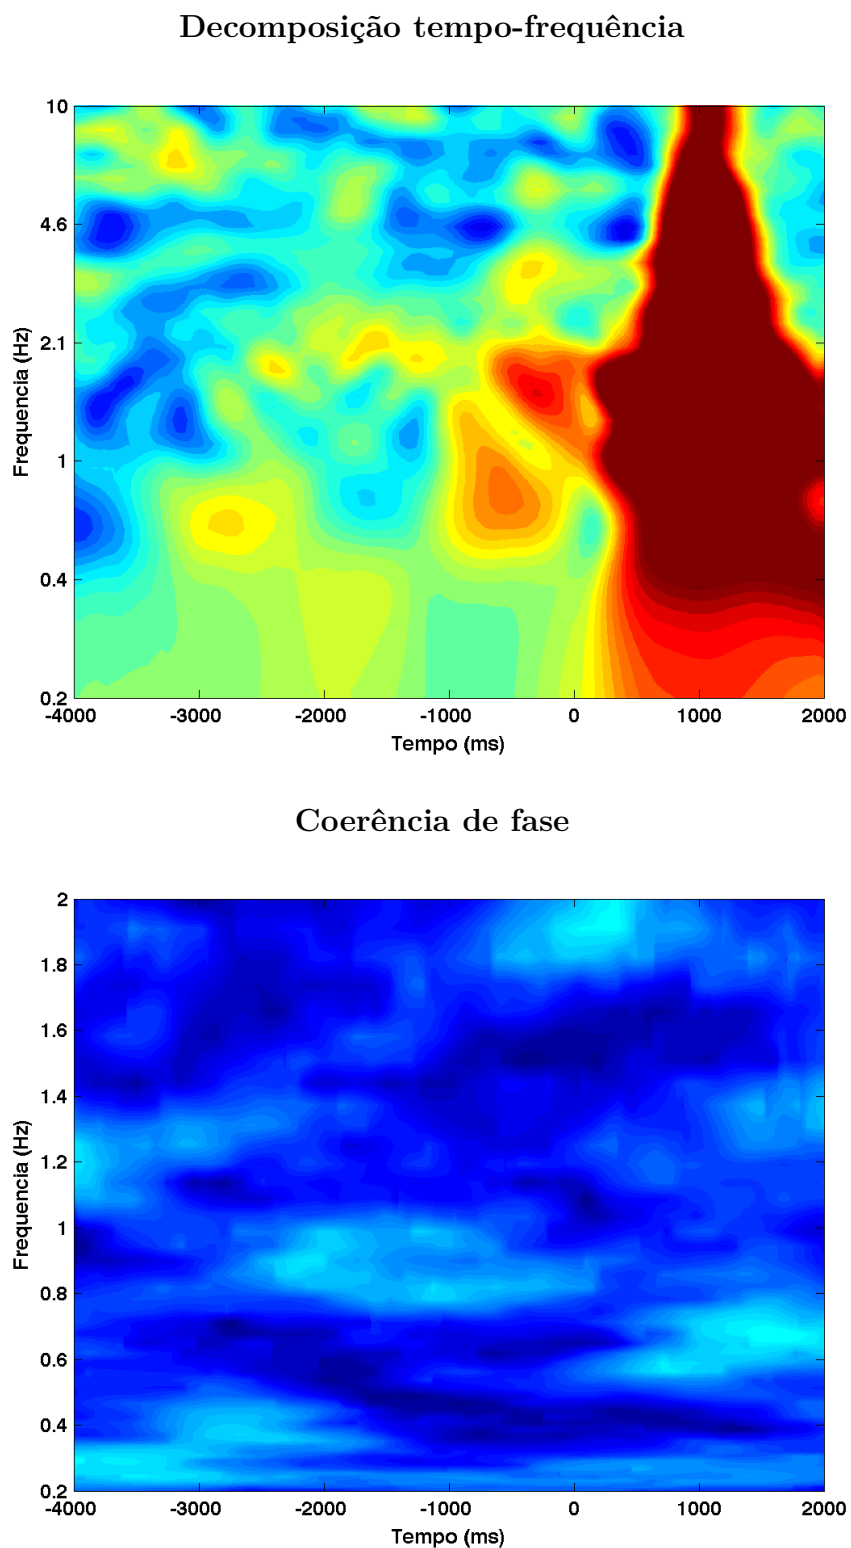



Figura 277 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 04, dia 1, eletrodo P7.

Decomposição tempo-frequência



Coerência de fase




Figura 278 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 04, dia 1, eletrodo P8.

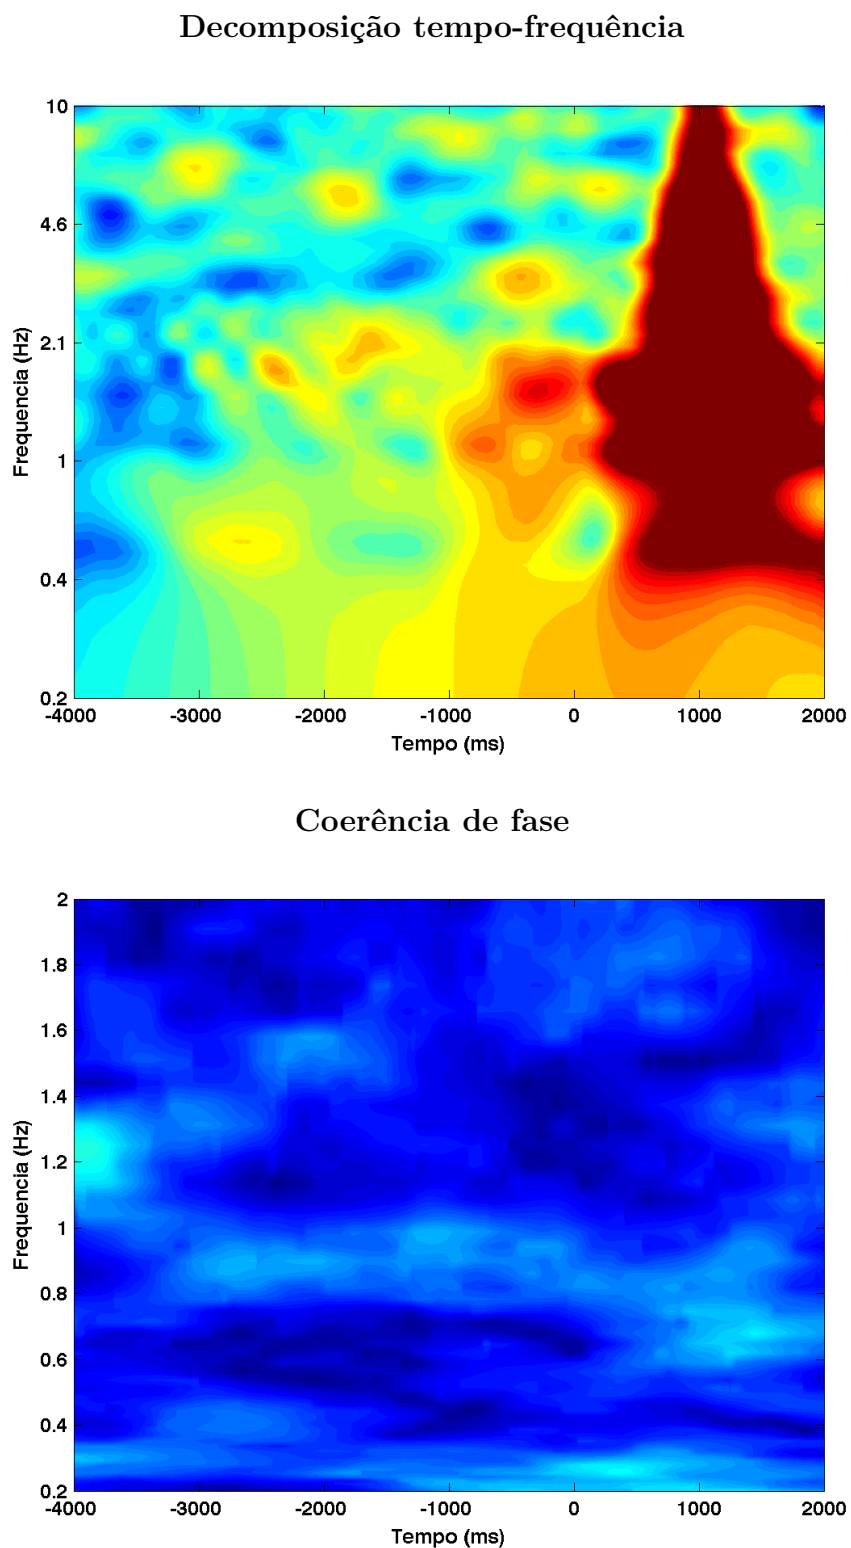


Figura 279 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 04, dia 1, eletrodo T7.

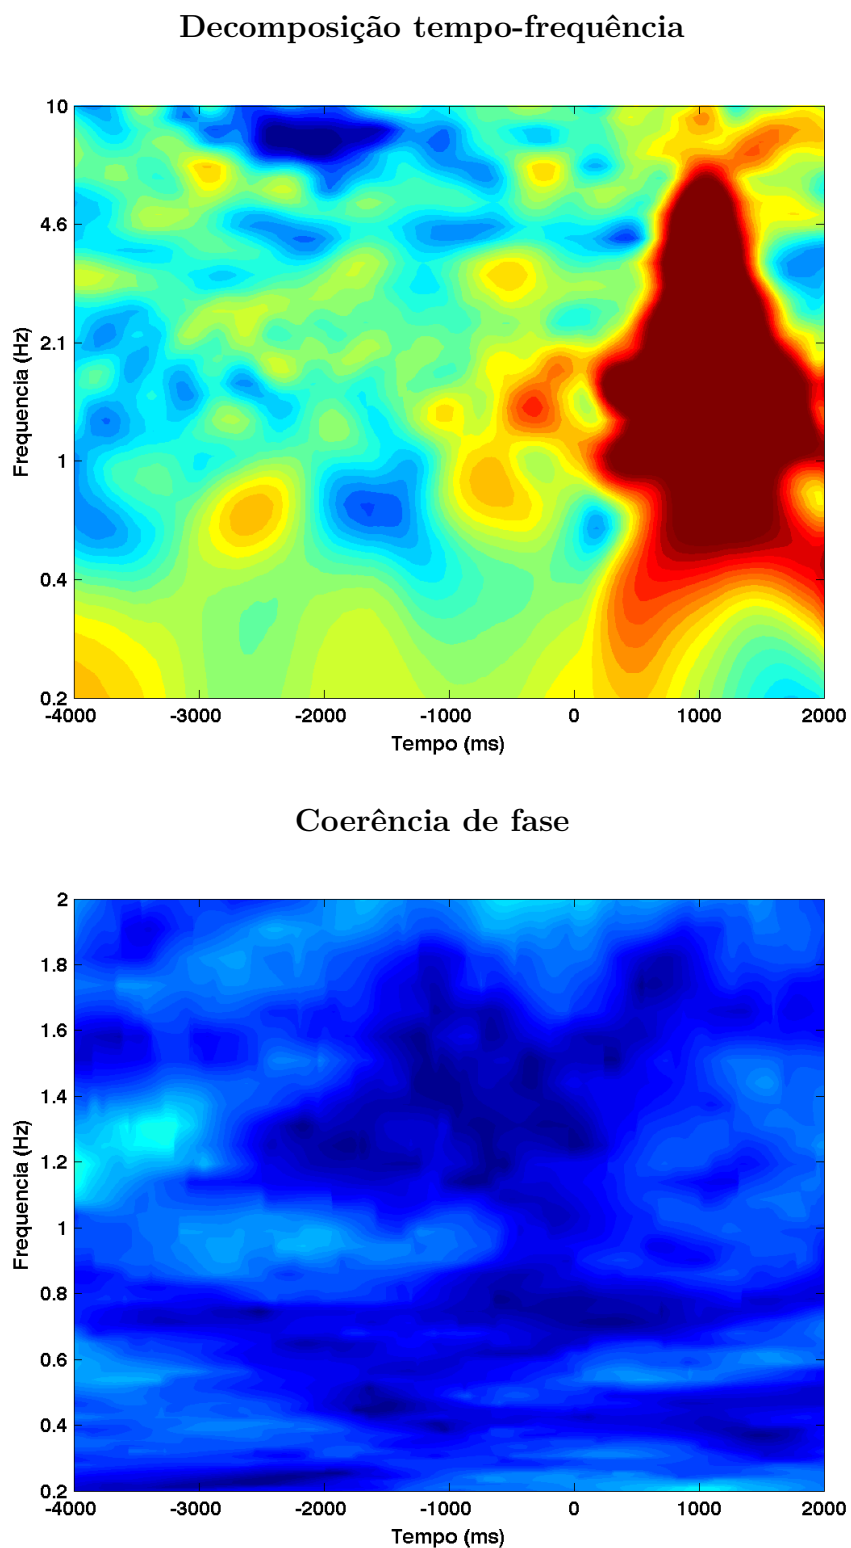


Figura 280 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 04, dia 1, eletrodo T8.

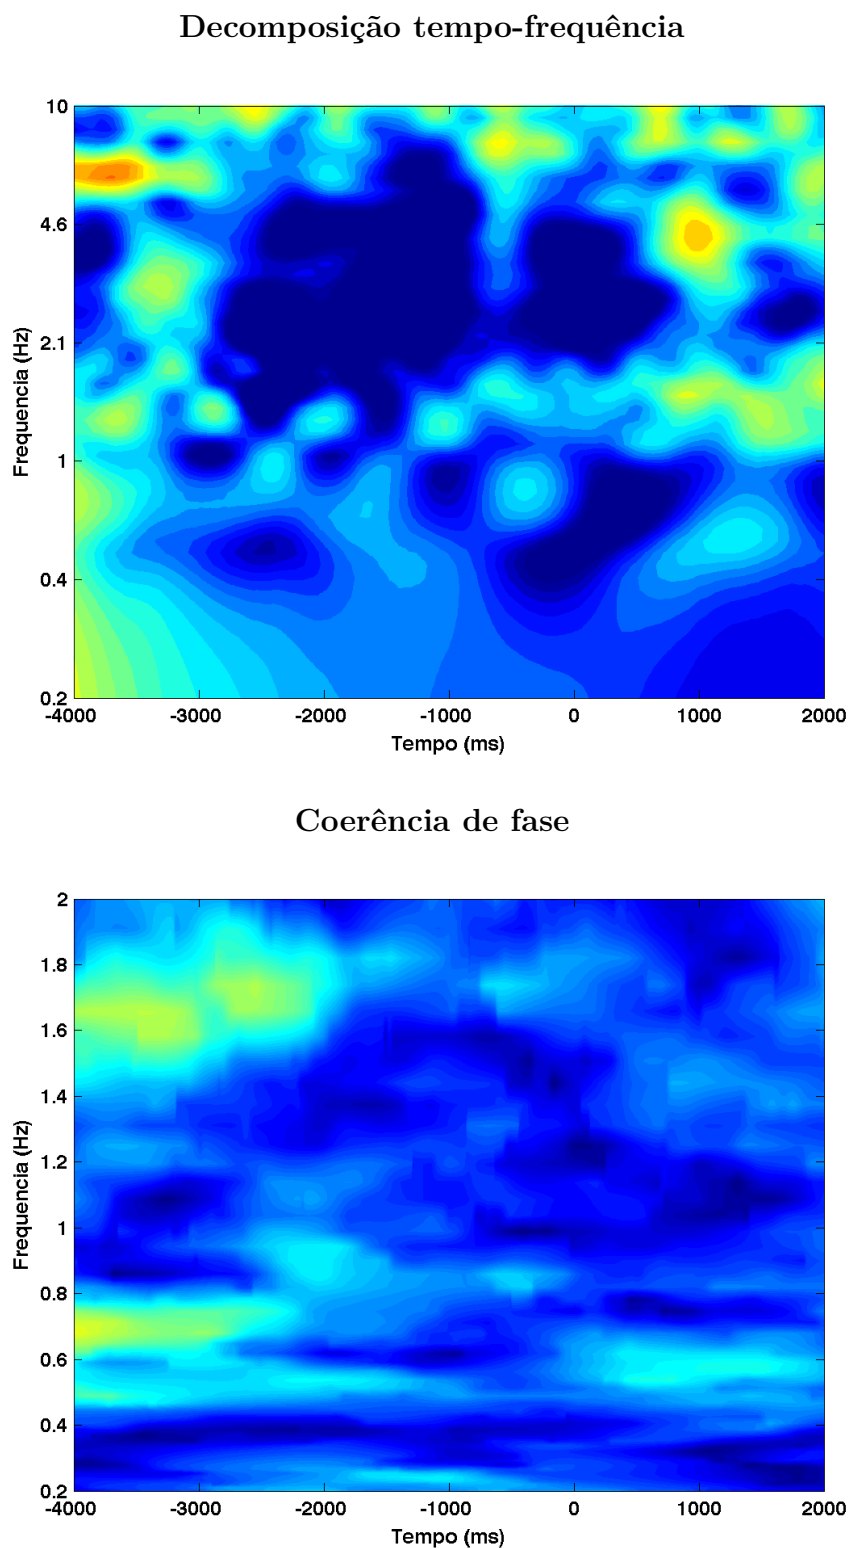



Figura 281 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 04, dia 2, eletrodo AF3.

Decomposição tempo-frequência



Coerência de fase





Figura 282 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 04, dia 2, eletrodo AF4.

Decomposição tempo-frequência



Coerência de fase





Figura 283 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 04, dia 2, eletrodo F3.

Decomposição tempo-frequência



Coerência de fase





Figura 284 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 04, dia 2, eletrodo F4.

Decomposição tempo-frequência



Coerência de fase





Figura 285 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 04, dia 2, eletrodo F7.

Decomposição tempo-frequência



Coerência de fase




Figura 286 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 04, dia 2, eletrodo F8.





Figura 287 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 04, dia 2, eletrodo FC5.

Decomposição tempo-frequência



Coerência de fase





Figura 288 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 04, dia 2, eletrodo FC6.

Decomposição tempo-frequência



Coerência de fase





Figura 289 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 04, dia 2, eletrodo O1.

Decomposição tempo-frequência



Coerência de fase





Figura 290 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 04, dia 2, eletrodo O2.

Decomposição tempo-frequência



Coerência de fase





Figura 291 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 04, dia 2, eletrodo P7.

Decomposição tempo-frequência



Coerência de fase





Figura 292 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 04, dia 2, eletrodo P8.

Decomposição tempo-frequência



Coerência de fase





Figura 293 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 04, dia 2, eletrodo T7.

Decomposição tempo-frequência



Coerência de fase





Figura 294 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 04, dia 2, eletrodo T8.

Decomposição tempo-frequência



Coerência de fase




Figura 295 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 04, dia 3, eletrodo AF3.




Figura 296 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 04, dia 3, eletrodo AF4.

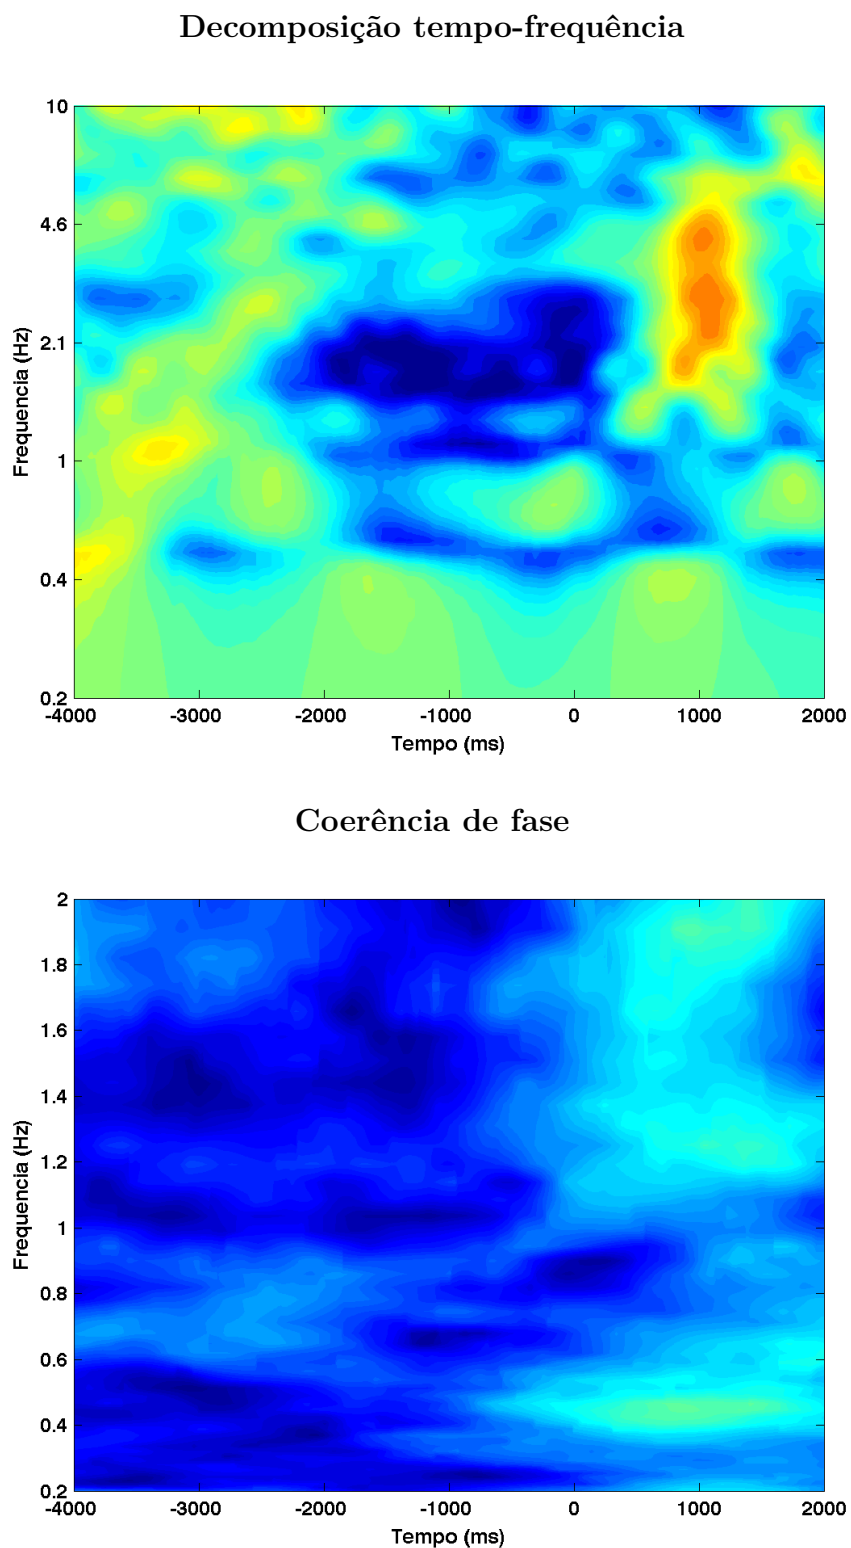


Figura 297 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 04, dia 3, eletrodo F3.

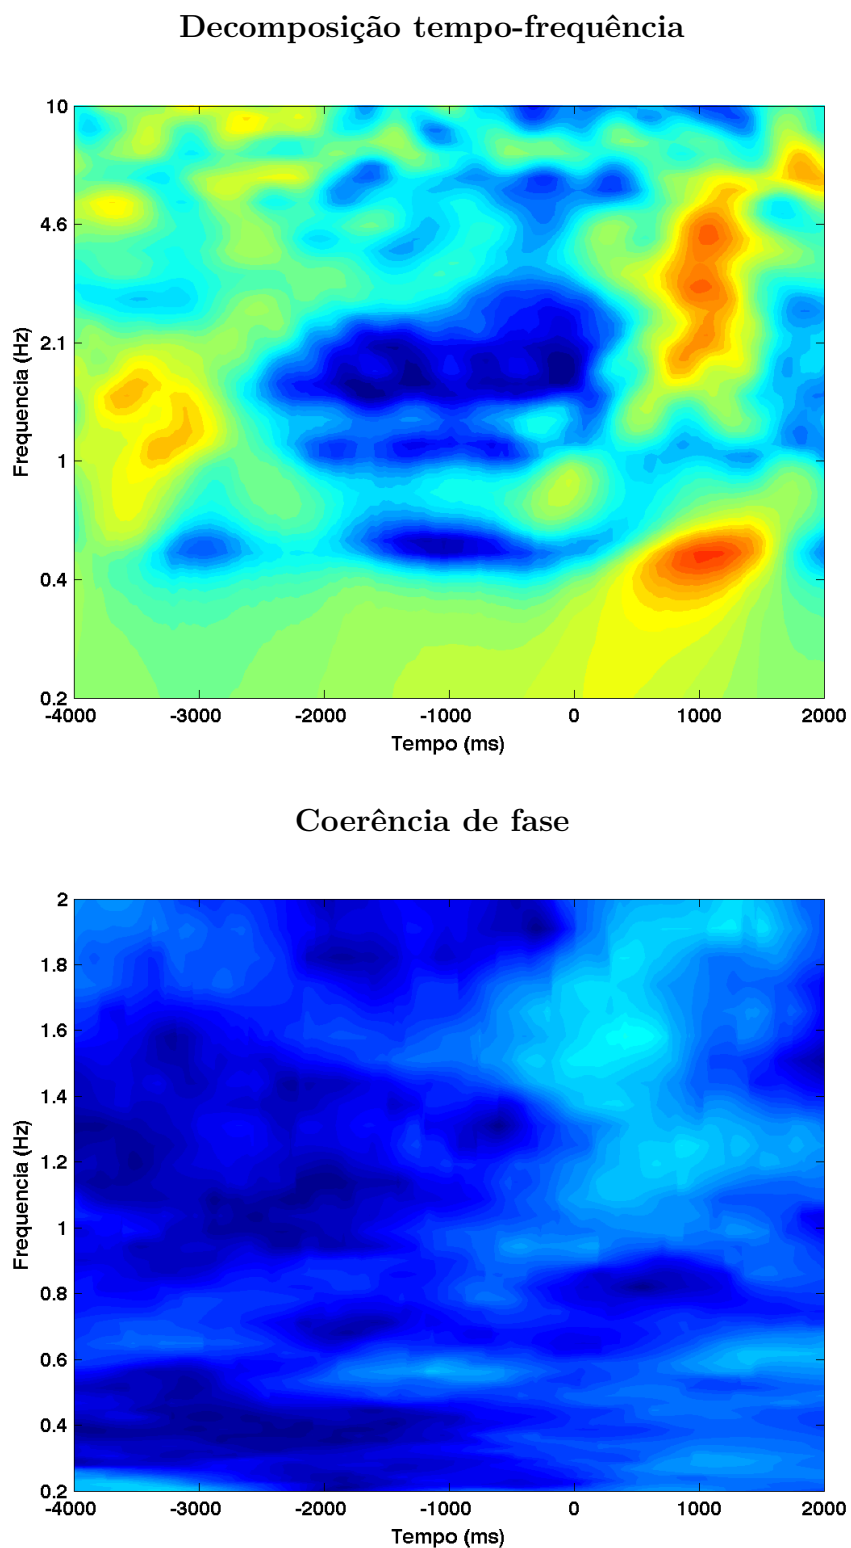


Figura 298 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 04, dia 3, eletrodo F4.

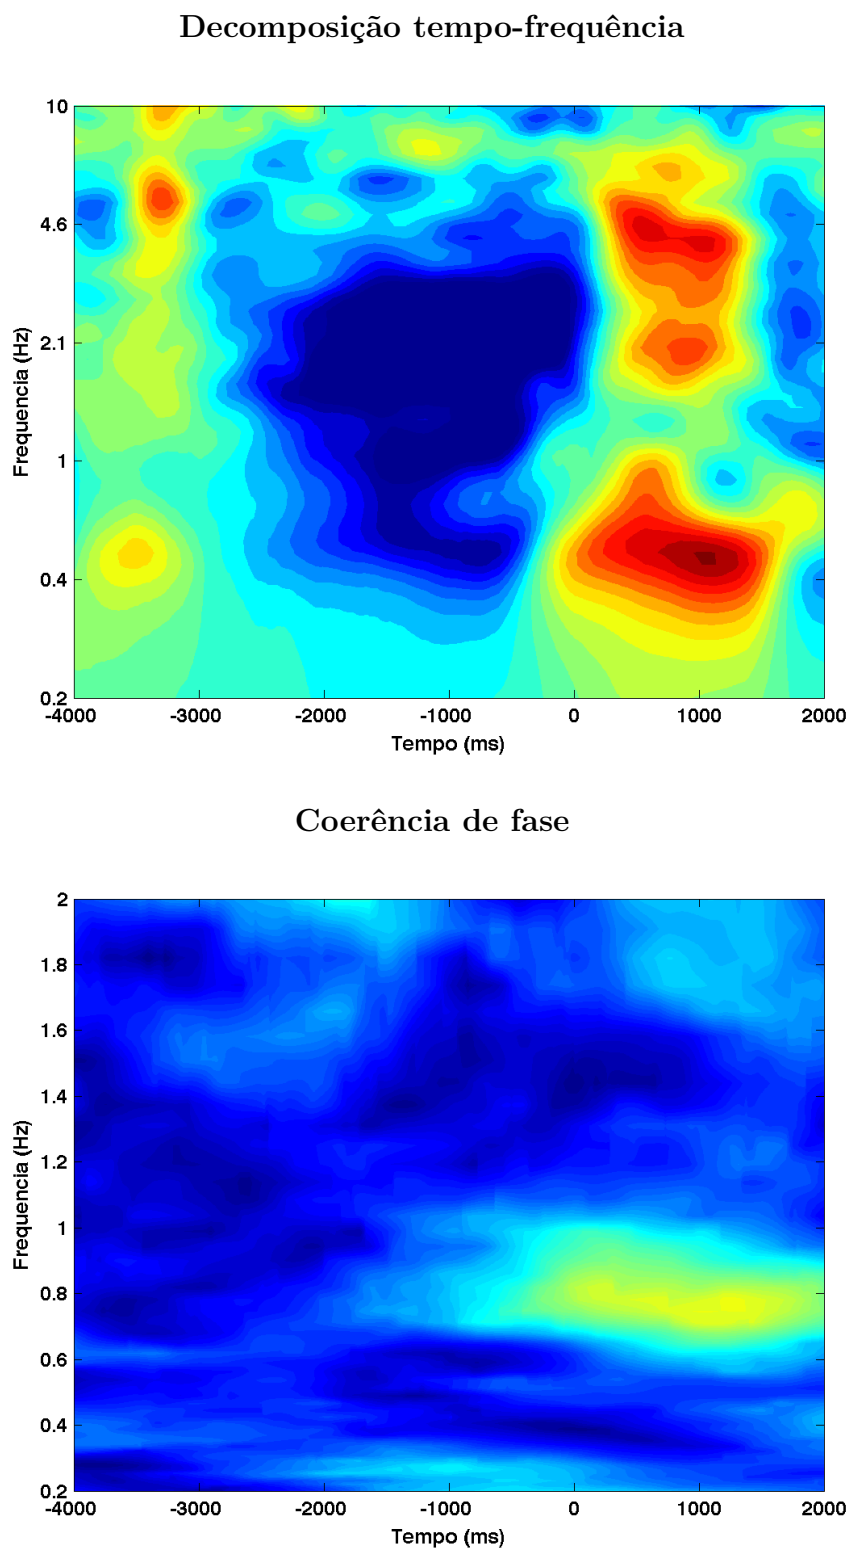


Figura 299 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 04, dia 3, eletrodo F7.

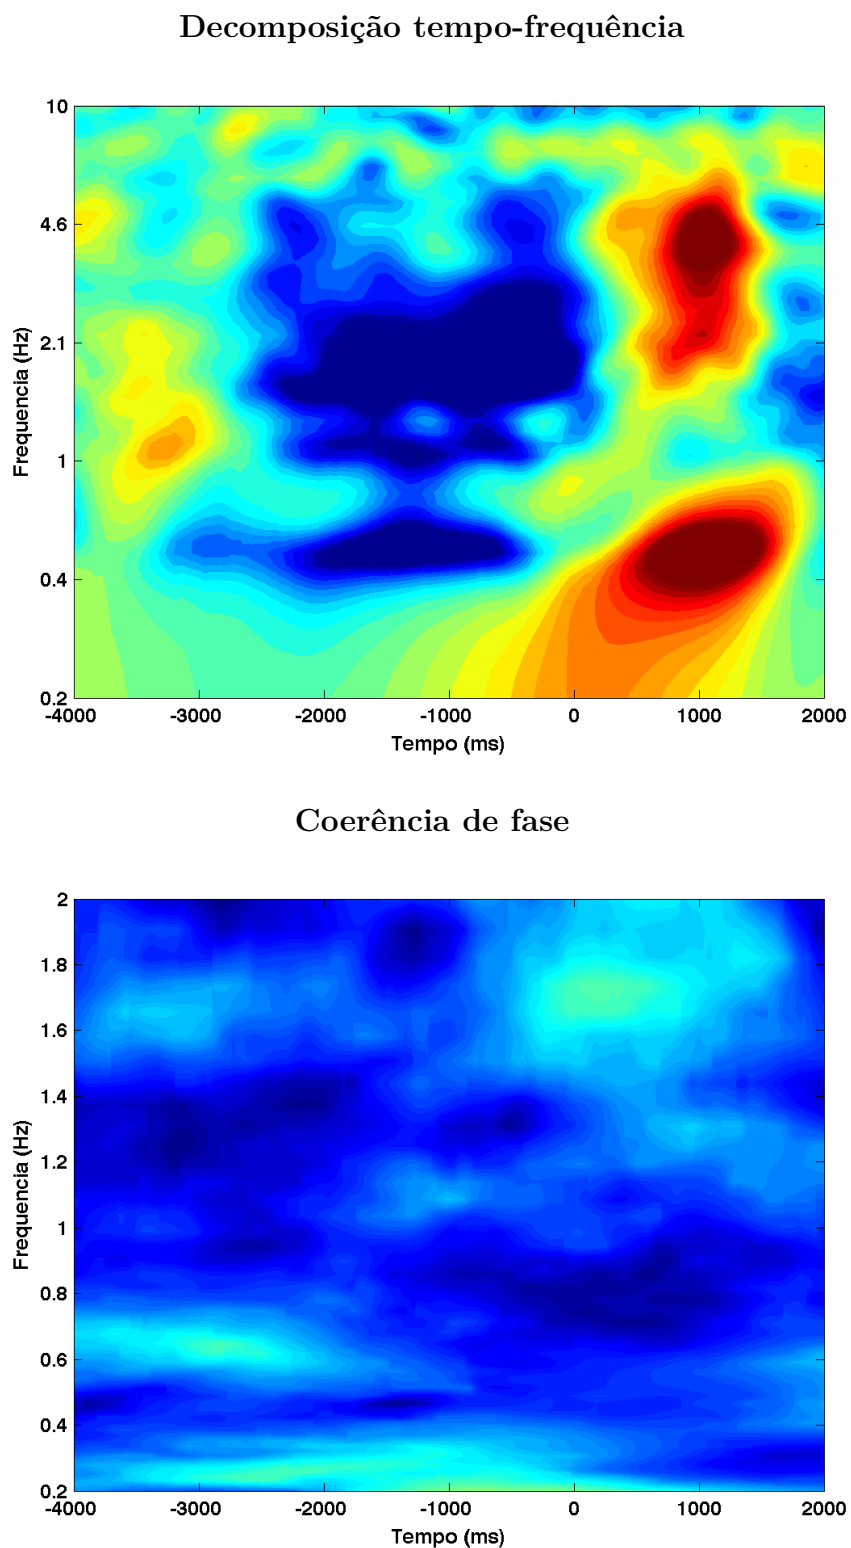


Figura 300 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 04, dia 3, eletrodo F8.

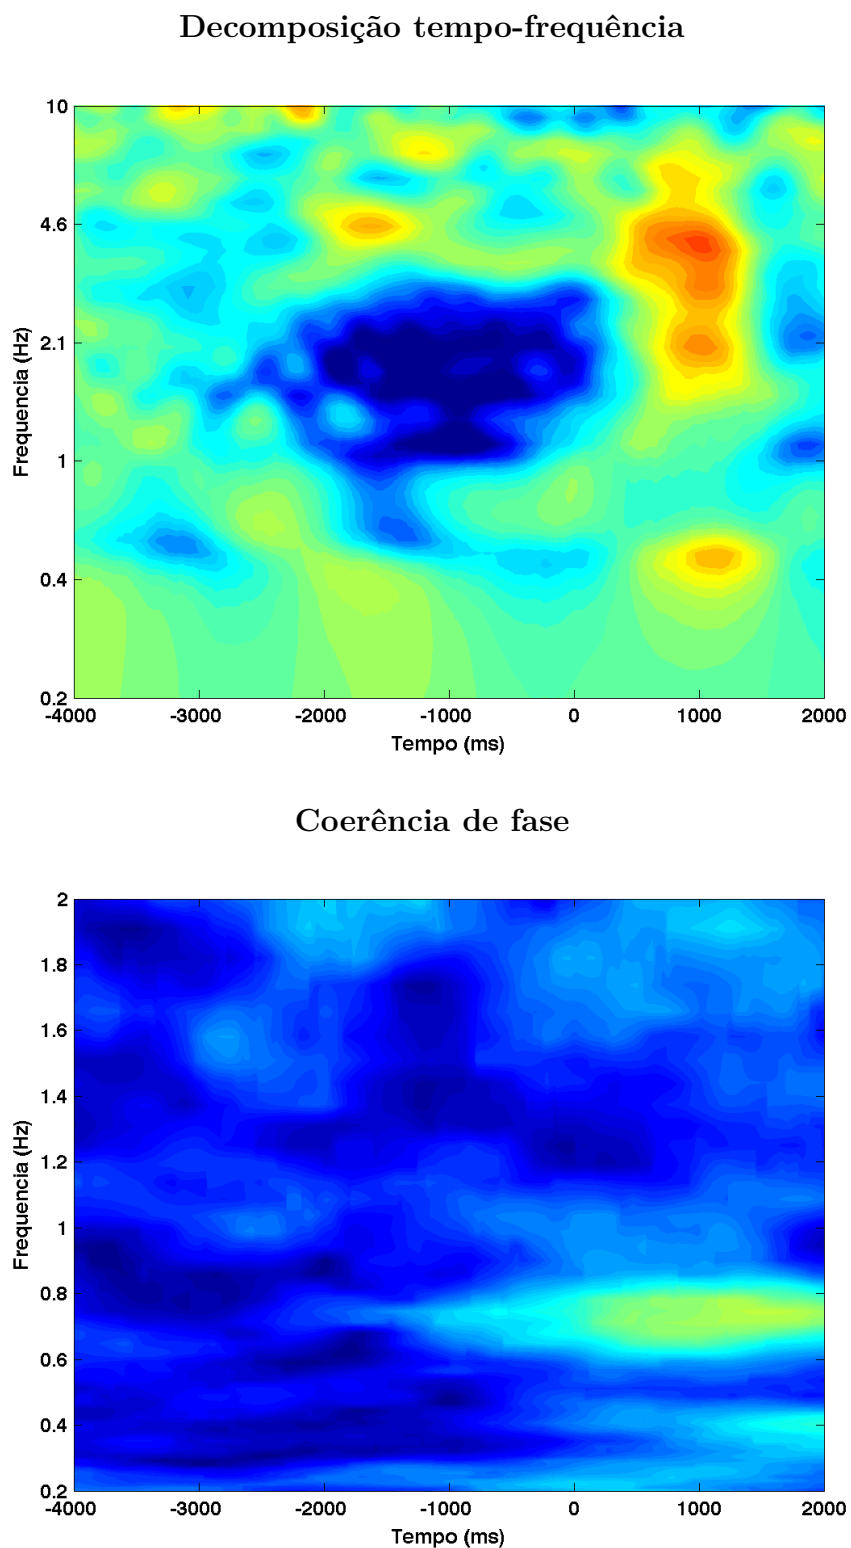



Figura 301 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 04, dia 3, eletrodo FC5.

Decomposição tempo-frequência



Coerência de fase




Figura 302 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 04, dia 3, eletrodo FC6.

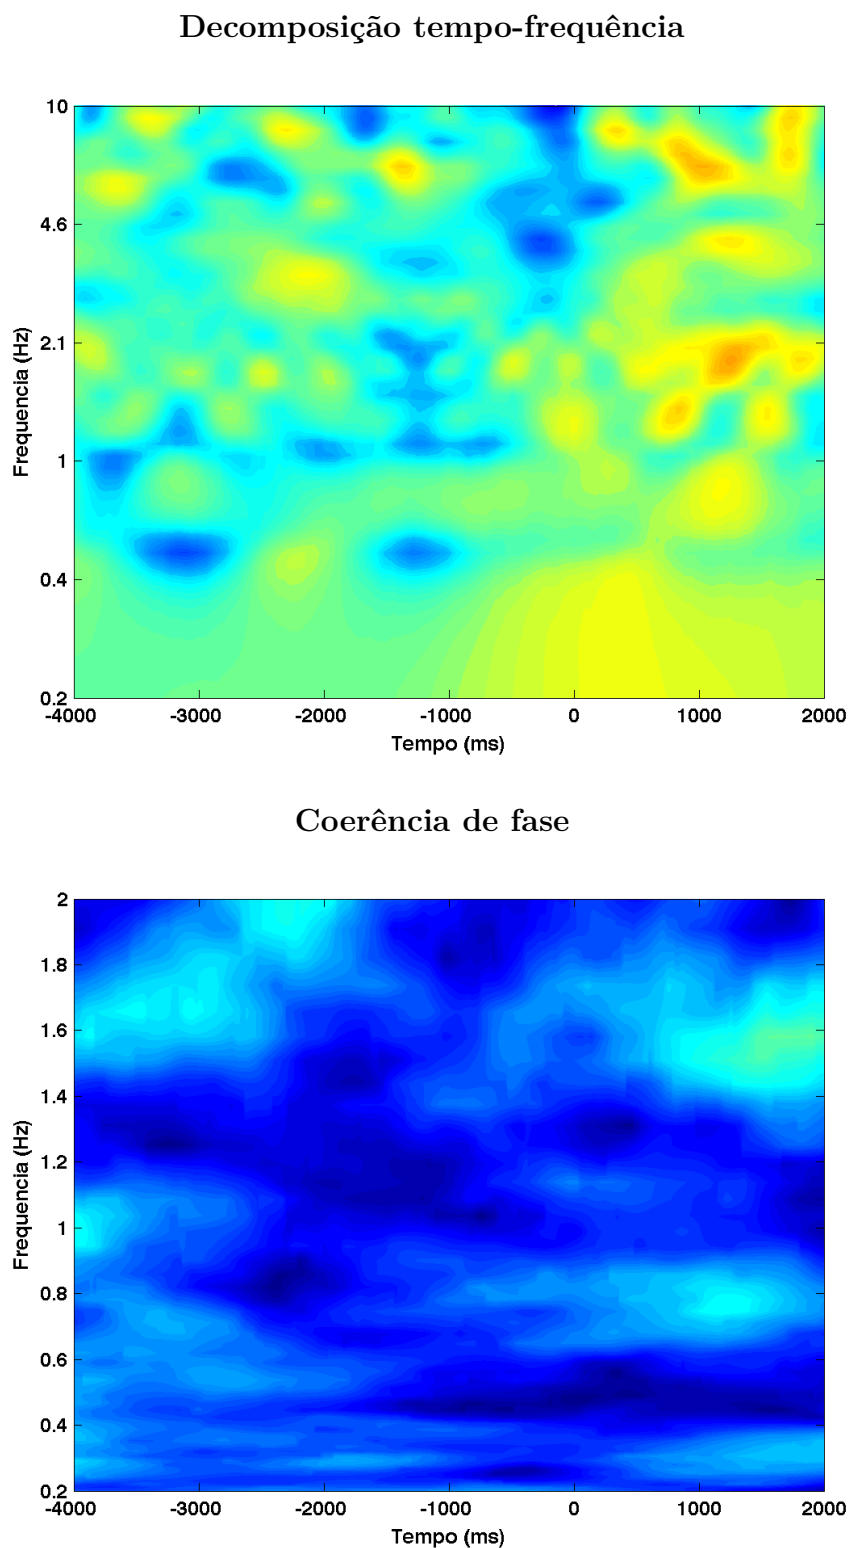


Figura 303 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 04, dia 3, eletrodo O1.

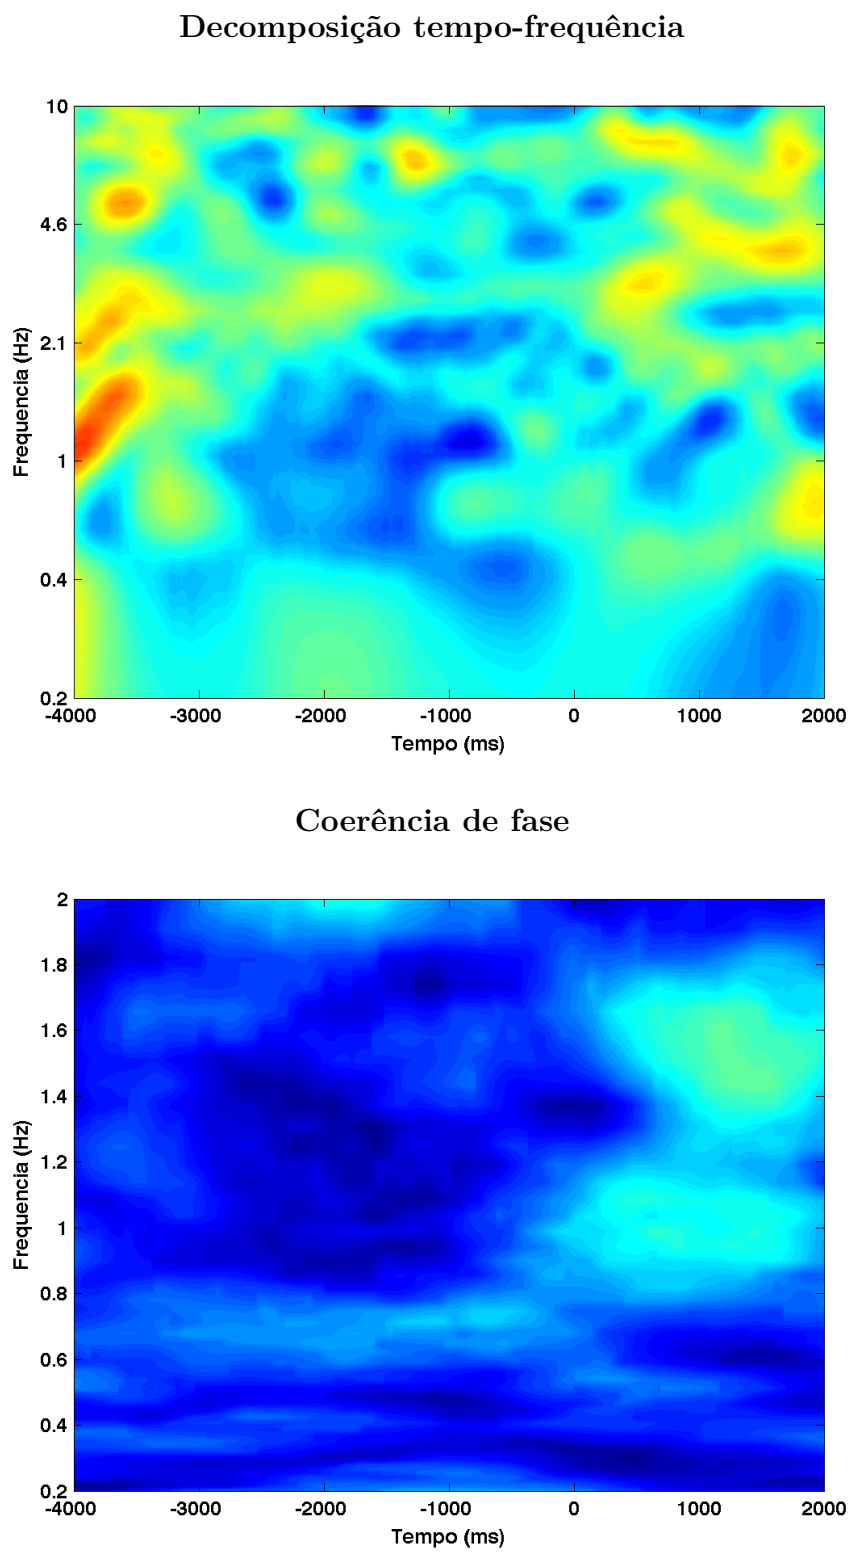


Figura 304 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 04, dia 3, eletrodo O2.

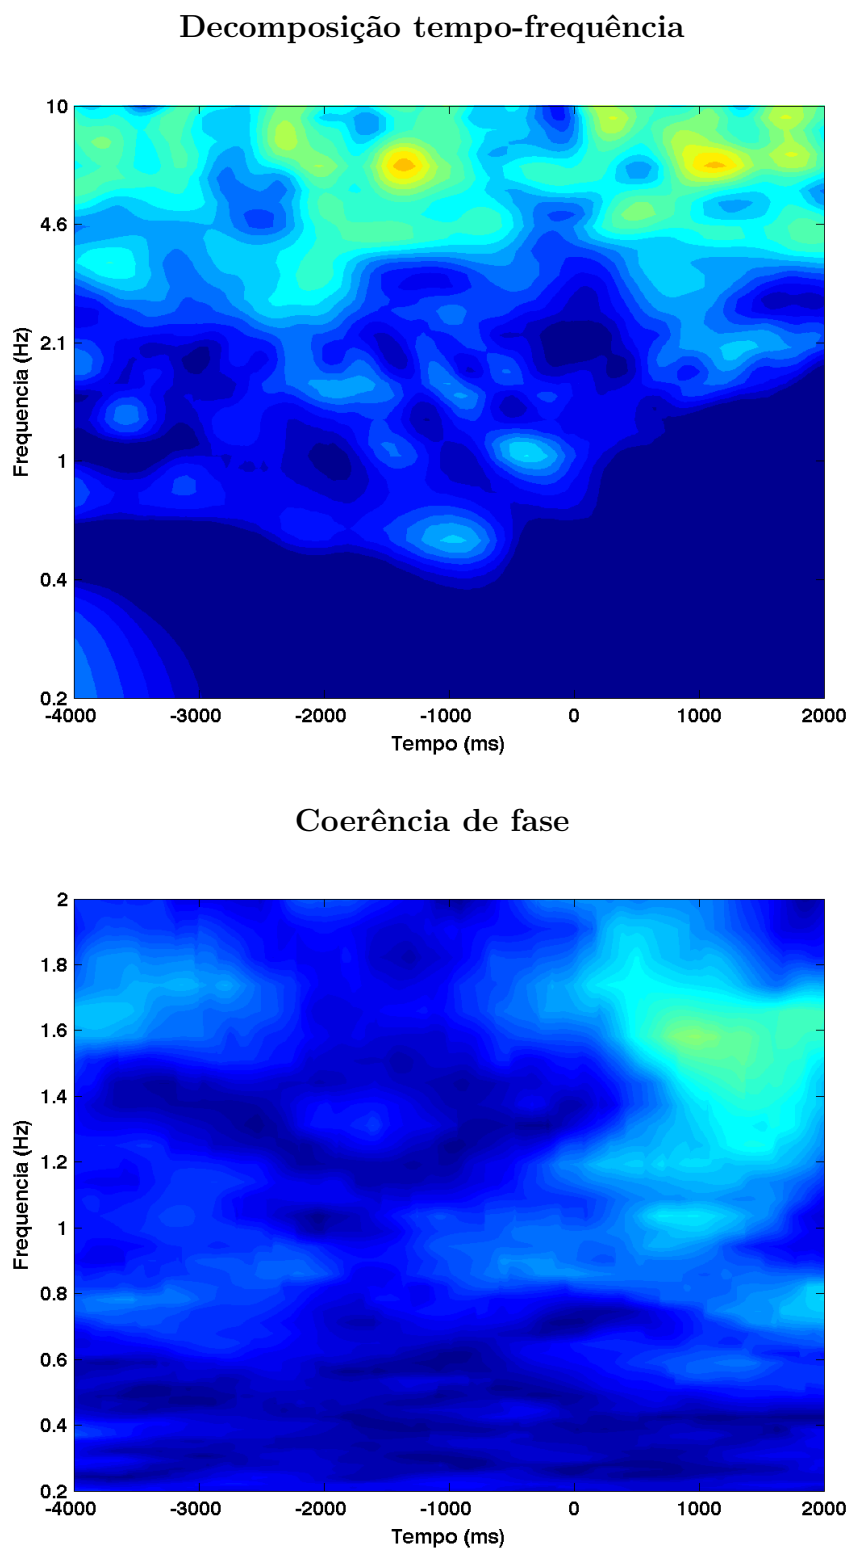


Figura 305 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 04, dia 3, eletrodo P7.

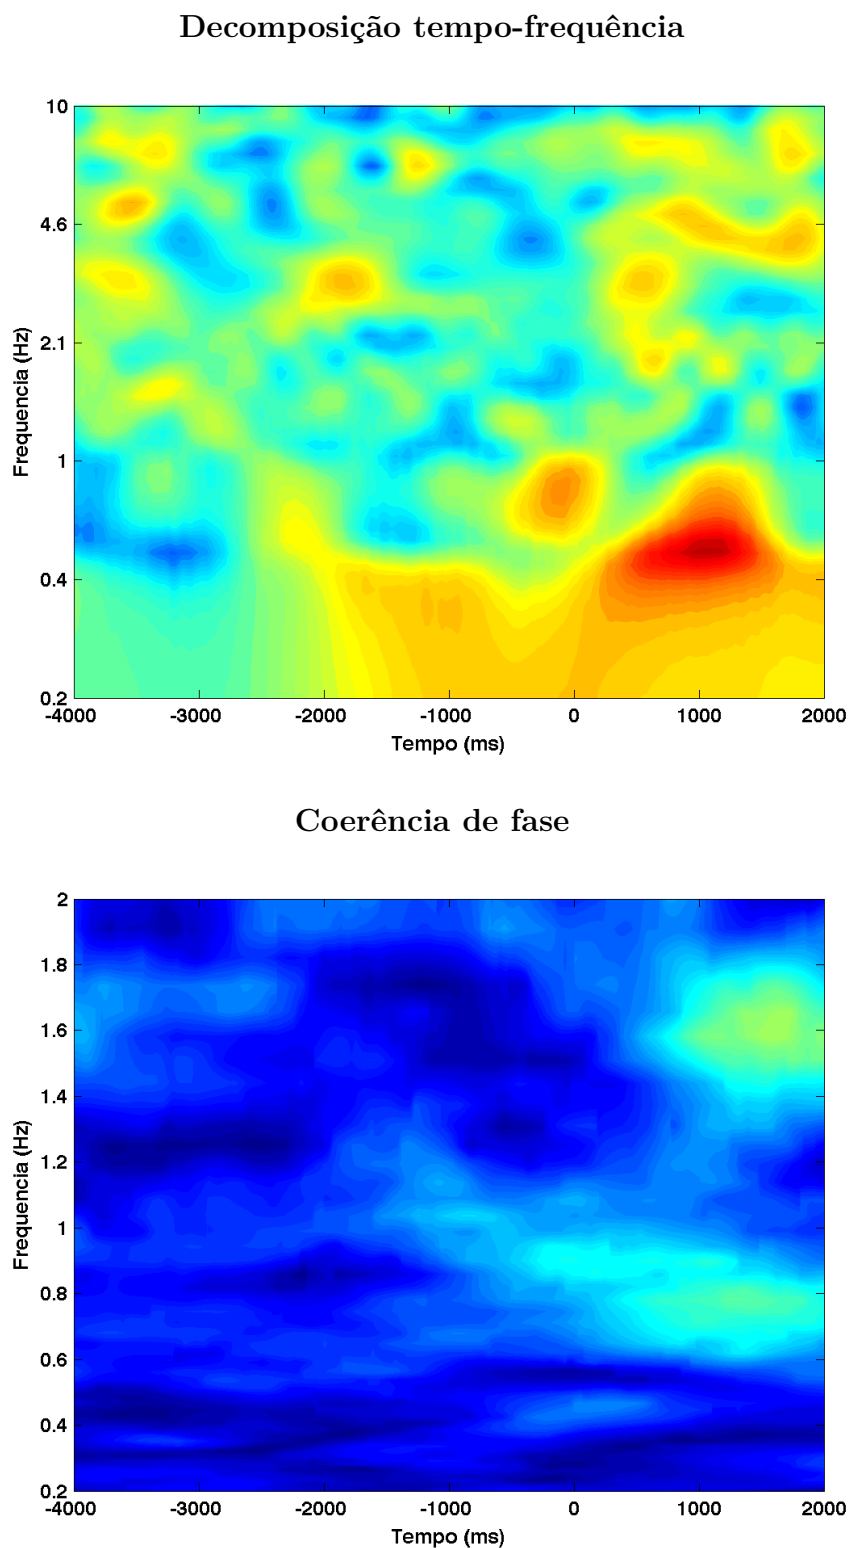


Figura 306 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 04, dia 3, eletrodo P8.

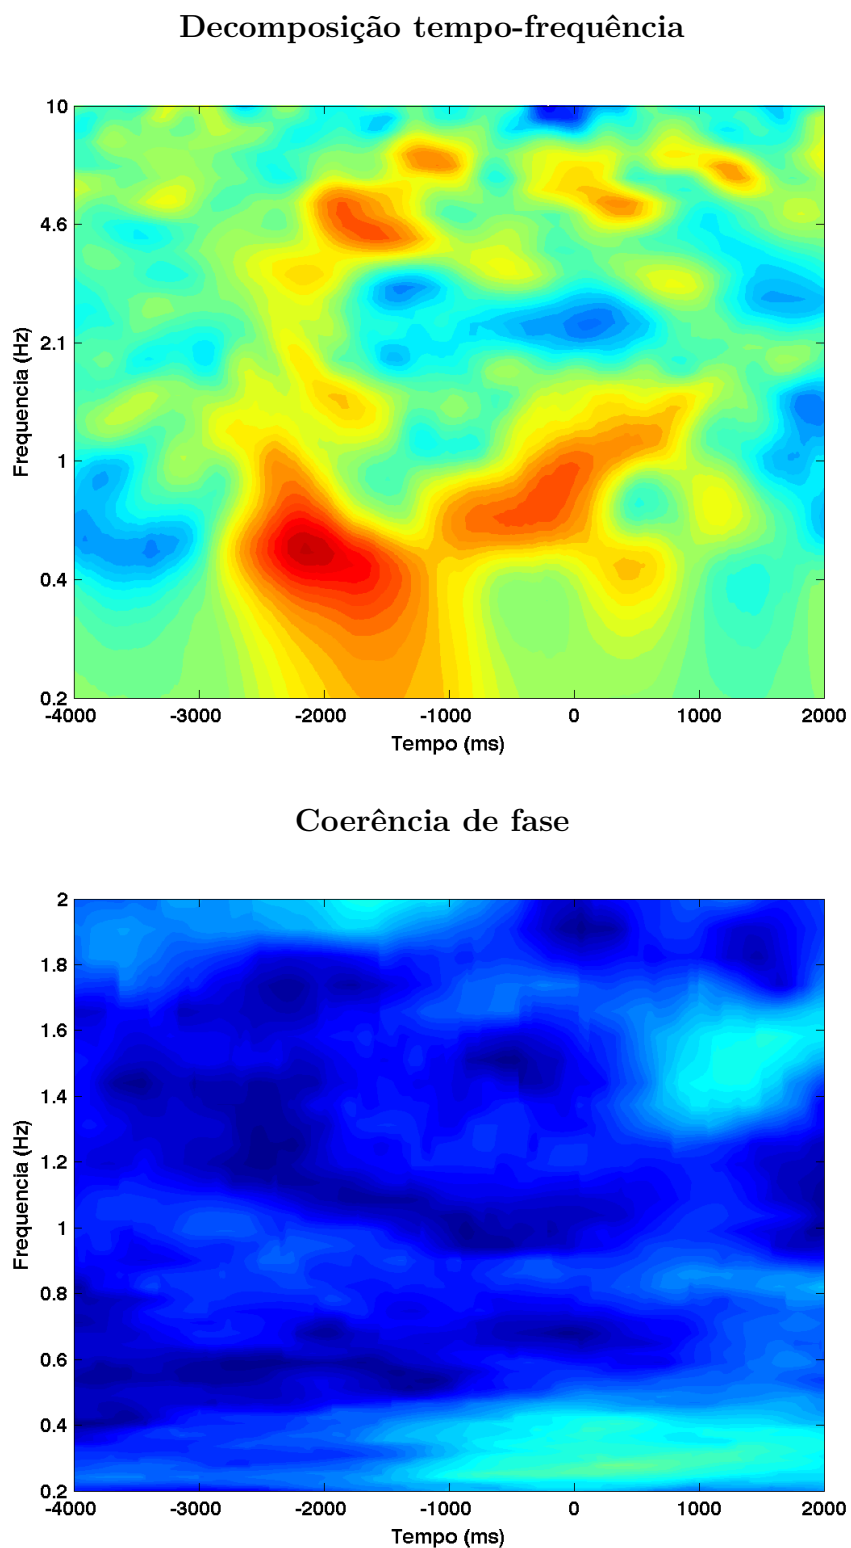


Figura 307 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 04, dia 3, eletrodo T7.

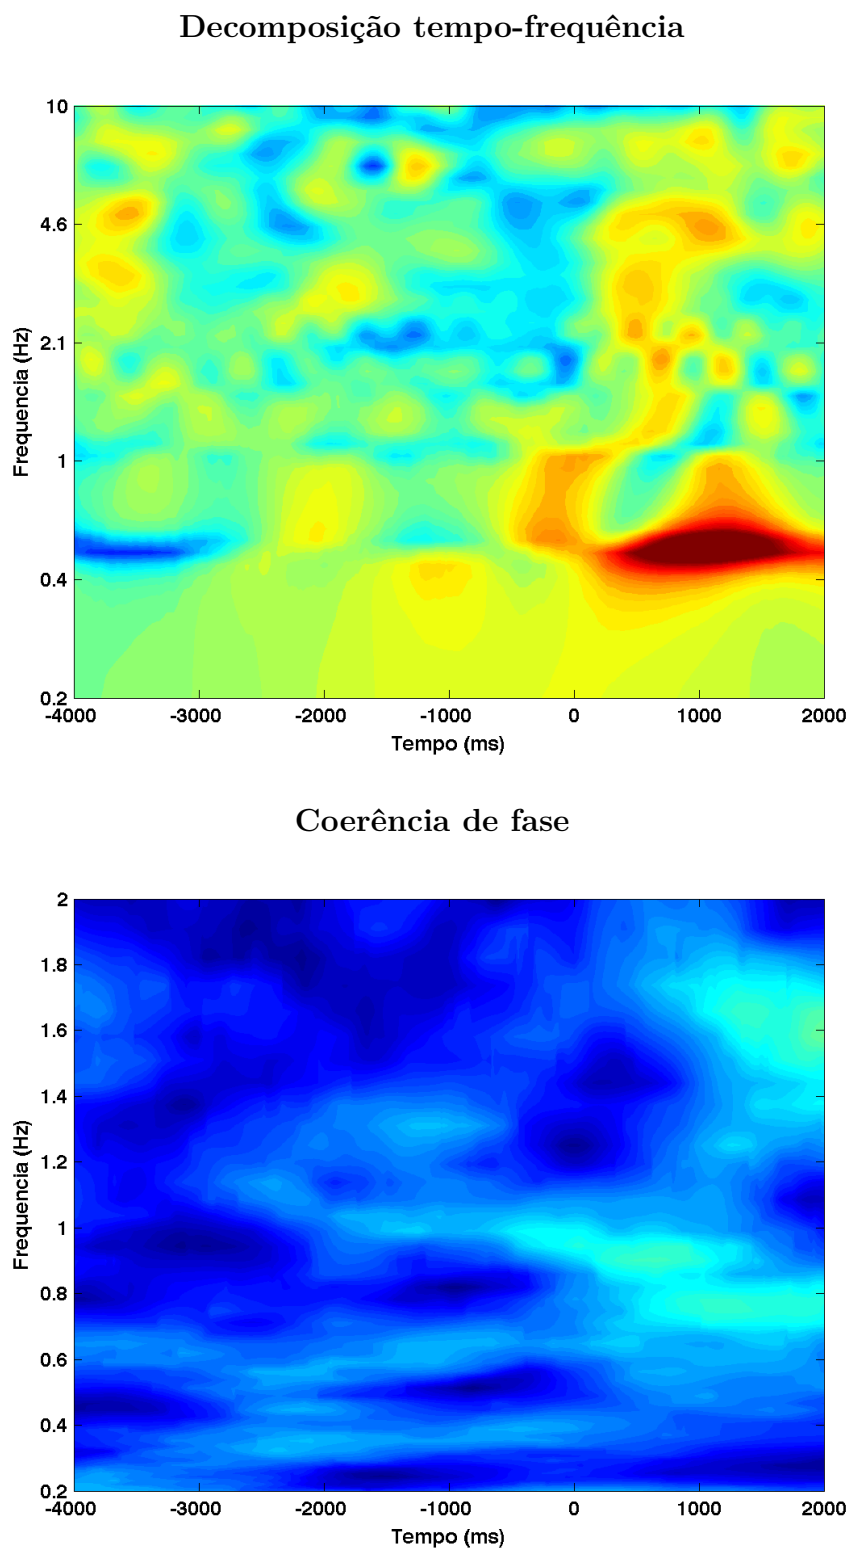


Figura 308 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 04, dia 3, eletrodo T8.

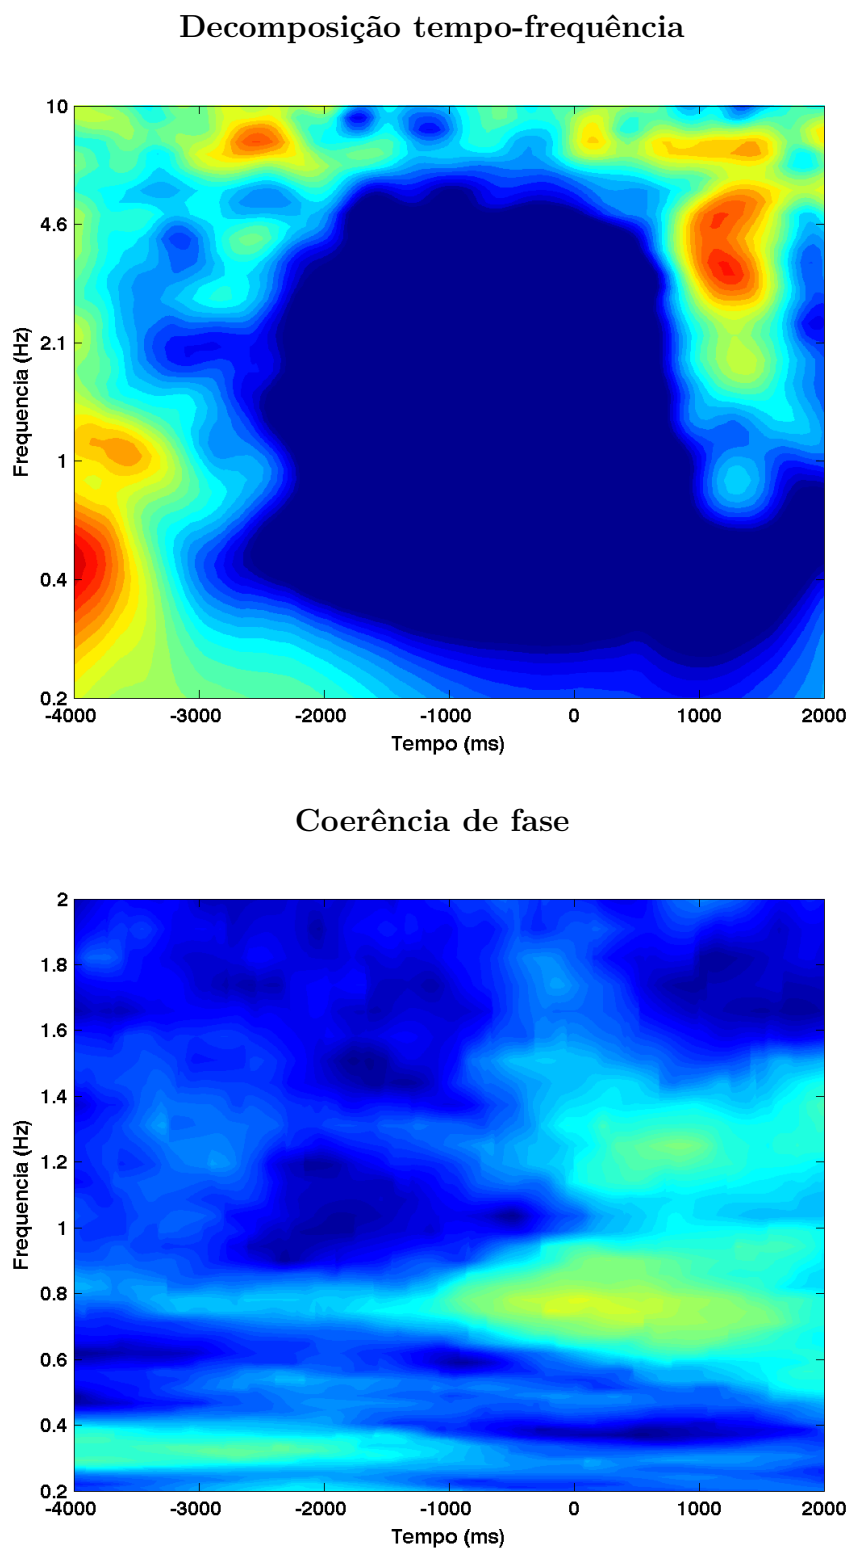


Figura 309 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 04, dia 4, eletrodo AF3.

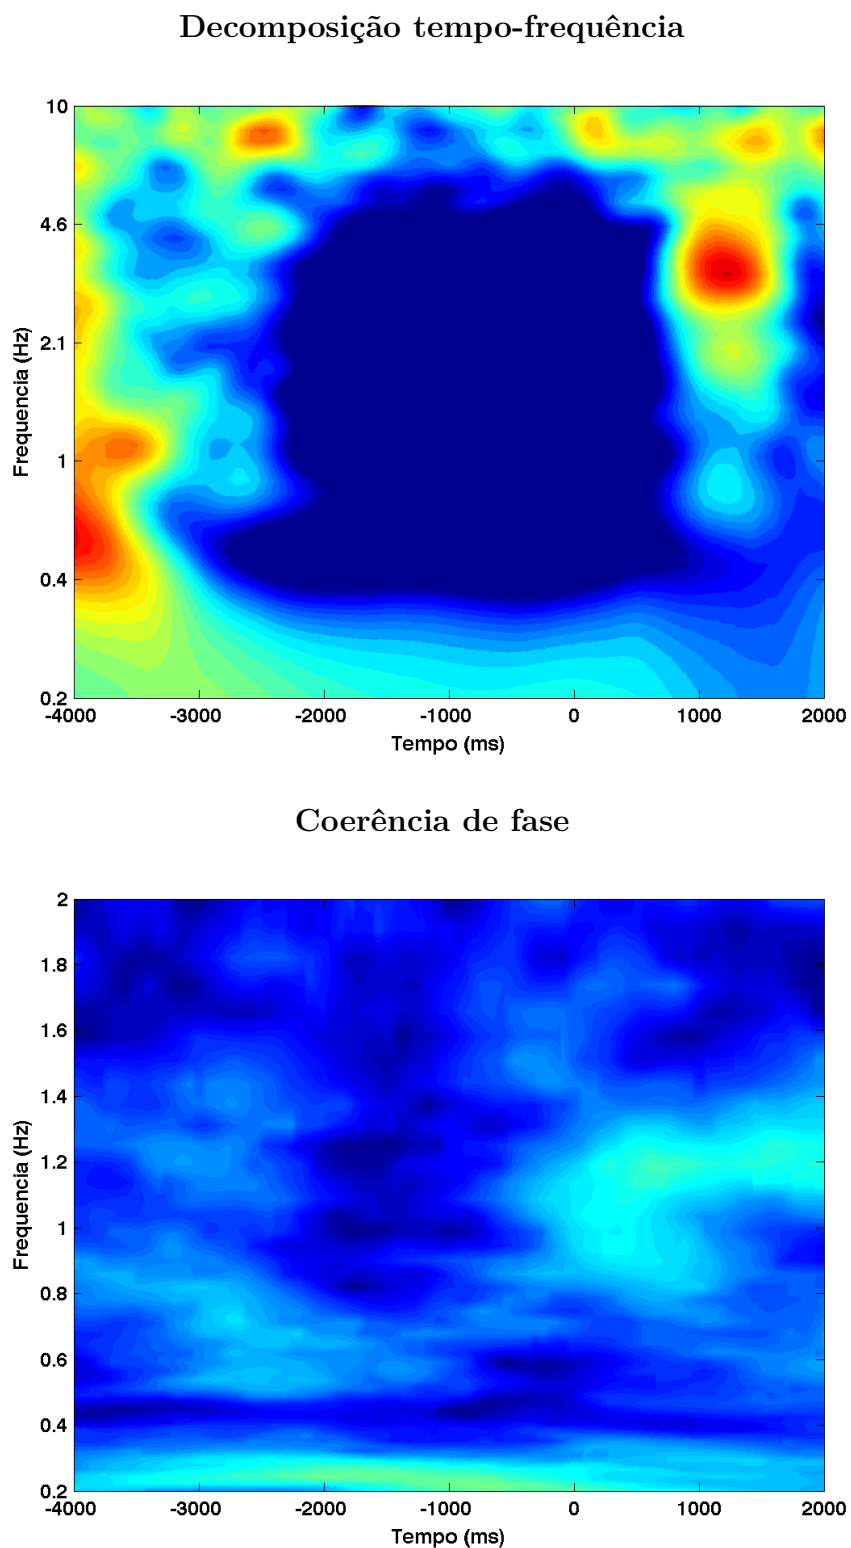


Figura 310 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 04, dia 4, eletrodo AF4.




Figura 311 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 04, dia 4, eletrodo F3.

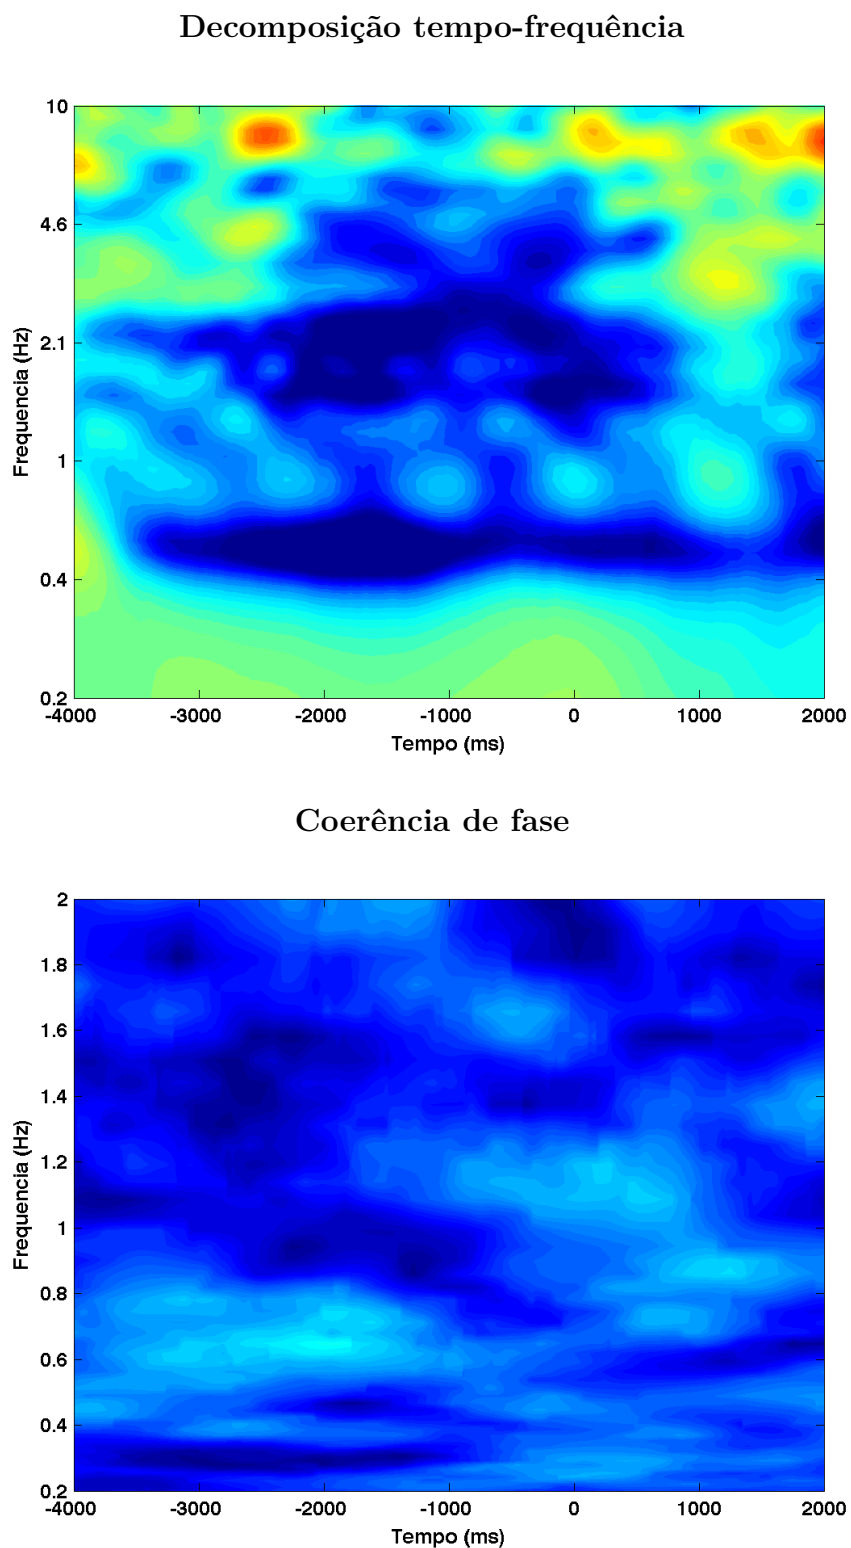


Figura 312 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 04, dia 4, eletrodo F4.




Figura 313 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 04, dia 4, eletrodo F7.

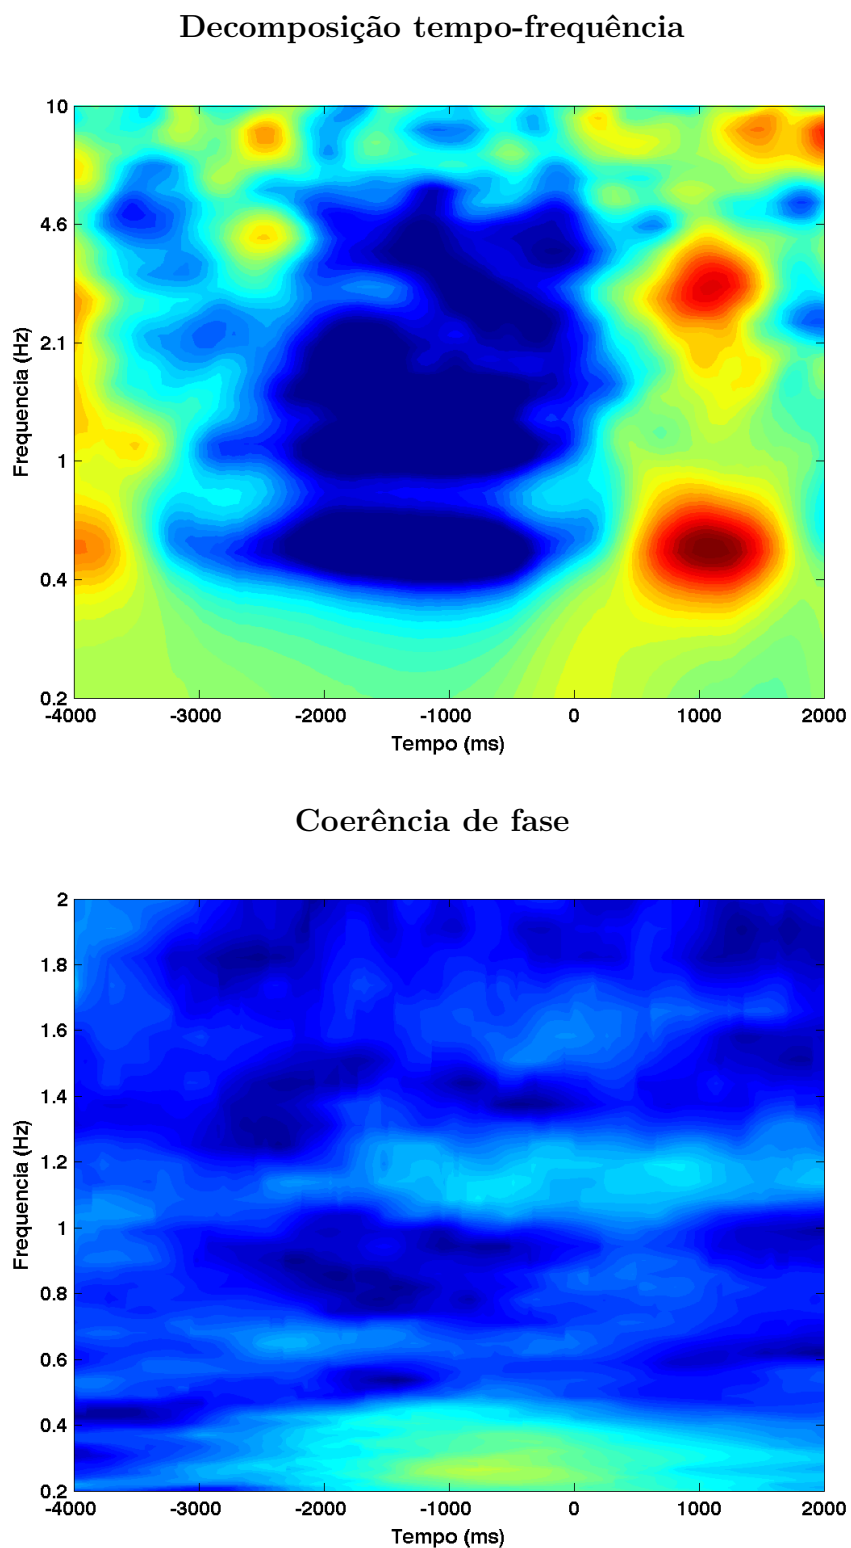


Figura 314 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 04, dia 4, eletrodo F8.




Figura 315 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 04, dia 4, eletrodo FC5.




Figura 316 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 04, dia 4, eletrodo FC6.




Figura 317 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 04, dia 4, eletrodo O1.




Figura 318 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 04, dia 4, eletrodo O2.

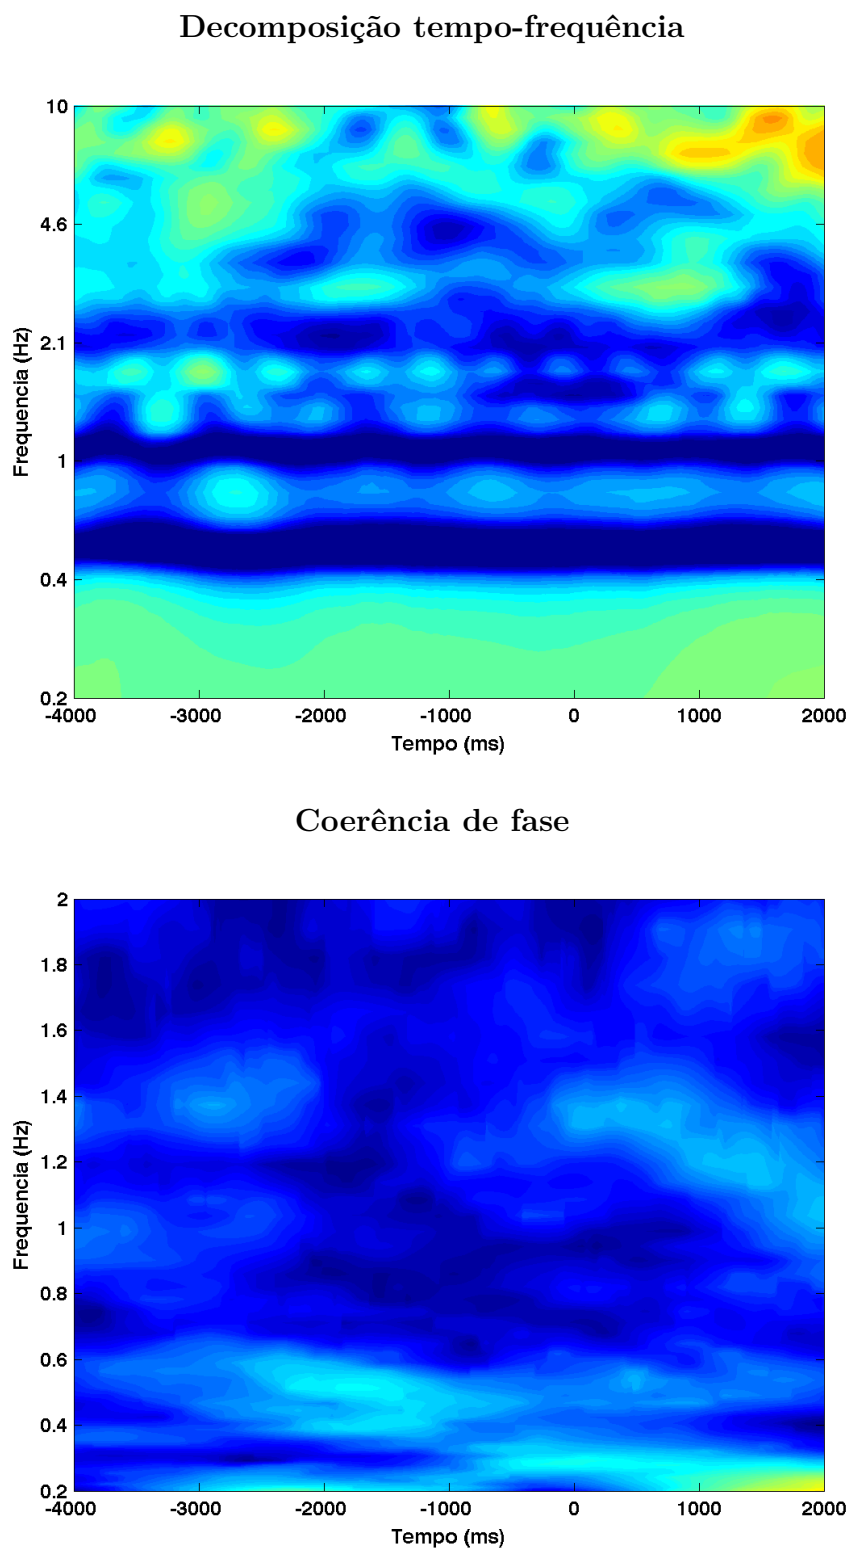



Figura 319 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 04, dia 4, eletrodo P7.

Decomposição tempo-frequência



Coerência de fase




Figura 320 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 04, dia 4, eletrodo P8.

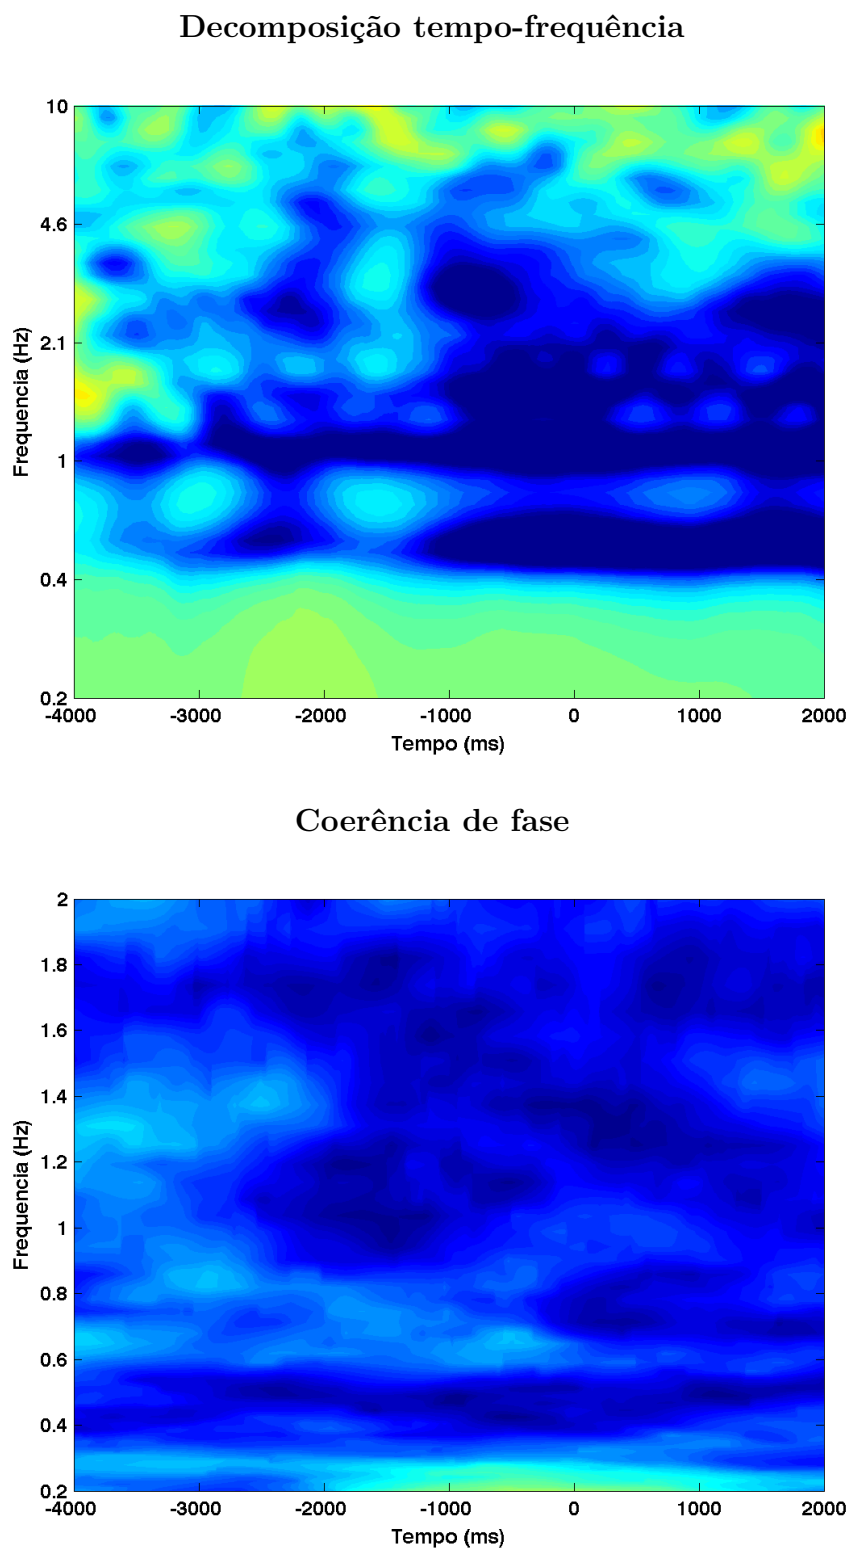


Figura 321 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 04, dia 4, eletrodo T7.




Figura 322 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 04, dia 4, eletrodo T8.

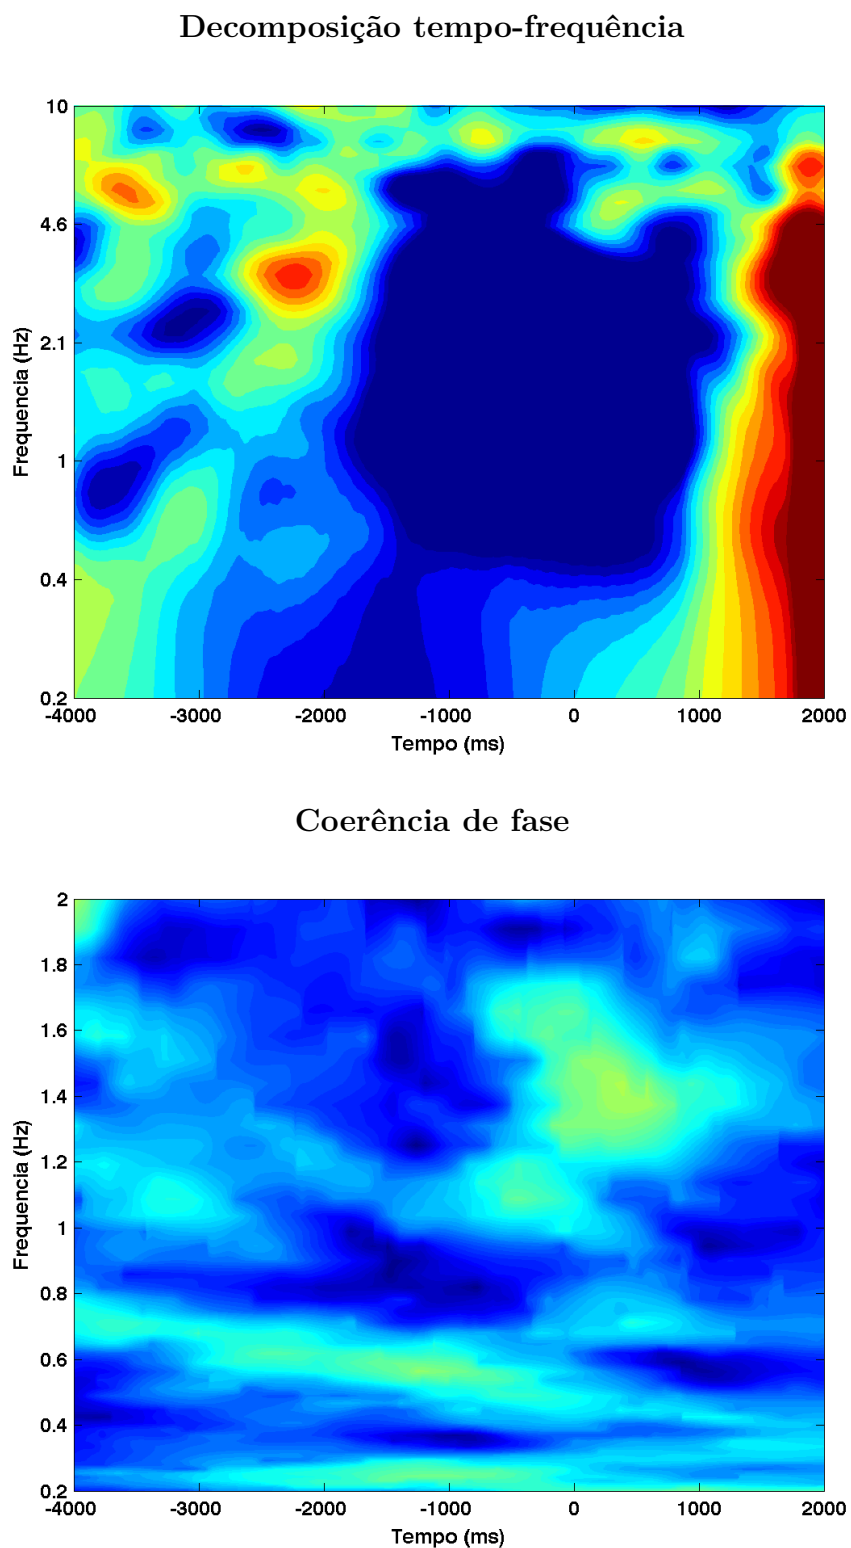


Figura 323 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 05, dia 1, eletrodo AF3.

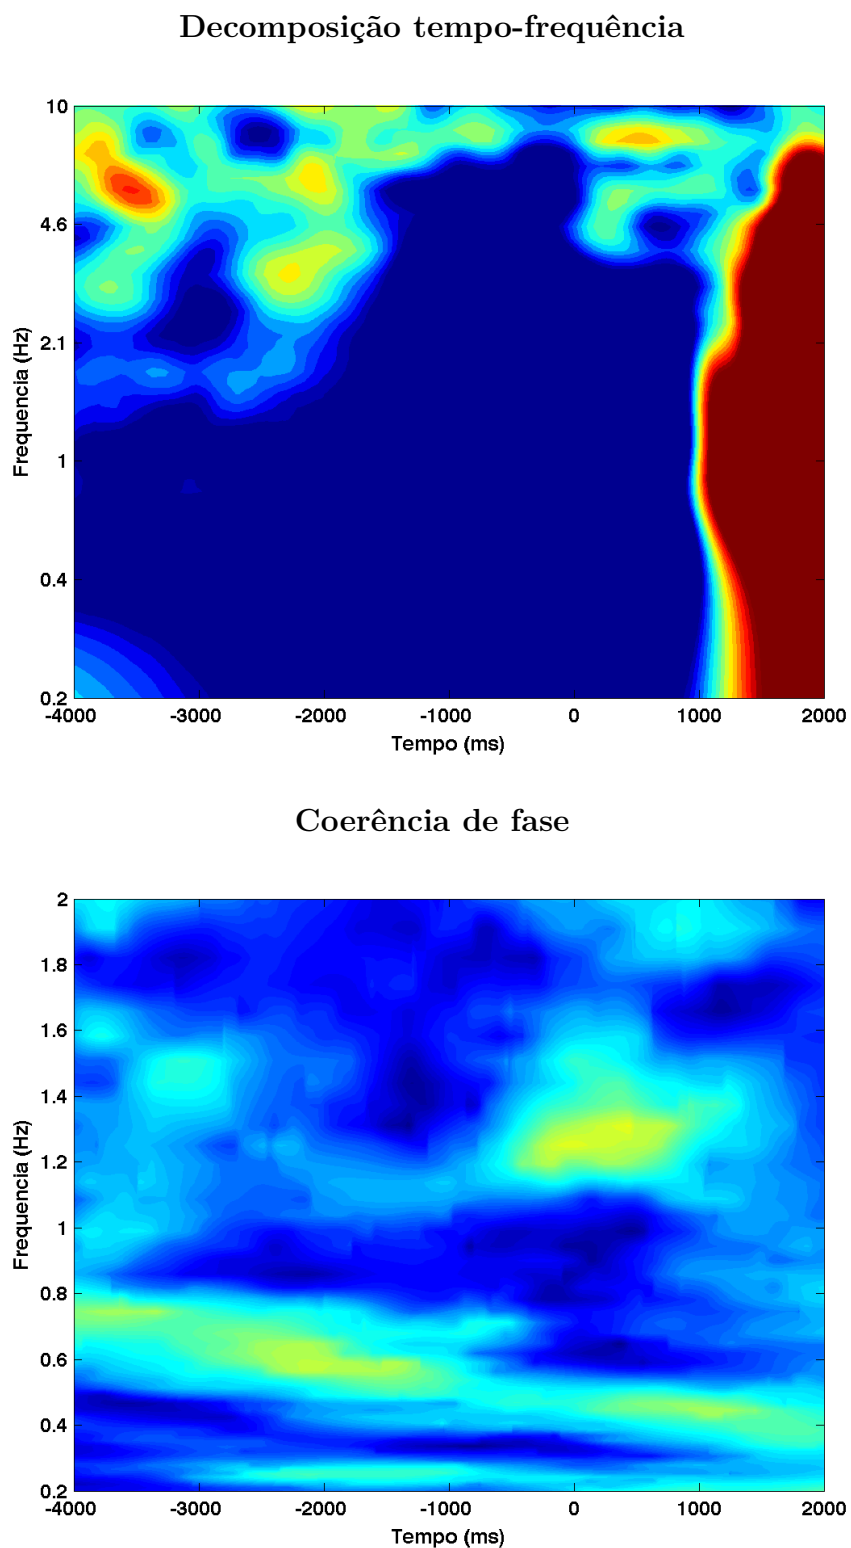


Figura 324 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 05, dia 1, eletrodo AF4.

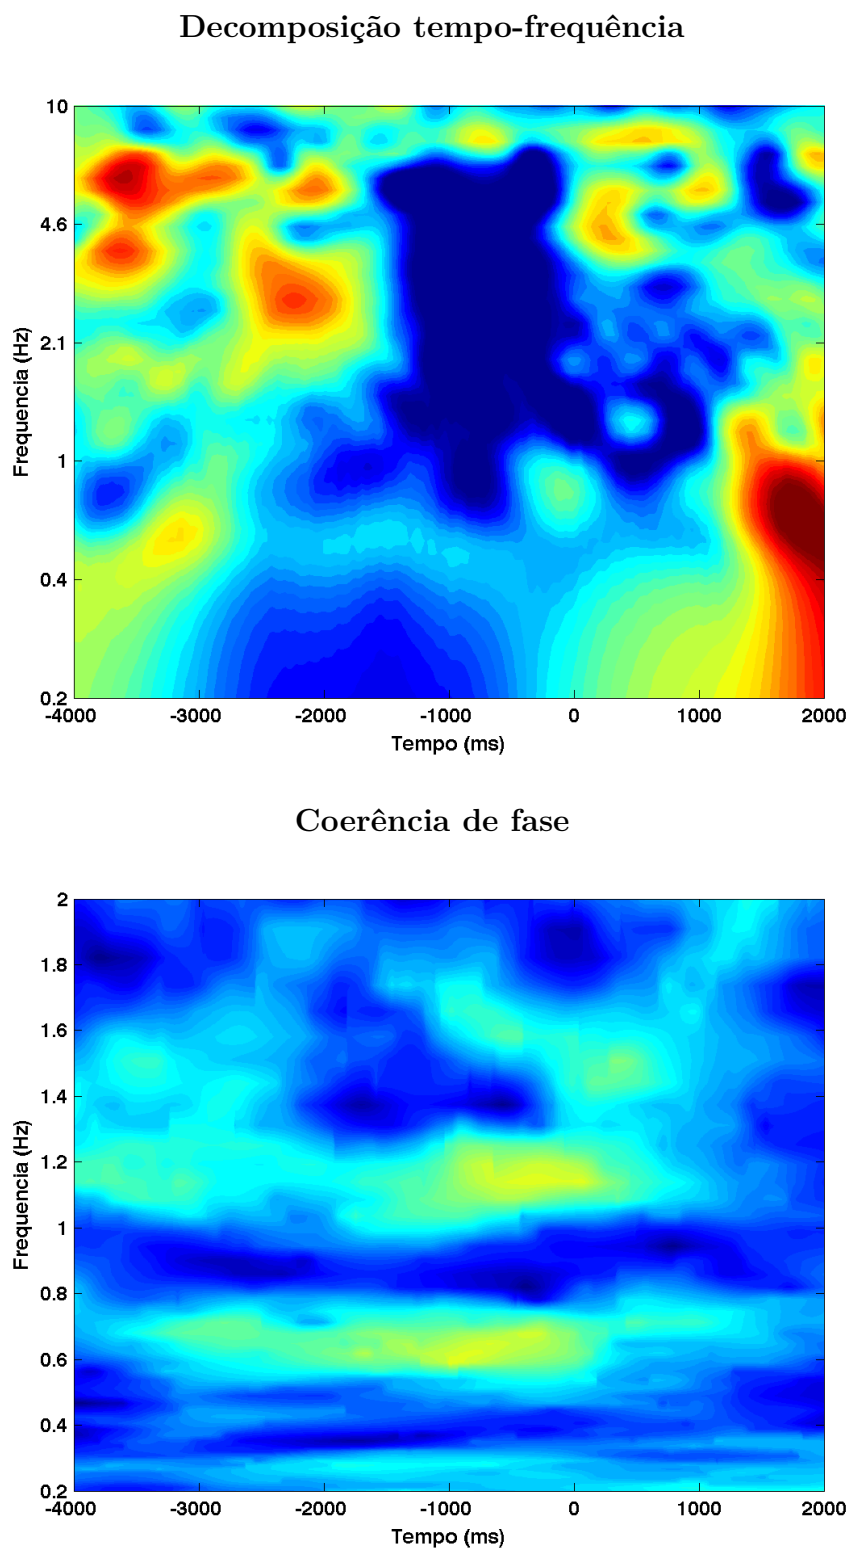


Figura 325 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 05, dia 1, eletrodo F3.

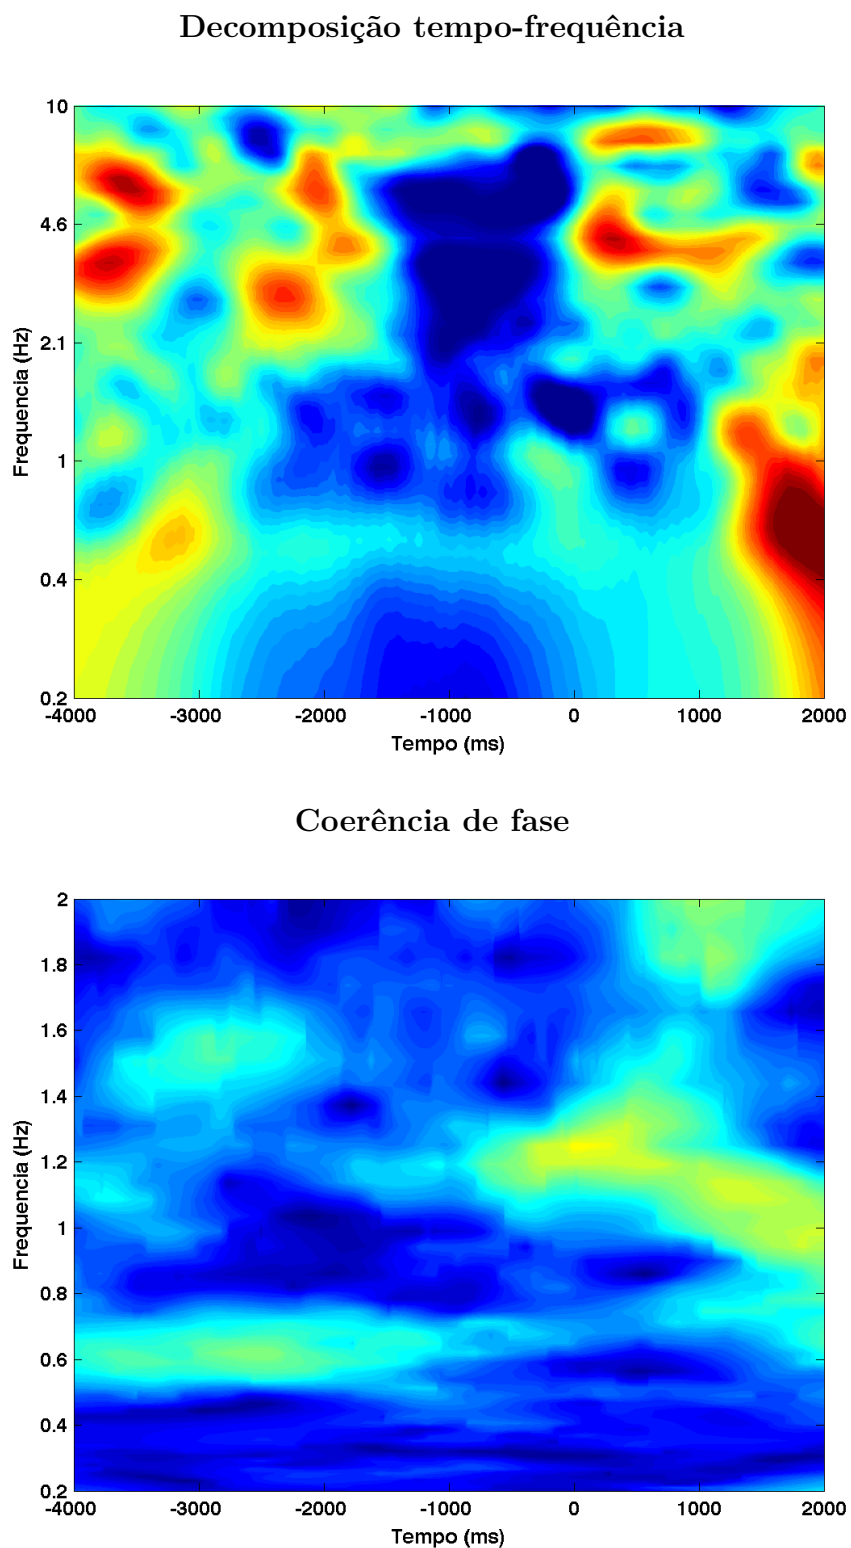


Figura 326 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 05, dia 1, eletrodo F4.

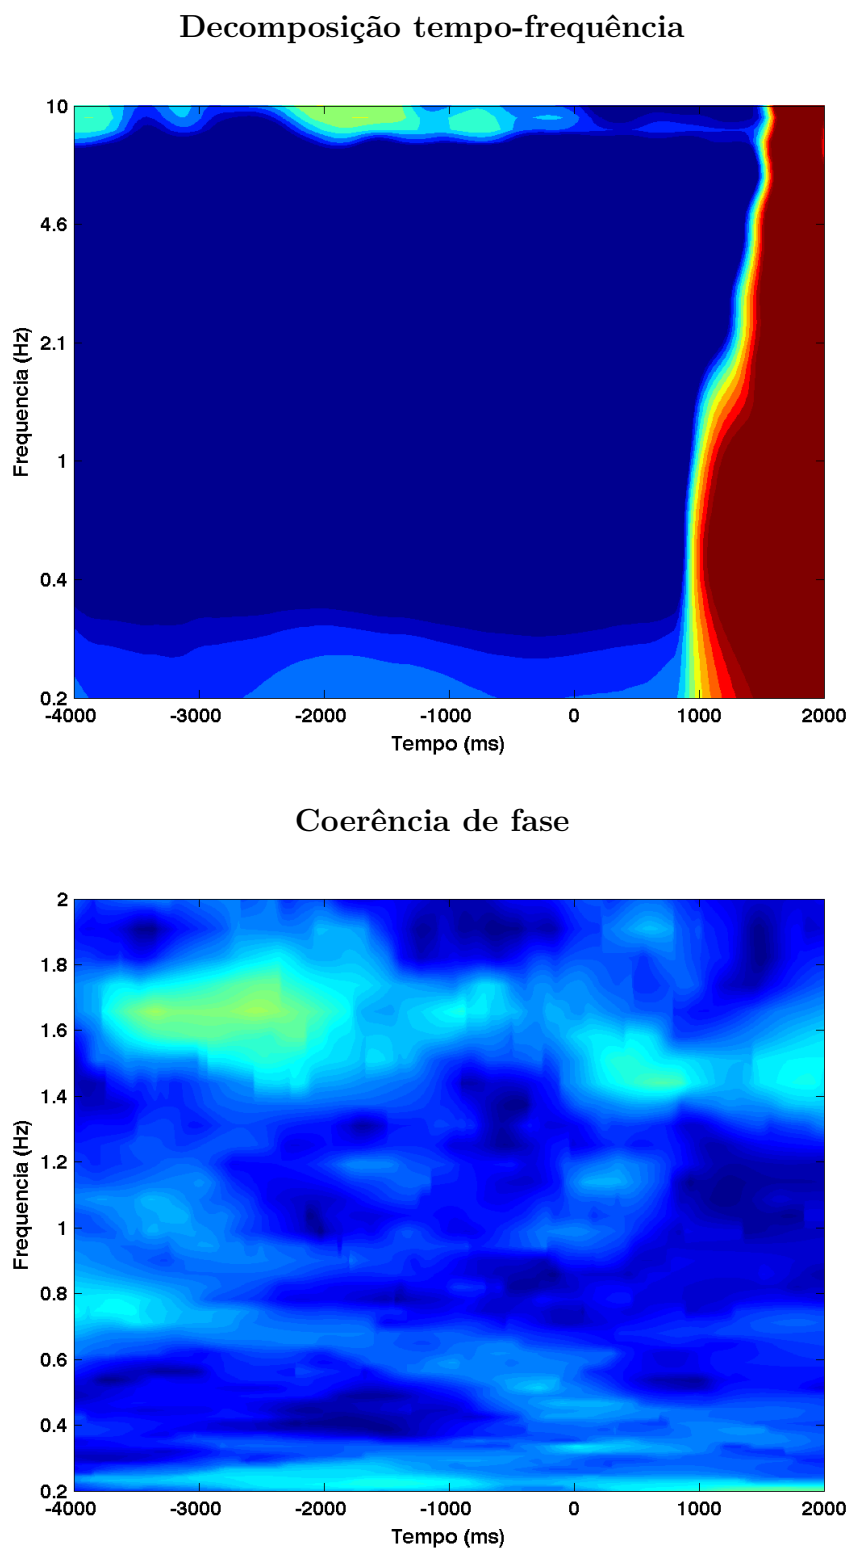



Figura 327 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 05, dia 1, eletrodo F7.

Decomposição tempo-frequência



Coerência de fase




Figura 328 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 05, dia 1, eletrodo F8.

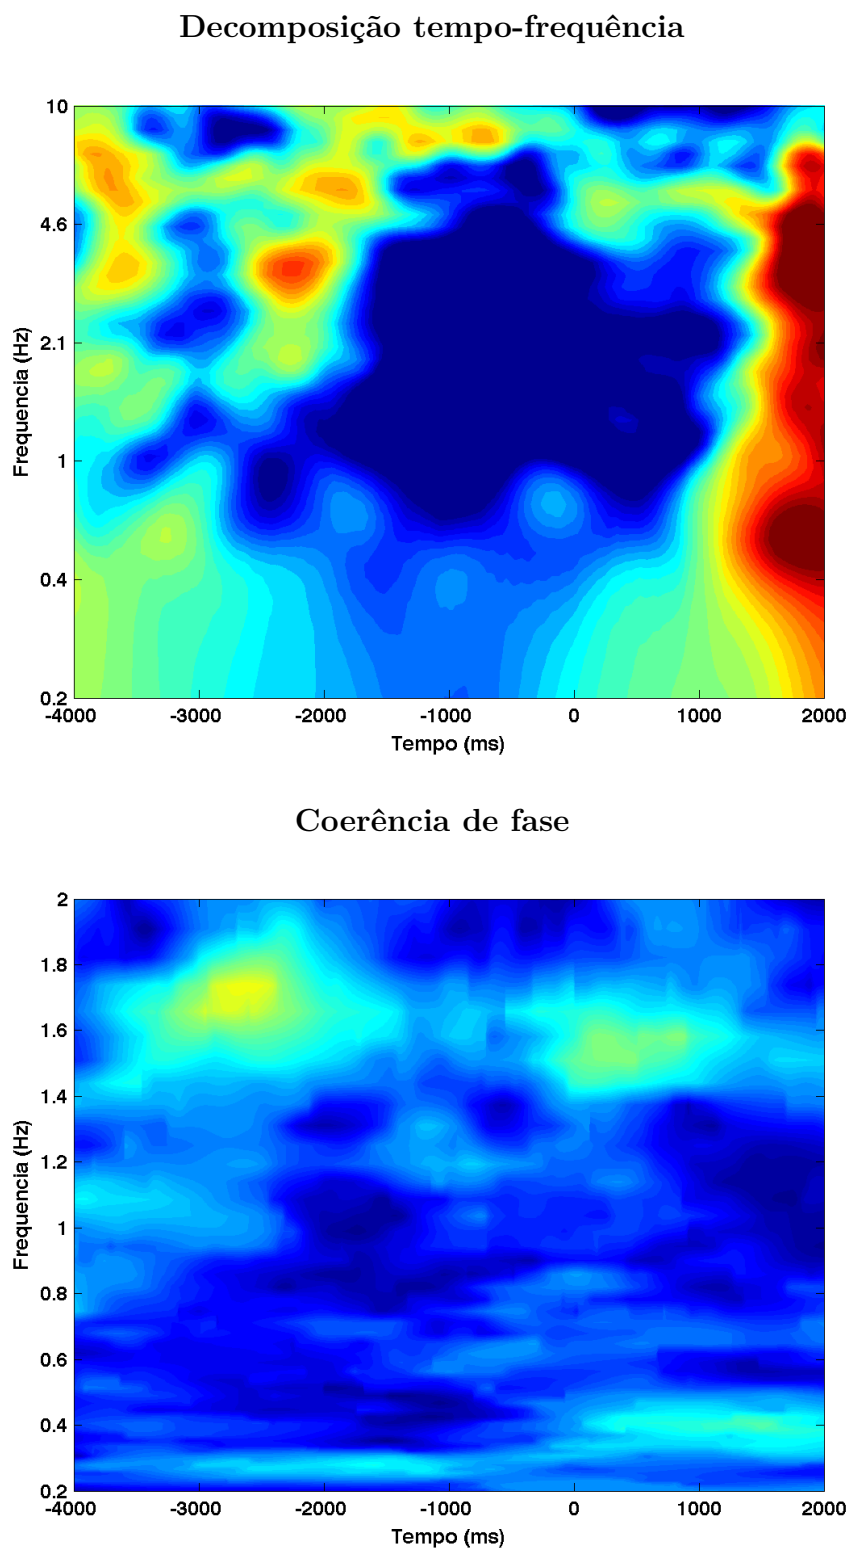


Figura 329 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 05, dia 1, eletrodo FC5.





Figura 330 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 05, dia 1, eletrodo FC6.

Decomposição tempo-frequência



Coerência de fase




Figura 331 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 05, dia 1, eletrodo O1.





Figura 332 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 05, dia 1, eletrodo O2.

Decomposição tempo-frequência



Coerência de fase




Figura 333 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 05, dia 1, eletrodo P7.

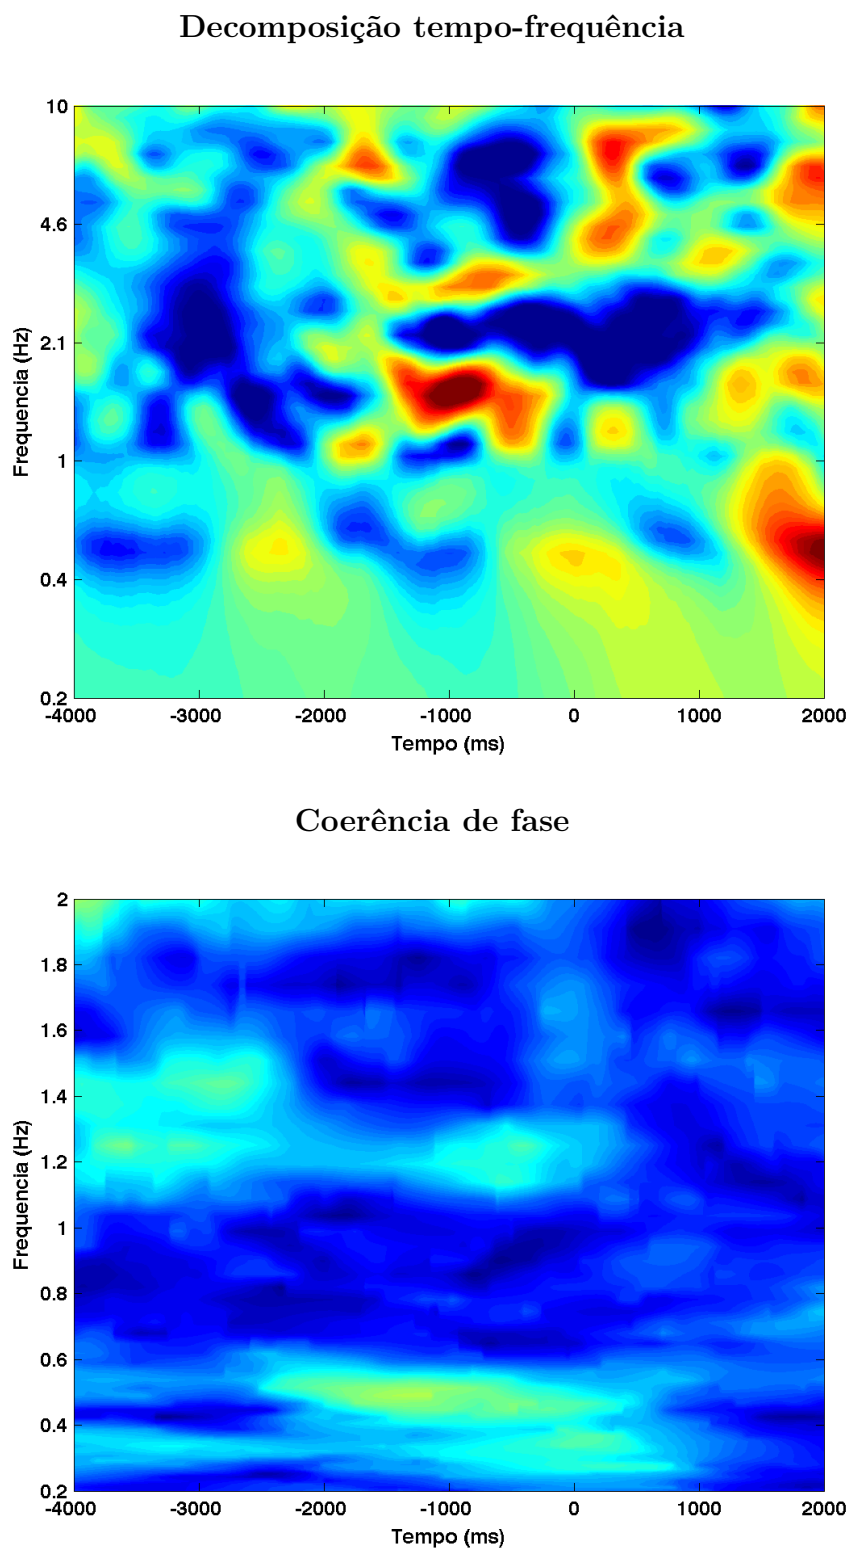


Figura 334 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 05, dia 1, eletrodo P8.

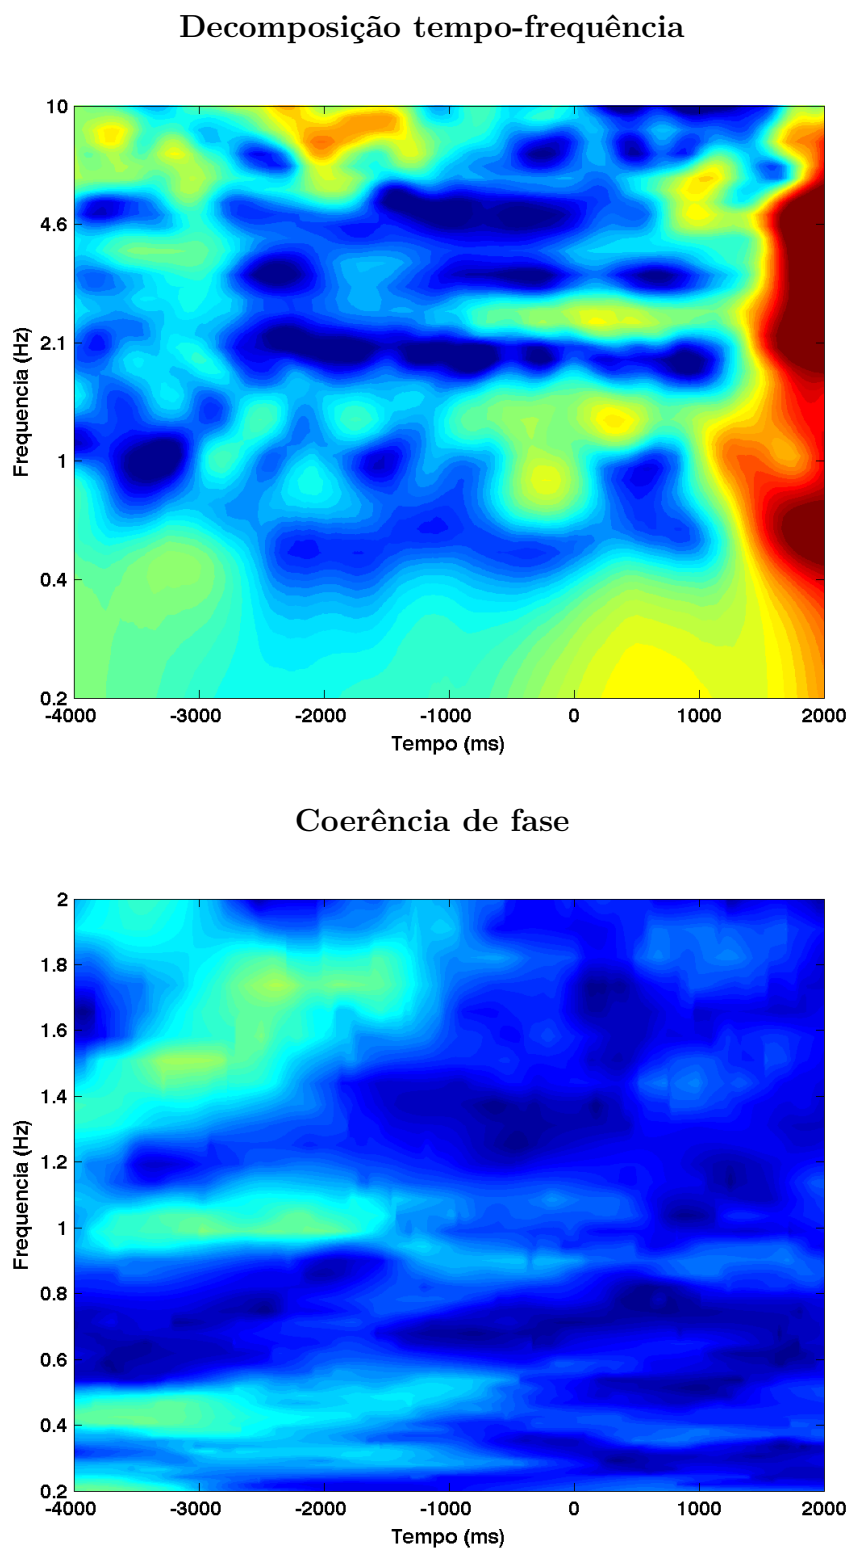


Figura 335 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 05, dia 1, eletrodo T7.




Figura 336 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 05, dia 1, eletrodo T8.

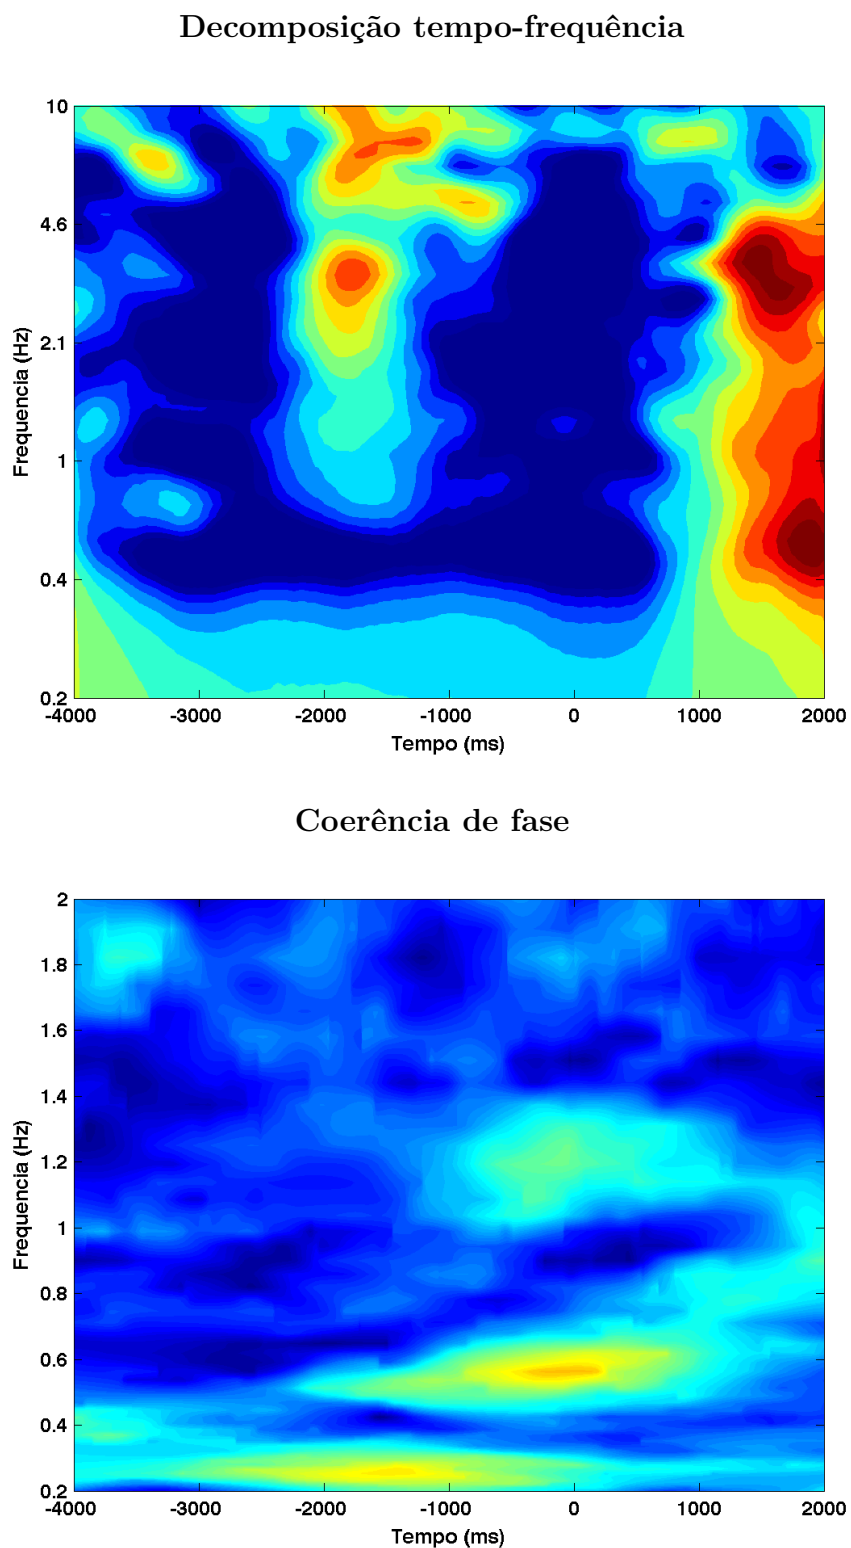



Figura 337 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 05, dia 2, eletrodo AF3.

Decomposição tempo-frequência



Coerência de fase




Figura 338 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 05, dia 2, eletrodo AF4.

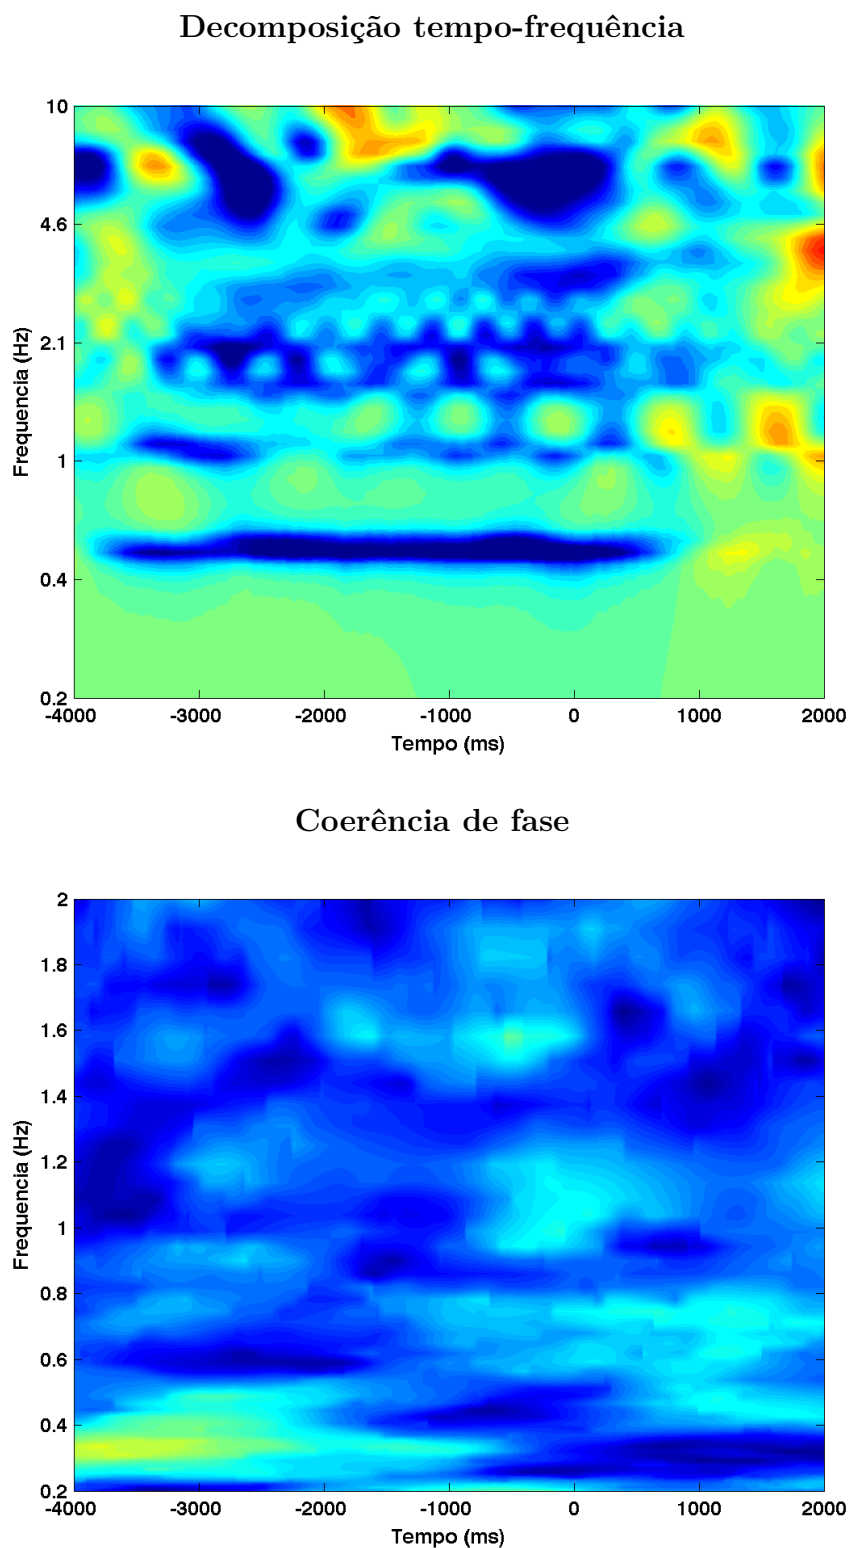


Figura 339 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 05, dia 2, eletrodo F3.

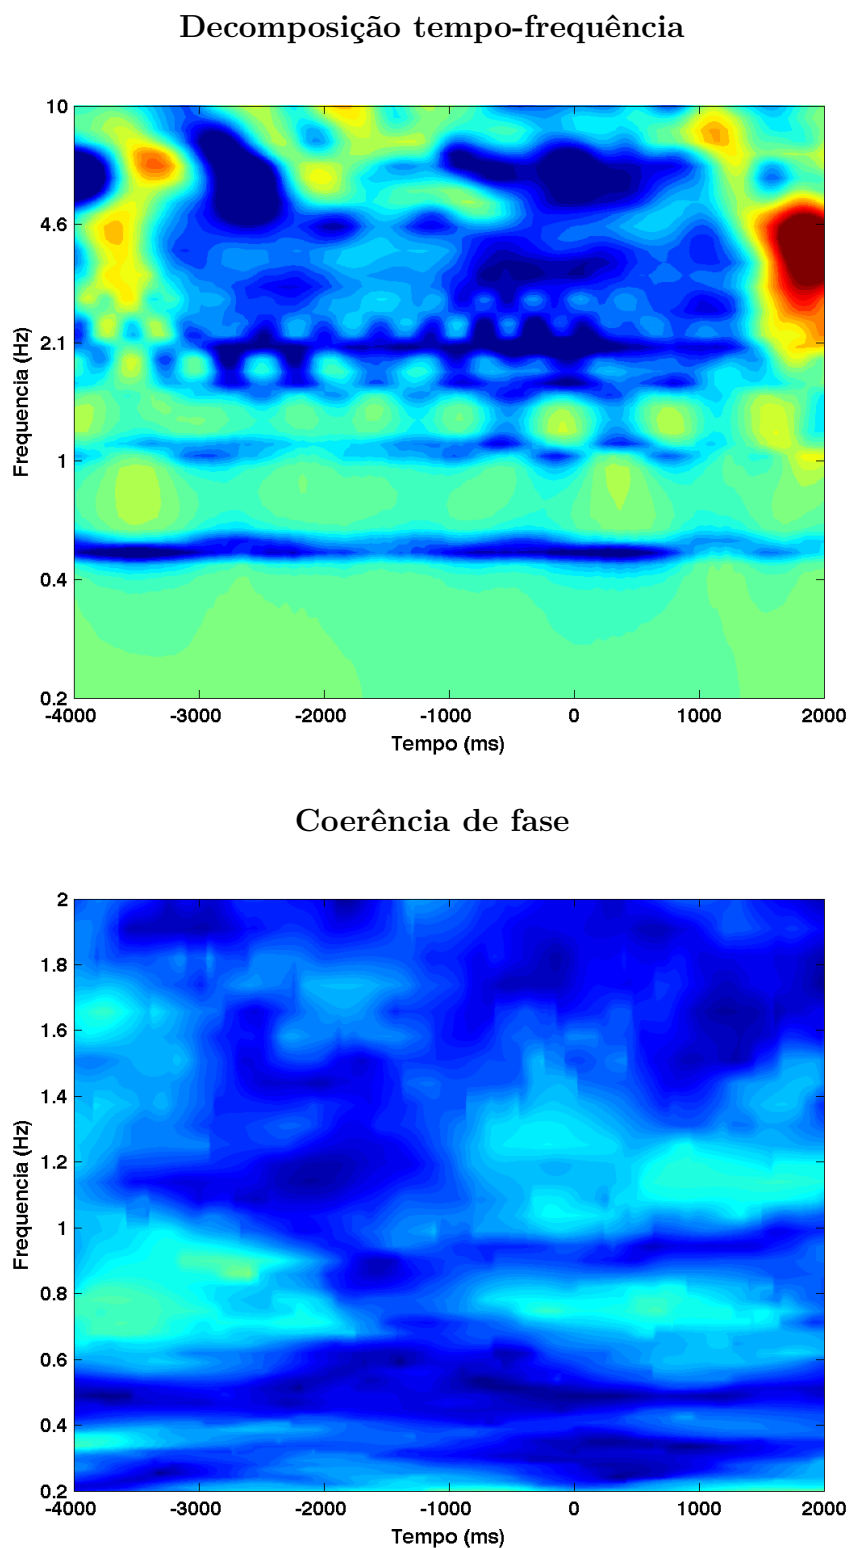


Figura 340 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 05, dia 2, eletrodo F4.





Figura 341 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 05, dia 2, eletrodo F7.

Decomposição tempo-frequência



Coerência de fase





Figura 342 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 05, dia 2, eletrodo F8.

Decomposição tempo-frequência



Coerência de fase





Figura 343 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 05, dia 2, eletrodo FC5.

Decomposição tempo-frequência



Coerência de fase




Figura 344 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 05, dia 2, eletrodo FC6.

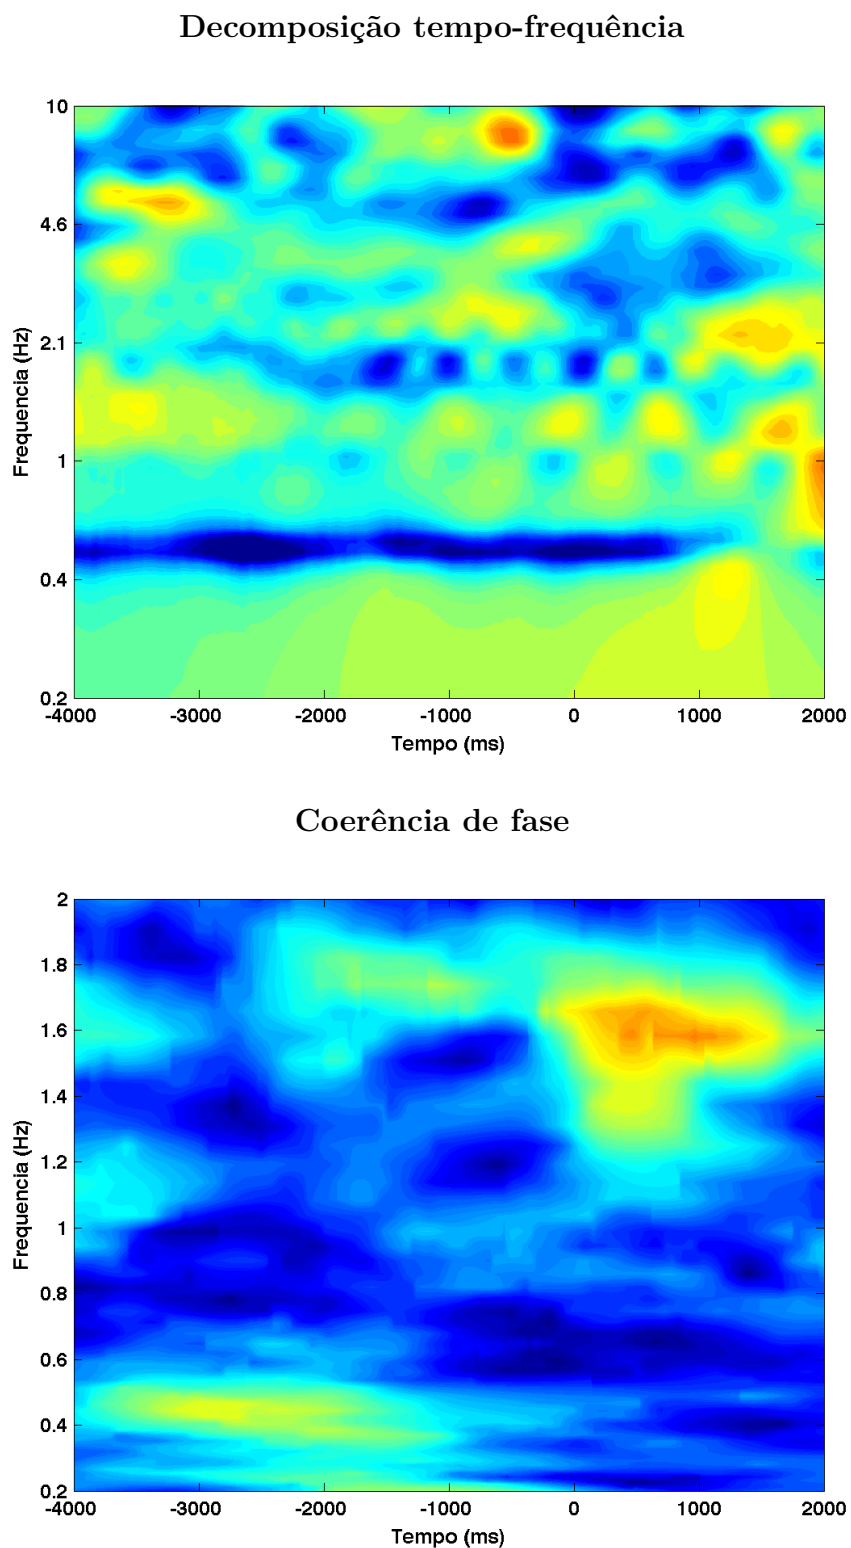



Figura 345 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 05, dia 2, eletrodo O1.

Decomposição tempo-frequência



Coerência de fase




Figura 346 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 05, dia 2, eletrodo O2.

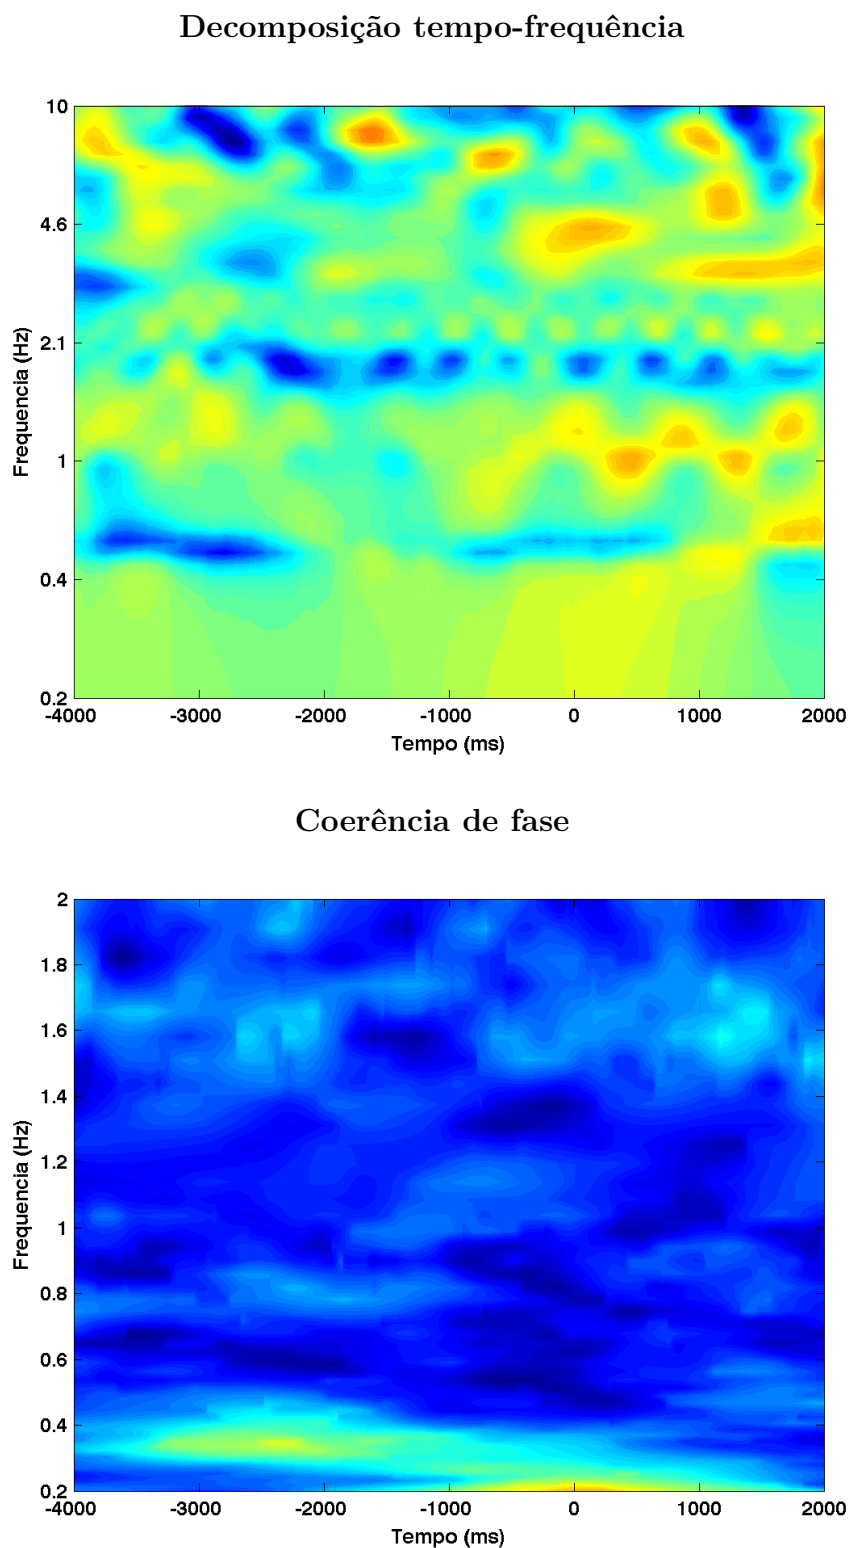



Figura 347 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 05, dia 2, eletrodo P7.

Decomposição tempo-frequência



Coerência de fase




Figura 348 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 05, dia 2, eletrodo P8.

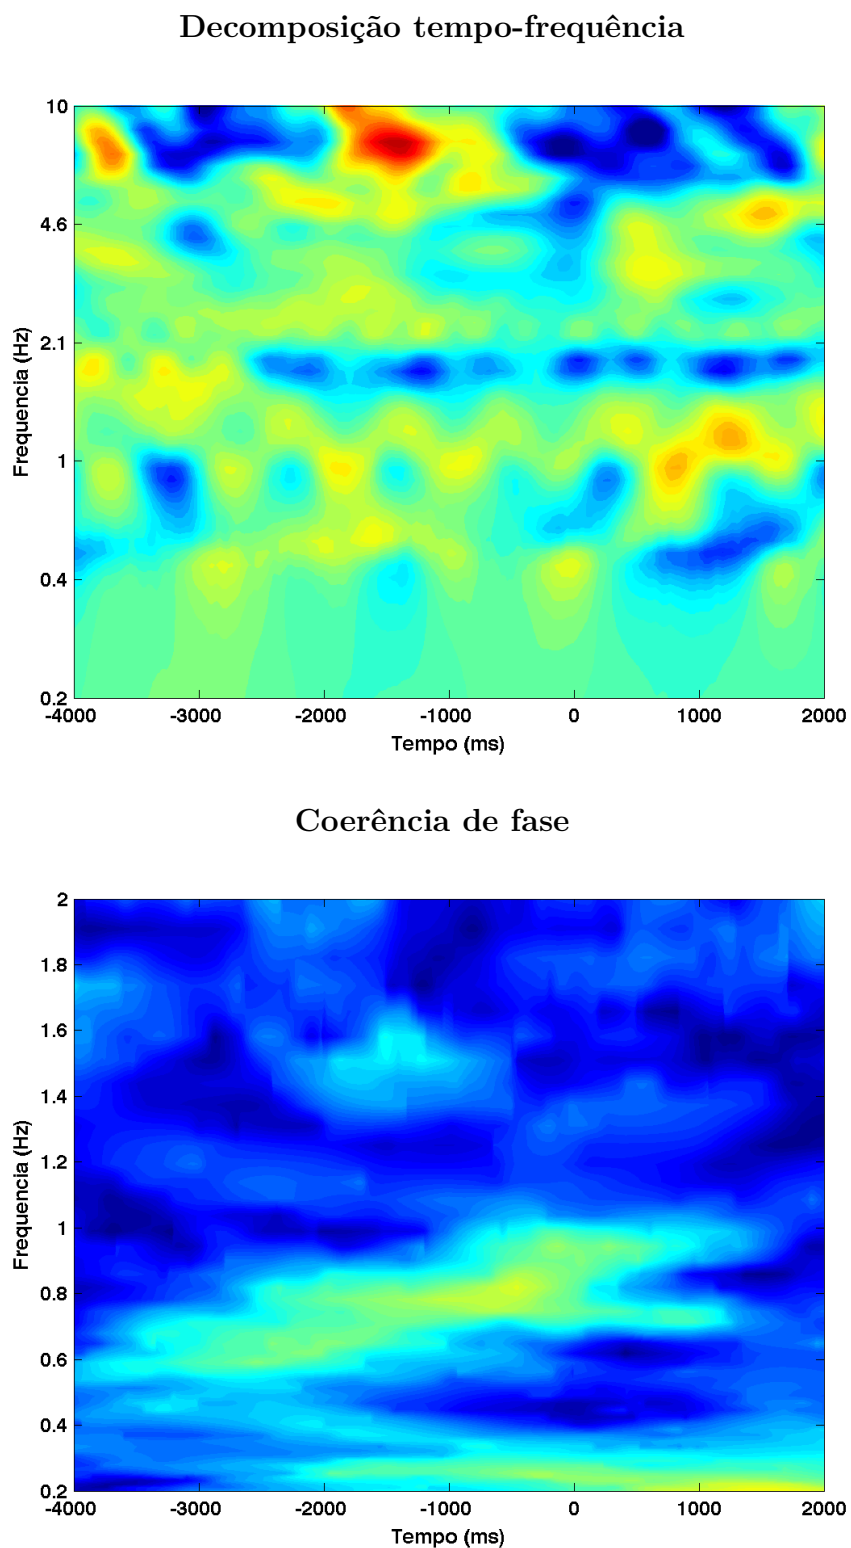



Figura 349 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 05, dia 2, eletrodo T7.

Decomposição tempo-frequência



Coerência de fase




Figura 350 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 05, dia 2, eletrodo T8.





Figura 351 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 05, dia 3, eletrodo AF3.

Decomposição tempo-frequência



Coerência de fase





Figura 352 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 05, dia 3, eletrodo AF4.

Decomposição tempo-frequência



Coerência de fase




Figura 353 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 05, dia 3, eletrodo F3.

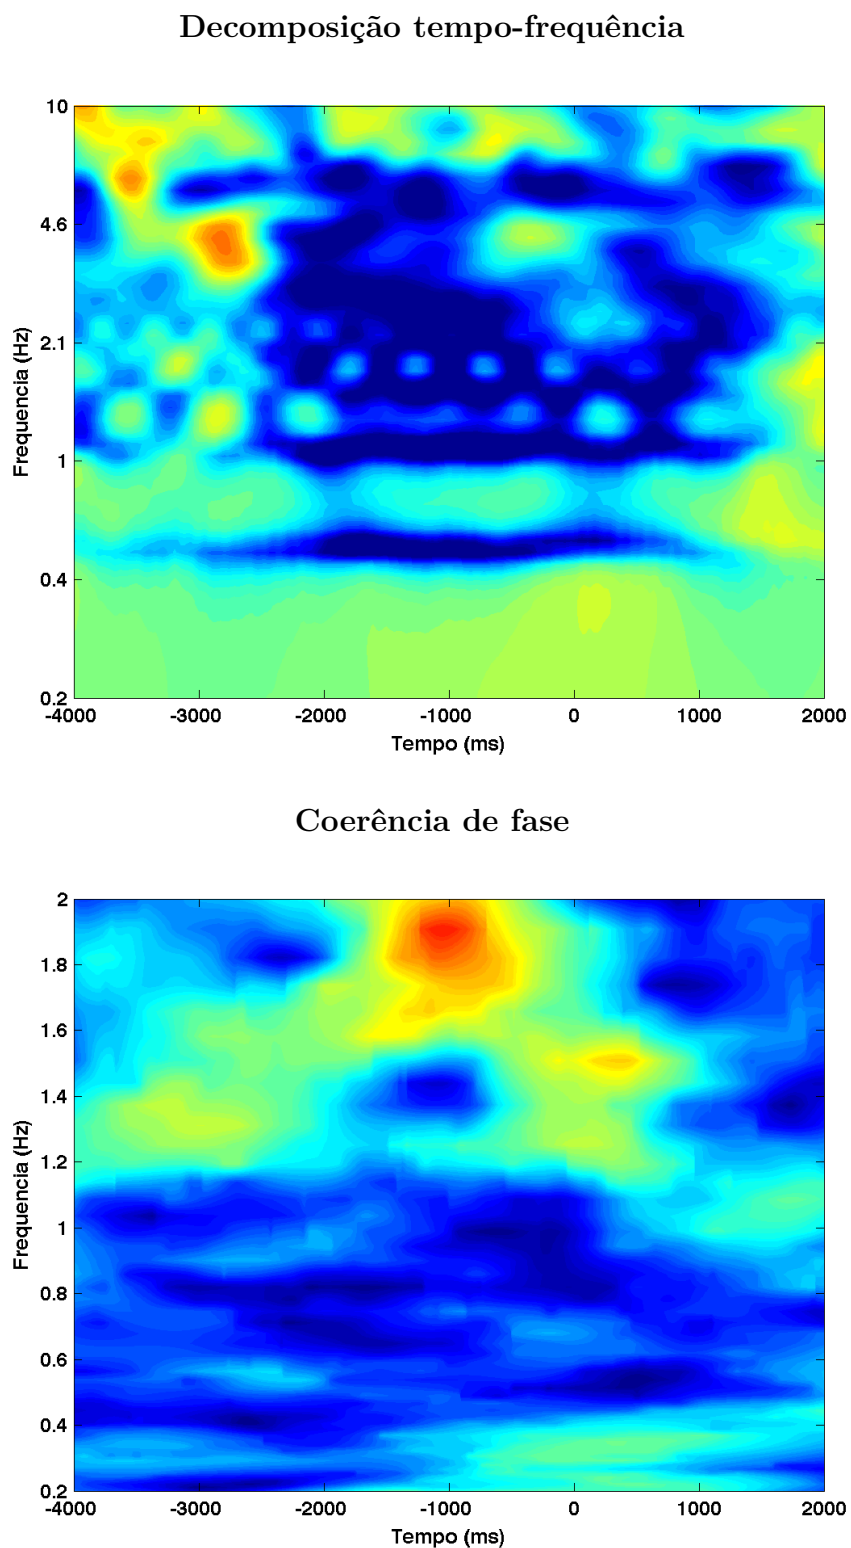



Figura 354 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 05, dia 3, eletrodo F4.

Decomposição tempo-frequência



Coerência de fase





Figura 355 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 05, dia 3, eletrodo F7.

Decomposição tempo-frequência



Coerência de fase





Figura 356 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 05, dia 3, eletrodo F8.

Decomposição tempo-frequência



Coerência de fase





Figura 357 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 05, dia 3, eletrodo FC5.

Decomposição tempo-frequência



Coerência de fase




Figura 358 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 05, dia 3, eletrodo FC6.

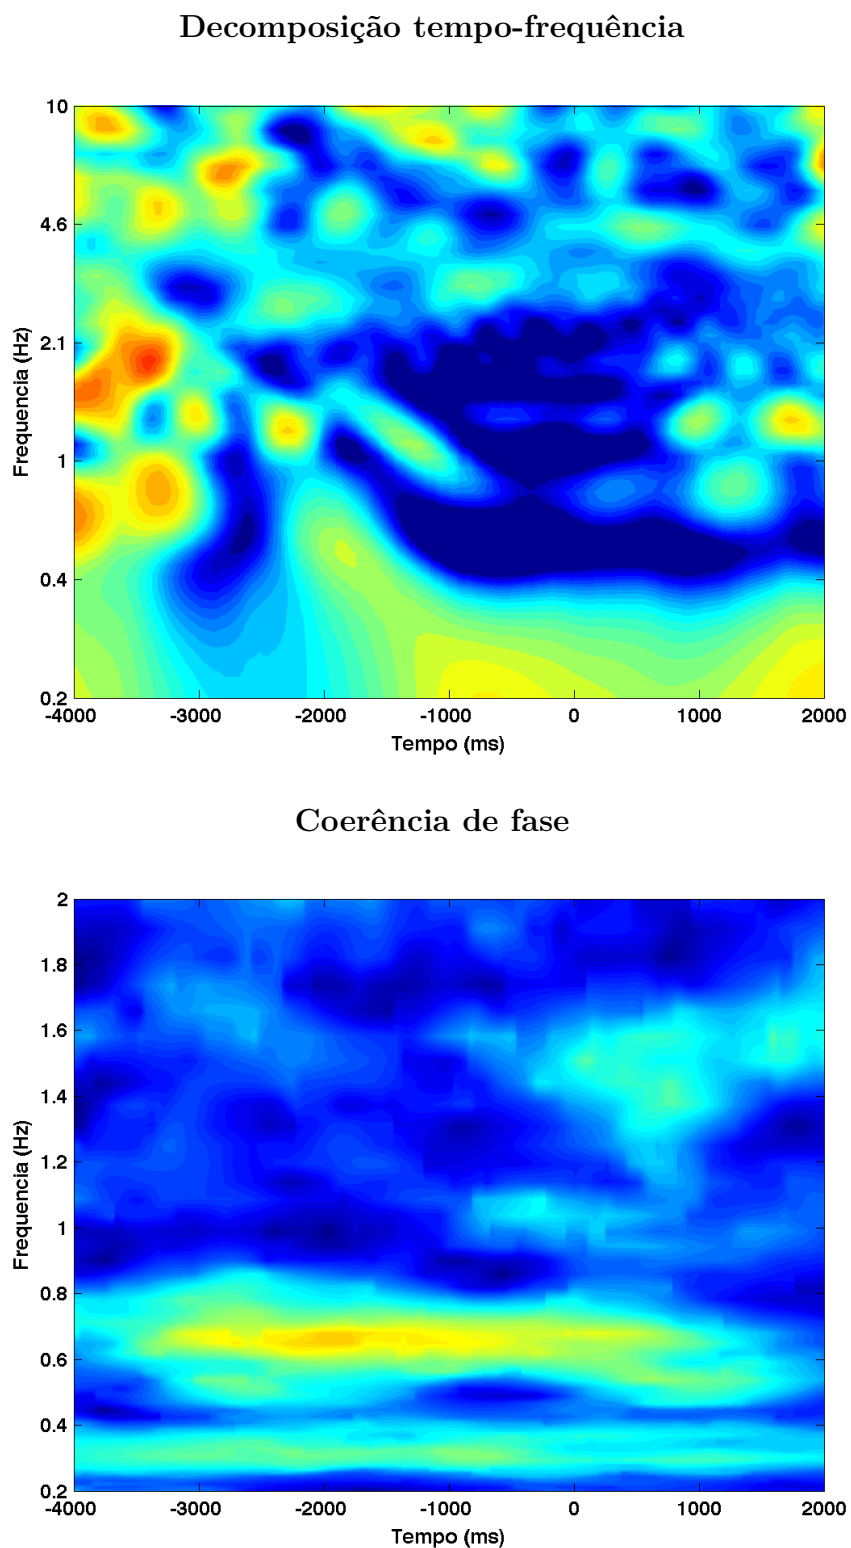



Figura 359 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 05, dia 3, eletrodo O1.

Decomposição tempo-frequência



Coerência de fase




Figura 360 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 05, dia 3, eletrodo O2.

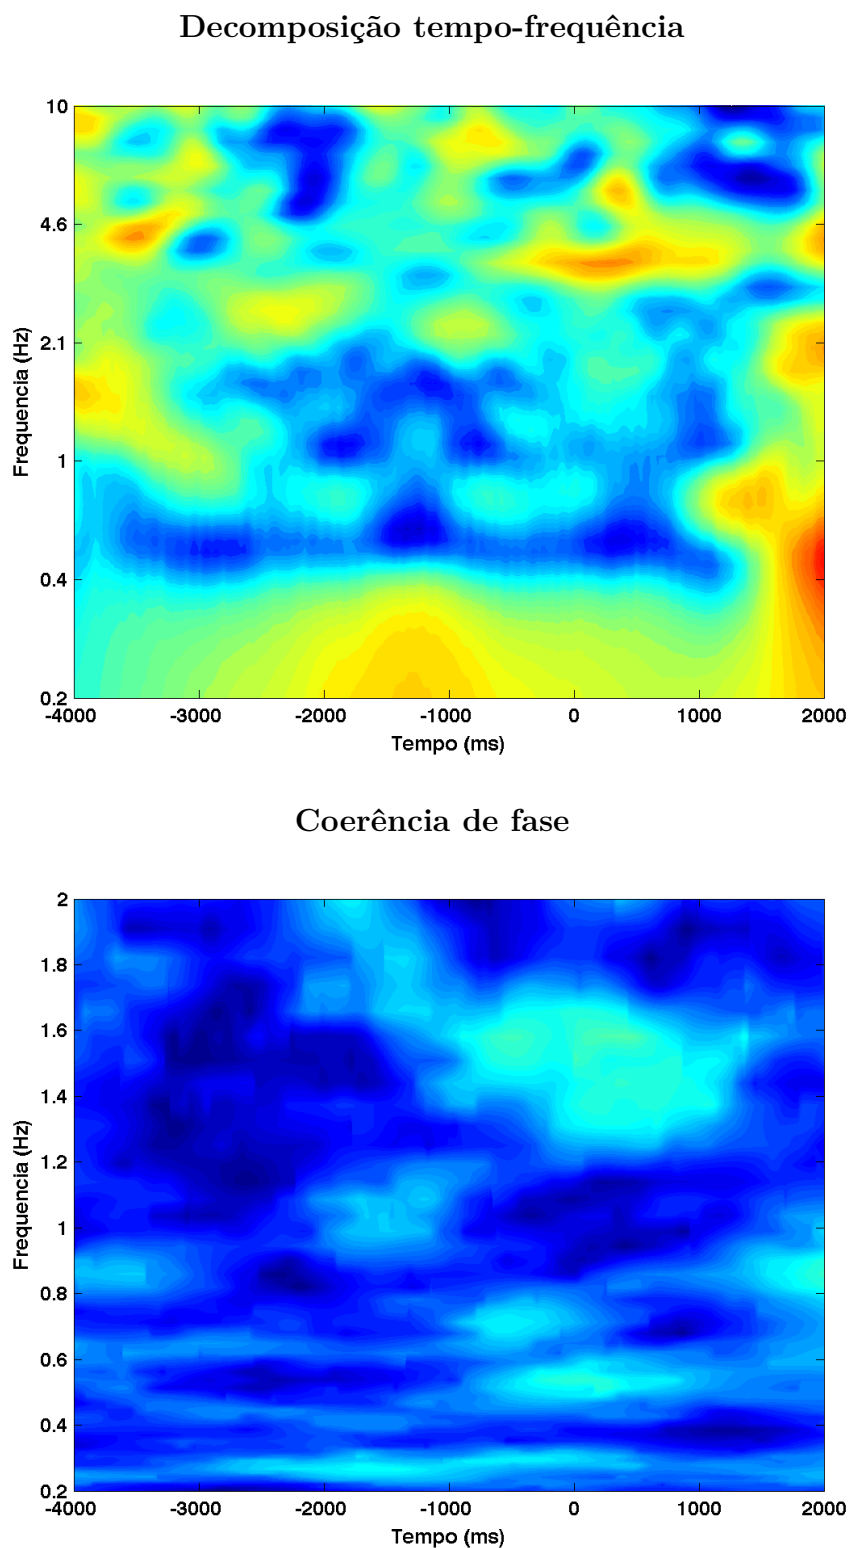



Figura 361 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 05, dia 3, eletrodo P7.

Decomposição tempo-frequência



Coerência de fase





Figura 362 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 05, dia 3, eletrodo P8.

Decomposição tempo-frequência



Coerência de fase





Figura 363 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 05, dia 3, eletrodo T7.

Decomposição tempo-frequência



Coerência de fase





Figura 364 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 05, dia 3, eletrodo T8.

Decomposição tempo-frequência



Coerência de fase





Figura 365 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 05, dia 4, eletrodo AF3.

Decomposição tempo-frequência



Coerência de fase




Figura 366 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 05, dia 4, eletrodo AF4.

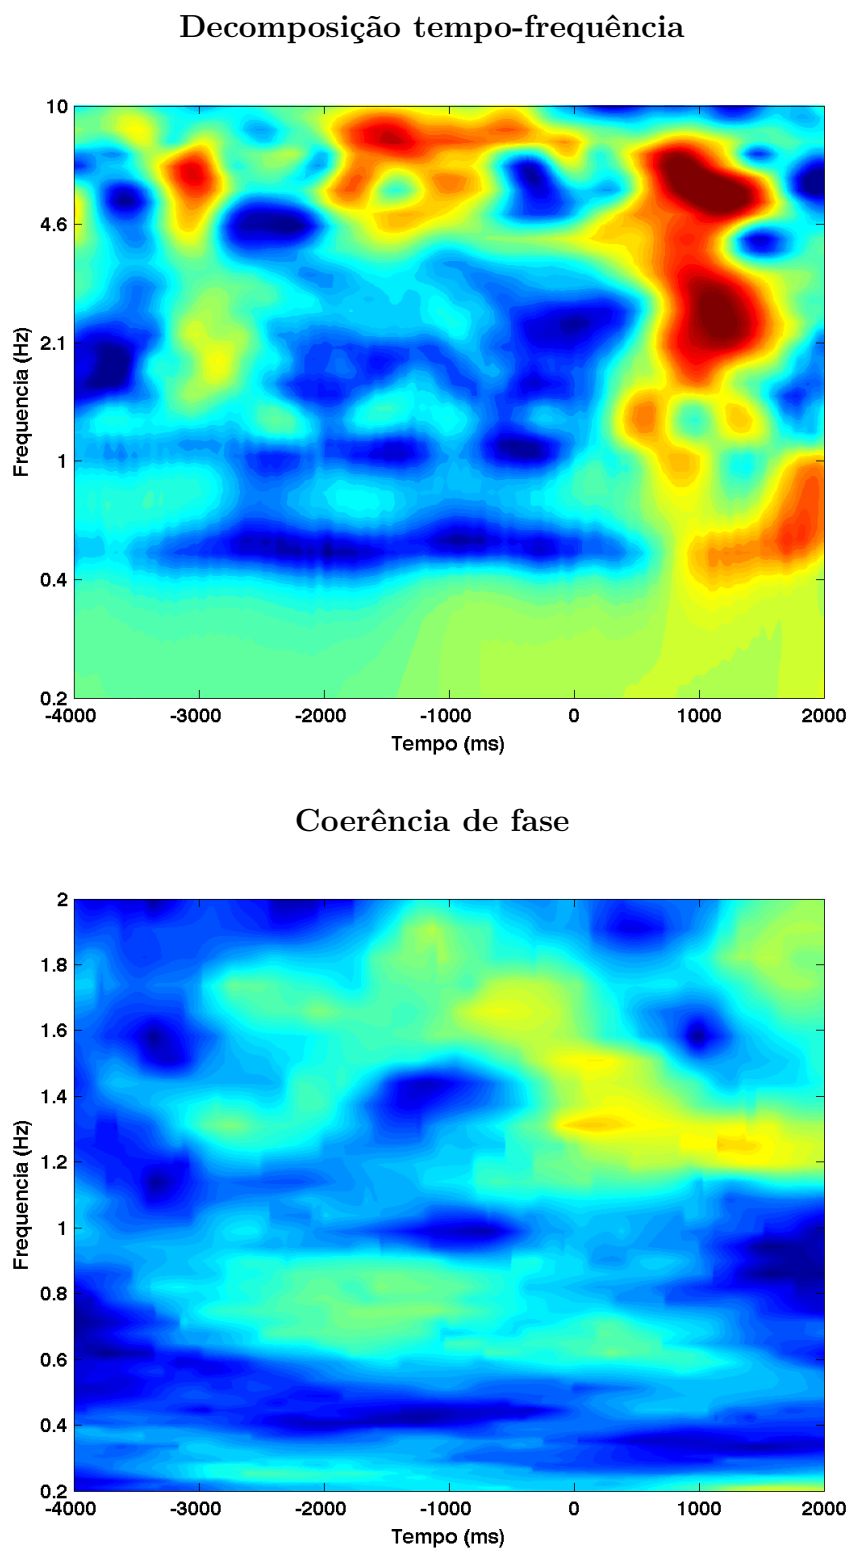



Figura 367 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 05, dia 4, eletrodo F3.

Decomposição tempo-frequência



Coerência de fase





Figura 368 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 05, dia 4, eletrodo F4.

Decomposição tempo-frequência



Coerência de fase





Figura 369 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 05, dia 4, eletrodo F7.

Decomposição tempo-frequência



Coerência de fase





Figura 370 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 05, dia 4, eletrodo F8.

Decomposição tempo-frequência



Coerência de fase





Figura 371 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 05, dia 4, eletrodo FC5.

Decomposição tempo-frequência



Coerência de fase





Figura 372 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 05, dia 4, eletrodo FC6.

Decomposição tempo-frequência



Coerência de fase




Figura 373 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 05, dia 4, eletrodo O1.




Figura 374 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 05, dia 4, eletrodo O2.

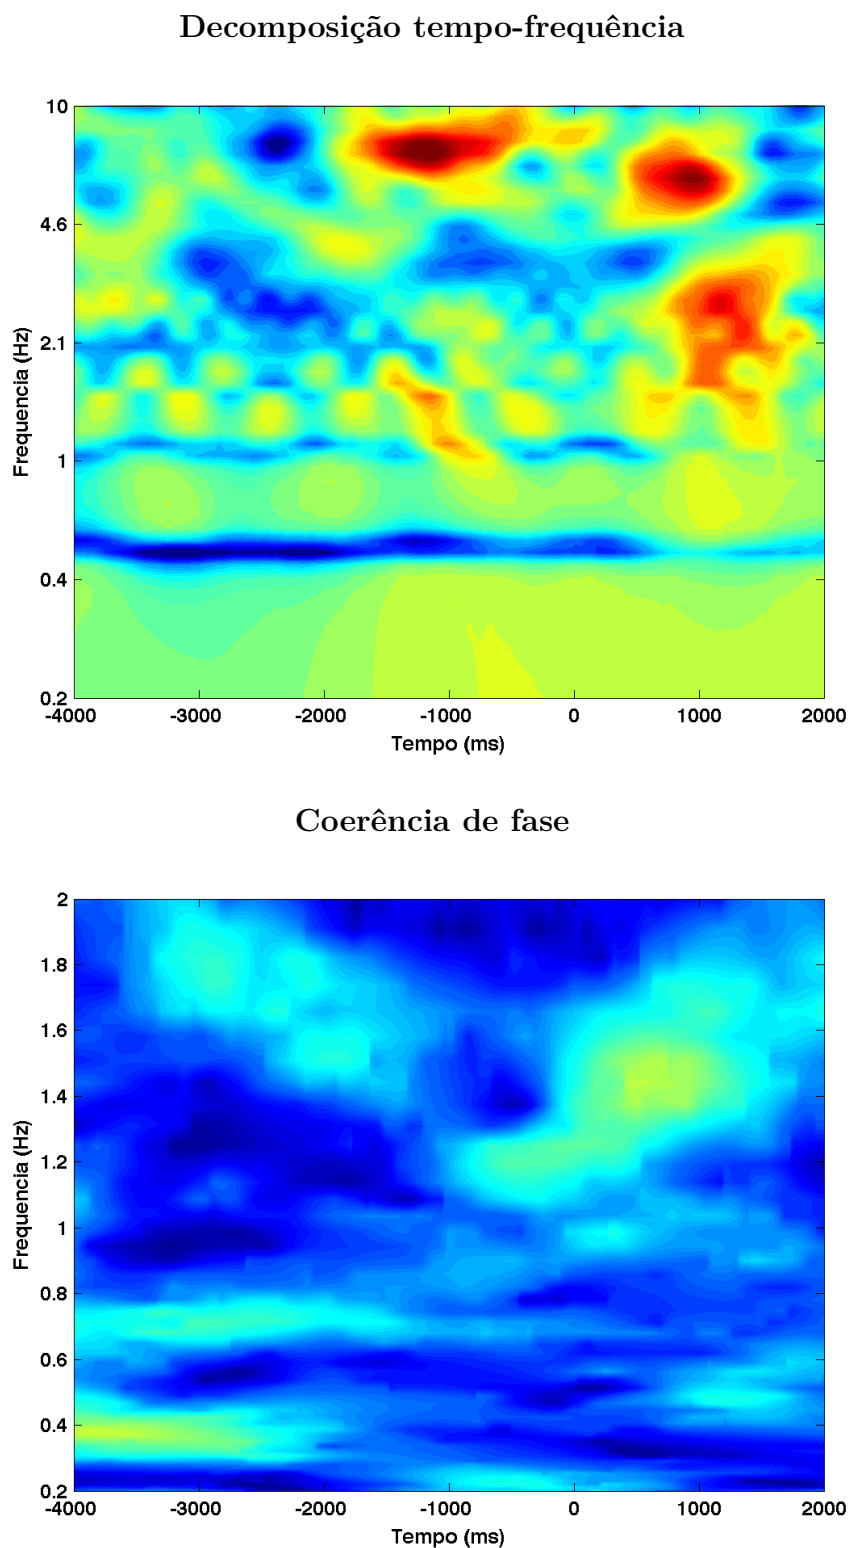


Figura 375 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 05, dia 4, eletrodo P7.

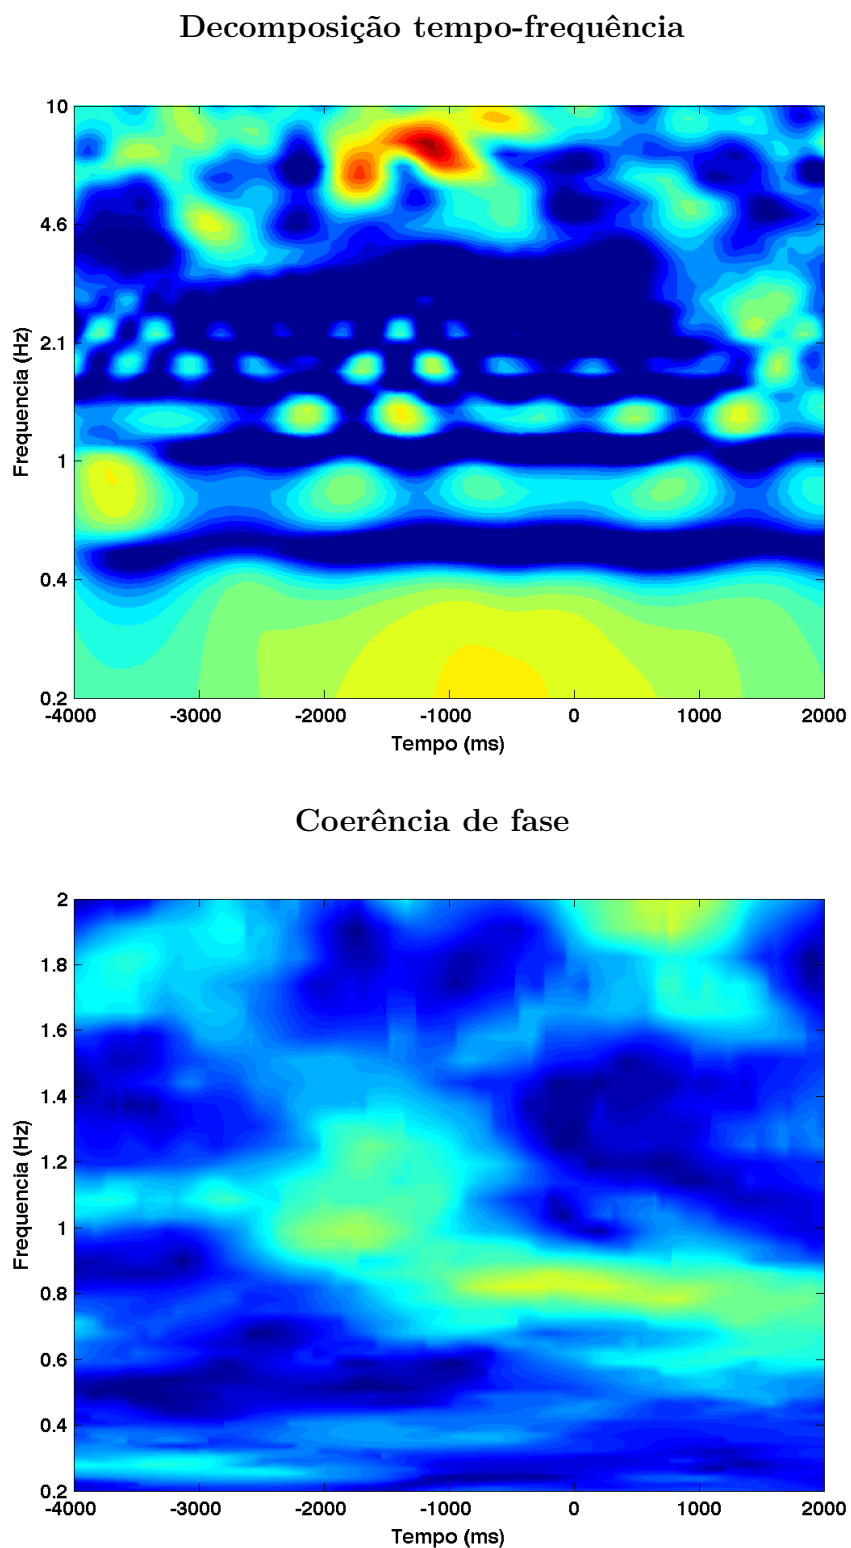



Figura 376 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 05, dia 4, eletrodo P8.

Decomposição tempo-frequência



Coerência de fase




Figura 377 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 05, dia 4, eletrodo T7.

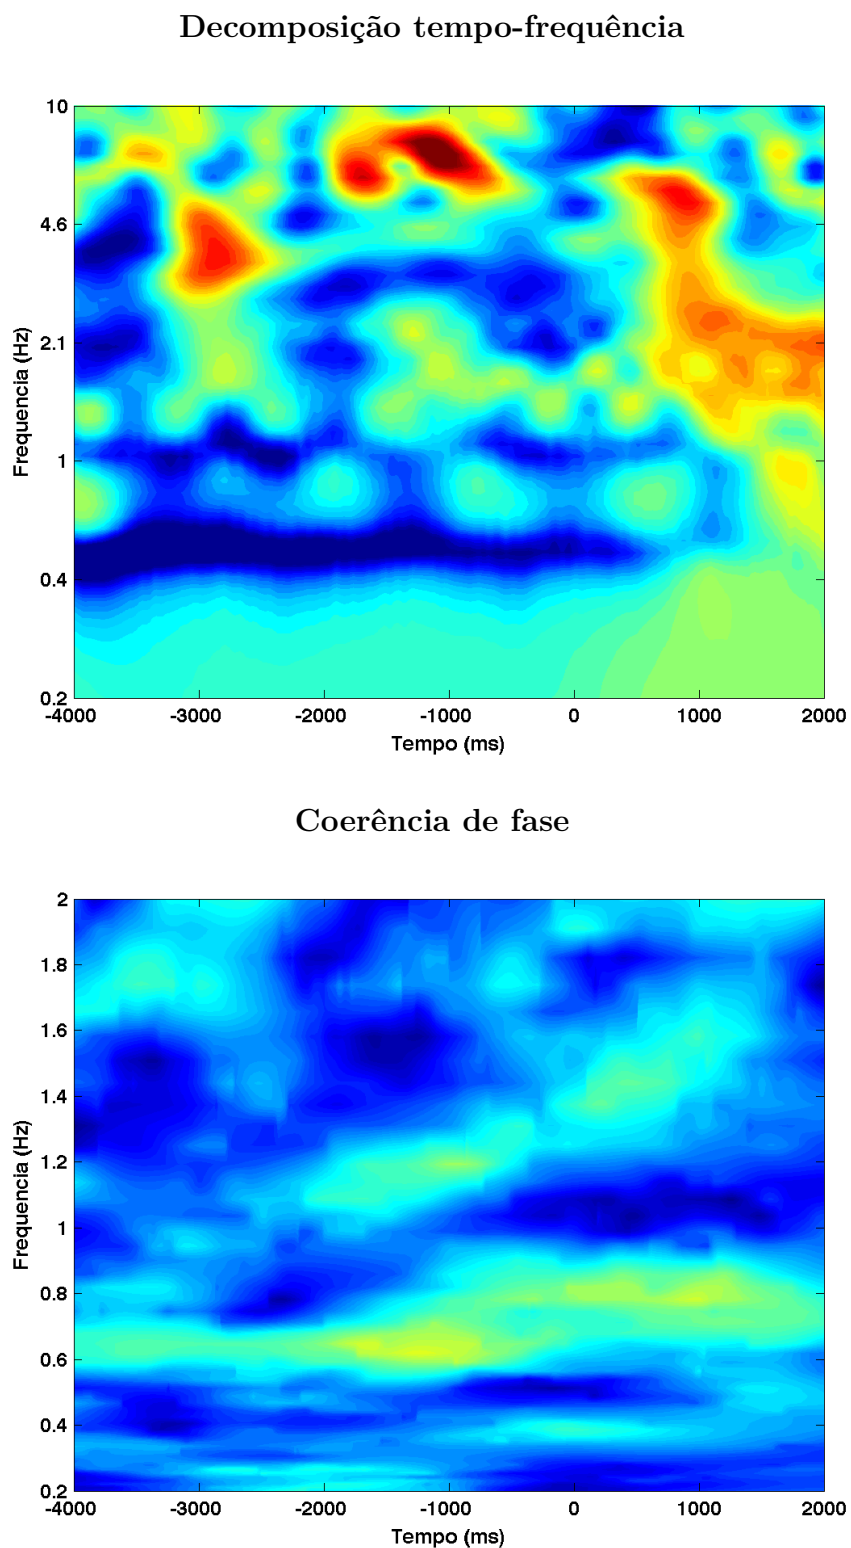


Figura 378 – Decomposição tempo-frequência (gráfico de cima) e coerência de fase (gráfico de baixo), para o sujeito 05, dia 4, eletrodo T8.