



**UNIVERSIDADE FEDERAL DE ALAGOAS - UFAL**  
**PROGRAMA DE PÓS GRADUAÇÃO EM FÍSICA**

**PEDRO FELYPE ALMEIDA SILVA**

**ANÁLISE DE SINAIS CEREBRAIS: UMA ABORDAGEM DE INFORMAÇÃO  
SIMBÓLICA PARA DISTINGUIR DIFERENTES PROCESSOS COGNITIVOS**

**MACEIÓ**

**2024**

Pedro Felype Almeida Silva

Análise de sinais cerebrais: uma abordagem de informação simbólica para distinguir diferentes processos cognitivos

Dissertação apresentada ao Instituto de Física da Universidade Federal de Alagoas como parte dos requisitos para obtenção do título de Mestre em Física.

Orientadora: Prof<sup>a</sup>. Dra. Fernanda Selingardi Matias.

Maceió

2024

**Catálogo na Fonte**  
**Universidade Federal de Alagoas**  
**Biblioteca Central**  
**Divisão de Tratamento Técnico**

Bibliotecário: Marcelino de Carvalho Freitas Neto – CRB-4 – 1767

- S586a Silva, Pedro Felype Almeida.  
Análise de sinais cerebrais : uma abordagem de informação simbólica para distinguir diferentes processos cognitivos / Pedro Felype Almeida Silva. – 2024.  
62 f. : il. color.
- Orientadora: Fernanda Selingardi Matias.  
Dissertação (Mestrado em Física) – Universidade Federal de Alagoas. Instituto de Física. Maceió, 2024.
- Bibliografia: f. 53-55.  
Apêndices: f. 56-62.
1. Sinais cerebrais. 2. Entropia de Shannon. 3. Complexidade estatística. 4. Metodologia simbólica de Bandt & Pompe. 5. Neurociências. I. Título.

CDU: 53:612.8



**Universidade Federal de Alagoas**  
**Instituto de Física**  
Programa de Pós Graduação em Física

BR 104 km 14. Campus A.C. Simões  
Cidade Universitária  
Tabuleiro dos Martins  
57072-970 Maceió - AL. Brasil  
FONE : (82) 3214-1423

**PARECER DA BANCA EXAMINADORA DE DEFESA DE**  
**DISSERTAÇÃO DE MESTRADO**

*“Análise de sinais cerebrais: uma abordagem de informação simbólica para distinguir diferentes processos cognitivos”*

**por**

**Pedro Felype Almeida Silva**

A Banca Examinadora composta pelos professores Fernanda Selingardi Matias, como presidenta da banca examinadora e orientadora, do Instituto de Física da Universidade Federal de Alagoas; André de Lima Moura, do Instituto de Física da Universidade Federal de Alagoas; e Fernando Antônio Nóbrega Santos, da Universiteit van Amsterdam, consideram o **candidato aprovado com conceito “A”**.

Maceió, 1º de julho de 2024.

Profa. Dra. Fernanda Selingardi Matias

Prof. Dr. André de Lima Moura

Prof. Dr. Fernando Antônio Nóbrega Santos

## **AGRADECIMENTOS**

Esse trabalho e essa vida não existiriam desta forma, e talvez de nenhuma outra, se não fossem todas as pessoas que estiveram ao meu lado nesses 24 anos de vida. Só tenho a agradecer à minha família, aos meus afetos e a todos que me ensinaram e me permitiram chegar até aqui. Amo todos vocês!

“Viver é Resistir!”

## RESUMO

Esta dissertação aborda a análise de sinais cerebrais e sua aplicação em diferentes contextos experimentais. Introduzimos os fundamentos teóricos sobre sinais e séries temporais, bem como as técnicas de captura e armazenamento desses sinais. Em seguida, discutimos a contribuição dos físicos para o estudo da neurociência, focando na análise estatística de séries temporais discretas obtidas de sinais cerebrais durante a realização de diferentes tarefas cognitivas. Detalhamos a aplicação da entropia de Shannon e da complexidade estatística MPR como quantificadores para caracterizar sinais cerebrais, utilizando a metodologia simbólica de Bandt & Pompe. Descrevemos ainda a implementação da metodologia simbólica de Bandt & Pompe utilizando a linguagem de programação Python. Finalmente, exploramos dois experimentos distintos: um envolvendo tarefas cognitivas visuais realizadas por humanos e outro relacionado a tarefas motoras realizadas por macacos. Mostramos que essas ferramentas de teoria da informação são úteis para caracterizar e distinguir diferentes processos cognitivos, bem como as escalas de tempos mais relevantes para o processamento das informações relativas às diferentes tarefas.

**Palavras-chave:** Sinais cerebrais; Entropia de Shannon; Complexidade estatística; Metodologia simbólica de Bandt & Pompe; Neurociência.

## ABSTRACT

This dissertation addresses the analysis of brain signals and their application in different experimental contexts. We introduce the theoretical foundations of signals and time series, as well as techniques for capturing and storing these signals. Next, we discuss the contribution of physicists to the study of neuroscience, focusing on the statistical analysis of discrete time series obtained from brain signals during the performance of different cognitive tasks. We detail the application of Shannon entropy and MPR statistical complexity as quantifiers to characterize brain signals, using Bandt & Pompe's symbolic methodology. We also describe the implementation of Bandt & Pompe's symbolic methodology using the Python programming language. Finally, we explored two distinct experiments: one involving visual cognitive tasks performed by humans and another related to motor tasks performed by monkeys. We show that these information theory tools are useful for characterizing and distinguishing different cognitive processes, as well as the most relevant time scales for processing information related to different tasks.

**Keywords:** Brain signals; Shannon entropy; Statistical complexity; Bandt & Pompe symbolic methodology; Neuroscience.

## LISTA DE FIGURAS

Figura 2.1: (a) Um traço de uma gravação extracelular (DC – 6 kHz) retirada do córtex visual de macacos. (b) A aplicação de um filtro passa-alta ( $> 400$ Hz) ao mEFP destaca a atividade do MUA de uma grande população de neurônios. (c) Aplicação de um filtro passa-baixa ( $<400$ Hz) para revelar atividade neural de mudança lenta (LFP). A caixa tracejada reflete períodos de forte atividade do MUA durante uma LFP negativa.....	13
Figura 2.2: Visão geral esquemática das técnicas de gravação SUA/MUA, LFP, ECoG e MEG/EEG mostrando (de cima para baixo): a escala espacial na qual os sinais são gravados, a característica do sinal (discreto vs. analógico) e a correspondência para diferentes escalas.....	15
Figura 3.1: Localização de três pinturas artísticas no plano entropia versus complexidade.....	19
Figura 3.2: Caracterizando a abordagem da informação simbólica: (a) os seis símbolos associados às permutações para padrões ordinais de comprimento $= 3$ e tempo de incorporação $= 1$ (b) Exemplo simples de uma série temporal dada por $, = 9$ e (c) sua própria função de densidade de probabilidade não normalizada.....	20
Figura 3.3: Ilustração do método B&P aplicado a uma série temporal e as sequências ordinais resultantes para incorporação dos parâmetros $= 3$ e $= 1$ .....	21
Figura 3.4: Curvas máxima e mínima para valores no plano entropia versus complexidade para $= 3, 4, 5$ e $6$ .....	22
Figura 3.5: Exemplos da aplicação de B&P. (a) Comportamento das funções analisadas. (b) Densidade de probabilidade encontrada a partir de B&P para as funções analisadas.....	23
Figura 3.6: Entropia versus complexidade obtidas através de B&P para as funções da Figura 3.5.....	23
Figura 4.1: Representação dos sinais analisados em dois cenários. (a) Primeiro cenário: sinal inteiro onde sua série temporal tem $N = 1000$ . (b) Segundo cenário: janela flutuante, onde pegamos e definimos passo $= 200$ e com isso dividimos a série temporal que inicialmente tinha $N = 1000$ em cinco séries temporais de $N = 200$ .....	26
Figura 4.2: Representação de no plano entropia versus complexidade.....	28

Figura 4.3: Pipeline para a caracterização usando B&P de um sinal.....	29
Figura 5.1: Representação do experimento. (a) Ilustração da tela durante o tempo do experimento: 2.000 ms de períodos de espera observando uma tela branca alternada com 2.000 ms de uma tarefa de busca visual ativa. (b) Sinal da atividade registrada de um eletrodo exemplar na área occipital durante as duas telas em branco e os dois períodos de tarefa ativa mostrados em (a).....	31
Figura 5.2: Representação dos sinais concatenados para o eletrodo 1 do paciente JT, pegando todo o intervalo(primeiro método de organizar os dados).....	32
Figura 5.3: Mapa de calor representando a distância euclidiana entre a tarefa de tela branca e a tarefa de pesquisa no plano complexidade versus entropia, para todos os 67 eletrodos e de 1 ms até 30 ms.....	33
Figura 5.4: Mapa de calor representando a distância euclidiana entre a tarefa de tela branca e a tarefa de busca no plano complexidade versus entropia em cada tarefa para 8 eletrodos ilustrativos de 3 pacientes diferentes. No eixo vertical mostramos e no eixo horizontal mostramos as janelas de tempo de 2ms iniciando a cada 10ms..	34
Figura 5.5: Caracterizando complexidade e entropia para ambas as condições no plano complexidade versus entropia em dois momentos distintos das tentativas: 0 a 200ms e 500ms a 700ms. (a) - (h) O plano de complexidade versus entropia para os 8 canais ilustrativos mostrados na Figura 5.4.....	35
Figura 5.6: Caracterizando diferentes tipos de atividade dos eletrodos para $\tau = 6$ ms. (a) Localização de todos os 67 canais de cinco sujeitos (separados pelas cores) em um mapa cerebral padrão. Pontos maiores indicam comportamento semelhante ao canal JT3. (b) Complexidade $C_{busca}$ e $C_{tela\ branca}$ e (c) distância $d_{tela\ branca,pesquisa}$ para todos os eletrodos do paciente JT. (d)-(h) Assimetria de complexidade $A(C_{tela\ branca},C_{busca})$ para todos os eletrodos de cada paciente. Os canais podem ser separados em três grupos: valores positivos de assimetria, valores negativos ou valores próximos de zero durante a maior parte do intervalo. Um eletrodo ilustrativo para cada paciente é destacado.....	36
Figura 6.1: Representação do passo a passo do experimento. (a) Representação visual dos movimentos do macaco. (b) Representação da informação visual dada ao macaco e dos momentos contido em uma tentativa.....	39
Figura 6.2: Histograma referente a separação temporal entre o marcador SR-ON e	

GO-ON.....	40
Figura 6.3: Representação dos sinais elétricos do Macaco L de todas as tentativas iniciadas em CUE-ON (pegando todo o intervalo até CUE-OFF) separadas por tipo e concatenada. Limite do eixo x colocado em 3000 ms para representação .....	41
Figura 6.4: Representação dos sinais elétricos do Macaco L de todas as tentativas iniciadas em SR (pegando todo o intervalo até WS-OFF) separadas por tipo e concatenada. Limite do eixo x colocado em 3000 ms para representação .....	42
Figura 6.5: Mapa de calor para a distância entre SG e PG, versus eletrodo. (a) Para o macaco L. (b) Para o macaco N.....	44
Figura 6.6: Mapa de calor para a distância entre SG e PG, versus tempo.....	45
Figura 6.7: Evolução dos quantificadores por intervalo de tempo. (a) Entropia e (b) Complexidade.....	45
Figura 6.8: Entropia versus complexidade. (a) Intervalo iniciado em 40 ms e indo até 140 ms. (b) Intervalo iniciado em 200 ms e indo até 300 ms.....	46
Figura 6.9: Mapa de calor para a distância entre SG e PG, versus tempo.....	46
Figura 6.10: Mapa de calor para a distância entre cada tipo de tarefa, versus tempo.	47
Figura 6.11: Evolução da assimetria entre SG e PG por intervalo de tempo. (a) Assimetria da entropia. (b) Assimetria da complexidade.....	48
Figura 6.12: Evolução dos quantificadores por intervalo de tempo para cada tipo de tarefa. (a) Entropia e (b) Complexidade.....	49
Figura 6.13: Entropia versus complexidade. (a) Intervalo iniciado em 40 ms e indo até 140 ms. (b) Intervalo iniciado em 130 ms e indo até 230 ms. (c) Intervalo iniciado em 160 ms e indo até 260 ms. (d) Intervalo iniciado em 220 ms e indo até 320 ms.	50

## SUMÁRIO

<b>1 APRESENTAÇÃO.....</b>	<b>11</b>
<b>2 SINAIS CEREBRAIS.....</b>	<b>13</b>
2.1 Métodos invasivos.....	14
2.2 Métodos não invasivos.....	15
<b>3 METODOLOGIA.....</b>	<b>17</b>
3.1 Entropia de Shannon.....	17
3.2 Complexidade.....	18
3.3 Metodologia simbólica de Bandt & Pompe.....	20
<b>4 ALGORITMO PARA APLICAÇÃO DA METODOLOGIA SIMBÓLICA DE BANDT &amp; POMPE.....</b>	<b>26</b>
4.1 Cálculo dos quantificadores.....	26
4.2 Análise dos quantificadores.....	28
<b>5 HUMANOS REALIZANDO UMA TAREFA VISUAL COGNITIVA.....</b>	<b>31</b>
5.1 Aquisição dos dados.....	31
5.2 Organização dos dados.....	32
5.3 Resultados.....	33
<b>6 MACACOS REALIZANDO UMA TAREFA MOTORA.....</b>	<b>39</b>
6.1 Aquisição dos dados.....	39
6.2 Organização dos dados.....	40
6.3 Resultados.....	44
6.3.1 CUE-ON: distinguindo o tipo de pegada: pegada lateral (SG) ou pegada de precisão (PG).....	44
6.3.1 SR-ON: caracterizando os quatro tipos possíveis de tentativas de acordo com o tipo de pegada (lateral ou de precisão) e de força (alta ou baixa): SGHF, SGLF, PGHF, PGLF.....	47
<b>REFERÊNCIAS.....</b>	<b>53</b>
<b>APÊNDICE A – ALGORITMO EM PYTHON PARA APLICAÇÃO DE B&amp;P.....</b>	<b>56</b>
<b>APÊNDICE B – HUMANOS REALIZANDO UMA TAREFA VISUAL COGNITIVA (ARTIGO).....</b>	<b>62</b>

## 1 APRESENTAÇÃO

Estudar o cérebro movimenta diferentes áreas da ciência e une pesquisadores e pesquisadoras de diversas áreas como biologia, neurociência e física. Uma das possíveis abordagens de entender como o cérebro funciona é estudar os sinais elétricos que são gerados por eles, os sinais cerebrais [1]. Ao estudar sinais cerebrais, podemos usar ferramentas computacionais e estatísticas para tentar quantificá-los. Neste trabalho, temos como objetivo usar quantificadores de teoria da informação para diferenciar sinais cerebrais obtidos durante a realização de tarefas cognitivas com diferentes respostas possíveis.

Esse trabalho se divide em seis capítulos. No segundo capítulo, exploraremos os diferentes tipos de sinais e suas características. Além disso, descreveremos as metodologias de captura e armazenamento de sinais cerebrais, destacando a transformação de sinais contínuos em séries discretas para fins computacionais. Também classificaremos as técnicas de captura de sinais cerebrais em invasivas e não invasivas.

No terceiro capítulo, abordaremos a contribuição dos físicos para o estudo da neurociência, focando na análise estatística de séries temporais discretas obtidas de sinais cerebrais. O objetivo é utilizar a entropia de Shannon e a complexidade estatística para quantificar fenômenos observados durante a captura dos sinais. Esses quantificadores serão calculados a partir de uma função de densidade de probabilidade dos sinais, empregando a metodologia simbólica de Bandt & Pompe (B&P) para encontrar essa função.

No quarto capítulo, exploraremos a implementação da metodologia simbólica de Bandt & Pompe utilizando a linguagem de programação Python, que é amplamente adotada na comunidade científica devido à sua acessibilidade e vasta quantidade de bibliotecas específicas para a análise de sinais cerebrais. Desenvolvemos um algoritmo baseado na biblioteca Ordpy para calcular a função de probabilidade dos sinais e seus quantificadores de entropia e complexidade. Este algoritmo analisa os sinais em dois cenários: ao longo de todo o intervalo de tempo e através de janelas flutuantes, dividindo o intervalo em segmentos menores.

Nos capítulos 5 e 6, examinaremos respectivamente os dados de dois experimentos distintos. O capítulo 5 abordará um estudo envolvendo tarefas

cognitivas visuais, onde os participantes foram submetidos a uma tarefa de busca ativa, enquanto no capítulo 6 analisaremos os dados gerados por macacos treinados para realizar uma tarefa motora de alcançar e agarrar uma alavanca. O trabalho realizado no capítulo 5 resultou no artigo disposto no apêndice B[2].

## 2 SINAIS CEREBRAIS

Muitas vezes, precisamos transmitir informação e podemos usar diferentes métodos para isso, por exemplo utilizando antenas para enviar sinais de rádio, ou fibras óticas. De outras maneiras, a natureza também transmite informações, conseguimos ouvir sons (ondas mecânicas) e visualizar imagens (ondas eletromagnéticas) a partir da leitura que o nosso organismo faz das informações oriundas dessas ondas. Um sinal é justamente a quantidade física que transmite essas informações [3].

Um sinal pode ter duas formas: a primeira é a de um sinal determinístico, que pode ser descrito por uma função, e a segunda a de um sinal estocástico, que não pode ser descrito por uma função. Quando observamos os sinais cerebrais, sinais elétricos gerados por reações químicas e biológicas do nosso cérebro, notamos que este é um sinal estocástico. Apesar de podermos representar alguns destes por um sinal determinístico somado a uma componente aleatória, o sinal cerebral tem como característica ter essa componente aleatória como um fator muito importante [4].

Quando estamos interessados em estudar esse sinais é necessário armazená-los em algum lugar, e para isso podemos usar as ferramentas computacionais. A natureza apresenta esses sinais de maneira contínua, mas não temos como armazenar infinitos pontos, a quantidade de pontos de um sinal contínuo. Com isso, no ato de capturá-los, os transformamos em uma série discreta. Em geral, armazenamos os sinais por um tempo  $T$  e fazemos a captura dos sinais em intervalos de tempos iguais,  $\Delta t$ . No final, computacionalmente falando, nosso sinal vai ser uma série discreta com  $N$  pontos, onde  $N = \frac{T}{\Delta t}$  [7].

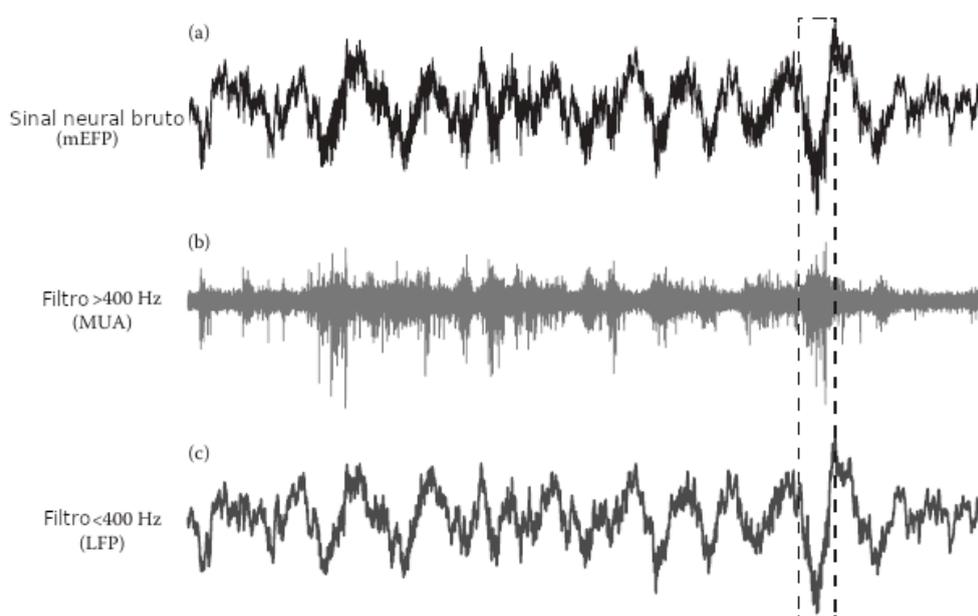
Existem várias técnicas para capturar os sinais cerebrais. Em geral, podemos separá-las em dois grupos: as técnicas invasivas e as técnicas não invasivas. Exemplos do primeiro grupo incluem atividade de unidades únicas (SUA, do inglês “Single-Unit Activity”), atividade de unidades múltiplas (MUA, do inglês “Mass-Spiking Activity”), potenciais de campo locais (LFP, do inglês “Local Field Potential”) e Eletrocorticografia (ECoG, do inglês “Electrocorticography”). Já do segundo grupo temos a eletroencefalografia (EEG, do inglês “electroencephalogram”) e a Magnetoencefalografia (MEG, do inglês “Magnetoencephalography”) [3-6].

## 2.1 Métodos invasivos

Métodos que consistem em eletrodos aplicados diretamente na superfície extracelular requerem um procedimento médico invasivo. Uma das maneiras de captar os sinais cerebrais é instalando uma matriz de eletrodos em uma pequena área do cérebro, e essas matrizes são chamadas de microarrays [6].

Eletrodos colocados diretamente na superfície do cérebro medem o potencial de campo extracelular médio (mEFP, do inglês “Mean Extracellular Field Potential”). Dependendo da proximidade do eletrodo com o soma ou o axônio do neurônio, é possível identificar o pico de atividade de apenas um neurônio, e esses sinais são chamados de SUA. Esse método apresenta algumas dificuldades que limitam sua aplicação em laboratório. A principal dificuldade é a alta sensibilidade à posição na qual o eletrodo é colocado. Essa sensibilidade acaba gerando problemas de estabilidade do sinal durante a captação, especialmente se o experimento tem uma duração longa, e se o indivíduo (humano ou não) estiver acordado e com movimentos livres [3].

Figura 2.1: (a) Um traço de uma gravação extracelular (DC – 6 kHz) retirada do córtex visual de macacos. (b) A aplicação de um filtro passa-alta (> 400 Hz) ao mEFP destaca a atividade do MUA de uma grande população de neurônios. (c) Aplicação de um filtro passa-baixa (<400 Hz) para revelar atividade neural de mudança lenta (LFP). A caixa tracejada reflete períodos de forte atividade do MUA durante uma LFP negativa.



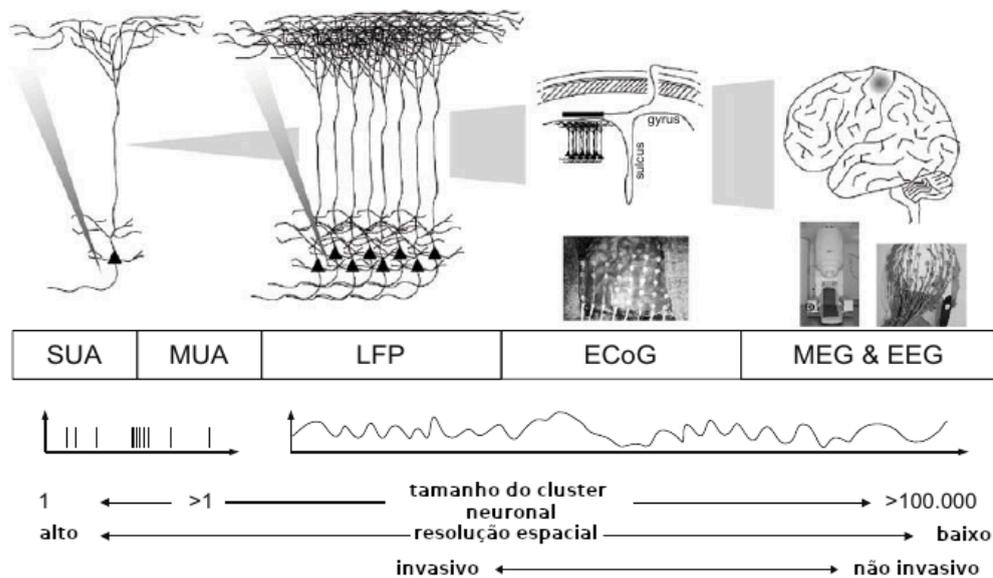
Fonte: Modificada de [3].

Uma alternativa ao SUA é posicionar os eletrodos mais distantes dos picos de atividade dos neurônios, o que faz com que o mEFP captado agora represente uma soma das atividades dos neurônios próximos. Ao fazer isso, podemos obter dois tipos de sinais, como representado na Figura 2.1: o primeiro é chamado de MUA, quando é aplicado um filtro passa-alta ( $> 400\text{Hz}$ ). O segundo tipo de sinal é chamado de LFP, quando é aplicado um filtro passa-baixa ( $< 400\text{Hz}$ ) [3,6].

## 2.2 Métodos não invasivos

Para analisar o comportamento dos sinais cerebrais em humanos, realizar procedimentos invasivos na maioria das vezes não é uma opção viável. Uma alternativa aos métodos invasivos apresentados anteriormente são os métodos não invasivos. Dois exemplos desses métodos são o EEG e o MEG. O EEG envolve a colocação de uma série de eletrodos no couro cabeludo. Devido à sua distância maior das células em comparação com os eletrodos que geram o LFP, o sinal medido por ele tem uma amplitude aproximadamente 100 vezes menor do que aqueles adquiridos a partir do LFP [3], além de uma resolução menor, pois mais neurônios influenciam nos sinais captados. O MEG é semelhante ao EEG, mas em vez de usar eletrodos para captar os sinais, ele utiliza magnetômetros para observar o campo magnético gerado pelas correntes elétricas no cérebro. Para isso, requer uma ampla blindagem magnética e que o indivíduo esteja em repouso [6].

Figura 2.2: Visão geral esquemática das técnicas de gravação SUA/MUA, LFP, ECoG e MEG/EEG mostrando (de cima para baixo): a escala espacial na qual os sinais são gravados, a característica do sinal (discreto vs. analógico) e a correspondência para diferentes escalas.



Fonte: Modificada de [5].

Quando analisamos os diferentes métodos, é possível observar que cada um apresenta suas próprias vantagens e desvantagens. Em geral, os métodos invasivos fornecem informações mais localizadas e uma amplitude maior dos sinais gerados pelo cérebro. No entanto, eles são limitados pelo fato de requererem procedimentos invasivos nos indivíduos, isso restringe sua aplicação em pacientes humanos. Para contornar essa limitação, recorreremos aos métodos não invasivos, que quebram essa barreira e abrem novas possibilidades de estudos. Ambos os métodos retornam sinais que são representados computacionalmente por séries temporais discretas que podem ser estudados à luz das ideias de análises de sinais e teoria da informação.

### 3 METODOLOGIA

Alguns são os questionamentos que podem aparecer ao saber que físicos estão estudando o cérebro. Um deles é sobre qual seria a contribuição que essa classe de pesquisadores e pesquisadoras podem dar ao estudo da neurociência. Para a análise de sinais, o objetivo deste trabalho é fazer análises estatísticas de séries temporais discretas que são obtidas a partir de sinais cerebrais. Aqui, usaremos a entropia de Shannon [8] e a complexidade estatística [9] como uma forma de quantificar algum fenômeno que ocorreu durante a captura dos sinais. Ambos quantificadores são calculados a partir de uma função de densidade de probabilidade dos sinais, para encontrar essa função utilizaremos a metodologia simbólica de Bandt & Pompe (B&P) [10].

Quando olhamos a literatura, observamos que B&P é aplicado em diversas áreas: na física, ao estudar sistemas dinâmicos e caóticos [11,12], na economia[13] no estudo de sinais de áudio [14]. Também, este método também tem sido aplicado a sinais cerebrais como neste trabalho, por exemplo, em estudos de criticalidade cerebral[15], dados de sincronização de áreas do cérebro distintas[16] e ao caracterizar sinais cerebrais obtidos durante diferentes estados corticais [17-19].

#### 3.1 Entropia de Shannon

Ao pesquisar sobre entropia percebemos que podemos abordá-la de diferentes maneiras, talvez a mais conhecida seja a entropia de Boltzmann estudada em mecânica estatística. Porém, neste trabalho iremos usar o conceito da entropia de Shannon, também conhecida como medida da informação de Shannon[20].

A entropia de Shannon diz o grau de informação que temos sobre a série temporal analisada, e é definida como:

$$S[P] = - \sum_{i=1}^N p_i \log(p_i) \quad (3.1)$$

onde N é a quantidade de estados acessíveis ao sistema, P é a distribuição de probabilidade desses estados ao longo da série

$$P \equiv \{p_i; i = 1, 2, \dots, N\} \quad (3.2)$$

com  $p_i$  sendo a probabilidade do estado  $i$  ocorrer na série temporal, sendo normalizada de tal forma que:

$$\sum_{i=1}^N p_i = 1 \quad (3.3)$$

Ao observar a sua definição, notamos que a entropia de Shannon é máxima justamente quando temos o máximo de ignorância sobre a série, o que acontece quando todos os estados do sistema têm a mesma probabilidade de ocorrer. A distribuição de probabilidade nesse caso é chamada de distribuição equiprovável:

$$P_E \equiv \left\{ p_i = \frac{1}{N}; \forall i = 1, 2, \dots, N \right\} \quad (3.4)$$

e ao calcularmos a entropia de Shannon, obtemos:

$$S[P_E] \equiv S_{max} = \log(N) \quad (3.5)$$

A partir de  $S[P_E]$ , conseguimos definir a entropia de Shannon normalizada, que iremos usar neste trabalho:

$$H[P] \equiv \frac{S[P]}{S[P_E]} = \frac{S[P]}{\log(N)} \quad (3.6)$$

A entropia de Shannon é uma medida que analisa a série temporal discreta como um todo, ou seja, é uma medida de desordem global e com isso não tem sensibilidades às mudanças que ocorrem de forma isoladas ao longo da série temporal discreta[17].

### 3.2 Complexidade

Ao estudar os fenômenos da natureza com o quantificador da entropia de Shannon, notamos que há dois extremos de comportamento. Dois exemplos clássicos desses extremos são o do gás ideal clássico e o do cristal. Enquanto no exemplo do gás ideal temos  $H[P] = 1$ , o cristal tem  $H[P] = 0$ . Essa diferença se dá por conta que o gás ideal é descrito por uma distribuição de probabilidade equiprovável, e o cristal de forma oposta tem um estado dominante na sua distribuição de probabilidade.

Ao estudar sinais com alta e baixa entropia observamos que esses extremos estão relacionados com o conhecimento que temos sobre o comportamento da série temporal discreta associada aos sinais. Sinais muito bem comportados, por exemplo

uma série monotônica, apresentam baixa entropia, enquanto séries ruidosas exibem altos valores de  $H$ .

A maioria dos sinais encontrados na natureza exibem entropias com valores intermediários entre a entropia máxima e mínima. Sendo assim, é possível definir uma medida de complexidade estatística que nos ajude a ter mais informação sobre os sinais que apresentam valores intermediários de entropia. A complexidade estatística tem algumas características que o favorece ao usá-la junto a entropia de Shannon. A complexidade estatística é nula, tanto para situações de ordem máxima (Cristal), quanto para situações de desordem máxima (Gás ideal), e é maximizada no intermédio entre a desordem e a ordem [9]. Com isso, foi definida uma complexidade baseada em um desequilíbrio  $E$ [21], essa complexidade também é chamada de complexidade Martin Plastino Rosso (complexidade MPR)[22]:

$$C[P] = EH[P] . \quad (3.7)$$

O conceito de equilíbrio nesse caso está relacionado com a distribuição uniforme, quanto mais a distribuição  $P$  se aproxima da distribuição  $P_E$ , mais próximo de 0 é o valor do desequilíbrio. Uma possível maneira de quantificar o desequilíbrio é utilizando a divergência de Jensen-Shannon (JSD)[9]:

$$E = \frac{D[P, P_E]}{D_{max}} , \quad (3.8)$$

onde

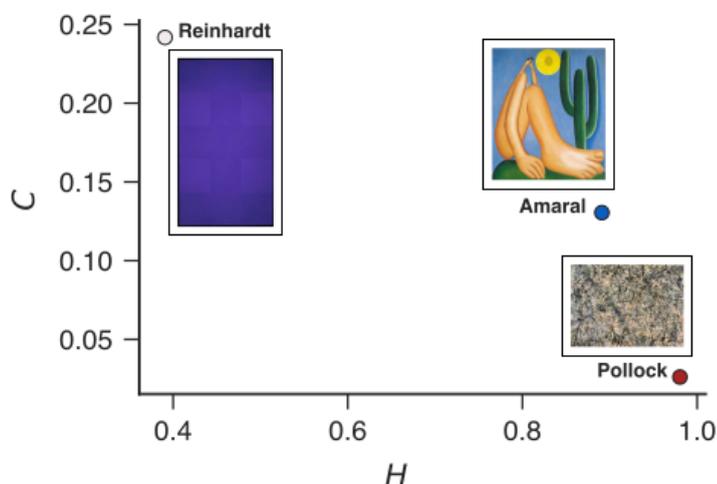
$$D[P, P_E] = S\left[\frac{(P + P_E)}{2}\right] - \frac{1}{2}S[P] - \frac{1}{2}S[P_E] \quad (3.9)$$

e

$$D_{max} = -\frac{1}{2}\left(\frac{N+1}{N} \log(N+1) - 2\log(2N) + \log(N)\right) . \quad (3.10)$$

A complexidade estatística fornece informação sobre organização, regularidade, memória e simetria do sinal. Sua medida ajuda a entender detalhes da dinâmica e a diferenciar regimes caóticos e estocásticos [14,23]. Assim, junto à entropia de Shannon, a complexidade se torna uma poderosa medida para caracterizar as funções de probabilidades associadas a sinais, como vemos na Figura 3.1.

Figura 3.1: Localização de três pinturas artísticas no plano entropia versus complexidade.



Fonte: Modificada de [24].

### 3.3 Metodologia simbólica de Bandt & Pompe

Para realizar o cálculo dos quantificadores  $H$  e  $C$  precisamos, de alguma forma, encontrar uma função de probabilidade associada ao sinal. Existem vários métodos que são usados para encontrar  $P$ , porém a maioria deles tem problemas para lidar com os ruídos que são encontrados nos sinais obtidos no mundo real. Por esse motivo, é necessário um pré-processamento complexo para eliminar esses ruídos antes de aplicar esses métodos [10]. Um problema é que nos sinais cerebrais o componente aleatório, ou seja o ruído, é importante para entender o funcionamento do sistema. Por esse e outros motivos, é proposto usar a metodologia simbólica de Bandt & Pompe, um método simples e eficiente que utiliza uma abordagem simbólica para analisar a série temporal obtida através do experimento eletrofisiológico.

Seja um sinal cerebral captado durante um intervalo  $T$ . A série temporal discreta associada a esse sinal é dada por:

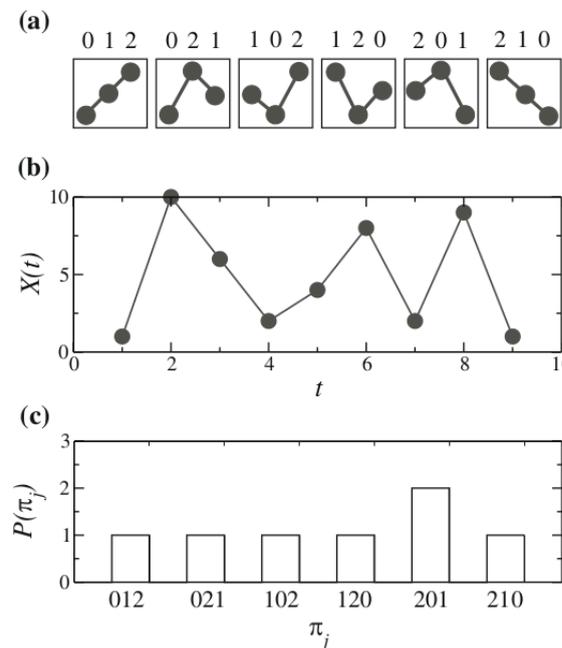
$$X(t) \equiv \{x_t; t = 1, 2, \dots, N\}, \quad (3.11)$$

onde  $N$  é a quantidade de pontos da série em todo o intervalo  $T$ . Para aplicar a metodologia de B&P precisamos definir dois parâmetros principais: 1) dimensão de imersão  $\mathcal{D}$  e 2) tempo de incorporação  $\tau$ .

A dimensão de imersão  $\mathcal{D}$  deve ser escolhida de tal forma a  $\mathcal{D} \in \mathbb{N}$  e  $\mathcal{D} \geq 2$ . Esse parâmetro está relacionado com a quantidade de pontos que serão usados

para gerar os símbolos que serão analisados. Essa quantidade de pontos vai determinar a quantidade de símbolos possíveis como sendo igual a  $\mathcal{D}!$ . Para  $\mathcal{D} = 3$ , temos que a quantidade de pontos que serão analisadas é igual a 3 e a quantidade de símbolos igual a 6. Os símbolos são uma representação visual de todas as maneiras que  $(0, 1, 2)$  podem ser ordenados, como visto na Figura 3.2a. A organização é realizada ao rearranjar os pontos em ordem crescente. Supondo que os três pontos analisados são  $(8, 1, 6)$ , temos que seus índices são  $(8 \rightarrow 0, 1 \rightarrow 1, 6 \rightarrow 2)$ . Agora reorganizando os pontos e seus índices temos  $(1, 6, 8)$  e  $(1, 2, 0)$  que é o quarto símbolo mostrado na Figura 3.2a.

Figura 3.2: Caracterizando a abordagem da informação simbólica: (a) os seis símbolos associados às permutações  $\pi_j$  para padrões ordinais de comprimento  $\mathcal{D} = 3$  e tempo de incorporação  $\tau = 1$  (b) Exemplo simples de uma série temporal dada por  $X(t) = \{1, 10, 6, 2, 4, 8, 2, 9, 1\}$ ,  $N = 9$  e (c) sua própria função de densidade de probabilidade não normalizada.



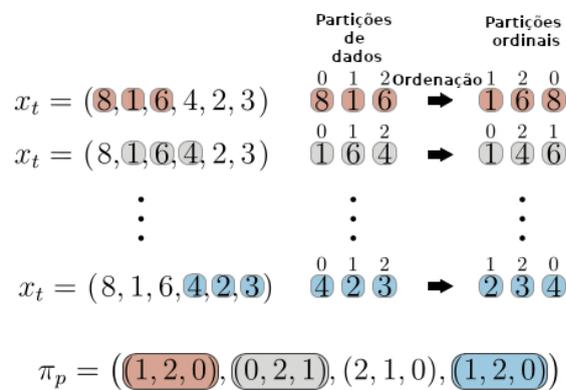
Fonte: Modificada de [17].

Para saber como escolher quais pontos da série serão analisados juntos, usamos o tempo de incorporação  $\tau$ . Para  $\tau = 1$ , analisaremos os pontos vizinhos. Ou seja, para  $\mathcal{D} = 3$  analisaremos a série de 3 em 3 pontos vizinhos até varrê-la completamente. Já para  $\tau = 2$ , estaremos analisando os pontos de tal forma a ser separado como  $(x_t, x_{t+2}, x_{t+4})$ . Logo, de forma geral para  $\tau \geq 1$  e  $\tau \in \mathbb{N}$ ,

analisamos a série em grupos que seguem  $(x_t, x_{t+\tau}, x_{t+\tau})$ , de tal forma a varrer toda a série. Com isso, podemos observar que o parâmetro  $\tau$  é ligado à correlação do sinal. Para sinais com correlação de longo alcance,  $\tau$  maiores podem ser mais relevantes para caracterizar o sinal.

Com os parâmetros escolhidos varremos todos os pontos da série temporal mostrada em 3.11 e encontramos a função de densidade de probabilidade  $P_{B\&P}$  a partir da frequência com que cada símbolo aparece na série (ver Figura 3.2c).

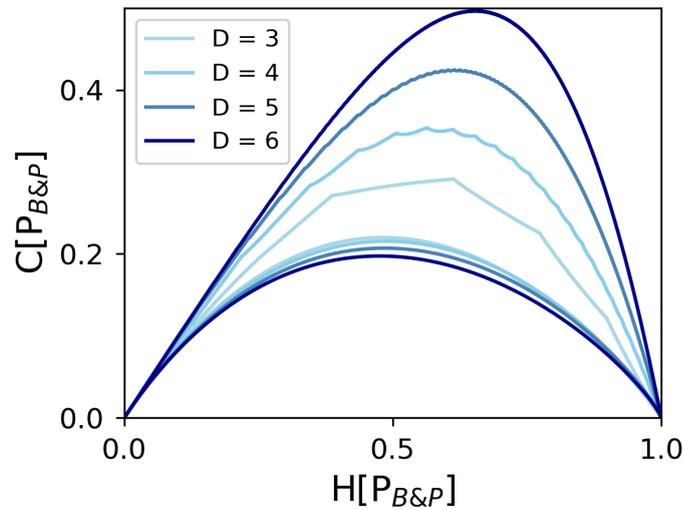
Figura 3.3: Ilustração do método B&P aplicado a uma série temporal e as sequências ordinais resultantes para incorporação dos parâmetros  $\mathcal{D} = 3$  e  $\tau = 1$ .



Fonte: Modificada de [24].

Ao encontrar  $P_{B\&P}$ , conseguimos encontrar H e C. Uma forma visual de representar o cálculo desses quantificadores para diferentes parâmetros é colocá-los em um plano H versus C, assim facilitando a comparação entre eles. Variando H de 0 a 1, conseguimos encontrar uma curva de C máxima e C mínima para cada  $\mathcal{D}$ , como observamos na Figura 3.4. Dado um certo  $\mathcal{D}$ , qualquer H e C encontrado deve estar entre essas curvas. O cálculo dessas curvas foi feito através da biblioteca Ordpy [24].

Figura 3.4: Curvas máxima e mínima para valores no plano entropia *versus* complexidade para  $\mathcal{D} = 3, 4, 5$  e  $6$ .



Fonte: Autor, 2024.

Para fins didáticos, geramos três séries temporais discretas, representada na Figura 3.5a, calculamos suas distribuições de probabilidade e entropia e complexidade. Para isso, utilizamos

- 1) Função linear com coeficiente angular positivo:

$$f(x) = 1.2x; \quad (3.12)$$

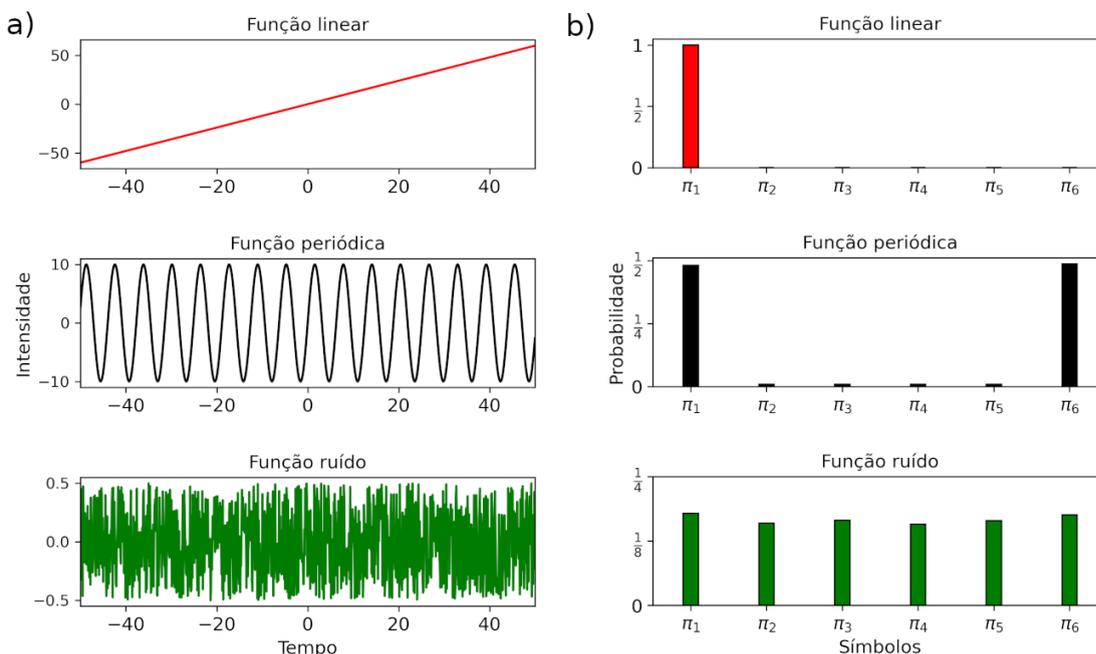
- 2) Função periódica com amplitude 10:

$$g(x) = 10 \sin(x); \quad (3.13)$$

3) Série ruidosa, onde para cada ponto temos um valor aleatório entre  $-0,5$  e  $0,5$ <sup>1</sup>. Em seguida, aplicamos B&P para  $\mathcal{D} = 3$  e  $\tau = 1$ , obtivemos as distribuições de probabilidade da Figura 3.5b.

<sup>1</sup> Calculada no python a partir da função `numpy.random.rand()` da biblioteca `numpy`.

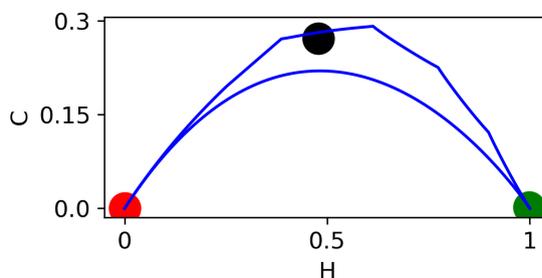
Figura 3.5: Exemplos da aplicação de B&P. (a) Comportamento das funções analisadas. (b) Densidade de probabilidade encontrada a partir de B&P para as funções analisadas.



Fonte: Autor, 2024.

Os símbolos no eixo horizontal dos gráficos mostrados na Figura 3.5b seguem a mesma ordem dos símbolos da Figura 3.2a. Notamos, que como a função linear só cresce, a frequência do símbolo que representa os pontos analisados como estando ordenados crescentemente domina os outros. Diferentemente, na função periódica há uma divisão na dominância entre os símbolos que representam crescimento e decrescimento puro. Já na função ruído, temos uma distribuição próxima da equiprovável, onde todos os símbolos têm uma frequência similar.

Figura 3.6: Entropia versus complexidade obtidas através de B&P para as funções da Figura 3.5.



Fonte: Autor, 2024.

Ao usar  $P_{B\&P}$  para encontrar os quantificadores de entropia e complexidade, obtemos os pontos dispostos na Figura 3.6, onde cada ponto é a representação da

entropia e da complexidade para uma das séries temporais gerais pelas funções acima. Notamos, que justamente para o sinal ruidoso a entropia é máxima e a complexidade é nula. Já para o sinal gerado pela função linear tanto a entropia como a complexidade são mínimas, função linear. Enquanto isso, para o sinal periódico, obtemos valores intermediários de entropia e complexidade. Diversas séries temporais obtidas a partir dos sinais cerebrais estão localizadas na região do plano CxH entre as séries periódicas e ruidosas , indicando a existência de componentes oscilatórias e aleatórias do sinal.

## 4 ALGORITMO PARA APLICAÇÃO DA METODOLOGIA SIMBÓLICA DE BANDT & POMPE

Para a aplicação da metodologia simbólica de Bandt & Pompe utilizamos o Python. Python é uma linguagem de programação aberta, gratuita e que facilita bastante o trabalho com os sinais cerebrais por ter uma grande quantidade de bibliotecas específicas para esse uso, além das bibliotecas mais gerais comumente usadas para trabalhar com matrizes, base de dados e cálculos matemáticos. Por ser uma das linguagens mais utilizadas, atualmente ocupando a posição de linguagem mais popular pelo índice TIOBE<sup>2</sup>, a maioria dos experimentos que fornecem base de dados abertas, disponibilizam-as de tal forma a ser compatível para leitura a partir do Python.

### 4.1 Cálculo dos quantificadores

Para o cálculo dos quantificadores, foi escrito um algoritmo baseado na biblioteca Ordpy [24] que está disponível no apêndice A. Essa biblioteca tem uma função para calcular a função de probabilidade de um sinal e calcular os seus quantificadores de entropia e complexidade. Dado um sinal cerebral captado durante um intervalo  $T$ , o algoritmo se baseia em analisar dois cenários: 1) Analisar a série discreta criada a partir dos sinais durante todo o intervalo  $T$ ; 2) Analisar a série discreta criada a partir dos sinais dividindo o intervalo  $T$  em um intervalo menor  $t'$  e o flutuando para analisar o intervalo total (Janelas flutuantes).

Seja um sinal cerebral captado durante um intervalo  $T$ . A série temporal discreta dele é dada por:

$$X(t) \equiv \{x_t; t = 1, 2, \dots, N\}, \quad (4.1)$$

onde  $N$  é a quantidade de pontos da série em todo o intervalo  $T$ . Para analisar essa série utilizando o segundo cenário selecionamos um intervalo  $t'$  da série  $X(t)$  e definimos uma nova série:

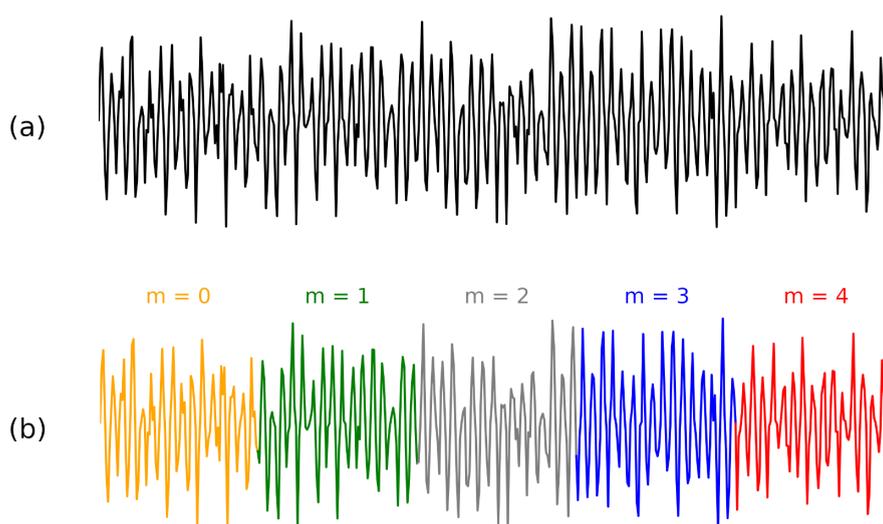
$$Y(t) \equiv \{y_t; t = 1 + passo \cdot m, 2 + passo \cdot m, \dots, n + passo \cdot m\}, \quad (4.2)$$

---

<sup>2</sup> Acessar <https://www.tiobe.com/tiobe-index>. Acesso em: 18 jun. 2024.

onde  $n$  é a quantidade de pontos dentro do intervalo  $t'$ , o  $passo$  é um parâmetro livre e  $m$  é uma variável inicialmente igual a 0. Definindo  $Y(t)$  calculamos os quantificadores e os armazenamos. Depois do armazenamento, mudamos o valor de  $m$  para  $m = m + 1$  e atualizamos o valor de  $Y(t)$ , calculamos os quantificadores, armazenamos e repetimos o mesmo processo enquanto  $n + passo \cdot m$  não é maior que  $N$ .

Figura 4.1: Representação dos sinais analisados em dois cenários. (a) Primeiro cenário: sinal inteiro onde sua série temporal tem  $N = 1000$ . (b) Segundo cenário: janela flutuante, onde pegamos e definimos  $passo = 200$  e com isso dividimos a série temporal que inicialmente tinha  $N = 1000$  em cinco séries temporais de  $N = 200$ .



Fonte: Autor, 2024.

O algoritmo do primeiro cenário foi feito de tal forma a receber de entrada o sinal organizado como uma matriz com  $N$  linhas e  $M$  colunas. A quantidade de linhas é referente a quantidade de pontos da série discreta do sinal. Já a quantidade de colunas é referente a quantidade de eletrodos que estão captando esses sinais. Ou seja, na primeira coluna temos o sinal para todo o intervalo  $T$  captado para o primeiro eletrodo. Além dos sinais o algoritmo também recebe mais 3 parâmetros, são eles: 1)  $\tau_{max}$  (tempo de incorporação máximo), o algoritmo vai retornar os quantificadores para todos os  $\tau$  de 1 até  $\tau_{max}$ ; 2)  $\mathcal{D}$  (dimensão de imersão), o algoritmo vai retornar os quantificadores para o  $\mathcal{D}$  informado; 3)  $Tarefas$ , aqui

colocamos todas as tarefas em uma lista. A maioria dos experimentos vão conter sinais para indivíduos realizando mais de um tipo de tarefa e com isso teremos uma matriz  $N \times M$  para cada tarefa. Ao receber os parâmetros e os sinais o algoritmo calcula os quantificadores e retorna uma matriz com as seguintes dimensões  $(1 \times (M + 1) \times Q_\tau \times Q_{tarefas} \times 2(H, C))$ , onde  $Q_\tau$  é a quantidade de  $\tau$  e  $Q_{tarefas}$  é a quantidade de tarefas e temos  $M + 1$  por conta que o algoritmo calcula os quantificadores para um sinal médio dado pela média dos  $M$  sinais. Com isso, ao final é obtido um valor de entropia e outro de complexidade para cada  $\tau$ , eletrodo e tarefa dos sinais apresentados.

Para o segundo cenário o algoritmo recebe o sinal organizado de maneira um pouco diferente, ele é dado por uma matriz de 3 dimensões  $(Q \times N \times M)$ . A dimensão a mais está ligada à quantidade de janelas criadas a partir do método descrito no segundo parágrafo deste tópico. Além desses sinais, o algoritmo vai precisar dos mesmos parâmetros descritos no primeiro cenário. Ao receber os parâmetros e os sinais o algoritmo calcula os quantificadores e retorna uma matriz com as seguintes dimensões  $(1 \times (M + 1) \times Q_\tau \times Q_{tarefas} \times 2(H, C)) \times Q$ . Com isso, ao final é obtido um valor de entropia e outro de complexidade para cada  $\tau$ ,  $Q$ , eletrodo e tarefa dos sinais apresentados.

## 4.2 Análise dos quantificadores

Ao realizar todos os procedimentos descritos no capítulo 4.1, obtemos centenas de valores de entropia e centenas de valores de complexidade. Um para cada combinação de parâmetros escolhida. Para avaliar numericamente os quantificadores calculados a partir de duas condições diferente, A e B, e conseguir quantificar diferença entre eles, definimos duas quantidades: 1) A distância entre A e B,  $d_{A,B}$  dada por

$$d_{A,B} = \sqrt{(H_A - H_B)^2 + (C_A - C_B)^2}; \quad (4.3)$$

2) A assimetria da entropia [17]

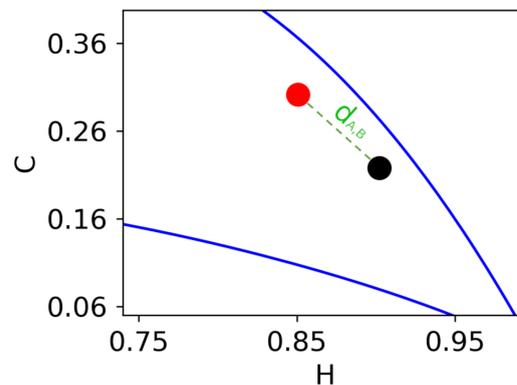
$$A[H_A, H_B] = \frac{H_A - H_B}{H_A + H_B} \quad (4.4)$$

e a assimetria da complexidade

$$A[C_A, C_B] = \frac{C_A - C_B}{C_A + C_B}. \quad (4.5)$$

A distância  $d_{A,B}$  representa a distância euclidiana dos quantificadores de entropia e complexidade de A comparado aos quantificadores de entropia e complexidade de B, no plano H *versus* C. A representação dessa quantidade está sendo mostrada na Figura 4.2. Para valores de  $d_{A,B}$  alto significa que conseguimos com mais facilidade descobrir que é A e quem é B no plano H *versus* B, e para  $d_{A,B}$  baixo significa que há uma dificuldade de fazer essa distinção.

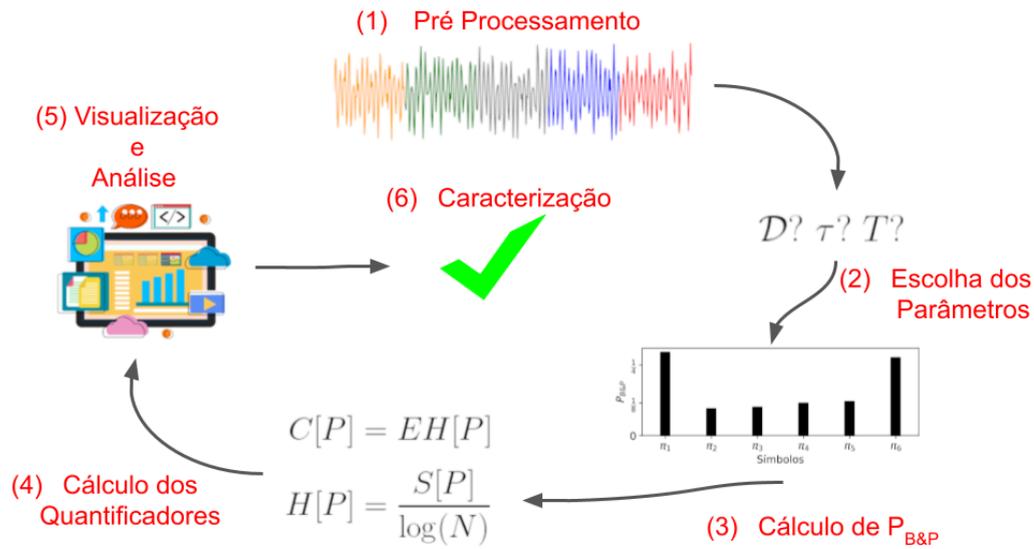
Figura 4.2: Representação de  $d_{A,B}$  no plano entropia *versus* complexidade.



Fonte: Autor, 2024.

Já a medida de assimetria vai nos informar qual dos quantificadores têm um valor maior ou menor, e informando a intensidade dessa diferença. Exemplificando, para  $A[H_A, H_B] > 0$ , sabemos que a entropia de A é maior que a entropia de B. Já para  $A[H_A, H_B] < 0$ , sabemos que a entropia de A é menor que a entropia de B. E para  $A[H_A, H_B] \approx 0$ , significa que a entropia de A e B tem valores parecidos.

Figura 4.3: Pipeline para a caracterização usando B&P de um sinal.



Fonte: Autor, 2024.

Com isso, podemos resumir o processo de aplicar B&P em 6 etapas, como representando na Figura 4.3: 1) pré Processamento, momento em que organizamos os sinais e obtemos as séries temporais discretas; 2) escolha dos parâmetros, momento em que escolhemos os parâmetros do método de B&P; 3) cálculo de  $P_{B\&P}$ , momento em que calculamos a função de distribuição de probabilidade de B&P; 4) cálculo dos quantificadores, aplicação de  $P_{B\&P}$  para encontrar  $H[P]$  e  $C[P]$ ; 5) visualização e Análise, observar os quantificadores para os diversos parâmetros e situações e 6) caracterização, a partir do passo 5 encontrar os melhores parâmetros e o usar para algum objetivo.

## 5 HUMANOS REALIZANDO UMA TAREFA VISUAL COGNITIVA

O experimento analisado neste capítulo envolveu duas tarefas cognitivas visuais diferentes nas quais os sujeitos se engajaram com estímulos exibidos em um monitor LCD posicionado a 1 metro de distância. A tarefa de busca ativa compreendeu 120 tentativas (comumente chamado de trials em inglês), cada uma consistindo de estímulos de busca visual de 2.000 ms (referidos daqui em diante como tentativas de busca) intercaladas com intervalos entre estímulos (ISIs) de 2.000 ms, durante os quais a tela permaneceu em branco (uma simples tarefa de espera referida daqui em diante como tentativas de tela branca). Na Figura 5.1a temos um exemplo da sequência observada de tipos de tentativas intercaladas na tela.

Cada estímulo de busca visual compreendia três elementos: (1) um conjunto de caixas coloridas de 5 linhas por 4 colunas, cada uma medindo 1 cm por 1 cm, (2) uma estrela branca posicionada no centro de uma dessas caixas, e (3) uma seta preta (medindo 2 cm por 1 cm) situada 1,5 cm à direita da caixa mais à direita na linha do meio. A colocação da estrela e da seta dentro das caixas coloridas foi aleatória, com a seta apontando em uma das quatro direções cardeais: “direita” “esquerda”, “para cima” ou “para baixo”. Os participantes são encarregados de identificar a cor da caixa adjacente à estrela na direção indicada pela seta. Por exemplo, na Figura 5.1a, os dois exemplos de tarefas visuais devem ser respondidos corretamente como “preto” e “preto”. E depois, repetindo a tarefa por 120 tentativas (30 tentativas para cada direção) [25].

### 5.1 Aquisição dos dados

Analisamos dados disponíveis gratuitamente em uma base de dados aberta<sup>3</sup> de 67 eletrodos eletrocorticográficos (ECoG) implantados em cinco seres humanos (chamados na documentação de JT, JM, RN, RR e WC) durante um paradigma cognitivo visual [25]. Declaração de ética: Todos os pacientes participaram de forma puramente voluntária, após fornecerem consentimento informado por escrito, sob protocolos experimentais aprovados pelo Conselho de Revisão Institucional da Universidade de Washington (#12193). Todos os dados dos pacientes foram

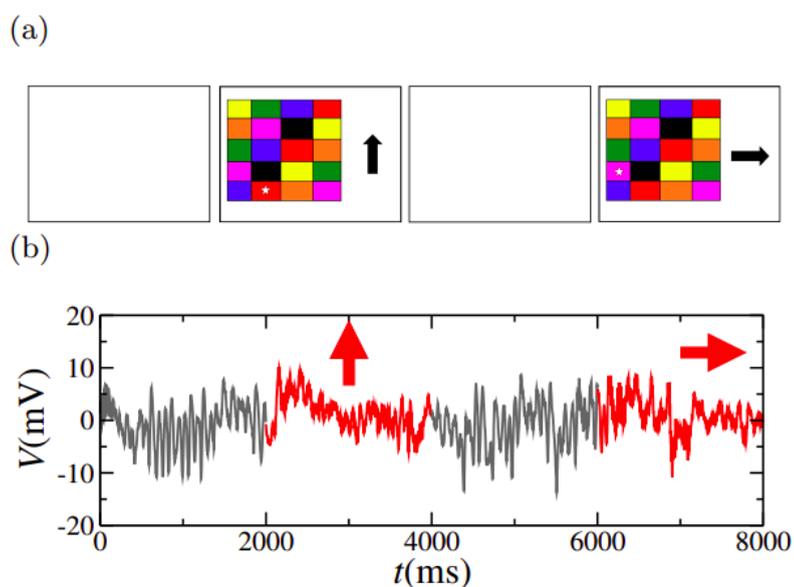
---

<sup>3</sup> Disponível em: <https://exhibits.stanford.edu/data/catalog/zk881ps0522>. Acesso em: 18 jun. 2024.

anonimizados de acordo com o protocolo IRB, de acordo com o mandato da HIPAA. Esses dados apareceram originalmente no manuscrito “Modulação dinâmica da atividade da população local por fase de ritmo no córtex occipital humano durante uma tarefa de busca visual” (traduzido do inglês, “Dynamic modulation of local population activity by rhythm phase in human occipital cortex during a visual search task”)[25].

Grades e tiras subdurais compostas por eletrodos de platina foram estrategicamente posicionadas sobre as regiões do córtex frontal, parietal, temporal e occipital para facilitar a observação clínica prolongada e a localização precisa dos focos convulsivos. Os eletrodos, com diâmetro de 4 mm e distância entre eletrodos de + 1 cm, foram utilizados para coleta de dados. Os potenciais foram amostrados a uma taxa de 1000 Hz (um ponto a cada 1 ms) em relação a uma referência de couro cabeludo e terra. Esses sinais foram submetidos a um filtro passo de banda imposto pelo instrumento, variando de 0,15 a 200 Hz.

Figura 5.1: Representação do experimento. (a) Ilustração da tela durante o tempo do experimento: 2.000 ms de períodos de espera observando uma tela branca alternada com 2.000 ms de uma tarefa de busca visual ativa. (b) Sinal da atividade registrada de um eletrodo exemplar na área occipital durante as duas telas em branco e os dois períodos de tarefa ativa mostrados em (a).

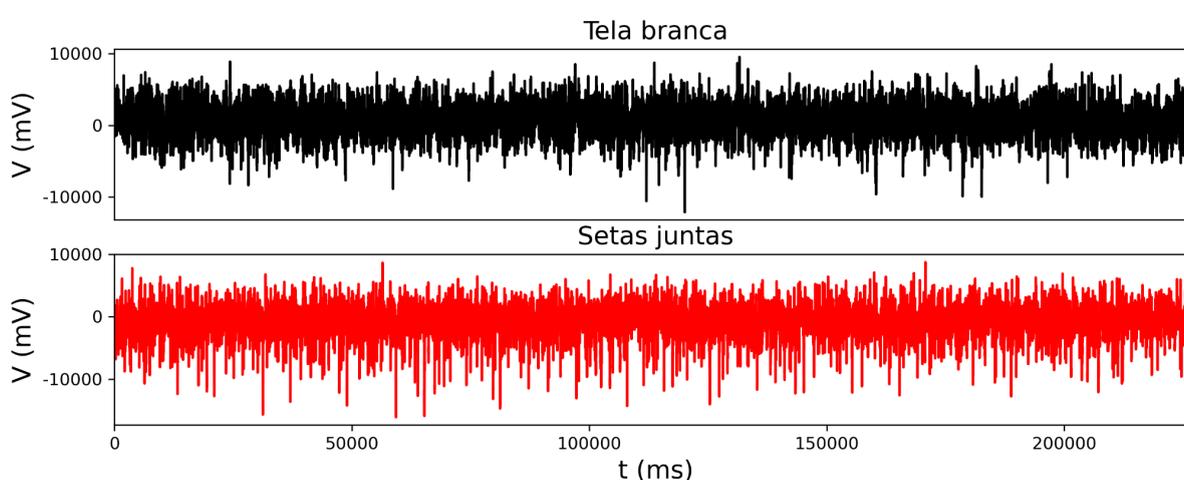


Fonte: Retirada de [2].

## 5.2 Organização dos dados

Para trabalhar com esses dados escolhemos separar os sinais de duas formas como descrito no capítulo 4. Inicialmente o intervalo inteiro de 2000 ms referente às 120 tentativas de busca e concatenamos em uma série temporal única com 240000 pontos. Com isso, criamos uma série temporal para cada eletrodo. Da mesma maneira tratamos os sinais das 120 tentativas de tela branca. Desta forma, ao final obtemos duas séries temporais por eletrodos, uma para a tarefa de busca e a outra para a tarefa de tela branca.

Figura 5.2: Representação dos sinais concatenados para o eletrodo 1 do paciente JT, pegando todo o intervalo(primeiro método de organizar os dados).



Fonte: Autor, 2024.

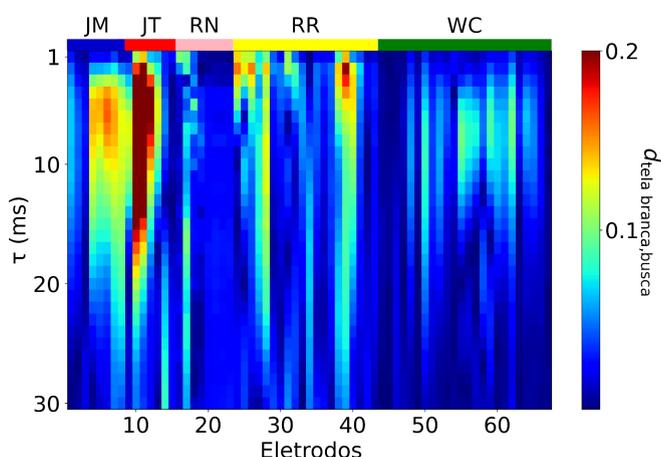
A outra forma de tratar os dados foi usar o conceito de janelas flutuantes, para isso escolhemos trabalhar com intervalos de 200 ms e um passo de 10 ms. Com esses parâmetros de entradas dividimos o nosso intervalo inicial de 2000 ms em 181 intervalos de 200 ms. No qual, concatenamos os intervalos de 200 ms de todas as 120 tentativas para cada tarefa. Assim, ao fim deste processo criamos 181 séries temporais discretas para a tarefa de busca e 181 séries temporais discretas para a tarefa de tela branca.

### 5.3 Resultados

Depois de organizar os dados foi realizado os cálculos dos quantificadores de entropia e complexidade usando a metodologia simbólica de Bandt & Pompe para cada série temporal discreta. Para isso escolhemos como 6 a dimensão de imersão  $\mathcal{D}$  e variamos  $\tau$  de 1 ms até a 30 ms.

Como queremos caracterizar os sinais, tentando observar diferenças significativas entre os dois tipos de tarefas, fizemos o cálculo da distância euclidiana no plano de entropia *versus* complexidade. Para cada entropia e complexidade ligado a um  $\tau$  e uma série temporal temos uma distância. A partir disso, considerando o primeiro cenário de organização dos dados obtemos a Figura 5.3: onde mostramos as distâncias entre a tarefa de tela branca e de busca para cada eletrodo e para cada  $\tau$ .

Figura 5.3: Mapa de calor representando a distância euclidiana entre a tarefa de tela branca e a tarefa de pesquisa no plano complexidade *versus* entropia, para todos os 67 eletrodos e  $\tau$  de 1 ms até 30 ms.



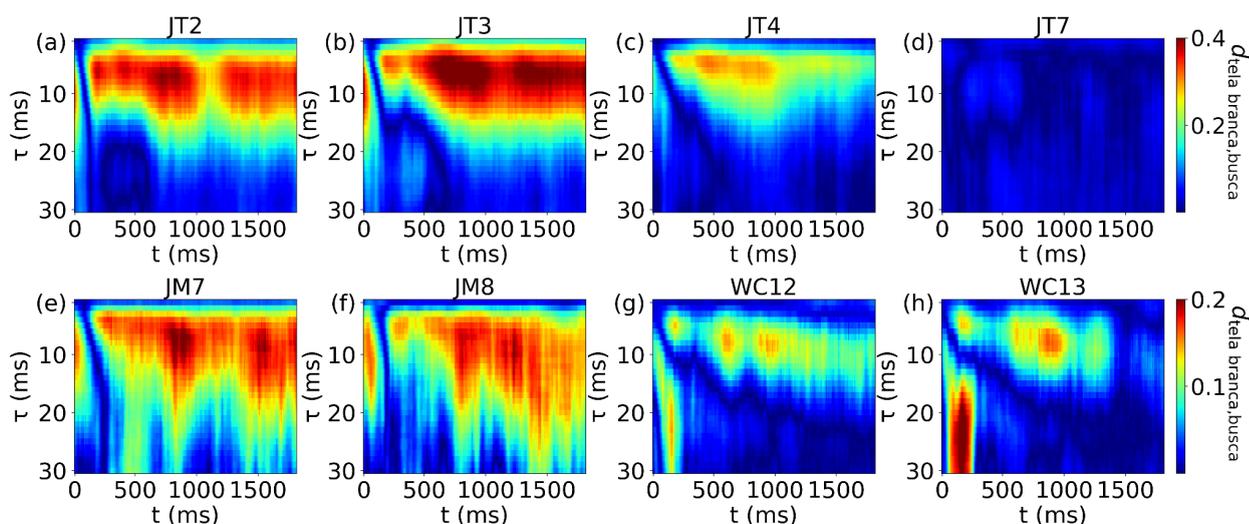
Fonte: Autor, 2024.

Ao observar a Figura 5.3 notamos que todos os pacientes têm eletrodos que apresentam distâncias próximas a 0,2. Porém, notamos que para os pacientes JM e JT, a intensidade e proporção em que esses valores mais altos aparecem é maior que para os outros pacientes. Em princípio, notamos que para  $\tau$  entre 3 ms e 12 ms encontramos os valores mais elevados da distância, esses valores aparecem de forma mais elevada.

Para investigar mais a fundo o que está ocorrendo durante o experimento procuramos olhar para as séries temporais discretas criadas a partir das janelas flutuantes. Com os quantificadores calculados encontramos a distância da mesma forma que fizemos para quando estávamos olhando para o intervalo inteiro. Porém, diferentemente da Figura 5.3 que temos um mapa de calor em duas dimensões, quando trabalhamos com essas novas séries temporais agora adicionamos mais uma dimensão. Dimensão extra essa ligada a quantidade de sub-intervalos dentro

dos 2000 ms, aqui 181 como dito anteriormente. Ao calcular essas distâncias, notamos que para alguns eletrodos há uma separação bem definida entre as tarefas de busca e de tela branca em alguns intervalos e  $\tau$ 's.

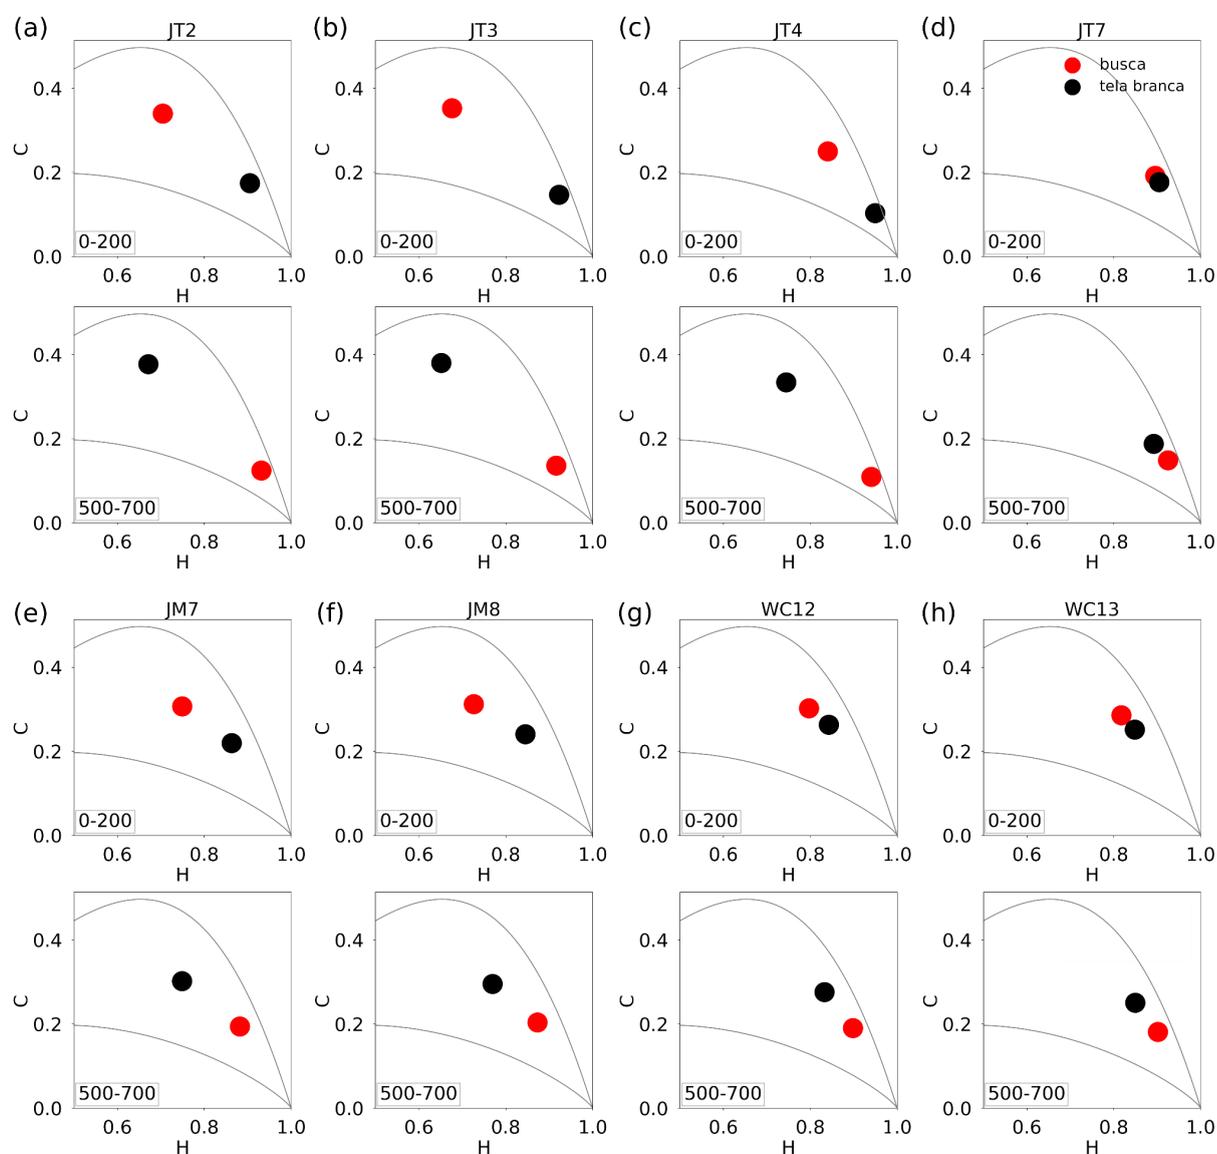
Figura 5.4: Mapa de calor representando a distância euclidiana entre a tarefa de tela branca e a tarefa de busca no plano complexidade *versus* entropia em cada tarefa para 8 eletrodos ilustrativos de 3 pacientes diferentes. No eixo vertical mostramos  $\tau$  e no eixo horizontal mostramos as janelas de tempo de 2ms iniciando a cada 10ms.



Fonte: Autor, 2024.

A partir dessas informações ilustramos o comportamento para  $\tau = 6$  ms de 8 eletrodos na Figura 5.4. Nesta figura mostramos os eletrodos de 3 pacientes, entre eles o paciente JT que apresentou mais eletrodos com distâncias mais elevadas e escolhemos colocar um eletrodo sem essa atividade por fins de comparação. Ao observar os eletrodos da figura, notamos que há um comportamento similar para  $\tau$  entre 3 ms e 12 ms. Uma pequena janela onde a distância que tinha valores próximo de 0,4 para JT e próximo de 0,2 para JM e WC acaba assumindo valores próximos a 0. Esse comportamento fez com que olhássemos com mais cuidado para esses intervalos, e para isso resolvemos visualizar os quantificadores, para  $\tau = 6$  ms e intervalos de 0 ms até 200 ms e 500 ms até 700 ms, no plano entropia versus complexidade, Figura 5.5.

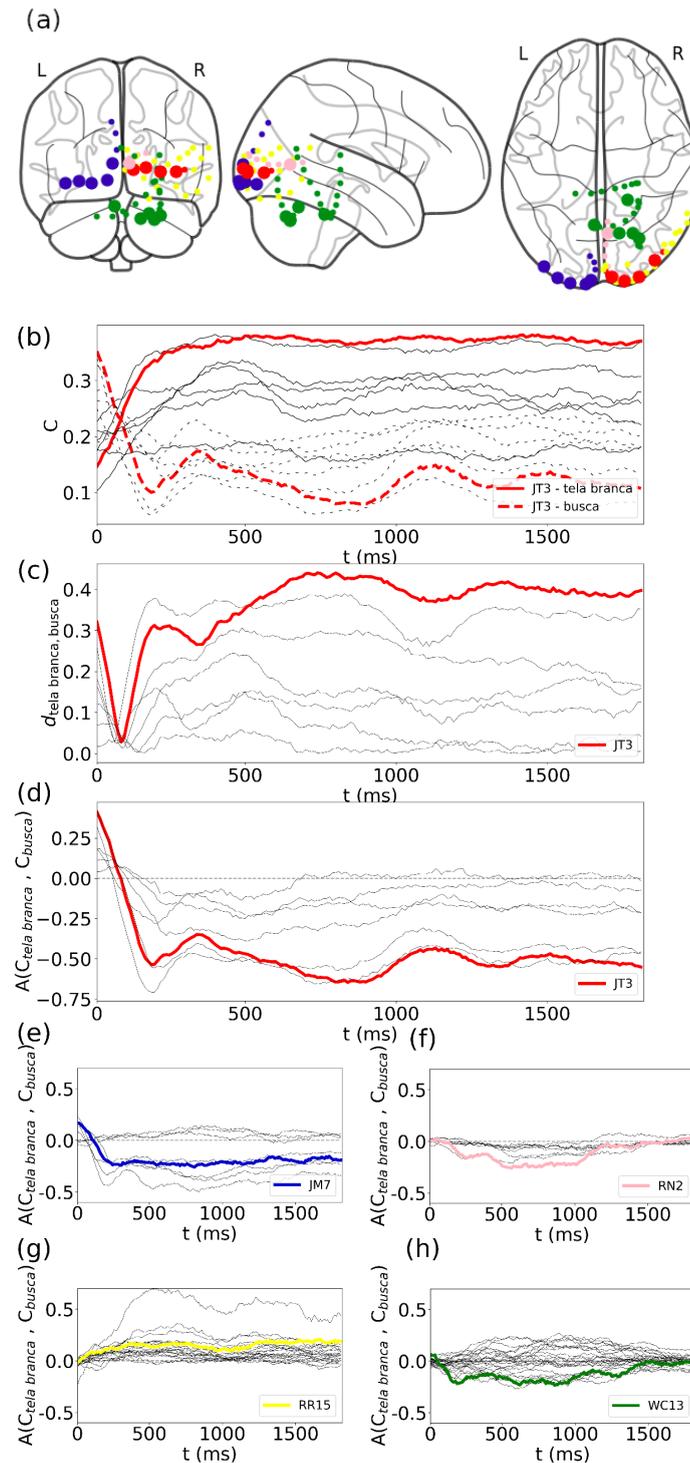
Figura 5.5: Caracterizando complexidade e entropia para ambas as condições no plano complexidade *versus* entropia em dois momentos distintos das tentativas: 0 a 200ms e 500ms a 700ms. (a) - (h) O plano de complexidade *versus* entropia para os 8 canais ilustrativos mostrados na Figura 5.4.



Fonte: Autor, 2024.

Na Figura 5.5 observamos um comportamento similar para todos os eletrodos, com exceção do JT7 escolhido como contraponto. Inicialmente o paciente que está esperando a informação na tela, ou seja, está visualizando uma tela branca (ponto preto no plano), tem uma entropia maior e complexidade menor que o mesmo paciente visualizando a informação (ponto vermelho no plano) na tela e tendo que realizar a tarefa relacionada com a informação. Porém, depois de um tempo ocorre a inversão na posição da entropia e complexidade dos pontos no plano.

Figura 5.6: Caracterizando diferentes tipos de atividade dos eletrodos para  $\tau = 6$  ms. (a) Localização de todos os 67 canais de cinco sujeitos (separados pelas cores) em um mapa cerebral padrão. Pontos maiores indicam comportamento semelhante ao canal JT3. (b) Complexidade  $C_{busca}$  e  $C_{tela\ branca}$  e (c) distância  $d_{tela\ branca, pesquisa}$  para todos os eletrodos do paciente JT. (d)-(h) Assimetria de complexidade  $A(C_{tela\ branca}, C_{busca})$  para todos os eletrodos de cada paciente. Os canais podem ser separados em três grupos: valores positivos de assimetria, valores negativos ou valores próximos de zero durante a maior parte do intervalo. Um eletrodo ilustrativo para cada paciente é destacado.



Fonte: Autor, 2024.

A partir da Figura 5.6b conseguimos observar essa inversão para a complexidade que é representada pelo momento em que a linha tracejada se encontra com a linha contínua. Uma outra informação que conseguimos adquirir dessa figura é que a complexidade fica mais instável depois da inversão até o final do intervalo de 2000 ms. O vale que encontramos na Figura 5.6c fortalece ainda mais essa leitura. Agora visualizando a assimetria da complexidade da tela branca com a busca, Figuras 5.6d, 5.6e, 5.6f, 5.6g e 5.6h. Podemos notar que esse comportamento acontece para vários eletrodos, principalmente para JT e JM. A assimetria maior que zero nos diz que a complexidade da busca é maior que a da tela branca. Enquanto que a assimetria menor que zero representa situações em que a complexidade da tela branca é maior que a da busca. Quando a assimetria de um eletrodo fica próxima de zero significa que a complexidade dos dois casos comparados são similares. Ou seja, essas figuras nos dão a informação que tem eletrodos que não obedecem esse comportamento de inversão dos quantificadores.

Em resumo, mostramos que usar o quantificador entropia de Shannon e o quantificador complexidade estatística juntos no plano de entropia *versus* complexidade, encontrados a partir de B&P, são uma ferramenta útil para caracterizar sinais intracranianos de humanos realizando tarefas cognitivas complexas. Usando dados de ECoG, a partir de uma base de dados aberta, mostramos que somos capazes distinguir os períodos de espera da tela branca dos períodos da tarefa de busca visual e inferir escalas de tempo relevantes para esses processos. Também é possível determinar regiões corticais que apresentam diferenças mais pronunciadas entre as duas tarefas cognitivas. Além disso, caracterizamos a atividade cerebral referente a processos específicos ao longo de diferentes intervalos de tempo durante as tarefas.

## 6 MACACOS REALIZANDO UMA TAREFA MOTORA

Os dados analisados neste capítulo foram gerados a partir de dois macacos treinados para realizar uma tarefa motora de alcançar e agarrar uma alavanca. Esta tarefa envolve o macaco partindo de uma posição de repouso, pegando uma alavanca e sendo capaz de agarrá-la de duas maneiras possíveis. A primeira, chamada de pegada lateral (SG), envolve colocar a ponta do polegar e a superfície lateral dos demais dedos nos lados direito e esquerdo da alavanca, respectivamente. A segunda é chamada de pegada de precisão (PG) e requer a colocação das pontas do indicador e do polegar em uma ranhura nos lados superior e inferior da alavanca, respectivamente. Ambas as pegadas estão representadas na Figura 6.1a.

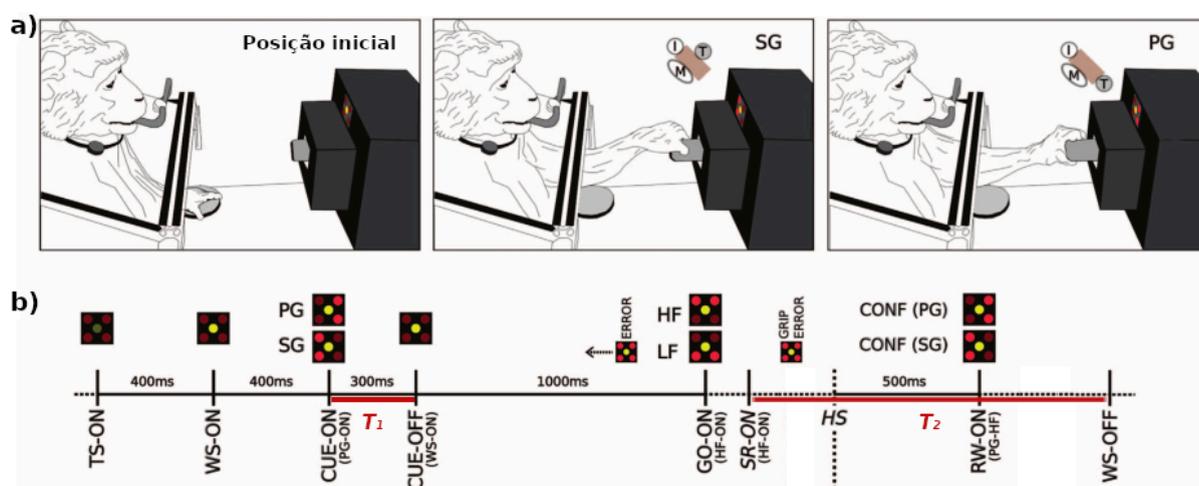
Após agarrar a alavanca, o macaco deve puxá-la com duas forças possíveis: força alta (HF) ou força baixa (LF). Assim, ao final da tarefa, o macaco terá realizado uma das quatro combinações possíveis: SG-HF, SG-LF, PG-HF e PG-LF. O macaco foi treinado para determinar qual das quatro combinações deveria realizar com base em informações visuais. Cada ação concluída pelo macaco é chamada de tentativa e, após o treinamento, foi realizada uma sessão onde foram capturados os sinais. O passo a passo de cada tentativa está na Figura 6.1b, onde em CUE-ON o macaco recebe a informação de qual tipo de pegada tem que realizar e em GO-ON a informação do tipo de força que deve fazer. Outro momento importante é o do SR-ON, momento no qual o macaco vai realizar a ação propriamente dita.

### 6.1 Aquisição dos dados

Os dados experimentais da série temporal para este estudo foram obtidos de um banco de dados de acesso aberto. Todos os detalhes da aquisição estão descritos no artigo [26]. O experimento conduzido para adquirir esses dados envolveu o treinamento de macacos Macaco L e Macaco N, para realizar uma tarefa motora de alcançar e agarrar. Para medir as atividades elétricas do cérebro de ambos os macacos, um conjunto Utah (Blackrock Microsystems, Salt Lake City, UT, EUA) foi implantado no córtex motor contralateral à mão ativa. O número de neurônios únicos capturados por esta matriz é 93 para Monkey L e 156 para Monkey N. Em ambos os casos, sinais neuronais "brutos" (amostrados em 30 kHz e filtrados

por passagem de banda ampla para 0,3 Hz a 7,5 kHz) foram capturados de 96 eletrodos. No banco de dados, estavam disponíveis dois potenciais de campo locais (LFPs), um para cada macaco. Para Monkey L, o LFP foi amostrado a 1 kHz simultaneamente com o sinal "bruto". No entanto, para Monkey N, foi realizada uma redução da resolução online (hardware) para aquisição de LFP.

Figura 6.1: Representação do passo a passo do experimento. (a) Representação visual dos movimentos do macaco. (b) Representação da informação visual dada ao macaco e dos momentos contido em uma tentativa.



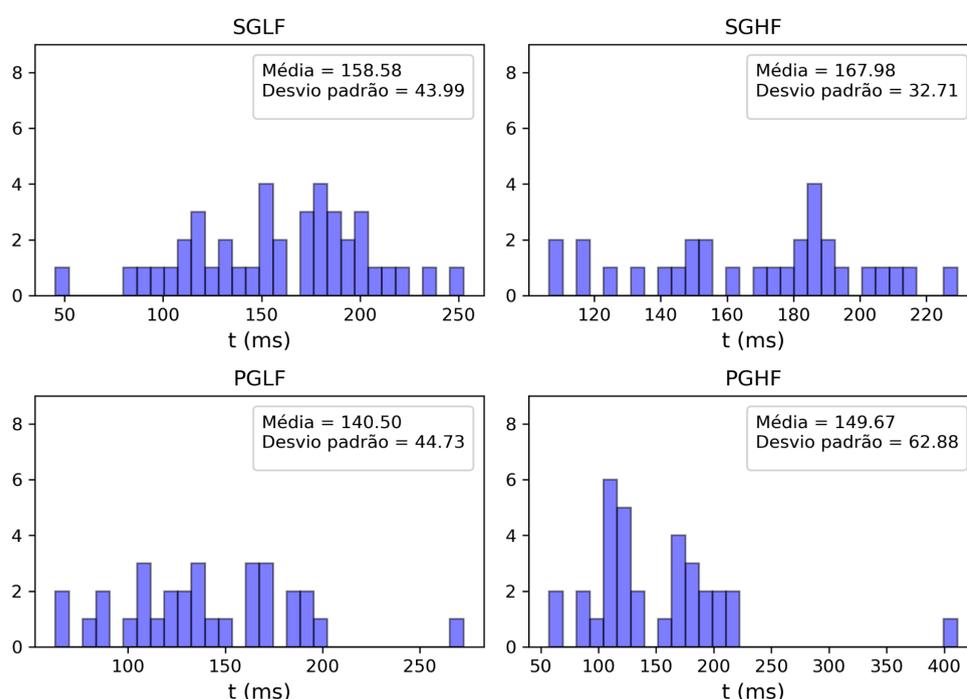
Fonte: Modificada de [26].

## 6.2 Organização dos dados

Aqui estudaremos dois momentos descritos na Figura 6.1b. O momento após o LED representar o marcador CUE-ON, onde o macaco recebe informações sobre o tipo de pegada que deverá realizar em breve, e o momento após o marcador SR-ON, que é justamente quando o macaco passa a agir. Como no primeiro momento os macacos não estão realizando nenhuma tarefa motora, nosso objetivo é observar se existem valores de entropia e complexidade semelhantes para séries temporais do mesmo tipo de pegada e valores significativamente distintos para séries temporais de pegadas diferentes. Isto caracteriza os sinais sem as atividades motoras do macaco. No segundo momento, haverá movimento mecânico, e o macaco já terá todas as informações, ou seja, já saberá qual tarefa deve realizar. Investigaremos os valores de entropia e complexidade das quatro tarefas, observando se existe uma diferença considerável entre elas e suas características.

Inicialmente, consideramos calcular um momento do marcador GO-ON até o marcador SR-ON, onde o macaco receberia a informação sobre qual força aplicar e ficaria em repouso, semelhante ao primeiro momento. Porém, conforme mostrado na Figura 6.2, não há uma separação uniforme entre esses marcadores. Essa falta de uniformização dos dados nesse intervalo gera a impossibilidade dessa análise sem pegar uma parte do sinal referente a o movimento dos macacos.

Figura 6.2: Histograma referente a separação temporal entre o marcador SR-ON e GO-ON.

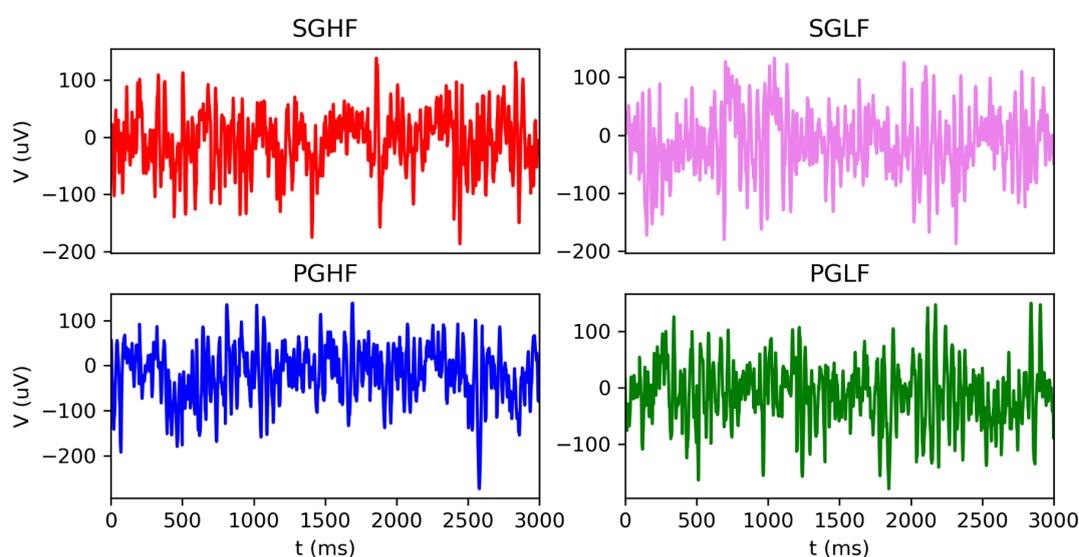


Fonte: Autor, 2024.

Para a análise desses dois momentos, CUE-ON e SR-ON, separamos os dados de duas formas como mostrado no capítulo 4. Na primeira forma pegamos os sinais referentes ao intervalo iniciado em CUE-ON e finalizado em CUE-OFF (momento onde a informação visual de qual tipo de pegada realizar é encerrada). Na segunda etapa utilizamos os sinais referentes ao intervalo iniciado em SR-ON e e finalizado em WS-OFF (momento onde a tentativa é encerrada). Note que nos intervalos após CUE-ON o macaco só tem informação sobre o tipo de pegada: PG ou SG. A informação sobre a força (HF ou LF) ainda não foi dada. Para o macaco N foram disponibilizadas 142 tentativas realizadas de forma correta e para o macaco L 135 tentativas. Pegamos os sinais referentes a cada tentativa e concatenamos,

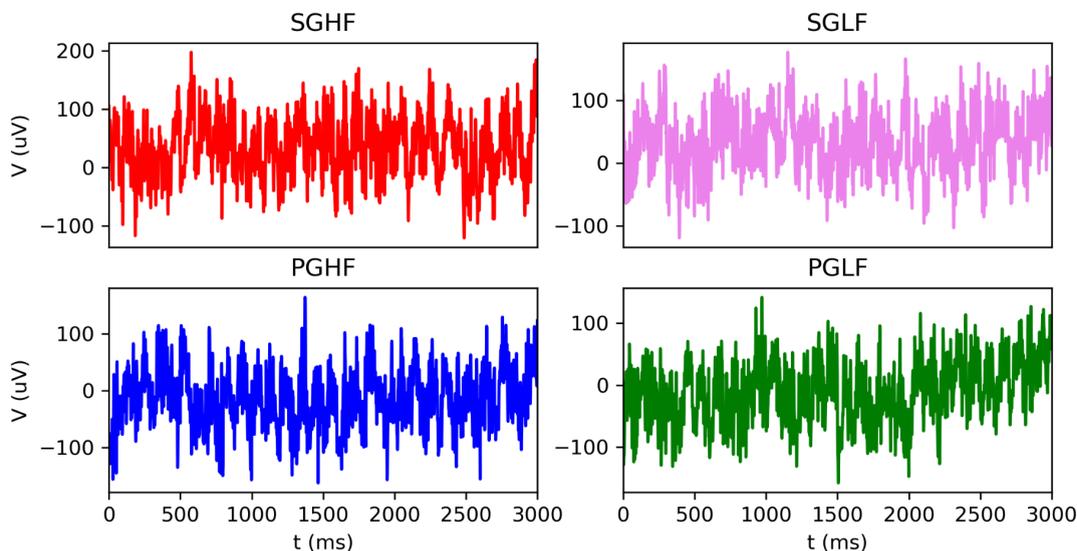
separados por macaco, tipo de pegada e início. Assim ao final obtivemos para cada macaco e cada eletrodo 8 séries temporais discretas: 4 para os intervalos iniciados em CUE-ON e 4 para os intervalos iniciados em SR-ON, vemos uma representação desta separação na Figura 6.3 e na Figura 6.4. No entanto, para os intervalos iniciados em CUE-ON, tanto SGHF como SGLF deveriam ser estatisticamente equivalentes, assim como PGHF e PGLF visto que a informação sobre a força que deve ser feita não é conhecida.

Figura 6.3: Representação dos sinais elétricos do Macaco L de todas as tentativas iniciadas em CUE-ON (pegando todo o intervalo até CUE-OFF) separadas por tipo e concatenada. Limite do eixo x colocado em 3000 ms para representação .



Fonte: Autor, 2024.

Figura 6.4: Representação dos sinais elétricos do Macaco L de todas as tentativas iniciadas em SR (pegando todo o intervalo até WS-OFF) separadas por tipo e concatenada. Limite do eixo x colocado em 3000 ms para representação .



Fonte: Autor, 2024.

Para a segunda forma de organizar os dados utilizamos intervalos de 100 ms e definimos um passo de 10 ms. Uma característica desse experimento é a de que cada tentativa tem um tempo de duração diferente no intervalo definido de SR-ON até WS-OFF. Com isso, pegamos e flutuamos com o passo até que chegasse no fim do intervalo com menor tempo de duração de todas as tentativas. Ao fazer essas considerações obtivemos para o intervalo CUE-ON até CUE-OFF uma quantidade de 21 e 20 janelas para o macaco L e N, respectivamente. E para o intervalo SR-ON até WS-OFF uma quantidade de 65 e 101 janelas para o macaco L e N, respectivamente. Para cada janela fazemos o mesmo processo da primeira forma de organizar os dados, assim elevando consideravelmente a quantidade de séries temporais discretas obtidas. Para o intervalo iniciado em CUE-ON criamos para cada eletrodo 84 e 80 séries para o macaco L e N, respectivamente. Para o intervalo iniciado em SR-ON criamos para cada eletrodo 260 e 404 séries para o macaco L e N, respectivamente. Uma observação é que para todos os dois casos fizemos uma separação extra levando em conta um sinal médio, que é resultado da média dos sinais de todos os eletrodos. Desta forma, temos ao final 97 séries temporais (uma para cada um dos 96 eletrodos e a última sendo o valor da média de todos os eletrodos).

### 6.3 Resultados

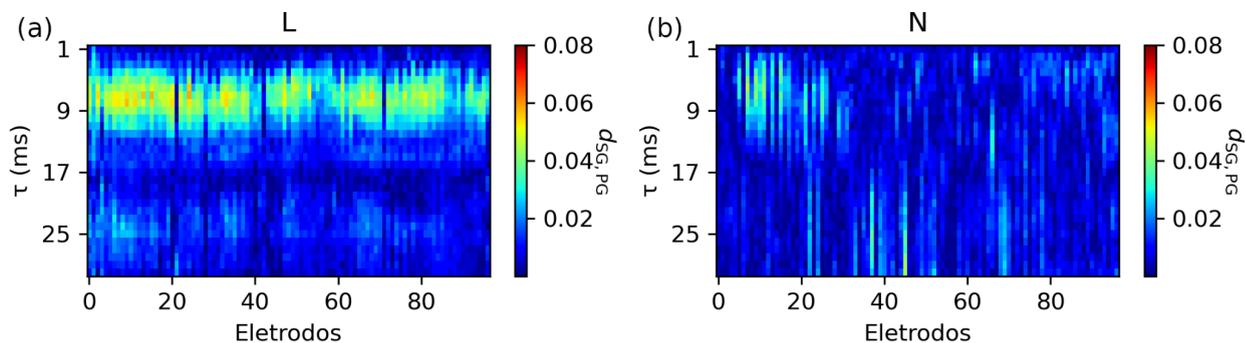
Depois de organizar os dados foram realizados os cálculos dos quantificadores de entropia e complexidade usando a metodologia simbólica de Bandt & Pompe. Para isso escolhemos como 6 a dimensão de imersão  $\mathcal{D}$  e variamos  $\tau$  de 1 ms até a 30 ms. Os cálculos foram realizados da mesma maneira para ambos intervalos CUE-ON (intervalo definido de CUE-ON até CUE-OFF) e SR-ON (intervalo definido de SR-ON até WS-OFF). Porém, por conta da vastidão de informação e natureza distintas dos intervalos iremos mostrá-los separadamente.

#### 6.3.1 CUE-ON: distinguindo o tipo de pegada: pegada lateral (SG) ou pegada de precisão (PG)

Este intervalo é justamente o intervalo onde a informação do tipo de pegada que o macaco terá que realizar no futuro é apresentada para ele. Desta forma, é intuitivo imaginar que não deveria haver diferença estatística significativa entre os sinais das tarefas SG-HF e SG-LF, e também dos sinais das tarefas PG-HF e PG-LF. Com isso, fizemos o cálculo da distância euclidiana no plano de entropia *versus* complexidade entre a média da entropia e complexidade de SG-HF e SG-LF (que chamamos somente de SG) e a média da entropia e complexidade de PG-HF e PG-LF (que chamamos somente de PG). Ao fazer isso, notamos visualizando a Figura 6.5 que para o cálculo desses valores levando em conta todo o intervalo (primeira forma de organizar os dados) a distância entre os pontos do plano de SG e PG são mais elevadas para  $\tau$  próximo de 8 ms, para o macaco L. Também, observamos que para o macaco N essa distância acaba não sendo observada para a maioria dos eletrodos, diferentemente do que ocorre para o macaco L.

Essa variância entre o comportamento dos macacos pode ser causada pelo método de captura dos sinais. Os dados LFP como dito anteriormente foram capturados de forma distintas, e junto ao método invasivo de capturar os sinais serem muitos sensíveis escolhemos analisar mais a fundo nesta dissertação somente os resultados para o macaco L.

Figura 6.5: Mapa de calor para a distância entre SG e PG,  $\tau$  versus eletrodo. (a) Para o macaco L. (b) Para o macaco N.

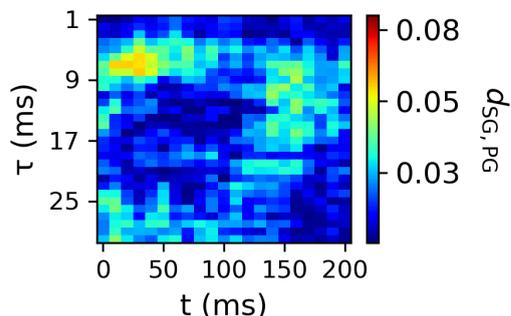


Fonte: Autor, 2024.

Ao observar a Figura 6.5a notamos um comportamento similar para todos os eletrodos, o que é confirmado ao visualizar a última linha vertical do mapa de calor, referente ao sinal médio de todos os eletrodos. A partir dessa informação escolhemos, principalmente por se tratar de um estudo inicial, focar nos resultados para o eletrodo médio. Com isso, a partir daqui todos os resultados serão referentes ao sinal dado pela média dos sinais dos 96 eletrodos iniciais (isso inclui os resultados do momento SR-ON).

Após olhar o intervalo inteiro buscamos analisar o que ocorre nos sinais de maneira mais localizada e com isso tentar estudar como esses sinais se modificam dentro deste intervalo ao evoluir o tempo. Para isso, observamos nossas janelas flutuantes como visto na Figura 6.6, e observamos o pico de separação entre os quantificadores está localizado nas janelas com início em 10 ms até as janelas com início em 50 ms. Depois desse pico de atividade notamos que a intensidade da separação diminui para os  $\tau$  próximo de 8 ms e acaba aparecendo uma separação não tão intensa em  $\tau$  maiores e por volta das janelas iniciadas em 150 ms.

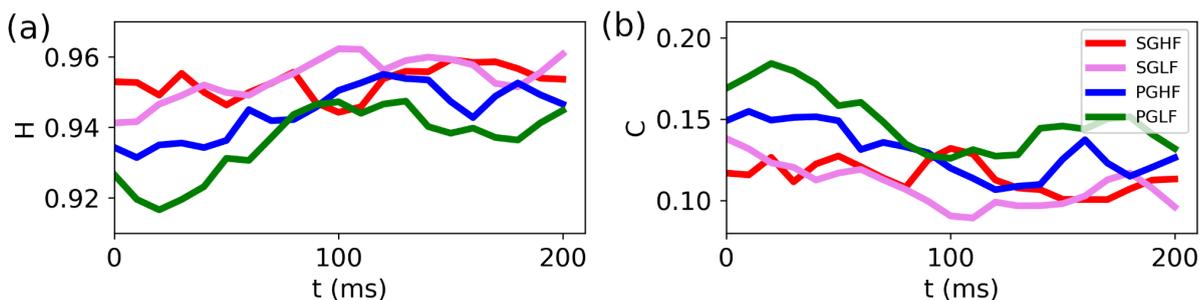
Figura 6.6: Mapa de calor para a distância entre SG e PG,  $\tau$  versus tempo.



Fonte: Autor, 2024.

Com essas informações resolvemos investigar em mais detalhes o  $\tau = 8$  ms. A partir daí geramos a Figura 6.7, que mostra como a entropia e a complexidade para esse  $\tau$  evolui com o tempo. Notamos que os valores dos 4 tipos de tarefas são muitos próximos, porém com valores de entropia para a pegada SG ligeiramente maior que a da pegada PG e com comportamento inverso para a complexidade. Também é observado que essa divisão ocorre no início do intervalo, aproximadamente da janela com início em 0 ms (início da informação visual do tipo de pegada) até a janela com início em 90 ms. Ao passar dessas janelas os quantificadores começam a ficar mais misturados.

Figura 6.7: Evolução dos quantificadores por intervalo de tempo. (a) Entropia e (b) Complexidade.

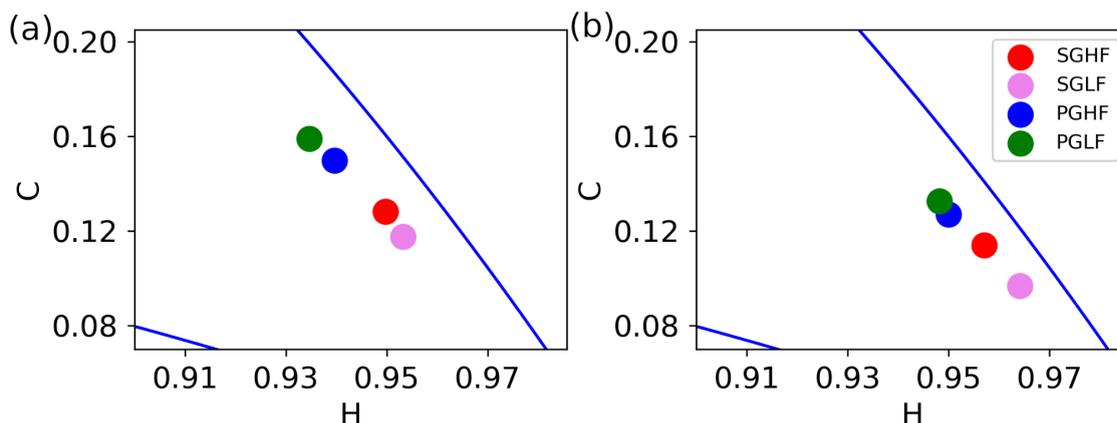


Fonte: Autor, 2024.

Com isso, mostramos os quantificadores no plano entropia versus complexidade para dois intervalos, como mostrado na Figura 6.8. A Figura 6.8a é referente aos quantificadores calculados para o intervalo de 40 ms até 140 ms depois da informação do tipo de pegada ser dado. Já a Figura 6.8b é referente aos quantificadores calculados para o intervalo de 200 ms até 300 ms depois da informação do tipo de pegada ser dado. E observamos que no início apesar de ser

uma diferença pequena conseguimos caracterizar que a pegada do tipo SG fica mais localizada abaixo da pegada do tipo PG no plano. Informação que continua no final do intervalo Figura 6.8b, porém menos característica.

Figura 6.8: Entropia *versus* complexidade. (a) Intervalo iniciado em 40 ms e indo até 140 ms. (b) Intervalo iniciado em 200 ms e indo até 300 ms.

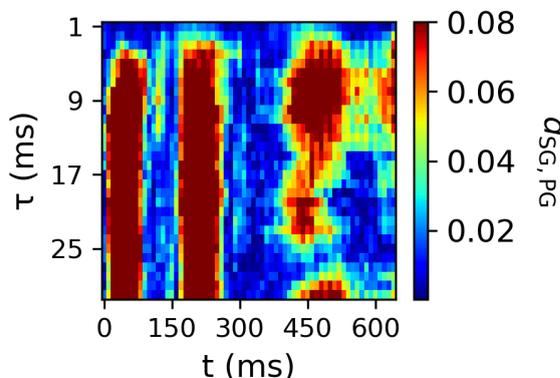


Fonte: Autor, 2024.

6.3.1 SR-ON: caracterizando os quatro tipos possíveis de tentativas de acordo com o tipo de pegada (lateral ou de precisão) e de força (alta ou baixa): SGHF, SGLF, PGHF, PGLF

Seguindo a análise feita para o intervalo anterior, buscamos olhar o mapa de calor para  $\tau = 8$  ms do eletrodo média para distância média entre o tipo de pegada SG e PG para as primeiras impressões. Ao fazer isso, notamos como visto na Figura 6.9 que há uma separação bem elevada em dois intervalos distintos.

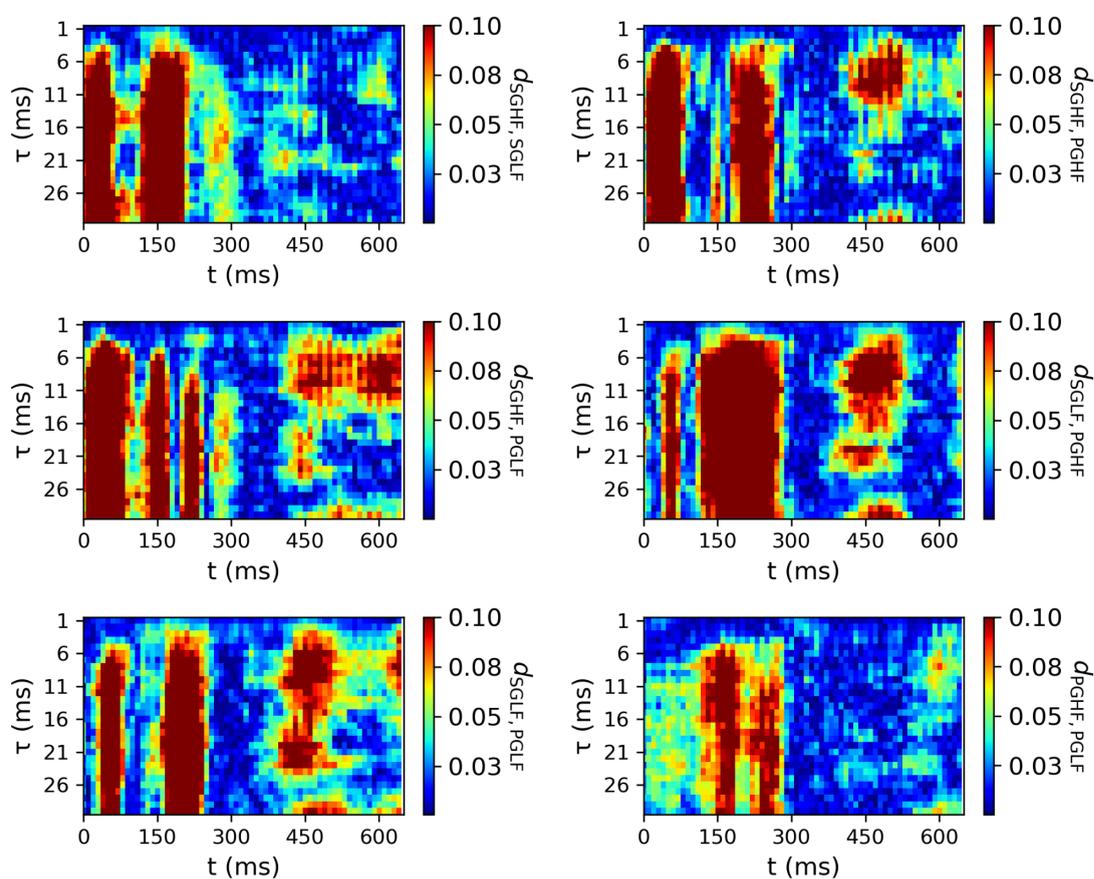
Figura 6.9: Mapa de calor para a distância entre SG e PG,  $\tau$  *versus* tempo.



Fonte: Autor, 2024.

Um fator importante para ser analisado neste momento é que o macaco já tem todas as informações necessárias para realizar as tarefas e sabendo qual das quatro ele deve realizar. Isso faz com que apesar de a Figura 6.9 nos dar alguma informação ela acaba mascarando o que está acontecendo na totalidade dos sinais. Pensando nisso, buscamos analisar a distância entre todos os tipos de tarefas, como mostra a Figura 6.10. Uma característica que se mantém é a mudança de comportamento que acontece em um intervalo de início próximo de 150 ms. E que ao observar a separação das tarefas com forças iguais e pegadas diferente notamos o aparecimento ainda mais forte desse comportamento.

Figura 6.10: Mapa de calor para a distância entre cada tipo de tarefa,  $\tau$  versus tempo.

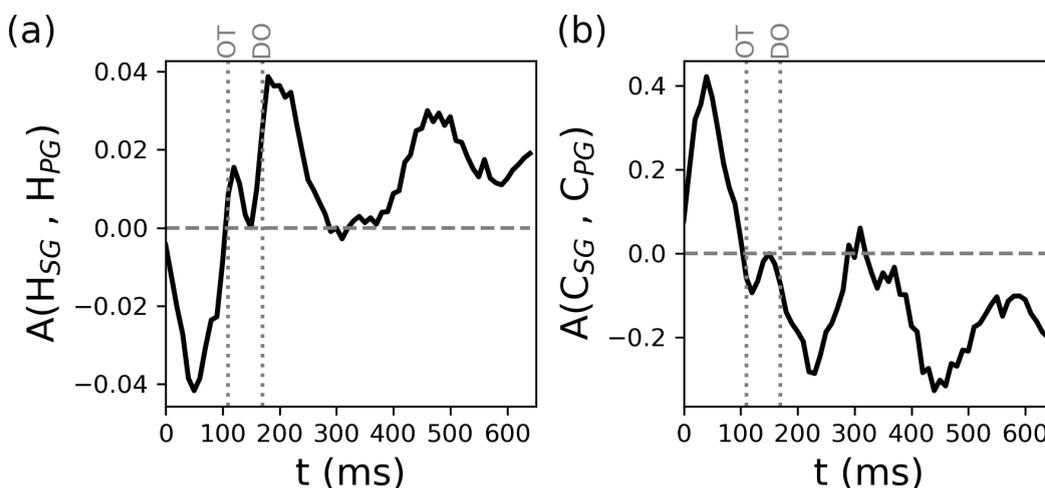


Fonte: Autor, 2024.

Esse comportamento fez com que gerasse curiosidade em observar o comportamento dessas pegadas. Já que inicialmente parece que estão relacionadas de alguma forma. Para investigar o que está acontecendo entre eles fizemos o cálculo da assimetria, ao longo das janelas, entre a entropia do SG médio e PG médio, Figura 6.11a. E da assimetria, ao longo das janelas, entre a complexidade do

SG médio e PG médio, Figura 6.11b. E notamos, uma mudança de comportamento no momento em que o macaco pega na alavanca(OT) e começa a puxá-la(DO).

Figura 6.11: Evolução da assimetria entre SG e PG por intervalo de tempo. (a) Assimetria da entropia. (b) Assimetria da complexidade.



Fonte: Autor, 2024.

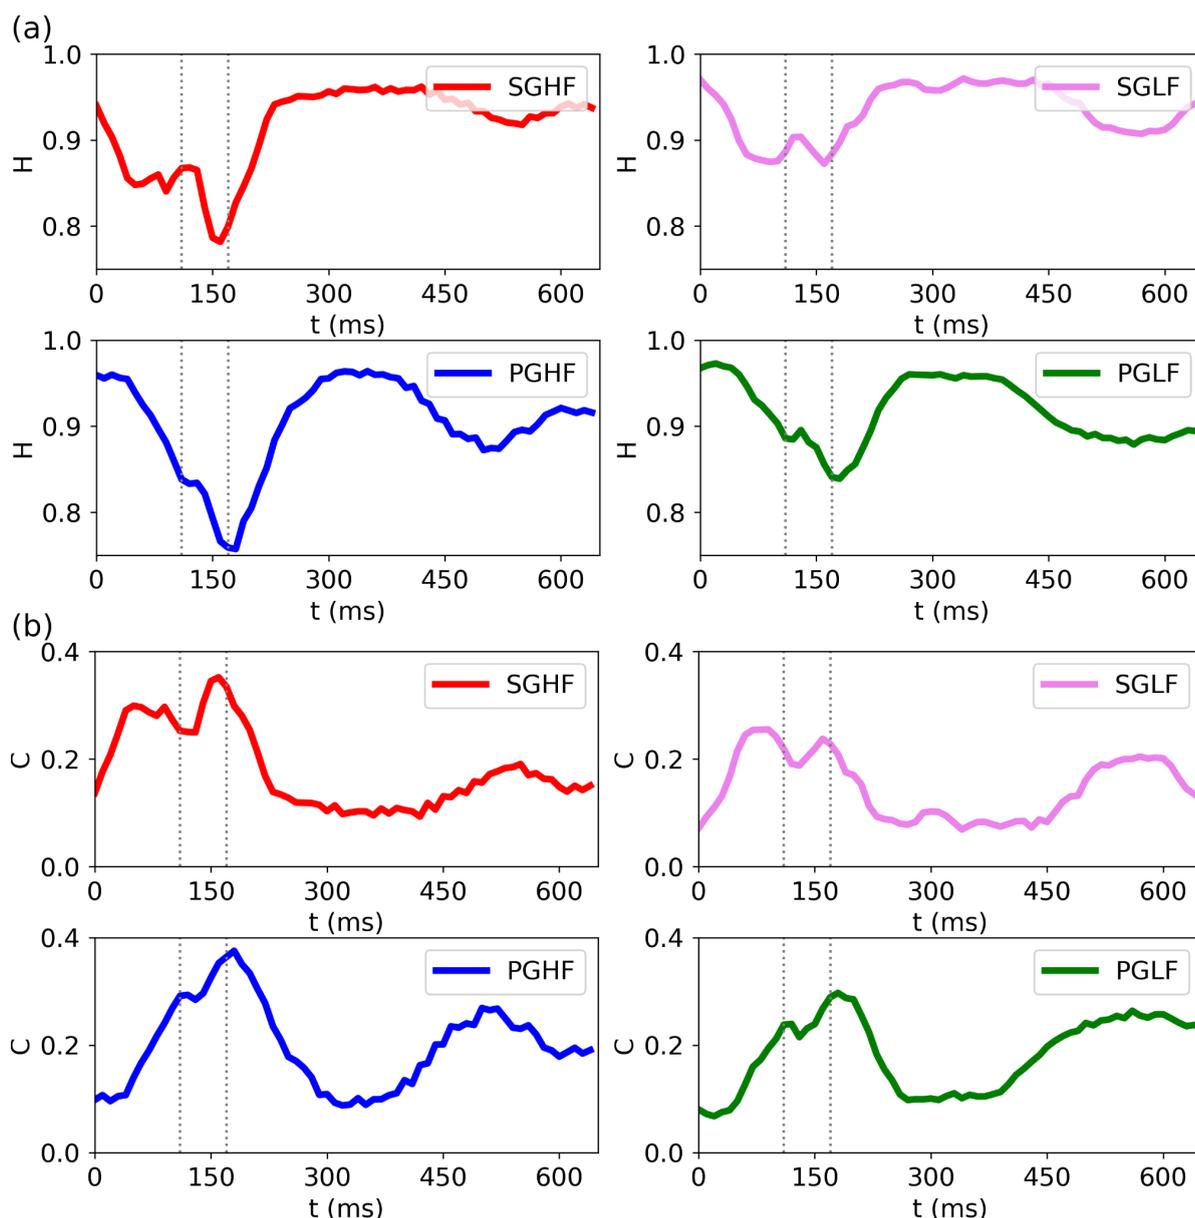
A mudança de comportamento vista na Figura 6.11, nos dá a informação que o tipo de pegada SG acaba tendo uma complexidade maior que a do tipo de pegada PG no momento em que o macaco está indo em direção a segurar a alavanca. E uma complexidade menor no momento em que o macaco puxa a alavanca. Já para a entropia vemos que o comportamento é inverso e menos intenso.

Para visualizar o que está ocorrendo de maneira mais precisa buscamos representar os quantificadores evoluindo a partir do tempo de início escolhido, como vemos na Figura 6.12. Ao observar essas figuras notamos que os quantificadores para todas as tarefas partem de um valor inicial próximo. Porém, existe um crescimento(complexidade) ou decrescimento(Entropia) muito mais intenso por parte das tarefas do tipo SG que as do tipo PG que se mantém mais suaves.

Outra característica é que os quantificadores das tarefas do tipo HF continuam crescendo ou decrescendo por um tempo maior que das tarefas do tipo LF. Porém, o que faz com que ocorra a inversão vista na Figura 6.12 é que as tarefas do tipo PG tem um amortecimento, pelo ato de tocar na alavanca, menor na subida para para a complexidade e na descida para a entropia. O que faz com que ela esteja com valores maiores para complexidade que os do tipo SG, e como a

queda desses valores de complexidade no momento de puxar a alavanca ocorre mais suave para o tipo de pegada PG acaba distanciando ainda mais os dois tipos de pegada.

Figura 6.12: Evolução dos quantificadores por intervalo de tempo para cada tipo de tarefa. (a) Entropia e (b) Complexidade.

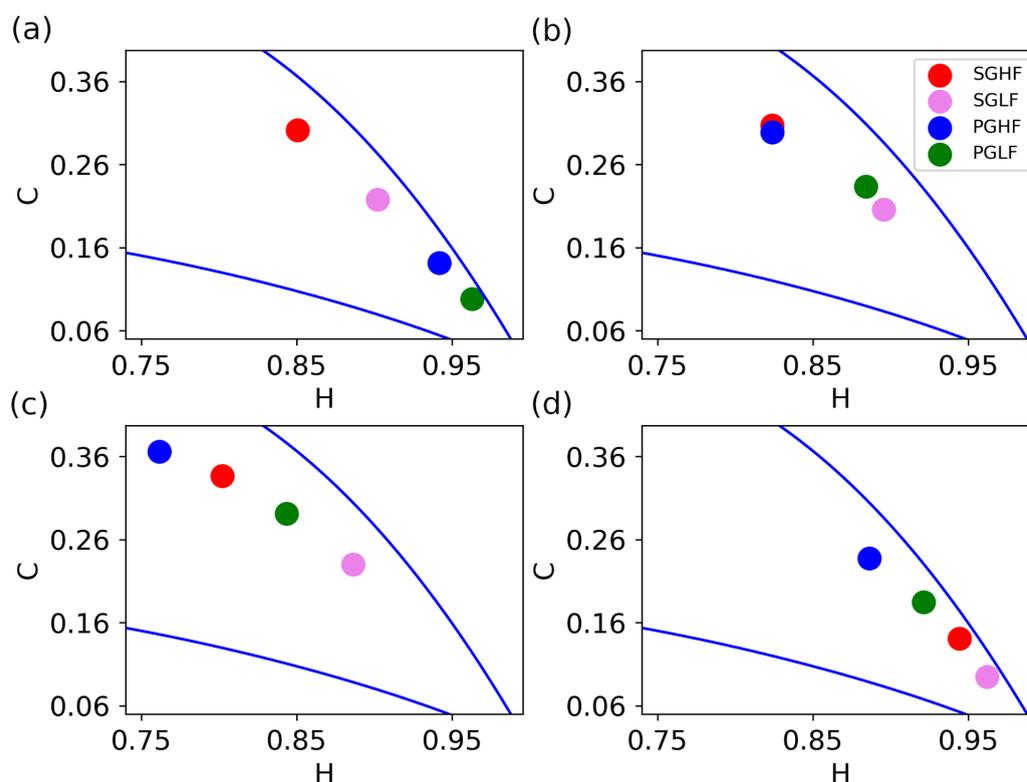


Fonte: Autor, 2024.

Esse comportamento se comprova ao ver o plano de entropia *versus* complexidade. Como vemos na Figura 6.13a, a uma separação bem definida no início do movimento (momento em que o macaco está indo agarrar a alavanca). Neste momento os tipos de pegada SG estão mais acima e a esquerda no plano que

os do tipo de pegada PG, e os tipo de força HF estão mais acima e a esquerda que os do tipo LF para o mesmo tipo de pegada. Essa separação bem definida acaba perdendo forças ao pegarmos intervalos com início mais próximos do macaco chega na alavanca, Figura 6.13b. E chegamos ao momento do macaco puxar a alavanca e vemos a inversão do comportamento das pegadas. Agora os tipos de pegada PG estão mais acima e mais à esquerda que os do tipo SG, como vemos na Figura 6.13d. Um intervalo em que mostra essa inversão acontecendo é o da Figura 6.13c, momento em que o macaco começa a puxar a alavanca. Algo para ser observado é que apesar de haver essa inversão para os tipos de pegada, as tarefas do tipo HF continuaram com uma complexidade maior e entropia menor que as do tipo LF durante todo o intervalo SR-ON analisado.

Figura 6.13: Entropia *versus* complexidade. (a) Intervalo iniciado em 40 ms e indo até 140 ms. (b) Intervalo iniciado em 130 ms e indo até 230 ms. (c) Intervalo iniciado em 160 ms e indo até 260 ms. (d) Intervalo iniciado em 220 ms e indo até 320 ms.



Fonte: Autor, 2024.

Mostramos que os quantificadores obtidos através do método B&P como entropia de Shannon e complexidade estatística podem ser utilizados para caracterizar e distinguir diferentes tipos de tarefas motoras realizadas por primatas

não humanos. Utilizando dados de LFP do cortex de macacos obtidos a partir de uma base de dados aberta, mostramos que somos capazes distinguir dois tipos de pegadas: lateral ou de precisão, bem como a força utilizada pelo animal como alta ou baixa. Utilizando diferentes valores de amostragem  $\tau$  mostramos que é possível inferir as escalas de tempo mais relevantes para diferenciar esses processos. Como perspectiva, é possível determinar regiões corticais que apresentam diferenças mais pronunciadas entre as diferentes tentativas, bem como investigar quais diferenças podemos encontrar estudando a série temporal tentativa por tentativa, sem concatenar os dados.

## REFERÊNCIAS

- [1] Parvizi, Josef, and Sabine Kastner. "Promises and limitations of human intracranial electroencephalography." *Nature neuroscience* 21.4 (2018): 474-483.
- [2] Da Paz, Ícaro Rodolfo Soares Coelho, et al. "A symbolic information approach applied to human intracranial data to characterize and distinguish different cognitive processes." *arXiv preprint arXiv:2404.17981* (2024).
- [3] Quiroga, Rodrigo Quian, and Stefano Panzeri, eds. *Principles of neural coding*. CRC Press, 2013.
- [4] Zygierewicz, J. *Practical Biomedical Signal Analysis Using MATLAB®*. 2011.
- [5] Waldert, Stephan, et al. "A review on directional information in neural signals for brain-machine interfaces." *Journal of Physiology-Paris* 103.3-5 (2009): 244-254.
- [6] Herff, Christian, and Tanja Schultz. "Automatic speech recognition from neural signals: a focused review." *Frontiers in neuroscience* 10 (2016): 204946.
- [7] Morettin, Pedro Alberto, and Clélia Maria de Castro Toloí. "Análise de séries temporais." (2022).
- [8] Shannon, Claude Elwood. "A mathematical theory of communication." *The Bell system technical journal* 27.3 (1948): 379-423.
- [9] Lamberti, Pedro W., et al. "Intensive entropic non-triviality measure." *Physica A: Statistical Mechanics and its Applications* 334.1-2 (2004): 119-131.
- [10] Bandt, Christoph, and Bernd Pompe. "Permutation entropy: a natural complexity measure for time series." *Physical review letters* 88.17 (2002): 174102.
- [11] Zunino, Luciano, Miguel C. Soriano, and Osvaldo A. Rosso. "Distinguishing chaotic and stochastic dynamics from time series by using a multiscale symbolic approach." *Physical Review E* 86.4 (2012): 046210.
- [12] Xiong, Hui, et al. "Complexity and information measures in planar characterization of chaos and noise." *Nonlinear Dynamics* 100 (2020): 1673-1687.
- [13] Bariviera, Aurelio F., et al. "Libor at crossroads: Stochastic switching detection using information theory quantifiers." *Chaos, Solitons & Fractals* 88 (2016): 172-182.

- [14] Colonna, Juan G., Eduardo F. Nakamura, and Osvaldo A. Rosso. "Feature evaluation for unsupervised bioacoustic signal segmentation of anuran calls." *Expert Systems with Applications* 106 (2018): 107-120.
- [15] Lotfi, Nastaran, et al. "Statistical complexity is maximized close to criticality in cortical dynamics." *Physical Review E* 103.1 (2021): 012415.
- [16] Montani, Fernando, et al. "A symbolic information approach to determine anticipated and delayed synchronization in neuronal circuit models." *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences* 373.2056 (2015): 20150110.
- [17] Lucas, Helena Bordini de. "Uma abordagem de informação simbólica para caracterizar diferenças relacionadas à resposta na atividade cortical durante uma tarefa Go/No-Go." (2021).
- [18] Mateos, Diego M., Jaime Gómez-Ramírez, and Osvaldo A. Rosso. "Using time causal quantifiers to characterize sleep stages." *Chaos, Solitons & Fractals* 146 (2021): 110798.
- [19] Baravalle, Roman, Osvaldo A. Rosso, and Fernando Montani. "Rhythmic activities of the brain: Quantifying the high complexity of beta and gamma oscillations during visuomotor tasks." *Chaos: An Interdisciplinary Journal of Nonlinear Science* 28.7 (2018).
- [20] Brissaud, Jean-Bernard. "The meanings of entropy." *Entropy* 7.1 (2005): 68-96.
- [21] Lopez-Ruiz, Ricardo, Héctor Mancini, and Xavier Calbet. "A statistical measure of complexity." *arXiv preprint arXiv:1009.1498* (2010).
- [22] Martin, M. T., A. Plastino, and Osvaldo A. Rosso. "Generalized statistical complexity measures: Geometrical and analytical properties." *Physica A: Statistical Mechanics and its Applications* 369.2 (2006): 439-462.
- [23] Rosso, Osvaldo A., et al. "Distinguishing noise from chaos." *Physical review letters* 99.15 (2007): 154102.
- [24] Pessa, Arthur AB, and Haroldo V. Ribeiro. "ordpy: A Python package for data analysis with permutation entropy and ordinal network methods." *Chaos: An Interdisciplinary Journal of Nonlinear Science* 31.6 (2021).
- [25] K. J. Miller, D. Hermes, C. J. Honey, M. Sharma, R. P. Rao, M. d. Nijs, E. E. Fetz, T. J. Sejnowski, A. O. Hebb, J. G. Ojemann, et al., *Frontiers in human neuroscience* 4, 197 (2010)
- [26] Brochier, Thomas, et al. "Massively parallel recordings in macaque motor cortex

during an instructed delayed reach-to-grasp task." Scientific data 5.1 (2018): 1-23.

## APÊNDICE A – ALGORITMO EM PYTHON PARA APLICAÇÃO DE B&P

```

import ordpy
import matplotlib.pyplot as plt
import numpy as np
import pandas as pd
from scipy.io import savemat, loadmat

def Criando_Dados_TI(diretorio,Tau_max,D,Nomes_Tasks,Experiento,NomInicio = None):

    """
    Função que salva uma matriz em .npy e .mat com as quantidades de H(Entropia) e
    C(Complexidade) formada pela seguinte dimensão

        Dados_TI = (1 x Numero de canais + 1(referente ao sinal médio) x Quantidade de taus
        analisados x Quantidades de tarefas x 2(H,C))

    Para isso precisamos do
        diretorio(caminho onde os sinais estão),
        Tau_max(Maior valor de tau que queremos calcular),
        D que é a dimensão de imersão,
        Nomes_Tasks(Uma lista com todas as tarefas, a ordem aqui será a mesma que sera salva na
        matriz final)

    São esperados dados na seguinte formatação

        Dados_Tarefa1.npy, Dados_Tarefa2.npy e etc com dimensão (T, N_Canais), onde T é a
        quantidade de pontos na série,
        onde Nomes_Tasks = ["Tarefa1","Tarefa2", ... ].
        Experiento = 0 ou 1. 0 Para o do macaco e 1 para o do humano
        NomInicio especifico para o do macaco, usado mostrar o marcador inicial que estamos
        analisando(CUE-ON ou SR).
    """
    if Experiento == 0:

        N_Tasks = len(Nomes_Tasks)

        Dados_temp = np.load("%s/npy/%s-Dados_%s.npy"%(diretorio,NomInicio,Nomes_Tasks[0]))
        N_Canais = Dados_temp.shape[1]
        tamanho = Dados_temp.shape[0]

```

```

del Dados_temp

Dados_TI = np.zeros((1,N_Canais + 1, Tau_max, N_Tasks, 2))

for Task in range(N_Tasks):

    Dados = np.load("%s/npys/%s-Dados_%s.npy"%(diretorio,NomeInicio,Nomes_Tasks[Task]))
    Dados_medio = 0

    for Canal in range(N_Canais):

        Dados_medio = Dados_medio + Dados[:,Canal]

        for tau in range(1,Tau_max + 1):
            H, C = ordpy.complexity_entropy(Dados[:,Canal], dx = D, taux = tau)
            Dados_TI[0,Canal, tau-1, Task, 0] = H
            Dados_TI[0,Canal, tau-1, Task, 1] = C

    Dados_medio = Dados_medio / N_Canais

    for tau in range(1,Tau_max + 1):
        H, C = ordpy.complexity_entropy(Dados_medio, dx = D, taux = tau)
        Dados_TI[0,N_Canais, tau-1, Task, 0] = H
        Dados_TI[0,N_Canais, tau-1, Task, 1] = C

np.save("%s/%s/%s-Dados_TI.npy"%(diretorio,Macaco,NomeInicio), Dados_TI)
savemat("%s/%s/%s-Dados_TI.mat"%(diretorio,Macaco,NomeInicio), {'Dados_TI': Dados_TI})

if Experiento == 1:

    N_Tasks = len(Nomes_Tasks)

    Dados_temp = np.load("%s/Dados_%s.npy"%(diretorio,Nomes_Tasks[0]))
    N_Canais = Dados_temp.shape[1]

    del Dados_temp

    Dados_TI = np.zeros((1,N_Canais + 1, Tau_max, N_Tasks, 2))

```

```

for Task in range(N_Tasks):

    Dados = np.load("%s/Dados_%s.npy"%(diretorio,Nomes_Tasks[Task]))

    Dados_medio = 0

    for Canal in range(N_Canais):

        Dados_medio = Dados_medio + Dados[:,Canal]

        for tau in range(1,Tau_max + 1):
            H, C = ordpy.complexity_entropy(Dados[:,Canal], dx = D, tau = tau)
            Dados_TI[0,Canal, tau-1, Task, 0] = H
            Dados_TI[0,Canal, tau-1, Task, 1] = C

        Dados_medio = Dados_medio / N_Canais

    for tau in range(1,Tau_max + 1):
        H, C = ordpy.complexity_entropy(Dados_medio, dx = D, tau = tau)
        Dados_TI[0,N_Canais, tau-1, Task, 0] = H
        Dados_TI[0,N_Canais, tau-1, Task, 1] = C

    np.save("%s/Dados_TI.npy"%(diretorio), Dados_TI)
    savemat("%s/Dados_TI.mat"%(diretorio), {'Dados_TI': Dados_TI})

```

```
def Criando_Dados_TI_Flutuante(diretorio,Tau_max,D,Nomes_Tasks,Experiento,NomelInicio = None):
```

```
    """
```

Função que salva uma matriz em .npy e .mat com as quantidades de H(Entropia), C(Complexidade) e I(Fisher information) formada pela seguinte dimensão

Dados\_TI = (1 x Numero de canais + 1(referente ao sinal médio) x Quantidade de taus analisados x Quantidades de tarefas x 2(H,C), Quantidades de Janelas)

Para isso precisamos do

diretorio(caminho onde os sinais estão),

Tau\_max(Maior valor de tau que queremos calcular),

D que é a dimensão de imersão,

Nomes\_Tasks(Uma lista com todas as tarefas, a ordem aqui será a mesma que sera salva na matriz final)

São esperados dados na seguinte formatação

Dados\_Tarefa1.npy, Dados\_Tarefa2.npy e etc com dimensão (T, N\_Canais), onde T é a quantidade de pontos na série,

onde Nomes\_Tasks = ["Tarefa1", "Tarefa2", ... ].

Experiento = 0 ou 1. 0 Para o do macaco e 1 para o do humano

NomeInicio especifico para o do macaco, usado mostrar o marcador inicial que estamos analisando(CUE-ON ou SR).

\*\*\*\*

```

if Experiento == 0:

    Dados_temp = np.load("%s/npy/%s-Dados_%s.npy"%(diretorio,NomeInicio,Nomes_Tasks[0]))
    N_Canais = Dados_temp.shape[1]

    Quantidades_Janelas = None
    for tasks in Nomes_Tasks:
        Dados_temp = np.load("%s/npy/%s-Dados_%s.npy"%(diretorio,NomeInicio,tasks))
        if Dados_temp.shape[2] < Quantidades_Janelas or Dados_temp.shape[2] == None:
            Quantidades_Janelas = Dados_temp.shape[2]

    del Dados_temp

    N_Tasks = len(Nomes_Tasks)

    Dados_TI = np.zeros((1,N_Canais + 1, Tau_max, N_Tasks, 2,Quantidades_Janelas))

    for Task in range(N_Tasks):
        Dados = np.load("%s/npy/%s-Dados_%s.npy"%(diretorio,NomeInicio,Nomes_Tasks[Task]))

        for Janela in range(Quantidades_Janelas):

            Dados_medio = 0

            for Canal in range(N_Canais):

                Dados_medio = Dados_medio + Dados[:,Canal,Janela]

            for tau in range(1,Tau_max + 1):
                H, C = ordpy.complexity_entropy(Dados[:,Canal,Janela], dx = D, taux = tau)

```

```

    Dados_TI[0,Canal, tau-1, Task, 0,Janela] = H
    Dados_TI[0,Canal, tau-1, Task, 1,Janela] = C

Dados_medio = Dados_medio / N_Canais

for tau in range(1,Tau_max + 1):
    H, C = ordpy.complexity_entropy(Dados_medio, dx = D, tau = tau)
    Dados_TI[0,N_Canais, tau-1, Task, 0,Janela] = H
    Dados_TI[0,N_Canais, tau-1, Task, 1,Janela] = C

print("FIM")
np.save('%s/%s-Dados_TI.npy'%(diretorio,NomeInicio), Dados_TI)
savemat('%s/%s-Dados_TI.mat'%(diretorio,NomeInicio), {'Dados_TI': Dados_TI})

if Experiento == 1:
    Dados_temp = np.load("%s/Dados_%s.npy"%(diretorio,Nomes_Tasks[0]))
    Quantidades_Janelas = Dados_temp.shape[2]
    N_Canais = Dados_temp.shape[1]

    del Dados_temp

    N_Tasks = len(Nomes_Tasks)

    Dados_TI = np.zeros((1,N_Canais + 1, Tau_max, N_Tasks, 3,Quantidades_Janelas))

    for Task in range(N_Tasks):

        Dados = np.load("%s/Dados_%s.npy"%(diretorio,Nomes_Tasks[Task]))

        for Janela in range(Quantidades_Janelas):

            Dados_medio = 0

            for Canal in range(N_Canais):

                Dados_medio = Dados_medio + Dados[:,Canal,Janela]

            for tau in range(1,Tau_max + 1):

```

```
H, C = ordpy.complexity_entropy(Dados[:,Canal,Janela], dx = D, taux = tau)
Dados_TI[0,Canal, tau-1, Task, 0,Janela] = H
Dados_TI[0,Canal, tau-1, Task, 1,Janela] = C
```

```
I = ordpy.fisher_shannon(Dados[:,Canal,Janela], dx = D, taux = tau)[1]
Dados_TI[0,Canal, tau-1, Task, 2,Janela] = I
```

```
Dados_medio = Dados_medio / N_Canais
```

```
for tau in range(1,Tau_max + 1):
```

```
    H, C = ordpy.complexity_entropy(Dados_medio, dx = D, taux = tau)
    Dados_TI[0,N_Canais, tau-1, Task, 0,Janela] = H
    Dados_TI[0,N_Canais, tau-1, Task, 1,Janela] = C
```

```
    I = ordpy.fisher_shannon(Dados_medio, dx = D, taux = tau)[1]
    Dados_TI[0,N_Canais, tau-1, Task, 2,Janela] = I
```

```
np.save('%s/Dados_TI.npy'%(diretorio), Dados_TI)
savemat('%s/Dados_TI.mat'%(diretorio), {'Dados_TI': Dados_TI})
```

# APÊNDICE B – HUMANOS REALIZANDO UMA TAREFA VISUAL COGNITIVA (ARTIGO)

## A symbolic information approach applied to human intracranial data to characterize and distinguish different cognitive processes

Ícaro Rodolfo Soares Coelho Da Paz,<sup>1</sup> Pedro F. A. Silva,<sup>1</sup> Helena Bordini de Lucas,<sup>1</sup> Sérgio H. A. Lira,<sup>1</sup> Osvaldo A. Rosso,<sup>1</sup> and Fernanda Selingardi Matias<sup>1,\*</sup>

<sup>1</sup>*Instituto de Física, Universidade Federal de Alagoas, Maceió, Alagoas 57072-970 Brazil.*

How the human brain processes information during different cognitive tasks is one of the greatest questions in contemporary neuroscience. Understanding the statistical properties of brain signals during specific activities is one promising way to address this question. Here we analyze freely available data from implanted electrocorticography (ECoG) in five human subjects during two different cognitive tasks in the light of information theory quantifiers ideas. We employ a symbolic information approach to determine the probability distribution function associated with the time series from different cortical areas. Then we utilize these probabilities to calculate the associated Shannon entropy and a statistical complexity measure based on the disequilibrium between the actual time series and one with a uniform probability distribution function. We show that an Euclidian distance in the complexity-entropy plane and an asymmetry index for complexity are useful for comparing the two conditions. We show that our method can distinguish visual search epochs from blank screen intervals in different electrodes and patients. By using a multi-scale approach and embedding time delays to downsample the data, we find important time scales in which the relevant information is being processed. We also determine cortical regions and time intervals along the 2-second-long trials that present more pronounced differences between the two cognitive tasks. Finally, we show that the method is useful to distinguish cognitive processes using brain activity on a trial-by-trial basis.

PACS numbers:

### I. INTRODUCTION

Understanding the statistical properties of the human brain activity during different cognitive processes is a great step toward comprehending how the brain processes information. Characterizing these properties in different cortical regions, and time scales can contribute to this issue. Electrophysiological data from intracranial electrodes in the human brain are promising to address these questions since it provides millisecond temporal resolution, clear signals from specific brain areas, and a good signal-to-noise rate [1]. However, the overall access to intracranial data is still rare and remains somewhat exclusive to the experimentalists who have produced it.

Here, we analyze freely available data from implanted electrocorticographic (ECoG) measurements of brain surface potentials in five human subjects during visual cognitive tasks [2]. It has been previously reported for this data that a comparison of visual search trials with interspersed blank screen intervals presents changes in the raw potential, in the amplitude of rhythmic activity, and in the decoupled broadband spectral amplitude [2]. In the present work, we extend this comparison between active visual search tasks and waiting windows by using statistical tools that can discriminate which brain areas are more engaged in one of the trial types during specific time intervals.

To characterize different features of time series we em-

ploy two time causal quantifiers based on Information Theory: Shannon entropy (see Eq. 1)[3], and the corresponding Martín-Platino-Rosso (MPR) statistical complexity (see Eq. 3), based on the disequilibrium between the actual time series and one with a uniform probability distribution function [4–8]. Using the MPR definition of complexity, both extremes of order and disorder present low complexity. For example, a constant time series or a very noisy time series would present low complexity. In the same fashion, a perfect crystal or a random distribution of atoms are not complex systems. We assign each time series under study a position in a two-dimensional space spanned by the entropy and the statistical complexity measure: the complexity-entropy plane  $C \times H$ . These quantifiers are evaluated using the Bandt-Pompe symbolization methodology [9], which includes naturally the time causal ordering provided by the time-series data in the corresponding associate probability distribution function (PDF).

This approach was originally introduced to distinguish chaotic from stochastic systems in time series analysis [6, 7]. Recently, it has been successfully applied to study brain signals: to estimate time differences during phase synchronization [10], to show that complexity is maximized close to criticality in cortical states [11, 12], to distinguish cortical states using EEG data [13, 14], to characterize neurological diseases using MEG [15], as well as to study neuronal activity [10, 16, 17]. Furthermore, it has been applied to monkey LFP to estimate response-related differences between Go and No-Go trials [18]. As far as we know it has not been applied to intracranial human data before.

\*fernanda@fis.ufal.br