



**UNIVERSIDADE ESTADUAL PAULISTA**  
**“JÚLIO DE MESQUITA FILHO”**  
Campus de Botucatu

UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA FILHO”  
INSTITUTO DE BIOCÊNCIAS DE BOTUCATU, CAMPUS BOTUCATU

MARCELINE ESPERANÇA GOMES

**COMPARAÇÃO DE TÉCNICAS COMPUTACIONAIS DE ANÁLISE  
DE EEG PARA A CLASSIFICAÇÃO DE IDOSOS EM DIFERENTES  
ESTÁGIOS DA DOENÇA DE ALZHEIMER**

Botucatu

Novembro de 2025



UNIVERSIDADE ESTADUAL PAULISTA  
“JÚLIO DE MESQUITA FILHO”  
Campus de Botucatu

MARCELINE ESPERANÇA GOMES

# COMPARAÇÃO DE TÉCNICAS COMPUTACIONAIS DE ANÁLISE DE EEG PARA A CLASSIFICAÇÃO DE IDOSOS EM DIFERENTES ESTÁGIOS DA DOENÇA DE ALZHEIMER

Relatório apresentado à Universidade Estadual Paulista “Júlio de Mesquita Filho”, Instituto de Biociências, Campus Botucatu, como parte dos requisitos para a conclusão do curso de graduação em Física Médica.

**Orientadora:** Prof<sup>a</sup>. Dr<sup>a</sup>. Andriana S. L. O. Campanharo

**Coorientador:** Dr. Mário Lucas Vicchietti

**Financiamento:** FAPESP

Botucatu

Novembro de 2025



G633c

Gomes, Marceline Esperança

Comparação de técnicas computacionais de análise de EEG para a classificação de idosos em diferentes estágios da doença de Alzheimer / Marceline Esperança Gomes. -- Botucatu, 2025

40 f. : tabs.

Trabalho de conclusão de curso (Bacharelado - Física Médica) - Universidade Estadual Paulista (UNESP), Instituto de Biociências, Botucatu

Orientadora: Andriana Susana Lopes de Oliveira Campanharo

Coorientador: Mário Lucas Vicchietti

1. Processamento de sinais. 2. Alzheimer, Doença de. 3. Eletroencefalografia. 4. Redes complexas. 5. Machine learning. I. Título.


MARCELINE ESPERANÇA GOMES

**COMPARAÇÃO DE TÉCNICAS COMPUTACIONAIS DE ANÁLISE DE  
EEG PARA A CLASSIFICAÇÃO DE IDOSOS EM DIFERENTES  
ESTÁGIOS DA DOENÇA DE ALZHEIMER**


Trabalho de Conclusão de Curso,  
apresentado a Universidade Estadual  
Paulista, como parte das exigências para  
a obtenção do título de Bacharel, do curso  
de Graduação em Física Médica.

Botucatu, 26 de novembro de 2025.


**BANCA EXAMINADORA**



Profa. Andriana Susana Lopes de Oliveira Campanharo  
Departamento de Biodiversidade e Bioestatística, IB



Prof. Luiz Eduardo Gomes Garcia Betting  
Departamento de Neurociências e Saúde Mental, FMB



Prof. Joel Mesa Hormaza  
Departamento de Biofísica e Farmacologia, IB

# Dedicatória

Dedico este trabalho a todas as mulheres cientistas e pessoas trans do Brasil.

Ao meu namorado Matheus e aos meus amigos, que fizeram esses 4 anos de graduação serem mais leves.

Aos meus professores que fizeram parte dessa jornada e me auxiliaram na minha formação.

# Agradecimentos

Agradeço à minha orientadora Profa. Dra. Andriana S. L. O. Campanharo e ao coordenador Mário Lucas Vicchietti.

Meus agradecimentos ao meu namorado e amigos pelo apoio emocional e psicológico durante todo esse período.

Ao Departamento de Biodiversidade e Bioestatística pela estrutura e auxílio nesta pesquisa.

À Unesp de Botucatu e ao Instituto de Biociências de Botucatu por toda a estrutura fornecida nesses 4 anos de graduação.

À Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP), pelo apoio financeiro, concedido por meio do Processo nº 2024/05536-0.

# Resumo

A doença de Alzheimer (DA) pode ser entendida como uma demência degenerativa e progressiva do Sistema Nervoso Central, irreversível e de causa desconhecida. Tal patologia é caracterizada por sintomas neuropsiquiátricos, como: perda de memória, desorientação no tempo e no espaço e deterioração intelectual acelerada. Apesar de ser o tipo mais comum de doença neurodegenerativa, ainda não foi encontrada a cura para ela. Entretanto, há tratamentos que retardam a evolução da DA. Desse modo, seu diagnóstico precoce, ou seja, em seu estágio inicial (DA leve) ou ainda no estágio de transição entre o envelhecimento saudável e a DA, conhecido como Declínio Cognitivo Leve (DCL), são de extrema importância para que a vida cotidiana dos indivíduos atingidos por essas condições não seja significativamente alterada, proporcionando assim uma melhor qualidade de vida.

Com isso em vista, a diferenciação entre o DCL e a DA desempenha um papel importante na detecção precoce da doença. Pesquisas recentes mostram que o eletroencefalograma (EEG) pode refletir mudanças funcionais sutis no córtex, consequentemente, a identificação do DCL e da DA a partir de dados de EEG tem sido alvo de vários estudos. Para o estudo desses dados, no atual projeto, foi utilizada a técnica de *Mapeamento em Grafos de Quantis*, que mapeia uma série temporal em redes complexas, tornando assim possível o estudo dessa série a partir de caracterizadores estruturais. Com base nos resultados, foi possível observar diferenças entre dois grupos de pacientes (portadores do DCL e da DA), evidenciando assim a eficiência da classificação dos indivíduos em diferentes condições patológicas.

**Palavras-chaves:** Doença de Alzheimer, Caracterizadores estruturais, EEG, Redes Complexas, Grafos de Quantis.

# Sumário

|          |                                                                     |           |
|----------|---------------------------------------------------------------------|-----------|
| <b>1</b> | <b>Introdução</b>                                                   | <b>8</b>  |
| <b>2</b> | <b>Objetivos</b>                                                    | <b>10</b> |
| <b>3</b> | <b>Base de dados</b>                                                | <b>11</b> |
| <b>4</b> | <b>Metodologia</b>                                                  | <b>13</b> |
| 4.1      | Análise espectral de wavelet . . . . .                              | 13        |
| 4.2      | Mapeamento de séries temporais em grafos de quantis . . . . .       | 15        |
| 4.3      | Caracterizadores estruturais . . . . .                              | 15        |
| 4.3.1    | Coeficiente de agrupamento ( $C$ ) . . . . .                        | 16        |
| 4.3.2    | Comprimento do salto médio ( $\Delta$ ) . . . . .                   | 16        |
| 4.3.3    | Reciprocidade ( $\rho$ ) . . . . .                                  | 17        |
| 4.3.4    | Grau de intermediação ( $B$ ) . . . . .                             | 17        |
| 4.3.5    | Comprimento do menor caminho médio ( $L$ ) . . . . .                | 17        |
| 4.4      | Dimensão fractal . . . . .                                          | 18        |
| 4.5      | Entropia quadrática . . . . .                                       | 18        |
| 4.6      | Máquina de vetores de suporte (SVM) . . . . .                       | 20        |
| <b>5</b> | <b>Resultados</b>                                                   | <b>21</b> |
| 5.1      | Comparação entre as técnicas de caracterização utilizadas . . . . . | 21        |
| <b>6</b> | <b>Conclusões</b>                                                   | <b>31</b> |

# Capítulo 1

## Introdução

A doença de Alzheimer (DA) é o tipo mais comum de patologia neurodegenerativa, caracterizada por demência progressiva e por sintomas neuropsiquiátricos, principalmente em pessoas mais velhas, levando à eventual morte. Ainda não foi desenvolvida nenhuma cura para essa doença, entretanto, há vários medicamentos que retardam a evolução da DA. Nesse sentido, o diagnóstico precoce, particularmente do declínio cognitivo leve (DCL), tem grande importância, uma vez que os medicamentos são mais eficazes nas fases iniciais da doença [36, 32, 6].

O DCL é uma síndrome de declínio cognitivo maior que o esperado para a idade e nível educacional de um dado indivíduo, mas que não altera significativamente a sua vida cotidiana. Entretanto, mais da metade dos diagnósticos de DCL progridem para demência dentro de 5 anos, constituindo assim um estágio prodromico da DA [36, 6]. Dessa forma, a diferenciação entre o DCL e a DA possui um papel importante na detecção, na prevenção, e na intervenção precoce dessa patologia. Para tal, biomarcadores patológicos da doença são amplamente utilizados na prática clínica. Entretanto, tais marcadores, como por exemplo a análise do líquido cefalorraquidiano, são caros e/ou invasivos, e os testes neuropsicológicos não são sensíveis a mudanças sutis na cognição [32, 25].

Um conjunto crescente de evidências sugere que biomarcadores de eletroencefalografia (EEG) podem ser usados para identificar anormalidades na função neural. Estudos de imagem cerebral mostraram a diminuição do metabolismo em regiões específicas do cérebro. Dessa forma, a EEG, que pode refletir mudanças funcionais sutis no córtex, tem

sido investigado nos últimos anos por muitos grupos de pesquisa como uma ferramenta de diagnóstico da DA [25, 43, 6].

É importante ressaltar que, apesar de sua alta resolução temporal, a eletroencefalografia possui uma resolução espacial limitada, levando a diversas discussões e estudos em relação ao número mínimo de eletrodos para evitar subamostragem [37]. Dessa forma, exames utilizando o capacete de EEG, com no mínimo 64 eletrodos, têm substituído, em pesquisas mais recentes, o sistema 10-20, segundo o qual 19 eletrodos eram posicionados no escalpo a uma distância média de 7 cm [23].

Dessa maneira, a atividade elétrica cerebral pode ser registrada com maior precisão em dados de EEG de alta densidade (HD-EEG em inglês), permitindo assim que mudanças em escalas menores sejam detectadas, o que pode aumentar a acurácia na identificação de doenças neurodegenerativas como a DA [34, 35].

Durante a coleta do EEG, a atividade elétrica cerebral é registrada na forma de série temporal, e pode ser analisada por meio de técnicas de processamento de sinais [29]. Entretanto, grande parte dessas técnicas, tais como as transformadas de Fourier e Wavelet [22, 27], ou métodos não lineares como a reconstrução de espaço de fases, a dimensão de correlação, o expoente de Lyapunov e a entropia [39, 20, 1], produzem resultados altamente sensíveis à escolha de parâmetros pré-fixados, ou até mesmo possuem pré-requisitos como estacionariedade e/ou elevada razão sinal-ruído. Isso torna desafiador o uso adequado dessas técnicas, principalmente em casos como o dos sinais de EEG, que geralmente são não estacionários e contaminados por ruído [7, 29].

Destarte, novas técnicas de análise desse tipo de série temporal são propostas e estudadas. Um método proposto em [3], conhecido como *Mapeamento em Grafos de Quantis*, mapeia séries temporais em grafos ou redes, resumizando propriedades relevantes da série temporal original, como periodicidade ou aleatoriedade, em características topológicas do grafo resultante [29]. Desse modo, torna-se possível analisar os sinais de EEG com o uso de caracterizadores de redes complexas, tais como: coeficiente de agrupamento, comprimento de salto médio, reciprocidade, intermediação, menor caminho médio, entre outros.



# Capítulo 2

## Objetivos

De modo geral, os objetivos deste trabalho são, a partir da utilização do método de grafos de quantis proposto por Campanharo *et al.* [3, 1], analisar um conjunto de sinais de EEG de alta densidade de idosos com DCL e com DA, fornecido pelo centro italiano de neurologia IRCCS Neurolesi “Bonino Pulejo”. Mais especificamente, deseja-se efetuar:

1. A distinção e classificação entre o DCL e a DA entre os 19 idosos em estudo;
2. A detecção das regiões mais afetadas do cérebro pela DA em seus estágios prodromico e avançado;
3. A comparação entre os novos resultados (com dados de HD-EEG) e os resultados obtidos anteriormente a partir de eletroencefalografia de baixa densidade.

Ademais, pretende-se também realizar um estudo comparativo quanto à performance de técnicas amplamente utilizadas na literatura, tais como: a dimensão fractal, a entropia quadrática, a análise espectral de wavelet e o método citado anteriormente, na classificação dos pacientes em diferentes estágios da DA a partir do novo conjunto de dados.

## Capítulo 3

### Base de dados

Neste projeto de pesquisa, foi utilizada uma base de dados construída pelos pesquisadores Angelo Quartarone e Maria De Cola, do Centro IRCCS Neurolesi “Bonino Pulejo” em Messina (Itália). A base de dados contém exames de EEG de alta densidade (HD-EEG) referentes a 19 pacientes em dois momentos de coleta diferentes, onde inicialmente, no período de aquisição T0, apenas 2 pacientes portavam a DA, mas, em um segundo momento, no período de aquisição T1, três pacientes evoluíram de DCL para DA. Os sinais de EEG foram coletados com o uso de 173 eletrodos de escalpo, sob uma frequência de amostragem de 250 Hz com um filtro passa-banda de 1-40 Hz previamente aplicado, enquanto os pacientes estavam em repouso e com os olhos fechados.

Os pacientes foram diagnosticados e classificados de acordo com as orientações do Manual Diagnóstico e Estatístico de Transtornos Mentais (DSM-5). Além disso, o desempenho cognitivo dos pacientes foi avaliado utilizando o teste *Montreal Cognitive Assessment* (MoCA) [9, 8, 31, 16].

A seguir, é mostrado um gráfico (3.1) exemplificando uma parte de dois sinais de EEG (referentes aos períodos T0 e T1) do eletrodo 44 de um paciente portador de DCL no período T0, que sofreu evolução da doença para DA até o período T1. Em seguida, é exibida a tabela 3.1, a qual contém informações sobre os pacientes em estudo, tais quais a identificação deles, data dos períodos de aquisição, o estágio da doença no período em questão e as pontuações de cada um no teste MoCA em ambos os períodos.




Figura 3.1: Exemplos de sinais de EEG do eletrodo 44 do paciente 12, o qual sofreu evolução da DCL para DA, com maior diferença entre suas pontuações da MoCA.

Tabela 3.1: Descrição da base de dados de EEG de alta densidade.

| ID | Label $T_0$ | Exame $T_0$ | Label $T_1$ | Exame $T_1$ | MoCA $T_0$ | MoCA $T_1$ |
|----|-------------|-------------|-------------|-------------|------------|------------|
| 1  | DCL         | 12/10/2017  | DA          | 30/11/2018  | 22         | 15         |
| 2  | DCL         | 19/04/2019  | DCL         | 19/07/2019  | 26         | 26         |
| 3  | DA          | 20/02/2018  | DA          | 12/11/2018  | 15         | 9          |
| 4  | DCL         | 22/03/2018  | DCL         | 28/05/2019  | 21         | 20         |
| 5  | DA          | 23/03/2018  | DA          | 26/07/2019  | 14         | 12         |
| 6  | DCL         | 04/10/2017  | DCL         | 25/10/2018  | 28         | 23         |
| 7  | DCL         | 04/07/2019  | DCL         | 04/11/2019  | 16         | 16         |
| 8  | DCL         | 06/05/2019  | DCL         | 06/08/2019  | 25         | 24         |
| 9  | DCL         | 20/06/2019  | DCL         | 20/09/2019  | 30         | 28         |
| 10 | DCL         | 17/01/2018  | DCL         | 25/01/2019  | 27         | 22         |
| 11 | DCL         | 17/04/2018  | DCL         | 24/07/2018  | 24         | 24         |
| 12 | DCL         | 11/07/2017  | DA          | 25/10/2018  | 23         | 12         |
| 13 | DCL         | 06/05/2019  | DCL         | 08/08/2019  | 20         | 20         |
| 14 | DCL         | 17/01/2018  | DA          | 17/04/2018  | 24         | 21         |
| 15 | DCL         | 09/01/2018  | DCL         | 09/04/2018  | 25         | 25         |
| 16 | DCL         | 26/04/2017  | DCL         | 03/10/2017  | 26         | 25         |
| 17 | DCL         | 26/04/2017  | DCL         | 03/10/2017  | 26         | 24         |
| 18 | DCL         | 26/07/2017  | DCL         | 18/04/2019  | 25         | 25         |
| 19 | DCL         | 11/10/2017  | DCL         | 19/01/2018  | 26         | 25         |

# Capítulo 4

## Metodologia

Em um primeiro momento, foi feita a decomposição wavelet do sinal em 4 bandas (alfa, beta, teta e delta) utilizando o tipo de onda “Coiflets 1”. Em seguida, para a análise dos sinais de EEG-HD foi usado o método de *Mapeamento em Grafos de Quantis* [3], o qual mapeia as séries temporais em redes complexas, e alguns caracterizadores de redes complexas (coeficiente de agrupamento, comprimento de salto médio, reciprocidade, intermediação e menor caminho médio) foram calculados para analisar tais redes. Tal método foi comparado com outros métodos amplamente utilizados na literatura, sendo eles: a dimensão fractal e a entropia quadrática.

Após a aplicação dessas técnicas, foi utilizada a técnica de máquina de vetores de suporte (SVM) para o treinamento da máquina e a classificação dos pacientes em dois grupos (DCL e DA), com as acurácias registradas para cada uma das técnicas, tanto em forma de gráficos (de linhas para o caso da dimensão fractal e boxplots para as demais técnicas) quanto em forma de tabelas.

### 4.1 Análise espectral de wavelet

Como o nome sugere, wavelets são “ondas pequenas”, as quais servem como ferramentas matemáticas para a análise de séries temporais ou imagens [27]. Tais ondas pertencem a uma classe especial de funções, obedecendo a algumas condições, como serem oscilatórias e possuírem integral igual a zero [40]. A partir da transformada discreta de wavelet é

possível decompor sinais não estacionários, como os EEGs, em bandas de subfrequências e uma série de coeficientes que os representam [18]. Ao considerar uma série temporal  $X$ , o coeficiente  $C_X(a, b)$  na escala  $a$  e no tempo  $b$  pode ser matematicamente obtido como:

$$C_X(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} f(t) \Psi \left( \frac{t - b}{a} \right) dt, \quad (4.1)$$

sendo  $\Psi$  a função wavelet denominada onda-mãe, e  $f(t)$  o sinal a ser decomposto [40].

Para a escolha do tipo de onda a ser utilizado para a decomposição das séries temporais, foi levado em consideração um estudo comparativo entre as famílias de wavelets na classificação de sinais de EEG, o qual constatou que a ondeleta mãe “Coiflets 1” foi o tipo mais adequado dentre os considerados no estudo [13]. Dessa forma, foi realizada a decomposição dos sinais utilizando a transformada discreta de wavelet, com tipo de onda Coiflets 1, e a partir dos coeficientes obtidos, foram reconstruídas as ondas alfa, beta, theta e delta, as quais foram analisadas com as mesmas técnicas utilizadas no sinal original.

Para a decomposição do sinal e a reconstrução das ondas  $\alpha$ ,  $\beta$ ,  $\theta$  e  $\delta$ , como exemplificadas nos gráficos da figura 4.1, foi utilizada a biblioteca PyWavelets [24].




Figura 4.1: Exemplo das bandas do eletrodo 44 do paciente 12 no tempo T0 (com DCL).

## 4.2 Mapeamento de séries temporais em grafos de quantis

No método de grafos de quantis (GQ), primeiramente são identificados os  $Q$  quantis da série temporal, onde  $Q = 2^{\sqrt[3]{T}}$ , e  $T$  é o número de pontos da série, sendo que cada quantil  $q_i$  é associado a um vértice  $n_i \in \mathcal{N}$  na rede correspondente, e que  $\mathcal{N}$  é o número total de vértices. Dois vértices  $n_i$  e  $n_j$  são conectados na rede com um arco  $(n_i, n_j, w_{ij}^\tau \in \mathcal{L})$ , onde o peso  $w_{ij}^\tau$  de cada arco é dado pelo número de vezes que um dado ponto  $x_t$  no quantil  $q_i$  é seguido por um ponto  $x_{t+K}$  no quantil  $q_j$ , com  $t = 1, 2, \dots, T$  e  $K = 1, \dots, \tau_{\max} < T$ .

A rede complexa resultante desse mapeamento é direcionada, possui peso e é conexa, e o tempo de processamento computacional gasto pelo mapeamento proposto é extremamente baixo. Na figura 4.2 é mostrado um exemplo da aplicação do método GQ em uma série temporal de 20 pontos para 3 valores de  $k$  (1, 2 e 5).




Figura 4.2: Exemplo do método QG para um série temporal de  $T = 20$ ,  $Q = 5$ , e  $k = 1$ , 2 e 5 [29].

## 4.3 Caracterizadores estruturais

A análise das redes complexas foi feita com base em cinco caracterizadores estruturais, sendo eles: o coeficiente de agrupamento ( $C$ ), o comprimento do salto médio ( $\Delta$ ), a reciprocidade ( $\rho$ ), o grau de intermediação ( $B$ ) e o comprimento do menor caminho médio

( $L$ ). Com isso, pretende-se encontrar diferenças entre os valores dos caracterizadores dos diferentes grupos de pacientes (controle, DCL e DA), e ao mesmo tempo observar padrões nos valores dentro de um mesmo grupo, e identificar, assim, os melhores caracterizadores para diferenciar pacientes pertencentes a cada grupo.

Com exceção do comprimento do salto médio, os caracterizadores foram calculados utilizando funções disponíveis na biblioteca *networkx* [15], e todos eles, incluindo o salto médio, foram testados inicialmente em uma rede de 4 vértices criada com esse propósito.

### 4.3.1 Coeficiente de agrupamento ( $C$ )

O coeficiente de agrupamento está relacionado com a tendência de formação de grupos de vértices conectados na rede. O coeficiente de agrupamento de um vértice  $n_i$  e o coeficiente de agrupamento médio de uma rede podem ser calculados, respectivamente, como:

$$C_i = \frac{E_i}{(K_i^2 - k_i)/2} \quad (4.2)$$

e

$$C = \frac{1}{\mathcal{N}} \sum_{i=1}^{\mathcal{N}} C_i, \quad (4.3)$$

onde  $E_i$  corresponde ao número de arestas existentes entre os vizinhos de um vértice  $n_i$  e  $(k_i^2 - k_i)/2$  é o número máximo de arestas que podem existir entre um vértice  $n_i$  e seus vizinhos [5, 30].

### 4.3.2 Comprimento do salto médio ( $\Delta$ )

O comprimento do salto médio ( $\Delta$ ) é definido como a média de todos os possíveis “saltos” realizados sobre uma dada rede, e é determinado por:

$$\Delta = \frac{1}{\mathcal{N}} \text{tr}(EP^T), \quad (4.4)$$

onde  $E$  é a matriz cujos elementos são obtidos por  $e_{ij} = |i - j|$ ,  $P^T$  é a transposta da matriz de transição  $P$  associada, de forma que  $p_{ij} = a_{ij} / \sum_{j=1}^{\mathcal{N}} a_{ij}$  e  $a_{ij}$  são os elementos

da matriz de adjacência, e  $\sum_j p_{ij} = 1$ , e  $tr$  é a operação de traço [2].

### 4.3.3 Reciprocidade ( $\rho$ )

A reciprocidade de uma rede direcionada diz respeito às arestas serem recíprocas ou não, ou seja, se para um vértice  $i$  ligado a um vértice  $j$ , este também é ligado a  $i$ . Para calculá-la, pode-se utilizar:

$$\rho = \frac{\sum_{ij} (a_{ij} - \bar{a})(a_{ji} - \bar{a})}{\sum_{ij} (a_{ij} - \bar{a})^2}, \quad (4.5)$$

sendo  $a_{ij}$  os elementos da matriz de adjacência e  $\bar{a}$  o valor médio desses elementos [5, 14].

### 4.3.4 Grau de intermediação ( $B$ )

O grau de intermediação é um caracterizador que quantifica a importância de um vértice  $u$  com base na presença dele em menores caminhos entre outros vértices  $i$  e  $j$ , podendo ser definida como:

$$B_u = \sum_{ij} \frac{\sigma(i, u, j)}{\sigma(i, j)}, \quad (4.6)$$

onde  $\sigma(i, u, j)$  é o número de menores caminhos de  $i$  até  $j$  que passam por  $u$  e  $\sigma(i, j)$  é o número de menores caminhos indo de  $i$  para  $j$  [5, 11]. Nesse projeto, foi considerada a intermediação média da rede, obtida a partir da soma dos valores de  $B$ , calculados para cada vértice, dividida por  $\mathcal{N}$ .

### 4.3.5 Comprimento do menor caminho médio ( $L$ )

O menor caminho é um caminho que conecta dois vértices,  $i$  e  $j$ , com comprimento mínimo, ou seja, passando pelo menor número de arestas. Em redes com peso, a mesma definição pode ser usada, levando em conta os pesos de cada aresta. A média desses valores pode ser calculada para assim encontrar o menor caminho médio, de forma que:

$$L = \frac{1}{\mathcal{N}(\mathcal{N} - 1)} \sum_{i \neq j} d_{ij}. \quad (4.7)$$



Na equação 4.7,  $d_{ij}$  são as menores distâncias, que podem ser calculadas a partir de diversos métodos numéricos, tais como os algoritmos de Dijkstra, Floyd-Warshall e Bellman-Ford. Nesse projeto, foi utilizado o algoritmo de Floyd-Warshall [5, 30, 10].

## 4.4 Dimensão fractal

Fractais podem ser definidos como objetos ou quantidades que apresentam auto-similaridade em todas as escalas, ou seja, suas partes repetem padrões do seu todo [40, 5]. Desse modo, a dimensão fractal pode representar a regularidade de uma série temporal, ou, se aplicada a sinais biomédicos, pode ser interpretada como uma medida quantitativa da complexidade do sinal [38].

Nesse trabalho, dentre vários algoritmos de estimação da dimensão fractal já apresentados na literatura, foi utilizado o proposto por Katz [21]. A partir disso, a dimensão fractal ( $\mathcal{F}$ ) de uma série temporal  $X = \{x(1), x(2), \dots, x(T)\}$ , com  $T$  pontos pode ser calculada como:

$$\mathcal{F} = \frac{\ln[T - 1]}{\ln[(dT - d)D^{-1}]}, \quad (4.8)$$

onde  $D$  é o comprimento total da série, obtido matematicamente por:

$$D = \sum_{i=1}^{T-1} \sqrt{1 + [x(i) - x(i+1)]^2}, \quad (4.9)$$

e  $d$  é a distância máxima, ou seja, a maior distância entre o primeiro ponto da série e todos os pontos sucessivos:

$$d = \max \left\{ \sqrt{(1-i)^2 + [x(1) - x(i)]^2} \mid i = 1, 2, \dots, T \right\}. \quad (4.10)$$

## 4.5 Entropia quadrática

O conceito de entropia foi, na física, utilizado por Boltzmann e Planck para medir a desordem de um sistema. Posteriormente, Shannon introduziu a entropia estatística na teoria da informação como uma medida de incerteza do sistema [41]. Quando aplicada

a um sinal, a entropia descreve seu nível de repetibilidade e previsibilidade [28]. Vários tipos de entropia foram propostos para superar as limitações de modelos anteriores. Por exemplo, a entropia de Kolmogorov–Sinai foi dada como incompatível com sinais biomédicos, então foi criada a entropia aproximada, mas seu nível de entropia para um sinal não é independente das combinações de seus parâmetros de entrada. Para superar isso, foi introduzida a entropia amostral, mas esta ainda era adversamente influenciada pelos parâmetros de entrada. Por fim, a entropia quadrática, utilizada nesse projeto, foi desenvolvida para superar as limitações da entropia amostral [33].

Matematicamente, para o cálculo da entropia de um sinal  $X$  com  $T$  pontos, deve-se primeiramente dividi-lo em  $T - m + 1$  partições, com  $m$  pontos adjacentes em cada uma. Sendo uma partição  $X_m(i)$  formada por:

$$X_m(i) = \{x(i), x(i+1), \dots, x(i+m-1)\} \quad i = 1, \dots, T - m + 1, \quad (4.11)$$

a distância  $d$  entre duas partições  $X_m(i)$  e  $X_m(j)$  pode ser calculada como:

$$d[X_m(i), X_m(j)] = \max\{|x(i+k) - x(j+k)|\} \quad k = 0, \dots, m-1. \quad (4.12)$$

A partir disso, é possível definir um vetor  $V$  com  $T - m$  posições, onde a quantidade de vezes que a desigualdade  $d[X_m(i), X_m(j)] \leq r$  é satisfeita para  $1 \leq j \leq T - m$  e  $j \neq i$  é armazenada em cada posição  $v(i)$ , sendo que  $r$  é a tolerância dentro da qual todos os elementos de duas partições devem estar para que uma combinação ocorra entre elas. A seguir, deve-se calcular a quantidade  $B_m(r)$  como:

$$B_m(r) = \frac{1}{T - m} \sum_{i=1}^{T-m} \frac{1}{T - m - 1} v(i). \quad (4.13)$$

Ao repetir esses passos substituindo  $m$  por  $m + 1$ , torna-se possível obter a entropia  $E$  do sinal:

$$E(m, r) = -\ln \left[ \frac{B_{m+1}(r)}{B_m(r)} \right]. \quad (4.14)$$

Por fim, a entropia quadrática  $\mathcal{Q}$  da série temporal é dada por:

$$\mathcal{Q}(m, r) = E(m, r) + \ln(2r). \quad (4.15)$$

Antes do cálculo de  $\mathcal{Q}$ , foi feita a padronização Z-score dos sinais, para garantir que todas as séries temporais tivessem média igual a 0 e desvio padrão igual a 1, o que limita a amplitude das séries e limita os valores da entropia quadrática de -1 a 1 [40]. Para a construção do código do cálculo da entropia quadrática, foi utilizado como base um código encontrado no GitHub [4].

## 4.6 Máquina de vetores de suporte (SVM)

Máquinas de vetores de suporte são um grupo de métodos de aprendizado supervisionado de máquina usados para classificação e regressão, propostos primeiramente em COLT-92, por Boser, Guyon e Vapnik [17]. Em termos mais gerais, a SVM é uma ferramenta comumente utilizada para lidar com problemas de classificação lineares e não lineares de aprendizado de máquina. Tal método constrói um hiperplano separador ótimo no espaço característico, o qual depende dos pontos mais próximos (chamados de vetores de suporte), levando o modelo de aprendizagem ao ótimo global [12, 19].

A boa capacidade de generalização independente da dimensão do espaço de entrada é uma propriedade marcante da SVM. Dessa forma, a SVM é adequada para a análise de dados biomédicos, como EEG, onde muitas características podem ser redundantes. Dessarte, muitos estudos recentes envolvendo sistemas automatizados de diagnósticos utilizando EEG, como detecção de transtorno do espectro autista em crianças, classificação de convulsões e até mesmo detecção de sonolência durante condução de carros, têm utilizado máquinas de vetores de suporte [42]. Para a aplicação da SVM nesse trabalho, foi utilizada a biblioteca scikit-learn [26].

# Capítulo 5

## Resultados

Primeiramente, em relação ao mapeamento das séries temporais com a utilização do método GQ, como todos os sinais possuem  $T = 46.000$  pontos, a divisão em quantis resultou em  $Q \approx 2 \times 46.000^{\frac{1}{3}} \approx 71$ . Além disso, o parâmetro  $k$  foi variado de 1 até 150. Já para o cálculo de  $\mathcal{Q}$ , os parâmetros  $m$  e  $r$  foram variados em  $m = 1$ ,  $m = 2$  e  $r = \{0,05, 0,10, \dots, 1,0\}$ .

### 5.1 Comparação entre as técnicas de caracterização utilizadas

A partir da máquina de vetores de suporte, as acurácias das diferentes técnicas e dos vários caracterizadores dos grafos foram registradas e puderam ser dispostas de três formas. A primeira é uma tabela com o maior valor de acurácia obtido e o número de vezes que foi obtido com cada técnica, tipo de sinal e período de aquisição. A segunda são gráficos com as distribuições das acurácias de 20 dos eletrodos com acurácias mais altas do sinal e tempo de aquisição para os quais foram obtidas as médias de acurácias mais altas com cada técnica, de forma que foram feitos boxplots para as técnicas mapeamento em GQ e QSE, e um gráfico de linhas para a dimensão fractal. A última forma foram mapas de calor dos eletrodos no escalpo, de acordo com as maiores acurácias obtidas com cada um, permitindo uma visualização ampla dos eletrodos com melhores resultados e das

áreas do cérebro onde esses eletrodos estão posicionados e houve uma melhor distinção entre pacientes com DCL e com DA.

A seguir estão dispostos a tabela 5.1, os gráficos das figuras 5.1, 5.2, 5.3, 5.4, 5.5, 5.6 e 5.7 e os mapas de calor das figuras 5.8, 5.9, 5.10, 5.11, 5.12, 5.13 e 5.14, descritos anteriormente.

Tabela 5.1: Maiores acurácias de cada técnica e tipo de sinal.

| <b>Técnica</b>  | <b>Sinal</b>   | <b>Acurácia máxima (T0/T1)</b> | <b>Número de vezes (T0/T1)</b> |
|-----------------|----------------|--------------------------------|--------------------------------|
| $(C)$           | Sinal original | 0,9444/0,8500                  | 2/1                            |
|                 | Alfa           | 1,0000/0,8000                  | 2/5                            |
|                 | Beta           | 1,0000/0,8833                  | 2/2                            |
|                 | Teta           | 1,0000/0,8333                  | 5/2                            |
|                 | Delta          | 1,0000/0,9000                  | 6/2                            |
| $(\Delta)$      | Sinal original | 1,0000/0,9500                  | 6/2                            |
|                 | Alfa           | 0,9500/0,9000                  | 4/1                            |
|                 | Beta           | 1,0000/0,9000                  | 2/4                            |
|                 | Teta           | 1,0000/0,9000                  | 4/4                            |
|                 | Delta          | 0,9500/0,9500                  | 4/2                            |
| $(\rho)$        | Sinal original | 1,0000/0,9500                  | 1/1                            |
|                 | Alfa           | 1,0000/0,9000                  | 4/3                            |
|                 | Beta           | 1,0000/0,9000                  | 11/1                           |
|                 | Teta           | 1,0000/0,9000                  | 3/2                            |
|                 | Delta          | 1,0000/0,9000                  | 2/5                            |
| $(B)$           | Sinal original | 1,0000/0,9500                  | 2/1                            |
|                 | Alfa           | 0,9500/0,8500                  | 8/4                            |
|                 | Beta           | 1,0000/0,9000                  | 2/1                            |
|                 | Teta           | 1,0000/0,9500                  | 4/2                            |
|                 | Delta          | 1,0000/0,9000                  | 2/2                            |
| $(L)$           | Sinal original | 0,9500/0,9500                  | 1/1                            |
|                 | Alfa           | 1,0000/0,9500                  | 14/1                           |
|                 | Beta           | 1,0000/0,9500                  | 23/1                           |
|                 | Teta           | 1,0000/0,9500                  | 18/8                           |
|                 | Delta          | 1,0000/0,9000                  | 6/6                            |
| $(\mathcal{F})$ | Sinal original | 0,8444/0,7500                  | 7/7                            |
|                 | Alfa           | 0,8444/0,7333                  | 2/4                            |
|                 | Beta           | 0,8944/0,7500                  | 4/2                            |
|                 | Teta           | 0,8944/0,7333                  | 41/15                          |
|                 | Delta          | 0,8944/0,7500                  | 40/1                           |
| $(\mathcal{Q})$ | Sinal original | 0,8944/0,7500                  | 38/41                          |
|                 | Alfa           | 0,8944/0,8000                  | 112/2                          |
|                 | Beta           | 0,8944/0,7833                  | 58/2                           |
|                 | Teta           | 0,8944/0,7500                  | 94/8                           |
|                 | Delta          | 0,8944/0,7333                  | 56/4                           |




Figura 5.1: Gráfico das distribuições das acurácias por eletrodos obtidas com o coeficiente de agrupamento aplicado às ondas Teta no tempo T0.




Figura 5.2: Gráfico das distribuições das acurácias por eletrodos obtidas com o comprimento do salto médio aplicado às ondas Beta no tempo T0.




Figura 5.3: Gráfico das distribuições das acurácias por eletrodos obtidas com a reciprocidade aplicada às ondas Delta no tempo T0.




Figura 5.4: Gráfico das distribuições das acurácias por eletrodos obtidas com o grau de intermediação aplicado às ondas Beta no tempo T0.




Figura 5.5: Gráfico das distribuições das acurácias por eletrodos obtidas com o comprimento do menor caminho médio aplicado às ondas Delta no tempo T0.




Figura 5.6: Gráfico das distribuições das acurácias por eletrodos obtidas com a entropia quadrática aplicada às ondas Teta no tempo T0.






Figura 5.7: Gráfico das distribuições das acurácias por eletrodos obtidas com a dimensão fractal aplicada às ondas Teta no tempo T0.

Mapa de calor dos eletrodos no escalpo - Coeficiente de agrupamento - Ondas Teta - T0




Figura 5.8: Mapa de calor dos eletrodos no escalpo classificados a partir das maiores acurácias obtidas para cada um com o coeficiente de agrupamento aplicado às ondas Teta no tempo T0.

Mapa de calor dos eletrodos no escalpo - Comprimento do salto médio - Ondas Beta - T0




Figura 5.9: Mapa de calor dos eletrodos no escalpo classificados a partir das maiores acurácias obtidas para cada um com o comprimento do salto médio aplicado às ondas Beta no tempo T0.

Mapa de calor dos eletrodos no escalpo - Reciprocidade - Ondas Delta - T0




Figura 5.10: Mapa de calor dos eletrodos no escalpo classificados a partir das maiores acurácias obtidas para cada um com a reciprocidade aplicada às ondas Delta no tempo T0.

Mapa de calor dos eletrodos no escalpo - Grau de intermediação - Ondas Beta - T0




Figura 5.11: Mapa de calor dos eletrodos no escalpo classificados a partir das maiores acurácias obtidas para cada um com o grau de intermediação aplicado às ondas Beta no tempo T0.

Mapa de calor dos eletrodos no escalpo - Comprimento do menor caminho médio - Ondas Delta - T0




Figura 5.12: Mapa de calor dos eletrodos no escalpo classificados a partir das maiores acurácias obtidas para cada um com o comprimento do menor caminho médio aplicado às ondas Delta no tempo T0.

Mapa de calor dos eletrodos no escalpo - Entropia quadrática - Ondas Teta - T0




Figura 5.13: Mapa de calor dos eletrodos no escalpo classificados a partir das maiores acurácias obtidas para cada um com a entropia quadrática aplicada às ondas Teta no tempo T0.

Mapa de calor dos eletrodos no escalpo - Dimensão fractal - Ondas Teta - T0




Figura 5.14: Mapa de calor dos eletrodos no escalpo classificados a partir das maiores acurácias obtidas para cada um com a dimensão fractal aplicada às ondas Teta no tempo T0.

A partir da tabela, é possível observar que as maiores acurácias em relação às técnicas foram obtidas por meio dos caracterizadores dos grafos de quantis, independentemente do tipo de sinal, uma vez que, com todos os caracterizadores, foram obtidas acurácias de 1,00. Entretanto, percebe-se que, em bandas distintas, o número de maiores acurácias varia, e diferentes caracterizadores demonstraram melhores resultados. Nesse sentido, com o comprimento do menor caminho médio ( $L$ ) foi obtido, ao todo, o maior número de acurácias 1,00, sendo esse total 62, e com a banda beta foi obtido o maior número de acurácias 1,00, mesmo ao considerar apenas o comprimento de menor caminho médio ou ao considerar todos os caracterizadores. Além disso, é possível notar que apenas nos tempos de aquisição T0 foram obtidas acurácias de 1,00, o que pode indicar uma melhor precisão em diagnósticos mais precoces.

Ademais, no que concerne aos gráficos, nota-se, em um olhar geral, que as distribuições das acurácias seguem comportamentos distintos, de forma que, enquanto algumas técnicas demonstraram intervalos mais amplos de acurácias, outras apresentaram acurácias com valores muito próximos. Nesse viés, percebe-se que, apesar de não alcançar acurácias de 100%, a QSE foi a técnica com maior concentração das acurácias e, em muitos casos, elevadas, podendo ser considerada a técnica com maior constância e estabilidade no que se refere aos 20 eletrodos de melhores resultados.

Por fim, ao observar os mapas de calor, é possível perceber os eletrodos mais sensíveis às mudanças causadas pela DA e as regiões do encéfalo onde houve uma melhor caracterização dos pacientes entre portadores de DCL e portadores de DA, o que pode indicar que são áreas mais afetadas durante o desenvolvimento da doença. Além disso, pode-se notar que as técnicas GQ, com uso do comprimento do menor caminho médio, e QSE, aplicadas, respectivamente, às ondas Delta e Teta no tempo T0 demonstraram acurácias mais altas em quase todas as regiões das figuras.

## Capítulo 6

### Conclusões

Neste trabalho, foi proposta a distinção entre o declínio cognitivo leve e a doença de Alzheimer de 19 pacientes, dos quais apenas 2 portavam a DA na data de aquisição T0 mas 3 sofreram evolução de DCL para DA até a data de aquisição T1, e a identificação das regiões encefálicas mais afetadas pela doença. Tal caracterização foi feita por meio de códigos em Python com a utilização de técnicas amplamente utilizadas na literatura e do método GQ. Por conseguinte, pôde ser feita a comparação do desempenho de tais técnicas computacionais, de acordo com suas acurácias, na indicação dos estágios da DA.

A partir dos resultados obtidos, é possível dizer que todos os métodos demonstraram bons resultados, apresentando acurácias superiores a 0,80 ou até mesmo iguais a 1,00 com a técnica GQ com a escolha adequada dos eletrodos, do tipo de sinal e dos parâmetros. Convém ressaltar que o comprimento do menor caminho médio apresentou resultados muito elevados em relação aos demais procedimentos, principalmente quando aplicado às ondas beta, possuindo o maior número de acurácias 1,00, porém, com distribuições de acurácias por eletrodos com amplitudes muito variadas, de forma que as médias mais altas foram obtidas com o coeficiente de agrupamento e o grau de intermediação.

Ao se comparar os resultados deste trabalho, no qual foi utilizada uma base de dados de HD-EEG, com os do estudo anterior, no qual foi utilizada uma base de dados de EEG comum, nota-se um grande aumento das acurácias obtidas em todas as técnicas e, principalmente, das maiores acurácias obtidas, uma vez que, com as eletroencefalografias comuns, foi obtida uma acurácia máxima de 0,7619, enquanto com as de alta densidade,

foram obtidas várias acurácias de 1,00. Entretanto, devido ao baixo número de pacientes que compõem a base de dados utilizada, é necessário apontar a necessidade de um estudo futuro envolvendo uma base de dados de HD-EEG com um maior número de pacientes a serem analisados, para que seja possível comprovar se as altas acurácias obtidas se manterão.

Em suma, foi mostrado que o uso de técnicas computacionais na análise de sinais de EEG pode ser eficaz na identificação e classificação automatizada de estágios da DA. Os resultados obtidos também mostraram as diferentes dinâmicas de cada técnica, uma vez que demonstraram diferentes sensibilidades, amplitudes e distribuições de acurácias. Com isso, conclui-se que os resultados obtidos neste estudo, no diagnóstico automático da doença, foram promissores e que, com a realização de trabalhos futuros com grupos amostrais maiores, será possível chegar a um estágio em que a detecção automática da DA, com a utilização da inteligência artificial, poderá ser implementada em âmbito clínico. Por fim, com o conhecimento das áreas do escalpo correspondentes a cada eletrodo, será possível mapear as regiões do encéfalo onde ocorreram as maiores acurácias e a doença foi melhor detectada, o que pode indicar as áreas mais afetadas do cérebro.

# Referências Bibliográficas

- [1] A. Campanharo, F. Ramos, E. Macau, R. Rosa, M. Bolzan, and L. Sá. Searching chaos and coherent structures in the atmospheric turbulence above the amazon forest. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 366(1865):579–589, 2008.
- [2] A. S. Campanharo and F. M. Ramos. Hurst exponent estimation of self-affine time series using quantile graphs. *Physica A: Statistical Mechanics and its Applications*, 444:43–48, 2016.
- [3] A. S. Campanharo, M. I. Sirer, R. D. Malmgren, F. M. Ramos, and L. A. N. Amaral. Duality between time series and networks. *PloS one*, 6(8):e23378, 2011.
- [4] K. J. CG. Vectorized implementations of sample entropy (sampen) and approximate entropy (apen). <https://github.com/kirajcg/pysampen>, 2025.
- [5] L. d. F. Costa, F. A. Rodrigues, G. Travieso, and P. R. Villas Boas. Characterization of complex networks: A survey of measurements. *Advances in physics*, 56(1):167–242, 2007.
- [6] J. Dauwels, F.-B. Vialatte, and A. Cichocki. On the early diagnosis of Alzheimer’s disease from EEG signals: a mini-review. In *Advances in Cognitive Neurodynamics (II) Proceedings of the Second International Conference on Cognitive Neurodynamics-2009*, pages 709–716. Springer, 2010.



- [7] J.-P. Eckmann and D. Ruelle. Fundamental limitations for estimating dimensions and Lyapunov exponents in dynamical systems. *Physica D: Nonlinear Phenomena*, 56(2-3):185–187, 1992.
- [8] G. Fiscon, E. Weitschek, A. Cialini, G. Felici, P. Bertolazzi, S. De Salvo, A. Bramanti, P. Bramanti, and M. C. De Cola. Combining EEG signal processing with supervised methods for Alzheimer’s patients classification. *BMC medical informatics and decision making*, 18:1–10, 2018.
- [9] G. Fiscon, E. Weitschek, G. Felici, P. Bertolazzi, S. De Salvo, P. Bramanti, and M. C. De Cola. Alzheimer’s disease patients classification through EEG signals processing. In *2014 IEEE Symposium on Computational Intelligence and Data Mining (CIDM)*, pages 105–112. IEEE, 2014.
- [10] R. W. Floyd. Algorithm 97: shortest path. *Communications of the ACM*, 5(6):345–345, 1962.
- [11] L. Freeman. A set of measures of centrality based on betweenness. *Sociometry*, 1977.
- [12] K. Fu, J. Qu, Y. Chai, and Y. Dong. Classification of seizure based on the time-frequency image of EEG signals using hht and svm. *Biomedical Signal Processing and Control*, 13:15–22, 2014.
- [13] T. Gandhi, B. K. Panigrahi, and S. Anand. A comparative study of wavelet families for EEG signal classification. *Neurocomputing*, 74(17):3051–3057, 2011.
- [14] D. Garlaschelli and M. I. Loffredo. Patterns of link reciprocity in directed networks. *Physical review letters*, 93(26):268701, 2004.
- [15] A. A. Hagberg, D. A. Schult, and P. J. Swart. Exploring network structure, dynamics, and function using networkx. In G. Varoquaux, T. Vaught, and J. Millman, editors, *Proceedings of the 7th Python in Science Conference*, pages 11 – 15, Pasadena, CA USA, 2008.

- [16] J. Hobson. The montreal cognitive assessment (moca). *Occupational Medicine*, 65(9):764–765, 2015.
- [17] V. Jakkula. Tutorial on support vector machine (svm). *School of EECS, Washington State University*, 37(2.5):3, 2006.
- [18] D.-H. Jeong, Y.-D. Kim, I.-U. Song, Y.-A. Chung, and J. Jeong. Wavelet energy and wavelet coherence as EEG biomarkers for the diagnosis of Parkinson’s disease-related dementia and Alzheimer’s disease. *Entropy*, 18(1):8, 2015.
- [19] J. Kang, X. Han, J. Song, Z. Niu, and X. Li. The identification of children with autism spectrum disorder by svm approach on EEG and eye-tracking data. *Computers in biology and medicine*, 120:103722, 2020.
- [20] H. Kantz and T. Schreiber. *Nonlinear time series analysis*. Cambridge university press, 2003.
- [21] M. J. Katz. Fractals and the analysis of waveforms. *Computers in biology and medicine*, 18(3):145–156, 1988.
- [22] T. W. Körner. *Fourier analysis*. Cambridge university press, 2022.
- [23] F. La Foresta, F. C. Morabito, S. Marino, and S. Dattola. High-density EEG signal processing based on active-source reconstruction for brain network analysis in Alzheimer’s disease. *Electronics*, 8(9):1031, 2019.
- [24] G. R. Lee, R. Gommers, F. Waselewski, K. Wohlfahrt, and A. O’Leary. Pywavelets: A Python package for wavelet analysis. *Journal of Open Source Software*, 4(36):1237, 2019.
- [25] A. H. Meghdadi, M. Stevanović Karić, M. McConnell, G. Rupp, C. Richard, J. Hamilton, D. Salat, and C. Berka. Resting state EEG biomarkers of cognitive decline associated with Alzheimer’s disease and mild cognitive impairment. *PloS one*, 16(2):e0244180, 2021.

- [26] F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, P. Prettenhofer, R. Weiss, V. Dubourg, J. Vanderplas, A. Passos, D. Cournapeau, M. Brucher, M. Perrot, and E. Duchesnay. Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, 12:2825–2830, 2011.
- [27] D. Percival. *Wavelet methods for time series analysis*. Cambridge University Press, 2000.
- [28] T. D. Pham, H. Z. Elfiqi, S. Knecht, H. Wersching, B. T. Baune, and K. Berger. Structural simplicity of the brain. *Journal of neuroscience methods*, 188(1):113–126, 2010.
- [29] A. M. Pineda, F. M. Ramos, L. E. Betting, and A. S. Campanharo. Quantile graphs for EEG-based diagnosis of Alzheimer’s disease. *Plos one*, 15(6):e0231169, 2020.
- [30] E. R. Pinto. Estudo da dinâmica de epidemias em redes complexas. 2018.
- [31] D. Pirrone, E. Weitschek, P. Di Paolo, S. De Salvo, and M. C. De Cola. EEG signal processing and supervised machine learning to early diagnose Alzheimer’s disease. *Applied sciences*, 12(11):5413, 2022.
- [32] J. Sheng, M. Shao, Q. Zhang, R. Zhou, L. Wang, and Y. Xin. Alzheimer’s disease, mild cognitive impairment, and normal aging distinguished by multi-modal parcellation and machine learning. *Scientific Reports*, 10(1):5475, 2020.
- [33] S. Simons, D. Abasolo, and J. Escudero. Classification of Alzheimer’s disease from quadratic sample entropy of electroencephalogram. *Healthcare technology letters*, 2(3):70–73, 2015.
- [34] A. Sohrabpour, Y. Lu, P. Kankirawatana, J. Blount, H. Kim, and B. He. Effect of EEG electrode number on epileptic source localization in pediatric patients. *Clinical Neurophysiology*, 126(3):472–480, 2015.

- [35] J. Song, C. Davey, C. Poulsen, P. Luu, S. Turovets, E. Anderson, K. Li, and D. Tucker. EEG source localization: Sensor density and head surface coverage. *Journal of neuroscience methods*, 256:9–21, 2015.
- [36] C. Sorg, V. Riedl, M. Muhlau, V. D. Calhoun, T. Eichele, L. Läer, A. Drzezga, H. Förstl, A. Kurz, C. Zimmer, et al. Selective changes of resting-state networks in individuals at risk for Alzheimer’s disease. *Proceedings of the National Academy of Sciences*, 104(47):18760–18765, 2007.
- [37] R. Srinivasan, D. M. Tucker, and M. Murias. Estimating the spatial nyquist of the human EEG. *Behavior Research Methods, Instruments, & Computers*, 30(1):8–19, 1998.
- [38] T. Staudinger and R. Polikar. Analysis of complexity based EEG features for the diagnosis of Alzheimer’s disease. In *2011 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, pages 2033–2036. IEEE, 2011.
- [39] S. H. Strogatz. *Nonlinear dynamics and chaos*. 1996.
- [40] M. L. Vicchietti. Aplicação de métodos computacionais no estudo e na detecção da doença de Alzheimer. Dissertação de mestrado, 2022.
- [41] X. Xing. Physical entropy, information entropy and their evolution equations. *Science in China Series A: Mathematics*, 44:1331–1339, 2001.
- [42] M. V. Yeo, X. Li, K. Shen, and E. P. Wilder-Smith. Can svm be used for automatic EEG detection of drowsiness during car driving? *Safety Science*, 47(1):115–124, 2009.
- [43] Y. Zhou, J. H. Dougherty Jr, K. F. Hubner, B. Bai, R. L. Cannon, and R. K. Hutson. Abnormal connectivity in the posterior cingulate and hippocampus in early Alzheimer’s disease and mild cognitive impairment. *Alzheimer’s & Dementia*, 4(4):265–270, 2008.

# Anexo I - Tabelas com os resultados dos 20 eletrodos com maiores acurácias dentre todas as técnicas

Tabela 1: Maiores acurácias para os sinais originais no tempo T0.

| Eletrodos | Sinal original - T0 |               |               |               |               |         |                     |
|-----------|---------------------|---------------|---------------|---------------|---------------|---------|---------------------|
|           | (C)                 | (Δ)           | (ρ)           | (B)           | (L)           | (F)     | (Q)                 |
| 2         | 0,7444; k=22        | 1,0000; k=132 | 0,7444; k=85  | 0,5889; k=7   | 0,7889; k=18  | 0,6389  | 0,7944; m=1; r=0,05 |
| 5         | 0,7889; k=51        | 1,0000; k=139 | 0,7444; k=57  | 0,8389; k=63  | 0,7944; k=89  | 0,6444  | 0,8944; m=1; r=0,05 |
| 40        | 0,8889; k=7         | 0,8389; k=52  | 1,0000; k=120 | 0,7944; k=74  | 0,8389; k=39  | 0,6889  | 0,8944; m=1; r=0,05 |
| 49        | 0,7889; k=95        | 0,8500; k=128 | 0,6833; k=100 | 1,0000; k=19  | 0,8944; k=105 | 0,5444  | 0,8944; m=1; r=0,05 |
| 161       | 0,7389; k=49        | 1,0000; k=26  | 0,65; k=123   | 0,7889; k=112 | 0,8333; k=99  | 0,5944  | 0,8944; m=1; r=0,05 |
| 172       | 0,6833; k=3         | 0,85; k=83    | 0,6833; k=125 | 1,0000; k=29  | 0,6778; k=14  | 0,5944  | 0,7944; m=1; r=0,05 |
| 196       | 0,7500; k=12        | 1,0000; k=52  | 0,7944; k=1   | 0,7500; k=1   | 0,8444; k=25  | 0,7444  | 0,7944; m=1; r=0,05 |
| 214       | 0,8944; k=46        | 1,0000; k=77  | 0,6889; k=1   | 0,6944; k=120 | 0,8944; k=26  | 0,7444; | 0,7389; m=1; r=0,05 |
| 224       | 0,7389; k=138       | 1,0000; k=87  | 0,6833; k=130 | 0,6889; k=17  | 0,7944; k=36  | 0,8444  | 0,6778; m=1; r=0,05 |
| 27        | 0,8944; k=8         | 0,9500; k=80  | 0,6889; k=22  | 0,7944; k=77  | 0,8444; k=140 | 0,5444  | 0,7944; m=1; r=0,05 |
| 62        | 0,7444; k=114       | 0,9500 k=68   | 0,6444; k=149 | 0,6944; k=60  | 0,6833; k=42  | 0,7444  | 0,8389; m=1; r=0,05 |
| 75        | 0,7944; k=29        | 0,7944; k=24  | 0,7333; k=64  | 0,8944; k=2   | 0,9500; k=75  | 0,8444  | 0,6778; m=1; r=0,05 |
| 144       | 0,8333; k=3         | 0,8444; k=64  | 0,5833; k=1   | 0,9500; k=65  | 0,9000; k=22  | 0,6167  | 0,8944 m=2; r=0,05  |
| 154       | 0,7389; k=26        | 0,95; k=10    | 0,7333; k=20  | 0,8389; k=2   | 0,7333; k=117 | 0,5444  | 0,7944; m=1; r=0,05 |
| 170       | 0,6389; k=4         | 0,9500; k=30  | 0,6444; k=75  | 0,6944; k=27  | 0,6889; k=52  | 0,5889  | 0,7444; m=1; r=0,05 |
| 220       | 0,7444; k=128       | 0,7389; k=127 | 0,6389; k=69  | 0,9500; k=84  | 0,8944; k=24  | 0,6944  | 0,7833; m=1; r=0,50 |
| 25        | 0,6278; k=97        | 0,9444; k=65  | 0,7944; k=85  | 0,7444; k=53  | 0,9444; k=49  | 0,5944  | 0,7944; m=1; r=0,05 |
| 26        | 0,6278; k=83        | 0,9444; k=64  | 0,7444; k=103 | 0,7333; k=2   | 0,7389; k=1   | 0,5444  | 0,7944; m=1; r=0,05 |
| 30        | 0,9444; k=122       | 0,8444; k=17  | 0,6444; k=31  | 0,7889; k=53  | 0,7944; k=69  | 0,5389  | 0,7944; m=1; r=0,05 |
| 90        | 0,6278 k=7          | 0,9444; k=61  | 0,5889; k=111 | 0,6333; k=114 | 0,7833; k=20  | 0,6722  | 0,7944; m=1; r=0,05 |

Tabela 2: Maiores acurácias para os sinais originais no tempo T1.

| Eletrodos | Sinal original - T1 |               |               |               |               |        |                     |
|-----------|---------------------|---------------|---------------|---------------|---------------|--------|---------------------|
|           | (C)                 | (Δ)           | (ρ)           | (B)           | (L)           | (F)    | (Q)                 |
| 3         | 0,5667; k=5         | 0,9000; k=64  | 0,8000; k=119 | 0,9500; k=45  | 0,8500; k=39  | 0,6000 | 0,7000; m=2; r=0,15 |
| 44        | 0,4833; k=1         | 0,9500; k=87  | 0,7500; k=19  | 0,7333; k=1   | 0,8000; k=92  | 0,6000 | 0,7500; m=1; r=0,05 |
| 110       | 0,6833; k=13        | 0,9500; k=93  | 0,7500; k=30  | 0,5833; k=7   | 0,6833; k=28  | 0,4833 | 0,7500; m=2; r=0,85 |
| 144       | 0,8000; k=7         | 0,6833; k=28  | 0,9500; k=1   | 0,8500; k=7   | 0,8333; k=65  | 0,5333 | 0,7500; m=2; r=0,40 |
| 211       | 0,6500; k=126       | 0,7833; k=4   | 0,5833; k=54  | 0,6500; k=92  | 0,9500; k=80  | 0,5167 | 0,6500; m=1; r=0,15 |
| 50        | 0,6000; k=20        | 0,9333; k=33  | 0,7833; k=6   | 0,6500; k=22  | 0,8333; k=4   | 0,6333 | 0,6833; m=1; r=0,15 |
| 63        | 0,6167; k=96        | 0,9333; k=34  | 0,7333; k=129 | 0,6667; k=4   | 0,7833; k=4   | 0,5333 | 0,6500; m=2; r=0,05 |
| 4         | 0,7333; k=37        | 0,6333; k=55  | 0,9000; k=137 | 0,7833; k=104 | 0,8833; k=130 | 0,5333 | 0,6833; m=2; r=0,15 |
| 8         | 0,7333; k=91        | 0,7833; k=89  | 0,9000; k=137 | 0,5833; k=101 | 0,8833; k=141 | 0,6500 | 0,6333; m=1; r=0,35 |
| 31        | 0,5833; k=17        | 0,9000; k=89  | 0,9000; k=132 | 0,7500; k=6   | 0,8500; k=6   | 0,7000 | 0,7333; m=1; r=0,05 |
| 51        | 0,5667; k=5         | 0,8833; k=34  | 0,7333; k=3   | 0,9000; k=6   | 0,8500; k=36  | 0,4667 | 0,5833; m=2; r=0,25 |
| 53        | 0,6167; k=19        | 0,7500; k=79  | 0,6833; k=141 | 0,7000; k=23  | 0,9000; k=41  | 0,4667 | 0,7500; m=1; r=0,05 |
| 59        | 0,6833; k=3         | 0,9000; k=66  | 0,8000; k=103 | 0,8000; k=4   | 0,7833; k=2   | 0,4833 | 0,6000; m=1; r=0,10 |
| 60        | 0,5167; k=34        | 0,8500; k=19  | 0,7000; k=55  | 0,8500; k=4   | 0,9000; k=63  | 0,4167 | 0,6500; m=1; r=0,40 |
| 64        | 0,7333; k=51        | 0,8000; k=61  | 0,7833; k=104 | 0,7000; k=4   | 0,9000; k=17  | 0,5167 | 0,6500; m=1; r=0,15 |
| 80        | 0,5333; k=6         | 0,7333; k=93  | 0,6333; k=138 | 0,7333; k=51  | 0,9000; k=36  | 0,3833 | 0,7500; m=1; r=0,10 |
| 85        | 0,5833; k=1         | 0,8000; k=31  | 0,9000; k=1   | 0,6333; k=1   | 0,6500; k=16  | 0,7000 | 0,7000; m=1; r=0,05 |
| 96        | 0,5333; k=1         | 0,7500; k=19  | 0,9000; k=2   | 0,7833; k=32  | 0,6833; k=2   | 0,7000 | 0,7000; m=1; r=0,05 |
| 127       | 0,6167; k=1         | 0,7833; k=3   | 0,6333; k=41  | 0,7833; k=68  | 0,9000; k=77  | 0,6500 | 0,6333; m=1; r=0,35 |
| 150       | 0,5333; k=110       | 0,6500; k=126 | 0,8167; k=3   | 0,7000; k=13  | 0,9000; k=108 | 0,6500 | 0,6833; m=2; r=0,20 |

Tabela 3: Maiores acurácias para as ondas alfa no tempo T0.

| Eletrodos | Ondas alfa T0 |               |               |               |               |        |                     |
|-----------|---------------|---------------|---------------|---------------|---------------|--------|---------------------|
|           | (C)           | (Δ)           | (ρ)           | (B)           | (L)           | (F)    | (Q)                 |
| 8         | 0,7889; k=96  | 0,7944; k=126 | 0,9500; k=22  | 0,6778; k=23  | 1,0000; k=23  | 0,5667 | 0,8944; m=1; r=0,05 |
| 14        | 0,7333; k=113 | 0,7944; k=2   | 1,0000; k=143 | 0,8444; k=105 | 0,9000; k=86  | 0,6278 | 0,7944; m=1; r=0,05 |
| 17        | 0,9000; k=14  | 0,7444; k=32  | 0,8444; k=114 | 0,7444; k=3   | 1,0000; k=3   | 0,7889 | 0,8944; m=1; r=0,05 |
| 23        | 0,9500; k=1   | 0,6944; k=52  | 0,9500; k=143 | 0,6389; k=88  | 1,0000; k=107 | 0,5167 | 0,8944; m=1; r=0,05 |
| 25        | 0,8444; k=109 | 0,8944; k=59  | 0,8500; k=108 | 0,8444; k=149 | 1,0000; k=22  | 0,7889 | 0,8944; m=1; r=0,05 |
| 26        | 0,8944; k=4   | 0,8500; k=30  | 0,8444; k=84  | 0,8944; k=150 | 1,0000; k=22  | 0,7333 | 0,8944; m=1; r=0,05 |
| 37        | 1,0000; k=12  | 0,9500; k=61  | 0,9000; k=107 | 0,8444; k=96  | 0,8444; k=20  | 0,6833 | 0,8944; m=1; r=0,05 |
| 61        | 0,9000; k=88  | 0,7389; k=126 | 0,6944; k=60  | 0,7889; k=75  | 1,0000; k=85  | 0,5722 | 0,7389; m=1; r=0,05 |
| 64        | 0,6778; k=36  | 0,8444; k=126 | 0,7889; k=127 | 0,9000; k=138 | 1,0000; k=138 | 0,5667 | 0,8444; m=1; r=0,05 |
| 127       | 0,7889; k=96  | 0,7944; k=126 | 0,9500; k=22  | 0,6778; k=23  | 1,0000; k=23  | 0,5667 | 0,8944; m=1; r=0,05 |
| 129       | 0,7444; k=106 | 0,8444; k=29  | 1,0000; k=114 | 0,7889; k=30  | 0,9444; k=59  | 0,8444 | 0,8944; m=1; r=0,05 |
| 137       | 0,7333; k=113 | 0,7944; k=2   | 1,0000; k=143 | 0,8444; k=105 | 0,9000; k=86  | 0,6278 | 0,7944; m=1; r=0,05 |
| 140       | 0,9000; k=14  | 0,7444; k=32  | 0,8444; k=114 | 0,7444; k=3   | 1,0000; k=3   | 0,7889 | 0,8944; m=1; r=0,05 |
| 150       | 0,9500; k=1   | 0,6944; k=52  | 0,9500; k=143 | 0,6389; k=88  | 1,0000; k=107 | 0,5167 | 0,8944; m=1; r=0,05 |
| 152       | 0,8444; k=109 | 0,8944; k=59  | 0,8500; k=108 | 0,8444; k=149 | 1,0000; k=22  | 0,7889 | 0,8944; m=1; r=0,05 |
| 153       | 0,8944; k=4   | 0,8500; k=30  | 0,8444; k=84  | 0,8944; k=150 | 1,0000; k=22  | 0,7333 | 0,8944; m=1; r=0,05 |
| 159       | 0,8944; k=1   | 0,7833; k=27  | 1,0000; k=148 | 0,6889; k=91  | 0,9500; k=6   | 0,4667 | 0,8944; m=1; r=0,05 |
| 171       | 1,0000; k=12  | 0,9500; k=61  | 0,9000; k=107 | 0,8444; k=96  | 0,8444; k=20  | 0,6833 | 0,8944; m=1; r=0,05 |
| 206       | 0,9000; k=88  | 0,7389; k=126 | 0,6944; k=60  | 0,7889; k=75  | 1,0000; k=85  | 0,5722 | 0,7389; m=1; r=0,05 |
| 211       | 0,6778; k=36  | 0,8444; k=126 | 0,7889; k=127 | 0,9000; k=138 | 1,0000; k=138 | 0,5667 | 0,8444; m=1; r=0,05 |

Tabela 4: Maiores acurácias para as ondas alfa no tempo T1.

| Eletrodos | Ondas alfa T1 |               |               |               |               |        |                     |
|-----------|---------------|---------------|---------------|---------------|---------------|--------|---------------------|
|           | (C)           | (Δ)           | (ρ)           | (B)           | (L)           | (F)    | (Q)                 |
| 129       | 0,5167; k=144 | 0,7500; k=29  | 0,7000; k=35  | 0,6833; k=29  | 0,9500; k=2   | 0,2000 | 0,6833; m=2; r=0,05 |
| 11        | 0,6500; k=76  | 0,7333; k=30  | 0,7000; k=78  | 0,6833; k=64  | 0,9000; k=6   | 0,5333 | 0,5333; m=2; r=0,05 |
| 18        | 0,7167; k=2   | 0,7333; k=144 | 0,6333; k=135 | 0,6333; k=51  | 0,9000; k=16  | 0,4333 | 0,6833; m=1; r=0,05 |
| 19        | 0,7333; k=2   | 0,7833; k=110 | 0,6500; k=29  | 0,6833; k=3   | 0,9000; k=149 | 0,5333 | 0,6333; m=2; r=0,05 |
| 36        | 0,5333; k=25  | 0,6167; k=61  | 0,8000; k=8   | 0,6833; k=109 | 0,9000; k=139 | 0,5333 | 0,6833; m=2; r=0,05 |
| 44        | 0,6667; k=41  | 0,7167; k=2   | 0,7833; k=20  | 0,7833; k=5   | 0,9000; k=64  | 0,5833 | 0,6833; m=2; r=0,05 |
| 53        | 0,6000; k=1   | 0,7000; k=63  | 0,9000; k=56  | 0,5833; k=110 | 0,8333; k=51  | 0,4833 | 0,6833; m=2; r=0,05 |
| 63        | 0,6833; k=2   | 0,7500; k=75  | 0,7333; k=21  | 0,7500; k=37  | 0,9000; k=93  | 0,3833 | 0,6833; m=1; r=0,05 |
| 79        | 0,4167; k=16  | 0,7500; k=16  | 0,9000; k=120 | 0,6667; k=48  | 0,7500; k=3   | 0,5333 | 0,5833; m=1; r=0,05 |
| 88        | 0,8000; k=70  | 0,7500; k=26  | 0,6333; k=130 | 0,5833; k=102 | 0,9000; k=28  | 0,5500 | 0,4833; m=1; r=0,20 |
| 89        | 0,6333; k=16  | 0,9000; k=38  | 0,7000; k=2   | 0,8500; k=44  | 0,7333; k=79  | 0,4333 | 0,5833; m=2; r=0,05 |
| 109       | 0,6333; k=113 | 0,6333; k=38  | 0,8000; k=121 | 0,6667; k=2   | 0,9000; k=110 | 0,3833 | 0,4833; m=1; r=0,05 |
| 141       | 0,7167; k=2   | 0,7333; k=144 | 0,6333; k=135 | 0,6333; k=51  | 0,9000; k=16  | 0,4333 | 0,6833; m=1; r=0,05 |
| 142       | 0,7333; k=2   | 0,7833; k=110 | 0,6500; k=29  | 0,6833; k=3   | 0,9000; k=149 | 0,5333 | 0,6333; m=2; r=0,05 |
| 170       | 0,5333; k=25  | 0,6167; k=61  | 0,8000; k=8   | 0,6833; k=109 | 0,9000; k=139 | 0,5333 | 0,6833; m=2; r=0,05 |
| 182       | 0,6667; k=41  | 0,7167; k=2   | 0,7833; k=20  | 0,7833; k=5   | 0,9000; k=64  | 0,5833 | 0,6833; m=2; r=0,05 |
| 195       | 0,6000; k=1   | 0,7000; k=63  | 0,9000; k=56  | 0,5833; k=110 | 0,8333; k=51  | 0,4833 | 0,6833; m=1; r=0,05 |
| 210       | 0,6833; k=2   | 0,7500; k=75  | 0,7333; k=21  | 0,7500; k=37  | 0,9000; k=93  | 0,3833 | 0,6833; m=1; r=0,05 |
| 10        | 0,6333; k=7   | 0,8833; k=27  | 0,8000; k=112 | 0,7000; k=1   | 0,8500; k=3   | 0,5833 | 0,4833; m=1; r=0,05 |
| 101       | 0,4833; k=18  | 0,6500; k=31  | 0,5500; k=20  | 0,4500; k=7   | 0,8833; k=5   | 0,4833 | 0,4333; m=1; r=0,40 |

Tabela 5: Maiores acurácias para as ondas beta no tempo T0.

| Eletrodos | Ondas beta T0 |               |               |              |               |        |                     |
|-----------|---------------|---------------|---------------|--------------|---------------|--------|---------------------|
|           | (C)           | (Δ)           | (ρ)           | (B)          | (L)           | (F)    | (Q)                 |
| 15        | 0,7889; k=26  | 0,7889; k=26  | 0,8889; k=82  | 0,6778; k=92 | 1,0000; k=38  | 0,6889 | 0,7944; m=1; r=0,05 |
| 66        | 0,8444; k=1   | 0,7389; k=47  | 1,0000; k=96  | 0,6389; k=28 | 0,8000; k=68  | 0,8444 | 0,8944; m=2; r=0,05 |
| 87        | 0,7889; k=41  | 0,7944; k=39  | 0,8944; k=25  | 0,7389; k=54 | 1,0000; k=101 | 0,5333 | 0,6889; m=2; r=0,10 |
| 98        | 0,7889; k=30  | 0,9000; k=29  | 0,9444; k=40  | 0,7944; k=4  | 1,0000; k=22  | 0,5333 | 0,7444; m=1; r=0,10 |
| 99        | 0,7278; k=63  | 0,7944; k=29  | 0,9444; k=88  | 0,6889; k=75 | 1,0000; k=22  | 0,5333 | 0,8944; m=2; r=0,05 |
| 100       | 0,8944; k=7   | 0,8500; k=29  | 0,9444; k=39  | 0,7389; k=63 | 1,0000; k=22  | 0,6833 | 0,8944; m=2; r=0,05 |
| 101       | 0,7944; k=120 | 0,8944; k=30  | 0,8333; k=55  | 0,7333; k=3  | 1,0000; k=13  | 0,5778 | 0,8944; m=1; r=0,05 |
| 107       | 0,8389; k=112 | 0,8444; k=29  | 1,0000; k=28  | 0,6333; k=12 | 0,9500; k=23  | 0,5444 | 0,4889; m=1; r=0,05 |
| 108       | 0,8389; k=42  | 0,7889; k=47  | 1,0000; k=41  | 0,6833; k=12 | 1,0000; k=26  | 0,6444 | 0,8944; m=2; r=0,10 |
| 109       | 0,8333; k=39  | 0,7944; k=30  | 0,8889; k=88  | 0,7389; k=82 | 1,0000; k=13  | 0,6944 | 0,7833; m=2; r=0,05 |
| 115       | 0,7278; k=119 | 0,7944; k=31  | 0,9444; k=88  | 0,7444; k=37 | 1,0000; k=13  | 0,6444 | 0,8389; m=1; r=0,05 |
| 118       | 0,8944; k=10  | 0,9000; k=29  | 1,0000; k=35  | 0,7389; k=31 | 0,9500; k=13  | 0,5278 | 0,8944; m=1; r=0,05 |
| 124       | 1,0000; k=1   | 0,8444; k=27  | 1,0000; k=55  | 0,7389; k=92 | 0,9000; k=26  | 0,6444 | 0,8944; m=1; r=0,05 |
| 127       | 0,9000; k=2   | 0,7944; k=30  | 0,8944; k=56  | 0,7389; k=13 | 1,0000; k=40  | 0,6889 | 0,8444; m=2; r=0,05 |
| 128       | 0,9000; k=2   | 0,7889; k=8   | 1,0000; k=81  | 0,7333; k=11 | 0,9000; k=70  | 0,5889 | 0,8444; m=1; r=0,10 |
| 138       | 0,7889; k=26  | 0,7889; k=26  | 0,8889; k=82  | 0,6778; k=92 | 1,0000; k=38  | 0,6889 | 0,7944; m=1; r=0,05 |
| 140       | 0,7944; k=2   | 0,7944; k=31  | 0,9500; k=104 | 0,7333; k=15 | 1,0000; k=5   | 0,6889 | 0,8944; m=2; r=0,05 |
| 143       | 0,7889; k=85  | 0,7444; k=22  | 0,9444; k=80  | 0,7444; k=34 | 1,0000; k=22  | 0,5722 | 0,8944; m=2; r=0,05 |
| 150       | 0,8944; k=41  | 0,7389; k=7   | 0,8444; k=40  | 0,6889; k=1  | 1,0000; k=38  | 0,7944 | 0,7444; m=1; r=0,05 |
| 206       | 0,8500; k=2   | 1,0000; k=126 | 0,9444; k=118 | 1,0000; k=45 | 0,8444; k=60  | 0,7944 | 0,7444; m=1; r=0,05 |

Tabela 6: Maiores acurácias para as ondas beta no tempo T1.

| Eletrodos | Ondas beta T1 |               |               |               |              |        |                     |
|-----------|---------------|---------------|---------------|---------------|--------------|--------|---------------------|
|           | (C)           | (Δ)           | (ρ)           | (B)           | (L)          | (F)    | (Q)                 |
| 97        | 0,6333; k=67  | 0,6000; k=95  | 0,6833; k=3   | 0,5833; k=8   | 0,9500; k=73 | 0,5500 | 0,6333; m=1; r=0,95 |
| 11        | 0,5833; k=80  | 0,8000; k=11  | 0,9000; k=129 | 0,8000; k=14  | 0,8500; k=25 | 0,4167 | 0,6333; m=1; r=0,05 |
| 12        | 0,6333; k=117 | 0,9000; k=9   | 0,7833; k=139 | 0,9000; k=15  | 0,7500; k=13 | 0,4167 | 0,6833; m=1; r=0,05 |
| 14        | 0,6333; k=149 | 0,8333; k=45  | 0,7000; k=72  | 0,8333; k=14  | 0,9000; k=72 | 0,6000 | 0,5833; m=2; r=0,10 |
| 17        | 0,6333; k=78  | 0,6333; k=45  | 0,8000; k=146 | 0,4333; k=16  | 0,9000; k=70 | 0,6000 | 0,6833; m=1; r=0,05 |
| 22        | 0,6167; k=142 | 0,7333; k=11  | 0,7500; k=55  | 0,5167; k=2   | 0,9000; k=24 | 0,6500 | 0,6333; m=1; r=0,05 |
| 87        | 0,6333; k=1   | 0,6833; k=80  | 0,6833; k=108 | 0,5333; k=2   | 0,9000; k=54 | 0,4833 | 0,6333; m=1; r=0,05 |
| 109       | 0,6333; k=38  | 0,6500; k=10  | 0,7500; k=1   | 0,6500; k=132 | 0,9000; k=26 | 0,5000 | 0,7333; m=1; r=0,05 |
| 115       | 0,6333; k=4   | 0,6333; k=23  | 0,8333; k=96  | 0,3333; k=8   | 0,9000; k=13 | 0,6000 | 0,7333; m=2; r=0,05 |
| 118       | 0,7833; k=1   | 0,6833; k=29  | 0,7833; k=6   | 0,6167; k=2   | 0,9000; k=13 | 0,6000 | 0,7333; m=2; r=0,05 |
| 124       | 0,6333; k=14  | 0,8333; k=94  | 0,8500; k=3   | 0,7500; k=126 | 0,9000; k=89 | 0,5500 | 0,6833; m=1; r=0,05 |
| 127       | 0,6833; k=20  | 0,6667; k=141 | 0,8000; k=22  | 0,5167; k=56  | 0,9000; k=25 | 0,6000 | 0,6833; m=2; r=0,05 |
| 130       | 0,6333; k=12  | 0,7000; k=1   | 0,7500; k=23  | 0,7500; k=123 | 0,9000; k=41 | 0,3667 | 0,6333; m=2; r=0,05 |
| 137       | 0,6333; k=149 | 0,8333; k=45  | 0,7000; k=72  | 0,8333; k=14  | 0,9000; k=72 | 0,6000 | 0,5833; m=2; r=0,10 |
| 140       | 0,6333; k=78  | 0,6333; k=45  | 0,8000; k=146 | 0,4333; k=16  | 0,9000; k=70 | 0,6000 | 0,6833; m=1; r=0,05 |
| 141       | 0,6333; k=23  | 0,7333; k=30  | 0,7333; k=36  | 0,6500; k=76  | 0,9000; k=22 | 0,6000 | 0,6333; m=2; r=0,05 |
| 149       | 0,6167; k=142 | 0,7333; k=11  | 0,7500; k=55  | 0,5167; k=2   | 0,9000; k=24 | 0,6500 | 0,6333; m=1; r=0,05 |
| 152       | 0,6333; k=9   | 0,8500; k=31  | 0,8000; k=118 | 0,6500; k=3   | 0,9000; k=38 | 0,6000 | 0,6333; m=1; r=0,05 |
| 159       | 0,6833; k=149 | 0,7333; k=40  | 0,8000; k=136 | 0,5667; k=34  | 0,9000; k=14 | 0,6000 | 0,6333; m=2; r=0,05 |
| 160       | 0,5333; k=44  | 0,6500; k=8   | 0,7333; k=32  | 0,5167; k=86  | 0,9000; k=54 | 0,6000 | 0,6333; m=2; r=0,05 |

Tabela 7: Maiores acurácias para as ondas teta no tempo T0.

| Eletrodos | Ondas teta T0 |               |               |               |               |        |                     |
|-----------|---------------|---------------|---------------|---------------|---------------|--------|---------------------|
|           | (C)           | (Δ)           | (ρ)           | (B)           | (L)           | (F)    | (Q)                 |
| 11        | 0,6222; k=2   | 1,0000; k=79  | 0,8444; k=2   | 0,9444; k=1   | 0,8444; k=3   | 0,3611 | 0,5833; m=1; r=0,10 |
| 12        | 0,6167; k=39  | 1,0000; k=47  | 0,8500; k=117 | 0,9500; k=51  | 0,8389; k=45  | 0,2556 | 0,6778; m=1; r=1,00 |
| 18        | 0,9000; k=136 | 0,7333; k=2   | 0,7944; k=70  | 1,0000; k=49  | 0,9500; k=37  | 0,8944 | 0,8944; m=1; r=0,05 |
| 19        | 1,0000; k=81  | 0,9000; k=112 | 1,0000; k=77  | 0,8389; k=127 | 1,0000; k=47  | 0,8944 | 0,8944; m=1; r=0,05 |
| 26        | 0,7944; k=45  | 0,7333; k=75  | 0,7444; k=58  | 0,8389; k=55  | 1,0000; k=7   | 0,8944 | 0,8944; m=1; r=0,05 |
| 30        | 0,9000; k=128 | 0,8944; k=92  | 0,8944; k=72  | 0,9000; k=39  | 1,0000; k=37  | 0,8944 | 0,7833; m=1; r=0,05 |
| 70        | 0,8944; k=4   | 0,9444; k=45  | 0,8444; k=8   | 1,0000; k=1   | 0,9500; k=3   | 0,3556 | 0,4333; m=1; r=0,05 |
| 77        | 0,7389; k=39  | 0,7889; k=88  | 0,8389; k=88  | 0,7944; k=38  | 1,0000; k=149 | 0,4667 | 0,8444; m=2; r=0,05 |
| 78        | 0,7389; k=21  | 0,8889; k=148 | 0,8944; k=39  | 0,7833; k=42  | 1,0000; k=50  | 0,3556 | 0,7944; m=2; r=0,05 |
| 87        | 0,8000; k=20  | 0,7944; k=76  | 0,7944; k=13  | 0,7889; k=3   | 1,0000; k=49  | 0,4556 | 0,8944; m=2; r=0,05 |
| 88        | 0,8389; k=9   | 0,7889; k=85  | 0,7833; k=18  | 0,8944; k=42  | 1,0000; k=51  | 0,3056 | 0,8444; m=1; r=0,05 |
| 100       | 0,9500; k=1   | 0,7889; k=149 | 0,8889; k=59  | 0,8944; k=49  | 1,0000; k=3   | 0,5111 | 0,8944; m=1; r=0,05 |
| 107       | 0,9500; k=29  | 0,7889; k=91  | 0,8944; k=63  | 0,8389; k=89  | 1,0000; k=41  | 0,5222 | 0,8944; m=1; r=0,05 |
| 128       | 0,9444; k=41  | 0,7944; k=56  | 0,8389; k=10  | 0,7889; k=144 | 1,0000; k=44  | 0,7333 | 0,8389; m=1; r=0,05 |
| 130       | 1,0000; k=2   | 0,8944; k=1   | 1,0000; k=1   | 0,9444; k=4   | 1,0000; k=39  | 0,7944 | 0,8444; m=1; r=0,05 |
| 141       | 0,9000; k=136 | 0,7333; k=2   | 0,7944; k=70  | 1,0000; k=49  | 0,9500; k=37  | 0,8944 | 0,8944; m=1; r=0,05 |
| 142       | 1,0000; k=81  | 0,9000; k=112 | 1,0000; k=77  | 0,8389; k=127 | 1,0000; k=47  | 0,8944 | 0,8944; m=1; r=0,05 |
| 192       | 0,8444; k=4   | 0,7944; k=17  | 0,8944; k=99  | 0,8389; k=139 | 1,0000; k=6   | 0,6278 | 0,8944; m=1; r=0,05 |
| 206       | 1,0000; k=1   | 1,0000; k=123 | 0,8500; k=14  | 0,8944; k=45  | 0,7944; k=3   | 0,5056 | 0,7333; m=2; r=0,05 |
| 220       | 0,8944; k=4   | 0,9444; k=45  | 0,8444; k=8   | 1,0000; k=1   | 0,9500; k=3   | 0,3556 | 0,4333; m=1; r=0,05 |

Tabela 8: Maiores acurácias para as ondas teta no tempo T1.

| Eletrodos | Ondas teta T1 |               |               |               |               |        |                     |
|-----------|---------------|---------------|---------------|---------------|---------------|--------|---------------------|
|           | (C)           | (Δ)           | (ρ)           | (B)           | (L)           | (F)    | (Q)                 |
| 17        | 0,4667; k=95  | 0,7833; k=73  | 0,7000; k=2   | 0,9500; k=60  | 0,8500; k=3   | 0,6333 | 0,6333; m=2; r=0,05 |
| 23        | 0,5833; k=2   | 0,7833; k=95  | 0,6833; k=97  | 0,6500; k=6   | 0,9500; k=122 | 0,5833 | 0,6333; m=2; r=0,05 |
| 30        | 0,7333; k=3   | 0,8333; k=51  | 0,7333; k=13  | 0,7333; k=42  | 0,9500; k=56  | 0,6333 | 0,6333; m=2; r=0,05 |
| 45        | 0,7833; k=33  | 0,8333; k=69  | 0,7833; k=85  | 0,6833; k=101 | 0,9500; k=120 | 0,6333 | 0,6833; m=2; r=0,05 |
| 53        | 0,7833; k=32  | 0,7333; k=30  | 0,7833; k=143 | 0,7833; k=38  | 0,9500; k=99  | 0,6333 | 0,6833; m=1; r=0,05 |
| 140       | 0,4667; k=95  | 0,7833; k=73  | 0,7000; k=2   | 0,9500; k=60  | 0,8500; k=3   | 0,6333 | 0,6333; m=2; r=0,05 |
| 150       | 0,5833; k=2   | 0,7833; k=95  | 0,6833; k=97  | 0,6500; k=6   | 0,9500; k=122 | 0,5833 | 0,6333; m=2; r=0,05 |
| 160       | 0,7333; k=3   | 0,8333; k=51  | 0,7333; k=13  | 0,7333; k=42  | 0,9500; k=56  | 0,6333 | 0,6333; m=2; r=0,05 |
| 183       | 0,7833; k=33  | 0,8333; k=69  | 0,7833; k=85  | 0,6833; k=101 | 0,9500; k=120 | 0,6333 | 0,6833; m=2; r=0,05 |
| 195       | 0,7833; k=32  | 0,7333; k=30  | 0,7833; k=143 | 0,7833; k=38  | 0,9500; k=99  | 0,6333 | 0,6833; m=1; r=0,05 |
| 13        | 0,6833; k=111 | 0,7333; k=36  | 0,9000; k=36  | 0,7500; k=3   | 0,7500; k=42  | 0,6833 | 0,6333; m=2; r=0,05 |
| 44        | 0,5833; k=36  | 0,7500; k=115 | 0,7333; k=27  | 0,9000; k=126 | 0,7333; k=87  | 0,6833 | 0,6833; m=2; r=0,05 |
| 54        | 0,6333; k=2   | 0,7833; k=44  | 0,6833; k=21  | 0,7667; k=65  | 0,9000; k=119 | 0,6333 | 0,7500; m=1; r=0,05 |
| 62        | 0,5833; k=3   | 0,9000; k=72  | 0,7833; k=16  | 0,7833; k=128 | 0,8333; k=98  | 0,6833 | 0,6333; m=1; r=0,20 |
| 142       | 0,6333; k=82  | 0,7833; k=96  | 0,5500; k=39  | 0,7500; k=12  | 0,9000; k=80  | 0,6333 | 0,5667; m=2; r=0,05 |
| 159       | 0,6333; k=2   | 0,7000; k=39  | 0,8000; k=109 | 0,7833; k=125 | 0,9000; k=54  | 0,6333 | 0,6333; m=2; r=0,05 |
| 162       | 0,5667; k=87  | 0,6833; k=76  | 0,7833; k=136 | 0,9000; k=110 | 0,7000; k=53  | 0,6333 | 0,6333; m=1; r=0,05 |
| 204       | 0,6500; k=43  | 0,8000; k=80  | 0,6500; k=12  | 0,7000; k=45  | 0,9000; k=138 | 0,6333 | 0,6333; m=2; r=0,05 |
| 205       | 0,5333; k=122 | 0,9000; k=48  | 0,7000; k=1   | 0,7833; k=4   | 0,9000; k=67  | 0,6333 | 0,6500; m=1; r=0,05 |
| 207       | 0,5833; k=3   | 0,9000; k=72  | 0,7833; k=16  | 0,7833; k=128 | 0,8333; k=98  | 0,6833 | 0,6333; m=1; r=0,20 |

Tabela 9: Maiores acurácias para as ondas delta no tempo T0.

| Eletrodos | Ondas delta T0 |               |               |               |               |        |                     |
|-----------|----------------|---------------|---------------|---------------|---------------|--------|---------------------|
|           | (C)            | (Δ)           | (ρ)           | (B)           | (L)           | (F)    | (Q)                 |
| 27        | 0,7944; k=3    | 0,8444; k=123 | 0,7444; k=108 | 0,8444; k=88  | 1,0000; k=121 | 0,7944 | 0,8944; m=1; r=0,05 |
| 31        | 1,0000; k=34   | 0,8444; k=7   | 0,8000; k=136 | 0,8944; k=4   | 0,7944; k=3   | 0,7944 | 0,8944; m=1; r=0,05 |
| 60        | 0,9000; k=1    | 0,7333; k=127 | 1,0000; k=64  | 1,0000; k=78  | 0,9500; k=64  | 0,5056 | 0,7833; m=1; r=0,05 |
| 62        | 0,9000; k=141  | 0,8944; k=1   | 0,7389; k=109 | 0,8889; k=114 | 1,0000; k=111 | 0,4056 | 0,8444; m=2; r=0,55 |
| 68        | 1,0000; k=33   | 0,8944; k=149 | 0,9444; k=95  | 0,8389; k=147 | 0,7278; k=40  | 0,5056 | 0,7333; m=1; r=0,05 |
| 86        | 0,7889; k=105  | 0,9000; k=112 | 0,6944; k=130 | 0,8500; k=85  | 1,0000; k=9   | 0,3556 | 0,8944; m=1; r=0,05 |
| 99        | 0,7444; k=4    | 0,8944; k=114 | 0,8389; k=1   | 0,8944; k=134 | 1,0000; k=59  | 0,6722 | 0,8944; m=1; r=0,05 |
| 109       | 1,0000; k=104  | 0,6833; k=5   | 0,6833; k=1   | 0,7778; k=140 | 0,7889; k=4   | 0,5056 | 0,8944; m=1; r=0,05 |
| 154       | 0,7944; k=3    | 0,8444; k=123 | 0,7444; k=108 | 0,8444; k=88  | 1,0000; k=121 | 0,7944 | 0,8944; m=1; r=0,05 |
| 161       | 1,0000; k=34   | 0,8444; k=7   | 0,8000; k=136 | 0,8944; k=4   | 0,7944; k=3   | 0,7944 | 0,8944; m=1; r=0,05 |
| 205       | 0,9000; k=1    | 0,7333; k=127 | 1,0000; k=64  | 1,0000; k=78  | 0,9500; k=64  | 0,5056 | 0,7833; m=1; r=0,05 |
| 207       | 0,9000; k=141  | 0,8944; k=1   | 0,7389; k=109 | 0,8889; k=114 | 1,0000; k=111 | 0,4056 | 0,8444; m=2; r=0,55 |
| 212       | 1,0000; k=1    | 0,7278; k=148 | 0,9500; k=117 | 0,6833; k=128 | 0,7389; k=128 | 0,5056 | 0,7833; m=1; r=0,05 |
| 214       | 1,0000; k=33   | 0,8944; k=149 | 0,9444; k=95  | 0,8389; k=147 | 0,7278; k=40  | 0,5056 | 0,7333; m=1; r=0,05 |
| 25        | 0,9500; k=72   | 0,7889; k=4   | 0,8000; k=19  | 0,6944; k=130 | 0,8444; k=136 | 0,7944 | 0,7833; m=1; r=0,05 |
| 26        | 0,8500; k=18   | 0,8389; k=86  | 0,6889; k=92  | 0,8389; k=105 | 0,9500; k=139 | 0,7944 | 0,8944; m=1; r=0,05 |
| 132       | 0,8444; k=23   | 0,8944; k=1   | 0,9500; k=11  | 0,7889; k=1   | 0,8444; k=10  | 0,8944 | 0,8389; m=1; r=0,05 |
| 141       | 0,8944; k=6    | 0,6833; k=88  | 0,8500; k=1   | 0,7500; k=115 | 0,9500; k=145 | 0,7944 | 0,7833; m=1; r=0,05 |
| 152       | 0,9500; k=72   | 0,7889; k=4   | 0,8000; k=19  | 0,6944; k=130 | 0,8444; k=136 | 0,7944 | 0,7833; m=1; r=0,05 |
| 221       | 0,9500; k=7    | 0,8944; k=123 | 0,9500; k=49  | 0,8444; k=110 | 0,8389; k=127 | 0,4556 | 0,8944; m=1; r=0,45 |

Tabela 10: Maiores acurácias para as ondas delta no tempo T1.

| Eletrodos | Ondas delta T1 |               |               |               |               |        |                     |
|-----------|----------------|---------------|---------------|---------------|---------------|--------|---------------------|
|           | (C)            | (Δ)           | (ρ)           | (B)           | (L)           | (F)    | (Q)                 |
| 14        | 0,6333; k=105  | 0,9500; k=115 | 0,8000; k=29  | 0,6833; k=110 | 0,7333; k=148 | 0,6833 | 0,6333; m=2; r=0,05 |
| 137       | 0,6333; k=105  | 0,9500; k=115 | 0,8000; k=29  | 0,6833; k=110 | 0,7333; k=148 | 0,6833 | 0,6333; m=2; r=0,05 |
| 5         | 0,6000; k=1    | 0,8833; k=121 | 0,9000; k=146 | 0,7500; k=83  | 0,7833; k=108 | 0,6333 | 0,5833; m=1; r=0,05 |
| 6         | 0,5333; k=99   | 0,9000; k=126 | 0,8000; k=79  | 0,7333; k=64  | 0,8500; k=8   | 0,6333 | 0,5833; m=1; r=0,05 |
| 10        | 0,6000; k=1    | 0,7833; k=109 | 0,9000; k=79  | 0,8500; k=89  | 0,8500; k=22  | 0,6333 | 0,5333; m=2; r=0,05 |
| 15        | 0,4833; k=2    | 0,9000; k=122 | 0,8000; k=9   | 0,7833; k=69  | 0,6833; k=18  | 0,6333 | 0,6333; m=1; r=0,05 |
| 19        | 0,5833; k=104  | 0,6833; k=79  | 0,6667; k=3   | 0,7500; k=3   | 0,9000; k=2   | 0,6833 | 0,3833; m=1; r=0,05 |
| 26        | 0,9000; k=142  | 0,6833; k=99  | 0,7500; k=3   | 0,8833; k=146 | 0,7833; k=1   | 0,6333 | 0,5833; m=1; r=0,05 |
| 49        | 0,5333; k=2    | 0,8000; k=42  | 0,7000; k=86  | 0,7000; k=58  | 0,9000; k=99  | 0,6333 | 0,4833; m=1; r=0,05 |
| 68        | 0,6167; k=7    | 0,8333; k=125 | 0,9000; k=41  | 0,8333; k=111 | 0,7167; k=42  | 0,4833 | 0,5833; m=1; r=0,05 |
| 86        | 0,5333; k=2    | 0,7333; k=147 | 0,6000; k=60  | 0,9000; k=98  | 0,8500; k=103 | 0,6833 | 0,4333; m=1; r=0,05 |
| 96        | 0,5333; k=2    | 0,8500; k=150 | 0,7833; k=11  | 0,7833; k=6   | 0,9000; k=17  | 0,6833 | 0,4333; m=1; r=0,05 |
| 110       | 0,7333; k=1    | 0,9000; k=93  | 0,8333; k=4   | 0,8000; k=4   | 0,9000; k=78  | 0,7333 | 0,5333; m=1; r=0,05 |
| 124       | 0,6000; k=1    | 0,8833; k=121 | 0,9000; k=146 | 0,7500; k=83  | 0,7833; k=108 | 0,6333 | 0,5833; m=1; r=0,05 |
| 125       | 0,5333; k=99   | 0,9000; k=126 | 0,8000; k=79  | 0,7333; k=64  | 0,8500; k=8   | 0,6333 | 0,5833; m=1; r=0,05 |
| 138       | 0,4833; k=2    | 0,9000; k=122 | 0,8000; k=9   | 0,7833; k=69  | 0,6833; k=18  | 0,6333 | 0,6333; m=1; r=0,05 |
| 142       | 0,5833; k=104  | 0,6833; k=79  | 0,6667; k=3   | 0,7500; k=3   | 0,9000; k=2   | 0,6833 | 0,3833; m=1; r=0,05 |
| 153       | 0,9000; k=142  | 0,6833; k=99  | 0,7500; k=3   | 0,8833; k=146 | 0,7833; k=1   | 0,6333 | 0,5833; m=1; r=0,05 |
| 191       | 0,5333; k=2    | 0,8000; k=42  | 0,7000; k=86  | 0,7000; k=58  | 0,9000; k=99  | 0,6333 | 0,4833; m=1; r=0,05 |
| 214       | 0,6167; k=7    | 0,8333; k=125 | 0,9000; k=41  | 0,8333; k=111 | 0,7167; k=42  | 0,4833 | 0,5833; m=1; r=0,05 |