

UNIVERSIDADE FEDERAL DO PARANÁ

JORGE VINICIUS MALOSTI DA SILVEIRA

UMA ANÁLISE ENTRÓPICA DA DINÂMICA CORTICAL VIA QUANTIFICADORES DE
RECORRÊNCIA E APRENDIZADO DE MÁQUINA

CURITIBA

2025

JORGE VINICIUS MALOSTI DA SILVEIRA

UMA ANÁLISE ENTRÓPICA DA DINÂMICA CORTICAL VIA QUANTIFICADORES DE
RECORRÊNCIA E APRENDIZADO DE MÁQUINA

Dissertação apresentada ao Programa de Pós-Graduação em Física do Setor de Ciências Exatas da Universidade Federal do Paraná como requisito parcial para a obtenção de título de Mestre em Física..

Orientador: Prof. Dr. Thiago de Lima Prado

CURITIBA

2025

DADOS INTERNACIONAIS DE CATALOGAÇÃO NA PUBLICAÇÃO (CIP)
UNIVERSIDADE FEDERAL DO PARANÁ
SISTEMA DE BIBLIOTECAS – BIBLIOTECA CIÊNCIA E TECNOLOGIA

Silveira, Jorge Vinicius Malosti da

Uma análise entrópica da dinâmica cortical via quantificadores de recorrência e aprendizado de máquina. / Jorge Vinicius Malosti da Silveira. – Curitiba, 2025.

1 recurso on-line : PDF.

Dissertação (Mestrado) – Universidade Federal do Paraná, Setor de Ciências Exatas, Programa de Pós-Graduação em Física.

Orientador: Prof. Dr. Thiago de Lima Prado.

1. Eletroencefalograma (EEG). 2. Aprendizado por computador. 3. Entropia (Física). I. Universidade Federal do Paraná. II. Programa de Pós-Graduação em Física. III. Prado, Thiago de Lima. IV. Título.

Bibliotecária: Roseny Rivelini Morciani CRB-9/1585

TERMO DE APROVAÇÃO

Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação FÍSICA da Universidade Federal do Paraná foram convocados para realizar a arguição da Dissertação de Mestrado de **JORGE VINICIUS MALOSTI DA SILVEIRA**, intitulada: **"Uma Análise Entrópica da Dinâmica Cortical via Quantificadores de Recorrência e Aprendizado de Máquina"**, sob orientação do Prof. Dr. THIAGO DE LIMA PRADO, que após terem inquirido o aluno e realizada a avaliação do trabalho, são de parecer pela sua APROVAÇÃO no rito de defesa.

A outorga do título de mestre está sujeita à homologação pelo colegiado, ao atendimento de todas as indicações e correções solicitadas pela banca e ao pleno atendimento das demandas regimentais do Programa de Pós-Graduação.

CURITIBA, 30 de Julho de 2025.

Assinatura Eletrônica

30/07/2025 16:57:49.0

THIAGO DE LIMA PRADO

Presidente da Banca Examinadora

Assinatura Eletrônica

04/08/2025 11:37:25.0

GILBERTO CORSO

Avaliador Externo (UNIVERSIDADE FEDERAL DO RIO GRANDE DO NORTE)

Assinatura Eletrônica

30/07/2025 16:40:43.0

RICARDO LUIZ VIANA

Avaliador Interno (UNIVERSIDADE FEDERAL DO PARANÁ)

AGRADECIMENTOS

Gostaria, primeiramente, de agradecer ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo apoio financeiro concedido à realização desta pesquisa.

Agradeço, de forma especial, ao meu orientador, Prof. Dr. Thiago de Lima Prado, por ter me acolhido no grupo com tanta generosidade, pelos ensinamentos, pelas oportunidades oferecidas, e, sobretudo, pela amizade.

Expresso também minha profunda gratidão à minha família, que, mesmo sem conseguir compartilhar plenamente os conteúdos aqui apresentados, nunca deixou de me apoiar e de me proporcionar a chance de seguir minha vocação.

E como o verdadeiro mestrado são os amigos que fazemos no caminho, são eles que desejo evidenciar: por tornarem a jornada mais tranquila, pelas conversas nas salas e no R.U. após as aulas, pelas risadas, fofocas e, principalmente, pelo apoio, inclusive nas semanas de eletromagnetismo.

*“E aí Jorge... e esse mestrado lero-lero aí?
Cê tá no poli hoje ou cê tá em casa?
Tem que trabalhar, ein.”*

– Prof. Dr. Guilherme Jean Pereira de Abreu

RESUMO

Neste trabalho, utilizamos dados de eletroencefalograma (EEG) de 19 indivíduos submetidos a quatro condições experimentais distintas, repouso e pedalar, com olhos abertos ou fechados, a fim de investigar a dinâmica cortical sob diferentes estados motores e sensoriais. Aplicamos dois quantificadores entrópicos inspirados na teoria de sistemas dinâmicos: a entropia de microestados de recorrência e um quantificador de desordem recentemente proposto, visando caracterizar a complexidade, no sentido de variabilidade e imprevisibilidade dos padrões de atividade cerebral ao longo do tempo, dos sinais de EEG em diferentes regiões corticais. Utilizando esses quantificadores como *features*, implementamos um classificador do tipo *Random Forest* com 100 árvores e validação por 50 repetições para cada cenário experimental. A acurácia da classificação foi avaliada em diferentes combinações de canais (1, 2, 4 ou 8 canais), considerando as condições de movimento e o estado visual. Os resultados indicaram que pedalar reduz significativamente a complexidade cortical, como previsto por Ferré et al. (2024), e que essa redução favorece a classificação dos estados comportamentais. O quantificador de desordem com tamanho de microestado $N = 4$ alcançou acurácias de até 82% na classificação do estado visual durante o movimento e 79% em repouso, superando a entropia de recorrência. Observamos também assimetrias entre regiões parietais e occipitais, e confirmamos que o uso conjunto dos 8 canais melhora substancialmente a performance do modelo em relação ao uso isolado de canais. Esses achados sugerem que a complexidade cortical influencia diretamente a capacidade preditiva de modelos computacionais, e que o quantificador de desordem oferece uma alternativa promissora para análises de sinais neurais em diferentes estados cognitivos e motores.

Palavras-chaves: EEG; entropia; microestados; aprendizado de máquina; recorrência.

ABSTRACT

In this work, we used electroencephalogram (EEG) data from 19 individuals under four distinct experimental conditions, resting and cycling, with eyes open or closed, to investigate cortical dynamics under different motor and sensory states. We applied two entropy-based quantifiers inspired by dynamical systems theory: the recurrence microstate entropy and a recently proposed disorder quantifier, aiming to characterize the complexity, in the sense of variability and unpredictability of brain activity patterns over time, of EEG signals across different cortical regions. These quantifiers were used as features in a Random Forest classifier with 100 trees, evaluated across 50 repetitions for each experimental scenario. Classification accuracy was assessed for different channel combinations (1, 2, 4, or 8 EEG channels), considering both movement and visual state conditions. Results showed that cycling significantly reduces cortical complexity, as originally suggested by Ferré et al. (2024), and that this reduction enhances behavioral state classification. The disorder quantifier with microstate size $N = 4$ achieved accuracies of up to 82% for classifying visual state during movement, and 79% during rest, outperforming the recurrence entropy. We also observed asymmetries between parietal and occipital regions, and confirmed that using all 8 channels together significantly improves model performance compared to using isolated channels. These findings suggest that cortical complexity directly influences the predictive power of computational models, and that the disorder quantifier provides a promising alternative for neural signal analysis across various cognitive and motor states.

Key-words: EEG; entropy; microstates; machine learning; recurrence.

LISTA DE ILUSTRAÇÕES

- FIGURA 1 – Diagrama esquemático evidenciando as principais estruturas de um neurônio. O neurônio ilustrado é um neurônio motor, visto que seus terminais sinápticos dão de encontro diretamente em células musculares. (Figura adaptada de Kandel et. al. (2014)). 26
- FIGURA 2 – Formação de um potencial de ação induzido artificialmente. Em (a), uma corrente elétrica externa é aplicada ao corpo celular do neurônio, reduzindo progressivamente seu potencial de membrana e tornando-o menos negativo. Em (b), o acúmulo de carga positiva atinge o limiar de despolarização, desencadeando o disparo do potencial de ação. Em (c), observa-se a propagação do processo de despolarização ao longo do axônio. Figuras extraídas de Bear et al. (2017). 28
- FIGURA 3 – À esquerda, uma ilustração destacando as diferentes regiões do hemisfério esquerdo do córtex, organizadas em lobos. À direita, são evidenciadas regiões ainda mais especializadas dentro desses lobos, como o córtex motor, responsável pelo controle dos movimentos voluntários, e o córtex somatossensorial, encarregado de processar informações sensoriais como pressão, temperatura, entre outras. Imagens extraídas de Kandel et al. (2014). 29
- FIGURA 4 – Esquema de detecção de sinal por eletroencefalograma. Neurônios piramidais organizados em colunas paralelas disparam de maneira sincronizada, gerando um acúmulo de cargas negativas no meio extracelular próximo aos dendritos apicais. O dipolo elétrico formado induz outros dipolos nas camadas superiores, permitindo que o campo elétrico resultante seja detectado pelos eletrodos do EEG posicionados no couro cabeludo. Imagem extraída de Bear et al. (2017). 31
- FIGURA 5 – Ilustração do sistema internacional 10-20, utilizado para padronizar o posicionamento de eletrodos no escalpo, com as respectivas nomenclaturas baseadas em regiões anatômicas do cérebro e sua distribuição nos hemisférios esquerdo, direito e linha média. . . . 32

- FIGURA 6 – A figura apresenta três conjuntos de gráficos. Imagem (a) mostra a série temporal senoidal com frequência de 2π radianos por segundo e sua matriz de recorrência, que revela um padrão regular refletindo a periodicidade da série. Imagem (b) exibe a variação temporal na coordenada x do atrator de Lorenz com parâmetros $\sigma = 10$, $\beta = \frac{8}{3}$ e $\rho = 28$, e sua matriz de recorrência, evidenciando a estrutura complexa e caótica da série. Imagem (c) ilustra a série temporal de ruído branco, gerada com uma distribuição normal padrão, e sua matriz de recorrência, que reflete a natureza aleatória e não estruturada do ruído. 35
- FIGURA 7 – Par de pontos recorrentes no atrator caótico de Lorenz com parâmetros $\sigma = 10$, $\beta = \frac{8}{3}$ e $\rho = 28$. O ponto na posição $\vec{x}_j$ (em azul) é recorrente ao ponto $\vec{x}_i$ (em vermelho) pois está dentro da esfera de raio ϵ (contorno vermelho) centrada no ponto vermelho e vice versa. 36
- FIGURA 8 – Exemplo de obtenção de microestados. Neste caso, pequenas matrizes de tamanho 2×2 são extraídas da RP, representando diferentes configurações de recorrência. 39
- FIGURA 9 – Entropia de microestado em função do limiar de recorrência ϵ para diferentes tamanhos de microestados. Pode-se observar uma curva bastante característica com máximo bem definido na entropia tanto para série da coordenada x do sistema de Lorenz em região caótica quanto para um ruído branco, ambas normalizadas. 43
- FIGURA 10 – Diagrama esquemático de uma Árvore de Decisão. O diagrama ilustra, de maneira simplificada, o funcionamento geral de um algoritmo de árvore de decisão. No exemplo, o conjunto de dados contém quatro classes distintas de animais a serem classificados: mamíferos, aves, insetos e aracnídeos. A estrutura da árvore é construída a partir de perguntas baseadas em características numéricas dos dados (*features*), como número de patas, número de asas, temperatura corporal, oviparidade, número de olhos ou antenas, entre outros. A cada nó da árvore, uma decisão é tomada com base no valor de um atributo, levando a uma subdivisão progressiva dos dados até atingir um nó terminal, onde a classificação final é definida. Esse modelo exemplifica como uma árvore de decisão pode ser utilizada para organizar e separar diferentes categorias com base em atributos mensuráveis. 50

FIGURA 11 – Diagrama esquemático do funcionamento do algoritmo <i>Random Forest</i> . Os dados de entrada são processados por um conjunto de árvores de decisão independentes (Decision Tree 1, Decision Tree 2, ..., Decision Tree n), cada uma treinada com uma amostra diferente dos dados. Cada árvore gera uma predição individual (Resultado 1, Resultado 2, ..., Resultado n). Em seguida, essas previsões são combinadas por meio de uma votação majoritária (no caso de classificação) ou média dos valores (no caso de regressão), resultando na predição final do modelo	51
FIGURA 12 – Distribuição média dos valores de entropia por canal para diferentes tamanhos de microestados ($N = 2, 3, 4$). As médias foram calculadas ao longo das janelas temporais e entre os indivíduos.	56
FIGURA 13 – Distribuição média dos valores do quantificador de desordem por canal para diferentes tamanhos de microestados ($N = 2, 3, 4$). As médias foram calculadas ao longo das janelas temporais e entre os indivíduos.	57
FIGURA 14 – Distribuição dos valores do quantificador de Desordem para $N = 3$, organizados por canal de EEG e condição experimental: Pedalando com olhos abertos (POA), Repouso com olhos abertos (ROA), Pedalando com olhos fechados (POF) e Repouso com olhos fechados (ROF). As barras representam a variabilidade entre indivíduos ao longo do tempo, e as marcas sobre as condições indicam comparações com diferença estatisticamente significativa ($p < 0,05$), obtidas via teste t pareado. As indicações de desigualdade mostram a direção da diferença entre os grupos.	58
FIGURA 15 – Distribuições da desordem ($N = 4$) entre as regiões corticais (occipital, parietal, central e frontal), separadas por condição experimental: POA, POF, ROA e ROF. Cada subgráfico apresenta as comparações estatisticamente significativas (teste t pareado com $p < 0,05$), representadas por linhas conectando os pares de regiões com diferença relevante, acompanhadas dos respectivos valores de t e p . Apenas comparações não redundantes (não transitivas) são exibidas.	62

FIGURA 16 – Distribuições da entropia de microestados ($N = 4$) entre as regiões corticais (occipital, parietal, central e frontal), separadas por condição experimental: POA, POF, ROA e ROF. Cada subgráfico apresenta as comparações estatisticamente significativas (teste t pareado com $p < 0,05$), representadas por linhas conectando os pares de regiões com diferença relevante, acompanhadas dos respectivos valores de t e p . Apenas comparações não redundantes (não transitivas) são exibidas.	63
FIGURA 17 – Acurácia média da classificação em função do número de canais utilizados, para diferentes tamanhos de microestado (N) e para os dois quantificadores considerados. As médias foram calculadas entre todas as diferentes execuções do algoritmo anteriormente discutidas.	65
FIGURA 18 – Acurácia média da classificação em função do número de canais utilizados, comparando o uso exclusivo do valor do quantificador com o uso conjunto das probabilidades associadas aos microestados (ou classes de microestados). São apresentados resultados para ambos os quantificadores.	66
FIGURA 19 – Matrizes de confusão para as diferentes condições experimentais. Cada subfigura corresponde a uma comparação binária entre duas condições, agrupadas por uma característica fixa (por exemplo, manter o movimento fixo e variar o estado dos olhos, ou vice-versa). As etiquetas dos eixos representam as classes reais (eixo y) e as classes preditas pelo modelo (eixo x). As células mostram a proporção de classificações feitas pelo modelo para cada combinação de classes reais e preditas, normalizada por linhas.	67
FIGURA 20 – Relação entre a entropia média e a acurácia média na classificação das condições fisiológicas (olhos abertos, olhos fechados, repouso, pedalando), considerando diferentes quantificadores e valores de N . Cada ponto representa a média dos indivíduos para um determinado cenário, com barras de erro horizontais indicando o desvio padrão do quantificador entre os indivíduos e ao longo do tempo, barras de erro verticais indicando o desvio padrão da acurácia. As acurácias sendo aquelas em que os oito canais foram usados para a classificação.	68

LISTA DE TABELAS

TABELA 1 – Microestados possíveis para $N = 2$. A tabela mostra as combinações possíveis de matrizes binárias, as cores alternadas representam grupos de microestados com recorrências similares, (a) com nenhuma recorrência, (b)-(e) com apenas uma, (f)-(i) duas recorrências na mesma linha ou coluna, (j)-(k) recorrências diagonais, (l)-(o) mostram 3 pontos recorrentes e por fim (p) com todos os pontos recorrentes.	38
TABELA 2 – Resultados dos testes t pareados entre condições, para cada canal e valor de N , utilizando o quantificador de Entropia. Cada célula exibe o par de valores (t, p) para a comparação entre duas condições. Apenas comparações estatisticamente significativas ($p < 0,05$) são exibidas. O sinal de t indica qual condição teve maior média do quantificador: $t > 0$ implica média maior na condição à esquerda da comparação, e $t < 0$ implica média maior na condição à direita.	59
TABELA 3 – Resultados dos testes t pareados entre condições, para cada canal e valor de N , utilizando o quantificador de Desordem. Cada célula exibe o par de valores (t, p) para a comparação entre duas condições. Apenas comparações estatisticamente significativas ($p < 0,05$) são exibidas. O sinal de t indica qual condição teve maior média do quantificador: $t > 0$ implica média maior na condição à esquerda da comparação, e $t < 0$ implica média maior na condição à direita.	60
TABELA 4 – Métricas médias da classificação por condição (Desordem, $N = 4, 8$ canais)	68
TABELA 5 – Acurácia do quantificador Entropia ($N=2$) para diferentes condições e agrupamento de canais utilizados para a classificação.	80
TABELA 6 – Acurácia do quantificador Entropia ($N=3$) para diferentes condições e agrupamento de canais utilizados para a classificação.	80
TABELA 7 – Acurácia do quantificador Entropia ($N=4$) para diferentes condições e agrupamento de canais utilizados para a classificação.	81
TABELA 8 – Acurácia do quantificador Desordem ($N=2$) para diferentes condições e agrupamento de canais utilizados para a classificação. . .	81
TABELA 9 – Acurácia do quantificador Desordem ($N=3$) para diferentes condições e agrupamento de canais utilizados para a classificação. . .	82

TABELA 10 – Acurácia do quantificador Desordem ($N=4$) para diferentes condições e agrupamento de canais utilizados para a classificação. . . 82

SUMÁRIO

1	INTRODUÇÃO	15
2	OBJETIVOS	18
2.1	OBJETIVO GERAL	18
2.1.1	OBJETIVOS ESPECÍFICOS	18
2.1.2	ORGANIZAÇÃO DA DISSERTAÇÃO	18
3	CONCEITOS BÁSICOS	19
3.1	SISTEMAS COMPLEXOS	19
3.1.1	Simplificando a complexidade	20
3.1.2	Entropia	21
3.2	NEURÔNIOS	25
3.2.1	Potenciais de Ação	26
3.3	CAPTURANDO A DINÂMICA CEREBRAL	27
3.3.1	Eletroencefalograma	30
3.3.2	Ondas cerebrais	32
3.4	RECORRÊNCIAS	34
3.4.1	Gráficos de Recorrência	34
3.4.2	Estruturas no RP	37
3.4.3	Quantificadores de Recorrência	37
3.4.4	Microestados de Recorrências	38
3.4.5	Escolha do limiar de Recorrência	41
3.5	APRENDIZADO DE MÁQUINA	45
3.5.1	Árvores de Decisão e Florestas Aleatórias	48
4	METODOLOGIA	52
4.1	COLETA E DISPONIBILIZAÇÃO DOS DADOS	52
4.2	PRÉ-PROCESSAMENTO DOS DADOS	53
4.3	CONFIGURAÇÃO DA CLASSIFICAÇÃO	54
5	RESULTADOS E DISCUSSÃO	55
5.1	QUANTO AOS QUANTIFICADORES	55
5.1.1	QUANTO À CLASSIFICAÇÃO	64
6	CONSIDERAÇÕES FINAIS	70
	REFERÊNCIAS	73
	ANEXO 1 – TABELAS DAS ACURÁCIAS	80

1 INTRODUÇÃO

O cérebro humano é um órgão tão enigmático e complexo que, em certo sentido, oculta seus segredos até mesmo de si próprio. A busca por compreender o cérebro antecede em muito o surgimento dos métodos modernos de neuroimagem e eletrofisiologia. Registros do Antigo Egito, por exemplo, já descreviam o córtex cerebral, algumas condições neurológicas e especulavam sobre a medula espinhal como via de comunicação entre cérebro e corpo, embora não considerassem o cérebro essencial para a vida após a morte (FANOUS; COULDWELL, 2012).

Com o passar dos séculos, essa curiosidade se transformou em investigação sistemática. No século XVIII, no auge dos estudos em eletricidade, experimentos como os de Luigi Galvani, que observou contrações musculares ao aplicar corrente elétrica em rãs, inauguraram uma nova era de compreensão da atividade elétrica nos organismos vivos (KEITHLEY, 1999). Essa perspectiva transformou radicalmente a forma como entendemos os processos fisiológicos e lançou as bases para investigações mais profundas da atividade elétrica do cérebro.

Hoje em dia, existem métodos sofisticados para extrair informações da complexidade e da dinâmica cerebral, especialmente em sua conexão com o movimento do corpo. Um dos principais instrumentos utilizados para isso é o eletroencefalograma (EEG), um método não invasivo capaz de captar os sinais elétricos gerados por grandes populações de neurônios no córtex, por meio de eletrodos posicionados sobre o couro cabeludo. A versatilidade do EEG está, justamente, no fato de não exigir procedimentos cirúrgicos para acessar a atividade neural, ao contrário de técnicas invasivas que requerem a inserção de eletrodos diretamente no cérebro.

É claro que essa acessibilidade tem um custo: o EEG está sujeito a ruídos, interferências externas e limitações na resolução espacial, o que dificulta a observação do comportamento de neurônios individuais. No entanto, essa limitação se torna uma vantagem quando o interesse está na análise da atividade neural em grande escala, ou seja, nos padrões coletivos que emergem durante diferentes estados mentais ou atividades motoras realizadas com certa liberdade pelo indivíduo estudado.

A relação entre o movimento e a atividade cerebral levanta uma série de enigmas ainda não totalmente resolvidos, especialmente quando observamos dissociações curiosas entre diferentes tipos de comportamento motor. Um caso notável é o congelamento de marcha na Doença de Parkinson, caracterizado por episódios súbitos de incapacidade de iniciar ou manter a caminhada. De forma surpreendente, muitos desses pacientes mantêm a capacidade de pedalar normalmente, como demonstrado

por Snijders et al. (2011), sugerindo que o pedalar mobiliza circuitos neurais distintos ou mais preservados em comparação à caminhada. Além disso, Ridgel et al. (2015) mostraram que pedalar, especialmente em alta cadência, pode reduzir temporariamente a severidade dos sintomas motores da doença, o que levanta a hipótese de que esse tipo de movimento influencia diretamente a dinâmica cerebral de forma benéfica.

Essa hipótese é reforçada por evidências eletrofisiológicas apresentadas por Störzer et al. (2016), que compararam a atividade oscilatória cortical durante o pedalar e a caminhada em indivíduos saudáveis. O estudo revelou que o pedalar está associado a uma supressão mais sustentada do poder espectral na faixa de ondas beta (20–30 Hz), enquanto a caminhada induz uma redução predominantemente na faixa alfa. Segundo os autores, o pedalar envolve uma ativação cortical mais contínua e menos faseada, refletindo uma menor exigência de processamento sensorial e planejamento motor dependentes da fase do movimento. Isso estaria relacionado à natureza mais contínua e estável do pedalar, em contraste com o caráter intermitente e de maior variabilidade sensório-motora da caminhada.

Essas observações motivam o estudo da atividade cerebral durante o pedalar, não apenas como um exercício motor, mas como uma oportunidade de compreender como dinâmicas rítmicas e contínuas podem reorganizar ou estabilizar circuitos neurais mesmo em condições de disfunção motora. Trata-se de um ponto de partida promissor para investigar a complexidade da dinâmica cortical sob diferentes condições.

Para investigar essa complexidade, é necessário recorrer a abordagens capazes de capturar a natureza não linear, multiescalar e altamente variável da atividade elétrica cerebral. Nas últimas décadas, métodos inspirados na teoria de sistemas dinâmicos e da física de sistemas complexos têm ganhado espaço na análise de sinais neurofisiológicos, particularmente do EEG (STAM, 2005). Ao contrário de técnicas tradicionais baseadas em transformadas espectrais ou estatísticas lineares, esses métodos oferecem ferramentas para explorar padrões recorrentes, transições entre estados e graus de imprevisibilidade nos dados, características fundamentais de sistemas biológicos complexos. Medidas como entropias dinâmicas, análise de recorrência e representações simbólicas têm se mostrado promissoras na identificação de estados cerebrais distintos, na caracterização da consciência e na análise de respostas a estímulos motores e sensoriais. Essa abordagem se alinha a uma visão do cérebro não apenas como um sistema reativo, mas como um sistema dinâmico em constante reorganização, cuja atividade pode ser estudada em termos de trajetórias no espaço de estados.

A ideia de que diferentes estados cerebrais podem ser distinguidos por sua complexidade também é explorada na chamada hipótese do cérebro entrópico, proposta por Carhart-Harris e colaboradores (CARHART-HARRIS, 2018). Segundo essa hipótese,

estados de consciência mais flexíveis, como o sonho ou o uso de psicodélicos, estariam associados a uma maior entropia cerebral, no sentido de uma maior variedade e imprevisibilidade na atividade neural. Já estados mais estáveis e focados, como o sono profundo ou o uso de sedativos, teriam menor entropia. Um ponto importante dessa proposta é que a entropia não é definida por uma fórmula única, mas sim como qualquer medida quantitativa que reflita a dinâmica do cérebro. Os autores defendem que essa entropia pode ser extraída de diferentes sinais fisiológicos, como o EEG ou a ressonância magnética funcional, desde que represente uma função da atividade cerebral ao longo do tempo. Essa visão dá suporte ao uso de medidas de entropia como ferramenta para comparar diferentes condições experimentais, como repouso, movimento ou variações sensoriais, e fornece uma base conceitual para interpretações.

Um exemplo recente da aplicação bem-sucedida desses métodos encontra-se no trabalho de Gancio et al. (2024), que investigaram a dinâmica cerebral de 107 indivíduos utilizando EEG de 64 canais nas condições de olhos abertos e olhos fechados. Os autores aplicaram uma abordagem baseada em dinâmica simbólica, extraíndo de cada canal a entropia por permutação como medida da complexidade temporal. Seus resultados mostraram que, em média, a entropia era mais baixa na condição de olhos fechados, o que está de acordo com a hipótese de maior sincronização cortical nesse estado. No entanto, também observaram que essa diferença não era suficientemente robusta para distinguir de forma confiável entre as condições em nível individual, o que motivou o uso dessas medidas como *features* para algoritmos de aprendizado de máquina, mais especificamente *Random Forest*, na tentativa de melhorar a classificação entre os estados corticais. Esse trabalho destaca tanto o potencial das entropias como indicadores de dinâmica cerebral, quanto a importância de combinar essas métricas com técnicas estatísticas avançadas para lidar com a variabilidade entre sujeitos.

De forma complementar, Ferré et al. (2024) aplicaram uma abordagem semelhante com foco na dinâmica cerebral durante o movimento. Utilizando EEG de adultos saudáveis em condições de repouso e pedalar, com olhos abertos e fechados, os autores analisaram a complexidade da atividade cortical por meio da entropia de microestados de recorrência, um quantificador não linear derivado da análise de padrões temporais em séries. Seus resultados indicaram que a entropia tende a ser menor durante o pedalar e também na condição de olhos fechados, sugerindo uma redução na variabilidade da atividade neural e, possivelmente, uma maior sincronização entre regiões corticais nesses estados. Embora não tenham utilizado técnicas de aprendizado de máquina, o estudo fornece uma base empírica importante para a ideia de que o movimento rítmico e o bloqueio sensorial visual (olhos fechados) estão associados a estados cerebrais menos entrópicos. Esses dados são os mesmos utilizados neste trabalho e motivam a expansão da análise com novos quantificadores e modelos preditivos.

2 OBJETIVOS

2.1 OBJETIVO GERAL

O objetivo geral deste trabalho é investigar a dinâmica cortical associada ao movimento de pedalar e ao estado de olhos abertos ou fechados por meio de dados de EEG, utilizando quantificadores baseados em recorrência, com foco especial nos microestados de recorrência, avaliando sua utilidade em tarefas de classificação de estados cerebrais.

2.1.1 OBJETIVOS ESPECÍFICOS

- Estudar o uso de dois quantificadores distintos baseados em microestados de recorrência, variando seus parâmetros de construção e analisando sua capacidade de capturar informações relevantes da dinâmica cerebral em diferentes regiões e condições experimentais;
- Comparar os valores desses quantificadores entre as condições de repouso e pedalar, olhos abertos e fechados, a partir de dados reais de EEG;
- Utilizar os quantificadores extraídos como *features* para algoritmos de aprendizado de máquina supervisionado (como *Random Forest*), avaliando sua eficácia na classificação automática das condições;
- Investigar como a escolha do quantificador, dos parâmetros e da localização dos canais influencia o desempenho dos modelos;
- Contribuir para o entendimento das relações entre complexidade neural, comportamento motor rítmico e sensorialidade visual, a partir de uma abordagem fundamentada na teoria de sistemas dinâmicos.

2.1.2 ORGANIZAÇÃO DA DISSERTAÇÃO

Esta dissertação está organizada da seguinte forma. O Capítulo 3 apresenta os conceitos teóricos e técnicos fundamentais para o desenvolvimento do trabalho, incluindo uma introdução aos sistemas complexos, fundamentos da neurociência, análise de recorrência e aprendizado de máquina. O Capítulo 4 descreve a metodologia empregada, detalhando os dados utilizados, as etapas de pré-processamento, os quantificadores aplicados e os procedimentos de classificação. No Capítulo 5, são apresentados e discutidos os principais resultados obtidos. Por fim, o Capítulo 6 traz as conclusões do trabalho e sugestões para investigações futuras.

3 CONCEITOS BÁSICOS

3.1 SISTEMAS COMPLEXOS

Quando pensamos em algo caracterizado como complexo, é comum associarmos essa palavra à ideia de “difícil”, mas por quê? Intuitivamente, associamos complexidade à necessidade de um conhecimento aprofundado e acumulado para compreender determinado tópico. Muitas vezes, trata-se de um conjunto de saberes que, individualmente, fornecem uma base, mas que só em conjunto permitem a emergência de uma explicação mais abrangente.

O planeta Terra é uma vitrine rica em exemplos de sistemas complexos, ela própria inclusa. Considere, por exemplo, você: um ser humano formado por átomos. O comportamento desses átomos pode ser descrito, em princípio, por leis da mecânica quântica. No entanto, os átomos não estão isolados, eles se agrupam em moléculas. À medida que essas moléculas aumentam em tamanho e complexidade, o formalismo quântico torna-se cada vez mais intratável, e passamos a utilizar outras abordagens, como a dinâmica molecular.

Dentro do seu corpo, essas moléculas formam estruturas ainda mais elaboradas, como aminoácidos e proteínas, já estudadas no domínio da bioquímica. As proteínas desempenham funções fundamentais na formação de células e tecidos, que por sua vez formam órgãos e sistemas, como o nervoso e o cardiovascular, áreas que requerem anos de estudo, por exemplo, por parte da medicina. E mesmo assim, tudo isso descreve apenas um indivíduo: você.

Mas você, enquanto indivíduo, interage com amigos, familiares, colegas, compartilha ideias, valores, experiências. Essas interações não são estáticas, mudam ao longo do tempo e dependem de fatores diversos: sociais, econômicos, culturais, ambientais. Você muda, suas relações mudam, e as relações dos outros ao seu redor também. Há interações entre famílias, vizinhos, grupos em redes sociais, bairros, cidades, estados, nações. Sociedades compostas por centenas a bilhões de indivíduos, cada um com sua própria complexidade.

A sociologia, a economia, a ciência política e tantas outras áreas emergem da tentativa de compreender essas interações em grande escala. Já não se trata mais de mecânica quântica. A pergunta que define a abordagem científica agora é: em que escala você quer observar o sistema? Isso é complexidade.

Não há uma definição única e formal para um *sistema complexo*, em parte porque não existe uma disciplina isolada que o estude de forma exclusiva. No entanto,

algumas características são recorrentes na maioria das definições formais (KWAPIEŃ; DROŹDŹ, 2012):

- **Comportamento emergente:** o sistema como um todo exibe propriedades que não podem ser explicadas apenas a partir do comportamento das partes;
- **Adaptação:** o sistema pode se reorganizar, aprendendo ou evoluindo em resposta a mudanças internas ou externas;
- **Processamento de informação:** sinais são recebidos e processados, tanto do ambiente interno quanto do externo.

Essas características são amplamente compartilhadas entre diferentes tipos de sistemas complexos. Para os fins deste trabalho, é suficiente manter essa ideia geral em mente, mesmo sem uma definição formal rigorosa.

Uma descrição informal bastante clara é apresentada por Melanie Mitchell, pesquisadora sênior no Santa Fe Institute, uma das principais instituições dedicadas ao estudo de sistemas complexos, em seu livro introdutório *Complexity: A Guided Tour* (2009), voltado ao público geral:

Um sistema complexo é uma rede de muitos componentes interagindo localmente, sem controle central, seguindo regras simples que dão origem a comportamento coletivo, processamento sofisticado de informação e adaptação via aprendizado ou evolução.

Embora essa descrição transmita bem a intuição sobre sistemas complexos, é importante notar que nem todas as interações nesses sistemas são estritamente locais, muitas vezes há conexões de longo alcance ou estruturas hierárquicas que também desempenham papel fundamental na dinâmica global.

3.1.1 Simplificando a complexidade

Devido à enorme diversidade de sistemas complexos existentes, não há uma maneira direta de quantificar complexidade que seja, ao mesmo tempo, intuitiva, abrangente e matematicamente rigorosa (KWAPIEŃ; DROŹDŹ, 2012) — embora muitas abordagens já tenham sido propostas com esse objetivo.

Apesar disso, há ferramentas poderosas à nossa disposição. Uma das mais fundamentais, e também uma das preferidas dos físicos, surgiu no contexto da teoria cinética dos gases: a **mecânica estatística**.

Um gás é composto por um número imenso de partículas — na ordem de 10^{26} — em constante movimento. Cada partícula, em um dado instante, possui uma posição

e uma velocidade, e interage com outras por meio de potenciais físicos. A princípio, seria possível tentar prever o comportamento do gás modelando cada uma dessas interações individualmente. No entanto, esse tipo de abordagem é inviável: o problema é intratável com a mecânica newtoniana tradicional.

Esse cenário se encaixa perfeitamente na definição de sistema complexo discutida anteriormente. E, como aponta Sethna (2021):

A mecânica estatística explica o comportamento simples de sistemas complexos.

Isso é verdade porque a mecânica estatística não nos fornece diretamente uma medida de complexidade, mas sim ferramentas poderosas para extrair informações relevantes de sistemas complexos. No caso de um gás, por exemplo, é possível obter grandezas macroscópicas, como temperatura, pressão, densidade e magnetização, a partir da análise estatística das propriedades microscópicas das partículas que o compõem.

3.1.2 Entropia

Dentre as grandezas macroscópicas mencionadas, a que merece maior destaque é a **entropia**. Você provavelmente já ouviu diferentes tentativas de explicá-la: como a quantidade de energia dissipada na forma de calor em processos termodinâmicos; como uma medida do espalhamento da energia em um sistema; como o grau de desordem; como uma medida da ignorância que temos sobre o estado microscópico do sistema; ou ainda como a grandeza responsável por indicar a direção do tempo, associada à irreversibilidade dos processos naturais. Todas essas interpretações, apesar de distintas, apontam para um mesmo conceito fundamental: a entropia está relacionada à incerteza, à aleatoriedade e à evolução dos sistemas em direção a estados mais prováveis. A ideia de entropia surgiu originalmente com Clausius (1879) na termodinâmica clássica, como uma grandeza associada à irreversibilidade dos processos naturais, culminando na formulação da segunda lei da termodinâmica. Posteriormente, essa noção foi reinterpretada por Boltzmann sob uma perspectiva estatística, ao introduzir os conceitos de microestados e macroestados.

Um microestado nada mais é do que uma configuração possível que um sistema pode assumir em certo instante. Por exemplo, vamos imaginar um sistema simples para ilustrar esse conceito na termodinâmica: duas “barras”, formadas por uma rede de 8 átomos cada. A temperatura em cada barra é definida como a quantidade de pacotes de energia que circulam livremente de átomo para átomo, fazendo com que eles vibrem mais ou menos dependendo da energia recebida. Cada átomo tem igual probabilidade de passar esse pacote de energia para o átomo subjacente na rede.

Agora, imagine que, na barra da esquerda, temos 7 pacotes de energia distribuídos entre os 8 átomos. Um átomo pode portar mais de um pacote, claro. Já na barra da direita, temos apenas 3 pacotes distribuídos entre os 8 átomos, ou seja, os átomos na barra da esquerda vibram mais do que os da direita. Cada vez que um pacote de energia flui de um átomo para outro, temos um novo microestado do sistema. O macroestado, por sua vez, é a configuração geral, ou seja, todas as possíveis formas de distribuir os pacotes de energia entre os átomos.

Agora vamos além: imagine que juntamos as duas barras, mas que a qualquer momento podemos separá-las novamente. Antes de fazer isso, deixamos os pacotes circularem livremente entre elas, como se tivéssemos agora uma rede maior de 16 átomos. Nossa intuição nos diz que a energia (e, portanto, o calor) deve fluir da barra mais quente para a mais fria. Mas por quê?

Imagine que, depois de um tempo, separamos as barras novamente, e a da esquerda acabou passando 2 pacotes para a da direita. Agora, cada barra ficou com 5 pacotes, temos equilíbrio térmico. Tudo certo, nossa intuição funcionou bem aqui. Mas e se repetirmos o processo e, ao separar novamente, a barra da esquerda tiver 9 pacotes e a da direita apenas 1? A energia fluiu do mais frio para o mais quente?

A resposta, curiosamente, é sim. E isso quebra a segunda lei da termodinâmica? Não exatamente. Mas por que não vemos isso acontecendo no cotidiano?

A questão está na probabilidade. Existem muito mais formas diferentes (microestados) de distribuir a energia de maneira equilibrada do que de forma extremamente desigual. O estado com energia balanceada é simplesmente muito mais provável. A segunda lei da termodinâmica não proíbe que a energia vá do frio para o quente, ela apenas diz que, estatisticamente, isso quase nunca acontece.

No nosso exemplo, lidamos com apenas 16 átomos. Mas, quando elevamos esse número à ordem de grandeza do número de átomos presentes na matéria do nosso cotidiano (algo em torno de 10^{26}), a probabilidade de os pacotes de energia fluírem da barra mais fria para a mais quente se torna infinitesimal. É tecnicamente possível, mas tão improvável que nunca veremos isso acontecer na prática.

Tendo em mente a ideia de que a energia de um sistema tende, estatisticamente, a se distribuir da forma mais provável entre os microestados, Boltzmann chegou à expressão que relaciona a entropia à quantidade de microestados acessíveis. Essa relação foi posteriormente utilizada por Max Planck em seu trabalho fundamental sobre a radiação térmica (PLANCK, 1914), e é hoje expressa na forma:

$$S = k_B \ln \Omega. \quad (3.1)$$

Em que S é a entropia, Ω representa o número de microestados acessíveis ao sistema, e k_B é a constante de Boltzmann. Ele mostrou que o sistema tende a evoluir no tempo

de maneira a maximizar a entropia, e essa maximização ocorre justamente quando a energia está o mais distribuída possível entre os microestados.

É por isso que, muitas vezes, ouvimos que entropia está relacionada à energia “perdida” ou dissipada na forma de calor: trata-se, na verdade, de uma consequência da tendência natural dos sistemas de ocupar estados mais prováveis.

Mas o conceito de entropia como medida da incerteza quanto à configuração do sistema não se limita apenas à termodinâmica. Em 1948, Claude Shannon (SHANNON, 1948), trabalhando com transmissão de informação, provou matematicamente que existe um limite para a quantidade de informação que pode ser transmitida de um transmissor a um receptor através de um canal de comunicação sem interferência. Mostrou que a entropia da informação pode ser escrita como

$$H(X) = - \sum_{i=1}^n p(x_i) \log_b p(x_i), \quad (3.2)$$

onde $H(X)$ é a entropia associada a uma variável aleatória X , e $p(x_i)$ representa a probabilidade de ocorrência do estado x_i . Essa equação, no entanto, já havia sido proposta por Gibbs (GIBBS, 1902) no âmbito da mecânica estatística, como uma generalização da entropia de Boltzmann, forma que foi posteriormente aceita pelo próprio Boltzmann em seus estudos sobre a teoria dos gases (BOLTZMANN, 1896, 1898).

A entropia de Shannon é uma medida da incerteza associada aos possíveis estados que uma variável aleatória pode assumir. Para uma moeda, por exemplo, existem dois estados possíveis: cara ou coroa. Se a moeda for justa, com iguais probabilidades para cada face (50%), temos:

$$H = - \left(\frac{1}{2} \log_2 \frac{1}{2} + \frac{1}{2} \log_2 \frac{1}{2} \right) = 1 \text{ bit}, \quad (3.3)$$

que é o valor máximo de entropia para duas opções.

Agora, se os estados não forem igualmente prováveis, a entropia diminui. Imagine um dado viciado em que a face 6 tem 90% de chance de sair, e as outras cinco faces dividem os 10% restantes. Nesse caso, a incerteza é bem menor, pois já esperamos que o 6 apareça na maioria das vezes, a entropia reflete isso assumindo um valor bem menor do que no caso de um dado justo, onde cada face teria $1/6$ de probabilidade e a entropia seria máxima.

Por isso, a entropia é uma ferramenta poderosa para explorar sistemas complexos. Ela nos dá uma maneira de quantificar a distribuição de informação, ou de microestados, no sistema, permitindo entender não só o comportamento térmico de gases ou líquidos, mas também fenômenos em redes, sinais biológicos e sistemas dinâmicos em geral. É justamente essa versatilidade que faz com que diferentes formas de

entropia venham sendo desenvolvidas e aplicadas nas mais diversas áreas. Algumas dessas abordagens alternativas serão discutidas nas próximas seções, com foco em como elas podem ser utilizadas para caracterizar e classificar sistemas complexos.

3.2 NEURÔNIOS

Nesta seção discutiremos brevemente a estrutura e funcionamento dos neurônios, com foco nos aspectos essenciais para a compreensão dos processos de comunicação neural. Os conteúdos desta seção foram sintetizados a partir das obras de Bear et al. (2017) e Kandel et al. (2014), que fornecem uma base sólida para aprofundamento no tema.

O sistema nervoso humano é composto por uma rede intrincada de células especializadas, os neurônios, que formam a base para a comunicação e o processamento de informações no cérebro. Essas células são caracterizadas por sua estrutura peculiar, formada por três partes principais: o soma, o axônio e os dendritos.

O soma, frequentemente descrito como “corpo celular” ou “cabeça” do neurônio, tem aproximadamente 20 micrômetros de diâmetro e contém o núcleo, onde está o material genético da célula, além de outras organelas responsáveis pelo metabolismo neuronal. O soma é preenchido por citosol, uma solução aquosa rica em íons potássio, e é isolado do meio extracelular pela membrana neuronal, que desempenha um papel crucial na geração e propagação dos sinais elétricos.

O axônio, por sua vez, é a estrutura responsável por conduzir os sinais elétricos gerados no soma até outras células, como neurônios ou células musculares. Ele pode variar de menos de 1 milímetro a até 1 metro de comprimento, com diâmetro que vai de 1 a 25 micrômetros. Nos mamíferos, muitos axônios são revestidos por uma bainha de mielina, formada por células gliais, o que aumenta significativamente a velocidade de propagação dos sinais elétricos ao longo do axônio.

Os dendritos são ramificações em forma de galhos de árvore que se estendem a partir do soma e são especializados na recepção de sinais químicos e elétricos de outras células por meio de sinapses. Cada neurônio pode receber milhares de conexões sinápticas nos dendritos, formando uma base complexa para a integração de informações no sistema nervoso.

O processo de comunicação entre os neurônios é realizado principalmente por meio de sinapses, que são conexões funcionais entre o terminal pré-sináptico de um neurônio e o terminal pós-sináptico de outro, geralmente localizado nos dendritos. A transmissão de informações inicia-se com um potencial de ação: um sinal elétrico gerado no soma que viaja rapidamente ao longo do axônio até os terminais pré-sinápticos. Nessa região, o sinal elétrico é convertido em um sinal químico pela liberação de moléculas chamadas neurotransmissores nas fendas sinápticas, o pequeno espaço entre os neurônios.

Os neurotransmissores difundem-se pela fenda sináptica e ligam-se a receptores específicos localizados na membrana pós-sináptica, onde o sinal químico é




FIGURA 1 – Diagrama esquemático evidenciando as principais estruturas de um neurônio. O neurônio ilustrado é um neurônio motor, visto que seus terminais sinápticos dão de encontro diretamente em células musculares. (Figura adaptada de Kandel et. al. (2014)).

convertido novamente em um sinal elétrico. Esse processo de transformação permite que a informação seja transmitida de um neurônio para outro de maneira eficiente e precisa. Dependendo do tipo de neurotransmissor liberado e dos receptores envolvidos, o efeito na célula pós-sináptica pode ser excitatório, promovendo a geração de novos potenciais de ação, ou inibitório, reduzindo a probabilidade de disparo.

Os neurônios podem ser classificados em diferentes tipos morfológicos e funcionais. Do ponto de vista morfológico, destacam-se os neurônios multipolares, que possuem múltiplos dendritos e um axônio, os neurônios bipolares, com um dendrito e um axônio, e os neurônios unipolares, que possuem apenas uma extensão a partir do soma que se bifurca em uma direção aferente (entrada) e eferente (saída). Já funcionalmente, os neurônios são divididos em neurônios motores, que conduzem comandos para músculos e glândulas; neurônios sensoriais, que transmitem informações do ambiente externo ou interno para o sistema nervoso central; e interneurônios, que conectam diferentes neurônios dentro do sistema nervoso central, formando circuitos complexos de processamento.

3.2.1 Potenciais de Ação

A função fundamental dos neurônios é a comunicação, baseada na capacidade de gerar e transmitir sinais elétricos conhecidos como potenciais de ação. Em condições de repouso, o neurônio apresenta um potencial elétrico uniforme através de sua membrana plasmática, com a face interna mais negativa em relação ao meio extracelular. Essa convenção de negatividade interna baseia-se na posição dos eletrodos ao medir a diferença de potencial com um voltímetro. Geralmente, o eletrodo de referência

é colocado no meio extracelular, enquanto o eletrodo de registro é inserido no interior da célula, definindo a polaridade negativa do meio intracelular de maneira relativa.

O potencial de ação é essencial para o funcionamento dos neurônios e a transmissão de informações pelo sistema nervoso. Em repouso, o interior do neurônio apresenta uma carga elétrica negativa em relação ao meio extracelular, com um potencial de repouso geralmente em torno de -70 mV. Essa diferença é mantida por mecanismos como a bomba de sódio e potássio e pela seletividade das membranas iônicas.

Quando um neurônio recebe um estímulo adequado, ocorre uma despolarização inicial, tornando o potencial de membrana menos negativo. Isso acontece devido à entrada de *íons* de sódio (Na^+) no meio intracelular através de canais específicos. Se a despolarização ultrapassa um limiar característico (geralmente em torno de -55 mV), inicia-se o potencial de ação.

Durante o potencial de ação, há uma rápida inversão da polaridade da membrana, com o interior da célula tornando-se momentaneamente positivo em relação ao exterior. Essa fase é seguida por um processo de repolarização, onde os *íons* de potássio (K^+) são expulsos do meio intracelular, restaurando a carga negativa interna. Em alguns casos, ocorre uma hiperpolarização transitória antes do retorno ao potencial de repouso.

O potencial de ação se propaga ao longo do axônio em alta velocidade comparada com a escala de tamanho dos neurônios (na ordem de algumas dezenas de metros por segundo), permitindo que sinais elétricos sejam transmitidos de forma eficiente para outras células. Essa propagação ocorre de maneira unidirecional devido ao período refratário, durante o qual uma nova despolarização não pode ser iniciada imediatamente.

Embora entrar em grandes detalhes sobre potenciais de ação esteja além do escopo deste trabalho, esta seção fornece uma introdução ao leitor sobre como sinais elétricos são gerados no cérebro, estabelecendo a base para entender os métodos de registro e análise dos sinais neurais.

3.3 CAPTURANDO A DINÂMICA CEREBRAL

O cérebro humano é uma estrutura altamente complexa e não linear (MITCHELL, 2009; KWAPIENÍ; DROŹDŹ, 2012), composta por bilhões de neurônios interconectados, cada um capaz de disparar dezenas de vezes por segundo e compartilhar informações com seus vizinhos (KANDEL et al., 2014). Embora o comportamento individual de um neurônio possa parecer simples, a dinâmica global que emerge da interação de bilhões de neurônios revela uma complexidade impressionante. Esses




FIGURA 2 – Formação de um potencial de ação induzido artificialmente. Em (a), uma corrente elétrica externa é aplicada ao corpo celular do neurônio, reduzindo progressivamente seu potencial de membrana e tornando-o menos negativo. Em (b), o acúmulo de carga positiva atinge o limiar de despolarização, desencadeando o disparo do potencial de ação. Em (c), observa-se a propagação do processo de despolarização ao longo do axônio. Figuras extraídas de Bear et al. (2017).

disparos não ocorrem de maneira estritamente sincronizada ou ordenada, mas seguem uma “dança” aparentemente aleatória aos olhos humanos, formando padrões emergentes de atividade coletiva. Essa coordenação entre neurônios é o que permite ao córtex cerebral desempenhar funções fundamentais, como cognição, controle motor e regulação sensorial.

O cérebro, apesar de sua imensa complexidade, é organizado em regiões funcionais que refletem conglomerados de neurônios responsáveis por tarefas específicas. Experimentalmente, essas áreas têm sido associadas a funções bem documentadas, como controle motor, processamento sensorial, linguagem e memória (KANDEL et al., 2014). Essa divisão funcional, no entanto, não elimina o enigma da dinâmica cerebral: mesmo com funções localizadas, o comportamento global do cérebro emerge de interações complexas entre essas regiões, conectadas por redes neuronais extensas e altamente interdependentes (SPORNS, 2010).

O córtex cerebral, composto por matéria cinzenta caracterizada por giros e sulcos na camada mais exposta do encéfalo, apresenta uma organização que, à primeira vista, pode parecer intrincada. No entanto, muitos desses sulcos e giros mais proeminentes são consistentemente semelhantes entre os indivíduos, servindo como marcos anatômicos para identificar as principais regiões do cérebro. Essa estrutura recobre os dois hemisférios cerebrais e desempenha um papel central em funções de alto nível, como percepção, planejamento motor e processamento cognitivo. O córtex é subdividido em quatro lobos principais, frontal, parietal, temporal e occipital, cada um especializado em funções distintas. Por exemplo, o lobo frontal está relacionado ao planejamento, memória de curto prazo e controle motor, enquanto o lobo occipital é dedicado ao processamento visual (BEAR et al., 2017), vide Figura 3. Além disso, o




FIGURA 3 – À esquerda, uma ilustração destacando as diferentes regiões do hemisfério esquerdo do córtex, organizadas em lobos. À direita, são evidenciadas regiões ainda mais especializadas dentro desses lobos, como o córtex motor, responsável pelo controle dos movimentos voluntários, e o córtex somatossensorial, encarregado de processar informações sensoriais como pressão, temperatura, entre outras. Imagens extraídas de Kandel et al. (2014).

córtex apresenta uma organização contralateral: os hemisférios controlam e processam informações sensoriais e motoras do lado oposto do corpo, refletindo a complexidade funcional dessa estrutura. Outras estruturas cerebrais, como o tálamo e o cerebelo, também desempenham papéis fundamentais, sendo o tálamo responsável por retransmitir informações sensoriais para o córtex e o cerebelo essencial para a coordenação motora. Essa rede interconectada evidencia como a dinâmica global do cérebro emerge da interação entre regiões locais e especializadas, formando um sistema altamente integrado e funcional (SPORNS, 2010).

Ferramentas para capturar e/ou analisar a dinâmica cerebral são fundamentais para a compreensão do funcionamento e do comportamento humano. Hoje em dia, a neurociência avança a passos largos ao redor do mundo, com o desenvolvimento de diversas tecnologias que permitem medir a dinâmica cerebral e relacioná-la com o comportamento momentâneo do indivíduo. Existem métodos modernos que possibilitam capturar a atividade de um grande número de neurônios simultaneamente, permitindo a identificação dos disparos neuronais responsáveis por comportamentos específicos (MARTUCCI et al., 2023). Tecnologias de imagem como a tomografia por emissão de pósitrons (PET) conseguem visualizar alterações no fluxo sanguíneo e identificar quais regiões do cérebro estão mais ativas durante determinados comportamentos (TEPLAN; al., 2002; CHRISTENSEN et al., 2000).

Dentre esses métodos, cabe destacar o Eletroencefalograma (EEG), uma técnica não invasiva e de fácil instalação, amplamente utilizada na neurociência para registrar a atividade elétrica do cérebro. O EEG mede as flutuações dos potenciais elétricos gerados pela atividade sináptica dos neurônios, particularmente nas camadas mais superficiais do córtex cerebral. Através de eletrodos posicionados no couro cabeludo, o EEG consegue capturar e registrar sinais elétricos de alta resolução temporal,

permitindo a análise de padrões de atividade cerebral em milissegundos. Esses sinais são representados por ondas de diferentes frequências, como as ondas delta, teta, alfa, beta e gama, cada uma associada a diferentes estados cognitivos ou comportamentais, como sono, atenção, relaxamento ou concentração (JACKSON; BOLGER, 2014). Uma das principais vantagens do EEG é sua capacidade de proporcionar uma visualização em tempo real da dinâmica cerebral, o que o torna uma ferramenta valiosa tanto para o estudo de funções cognitivas, quanto para a monitorização de distúrbios neurológicos, como epilepsia e transtornos do movimento (JACKSON; BOLGER, 2014).

3.3.1 Eletroencefalograma

O eletroencefalograma foi utilizado pela primeira vez em humanos em 1929 pelo médico alemão Hans Berger (VERGANI, 2024). Em seus estudos pioneiros, Berger observou que os sinais registrados apresentavam diferenças evidentes entre indivíduos em estados de vigília e sono, estabelecendo as bases para o uso do EEG no estudo dos ciclos do sono. Desde então, o EEG tem encontrado aplicações em uma ampla gama de áreas, incluindo neurologia, neuropsicologia e pesquisa clínica. Além de sua importância histórica, ele continua sendo uma ferramenta fundamental na investigação da dinâmica cerebral em condições normais e patológicas, como epilepsia, transtornos do sono e doenças neurodegenerativas.

Os sinais de EEG surgem principalmente da sincronização sináptica em populações de neurônios piramidais do córtex (JACKSON; BOLGER, 2014; BEAR et al., 2017). Esses neurônios têm dendritos apicais que se estendem em direção à superfície cortical, onde ocorrem potenciais pós-sinápticos excitatórios devido ao influxo de íons positivos. Esse influxo resulta em um acúmulo de cargas negativas no meio extracelular próximo aos dendritos apicais, enquanto a região mais profunda, perto do corpo celular e das camadas basais, permanece relativamente positiva. Essa diferença cria um dipolo elétrico temporário no neurônio. A organização dos neurônios piramidais em colunas paralelas desempenha um papel crucial na detecção dos sinais de EEG. Essa disposição permite que os dipolos gerados por diferentes neurônios se alinhem e se somem de forma construtiva, quando os neurônios estão sincronizados. Caso esses neurônios estivessem dispostos de maneira aleatória, os dipolos gerados tenderiam a se cancelar, resultando em sinais insignificantes ou mesmo indetectáveis.

Além disso, o dipolo elétrico gerado por um grupo de neurônios pode induzir dipolos adicionais em camadas superiores do tecido cortical, criando uma cascata de campos elétricos que se propagam através das diversas camadas do cérebro (JACKSON; BOLGER, 2014). Essa indução continua por meio de estruturas como as meninges, o líquido cefalorraquidiano, o crânio e o couro cabeludo, até que o sinal alcança os eletrodos posicionados no escalpo, conforme mostra a Figura 4.




FIGURA 4 – Esquema de detecção de sinal por eletroencefalograma. Neurônios piramidais organizados em colunas paralelas disparam de maneira sincronizada, gerando um acúmulo de cargas negativas no meio extracelular próximo aos dendritos apicais. O dipolo elétrico formado induz outros dipolos nas camadas superiores, permitindo que o campo elétrico resultante seja detectado pelos eletrodos do EEG posicionados no couro cabeludo. Imagem extraída de Bear et al. (2017).

Embora o campo elétrico de um único neurônio seja insignificante para detecção prática, a sincronização da atividade em milhares ou milhões de neurônios pode gerar um sinal forte o suficiente para ser captado por eletrodos posicionados no escalpo. Esse registro é realizado de maneira não invasiva e indolor, utilizando eletrodos fixados ao couro cabeludo com adesivos condutores ou dispositivos semelhantes.

A amplitude do sinal EEG registrado depende diretamente do grau de sincronização das populações neuronais próximas ao eletrodo. Quando essas populações disparam em sincronia, os campos elétricos se somam construtivamente, amplificando o sinal e permitindo que ele atravesse as camadas de tecido entre o córtex e o eletrodo, incluindo o escalpo e o crânio. Em contrapartida, quando os neurônios disparam de forma desorganizada, os campos elétricos podem se somar ou subtrair de maneira irregular, resultando em sinais mais fracos ou menos regulares.

Para garantir a padronização na aplicação de eletrodos em estudos de EEG, utiliza-se o sistema internacional 10-20. Essa convenção define a posição dos eletrodos com base em distâncias percentuais relativas ao tamanho da cabeça do indivíduo, assegurando reprodutibilidade e comparabilidade dos dados entre estudos. Os eletrodos recebem nomes que refletem sua localização anatômica aproximada: Fp (frontal polar), F (frontal), C (central), P (parietal), O (occipital), entre outros. Além disso, letras adicionais indicam hemisférios (esquerdo representado por números ímpares e direito por números pares), enquanto o termo z designa eletrodos posicionados na linha média,




FIGURA 5 – Ilustração do sistema internacional 10-20, utilizado para padronizar o posicionamento de eletrodos no escalpo, com as respectivas nomenclaturas baseadas em regiões anatômicas do cérebro e sua distribuição nos hemisférios esquerdo, direito e linha média.

conforme mostra a Figura 5. Essa padronização é essencial para interpretar os sinais capturados em regiões específicas do cérebro, facilitando sua análise em diferentes aplicações clínicas e experimentais.

3.3.2 Ondas cerebrais

As ondas cerebrais, primeiramente descritas pelo próprio Berger, (VERGANI, 2024), são padrões rítmicos de atividade elétrica gerados pelo cérebro, classificados em diferentes frequências que refletem os estados funcionais e cognitivos de uma pessoa. Elas variam de acordo com a atividade realizada e o estado mental (ABHANG et al., 2016). As ondas delta (0,5–4 Hz) são as mais lentas, associadas ao sono profundo e à recuperação física; as ondas teta (4–8 Hz) ocorrem em momentos de relaxamento profundo, meditação e sono leve; as ondas alfa (8–13 Hz) são predominantes em estados de repouso e relaxamento com olhos fechados, promovendo tranquilidade mental; as ondas beta (13–30 Hz) estão relacionadas a estados de alerta, concentração e atividade mental; e as ondas gama (>30 Hz), as mais rápidas, são responsáveis por funções cognitivas avançadas, como aprendizado, memória e processamento de informações.

O estudo das oscilações cerebrais também revela padrões característicos associados a condições neurológicas específicas, permitindo compreender melhor os mecanismos subjacentes a essas doenças. Um exemplo intrigante é a Doença de Parkinson (DP), onde indivíduos, mesmo apresentando déficits motores graves e congelamento de marcha, frequentemente preservam a capacidade de pedalar sem

dificuldades (STORZER et al., 2016). Este fenômeno, ainda pouco compreendido, destaca a complexidade das redes neurais envolvidas na locomoção humana. Estudos recentes apontam que oscilações beta no córtex sensório-motor e nos gânglios da base apresentam uma sincronização exacerbada em indivíduos com DP, contribuindo para os sintomas motores típicos da doença (HAMMOND et al., 2007; YAQIAN et al., 2024). Contudo, essas oscilações beta patológicas são suprimidas durante o ato de pedalar (STORZER et al., 2016), indicando que esta atividade pode modular de forma única a dinâmica neural em sistemas comprometidos. Este trabalho busca explorar a dinâmica cerebral associada ao pedalar em indivíduos saudáveis, comparando-a com estados de repouso, com o objetivo de aprofundar o entendimento das diferenças funcionais entre essas condições. Ao investigar como o cérebro regula sua atividade em uma tarefa locomotora cíclica, como pedalar, este estudo pode contribuir para elucidar mecanismos fundamentais da coordenação motora e sua modulação por diferentes estados comportamentais. As ferramentas utilizadas para investigar essas questões serão apresentadas nas próximas seções.

3.4 RECORRÊNCIAS

Muitos sistemas físicos que observamos exibem comportamentos que parecem ser aproximadamente periódicos, como as estações do ano, as fases da lua, as marés, entre outros. No entanto, embora o inverno de um ano possa se assemelhar ao do ano anterior, a temperatura, a umidade e outras condições climáticas podem variar significativamente, mesmo no mesmo dia do ano. Esses fenômenos, embora não sejam idênticos a cada ciclo, mostram uma tendência de recorrência, isto é, eles tendem a se repetir ou a apresentar semelhanças após um certo período.

Em 1890, o matemático, físico e engenheiro francês Henri Poincaré, estudando o problema dos três corpos, publicou um trabalho seminal (POINCARÉ, 1890) que lançou as bases para o teorema que hoje leva seu nome. O Teorema de Recorrência de Poincaré afirma que, em um sistema dinâmico ergódico, após um intervalo de tempo suficientemente grande, mas finito, o sistema retornará a um estado arbitrariamente próximo ao seu estado inicial.

A recorrência em sistemas dinâmicos é especialmente relevante na análise de sistemas caóticos, que são determinísticos, mas extremamente sensíveis a pequenas variações nas condições iniciais, o que os torna imprevisíveis na prática, uma vez que não é possível trabalhar com precisão infinita. Em sistemas dinâmicos, existe um conceito chamado fluxo, que descreve como o sistema contínuo evolui ao longo do tempo através de uma equação diferencial ordinária. Alguns sistemas, como os sistemas hamiltonianos, preservam o volume no espaço de fase, ou seja, o “espaço” ocupado pelo sistema não muda à medida que ele evolui, conforme o Teorema de Liouville. Formalmente, o Teorema de Poincaré, diz que em sistemas onde o volume é preservado e as órbitas são limitadas, o sistema inevitavelmente retornará repetidas vezes a qualquer região específica pela qual tenha passado. Isso significa que, mesmo em sistemas caóticos, onde tudo parece desordenado, ainda podemos identificar padrões e regularidades através da análise de recorrência. Dessa forma, a recorrência não só nos ajuda a entender a estrutura interna desses sistemas, mas também nos permite extrair informações valiosas sobre fenômenos que, à primeira vista, parecem totalmente desordenados.

3.4.1 Gráficos de Recorrência

Como uma maneira de visualizar as recorrências em um sistema, Eckmann et al. propuseram os gráficos de recorrência (**RPs**, sigla em inglês para *recurrence plots*) (ECKMANN et al., 1995). Um gráfico de recorrência é uma matriz que compara diferentes instantes de tempo para o vetor de estado no espaço de fase. Em outras palavras, dada uma trajetória de tamanho K do vetor de estado no espaço de fase de dimensão arbitrária d , $\{\vec{x}_i\}_{i=1}^K$, onde $\vec{x}_i = (x_1, x_2, \dots, x_d)^T$, o RP então compara todas

as possíveis combinações de vetores $\vec{x}_i$ e $\vec{x}_j$ para $i, j = 1, \dots, K$. O RP originalmente proposto era então montado na forma da matriz de recorrência de tamanho $K \times K$ na forma

$$R_{ij} = \begin{cases} 1 & \text{se } \vec{x}_i \approx \vec{x}_j, \\ 0 & \text{se } \vec{x}_i \not\approx \vec{x}_j, \end{cases} \quad i, j = 1, \dots, K. \quad (3.4)$$

Você pode se perguntar se comparar os diferentes pontos com base na proximidade entre eles pode parecer arbitrário, e você está correto. Originalmente, Eckmann propôs utilizar uma esfera de raio r_i centrada no ponto $\vec{x}_i$, de modo que a esfera englobasse pontos $\vec{x}_j$ suficientes para serem considerados recorrentes em relação ao ponto $\vec{x}_i$. No artigo original, os autores empregaram um número crescente de r_i para cada ponto $\vec{x}_i$, de forma que cada ponto tivesse 10 pontos recorrentes.

Já no trabalho original de Eckmann os RPs se mostraram uma poderosa maneira para a visualização e distinção de sistemas periódicos, caóticos ou estocásticos. Para séries periódicas, o RP mostra claramente linhas igualmente espaçadas que se cruzam em intervalos regulares, séries caóticas mostram estruturas diagonais e padrões bastante particulares e, por fim, séries completamente aleatórias não aparentam indicar nenhum padrão, apenas pontos espalhados na tela como uma televisão antiga sem sinal, vide Figura 6.




FIGURA 6 – A figura apresenta três conjuntos de gráficos. Imagem (a) mostra a série temporal senoidal com frequência de 2π radianos por segundo e sua matriz de recorrência, que revela um padrão regular refletindo a periodicidade da série. Imagem (b) exhibe a variação temporal na coordenada x do atrator de Lorenz com parâmetros $\sigma = 10$, $\beta = \frac{8}{3}$ e $\rho = 28$, e sua matriz de recorrência, evidenciando a estrutura complexa e caótica da série. Imagem (c) ilustra a série temporal de ruído branco, gerada com uma distribuição normal padrão, e sua matriz de recorrência, que reflete a natureza aleatória e não estruturada do ruído.

Claro que apesar de nesses exemplos parecer bastante clara a diferença entre séries periódicas, caóticas ou estocásticas, na prática isso não necessariamente será




FIGURA 7 – Par de pontos recorrentes no atrator caótico de Lorenz com parâmetros $\sigma = 10$, $\beta = \frac{8}{3}$ e $\rho = 28$. O ponto na posição $\vec{x}_j$ (em azul) é recorrente ao ponto $\vec{x}_i$ (em vermelho) pois está dentro da esfera de raio ϵ (contorno vermelho) centrada no ponto vermelho e vice versa.

um trabalho tão simples assim, por isso que este método e suas ramificações, apesar de seus grandes feitos, ainda estão em desenvolvimento e parte do que será mostrado nas próximas sessões mostrará métodos e análises mais refinadas para melhorar a precisão e abrangência da ferramenta.

A maneira mais atual de escrever a ferramenta que mede as recorrências de uma trajetória $\vec{x}_i \in R^d$ no espaço de fase é dada por

$$R_{ij}(\epsilon) = \Theta(\epsilon - \|x_i - x_j\|), \quad i, j = 1, \dots, K, \quad (3.5)$$

onde K é o número total de pontos medidos $\vec{x}_i$, ϵ é o limiar de recorrência, $\Theta(\cdot)$ é a função de Heaviside (isto é, $\Theta(x) = 0$ se $x < 0$, e $\Theta(x) = 1$ caso contrário) e $\|\cdot\|$ representa a norma utilizada para calcular a distância (MARWAN et al., 2007). Essa equação nos diz que se a distância entre os pontos i e j for menor que limiar de recorrência então a diferença será maior que zero e portando o elemento de matriz será 1, caso contrário, se essa distância for maior que esse parâmetro então o elemento de matriz é zero e, portanto, o ponto é dito como não recorrente, como mostrado na Figura 7.

3.4.2 Estruturas no RP

Uma análise mais detalhada dos gráficos de recorrência (**RPs**) revela estruturas em pequena escala, como pontos isolados, linhas diagonais, verticais e horizontais, que formam padrões característicos (MARWAN, 2003).

- **Pontos isolados** aparecem quando estados são raros, não persistem por muito tempo ou apresentam grandes flutuações. Embora possam indicar ruído, não são necessariamente sinais de aleatoriedade.
- **Linhas diagonais** ($R_{i+k,j+k} = 1$, para $k = 1, \dots, l$, onde l é o comprimento da diagonal) surgem quando segmentos da trajetória são paralelos a outros segmentos, indicando que o sistema visita a mesma região do espaço de fase em diferentes momentos. O comprimento dessas linhas é proporcional ao tempo durante o qual essa evolução similar ocorre.
- **Linhas verticais ou horizontais** ($R_{i,j+k} = 1$, para $k = 1, \dots, v$, onde v é o comprimento da linha vertical ou horizontal) indicam períodos em que um estado permanece inalterado ou muda muito lentamente.

3.4.3 Quantificadores de Recorrência

As quantificações de recorrências (RQA, do inglês *Recurrence Quantification Analysis*) inicialmente propostas por Zbilut e Webber (1992; 1994) são um conjunto de métricas desenvolvidas para extrair informações quantitativas de gráficos de recorrência. Os autores originalmente mediram a densidade de pontos recorrentes assim quantidade de estruturas diagonais nos RPs para definir medidas de complexidade.

Uma dessas medidas é a taxa de recorrência (RR, do inglês *Recurrence Rate*), que calcula a porcentagem de pontos de recorrência em um gráfico de recorrência (**RP**). Essa métrica reflete a densidade de recorrências no sistema e é equivalente à soma das correlações presentes no RP, oferecendo uma visão geral da frequência com que o sistema retorna a estados semelhantes.

O determinismo (DET) é outra medida importante, referindo-se à porcentagem de pontos de recorrência que formam linhas diagonais no RP. Essas linhas diagonais indicam que segmentos da trajetória do sistema evoluem de maneira semelhante em momentos distintos, sugerindo uma dinâmica determinística subjacente. Um valor alto de determinismo sugere que o comportamento do sistema é mais previsível e ordenado.

Além disso, a laminaridade (LAM) avalia a porcentagem de pontos de recorrência que formam linhas verticais no RP. As linhas verticais indicam períodos em que o sistema permanece em um estado específico por um tempo prolongado ou muda lentamente, caracterizando estados laminares ou fases de comportamento intermitente.

A laminaridade é particularmente útil para identificar momentos em que o sistema fica “preso” em um estado ou apresenta variações lentas.

As medidas baseadas em estruturas diagonais são capazes de identificar transições entre caos e ordem (TRULLA et al., 1996). Por outro lado, as medidas que se baseiam em estruturas verticais e horizontais ajudam a identificar transições entre diferentes tipos de caos, como fases laminares (MARWAN et al., 2002). Esses foram só alguns exemplos dos principais quantificadores de recorrência que existem, para se aprofundar nestes e outros veja as referências (MARWAN et al., 2007, 2024).

3.4.4 Microestados de Recorrências

Entre os diversos quantificadores de recorrência disponíveis, este trabalho foca no conceito de Microestados de Recorrência, conforme proposto por Corso et al. (CORSO et al., 2018). Este método envolve a extração de submatrizes de dimensão $N \times N$ do RP, que são intituladas de microestados. Considerando que a RP é uma matriz binária, composta exclusivamente de uns e zeros, os microestados são formados por todas as combinações possíveis dessas matrizes binárias.

Por exemplo, ao selecionar um microestado com $N = 2$, o número total de microestados possíveis é dado por $N^* = 2^{N^2}$, resultando em 16 microestados distintos para este caso específico, listados na Tabela 1. Esses microestados capturam diferentes configurações de recorrência presentes na RP, fornecendo uma maneira rica de caracterizar as dinâmicas subjacentes da série temporal analisada.

$\begin{bmatrix} 0 & 0 \\ 0 & 0 \end{bmatrix}$ (a)	$\begin{bmatrix} 1 & 0 \\ 0 & 0 \end{bmatrix}$ (b)	$\begin{bmatrix} 0 & 1 \\ 0 & 0 \end{bmatrix}$ (c)	$\begin{bmatrix} 0 & 0 \\ 1 & 0 \end{bmatrix}$ (d)	$\begin{bmatrix} 0 & 0 \\ 0 & 1 \end{bmatrix}$ (e)	$\begin{bmatrix} 1 & 1 \\ 0 & 0 \end{bmatrix}$ (f)	$\begin{bmatrix} 1 & 0 \\ 1 & 0 \end{bmatrix}$ (g)	$\begin{bmatrix} 0 & 0 \\ 1 & 1 \end{bmatrix}$ (h)	$\begin{bmatrix} 0 & 1 \\ 0 & 1 \end{bmatrix}$ (i)
$\begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}$ (j)	$\begin{bmatrix} 0 & 1 \\ 1 & 0 \end{bmatrix}$ (k)	$\begin{bmatrix} 1 & 1 \\ 1 & 0 \end{bmatrix}$ (l)	$\begin{bmatrix} 0 & 1 \\ 1 & 1 \end{bmatrix}$ (m)	$\begin{bmatrix} 1 & 0 \\ 1 & 1 \end{bmatrix}$ (n)	$\begin{bmatrix} 1 & 1 \\ 0 & 1 \end{bmatrix}$ (o)	$\begin{bmatrix} 1 & 1 \\ 1 & 1 \end{bmatrix}$ (p)		

TABELA 1 – Microestados possíveis para $N = 2$. A tabela mostra as combinações possíveis de matrizes binárias, as cores alternadas representam grupos de microestados com recorrências similares, (a) com nenhuma recorrência, (b)-(e) com apenas uma, (f)-(i) duas recorrências na mesma linha ou coluna, (j)-(k) recorrências diagonais, (l)-(o) mostram 3 pontos recorrentes e por fim (p) com todos os pontos recorrentes.

Cada microestado é identificado de acordo com a configuração dos valores dentro da submatriz. Para ilustrar, a Figura 8 mostra três exemplos de microestados 2x2 com diferentes disposições dos valores binários, como 1001, 0100, e 1111. A partir dessas configurações, é possível calcular a frequência de ocorrência de cada microestado em um dado conjunto de amostras $\bar{N}$, isto é, selecione um número $\bar{N}$ de microestados aleatoriamente do RP, dentre esses sorteados, cada microestado i aparecerá um número n_i de vezes, com isso, têm-se a probabilidade de um dado microestado aparecer em um certo número de amostras, ou seja, $P_i = n_i / \bar{N}$. Tendo




FIGURA 8 – Exemplo de obtenção de microestados. Neste caso, pequenas matrizes de tamanho 2×2 são extraídas da RP, representando diferentes configurações de recorrência.

então essas probabilidades, pode-se calcular a entropia do RP associada com a probabilidade de ocorrência dos microestados como (CORSO et al., 2018)

$$S(N^*) = - \sum_{i=1}^{N^*} P_i \ln P_i. \quad (3.6)$$

Como demonstrado pelos autores, a entropia de microestados de recorrência é uma ferramenta eficaz para quantificar a complexidade em séries temporais, tanto em sistemas discretos quanto contínuos. Observou-se que o valor da entropia aumenta proporcionalmente à caoticidade do sistema, o que também é observado em outras entropias, apresentando uma boa correlação com o maior expoente de Lyapunov do sistema. Além disso, essa métrica mostra baixa dependência do limiar de recorrência ϵ e oferece resultados consistentes para séries temporais de diferentes tamanhos, sendo eficaz tanto para séries grandes, já que foi mostrado que apenas um certo número de amostras já é suficiente para capturar a dinâmica e complexidade dos dados, não precisando usar todo o RP, quanto para séries menores, com $K = 100$ pontos, o que diminui o custo computacional. Além disso, a entropia de microestados de recorrência não apresenta algumas inconsistências (EROGLU et al., 2014) encontradas em outros quantificadores entrópicos baseados nas diagonais do RP (MARWAN et al., 2007).

Mais recentemente, Flauzino et al. (FLAUZINO et al., 2025) propuseram um método que pode ser considerado uma evolução da entropia de recorrência 3.6. Esse

método baseia-se na premissa de que, para uma série perfeitamente aleatória, como o ruído branco, qualquer permutação de uma sequência de valores, em uma série de tamanho finito, teria a mesma probabilidade de ocorrer. Essa ideia estabelece o que os autores definem como a condição de desordem, expressa pela equação:

$$p(\tilde{X}_{(n)}) = p(\sigma(\tilde{X}_{(n)})), \quad \forall \sigma \in S_N. \quad (3.7)$$

Essa condição implica que, em uma série completamente desordenada, a probabilidade de observar uma sequência específica de T valores $(\tilde{X}_{(t)})$, onde $\tilde{X}_{(t)} = (\tilde{x}_i)_{i=t+1}^{t+T}$ representa um segmento de tamanho T iniciado em t (com $0 \leq t \leq K - T$), sendo K o tamanho total da série $D = (x_i)_{i=1}^K$, é igual à probabilidade de encontrar qualquer permutação dessa sequência. Essas permutações, representadas pela função σ , abrangem todas as possíveis configurações dos T elementos no conjunto S_T .

Os autores aplicaram e estenderam essa condição aos microestados de recorrência, demonstrando que, dado um microestado de tamanho N , representado como $\mathbf{M} = \mathbf{R}(\tilde{X}_{(t)}, \tilde{X}_{(t')})$, onde $\mathbf{R}$ é uma submatriz da matriz de recorrência definida em (3.5), com índices iniciando em t e t' , as classes de microestados equiprováveis $\mathcal{M}_a$ podem ser definidas como:

$$\mathcal{M}_a(\mathbf{M}) = \bigcup_{\sigma_i, \sigma_j \in S_N} \{\mathcal{L}_{\sigma_j} \mathcal{T} \mathcal{L}_{\sigma_i} \mathbf{M}, \quad \mathcal{T} \mathcal{L}_{\sigma_j} \mathcal{T} \mathcal{L}_{\sigma_i} \mathbf{M}\}. \quad (3.8)$$

Nesse contexto, é importante destacar que $\mathcal{M}_a$ representa a classe à qual o microestado $\mathbf{M}$ pertence. O operador $\mathcal{L}$ é definido como o operador de troca de linhas, parametrizado por uma permutação $\sigma_i, \sigma_j \in S_N$. Por exemplo, para um microestado de tamanho $N = 3$ e uma permutação σ_{132} , o operador $\mathcal{L}_{132}$ permuta a linha 3 com a linha 2, mantendo a linha 1 inalterada.

Além disso, o operador $\mathcal{T}$ refere-se à transposição da matriz, ou seja, $\mathcal{T}\mathbf{M} = \mathbf{M}^T$. Isso implica que, ao aplicar $\mathcal{T}$, as linhas e colunas de $\mathbf{M}$ são invertidas.

A Equação 3.8 indica que as classes de microestados são formadas pela união de conjuntos obtidos por meio da aplicação sucessiva de duas operações sobre os microestados. A primeira consiste em permutar uma linha, transpor o microestado e, em seguida, permutar outra linha. A segunda operação segue a mesma etapa inicial, mas é seguida por uma segunda transposição. Essas transformações são aplicadas a todas as permutações possíveis dentro do conjunto de permutações de tamanho N , definindo assim as equivalências entre os microestados.

A definição dessas operações permite identificar as classes de microestados $\mathcal{M}_a$ como conjuntos equiprováveis de microestados que respeitam a condição de desordem, na Tabela 1 são mostrados cada classe de microestados de tamanho $N = 2$. Os microestados destacados pertencentes a mesma classe são equiprováveis de

aparecer em uma série completamente aleatória, ou seja

$$p(\mathbf{M}) = p(\mathbf{M}'), \forall \mathbf{M}' \in \mathcal{M}_a(\mathbf{M}).$$

Os autores propõem (FLAUZINO et al., 2025) uma maneira de quantificar a desordem em um conjunto de dados por meio de uma função monotonicamente crescente no intervalo $[0, 1]$. Nessa escala, o valor 0 representa uma série perfeitamente ordenada, enquanto 1 corresponde a uma série completamente aleatória.

Para alcançar esse objetivo, após construir a matriz de recorrência da série temporal, contabiliza-se o número de ocorrências de um dado microestado $\Omega(\mathbf{M}) \in \mathcal{M}_a$. O número total de microestados pertencentes à mesma classe é dado por $\sum_{\mathbf{M}' \in \mathcal{M}_a} \Omega(\mathbf{M}')$. Assim, é possível calcular diretamente a probabilidade de ocorrência de um microestado específico dentro de sua classe como:

$$p(\mathbf{M}) = \frac{\Omega(\mathbf{M})}{\sum_{\mathbf{M}' \in \mathcal{M}_a} \Omega(\mathbf{M}')} \quad (3.9)$$

Com isso, para cada classe, existe uma entropia da informação associada que quantifica tanto o grau de diversidade dos microestados na classe quanto a uniformidade da distribuição de probabilidades dos microestados. Essa entropia é definida como:

$$\xi_a(\epsilon) = - \sum_{\mathbf{M} \in \mathcal{M}_a} p(\mathbf{M}) \ln p(\mathbf{M}). \quad (3.10)$$

Por fim, é possível definir uma grandeza normalizada que considera o número total de classes contribuintes A , onde m_a representa o número de microestados distintos pertencentes a cada classe. Os autores propõem a seguinte formulação:

$$\xi(\epsilon) = \frac{1}{A} \sum_{a=1}^A \frac{\xi_a(\epsilon)}{\ln m_a}. \quad (3.11)$$

Essa grandeza, $\xi(\epsilon)$, representa a entropia total de todas as classes. Ela é uma função monotonicamente crescente em relação à condição de desordem, atingindo seu valor máximo igual a 1 quando a distribuição de classes de microestados se torna completamente uniforme.

É importante ressaltar que essa função depende do limiar de recorrência definido na Equação 3.5. A maneira de eliminar essa dependência será discutida na próxima seção.

3.4.5 Escolha do limiar de Recorrência

O limiar de recorrência é um parâmetro fundamental na análise de recorrências, e sua escolha pode influenciar significativamente os resultados da análise. Um limiar muito pequeno pode resultar em um RP com poucos pontos recorrentes, levando à

perda de informações importantes sobre a dinâmica do sistema. Por outro lado, um limiar muito grande pode fazer com que pontos distantes no espaço de fase sejam erroneamente classificados como recorrentes, distorcendo a interpretação do RP e comprometendo a análise.

Não há consenso na literatura quanto à melhor forma de selecionar o limiar de recorrência, e diversas abordagens têm sido propostas para lidar com essa questão. Uma delas consiste em utilizar uma pequena fração da distância máxima no espaço de fase, conforme sugerido por Mindlin et al. (MINDLIN; GILMORE, 1992). Outra estratégia frequente é definir o limiar como 10% da distância média ou máxima entre os pontos no espaço de fase (MARWAN et al., 2007). Koebbe e Mayer-Kress (KOEbbe et al., 1994) propõem, por sua vez, fixar o número de pontos recorrentes, o que resulta em um RP assimétrico. Além disso, há métodos que recomendam ajustar o limiar de acordo com a densidade de pontos recorrentes no RP, como discutido por Zbilut e Webber (ZBILUT et al., 2002).

Essas diferentes abordagens refletem a complexidade envolvida na escolha do limiar de recorrência e a necessidade de considerar as características específicas do sistema em estudo. A seleção adequada desse parâmetro é essencial para garantir que o RP capture com precisão as propriedades dinâmicas do sistema, permitindo uma análise confiável das recorrências e das transições entre diferentes regimes dinâmicos.

Uma alternativa à dependência no parâmetro é o método proposto por Prado et al. (PRADO et al., 2020) que utiliza a maximização da entropia de microestado (3.6) para definir o parâmetro ϵ . Esse método consiste em calcular a entropia de microestados da série para uma faixa de valores do limiar de recorrência e escolher aquele que maximiza a entropia. O método além de ser livre de parâmetros arbitrários, possibilita a escolha de um limiar ótimo para as RQA e mostrou correlações ainda maiores entre a entropia de microestado e o expoente de Lyapunov utilizando o ϵ que maximiza a entropia, em comparação com a utilização de um valor fixo (CORSO et al., 2018).

Além disso, o formato da curva da entropia de microestado em função do limiar de recorrência exibe um formato muito característico independentemente do tipo de série temporal, vide Figura 9, tendo sempre um máximo bem definido (PRADO et al., 2020) e também se mostra invariante à mudança do tamanho do microestado, isto é, mudar o valor de N muda o valor da entropia máxima mas preserva o formato da curva e pouco varia o valor ótimo do limiar de recorrência, tornando-o portanto também um quantificador de recorrência por si só.

Tanto a máxima entropia quanto o limiar de recorrência ótimo não são apenas quantificadores de recorrência (PRADO et al., 2022, 2024), mas também desempenham um papel crucial na classificação de sistemas dinâmicos quando se utilizam




FIGURA 9 – Entropia de microestado em função do limiar de recorrência ϵ para diferentes tamanhos de microestados. Pode-se observar uma curva bastante característica com máximo bem definido na entropia tanto para série da coordenada x do sistema de Lorenz em região caótica quanto para um ruído branco, ambas normalizadas.

microestados em aprendizado de máquina (ML, sigla em inglês para *Machine Learning*). Spezzatto et al. (SPEZZATTO et al., 2024) demonstraram que a acurácia de modelos de ML na previsão de características do sistema que gerou os dados atinge seu ápice quando o RP é construído com um limiar de recorrência que também maximiza a entropia. Isso sugere que a escolha cuidadosa do limiar não só melhora a representação das dinâmicas subjacentes, mas também potencializa o poder discriminatório dos algoritmos de ML, fornecendo um novo caminho para a análise de recorrência em sistemas complexos.

Por fim, uma abordagem não apenas para selecionar um parâmetro ótimo para o limiar de recorrência, mas também para reduzir o erro na estimativa das probabilidades, é descrita por Flauzino et al. (FLAUZINO et al., 2025). Seguindo a mesma lógica da entropia de recorrências, os autores propõem maximizar a entropia total associada às classes de microestados, apresentada na Equação 3.11. Com isso, eles introduzem o que denominam como quantificador de desordem, definido por:

$$\Xi = \max(\xi(\epsilon)). \quad (3.12)$$

Maximizar a função $\xi(\epsilon)$ da Equação 3.11 em relação ao limiar de recorrência ϵ não apenas elimina a dependência desse parâmetro, mas também fornece uma medida de desordem que minimiza o erro associado à estimativa das probabilidades dos microestados. Essa estratégia é essencial para calcular a desordem de forma otimizada.

O quantificador de desordem Ξ , definido em (3.12), demonstrou ser extremamente eficaz e robusto na distinção entre séries caóticas e estocásticas, além de discriminar variações dentro de séries estocásticas, como diferentes tipos de ruídos. Adicionalmente, os autores evidenciaram que, ao longo do tempo, mínimos locais na medição do quantificador podem estar relacionados à identificação de transições forçadas no sistema. Essa ligação foi exemplificada em dados experimentais, onde esses eventos foram associados a episódios de extinção em massa.

3.5 APRENDIZADO DE MÁQUINA

Vimos que o cérebro humano é uma máquina extraordinariamente complexa, capaz de feitos que talvez jamais consigamos compreender completamente, apesar de séculos de estudo e esforço. Projetado ao longo de milhões de anos de evolução, o cérebro humano tem como objetivo primordial a sobrevivência. Sua capacidade de capturar, armazenar e processar informações é inegável, mas está intrinsecamente ligada às demandas evolutivas pelas quais passamos. Como resultado, somos especialistas em identificar padrões relevantes para nossa sobrevivência, como diferenciar um predador de uma presa ou reconhecer expressões faciais humanas (HARARI, 2013; DE WALL, 2016).

Entretanto, nossa capacidade de identificar padrões é limitada a contextos que tiveram importância adaptativa ao longo da história evolutiva. Conseguimos diferenciar um gato de um cachorro com facilidade, mas temos dificuldade em interpretar padrões complexos, como as flutuações de um mercado financeiro ou os sinais oriundos de sistemas dinâmicos não lineares, como a atividade elétrica do cérebro. Além disso, o cérebro humano não foi projetado para realizar cálculos em alta velocidade ou processar grandes volumes de dados em paralelo.

Apesar de não sermos capazes de tais feitos, ainda somos capazes de criar ferramentas e sistemas que conseguem. É nesse cenário que as máquinas entram em cena. Criadas para superar essas limitações humanas, elas se destacam pela capacidade de executar milhares de cálculos por segundo e de processar volumes imensos de dados de forma eficiente. O surgimento do aprendizado de máquina (ML, sigla em inglês para *machine learning*) representa um marco nesse avanço, permitindo que as máquinas aprendam a identificar padrões que muitas vezes escapam à percepção humana, mesmo em domínios altamente complexos.

A inteligência artificial (IA), juntamente com o aprendizado de máquina, teve sua origem em meados do século XX, com os primeiros trabalhos que buscavam modelar o funcionamento do cérebro humano de forma computacional. O perceptron, introduzido nos anos 1940 e 1950 (MCCULLOCH; PITTS, 1943), é considerado um dos marcos iniciais das redes neurais artificiais. Desde então, a área passou por um crescimento exponencial, impulsionado pelo aumento do poder computacional, pela disponibilidade de grandes volumes de dados e pelos avanços em algoritmos. Esse progresso culminou no Prêmio Nobel de Física de 2024, concedido conjuntamente a John J. Hopfield e Geoffrey Hinton “por descobertas e invenções fundamentais que possibilitaram o aprendizado de máquina com redes neurais artificiais” (2025). Esse reconhecimento destaca o impacto transformador dessas tecnologias em diversos campos científicos, incluindo o estudo de sistemas dinâmicos complexos.

O ML é uma área da inteligência artificial que busca criar algoritmos capazes de aprender padrões a partir de dados, possibilitando a generalização para novos cenários sem que regras explícitas precisem ser programadas manualmente. Esses algoritmos têm ampla aplicação em tarefas que vão desde o reconhecimento de padrões em imagens (BOTTOU et al., 1994) até a previsão de fenômenos complexos em sistemas dinâmicos, como o controle de plasmas magneticamente confinados em reatores de fusão (DEGRAVE et al., 2022).

Os métodos de aprendizado de máquina podem ser classificados em três principais categorias: aprendizado supervisionado, aprendizado não supervisionado e aprendizado por reforço (GÉRON, 2022).

No aprendizado supervisionado, o algoritmo recebe um conjunto de dados de treinamento onde cada entrada está associada a uma saída desejada, ou *label*. O objetivo do modelo é aprender uma função que mapeie corretamente as entradas para os rótulos. Por exemplo, em problemas de classificação, como o reconhecimento de dígitos escritos à mão, o modelo recebe imagens de números juntamente com seus respectivos valores (0 a 9). Da mesma forma, em tarefas de regressão, como a previsão do preço de um imóvel, as entradas podem incluir características como localização e área construída e os valores dos imóveis em tempos passados, enquanto a saída é o valor esperado do imóvel em um instante de tempo futuro. O aprendizado supervisionado requer grandes quantidades de dados rotulados, o que pode ser uma limitação em algumas áreas.

O aprendizado não supervisionado, por outro lado, não utiliza rótulos durante o treinamento. O foco está em identificar padrões ocultos ou estruturas intrínsecas nos dados. Um exemplo clássico é a clusterização, onde o modelo agrupa os dados em subconjuntos com base em similaridades. Isso pode ser aplicado na segmentação de clientes por comportamento de compra ou na organização de documentos por tópicos principais. Além da clusterização, métodos de redução de dimensionalidade, desde os mais simples, como a Análise de Componentes Principais (PCA) (JOLLIFFE; CADIMA, 2016), até abordagens mais complexas, como t-SNE e UMAP (MAATEN; HINTON, 2008; MCINNIS; HEALY, 2018), também se enquadram nessa categoria.

Já o aprendizado por reforço é inspirado no comportamento de agentes inteligentes que aprendem interagindo com um ambiente. Nesse caso, o modelo toma ações em sequência, recebendo recompensas ou penalidades com base no impacto de suas escolhas. O objetivo é maximizar a recompensa acumulada ao longo do tempo. Aplicações desse tipo de aprendizado incluem o treinamento de robôs para tarefas como caminhar ou manipular objetos, o desenvolvimento de agentes para jogar jogos como xadrez, e a otimização de sistemas complexos em ambientes dinâmicos (DEGRAVE et al., 2022).

Cada uma dessas abordagens é adequada para diferentes tipos de problemas e apresenta desafios específicos. Por exemplo, enquanto o aprendizado supervisionado pode oferecer soluções precisas para tarefas bem definidas, ele exige dados rotulados, cuja obtenção pode ser custosa. O aprendizado não supervisionado é valioso para explorar dados sem rótulos, mas frequentemente depende de suposições sobre a estrutura subjacente. Já o aprendizado por reforço, embora poderoso para resolver problemas sequenciais, requer simulações de alta qualidade para treinamento.

O treinamento de modelos de aprendizado de máquina consiste em ajustar os parâmetros do modelo para que ele possa realizar previsões precisas com base em dados previamente observados. Esse processo segue, geralmente, as seguintes etapas (GÉRON, 2022):

Inicialmente, os dados são submetidos a um processo de pré-processamento, que inclui a remoção de inconsistências, o preenchimento de valores ausentes e a normalização das características para garantir que estejam em escalas comparáveis. Em seguida, o conjunto de dados é dividido em três subconjuntos: treinamento, validação e teste. O conjunto de treinamento é utilizado para ajustar os parâmetros internos do modelo, enquanto o conjunto de validação serve para otimizar os hiperparâmetros e evitar o *overfitting*, um fenômeno em que o modelo se torna excessivamente ajustado aos dados de treinamento, resultando em ótimo desempenho nesse conjunto, mas com baixa capacidade de generalização para novos dados. Por fim, o conjunto de teste, mantido isolado durante o treinamento, é usado para avaliar de forma imparcial o desempenho do modelo em dados inéditos.

Durante o treinamento, o modelo é alimentado com entradas (os dados) e os rótulos correspondentes (em problemas supervisionados), e a qualidade de suas previsões é avaliada por meio de uma função de perda. O algoritmo de otimização ajusta os parâmetros do modelo para minimizar essa perda iterativamente.

Para modelos supervisionados, como classificação e regressão, o objetivo é mapear os dados de entrada para os rótulos ou valores esperados. No caso de tarefas não supervisionadas, como clusterização, o modelo busca padrões inerentes nos dados sem a necessidade de rótulos. Já no aprendizado por reforço, o modelo interage com o ambiente, recebendo recompensas ou penalidades para otimizar suas ações.

Por fim, a avaliação do modelo em dados de teste mede sua capacidade de generalizar, usando métricas apropriadas como acurácia, erro médio ou *F1-score*, dependendo da tarefa (GÉRON, 2022). Esse processo é fundamental para garantir que o modelo seja confiável e aplicável a novos dados em cenários reais.

Dentre algumas das métricas, a acurácia representa a proporção de previsões corretas em relação ao total de previsões, sendo uma métrica geral de desempenho.

A precisão indica a proporção de acertos entre as amostras que o modelo classificou como positivas, enquanto o recall mede a proporção de acertos entre todas as amostras que realmente pertencem à classe positiva. Já o *F1-score* é a média harmônica entre precisão e recall, sendo especialmente útil em cenários com classes desbalanceadas, pois equilibra a importância de ambas as métricas em uma única medida.

No que diz respeito à aplicação de aprendizado de máquina em sistemas dinâmicos, uma área de destaque é a redução de dimensionalidade, que permite otimizar o uso de dados complexos ao condensar a maior quantidade possível de informações em espaços reduzidos, mas ainda informativos. Como discutido na seção anterior, essa abordagem equilibra o desempenho computacional e a precisão do modelo, evitando redundâncias e focando nos aspectos essenciais dos dados. Nesse contexto, Spezzatto et al. (2024) mostraram que o uso combinado de microestados de recorrência e entropia melhora significativamente a acurácia de redes neurais ao trabalhar com sistemas dinâmicos. A maximização da entropia, em particular, foi evidenciada como um fator crucial para capturar as dinâmicas subjacentes e aumentar o poder discriminatório dos modelos.

Expandindo os trabalhos anteriores, nosso grupo explorou essa combinação de microestados e entropia não apenas em redes neurais, mas também em uma ampla gama de algoritmos de aprendizado de máquina. Testamos essa abordagem em diferentes tipos de sistemas dinâmicos tanto caóticos contínuos e discretos, como também em séries aleatórias, evidenciando que o uso de um espaço reduzido pode preservar toda a informação relevante do sistema, enquanto otimiza o tempo computacional. Essa generalização reforça a aplicabilidade das técnicas de redução de dimensionalidade, demonstrando que, com o uso correto de quantificadores, é possível obter modelos mais eficientes sem sacrificar a precisão ou a complexidade das análises.

3.5.1 Árvores de Decisão e Florestas Aleatórias

Algoritmos de aprendizado de máquina possuem a capacidade de identificar e prever padrões que, muitas vezes, não são facilmente perceptíveis por observadores humanos. Essa característica torna-os ferramentas poderosas na análise de sistemas complexos, como a atividade cerebral, permitindo uma abordagem complementar à psicologia comportamental experimental e à neurociência tradicional. Enquanto métodos convencionais frequentemente requerem hipóteses prévias sobre os dados, modelos baseados em aprendizado de máquina são capazes de encontrar padrões e relações sutis a partir dos próprios dados, fornecendo novas perspectivas sobre fenômenos biológicos e cognitivos.

Dentre os diversos algoritmos de aprendizado supervisionado, um dos mais utilizados é o de Florestas Aleatórias (RF, do inglês *Random Forest*). Esse método

consiste em um conjunto de Árvores de Decisão, onde cada árvore aprende de forma independente a partir de diferentes subconjuntos de dados e variáveis. O princípio central do *Random Forest* é combinar a previsão de múltiplas árvores para obter um resultado mais preciso e robusto, mitigando problemas comuns em modelos individuais, como o *overfitting* (GÉRON, 2022). Essa abordagem inspirada na ideia de “sabedoria das multidões” faz com que o modelo alcance um melhor equilíbrio entre viés e variância, sendo amplamente empregado em tarefas de classificação e regressão.

Árvores de Decisão recebem esse nome devido à maneira como esses algoritmos realizam classificações nos conjuntos de dados¹. A estrutura da tomada de decisão assemelha-se a uma árvore, onde uma entrada principal (tronco) se ramifica progressivamente (galhos) até alcançar os possíveis resultados (folhas).

Árvores de Decisão são modelos baseados em uma estrutura hierárquica de tomadas de decisão, onde um conjunto de regras sucessivas é aplicado aos dados para classificá-los ou realizar previsões. Esses algoritmos funcionam particionando iterativamente o espaço de amostras em subconjuntos cada vez mais homogêneos com relação à variável alvo.

O processo de tomada de decisão inicia-se no tronco da árvore, onde uma pergunta é feita sobre uma das características (*features*) dos dados. Com base na resposta, a amostra segue para um dos nós internos, onde novas perguntas são feitas, refinando a separação dos dados em diferentes grupos. Esse processo continua até que a amostra alcance um nó folha, que contém a predição final do modelo.

A escolha das divisões em cada nó é feita com base em métricas de impureza, como a entropia ou o índice de Gini, que medem o grau de mistura entre as classes dentro de um subconjunto. O algoritmo seleciona, a cada passo, a melhor divisão possível, ou seja, aquela que maximiza a pureza dos subconjuntos resultantes. Esse processo é repetido recursivamente até atingir um critério de parada, como um número mínimo de amostras por nó ou uma profundidade máxima da árvore, vide Figura 10.

A democracia parte da premissa de que sociedades inteiras, multidões compostas por centenas ou milhares de pessoas com opiniões distintas, tomam, em média, decisões melhores do que indivíduos isolados, especialmente no que diz respeito à escolha de representantes políticos. Enquanto uma única pessoa não tem o poder absoluto de determinar quem ocupará um cargo, a média das escolhas da população tende a produzir um resultado mais equilibrado. Embora a validade dessa premissa seja debatida, o conceito subjacente é simples e é exatamente nele que se baseiam as

¹ Tanto Árvores de Decisão quanto Florestas Aleatórias também podem ser utilizadas para tarefas de regressão. Existem variações desses algoritmos projetadas especificamente para esse fim. No entanto, como este trabalho foca exclusivamente em classificação, optou-se por destacar essa aplicação.




FIGURA 10 – Diagrama esquemático de uma Árvore de Decisão. O diagrama ilustra, de maneira simplificada, o funcionamento geral de um algoritmo de árvore de decisão. No exemplo, o conjunto de dados contém quatro classes distintas de animais a serem classificados: mamíferos, aves, insetos e aracnídeos. A estrutura da árvore é construída a partir de perguntas baseadas em características numéricas dos dados (*features*), como número de patas, número de asas, temperatura corporal, oviparidade, número de olhos ou antenas, entre outros. A cada nó da árvore, uma decisão é tomada com base no valor de um atributo, levando a uma subdivisão progressiva dos dados até atingir um nó terminal, onde a classificação final é definida. Esse modelo exemplifica como uma árvore de decisão pode ser utilizada para organizar e separar diferentes categorias com base em atributos mensuráveis.

RF para realizar classificações. Diferentes Árvore de Decisão, com profundidades variadas e distintos números de nós folha, analisam os dados sob diferentes perspectivas, como mostrado na Figura 11. No entanto, ao combinar os resultados dessas múltiplas árvores e calcular a média de suas previsões, obtém-se um modelo mais robusto e preciso, menos suscetível a variações e ruídos do que uma única árvore isolada.




FIGURA 11 – Diagrama esquemático do funcionamento do algoritmo *Random Forest*. Os dados de entrada são processados por um conjunto de árvores de decisão independentes (Decision Tree 1, Decision Tree 2, ..., Decision Tree n), cada uma treinada com uma amostra diferente dos dados. Cada árvore gera uma previsão individual (Resultado 1, Resultado 2, ..., Resultado n). Em seguida, essas previsões são combinadas por meio de uma votação majoritária (no caso de classificação) ou média dos valores (no caso de regressão), resultando na previsão final do modelo

4 METODOLOGIA

4.1 COLETA E DISPONIBILIZAÇÃO DOS DADOS

Os dados utilizados neste trabalho foram coletados e gentilmente cedidos por Ferré et al. (2024). O conjunto de dados consiste em registros de eletroencefalograma de 24 indivíduos saudáveis, sendo 54% mulheres, com idade média de 21,30 anos, e 46% homens, com idade média de 21,63 anos.

Os experimentos foram analisados e aprovados pelo Comitê de Ética em Pesquisa da Universidade Federal do Rio Grande do Norte, sob o CAAE de número 02979318.0.0000.5537. Todos os indivíduos participaram voluntariamente e assinaram um termo de consentimento livre e esclarecido, em conformidade com a Declaração de Helsinki.

Os registros de EEG foram realizados enquanto os indivíduos realizavam quatro diferentes tarefas: pedalando com olhos abertos (POA), pedalando com olhos fechados (POF), repouso com olhos abertos (ROA) e repouso com olhos fechados (ROF). Cada atividade foi realizada durante dois minutos.

Os sinais de EEG foram capturados por eletrodos de Ag-AgCl posicionados no escalpo dos participantes, seguindo o sistema internacional 10-20. Foram utilizados oito eletrodos dispostos simetricamente, distribuídos entre diferentes regiões corticais: dois na região frontal (F3-Fz e F4-Fz), dois na região central (C3-Cz e C4-Cz), dois na região parietal (P3-Pz e P4-Pz) e dois na região occipital (O1-A2 e O2-A1). Para fins de simplicidade e padronização ao longo deste trabalho, adotamos uma nomenclatura abreviada para os canais: a primeira letra indica a região cortical (F para frontal, C para central, P para parietal e O para occipital) e a segunda letra indica o hemisfério (D para direito e E para esquerdo). Assim, os canais são denominados FD, FE, CD, CE, PD, PE, OD e OE.

Os dados foram coletados a uma taxa de amostragem de 1000 Hz utilizando o sistema PowerLab 8/30 (AdInstruments, Austrália) e registrados com o software LabChart 7 Pro (AdInstruments, Austrália). Durante a aquisição, foi aplicado um filtro passa-faixa de 1 a 100 Hz para capturar as frequências relevantes dos sinais. Para a análise, utilizou-se um filtro rejeita-faixa de 59–61 Hz para eliminar ruídos da rede elétrica. Nas condições de pedalada, foi aplicado um filtro passa-faixa adicional de 3 a 35 Hz, isolando as frequências associadas à atividade motora, garantindo que as características essenciais dos sinais fossem preservadas para as etapas posteriores de processamento e análise.

Para a coleta de dados dos indivíduos durante a atividade de pedalada, foi utilizada uma bicicleta ergométrica horizontal, na qual o participante permanece sentado com as pernas à frente. Esse tipo de bicicleta é amplamente utilizado em exercícios aeróbicos, como os realizados em academias. O modelo específico utilizado foi a MAX-H, fabricada pela Dream Fitness (Brasil).

4.2 PRÉ-PROCESSAMENTO DOS DADOS

Com os dados em mãos, temos, para cada indivíduo, registros de 8 canais de EEG sob 4 condições distintas (POA, POF, ROA, ROF), totalizando 32 séries temporais por indivíduo. Cada série possui, em média, 120 mil pontos, valor aproximado devido à taxa de amostragem de 100 Hz durante cerca de 2 minutos. No entanto, essa duração não é exatamente constante, variando tanto entre indivíduos quanto entre as condições de um mesmo indivíduo.

Para a aplicação dos quantificadores entrópicos, cada série temporal foi segmentada em janelas de tamanho fixo. Especificamente, para o cálculo da entropia de microestados (Eq. 3.6), as séries foram divididas em janelas de 1000 pontos, correspondentes a aproximadamente 1 segundo de sinal de EEG. Esse intervalo é considerado adequado para a identificação de recorrências, uma vez que, nas condições do experimento, são esperadas oscilações nas faixas de frequência alfa e beta, o que implica, em média, entre 8 e 30 repetições dos eventos ao longo de um segundo. Assim, para cada combinação de indivíduo, condição e canal, foram calculados, em média, 120 valores de entropia. Esse cálculo foi realizado para três diferentes tamanhos de microestado ($N = 2, 3, 4$), resultando, para cada conjunto de dados, em uma matriz com aproximadamente 120 linhas e $2^{N^2} + 1$ colunas — sendo uma coluna para o valor da entropia e as demais para as probabilidades associadas a cada microestado possível no RP.

Para o quantificador de desordem (Eq. 3.12), o procedimento foi similar, com a diferença de que se utilizaram janelas maiores, de 3000 pontos (equivalente a 3 segundos), a fim de melhorar a convergência do cálculo. Para manter comparável o número de janelas entre os dois quantificadores, as janelas foram extraídas com salto de 1000 pontos, resultando também em cerca de 120 janelas por série. Diferentemente da entropia de microestados, no caso da desordem não há uma fórmula fechada para o número de classes possíveis para cada valor de N . Através do conjunto de permutações possíveis pra cada tamanho de microestado, obtêm-se então 6 classes para $N = 2$ (como ilustrado na Tabela 1), 26 classes para $N = 3$ e 192 para $N = 4$. Isso torna o número de colunas (i.e., atributos) significativamente menor do que no caso da entropia de microestados, já que apenas as probabilidades das classes, e não dos microestados individuais, são utilizadas.

Para ambos os quantificadores, o valor máximo foi extraído ao se variar o limiar de recorrência em 50 valores, uniformemente distribuídos entre 1×10^{-5} e 0.5 (isto é, até metade do valor máximo da série, uma vez que cada janela foi normalizada entre 0 e 1). A escolha de ir somente até metade do espaço de valores em vez de procurar o valor máximo entre todos os valores do limiar de recorrência se deu pelo próprio formato da curva da entropia de microestados em função do parâmetro ϵ , como mostra a Figura 9.

4.3 CONFIGURAÇÃO DA CLASSIFICAÇÃO

Os dados processados foram utilizados como *features* para um algoritmo de classificação do tipo *Random Forest*. Esse algoritmo foi configurado com um conjunto de 100 classificadores (ou Árvores de Decisão), inicializados aleatoriamente, sem limitação de profundidade máxima. Para cada tarefa de classificação, o algoritmo foi executado 50 vezes, a fim de calcular a média da acurácia obtida.

A classificação foi dividida em diferentes cenários, considerando as duas principais condições experimentais: **movimento corporal** (pedalando ou em repouso) e **estado dos olhos** (abertos ou fechados). Assim, fixando-se uma dessas condições, buscou-se classificar a outra. Por exemplo, foi avaliado o desempenho do classificador ao distinguir entre olhos abertos e fechados, considerando apenas os dados do estado de repouso, de modo a comparar a diferença na acurácia da mesma classificação mas com os dados dos indivíduos pedalando (e vice-versa para o movimento).

Além disso, a análise foi realizada considerando diferentes combinações de canais de EEG:

- **1 canal:** cada canal foi testado isoladamente;
- **2 canais:** pares de canais de regiões simétricas do córtex — frontal (FE e FD), parietal (PE e PD), central (CE e CD) e occipital (OE e OD);
- **4 canais:** canais agrupados por hemisfério — direito (FD, PD, CD e OD) e esquerdo (FE, PE, CE e OE);
- **8 canais:** todos os canais considerados simultaneamente como *features*.

Essa abordagem permitiu avaliar o impacto da quantidade e da localização dos canais na acurácia da classificação.

5 RESULTADOS E DISCUSSÃO

Nesta seção, apresentamos os principais resultados obtidos com base nos dois quantificadores utilizados: a entropia de microestados e a desordem. As análises são organizadas em duas subseções principais. Na primeira, examinamos o comportamento dos quantificadores em diferentes regiões corticais e condições experimentais, buscando interpretar possíveis padrões na dinâmica da atividade cerebral. Na segunda, avaliamos o desempenho desses mesmos quantificadores como atributos para algoritmos de aprendizado de máquina, explorando sua capacidade de discriminar entre as condições analisadas.

Ao longo da discussão, adotamos o termo **complexidade** como uma forma unificada de nos referirmos aos aspectos da atividade neural capturados tanto pela entropia de microestados quanto pela desordem. Ainda que o conceito de complexidade não possua uma definição operacional única ou uma medida consensual, utilizamos essa palavra como uma convenção para facilitar a leitura e interpretação dos resultados. Assim, quando mencionarmos que determinada região ou condição apresenta maior ou menor complexidade, estaremos nos referindo a comportamentos indicados por um ou ambos os quantificadores, sempre contextualizados pelas análises anteriores.

5.1 QUANTO AOS QUANTIFICADORES

Antes de partirmos para análises detalhadas por canal e condição, apresentamos a distribuição espacial média dos quantificadores ao longo do tempo e entre os indivíduos, conforme mostram as Figuras 12 e 13. De cara, podemos ver que, para a entropia de microestados, o comportamento do quantificador se mantém o mesmo em relação aos canais, independentemente do valor de N . Apesar da mudança no valor absoluto da entropia, algo já esperado, vide Figura 9, a distribuição relativa entre os canais não se altera. Assim, podemos observar que, principalmente na condição de olhos abertos, tanto pedalando quanto em repouso, o valor absoluto da entropia tende a ser menor nas regiões frontais e na parietal esquerda, enquanto tende a ser maior nas regiões centrais e occipitais. Para a condição de olhos fechados, esse comportamento se repete nas regiões centrais com os indivíduos em repouso, ao passo que, na condição de pedalar, a entropia geral no cérebro parece mais uniforme.

Para o quantificador de desordem, já não observamos o mesmo comportamento relativo independente de N , visto que para $N = 2$ é visível uma discrepância no valor relativo do quantificador entre os canais quando comparado com $N = 3$ ou $N = 4$. Isso se deve ao fato de que, pela própria definição do quantificador, que se baseia




FIGURA 12 – Distribuição média dos valores de entropia por canal para diferentes tamanhos de microestados ($N = 2, 3, 4$). As médias foram calculadas ao longo das janelas temporais e entre os indivíduos.

em permutações nos microestados, não é possível fazer uma analogia direta com a condição de desordem — no sentido de que qualquer permutação de uma sequência de valores seria igualmente provável em uma série perfeitamente aleatória — quando temos microestados de tamanho 2. Nesse caso, a desordem serve mais como um quantificador de reversibilidade da série temporal. Esse é provavelmente o motivo pelo qual, para $N = 2$, os valores são tão próximos à unidade, o que indicaria que a série é quase perfeitamente reversível e, portanto, interpretada como aleatória para esse tamanho de microestado.

Diferentemente disso, os casos com $N = 3$ e $N = 4$ sim se encaixam na definição de desordem, e apresentam comportamento semelhante ao da entropia — com a diferença de que regiões que pareciam praticamente uniformes ao utilizar a entropia tornam-se mais distinguíveis com o uso da desordem. Isso pode indicar




FIGURA 13 – Distribuição média dos valores do quantificador de desordem por canal para diferentes tamanhos de microestados ($N = 2, 3, 4$). As médias foram calculadas ao longo das janelas temporais e entre os indivíduos.

um acréscimo de informação que o quantificador é capaz de captar. Análises mais específicas sobre isso serão apresentadas adiante.

A partir dessas distribuições espaciais, realizamos uma análise estatística detalhada comparando os valores médios dos quantificadores entre as diferentes condições (POA, POF, ROA, ROF), separadamente para cada canal. Os testes estatísticos foram realizados utilizando a biblioteca *SciPy* em *Python*, que aplica o teste t de Student para duas amostras independentes, e realizando mil permutações para cada par de condições comparadas, conforme mostra a Figura 14. Os resultados completos das análises estatísticas tanto para a entropia de microestados quanto para a desordem estão mostrados nas Tabelas 2 e 3 respectivamente.

Dos resultados obtidos, observa-se que, ao comparar as condições de pedalar e repouso com os olhos abertos, todos os canais indicam que a média de ambos




FIGURA 14 – Distribuição dos valores do quantificador de Desordem para $N = 3$, organizados por canal de EEG e condição experimental: Pedalando com olhos abertos (POA), Repouso com olhos abertos (ROA), Pedalando com olhos fechados (POF) e Repouso com olhos fechados (ROF). As barras representam a variabilidade entre indivíduos ao longo do tempo, e as marcas sobre as condições indicam comparações com diferença estatisticamente significativa ($p < 0,05$), obtidas via teste t pareado. As indicações de desigualdade mostram a direção da diferença entre os grupos.

Canal	N	POA vs ROA	POF vs ROF	POA vs POF	ROA vs ROF
CD	N=2	$t = -9.26, p = 0.001$	$t = -7.44, p = 0.001$	$t = -5.74, p = 0.001$	$t = -3.36, p = 0.001$
	N=3	$t = -9.27, p = 0.001$	$t = -7.30, p = 0.001$	$t = -5.06, p = 0.001$	$t = -3.00, p = 0.003$
	N=4	$t = -8.93, p = 0.001$	$t = -7.11, p = 0.001$	$t = -4.43, p = 0.001$	$t = -2.68, p = 0.005$
CE	N=2	$t = -15.59, p = 0.001$	$t = -9.30, p = 0.001$	$t = -9.13, p = 0.001$	—
	N=3	$t = -16.29, p = 0.001$	$t = -9.01, p = 0.001$	$t = -9.09, p = 0.001$	—
	N=4	$t = -16.13, p = 0.001$	$t = -8.83, p = 0.001$	$t = -8.37, p = 0.001$	—
FD	N=2	$t = -9.52, p = 0.001$	$t = -9.33, p = 0.001$	$t = -10.20, p = 0.001$	$t = -10.56, p = 0.001$
	N=3	$t = -9.72, p = 0.001$	$t = -9.15, p = 0.001$	$t = -9.82, p = 0.001$	$t = -9.83, p = 0.001$
	N=4	$t = -9.75, p = 0.001$	$t = -8.98, p = 0.001$	$t = -9.52, p = 0.001$	$t = -9.36, p = 0.001$
FE	N=2	$t = -13.41, p = 0.001$	$t = -5.98, p = 0.001$	$t = -17.83, p = 0.001$	$t = -9.43, p = 0.001$
	N=3	$t = -13.88, p = 0.001$	$t = -5.84, p = 0.001$	$t = -18.12, p = 0.001$	$t = -8.72, p = 0.001$
	N=4	$t = -13.72, p = 0.001$	$t = -5.72, p = 0.001$	$t = -17.79, p = 0.001$	$t = -8.25, p = 0.001$
OD	N=2	$t = -11.79, p = 0.001$	—	$t = -5.28, p = 0.001$	$t = 13.44, p = 0.001$
	N=3	$t = -11.95, p = 0.001$	—	$t = -3.14, p = 0.003$	$t = 13.66, p = 0.001$
	N=4	$t = -9.13, p = 0.001$	—	$t = 3.57, p = 0.001$	$t = 13.95, p = 0.001$
OE	N=2	$t = -14.97, p = 0.001$	—	$t = -11.23, p = 0.001$	$t = 9.82, p = 0.001$
	N=3	$t = -16.13, p = 0.001$	—	$t = -11.02, p = 0.001$	$t = 10.18, p = 0.001$
	N=4	$t = -13.86, p = 0.001$	—	$t = -6.79, p = 0.001$	$t = 10.57, p = 0.001$
PD	N=2	$t = -9.88, p = 0.001$	$t = -5.42, p = 0.001$	$t = -5.35, p = 0.001$	—
	N=3	$t = -9.67, p = 0.001$	$t = -5.15, p = 0.001$	$t = -4.51, p = 0.001$	—
	N=4	$t = -9.22, p = 0.001$	$t = -5.00, p = 0.001$	$t = -3.80, p = 0.001$	—
PE	N=2	$t = -9.90, p = 0.001$	—	$t = -8.67, p = 0.001$	$t = 2.90, p = 0.005$
	N=3	$t = -9.90, p = 0.001$	—	$t = -8.44, p = 0.001$	$t = 3.20, p = 0.002$
	N=4	$t = -9.51, p = 0.001$	—	$t = -7.91, p = 0.001$	$t = 3.52, p = 0.002$

TABELA 2 – Resultados dos testes t pareados entre condições, para cada canal e valor de N , utilizando o quantificador de Entropia. Cada célula exibe o par de valores (t, p) para a comparação entre duas condições. Apenas comparações estatisticamente significativas ($p < 0,05$) são exibidas. O sinal de t indica qual condição teve maior média do quantificador: $t > 0$ implica média maior na condição à esquerda da comparação, e $t < 0$ implica média maior na condição à direita.

os quantificadores (entropia de microestados e desordem) é maior na condição de repouso. Isso evidencia uma clara redução de entropia, no sentido amplo, como medida de distribuição de informação, em indivíduos pedalando, quando comparados ao estado de repouso com olhos abertos.

Para a mesma comparação entre movimento e repouso, mas com os olhos fechados, o comportamento da entropia de microestados é semelhante, embora menos evidente. Isso é refletido pela magnitude do parâmetro t : nos canais com diferença estatisticamente significativa, a entropia foi consistentemente menor durante o pedalar. No entanto, para esse quantificador, não houve diferenças estatísticas nos canais da região occipital nem na parietal esquerda.

Por outro lado, o quantificador de desordem reforça em parte essa conclusão, mas com uma importante exceção. Nos canais significativos, os resultados corroboram a ideia de menor entropia durante o pedalar. Contudo, no canal occipital esquerdo, observou-se o oposto: a desordem foi maior durante o pedalar, um achado relevante, que pode significar alguma assimetria nessa região, considerando que ela está diretamente relacionada ao processamento visual no córtex.

Canal	N	POA vs ROA	POF vs ROF	POA vs POF	ROA vs ROF
CD	N=2	$t = -2.47, p = 0.008$	$t = -2.33, p = 0.001$	—	$t = -2.75, p = 0.001$
	N=3	$t = -7.50, p = 0.001$	$t = -7.00, p = 0.001$	$t = -7.01, p = 0.001$	$t = -7.56, p = 0.001$
	N=4	$t = -5.62, p = 0.001$	$t = -3.64, p = 0.001$	$t = -5.64, p = 0.001$	$t = -4.20, p = 0.001$
CE	N=2	$t = -1.85, p = 0.001$	—	—	—
	N=3	$t = -14.81, p = 0.001$	$t = -9.09, p = 0.001$	$t = -10.09, p = 0.001$	$t = -4.02, p = 0.001$
	N=4	$t = -13.44, p = 0.001$	$t = -5.28, p = 0.001$	$t = -8.72, p = 0.001$	—
FD	N=2	$t = -3.24, p = 0.001$	$t = -4.65, p = 0.001$	—	$t = -6.37, p = 0.001$
	N=3	$t = -3.66, p = 0.001$	$t = -10.38, p = 0.001$	$t = -15.43, p = 0.001$	$t = -25.29, p = 0.001$
	N=4	—	$t = -7.99, p = 0.001$	$t = -14.93, p = 0.001$	$t = -23.53, p = 0.001$
FE	N=2	$t = -4.31, p = 0.001$	$t = -2.34, p = 0.001$	$t = -5.67, p = 0.001$	$t = -4.07, p = 0.001$
	N=3	$t = -7.44, p = 0.001$	$t = -7.52, p = 0.001$	$t = -23.91, p = 0.001$	$t = -24.63, p = 0.001$
	N=4	$t = -6.26, p = 0.001$	$t = -4.82, p = 0.001$	$t = -23.54, p = 0.001$	$t = -22.88, p = 0.001$
OD	N=2	$t = -2.32, p = 0.001$	$t = -1.72, p = 0.001$	—	$t = 3.18, p = 0.001$
	N=3	$t = -8.03, p = 0.001$	$t = -2.20, p = 0.032$	$t = 2.86, p = 0.010$	$t = 11.28, p = 0.001$
	N=4	$t = -6.48, p = 0.001$	—	$t = 7.42, p = 0.001$	$t = 17.99, p = 0.001$
OE	N=2	$t = -3.27, p = 0.001$	—	$t = -3.28, p = 0.001$	—
	N=3	$t = -13.32, p = 0.001$	$t = 2.52, p = 0.013$	$t = -8.05, p = 0.001$	$t = 9.38, p = 0.001$
	N=4	$t = -12.23, p = 0.001$	$t = 6.29, p = 0.001$	$t = -3.40, p = 0.001$	$t = 16.59, p = 0.001$
PD	N=2	—	$t = -3.88, p = 0.001$	—	$t = -4.32, p = 0.001$
	N=3	$t = -6.37, p = 0.001$	$t = -8.18, p = 0.001$	$t = -2.48, p = 0.014$	$t = -4.54, p = 0.001$
	N=4	$t = -7.06, p = 0.001$	$t = -6.13, p = 0.001$	—	—
PE	N=2	$t = -2.83, p = 0.001$	$t = -2.15, p = 0.003$	$t = -2.19, p = 0.027$	—
	N=3	$t = -9.22, p = 0.001$	—	$t = -7.49, p = 0.001$	$t = 2.72, p = 0.006$
	N=4	$t = -6.79, p = 0.001$	$t = 5.44, p = 0.001$	$t = -4.13, p = 0.001$	$t = 8.35, p = 0.001$

TABELA 3 – Resultados dos testes t pareados entre condições, para cada canal e valor de N , utilizando o quantificador de Desordem. Cada célula exibe o par de valores (t, p) para a comparação entre duas condições. Apenas comparações estatisticamente significativas ($p < 0,05$) são exibidas. O sinal de t indica qual condição teve maior média do quantificador: $t > 0$ implica média maior na condição à esquerda da comparação, e $t < 0$ implica média maior na condição à direita.

Já na região parietal esquerda, onde a entropia de microestados não indicou diferenças relevantes, a desordem apresentou resultados aparentemente conflitantes: para $N = 2$, os valores foram maiores em repouso, enquanto para $N = 4$, foram maiores durante o pedalar. Embora esse comportamento possa parecer inconsistente, é importante lembrar que a desordem com $N = 2$ não se comporta como uma medida entrópica no sentido de complexidade. Isso pode limitar sua interpretação e nos leva a considerar com mais confiança o resultado obtido para $N = 4$, sugerindo maior desordem durante o pedalar.

Os resultados que apontam para a diminuição da complexidade durante o pedalar estão de acordo com achados prévios na literatura, como demonstrado por Ferré et al. (2024). Nesse estudo, os autores utilizaram modelos lineares mistos e mostraram que a entropia de microestados é menor ao pedalar com os olhos fechados, especialmente nas regiões occipital direita e parietal esquerda. No entanto, o comportamento dos demais canais nessa comparação não foi explorado em detalhe.

Neste trabalho, oferecemos uma análise mais abrangente da variação da complexidade entre as condições, evidenciando que, para o canal occipital esquerdo, ocorre o oposto do esperado quando se utiliza o quantificador de desordem, a entropia é maior

durante o pedalar. Além disso, os resultados obtidos para a região parietal esquerda se mostraram os mais inconclusivos, com divergências entre os quantificadores utilizados, indicando a necessidade de uma investigação mais aprofundada nessa área.

Nesta etapa da análise, fixamos a variável “movimento” e avaliamos o impacto da condição dos olhos (abertos ou fechados) sobre os quantificadores de complexidade. Na terceira coluna das tabelas, observamos como essa variável influencia especialmente durante o pedalar. Em praticamente todos os canais, os resultados indicam maior entropia e desordem quando os indivíduos pedalam com os olhos fechados, em comparação com olhos abertos. A exceção ocorre novamente na região occipital direita, onde tanto a entropia de microestados com $N = 4$ quanto a desordem indicam valores maiores na condição POA.

De forma análoga, ao comparar as condições de repouso com olhos abertos ou fechados, observa-se que ambos os quantificadores indicam maior complexidade com olhos abertos apenas nas regiões occipitais e parietal esquerda. Nas demais regiões — parietal direita, frontais e centrais — a complexidade tende a ser maior com olhos fechados. Esses resultados ajudam a contextualizar os achados prévios da literatura. Ferré et al. (2024) relataram menor entropia com olhos fechados, embora tenham se concentrado apenas na região occipital direita, enquanto Gancio et al. (2024) observaram maior entropia com olhos abertos ao utilizar dinâmica simbólica, ambos utilizando indivíduos em repouso para essa análise. Embora esses resultados não estejam incorretos, eles não representam uma tendência generalizada para todo o córtex. Nossos achados mostram que tais diferenças se manifestam de forma mais evidente na região occipital e durante o repouso. Durante o pedalar, por outro lado, observa-se uma assimetria relevante entre os canais occipitais, reforçando a complexidade e variabilidade regional da atividade cortical frente às condições experimentais.

Observamos anteriormente como os quantificadores entrópicos se comportam individualmente em diferentes condições. Agora, podemos realizar análises semelhantes para verificar quais regiões corticais apresentam maior complexidade em relação às outras. As imagens 15 e 16 mostram essa comparação para o quantificador de desordem e a entropia de microestados, respectivamente, com ambos os quantificadores calculados para $N = 4$, separadamente para cada uma das quatro condições.

De maneira geral, nas condições com os olhos abertos (POA e ROA), a região occipital se destaca como a mais complexa entre as avaliadas, tanto em termos de entropia quanto de desordem. Esse aumento de complexidade na região occipital é consistente com seu papel fundamental no processamento visual. A presença de estímulos visuais parece intensificar a dinâmica local dessa região, refletindo uma maior diversidade e desorganização nos microestados associados à atividade elétrica cortical.


Desordem, $N=4$ 

FIGURA 15 – Distribuições da desordem ($N = 4$) entre as regiões corticais (occipital, parietal, central e frontal), separadas por condição experimental: POA, POF, ROA e ROF. Cada subgráfico apresenta as comparações estatisticamente significativas (teste t pareado com $p < 0,05$), representadas por linhas conectando os pares de regiões com diferença relevante, acompanhadas dos respectivos valores de t e p . Apenas comparações não redundantes (não transitivas) são exibidas.

Por outro lado, nas condições com os olhos fechados (POF e ROF), a complexidade tende a se redistribuir. A região central passa a se destacar, especialmente em termos de desordem, indicando que, na ausência de estimulação visual, outras áreas corticais, possivelmente associadas à integração sensorio-motora ou ao estado interno do indivíduo, assumem maior protagonismo na dinâmica da atividade neural. A entropia também reflete esse padrão, com valores mais elevados na região central em comparação às demais.

Essa mudança no perfil de complexidade espacial entre condições com olhos abertos e fechados sugere uma reorganização funcional do cérebro frente à disponibilidade ou ausência de estímulos sensoriais externos. Com os olhos abertos, a atividade se concentra em áreas diretamente ligadas à percepção visual; com os olhos

Entropia, N=4




FIGURA 16 – Distribuições da entropia de microestados ($N = 4$) entre as regiões corticais (occipital, parietal, central e frontal), separadas por condição experimental: POA, POF, ROA e ROF. Cada subgráfico apresenta as comparações estatisticamente significativas (teste t pareado com $p < 0,05$), representadas por linhas conectando os pares de regiões com diferença relevante, acompanhadas dos respectivos valores de t e p . Apenas comparações não redundantes (não transitivas) são exibidas.

fechados, há uma transição para regiões mais envolvidas em processos internos ou em repouso ativo. Além disso, a consistência entre os dois quantificadores fortalece a interpretação de que essas diferenças refletem alterações reais na complexidade dinâmica das diferentes regiões corticais.

Embora nossa análise tenha se concentrado em quantificadores de entropia e desordem como medida da complexidade da atividade cortical, vale destacar que assimetrias hemisféricas não são um fenômeno novo na literatura de EEG (METZEN et al., 2022). Estudos anteriores já observaram que a atividade na banda alfa tende a apresentar assimetrias, especialmente em regiões parietais, sendo geralmente mais pronunciada com os olhos fechados. A potência alfa, por sua vez, é inversamente relacionada à atividade cortical, ou seja, um aumento em alfa sugere menor atividade

na região correspondente. Além disso, há evidências de que essas assimetrias podem estar relacionadas ao lado motor dominante do indivíduo, como destros ou canhotos, com tendências opostas entre os grupos. Assim, embora a presente análise não tenha abordado diretamente a potência alfa, os padrões de desordem observados sugerem que assimetrias na dinâmica cortical também podem ser acessadas por meio de medidas de complexidade, o que representa uma direção interessante para investigações futuras.

5.1.1 QUANTO À CLASSIFICAÇÃO

Nesta seção, analisamos o desempenho dos quantificadores quando utilizados como características para algoritmos de aprendizado de máquina na tarefa de classificar as diferentes condições experimentais. A motivação baseia-se, primeiramente, na ideia apresentada por Spezzatto et al. (2024), que introduz o conceito de espaço de recorrência: uma representação construída a partir da extração da entropia de microestados, do limiar de recorrência que maximiza essa entropia, e das probabilidades associadas aos microestados. Esses elementos são então utilizados como atributos representativos das séries temporais.

No presente trabalho, ampliamos essa abordagem ao considerar, além da entropia de microestados, um novo quantificador, a desordem, que também se propõe a mensurar aspectos de complexidade das séries. Para ambas as medidas, utilizamos apenas os valores máximos extraídos (isto é, a entropia ou desordem maximizada em relação ao limiar) e, em uma análise complementar, investigamos a contribuição das probabilidades associadas aos microestados (ou às classes de microestados, no caso da desordem) no processo de classificação.

Outro objetivo central aqui é testar se os quantificadores de complexidade realmente se relacionam à dificuldade da tarefa de classificação. Como discutido anteriormente, ambos os quantificadores são de natureza entrópica e, portanto, avaliam o grau de desordem ou variabilidade do sinal. Caso essa interpretação se sustente, é razoável esperar que sinais mais desordenados, isto é, mais complexos, sejam mais difíceis de classificar corretamente, o que se refletiria em acurácias mais baixas.

Para explorar essas questões, iniciamos com uma comparação direta entre os dois quantificadores. A Figura 17 apresenta as acurácias médias obtidas ao tentar prever as diferentes condições em função do número de canais utilizados. Observa-se que a entropia de microestados apresenta um comportamento relativamente constante independentemente do valor de N , sugerindo que, nesse conjunto de dados, a quantidade de informação extraída por esse quantificador não se altera significativamente com o número de microestados disponíveis. Em contraste, a desordem mostra uma clara dependência do tamanho dos microestados: para $N = 2$, o desempenho é visível-




FIGURA 17 – Acurácia média da classificação em função do número de canais utilizados, para diferentes tamanhos de microestado (N) e para os dois quantificadores considerados. As médias foram calculadas entre todas as diferentes execuções do algoritmo anteriormente discutidas.

mente inferior, tanto em relação à própria entropia quanto à desordem para $N = 3$ e $N = 4$.

Esse resultado está de acordo com a interpretação discutida anteriormente, na qual o caso $N = 2$ não capta adequadamente a natureza desordenada das sequências. Por outro lado, para $N = 3$ e $N = 4$, a desordem supera a entropia em termos de acurácia, sugerindo que, nesses casos, o quantificador consegue extrair informações mais relevantes das séries temporais, com ganhos médios que chegam a aproximadamente 15% quando se utilizam todos os oito canais disponíveis. Esse aumento de desempenho com o número de canais reforça a hipótese de que a distinção entre as condições requer a integração de informações provenientes de diferentes regiões corticais, destacando a importância da análise multicanal.

Outro aspecto importante da análise diz respeito à influência do uso das probabilidades associadas aos microestados (ou às classes, no caso da desordem) no desempenho do modelo de classificação. A Figura 18 apresenta essa comparação de forma clara. Nela, observa-se novamente a tendência de aumento da acurácia com o número de canais utilizados, bem como a diferença de desempenho entre os quantificadores considerados.

No entanto, um ponto que merece destaque é que o uso das probabilidades associadas, em conjunto com o valor do quantificador, não parece trazer melhorias significativas na acurácia média do modelo. Isso sugere que o valor maximizado da entropia




FIGURA 18 – Acurácia média da classificação em função do número de canais utilizados, comparando o uso exclusivo do valor do quantificador com o uso conjunto das probabilidades associadas aos microestados (ou classes de microestados). São apresentados resultados para ambos os quantificadores.

ou da desordem já é, por si só, suficiente para capturar a informação relevante contida no espaço de recorrências descrito por Spezzatto et al. (2024). Em outras palavras, um único valor escalar parece ser capaz de sintetizar eficientemente a complexidade da série temporal, dispensando a necessidade de incluir a distribuição completa das probabilidades como entrada para o classificador, o que diminui significativamente o custo computacional principalmente ao utilizar a entropia de microestados.

Para uma análise mais específica, selecionamos os resultados obtidos com o quantificador de Desordem, para $N = 4$, considerando todos os 8 canais simultaneamente e sem o uso das distribuições de probabilidade associadas, devido ao seu melhor desempenho quando comparado com as outras possibilidades. A Tabela 4 apresenta, respectivamente, os valores médios de acurácia, F1-Score, precisão e revocação obtidos para cada condição avaliada, bem como o ranking de desempenho. Os valores completos para as acurácias obtidas para classificar as diferentes condições variando-se os canais em número e tipo estão mostrados no 1.

A ordem de desempenho observada indica que a tarefa de classificar a condição visual (olhos abertos ou fechados) quando a condição de movimento está fixada (Pedalando ou Repouso) é mais simples do que o contrário — classificar o tipo de movimento com a condição visual fixa. Isso sugere que a modulação do estado visual sobre os padrões de atividade cortical é mais pronunciada do que a do movimento, em termos de recorrência.

Além disso, destaca-se que a condição “Pedalando” apresenta a maior acurácia, o que pode estar relacionado com a redução da desordem observada durante o exercício, como reportado em Ferré et al. (2024). Essa diminuição na complexidade pode estar facilitando a separação entre as classes, tornando a classificação mais eficiente.




FIGURA 19 – Matrizes de confusão para as diferentes condições experimentais. Cada subfigura corresponde a uma comparação binária entre duas condições, agrupadas por uma característica fixa (por exemplo, manter o movimento fixo e variar o estado dos olhos, ou vice-versa). As etiquetas dos eixos representam as classes reais (eixo y) e as classes preditas pelo modelo (eixo x). As células mostram a proporção de classificações feitas pelo modelo para cada combinação de classes reais e preditas, normalizada por linhas.

As matrizes de confusão apresentadas na Figura 19 complementam a análise quantitativa, evidenciando os padrões de acertos e erros do modelo em cada uma das tarefas avaliadas. A partir dessa figura, é possível observar com maior clareza quais condições foram mais bem classificadas pelo modelo. Em todos os casos, a classe com maior número de acertos corresponde àquela previamente identificada como de menor complexidade em relação à classe oposta. Por exemplo, nas tarefas que comparam condições com olhos abertos e fechados, o maior número de acertos ocorreu para as condições POA e POF, respectivamente. Isso está em conformidade com análises anteriores, que indicaram menor complexidade na condição de pedalar em comparação ao repouso. Já nas tarefas em que se fixa o movimento (Pedalando ou Repouso) e se avalia a influência da condição ocular, os resultados são mais sutis. Embora as matrizes de confusão apoiem a hipótese de que a condição de olhos fechados apresenta menor complexidade em relação à de olhos abertos, também apredentada por Ferré et al. (2024) e Gancio et al. (2024), conforme discutido na seção anterior, essa tendência se mostrou fortemente dependente do canal de EEG analisado e na condição de movimento.

A Figura 20 apresenta uma comparação direta entre a acurácia do modelo

TABELA 4 – Métricas médias da classificação por condição (Desordem, $N = 4, 8$ canais)

Condição Fixada	Acurácia	F1-Score	Precisão	Recall
Pedalando	0.830	0.829	0.830	0.830
Repouso	0.791	0.790	0.792	0.790
Abertos	0.737	0.736	0.739	0.737
Fechados	0.700	0.698	0.701	0.699




FIGURA 20 – Relação entre a entropia média e a acurácia média na classificação das condições fisiológicas (olhos abertos, olhos fechados, repouso, pedalando), considerando diferentes quantificadores e valores de N . Cada ponto representa a média dos indivíduos para um determinado cenário, com barras de erro horizontais indicando o desvio padrão do quantificador entre os indivíduos e ao longo do tempo, barras de erro verticais indicando o desvio padrão da acurácia. As acurácias sendo aquelas em que os oito canais foram usados para a classificação.

de classificação e a entropia média dos quantificadores, para diferentes condições experimentais e valores de N . Observa-se, mais uma vez, que a tarefa de classificar a condição dos olhos (abertos ou fechados) tende a apresentar maior acurácia do que a de classificar a condição de movimento (repouso ou pedalando). Vale lembrar que os rótulos das categorias na figura indicam a condição fixada, ou seja, por exemplo, “Pedalando” refere-se à classificação entre olhos abertos e fechados utilizando apenas os dados dessa condição.

Além disso, é evidente que a condição “Pedalando” resulta nas maiores acurácias de classificação, independentemente do quantificador e do tamanho do microestado, seguida por “Repouso”, “Olhos Abertos” e, por fim, “Olhos Fechados”. A figura também revela uma tendência clara: quanto menor a complexidade média dos sinais, maior tende a ser a acurácia do modelo. Isso pode ser observado, por exemplo, ao comparar os pares “Pedalando” e “Repouso”, em que a menor complexidade em “Pedalando” se associa a uma maior acurácia, padrão semelhante é visto ao comparar “Olhos Abertos” e “Olhos Fechados”.

Embora haja sobreposição entre as barras de erro, indicando que a distinção entre condições com base apenas nos quantificadores pode ser desafiadora em alguns casos, a média das observações sugere que é possível melhorar o desempenho do modelo ao induzir estados de menor complexidade neural. Esse resultado levanta questões interessantes sobre a possível relação entre complexidade cortical e estados de consciência, especialmente durante o movimento. Tal associação é discutida, por exemplo, na hipótese do cérebro entrópico proposta por Carhart-Harris et al. (2018), e poderia ser explorada mais profundamente em investigações futuras que relacionem dinâmicas cerebrais a alterações do estado mental em tarefas motoras como o pedalar.

Não houve nenhuma diferença significativa na acurácia do modelo ao restringir os canais utilizados como *features* para a classificação, vide 1. Ao utilizar apenas um canal, o desempenho do modelo na predição de qualquer uma das condições é equivalente ao de uma escolha aleatória, com acurácia próxima ao acaso. Com dois canais, observa-se um pequeno aumento na acurácia, embora os resultados ainda estejam longe do ideal e sejam independentes do par de canais utilizados para cada região (frontal, central, parietal e occipital). Para quatro canais, também não se nota diferença relevante entre utilizar canais apenas do lado esquerdo ou apenas do hemisfério direito do córtex. Todas essas análises mantêm o mesmo padrão de desempenho, independentemente do quantificador utilizado ou do tamanho do microestado considerado.

6 CONSIDERAÇÕES FINAIS

Neste trabalho, exploramos a dinâmica cortical utilizando dados experimentais de eletroencefalograma (EEG) coletados de indivíduos submetidos a diferentes tarefas motoras e visuais, especificamente repouso e pedalada, com olhos abertos e fechados. O principal objetivo foi aplicar quantificadores de recorrência, derivados da teoria de sistemas dinâmicos, para extrair informações relevantes sobre a complexidade da atividade cortical sob essas condições distintas. Essa abordagem permite uma análise mais profunda da dinâmica cerebral, indo além das medidas tradicionais de potência espectral, por exemplo, ao considerar a estrutura temporal e a recorrência dos estados neuronais.

Observamos claramente que a pedalada diminui significativamente a complexidade da dinâmica cortical, um resultado consistente com as previsões de Ferré et al. (2024), que associam a redução da entropia cerebral a estados motores ativos. Essa queda na complexidade foi validada por ambos os quantificadores utilizados neste estudo, reforçando a robustez dessa conclusão. Ademais, constatamos que uma dinâmica cortical menos complexa, isto é, de entropia reduzida, facilita a classificação computacional dos estados comportamentais. Isso ocorre porque a redução da variabilidade e da aleatoriedade na atividade neural torna os padrões associados a diferentes condições mais distinguíveis, aumentando a precisão dos modelos preditivos.

Ao longo das análises, observamos o comportamento da complexidade dos sinais provenientes dos diferentes canais de EEG, destacando variações significativas entre as condições estudadas. Os resultados obtidos foram comparados com achados reportados na literatura, encontrando consistências que reforçam a validade dos quantificadores utilizados, bem como algumas evidências inéditas. Um dos achados mais relevantes foi a identificação de uma possível assimetria funcional nas regiões occipital e parietal quando comparamos as condições de pedalada e repouso, especialmente em indivíduos com olhos fechados. Essa assimetria sugere que a dinâmica cortical não é homogênea entre hemisférios ou regiões, o que pode refletir diferentes mecanismos de processamento neural relacionados ao estado motor e visual do indivíduo.

Além disso, observamos que a complexidade associada ao estado dos olhos, abertos ou fechados, apresenta diferenças regionais importantes. Em repouso, a complexidade é maior para olhos abertos nas regiões occipital e parietal esquerda, enquanto durante a pedalada essa diferença se manifesta apenas na região occipital direita. Essa modulação regional pode indicar que o movimento de pedalar exerce uma influência específica sobre a atividade cortical, possivelmente suprimindo ou mascarando informações relativas ao estado visual, o que complica a análise isolada

do efeito dos olhos nessas condições.

Para a análise quantitativa e classificatória das condições experimentais, utilizamos dois quantificadores entrópicos distintos como características para algoritmos de aprendizado de máquina. O primeiro, a entropia de microestados de recorrência, segue a metodologia proposta por Spezzatto et al. (2024), enquanto o segundo, denominado quantificador de desordem, é uma métrica recentemente introduzida por Flauzino et al. (2025). A comparação entre esses quantificadores revelou que o quantificador de desordem é mais eficiente na extração de informações relevantes para a tarefa de classificação, apresentando desempenho superior em dados experimentais reais.

Ressaltamos, ainda, que a interpretação do quantificador de desordem depende fortemente do tamanho dos microestados utilizados na análise. No caso específico de microestados de ordem $N = 2$, embora a condição de desordem possa ser satisfeita, a simples permutação de dois valores consecutivos na série temporal não fornece uma medida efetiva do grau de desorganização da dinâmica. Em vez disso, essa permutação está mais relacionada à reversibilidade entre os dois valores considerados. Esse aspecto evidencia a importância da escolha criteriosa do parâmetro N , uma vez que ele influencia diretamente os resultados obtidos e sua posterior interpretação neurofisiológica.

Um aspecto importante encontrado foi que um único valor numérico derivado do quantificador de desordem é suficiente para fornecer ao modelo de aprendizado de máquina a informação necessária para classificar as condições experimentais, sem a necessidade de utilizar a distribuição completa de probabilidades dos microestados ou a categorização das classes de microestados, como sugerido inicialmente por Spezzatto et al. (2024). Esse achado simplifica significativamente a modelagem e indica que métricas compactas podem ser poderosas para descrever a dinâmica cortical em tarefas complexas.

Os modelos construídos a partir dos dados de apenas 8 canais de EEG e 19 indivíduos conseguiram identificar e classificar as diferentes condições experimentais com acurácias que ultrapassam 80%, especialmente na tarefa de discriminar o estado visual dos participantes quando utilizamos o quantificador de desordem. Esse desempenho é notável ao compararmos com trabalhos anteriores, como o de Gancio et al. (2024), que utilizaram um conjunto maior de indivíduos e um número substancialmente maior de canais (mais de 100 indivíduos e 64 canais), reforçando a eficiência e o potencial do quantificador para análises neurais baseadas em sinais de EEG.

Além disso, mostramos que a complexidade do sinal de EEG exerce um papel fundamental na capacidade preditiva dos modelos computacionais para a identificação do estado do indivíduo. Em particular, constatamos que sinais com menor complexidade (entropia reduzida) possibilitam modelos com maior desempenho na classificação das

condições experimentais. Isso sugere que futuras pesquisas poderiam explorar a manipulação e modulação da complexidade cortical como uma estratégia para aprimorar a precisão de análises e classificações, possibilitando uma melhor compreensão do comportamento cerebral em diferentes estados cognitivos e motores.

Outra contribuição importante deste trabalho foi demonstrar que a combinação da informação conjunta dos 8 canais forneceu resultados classificatórios mais robustos do que a utilização isolada de canais ou regiões específicas. Para subconjuntos menores de canais, observamos que o desempenho do quantificador isolado diminuiu, o que indica que a integração de múltiplos canais é fundamental para capturar a complexidade da atividade neural e melhorar a generalização dos modelos de aprendizado de máquina.

Por fim, nossos resultados indicam que assimetrias hemisféricas na dinâmica cortical, especialmente em regiões parietais, podem estar refletindo mecanismos já descritos na literatura envolvendo a banda alfa. A relação entre complexidade e assimetria funcional ainda demanda investigação mais direta, mas os padrões observados sugerem que os quantificadores de desordem podem capturar aspectos relevantes dessa dinâmica, representando uma via promissora para estudos futuros.

Nesse sentido, propomos aprofundar a investigação sobre a redução da complexidade cortical durante a pedalada, buscando relacionar esse fenômeno com teorias contemporâneas da consciência, como o modelo do cérebro entrópico, que associa a entropia cerebral a diferentes estados conscientes. Estudos futuros também poderiam se beneficiar do uso de um número maior de canais de EEG, ou da combinação com outras modalidades de registro neural, permitindo explorar com maior precisão a assimetria funcional nas regiões occipital e parietal — especialmente em situações de movimento, o que pode revelar novos insights sobre a organização espacial e dinâmica do cérebro.

Além disso, este estudo teve como um de seus objetivos principais testar e validar o quantificador de desordem na análise de sinais eletrofisiológicos. Os resultados obtidos demonstram seu potencial, abrindo novas perspectivas para sua aplicação em investigações neurocientíficas e no desenvolvimento de interfaces cérebro-computador baseadas em sinais de EEG.

REFERÊNCIAS

- AB, N. P. O. **The Nobel Prize in Physics 2024**. [S.l.]: The Nobel Prize Outreach AB, 2025. Disponível em: <https://www.nobelprize.org/prizes/physics/2024/summary/>. Acesso em: 26 jan. 2025. Citado 0 vez na página 45.
- ABHANG, P. A.; GAWALI, B. W.; MEHROTRA, S. C. **Introduction to EEG-and speech-based emotion recognition**. [S.l.]: Academic Press, 2016. Citado 1 vez na página 32.
- BEAR, M. F.; CONNORS, B. W.; PARADISO, M. A. **Neurociências: Desvendando o sistema nervoso**. [S.l.]: Artmed editora, 2017. Citado 2 vezes nas páginas 25, 28, 30, 31.
- BOLTZMANN, L. **Vorlesungen über gastheorie, Vol. I**. Leipzig: J.A. Barth, 1896. Citado 1 vez na página 23.
- BOLTZMANN, L. **Vorlesungen über gastheorie, Vol. II**. Leipzig: J.A. Barth, 1898. Citado 1 vez na página 23.
- BOTTOU, L.; CORTES, C.; DENKER, J. S.; DRUCKER, H.; GUYON, I.; JACKEL, L. D.; LECUN, Y.; MULLER, U. A.; SACKINGER, E.; SIMARD, P.; VAPNIK, V. Comparison of classifier methods: a case study in handwritten digit recognition. In: PROCEEDINGS of the 12th IAPR International Conference on Pattern Recognition, Vol. 3 - Conference C: Signal Processing (Cat. No.94CH3440-5). [S.l.: s.n.], 1994. v. 2, p. 77–82. DOI: 10.1109/ICPR.1994.576879. Citado 1 vez na página 46.
- CARHART-HARRIS, R. L. The entropic brain-revisited. **Neuropharmacology**, Elsevier, v. 142, p. 167–178, 2018. Citado 1 vezes nas páginas 16, 69.
- CHRISTENSEN, L. O. D.; JOHANNSEN, P.; SINKJÆR, T.; PETERSEN, N.; PYNDT, H. S.; NIELSEN, J. B. Cerebral activation during bicycle movements in man. **Experimental Brain Research**, Springer, v. 135, p. 66–72, 2000. DOI: 10.1007/s002210000493. Citado 1 vez na página 29.
- CLAUSIUS, R. **The mechanical theory of heat**. [S.l.]: Macmillan, 1879. Citado 0 vez na página 21.

CORSO, G.; PRADO, T. L.; LIMA, G. Z. d. S.; KURTHS, J.; LOPES, S. R. Quantifying entropy using recurrence matrix microstates. **Chaos: An Interdisciplinary Journal of Nonlinear Science**, AIP Publishing, v. 28, n. 8, 2018. DOI: 10.1063/1.5042026. Citado 3 vezes nas páginas 38, 39, 42.

DE WALL, F. **Are we smart enough to know how smart animals are?** [S.l.]: WW Norton & Company, 2016. Citado 1 vez na página 45.

DEGRAVE, J.; FELICI, F.; BUCHLI, J.; NEUNERT, M.; TRACEY, B.; CARPANESE, F.; EWALDS, T.; HAFNER, R.; ABDOLMALEKI, A.; LAS CASAS, D. de; AL., et. Magnetic control of tokamak plasmas through deep reinforcement learning. **Nature**, Nature Publishing Group, v. 602, n. 7897, p. 414–419, 2022. DOI: 10.1038/s41586-021-04301-9. Citado 2 vez na página 46.

ECKMANN, J.; KAMPHORST, S. O.; RUELLE, D. Recurrence plots of dynamical systems. In: **TURBULENCE, Strange Attractors and Chaos**. [S.l.]: World Scientific Publishing, 1995. P. 441–445. DOI: 10.1142/9789812833709_0030. Citado 1 vez na página 34.

EROGLU, D.; PERON, T. K. D. M.; MARWAN, N.; RODRIGUES, F. A.; COSTA, L. D. F.; SEBEK, M.; KISS, I. Z.; KURTHS, J. Entropy of weighted recurrence plots. **Physical Review E**, American Physical Society, v. 90, 4 2014. DOI: 10.1103/PhysRevE.90.042919. Citado 1 vez na página 39.

FANOUS, A. A.; COULDWELL, W. T. Transnasal excerebration surgery in ancient Egypt: Historical vignette. **Journal of neurosurgery**, American Association of Neurological Surgeons, v. 116, n. 4, p. 743–748, 2012. Citado 1 vez na página 15.

FERRÉ, I. B. S.; CORSO, G.; DOS SANTOS LIMA, G. Z.; LOPES, S. R.; LEOCADIO-MIGUEL, M. A.; FRANÇA, L. G. S.; DE LIMA PRADO, T.; ARAÚJO, J. F. Cycling reduces the entropy of neuronal activity in the human adult cortex. **Plos One**, Public Library of Science San Francisco, CA USA, v. 19, n. 10, 2024. DOI: 10.1371/journal.pone.0298703. Citado 0 vezes nas páginas 6, 7, 17, 52, 60, 61, 66, 67, 70.

FLAUZINO, J. V. V.; PRADO, T. L.; MARWAN, N.; KURTHS, J.; LOPES, S. R. Quantifying disorder in data. **Physical Review Letters**, 2025. DOI: 10.1103/1y98-x33s. Citado 3 vezes nas páginas 39, 41, 43, 71.

GANCIO, J.; MASOLLER, C.; TIRABASSI, G. Permutation entropy analysis of EEG signals for distinguishing eyes-open and eyes-closed brain states: Comparison of different approaches. **Chaos: An Interdisciplinary Journal of Nonlinear Science**, v. 34, n. 4, p. 043130, 2024. DOI: 10.1063/5.0200029. Citado 0 vezes nas páginas 17, 61, 67, 71.

GÉRON, A. **Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow**. [S.l.]: O'Reilly Media, 2022. Citado 4 vezes nas páginas 46, 47, 49.

GIBBS, J. W. **Elementary principles in statistical mechanics**. New Haven: Yale University Press, 1902. Citado 1 vez na página 23.

HAMMOND, C.; BERGMAN, H.; BROWN, P. Pathological synchronization in Parkinson's disease: Networks, models and treatments. **Trends in Neurosciences**, v. 30, n. 7, 2007. DOI: 10.1016/j.tins.2007.05.004. Citado 1 vez na página 33.

HARARI, Y. N. **Sapiens: História breve da humanidade**. [S.l.]: Elsinore, 2013. Citado 1 vez na página 45.

JACKSON, A. F.; BOLGER, D. J. The neurophysiological bases of EEG and EEG measurement: A review for the rest of us. **Psychophysiology**, Wiley Online Library, v. 51, p. 1061–1071, 11 2014. DOI: 10.1111/psyp.12283. Citado 4 vez na página 30.

JOLLIFFE, I. T.; CADIMA, J. Principal component analysis: a review and recent developments. **Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences**, Royal Society, v. 374, n. 2065, 2016. DOI: 10.1098/rsta.2015.0202. Citado 1 vez na página 46.

KANDEL, E.; SCHWARTZ, J.; JESSELL, T.; SIEGELBAUM, S.; HUDSPETH, A. J. **Princípios de neurociências-5**. [S.l.]: AMGH Editora, 2014. Citado 2 vezes nas páginas 25–29.

KEITHLEY, J. F. **The story of electrical and magnetic measurements: from 500 BC to the 1940s**. [S.l.]: John Wiley & Sons, 1999. Citado 1 vez na página 15.

KOEBBE, M.; MAYER-KRESS, G.; ZBILUT, J. **Use of recurrence plots in the analysis of time-series data**. [S.l.: s.n.], 1994. Disponível em: <https://citeseerx.ist.psu.edu/document?repid=rep1&type=pdf&doi=37ae58bae759a7d719fdcf1cb44>. Citado 1 vez na página 42.

KWAPIEŃ, J.; DROŹDŹ, S. Physical approach to complex systems. **Physics Reports**, Elsevier, v. 515, n. 3-4, p. 115–226, 2012. DOI: 10.1016/j.physrep.2012.01.007.

Citado 3 vezes nas páginas 20, 27.

MAATEN, L.; HINTON, G. Visualizing data using t-SNE. **Journal of Machine Learning Research**, v. 9, 2008. Citado 1 vez na página 46.

MARTUCCI, L. L.; LAUNAY, J.-M.; KAWAKAMI, N.; AL., et. Endolysosomal TPCs regulate social behavior by controlling oxytocin secretion. **Proceedings of the National Academy of Sciences**, v. 120, n. 7, 2023. DOI: 10.1073/pnas.2213682120. Citado 1 vez na página 29.

MARWAN, N. **Encounters with neighbours: Current developments of concepts based on recurrence plots and their applications**. [S.l.]: Norbert Marwan, 2003. cap. 2, p. 18–22. Citado 1 vez na página 37.

MARWAN, N.; ROMANO, M.; THIEL, M. **Recurrence plots and cross recurrence plots**. [S.l.: s.n.], 2024. Site na Internet. Disponível em: <http://www.recurrence-plot.tk>. Acesso em: 22 ago. 2024. Citado 1 vez na página 38.

MARWAN, N.; ROMANO, M. C.; THIEL, M.; KURTHS, J. Recurrence plots for the analysis of complex systems. **Physics Reports**, v. 438, n. 5, p. 237–329, 2007. ISSN 0370-1573. DOI: 10.1016/j.physrep.2006.11.001. Citado 4 vezes nas páginas 36, 38, 39, 42.

MARWAN, N.; WESSEL, N.; MEYERFELDT, U.; SCHIRDEWAN, A.; KURTHS, J. Recurrence-plot-based measures of complexity and their application to heart-rate-variability data. **Physical Review E**, American Physical Society, v. 66, p. 026702, 2 2002. DOI: 10.1103/PhysRevE.66.026702. Citado 1 vez na página 38.

MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **The Bulletin of Mathematical Biophysics**, Springer, v. 5, p. 115–133, 1943. DOI: 10.1007/BF02478259. Citado 1 vez na página 45.

MCINNES, L.; HEALY, J. **UMAP: Uniform Manifold Approximation and Projection for Dimension Reduction**. [S.l.: s.n.], 2018. DOI: 10.48550/arXiv.1802.03426. Citado 1 vez na página 46.

METZEN, D.; GENÇ, E.; GETZMANN, S.; LARRA, M. F.; WASCHER, E.; OCKLENBURG, S. Frontal and parietal EEG alpha asymmetry: a large-scale investigation of short-term reliability on distinct EEG systems. **Brain Structure and Function**, v. 227, p. 725–740, 2022. DOI: 10.1007/s00429-021-02372-1. Disponível em: 10.1007/s00429-021-02372-1. Citado 1 vez na página 63.

MINDLIN, G. M.; GILMORE, R. Topological analysis and synthesis of chaotic time series. **Physica D: Nonlinear Phenomena**, v. 58, n. 1, p. 229–242, 1992. ISSN 0167-2789. DOI: 10.1016/0167-2789(92)90111-Y. Citado 1 vez na página 42.

MITCHELL, M. **Complexity: A guided tour**. [S.l.]: Oxford university press, 2009. Citado 1 vezes nas páginas 20, 27.

PLANCK, M. **The theory of heat radiation**. Philadelphia: P. Blakiston's Son & Co., 1914. Translated by M. Masius, second edition. Citado 1 vez na página 22.

POINCARÉ, H. Sur le problème des trois corps et les équations de la dynamique. **Acta Mathematica**, Springer Netherlands, v. 13, n. 1, a3–a270, 1890. Citado 1 vez na página 34.

PRADO, T. L.; BOARETTO, B. R. R.; CORSO, G.; DOS SANTOS LIMA, G. Z.; KURTHS, J.; LOPES, S. R. A direct method to detect deterministic and stochastic properties of data. **New Journal of Physics**, IOP Publishing, v. 24, n. 3, p. 033027, 2022. Citado 1 vez na página 42.

PRADO, T. L.; CORSO, G.; DOS SANTOS LIMA, G. Z.; BUDZINSKI, R. C.; BOARETTO, B. R. R.; FERRARI, F. A. S.; MACAU, E. E. N.; LOPES, S. R. Maximum entropy principle in recurrence plot analysis on stochastic and chaotic systems. **Chaos: An Interdisciplinary Journal of Nonlinear Science**, AIP Publishing, v. 30, 4 2020. DOI: 10.1063/1.512592. Citado 2 vez na página 42.

PRADO, T. L.; MACHADO, V. S.; CORSO, G.; LIMA, G. Z. S.; LOPES, S. R. How to compute suitable vicinity parameter and sampling time of recurrence analysis. **Nonlinear Dynamics**, Springer, v. 112, n. 2, p. 1141–1152, 2024. DOI: 10.1007/s11071-023-09063-9. Citado 1 vez na página 42.

RIDGEL, A. L.; PHILLIPS, R. S.; WALTER, B. L.; DISCENZO, F. M.; LOPARO, K. A. Dynamic high-cadence cycling improves motor symptoms in Parkinson's disease.

Frontiers in Neurology, Frontiers Media SA, v. 6, p. 194, 2015. DOI: 10.3389/fneur.2015.00194. Citado 0 vez na página 16.

SETHNA, J. P. **Statistical mechanics: Entropy, order parameters, and complexity**. [S.l.]: Oxford University Press, 2021. v. 2. Citado 0 vez na página 21.

SHANNON, C. E. A mathematical theory of communication. **Bell System Technical Journal**, v. 27, n. 3, p. 379–423, 1948. Citado 1 vez na página 23.

SNIDJERS, A. H.; TONI, I.; RUŽIČKA, E.; BLOEM, B. R. Bicycling breaks the ice for freezers of gait. **Movement Disorders**, v. 26, n. 3, p. 367–371, 2011. DOI: 10.1002/mds.23530. Citado 0 vez na página 16.

SPEZZATTO, G. S.; FLAUZINO, J. V. V.; CORSO, G.; BOARETTO, B. R. R.; MACAU, E. E. N.; PRADO, T. L.; LOPES, S. R. Recurrence microstates for machine learning classification. **Chaos: An Interdisciplinary Journal of Nonlinear Science**, AIP Publishing, v. 34, 7 2024. DOI: 10.1063/5.0203801. Citado 1 vezes nas páginas 43, 48, 64, 66, 71.

SPORNS, O. **Networks of the brain**. [S.l.]: MIT press, 2010. Citado 2 vezes nas páginas 28, 29.

STAM, C. J. Nonlinear dynamical analysis of EEG and MEG: Review of an emerging field. **Clinical Neurophysiology**, v. 116, n. 10, p. 2266–2301, 2005. DOI: 10.1016/j.clinph.2005.06.011. Citado 1 vez na página 16.

STORZER, L.; BUTZ, M.; HIRSCHMANN, J.; ABBASI, O.; GRATKOWSKI, M.; SAUPE, D.; SCHNITZLER, A.; DALAL, S. S. Bicycling and walking are associated with different cortical oscillatory dynamics. **Frontiers in Human Neuroscience**, Frontiers Media SA, v. 10, 2016. DOI: 10.3389/fnhum.2016.00061. Citado 2 vezes nas páginas 16, 33.

TEPLAN, M.; AL., et. Fundamentals of EEG measurement. **Measurement Science Review**, v. 2, n. 2, 2002. Citado 1 vez na página 29.

TRULLA, L. L.; GIULIANI, A.; ZBILUT, J. P.; WEBBER, C. L. Recurrence quantification analysis of the logistic equation with transients. **Physics Letters A**, v. 223, n. 4, p. 255–260, 1996. ISSN 0375-9601. DOI: 10.1016/S0375-9601(96)00741-4. Citado 1 vez na página 38.

VERGANI, A. A. Hans Berger (1873–1941): the German psychiatrist who recorded the first electrical brain signal in humans 100 years ago. **Advances in Physiology Education**, v. 48, n. 4, p. 878–881, 2024. DOI: 10.1152/advan.00119.2024. Citado 2 vezes nas páginas 30, 32.

WEBBER, C. L.; ZBILUT, J. P. Dynamical assessment of physiological systems and states using recurrence plot strategies. **Journal of Applied Physiology**, v. 76, n. 2, p. 965–973, 1994. PMID: 8175612. DOI: 10.1152/jappl.1994.76.2.965. Citado 0 vez na página 37.

YAQIAN, C.; HIROYA, N.; YANMEI, K. Emergence of pathological beta oscillation and its uncertainty quantification in a time-delayed feedback Parkinsonian model. **Chaos, Solitons Fractals**, v. 185, 2024. DOI: 10.1016/j.chaos.2024.115113. Citado 1 vez na página 33.

ZBILUT, J. P.; WEBBER JR., C. L. Embeddings and delays as derived from quantification of recurrence plots. **Physics Letters A**, v. 171, n. 3, p. 199–203, 1992. ISSN 0375-9601. DOI: 10.1016/0375-9601(92)90426-M. Citado 0 vez na página 37.

ZBILUT, J. P.; ZALDIVAR-COMENGES, J. M.; STROZZI, F. Recurrence quantification based Liapunov exponents for monitoring divergence in experimental data. **Physics Letters A**, v. 297, n. 3, p. 173–181, 2002. ISSN 0375-9601. DOI: 10.1016/S0375-9601(02)00436-X. Citado 1 vez na página 42.

ANEXO 1 – TABELAS DAS ACURÁCIAS

TABELA 5 – Acurácia do quantificador Entropia (N=2) para diferentes condições e agrupamento de canais utilizados para a classificação.

Região	Condição			
	Pedalando	Repouso	Abertos	Fechados
Frontal Esquerdo	0.559 ± 0.019	0.533 ± 0.020	0.517 ± 0.021	0.525 ± 0.021
Frontal Direito	0.532 ± 0.024	0.542 ± 0.019	0.515 ± 0.021	0.533 ± 0.024
Central Esquerdo	0.520 ± 0.020	0.505 ± 0.018	0.518 ± 0.022	0.540 ± 0.023
Central Direito	0.516 ± 0.021	0.503 ± 0.021	0.518 ± 0.023	0.525 ± 0.022
Parietal Esquerdo	0.518 ± 0.023	0.495 ± 0.020	0.510 ± 0.020	0.507 ± 0.022
Parietal Direito	0.512 ± 0.024	0.519 ± 0.019	0.526 ± 0.019	0.511 ± 0.020
Occipital Esquerdo	0.543 ± 0.019	0.520 ± 0.018	0.541 ± 0.021	0.502 ± 0.022
Occipital Direito	0.513 ± 0.022	0.531 ± 0.022	0.515 ± 0.022	0.506 ± 0.020
Frontal	0.595 ± 0.022	0.562 ± 0.018	0.550 ± 0.024	0.541 ± 0.020
Central	0.540 ± 0.021	0.519 ± 0.021	0.586 ± 0.019	0.543 ± 0.023
Parietal	0.523 ± 0.023	0.540 ± 0.020	0.533 ± 0.024	0.533 ± 0.020
Occipital	0.580 ± 0.023	0.553 ± 0.019	0.561 ± 0.021	0.533 ± 0.022
Esquerdo	0.657 ± 0.020	0.656 ± 0.020	0.603 ± 0.021	0.605 ± 0.022
Direito	0.649 ± 0.022	0.651 ± 0.020	0.608 ± 0.022	0.609 ± 0.022
Todos os Canais	0.744 ± 0.020	0.676 ± 0.018	0.663 ± 0.019	0.678 ± 0.022

TABELA 6 – Acurácia do quantificador Entropia (N=3) para diferentes condições e agrupamento de canais utilizados para a classificação.

Região	Condição			
	Pedalando	Repouso	Abertos	Fechados
Frontal Esquerdo	0.555 ± 0.020	0.532 ± 0.021	0.524 ± 0.023	0.515 ± 0.020
Frontal Direito	0.524 ± 0.024	0.514 ± 0.022	0.518 ± 0.022	0.527 ± 0.017
Central Esquerdo	0.506 ± 0.018	0.507 ± 0.022	0.526 ± 0.020	0.530 ± 0.021
Central Direito	0.506 ± 0.023	0.502 ± 0.017	0.532 ± 0.020	0.534 ± 0.024
Parietal Esquerdo	0.506 ± 0.020	0.518 ± 0.022	0.521 ± 0.023	0.509 ± 0.021
Parietal Direito	0.497 ± 0.018	0.516 ± 0.023	0.524 ± 0.022	0.504 ± 0.021
Occipital Esquerdo	0.523 ± 0.023	0.534 ± 0.023	0.531 ± 0.023	0.504 ± 0.021
Occipital Direito	0.507 ± 0.021	0.540 ± 0.020	0.519 ± 0.018	0.515 ± 0.021
Frontal	0.592 ± 0.023	0.565 ± 0.020	0.572 ± 0.019	0.544 ± 0.021
Central	0.535 ± 0.022	0.526 ± 0.020	0.571 ± 0.022	0.546 ± 0.020
Parietal	0.530 ± 0.019	0.539 ± 0.020	0.539 ± 0.021	0.529 ± 0.020
Occipital	0.561 ± 0.024	0.571 ± 0.022	0.565 ± 0.021	0.512 ± 0.020
Esquerdo	0.661 ± 0.020	0.626 ± 0.019	0.612 ± 0.020	0.591 ± 0.020
Direito	0.644 ± 0.023	0.641 ± 0.018	0.589 ± 0.020	0.603 ± 0.023
Todos os Canais	0.734 ± 0.017	0.680 ± 0.018	0.674 ± 0.020	0.662 ± 0.021

TABELA 7 – Acurácia do quantificador Entropia (N=4) para diferentes condições e agrupamento de canais utilizados para a classificação.

Região	Condição			
	Pedalando	Repouso	Abertos	Fechados
Frontal Esquerdo	0.552 ± 0.021	0.533 ± 0.020	0.514 ± 0.020	0.513 ± 0.018
Frontal Direito	0.542 ± 0.020	0.544 ± 0.021	0.525 ± 0.023	0.529 ± 0.023
Central Esquerdo	0.522 ± 0.022	0.527 ± 0.023	0.537 ± 0.022	0.516 ± 0.021
Central Direito	0.508 ± 0.018	0.520 ± 0.019	0.505 ± 0.020	0.524 ± 0.025
Parietal Esquerdo	0.501 ± 0.020	0.499 ± 0.020	0.502 ± 0.021	0.508 ± 0.019
Parietal Direito	0.486 ± 0.021	0.499 ± 0.020	0.482 ± 0.021	0.496 ± 0.021
Occipital Esquerdo	0.526 ± 0.016	0.523 ± 0.022	0.541 ± 0.019	0.529 ± 0.023
Occipital Direito	0.516 ± 0.019	0.541 ± 0.020	0.504 ± 0.020	0.510 ± 0.022
Frontal	0.584 ± 0.020	0.545 ± 0.023	0.567 ± 0.016	0.544 ± 0.020
Central	0.541 ± 0.023	0.518 ± 0.022	0.559 ± 0.019	0.576 ± 0.021
Parietal	0.533 ± 0.027	0.531 ± 0.018	0.549 ± 0.022	0.521 ± 0.018
Occipital	0.566 ± 0.020	0.560 ± 0.023	0.558 ± 0.019	0.517 ± 0.023
Esquerdo	0.636 ± 0.019	0.630 ± 0.024	0.604 ± 0.023	0.595 ± 0.020
Direito	0.619 ± 0.022	0.627 ± 0.022	0.601 ± 0.020	0.613 ± 0.022
Todos os Canais	0.731 ± 0.019	0.685 ± 0.019	0.674 ± 0.024	0.663 ± 0.024

TABELA 8 – Acurácia do quantificador Desordem (N=2) para diferentes condições e agrupamento de canais utilizados para a classificação.

Região	Condição			
	Pedalando	Repouso	Abertos	Fechados
Frontal Esquerdo	0.557 ± 0.019	0.546 ± 0.023	0.508 ± 0.020	0.496 ± 0.022
Frontal Direito	0.504 ± 0.022	0.540 ± 0.019	0.505 ± 0.022	0.538 ± 0.022
Central Esquerdo	0.486 ± 0.019	0.506 ± 0.021	0.516 ± 0.019	0.509 ± 0.019
Central Direito	0.512 ± 0.021	0.500 ± 0.022	0.495 ± 0.020	0.508 ± 0.023
Parietal Esquerdo	0.512 ± 0.022	0.511 ± 0.020	0.518 ± 0.021	0.500 ± 0.023
Parietal Direito	0.509 ± 0.022	0.514 ± 0.019	0.515 ± 0.020	0.519 ± 0.020
Occipital Esquerdo	0.506 ± 0.022	0.516 ± 0.022	0.521 ± 0.023	0.477 ± 0.023
Occipital Direito	0.516 ± 0.021	0.512 ± 0.023	0.520 ± 0.020	0.498 ± 0.020
Frontal	0.588 ± 0.022	0.575 ± 0.024	0.553 ± 0.022	0.536 ± 0.021
Central	0.517 ± 0.022	0.516 ± 0.022	0.537 ± 0.020	0.526 ± 0.019
Parietal	0.534 ± 0.019	0.513 ± 0.020	0.529 ± 0.019	0.524 ± 0.024
Occipital	0.527 ± 0.021	0.531 ± 0.022	0.536 ± 0.017	0.514 ± 0.021
Esquerdo	0.614 ± 0.021	0.562 ± 0.025	0.568 ± 0.021	0.515 ± 0.018
Direito	0.577 ± 0.022	0.594 ± 0.017	0.557 ± 0.022	0.523 ± 0.022
Todos os Canais	0.680 ± 0.020	0.631 ± 0.021	0.632 ± 0.021	0.585 ± 0.021

TABELA 9 – Acurácia do quantificador Desordem (N=3) para diferentes condições e agrupamento de canais utilizados para a classificação.

Região	Condição			
	Pedalando	Repouso	Abertos	Fechados
Frontal Esquerdo	0.577 ± 0.020	0.592 ± 0.022	0.503 ± 0.020	0.513 ± 0.019
Frontal Direito	0.543 ± 0.022	0.588 ± 0.020	0.525 ± 0.020	0.524 ± 0.020
Central Esquerdo	0.508 ± 0.022	0.513 ± 0.019	0.518 ± 0.020	0.507 ± 0.022
Central Direito	0.519 ± 0.021	0.508 ± 0.023	0.518 ± 0.022	0.502 ± 0.025
Parietal Esquerdo	0.510 ± 0.021	0.538 ± 0.022	0.515 ± 0.021	0.510 ± 0.022
Parietal Direito	0.491 ± 0.021	0.521 ± 0.021	0.506 ± 0.022	0.519 ± 0.021
Occipital Esquerdo	0.509 ± 0.022	0.510 ± 0.023	0.494 ± 0.022	0.507 ± 0.019
Occipital Direito	0.508 ± 0.020	0.519 ± 0.025	0.495 ± 0.019	0.518 ± 0.020
Frontal	0.607 ± 0.021	0.640 ± 0.018	0.561 ± 0.020	0.552 ± 0.020
Central	0.545 ± 0.022	0.524 ± 0.021	0.563 ± 0.020	0.547 ± 0.024
Parietal	0.552 ± 0.020	0.538 ± 0.022	0.558 ± 0.020	0.551 ± 0.023
Occipital	0.545 ± 0.021	0.555 ± 0.023	0.541 ± 0.020	0.525 ± 0.019
Esquerdo	0.714 ± 0.017	0.727 ± 0.021	0.656 ± 0.020	0.626 ± 0.022
Direito	0.688 ± 0.019	0.730 ± 0.020	0.603 ± 0.021	0.610 ± 0.021
Todos os Canais	0.815 ± 0.018	0.791 ± 0.019	0.750 ± 0.019	0.708 ± 0.020

TABELA 10 – Acurácia do quantificador Desordem (N=4) para diferentes condições e agrupamento de canais utilizados para a classificação.

Região	Condição			
	Pedalando	Repouso	Abertos	Fechados
Frontal Esquerdo	0.557 ± 0.018	0.579 ± 0.020	0.475 ± 0.020	0.505 ± 0.020
Frontal Direito	0.523 ± 0.023	0.582 ± 0.021	0.495 ± 0.021	0.528 ± 0.022
Central Esquerdo	0.507 ± 0.020	0.495 ± 0.022	0.535 ± 0.019	0.512 ± 0.020
Central Direito	0.483 ± 0.021	0.505 ± 0.021	0.513 ± 0.021	0.496 ± 0.021
Parietal Esquerdo	0.509 ± 0.020	0.484 ± 0.021	0.506 ± 0.020	0.520 ± 0.019
Parietal Direito	0.506 ± 0.022	0.522 ± 0.021	0.491 ± 0.022	0.506 ± 0.021
Occipital Esquerdo	0.508 ± 0.022	0.536 ± 0.019	0.517 ± 0.021	0.496 ± 0.024
Occipital Direito	0.507 ± 0.020	0.539 ± 0.019	0.515 ± 0.024	0.485 ± 0.018
Frontal	0.617 ± 0.022	0.615 ± 0.018	0.533 ± 0.020	0.533 ± 0.021
Central	0.522 ± 0.020	0.521 ± 0.021	0.562 ± 0.026	0.548 ± 0.023
Parietal	0.548 ± 0.019	0.548 ± 0.019	0.543 ± 0.021	0.571 ± 0.021
Occipital	0.545 ± 0.020	0.587 ± 0.021	0.546 ± 0.019	0.504 ± 0.021
Esquerdo	0.723 ± 0.018	0.736 ± 0.017	0.641 ± 0.020	0.614 ± 0.020
Direito	0.702 ± 0.020	0.725 ± 0.018	0.577 ± 0.021	0.616 ± 0.024
Todos os Canais	0.822 ± 0.015	0.793 ± 0.018	0.742 ± 0.019	0.703 ± 0.018