

# Processamento de Sinais de EEG com Redes Neurais Profundas

Prof. Raphael Y. de Camargo

Centro de Matemática, Computação e Cognição (CMCC)  
Universidade Federal do ABC





# Parte I

## Como podemos ler informações do Cérebro?

# Neurônios e Nosso Cérebro



Nosso cérebro: 100 bilhões de neurônios



Neurônio realiza processamentos “simples”

Em conjunto possuem grande poder computacional

Processamento depende de conexões:

- Sistema visual, memória, movimentos, planejamento, etc.

Padrão de ativação: conjunto de neurônios que estão ativos em um determinado momento



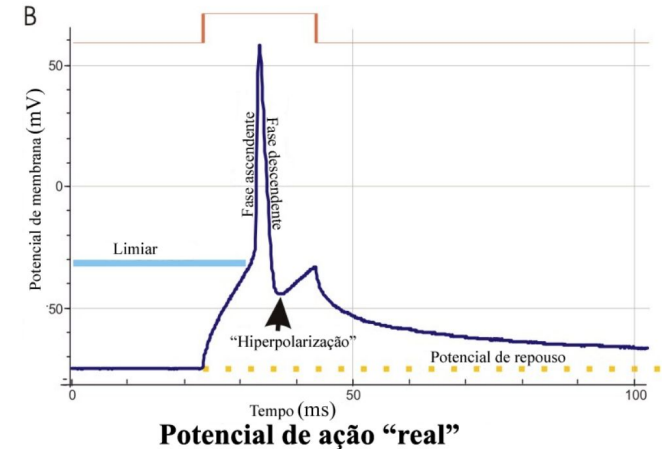


# Neurônios e Nosso Cérebro



Neurônios → membrana com diferentes concentrações de íons em cada lado




Processamento de informação → mudanças no potencial de membrana

Neurônios se comunicam por meio de sinapses



# Como Extrair informações do Cérebro?


- A atividade dos neurônios gera campos elétricos -> podem ser capturados por eletrodos
- Eletroencefalografia (EEG), Eletrocorticografia (ECoG), Eletrodos Implantados



fonte: en.wikipedia.org/

Obien, Marie Engelen & Deligkaris, Kosmas & Bullmann, Torsten & Bakkum, Douglas & Frey, Urs. (2015). Revealing Neuronal Function through Microelectrode Array Recordings. *Frontiers in Neuroscience*. 8. 10.3389/fnins.2014.00423.

# Tipos de ondas cerebrais



Neurônios frequentemente disparam em sincronia.


A atividade sincronizada de neurônios dá origem a oscilações regulares no campo elétrico gerado

Diferentes tipos de atividade neural podem gerar padrões de ondas cerebrais distintos

Podem ser detectado por eletrodos e classificados por algoritmos de aprendizado de máquina

Frequency band	Frequency	Brain states
Gamma ( $\gamma$ )	$>35$ Hz	Concentration
Beta ( $\beta$ )	12–35 Hz	Anxiety dominant, active, external attention, relaxed
Alpha ( $\alpha$ )	8–12 Hz	Very relaxed, passive attention
Theta ( $\theta$ )	4–8 Hz	Deeply relaxed, inward focused
Delta ( $\delta$ )	0.5–4 Hz	Sleep

# Classificação de EEG



Sinais extraídos são ruidosos e com artefatos

Primeiro passo é limpar o sinal:

- Remover artefatos e filtrar o sinal
- Ajustar a frequência de captura

Em seguida, sinal é transformado:

- Frequências do sinal
- Co-variâncias entre os eletrodos
- Conectividade de áreas

Algoritmo de aprendizado de máquina realiza então a classificação ou regressão no sinal



# **Parte II**

## **Decodificação Usando Aprendizado Profundo**



# Como Treinar Redes Neurais?



O mais comum é o **aprendizado supervisionado**:

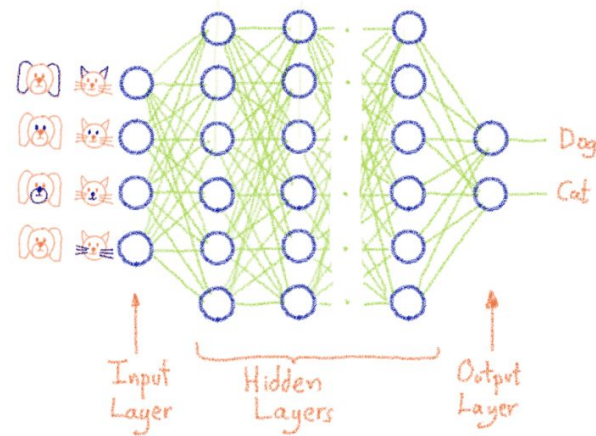
Mostra muitos pares (entrada, saída)

Rede modifica os pesos para aprender o mapeamento

**Algoritmo de retropropagação:** erros dos últimos neurônios são propagados para neurônios de camadas anteriores

Existe também o aprendizado **não-supervisionado**, onde a rede aprende sobre padrões estatísticos a partir das imagens apresentadas


E o aprendizado **auto-supervisionado**, onde a rede deve fazer previsões sobre os dados de entrada: qual a palavra faltante em uma frase ou o conteúdo do próximo quadro em um vídeo.




<https://www.ovh.com/blog/what-does-training-neural-networks-mean/>

# Desafios para Decodificação de EEG

- **Alta-dimensionalidade:** múltiplos eletrodos e séries temporais com muitos pontos
- **Baixa relação sinal-ruído:** artefatos, dados de múltiplas regiões, interferências, outras funções
- **Quantidade limitada de dados:** são caros e trabalhosos para obter
- **Dados não-estacionários:** dados de um mesmo indivíduo mudam entre sessões e dados de diferentes indivíduos são incompatíveis

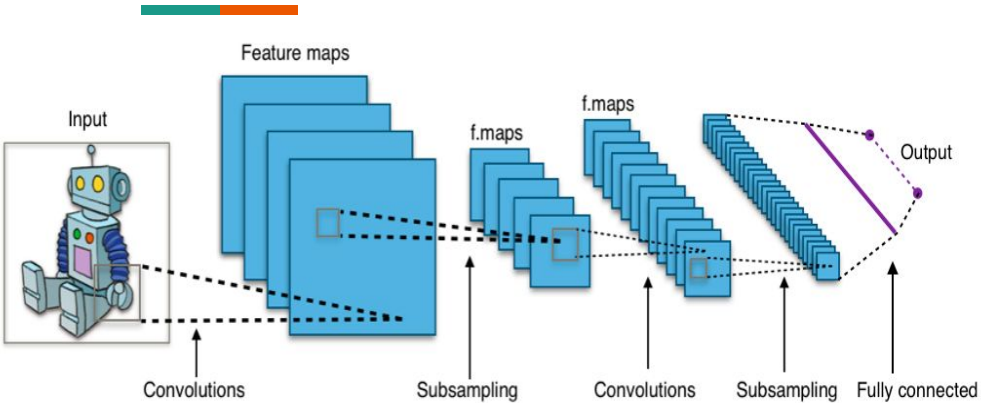


fonte: en.wikipedia.org/




DOI: [10.1590/S1676-26492007000300009](https://doi.org/10.1590/S1676-26492007000300009)

# Redes Convolucionais



[https://en.wikipedia.org/wiki/Convolutional\\_neural\\_network](https://en.wikipedia.org/wiki/Convolutional_neural_network)


Uso de redes neurais para fazer a classificação dos sinais de EEG  
Permite aprendizado end-to-end




Neurônio operam sobre dados de uma pequena região da camada anterior

- Pesos das conexões (filtros) são compartilhados entre neurônios
- Múltiplos filtros por camada

**Convolution (temporal)**  
40 Units




**Spatial filter (all electrodes, all previous filters)**  
40 Units




**Square**

**Mean Pooling**  
Stride 15x1



**Log**


**Linear Classification (Dense Layer+Softmax)**  
4 Units



ShallowNet

# Modelos de Atenção

Song, Y., Zheng, Q., Liu, B., Gao, X., 2023. EEG Conformer: Convolutional Transformer for EEG Decoding and Visualization. IEEE Transactions on Neural Systems and Rehabilitation Engineering 31



São a base dos LLMs como ChatGPT

Módulos de auto-atenção permitem relacionar diferentes partes do sinal

Entradas são tokens: podem ser gerados a partir do sinal por meio de redes convolutivas

BENDR: Wav2Vec 2.0 para redes neurais


# Transferência de Aprendizado

Os cérebros de diferentes indivíduos são diferentes

- Modelos treinados em um indivíduo não funcionam no outro
- Mesmo em um único indivíduo, modelos treinados em uma sessão podem não funcionar em outra

**Adaptação de Domínio:** modifica os dados de cada indivíduo para que todos tenham características similares


**Adaptação de Regra:** adapta o classificador para cada indivíduo (supõe que sinais possuem similaridades)



# Alinhamento Euclidiano



Figure 1: Euclidean Alignment steps illustrated. The star represents the origin of the space.



$$\bar{R}^j = \frac{1}{n} \sum_{i=1}^n X_i^j X_i^{j\top},$$

$$\tilde{X}_i^j = (\bar{R}^j)^{-1/2} X_i^j.$$

**Pré-processamento:**  
Transforma os sinais de EEG de cada indivíduo


Média aritmética de matriz de covariância passa a ser a matriz identidade

**Decorrelação:** pares de canais passam a ter covariância média zero

**Variância unitária:** para a média dos sinais de cada canal

# Treinamento de DNNs com dados de múltiplos indivíduos

## A SYSTEMATIC EVALUATION OF EUCLIDEAN ALIGNMENT WITH DEEP LEARNING FOR EEG DECODING

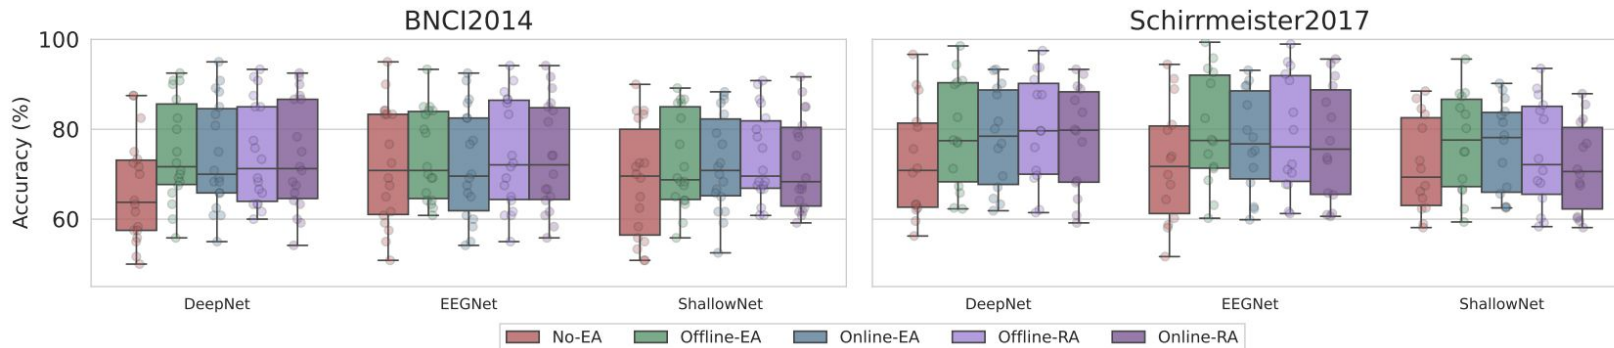


**Bruna Junqueira<sup>1,2</sup>** **Bruno Aristimunha<sup>2,3</sup>** **Sylvain Chevallier<sup>2</sup>** **Raphael Y. de Camargo<sup>3</sup>**

<sup>1</sup>University of São Paulo, Sao Paulo, Brazil

<sup>2</sup>Université Paris-Saclay, Inria TAU team, LISN-CNRS, France

<sup>3</sup>Federal University of ABC, Santo Andre, Brazil





# Combining Euclidean Alignment and Data Augmentation for BCI decoding

Gustavo H. Rodrigues\*, Bruno Aristimunha<sup>†‡</sup>, Sylvain Chevallier<sup>†</sup>, and Raphael Y. de Camargo<sup>‡</sup>

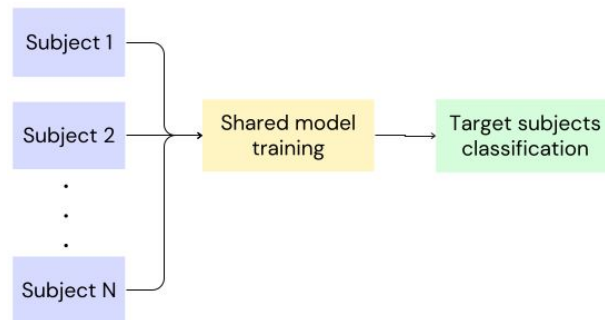
\*University of São Paulo, Sao Paulo, Brazil

<sup>†</sup>Université Paris-Saclay, Inria TAU team, LISN-CNRS, France

<sup>‡</sup>Federal University of ABC (UFABC), Santo André, Brazil



Tanto o Alinhamento Euclidiano, quanto a Aumentação de Dados contribuíram na melhora do desempenho





# EVALUATING THE STRUCTURE OF COGNITIVE TASKS WITH TRANSFER LEARNING

Bruno Aristimunha<sup>1,2</sup> Raphael Y. de Camargo<sup>2</sup> Walter H. Lopez Pinaya<sup>3</sup>  
Sylvain Chevallier<sup>1</sup> Alexandre Gramfort<sup>1</sup> Cédric Rommel<sup>1,4</sup>


<sup>1</sup>Université Paris-Saclay, Inria, France

<sup>2</sup>Federal University of ABC, Santo Andre, Brazil


<sup>3</sup>King's College London, London, United Kingdom

<sup>4</sup>Valeo.ai, Paris, France


Face Perception N170




Flankers ERN and LRP




Passive Auditory Oddball MMN




Active Visual Oddball P3



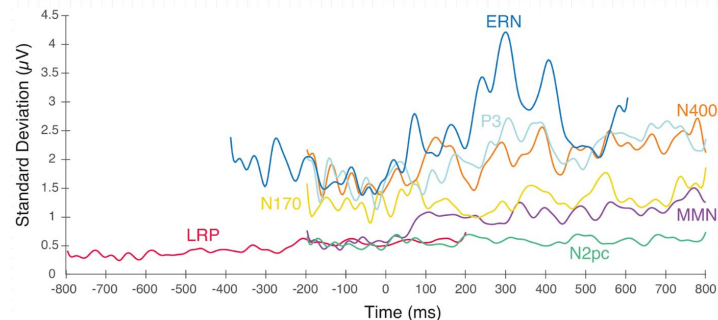
Visual Search N2pc



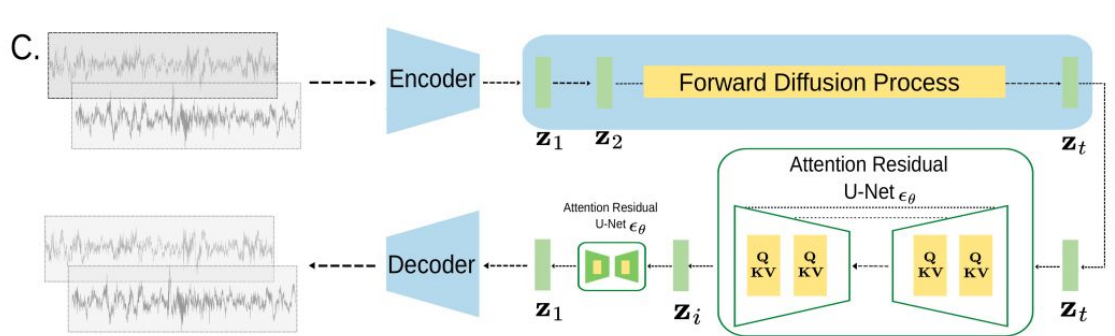


Word Pair Judgment N400



		ShallowNet						
Source Task	ERN	84.68 ±0.85	50.01 ±0.02	59.11 ±0.79	71.12 ±1.23	56.82 ±1.93	50.00 ±0.00	60.60 ±1.24
	LRP	82.91 ±1.52	76.85 ±1.34	82.79 ±1.40	66.51 ±1.02	60.76 ±0.72	50.00 ±0.01	57.31 ±1.36
	MMN	59.32 ±1.15	50.96 ±0.31	54.49 ±0.65	60.08 ±1.51	55.64 ±0.76	50.89 ±0.31	54.20 ±1.05
	N170	57.35 ±0.93	50.00 ±0.01	56.73 ±1.37	69.47 ±0.85	56.49 ±1.33	50.00 ±0.01	54.64 ±0.82
	N2pc	59.83 ±1.50	50.03 ±0.03	60.58 ±1.85	56.84 ±1.09	63.25 ±0.43	50.00 ±0.01	53.88 ±1.17
	N400	58.53 ±1.59	50.00 ±0.00	58.20 ±2.20	60.46 ±2.09	56.73 ±0.61	67.83 ±1.66	55.56 ±2.11
	P3	57.18 ±0.74	50.00 ±0.00	57.14 ±1.70	59.17 ±1.17	55.81 ±0.68	50.00 ±0.00	69.23 ±1.14
		ERN	LRP	MMN	N170	N2pc	N400	P3



# Gerando Dados Extras de EEG



## Synthetic Sleep EEG Signal Generation using Latent Diffusion Models

**Bruno Aristimunha**  
Université Paris-Saclay, Inria TAU, France  
Federal University of ABC, Brazil  
b.aristimunha@gmail.com

**Raphael Y. de Camargo**  
Federal University of ABC,  
Santo Andre, Brazil

**Sylvain Chevallier**  
Université Paris-Saclay,  
Inria TAU, France

**Adam G. Thomas**  
Data Science and Sharing Team,  
NIMH, USA

**Oeslle Lucena**  
King's College London,  
London, United Kingdom

**M. Jorge Cardoso**  
King's College London,  
London, United Kingdom

**Walter H. Lopez Pinaya**  
King's College London,  
London, United Kingdom

**Jessica Dafflon**  
Data Science and Sharing Team, NIMH, USA  
Machine Learning Team, NIMH, USA

**Modelos Generativos de Difusão**  
Conhecidos na geração de imagens:  
DALL-E, Midjourney

Adicionam ruído a imagem (ou EEG) e aprendem como reconstruir sinal a partir do ruído

# Estágios do Sono

## Classificação de Estágio do Sono

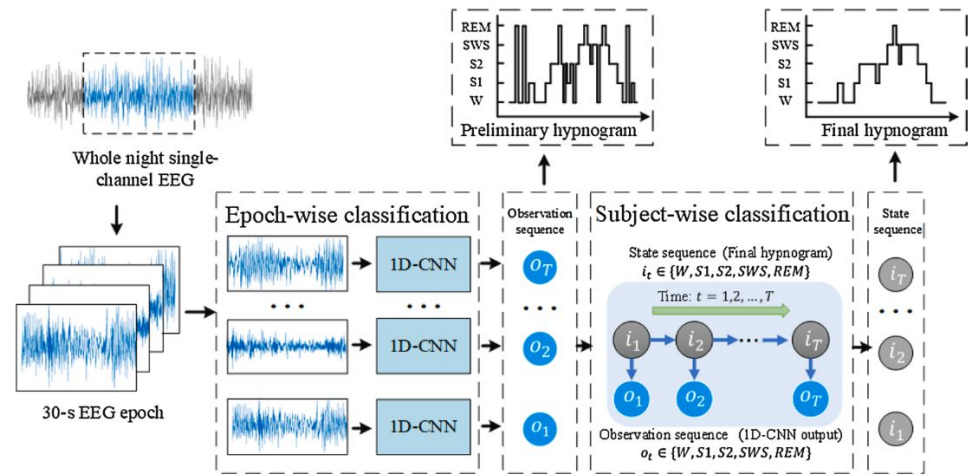
- Tarefa tediosa e intensiva de trabalho

## Uso de Redes Neurais para classificação

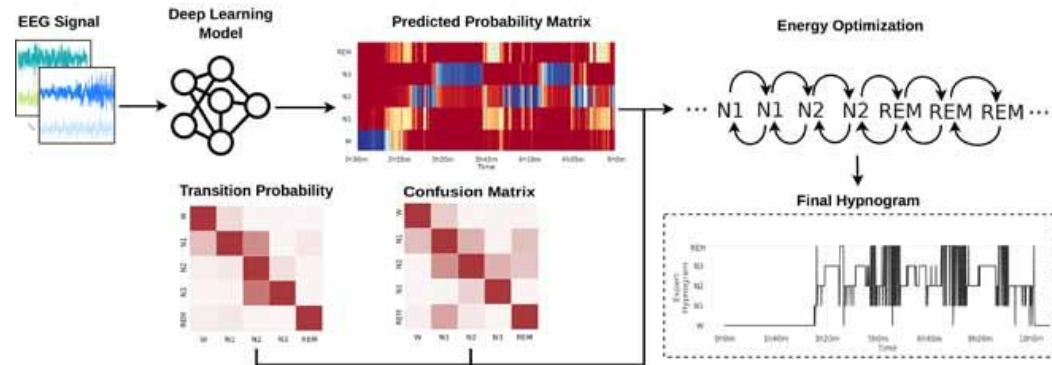
- Saída gerada é muito ruidosa

## Técnicas para ajustar a classificação

- Modelo de energia que considera probabilidades de classificação e transição
- Outras abordagens



A single-channel EEG based automatic sleep stage classification method leveraging deep one-dimensional convolutional neural network and hidden Markov model. Yang et al (2021)



# Conclusões



- Existem diversos métodos para classificação de sinais de EEG
- Métodos clássicos
  - Baseados em frequências do sinal
  - Covariâncias entre os eletrodos (espaço Riemanniano)
- Métodos de Aprendizado profundo, que permitem aprendizado fim-a-fim
  - Mas se beneficiam de pre-processamento, como alinhamento Euclidiano
  - Requerem muitos dados de treinamento (aumentação de dados)
- Outras abordagens: aprendizado auto-supervisionado