

Gráficos de Recorrência para Classificação de Sinais de EEG Usando Aprendizado Profundo*

Patrick O. de Paula¹, Henrique L. V. Giuliani¹, Denis G. Fantinato¹

¹Centro de Matemática, Computação e Cognição
Universidade Federal do ABC (UFABC) – Santo André – SP – Brazil

patrick.oliveira@aluno.ufabc.edu.br
{henrique.voni, denis.fantinato}@ufabc.edu.br

Abstract. *The development of Brain-Computer Interfaces (BCI) requires the capacity to process and classify brain signals, generated by certain stimuli, from a wide variety of users. With this goal, we analyze the use of Convolutional Neural Networks, known for its high performance in computer vision tasks, for classification of electroencephalography (EEG) signals. The EEG signals were first preprocessed by Canonical Correlation Analysis and transformed into images using the Recurrence Plot technique, achieving an accuracy of 96% for signals with a time window as short as 0,5 s (128 points), being a promising result towards this approach for the development of robust BCI systems.*

Resumo. *O desenvolvimento de Interfaces Cérebro-Computador (BCI) exige a capacidade de processamento e classificação de sinais neuronais, gerados por certos estímulos sensoriais, de uma grande variedade de usuários. Com este objetivo, o presente trabalho busca a aplicação de Redes Neurais Convolucionais, reconhecidas pelo seu alto desempenho em problemas de classificação, para o processamento de sinais de eletroencefalografia (EEG). Os sinais de EEG foram primeiramente pré-processados pela técnica de Análise de Correlações Canônicas e convertidos em imagens através de Gráficos de Recorrência. Os resultados corroboram o uso desta abordagem em sistemas de BCI, atingindo uma taxa de acerto de 96% para sinais de 128 pontos (0,5 s).*

1. Introdução

Um dispositivo capaz de estabelecer uma interface que recebe como entrada sinais relativos à atividade neuronal e que gera como saída comandos de ativação em máquinas recebe o nome de sistemas de interface cérebro-computador (*Brain-Computer Interface*, BCI) [Nam et al. 2018]. Tais sistemas geralmente fazem uso de sinais de eletroencefalografia (EEG), um método não invasivo e de baixo custo para registrar a atividade neuronal. Todavia, a presença intensa de ruídos e artefatos nos sinais podem tornar a análise e a classificação destes bastante difícil. Somado a isso, se considerada a alta variabilidade nos padrões da atividade neuronal para diferentes sujeitos (usuários do sistema BCI), a concepção de um sistema BCI genérico capaz de intercambiar usuários ganha proporções ainda mais desafiadoras.

Recentemente, métodos de aprendizagem profunda (*Deep Learning*, DL) como as redes neurais convolucionais (*Convolutional Neural Networks*,

*Esse trabalho foi parcialmente financiado pela Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP), processo nº 2019/17997-4 e 2020/10014-2.

CNNs) [Goodfellow et al. 2016] estão se mostrando promissoras em sistemas BCI [Xing et al. 2020]. No contexto de potenciais evocados visualmente em estado estacionário (*Steady State Visually Evoked Potential*, SSVEP), em que estímulos visuais oscilam em frequências pré-determinadas, as CNNs mostraram-se capazes de alcançar boa taxa de acurácia, mesmo reduzindo ou até suprimindo etapas de pré-processamento [Xing et al. 2020]. Esse desempenho se mantém quando (i) a janela de estimação – i.e. a quantidade de amostras dos sinais de EEG ao longo do tempo – é grande o suficiente para representar as informações (atualmente, com cerca de 2 ou 3 segundos) [Nam et al. 2018]; e (ii) os classificadores baseados em CNN são ajustados para um único usuário do sistema. Entretanto, neste trabalho, visamos aprimorar os sistemas BCI reduzindo o tamanho da janela de estimação para até 0,5 segundo, e criando um classificador que seja treinado para vários sujeitos. Em outras palavras, tem-se como objetivo um sistema BCI mais eficiente com menor tempo de resposta e que tende a tornar-se independente de períodos de calibração. Para isso, buscaremos explorar de forma mais efetiva o potencial das CNNs em relação ao processamento de imagens, transformando os sinais de EEG em gráficos de recorrência (*Recurrence Plot*, RP) [Eckmann et al. 1995].

2. Sistemas BCI Baseados em SSVEP

Os sistemas BCI são capazes de estabelecer uma comunicação direta entre o cérebro e dispositivos periféricos através da identificação de padrões cerebrais estáveis de indivíduos durante a execução de determinadas tarefas. Inicialmente, os sinais são adquiridos, amplificados e digitalizados; em seguida, são aplicadas técnicas de processamentos de sinais com objetivo de extrair a informação de interesse e mapeá-la a comandos predefinidos por meio de algoritmos de aprendizado de máquina. Dentre os principais paradigmas de BCI, destaca-se a abordagem SSVEP, baseadas no uso de sinais gerados por meio de estímulos visuais, cada qual associado a um comando específico, de forma que seja possível identificar variações da resposta do cérebro às propriedades de cada estímulo [Nam et al. 2018]. Os conjuntos de dados¹ utilizados neste trabalho correspondem a esse paradigma, envolvendo 4 frequências de estímulo (10, 11, 12 e 13 Hz) e uma frequência de descanso (0 Hz), extraídos, utilizando uma touca de eletrodos secos com 16 canais seguindo o padrão 10-20, de 5 voluntários saudáveis, com uma média de $26,3 \pm 3,3$ anos, a uma taxa de amostragem de 256 Hz. O intervalo de aquisição para cada estímulo foi de 12 segundos, repetindo o procedimento 8 vezes com intervalos de descanso. Neste contexto, um sistema de aprendizado de máquina é construído para classificar os sinais de acordo com sua frequência de estímulo, correspondente a um comando de controle do sistema BCI. É necessário que o sistema seja capaz de processar os sinais de diversos usuários, de modo que neste trabalho treinamos um classificador reunindo no conjunto de treinamento e validação os dados dos 5 voluntários.

2.1. Classificador: Redes Neurais Convolucionais

Redes Neurais Convolucionais [Goodfellow et al. 2016] são uma classe de Redes Neurais Artificiais (RNAs) particularmente adequadas para o processamento de tensores n -dimensionais, sendo mais eficiente computacionalmente que RNAs convencionais e possuindo propriedades pertinentes para a extração de atributos relevantes em dados com

¹Aprovado pelo Comitê de Ética da Universidade de Campinas (CAAE 58592916.9.1001.5404)

estrutura espacial, como imagens. Seu diferencial está na presença de uma ou mais camadas convolucionais, cuja estrutura tipicamente envolve a operação de convolução, seguido de uma operação de *pooling* para síntese dos dados (e.g. média local), e uma função de ativação. A operação de convolução consiste na aplicação de um filtro K , denominado *Kernel*, um tensor de dimensões significativamente reduzidas, ao longo de um tensor de entrada. As entradas do kernel K são pesos ajustáveis por aprendizado de tal modo que a camada convolucional consiga representar informações relevantes dos dados de entrada. Tais representações são chamadas de “mapas de atributo” e, em problemas de classificação, os mapas de atributos são convertidos em entradas para um classificador e o ajuste dos pesos se dá pelo método de Gradiente Descendente sobre uma função custo. Neste trabalho, o classificador do sistema BCI será uma CNN chamada Rede Convolucional Residual (ResNet) [Goodfellow et al. 2016]. No entanto, antes de realizar seu treinamento, transformou-se os sinais de EEG em gráficos de recorrência.

3. Imageamento dos Sinais de EEG: Gráficos de Recorrência

O Gráfico de Recorrência é uma ferramenta gráfica utilizada tipicamente para inspecionar propriedades de sistemas dinâmicos [Eckmann et al. 1995]. Dada uma série temporal $x(1), \dots, x(n)$, e considerando $i \in \{1, \dots, n - d + 1\}$, escolhemos um valor d a fim de construir uma órbita d -dimensional $y(i)$ dada por

$$y(i) = (x(i), x(i + 1), \dots, x(i + d - 1)). \quad (1)$$

O gráfico é construído pelos pontos $R_{i,j} = \Theta(\varepsilon_i - \|y(i) - y(j)\|)$, onde $\Theta(\cdot)$ é a função de Heaviside, que assume valores 1 ou 0 se seu argumento é positivo ou não-positivo, respectivamente, e ε_i é um limiar. O limiar precisa ser escolhido de tal modo que um número razoável de pontos $y(j)$ esteja contido dentro do raio centrado em $y(i)$, portanto pode depender de i .

Para a conversão em imagens, a matriz de sinais dos 16 eletrodos foi primeiramente pré-processada pela técnica CCA (Canonical Correlation Analysis) [Nam et al. 2018], transformando-os de tal modo a aumentar a correlação com os sinais de estímulo (apenas duas harmônicas foram utilizada). Em seguida, obteve-se uma série única pela média dos 16 sinais, com a qual o gráfico RP foi construído.

4. Resultados

Os gráficos de recorrência foram obtidos a partir do algoritmo disponibilizado pelo pacote PyTs [Faouzi and Janati 2020], sendo todos os RP reunidos para formar um único *dataset*. Para a classificação das imagens utilizou-se o modelo ResNet50 pré-treinado no dataset ImageNet e disponibilizada pelo pacote PyTorch.

Para o treinamento, o sinal original foi segmentado considerando diferentes janelas (sem sobreposição): $L = 128$ (0.5 segundos), 256 (1 s), 512 (2 s), 768 (3 s), 1024 (4 s) e 1280 (5 s). As taxas de acerto obtidas por Validação Cruzada 5-Fold e 20 épocas para cada fold (F) são dadas na Tabela 1.

Os resultados apresentados apontam a possibilidade de realizar a classificação de sinais SSVEP utilizando CNNs e sinais transformados em imagens pela técnica de

Sem imageamento						
Intervalo	F 1	F 2	F 3	F 4	F 5	Média
0.5s	0.34	0.26	0.27	0.27	0.57	0.34
1s	0.97	0.96	0.96	0.97	0.87	0.95
2s	0.93	0.93	0.96	0.93	0.91	0.93
3s	0.96	0.96	0.98	0.96	0.94	0.96
4s	0.81	0.81	0.80	0.85	0.81	0.82
5s	0.70	0.72	0.71	0.72	0.68	0.71
Com imageamento						
Intervalo	F 1	F 2	F 3	F 4	F 5	Mean
0.5s	0.96	0.96	0.96	0.97	0.96	0.96
1s	0.98	0.96	0.95	0.94	0.96	0.96
2s	0.94	0.97	0.96	0.96	0.97	0.96
3s	0.33	0.29	0.32	0.31	0.34	0.32
4s	0.52	0.56	0.50	0.57	0.52	0.53
5s	0.28	0.30	0.26	0.26	0.31	0.28

Tabela 1. Acurácias das validações obtidas com a ResNet50.

Gráficos de Recorrência. Para 0,5, 1,0 e 2,0 segundos, a técnica de imageamento RP demonstrou uma capacidade notável e consistente de extrair informações relevantes dos sinais de EEG, resultando em taxas de classificação em um contexto multiusuário superiores às obtidas por técnicas de classificação convencionais.

Tendo em vista que um problema relevante em BCIs consiste em diminuir o intervalo de aquisição necessário para se obter informação suficiente para uma classificação robusta, o potencial da abordagem considerada neste trabalho é acentuada pelo desempenho de classificação com intervalos de 0,5 s, atingindo uma acurácia média de validação de 96% utilizando imageamento RP, superando a taxa obtida sem imageamento.

5. Conclusão

Neste trabalho, propusemos a transformação dos sinais de EEG em gráficos de recorrência para sua posterior classificação por CNNs. A abordagem permitiu o desenvolvimento de um sistema BCI-SSVEP robusto, capaz de alcançar 96% de taxa de acurácia para janelas de estimação de até 0,5 segundos, considerando um usuário genérico. Superando, portanto, outras estratégias que fazem o processamento direto dos sinais de EEG.

Referências

- Eckmann, J., Kamphorst, S. O., Ruelle, D., et al. (1995). Recurrence plots of dynamical systems. *World Scientific Series on Nonlinear Science Series A*, 16:441–446.
- Faouzi, J. and Janati, H. (2020). pyts: A python package for time series classification. *Journal of Machine Learning Research*, 21(46):1–6.
- Goodfellow, I., Bengio, Y., Courville, A., and Bengio, Y. (2016). *Deep learning*, volume 1. MIT press Cambridge.
- Nam, C. S., Nijholt, A., and Lotte, F. (2018). *Brain–Computer Interfaces Handbook: Technological and Theoretical Advances*. CRC Press.
- Xing, J., Qiu, S., Ma, X., Wu, C., Li, J., Wang, S., and He, H. (2020). A CNN-Based Comparing Network for the Detection of Steady-State Visual Evoked Potential Responses. *Neurocomputing*.