

Estudo Preliminar do Uso de Meta-heurísticas para Seleção de Canais em Sistemas BCI-SSVEP*

Raquel Queiroz¹, Denis G. Fantinato¹

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

{`raquel.queiroz, denis.fantinato`}@ufabc.edu.br

Abstract. *Classification of electroencephalography (EEG) signals is a crucial problem in Brain-Computer Interfaces (BCI) systems. The EEG signals can be seen as a set of temporal series, being the use of Recurrent Neural Networks (RNNs) interesting for their processing, particularly the Long Short-Term Memory (LSTM) network. In this work, we propose the use of a LSTM classifier along with the Genetic Algorithm (GA) or the Clonal Selection Algorithm (CSA) for selection of electrodes in a set of artificial EEG data.*

Resumo. *A classificação dos sinais eletroencefalográficos (EEG) é um problema fundamental nos sistemas de Interface Cérebro-Computador (BCI). Os sinais de EEG podem ser vistos como um conjunto de séries temporais, sendo interessante o uso das Redes Neurais Recorrentes (RNNs) para seu processamento, em particular a rede LSTM (Long Short-Term Memory). Neste artigo é proposto uma estrutura de classificação baseada em LSTM utilizando o Algoritmo Genético (GA) e o Algoritmo de Seleção Clonal (CSA) para realizar a seleção do número de canais em um conjunto de dados de EEG artificiais.*

1. Introdução

Um sistema de Interface Cérebro-Computador (BCI, do inglês *Brain-Computer Interface*) é um sistema capaz de traduzir padrões de ativações cerebrais e ativar comandos no mundo exterior [Bablani et al. 2019]. Esse sistema inicialmente faz a aquisição do sinal cerebral, geralmente sinais de eletroencefalogramas (EEG), uma técnica não invasiva e de custo relativamente baixo, porém apresenta baixa resolução espacial e um alto nível de ruído, o que torna difícil extrair informações úteis [Nam et al. 2018]. Após a captura, as informações são processadas nas etapas de pré-processamento, extração e seleção de atributos e, por fim, a classificação, cujo resultado é utilizado para acionar comandos de controle em dispositivos protéticos, cadeiras de rodas ou computadores.

Dentre os algoritmos de classificação, as Redes Neurais Artificiais (ANNs, do inglês *Artificial Neural Networks*) são inspiradas em sistemas neurais biológicos com recursos como computação paralela, não linearidade, adaptabilidade, capacidade de resposta e tolerância a falhas [Goodfellow et al. 2016]. Uma classe de ANN que merece destaque é a Rede Neural Recorrente (RNN, do inglês *Recurrent Neural Networks*). Particularmente, destacando a rede *Long Short-Term Memory* (LSTM) foi criada para ser

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

capaz de processar informações de curto e longo prazo. Por tratar os dados de entrada como séries temporais, torna-se uma ferramenta promissora para o tratamento de sinais de EEG. Em um sistema BCI, a etapa de classificação pode ser auxiliada pela etapa de seleção de canais (dos eletrodos), usando apenas aqueles mais relevantes para a tarefa [Nam et al. 2018]. Apesar de contar apenas com algumas dezenas de eletrodos, as combinações possíveis para seleção geram um espaço de busca consideravelmente grande, muitas vezes inviabilizando a busca exaustiva. Assim, será analisado neste trabalho o uso de duas meta-heurísticas para esta busca: o Algoritmo Genético (GA, do inglês *Genetic Algorithm*) e o Algoritmo de Seleção Clonal (CSA, do inglês *Clonal Selection Algorithm*). Serão considerados dados artificiais de EEG para a análise do sistema BCI.

2. As Interfaces Cérebro-Computador

Em um sistema BCI, existe uma ampla gama de técnicas comumente empregadas em cada uma das etapas, e a escolha do conjunto de técnicas a ser adotado depende do paradigma escolhido [Nam et al. 2018]. Neste trabalho, será dado foco ao paradigma de BCI baseado em Potencial Evocado Visual em Regime Estacionário (SSVEP, do inglês *Steady-State Visual Evoked Potential*), em que utilizam-se estímulos visuais que oscilam em frequências específicas. Nesse caso, métodos seletores de bandas e de análise espectral (Transformada de Fourier, de Welch e Wavelet) [Nam et al. 2018] podem ser utilizados. No entanto, recentes métodos de aprendizado profundo (DL, do inglês *Deep Learning*) aplicados a BCI demonstraram altas taxas de acurácia, mesmo sem as etapas de pré-processamento e extração de atributos [Nam et al. 2018]. Assim, neste trabalho, será gerado dados artificiais de EEG e analisado um sistema BCI composto apenas da etapa de seleção de canais (usando meta-heurísticas) e da etapa de classificação (com a LSTM).

2.1. Conjunto de Dados baseados em Potencial Evocado

Em SSVEP, o estímulo visual gera a resposta nos sinais de EEG com conteúdo em mesma frequência do estímulo. Assim, uma maneira de gerar artificialmente os dados de sinais EEG-SSVEP é combinar senóides na frequência de estímulo a ruídos inerentes do processo. Neste trabalho, os sinais dos eletrodos foram gerados como:

$$s_i(n) = \cos(2\pi f_j t n / T) + \eta(i), \quad (1)$$

em que $i = \{1, \dots, 16\}$ é o índice do eletrodo, f_j é a frequência de estímulo, aqui podendo ser 10, 15, 20 e 25 Hz, $n = \{0, \dots, 255\}$ e período $T = 256$ Hz. Foram geradas 200 instâncias para cada frequência de estímulo. Também foi inserido ruído branco gaussiano η , com média nula e variância igual a i . Assim, à medida que se aumentam os índices do canal, mais ruído é adicionado. Ressaltando que esse tipo de ruído não acontece na prática, sendo portanto utilizados para um estudo teórico da seleção de canais pelas meta-heurísticas, em que, espera-se que seja capaz de selecionar os canais com menor índice.

2.2. Seleção de Canais Usando Meta-heurísticas

Os GAs são uma técnica de busca probabilística global inspirada na evolução darwiniana e visam encontrar soluções ótimas por meio da simulação de um processo evolutivo natural. Os operadores genéticos como *crossover* (feita por *Single Point*), mutação (aqui, *Bit Flip*) e seleção (feita por torneio) são usados para manter a diversidade genética, que é necessária para o processo de evolução [Bouktif et al. 2020]. Já o CSA é um modelo

inspirado na teoria de seleção clonal (baseado no sistema imunológico). Seu princípio de funcionamento usa a resposta imune no corpo chamada de anticorpo, que é induzida quando uma substância estranha chamada antígeno é detectada. Consiste em quatro componentes que são seleção (feita por elitismo), expansão clonal, hipermutação e re-seleção [Pang et al. 2015]. O CSA possui similaridade com o GA, porém pode alcançar um conjunto diversificado de soluções ótimas locais, enquanto todas as soluções candidatas no GA convergem para a melhor solução encontrada.

No contexto de BCI, o GA e o CSA deverão encontrar quais canais de eletrodos são mais úteis para o treinamento da rede neural LSTM, em termos de maior taxa de acerto, ou seja, em canais cujo *fitness* (acurácia do modelo) sejam mais altos. Para ambas as meta-heurísticas, uma solução candidata é um vetor com 16 bits, cada um associado a um eletrodo. Um bit 1 na i -ésima posição indica que o sinal do eletrodo i será usado na classificação.

2.3. Classificador Baseado em Redes Neurais Recorrentes

Os sinais dos eletrodos selecionados são então submetidos ao classificador, que é uma rede LSTM. Esta rede possui estrutura fixa, sendo 3 camadas LSTM e uma camada densa, conforme apresentado na Tab. 1, sendo b o *batchsize*, igual a 402.

Camada (tipo)	Dim. Saída	N. Parâmetros
LSTM	$(b, 256, 10)$	1080
LSTM	$(b, 256, 5)$	320
LSTM	$(b, 3)$	108
Dense	$(b, 4)$	20

Tabela 1. Estrutura do classificador baseado em LSTM

A saída da camada *Dense* (com função de ativação *softmax*) tem dimensão 4, cada uma correspondendo a uma determinada classe (frequências do estímulo).

3. Resultados

Baseado no conjunto de dados baseados em Potencial Evocado, para cada experimento foram criadas amostras a partir de 16 canais e 4 rótulos de frequência em [10, 15, 20, 25] Hz. Foram utilizadas 600 amostras – organizadas como $(600, 256, 16)$, onde são (amostras, experimentos, eletrodos) –, das quais 402 amostras foram para o treino do modelo e 198 para teste. O modelo treinado com todos os canais sem nenhuma meta-heurística aplicada obteve uma acurácia média de 26.8%, com o desvio padrão de 1.5% para 30 repetições, em que cada repetição foi considerado o modelo com maior precisão dentre 4 modelos treinados.

Utilizando a meta-heurística de GA, foi executado para um total de 100 gerações, a quantidade 60 indivíduos e o percentual de mutação em 10%. A Fig. 1a exibe a precisão ao longo das geração usando o GA. A melhor precisão ocorreu primeiramente na geração 46 com 96.5% utilizando os canais [0, 1, 2, 4, 5, 6], sendo encontrada novamente a partir da geração 95.

Em contrapartida com o CSA, Fig. 1b, utilizando a geração de amostras com os mesmos parâmetros anteriormente descritos, o experimento com a maior precisão foi de

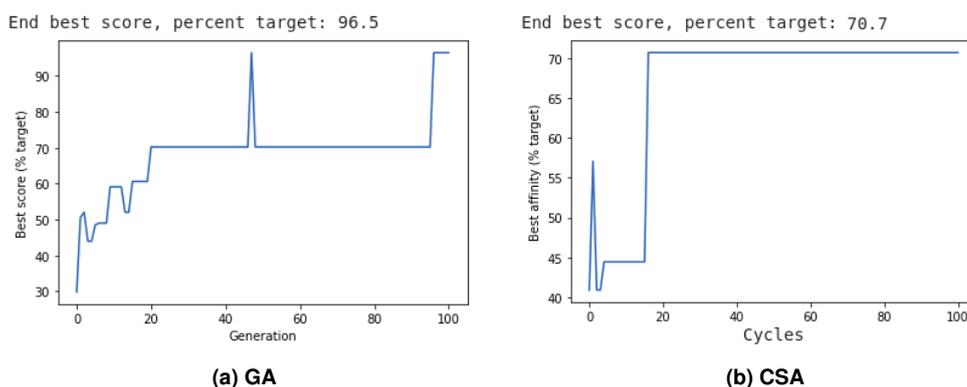


Figura 1. Taxa de acerto ao longo das gerações usando (a) GA e (b) CSA.

70.7% na iteração 15. Os canais desta solução foram [4,12,13,14] e o desvio padrão do modelo treinado com estes canais e com 30 repetições foi de 2.8%.

4. Conclusão

Neste trabalho foi proposto o uso de meta-heurísticas para classificar sinais de EEG artificiais (baseados em Potenciais Evocados) e, como mostrado na seção de resultados, tanto o GA quanto o CSA conseguiram encontrar soluções com baixa complexidade estrutural e melhor precisão no treino de LSTMs.

A partir dos experimentos, é possível observar que os canais a serem escolhidos pelo GA são os primeiros canais, que revela uma escolha coerente com os sinais gerados artificialmente. Assim, o GA tende a remover canais cujo a quantidade de ruído seja mais elevada. Em alternativa, os experimentos com o algoritmo CSA obtiveram uma precisão menor do que com o GA, selecionando os canais 4, 12, 13 e 14. Muito provavelmente, isto decorre do fato do algoritmo de seleção clonal alcançar um conjunto mais diversificado de soluções ótimas locais, enquanto todas as soluções candidatas no GA convergem para a melhor solução encontrada. Posteriormente, a intenção seria evoluir o estudo aplicando as meta-heurísticas em sinais de EEG reais baseados em SSVEP.

Referências

- Bablani, A., Edla, D., Tripathi, D., and Cheruku, R. (2019). Survey on brain-computer interface: An emerging computational intelligence paradigm. *ACM Computing Surveys*, 52(1):1–32.
- Bouktif, S., Fiaz, A., Ouni, A., and Serhani, M. A. (2020). Multi-sequence lstm-rnn deep learning and metaheuristics for electric load forecasting. *Energies*, 13(2):391.
- 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.
- Pang, W., Wang, K., Wang, Y., Ou, G., Li, H., and Huang, L. (2015). Clonal selection algorithm for solving permutation optimisation problems: a case study of travelling salesman problem. In *International Conference on Logistics Engineering, Management and Computer Science (LEMCS 2015)*, pages 575–580. Atlantis Press.