

Análise de Classificadores para Interfaces Cérebro-Computador baseadas em Imaginação de Movimento

Palavras-chave: Interface cérebro-computador, Aprendizado de máquina, Classificação de Padrões

Aluno: Caio Eduardo Ferraz da Silva

Orientador: Prof. Levy Bocato
Faculdade de Engenharia Elétrica (FEEC)

1. Introdução

Uma interface cérebro-computador (BCI, do inglês *brain-computer interface*) é um dispositivo que promove a comunicação de intenções de um usuário por vias biológicas não-usuais [1]. Em essência, a partir de registros da atividade cerebral, uma BCI tenta identificar o comando desejado pelo usuário. Para isso, os sinais cerebrais tipicamente passam por algumas etapas de processamento que visam remover artefatos indesejados e extrair atributos representativos, os quais servem de entrada para o sistema classificador, responsável por decidir qual o comando correto.

Em vista disso, este trabalho se propõe a analisar e avaliar o desempenho de classificadores, tanto lineares quanto não-lineares, no contexto de uma interface cérebro-computador baseada no paradigma de imaginação de movimento (MI, do inglês *motor imagery*) [2].

Dentre as técnicas de classificação, foram exploradas a regressão logística, a máquina de vetores-suporte (SVM) e as clássicas redes neurais do tipo *perceptron* de múltiplas camadas (MLP, do inglês *multilayer perceptron*) [3].

A construção de uma interface cérebro-computador completa baseada em MI, considerando cada um dos três classificadores escolhidos, foi feita utilizando a programação em Python. Os dados utilizados foram fornecidos pelo grupo de pesquisa ligado ao DSPCom (Laboratório de Processamento de Sinais para Comunicações) (CAAE 0617.0.146.000-10). No caso, os dados referem-se a registros de EEG (eletroencefalografia) captados por 16 eletrodos durante a imaginação de movimento das mãos esquerda e direita.

Tais dados foram tratados passando por um filtro CAR e, em seguida, tiveram seus atributos extraídos para que pudessem ser utilizados no treinamento dos classificadores. Por

fim, os modelos de classificação foram analisados e comparados.

2. Fundamentação Teórica

2.1 Interface Cérebro-Computador (BCI)

Uma interface cérebro-computador é um dispositivo que possibilita a comunicação entre um usuário e o ambiente externo por vias biológicas não-convencionais (não-musculares) [1,4]. Tipicamente, para a construção de uma BCI é necessário definir alguns aspectos, tais como: a forma de coleta dos sinais cerebrais, o paradigma explorado, as metodologias utilizadas para pré-processamento dos sinais, a técnica de extração de características e, finalmente, a estratégia de classificação.

Os paradigmas mais utilizado em BCIs são os baseados em potenciais visualmente evocados (SSVEP, do inglês *steady-state visually evoked potentials*), em potencial relacionado a evento - conhecido como P300 - e em imaginação de movimento [4].

2.1.1 Imaginação de Movimento

O paradigma de imaginação de movimento não requer a estimulação externa do usuário (por isso, é do tipo endógeno), mas sim que o usuário de forma autônoma e intencional imagine a realização de determinados movimentos (e.g. abrir e fechar as mãos direita e esquerda). Esse processo dá origem a uma atividade mensurável em determinadas bandas de frequência, especialmente nos eletrodos localizados na região do córtex motor [5].

2.1.2 Processamento de Sinais

É necessário que o sinal capturado por meio de eletroencefalografia (EEG) passe por três etapas antes de chegar à classificação, independente do paradigma adotado. A Figura 1 exibe um esquema geral de uma BCI.

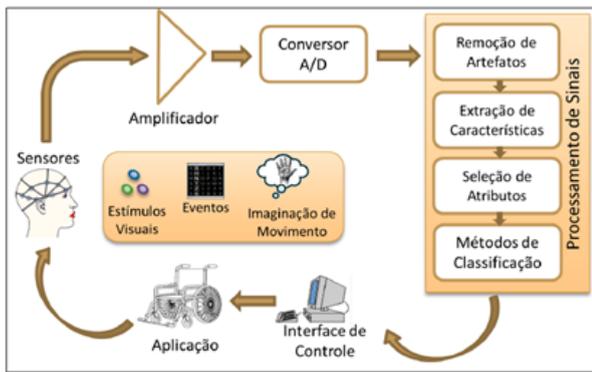


Figura 1: Esquema Geral de uma BCI. Baseada em [4].

Na primeira etapa, o sinal é filtrado temporal e espacialmente de modo que se removam ruídos, artefatos e interferências. Usualmente, o pré-processamento envolve filtragem para cancelamento de atividade em 60 Hz, filtragem passa-banda e filtragem espacial [4,6].

2.1.3 Filtro por Referência Média Comum (CAR)

Dentre as várias formas de filtragem espacial (uma forma de reduzir a presença de elementos indesejáveis na base de dados), uma das mais utilizadas no pré-processamento é o Filtro por Referência Média Comum (CAR, do inglês *common average reference*). Neste caso, o valor médio entre todos os sinais coletados é subtraído de cada um dos canais, podendo ser expresso como a seguir [7]:

$$V_i^{CAR} = V_i - \frac{1}{n} \sum_{k=1}^n V_k, \quad (1)$$

onde n denota o número de eletrodos e V_i representa o potencial originalmente registrado no i -ésimo eletrodo.

2.1.4 Extração de Características

Na etapa de extração de características, os sinais já pré-processados são traduzidos para um domínio em que seja mais factível reconhecer os padrões subjacentes. No caso de imaginação de movimento tipicamente se realiza a transformação do sinal para o domínio da frequência, dando preferência à análise do conteúdo espectral nas faixas de frequência associadas à atividade motora [8].

2.1 Classificadores

Por fim, o conjunto de atributos é fornecido a um classificador, o qual é responsável por identificar o comando desejado pelo usuário.

Em muitos casos, opta-se pelo uso de classificadores lineares por sua tratabilidade matemática e relativa robustez. No entanto, existe espaço para buscar um melhor desempenho lançando mão de estruturas não-lineares.

Este trabalho se propõe a analisar alguns modelos de classificação, tanto lineares quanto não-lineares, cujas entradas estão divididas em duas classes (classificação binária). Nas subseções a seguir, apresentamos uma descrição resumida dos classificadores estudados no projeto.

2.2.1 Regressão Logística

A regressão logística (LR, do inglês *logistic regression*) é uma abordagem de classificação que tenta promover a separação dos padrões a partir de fronteiras de decisão lineares. A saída do modelo é obtida a partir de um mapeamento não-linear, conforme mostra a Equação (2) [9], e indica a probabilidade de o padrão de entrada pertencer à classe positiva:

$$\hat{y}(x) = \frac{1}{1 + e^{-w^T x}}, \quad (2)$$

onde w contém os coeficientes do modelo e x é o vetor com os atributos do padrão de entrada.

Durante o treinamento, os parâmetros da LR são ajustados visando minimizar a entropia cruzada entre as probabilidades estimadas (vide Equação (2)) e as probabilidades verdadeiras para cada classe. Para isso, são empregados algoritmos baseados em derivadas da função custo, sendo que o problema de otimização envolvido tem caráter convexo [3].

2.2.2 Máquina de Vetores-Suporte

As máquinas de vetores-suporte (SVMs, do inglês *support-vector machines*) são modelos de classificação que se apoiam na teoria de aprendizado estatístico [10] visando alcançar uma melhor generalização ao formalmente explorarem a noção de maximização da margem.

A ideia central em SVM é a busca pelo hiperplano que separe os padrões das duas classes corretamente e que deixe a maior separação entre estas classes. O poder de classificação da SVM é significativamente ampliado através: (1) do uso de funções *kernel* para calcular os produtos internos em um espaço de características implícito, no qual os dados, em teoria, seriam mais facilmente separáveis; e (2) da incorporação de variáveis de relaxação, a fim de permitir violações da condição de separabilidade linear.

2.2.1 Perceptron de Múltiplas Camadas

Dentro da classe de redes FNNs (do inglês *feedforward neural networks*), que engloba as arquiteturas cujos sinais recebidos são propagados em um único sentido até a saída, a rede *perceptron* de múltiplas camadas (MLP, do inglês *multilayer perceptron*) constitui uma solução paradigmática.

A MLP possui múltiplas camadas de processamento, devendo haver ao menos uma camada intermediária entre a entrada e a saída. Além disso, como todos os neurônios de uma camada estão conectados a todos os neurônios da camada seguinte, essa estrutura também é chamada de totalmente conectada (ou densa).

A camada de entrada representa a passagem dos atributos à rede, as camadas intermediárias realizam mapeamentos não-lineares que explicitam a informação subjacente aos dados do ponto de vista da tarefa que se deseja realizar e os neurônios da camada de saída combinam a informação que lhes é oferecida, produzindo as respostas da rede para aquele padrão de entrada. A arquitetura geral de uma MLP pode ser observada na Figura 2 abaixo.

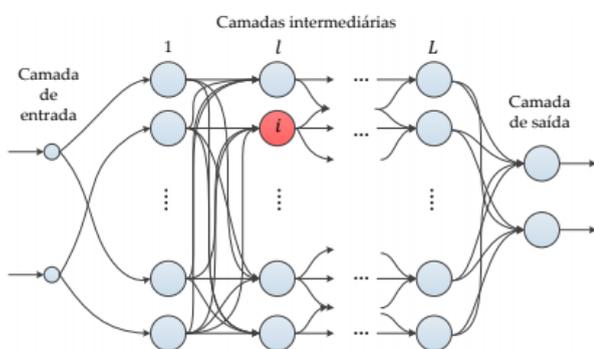


Figura 2: Arquitetura geral de uma rede MLP. Extraída de [11].

Uma característica interessante que as MLPs possuem é sua capacidade de aproximação universal, ou seja, elas são capazes de aproximar qualquer mapeamento definido em um espaço compacto com um nível de erro extremamente pequeno [12].

3. Resultados e Discussão

3.1 Implementação

O primeiro passo para implementar as BCIs foi o pré-processamento dos dados brutos. No caso, os dados referem-se a registros de EEG (eletroencefalografia) utilizando o paradigma de imaginação de movimentos das mãos esquerda e direita.

3.1.1 Pré-processamento dos Dados

Primeiramente, todos os dados passaram por um filtro CAR a fim de reduzir elementos indesejáveis. Em seguida, cada registro de 10 segundos de cada um dos 20 arquivos brutos, em cada um dos 16 eletrodos utilizados, foi dividido em 8 janelas de 3 segundos (0 a 3 s, 1 a 4 s,... e 8 a 10 s).

Em seguida, cada janela passou pela Transformada Rápida de Fourier (FFT), para que, por fim, a partir de cada janela no domínio da frequência fossem extraídos 3 atributos a partir da média de uma banda de frequências (8 a 12 Hz, 13 a 17 Hz e 18 a 22 Hz). Desse modo, obteve-se uma matriz de dados de tamanho 160 x 48 (dados x atributos).

3.1.1 Divisão em Treinamento/Teste

Em seguida, foi preciso dividir quais dados seriam utilizados para o teste e para o treinamento dos modelos. A primeira decisão foi que a escolha dos dados não poderia ser totalmente aleatória, pois, simulando uma situação real de uso da BCI, todos os dados de um *trial* (se referindo ao dado bruto) seriam utilizados. Desse modo, foi decidido que para o treinamento seria necessário utilizar pelo menos um *trial* referente a cada classe (mão esquerda e direita), para que a simetria de dados por classe também se mantivesse.

Tendo em vista a decisão anterior, optou-se por utilizar, então, 4 *trials* (2 de cada classe), ou seja, 20% dos dados para teste e os outros 80% para o treinamento. Além disso, visando uma maior confiabilidade na comparação e análise entre os classificadores, propôs-se utilizar os resultados de uma média de 10 treinamentos com 2 *trials* de cada classe escolhidos aleatoriamente. Desse modo, seria obtido a média dos resultados dos 3 classificadores para as mesmas 10 divisões.

3.1.3 BCIs

Com os dados pré-processados divididos corretamente entre treinamento e teste, a última etapa foi implementar 3 BCIs utilizando cada um dos classificadores diferentes. Os principais parâmetros de comparação entre os classificados são suas acurácias e matrizes de confusão. Todavia, eles apresentam particularidades em suas análises.

Além disso, para a LR, também foi calculada sua curva ROC e F1; para o SVM, no qual utiliza-se o *kernel* Gaussiano, analisamos qual a melhor combinação média de seus

parâmetros (C e gamma); e para a rede MLP, avaliamos sua sensibilidade em relação à quantidade de neurônios utilizados em sua camada intermediária.

3.2 Comparação entre Classificadores

Realizados os 10 experimentos com diferentes separações dos dados em treinamento e teste, foram obtidas as médias de suas acurácias (acc.) e de sua matriz de confusão com os dados de verdadeira mão direita (VD), falsa mão direita (FD), verdadeira mão esquerda (VE) e falsa mão esquerda (FE). Os valores de desempenho obtidos pelos classificadores são apresentados na Tabela 1.

Tabela 1: Resultados finais da média de 10 treinamentos.

Modelo de Clas.	Acc. (%)	VD (%)	FD (%)	VE (%)	FE (%)
LR	68,13	69,56	30,44	68,66	31,34
SVM	77,81	80,59	19,41	77,28	22,72
MLP	71,90	70,23	29,77	67,52	32,48

O primeiro ponto a ser destacado é que o classificador que apresenta a melhor acurácia é a SVM, seguido da rede MLP e, por último, a LR. A SVM também apresentou um melhor desempenho para cada um dos 4 dados da matriz de confusão.

Por outro lado, a relação de desempenho dos outros dois métodos foi diferente. Nesse caso, a rede MLP apresentou um pouco mais de VDs que a LR, enquanto a LR apresentou um pouco mais de VEs.

Outro ponto importante a ser observado, é que para os 3 modelos, há uma acurácia maior em relação à mão direita que à mão esquerda, sendo que a LR apresentou a menor variação de acurácia entre os modelos.

Com relação à sensibilidade paramétrica da SVM, apresentamos na Figura 3 os valores de acurácia média em função dos parâmetros C e gamma.

Analisando o mapeamento obtido (Figura 3), podemos observar que o modelo SVM passa a apresentar uma acurácia crescente à medida que o parâmetro C aumenta. Em contrapartida, a acurácia decresce conforme o parâmetro gamma cresce. Ao final, foi feita uma varredura pelo mapeamento e identificamos que o melhor

conjunto (C; gamma) para esse modelo é (0,776; 0.036).

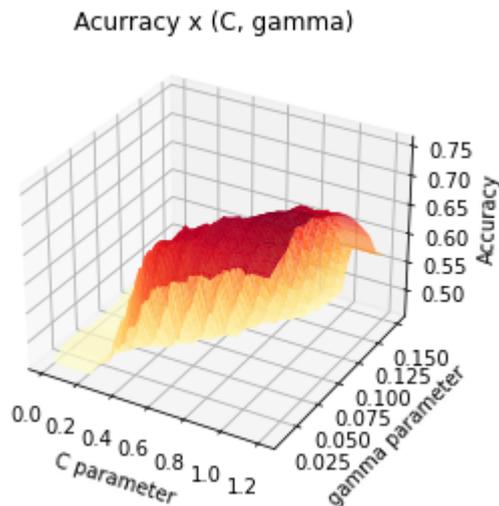


Figura 3: Mapeamento de parâmetros C e gamma para o modelo SVM.

A rede MLP também teve seu desempenho monitorado em função de um importante hiperparâmetro, a saber, o número de neurônios na camada intermediária. A Figura 4 exibe a acurácia média obtida para diferentes tamanhos da rede.

Analisando o gráfico da Figura 4, é possível observar grandes flutuações da acurácia do modelo conforme o número de neurônios da camada intermediária cresce. Por exemplo, vemos alguns picos de acurácia média em diferentes intervalos do parâmetro. Ao final, por meio de uma varredura detalhada, identificamos que a rede MLP alcançou o melhor desempenho quando 9 neurônios foram utilizados em sua camada intermediária.

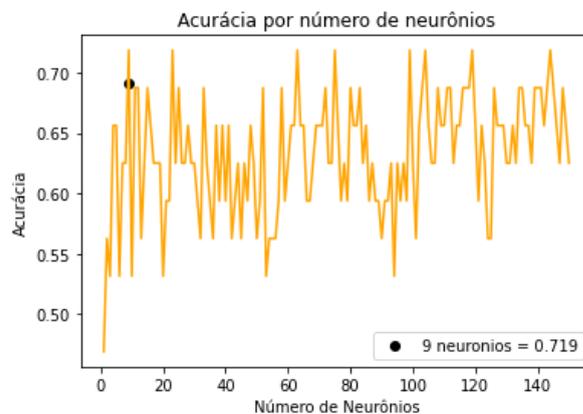


Figura 4: Acurácia em função do número de neurônios para o modelo MLP.

4. Conclusões

A tecnologia de BCI tem evoluído muito nas últimas décadas, sendo, hoje, a área de medicina assistiva a que mais a utiliza. Dentre as diversas pesquisas, existem algumas envolvendo digitação controlada (conseguindo, hoje, chegar a 90 palavras por minuto) e o movimento de um mouse, movimentação de prótese e cadeiras de rodas. Estas perspectivas têm o potencial de ajudar inúmeros pacientes com alguma debilidade motora e, com certeza, a área pode ainda evoluir bastante.

Tendo esse contexto em vista, fica evidente a importância de se saber qual classificador apresenta um melhor desempenho no contexto de BCI. Em particular, neste trabalho, foi considerado o paradigma de imaginação de movimento e um conjunto de três classificadores candidatos: LR, SVM e MLP. Desse modo, a partir desse estudo e utilizando o banco de dados, mesmo que limitado, foi possível constatar que para um problema de classificação binária entre mão esquerda e direita, o melhor classificador é a máquina de vetores-suporte, a qual alcançou uma acurácia média de 77,81%, com uma variação de pouco mais de 3% entre os acerto para a mão direita em relação à mão esquerda. Os demais modelos (MLP e LR) alcançaram os valores de 71,9% e 68,13% de acurácia, respectivamente.

Ainda há um longo caminho de evolução da tecnologia, principalmente com relação à captação das ondas cerebrais, que apresentam muitos ruídos e artefatos. Porém, à medida que as pesquisas superarem tais dificuldades, as BCIs podem ser aplicadas de diversas formas, como no entretenimento, em realidades virtuais e video games.

Tendo em vista os diversos avanços na área, a realização deste trabalho introduziu e colocou o aluno em contato com o cenário atual de BCIs e também de aprendizado de máquina, com foco no problema de classificação, dando, assim, subsídios teóricos e práticos para sua atuação futura nesta empolgante área.

5. Bibliografia

- [1] WOLPAW J. R.; BIRBAUMER N.; MCFARLAND D. J.; PFURTSCHELLER G.; VAUGHAN T. M. **Brain-computer interfaces for communication and control**. Clinical Neuro-physiology, 2002.
- [2] AGGARWAL S.; CHUGH N. **Signal processing techniques for motor imagery brain computer interface: A review**. Array, 2019.
- [3] GÉRON A. **Hands-On Machine Learning with Scikit-Learn, Keras & TensorFlow**. O'Reilly Media, 2019.
- [4] LEITE S. N. C. **Análise de Técnicas de Processamento de Sinais Cerebrais e Contribuições no Âmbito do Desenvolvimento de Interfaces Cérebro-Computador Baseadas em Potenciais Evocados Visualmente em Regime Estacionário**. Tese de Doutorado, UNICAMP, 2016.
- [5] DORNHEGE G.; MILLÁN J. R.; HINTERBERGER T.; MCFARLAND D. J.; MÜLLER K. **Toward brain-computer interfacing**. 2007.
- [6] KACHENOURA A.; ALBERA L.; SENHADJI L.; COMON P. **ICA: a Potential Tool for BCI Systems**. Clinical Neurophysiology, 2007.
- [7] COSTA T. B. S. **Desenvolvimento de interface cérebro-computador baseada em potenciais evocados visualmente em regime estacionário**. 2015.
- [8] KERSANACH M. B.; URIBE L. F. S.; COSTA T. B. S.; ATTUX R. **Um wrapper para seleção de eletrodos em interfaces cérebro-computador baseadas em imaginação de movimento**. 2016.
- [9] DUDA R. O., STORK D. G.; HART P. E. **Pattern Classification**. 2000.
- [10] BISHOP C. M. **Pattern recognition and machine learning**. 2007.
- [11] BOCCATO L. **Novas Propostas e Aplicações de Redes Neurais com Estados de Eco**. PhD thesis, Faculdade de Engenharia Elétrica e de Computação (FEEC) – Universidade Estadual de Campinas (UNICAMP), 2013.
- [12] CYBENKO G. **Approximation by Superpositions of a Sigmoidal Function**, 1989.