

Identificação de Intenção de movimento por meio de Eletroencefalografia (EEG)

Leonardo Rodrigues*, Samuel Lourenço Nogueira⁺

Resumo—Este artigo apresenta os estudos realizados afim de utilizar os sinais provenientes do córtex motor, lidos por meio de eletroencefalografia (EEG), para classificar tipos de intenção de movimento de um usuário com o intuito de auxiliar na reabilitação e recuperação de movimento em pacientes que perderam funções neuromotoras. Analisa-se a realização de três tipos de movimento principais: Fechamento do punho, Levante do pé e Piscar de olhos. Para isto foi utilizado um capacete de Eletroencefalografia não invasivo afim de monitorar a atividade cerebral eletromagnética. O EEG não invasivo é o meio mais conveniente para aplicações de Interface Cérebro-Computador, mas também o que contém mais ruídos quando comparado aos outros meios de obter sinais de atividade cerebral. Por causa dos ruídos, a utilização do método não invasivo exige precauções extras ao lidar com os sinais, como filtros e sistemas classificadores que eliminam artefatos indesejados. Neste estudo utiliza-se um dispositivo de baixíssimo custo, que frente à outros dispositivos mais caros se mostra funcional para o objetivo, porém apresenta uma série de problemas envolvendo a qualidade do sinal.

Entretanto, após tratar os sinais, notam-se diferenças expressivas no Eletroencefalograma durante a realização de movimento, mostrando a correlação entre o evento e a leitura, além disso percebem-se as diferenças no sinal para movimentos diferentes, o que permitiu a distinção entre os movimentos com auxílio de classificadores baseados em Inteligências Artificiais e outros métodos de classificação implementados computacionalmente.

Palavras Chaves—EEG, Eletroencefalografia, identificação de movimento, reabilitação, classificadores, Sistemas de Inferência Fuzzy, Redes Neurais, Inteligência Artificial, Classificação de atributos.

1 Introdução

Cada dia mais percebe-se a necessidade de identificar os sinais cerebrais e distingui-los afim de reconhecer a atividade do cérebro como um todo. Esta necessidade surge de várias maneiras, como a compreensão da função de cada neurônio - ou grupos de neurônios - quando se faz uma cirurgia invasiva para recuperação de movimento de um paciente; ou até para simplificar ações do dia a dia, como utilização de eletrônicos com ações controladas pela atividade cerebral. Ambos os exemplos já são realidade hoje e busca-se melhorar os métodos já existentes de captura, tratamento e classificação dos sinais afim de tornar possível tanto as cirurgias, como a simples integração com dispositivos do dia-a-dia.

Para medir esta atividade cerebral, uma opção é a Eletroencefalografia, que funciona a partir do seguinte princípio: existe uma variação nos potenciais elétricos no escâlpo devido ao fluxo de corrente nos neurônios e ao redor dos mesmos. A medição dessas variações de potencial elétrico é facilmente realizada utilizando-se de eletrodos passivos posicionados em contato elétrico com o escâlpo. Estes sistemas podem ser integrados com estruturas como capacetes ou toucas adaptáveis, permitindo a utilização por pessoas diferentes e permite que seja um método não invasivo, já que os eletrodos só precisam estar tocando a pele. [?]

Isto torna a Eletroencefalografia o método mais utilizado

para monitoramento e estudo da atividade cerebral, pois o usuário pode se mover livremente, não há necessidade de cirurgia, demanda pouca preparação e não apresenta risco algum ao paciente [?]. Porém este método apresenta limitações significativas: primeiramente, a falta de homogeneidade nos perfis de condutividade do próprio escâlpo significa que os potenciais elétricos são reduzidos em amplitude e sofrem distorção ao longo do escâlpo. Isso não seria problema caso estas distorções fossem conhecidas e pudessem ser tomadas em consideração, porém elas variam de pessoa para pessoa e podem ocasionar modificações da leitura no próprio crânio do mesmo paciente apenas alterando o posicionamento de um eletrodo.

Além disso, estudos anteriores mostram que o EEG é suscetível a artefatos (sinais indesejados) gerados por atividade elétrica por atrito dos eletrodos com a pele ou com cabelo e na própria contração muscular, que pode representar um empecilho significativo já que os movimentos da cabeça podem gerar estes artefatos [?]. Além disso, a própria atividade cerebral paralela, relacionada aos pensamentos do participante, leituras somatossensoriais (tato, olfato, audição..) e à atividade básica de todos os órgãos do corpo, geram sinais que podem ser confundidos com os de intenção de movimento [?].

Para compreender os sinais relacionados à intenção de movimento no cérebro, estuda-se primeiro as regiões principais relacionadas à ela. Segundo [?] e como pode se observar na Figura 1, o córtex motor se localiza na região externa do cérebro como uma faixa mediana ao lado do córtex somatossensorial.

Compreender este diagrama é importante para identifi-

- *Graduando:* *L. Pimenta do departamento de Engenharia Elétrica da Universidade Federal de São Carlos
E-mail: pimenta.lar@gmail.com
- *Orientador:* +S. Nogueira docente da Universidade Federal de São Carlos.

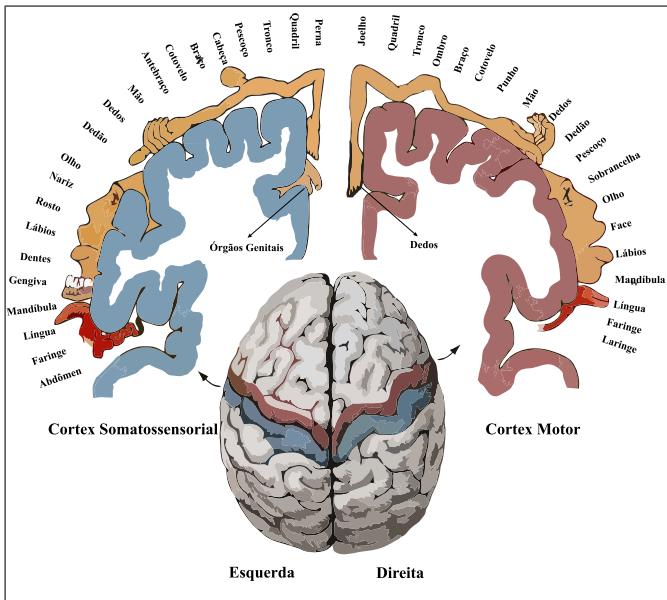


Figura 1: Homúnculos sensorial (hemisfério esquerdo) e motor. Fonte: [?]

car o posicionamento correto dos eletrodos e quais eletrodos devem estar mais ativos durante a intenção de movimento de cada membro. Ainda assim espera-se que haja intensa atividade em outros eletrodos devido ao perfil de propagação eletromagnética das ondas do cérebro, pois como há regiões do cérebro referentes a membros específicos mais internas, isto pode gerar um sinal eletromagnético em uma direção imprevisível, e acionar um eletrodo mais distante. Por exemplo o movimento do pé que, segundo a representação do Homúnculo motor, tem sua região correspondente em uma espécie de cavidade do cérebro e esta região pode gerar sinais eletromagnéticos mais intensos em lugares não necessariamente acima da sua região correspondente no escalp.

Outro parâmetro importante de estudo é o dos intervalos de frequência mais comuns no cérebro que estão relacionados à atividade cerebral, ou também chamados de tipos de oscilação neural. Os tipos de oscilação, conforme dito em [?], são seis:

- delta (0,5 a 4Hz) - Sempre presentes, porém mais intensos durante o sono.
- teta (4 a 8Hz) - Mais intensos no sono, mas comuns a todo tempo e relacionado a memória e aprendizado.
- alfa (8 a 13Hz) - Predominantes quando o indivíduo está acordado e relaxado, mais presentes na região do córtex visual.
- mu (8 a 13Hz) - Mesmo intervalo das ondas alfa, mas presentes no córtex motor e relacionadas ao movimento.
- beta (13 a 30Hz) - Relacionados aos estados de Alerta e à intenção de movimento.
- gamma (> 30Hz) - Relacionados ao processamento de informações no cérebro.

Neste estudo estudam-se as frequências de 8Hz a 30Hz por estarem mais relacionadas ao movimento.

A compreensão da fisiologia do cérebro permite um norteamento melhor dos procedimentos corretos a serem seguidos, quais filtros implementar e o que esperar dos

sinais. Mesmo assim, como o próprio comportamento do participante durante a coleta pode interferir nos resultados, é imprescindível que a coleta siga protocolos bem definidos para forçar o usuário a concentrar-se na atividade.

2 Aspectos Metodológicos

2.1 Descrição do experimento

O experimento foi realizado no próprio pesquisador, participante saudável de 23 anos, homem, destro, com visão e audição normais e sem histórico de disfunção neurológica ou doenças psiquiátricas. O teste foi realizado em uma sala fechada para prevenção de distrações, sem sons externos ou perturbações de tipo, conforme pode-se observar na Figura 2.

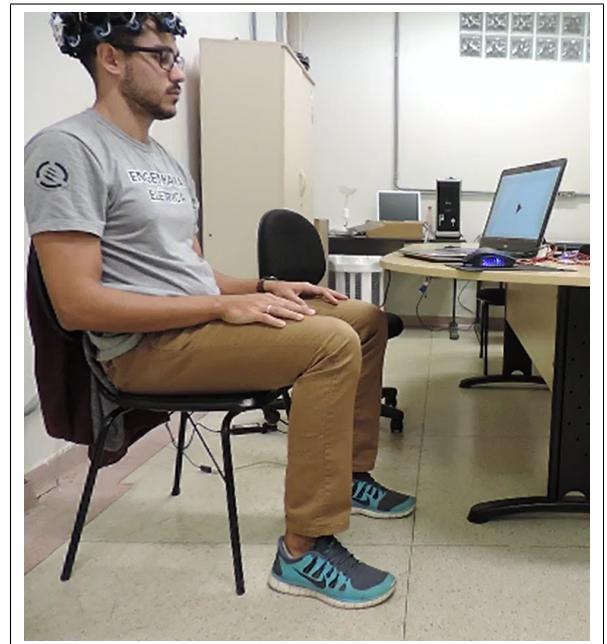


Figura 2: Participante recebendo instrução na tela durante uma captura

2.1.1 Dispositivo, transmissão e aquisição de dados

A configuração de posicionamento dos eletrodos no capacete foi escolhida de forma a abranger a maior parte possível do cérebro sem perder informações de intenção de movimento, conforme a Figura 3, afim de capturar toda a atividade de maneira mais generalizada para poder analisar possíveis fontes de ruído em cada eletrodo e discriminá-los de sinal desejado, como o piscar de olhos, que provoca sinais mais acentuados nos eletrodos posicionados à frente do córtex. Saber os eletrodos mais reativos é importante para durante as análises reconhecer se a perturbação se deve ao movimento realizado ou a algum artefato, ou uma movimentação diferente do participante.

Os dados eram enviados dos eletrodos para a placa OpenBCI [?] instalada no capacete e para a placa bluetooth do conjunto de hardware da OpenBCI [?] posicionada em uma porta USB do computador para receber os dados em tempo real. Foi necessário desenvolver um capacete para o posicionamento dos eletrodos conforme mostra a Figura

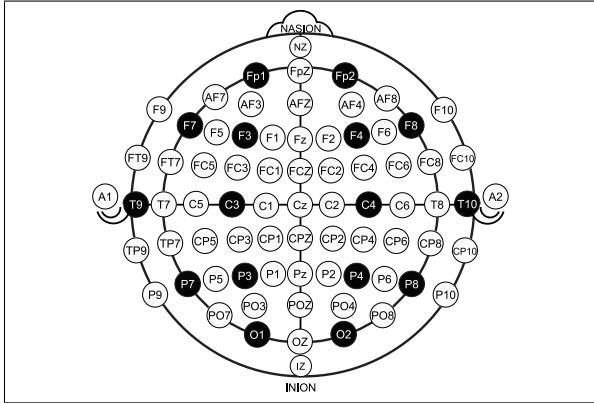


Figura 3: Sistema Internacional 10-20 com marcações dos eletrodos utilizados em preto

4, em que é possível também observar os eletrodos posicionados nos pontos escolhidos e com a placa da *OpenBCI* [?] instalada. Cada eletrodo tem uma rosca de encaixe no capacete e permite ajustes de altura e molas em cada eletrodo promovem maior conforto para o usuário.




Figura 4: Capacete de Eletroencefalografia construído pelo autor

Os dados eram recebidos no computador de maneira serial e enviados para o ambiente do Matlab [?] por intermédio de um software em Python e plotados. O sistema todo é carregado de interfaces, porém reagia muito melhor do que enviar os sinais seriais direto para o Matlab, e o objetivo do envio em tempo real era apenas visualização da qualidade do sinal ou desligamento do Hardware. Portanto, o sinal era armazenado, o que será chamado de "Ambiente de Armazenamento", e amostrados para o pesquisador no chamado "Feedback Visual", conforme na Figura 5.

O código de armazenamento dos dados, por outro lado, independia da gravação ser efetivamente em tempo real, pois este código, desenvolvido no Matlab, recebe os dados e grava em uma variável do ambiente. Quando se inicia a gravação dos dados, iniciam-se também as instruções para o

participante, que fazem parte do mesmo código, e assim que é gerada a imagem de instrução é sinalizado um gatilho, para posteriormente saber o instante em que a instrução foi enviada para o participante e identificar no Eletroencefalograma as mudanças ocorridas no período.

De fato não é possível saber com certeza se o gatilho é gerado no mesmo instante que a imagem aparece para o usuário, mas sabe-se com certeza que o participante só realiza a ação depois de visualizar a imagem e isto já garante encontrar o sinal visualmente, ou criar uma janela de análise. Portanto, para a validação deste sistema analisaram-se os sinais de intenção de movimento e os instantes do gatilho. Outra ferramenta para validação do instante do movimento é uma câmera gravando as coletas. Nos vídeos gravados é possível ter certeza de que o participante realizou o movimento correto após a aparição da instrução na tela, e ter uma ideia do tempo, em segundos, entre as realizações do movimento.

2.1.2 Procedimentos durante a coleta

A coleta se inicia com o participante posicionado em frente à tela do computador sentado e com o capacete já ajustado e ligado. Em uma segunda tela outra pessoa verifica a atividade cerebral sendo enviada em tempo real e avalia se o sinal está de acordo com o esperado, pedindo que o participante realize alguns movimentos que geram perturbações conhecidas, como o piscar de olhos ou levantar suave do pé. O participante vê na tela a instrução que pode ser de descanso, marcada por uma cruz, conforme a Figura 6 ou um triângulo que instrui para a realização da ação daquela coleta. São realizadas coletas para cada movimento específico, ou seja, em cada coleta será realizado apenas um movimento, como levantar o pé esquerdo. Os movimentos são três: Piscar dos dois olhos simultaneamente, levantar um pé sem tirar o calcanhar do chão e fechar um punho. Portanto, considerando punhos e pés direito e esquerdo, foram feitas 5 coletas por participante, e em cada coleta cada movimento é repetido 13 vezes.

É pedido que o participante realize o movimento específico assim que a instrução apareça na tela, quantas vezes a instrução aparecer e imediatamente após retorno para a posição de descanso (a posição de descanso é simplesmente um estado sem movimentação e focado na instrução de descanso) e enquanto isso é observado na segunda tela separada, fora da vista do participante, como está a atividade cerebral, para acompanhar desligamentos do hardware, perda de contato de algum eletrodo, entre outros.

Por exemplo, se a instrução da coleta é piscar os dois olhos, o participante inicia no descanso com olhos abertos e assim que a atividade cerebral se estabilizar (continua oscilando, porém sem perturbações maiores visíveis) a pessoa na segunda tela inicia e compila o Código de Captura e Instruções, dando início ao vídeo para o participante e já salvando os dados a partir dali, que estavam sendo apenas apresentados na segunda tela de Feedback Visual, sem serem salvos. Depois de alguns segundos (variam para cada coleta) a primeira instrução é apresentada na tela e no mesmo instante um marcador (gatilho) é gerado no Matlab. O participante piscá os olhos e retorna para o descanso (olhos abertos neste caso). A instrução aparece mais algumas vezes em tempos diferentes para também medir o tempo de reação




Figura 5: Diagrama de blocos do processamento e feedback visual

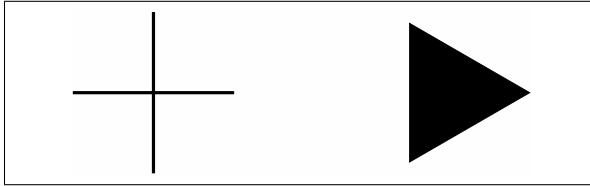


Figura 6: Indicadores para o participante: à esquerda o indicador de descanso e à direita o indicador de ação

do participante e para que este não se acostume com os intervalos.

Após as instruções o vídeo é fechado e é gerado um gráfico do sinal gravado naquela coleta para verificar se a coleta foi boa ou não, já que as perturbações são visíveis para a maioria dos movimentos escolhidos. Caso a coleta seja válida, parte-se para o próximo movimento, repetindo o procedimento e caso haja algum problema visível, como reinicialização do hardware, repete-se o procedimento para o mesmo movimento.

O objetivo da análise é perceber inicialmente se houve mudança geral no sinal durante o período após os gatilhos. Muitas vezes as perturbações não são tão perceptíveis, pois há aparição de ruídos diversos que impossibilitam a interpretação do sinal gerado. A primeira coisa a se fazer com os dados é a filtragem dos ruídos conhecidos para posteriormente interpretar o sinal que, agora filtrado, permite o reconhecimento de padrões.

3 Resultados e Discussões

Neste estudo foram comparados sinais de dois movimentos diferentes realizados pelo paciente: Piscar os dois olhos e levantar o pé esquerdo. Neste seção explica-se os procedimentos para a classificação automática dos movimentos de forma que um código do Matlab possa receber o sinal de um movimento e classificar se o Paciente piscou os olhos ou se moveu o pé.

3.1 Filtragem e Trato dos sinais

Na maioria das coletas houve desligamento espontâneo do Dispositivo, acredita-se que pode ser uma sobrecarga do

A imagem está em baixa qualidade.

hardware em que ele realiza um *soft reset*, mantendo algumas funcionalidades e transmitindo um sinal zerado para o bluetooth. Quando isto acontecia, obviamente perdia-se os dados daquela coleta. Porém algumas coletas foram muito efetivas, permitindo a gravação de vários movimentos, como os experimentos escolhido para serem apresentados neste trabalho: o movimento do pé esquerdo e o piscar de dois olhos.

O sinal "cru"(sem filtragem), apenas com a remoção da componente DC, segue na Figura 7 mostrando os 16 canais e como o sinal é recebido direto do capacete.




Figura 7: Gráfico do sinal de EEG n.º 7. Mostra dois movimentos consecutivos do pé esquerdo, sem escala. Este Gráfico foi exportado do ambiente de programação do EEGLab [?]

Os únicos tratos feitos neste sinal foram a remoção da componente DC e uma normalização usando como peso a média dos valores daquele canal, apenas para apresentação no formato padrão. O que se nota imediatamente é a presença de muitos ruídos, porém vê-se claramente a perturbação nos instantes conhecidos do movimento. Vale lembrar que este é um recorte, a coleta completa tem 60 segundos e este gráfico 7 segundos.

Fazendo a transformada de Fourier do canal 1 (eletrodo fp1) e plotando o espectro de frequência, conforme mostra a Figura 8, notam-se a componente DC, os ruídos intensos abaixo de 5Hz e um pico em 60Hz. O pico de 60Hz é a interferência da rede elétrica, que produz campo eletromagnético e, como esperado, aparece em todos os canais já que os eletrodos são dispositivos muito sensíveis.




Figura 8: Comparativo entre espectros de amplitude antes (em vermelho, acima) e depois do processo de filtragem (em azul, no gráfico de baixo)

Os ruídos abaixo de 5Hz são as ondas Delta (0.5Hz a 4Hz), estas ondas são mais intensas durante o sono, mas aparecem durante toda a atividade do cérebro.

Pode-se aplicar filtros para remover os dados indesejados. O filtro modelado é um passa-banda desenvolvido no próprio ambiente de programação do EEGLab [?] com frequências de corte entre 4Hz e 50Hz. Isto permite visualizar as ondas Teta (4 a 8Hz), Alfa e Mu (8 a 13Hz), Beta (13 a 30Hz) parte das ondas Gama (>30Hz). Foi escolhido este filtro pois deseja-se analisar em vários espectros o que ocorre afim de estudar o comportamento do cérebro [?]. Em aplicações relacionadas apenas à intenção de movimento, para aplicar algum algoritmo de reconhecimento de padrões, o recomendado é manter apenas o espectro de frequência desejado, neste caso as ondas Beta [?]. Porém, notou-se intensa atividade das ondas Mu durante a execução do movimento, que por mais que não sejam exatamente da intenção de movimento, podem auxiliar em aplicações em que o usuário tenha efetivamente realizado o movimento, ou como uma etapa de validação.

O filtro escolhido deixa o sinal da Figura 7 como o sinal da Figura 9, e o novo espectro de frequência consta na Figura 8 que já mostra a alta atividade entre as frequências mais baixas.

Nota-se claramente a atenuação do sinal e já é possível ver com mais clareza as duas repetições do movimento, que estão visualmente muito parecidas. No novo espectro de frequências percebe-se a atenuação das frequências indesejadas. Além disso, o gráfico foi plotado a partir do instante do gatilho, que é o instante zero neste caso, e o participante responde em menos de 0,5 segundos, o que está dentro da margem esperada e, segundo [?], valida a relação do evento à instrução.

Pode-se ainda, referenciar as localizações dos eletrodos na cabeça e levantar um mapa espectral com as intensidades de aparição de cada frequência por eletrodo conforme mostra a Figura 10. Para as frequências 9Hz, 15Hz e 22Hz notase que a região com maior amplitude de sinal foi a de F4,




Figura 9: Gráfico do sinal de EEG filtrado, 16 canais durante dois movimentos consecutivos do pé esquerdo, sem escala. Este Gráfico foi exportado do ambiente de programação do EEGLab. [?]

que visivelmente é o eletrodo com maior sinal nos gráficos das Figuras 7 e 9. Provavelmente a impedância de f4 estava menor durante o experimento ou ficou em um contato melhor com a pele do participante. Isto na realidade é algo ruim para o experimento, pois causa dúvida sobre as regiões que realmente apresentam atividade cerebral mais elevada, mas ajuda a identificar fontes de problemas para estudos futuros.




Figura 10: Mapas

e 22Hz

Porém alguns dos eletrodos mais ativos foram F7 e F8 que estão na região do córtex motor.

Agora, analisa-se o sinal comparado com o de outro movimento, neste caso o movimento de piscar os dois olhos do mesmo participante conforme a Figura 11, que de imediato é possível observar que os eletrodos mais ativos foram diferentes dos eletrodos para o pé esquerdo.




Figura 11: Gráfico do sinal dos 16 canais para o movimento de piscar os dois olhos do mesmo participante, sem escala. Este Gráfico foi exportado do ambiente de programação do EEGLab

Isso mostra a possibilidade de distinção entre movimentos utilizando o dispositivo. Sobrepondo os dois gráficos nos

mesmos intervalos para os movimentos do pé esquerdo e de piscar os dois olhos vemos algumas diferenças visuais com mais clareza, conforme mostra a Figura 12. Segundo [?] os movimentos do dedo indicador, do dedão e da mão inteira são visualmente muito parecidos, mas utilizando-se de ferramentas computacionais é possível diferenciar os padrões e também a região em que cada sinal é formado. Com isto em mente, sabendo que os atributos da onda são os padrões a serem analisados, o fato dos padrões serem visualmente diferentes é um indicativo de que representam movimentos diferentes.




Figura 12: Gráfico Comparativo entre sinais de coletas de dois movimentos diferentes em um mesmo canal

3.2 Preprocessamentos para classificação automática

Após as filtragens e tratos iniciais, podem-se aplicar algumas funções conhecidas afim de extrair atributos dos sinais, e a produção de uma resposta esperada para a utilização de algoritmos de classificação, que tomam parâmetros de entrada para comparar com uma saída predeterminada e gerar uma função que permita uma classificação geral de sinais semelhantes.

3.2.1 Normalização e limpeza de artefatos desnecessários

Como os sinais dos canais tinham intensidades muito diferentes devido aos ganhos cada canal, foi executada uma normalização de cada sinal convertendo os valores em escala de zero a um. Este processo não seria necessário se uma calibração prévia fosse feita nos canais e os ganhos ajustados dentro do ambiente de Software afim de calibrar esses ganhos para que os sinais de cada eletrodo representem igualmente um sinal gabarito.

A Normalização gera a incapacidade de analisar eletrodos mais ativos, processo feito pela comparação de intensidade dos canais. Porém, se fez necessária conforme mostra a Figura 13, em que o canal FP1 apresentou ganho de aproximadamente 63 vezes maior que FP2, o que com certeza causaria mais problemas nas análises já que os ganhos eram iguais para cada canal no Ambiente de Armazenamento do software. Isto só foi visualizado depois de verificar os sinais crus coletados, pois a visualização dentro do Feedback

Visual mostrava sinais já normalizados para avaliar apenas a qualidade do sinal e perturbações do sinal pelo pesquisador.

Vale lembrar que os sinais crus, mesmo que apresentados em tempo real no Feedback Visual, eram tratados com um filtro passa-banda e ajuste de *offset*, pois a finalidade era apenas uma avaliação sem muitos detalhes de que os movimentos geravam perturbação.




Figura 13: Gráficos Comparativos entre a sensibilidade de dois canais em uma mesma coleta

Na figura 14 pode-se observar os sinais normalizados para o movimento do pé esquerdo dos canais FP1, FP2, C3, C4 e C7.

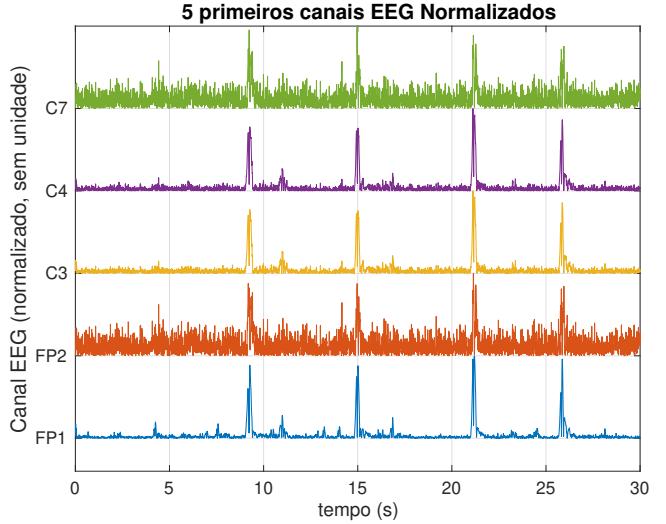


Figura 14: Gráfico dos 5 Primeiros canais EEG normalizados. Nome de cada canal no eixo das abscissas.

Notou-se que na maioria das coletas houve uma queda na intensidade dos sinais aproximadamente após cerca de 30 segundos de coleta e por isto, só os primeiros 30 segundos de coleta foram considerados, representando 4 movimentos consecutivos.

3.2.2 Dassincronização relacionada a evento (ERD)

Como o instante do movimento é conhecido e cada coleta representa um único movimento, pode-se gerar uma "Resposta

Esperada”, em que o instante do movimento é representado com um sinal, neste caso o Gatilho que é um pulso digital de 2 segundos de duração. Porém, como o Gatilho é gerado no instante em que o comando visual é emitido ao paciente, ele possui um período de relaxação referente ao tempo de reação do paciente e ao tempo de relaxação após a execução do movimento. Esse tempo de reação varia com o tipo de movimento e com os reflexos do paciente, portanto se o período de tempo baseado no gatilho for utilizado, artefatos indesejados serão associados ao movimento.

Para resolver isto, foi utilizada a técnica do Dessincronização Relacionada a Evento (ERD), que basicamente analisa onde há perturbações (Dessincronizações) maiores do que uma variância média durante a relaxação. Determina-se a variância média num instante sem movimento e mede-se a variância em uma janela de tempo ao longo do sinal de EEG procurando por perturbações no sinal que aumentem a variância, naquela janela, mais do que a média por tempo o suficiente para inferir que a Dessincronização foi relacionada a um evento. O tamanho da janela de tempo mínimo foi de 300ms, pois visualmente nos dados percebe-se que a perturbação dura mais do que 300ms.

Após a aplicação do algoritmo de ERD pode-se segmentar o sinal para selecionar um período de tempo relacionado ao movimento com maior precisão do que o do gatilho para que apenas intervalos referente ao movimento sejam recortados e analisados. O resultado desta segmentação para um dos canais do Pé Esquerdo (FP1) está representado na Figura 15




Figura 15: Gráfico da Segmentação do sinal baseado em ERD.

Notam-se 4 perturbações mais intensas que representam os 4 movimentos consecutivos que serão analisados.

3.2.3 Comparação no domínio da frequência durante relaxação e durante o Movimento

Baseado na segmentação é possível recortar o sinal apenas no instante do movimento e eliminar os instantes de relaxação. O objetivo aqui é analisar computacionalmente os atributos e diferenças fundamentais de cada onda. Segundo [?], extraíndo informações que caracterizam o sinal é possível gerar

classificadores para reconhecer os padrões de sinais semelhantes. Dessa maneira, uma análise simples pode ser feita, avaliando o espectro de amplitudes durante o movimento e durante a relaxação. O resultado encontra-se na Figura 16, que representa o espectro de amplitudes no domínio da frequência, portanto o eixo das abscissas é dado em módulo da tensão normalizada.




Figura 16: Gráfico das diferenças nos espectros de amplitude em instante com movimento e instante sem movimento (relaxação).

Nota-se a diferença de amplitudes do instante de movimento nas frequências entre 8Hz e 30Hz que representam ondas mu e beta que, segundo [?], podem representar um sinal referente a intenção movimento. Baseado nesta diferença do espectro entre instantes, pode-se extrair informações do sinal utilizando a transformada de Fourier. Para isto foi desenvolvida uma função que seleciona automaticamente as frequências nas quais vê-se as amplitudes mais significativas dentro da faixa entre 8Hz a 30Hz durante a realização do movimento. As frequências referentes às amplitudes mais significativas compõem 10 dos 12 atributos que serão analisados, portanto esta função gera uma matriz coluna com dez linhas em ordem decrescente em que cada linha representa as frequências mais ativas do sinal segmentado. Esta matriz é gerada para cada movimento consecutivo, produzindo assim 4 colunas de dez linhas. O intuito é que os classificadores utilizem a coluna como o padrão para treinar redes que possam distinguir entre as diferentes linhas.

3.2.4 Energia do sinal

Outro atributo extraído foi a energia do sinal que, segundo o Teorema de Parseval (cite?????????????????????????????), é dado pela soma dos quadrados do valores em cada ponto de coleta dividido pelo numero total de pontos coletados, conforme equação 2 a seguir

$$X_f = \mathcal{F}(x(t)); \quad (1)$$

$$E = \frac{\sum_{n=1}^n |X_f|^2}{n}; \quad (2)$$

Onde: X_f é o sinal no domínio da frequência depois da transformada de Fourier; $x(t)$ é o sinal do EEG no tempo; n é o número de pontos no domínio da frequência; E é a energia do sinal durante o intervalo analisado

O valor adquirido após aplicar esta função ao sinal é um novo atributo, que será utilizado na mesma matriz de atributos como uma décima primeira linha, para cada movimento.

3.2.5 Valor RMS

O último atributo, na décima segunda linha, foi o valor RMS (Raiz Quadrada Média, do inglês *Root Mean Square*) que mostra um valor médio do sinal durante o movimento.

3.2.6 Composição das matrizes de amostra e de resposta

Dessa maneira, foi composta uma matriz com 12 atributos de cada movimento com os quatro movimentos do pé esquerdo nas quatro primeiras colunas, e os quatro movimentos de piscar os dois olhos nas quatro últimas colunas. Esta é chamada de Matriz das amostras.

A próxima etapa foi a composição de uma resposta esperada que representa numericamente o movimento executado, chamado de Classe de Movimento. Para alguns dos classificadores esta é simplesmente um valor numérico, portanto, para os atributos que representam o movimento de pé esquerdo, foi dado o valor 1 (um) e para o movimento do piscar dos olhos foi atribuído o valor 2 (dois). Compondo uma matriz linha de 8 colunas:

$$\begin{bmatrix} 1 & 1 & 1 & 1 & 2 & 2 & 2 & 2 \end{bmatrix}$$

Outros classificadores utilizam uma matriz "alvo", em que o alvo é a resposta esperada para o treinamento do classificador. Para a matriz alvo os movimentos representam linhas da mesma, portanto para dois movimento diferentes foi utilizada uma matriz alvo de duas linhas, em que zeros representam a falta do movimento daquela linha e 1 (um) representa a existência de movimento.

Para uma sequência de dois movimentos, por exemplo, a matriz Alvo é como na Matriz a seguir, em que as linhas representam a Classe de Movimento e cada coluna é a resposta para um conjunto de atributos referente a um movimento específico, que espera-se que seja necessariamente um movimento ou o outro, já que os atributos foram determinados apenas para instantes com movimentos conhecidos.

$$\begin{bmatrix} 1 & 1 & 1 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 1 & 1 & 1 \end{bmatrix}$$

3.2.7 Composição de amostras sintéticas para análise de robustez dos classificadores

Como não há várias coletas, conjuntos de dados sintéticos foram gerados a partir das matrizes de amostra originais aplicando ruídos gaussianos de $-0,5dB$ a $-30dB$ com incremento de $-0,5dB$ portanto 60 novos conjuntos de dados sintéticos para cada tipo de movimento. O objetivo destes é comparar a robustez dos classificadores mesmo com a inserção de ruído.

É importante ressaltar que isto não avalia a performance do classificador em relação à identificação de intenção de movimento, para isto seria necessário uma amostra muito maior. Esta análise com os sinais sintéticos proporciona uma verificação para a robustez do classificador dadas variações

controladas dos parâmetros que os classificadores recebem como entrada. O objetivo é verificar se a inserção de pequenos ruídos da ordem de $-20dB$, por exemplo - que adicionam entre -0.3 a $+0.3$ aos dados originais, praticamente não tenham impacto na identificação do tipo de movimento, já que estes estão dentro da faixa esperada de variação do espectro de freqüências, energia do sinal e valor RMS conforme visto em [?] e [?].

Portanto, espera-se que os classificadores cometam erros para ruídos de mais de $-10dB$, pois se "acertarem" qual o tipo de movimento, significa que estão considerando parâmetros dentro de um intervalo muito amplo. É evidente que se o ruído estiver dentro da faixa de variação da própria amostra, o resultado será correto, já que o classificador foi treinado para aquela variação.

Resultados dos classificadores?

3.3 Classificadores

3.3.1 Classification Learner

Com os atributos dos sinais e a resposta esperada em mãos, utilizou-se a Ferramenta *Classification Learner* do Matlab para geração de classificadores. Na ferramenta é possível selecionar tipos de classificadores e treiná-los com diferentes informações de entrada para uma saída esperada. Ao fim do treino o aplicativo retorna a eficácia de cada classificador em predizer a resposta baseado na entrada fornecida.

Dicutir KNN Discutir Ensemble Discutir Ávore de decisão?

3.3.2 IAs baseadas em Redes Neurais

NN

3.3.3 Sistemas de Inferência Neuro-Fuzzy Adaptativos

A teoria Fuzzy, também chamada de Lógica Difusa, tem um papel importante em lidar com tomadas de decisões em aplicações médicas, principalmente considerando as incertezas envolvidas. De maneira geral, a lógica Fuzzy permite atribuir vários valores às variáveis ao invés de 0 ou 1 como na lógica Booleana. [?]

Os Sistemas Neuro-Fuzzy são sistemas Fuzzy que utilizam Redes Neurais para determinar as características Fuzzy (Regras Fuzzy e Conjuntos Fuzzy) processando os dados amostrais. Um dos métodos de utilização de Lógica Neuro-Fuzzy é o desenvolvimento de Sistemas de Inferência Neuro-Fuzzy Adaptativos (ANFIS, do inglês *Adaptive Neuro-Fuzzy Inference Systems*), que apresenta resultados significativos na classificação de sinais EEG, que segundo [?] chegam a ser maiores que 98%. Este método é amplamente utilizado para analisar dados de sinais biológicos.

As estruturas ANFIS aprendem os atributos do conjunto de dados e ajustam os parâmetros do sistema de acordo com um dado critério de erro [?].

Anfis Quais parâmetros?

Impedimentos para Classificação automática falta de repetibilidade canais mortos e perdas ganhos diferentes não permitem heatmap confiável Como corrigir? - Calibração problemas com o hardware

3.4 Aspectos impeditivos e outros empecilhos

Alguns dos problemas impeditivos para uma análise estatística dos resultados são a falta de repetibilidade e reproduzibilidade, pois tanto não houveram coletas com diversos pacientes, o que permitiria a reproduzibilidade, quanto não foram realizadas repetições do experimento sob mesmas condições, pois o hardware só suportava cerca de 30 minutos devido a limitações da bateria. Este tempo limitado só permite uma coleta completa para cada tipo movimento e muitas vezes antes de terminar a coleta a carga da bateria já não suportava mais uma nova série.

Após recarregar a bateria e iniciar uma nova coleta muitos dos parâmetros já eram diferentes, por exemplo os ruídos poderiam mudar de acordo com a oleosidade da pele do paciente, que certamente estaria diferente de uma coleta para a outra considerando 4 horas de carga para as baterias. Outros parâmetros que mudariam as condições certamente seriam: ponto de contato dos eletrodos, umidade do cabelo

Infelizmente, o dispositivo da OpenBCI foi adquirido com um problema em um dos indutores. Isto causou atraso de meses para as primeiras coletas, pois o dispositivo SMD (Dispositivo acoplado na superfície, do inglês *Surface Mount Device*) teve que ser substituído, e acredita-se que a substituição do dispositivo, mesmo que por outro idêntico, causou parte dos problemas experienciados, ou outra parte do dispositivo já estava prejudicada, o que pode inclusive ter sido a causa da falha do SMD no passado.

4 Expectativas de resultados futuros

Para trabalhos futuros o intuito é fazer mais coletas para poder realizar um estudo estatístico completo sobre classificação de intenção de movimento e talvez implementar algoritmos de distinção em tempo real, para aplicações em sistemas neuroprostéticos ou de assistência ao movimento de pacientes com perdas neuromotoras.

Um questão a ser estudada é a variação de impedância dos eletrodos, que foi um problema recorrente durante as gravações e era evidente sua atuação no sinal. Esta variação pode se dar por vários motivos, dentre eles movimentação do eletrodo para uma região com mais ou menos cabelo ou o sebo da pele que pode provocar a mudança no ponto de contato do eletrodo. Uma maneira de resolver grande parte deste problema com as impedâncias é a utilização de uma touca que permite a inserção de gel condutor no contato dos eletrodos com a pele. O gel permite um aumento significativo da área de contato do eletrodo com a pele e mantém a impedância por fatores externos (sebo, cabelo) controlável, pois pode-se alterar a quantidade de gel por eletrodo externamente, sem remover o capacete. Além disto a touca permite um ajuste melhor à cabeça do participante, impedindo que o eletrodo se move de maneira significativa ou haja perda de contato e dessa maneira permitindo que o participante se move livremente afim de realizar capturas diferentes ou sob diferentes condições, como com o usuário andando.

Outra etapa essencial é a calibração dos eletrodos, que permitiria extração de atributos que foram impossíveis neste trabalho.

Outro ponto a ser estudado no futuro é a variação de intensidade e duração dos sinais, pois observou-se que alguns sinais, para um mesmo movimento, possuem durações diferentes e há estudos que relacionam a força de um movimento, ou a velocidade em que foi realizado, com esses atributos do sinal no EEG.

5 Conclusão

Para um sistema de baixo custo os resultados se apresentam promissores, pois mostram que é possível implementar os sistemas desejados se as precauções e processos corretos forem tomados.

Infelizmente o sistema apresenta ainda muita instabilidade devido à sua simplicidade, como por exemplo a impedância dos eletrodos que variava durante a coleta ou os problemas com reinicializações inesperadas do Hardware. A resolução desses problemas toma muito tempo que poderia ter sido utilizado com a filtragem em tempo real dos dados ou utilização de vários métodos para a identificação dos movimentos por meio de IAs. Porém após adaptação aos problemas é possível realizar as coletas, preocupando-se com os problemas, tentando prevê-los e preveni-los.

A utilização de uma leitura mais abrangente mostra-se eficiente para a compreensão dos sinais. Para pesquisas futuras sabe-se exatamente quais sinais eliminar e como fazer isto. Outro fato interessante sobre leituras abrangentes é reconhecer os sinais provenientes de eletrodos específicos afim de eliminar os artefatos imediatamente. Um dos grandes desafios do estudo de intenção de movimento é eliminar os sinais de intenção dos movimentos que não são de interesse e para isto deve-se conhecer a todos eles.

As observações se mostraram interessantes e permitiram muito aprendizado e desenvolvimento de habilidades com software, hardware, filtros, estudos de classificadores, análise de dados e principalmente a o estudo interdisciplinar com conhecimentos muito distintos que permitem integrar grandes áreas do conhecimento que tanto precisam uma da outra.

6 Apêndice

Agradecimentos