



Processamento, classificação e transmissão de sinais de eletrooculograma utilizando ESP32

Processing, classification and transmission of electrooculogram signals using ESP32

João Vitor Ferro Simões*, Sergio Luiz Stevan Junior†, Luiz Henrique de Almeida Mattos§

RESUMO

O presente trabalho investigou a possibilidade de realizar o pré-processamento (conversão analógico-digital, filtragem do sinal digital e janelamento), o processamento (extração de características das janelas do sinal), classificação da posição do olho (através de redes neurais artificiais) e a transmissão do resultado desta classificação de sinais de eletrooculograma (EOG) utilizando um microcontrolador ESP32 como transmissor e outro ESP32 como receptor. O estudo também realiza a contagem de tempo para cada etapa deste processo. Foi descoberto que o tempo para realização de todas as etapas listadas, por canal, é de 2,8ms, assim, argumenta-se que é possível realizar todas as etapas de processamento do sinal de EOG, em um curto espaço de tempo, visto que as janelas utilizadas são quase 18 vezes maiores do que o tempo para processar cada canal.

Palavras-chave: Eletrooculograma, Processamento, ESP32

ABSTRACT

The work presented sought the possibility of performing pre-processing (Analog-digital conversion, digital signal filtering and windowing), processing (extraction of signal features), classification of eye position (through artificial neural networks) and transmission of the result of this classification of electrooculogram (EOG) signals using an ESP32 microcontroller as a transmitter and another ESP32 as a receiver. The study also counts the time for each step of this process. It was found that the time to perform all the steps listed, per channel, is 2.8ms, thus, it is argued that it is possible to perform all EOG signal processing steps, in a short amount of time, as the windows used are almost 18 times bigger than the time for processing each channel.

Keywords: Electrooculogram, Processing, ESP32

1. INTRODUÇÃO

O eletrooculograma (EOG) é a medição da diferença de potencial gerada entre a córnea e a retina sendo realizada através de eletrodos posicionados em volta do olho, com amplificação diferencial (SPLINTER, 2015). Esse sinal é considerado o sinal mais estável para captura de variação de movimentos do olho, ganhando mais força nos anos recentes para superar as dificuldades de pacientes com paralisia (C. -T. LIN ET AL., 2019). O potencial gerado pelo eletrooculograma e classificação abrem diversas possibilidades, como o controle de cadeira de rodas utilizando o posicionamento do olho, apresentando bons resultados neste campo, podendo fazer comandos em diferentes níveis, através do ângulo detectado pelo computador (BAREA, 2000). Assim,

* Engenharia Elétrica, Universidade Tecnológica Federal do Paraná, Câmpus Ponta Grossa, Paraná, Brasil;
joaosimoes@alunos.utfpr.edu.br

† Universidade Tecnológica Federal do Paraná, Câmpus Ponta Grossa, Paraná, Brasil; sstevanjr@utfpr.edu.br

§ Engenharia Elétrica, Universidade Tecnológica Federal do Paraná, Câmpus Ponta Grossa, Paraná, Brasil;
lmattos@alunos.utfpr.edu.br



SEI-SICITE 2021

Pesquisa e Extensão para um mundo em transformação

o processamento e classificação dos sinais de eletrooculograma se torna necessária, e, para auxiliar na questão de mobilidade, abrange-se a utilização de microcontroladores.

Um problema recorrente na utilização de EOG para controle de interfaces humano máquina (HMI) é realizar precisamente e rapidamente os comandos de controle a partir da movimentação dos olhos (HUANG, 2017, pág.10). No estudo de Huang, foi utilizado para processar os dados um notebook alocado no braço da cadeira de rodas.

Em outro estudo, foi feita a captura e envio dos dados através de um óculos com transmissão bluetooth (KOSMYNA et al, 2019, pág.3), porém, ainda assim utilizou-se um computador para processar os dados recebidos.

Também é possível aplicar o EOG para controlar o ponteiro do mouse de um computador, utilizando módulos de amplificação de sinais, Arduino e transmissão *bluetooth*, com interface em *Python* no computador, para fazer a ligação entre o sinal digital convertido pelo Arduino com o comando de movimentação de ponteiro (SHAWON et al. ,2020, pág. 6), ainda assim utilizando-se do computador para processar os dados.

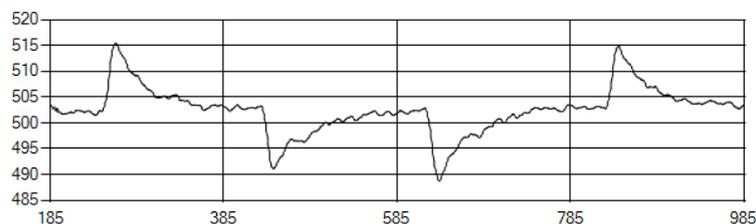
Assim, levanta-se a hipótese: seria possível realizar a captura, pré-processamento, processamento, classificação e transmissão dos dados classificados através de um único módulo, sem o auxílio de um computador?

Este estudo busca realizar todas as fases do processamento de um sinal de EOG, desde a captura do sinal analógico até sua classificação e transmissão do resultado desta classificação para qualquer equipamento. Para isso, levantou-se a hipótese de utilizar o microcontrolador ESP32, pois possui *bluetooth* e *wifi* integrados, além de poder de processamento maior que o microcontrolador Arduino, podendo assim realizar cálculos de forma mais eficiente e em menor tempo possível.

2. MATERIAIS E MÉTODOS

O sinal de eletrooculograma possui características distintas, como picos para mais e para menos de uma média central (repouso). Na Figura 1 é possível visualizar um sinal de EOG horizontal, em que segue-se a seguinte ordem: direita, centro, esquerda, centro.

Figura 1: Sinal exemplo de EOG para um canal horizontal



Fonte: Autoria própria

Na Figura 1, os picos do sinal para cima significam movimento para a direita, já os picos do sinal para baixo representam movimento para a esquerda, assim, observa-se a ordem: movimento para direita (posição direita), movimento para esquerda (posição centro), movimento para esquerda (posição esquerda) e movimento para direita (posição centro), sendo posição a referência de posição dos olhos.

2.1. AQUISIÇÃO DOS SINAIS BIOELÉTRICOS

A Aquisição dos sinais é realizada por eletrodos que podem ser invasivos ou não-invasivos. Os invasivos buscam captar os sinais elétricos de camadas mais profundas dos músculos exigindo uma acuidade maior em sua utilização, enquanto os não-invasivos, captam os sinais periféricos da pele e são de mais fácil aplicação. Existem diversos tipos de eletrodos para a captura de sinais biomédicos, sendo mais comumente divididos em eletrodos passivos e ativos. Eletrodos ativos são eletrodos com microcircuitos para casamento de impedâncias entre sensor e pele, além de blindagem ativa, gerando uma melhor relação sinal-ruído (NORONHA, 2019).

Eletrodos passivos não-invasivos, de Ag/AgCl (geralmente fixados com gel condutor) têm a função de captar os sinais biomédicos sem amplificação ou blindagens ativas, não necessitando ser alimentado com uma diferença de potencial elétrico (ddp) (NORONHA, 2019). Menos comuns que os eletrodos fixados com gel condutor, existem eletrodos secos, geralmente não descartáveis e eletrodos têxteis.

No caso deste estudo foram utilizados eletrodos não-invasivos de Ag/AgCl fixados com gel, descartáveis, pois são de fácil aquisição e apresentaram bons resultados em pesquisas anteriores.

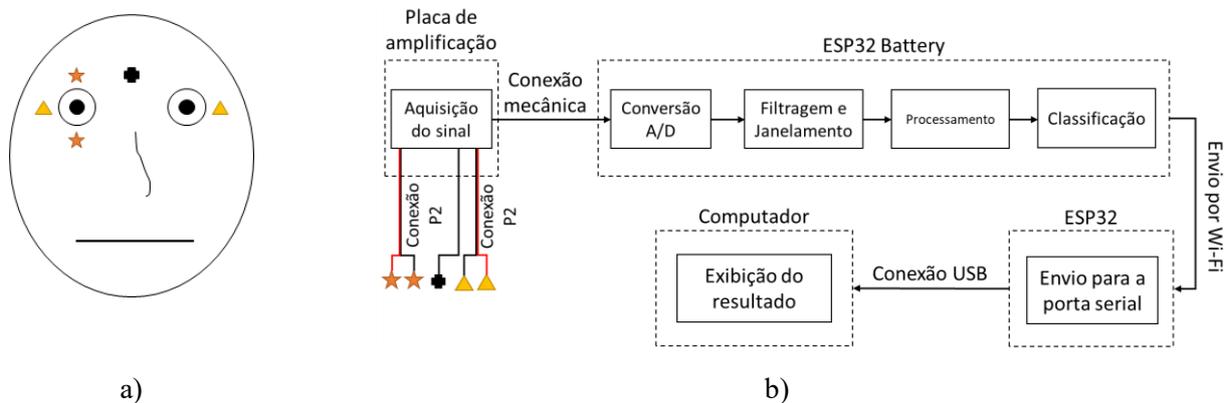
Existe uma grande variedade de posicionamento de eletrodos para eletrooculograma, mais usualmente para o canal horizontal posiciona-se os eletrodos diferenciais nas têmporas, já para o canal vertical, posiciona-se os eletrodos acima e abaixo dos olhos esquerdo ou direito e com referência no meio (C. -T. Lin et al,2019). A Figura 2 a) exemplifica este posicionamento, onde os canais estão divididos em laranja e azul, enquanto a referência está em preto.

A amplificação dos sinais bioelétricos foram feitos através de uma placa de amplificação instrumental baseada no chip INA 128, que possui filtros passa alta de 0,5 Hz (para filtrar artefatos de movimento) e rejeita faixa de 60Hz (para filtrar interferências eletrostáticas). A placa de amplificação acopla-se mecanicamente nos pinos do ESP32 com bateria de lítio integrada (*ESP32 battery*), estando assim, completamente isolado da rede.

Os sinais utilizados para este estudo, seja para treinamento ou validação foram todos captados do pesquisador-chefe (orientador). Para demonstração de conceito, neste estudo foi captado somente o canal horizontal, assim, consegue-se obter o tempo de processamento para um canal.

O diagrama de blocos com o hardware e as etapas de processamento do sinal estão ilustrados na Figura 2 b).

Figura 2: a) Posicionamento de eletrodos para o EOG; b) Diagrama de blocos do *hardware* utilizado



Fonte: Autoria própria

2.2. PRÉ-PROCESSAMENTO E JANELAMENTO

A média móvel é um método de filtragem que tem a função de calcular o n-ésimo valor da sequência de saída, fazendo a média simples dos valores de entrada, através da equação 1(De La Vega, 2018). Este procedimento serve como um filtro a ruídos, reduzindo a influência dos valores fora da média (*outliers*).



$$y[n] = \frac{1}{M_T} \sum_{k=M_1}^{M_2} x[n - k] \quad (1)$$

Para processamento online (ao mesmo tempo que se captura), é necessário delimitar a quantidade de dados para serem efetivamente manipulados. Este processo é conhecido como janelamento do sinal. Para este estudo foram utilizadas médias móveis de 10 dados coletados com uma frequência de amostragem de 250 Hz e janelamento de 50ms. Foram testadas também janelas maiores (de 100 e 150 ms) e janelas menores (de 10 e 25 ms), porém, como desejava-se encontrar a menor janela possível (visando não prejudicar a captura dos dados) em que ainda fosse possível realizar as estimativas de posição com precisão, chegou-se ao resultado de 50 ms por janela.

2.3. PROCESSAMENTO DOS DADOS

A extração de características (chamada também de *features*) do sinal deve ser realizada antes da classificação (S. AUNGSAKUL et al., 2012, pág 1), assim, observando a morfologia do sinal de EOG, foram escolhidos a integral e derivada como *features*, pois como a determinação de direita e esquerda é feita através de picos, supôs-se que a integral, pelo fato de obter a soma dos pontos do sinal seria útil, e a derivada, pelo fato de obter a inclinação do sinal também seria útil para detectar a movimentação do olho.

As equações 2 e 3 apresentam os cálculos para integral (I) e derivada (D), respectivamente.

$$I = \sum_{i=1}^N |X_i| \quad (2)$$

$$D = \frac{(X_i - X_{N-i})}{N} \quad (3)$$

Em que: X_i é o valor do sinal na posição i ; e N é o tamanho da janela.

Assim, após cada janela, a integral e derivada eram calculadas no ESP32 e armazenadas em variáveis do tipo *double*. Além disso, foi utilizada uma *feature* chamada último estado, em que era registrado a última posição do olho.

2.4. CLASSIFICAÇÃO DOS DADOS POR REDES NEURAIS

Para este estudo a classificação dos dados foi feita por Redes Neurais, mais especificamente por um classificador de multi-camadas. Uma rede neural basicamente é formada por 3 grupos de neurônios, uma camada de entrada, várias camadas intermediárias e uma camada de saída. As camadas intermediárias podem ser aumentadas para aumentar a capacidade de processamento da rede neural, fazendo com que seja possível realizar o “*deep learning*”, fazendo com que o computador identifique padrões em muitas camadas de processamento (SAS - *Analytic Software and Solutions*, 2021).

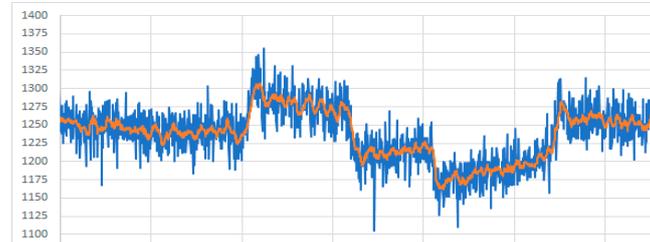
A rede neural utilizada foi de uma camada com três entradas, e duas camadas intermediárias com 10 e 5 neurônios respectivamente e com três saídas. Após treinada, foram extraídos os coeficientes da rede neural (funcionam como pesos em multiplicações dos neurônios) e estes coeficientes foram alocados em matrizes no ESP32, assim, é possível com as entradas e os coeficientes, obter a saída mais provável, sendo as opções centro (representado por 0), direita (representado por 1) e esquerda (representado por 2)

3. DISCUSSÃO E RESULTADOS

Ao utilizar o ESP32 para realizar a filtragem por média móvel, foram encontrados bons resultados, observando a Figura 3, pode-se verificar que o sinal filtrado (em laranja) mantém o mesmo formato do sinal original (em azul), porém com menos ruído.



Figura 3: Sinal original (em azul) e sinal filtrado pela média móvel (em laranja)



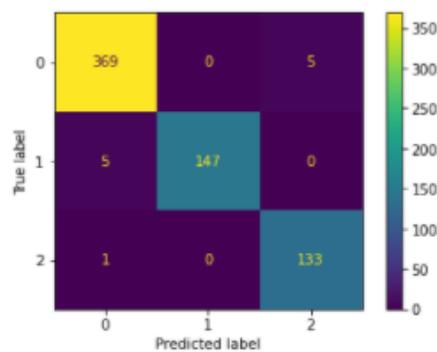
Fonte: Autoria própria

Estimou-se o período de aquisição dos dados, calculando-se o tempo de uma conversão do microcontrolador, obtendo-se um período de aquisição e conversão analógico-digital em torno de 40 μ s.

O janelamento, integral e derivada foram calculados pelo ESP32 e comparados posteriormente com os dados armazenados, não apresentando diferenças. Assim, com a extração de *features* funcional, calculou-se o tempo para filtragem e extração de *features*, chegando em um resultado de 1300 μ s.

A rede neural foi treinada externamente utilizando 70% das 2200 janelas amostradas. Os outros 30% foram utilizados para a validação da rede neural. Foi obtido uma precisão de 99% para cálculo de centro e 98% para cálculo de esquerda e direita, o que pode ser visualizado na matriz de confusão ilustrada na Figura 4.

Figura 4: Matriz de confusão



Fonte: Autoria própria

Ao analisar-se a matriz de confusão, verifica-se que: Para a posição Centro, 5 vezes a rede neural classificou como esquerda. Para a posição Direita, 5 vezes a rede neural classificou como centro. E para a posição Esquerda, 1 vez a rede neural classificou como centro.

Foram então inseridos os coeficientes em matrizes no ESP32 e calculado com dados de teste o tempo que a rede neural leva para realizar a previsão (cálculo de multiplicação das matrizes), chegando em um tempo médio de 600 microssegundos.

Agora, após a classificação, a identificação de posição do canal precisa ser enviada, então, através do protocolo de comunicação ESPNOW, que utiliza o *wifi* do ESP32 para realizar transmissão em formato de broadcast (envia os dados para quaisquer ESP32 configurados para receber, sem relação cliente-servidor, não necessitando de uma conexão estabelecida), obteve-se que, para um pacote de 250 bits, o tempo de transmissão do pacote se encontra em uma média de 800 microssegundos.

Ao realizar os testes com todo o conjunto funcionando, foram encontrados bons resultados, porém, no momento que a rede neural errar uma previsão, todas as seguintes se tornam erradas, pois, ao utilizar o último estado do olho, faz com que uma única previsão errada prejudique as subsequentes.

Já que as janelas de cálculo de *features* possuem 50ms e todo o processo de pré-processamento, processamento, classificação e transmissão do resultado possuem 2,8ms em média, é possível concluir que o ESP32 possui capacidade de realizar todas as etapas, desde a conversão Analógico-Digital até a classificação



e envio de um sinal de EOG ainda dentro de uma janela, ou seja, de forma online. Para mais canais, de forma grosseira, pode-se estimar o tempo através de simples multiplicação do tempo necessário para um canal, assim, para dois canais o tempo seria de 5,6ms, para três canais seria de 8,4ms e assim por diante.

Como próximos passos da pesquisa, têm-se a adição de mais canais e adaptação da rede neural, assim como as etapas de processamento e pré-processamento de forma independente. Pode-se também realizar o processamento de sinais de sEMG, já que a placa de captura tem a possibilidade de tal. Também se estuda uma forma de reiniciar a rede neural, visto que um erro na classificação leva a uma sequência de erros.

4. CONCLUSÃO

Pode-se concluir que o ESP32 possui capacidade para realizar todas as etapas que consistem em extrair e classificar o sinal de eletrooculograma, assim, comparando com outros trabalhos anteriormente apresentados, pode-se dizer que é possível em um futuro próximo a utilização de microcontroladores para realizar todo o processamento e comando de aplicações biomédicas, como no caso de controle de cadeira de rodas.

AGRADECIMENTOS

Os autores agradecem ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo fomento da pesquisa.

REFERÊNCIAS

- NAJARIAN, Kayvan; SPLINTER, Robert. **Biomedical signal and image processing**. Taylor & Francis, 2012.
- C. -T. LIN et al., "EOG-Based Eye Movement Classification and Application on HCI Baseball Game," vol. 7, 2019.
- R. BAREA, L. Boquete, M. Mazo, E. Lopez and L. M. Bergasa, "EOG guidance of a wheelchair using neural networks," vol. 4, 2000.
- Q. HUANG et al., "An EOG-Based Human–Machine Interface for Wheelchair Control," in IEEE Transactions on Biomedical Engineering, vol. 65, no. 9, 2017.
- N. KOSMYNA, C. Morris, U. Sarawgi, T. Nguyen and P. Maes, "AttentivU: A Wearable Pair of EEG and EOG Glasses for Real-Time Physiological Processing," 16th International Conference on Wearable and Implantable Body Sensor Networks (BSN), 2019.
- SHAWON, AHSAN-UI & Shahin, FAISAL & Islam, MD. Kafiul. **Design and Implementation of an EOG-based Mouse Cursor Control for Application in Human-Computer Interaction**. Journal of Physics: Conference Series, no.1487, 2020.
- NORONHA, César. **Uma breve introdução ao EEG e aos tipos de eletrodos**. [S. l.], 2019. Disponível em: <https://www.brainlatam.com/blog/uma-breve-introducao-ao-eeg-e-aos-tipos-de-eletrodos-717>. Acesso em: 28 jun. 2021.
- DE LA VEGA, Alexandre - **Tutorial sobre Sistema de Média Móvel para Fundamentos de Processamento Digital de Sinais**, 2018 Disponível em: <http://www.telecom.uff.br/~delavega/public/DSP/tutorial_SMM_dsp.pdf> Acesso em: 10/05/2021
- S. AUNGSAKUL, A. Phinyomark, P. Phukpattaranont, C. Limsakul, **Evaluating Feature Extraction Methods of Electrooculography (EOG) Signal for Human-Computer Interface**, Procedia Engineering, Volume 32, 2012, Pages 246-252.
- SAS - Analytic Software Solutions – **Redes Neurais: O que são e qual sua importância?**, 2021 Disponível em: <https://www.sas.com/pt_br/insights/analytics/neural-networks.html> Acesso em: 10/05/2021