

A era digital e suas implicações sociais: Desafios e contribuições

SISTEMA DE AQUISIÇÃO E ANÁLISE DE DADOS DE ELETRONEUROMIOGRAFIA

Lucas Camargo Ekroth¹, Matheus Mascarenhas¹,
Gabriel de Souza Pereira Gomes².

¹Instituto Federal de Educação, Ciência e Tecnologia de São Paulo, Rod. Pres. Dutra, km 145, s/n, Jardim Diamante, São José dos Campos-SP, Brasil, lucas.ekroth@aluno.ifsp.edu.br, mascarenhas@ifsp.edu.br.

²Genesis Pesquisa e Desenvolvimento, Rua das Arraias, 50, Sala 101, Parque Residencial Aquarius, São José dos Campos-SP, Brasil, gabriel.gomes@genesis-dataculture.com.

Resumo

O aumento da massa muscular é vital para a saúde, melhorando a força, resistência e desempenho físico, e auxiliando na regulação da glicose e no aumento do metabolismo basal. Também é útil na prevenção de obesidade e diabetes tipo 2. Muitas questões surgem sobre o treinamento adequado para o ganho muscular. A eletroneuromiografia (ou eletromiografia) é um método para monitorar a ativação muscular e avaliar a eficácia dos movimentos. O projeto descrito envolve o desenvolvimento de um protótipo que monitora os músculos durante o exercício físico para melhorar a performance e analisar a fadiga muscular. As amostras coletadas podem permitir análises de dados automatizadas.

Palavras-chave: Eletromiografia; Processamento de Sinais; Bioengenharia.

Área do Conhecimento: Engenharia Biomédica.

Introdução

A eletromiografia de superfície (SEMG) é um método amplamente utilizado em diversas áreas, como neurologia, reabilitação, ortopedia, ergonomia e esportes. Neste projeto, concentramo-nos na área de *fitness* e esportes, visando desenvolver um protótipo que auxilie atletas a realizar exercícios mais eficientes.

O aumento da massa muscular é fundamental para a saúde e bem-estar geral, além de proporcionar uma aparência física mais definida e atlética. Aumentar a massa muscular está diretamente relacionado com a melhoria da força, resistência e desempenho físico, além de contribuir para a regulação dos níveis de glicose no sangue e o aumento do metabolismo basal. No entanto, vários fatores devem ser considerados quando se trata de ganho de massa muscular.

A eletroneuromiografia é um exame que analisa a atividade elétrica dos músculos para monitorar a ativação muscular durante os exercícios. Esse exame permite identificar a ativação muscular em relação a um determinado movimento, avaliar a eficácia dos movimentos em relação à carga e analisar a fadiga muscular. Nesse contexto, o projeto busca desenvolver um protótipo que monitore os músculos durante os exercícios físicos, auxiliando no aprimoramento da performance e possibilitando a aquisição de dados para análise e automação futura. Trata-se de um projeto em andamento com potenciais aplicações em diversas áreas.

A aquisição de sinais musculares por meio de eletrodos de superfície/gel é uma técnica comumente empregada na pesquisa biomédica. Esses eletrodos, posicionados na superfície da pele, captam os sinais elétricos gerados pelos músculos durante a contração. No entanto, esses sinais são fracos e requerem amplificação para aumentar sua intensidade. Além disso, é necessário converter esses sinais de analógico para digital para que possam ser processados e analisados digitalmente.

De acordo com o Jayaweera, P. (2021) uma abordagem comum para a aquisição de dados de EMG (eletromiografia) envolve o uso de vários canais de eletrodos, posicionados em diferentes áreas do corpo para capturar simultaneamente os sinais de diferentes músculos. Isso permite uma análise mais abrangente e precisa dos padrões de atividade muscular.

A era digital e suas implicações sociais: Desafios e contribuições

No entanto, é importante ressaltar que o uso de vários canais de aquisição de EMG também apresenta desafios. A sincronização dos dados de diferentes canais, o processamento em tempo real e a redução de ruídos e interferências são aspectos que devem ser considerados durante a implementação do sistema de aquisição de dados.

Em resumo, a aquisição de sinais musculares por meio de eletrodos de superfície/gel requer amplificação e conversão analógico-digital. O uso de vários canais de aquisição de EMG permite uma análise mais abrangente, mas também apresenta desafios técnicos. Recomenda-se o uso de microcontroladores ou placas de desenvolvimento com conversor analógico-digital para a amostragem e processamento eficiente dos dados de EMG. Algumas placas de desenvolvimento sugeridas incluem placas Arduino, Espressif (ESP32) e placas de desenvolvimento STM32, mas não há limitação.


Metodologia

O projeto será semelhante ao projeto do Karlik, B (2014) que pode ser visto na figura 1 envolverá o desenvolvimento de um protótipo para aquisição dos sinais de EMG, através de um dispositivo portátil, utilizando plataformas microprocessadas e/ou microcontroladas para aquisição do sinal do sensor EMG. Em seguida, foi desenvolvida uma aplicação para armazenar e classificar as amostras. Utilizaremos o sensor AD8232, um microcontrolador ESP32 e eletrodos de superfície, a princípio vamos classificar apenas o bíceps do braço direito. A posição dos eletrodos não invasivos é de acordo com a SENIAM (*Surface ElectroMyoGraphy for the Non-Invasive Assessment of Muscles*): são posicionados três elétrodos de superfície no bíceps, como referencia temos as 3 cores: vermelho: que é posicionado no começo do segmento do músculo, amarelo: posicionado próximo a algum osso (como o ombro) e verde: posicionado no meio do músculo.

Exportamos as amostras da leitura serial para uma série de arquivos de dados que posteriormente serão tratados e analisados utilizando a linguagem *Python* em conjunto a biblioteca de análise de dados *Pandas*. A partir das amostras adquiridas faremos o *feature extraction* dos dados, retiraremos métricas como o desvio padrão, média, máximo e mínimo. Após isso, é feita a normalização dos dados para que todos dados estejam em mesmo nível de referência e não enviesem nosso resultado. Neste projeto vamos abordar dois métodos de *machine learning* para classificação: *Ridge Classifier* e *Random Forest*.

A princípio tiramos 32 amostras de 4 pessoas diferentes, para cada pessoa foram extraídas quatro amostras sem contração muscular e outras quatro com contração. Depois, para aprimorar nossos testes, retiramos mais 40 amostras, de mais 5 pessoas diferentes, utilizando o mesmo padrão e escala de amostras. Fizemos a separação das amostras, parte para treinamento, parte para validação e outra para um teste. Dessa forma, temos um resultado mais justo. Essa distribuição pode ser melhor visualizada na figura 2.

Figura 1 - Diagrama de blocos do controle mioelétrico de prótese de braço.



Fonte: Machine Learning Algorithms for Characterization of EMG Signals (Karlik, B., 2014)

Figura 2 - Divisão das amostras entre teste e treino.

A era digital e suas implicações sociais: Desafios e contribuições

Primeiras Amostras (32)		Amostras Posteriores (40)
Para Treino (75%)	Para Validação (25%)	Para Teste[100%]

Fonte: Do Autor.

Resultados

O primeiro protótipo foi feito com um sensor EMG genérico, que necessitava de uma fonte externa simétrica, então ele foi adaptado em uma caixa de madeira, conforme a figura 3.


Figura 3 - Primeiro Protótipo.



Fonte: Do Autor.


Obtivemos alguns resultados com este protótipo, porém ele apresentava instabilidade, às vezes sua leitura com o ESP32 apresentava uma saturação no sinal (Figura 4). Então resolvemos utilizar um sensor AD8232, assim nosso segundo protótipo ficou de acordo com a figura 5.

Figura 4 - Leitura Saturada do Sensor.



Fonte: Do Autor.

Figura 5 - Segundo Protótipo com o Sensor AD8232.




Fonte: Do Autor.

A era digital e suas implicações sociais: Desafios e contribuições


Este sensor nos tirou a necessidade de uma fonte simétrica e trouxe resultados mais satisfatórios. Na figura 6 podemos ver uma leitura serial onde não havia contração do músculo, e na figura 7 podemos ver a leitura com a contração.

figura 6 - Leitura sem Contração do Músculo.



Fonte: Do Autor.

figura 7 - Leitura com Contração do Músculo.



Fonte: Do Autor.

A partir da sequência de leituras em série e de todo o processo de aquisição, extração de características e normalização, selecionamos uma parcela das amostras, mais precisamente 24 delas, para o treinamento de modelos de *Machine Learning* utilizando os métodos *Ridge Classifier* e *Random Forest*. Realizamos dois conjuntos de testes: um para fins de validação e outro para fins de teste. Os resultados desses testes estão apresentados nas tabelas 1 e 2, onde podemos observar as diferenças entre cada teste e entre os dois métodos utilizados. Além disso, as matrizes de confusão nas figuras 8, 9, 10 e 11 nos ajudam a identificar os pontos em que nosso treinamento indicou falsos positivos e falsos negativos.

Tabela 1 - Comparação de resultados entre o grupo de amostras com método *Ridge Classifier*

Grupo de Teste	Precisão	Recall	Acurácia
Validação	88%	90%	87%
Teste	95%	95%	95%


Fonte: Do Autor.

Tabela 2 - Comparação de resultados entre o grupo de amostras com método *Random Forest*

Grupo de Teste	Precisão	Recall	Acurácia
Validação	100%	100%	100%
Teste	100%	100%	100%

Fonte: Do Autor.


Figura 8 - Matriz de Confusão com método *Ridge Classifier* utilizando o conjunto de validação.



Fonte: Do Autor.

A era digital e suas implicações sociais: Desafios e contribuições

Figura 9 - Matriz de Confusão com método Ridge Classifier utilizando o conjunto de teste.




Fonte: Do Autor.

Figura 10 - Matriz de Confusão com método Random Forest utilizando o conjunto de validação



Fonte: Do Autor.

Matriz de Confusão com método Random Forest utilizando o conjunto de teste.



Fonte: Do Autor.

Discussão

Os resultados obtidos com o uso do protótipo foram promissores. O protótipo permitiu a medição do sinal EMG dos músculos bíceps durante a prática de exercícios físicos, desempenhando um papel crucial na avaliação da eficácia dos movimentos, análise da fadiga muscular e aprimoramento da performance dos atletas.

Ao analisar os resultados, destacamos que o método *Random Forest* demonstrou uma precisão superior em comparação ao *Ridge Classifier*. No entanto, é importante ressaltar que o *Ridge Classifier* também alcançou uma precisão satisfatória, o que reforça sua viabilidade em termos de aplicabilidade. Essa viabilidade decorre do fato de que o *Ridge Classifier* requer menos recursos computacionais e poder de processamento, tornando-o uma alternativa viável em contextos onde um tempo de resposta pequeno é esperado e onde se tem menos memória e processamento disponível. Notavelmente, a diferença na precisão entre esses dois métodos não se mostrou excessivamente substancial, sugerindo

A era digital e suas implicações sociais: Desafios e contribuições

que, em algumas aplicações, a adoção de um modelo mais complexo, como o *Random Forest*, talvez não seja totalmente justificada.

Esse cenário é especialmente válido em situações como esta, uma vez que essa abordagem oferece vantagens notáveis, como a capacidade de realizar a classificação integralmente dentro do nosso sistema embarcado. Além de simplificar o projeto, essa abordagem proporcionaria uma vantagem significativa, melhorando consideravelmente sua praticidade.

Conclusão

O desenvolvimento do protótipo de um dispositivo *wearable* baseado em um sensor EMG e técnicas de aprendizado de máquina representa uma contribuição significativa para a área de *fitness* e esportes. Esse projeto permite a medição da atividade muscular durante o exercício físico, fornecendo aos atletas uma ferramenta para melhorar a eficácia dos movimentos, analisar a fadiga muscular e otimizar o treinamento.

Além disso, a combinação da tecnologia de sensor EMG com técnicas de aprendizado de máquina possibilitou a análise e interpretação dos dados de forma mais eficiente. Isso nos permitiu uma compreensão mais aprofundada da ativação muscular durante o exercício, podendo gerar *insights* valiosos para otimizar o treinamento e prevenir lesões.

Por fim, é importante ressaltar que esse projeto está em andamento e possui potenciais aplicações em diversas áreas além do esporte e *fitness*. A aquisição de dados de EMG por meio de eletrodos de superfície/gel e o uso de técnicas de aprendizado de máquina podem ser explorados em campos como medicina, reabilitação, ergonomia e ortopedia, ampliando ainda mais o impacto e as possibilidades dessa tecnologia.

Referências

Jayaweera, Pasan. (2021). **Design and Implementation of Electromyography (EMG) based Real-Time Pattern Recognition model for Prosthetic hand Control**. 10.31219/osf.io/rd2cf.

Karlik, Bekir. (2014). **Machine Learning Algorithms for Characterization of EMG Signals**. International Journal of Information and Electronics Engineering. 4. 10.7763/IJIEE.2014.V4.433.

Karthick, P. A., Ghosh, D. M., & Ramakrishnan, S. (2018). **Surface electromyography based muscle fatigue detection using high-resolution time-frequency methods and machine learning algorithms**. Computer Methods and Programs in Biomedicine, 154, 45–56. doi:10.1016/j.cmpb.2017.10.024

Mekruksavanich, S., & Jitpattanakul, A. (2020). **Exercise Activity Recognition with Surface Electromyography Sensor using Machine Learning Approach**. 2020 Joint International Conference on Digital Arts, Media and Technology with ECTI Northern Section Conference on Electrical, Electronics, Computer and Telecommunications Engineering (ECTI DAMT & NCON). doi:10.1109/ectidamtncon48261.2020.9090711

Singh, A., Prakash, B. S., & Chandrasekaran, K. (2016). **A comparison of linear discriminant analysis and ridge classifier on Twitter data**. 2016 International Conference on Computing, Communication and Automation (ICCCA). doi:10.1109/ccaa.2016.7813704

Yousefi, J., & Hamilton-Wright, A. (2014). **Characterizing EMG data using machine-learning tools**. Computers in Biology and Medicine, 51, 1–13. doi:10.1016/j.combiomed.2014.04.018