

Fontos megjegyezni, hogy bár a kapott eredmények kedvezőek és informatívak, a szakirodalomban dokumentált, esetenként orvosi mérőeszközökkel végzett kutatások gyakran magasabb pontossági értékeket érnek el. Ennek egyik oka, hogy a dolgozatban használt mérésekben, egyetlen szenzort használtam (Elemlyo 1.4), ami nem minősül orvosi eszköznek. Ennek köszönhetően nem tudtam olyan pontosan megejteni a méréseimet. Ezentúl az adathalmazom is korlátoosnak tekinthető, mert egyetlen alanyra korlátozódott a mérés, így nem biztosította a legjobb adatbázist a legjobb kategorizálási eredmények elérésére és szélesebb körű következtetések levonására.

Fejlesztésként a jövőben javasolt a szenzor minőségének javítása, esetlegesen több szenzor használata egy mérés alkalmával, ezzel lehetőséget biztosítva a finomabb izomaktivitási jelek megbízhatóbb és pontosabb rögzítésére. A több szenzor még részletesebb információt biztosíthat az izom körüli izomaktivitás mintázatokról.

A jelfeldolgozó egység továbbfejlesztése során különösen érdemes a **valós** idejű feldolgozás lehetőségére összpontosítani. A betanított modellek közül az SVM és a CNN algoritmusok könnyedén optimalizálhatók fix adatstruktúrával MCU-ra, és a már betanított modellek különösen gyorsak, ami előnyös valós idejű alkalmazások esetén. A KNN modell esetében hatékony adatrepresentációra van szükség, hogy gyorsan meghatározható legyen az új pont helye, amihez léteznek hatékony algoritmusok. Emellett a digitális szűrők finomhangolása és a többfokozatú szűrés alkalmazása is hozzájárulhat a jelek tisztaságának javításához, és így a teljes algoritmus teljesítményéhez.

A mérési környezet és az adatgyűjtés is tovább fejleszthető, például lehetséges több alany bevonása, különböző életkorú csoportok és különböző fizikai állapotú személyek részvétele, amellyel nagyobb variabilitást lehetne vinni az adatbázisba, ezzel lehetővé téve az eredmények szélesebb körű általánosíthatóságát.

Érdekes lenne több tanuló algoritmus kipróbálása, a mesterséges intelligencián alapuló fejlettebb algoritmusok alkalmazása, például a mélytanulási modellek további finomhangolása, vagy új architektúrák, mint a rekurzív neurális hálózatok (RNN) vagy a konvolúciós hálózatok kombinált alkalmazása. Az ilyen algoritmusok képesek lehetnek pontosabb mintafelismerésre, és jobban adaptálódnak a komplex, nemlineáris mintázatokhoz, amelyek az EMG adatokban gyakran előfordulnak. Az ilyen módszerek implementálása és finomítása hozzájárulhat az EMG-alapú izomcsoport-elemzés jövőbeli alkalmazhatóságának és hatékonyságának növeléséhez.

4. ÖSSZEGZÉS

Munkám során az eltérő izomcsoportok aktivitásának feltérképezésével foglalkoztam EMG szenzorok és neurális hálózatok segítségével. Ehhez elkészítettem a szükséges adatgyűjtő rendszert és az adatok feldolgozásához szükséges szoftvereket. Hét izomcsoportból mérési EMG adatokat gyűjtöttem, amiket sikeresen használtam fel a tanuló algoritmusaim (CNN, SVM, KNN) betanítására, melyek a minták alapján elfogadhatóan teljesítettek az izomcsoport minták kategorizálásában.

A kapott eredmények alátámasztják, hogy az EMG alapú izomcsoport-elemzés megfelelő jelfeldolgozási technikákkal és gépi tanulási algoritmusokkal kiegészítve, alkalmas az izomcsoportok közötti aktivitási különbségek azonosítására és vizsgálatára. Az általam elért mérések hatékonysága fejleszthető más algoritmusok és pontosabb szűrési eljárásokkal, így gyakorlati alkalmazhatósága később javítható a munkámnak. Ebben a dolgozatban alkalmazott módszerek széles körben hasznosak lehetnek olyan iparágak számára, ahol fontos az izomaktivitás mérése és az izomcsoportok pontos megkülönböztetése. Az izomcsoportok mozgásainak elkülönítése hasznos lehet a robotizált protézisek alkalmazása, sportteljesítmények mérése, sportolók edzése során. Az EMG alapú elemzések lehetőséget adnak arra, hogy az izomaktivitás pontosabb és személyre szabottabb módon váljon mérhetővé, amely új perspektívát nyithat a rehabilitáció, sport, robotizált protézisek és az ergonómia területén.

Összegezve elmondhatom, hogy sikerült megvalósítanom egy adatgyűjtő rendszert ArduinoUno és egy Elemyo 1.4 EMG szenzor segítségével, majd ezt felhasználva hét izomcsoportból elfogadható minőségű EMG adathalmazt gyűjtenem. Ezen adatokat feldolgoztam különféle szűrési technikákkal (Butterworth, MA), hogy megfelelő minőségű legyen a tanuló algoritmusaim számára. Ezt követve három tanuló algoritmust (CNN, SVM, KNN) implementáltam, amelyeknél aztán megvizsgáltam, hogy milyen hatékonysággal tudják feldolgozni az adataimat.


Az izomcsoportok közötti aktivitási különbségek vizsgálata az élet számos területén kiemelt fontossággal bírhat, erre alkalmas lehet az általam leírt és kipróbált módszer, illetve később annak továbbfejlesztett változatai.

5. IRODALOMJEGYZÉK


- (2019). Forrás: seeedstudio.com: <https://www.seeedstudio.com/blog/2019/12/29/what-is-emg-sensor-myoware-and-how-to-use-with-arduino/> (2024.11.10.)
- Bekir, K. (2014). Machine Learning Algorithms for Characterization of EMG Signals. International Journal of Information and Electronics Engineering. doi: 10.7763/IJIEE.2014.V4.433 (189-194 oldal)
- Chaoming, F., Bowei, H., Yixuan, W., Jin, C., & Shuo, G. (2020). EMG-Centered Multisensory Based Technologies for Pattern Recognition in Rehabilitation: State of the Art Challenges. doi:10.3390/bios10080085 (1-23)
- Graupe, D. (2013). Principles of Artificial Neural Networks 3rd Edition. 5 Toh Tuck Link, Singapore 596224: World Scientific Publishing Co. Pte. Ltd. (5-25 oldal)
- Haryanto, T., Sitanggang, S. I., Agmalara, A. M., & Rulaningtyas, R. (2020). The Utilization of Padding Scheme on Convolutional Neural Network for Cervical Cell. International Conference on Computer Engineering, Network, and Intelligent Multimedia (CENIM). doi:10.1109/CENIM51130.2020.9297895 (34-38 oldal)
- Himani, B., & Mahesh H., P. (2012). A Review on Support Vector Machine for Data Classification. International Journal of Advanced Research in Computer Engineering & Technology (IJARCET). (185-188 oldal)
- Jamal, Z. M. (2012). Signal Acquisition Using Surface EMG and Circuit Design Considerations for Robotic Prosthesis. Forrás: <http://dx.doi.org/10.5772/52556> (434-443 oldal)
- Jay, M., Lyn, D., & Julie, K. (2016). Easy EMG A guide to Performing Nerve Conduction Studies and Electromyography. Elsevier Inc. (1-13, 17-19 oldal)
- Jiajia, W., Xiaoou, L., & Z. Jane, W. (2019). sEMG Signal Processing Methods: A Review. doi: 10.1088/1742-6596/1237/3/032008 (1-5 oldal)
- Kelemen, A. (2016). Jelfeldolgozás és számítógépes mérés technika. (8-16, 25-16 oldal)
- Lopez-Bernal, D., Balderas, D., Ponce, P., & Molina, A. (2021). Education 4.0: Teaching the Basics of KNN, LDA and Simple Perceptron Algorithms for Binary Classification Problems. Forrás: <https://doi.org/10.3390/fi13080193> (1-10)
- Michell, A. W. (2013). Understanding EMG. United Kingdom: Oxford University Press. (9-16 oldal)
- Miftachul, U. (2019). Signal Classification and Electromyography (EMG) Instrumentation Design as Basic Electronic Control System. Journal of Physics: Conference Series. doi: 10.1088/1742-6596/1569/3/032081 (1-5 oldal)

- Mohammed, Z. A.-F., Abduladhem, A. A., & Abbas, M. (2010). A k-Nearest Neighbor Based Algorithm for Human Arm Movements Recognition Using EMG Signals. Iraqi Journal for Electrical And Electronic Engineering. Forrás: https://www.researchgate.net/publication/232322008_A_k-nearest_neighbor_based_algorithm_for_human_arm_movements_recognition_using_EMG_signals (2024.10.20.)
- Mokaya, F., Nguyen, B., Kuo, C., Jacobson, Q., Rowe, A., & Pei, Z. (2023). MARS: A Muscle Activity Recognition System Enabling Self-configuration Musculoskeletal Sensor Networks. doi: 10.1145/2461381.2461406 (191-200 oldal)
- Moritani, T., Stegeman, D., & Merletti, R. (2004). Basic physiology and biophysics of EMG signal generation. doi: 10.1136/jnnp.2005.069211 (32-35 oldal)
- NIST/SEMATECH e-Handbook of Statistical Methods. (dátum nélk.). Forrás: <https://www.itl.nist.gov/div898/handbook/prc/prc.htm> (2024.11.02.)
- Peter, K. (2005). The ABC of EMG. (4-11, 15-17, 21-29 oldal)
- Phil, K. (2017). MATLAB Deep Learning With Machine Learning, Nerual Networks and Artificial Intelligence. (121-129 oldal)
- Sarcevic, P. (2019). Mérésadatgyűjtés, jelfeldolgozás. Szeged. (24-44 oldal)
- Shojaei, M. (dátum nélk.). electropeak.com. Forrás: <https://electropeak.com/learn/interfacing-emg-muscular-signal-sensor-with-arduino/> (2024.09.10.)
- Sokolova, M., & Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks. Information Processing & Management, 427-437. Forrás: <https://doi.org/10.1016/j.ipm.2009.03.002>. (427-435 oldal)
- Wilcox, R. R. (2002). Understanding the Practical Advantages of Modern ANOVA Methods. Journal of Clinical Child & Adolescent Psychology. Forrás: http://dx.doi.org/10.1207/S15374424JCCP3103_12 (399-410 oldal)
- www.biosourcesoftware.com. (2022. December 2024.10.10.). Forrás: <https://www.biosourcesoftware.com/post/bcia-essential-skills-emg-sensor-placement> (2024.10.10.)
- www.docs.arduino.cc. (dátum nélk.). Forrás: <https://docs.arduino.cc/hardware/> (2024.10.10.)
- www.educba.com. (dátum nélk.). Forrás: <https://www.educba.com/kernel-methods/> (2024.10.15.)
- www.elemyo.com. (dátum nélk.). Forrás: https://elemyo.com/support/datasheet_lib (2024.06.20.)


MELLÉKLETEK



1. Melléklet: Tanuló algoritmus modellek és filterek kombinációinak eredményei



2. Melléklet: ANOVA eredmények



3. Melléklet: Izomcsoportok EMG jelei, próbamérések szemléltetése