

Rozdział 4

Środowisko symulacyjne Matlab w analizie sygnałów EEG i EMG w celach klasyfikacji poleceń mentalnych

Dawid Pawuś, Szczepan Paszkiel*

Streszczenie. Artykuł przedstawia opracowany system ekspercki służący do klasyfikacji poleceń mentalnych na podstawie sygnałów EEG oraz weryfikacji ich „czystości” poprzez analizę równoległego sygnału EMG. System został zaprojektowany i przetestowany w środowisku Matlab-Simulink, z wykorzystaniem zestawu Emotiv EPOC Flex Gel do pomiaru EEG oraz MyoWare Muscle Sensor do EMG. Kluczowym aspektem badań było zapewnienie, aby polecenia wydawane przez użytkownika nie były wynikiem aktywności mięśni, co jest szczególnie istotne dla osób sparaliżowanych. Zastosowano metodę kroczącego całkowania sygnału EEG i binarnej weryfikacji aktywności mięśni. System wykorzystuje sieć neuronową o złożonej strukturze do klasyfikacji danych EEG. Wyniki potwierdzają skuteczność proponowanego rozwiązania w odróżnianiu czystych poleceń mentalnych.

Słowa kluczowe: EEG, EMG, polecenia mentalne, Matlab, klasyfikacja sygnałów, sieć neuronowa, BCI, system ekspertowy, analiza biosygnałów

Wprowadzenie

Elektroencefalografia (EEG) jest szeroko stosowana w badaniach z zakresu inżynierii biomedycznej, neuronauki i innych (np. Brain-Computer Interface, BCI), a także w analizie snu i wykrywaniu nieprawidłowego funkcjonowania mózgu. Wynika to m.in. z jej nieinwazyjności i stosunkowo niskich kosztów finansowych Bricker (2020); Gao i in. (2019); Gordleeva i in. (2020). Elektromiografia (EMG) to rodzaj badania elektrofizjologicznego pozwalającego na rejestrację impulsów elektrycznych, które są generowane przez aktywność mięśni. W badaniach neuromodulacyjnych EMG jest często wykorzystywane do pomiaru różnych efektów stymulacji w obszarach motorycznych mózgu Browarska i in. (2021); Farina, Merletti i Enoka (2014); Raghu, Sriraam, Temel, Rao i Kubben (2020); Reilly i Lee (2010). Niniejszy artykuł przedstawia badania, które opierały się na analizie nie tylko sygnału EEG, ale także EMG. Co

* Wydział Automatyki, Elektrotechniki i Informatyki, Politechnika Opolska, Prószkowska 76, 45-758 Opole, dawid.pawus@student.po.edu.pl

DOI 10.24427/978-83-68673-08-1_4


więcej, w tym przypadku wykorzystano środowisko symulacyjne Matlab–Simulink. Literatura zawiera badania poruszające tematykę jednoczesnego korzystania z właściwości pomiarów tych sygnałów. Badania nad interfejsami mózg–komputer, a także badań obejmujących projekty z wykorzystaniem sztucznej inteligencji były poruszane w Antoniou i in. (2021); Khan, Aziz, Bilal i Aamir (2019); Pawuś i Paszkiel (2022a, 2022b, 2022c); Qi, Ovr, Li, Marzullo i Song (2021); Sokół, Pawuś, Majewski i Krok (2022); Tortora, Ghidoni, Chisari, Micera i Artoni (2020). Autorzy tych prac poruszali różne kwestie, od systemów BCI, poprzez klasyfikatory i symulacje, po różnego rodzaju zastosowania medyczne i biomedyczne. Celem przeprowadzonych badań było zaprojektowanie systemu klasyfikacji sygnału EEG w sterowaniu robotem mobilnym, przy jednoczesnej weryfikacji czystych poleceń mentalnych za pomocą czujnika dokonującego pomiaru sygnału EMG. Ma to absolutnie kluczowe znaczenie, gdyż osoby sparaliżowane mogą dzięki temu sterować obiektami jedynie za pomocą wygenerowanych zmian w sygnale EEG, bez dodatkowego "wspomagania" ruchami mięśni kończyn.

4.1. Prezentacja komponentów, metodologii, akwizycji danych i systemu

Przedstawione w niniejszej pracy analiza i system klasyfikacji sygnałów EEG oraz EMG składają się z wielu elementów. Surowy sygnał EEG zarejestrowano za pomocą Emotiv EPOC Flex Gel. Akwizycja pomiarów została wykonana przy użyciu specjalnego oprogramowania EmotivPRO. Sygnał EMG poddano z kolei akwizycji za pomocą urządzenia MyoWare Muscle Sensor, które połączone było z Arduino UNO. Ten zestaw zsynchronizowano natomiast z programem Matlab, w którym gromadzono i analizowano zmierzone dane. Oba sygnały (EEG, EMG) poddawane są analizie przez system ekspercki złożony z algorytmów sztucznej inteligencji w postaci sieci neuronowej oraz klasycznego algorytmu do wykrywania artefaktów i aktywacji mięśni ramienia. Postać omawianego systemu przedstawiono na Rysunku 4.1.

Przykładową formę przeprowadzanych badań pokazano na Rysunku 4.2, który obrazuje moment pomiarów sygnałów EEG oraz EMG przez dwie uczestniczki badania. Łączna liczba przebadanych osób wynosiła 10. Taka grupa przebadanych osób umożliwia sprawną ocenę skuteczności algorytmu, a przede wszystkim zaprojektowanie go z określoną odpornością na wahania wartości pomiarowych, które zależą od cech badanych osób. Obecne w urządzeniu Emotiv EPOC Flex Gel 22 elektrody nazwano zgodnie z następującymi nazwami kanałów: Cz, Fz, Fp1, F7, F3, FC1, C3, FC5, FT7, T7, CP5, CP1, CP2, CP6, FT8, FC6, C4, T8, FC2, F4, F8 i Fp2.

Każdy z uczestników testów wykonał 15 pomiarów powtarzalnych sekwencji poleceń mentalnych zawartych w każdej z prób. Pomiar składał się z następujących sekwencji, w których każda trwała kilka sekund: stan neutralny, wyobrażenie ruchu



Rysunek 4.1: Prezentacja zaprojektowanego systemu eksperckiego
Źródło: Pawuś i Paszkiel (2022b).



Rysunek 4.2: Prezentacja przykładowego przebiegu badań
Źródło: Pawuś i Paszkiel (2022b).

ramienia (polecenie mentalne– ruchu robota mobilnego), mrugnięcie prawym okiem (od tej pory każde polecenie ruchu skutkowało ruchem robota w prawo), wyobrażenie ruchu ramienia, mrugnięcie lewym okiem (od tej pory każde polecenie ruchu będzie skutkowało ruchem robota w lewo), wyobrażenie ruchu ramienia, mrugnięcie obojgiem oczu (powrót do stanu początkowego, każde następne wyobrażenie ruchu ramienia oznacza rozkaz ruchu robota do przodu), wyobrażenie ruchu ramienia. W efekcie takiej sekwencji czynności sygnały zebrane na skutek pomiarów trwały około 45 sekund.

W tym samym czasie, gdy dokonywano pomiaru EEG, uczestnik badania miał założone urządzenie MyoWare Muscle Sensor na mięśniu dwugłowym ramienia. Pozwoliło to skutecznie zebrać sygnał EMG, co umożliwiło później weryfikację dotyczącą czystych poleceń mentalnych bez wspomagania dodatkowymi ruchami mięśni. Osoby sparaliżowane nie mają możliwości takich ruchów, w związku z czym badania nad systemem, który wykorzystuje jedynie prawdziwe polecenia mentalne na bazie wyobrażenia ruchu ramienia są niezwykle istotne i warte rozwijania.

Osoby badane poproszono także o zachowanie możliwie najwyższego stopnia koncentracji. Jej brak spowodowałaby zakłócenie przebiegu badań a co za tym idzie uzyskanie nieprawidłowych wyników. Po zebraniu stosownej liczby pomiarów możliwa była ich dalsza obróbka i klasyfikacja przy pomocy sztucznej inteligencji i klasycznych algorytmów Pawuś i Paszkiel (2022b).

4.2. Metoda całkowania i filtracji sygnału EEG

Akwizowany przez headset sygnał EEG jest filtrowany. Surowy sygnał pochodzący z 22 najbardziej kluczowych elektrod nie jest poddawany bezpośredniej klasyfikacji przez zaprojektowany system. Wiązałoby się to ze zwiększoną trudnością powstałą na etapie tworzenia algorytmu, gdyż nieprzefiltrowane przebiegi charakteryzują się długim czasem stabilizacji i stanu nieustalonego w przypadku wzrostu napięcia zmierzzonego przez czujniki. Użyto zatem filtra górnoprzepustowego o częstotliwości próbkowania $f_s = 1000$ Hz i szerokości pasma $f_p = 200$ Hz Pawuś i Paszkiel (2022b). Przeznaczona aplikacja zapewnia próbkowanie sygnału EEG z częstotliwością $f_e = 128$ Hz. Korzystając z tej wiedzy autorzy zaproponowali ponownie podejście wykorzystujące kroczące całkowanie sygnału każdej z elektrod przez okres jednej sekundy. Jest to oryginalne podejście do tematu preklasyfikacji sygnału biomedycznego, jakim jest elektroencefalogram. Przy wykorzystaniu przedstawionej metodyki można sprawnie zaprezentować jej analityczną postać. Zmienna M prezentuje liczbę próbek zawartych w sygnale, natomiast k zawiera wartość pełnych jednosekundowych okresów w sygnale. Dzięki informacji o częstotliwości próbkowania f_e wiadomo, iż przykładowy pięciosekundowy sygnał EEG będzie złożony z $M = 640$ próbek. Dzięki obliczeniom w równaniu 1 wiadomo, że liczba pełnych okresów jednosekundowych, które później zostaną poddane klasyfikacji wynosi $k = 5$. Co istotne, w przypadku przykładowego sygnału trwającego 10.5 sekundy, pod uwagę wziętych zostanie jedynie 10 sekund, a więc pełnych okresów próbkowania o liczbie $M = 1280$ próbek, co da $k = 10$ scałkowanych próbek sygnału. Takie podejście spowodowane jest dbałością o skuteczność i jednoznaczność w interpretacji każdego przebiegu Pawuś i Paszkiel (2022b).

$$k = \frac{M}{128} \quad (4.1)$$

Zmienną S definiuje się dla każdej z elektrod z osobna. W efekcie przyjmują one postać: $S_1 - S_{22}$, co można zaobserwować w niżej przedstawionym wzorze 4.2.

Każda z 22 zmiennych $S_1 - S_{22}$ jest tablicą. W niej gromadzone są wartości wynikające z zastosowania kroczącego całkowania jednosekundowych okresów sygnału EEG każdej z elektrod. Jej górny indeks zawiera $1 - k$ próbkę scałkowanej wartości. Biorąc pod uwagę ten fakt, można wskazać przykładową postać zmiennej S dla dziesięciosekundowego sygnału drugiej elektrody. W takim przypadku $k = 10$, zatem $S_2(1 \dots k)$. Gromadzenie danych w następujący tablicowy sposób jest wygodne i skuteczne w przypadku aplikacji tego typu Pawuś i Paszkiel (2022b).

$$S_{1 \dots 22}^{(1 \dots k)} = \left[\int_{((1 \dots k) - 1) \cdot 128 + 1}^{(1 \dots k) \cdot 128} |E_{1 \dots 22}^{EEG}| \right] \quad (4.2)$$

Zmienna E^{EEG} prezentuje sygnał z poszczególnych elektrod zestawu. Zgodnie ze wzorem 4.2 zauważyć można, że całkowana jest wartość bezwzględna sygnału każdego kanału przez czas trwania 128 próbek. Niniejszy sposób umożliwia zastosowanie kroczącej metody całkowania i zapisu wartości do zmiennych S Pawuś i Paszkiel (2022b).

4.3. Metoda przygotowania sygnału EMG do klasyfikacji

Urządzenie MyoWare Muscle Sensor (EMG) jest oddzielnym zestawem, w wyniku czego nie jest w pełni zsynchronizowane z zestawem Emotiv EPOC Flex Gel (EEG). To z kolei wpływa na zastosowany czas próbkowania, który został dobrany arbitralnie przez projektantów systemu. Warto zwrócić uwagę, że urządzenie służące do pomiaru EMG nie musi dawać sygnału identycznie próbkowanego, jak robi to elektroencefalograf. Nie jest tu też kluczowa dłuższa analiza sygnału. Ważne jest zatem skuteczne i szybkie wykrycie pobudzenia mięśni zobrazowanego poprzez zmierzony sygnał.

$$h = \frac{N}{k} \quad (4.3)$$

Przyjęto, że metoda podziału ciągu zebranych próbek będzie zgodna ze wzorem 4.3. Mając zatem dziesięciosekundowy sygnał EEG o wartości $k = 10$ i sygnał EMG o liczbie $N = 100$ próbek można obliczyć, iż na każdą sekundę sygnału elektroencefalograficznego będzie przypadać $h = 10$ próbek przebiegu EMG Pawuś i Paszkiel (2022b).


$$L^{(1 \dots k)} = \begin{cases} 1, & \text{dla } E_{(1 \dots h) \dots (N-h \dots N)}^{EMG} \geq V_{\max} \\ 0, & \text{dla } E_{(1 \dots h) \dots (N-h \dots N)}^{EMG} < V_{\max} \end{cases} \quad (4.4)$$

Weryfikacja sygnału elektromiograficznego będzie dokonywana binarnie, co przedstawia wzór (4.4). Jako zmienna L zapisywany będzie ciąg wartości 0–1, które oznaczają brak ruchu mięśni ($E_{EMG} < V_{max}$) oraz ich aktywność ($E_{EMG} \geq V_{max}$). Zmienna V_{max} oznacza maksymalne napięcie, dobrane na bazie obserwacji układu, dla którego przyjmowany jest spoczynek mięśni ramienia. Wynosi ono 4,5 V. Można więc podać następujący przykład: w przypadku gdy, choć jedna z próbek przedziału 70–80 sygnału EMG przyjmie wartość większą niż wymienione napięcie, tzn. $E_{70...80}^{EMG} \geq V_{max}$, to $L(8) = 1$. To z kolei bezwzględnie przerwie ewentualne polecenie ruchu robota, nawet w przypadku spełnienia warunków w postaci wyobrażenia ruchu ramienia Pawuś i Paszkiel (2022b).

Wykorzystane podejście ma swoje zalety. Główną z nich jest fakt, iż uniezależnia ono funkcjonowanie systemu od próbkowania urządzenia EMG. Zastosowane rozwiązanie pozwala na dowolne próbkowanie czujnika MyoWare Muscle Sensor, ponieważ będzie ono zależało od zmiennej k , która wpływa na zakres próbek h przypadających na 1 sekundę sygnału EEG Pawuś i Paszkiel (2022b).

4.4. Zasada działania zaprojektowanej sieci neuronowej

Sieć została nauczona w oparciu o zestaw danych uczących: I (input) oraz O (output). Pierwszym z nich był zestaw uczący wejściowy składający się z 22 wejść sieci odpowiadających kanałom pomiarowym sygnału EEG. Zostały one oznaczone jako macierz wzorców o liczbie wierszy $a = 22$. Wartościami wejściowymi były scałkowane jednosekundowe okresy sygnału EEG. Zestaw danych uczących wyjściowych zawarty był natomiast w innej macierzy o liczbie wierszy $b = 2$. Taki stan rzeczy podyktowany jest wymaganiami stawianymi użytej sieci, która realizuje rozpoznawanie sygnału o charakterze binarnym (0–1), tj. wyobrażenie ruchu ramienia lub jego brak Pawuś i Paszkiel (2022b).




Rysunek 4.3: Struktura użytej sieci neuronowej
Źródło: Pawuś i Paszkiel (2022b).


Wzorce uczące wejściowe i wyjściowe obejmowały jednakową liczbę elementów wejściowych i wyjściowych, dobraną metodą prób i błędów. Ustalono, że satysfakcjonujące wyniki daje zestaw złożony z $n = 450$. Rysunek 4.3 obrazuje jednokierunkową sieć neuronową użytą do klasyfikacji okresowo scałkowanego sygnału EEG. Sieć jednokierunkowa, którą zastosowano w ramach przeprowadzonych badań składa się z czterech warstw ukrytych oraz jednej warstwy wyjściowej. Pierwsza warstwa obejmuje funkcję tangensoidalną z 25 neuronami. Druga natomiast jest funkcją logsigmoidalną o dwudziestu neuronach. Trzecia warstwa, składająca się z 15 neuronów to funkcja radialna. Przedostatnia, czwarta funkcja aktywacji, składająca się z 10 neuronów, to funkcja tangensoidalna. Z kolei warstwę wyjściową prezentuje liniowa funkcja aktywacji złożona z dwóch neuronów. Jest ona ściśle powiązana z liczbą wyjść sieci neuronowej. Odpowiada za zsumowanie nieliniowych funkcji aktywacji neuronów [6].

4.5. Wyniki testów

W ramach obecnej sekcji na Rysunkach 4.4 i 4.5 zaprezentowano efekty działania zaprojektowanego systemu klasyfikacyjnego. Przetestowano klasyfikację oraz weryfikację sygnałów EEG oraz EMG przez system ekspercki złożony z klasycznych algorytmów, jak również tych obejmujących sztuczną inteligencję.



Rysunek 4.4: Obserwacja klasyfikacji sygnałów i wyników weryfikacji na robocie
Źródło: Pawuś i Paszkiel (2022b).



Rysunek 4.5: Przykład przerwania sterowania robotem podczas ruchu mięśni ramion
Źródło: Pawuś i Paszkiel (2022b).

Podsumowanie

Przedstawiony w niniejszym rozdziale system daje wiele możliwości rozwoju i pozwala na prowadzenie dalszych badań pod kątem wykorzystania go przez osoby niepełnosprawne. Weryfikacja sygnału EMG umożliwiła sprawdzenie, w jaki sposób będzie działał algorytm w przypadku poleceń mentalnych bez dodatkowych aktywacji mięśni, tak jak miałyby to miejsce w przypadku osób sparaliżowanych. Jest to bardzo ważne, gdyż takie osoby nie mają możliwości poruszania kończynami. Wyniki uzyskane w eksperymencie pozwalają uznać, że zadania postawione przed systemem klasyfikującym scałkowane sygnały EEG oraz weryfikującym ruchy mięśni zostały spełnione.

Bibliografia

- Antoniou, E., Bozios, P., Christou, V., Tzimourta, K. D., Kalafatakis, K., G Tsipouras, M., Giannakeas, N. i Tzallas, A. T. (2021). Eeg-based eye movement recognition using the brain–computer interface and random forests. *Sensors*, 21(7), 2339.
- Bricker, A. M. (2020). The neural and cognitive mechanisms of knowledge attribution: An eeg study. *Cognition*, 203, 104412.
- Browarska, N., Kawala-Sterniuk, A., Zygarlicki, J., Podpora, M., Pelc, M., Martinek, R. i Gorzelańczyk, E. J. (2021). Comparison of smoothing filters' influence on quality of data recorded with the emotiv epoc flex brain–computer interface headset during audio stimulation. *Brain Sciences*, 11(1), 98.

- Farina, D., Merletti, R. i Enoka, R. M. (2014). The extraction of neural strategies from the surface emg: an update. *Journal of Applied Physiology*, 117(11), 1215–1230.
- Gao, Z., Wang, X., Yang, Y., Mu, C., Cai, Q., Dang, W. i Zuo, S. (2019). Eeg-based spatio-temporal convolutional neural network for driver fatigue evaluation. *IEEE transactions on neural networks and learning systems*, 30(9), 2755–2763.
- Gordleeva, S. Y., Lobov, S. A., Grigorev, N. A., Savosenkov, A. O., Shamshin, M. O., Lukoyanov, M. V., Khoruzhko, M. A. i Kazantsev, V. B. (2020). Real-time eeg–emg human–machine interface-based control system for a lower-limb exoskeleton. *IEEE Access*, 8, 84070–84081.
- Khan, M. U., Aziz, S., Bilal, M. i Aamir, M. B. (2019). Classification of emg signals for assessment of neuromuscular disorder using empirical mode decomposition and logistic regression. W: *2019 international conference on applied and engineering mathematics (icaem)* 237–243.
- Pawuś, D., i Paszkiel, S. (2022a). The application of integration of eeg signals for authorial classification algorithms in implementation for a mobile robot control using movement imagery—pilot study. *Applied Sciences*, 12(4), 2161.
- Pawuś, D., i Paszkiel, S. (2022b). The application of integration of eeg signals for authorial classification algorithms in implementation for a mobile robot control using movement imagery—pilot study. *Applied Sciences*, 12(4), 2161.
- Pawuś, D., i Paszkiel, S. (2022c). Bci wheelchair control using expert system classifying eeg signals based on power spectrum estimation and nervous tics detection. *Applied Sciences*, 12(20), 10385.
- Qi, W., Ovrur, S. E., Li, Z., Marzullo, A. i Song, R. (2021). Multi-sensor guided hand gesture recognition for a teleoperated robot using a recurrent neural network. *IEEE Robotics and Automation Letters*, 6(3), 6039–6045.
- Raghu, S., Sriraam, N., Temel, Y., Rao, S. V. i Kubben, P. L. (2020). Eeg based multi-class seizure type classification using convolutional neural network and transfer learning. *Neural Networks*, 124, 202–212.
- Reilly, R. B., i Lee, T. C. (2010). Electrograms (ecg, eeg, emg, eog). *Technology and Health Care*, 18(6), 443–458.
- Sokół, S., Pawuś, D., Majewski, P. i Krok, M. (2022). The study of the effectiveness of advanced algorithms for learning neural networks based on fpga in the musical notation classification task. *Applied Sciences*, 12(19), 9829.
- Tortora, S., Ghidoni, S., Chisari, C., Micera, S. i Artoni, F. (2020). Deep learning-based bci for gait decoding from eeg with lstm recurrent neural network. *Journal of neural engineering*, 17(4), 046011.