

Efektywność klasyfikacji mrugnięcia z wykorzystaniem wybranych sieci neuronowych

Krzysztof Galas¹

¹ *Institut Informatyki, Uniwersytet Kazimierza Wielkiego w Bydgoszczy*

Streszczenie: *Głównym celem badania było porównanie i wykazanie, która z przedstawionych typów sieci neuronowych najlepiej sklasyfikuje pobierany sygnał EEG mierzony przez headset Emotiv EPOC. Przedstawione sieci neuronowe są stosowane w szerokim zakresie przetwarzania danych. Została wybrana sieć splotowa oraz sieć Kohonena. Parametry sieci, takie jak ilość przejść danych uczących w jednej sesji uczącej zostały modyfikowane. Badanie uwzględnia stopień błędu klasyfikacji sygnału przez sieć oraz ilość czasu potrzebna do treningu modelu. Wartością porównywalną jest stosunek czasu treningu do stopnia dokładności klasyfikacji. Otrzymane wyniki zostały przedstawione jako wykresy zależności w/w wartości do parametrów dotyczących uczenia modelu sieci.*

Słowa kluczowe: *Sieci neuronowe, sztuczna inteligencja, headset, BCI, EEG.*

Effectiveness of blink classification using selected neural networks

Abstract: *The main objective of this study was to compare and demonstrate which of the presented neural network types will best classify the extracted EEG signal measured by the Emotiv EPOC headset. The presented neural networks are used in a wide range of data processing. A convolutional network and a Kohonen network have been selected. The network parameters such as number of learning data transitions in one learning session have been modified. The study considers the degree of signal classification error by the network and the amount of time required to train the model. The comparative value is the ratio of training time to classification accuracy. The obtained results are presented as plots of the relation of the above-mentioned values to the parameters concerning the learning of the network model.*

Keywords: *Neural networks, artificial intelligence, headset, BCI, EEG.*

1. Wprowadzenie

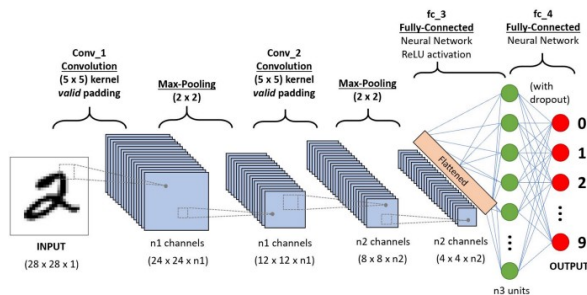
Głównym celem badania jest wybranie najsukcesywniejszej sieci neuronowej w rozpoznawaniu artefaktu, jakim jest mrugnięcie. Celem szczegółowym jest dogłębna analiza wykorzystywanych do tych celów sieci neuronowych oraz ich skuteczności w wykrywaniu artefaktów sygnału EEG. Drugim celem szczegółowym jest wybranie sieci, która zapewni największą skuteczność i efektywność tego procesu.

W pracy zostanie dowiedzione czy wybrana sieć gwarantowała wykrywanie mrugnięć oczami. Sygnał wejściowy zostanie pobrany za pomocą urządzenia EMOTIV EPOC. Pobrane sygnały będą klasyfikowane w dwóch kategoriach: sygnały błędne

(nieposiadające oczekiwanego kształtu) oraz sygnały prawidłowe (z kształtem występującym w trakcie mrugnięcia) przeznaczone do treningu. Mrugnięcia zostaną wyselekcjonowane ręcznie z sygnału treningowego, znany będzie zakres czasowy wystąpienia mrugnięcia w pobranym sygnale. Następnie zostanie przeprowadzony trening sieci neuronowej pod kątem wykrycia anomalii. Wytrenowana sieć zostanie sprawdzona na sygnale testowym. Oczekiwany efekt to zaznaczenie występujących mrugnięć na obrazach. Program zostanie napisany w języku Python z wykorzystaniem dostępnych bibliotek m.in. OpenCV oraz TensorFlow. Na podstawie wyników działania programu zostanie stwierdzone czy wybrana sieć gwarantowała wykrywanie mrugnięć oczami.

2. Wybrane sieci neuronowe

Sieć spłotowa W literaturze nazywana jest konwolucyjną siecią neuronową lub spłotową siecią neuronową. Należy do głębokich sieci neuronowych (ang. Deep Neural Network). Jest to rodzaj sieci składająca się z dużej ilości warstw biorących udział w przetwarzaniu sygnałów co widać na przedstawionym rysunku (Rys. 1). Wykorzystywane są dla złożonych elementów takich jak zdjęcia czy inne obrazy. Skomplikowany pod względem analitycznym sygnał wejściowy można podzielić na jednostkowe zestawy cech, które składają się na dane wejściowe. Cechą charakterystyczną tego rodzaju sieci jest idea początkowego ustalania wag jako liczby o losowych, małych wartościach. Ten zabieg ma za zadanie usprawnić proces uczenia się złożonej w hierarchii sieci neuronowej.



Rysunek 1: Schemat CNN.

Źródło: towardsdatascience.com/a-comprehensive-guide-to-convolutional-neural-networks-the-eli5-way-3bd2b1164a53

Zadaniem sieci jest redukcja obrazu do formy uproszczonej do zminimalizowanej formy, która jednak nie modyfikuje obrazu do formy uniemożliwiającej działanie pozostałych elementów sieci. Neurony w pierwszej warstwie spłotowej jako wejścia przyjmują wartości związane tylko z przetwarzanym obrazem.

Następnym krokiem jest wykonanie operacji uśredniania wartości obrazu. Wykorzystywane są trzy rodzaje redukcji max, min oraz average. W operacji max wybierana jest największa wartość z danego obszaru składającego się na cały obraz. Odpowiednio dobrze działają filtry min, a operacja average - uśrednia cały obszar do jednej wartości. Operacje te powodują odpowiednio zmianę wielkości obrazu. W przypadku, gdy maska wychodzi poza obszar obrazu, puste przestrzenie (brak danych) jest wypełniane zerami.

Przefiltrowany obraz (po wyjściu z każdej ukrytej warstwy neuronowej) otrzymujemy obraz nazy-

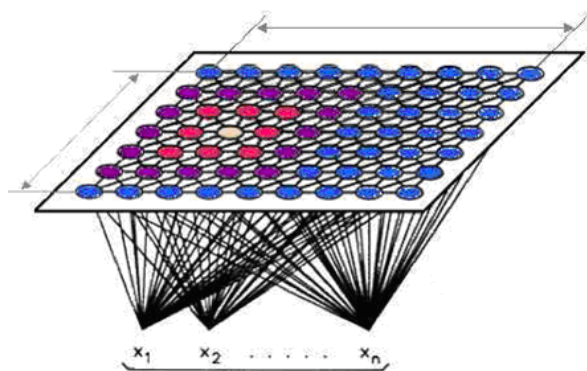
wanym mapą cech. Posiada on trzy atrybuty, takie jak wysokość, szerokość oraz głębia. Sieć neuronowa wykorzystuje wyszukuje filtry najodpowiedniejsze do danego wyodrębnienia cech. Najprostszą cechą do wyodrębnienia jest wykrycie przez filtr krawędzi pionowych oraz poziomych. W rezultacie zastosowania takiego filtra otrzymujemy charakterystyczny obraz o dużym kontraście. Dzięki zastosowaniu filtrów możemy wyodrębnić poziome oraz pionowe linie. Jednak nie zawsze spotyka się linie idealnie pionowe lub poziome, widoczne na rysunku linie ukośne także są rozpoznawane jako przynależne do jednego i drugiego zbioru. Wynika to z tego, że filtr klasyfikuje krótkie odcinki prostej, które mogą być poziome lub pionowe, jednak występować na różnych wysokościach względem siebie. Rezultatem może być ich widoczność po przejściu tych dwóch filtrów.

Sieć Kohonena Kohonen jako pierwszy zastosował uczenie sieci z rywalizacją w literaturze spotyka się również określenie *sieci samoorganizujące się*. Odnosi się to do sieci, których zadaniem jest uczenie się z dowolnych relacji wektorów wejścia i wyjścia. W odróżnieniu od podstawowego uczenia jest to, że wektor wejściowy X zostaje poddany procesowi normalizacji tak, aby jego długość była równa 1 ($\|X\| = 1$).

W tym rodzaju sieci uczeniu nie są poddawane wszystkie neurony wejściowe, tylko ten, który posiada największy sygnał wyjściowy oznaczany $y_m^{(j)}$. Z powodu zastosowania takiego rozwiązania sieci Kohonena nazywane są jako sieci uczone metodą rywalizacji. Przejawia się przez rywalizację neuronów po przejściu sygnału o najwyższy wynik za co jest nagradzany w postaci uczenia czyli zmodyfikowaniu wagi. Dla licznej ilości zróżnicowanych obiektów wejściowych, neurony będą wykazywać inne wartości co skutkuje coraz lepszym dopasowaniem obiektów podobnych do wzorcowego.

Przez pryzmat operowania na wielowymiarowych wartości wejściowych tworzona jest mapa topologiczna, która reprezentuje wynik uczenia się neuronów (odpowiedź na zadane dane). Każdemu z tych wyjść przypisana jest odpowiedź na daną wartość sygnału wejściowego oznacza to, że siła odpowiedzi jest wprost proporcjonalna dla podobieństwa do zestawu uczącego. Mapa topologiczna (Rys. 2) przybiera formę dwuwymiarowej płaszczyzny, których wartości można przedstawiać za pomocą gradientu. Neurony przedstawiono odpowiednio od x_1 do x_n . Dzięki takiej reprezentacji wyników łatwiej jest wyłonić zwycięzcę.

Neurony posiadają własne numery i zostają one



Rysunek 2: Mapa topologiczna sieci Kohonena.

Źródło: [researchgate.net/figure/Kohonen-topological-map-fig8-304161914](https://www.researchgate.net/figure/Kohonen-topological-map-fig8-304161914)

uporządkowane (przedstawia się to za pomocą współczynnika m). Całą metodę uczenia można rozszerzyć do neuronów sąsiadujących ze zwycięzcą przez co usprawniamy metodę uczenia przedstawianą wcześniej. Na przedstawionym schemacie (Rys. 2) widać gradient na warstwie wyjściowej od wyjścia najbardziej dopasowanego poprzez do neuronów sąsiednich. Sąsiedztwo może być określane do 4 lub 8 neuronów najbliższych, mogą mieć kształt zwykłego kwadratu 3×3 (środkowy neuron wyjścia jako zwycięzca). W przypadku czterech sąsiadujących neuronów stosuje się tzw. sąsiedztwo Von Neumanna, gdzie jego zasięg wynosi 2. Gdy znany jest neuron o najwyższej wartości, realizowane jest uczenie realizowane poprzez zmianę wag dla sygnałów wejściowych realizowane jest to wzorem (1). Sam proces jest wielokrotnie powtarzany samoczynnie do uzyskania zadowalających wyników.

$$w_i^{(m)(j+1)} = w_i^{(m)(j)} + \eta^{(j)} h(m, m^*) (\dot{x}_i^{(j)} - w_i^{(m)(j)}) \quad (1)$$

gdzie:

- \dot{x} - wejście podlegające uczeniu,
- m - numer porządkowy neuronu,
- j - liczba iteracji/przejść,
- η - stopień uczenia się w danej iteracji,
- h - stopień nauczania ze względu na odległość od neuronu od zwycięzcy (m^*).

3. EEG oraz artefakty


Sygnal EEG Sygnal EEG (Elektroencefalografia) jest to zebrane przez elektrodę wzbudzenie potencjałów elektrycznych wywoływanych poprzez zmianę potencjałów wywoływanych przez pracę neuronów. Punkt kontaktu elektrody z głową użyt-

kownika lub osób badanych pobiera sygnały nie tylko związane z aktywnością jednego neuronu, tylko z całego obszaru mózgu zaangażowanego w wykonanie jakiejś czynności. Źródłem sygnału jest kora mózgowa, a rozkład elektronów jest determinowany przez określony ich rozkład na powierzchni głowy.

Elektrody o numerach nieparzystych leżą na lewej półkuli głowy, parzyste po prawej.

Litery opisują elektrody według anatomicznych obszarów czaszki:

- Fp - przedczołowe,
- F - czołowe,
- C - centralne,
- T - skroniowe,
- P - ciemieniowe,
- O - potyliczne,
- S - uszne.



30

Rysunek 3: Schemat przedstawiający jednostkową elektrodę pobierającą sygnał.

Źródło: Kolodziej M. „Przetwarzanie, analiza i klasyfikacja sygnału EEG na użytek interfejsu mózg-komputer”.


Na przedstawionym schemacie (Rys. 3) widoczny w układzie pomiarowym jest wzmacniacz, poprawiający wydobywanie zmiany potencjałów wywoływanych przez neurony. Powodem jego zastosowania jest słaba siła sygnału, który musi zostać odebrany przez różne warstwy głowy (skórę, czaszkę, płyn mózgowo rdzeniowy). Sama siła sygnału uzyskanego jest wielkością rzędu kilkudziesięciu miliwoltów.

Można zauważyć, że sygnał nie jest generowany przez typowe neurony, tylko te znajdujące się w warstwie kory mózgowej znajdującej się na powierzchni mózgu. Znajdują się tam komórki piramidalne, które wzbudzone generują skierowaną różnicę potencjałów ułatwiającą odczyt wartości wzbudzenia.

Kora mózgowa dzieli się na obszary odpowiadające za ruchy całego ciała. Poszczególne partie naszego ciała generują aktywność, której siła jest wprost proporcjonalna do obszaru kory mózgowej za nie odpowiedzialną.

Artefakty Wspomniane wcześniej obszary mózgu odpowiedzialne za elementy ruchowe lub zmysłowe nie zaprzestają aktywności, mogą być wykonywane ruchy podświadomie lub być odruchami. Powoduje to powstawaniem, zakłóceń o różnej dłu-

gości. Mogą one być powiązane również z uszkodzeniem diody czy używaniem różnego rodzaju sprzętu elektrycznego. Mogą być związane z zastosowaniem wzmocnienia sygnału lub nawet przesunięcie elektrod.



Rysunek 4: Mrugnięcie numer 1 (od 2 do 3 sekundy).

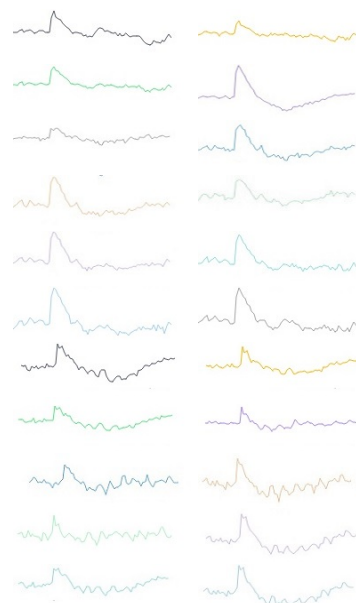
Źródło: Własne.

Analiza częstotliwościowa wskazuje na najwyższą wartość ok. 20 Hz. W obrębie charakterystyki sygnału należy przyjrzeć się wykresów z zapisów poszczególnych elektrod. Zapis występuje cyklicznie o krótkim zakresie czasu, występuje głównie w elektrodzie oznaczonej nazwą F_{p2} . Podczas badania można pominąć całe okno czasowe, które zawiera ten artefakt.

Przy wykorzystywaniu wzmacniacza dla akwizycji sygnału możliwe jest powstawanie fal elektromagnetycznych związanych z przepływem prądu. Mogą one być wychwytywane przez elektrodę, występują charakterystyczne artefakty o dużej częstotliwości związanej z częstotliwością przepływu prądu, posiadają one charakterystykę o wartości 50 Hz (widoczne jest to również na wykresie analizy częstotliwościowej poprzez duży skok w okolicach 50 Hz). Występujący na całej długości zapisywanego sygnału. W tym przypadku może pomóc zaprzestanie badania czy pomiaru aby naprawić ewentualną awarię oraz ponownie przystąpić do pomiaru.


4. Stworzenie zbioru uczącego i kontrolnego

Zbiór mrugnięć Jako zestaw danych wejściowych zostało wytypowanych 32 zdjęć sygnałów (z czego 22 przedstawiające mrugnięcia (rys.5) oraz 10 bez mrugnięcia (rys.6).



Rysunek 5: Zestaw przedstawiający mrugnięcia.

Źródło: własne



Rysunek 6: Zestaw przedstawiający stan neutralny.

Źródło: własne

Zbiorem kontrolnym jest część zbioru z sygnałem, w którym występuje mrugnięcie czyli 10 losowych fragmentów. Do tego zbioru zalicza się też kilka elementów ze zbioru ze stanem neutralnym zawierającym 4 losowo wybrane wycinki sygnału.

5. Topologia sieci

Sieć spłotowa Zgodnie z założeniami sieć spłotowa została dopasowana odpowiednio do potrzeb. Z myślą o znanej wielkości analizowanych fragmentów sygnału pierwsza warstwa wejściowa została stworzona o wielkości wejściowej warstwy 200 x 60 (jako fragment sygnału), później odpowiednio warstwy maxPool o wielkości 2 x 2 i ich odpowiednio zwiększających się wartości wyjściowych, odpowiednio 16, 32, 64. Ostatnia warstwa posiada 512 wejść. Funkcja aktywacji warstwy spłotowej to tak zwana funkcja rectifier (skrót to ReLU). Ostatnim neuronem tej sieci jest neuron o sigmoidalnej funkcji aktywacji ze względu na klasyfikację sygnału jako mrugnięcie lub brak mrugnięcia co zważając na zakres obejmowany przez tę funkcję może klasyfikować jako brak mrugnięcia sygnał w niewielkiej mierze podobny do tego, w którym mrugnięcie występuje.

Sieć Kohonena Sieć została stworzona z 1000 neuronów wejściowych, których metoda rywalizacji została dobrana jako metoda sąsiedztwa trójkątnego. Program ma za zadanie klasyfikację na mapie wielkości 4 x 5 przyporządkować do zbiorów przedstawiony fragment jako mrugnięcie lub stan neutralny.

6. Rezultaty

Wyniki sieci spłotowej Dla przedstawionej wcześniej sieci spłotowej wykonano trzy różne sesje uczące dla różnych ilości przejść danych w jednej sesji uczącej sieci neuronowej. Odpowiednio dla 3 przejść po 10 danych wejściowych, w konfiguracji 5 sesji uczących zawierających 6 pakietów danych oraz 10 sesjach po 3 zdjęcia wejściowe. W dalszej części pracy oraz w zapisie z programów odpowiadają temu nazwy epoch (dane przetwarzane są raz przez całą sieć neuronową), steps per epoch (ilość kroków w sesji uczenia, gdzie podawany jest jeden zestaw danych).

Tabela 1: Dokładność klasyfikacji.

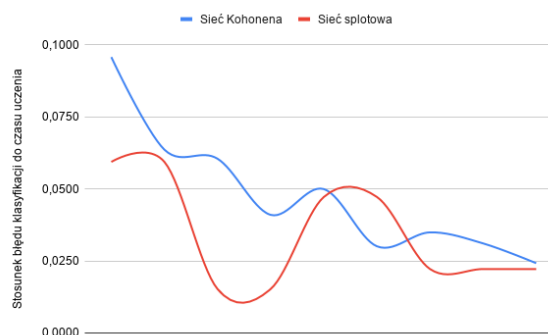
Parametry	Czas uczenia	Dokładność
E:2 S:16	00:00:10	0.5940
E:3 S:10	00:00:45	0.6870
E:5 S:5	00:00:15	0.7087
E:10 S:3	00:00:30	0.6667

Wyniki sieci Kohonena Przeprowadzono pomiary zaczynając od 500 iteracji, zwiększając ich ilość stopniowo o 250. Otrzymane wyniki przedstawione są w tabeli poniżej.

Tabela 2: Wyniki klasyfikacji sieci Kohonena.

Iteracje	Czas uczenia	Dokładność
500	00:00:05	0.4790
750	00:00:08	0.5092
1000	00:00:10	0.6051
1250	00:00:15	0.6154
1500	00:00:15	0.7496
1750	00:00:20	0.6023
2000	00:00:20	0.6988
2250	00:00:25	0.7778
2500	00:00:30	0.7273

Zestawienie wyników Wskazane wyniki w postaci tabel zostały zestawione ze sobą w sposób obliczenia stosunku czasu uczenia do ich dokładności w celu jednoznacznego porównania wyników otrzymanych przez obie sieci. Przedstawiono je w postaci wykresów odpowiadających sieci spłotowej oraz sieci Kohonena. W celu łatwiejszej interpretacji wyników zestawiono je ze sobą na jednym wykresie (rys.7). Aby porównać obie sieci powielono wyniki sieci spłotowej w taki sposób, aby ilość parametrów była równa.



Rysunek 7: Zestawienie wykresów.

Źródło: Własne.

7. Wnioski

Celem głównym przeprowadzonego badania było wybranie najskuteczniejszej sieci neuronowej w rozpoznaniu artefaktu występującego, gdy użytkownik mruga. Podczas tego działania widoczny jest

charakterystyczny zapis sygnału, który odpowiada otwarciu i zamknięciu powieki. Jest to łatwe do wywołania zaburzenie stanu neutralnego. Sygnał został pobrany za pomocą urządzenia EMOTIV EPOC. Podczas pomiaru wprowadzono celowo artefakt, który następnie został odpowiednio przygotowany do analizy przez sieć neuronową.

Celem szczegółowym była analiza wykorzystywanych do tych celów sieci neuronowych oraz ich skuteczności w wykrywaniu artefaktów sygnału EEG. Jako sieci analizujące dostępny typ danych wybrano sieci Kohonena oraz sieć RCNN. Zostały one stworzone na potrzeby eksperymentu zgodnie z ich przeznaczeniem. Kolejnym celem szczegółowym było określenie, która z wytypowanych sieci, osiągnie największą dokładność przy możliwie jak najniższym czasie treningu. Wybrane elementy sygnału zostały przeanalizowane przez obie sieci, a ich osiągi czasowe wraz z dokładnością zostały przedstawione w tabelach. Wyliczona została zależność między długością treningu, a dokładnością wskazania odpowiedniego fragmentu sygnału.

Obie sieci zadziałały poprawnie oraz wykonały zakładane przez Autora zadania. Najlepszym wskaźnikiem założonym w eksperymencie okazała się sieć splotowa, co potwierdza tezę zawartą w pracy dyplomowej.

Literatura

- [1] D. L. Felten, R. F. Józefowicz, J. A. Craig, C. A. Machado, and J. A. Perkins, *Atlas neuroanatomii i neurofizjologii Nettera*. Elsevier Urban & Partner, 2012.
- [2] L. Grad, "Przykład optymalizacji struktury sztucznej sieci neuronowej metodą algorytmów genetycznych," *Biuletyn Instytutu Automatyki i Robotyki*, vol. 12, no. 23, pp. 27–36, 2006.
- [3] N. F. Güler, E. D. Übeyli, and I. Güler, "Recurrent neural networks employing lyapunov exponents for eeg signals classification," *Expert systems with applications*, vol. 29, no. 3, pp. 506–514, 2005.
- [4] M. Jukiewicz, M. Buchwald, and A. Cysewska-Sobusiak, "Usuwanie artefaktów z sygnałów sterujących interfejsem mózg-komputer," *Poznan University of Technology Academic Journals. Electrical Engineering*, 2017.
- [5] M. Kołodziej, R. J. Rak, and A. Majkowski, "Interfejs mózg-komputer – wybrane problemy rejestracji i analizy sygnału EEG," *PRZEGLĄD ELEKTROTECHNICZNY*, 2009.
- [6] A. Krizhevsky, I. Sutskever, and G. H. Hinton, "Imagenet classification with deep convolutional neural networks," *Adv. Neural Inf. Process. Syst.*, vol. 25, 2012.
- [7] R. Leszek, "Metody i techniki sztucznej inteligencji," PWN, Warszawa, 2005.
- [8] D. Matthew and R. Fergus, "Visualizing and understanding convolutional neural networks," in *Proceedings of the 13th European Conference Computer Vision and Pattern Recognition, Zurich, Switzerland*, 2014.
- [9] D. Mikołajewski, E. Tomaszewska, and M. Karczmarek, "Interfejsy mózg-komputer w sterowaniu urządzeniami i systemami mechatronicznymi," *Studia i Materiały Informatyki Stosowanej*, vol. 10, no. 2, pp. 4–9, 2018.
- [10] S. Paszkiel, "Wykorzystanie metody PCA i ICA do analizy sygnału EEG w kontekście usuwania zakłóceń," *Pomiary Automatyka Kontrola*, vol. 59, no. 3, pp. 204–207, 2013.
- [11] S. M. Plis, D. R. Hjelm, R. Salakhutdinov, E. A. Allen, H. J. Bockholt, J. D. Long, H. J. Johnson, J. S. Paulsen, J. A. Turner, and V. D. Calhoun, "Deep learning for neuroimaging: a validation study," *Frontiers in neuroscience*, vol. 8, 2014.
- [12] T. Pracki and D. Pracka, "Elektroencefalografia cyfrowa," *Sen*, vol. 4, pp. 71–77, 01 2004.
- [13] R. Tadeusiewicz, *Sieci neuronowe*. Akademicka Oficyna Wydawnicza Warszawa, 1993, vol. 180.
- [14] R. Tadeusiewicz and M. Szaleniec, *Leksykon sieci neuronowych*. Projekt Nauka. Fundacja na rzecz promocji nauki polskiej, 2015.
- [15] M. D. Zeiler, D. Krishnan, G. W. Taylor, and R. Fergus, "Deconvolutional networks," in *2010 IEEE Computer Society Conference on computer vision and pattern recognition*. IEEE, 2010.
- [16] J. Żurada, M. Barski, and W. Jędruch, *Sztuczne sieci neuronowe: podstawy teorii i zastosowania*. Wydawnictwo Naukowe PWN, 1996.