

doi:10.15199/48.2021.10.26

Rozpoznawanie sygnałów radarowych z wykorzystaniem sieci neuronowych

Streszczenie. Artykuł przedstawia sposób budowy metryk radarów i badanie możliwości zastosowania sieci neuronowych do rozpoznawania sygnałów radarowych. Badania skuteczności sieci neuronowej przeprowadzono w środowisku MATLAB przy użyciu programów Neural Pattern Recognition Tool z wykorzystaniem metody gradientu sprzężonego oraz Neural Fitting Tool z algorytmem Levenberga-Marquardta. Przeprowadzone badania symulacyjne potwierdziły wysoką skuteczność sieci neuronowych w rozpoznawaniu sygnałów radarowych.

Abstract. The article presents the way of construction of radar metrics and the study of the possibility of using the neural networks to recognize radar signals. Research on the effectiveness of the neural network was carried out in the MATLAB environment using the Neural Pattern Recognition Tool program using the coupled gradient method and the Neural Fitting Tool with the Levenberg-Marquardt algorithm. The performed simulation studies confirmed the high efficiency of neural networks in recognizing radar signals.
(Radar signals recognition using neural networks).

Słowa kluczowe: rozpoznawanie radioelektroniczne, metryka radaru, sieci neuronowe.

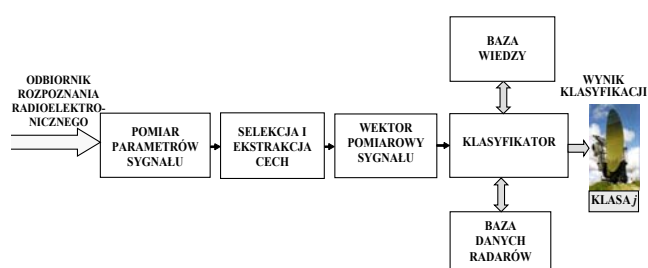
Keywords: radar recognition, radar signature, neural networks.

Wstęp

Współczesne środowisko elektromagnetyczne jest bardzo złożone, ponieważ w urządzeniu rozpoznawczym odbierane są jednocześnie sygnały od wielu różnych nadajników (radarów), a dodatkowo ich parametry mogą się zmieniać w czasie lub w zależności od wykonywanego przez radar zadania. [1].

Istota rozpoznania polega na tym, że identyfikacja źródeł emisji elektromagnetycznej (głównie radarów) następuje wskutek porównania wyników pomiarów podstawowych parametrów sygnału z danymi zawartymi w bazie danych, która jest jednym z podstawowych ogniw skutecznego funkcjonowania systemu rozpoznania radioelektronicznego.

Nowoczesny system rozpoznania radioelektronicznego (ang. ELINT - *Electronic Intelligence*) powinien zapewniać w czasie rzeczywistym identyfikację lub klasyfikację radarów na podstawie pomiaru parametrów czasowych i częstotliwościowych w odbiorniku rozpoznawczym w celu wskazania znanego lub nieznanego źródła emisji sygnałów, Rys. 1.




Rys. 1. System rozpoznawania sygnałów radarowych


Konwencjonalne systemy rozpoznania mierzą podstawowe parametry odbieranego sygnału radarowego, t. j. częstotliwość nośną, amplitudę, szerokość impulsu, czas odbioru impulsów, namiar na źródło emisji i niekiedy również polaryzację sygnału, Rys. 2. Zebrane dane pomiarowe są sortowane na grupy pochodzące od jednego emitera i są następnie wykorzystywane do obliczania parametrów wtórnych radaru, jak np. okres obrotów anteny, częstotliwość powtarzania impulsów, Rys. 3.

W końcowym etapie system rozpoznawczy dopasowuje „sygnatury sygnałów”, utworzone na podstawie wartości średnich poszczególnych parametrów do charakterystyk

znanych emiterów przechowywanych w Bazie danych radarów. Działanie to umożliwia systemowi rozpoznawanie i klasyfikację odbieranych sygnałów radarowych, które mogą mieć wysoki stopień niepewności wynikającej z metod pomiaru i przetwarzania danych pomiarowych.



Rys. 2. Ilustracja procesu pomiarowego sygnału radarowego



Rys. 3. Zobrazowanie w funkcji czasu kolejno odbieranych impulsów pochodzących od trzech różnych radarów (oznaczonych kolorem czerwonym, zielonym i niebieskim)

Budowa metryk (sygnatur) radarów

Ogólnie rozpoznawanie źródeł zagrożeń (emiterów, radarów) polega na przyporządkowaniu odebranego w odbiorniku rozpoznawczym sygnału do odpowiedniej klasy ω_j (j - numer klasy) reprezentującej dany radar w bazie danych (BD). W praktyce nie jest możliwe posiadanie

wystarczającej informacji pozwalającej na opis klas w pełni zgodny z rzeczywistością. Możliwe jest tylko określenie bardziej lub mniej dokładnych odpowiedników tych klas, zwanych metrykami, sygnaturami lub wzorcami klas [7]. Z powodu występowania błędów pomiarowych, zakłóceń losowych w kanale propagacji oraz niestabilności samych parametrów, uzyskiwane wielkości pomiarowe mają charakter losowy.

W wyniku przeprowadzonych pomiarów uzyskuje się wektor pomiarowy \mathbf{x}_i o N składowych, reprezentujących poszczególne parametry sygnału radarowego, gdzie: $\mathbf{x}_i = [x_{i1}, x_{i2}, \dots, x_{iN}]^T$ oznacza i -ty wektor pomiarowy, x_{ik} - wartość k -tej składowej i -tego wektora pomiarowego, ($i = 1, 2, \dots, M$, $k = 1, 2, \dots, N$), M - całkowitą liczbę uzyskanych z pomiarów wektorów pomiarowych, N - liczba parametrów sygnału.

W wyniku wielokrotnych pomiarów sygnałów radarowych od tego samego źródła emisji otrzymamy zbiór wektorów pomiarowych, na podstawie którego można utworzyć w prosty sposób wzorec j -tej klasy W_j , który składa się z wartości średnich oraz odchyłeń standardowych:

$$(1) \quad W_j = \left(\left(\bar{x}_{j1}, \sigma_{j1} \right), \dots, \left(\bar{x}_{jN}, \sigma_{jN} \right) \right), \quad j = \overline{1, L}$$

gdzie: $\bar{x}_{jk} = \frac{1}{n^{(j)}} \sum_{i=1}^{n^{(j)}} x_{ik}^{(j)}$ oznacza wartość średnią k -tego parametru j -tej klasy, σ_{jk} - odchylenie standardowe k -tego parametru j -tej klasy, $x_{ik}^{(j)}$ - wartość k -tego parametru j -tej klasy w i -tym pomiarze, $n^{(j)}$ - liczbę pomiarów parametrów sygnału dla j -tej klasy, L - liczbę klas.

Metoda ta polega na określeniu stałych rozmiarów wzorców klas emiterów, zadawanych tzw. bramkami decyzyjnymi [7]. W przypadku posiadania wystarczającej liczby pomiarów, szerokość bramki decyzyjnej dla każdego parametru sygnału radarowego ustalana jest zwykle jako podwójna lub potrójna wartość odchylenia standardowego, natomiast środek bramki jest wyznaczany przez wartość średnią dla tego parametru, t.j. w postaci:

$$(2) \quad W_j = \left(\left(\bar{x}_{j1}, \pm r\sigma_{j1} \right), \dots, \left(\bar{x}_{jN}, \pm r\sigma_{jN} \right) \right), \quad j = \overline{1, L}$$

gdzie: r przyjmuje wartość 2 lub 3.

Takie - w zasadzie deterministyczne - podejście do problemu tworzenia wzorców klas (metryki radarów) nie pozwala na regulację szerokości bramki decyzyjnej, z czym ściśle związane jest prawdopodobieństwo poprawnej klasyfikacji.

Stosując podejście statystyczne granice bramki decyzyjnej (wzorca parametru radaru) wyznacza się metodą estymacji przedziałowej dla poziomu istotności α . Dla każdego radaru na podstawie próby pomiarowej o liczności n wyznacza się jego wzorec (metrykę) dla jego mierzalnych parametrów sygnału k , ($k = 1, 2, \dots, N$) w postaci przedziałów ufności określonych wzorem:

$$(3) \quad \left\langle \bar{x}_k - \frac{x_\alpha \sigma_k}{\sqrt{n}}; \bar{x}_k + \frac{x_\alpha \sigma_k}{\sqrt{n}} \right\rangle$$

gdzie: \bar{x}_k oznacza wartość średnią parametru k , σ_k - odchylenie standardowe parametru k . Wartość x_α można odczytać z tablic rozkładu normalnego $N(0, 1)$ dla zadanego poziomu istotności α .

W klasycznym podejściu podstawą zakwalifikowania wektora pomiarowego \mathbf{x}_i do danej klasy ω_j ze zbioru L klas jest zawieranie się wszystkich składowych tego wektora w

przedziałach wartości parametrów ustalonych dla danej klasy ω_j , co można zapisać w postaci:

$$(4) \quad \mathbf{x}_i \in \omega_j \Leftrightarrow \bigwedge_k x_k^{(j)} \min \leq x_{ik} \leq x_k^{(j)} \max$$

gdzie: $x_k^{(j)} \min$ oznacza dolną granicę przedziału wartości k -tego parametru j -tej klasy a $x_k^{(j)} \max$ - górną granicę przedziału wartości k -tego parametru j -tej klasy.

W ostatnich latach coraz częściej do rozpoznawania i klasyfikacji różnego rodzaju obiektów [12,13], w tym również źródeł emisji sygnałów radarowych wykorzystuje się sieci neuronowe (ang. *Neural Network*) [4, 5-7, 9-11,14,15]. Ze względu na złożoną i różnorodną strukturę sygnałowych radarów coraz szerszego znaczenia nabierają algorytmy głębokiego uczenia konwolucyjnych sieci neuronowych CNN (ang. *Convolutional Neural Network*) [5,8].

Do oceny prawdopodobieństwa poprawnej klasyfikacji sygnałów radarowych przy użyciu sieci neuronowej zostały wykorzystane dane pomiarowe czterech parametrów: okresu powtarzania impulsów, czasu trwania impulsu, częstotliwości nośnej i okresu obrotów anteny pochodzące od 17 różnych typów radarów [12]. Na podstawie danych pomiarowych zostały obliczone dla tych parametrów przedziały ufności na podstawie zależności (3), Tabela 1.

Tabela 1. Wartości średnie 4 podstawowych parametrów sygnału radarowego dla 17 radarów

Numer radaru	Okres powtarzania impulsów [s]	Czas trwania impulsu [μs]	Częstotliwość nośna [GHz]	Okres obrotów anteny [s]
0	0.877 - 0.878	0.929 - 1.725	2.800 - 2.832	3.97 - 4.00
1	1.229 - 1.230	3.958 - 4.492	1.255 - 1.368	2.85 - 2.87
2	1.223 - 1.223	2.512 - 2.863	1.221 - 1.339	5.80 - 5.96
3	1.223 - 1.223	3.277 - 3.277	1.228 - 1.330	2.86 - 2.88
4	1.248 - 1.250	2.512 - 3.015	1.215 - 1.351	2.86 - 2.87
5	1.247 - 1.250	3.216 - 3.571	1.248 - 1.303	2.85 - 2.88
6	1.250 - 1.252	3.727 - 3.885	1.308 - 1.365	2.87 - 2.88
7	1.751 - 1.752	0.431 - 0.705	3.144 - 3.162	2.81 - 2.92
8	1.251 - 1.252	2.018 - 2.379	2.816 - 2.842	5.04 - 5.08
9	0.768 - 0.768	1.308 - 3.384	2.832 - 2.854	3.96 - 3.99
10	1.738 - 1.739	2.811 - 3.514	1.203 - 1.254	6.02 - 6.07
11	1.775 - 1.778	3.482 - 3.482	1.220 - 1.240	9.72 - 9.76
12	1.856 - 1.858	1.727 - 4.592	3.040 - 3.092	6.03 - 6.09
13	1.905 - 1.905	0.888 - 1.466	2.219 - 2.235	9.85 - 9.91
14	2.150 - 2.150	4.898 - 5.570	1.100 - 1.389	5.41 - 5.53
15	2.225 - 2.228	5.280 - 5.529	1.180 - 1.205	5.44 - 5.47
16	2.224 - 2.226	4.138 - 4.917	1.633 - 1.650	5.43 - 5.59
17	2.375 - 2.375	5.440 - 5.548	1.171 - 1.19	5.42 - 5.76

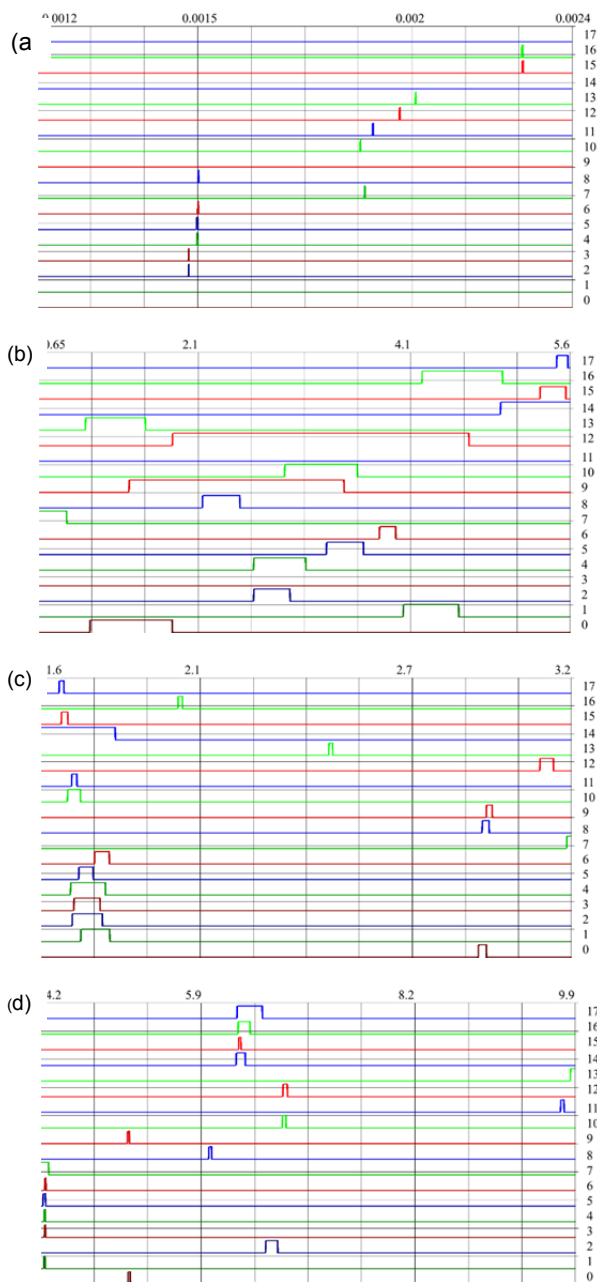
Dla potrzeb sieci neuronowych wartości tych parametrów zostały unormowane do zakresu (0, 1). Zakresy zmian wartości tych parametrów dla badanych radarów, oznaczonych kolejnymi numerami od 1 do 17, zostały przedstawione na rysunku 3. Na podstawie tego zobrazowania widać, że na osiach współrzędnych poszczególnych parametrów występują przedziały wzajemnie pokrywające się.

Najwięcej przedziałów pokrywających się występuje dla czasu trwania impulsów i okresu obrotów anteny. Oznacza to, że w procesie rozpoznawania mogą wystąpić decyzje wieloznaczne, tzn. że dany sygnał może zostać zaliczony jednocześnie do kilku klas.

Wyniki obliczeń symulacyjnych

Do badania skuteczności rozpoznawania sygnałów radarowych została użyta wielowarstwowa sieć neuronowa ze sprzężeniem zwrotnym [10, 12], składająca się z

warstwy wejściowej, jednej warstwy ukrytej i warstwy wyjściowej, Rys. 4. Sieć ta generuje statyczne odwzorowanie między wektorem wejściowym \mathbf{x}_i a wektorem wyjściowym \mathbf{y}_i .



Rys. 4. Ilustracja zakresów zmian: (a) okresu powtarzania impulsów, (b) czasu trwania impulsów, (c) częstotliwości nośnej, (d) okresu obrotów anteny dla 17 radarów

To odwzorowanie jest parametryzowane przez wagi sieci, które są dostosowywane w trakcie procesu uczenia.

Na powyższym rysunku użyte symbole oznaczają: $\mathbf{x} = [x_0, x_1, \dots, x_N]^T$ – wektor wejściowy parametrów sygnału radarowego; x_0 – wektor jednostkowy (równy 1); $\mathbf{y} = [y_1, y_2, \dots, y_M]^T$ – wektor wyjściowy, $w_{ij}^{(1)}$ – waga neuronu w warstwie ukrytej, $w_{ij}^{(2)}$ – waga neuronu w warstwie wyjściowej, v_j – sygnał wyjściowy neuronu z warstwy ukrytej ($j=1,2,\dots,K$); y_j – sygnał neuronu w warstwie wyjściowej, ($j=1,2,\dots,M$).


W badanej sieci neuronowej minimalizuje się funkcję kryterium E , która uwzględnia różnice między aktualnymi

odpowiedziami neuronów a zadanymi wartościami d_i , czyli:

$$(5) \quad E = \sum_{k=1}^p \left(y_i^{(k)} - d_i^{(k)} \right)^2$$

gdzie p oznacza liczbę podanych próbek uczących.

W przypadku bardziej złożonych rozkładów parametrów sygnału radarowego w przestrzeni obserwacji liczba próbek uczących i czas uczenia bardzo szybko zwiększa się. Celem uczenia sieci jest wyznaczenie wag współczynników $w_{ij}^{(1)}$ oraz $w_{ij}^{(2)}$ dla wszystkich warstw sieci w taki sposób, aby dla danego sygnału wejściowego \mathbf{x}_i sygnał wyjściowy \mathbf{y}_i był równy znanej wartości odpowiedzi \mathbf{d}_i przy założonej dokładności pomiarowej, $i = 1, 2, \dots, M$.



Rys. 5. Ilustracja wielowarstwowej sieci neuronowej z jedną warstwą ukrytą

Do badania skuteczności rozpoznawania sygnałów radarowych przy użyciu sieci neuronowych użyto dwa różne programy dostępne w MATLAB, tj. *Neural Fitting Toolbox* bazujący na algorytmie Levenberga-Marquardta oraz *Neural Pattern Recognition Toolbox* z wykorzystaniem metody gradientu sprzężonego [3].

Algorytm Levenberga-Marquardta jest zaawansowanym algorytmem iteracyjnym optymalizacji nieliniowej, łączącym w sobie cechy metody największego spadku oraz metody Gaussa-Newtona w celu wyznaczenia przybliżonej wartości pierwiastka funkcji [2]. Algorytm Levenberga-Marquardta w sieciach neuronowych wykorzystuje, podobnie jak algorytm wstecznej propagacji błędów, funkcję błędu w postaci minimalizacji sumy kwadratów (5). Metoda gradientu sprzężonego służy do rozwiązywania niektórych układów równań liniowych [2]. Kierunki poszukiwań tworzone są w taki sposób aby każdy kolejny kierunek był sprzężony ze wszystkimi poprzednimi.

Do procesu badań symulacyjnych użyto sieci neuronowej zawierającej 20 neuronów w warstwie ukrytej. Do uczenia sieci przeznaczono 80% danych a do sprawdzania poprawności (walidacji) i testowania sieci po 10%. Liczba próbek przeznaczonych do uczenia wynosiła 4576, a liczba próbek przeznaczonych do walidacji oraz liczba próbek do testowania odpowiednio po 572 dla każdego [14].

Dane dla 4 parametrów sygnału radarowego dla każdego z 17 radarów wygenerowano z zadanych przedziałów (Tabela 1), wykorzystując w tym celu rozkład równomierny. Wygenerowane wartości zostały następnie znormalizowane, oddzielnie dla każdego parametru, poprzez podzielenie wygenerowanej wartości przez jego największą wartość z wygenerowanych próbek dla 17 radarów. Wyniki obliczeń symulacyjnych z użyciem algorytmu Levenberga-Marquardta i metody gradientu sprzężonego zawarto w Tabelach 2 i 3.

Tablica 2. Wyniki uczenia sieci dla algorytmu Levenberga-Marquardta

Liczba epok w procesie uczenia	1	2	3	4	5	6
Liczba iteracji	1000	399	1000	308	102	191
Czas uczenia [min]	75	30	81	23	10	17
Prawdopodobieństwo poprawnej klasyfikacji [%]	81,1	86,3	89,3	97,8	99,1	99,4

Na podstawie przeprowadzonych badań symulacyjnych widać, że sieć uczona za pomocą algorytmu Levenberga-Marquardta daje wysokie prawdopodobieństwo poprawnej klasyfikacji. Liczba przeprowadzonych iteracji wpływa na długość czasu trwania uczenia. Otrzymane wyniki były zadowalające, dlatego zakończono proces kolejnego uczenia sieci na szóstej epoce. Współczynnik określający ile procent próbek zostało dobrze dopasowanych w każdym przypadku osiągnął wartość 0,99.

Tablica 3. Wyniki uczenia sieci dla metody gradientu sprzężonego

Liczba epok w procesie uczenia	1	4	5	7	9	10
Liczba iteracji	236	194	248	216	278	123
Czas uczenia [s]	58	42	54	40	66	24
Prawdopodobieństwo poprawnej klasyfikacji [%]	54,4	77,5	77,5	74,5	82,4	91,6

W metodzie gradientu sprzężonego czas uczenia się sieci był znacznie krótszy niż w algorytmie Levenberga-Marquardta. W tej metodzie najdłuższy czas uczenia się sieci wyniósł 66 sekund, natomiast w algorytmie Levenberga-Marquardta najdłuższy czas uczenia się sieci osiągnął 81 minut. Widać również, że w algorytmie Levenberga-Marquardta najmniejsza liczba iteracji (102) wykonanych podczas procesu uczenia została osiągnięta w czasie 10 minut, natomiast w metodzie gradientu sprzężonego ta sama liczba iteracji została wykonana w czasie 24 sekund.

Z porównania obu metod uczenia sieci wynika, że metoda Neural Fitting Tool bazująca na algorytmie Levenberga-Marquardta poprawnie nauczyła sieć i nie było konieczne ponowne jej uczenie. Metoda Neural Pattern Recognition Tool bazująca na metodzie gradientu sprzężonego, mimo że uczenie trwa znacznie krócej, to wyniki uczenia nie są zadowalające, ponieważ z dziesięciu przeprowadzonych badań aż sześć dało błędne wyniki uczenia, choć zauważalna była tendencja malejąca błędów.

Wyniki obliczeń

Przeprowadzone obliczenia pokazały, że metoda oparta o algorytm Levenberga-Marquardta jest dokładniejsza ale wymaga dłuższego czasu uczenia sieci. Sieć konstruowana przy użyciu tej metody poprawnie sklasyfikowała ponad 99% sygnałów wejściowych, natomiast przy użyciu algorytmu Levenberga-Marquardta tylko 91,6%. Otrzymanie poprawnie działającej sieci w metodzie gradientu sprzężonego wymaga ponadto przeprowadzenia wielokrotnego procesu jej uczenia. Wyniki badań symulacyjnych wykazały, że każde kolejne uczenie sieci dawało odmienne rezultaty, znacznie różniące się skutecznością klasyfikacji.

W następnym etapie badań do rozpoznawania radarów na podstawie większej liczby parametrów, zarówno mierzalnych jak i niemierzalnych oraz o różnej postaci ich zapisu, zostaną użyte sieci neuronowe o bardziej rozbudowanej architekturze, w tym konwolucyjne sieci neuronowe.

Przeprowadzone badania dowodzą, że automatyczne rozpoznawanie sygnałów radarowych przy wykorzystaniu sieci neuronowych w roli klasyfikatora, daje dobre rezultaty. Odpowiedni dobór architektury sieci neuronowej i sposobu jej uczenia może znacznie poprawić prawdopodobieństwo poprawnej klasyfikacji.

Podziękowania

Praca została sfinansowana przez Wojskową Akademię Techniczną w ramach projektu UGB 856.

Autor: dr inż. Jan Matuszewski, Wojskowa Akademia Techniczna, Wydział Elektroniki, Instytut Radioelektroniki, ul. gen. S. Kaliskiego 2, 00-908 Warszawa, E-mail: jan.matuszewski@wat.edu.pl
Praca została sfinansowana przez Wojskową Akademię Techniczną w ramach projektu UGB 856.

LITERATURA

- [1] D. Adamy, EW 102. *A Second Course in Electronic Warfare*. Artech House, Boston & London, 2004.
- [2] B. Baron B., Piątek Ł., *Metody numeryczne w C++ Builde*. Helion, 2004.
- [3] M. H. Beale, M. T. Hagan, H. B. Demuth, MatLab. *Neural Network Toolbox. User's Guide*, MathWorks, 2017.
- [4] Ch. A.P. Carter, N. Masse, *Neural Networks for Classification of Radar Signals*, Defence Research Establishment Ottawa, Technical Note 93-33, Nov. 1993, Ottawa, Canada.
- [5] L. Ding, S. Wang, F. Wang and W. Zhang, Specific emitter identification via convolutional neural networks, IEEE COMMUN LETT, vol. 22, no. 12, pp. 2591-2594, 2018.
- [6] M. Elamien Abd Elmagheed, A. Jabar Alzubaidi, Neural Network Algorithm for Radar Signal Recognition, *Int. Journal of Engineering Research and Applications*, www.ijera.com, ISSN: 2248-9622, Vol. 5, Issue 2, (Part -2) February 2015, pp.123-125.
- [7] J. Matuszewski, The methods of class pattern forming in order to emitters recognition [Article@Metody tworzenia wzorców klasy dla celów rozpoznawania źródeł emisji]. *Przegląd Elektrotechniczny*, 84 (2008), nr 5, Warszawa, str. 104-108.
- [8] J. Matuszewski, The Specific Radar Signature in Electronic Recognition System. *Przegląd Elektrotechniczny*, 89 (2013), nr 7, Warszawa, str. 236-239.
- [9] J. Matuszewski, D. Pietrow, Recognition of electromagnetic sources with use of deep neural networks. *12th Conference on Reconnaissance and Electronic Warfare Systems (CREWS), Proceedings of SPIE 11055, 110550D (27 March 2019)*; DOI: 10.1117/12.2524536.
- [10] S. Osowski, *Sieci neuronowe do przetwarzania informacji*; Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa 2006.
- [11] N. Petrov, I. Jordanov, Radar Emitter Signals Recognition and Classification with Feedforward Networks. *17th International Conference in Knowledge Based and Intelligent Information and Engineering Systems - KES2013*, Procedia Computer Science, Vol. 22, 2013, pp. 1192-1200, <https://doi.org/10.1016/j.procs.2013.09.206>.
- [12] T. Pietkiewicz, K. Sikorska-Lukasiewicz, Comparison of two classifiers based on neural networks and the DTW method of comparing time series to recognize maritime objects upon FLIR images. *Proc. SPIE 11055, XII Conference on Reconnaissance and Electronic Warfare Systems, 110550V (27 March 2019)*; doi: 10.1117/12.2524918.
- [13] T. Pietkiewicz T., Porównanie dwóch klasyfikatorów opartych na metodzie DTW i połączonych metodach PCA-LDA do rozpoznawania obiektów morskich na podstawie obrazów FLIR. *Przegląd Elektrotechniczny*, vol. 95, nr 11, 2019, ss. 215-222.
- [14] I. Tomaszewska, Koncepcja i badanie jakości rozpoznawania radarów przy użyciu sieci neuronowych. Praca dyplomowa, Warszawa, WAT, 2015.
- [15] L. Yun, L. Jing-chao, Radar signal recognition algorithms based on neural network and grey relation theory. *Proceedings of 2011 Cross Strait Quad-Regional Radio Science and Wireless Technology Conference*, 26-30 July 2011, Harbin, China, doi: 10.1109/CSQRWC.2011.6037247.