

Badanie jakości predykcji obciążeń elektroenergetycznych za pomocą sieci neuronowych SVM, RBF i MLP

Streszczenie. W pracy porównane zostały metody predykcji obciążeń w małym systemie elektroenergetycznym w Polsce, bazujące na wykorzystaniu jako modeli predykcyjnych sieci neuronowych SVM, RBF i MLP. Symulacje sieci neuronowych zostały przeprowadzone w środowisku MATLAB z uwzględnieniem dwóch zadań prognozy: z wyprzedzeniem jedno i 24-godzinny.

Abstract. This paper compares three methods of load forecasting in a small power system in Poland. The solution is based on application of the SVM, RBF and MLP neural networks. The simulations of neural networks performed in MATLAB were conducted for two tasks of prognosis: one hour ahead and 24-hour ahead. The results have been compared to the naïve prognoses. **Comparison of three methods of load forecasting in a small power system based on neural networks**

Słowa kluczowe: predykcja obciążeń, eksploracja danych, sieci neuronowe, systemy elektroenergetyczne.

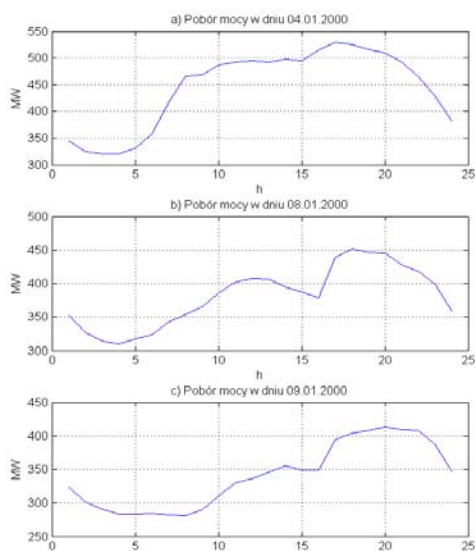
Keywords: load forecasting, data mining, neural networks, electric power systems.

doi:10.12915/pe.2014.08.34

Wstęp

Praca przedstawia metody prognozowania obciążeń elektrycznych w małym systemie elektroenergetycznym w Polsce, bazujące na wykorzystaniu sieci neuronowych SVM, RBF i MLP jako modeli predykcyjnych. Symulacje sieci neuronowych zostały przeprowadzone w środowisku MATLAB z uwzględnieniem dwóch zadań prognozy [2,4]:

- z wyprzedzeniem 1-godzinny,
- z wyprzedzeniem 24-godzinny.



Rys.1. Wykres poboru mocy przykładowego dnia roboczego (a) sobocie (b) oraz niedzieli (c).

Dane do symulacji stanowią wartości poboru mocy elektrycznej w małym systemie elektroenergetycznym dla każdej godziny i doby spośród wszystkich dni z przedziału od 1 stycznia 2000 r. do 31 grudnia 2008 r. (wyrażone w megawatach).

Na rys. 1 przedstawiony został dobowy pobór mocy elektrycznej w badanym systemie elektroenergetycznym dla przykładowego dnia roboczego, soboty oraz niedzieli. Dla dnia roboczego najniższe zużycie, na poziomie 300÷350 MW odnotowuje się dla godzin 1÷6 rano. Z kolei szczyt zużycia przypada na godziny wieczorne, tj. 16÷20 i kształtuje się na poziomie 500÷550 MW.

Odnośząc się do dni weekendowych zauważyć można znaczną różnicę zarówno w kształcie krzywej odniesienia jak i wartości mocy. W przypadku soboty, zużycie spada

względem dnia pracującego zwłaszcza dla godzin popołudniowych oraz wieczornych i kształtuje się na poziomie 370÷450 MW dla godzin 16÷20. Natomiast w przypadku niedzieli pobór mocy spada jeszcze bardziej do wartości 270÷350 MW dla godzin 8÷16 oraz 350÷420 MW dla godzin 16÷20.

Zastosowanie predykcji naiwnej

Jednym z najprostszych systemów prognozy niewymagających specjalnych metod obliczeniowych jest użycie predykcji naiwnej zerowego rzędu przyjmujący jako prognozę wartość znaną dokładnie (element wektora d) z poprzedniego kroku, czyli $y_i = d_{i-1}$. [4,8]. Metoda ta stanowić będzie bazę porównawczą dla opracowanych, bardziej zaawansowanych metod predykcji przy użyciu sztucznych sieci neuronowych. Ograniczając się do miary MAPE (*Mean Absolute Percentage Error*) czyli średniego absolutnego błędu procentowego (d_i – znana wartość obciążenia w kroku i -tym, y_i – wartość prognozowana dla kroku i -tego).

$$(1) \quad MAPE = \frac{1}{n} \left(\sum_{i=1}^n \frac{|d_i - y_i|}{d_i} \right) \cdot 100\%$$

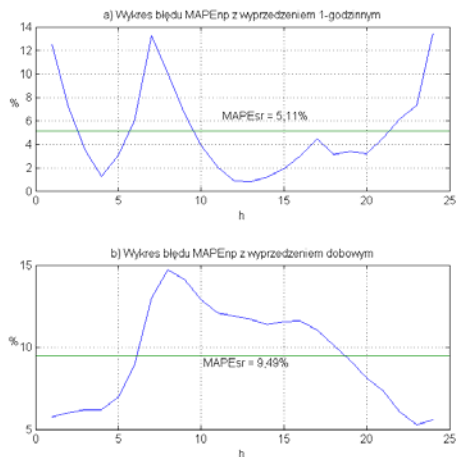
błąd naiwnej prognozy będzie wyrażony wzorem:

$$(2) \quad MAPE_{np} = \frac{1}{n-1} \left(\sum_{i=2}^n \frac{|d_i - d_{i-1}|}{d_i} \right) \cdot 100\%$$

Błąd ten może odnosić się do wyprzedzenia (kroku prognozy) – całej doby lub wyprzedzenia 1-godzinnego. W obu przypadkach zakładając będziemy, że prognoza rozpoczyna się od godziny pierwszej w nocy. Na rys. 2 przedstawiony został wykres godzinny błędu MAPE prognozy naiwnej dla 24 godzin doby z wyprzedzeniem 1-godzinnym (rys. 2a) oraz z wyprzedzeniem dobowym (rys. 2b) uzyskany dla całej bazy danych (lata 2000 – 2008) małego systemu elektroenergetycznego.

W przypadku prognozy z wyprzedzeniem 1-godzinnym charakterystyczna jest skokowa zmiana obciążenia o godzinie 8 z rana (prawdopodobnie włączenie na raz wielu odbiorców zakładowych) oraz w godzinach 23–24 (prawdopodobnie wyłączenie „jednoczesne” wielu odbiorców).

To powoduje, że prognoza naiwna generuje wówczas duże błędy. W przypadku wyprzedzenia 1-godzinnego wartość maksymalna błędu MAPE występuje dla godziny 24 i wynosi 13,45%, natomiast wartość minimalna dla godziny 13 (0,84%). Wartość średnia dobowa błędu MAPE w tym rodzaju prognozy wynosi 5,11%.



Rys.2. Wykres błędów MAPE prognozy naiwnej dla poszczególnych godzin doby na całej bazie danych: a) z wyprzedzeniem 1-godzinnym, b) z wyprzedzeniem dobowym.

W przypadku prognozy z wyprzedzeniem dobowym błąd ten przyjmuje wartości skrajne maksymalne dla godziny 8 (14,72%) oraz wartości skrajnie minimalne dla godziny 23 (5,29%). Wartość średnia dobowa błędów prognozy naiwnej, zwłaszcza w odniesieniu do wyprzedzenia dobowego, zmuszają do zastosowania innych bardziej zaawansowanych metod predykcji. W pracy przeanalizowane zostaną metody predykcji bazujące na modelach wybranych sieci neuronowych trenowanych z nauczycielem: SVM, RBF i MLP.

Przygotowanie danych uczących

Ważnym krokiem w tworzeniu modelu neuronowego predykcji jest wygenerowanie danych uczących [3,5,9,10], zwłaszcza określenie składu atrybutów wejściowych (cech prognostycznych). Na podstawie analizy rozkładu danych za ważne uznano czynniki związane z typem dnia: dni robocze (od poniedziałku do piątku) i weekendowe (soboty i niedziele [1,7]). Zakodowano je w postaci binarnej. Uwzględniono również porę roku, do której analizowane dni należą. Dla zakodowania pór roku zostały przyjęte dwa bity: 11 – zima, 01 – wiosna, 00 – lato, 10 – jesień. Najważniejszą pozycję atrybutów wejściowych stanowią obciążenia znane z przeszłości. Dotyczą one przeszłych dni oraz godzin. W przypadku prognozy z wyprzedzeniem godzinnym założono dostępność do danych z poprzedniej godziny. Przy prognozie z wyprzedzeniem dobowym założono dostępność rzeczywistych obciążeń sprzed 24 godzin. Dane wejściowe dla modelu prognostycznego sieci zorganizowane zostały w formie macierzy X_{we} oraz wektora wartości zadanych $dest$. Dla dostępnej bazy danych wynikowa macierz X_{we} ma wymiar 3283×27 . Następnie dokonano normalizacji danych, dzieląc każdą kolumnę macierzy X_{we} i $dest$ przez wartość największą występującą w danej kolumnie.

W przypadku wyprzedzenia dobowego macierz wejściową X_{we} tworzy się podobnie jak dla wyprzedzenia godzinowego. Są to: kod dnia i pory roku oraz znane obciążenia 24-godzinne z dnia poprzedniego. W efekcie dane wejściowe dla modelu neuronowego predykcji zawierają również 27 zmiennych wejściowych, choć inaczej zorganizowanych.

Badanie modeli prognozy w wyprzedzeniem godzinnym.

Sieć SVM

Sieć Support Vector Machine (SVM) zastosowana w rozwiązaniu pracuje w trybie regresji [8] przy z góry zadanej

wartości marginesu tolerancji $\epsilon = 0,01$, wybranego na podstawie wielu wstępnych prób. Wybrano sieć z uniwersalnym nieliniowym typem jądra w postaci jądra gaussowskiego opisanego wzorem:

$$(3) \quad K(\mathbf{x}, \mathbf{x}_i) = \exp\left(-\gamma \|\mathbf{x} - \mathbf{x}_i\|^2\right)$$

gdzie: \mathbf{x}_i jest wektorem podtrzymującym, wybranym spośród wektorów \mathbf{x} uczących przez algorytm uczenia, natomiast γ jest współczynnikiem funkcji gaussowskiej.


Do symulacji użyty został algorytm uczący sieci regresyjnej SVR – (Support Vector Regression) BSVM Platta–Lina. Jest to zmodyfikowany algorytm sekwencyjny, w którym podzadanie drugiego rzędu (dwa mnożniki Lagrange'a) jest rozwiązywane w każdym kroku iteracyjnym. [8].

Ważnym hiperparametrem sieci SVM jest współczynnik regularyzacji C , który ma decydujący wpływ na liczbę wektorów podtrzymujących i w efekcie na zdolności generalizacyjne sieci. Współczynnik ten został dobrany w wyniku wstępnych symulacji, a jego wartość ustalono na 1000. Wartość tego współczynnika decyduje o złożoności wytrenowanej sieci SVM.

Dane uczące sieci zostały dobrane losowo spośród dostępnych w bazie. W uczeniu wykorzystano 2000 par danych, pozostawiając pozostałe 1288 do testowania wytrenowanej sieci.

Skrajne wartości uzyskanych błędów testowania MAPE wynoszą odpowiednio: błąd największy dla godziny 6 równy 1,54% oraz błąd najmniejszy dla godziny 4 wynosi 0,52%. Współczynnik γ przyjęty w symulacji równał się 0,1.

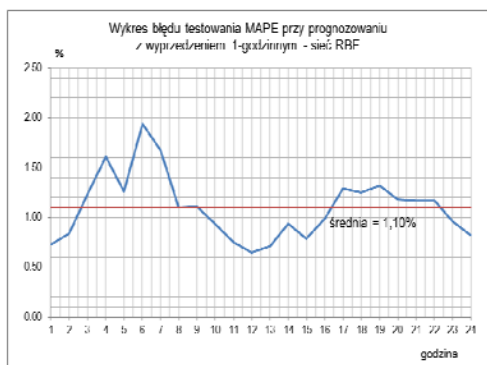
Wykres na rys. 3 przedstawia graficznie błąd testowania MAPE przy predykcji z wyprzedzeniem godzinnym dla sieci SVM. Jak widać gwałtowne zmiany obciążenia systemu obserwowane w godzinach 23–24 oraz w okolicy godziny 8 nie mają istotnego wpływu na wartość błędów MAPE. Dla tych godzin wartość błędów MAPE jest równa praktycznie wartości średnio-dobowej 0,91%. Oznacza to ponad 5,5-krotną redukcję w stosunku do błędów prognozy naiwnej.



Rys.3. Wykres błędów MAPE testowania dla sieci SVM dla predykcji z horyzontem 1-godzinnym.

Sieć RBF

Model sieci RBF zawiera jedną warstwę ukrytą z neuronami typu gaussowskiego [2,8] (odpowiada to jądro gaussowskie w sieci SVM) i warstwę wyjściową liniową zawierającą 24 neurony, każdy odpowiadający za prognozę obciążenia dla odpowiedniej godziny doby. Doborowi podlegają centra funkcji gaussowskich, ich szerokość oraz wagi liniowych neuronów wyjściowych. Dobór położenia centrów wykonany został przy użyciu algorytmu samoorganizacji K-means natomiast adaptacja wag neuronów wyjściowych została przeprowadzona przy użyciu techniki pseudoinwersji i wykorzystaniu dekompozycji SVD.



Rys.4. Wykres błędów MAPE testowania przy prognozowaniu z wyprzedzeniem 1-godzinnym w sieci RBF.

Dane uczące i testujące użyte w symulacji sieci RBF zostały przygotowane identycznie, jak w przypadku sieci SVM. Proces uczenia sieci RBF odbywał się z uwzględnieniem następujących założeń: algorytm uczenia przy zastosowaniu samoorganizacji K-means i wyborze położenia centrów funkcji gaussowskich z liczbą centrów równą 53, dekompozycja SVD w adaptacji wag wyjściowych sieci. Najmniejszy błąd MAPE testowania wystąpił dla godziny 12 i wyniósł 0,65%, z kolei największy błąd testowania występuje dla godziny 6 i wynosi 1,94%. Średnio-dobowa wartość błędów MAPE jest równa 1,10%, a więc większa niż w przypadku zastosowania sieci SVM. Na rys. 4 przedstawiony został wykres błędów MAPE testowania przy prognozowaniu z wyprzedzeniem 1-godzinnym z zaznaczeniem średniej dobowej wartości MAPE. Błąd średni MAPE dotyczący całej doby na danych użytych w testowaniu wytrenowanej sieci wyniósł 1,10%.

Sieć MLP

Sieć perceptronu wielowarstwowego (MLP) należy do najbardziej popularnych rozwiązań neuronowych stosowanych w rozwiązywaniu zadań predykcji [2,9,10]. W odróżnieniu od SVM i RBF, stosuje sigmoidalną funkcję aktywacji [8].


Dane uczące użyte do symulacji sieci MLP zostały przygotowane identycznie, jak w przypadku sieci SVM, z tym wyjątkiem, że wektor wyjściowy zawiera teraz 24 pozycje (podobnie jak w sieci RBF), z których każda oznacza wartość obciążenia jednej z 24 godzin doby.

W symulacji sieci MLP z wyprzedzeniem 1-godzinnym zostały przyjęte następujące parametry:

- liczba wejść warstwy wejściowej: 27;
- liczba neuronów warstwy ukrytej: 9;
- funkcja aktywacji: sigmoidalna jednopolarna;
- miara funkcji celu: wartość średnia sumy kwadratów błędów (MSE – Mean Squared Error);
- metoda ucząca: metoda zmiennej metryki BFGS (Broyden-Fletcher-Goldfarb-Shanno).

Na rys. 5 przedstawiony został wykres błędów MAPE testowania sieci MLP dla prognozy z wyprzedzeniem 1-godzinnym. Podobnie, jak w przypadku sieci RBF, zauważalne są pewne cechy charakterystyczne tego przebiegu.

Błąd testowania przyjmuje najniższą wartość dla godziny 4 i wynosi 0,58%, z kolei wartość najwyższa występuje w przypadku godziny 6 i wynosi 1,63%. Dla szczytu porannego w godzinach 6÷8 występuje stosunkowo duża wartość błędów, która spowodowana jest zmiennością zużycia energii w różnych dniach w roku. Kolejny przedział godzin z wyższą wartością błędów to przedział godzinowy 17÷22 stanowiący szczyt wieczorny.



Rys.5. Wykres błędów MAPE testowania przy prognozowaniu z wyprzedzeniem 1-godzinnym w sieci MLP.

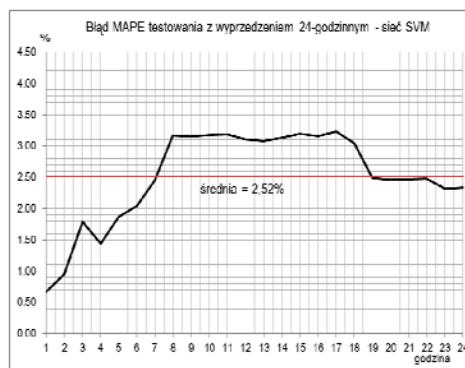
Średnia dobowa wartość błędów MAPE w tym przypadku wyniosła 1,02%. Zatem średni błąd MAPE testowania dla wszystkich 3 prognoz wynosi 1,01%. Stąd wniosek, że najlepszymi właściwościami predykcji cechuje się sieć SVM.

Badanie modeli prognozy w wyprzedzeniu dobowym

Prognoza zapotrzebowania na energię z wyprzedzeniem dobowym przedstawia znacznie bardziej wymagające zadanie predykcji, gdyż sieć prognozująca „widzi” jedynie dane sprzed całej doby. Podobnie jak przy wyprzedzeniu 1-godzinnym, zbadane zostały 3 rodzaje sieci: SVM, RBF oraz MLP.

Sieć SVM

Na rys. 6 przedstawiony został wykres błędów testowania w sieci SVM oraz prognozy naiwnej dla predykcji z horyzontem 24-godzinnym. Sieć SVM wykazuje wyraźnie wyższy błąd testowania dla wszystkich godzin w stosunku do prognozy z wyprzedzeniem 1-godzinnym.




Rys.6. Wykres błędów MAPE testowania dla sieci SVM dla prognozy z horyzontem 24-godzinnym.

Błąd MAPE testowania sieci SVM przyjmuje najmniejszą wartość dla godziny 1 i wynosi 0,67%, z kolei wartość największą – dla godziny 17, wynoszącą 3,23%. Średni dobowy błąd MAPE dla tej sieci jest równy 2,52%. Jest on znacznie mniejszy niż błąd średni prognozy naiwnej (9,49%). Liczba wektorów podtrzymujących wytrenowanej sieci była równa 1067.

Sieć RBF

W przypadku prognozowania z wyprzedzeniem 24-godzinnym sieci RBF, symulacja odbyła się z uwzględnieniem następujących parametrów: algorytm uczenia: samoorganizacja K-means przy wyborze położenia centrów funkcji gaussowskich i dekompozycja SVD w adaptacji wag wyjściowych sieci, liczba centrów: 120.




Rys.7. Wykres błędu MAPE testowania przy prognozowaniu z wyprzedzeniem 24-godzinnym w sieci RBF.

Na rys. 7 przedstawiony został wykres błędu MAPE testowania. Najmniejszy błąd MAPE testowania występuje dla godziny 1 i wynosi 0,67%, z kolei największy błąd testowania występuje dla godziny 16 i jest równy 3,80%. Średnia dobowo wartość błędu MAPE wyniosła dla tej sieci 2,77%. Jest to wartość porównywalna, choć nieco większa niż sieci SVM. Zaletą rozwiązania predykcji za pomocą sieci RBF jest prosta struktura prognozowania. Dla uzyskania prognozy 24-godzinnej wystarczy użycie jednej sieci z 24 wyjściami, każde odpowiedzialne za określoną godzinę doby.

Sieć MLP

W przypadku prognozowania 24-godzinnego warstwa wyjściowa sieci MLP posiada 24 wyjścia (podobnie jak w sieci RBF). Sieć ta zawiera neurony sigmoidalne z wyjątkiem neuronów wyjściowych liniowych. W uczeniu wykorzystano algorytm Levenberga-Marquardta. Algorytm ten należy do najbardziej efektywnych, pozwalając dojść do minimum lokalnego przy najmniejszej liczbie cykli uczących. Zastosowano adaptację typu wsadowego po zaprezentowaniu sieci wszystkich danych uczących.

Na rys. 8 przedstawiono wykres błędu MAPE testowania w predykcji obciążeń z wyprzedzeniem 24-godzinnym. Najmniejszy błąd testowania występuje dla godziny 1 i jest równy 1,01%. Natomiast największy błąd wystąpił dla godziny 16 i wyniósł 3,54%. Średni dobowy błąd testowania dla tej sieci wynosił 2,68%.



Rys.8. Wykres błędu MAPE testowania predykcji obciążeń przy użyciu sieci MLP (prognoza 24-godzinna).

Średni błąd MAPE testowania dla wszystkich 3 prognoz 24-godzinnych wynosi 2,67%. Najlepszymi własnościami predykcji cechuje się sieć SVM (średnia dobowo MAPE równa 2,52%). Pozostałe sieci wykazują podobny, choć nieco wyższy poziom błędów (od 2,68% – sieć MLP do 2,77% – sieć RBF).

Wnioski końcowe

W pracy dokonano porównania trzech sieci neuronowych w zastosowaniu do predykcji obciążeń elektroenergetycznych 24-godzinnych w małym systemie elektroenergetycznym. Do symulacji przeprowadzonych w środowisku MATLAB [6] posłużyły sieci neuronowe SVM, RBF i MLP. Rozważono dwa zadania: predykcję z wyprzedzeniem godzinowym oraz zadanie predykcji z wyprzedzeniem 24-godzinnym.

W obu przypadkach najlepsze wyniki zostały uzyskane przy zastosowaniu sieci SVM. Błąd MAPE testowania sieci dla horyzontu 1-godzinnego kształtował się na poziomie od 0,52% (godziny nocne) do 1,54% (godziny szczytowe dzienne). Błąd MAPE w tym przypadku uśredniony dla całej doby wyniósł w najlepszym przypadku 0,91% (prognoza z użyciem sieci SVM). W przypadku prognozowania z horyzontem 24-godzinnym błąd MAPE testowania sieci dla poszczególnych godzin doby kształtował się na poziomie od 0,67% (godziny nocne) do 3,23% (godziny szczytowe dzienne). Średni dobowy błąd MAPE uzyskany dla najlepszego predyktora SVM wyniósł 2,52%. Pozostałe sieci niewiele odstawały od wyników najlepszego predyktora. Wyniki te można uznać za bardzo dobre. Przewyższają one zdecydowanie pod względem dokładności prognozę naiwną.

Na podstawie powyższych wyników badań można wnioskować że sieci neuronowe stanowią efektywne narzędzie w prognozowaniu obciążeń w systemie elektroenergetycznych, zwłaszcza małych rejonów, gdzie obserwuje się znaczące wahania obciążeń z godziny na godzinę.

LITERATURA

- [1] T. Ciechulski: *Data clusterization in application to the analysis of load distribution in small power system*, 5th AFCEA Student Conference SECON 2013.
- [2] H. S. Hippert, C. E. Pereira, R. C. Souza, *Neural networks for short-term load forecasting: a review and evaluation*, IEEE Trans. on Power Systems, 2001, vol. 16, pp. 44-55.
- [3] N. Kandil, R. Wamkeue, M. Saad, S. Georges, *An efficient approach for short term load forecasting using artificial neural networks*, Electrical Power and Energy Systems, vol. 28, 2006, pp. 525-530.
- [4] Z. Kowalski: *Podstawy prognozowania el-energetycznego*, Łódź 1980.
- [5] P. Mandal, T. Senjyu, N. Urasaki, T. Funabashi, *A neural network based several hours ahead electric load forecasting using similar days approach*, Electrical Power and Energy Systems, vol. 28, 2006, pp. 367-373.
- [6] *Matlab manual, user's guide*, MathWorks, Natick, 2002.
- [7] S. Osowski, K. Siwek: *The Self-organizing Neural Network Approach to Load Forecasting in the Power System*, Neural Networks, 1999. IJCNN '99.
- [8] S. Osowski: *Metody i narzędzia eksploracji danych*, BTC 2013.
- [9] K. Siwek, S. Osowski: *Regularization of neural networks for improved load forecasting in power system*, Electronics, Circuits and Systems, 2001. ICECS 2001.
- [10] A. Sorjamaa, J. Hao, N. Reyhani, Y. Li, A. Lendasse, *Methodology for long-term prediction of time series*, Neurocomputing, vol. 70, 2007, pp. 2861-2869.

Autorzy: mgr inż. Tomasz Ciechulski, Wojskowa Akademia Techniczna, Instytut Systemów Elektronicznych, Zakład Systemów Informacyjno-Pomiarowych, ul. Kaliskiego 2, 00-908 Warszawa, E-mail: tciechulski@wat.edu.pl; prof. dr hab. inż. Stanisław Osowski, Politechnika Warszawska, Instytut Elektrotechniki Teoretycznej i Systemów Informacyjno-Pomiarowych, Zakład Elektrotechniki Teoretycznej i Informatyki Stosowanej, ul. Koszykowa 75, 00-661 Warszawa, E-mail: sto@iem.pw.edu.pl.