

Andrzej STACHNO<sup>1</sup>, Marek SUPRONIUK<sup>2</sup>

<sup>1</sup> POLITECHNIKA WROCLAWSKA, INSTYTUT INFORMATYKI, AUTOMATYKI I ROBOTYKI, ul. Janiszewskiego 11/17, 50-370 Wrocław

<sup>2</sup> WOJSKOWA AKADEMIA TECHNICZNA, INSTYTUT SYSTEMÓW ELEKTRONICZNYCH, ul. gen. Sylwestra Kaliskiego 2, 00-908 Warszawa 49

## Prognozowanie kolejnych wartości pomiarowego szeregu czasowego z zastosowaniem sztucznych sieci neuronowych i funkcji trygonometrycznych

Mgr inż. Andrzej STACHNO

Pracownik Instytutu Informatyki, Automatyki i Robotyki Wydziału Elektroniki Politechniki Wrocławskiej. Zainteresowania naukowe związane z analizą szeregów czasowych obrazujących dane pomiarowe w systemach automatyki budynkowej ze szczególnym uwzględnieniem systemu KNX.



e-mail: andrzej.stachno@pwr.wroc.pl

Dr inż. Marek SUPRONIUK

Pracownik Instytutu Systemów Elektronicznych Wydziału Elektroniki Wojskowej Akademii Technicznej. Zainteresowania naukowe związane są z badaniem struktury defektowej w materiałach półprzewodnikowych, badaniem fotoprzewodnictwa, opisem kinetyki zjawisk zachodzących w materiałach półprzewodnikowych. Dodatkowo zainteresowania związane są z automatyką budynkową.



e-mail: msuproniuk@wat.edu.pl

### Streszczenie

W artykule przedstawiono wyniki badań prognozowania kolejnych wartości pomiarowych szeregów czasowych z zastosowaniem sztucznych sieci neuronowych. Metoda ta umożliwia analizę danych pomiarowych, pochodzących z obiektu, który nie posiada modelu matematycznego. Zbudowanie modelu neuronowego na podstawie szeregu czasowego, odzwierciedlającego dane pomiarowe jest często jedyną metodą przybliżenia sposobu działania obiektu. Wykorzystanie tego modelu do prognozowania zachowania się obiektu w przyszłości może uwzględnić dodatkowo zestaw funkcji trygonometrycznych oraz autorskiej metody WMF wykładania szeregu czasowego. Przeprowadzone badania wykazały znaczący wzrost dokładności prognoz oraz możliwość uniezależnienia ich od wyprzedzenia czasowego.

**Słowa kluczowe:** prognozowanie, szeregi czasowe, sieci neuronowe.

### Forecasting the next value measurement time series with the use of artificial neural networks and trigonometric functions

#### Abstract

The paper presents the results of forecasting subsequent measurement values of the time series (Fig. 1) using artificial neural networks. This method allows the analysis of measurement data [1], coming from an object that does not have a mathematical model. The only representation of the actual state of the output object is approximation of its properties using the neural model, automatically-adapting with respect to the output (Fig. 2). Creating a neural model based on the time series reflecting the measurement data is often the only way to approach the object operation. The use of this model for forecasting the behavior of the object in the future may include an additional set of trigonometric functions (Fig. 7), appropriately presented at the inputs of the neural network. As described in the work, the result of the time series to supplement additional, independent from the object data is to improve the forecast accuracy of successive values of the time series. Taking into account in the forecasting process data smoothing the author's method WMF [1] (Fig. 8), causes a significant increase in the accuracy of the obtained forecast results. The study showed the possibility of using trigonometric functions as input learning network. In addition, there was shown the increase in the accuracy of forecasts of successive values of the time series with different advance and independence of it from historical data (Fig. 10).

**Keywords:** forecasting, time series, artificial neural networks.

## 1. Wprowadzenie

Systemy sterowania automatyką „inteligentnego budynku” wymagają akwizycji i analizy dużej ilości danych pomiarowych. Są one wykorzystywane do procesów monitorowania i sterowania poszczególnymi funkcjami budynku. Przykładem są pomiary temperatury, stężenia gazów, jasności wewnątrz pomieszczeń i na

zewnątrz budynku [1]. Dane te są wykorzystywane w układach sterowania między innymi utrzymujących komfort cieplny w pomieszczeniach. Układy sterowania mogą wykorzystywać bezpośrednio wyniki pomiarów lub korzystać z danych wstępnie przetworzonych. Przykładem wykorzystania danych przetworzonych są predykcyjne systemy sterowania. Wstępne przetworzenie danych pomiarowych poprzez predykcję kolejnych wartości, umożliwiają zastosowanie standardowych regulatorów. W pracy dokonano analizy przykładowych danych pomiarowych napięcia zasilania. Jak wynika z przedstawionego na rysunku 4 przebiegu zmienności, odchylenia od standardowej wartości 230 V, są chwilowe i sięgają 6% wartości deklarowanej przez dostawcę energii elektrycznej. Zastosowanie tego rodzaju zasilania np. do ogrzewania pomieszczenia, skutkują niekontrolowanym wzrostem jego temperatury. Standardowy regulator, wzrost napięcia zasilania uwzględni jako efekt dodatkowego wzrostu temperatury i zareaguje na niego po upływie czasu związanego z inercją spowodowaną przekazywaniem zmian temperatury poprzez elementy pośredniczące (układ wodny, powietrze) po upływie czasu związanego z ich inercją termiczną.

Uwzględnienie zmian napięcia zasilania ogrzewania elektrycznego, jeszcze przed jego faktycznym wystąpieniem, może zdecydowanie poprawić utrzymywanie stałej temperatury pomieszczenia, bez dodatkowych kosztów ponoszonych na dodatkowe zużycie energii elektrycznej.

Zastosowanie sztucznych sieci neuronowych w algorytmach predykcyjnych, umożliwia ich adaptację poprzez dopasowanie parametrów sieci neuronowej, do warunków pracy. Proces uczenia sieci neuronowej polega na podaniu na jej wejścia historycznych wartości szeregu czasowego, a na wyjście wartości prognozowanej. Pozwala to dostosować wewnętrzną strukturę powiązań między neuronami do właściwości obiektu generującego dane (szereg czasowy) [2]. Ponieważ przystosowanie sieci dobrze odzwierciedla zależność pomiędzy prezentowanymi danymi tylko w jednym kroku, konieczne jest cykliczne uczenie sieci neuronowej. Sieć neuronowa poddana procesowi uczenia w każdym cyklu przypisywania danych historycznych do generowanej prognozy, automatycznie dostosowuje swoją wewnętrzną strukturę (wagi powiązań pomiędzy poszczególnymi neuronami) do zmian, jakie następują w kolejnych wartościach szeregu czasowego.


## 2. Opis sposobu prognozowania kolejnych wartości szeregu na podstawie historii i uczenia krokowego

Prognozowanie kolejnych wartości szeregu czasowego na podstawie danych historycznych zakłada prezentację wektora danych obrazujących dane historyczne na wejścia sztucznej sieci neuronowej oraz danych prognozowanych na jej wyjściu [1].

Jako parametry procesu prognozowania przyjęte zostały:

- wielkość wektora wejściowego  $w$  - ilość równoodległych próbek uczących pochodzących z danych historycznych szeregu czasowego przedstawianego sieci w jednym kroku uczenia/prognozowania;
- ilość cykli uczących  $k$  - określająca ilość prezentowanych na wejściach sieci neuronowej wektorów uczących w jednym procesie uczenia dla potrzeb obliczenia pojedynczej prognozy;
- wyprzedzenie prognozy  $p$  - jest ilością kroków wyprzedzających szereg czasowy podczas realizacji prognozy.


Poszczególne parametry prezentowane sieci neuronowej na jej wejściach i wyjściu przedstawione zostały na rysunku 1, sposób prognozowania na rysunku nr 2.



Rys. 1. Sposób przygotowanie danych uczących w postaci szeregu czasowego dla potrzeb uczenia i prognozowania z zastosowaniem sztucznej sieci neuronowej

Fig. 1. The method of preparation of the training data in the form of time series for learning and forecasting using the artificial neural network

W pracy analizie poddane zostały trzy sposoby prognozowania kolejnych wartości szeregu czasowego. Prognozowanie proste kolejnej wartości szeregu z wyprzedzeniem prognozy  $n = \{1,2..10,20\}$  próbek, prognozowanie wygładzonego szeregu czasowego[3] dla tych samych wartości wyprzedzenia. Obie metody wykorzystujące dane historyczne do uczenia sieci neuronowej. A także nowa metoda, wykorzystująca niezależne dane wejściowe wygenerowane na podstawie funkcji trygonometrycznych, uniezależniająca dane prezentowane sieci od danych historycznych a tym samym od wyprzedzenia prognozowanej wartości szeregu czasowego.



Rys. 2. Prezentacja danych wejściowych i wyjściowych sztucznej sieci neuronowej

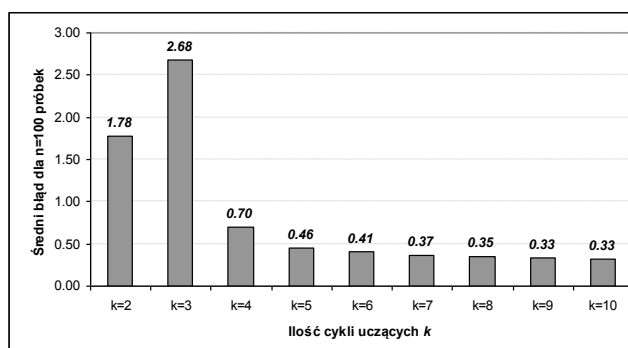
Fig. 2. Presentation of the data input and output of the artificial neural network

Na podstawie badań[1] określono różnorodność zachowania się wewnętrznej struktury sieci w poszczególnych cyklach uczenia się w zależności od typu szeregu czasowego. Konsekwencją klasyfikacji jest ilość cykli uczących podczas prezentacji danych sieci neuronowej. Z tego powodu zbadana została dokładność prognozy dla badanego szeregu czasowego w zależności od ilości danych historycznych prezentowanych na wejściach sieci. Wyniki przedstawione zostały na rysunku nr 3. Na podstawie badań określono minimalną ilość cykli  $k = 10$ , przy której następuje stabilizacja błędu prognozy. Wartość tą przyjęto jako bazową dla pozostałych badań.

Jako kryterium błędu prognozy, przyjęto średni błąd względny dla stu próbek prognozy, określony zależnością:

$$\delta = \frac{1}{100} * \sum_{n=1}^{100} \left( \left| \frac{P_n - R_n}{R_n} \right| \right) * 100\% \quad (1)$$


gdzie:  $\delta$  - średnia wartość błędu dla obliczonych prognoz,  $P_n$  - wartość prognozy w punkcie  $n$ ,  $R_n$  - wartość rzeczywista szeregu w punkcie  $n$ ,



Rys. 3. Średni błąd prognozy dla wyprzedzenia  $n+1$  w zależności od ilości danych prezentowanych  $n-k$  na wejściach sieci neuronowej

Fig. 3. The average forecast error for the timing  $n+1$ , depending on the amount of data presented  $n-k$  at the inputs of the neural network

Przykładowa prognoza, obliczana w kolejnych krokach, w odstępach równych 10 [min] na podstawie historii  $n-10$  próbek uczących z wyprzedzeniem  $n+1$  przedstawiona została na rysunku nr 4.




Rys. 4. Dane rzeczywiste oraz ich prognoza - wartość napięcia dołączonego do stanowiska laboratoryjnego

Fig. 4. Actual data and their forecasts - the voltage supplied to the position of the laboratory

### 3. Prognozowanie proste

Prognozowanie proste polega na przedstawieniu na wejściach sieci neuronowej danych pochodzących z bezpośredniej historii, poprzedzającej wartość prognozowaną.



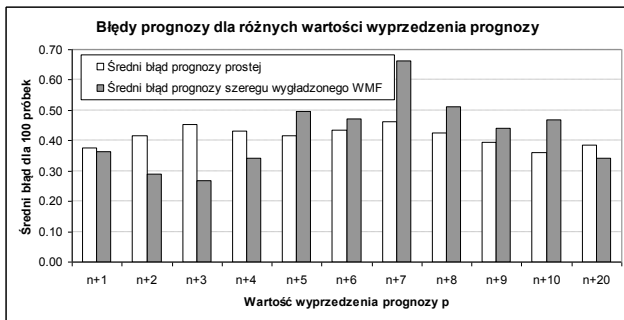
Rys. 5. Błędy prognozy kolejnych wartości szeregu czasowego dla różnych wartości wyprzedzenia  $n+1, n+2.. n+10$  i  $n+20$

Fig. 5. Errors forecast of the successive values of the time series for different values of timing  $n+1, n+2.. n+10$  and  $n+20$

Na rysunku nr 5 przedstawione zostały błędy prognozy kolejnych wartości szeregu czasowego dla różnych wartości wyprzedzenia  $n+1, n+2 \dots n+10, n+20$ . Metoda ta stanowi odniesienie do zaproponowanych w dalszej części modyfikacji szeregu czasowego w części uczącej oraz prognozowanej.

#### 4. Prognozowanie szeregu wygładzonego z zastosowaniem metody Kroczącego Okienka Fouriera WMF

Dokładność prognozy dla szeregu czasowego w znaczący sposób zależy od jego wstępnej klasyfikacji [1]. Szeregi, które w ramach klasyfikacji przyporządkowane są do grupy o gorszych właściwościach prognostycznych powinny być poddane wygładzeniu [4]. Metodą, która redukuje niepożądane właściwości szeregu czasowego, zachowując przy tym możliwie dużo informacji o obiekcie generującym szereg jest metoda WMF (Kroczące Okienko Fouriera). Na rysunku nr 6, przedstawione zostały błędy prognoz dla szeregu wygładzonego metodą MWF z wyprzedzeniem  $n+1, n+2 \dots n+10, n+20$  w zestawieniu z błędami prognozowania prostego.




Rys. 6. Błędy prognoz dla szeregu wygładzonego metodą MWF z wyprzedzeniem  $n+1, n+2 \dots n+10$  i  $n+20$  w zestawieniu z błędami prognozowania prostego

Fig. 6. Errors of forecasts for a series smoothed by the MWF in advance of  $n+1, n+2 \dots n+10$  and  $n+20$  in combination with simple forecasting errors

#### 5. Prognozowanie z zastosowaniem funkcji trygonometrycznych prezentowanych na wejściu sztucznej sieci neuronowej

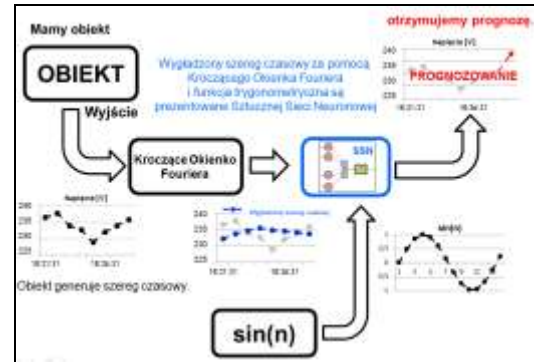
W pracy zaproponowano zamianę danych wejściowych pochodzących z szeregu pierwotnego, na dane obliczone na podstawie funkcji trygonometrycznych. Uzyskano w ten sposób jednolitą strukturę danych uczących, całkowicie niezależnych od danych prognozowanych. Na rysunku nr 7 przedstawiono zestawienie danych wejściowych prezentowanych sieci neuronowej na jej wejściach oraz odpowiadające im próbki pochodzące z szeregu czasowego podawanych w trakcie uczenia na wyjście sieci.



Rys. 7. Zestawienie danych wejściowych i wyjściowych prezentowanych sztucznej sieci neuronowej w trakcie procesu uczenia

Fig. 7. Summary of the input and output data presented the artificial neural network during the learning process


Schemat postępowania podczas przygotowywania danych i uczenia sieci neuronowej, przedstawiony został na rysunku nr 8. Uwzględnione zostały tu zarówno pozyskiwanie danych pomiarowych z obiektu, wstępne ich przetwarzanie poprzez wygładzanie metodą Kroczącego Okienka Fouriera [1] oraz zestawienie danych pomiarowych z szeregiem zbudowanym z funkcji trygonometrycznych.



Rys. 8. Schemat obliczania prognozy na podstawie wygładzonych danych historycznych z szeregu czasowego i funkcji trygonometrycznych


Fig. 8. Schematic of calculating the forecasts based on historical data from the smoothed time series and trigonometric functions

Na rysunku nr 9 przedstawiono zostało porównanie błędów prognozy kolejnych wartości szeregu czasowego dla różnych metod uczenia sieci neuronowej. Warto zauważyć, że zastosowanie niezależnych danych wejściowych do uczenia sztucznej sieci neuronowej nie jest zależne od wyprzedzenia  $p$ . Dzięki temu prognoza z dowolnym wyprzedzeniem będzie miała ten sam przedział błędów. W przypadku prognozowania wykorzystującego dane historyczne, niezależnie od wygładzenia szeregu czasowego, im większe jest wyprzedzenie prognozy tym większy błąd popełnia struktura sieci neuronowej podczas wyznaczania prognozy.



Rys. 9. Porównanie błędów prognozy dla sieci neuronowej na której wejściach prezentowany były dane historyczne szeregu czasowego oraz funkcje trygonometryczne

Fig. 9. Comparison of the forecast errors for the neural network in which the inputs were presented historical data time series and trigonometric functions



Rys. 10. Porównanie błędów prognozy dla różnych typów danych uczących i różnych ilości cykli uczących

Fig. 10. Comparison of the forecast errors for different data types of learners and different number of cycles learners

Analiza wpływu ilości cykli uczących prezentowanych sieci neuronowej wskazuje na dużo lepsze wyniki prognoz podczas uczenia sieci neuronowej z zastosowaniem funkcji trygonometrycznych dla szeregów wygładzonych. Również wraz ze wzrostem ilości cykli uczących, dokładność prognozy tego typu szeregów jest prawie niezmienna i bardzo dobra. Wyniki przedstawione zostały na rysunku nr 10.

## 6. Podsumowanie

Prezentowane, standardowe metody prognozowania kolejnych wartości szeregu czasowego z zastosowaniem sztucznych sieci neuronowych, pozwalają na realizację dokładnych prognoz po wstępnej klasyfikacji typu szeregu czasowego lub jego wygładzeniu. Typ szeregu czasowego zależy od obiektu (zjawiska), który generuje dane otrzymane w trakcie pomiarów. Jest to szczególnie istotne w sytuacji braku możliwości wpływania na obiekt generujący dane (pomiarowy szereg czasowy).

Dokładność prognozy można jednak zwiększyć niezależnie od klasyfikacji szeregu czasowego oraz ewentualnej jego modyfikacji. Bardzo interesujący efekt uzyskano zastępując historyczne dane wejściowe prezentowane sieci neuronowej, szeregami zbudowanymi na podstawie funkcji trygonometrycznych. Uzyskano w ten sposób uniezależnienie prognozy generowanej przez sieć od danych historycznych otrzymując jednocześnie prognozę nie gorszą od zrealizowanej za pomocą metody tradycyjnej. Ponadto, eliminacja historycznych danych prezentowanych jako wejścia sieci neuronowej uniezależniają metodę prognozowania od wyprzedzenia z jakim ma być zrealizowana prognoza. Połączenie metod wygładzania szeregu czasowego metodą Kroczonego Okienka Fouriera (WMF), pozwala na wielokrotne zmniejszenie błędu prognozy oraz zdecydowane poprawienie jej dokładności dla większych wartości wyprzedzenia prognozy.

Możliwość uzupełnienia lub zastąpienia danych historycznych, prezentowanych na wejściach sieci neuronowej, zestawem uniwersalnych danych uczących, zwiększając jednocześnie dokład-

ność prognozy, pozwala na zbudowanie automatycznego systemu prognostycznego. W przypadku prognozy zmian napięcia zasilania systemu ogrzewania budynku, predykcja z wyprzedzeniem większym niż inercja przekazywania wzrostu temperatury elementów oddających ciepło do pomieszczenia, a czujnikami temperatury, umożliwi uwzględnienie tych zmian w układzie sterowania przed ich wystąpieniem, a tym samym zniweluje oscylacje temperatury w budynku oraz obniży koszty związane ze zużyciem energii elektrycznej. Szczególne zastosowanie ma tu zaproponowana metoda prognozowania z zastosowaniem funkcji trygonometrycznych. Jak wykazano w przykładzie, umożliwia ona prognozowanie kolejnych wartości pomiarowego szeregu czasowego ze znacznie większym wyprzedzeniem, niż metody standardowe.

## 7. Literatura

- [1] Stachno A., Jablonski A., Application of Artificial Neuron Networks to Forecasting of Successive Values of a Time Series Representing Environmental Measurements in an Intelligent Building, 14th International Conference Computer Aided Systems Theory, Instituto Universitario de Ciencias y Tecnologías Cibernéticas, Las Palmas de Gran Canaria 2013.
- [2] Peitgen H.-O., Jürgens H., Saupe D.: Granice Chaosu. Fraktale, Wydawnictwo Naukowe PWN, Warszawa 1995, s. 543.
- [3] Stachno A., Suproniuk M. System pomiarowy parametrów środowiskowych z przeznaczeniem do prognozowania w budynkach inteligentnych, Przegląd Elektrotechniczny, R. 89 NR 9/2013, str. 152-155. ISSN 0033-2097.
- [4] Tadeusiewicz R., Korohoda P., Komputerowa analiza i przetwarzanie obrazów, : Wydawnictwo Fundacji Postępu Tele-komunikacji, Kraków 1997, 272 s.

*otrzymano / received: 10.06.2014*

*przyjęto do druku / accepted: 01.08.2014*

*artykuł recenzowany / revised paper*

## INFORMACJE

### Procedura recenzowania artykułu w miesięczniku PAK

1. Wszystkie artykuły naukowe zgłoszone do publikacji w miesięczniku PAK podlegają procedurze recenzowania.
2. Artykuł recenzowany jest przez dwóch niezależnych Recenzentów.
3. Recenzentami są samodzielni pracownicy nauki lub pracownicy ze stopniem naukowym doktora, kompetentni w danym zakresie merytorycznym, spoza ośrodka, z którego jest autor/-rzy.
4. Recenzentów wskazuje redaktor naczelny lub redaktorzy tematyczni.
5. Artykuł w języku innym niż język polski jest recenzowany conajmniej przez jednego recenzenta z instytucji zagranicznej innej niż narodowość autora publikacji.
6. Okres oczekiwania na recenzje wynosi 1 miesiąc.
7. Dla autorów poszczególnych artykułów recenzenci są anonimowi.
8. Recenzent przygotowuje recenzje na formularzu recenzji (2012-formularz-recenzji.doc) opracowanym przez redakcję.
9. Recenzja jest w formie pisemnej i kończy się jednoznacznym wnioskiem co do dopuszczenia artykułu do publikacji lub jego odrzucenia.
10. Nazwiska recenzentów poszczególnych artykułów nie są ujawniane. Pełna lista recenzentów zostaje opublikowana w ostatnim numerze miesięcznika PAK w danym roku oraz na stronie internetowej ([www.pak.info.pl](http://www.pak.info.pl)).
11. Recenzje przechowywane są w redakcji PAK w Gliwicach przez okres 5 lat.

Tadeusz SKUBIS  
Redaktor naczelny Wydawnictwa PAK