

## PORÓWNANIE MODELI GRNN UTWORZONYCH Z WYKORZYSTANIEM MODUŁÓW SIECI NEURONOWYCH PAKIETÓW MATLAB I STATISTICA

### Streszczenie

Przedstawiono wyniki badań wpływu modeli *GRNN*, utworzonych z wykorzystaniem modułów Sieci Neuronowych pakietów MATLAB i STATISTICA, na dokładność estymacji wartości temperatury powietrza atmosferycznego. Stwierdzono, że model neuronowy *GRNN*, powstały na bazie Toolbox Neural Networks v.4 pakietu MATLAB, lepiej aproksymuje temperaturę powietrza atmosferycznego niż modele powstałe na bazie modułu Neural Networks pakietu STATISTICA 6.1. Wśród modeli *GRNN* powstałych na bazie modułu Neural Networks pakietu STATISTICA 6.1 uzyskano lepszą aproksymację temperatury powietrza atmosferycznego, wykorzystując dostępne opcje funkcji związanych z modułem *Projektant sieci użytkownika*.

**Słowa kluczowe:** model regresyjny, sieci neuronowe *GRNN*, MATLAB, STATISTICA

### Wykaz oznaczeń

$err$  - lokalny bezwzględny błąd estymacji temperatury, °C  
 $t$  - czas, h  
 $T$  - temperatura powietrza atmosferycznego, °C

### Wprowadzenie

Modele regresyjne są bardzo często wykorzystywane w symulacjach komputerowych systemów rolniczych. Jednym z częściej stosowanych wielkości w symulacjach komputerowych procesów suszenia i przechowywania jest temperatura powietrza atmosferycznego [Ryniecki, Jayas 1992]. Utworzenie dokładnego modelu regresyjnego tej wielkości jest trudne, ponieważ jest to zmienna stochastyczna, o silnie nieliniowym charakterze. Tworzenie takiego modelu na podstawie funkcji ciągłej często prowadzi do mała

zadowalających wyników, szczególnie jeśli czasowy przedział symulacji wynosi wiele miesięcy. Siejkowski i Markowski [2000] zaproponowali ciągły model dobowych zmian temperatury powietrza, ale przy przyjęciu założeń upraszczających, pomijając nieokresowe i przypadkowe zmiany parametrów powietrza w ich przebiegu dobowym. Nowoczesnymi metodami, stosowanymi zarówno w zagadnieniach estymacji, jak i predykcji temperatury w różnych systemach, są sieci neuronowe. Szczególnie wykazały swoją przydatność w analizie wielkości stochastycznych. Raju [2001] z powodzeniem zastosował algorytmy sieci neuronowych do opisu parametrów pogodowych, m.in. temperatury. Ferreira i in. [2002] wykorzystali sieci neuronowe do przewidywania zmian temperatury w cieplarni. Bodri i Jermak [2003] wykorzystali sieci neuronowe do przewidywania zmian temperatury gruntu. Jednym z rodzajów sieci neuronowych są sieci realizujące regresję uogólnioną (*Generalized Regression Neural Network - GRNN*). Często są to sieci o dwóch warstwach ukrytych. Pierwszą stanowi sieć o radialnych funkcjach bazowych (*Radial Basis Functions – RBF*), natomiast druga jest warstwą liniową. Sieci *GRNN* zazwyczaj mają więcej neuronów niż standardowe sieci jednokierunkowe, wykorzystujące algorytmy wstecznej propagacji błędu [Demuth, Beale 2001; StatSoft, Inc. 2004]. Chtioui i in. [1999], porównując model *GRNN* i standardowy model regresji wielokrotnej opisujący zmiany wilgotności liścia pszenicy odmiany *Spring wheat*, stwierdzili większą dokładność modelu *GRNN*.

W pracy porównano algorytmy uczenia sieci neuronowych *GRNN* wykorzystanych do zagadnienia estymacji wartości temperatury powietrza atmosferycznego.

### **Metodyka badań**

W badaniach wykorzystano pomiary temperatury powietrza atmosferycznego wykonane w ciągu 100 dni 1988 r. w Stacji Meteorologicznej w Olsztynie. Rejestracja pomiarów dokonywana była co 3 godziny.

Ocenie porównawczej poddano trzy modele neuronowe. Pierwszy utworzony na bazie Toolbox Neural Networks v.4 pakietów MATLAB (MathWorks Inc., MA, USA) oraz dwa modele utworzone na bazie

modułu Neural Networks pakietu STATISTICA 6.1 [StatSoft, Inc., Ok., USA]. Wykorzystując Toolbox Neural Networks v.4 pakietów MATLAB, sieć została zaprojektowana i nauczona przy użyciu funkcji *newgrnn*, 100% danych doświadczalnych zostało wykorzystanych w uczeniu sieci [Demuth, Beale 2001].

Wykorzystując program STATISTICA jeden model utworzono w *Automatycznym projektancie* sieci z wszystkimi domyślnymi ustawieniami tego modułu. W tym module testowano 100 sieci, zachowywano 5 najlepszych przy czterech możliwościach wykorzystania opcji: *Twórz zespół z zachowywanych sieci* i *Wybierz podzbiór spośród zmiennych niezależnych*. Natomiast drugi model powstał na bazie modułu *Projektanta sieci użytkownika*, gdzie użytkownik może decydować o pewnych parametrach tworzonej sieci. W tym ostatnim przypadku przetestowano sieci [StatSoft, Inc. 2004; Krzyżak, Rafałłowicz 2000]:

- z uwzględnieniem wyboru i bez uwzględnienia wyboru opcji *Normalizuj zmienne wejściowe i wektory kodowe*,
- centra funkcji bazowych były przepisywane losowo ze zbioru uczącego oraz metodą K-średnich,
- przy różnych wartościach współczynnika wygładzania przyjętych z przedziału [10, 0.0001],
- z uwzględnieniem wyboru i bez uwzględnienia wyboru opcji *Odrzuć wejścia o małej wrażliwości*, przy czym progowa wartość ilorazu wrażliwości wynosiła 1,0.

We wszystkich zastosowanych algorytmach pakietu STATISTICA wykorzystano, domyślnie zaimplementowany w tym pakiecie, automatyczny mechanizm podziału danych na trzy podzbiory: uczący (ok. 50% punktów pomiarowych), walidacyjny (ok. 25% punktów pomiarowych) oraz testowy (ok. 25% punktów pomiarowych) i domyślną liczbę dwóch neuronów w liniowej warstwie sieci. Z przetestowanych sieci (na podstawie modułu *Automatyczny projektant* i *Projektanta sieci użytkownika*) wybrano odpowiednio po jednej najlepszej sieci, gdzie ocena dla pierwszego modułu dokonana została przy wybranej opcji *Zachowaj równowagę między błędem a różnorodnością sieci*, natomiast dla drugiego kryterium oceny był współczynnik korekcji *r Pearsona*.

Jako kryteria oceny trzech wybranych modeli neuronowych przyjęto wartości: minimalną, maksymalną, średnią, odchylenie standardowe z próby (oceniając, na ile te wartości odbiegają od danych eksperymentalnych) oraz współczynnik korelacji  $r$  *Pearsona*. Dodatkowo ocenie poddano wartości lokalnego bezwzględnego błędu estymacji temperatury: minimalną, maksymalną, średnią bezwzględną wartość, odchylenie standardowe z próby, gdzie błąd zdefiniowany był według formuły (1):

$$err(t) = T(t)_{empiryczne} - T(t)_{modelowe} \quad (1)$$

Wybrane kryteria oceny zostały obliczone z wykorzystaniem procedur środowiska MATLAB. W tym celu rozwiązania modeli neuronowych uzyskanych przy wykorzystaniu pakietu STATISTICA zostały wygenerowane w kodzie źródłowym języka C (z wykorzystaniem modułu generatora kodu pakietu STATISTICA). Następnie uzyskany kod źródłowy został zaimplementowany w środowiska MATLAB.

Metoda weryfikacji, czy sieci neuronowe nie wykazują cech przeuczenia polegała na ocenie modelowych wartości estymowanych temperatury uzyskanych przy kroku czasowym 1 h (krok pomiarowy 3 h). Oceniano wartości temperatury: minimalną, maksymalną, średnią oraz odchylenie standardowe z próby.


### **Wyniki badań i ich analiza**

Dla sieci uczonych na bazie modułu *Projektanta sieci użytkownika* najlepiej estymującą sieć uzyskano przy ustawieniach: z uwzględnieniem wyboru opcji *Normalizuj zmienne wejściowe i wektory kodowe*; centra funkcji bazowych były przepisywane losowo ze zbioru uczącego, przy wartości współczynnika wygładzania 0,002, bez uwzględnienia wyboru opcji *Odrzuć wejścia o małej wrażliwości*. Sieci uczone w *Automatycznym projektancie* nie wykazywały wrażliwości na różny wybór dostępnych opcji.

W tabeli 1 przedstawiono wyniki statystyk opisowych dla danych empirycznych oraz danych estymowanych pochodzących z badanych modeli *GRNN*. Jednoznacznie najlepszym modelem jest model utworzony w środowisku MATLAB ( $r$  *Pearsona* = 1,000). Z modeli środowiska STATISTICA lepszą dokładność można uzyskać wykorzystując możliwości modułu *Projektant sieci użytkownika*, wskazują na to wszystkie wartości zamieszczonych kryteriów oceny.


Analiza wielkości zamieszczonych w tabeli 2, opisujących statystyki opisowe lokalnego bezwzględnego błędu estymacji temperatury, także wskazuje na następującą kolejność modeli *GRNN* estymujących temperaturę powietrza atmosferycznego: MATLAB, STATISTICA *Projektant sieci użytkownika*, STATISTICA *Automatyczny projektant*.

Interpretacja graficzna tych spostrzeżeń przedstawiona jest na rysunkach 1 i 2, na których oś czasową ograniczono do 200 h, ale przedstawione przebiegi są reprezentatywne dla całego zakresu pomiarowego. Przedstawienie analizowanych wielkości dla całego zakresu pomiarowego powoduje, że rysunki są mało czytelne. Na rysunku 1 dwa analizowane przebiegi (empiryczny i uzyskany z wykorzystaniem modelu programu MATLAB) praktycznie pokrywają się, natomiast przebieg dla modułu *Automatyczny projektant* przedstawia bardzo wygładzoną linię sigmoidalną w bardzo nieznacznym stopniu odwzorowującą stochastyczne wartości temperatury. Na rysunku 2 można zaobserwować interpretację graficzną analizowanego błędu predykcji temperatury. W skali wartości  $[-12^{\circ}\text{C}, 8^{\circ}\text{C}]$  osi rzędnych lokalny bezwzględny błąd estymacji temperatury jest linią prostą o rzędnej  $0^{\circ}\text{C}$ .



Rys. 1. Przebiegi zmian temperatury: empiryczne, estymowane modelami GRNN uzyskanymi z wykorzystaniem modułów Neural Network środowisk MATLAB i STATISTICA

Fig. 1. The courses of temperature changes: empirical, estimated by GRNN models obtained by using the Neural Network moduli of MATLAB and STATISTICA media



Rys. 2. Przebiegi lokalnych bezwzględnych błędów estymacji temperatury uzyskanych dla modeli GRNN uzyskanymi z wykorzystaniem modułów Neural Network środowisk MATLAB i STATISTICA

Fig. 2. Courses of local absolute errors of temperature estimation obtained for GRNN models by using the neural network moduli of MATLAB and STATISTICA media

*Tabela 1. Wyniki statystyk opisowych dla danych empirycznych, oraz danych estymowanych pochodzących z modeli GRNN utworzonych z wykorzystaniem modułów Neural Network środowiska MATLAB i STATISTICA*

*Table 1. Results of descriptive statistics for empirical data and for data estimated with the use of GRNN models developed by means of neural network moduli of the MATLAB and STATISTICA medium*

	$T_{\min}$ °C	$T_{\max}$ °C	$T_{\text{mean}}$ °C	std(T) °C	r
Empiryczne	5,2	30,7	15,8	4,26	
GRNN MATLAB	5,2	30,7	15,8	4,25	1,000
GRNN STAT AUTOMATYCZNY	8,4	25,6	15,9	2,91	0,673
GRNN STAT UŻYTKOWNIKA	7,7	26,3	16,4	3,22	0,824

*Tabela 2. Wyniki statystyk opisowych dla lokalnego bezwzględnego błędu estymacji temperatury modeli GRNN utworzonych z wykorzystaniem modułów Neural Network środowiska MATLAB i STATISTICA*

*Table 2. Results of descriptive statistics for local absolute error of temperature estimation obtained for GRNN models with the use of Neural Network moduli of the MATLAB and STATISTICA medium*

	$\text{err}_{\min}$ °C	$\text{err}_{\max}$ °C	$ \text{err}_{\text{mean}} $ °C	std(err) °C
GRNN MATLAB	-0,01	0,02	<0,00	0,01
GRNN STAT AUTOMATYCZNY	-10,3	8,5	2,6	3,14
GRNN STAT UŻYTKOWNIKA	-16,6	8,5	1,8	2,42

*Tabela 3. Wyniki statystyk opisowych dla weryfikacji logicznej modeli GRNN utworzonych z wykorzystaniem modułów Neural Network środowiska MATLAB i STATISTICA*

*Table 3. Results of descriptive statistics for logical verification of GRNN models developed by using Neural Network moduli of the MATLAB and STATISTICA medium*

	$T_{\min}$ °C	$T_{\max}$ °C	$T_{\text{mean}}$ °C	std(T) °C
GRNN MATLAB	5,2	30,7	15,8	4,20
GRNN STAT AUTOMATYCZNY	8,4	25,6	15,9	2,90
GRNN STAT UŻYTKOWNIKA	7,7	26,3	16,4	3,22

Tak dużą różnicę w jakości estymacji temperatury sieciami *GRNN* środowiska MATLAB i STATISTICA można wyjaśnić analizując sposób tworzenia sieci w tych aplikacjach. W STATISTICE wykorzystano zaimplementowany automatyczny mechanizm podziału danych na trzy podzbiory: uczący (ok. 50% punktów pomiarowych), walidacyjny (ok. 25% punktów pomiarowych) oraz testowy (ok. 25% punktów pomiarowych).

W sieci *GRNN* każdy punkt zbioru uczącego jest odwzorowany w pierwszej, ukrytej warstwie sieci, która w zasadzie decyduje o dokładności estymacji. Jeśli (tak jak w wypadku domyślnych ustawień pakietu STATISTICA) wykorzystywanych jest 50% dostępnych danych do uczenia sieci *GRNN*, to prawdopodobnie sieć taka będzie gorzej estymowała wartości od sieci, która w swojej strukturze zawiera 100% danych doświadczalnych. Podział zbioru danych na trzy podzbiory nie zawsze jest zasadny, np. nie wtedy, kiedy możemy zaproponować inną metodę sprawdzenia, czy sieć nie przejawia cech przeuczenia. Tabela 3 zawiera wyniki logicznej weryfikacji tej niepożądanego cechy sieci neuronowej. Jeśli różnice pomiędzy odpowiednimi wartościami temperatury: minimalną, maksymalną, średnią, odchylenie standardowe z próby przedstawione w tabelach 1 i 3 są małe, to możemy przyjąć, że sieć nie jest przeuczona. Przy tak przyjętym kryterium żadna z analizowanych sieci nie przejawia tej cechy.

## **Wnioski**

1. Model neuronowy *GRNN* powstały na bazie Toolbox Neural Networks v.4 pakietu MATLAB lepiej aproksymuje temperaturę powietrza atmosferycznego niż modele powstałe na bazie modułu Neural Networks pakietu STATISTICA 6.1.
2. Wśród modeli *GRNN* powstałych na bazie modułu Neural Networks pakietu STATISTICA 6.1 uzyskano lepszą aproksymację temperatury powietrza atmosferycznego, wykorzystując dostępne opcje funkcji związanych z *Projektantem sieci użytkownika*.



## **Bibliografia**

*Bodri L., Čermak V. 2003. Prediction of surface air temperatures by neural network, example based on three-year temperature monitoring at Sporilov Station. Studia Geophysica et Geodaetica, 47(1): 173-184*

*Chtioui Y., Panigrahi S., Francl L. 1999. A generalized regression neural network and its application for leaf wetness prediction to forecast plant disease. Chemometrics and Intelligent Laboratory Systems: 48, 47–58*

*Demuth H., Beale M. 2001. Neural Network Toolbox For Use with MATLAB. The MathWorks, Inc.*

*Ferreira P.M.; Faria E.A., Ruano A.E. 2002. Neural network models in greenhouse air temperature prediction. Neurocomputing, 43: 51–75*

*Krzyżak A., Rafałowicz E. 2000. Aproksymacja funkcji przy pomocy jednokierunkowych sieci neuronowych. Biocybernetyka i Inżynieria Biomedyczna, Tom 6 Sieci Neuronowe. Akademicka Oficyna Wydawnicza EXIT, Warszawa*

*Raju K.G. 2001. Prediction of Soil Temperature by Rusing Artificial Neural Networks Algorithms. Nonlinear Analysis, 47: 1737-1748*

*Ryniecki A. Jayas D.S. 1992. Stochastic modeling of grain temperature in near–ambient drying. Drying Technology, 10, 1: 123–137*

*Siejkowski, S., Markowski, M. 2000. Model dobowych zmian temperatury powietrza atmosferycznego. Problemy Inżynierii Rolniczej, 2 (28): 35-40*

*StatSoft, Inc. 2004. Electronic Statistics Textbook. Tulsa, OK: StatSoft. WEB: <http://www.statsoft.com/textbook/stathome.html>*

## **COMPARISON OF THE GRNN MODELS DEVELOPED BY USING NEURAL NETWORK MODULI OF THE MATLAB AND STATISTICA PACKETS**

### **Summary**

The effects of GRNN models, developed by using the neural network moduli of the MATLAB and STATISTICA packets on the accuracy of atmospherical air temperature estimation, were studied. It was stated that the GRNN neural

model developed on the basis of Toolbox Neural Network v.4 of the MATLAB packet approximated the temperature of atmospherical air better than the models based on Neural Network modulus of STATISTICA 6.1 packet. Among the GRNN models developed on the basis of Neural Network modulus of STATISTICA 6.1 packet, the better approximation of air temperature was obtained by using available options of the functions bound to modulus of the "User's network designer ..."

**Key words:** regressive model, GRNN neural networks, MATLAB, STATISTICA