

Ireneusz Białobrzewski

Katedra Inżynierii Procesów Rolniczych  
Uniwersytet Warmińsko-Mazurski w Olsztynie

## WYKORZYSTANIE SIECI NEURONOWEJ DO ESTYMACJI WARTOŚCI WILGOTNOŚCI WZGLĘDNEJ POWIETRZA NA PODSTAWIE WARTOŚCI JEGO TEMPERATURY

### Streszczenie

Przedstawiono wyniki badań wykorzystania sieci neuronowej do estymacji wartości wilgotności względnej powietrza atmosferycznego na podstawie wartości jego temperatury. Stwierdzono, że modelowe wartości uzyskane dla jednokierunkowej sieci neuronowej, o topologii perceptronu wielowarstwowego z czasowym opóźnieniem, wykorzystującej algorytm wstecznej propagacji błędów oddają charakter zmian empirycznych  $RH$ . Sieć taka może być z zadawalającą dokładnością wykorzystana do estymacji dobowych, średnich wartości wilgotności względnej powietrza atmosferycznego.

**Słowa kluczowe:** wilgotność względna powietrza, sieci neuronowe, MATLAB

### Oznaczenia

$err$  – lokalny błąd bezwzględny estymacji wilgotności względnej powietrza [%]  
 $RH$  – wilgotność względna powietrza atmosferycznego [%]  
 $t$  – numer kroku czasowego symulacji [-]  
 $T$  – temperatura [°C]

### Indeksy dolne

$emp$  – wartości empiryczne  
 $mod$  – wartości modelowe

## Wprowadzenie

Estymacja i przewidywanie zmian termodynamicznych parametrów powietrza atmosferycznego są ważne w wielu inżynierskich i agrotechnicznych zastosowaniach. Regresyjne i predykcyjne modele psychrometrycznych parametrów powietrza mogą być wykorzystane np. w optymalizacji procesów suszenia produktów rolniczych a także w systemach podejmowania decyzji dotyczących wentylacji budynków inwentarskich. Zależności pomiędzy poszczególnymi wielkościami opisującymi stan powietrza atmosferycznego są często trudno do sformalizowania w postaci użytecznego modelu matematycznego. Istnieje istotna korelacja pomiędzy temperaturą powietrza atmosferycznego a jego wilgotnością względną (współczynnik korelacji  $r$  *Pearsona* dla danych prezentowanych w tej pracy jest istotny przy poziomie  $p < 0.01$  i wynosi  $-0.774$ ) ale taki model regresyjny jest mało dokładny. Utworzenie dokładnego modelu regresyjnego czy predykcyjnego takich wielkości jest trudne ponieważ są to zmienne stochastyczne, o silnie nieliniowym charakterze [Białobrzewski, 2004a; Białobrzewski 2004b]. Dlatego też często w zagadnieniach estymacji i predykcji poszukuje się metod i narzędzi umożliwiających budowę dokładniejszych modeli. Jedną z takich metod są metody sztucznej inteligencji wykorzystujące m.in. sztuczne sieci neuronowe. Mitall i Zhang [2003] wykorzystali sztuczną sieć neuronową do predykcji w czasie rzeczywistym parametrów psychrometrycznych powietrza atmosferycznego uzyskując wartość błędu względnego dla predykcji temperatury i wilgotności względnej wynoszącą mniej niż 5%. Często zadanie predykcji rozwiązywane jest na podstawie analizy jednowymiarowego szeregu czasowego. Czyli obliczenie wartości prognozowanych (horyzont prognozy) dokonywane jest na podstawie pewnej liczby wartości poprzedzających (rząd prognozy) [Frank i in. 2001]. Sieciami neuronowymi dedykowanymi do realizacji regresji uogólnionej są sieci *GRNN* (*Generalized Regression Neural Network*). 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*. Białobrzewski [2004b] wykorzystał model neuronowy *GRNN* dostępny w środowisku MATLAB do estymacji temperatury powietrza atmosferycznego uzyskując współczynnik korelacji  $r$  *Pearsona* równy 1.000.

W niniejszej pracy podjęto próbę wykorzystania sieci neuronowej, o topologii perceptronu wielowarstwowego z czasowym opóźnieniem, do estymacji wartości wilgotności względnej powietrza atmosferycznego na podstawie wartości jego temperatury.

## Cel i zakres pracy

Celem pracy było wykorzystanie sieci neuronowej, o topologii perceptronu wielowarstwowego z czasowym opóźnieniem, do estymacji wartości wilgotności względnej powietrza atmosferycznego na podstawie wartości jego temperatury.

## Metodyka badań

W badaniach wykorzystano 1472 pomiary wilgotności względnej i temperatury powietrza atmosferycznego wykonane w latach 1988 i 1989 w Stacji Meteorologicznej w Olsztynie. Rejestracja pomiarów dokonywana była co 3 godziny.

Do badań wykorzystano oprogramowanie Toolbox Neural Networks v.4 pakietu MATLAB (MathWorks Inc., MA, USA). W środowisku tym zaprojektowano sieć neuronową jednokierunkową, o topologii perceptronu wielowarstwowego z czasowym opóźnieniem. W symulacjach wykorzystano algorytm, *br* (regularyzacja Bayesian), uczenia sieci oparty na zasadzie wstecznej propagacji błędów. Algorytm *br* jest zmodyfikowanym algorytmem Levenberg-Marquardt zaprojektowanym m.in. w celu tworzenia sieci nie przejawiających cech przeuczenia mimo, że w procesie uczenia sieci nie wyodrębnia się zbioru walidacyjnego [Białobrzeski 2004]. W algorytmie tym zaimplementowane są też procedury optymalizacji sieci pozwalające w znacznym stopniu zredukować liczbę jej parametrów [Demuth i Beale 2001]. Szczególnie jest to ważne wtedy gdy nie dysponujemy zbiorem uczącym znacznie większym od liczby parametrów projektowanej sieci neuronowej [Tadeusiewicz i Lula 2000]. We wszystkich przeprowadzonych symulacjach sieć posiadała te same parametry uczenia: współczynnik uczenia = 0.05; współczynnik momentum = 0.2; liczba epok = 3000; minimalna wartość gradientu =  $1.0 \cdot 10^{-10}$ ; wartość funkcji celu =  $1.0 \cdot 10^{-5}$ . Dla potrzeb uczenia sieci dane zostały przeskalowane do zakresu [-1,1] [Demuth i Beale 2001].

Poszukiwano takiej struktury sieci: wartość opóźnienia (od 2 do 30 z krokiem co 2), liczba warstw ukrytych (1 lub 2), liczba neuronów w pierwszej warstwie ukrytej (od 2 do 20 z krokiem co 2) z funkcją przejścia - *tan-sigmoid*, liczba neuronów w drugiej warstwie ukrytej (od 2 do 6 z krokiem co 1) z funkcją przejścia - *tan-sigmoid*, 1 neuron w warstwie wyjściowej z *liniową* funkcją przejścia, która pozwala uzyskać najlepsze wyniki estymacji wilgotności względnej powietrza atmosferycznego na podstawie temperatury powietrza atmosferycznego. Jako kryterium oceny wyboru najlepszego modelu neuronowego przyjęto współczynnik korelacji *r Pearsona* pomiędzy zbiorem danych empirycznych i uzyskanych z modelu. Ponadto dla danych uzyskanych z najlepszego modelu, oraz danych empirycznych zostały obliczone wartości statystyk opisowych wartości wilgotności

względnej: minimalna, maksymalna, średnia i odchylenie standardowe z próby. Dodatkowymi parametrami oceny był lokalny błąd bezwzględny predykcji  $RH$  opisany formułą (1):

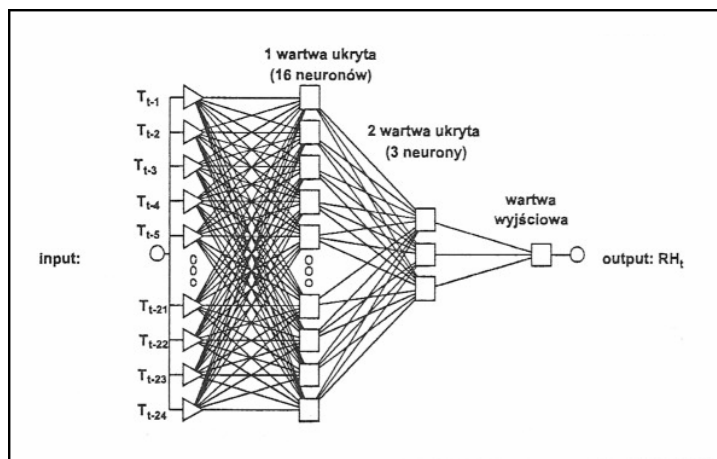
$$err(t) = RH_{\text{mod}}(t) - RH_{\text{emp}}(t). \quad (1)$$

Do obliczeń statystycznych wykorzystano procedury środowiska MATLAB (MathWorks Inc., MA, USA).

### **Wyniki badań i ich analiza**


Na rys. 1 przedstawiono schemat najlepszej z rozpatrywanych sieci neuronowej estymującej wartości wilgotności względnej powietrza atmosferycznego na podstawie temperatury powietrza atmosferycznego, zaprojektowanej i wytrenowanej na podstawie procedur dostępnych w pakiecie MATLAB. Najlepsze właściwości estymacyjne, wartość współczynnika korelacji  $r$  *Pearsona* 0.948, wykazała sieć o strukturze: wielkość opóźnienia - 24; 16 neuronów w pierwszej warstwie ukrytej; 3 neurony w drugiej warstwie ukrytej. Zoptymalizowana, efektywna liczba parametrów sieci wyniosła 400 natomiast początkowa liczba parametrów była równa 1175. Dzięki algorytmowi uczenia optymalizującemu liczbę parametrów sieci oraz liczności zbioru uczącego i efektywnej ilości parametrów sieci wyniósł ok. 4. Wielkość tego ilorazu jest jeszcze praktyczną, akceptowalną wartością dla uzyskania poprawnego modelu neuronowego. Natomiast jeśli liczba parametrów sieci wynosiłaby 1175, a w związku z tym omawiany iloraz wynosiłby ok. 1, to należałoby przyjąć, że modelowanie neuronowe nie byłoby właściwym narzędziem rozwiązywania analizowanego problemu [Tadeusiewicz, Lula 2000].

Na rys. 2 przedstawione przebiegi zmian empirycznych i modelowych wartości wilgotności względnej powietrza atmosferycznego. Ze względu na czytelności rysunku zakres osi odciętych ograniczono do 6 dni, pomiędzy dniem 50 i 56 trwania obserwacji. Charakter przebiegów zmian empirycznych i modelowych prezentowanych na rys. 2 jest typowy dla całego zakresu pomiarowego. Natomiast wartości statystyk opisowych dla całej próby przedstawiono w tabeli 1. Wartości prezentowanych statystyk (minimalna, maksymalna, średnia, odchylenie standardowe) są zbliżone do siebie co mogłoby świadczyć, że model neuronowy poprawnie estymuje wartości wilgotności względnej powietrza na podstawie wartości jego temperatury. Komentarza wymaga maksymalna wartość modelowa  $RH$  wynosząca 106%. Oczywiście jest ona fizycznie nie zgodna z tym jaką maksymalną wartość może przyjmować ten parametr. Dzieje się tak, ponieważ zastosowana sieć neuronowa operuje na zmiennych ciągłych a nie skategoryzowanych.



Rys. 1. Schemat najlepszej sieci neuronowej estymującej wartości wilgotności względnej powietrza atmosferycznego na podstawie temperatury powietrza atmosferycznego.

Fig. 1. The structure of the best neural network estimating the atmospheric air relative humidity on the basis of the atmospheric air temperature



Rys. 2. Przebiegi zmian empirycznych (• - punkty pomiarowe, — - linia łącząca punkty pomiarowe) i modelowych (○ - punkty modelowe, - linia łącząca punkty modelowe) wartości wilgotności względnej powietrza atmosferycznego


Fig. 2. Courses of empirical changes (• - measurement points, — - a line joining measurement points) and the model ones (○ - model points - a line joining model points) of the atmospheric air relative humidity value

Tabela 1. Statystyki opisowe dla danych: empirycznych i modelowych wilgotności względnej powietrza atmosferycznego

Table 1. Descriptive statistics for data: empirical and model ones of the atmospheric air relative humidity

Wyszczególnienie	RH <sub>min</sub> [ % ]	RH <sub>max</sub> [ % ]	RH <sub>mean</sub> [ % ]	std(RH) [ % ]	r
Pomiar	23	100	78	19.3	
Model	22	106	78	18.0	0.948

W zastosowaniu praktycznym tego modelu neuronowego należałoby nałożyć dodatkowe ograniczenia brzegowe na uzyskane wartości modelowe. Na rys. 3 przedstawiono przebiegi zmian lokalnego bezwzględnego błędu estymacji  $RH$ .



Rys. 3. Przebiegi zmian lokalnego bezwzględnego błędu estymacji wilgotności względnej powietrza atmosferycznego

Fig. 3. Change courses of the local absolute estimation error of the atmospheric air relative humidity

Maksymalna wartość  $err = 25\%$ , minimalna  $err = -23\%$ , wartość średnia  $|err| = 5\%$ ,  $std(err) = 6\%$ . Wartości te pozwalają przypuszczać, że dokładność estymacji byłaby zadawalająca dla wartości średniej z dłuższego, niż krok pomiarowy wykorzystanych danych empirycznych, okresu czasu np. doby. Charakter średnio-dobowych zmian wartości  $RH$  jest mniej nieliniowy niż charakter zmian wartości tej wielkości uzyskanych z pomiarów co 3 godziny dlatego też jest może być estymowany z większą dokładnością.

## Wnioski

W wyniku przeprowadzonych badań sformułowano następujące wnioski:

1. Jednokierunkowa sieć neuronowa, o topologii perceptronu wielowarstwowego z czasowym opóźnieniem, wykorzystująca algorytm wstecznej propagacji błędów wykorzystana do estymacji wartości wilgotności względnej powietrza atmosferycznego na podstawie jej temperatury oddaje charakter zmian empirycznych *RH*.
2. Sieć taka może być z zadawalającą dokładnością wykorzystana do estymacji dobowych, średnich wartości wilgotności względnej powietrza atmosferycznego.

## Bibliografia

Białobrzewski I. 2004a. Porównanie algorytmów uczenia sieci neuronowej jednokierunkowej, z czasowym opóźnieniem, wykorzystanej do predykcji wartości temperatury powietrza atmosferycznego. Inżynieria Rolnicza. (złożone do druku)

Białobrzewski I. 2004b. Porównanie modeli GRNN utworzonych z wykorzystaniem modułów sieci neuronowych pakietów MATLAB i STATISTICA. Inżynieria Rolnicza. (złożone do druku)

Chtioui Y., Panigrahi S., Franci 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.

Frank R.J., Davey N., Hunt S.P. 2001. Time Series Prediction and Neural Networks. *Journal of Intelligent and Robotic Systems*, 31, 91–103.

Mittal G.S. Zhang J. 2003. Artificial Neural Network-based Psychrometric Predictor. *Biosystems Engineering*, 85 (3), 283–289, doi:10.1016/S1537-5110(03)00071-0.

Tadeusiewicz R., Lula P. 2000. Neuronowe metody analizy szeregów czasowych i możliwości ich zastosowań w zagadnieniach biomedycznych. *Biocybernetyka i Inżynieria Biomedyczna 2000. Tom 6 Sieci Neuronowe*. Akademicka Oficyna Wydawnicza EXIT, Warszawa.

**USING THE NEURAL NETWORK TO ESTIMATE THE AIR  
RELATIVE HUMIDITY ON THE BASIS OF ITS TEMPERATURE  
VALUE**

**Summary**

The work presents the research results of using the neural network to estimate the air relative humidity on the basis of its temperature value. It was established that the model values obtained for the unidirectional neural network of the multi-layer perceptron topology with time delay, using error backward propagation algorithm, reflect the character of RH empirical changes. Such network may be used, with satisfactory precision, for daily estimations of the average relative humidity values of atmospheric air.

**Key words:** air relative humidity, neural networks