

PROGNOZOWANIE ZMIAN MIKROKLIMATU SZKLARNI W OKRESIE LETNIM

GRABARCZYK Sławomir

Zakład Instalacji Budowlanych i Fizyki Budowli, Politechnika Warszawska

PREDICTION OF VARIABILITY GREENHOUSE MICROCLIMATE IN SUMMER TIME

The paper deals with a problem of use artificial neural network type the Multi Layer Perception (MLP) to prediction of temperature inside greenhouses. The ANN models are described as function of the outside climate and the control actions performed. The data for training and testing the MLP neural-networks model of greenhouse were collected in two greenhouses with thermal screens.

STRESZCZENIE

W referacie przedstawiono problem zastosowania sieci neuronowych typu MLP do prognozowania temperatury wewnątrz szklarni. Sieci neuronowe są opisywane jako funkcja zewnętrznych warunków klimatycznych oraz parametrów opisujących funkcjonowanie wyposażenia szklarni. Dane do uczenia i testowania sieci neuronowej MLP mającej na celu prognozowanie temperatury w szklarni zostały zgromadzone na podstawie badań w dwóch szklarniach pojedynczych z ekranami termoizolacyjnymi.

1. WPROWADZENIE

Istotny wpływ na zmiany warunków mikroklimatycznych w szklarni w okresie letnim mają zewnętrzne czynniki klimatyczne. Przewidywanie tych zmian jest pożądane z punktu widzenia odpowiedniego kształtowania warunków do prowadzenia uprawy. Zagadnienie prognozowania parametrów mikroklimatu szklarni jest często poruszane w literaturze, głównie ze względu na konieczność uzyskania pożądanych warunków wewnętrznych oraz właściwego funkcjonowania systemów sterowania i kontroli mikroklimatu [1]. Szczególnie szerokim powodzeniem cieszą się modele w których stosuje się sztuczne sieci neuronowe [2], zwłaszcza o radialnych funkcjach bazowych (RBF) ze względu na stosunkowo szybki proces uczenia oraz tzw. perceptrony warstwowe (MLP), czyli sieci, których uczenie jest czasochłonne ale dają w efekcie lepsze wyniki [3].

W przedstawionym referacie skoncentrowano się na prognozowaniu zmian temperatury wewnętrznej w szklarni w oparciu o pomiary wielkości, które mają istotny wpływ na jej kształtowanie. Zgromadzony przez autora materiał badawczy pozwala na zbudowanie modelu opartego na sieci neuronowej w celu prognozowania zmian temperatury wewnątrz szklarni. Podjęto próbę określenia przydatności sztucznych sieci neuronowych w tym zakresie oraz ustalenia efektów stosowalności SSN w obiektach o istotnym znaczeniu zmiennych warunków klimatycznych. Wpływ warunków zewnętrznych

na wahania parametrów mikroklimatu szklarni oraz zużycie energii cieplnej był przedstawiany we wcześniejszych publikacjach autora [4][5]. Współczesne obiekty szklarniowe są wyposażone w ruchome ekrany o właściwościach cieniująco-energooszczędnych, które ograniczają znacząco wpływ promieniowania słonecznego na warunki panujące w szklarni [6]. Ekrany te funkcjonują zależnie od intensywności promieniowania słonecznego bezpośredniego, dostępnego w terenie otwartym, co istotnie zmienia charakterystykę obiektu.

2. ZAŁOŻENIA DO BADAŃ

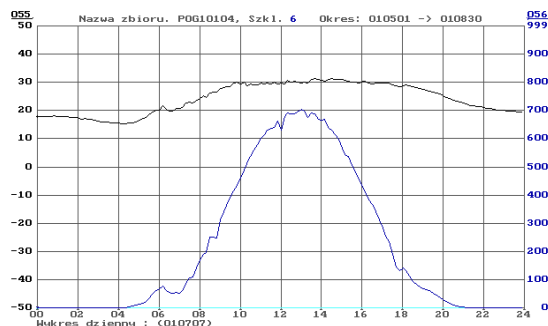
Podstawą wykonanych analiz są badania parametrów mikroklimatu szklarni, klimatu zewnętrznego oraz zużycia energii cieplnej. Badania te prowadzone są od kilku lat i obejmują trzy obiekty z różnymi rozwiązaniami energooszczędnymi. W referacie przedstawiono wyniki obliczeń przy wykorzystaniu oprogramowania *Statistica Neural Networks*, dla dwóch szklarni pojedynczych z osłonami aktywnymi w postaci zainstalowanych wewnątrz ekranów cieniująco-energooszczędnych.

Obliczenia dla okresu letniego wykonane zostały z wykorzystaniem danych pomiarowych z interwałem 1 godzinowym, zarejestrowanych w szklarniach od 1 maja do 30 sierpnia. Zastosowano metodę prognozowania przyczynowo-skutkowego, w której podstawą jest określenie mechanizmu zmian temperatury wewnętrznej, czyli zmiennej prognozowanej przez zmiany parametrów opisujących funkcjonowanie wyposażenia szklarni oraz zewnętrznych warunków klimatycznych. Uwzględniono najbardziej istotne parametry z punktu widzenia prognozowania temperatury wewnątrz szklarni: wilgotność względną powietrza wewnętrznego, stan zamknięcia ekranu, stan otwarcia wietrzników kalenicowych, temperaturę powietrza zewnętrznego, promieniowanie słoneczne bezpośrednie na płaszczyznę poziomą, prędkość wiatru, temperaturę zasilania górnego i dolnego systemu ogrzewczego szklarni oraz zużycie energii cieplnej w szklarni.


Wykorzystanie jako wielkości objaśniającej wilgotności względnej powietrza było uproszczeniem modelu, tak aby prognozowany był jeden parametr czyli temperatura wewnętrzna. Temperaturę powietrza wewnętrznego w szklarni potraktowano zarówno jako zmienną wejściową jak i wyjściową. Pozwoliło to na uzyskanie dokładniejszych wyników i uwzględnienie w prognozowaniu temperatury jej wartości poprzedniej.

W obliczeniach testowano i uczono sieci neuronowe liniowe, perceptrony wielowarstwowe (MLP) oraz sieci z radialnymi funkcjami bazowymi (RBF). Proces uczenia perceptronów wielowarstwowych MLP realizowano metodą wstecznej propagacji błędów oraz gradientów sprzężonych, zarówno z liniowymi jak i logistycznymi funkcjami aktywacji neuronów. Zakres obserwacji szeregu wykorzystywany na wejściu sieci przyjęto równy 48 przypadkom, co odpowiada danym z dwóch dni pomiarowych. Wyniki obliczeń przedstawiono dla całego zbioru danych w okresie od V do VIII, a także dla trzech przykładowych dni z w/w okresu. Podstawą wyboru wyselekcjonowanych przypadków było występowanie promieniowania słonecznego bezpośredniego padającego na płaszczyznę poziomą. Pierwszy dzień charakteryzował się prawie idealnym przebiegiem występowania promieniowania słonecznego (Rys. 1), w dniu 13 czerwca 2001r. (Rys. 2) zaobserwowano okresowo zmienne nasłonecznienie wywołane przejściowym

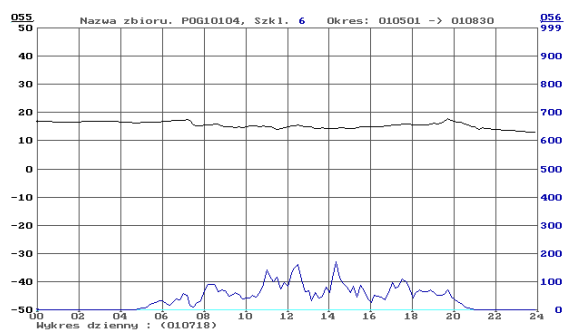
występowaniem zachmurzenia. Trzeci dzień to typowy dzień pochmurny z wyraźnym ograniczeniem promieniowania słonecznego dostępnego w terenie otwartym (Rys. 3).



Rys. 1. Temperatura powietrza zewnętrznego (055) i bezpośrednie promieniowanie słoneczne na płaszczyznę poziomą (056) w dniu 7 lipca 2001r.
 Fig. 1. Outside air temperature (055) and direct solar radiation (056) on 7 July 2001.



Rys. 2. Temperatura powietrza zewnętrznego (055) i bezpośrednie promieniowanie słoneczne na płaszczyznę poziomą (056) w dniu 13 czerwca 2001r.
 Fig. 2. Outside air temperature (055) and direct solar radiation (056) on 13 June 2001.



Rys. 3. Temperatura powietrza zewnętrznego (055) i bezpośrednie promieniowanie słoneczne na płaszczyznę poziomą (056) w dniu 18 lipca 2001r.
 Fig. 3. Outside air temperature (055) and direct solar radiation (056) on 18 July 2001.

3. WYNIKI ANALIZ

Przegląd wyników dla testowanych sieci o radialnych funkcjach bazowych (RBF), perceptronów wielowarstwowych (MLP) i sieci liniowych wskazał na niezadowalające możliwości adaptacji sieci typu RBF oraz pozytywne efekty prognozowania temperatury wewnętrznej uzyskiwane przez zastosowanie sieci liniowych i sieci MLP. Szczególnie te drugie w przypadku obu obiektów okazały się najlepsze. Ogólne wyniki uczenia sieci neuronowych MLP na zbiorach danych historycznych dla analizowanych szklarni 6A i 6B przedstawiono w Tab. 1. Podstawą oceny i wyboru najlepszej sieci było kryterium związane z minimalizacją błędu zbioru walidacyjnego, czyli zbioru pozwalającego na niezależne sprawdzenie jakości sieci w trakcie jej uczenia.

TABELA 1. Wyniki otrzymane w procesie uczenia sieci neuronowych MLP.

TABLE 1. Result obtained with the multi layer perception neural networks model.

obiekt	szklarnia 6A		szklarnia 6B	
	typ sieci	MLP s24 5:120-4-1:1	MLP s24 1:24-5-6-1:1	
zbiór danych	<i>jakość</i>	<i>błąd</i>	<i>jakość</i>	<i>błąd</i>
uczący	0,2455	0,0386	0,2707	0,0385
walidacyjny	0,2564	0,0415	0,2607	0,0387
testowy	0,3002	0,0470	0,3172	0,0454
metoda uczenia	BP100,CG20,CG106b		BP100,CG20,CG57b	


Statystyczną ocenę uzyskiwanych przez sieci neuronowe MLP wyników prognozowania na zbiorach danych przedstawiono w Tab. 2. Rozrzut występowania parametrów określono miarami statystycznymi określającymi minimum i maksimum występowania wartości temperatur obserwowanych względem prognozowanych oraz dolnym i górnym percentylem.

TABELA 2. Podsumowanie statystyczne dla sieci neuronowych MLP.

TABLE 2. Statistical analysis for the MLP neural network.

obiekt	szklarnia 6A	szklarnia 6B
sieć	MLP	MLP
średnia	21,997	22,419
odchylenie standardowe	4,873	5,0419
średni błąd	-0,057	0,075
odchylenie błędu	1,301	1,871
średni błąd bezwzględny	0,908	1,035
iloraz odchyłeń	0,267	0,371
korelacja	0,964	0,929
min / max	-6,6 / 5,9	-6,3 / 7,4
dolny (5%) i górny (95%) percentyl	-1,93 / 2,23	-1,87 / 2,18

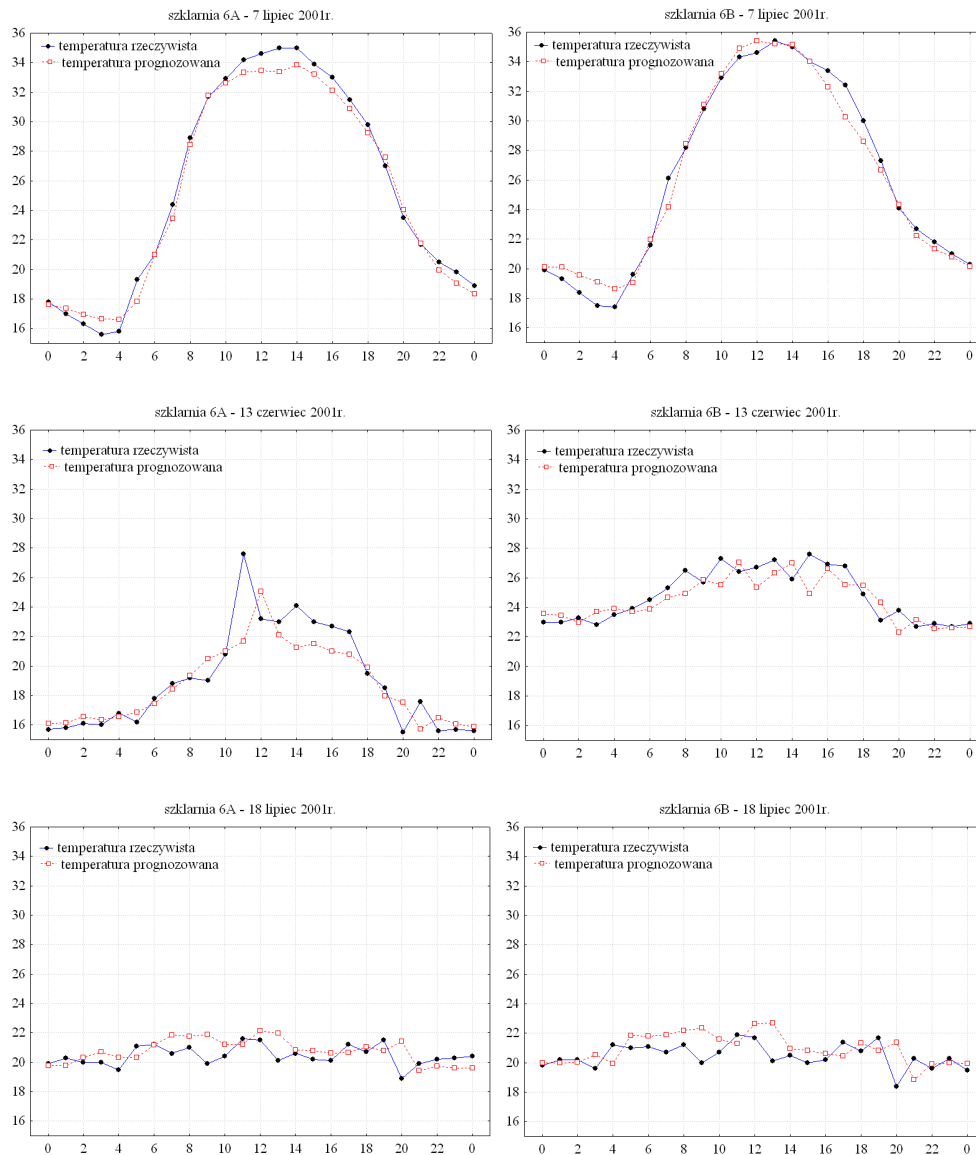
Zaobserwowane wartości ekstremalne występują w przypadku znaczących wahań bezpośredniego promieniowania słonecznego lub zmian w funkcjonowaniu wyposażenia technicznego szklarni: otwarcie/zamknięcie ekranu lub wietrzników. Występowanie ekstremów ma charakter losowy i dotyczy głównie dni z przebiegami promieniowania słonecznego obserwowanymi jak na Rys. 2 i 3. Rozrzut występowania wartości obserwowanych i prognozowanych dla obu całych zbiorów danych od maja do sierpnia zaprezentowano także na wykresach (Rys. 4).



Rys. 4. Obserwowane i prognozowane wartości temperatur w szklarniach 6A i 6B.
 Fig. 4. Measured and simulated temperatures in investigated greenhouses 6A and 6B.

Podstawowe statystyki podsumowujące dopasowane modele sieci neuronowych MLP potwierdzają dokładne odzwierciedlenie zachodzących zmian w szklarni. Wyniki prognozowania temperatury wewnętrznej na przykładzie wybranych dni z okresu letniego wskazują na istotny wpływ bezpośredniego promieniowania słonecznego jako zmiennej wejściowej na funkcjonowanie sieci neuronowej MLP (Rys. 5).

Średni błąd wartości temperatur prognozowanych i obserwowanych nie przekracza 1% dla dni pomiarowych przedstawionych na Rys. 1 i 2. W dniu 18 lipca wartości prognozowane różnią się od obserwowanych w szklarniach odpowiednio: w obiekcie 6A o -1.6% i w obiekcie 6B -2.4% . Ekstremalne różnice bezwzględne wartości prognozowanych i obserwowanych wskazują na gorsze przewidywanie temperatury wewnętrznej szklarni w dniach o okresowo zmiennym (Rys. 2) i silnym (Rys. 3) zachmurzeniu. Zmienność występującego bezpośredniego promieniowania słonecznego nie jest dokładnie odzwierciedlana w zbiorach godzinowych, co jest źródłem występujących rozbieżności. Potwierdzają to obliczone na podstawie wartości godzinowych a także w oparciu o dane pomiarowe z interwałem 10-cio minutowym dzienne dawki zintegrowanego promieniowania słonecznego bezpośredniego na płaszczyznę poziomą (Tab. 3). Największe różnice dotyczą 13 czerwca i 18 lipca, czyli dni w których występują największe rozbieżności w prognozowanych wartościach temperatury wewnątrz szklarni.



Rys. 5. Porównanie wyników otrzymanych dla sieci neuronowych MLP w badanych obiektach dla wybranych dni.

Fig. 5. Comparison result obtained for the MLP neural networks in greenhouses during selected day.

TABELA 3. Dienne zintegrowane promieniowanie słoneczne bezpośrednie.

TABLE 3. Integrated outside direct solar radiation per 24-hours.

Dzień	Dienne zintegrowane promieniowanie słoneczne bezpośrednie [Wh/m ² .dzień]		
	zbiór 1 - godzinowy	zbiór 10-cio minutowy	różnica
7 lipiec 2001	5189	5204	-0,3%
13 czerwiec 2001	4367	4074	+7,2%
18 lipiec 2001	953	985	-3,3%

4. PODSUMOWANIE

Metoda pośrednia prognozowania zmian temperatury wewnętrznej w szklarniach w okresie letnim została z pozytywnym skutkiem zastosowana w przypadku badanych obiektów szklarniowych. Ogólne wyniki uczenia sieci neuronowych typu MLP, wskazują na jakościowo dobre przewidywanie zmian temperatury wewnętrznej w analizowanych obiektach. Taka metoda prognozowania może być wykorzystana pod warunkiem, że znane są przyszłe wartości zmiennych objaśniających. Metoda przyczynowo-skutkowa może być zatem wykorzystana do przewidywania temperatury w szklarni w oparciu o prognozę pogody lub przewidywania jej zmian na podstawie zgromadzonego zbioru danych historycznych mikroklimatu i klimatu zewnętrznego.

Znacząco odstające różnice między wartościami obserwowanymi a prognozowanymi wg sieci neuronowych występowały w okresie gwałtownych zmian warunków zewnętrznych, głównie związanych z wahaniami promieniowania słonecznego bezpośredniego lub wymuszonymi tymi zmianami stanem zamknięcia ekranu termoizolacyjnego.

W przyszłych analizach prognozowanie zmian temperatury uzupełnione zostanie także o przewidywanie zmian wilgotności względnej powietrza wewnętrznego. Badania w tym zakresie będą kontynuowane i zamierzeniem autora jest wykorzystanie do uczenia sieci neuronowej zbiorów danych o interwale 10-cio minutowym.

Wyniki analiz wskazują na duże możliwości poznawcze wynikające z zastosowania sieci neuronowych do prognozowania warunków mikroklimatu szklarni w zmiennych warunkach klimatu zewnętrznego. Oczekuje się, że zastosowanie modeli neuronowych pozwoli na prognozowanie temperatury wewnętrznej w szklarni w warunkach odbiegających od zaobserwowanych, które były podstawą uczenia sieci neuronowej. Porównanie wyników działania sieci neuronowej zamierza się w przyszłości dokonać także na podstawie identycznych pomiarów przeprowadzonych w podobnym obiekcie o innej lokalizacji.

5. LITERATURA

- [1] BOULARD T., WANG S.: „Predicting the microclimate in a naturally ventilated Plastic House in a Mediterranean climate”. *Journal of Agricultural Engineering Research*, 75/2000, s. 27 – 38.
- [2] CUNHA J.B.: „Greenhouse climate models: an overview”. *Conference EFITA. Debrecen 2003*, s. 823 – 829.
- [3] FERREIRA P.M., FARIA E.A., RUANO A.E.: „Neural networks models in greenhouse air temperature prediction”. *Neurocomputing* 43/2002, s. 51 – 75.
- [4] GRABARCZYK S.: „Badania zmienności zużycia ciepła w obiektach szklarniowych”. *IX Polska Konferencja Naukowo-Techniczna „Fizyka Budowli w Teorii i Praktyce”*. Łódź 2003, część 1, s. 180 – 187.
- [5] GRABARCZYK S.: „Wahania zużycia energii cieplnej i parametrów mikroklimatu szklarni w zmiennych warunkach klimatu zewnętrznego”. *VII Ogólnopolska Konferencja Naukowo-Techniczna „Problemy projektowania, realizacji i eksploatacji budynków o niskim zapotrzebowaniu na energię - ENERGODOM 2004”*. Zakopane – Polana Zgorzelisko 2004r., Tom II, s. 603 – 610.
- [6] WOLSKI L., GRABARCZYK S.: „Ograniczenie wnikania promieniowania słonecznego w miesiącach letnich w szklarni z ekranami termoizolacyjnymi”. *VIII Konferencja Naukowo-Techniczna „Fizyka Budowli w Teorii i Praktyce”*. Łódź 2001, s. 633 – 640.



Dr inż., adiunkt w Zakładzie Instalacji Budowlanych i Fizyki Budowli Politechniki Warszawskiej.
Tematyka zainteresowań: fizyka budowli, wentylacja, wymiana ciepła w obiektach szklarniowych.
e-mail: slawekg@pw.plock.pl