

## OCENA WARUNKÓW TERMICZNYCH PROFILU GLEBOWEGO PRZY WYKORZYSTANIU SZTUCZNYCH SIECI NEURONOWYCH

*Paweł Licznar<sup>1</sup>, Marian Rojek<sup>2</sup>*

<sup>1</sup>Instytut Budownictwa i Architektury Krajobrazu, Akademia Rolnicza  
Pl. Grunwaldzki 24, 50-363 Wrocław  
e-mail: licznarp@ozi.ar.wroc.pl

<sup>2</sup>Instytut Kształtowania i Ochrony Środowiska, Akademia Rolnicza  
Pl. Grunwaldzki 24, 50-363 Wrocław

**Streszczenie.** Temperatura gleby jest ważnym czynnikiem warunkującym przydatność rolniczą terenu. Warunki termiczne są istotne dla kiełkowania nasion oraz późniejszego wzrostu roślin. Obecnie profile temperatur gleby są przedmiotem szczegółowych obserwacji prowadzonych przy pomocy automatycznych stacji meteorologicznych. Celem badań było zastosowanie sztucznych sieci neuronowych do analizy warunków termicznych profilu glebowego. Badania wykonano na bazie pomiarów temperatury powietrza i gleby zarejestrowanych w pierwszej połowie 2000 r. w Obserwatorium Agro- i Hydro-meteorologii AR Wrocław-Swojec. Dla prognozowania temperatury gleby na różnych głębokościach, na podstawie minimalnej temperatury powietrza na wysokości 5 cm oraz temperatur gleby mierzonych na wybranych głębokościach, opracowano i zastosowano pięć sieci perceptronowych o pojedynczej warstwie ukrytej, o pięciu neuronach. Wyniki badań wykazały, że sieci neuronowe mogą być z powodzeniem używane do uzupełniania przerwanych serii pomiarowych temperatury gleby. Ponadto dają one możliwość ograniczenia niezbędnej liczby prowadzonych obserwacji, dla oceny warunków termicznych całego profilu glebowego, do tylko dwóch parametrów: minimalnej temperatury powietrza 5 cm nad poziomem terenu oraz temperatury gleby na głębokościach 5 cm lub 50 cm.

**Słowa kluczowe:** pomiary temperatury gleby, sztuczne sieci neuronowe, automatyczne stacje pomiarowe

### WSTĘP

Temperatura gleby jest ważnym parametrem wpływającym na jej przydatność rolniczą [2]. Jest ona ściśle uzależniona od właściwości cieplnych gleby, czynników meteorologicznych oraz agrotechnicznych [11]. Temperatura gleby zmienia się w czasie i z głębokością profilu glebowego. W większości gleb Polski dobowe zmiany temperatury występują do głębokości ok. 0,5-0,6 m. Szybki zanik wahań

temperatury gleby jest zauważalny zwłaszcza w suchych profilach gleb piaszczystych. Przesuszone gleba jest stosunkowo złym przewodnikiem ciepła w porównaniu z glebą moką (współczynnik przewodnictwa cieplnego dla wody  $\lambda = 0,519 \text{ W}\cdot\text{m}^{-1}\cdot\text{K}^{-1}$ , dla piasku w stanie suchym  $\lambda = 0,192\text{-}0,197 \text{ W}\cdot\text{m}^{-1}\cdot\text{K}^{-1}$ ) [11,12]. Zabiegi melioracyjne mają więc znaczący wpływ na warunki termiczne profilu glebowego. Badania warunków termicznych gleb piaszczystych i torfów, po przeprowadzonych melioracjach, podjął jako pierwszy w Polsce S. Bac [1] już w latach 30-tych XX wieku.

U podstawowych roślin uprawnych w Polsce, zaliczanych do kriofitów, np. pszenica, jęczmień, żyto, owies, burak cukrowy, itp. wzrost rozpoczyna się już w temperaturze ok.  $3^{\circ}\text{C}$ , a optymalne warunki są osiągane przy  $20\text{-}25^{\circ}\text{C}$ . W przypadku roślin pochodzących z cieplejszych stref klimatycznych (mezofitów), takich jak np. kukurydza, słonecznik, ogórek, pomidor, tytoń, itp. kiełkowanie rozpoczyna się przy temperaturze co najmniej  $10^{\circ}\text{C}$ , a optymalny dalszy rozwój w temperaturach  $25\text{-}40^{\circ}\text{C}$  [11].

Obecnie coraz częściej szczegółowa ocena warunków termicznych profilu glebowego jest prowadzona przy pomocy automatycznych stacji meteorologicznych z wykorzystaniem zainstalowanych na różnych głębokościach termometrów glebowych. Czujniki te zwykle są oparte na termorezystorze Pt-100 i umożliwiają pomiar temperatury z dokładnością  $0,2^{\circ}\text{C}$  [9]. Przy pomiarach temperatury gleby za pomocą automatycznych stacji meteorologicznych pojawia się potrzeba optymalizacji liczby instalowanych termometrów glebowych, tak aby nie przeciążać pamięci loggера zbędnymi danymi. Odrębnym zagadnieniem jest uzupełnianie przerwanych ciągów pomiarowych w przypadku awarii zasilania lub pracy komputerowego systemu zbierania i archiwizacji danych.

Dla rozwiązania analogicznego zagadnienia, dotyczącego uzupełniania ciągów pomiarowych temperatury powietrza z automatycznych stacji meteorologicznych, Licznar i Rojek [7] zaproponowali użycie sztucznych sieci neuronowych. U zarania powstania sztucznych sieci neuronowych leżała koncepcja odwzorowania pracy układu nerwowego człowieka [5]. Sieć neuronowa składa się z komórek (neuronów), które są ze sobą powiązane. Sieci perceptronowe o pojedynczej warstwie ukrytej są jednymi z najczęściej spotykanych w praktyce modelowania meteorologicznego. Wynika to zarówno z łatwości ich budowania, jak i możliwości użycia do ich uczenia prostego i skutecznego algorytmu propagacji wstecznej [6].

Celem niniejszej pracy było zastosowanie sztucznych sieci neuronowych do analizy warunków termicznych profilu glebowego rejestrowanych przez automatyczną stację pomiarową.

## MATERIAŁ I METODY

W badaniach wykorzystano cogodzinne wyniki pomiarów: minimalnej temperatury powietrza na wysokości 5 cm nad poziomem terenu ( $T_{min+5}$ ) oraz temperatury gleby na głębokościach: 5 cm ( $T_{g-5}$ ), 10 cm ( $T_{g-10}$ ), 20 cm ( $T_{g-20}$ ), i 50 cm ( $T_{g-50}$ ). Pomiary te zostały przeprowadzone dla jednego profilu glebowego w Obserwatorium Agro- i Hydrometeorologii AR Wrocław-Swojec, należącym do Instytutu Kształtowania i Ochrony Środowiska Akademii Rolniczej we Wrocławiu. Stacja ta jest zlokalizowana na północno-wschodnim skraju miasta na wysokości 122,88 m n.p.m., długości geograficznej 17°07' E i szerokości geograficznej 51°07' N. Użyte w badaniach dane pochodziły z pierwszej połowy 2000 r., z rejestracji prowadzonych na poletku gleby bez roślin. Glebą, w której zainstalowano czujniki temperatury była mada rzeczna wytworzona z piasku gliniastego lekkiego, o zawartości 12% części spławialnych i 7% łu koloidalnego.

Dla realizacji celu badań opracowano pięć sieci neuronowych, o bardzo zbliżonej architekturze (tab. 1). Sieci te były sieciami perceptronowymi o pojedynczej warstwie. Dokładny opis budowy tego typu sieci, możliwego zakresu ich stosowania oraz sposobu ich uczenia można znaleźć w literaturze angielskojęzycznej u Demutha i Beale'a [3] oraz Hagana i in. [4] oraz w polskojęzycznej u Tadeusiewicza [10] i Osowskiego [8]. Wybór takiej topologii sieci wynikał głównie z jej prostoty, a zarazem znanych z literatury przedmiotu, licznych przykładów wcześniejszego jej pomyślnego stosowania do analogicznych zagadnień w zakresie meteorologii [6,7].

**Tabela 1.** Opracowane sieci neuronowe  
**Table 1.** Developed neural networks

Sieć – Net	Architektura – Architecture	Wejście – Input	Wyjście – Output
1	4 : 5 : 1	$T_{min+5}, T_{g-5}, T_{g-10}, T_{g-20}$	$T_{g-50}$
2	3 : 5 : 2	$T_{min+5}, T_{g-5}, T_{g-10}$	$T_{g-20}, T_{g-50}$
3	2 : 5 : 3	$T_{min+5}, T_{g-5}$	$T_{g-10}, T_{g-20}, T_{g-50}$
4	3 : 5 : 2	$T_{min+5}, T_{g-5}, T_{g-50}$	$T_{g-10}, T_{g-20}$
5	2 : 5 : 3	$T_{min+5}, T_{g-50}$	$T_{g-5}, T_{g-10}, T_{g-20}$

Każda z sieci składała się z trzech warstw: wejściowej, ukrytej oraz wyjściowej. Liczba neuronów w warstwie ukrytej została przyjęta *a priori* za równą 5. Liczba neuronów w warstwie wejściowej i wyjściowej była zdeterminowana przez liczbę zmiennych wejściowych oraz prognozowanych wielkości na wyjściu sieci. Jako funkcje transferu w sieciach zastosowano funkcję bipolarną w warstwach ukrytych, a w warstwach wyjściowych funkcję liniową.

Proces uczenia sieci przeprowadzono według algorytmu Levenberga-Marquardta, należącego do grupy algorytmów quasi-newtonowskich [4]. Pliki wejściowe i wyjściowe niezbędne dla przeprowadzenia procesu uczenia sieci jak i weryfikacji ich późniejszego funkcjonowania zestandaryzowano na początku badań. W wyniku zestandaryzowania osiągnięto w ich obrębie średnią wartość równą zero i jednostkowe odchylenie standardowe. Zabieg taki uznaje się zwykle za korzystny dla procesu uczenia i późniejszego funkcjonowania sieci perceptronowych [3]. Liczebność plików wejściowych i wyjściowych wynosiła 4367 (liczba zarejestrowanych temperatur przez automatyczną stację pomiarową w pierwszym półroczu 2000 r.). Dla dalszej analizy pliki te podzielono na trzy podzbiory: podzbiór „training” [uczenie] (33% całości zbioru), podzbiór „validation” [sprawdzenie poprawności] (33% całości zbioru), podzbiór „test” [testowanie] (33% całości zbioru). Podział został dokonany w oparciu o wybór co trzecich elementów zbiorów. Pozwolił on na zastosowanie w procesie uczenia metody wczesnego zatrzymania [early stopping], polepszającej zdolności generalizacyjne uczonej sieci. W metodzie tej błąd podzbioru „validation” jest stale monitorowany w procesie uczenia. Jego wartość przeważnie zmniejsza się na początku uczenia, tak jak wartość błędu podzbioru „training”. Po pewnym czasie uczenia, sieci zaczynają zwykle zatracać zdolności generalizacyjne, zapamiętują jedynie podawane wzorce. Wtedy też zaczyna rosnąć wartość błędu podzbioru „validation”. Jeśli wzrasta ona przez pewną określoną liczbę iteracji, proces uczenia jest kończony, a wagi odpowiadające minimalnej wartości błędu podzbioru „validation” uznaje się za końcowe.

Obliczenia wykonano z wykorzystaniem programu MATLAB (Release 12) i jego aplikacji do modelowania sieci neuronowych – Neural Network Toolbox (Version 4). Dla wszystkich sieci rejestrowano liczbę iteracji przeprowadzanych w procesie ich uczenia oraz obserwowano spadek wartości średniego błędu kwadratowego (Mean Squared Error – MSE). Początkowa wartość średniego błędu kwadratowego była zależna od architektury sieci i sposobu jej inicjalizacji, a w toku uczenia sieci spadała wraz z optymalizacją wartości wag. Dla ustalonych w procesie uczenia optymalnych wag, wykonano wykresy przedstawiające zależność zarejestrowanych i prognozowanych przez sieci wartości temperatur gleby dla podzbiorów „test”. Dla wszystkich tych wykresów opracowano równania regresji i określono ich parametry.

## WYNIKI I DYSKUSJA

Proces uczenia wszystkich sieci miał zbliżony przebieg, spadek wartości błędu kwadratowego przebiegał analogicznie dla podzbiorów „training”, „validation” i „test”. W trakcie procesu uczenia nie ujawniła się tendencja do zatracania przez sieci zdolności generalizacyjnej. Największy gradient spadku wartości błędu kwadratowego obserwowano w pierwszych 10 cyklach uczenia sieci.

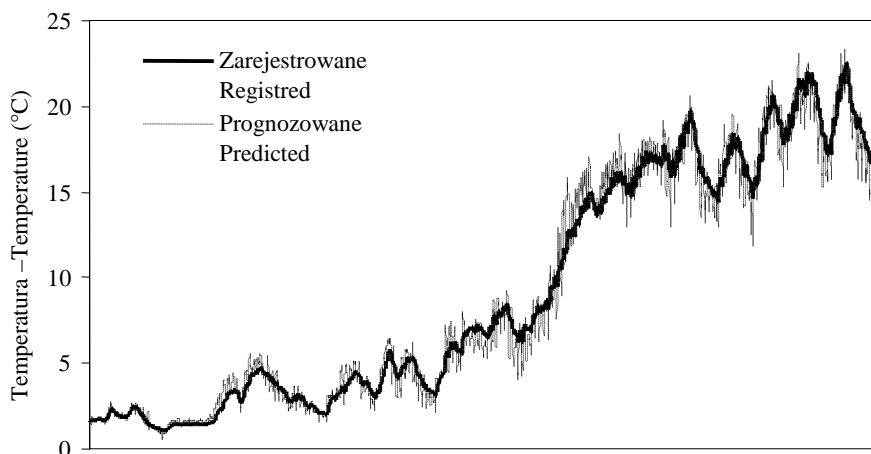
Prognozy temperatury gleby uzyskiwane z sieci były bardzo zbliżone, a często wręcz identyczne z rzeczywiście zarejestrowanymi wartościami. Wskazują na to, podane w tabeli 2, bliskie jedności wartości współczynnika korelacji  $r$  oraz parametry liniowych równań regresji ( $y = ax + b$ ), zbliżone do idealnego modelu postaci  $y = x$  (wartość prognozowana = wartość rzeczywista).

**Tabela 2.** Liczba cykli uczenia sieci, redukcja średniego błędu kwadratowego, równania regresji prognozowanych i pomierzonych wartości temperatury gleby na różnych głębokościach oraz ich współczynniki korelacji ( $r$ )

**Table 2.** Number of net training epochs, mean squared error reduction, regression relationships of measured versus predicted soil temperatures at the different depths and their correlation coefficients ( $r$ )

Sieć Net	Liczba cykli Number of epochs	Początkowa/końcowa wartość średniego błędu kwadratowego Initial/final value of mean squared error	Równania regresji dla temperatur gleby na różnych głębokościach Regression relationships for soil temperatures at the different depth
1	49	0,485/0,012	$T_{g-50}: y = 0,986 \cdot x + 0,122$ ( $r = 0,994$ )
2	40	2,206/0,018	$T_{g-20}: y = 0,997 \cdot x + 0,044$ ( $r = 0,998$ ) $T_{g-50}: y = 0,966 \cdot x + 0,316$ ( $r = 0,984$ ) $T_{g-10}: y = 0,996 \cdot x + 0,043$ ( $r = 0,997$ )
3	49	3,853/0,043	$T_{g-20}: y = 0,964 \cdot x + 0,331$ ( $r = 0,980$ ) $T_{g-50}: y = 0,911 \cdot x + 0,819$ ( $r = 0,952$ ) $T_{g-10}: y = 0,998 \cdot x + 0,026$ ( $r = 0,999$ )
4	42	1,200/0,004	$T_{g-20}: y = 0,996 \cdot x + 0,055$ ( $r = 0,997$ ) $T_{g-5}: y = 0,954 \cdot x + 0,396$ ( $r = 0,980$ )
5	22	1,728/0,037	$T_{g-10}: y = 0,952 \cdot x + 0,423$ ( $r = 0,979$ ) $T_{g-20}: y = 0,973 \cdot x + 0,249$ ( $r = 0,987$ )

Duża zgodność prognozowanych temperatur gleby otrzymywanych z opracowanych sieci względem wartości rzeczywiście pomierzonych spowodowała, że nie istniała potrzeba zmian w konfiguracji sieci, polegających np. na zwiększeniu liczby neuronów w warstwie ukrytej lub też zmianie używanych funkcji transferu. Przykładowe porównanie wartości temperatury gleby na głębokości 50 cm pomierzonych i prognozowanych przez sieć 1 przedstawiono na rysunku 1. Na podstawie wyników otrzymanych dla sieci 3 i 5 można stwierdzić, że do pełnej oceny warunków termicznych całego profilu glebowego, przy zastosowaniu sztucznych sieci neuronowych, wystarczający jest pomiar temperatury minimalnej powietrza na poziomie 5 cm oraz temperatury gleby tylko dla jednej głębokości.



**Rys. 1.** Porównanie szeregów czasowych zarejestrowanych i prognozowanych przez sieć 1 temperatur gleby na głębokości 50 cm w pierwszym półroczu 2000 roku

**Fig. 1.** Comparison of time series of measured and predicted by net 1 soil temperatures at the depth of 50 cm for the first half-year of 2000

#### WNIOSEK

Na podstawie przeprowadzonych badań można wnioskować o przydatności stosowania prostych sieci neuronowych (perceptronów o pojedynczej warstwie ukrytej) dla oceny warunków termicznych profilu glebowego. Zastosowanie sieci neuronowych pozwala ograniczyć liczbę prowadzonych w tym celu pomiarów do obserwacji jedynie dwóch wielkości: temperatury minimalnej powietrza na poziomie 5 cm oraz temperatury gleby tylko dla jednej głębokości (5 cm lub 50 cm). Przy prowadzeniu rejestracji temperatury gleby na kilku głębokościach, opracowane sieci mogą służyć do uzupełniania przerwanych ciągów pomiarowych, w przypadku awarii jednego lub kilku czujników.

#### PIŚMIENNICTWO

1. **Bac S.:** Obserwacje zimowe na torfowisku Czerzne (Z Zakładu Doświadczalnego Uprawy Torfowisk pod Sarnami). Wiad. Meteor. i Hydrogr., 15 (4-6), 1-16, 1935.
2. **Buckman H.C., Brady N.C.:** Gleba i jej właściwości. PWRiL, Warszawa, 1971.
3. **Demuth H., Beale M.:** Neural network toolbox for use with MATLAB, Users Guide Version 4, The MathWorks Inc. Natic, Maine, 2000.
4. **Hagan M., Demuth H., Beale M.:** Neural Network Design. PWS Publ., Boston, MA, 1996.

5. **Haykin S.:** Neural networks, a comprehensive foundation. MacMillan College Publ. Comp., New York, 1994.
6. **Licznar P.:** Sieci neuronowe w modelowaniu procesów meteorologicznych. W: Wybrane zagadnienia z zakresu pomiarów i metod opracowania danych automatycznych stacji meteorologicznych. (Red. J. Łomotowski, M. Rojek.) Zesz. Nauk. AR we Wrocławiu, ser. Monografie, XXV, 56-79, 2001.
7. **Licznar P., Rojek M.:** Uzupełnianie ciągów pomiarowych temperatury powietrza z automatycznych stacji pomiarowych z użyciem sztucznych sieci neuronowych. Acta Scien. Pol. Formatio Circumiectus, 2(1), 103-111, 2003.
8. **Osowski S.:** Sieci neuronowe do przetwarzania informacji. Ofic. Wyd. PW, Warszawa, 2000.
9. **Rojek M.:** Główne rodzaje automatycznych stacji meteorologicznych. W: Wybrane zagadnienia z zakresu pomiarów i metod opracowania danych automatycznych stacji meteorologicznych. (Red. J. Łomotowski, M. Rojek.) Zesz. Nauk. AR we Wrocławiu, ser. Monografie, XXV, 9-24, 2001.
10. **Tadeusiewicz R.:** Sieci neuronowe. Akadem. Ofic. Wyd., Warszawa, 1993.
11. **Turski R., Słowińska-Jurkiewicz A., Hetman J.:** Zarys gleboznawstwa. Wyd. AR w Lublinie, 1999.
12. **Ugla H.:** Gleboznawstwo rolnicze. PWN, Warszawa, 1976.

## SOIL PROFILE THERMAL CONDITIONS EVALUATION BY MEANS OF ARTIFICIAL NEURAL NETWORKS

*Paweł Licznar<sup>1</sup>, Marian Rojek<sup>2</sup>*

<sup>1</sup>Institute of Building and Landscape Architecture, University of Agriculture  
Pl. Grunwaldzki 24, 50-363 Wrocław  
e-mail: licznarp@ozi.ar.wroc.pl

<sup>2</sup>Institute for Land Reclamation and Environmental Development, University of Agriculture  
Pl. Grunwaldzki 24, 50-363 Wrocław

**Abstract.** Soil temperature is an important factor limiting agricultural use of the land. Thermal conditions are significant for seeds' germination and the former plants' growth. Presently the soil temperature's profiles are being subject of the detailed observation conducted on the automatic meteorological stations. Artificial neural networks implementation for the soil profile thermal conditions analysis was the aim of the research. The study was made on the base of the air and soil temperature records registered in the first half-year of 2000 at the Wrocław-Swojec meteorological station. Five perceptrons with single hidden layer of five neurons were developed and applied for prediction of soil temperature at different depths on the base of the minimal air temperature 5 cm above the ground and the soil temperature measured at the chosen depths. The results of the study showed that the neural networks may be successfully used for supplementing broken soil temperature measurement series. Moreover they provide a possibility to limit the number of conducted observations, necessary for the whole soil profile thermal conditions evaluation, to only two parameters: the minimal air temperature 5 cm above the ground and the soil temperature at the depth of 5 cm or 50 cm.

**Keywords:** soil temperature measurements, artificial neural networks, automatic meteorological stations