

ZASTOSOWANIE SIECI NEURONOWYCH DO WYZNACZANIA WARTOŚCI PARAMETRÓW KRZYWEJ RETENCJI WODY W GLEBIE

K. Lamorski, R. T. Walczak

Instytut Agrofizyki im. B. Dobrzańskiego PAN, ul. Doświadczalna 4, 20-290 Lublin 27

Streszczenie. W pracy przedstawiono wyniki badań dotyczących możliwości zastosowania sieci neuronowych do wyznaczania wartości parametrów hydrologicznych gleb. Zastosowano jednokierunkową wielowarstwową sieć neuronową, do jej uczenia wykorzystano dane hydrologiczne dotyczące 39 gleb mineralnych o różnych zagęszczeniach. Dane hydrofizyczne gleb pochodzące z pomiarów zostały wykorzystane do wyliczenia wartości współczynników krzywej retencji w modelu Mualema – van Genuchtena. Jako parametry wejściowe opisujące glebę zastosowano jej gęstość, oraz zespół czterech parametrów wyznaczanych na podstawie rozkładu granulometrycznego gleby: powierzchnię geometryczną, wskaźnik rozkładu wymiaru cząstek, środkową statystycznie średnicę cząstek glebowych, średnią średnicę cząstek glebowych. Przygotowana sieć neuronowa została zastosowana do aproksymacji parametrów krzywej retencji materiału glebowego na którym sieć nie była trenowana. Uzyskano pozytywne rezultaty. Sieci neuronowe mogą służyć do wyznaczania w sposób przybliżony wartości parametrów hydrologicznych gleby.

Słowa kluczowe: krzywa retencji, sieć neuronowa, aproksymacja.

WSTĘP

Właściwości hydrologiczne gleby należą do jej podstawowych charakterystyk fizycznych. Zaliczyć do nich można między innymi, krzywą retencji wodnej gleby oraz współczynnik przewodnictwa wodnego. Wyznaczenie eksperymentalne wartości parametrów hydrologicznych gleby wiąże się z długotrwałymi i drogimi pomiarami. Natomiast istnieje szereg metod służących wyznaczaniu właściwości hydrologicznych gleby na podstawie zmierzonych jej podstawowych parametrów, takich jak rozkład granulometryczny, powierzchnia właściwa i innych [8,9,10].

Krzywa retencji wodnej określająca zależność wilgotności danej gleby od potencjału wody glebowej jest podstawową charakterystyką hydrologiczną gleby. Przebieg krzywej retencji określa szereg właściwości hydrofizycznych gleby oraz kształtowanie się stosunków wodnych w glebie. Stopień uwilgotnienia gleby ma natomiast podstawowe znaczenie, dla rozwoju roślin i przebiegu szeregu procesów glebowych.

Celem pracy było wytrenowanie sieci neuronowej na istniejącym zbiorze danych właściwości hydrologicznych gleb, oraz zbadanie możliwości zastosowania sieci neuronowych do wyznaczania wartości parametrów krzywej retencji w modelu Mualema-van Genuchtena. Jako parametry wejściowe dla sieci neuronowej wybrano zagęszczenie gleby raz parametry statystyczne wyznaczone na podstawie rozkładu granulometrycznego. Wybór takich parametrów był podyktowany chęcią zbadania czy w oparciu o znajomość szczególnie łatwo mierzalnych wielkości (zagęszczenie i rozkład granulometryczny) jest możliwe aproksymowanie krzywej retencji przy zastosowaniu sieci neuronowej. Taka wytrenowana sieć neuronowa mogła by służyć do wyznaczania krzywej retencji dla określonego zestawu parametrów wejściowych, charakteryzujących glebę, w sposób przybliżony, bez konieczności wykonywania pomiarów. Zastosowanie sieci neuronowych w tego typu zagadnieniach było już badane i przyniosło obiecujące rezultaty [1,2,3,5,6,7,11].

MATERIAŁ I METODY

Sieci neuronowe są obecnie szeroko stosowane, między innymi w zagadnieniach gdzie konieczne jest uogólnianie właściwości reprezentowanych przez skończony zbiór danych pomiarowych, na przypadki które nie były zmierzone eksperymentalnie. Takie zastosowanie sieci neuronowych polega na wyznaczaniu wartości parametrów wyjściowych odpowiadających zbiorowi parametrów wejściowych. Jest to szczególny przypadek zagadnienia interpolacyjnego, gdzie interpolacja jest dokonywana w wielowymiarowej przestrzeni zmiennych, a wynikiem funkcji interpolującej jest wieloelementowy zbiór wartości. Tego typu interpolację daje się wykonywać bądź przy wykorzystaniu sieci neuronowych, bądź przy zastosowaniu technik wielokrotnej regresji liniowej. Jednak, jak pokazują badania, sieci neuronowe zdają się sprawdzać lepiej w tego typu zagadnieniach, niż klasyczne techniki statystyczne [1,7].

Dla potrzeb tej pracy stosowano wielowarstwową jednokierunkową sieć neuronową o pięciu neuronach wejściowych, stu neuronach w warstwie ukrytej oraz czterech neuronach wyjściowych [4,13]. Do konstrukcji i uczenia sieci wykorzystywane było uniwersalne oprogramowanie do eksperymentów z sieciami neuronowymi SNNS (Stuttgart Neural Network Simulator) [12]. Do uczenia tej sieci były wykorzystane dane pochodzącymi z pomiarów właściwości hydrologicznych i fizycznych 39 różnych gleb. Właściwości każdej z tych gleb były zmierzone dla różnych wartości zagęszczeń. Efektywnie dysponowano więc właściwościami 370 próbek glebowych, dla których zmierzony był rozkład granulometryczny, powierzchnia właściwa, gęstość, ilość substancji organicznej, krzywa pF wyznaczana w 10-ciu punktach oraz inne parametry [13]. Z tej grupy 370 próbek glebowych wybrano losowo 9 próbek na których dokonywano później weryfikacji dopasowania odwzorowań wykonywanych przez sieć neuronową. Pozostałe były użyte do uczenia sieci neuronowej.

Na podstawie rozkładu granulometrycznego wyznaczono wartości czterech parametrów opisujących syntetycznie właściwości rozkładu granulometrycznego ośrodka. Są to następujące parametry: właściwa powierzchnia geometryczna S , wskaźnik rozkładu wymiaru cząstek f , środkowa statystycznie średnica cząstek $D(50\%)$, średnia statystyczna średnic cząstek glebowych R .

Wielkość właściwej powierzchni geometrycznej ośrodka glebowego S , wyliczana była przy założeniu kulistości cząstek glebowych według następującej formuły:

$$S = \sum_{i=1}^N \frac{4\pi \left(\frac{D_i}{2}\right)^2}{\frac{4}{3}\pi \left(\frac{D_i}{2}\right)^3 \rho} p_i = \sum_{i=1}^N \frac{6}{\rho D_i} p_i = \sum_{i=1}^N \frac{12}{\rho(D_i^{\min} + D_i^{\max})} p_i$$

przy założeniu, że średnicą reprezentatywną dla danej frakcji rozkładu granulometrycznego jest średnica środkowa danej frakcji, oraz gdzie: p_i jest procentową zawartością i -tej frakcji, ρ jest gęstością fazy stałej ośrodka glebowego, N określa w ilu frakcjach był wyznaczany rozkład granulometryczny, natomiast D_i^{\min} oraz D_i^{\max} są odpowiednio minimalną średnicą oraz maksymalną średnicą cząstek glebowych w danej frakcji.

Wskaźnik rozkładu wymiaru cząstek f jest liczony według następującego wzoru:

$$f = \sum_{i=1}^N \frac{\log\left(\frac{P_{i+1}}{P_i}\right) P_{i+1} - P_i}{\log\left(\frac{D_{i+1}^{\max}}{D_i^{\max}}\right) P_N - P_i}$$

gdzie: P_i jest procentowym udziałem i -tej frakcji granulometrycznej i frakcji drobniejszych odczytanym z dystrybuanty rozkładu granulometrycznego.

Środkową statystycznie średnicę cząstek glebowych wyznaczono z dystrybuanty rozkładu granulometrycznego, jako średnicę cząstek odpowiadającą wartości dystrybuanty równej 0,5 (50%).

Średnia statystyczna średnic cząstek R wyznaczona została jako średnia ważona, średnic odpowiadających poszczególnym frakcjom granulometrycznym:

$$R = \sum_{i=1}^N \frac{D_i^{\min} + D_i^{\max}}{2} p_i$$


Wartości parametrów S , R , f , $D(0,5)$ oraz zagęszczenie próbki glebowej były wykorzystywane jako wartości wejściowe dla sieci neuronowej. Sieć na wyjściu generowała wartości parametrów θ_{res} , θ_{sat} , α oraz n krzywej retencji Mualema-van Genuchtena.

WYNIKI BADAŃ

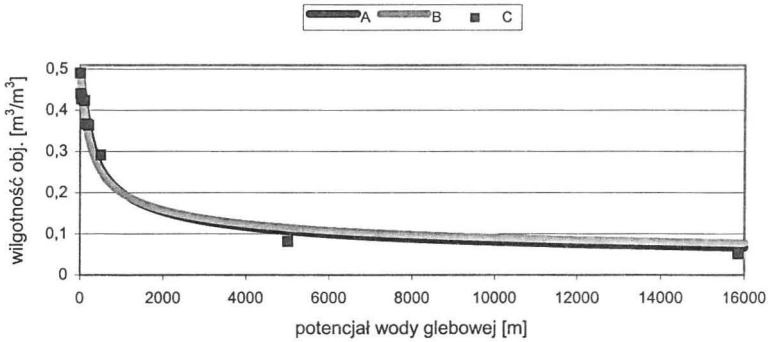
Na podstawie przygotowanych danych pomiarowych uczono sieć neuronową. Tak przygotowaną sieć neuronową poddano testom, polegającym na wygenerowaniu przez sieć parametrów modelu retencji dla podanych wartości parametrów wejściowych opisujących ośrodek glebowy.

Rysunki 1, 2 oraz 3 przedstawiają zmierzoną eksperymentalnie krzywą pF (prostokątne symbole – seria C), dopasowanie metodą najmniejszych kwadratów krzywej retencji w postaci Mualema - van Genuchtena do danych pomiarowych (linia czarna – seria A) oraz krzywą retencji która wyznaczona była na podstawie parametrów wygenerowanych przez wytrenowaną sieć neuronową (linia szara – seria B). Dane te dotyczą trzech różnych gleb każda badana w trzech różnych zagęszczeniach.

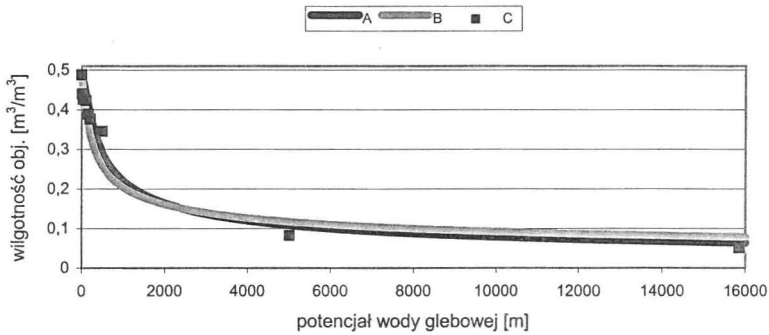
Tabela 1 zestawia wartości współczynników modelu retencji Mualema-van Genuchtena wyznaczonych na podstawie danych pomiarowych oraz aproksymowanych przez wytrenowaną sieć neuronową, dla poszczególnych gleb i różnych zagęszczeń gleb.



a) $\rho = 1,27 \text{ [Mg/m}^3\text{]}$



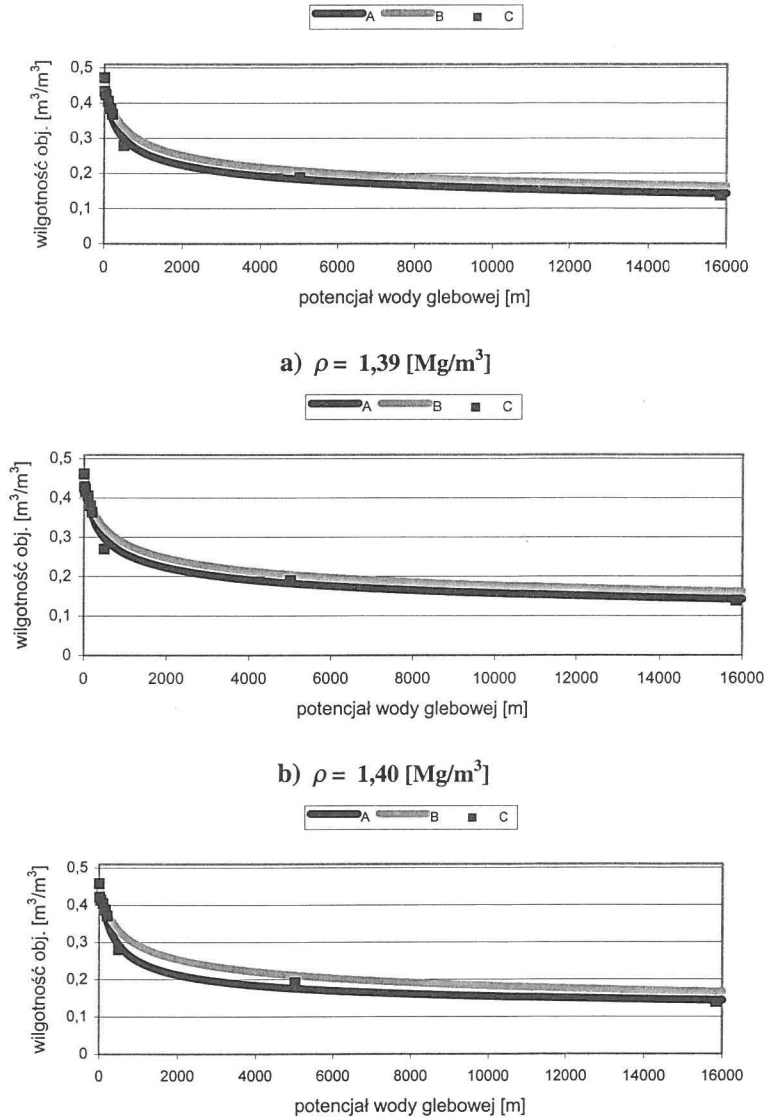
b) $\rho = 1,30 \text{ [Mg/m}^3\text{]}$



c) $\rho = 1,31 \text{ [Mg/m}^3\text{]}$

Rys. 1. Porównanie krzywej pF dopasowanej do punktów pomiarowych i wyznaczonej na podstawie parametrów aproksymowanych przez sieć neuronową.


Fig. 1. Comparison of a retention curve fitted to experimental results and determined on the base of parameters approximated by the neural network.



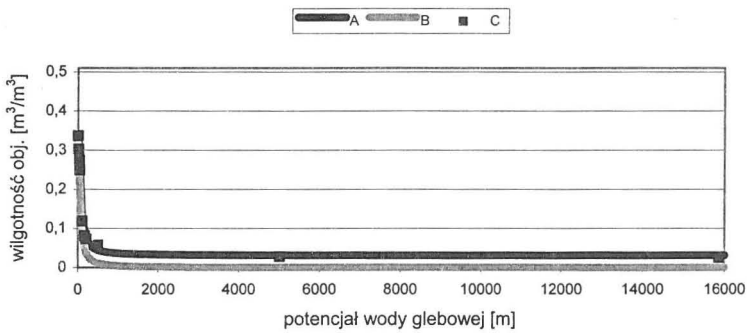
c) $\rho = 1,41 \text{ [Mg/m}^3\text{]}$

Rys. 2. Porównanie krzywej pF dopasowanej do punktów pomiarowych i wyznaczonej na podstawie parametrów aproksymowanych przez sieć neuronową.

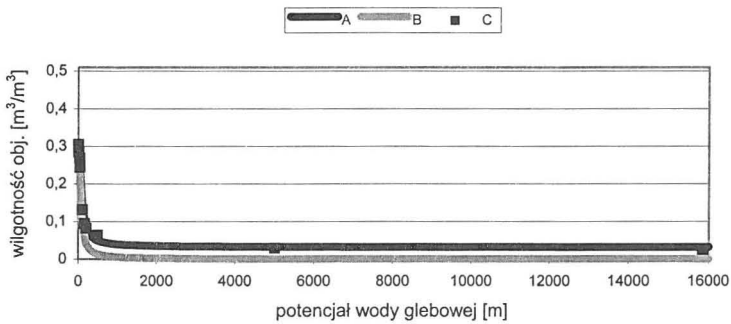
Fig. 2. Comparison of a retention curve fitted to experimental results and determined on the base of parameters approximated by the neural network.



a) $\rho = 1,67 \text{ [Mg/m}^3\text{]}$



b) $\rho = 1,71 \text{ [Mg/m}^3\text{]}$



c) $\rho = 1,76 \text{ [Mg/m}^3\text{]}$

Rys. 3. Porównanie krzywej pF dopasowanej do punktów pomiarowych i wyznaczonej na podstawie parametrów aproksymowanych przez sieć neuronową.

Fig. 3. Comparison of a retention curve fitted to experimental results and determined on the base of parameters approximated by the neural network.

Tabela. 1. Parametry krzywej retencji pochodzące z dopasowania metodą najmniejszych kwadratów i parametry wygenerowane przez sieć neuronową

Table. 1. Parameters of soil water retention curve fitted to experimental results and approximated by the neural network

Lp.	gleba	ρ [Mg/m ³]	dopasowanie do danych pomiarowych				aproksymowane przez sieć			
			θ_{rez} [m ³ /m ³]	θ_{sat} [m ³ /m ³]	α	n	θ_{rez} [m ³ /m ³]	θ_{sat} [m ³ /m ³]	α	n
1		1,27	0,0	0,507	0,00854	1,42	0,0046	0,497	0,013	1,35
2	bielicowa	1,30	0,0	0,491	0,00878	1,40	0,0044	0,487	0,012	1,35
3		1,31	0,0	0,489	0,00535	1,45	0,0043	0,484	0,011	1,36
4	brunatna	1,39	0,0	0,473	0,01550	1,21	0,0137	0,459	0,008	1,22
5		1,40	0,009	0,462	0,01316	1,22	0,0136	0,451	0,008	1,22
6		1,41	0,086	0,459	0,00877	1,37	0,0137	0,459	0,008	1,22
7	czarnoziem	1,67	0,028	0,336	0,02294	2,33	0,0	0,324	0,027	2,31
8		1,71	0,031	0,338	0,02427	2,23	0,0	0,317	0,027	2,27
9		1,76	0,032	0,306	0,02032	2,18	0,0	0,309	0,026	2,22

Przetestowano również z jakim błędem sieć neuronowa odtwarza dane które były wykorzystywane do jej uczenia. Wyniki tego testu przedstawia Tabela 2. Przedstawia ona średni błąd kwadratowy dla każdej z dziesięciu wartości pF, między wartością wilgotności pochodzącą z pomiaru a wartością wilgotności wyliczoną z krzywej retencji, której współczynniki wyznaczone były przy pomocy wyuczonej sieci neuronowej.

Tabela. 2. Średni błąd kwadratowy aproksymacji wilgotności przy zastosowaniu sieci neuronowej dla poszczególnych wartości pF.

Table. 2. Mean square error of soil moisture approximation by neural network for different pF values.

pF	0,2	1,3	1,5	1,6	2,0	2,2	2,3	2,7	3,7	4,2
błąd $\Delta\theta$	0,0013	0,0030	0,0043	0,0047	0,0067	0,0080	0,0087	0,0120	0,0268	0,0417

Widać, że błąd ten rośnie wraz ze wzrostem wartości pF. Sieć przybliża gorzej wilgotności dla wyższych wartości pF niż wilgotności dla pF o niższych wartościach.

WNIOSKI

Pokazano że sieci neuronowe mogą być stosowane do wyznaczania parametrów opisujących retencję wody w ośrodku glebowym. Przedstawione wyniki są obiecujące, biorąc pod uwagę praktyczne możliwości stosowania odpowiednio uczonej sieci neuronowej do bardzo szybkiego oszacowywania parametrów hydrologicznych na podstawie podstawowych parametrów ośrodka glebowego. Wydaje się, że w przypadku zagadnienia zastosowania sieci neuronowych do skutecznej aproksymacji parametrów hydrologicznych, problem nie leży w samej metodzie, lecz w dostępności odpowiednio szerokiej bazy danych na podstawie których można by było sieć neuronową uczyć. Dalsze badania wymagają zaangażowania znacznie szerszego zbioru danych właściwości hydrofizycznych gleb, tak by sieć była uczona na danych dotyczących maksymalnie różnorodnego materiału glebowego.

PIŚMIENNICTWO

1. **Altendorf C.T., Elliott R.L., Stevens E.W., Stone M.L.:** Development and validation of neural network model for soil water content prediction with comparison to regression technique. *Transactions of the ASAE*, 42 (3), 1999.
2. **Koekkoek E. J. W., Booltink H.:** Neural network models to predict soil water retention. *European Journal of Soil Science*, 50 (3), 1999.
3. **Minasny B., Mc Bratney A. B.:** The neuro-m method for fitting neural network parametric pedotransfer functions. *Soil. Sci. Soc. Amer.*, 66 (2), 2002.
4. **Osowski S.:** Sieci neuronowe w ujęciu algorytmicznym. WNT, Warszawa 1996.
5. **Schaap M.G., Leij F.J., van Genuchten M.T.:** ROSETTA: a computer program for estimating hydraulic parameters with hierarchical pedotransfer functions. *Journal of Hydrology*, 251 (3-4), 2001.
6. **Schaap M.G., Leij F.J.:** Improved predictions of unsaturated hydraulic conductivity with the Mualem – van Genuchten model. *Soil. Sci. Soc. Amer.*, 64 (3), 2000.
7. **Schultz A., Wieland R., Lutze G.:** Neural networks in agroecological modeling – stylish application or helpfull tool? *Computer and electronics in agriculture*, 29 (1-2), 2000.
8. **Sobczuk H., Plagge R., Walczak R., Roth C.:** Laboratory equipment and calculation procedure to rapidly determine hysteresis of some soil hydrophysical properties under nonsteady flow conditions. *Z. Pflanzenernähr. Bodenk.* 155, 1992.
9. **Walczak R.:** Modelowe badania zależności retencji wodnej od parametrów fazy stałej gleby, *Problemy Agrofizyki*, 41, 1884.

10. **Walczak R., Sławiński C., Malicki M., Sobczuk H.:** Measurement of water characteristics in soils using TDR technique: Water characteristics of loess soil under different treatment. *Int. Agrophysics*, 7, 1993.
11. **Wosten. J.H.M, Pachepsky Y.A., Rawls W.J.:** Pedotransfer functions: bridging the gap between available basic soil data and missing soil hydraulic characteristics. *Journal of Hydrology*, 251 (3-4), 2001.
12. **Zell A., et al:** SNNS, Stuttgart Neural Network Simulator. User Manual, v 4.2. University of Stuttgart, 2001.
13. **Żurada J., Barski M., Jędruch W.:** Sztuczne sieci neuronowe, podstawy teorii i zastosowania. PWN, Warszawa 1996.

USE OF NEURAL NETWORKS FOR SOIL WATER RETENTION CURVE PARAMETERS APPROXIMATION

K. Lamorski, R.T. Walczak

Institute of Agrophysics, Polish Academy of Sciences, ul. Doświadczalna 4, 20-290 Lublin 27

Summary. Possibility of use of neural networks for soil water retention curve approximation is investigated in this paper. Feed-forward neural network was used for this purpose. Network was trained on the set of measured hydraulic parameters of thirty nine mineral soils in different densities. Measured soil water retention curves were used for approximation of parameters of Mualem – van Genuchten retention curve for each soil. Input parameters for neural network were, soil density and four parameters calculated from soil's granulometric distribution: specific geometric surface of soil, ratio of distribution of soil particles and mean diameter of soil particles. Trained neural network was used for approximation of parameters of Mualem – van Genuchten water retention curve. Good results was achieved. Neural networks seem to be a good tool, complementary to classical pedotransfer functions.

Key words: pedotransfer functions, soil water retention, neural network, approximation.