

Anna BURDUK<sup>1</sup>, Svitlana MATUS<sup>2</sup>, Anastasia STETSENKO<sup>2</sup>, Vitalii KUTIA<sup>1</sup>

<sup>1</sup>Politechnika Wrocławska

<sup>2</sup>The National University of Water and Environmental Engineering

## IMPLEMENTACJA INTELIGENTNEJ METODY STEROWANIA WILGOTNOŚCIĄ GLEBY

**Streszczenie.** W artykule przedstawiono metodę inteligentnego sterowania wilgotnością gleby w systemach odwadniająco-nawadniających z nawadnianiem wgłębnym. Zaproponowano strukturę układu sterowania, dobrano urządzenia techniczne oraz opracowano oprogramowanie do realizacji zautomatyzowanego systemu sterowania.

## IMPLEMENTATION OF AN INTELLIGENT METHOD OF SOIL MOISTURE CONTROL

**Summary.** In the paper the method of soil moisture control on the drained-humidifying systems with underground moistening was developed. The structure of control loops was proposed, hardware and software of the automated control system were developed.

### 1. Wstęp

Problem sterowania wilgotnością gleby w uprawach rolniczych jest niezwykle ważny na całym świecie. Aby można było przekształcić tradycyjne gospodarstwo rolne w nowoczesne przedsiębiorstwo produkcyjne należy przede wszystkim zmniejszyć zależność upraw od niekorzystnych warunków przyrodniczo-klimatycznych, co jest możliwe poprzez zastosowanie rolnictwa irygacyjnego w miejscach słabego i niestabilnego nawilżania.

W okresie wzrostu rośliny zużywają dużą ilość wody, z której 0,01-0,03 % idzie na tworzenie roślinnych tkanek, natomiast pozostała część jest zużywana na transpirację przez liście i łodygi roślin. Uprawy rolnicze wymagają odpowiedniego poziomu wilgotności gleby. Maksymalne plony uzyskuje się tylko przy odpowiednim poziomie wilgoci, składników odżywczych, ciepła, powietrza i światła. Przy braku lub nadmiarze wilgoci w glebie, plon upraw zmniejsza się. W pierwszym przypadku z powodu braku wilgoci i składników odżywczych, w drugim z uwagi na brak powietrza w glebie.

Niezbędny dla upraw rolniczych poziom wilgotności gleby zapewnia się odpowiednim sposobem nawadniania, który określają normy dobrane od rodzaju upraw, okresu wegetacyjnego rośliny oraz warunków przyrodniczych. Zużycie wody

zależy od warunków klimatycznych, temperatury i nasłonecznienia, rodzaju gleby, gatunku oraz okresu wegetacyjnego roślin.

Optymalizacja trybu wodno-powietrznego strefy aeracji przy uprawie roślin rolniczych w systemach odwadniająco-nawadniających (SON) z nawadnianiem wglębnym jest możliwa tylko z zastosowaniem zautomatyzowanych systemów sterowania (ZSS) wilgotnością gleby, które biorą pod uwagę losowe zmiany warunków pogodowych i mogą pracować przy niepełnej informacji o obiekcie sterowania.

## **2. Metody i środki techniczne do automatycznej regulacji stosunków wodnych w systemach odwadniająco-nawadniających**

Opracowanie metod automatycznej regulacji stosunków wodnych w systemach odwadniająco-nawadniających (SON) odbywa się na podstawie modelu matematycznego obiektu regulacji. Model matematyczny, opracowuje się poprzez teoretyczną analizę z wykorzystaniem wzorów fizycznych, które są właściwe dla obiektu regulacji lub na podstawie danych doświadczalnych, aproksymując obiekt dynamicznymi członami, znanymi z teorii sterowania automatycznego.

Realizacja automatycznej regulacji stosunków wodnych w SON wymaga stosowania skutecznego podejścia do kwestii regulacji stosunków powietrzno-wodnych za pomocą urządzeń automatyki hydraulicznej ze zdolnością do szybkiej regulacji na każdym polu.

Szybka regulacja poziomu wód gruntowych (PWG) i utrzymanie wymaganej wilgotności gleby z wykorzystaniem urządzeń automatycznych odbywa się według następujących operacji technologicznych:


- dodatkowe nawilżanie odwadnianych terenów,
- zakończenie dodatkowego nawilżania,
- odwadnianie w przypadku podniesienia PWG powyżej założonego poziomu, spowodowane dużą ilością opadów.

Istniejące modele regulatorów umożliwiają regulację przy odwadnianiu i nawadnianiu, ale nie mają możliwości szybkiej i samodzielnej analizy stanu systemu, co oznacza, że nie mogą jednocześnie kontrolować cech takich jak: poziom wody w studziencie drenarskiej, rzeczywisty PWG na działce, wilgotność gleby, temperatura, prędkość i wilgotność powietrza nad warstwą gleby zawierającą korzenie. Brak tych funkcji powoduje, że nie ma możliwości wyznaczenia optymalnego poziomu wilgotności warstwy gleby, w której znajdują się korzenie roślin. Ponadto, poziom wody w studziencie drenarskiej nie zawsze właściwie odzwierciedla PWG na terenie, co zmniejsza dokładność regulacji wilgotności gleby.

W związku z tym, przy projektowaniu SON trzeba brać pod uwagę tryby ich pracy i sposoby regulacji stosunków wodnych, a także używać takich urządzeń technicznych, które by skutecznie realizowały proces regulacji przez cały okres wegetacji, z wysoką dokładnością i takich, które by samodzielnie, na podstawie danych z czujników obliczały tryb regulacji poziomu wody w studziencie.

Opracowano konstrukcję hydroregulatora z elementem wykonawczym działania pośredniego [1]. Dodatkowo rozszerzono jego funkcjonalność w oparciu o zasadę sytuacyjnego sterowania za pomocą mikrokontrolera programowalnego, co daje możliwość organizowania kontroli i pracy zgodnie z określonym algorytmem

sterowania. Dzięki temu zapewniono odpowiednią dokładność, wydajność i skuteczność regulacji stosunków wodnych na każdym obsługiwany module SON (rys. 1).



Rys. 1. Hydroregulator poziomu wód gruntowych działania dwustronnego:  
 1 – studnia regulująca; 2 – kolektor; 3 – organ zamykający; 4 – czujnik poziomu; 5 – rura; 6, 7, 11, 12, 15, 16, 17 – zawory elektromagnetyczne; 8 – rura z filtrem; 9, 10 – komory; 13, 14 – rurki; 18 – blok mikroprocesorowy; 19 – czujnik poziomu opadów; 20 – czujnik temperatury; 21 – czujnik wilgotności powietrza; 22 – czujnik prędkości wiatru [2]

W zależności od gatunku roślin, zastosowanego systemu nawadniania, czasu wegetacji i warunków pogodowych, regulator może pracować w różnych trybach. Regulacja poziomu wód gruntowych na modułach może odbywać się albo poprzez zatrzymanie przepływu drenażowego w początkowych okresach wegetacji lub w deszczowe okresy, albo poprzez podawanie wody na nawilżenie z kanału przez kolektor (2). Hydroregulator jest zainstalowany w studni regulującej (1) i zawiera umieszczony na kolektorze organ zamykający (3) oraz czujnik poziomu (4). Czujnik poziomu znajduje się w rurze (5), która jest połączona ze studnią przez zawór elektromagnetyczny ZE (6), a przez ZE (7) i rurę z filtrem (8) – z glebą. Organ zamykający zawiera elastyczne elementy w kształcie klina połączone z kolektorem (2) oraz przez ZE (15) i (16) – ze studnią. Komora (10) jest połączona z atmosferą przez wąż z ZE (17). Czujnik poziomu (4) jest związany elektrycznie z portem wejściowym regulatora mikroprocesorowego (18), wyposażonego w bezprzewodowy interfejs komunikacyjny. Do portów wejściowych regulatora (18) podłączone są również czujniki poziomu opadów (19), temperatury (20) i wilgotności powietrza (21), prędkości wiatru (22). Wyjściowe porty mikrokontrolera sterują stanami zaworów elektromagnetycznych (6), (7), (11), (12), (15), (16) i (17). Urządzenia techniczne do pomiaru ciśnienia ssącego gleby w ramach systemu kontroli realizowane są na podstawie miernika wilgotności gleby. Mikroprocesorowy regulator (18) za pomocą organu



Pierwszy człon *OS2.1* odzwierciedla system kolektorowo-drenażowy i nasyconą strefę gleby i przekształca poziom wody w studni sterowniczej w napór w systemie kolektorowo-drenażowym, a zatem – w PWG ( $L_{w.g.}$ ).

Drugi człon *OS2.2* przedstawia nienasyconą strefę gleby i przekształca PWG modułowej działki w ciśnienie ssące  $W$  (mierzone czujnikiem *ME1*) warstwy gleby zawierającej korzenie roślin. Oprócz PWG, który jest wielkością wyjściową obiektu *OS2.1*, na obiekt *OS2.2* działają również zmienne zakłócenia. W związku z tym przedstawienie modelu obiektu w postaci transmitancji wydaje się zbyt trudnym zadaniem. Więc zaproponowano opracować model obiektu sterowania *OS2.2* w postaci sztucznych sieci neuronowych, zbudowanych na podstawie danych eksperymentalnych z Rówieńskiej rolniczej stacji badawczej. Parametrem wyjściowym sieci neuronowej jest ciśnienie ssące gleby, które związane jest z wilgotnością gleby za pomocą krzywej retencyjności wodnej. Ponieważ wilgotność gleby na następnym kroku sterowania jest zależna od parametrów meteorologicznych, PWG i bieżącej zawartości wody w glebie, to sieć neuronowa do prognozowania wilgotności gleby została przedstawiona w postaci:

$$W_{k+1}^h = NN(P_{k+1}, D_{k+1}, L_{k+1}, W_{k-1}^h, W_k^h), \quad (1)$$

gdzie parametrami wejściowymi są: opady  $P$  (mm), deficyt wilgotności powietrza  $D$  (mbar), poziom wód gruntowych  $L$  od powierzchni terenu (m). Parametrem wyjściowym jest ciśnienie ssące  $W$  (m) w określonej warstwie gleby  $h$ ,  $NN(\ )$  – transformacja, wykonywana siecią neuronową,  $k$  – bieżący krok.

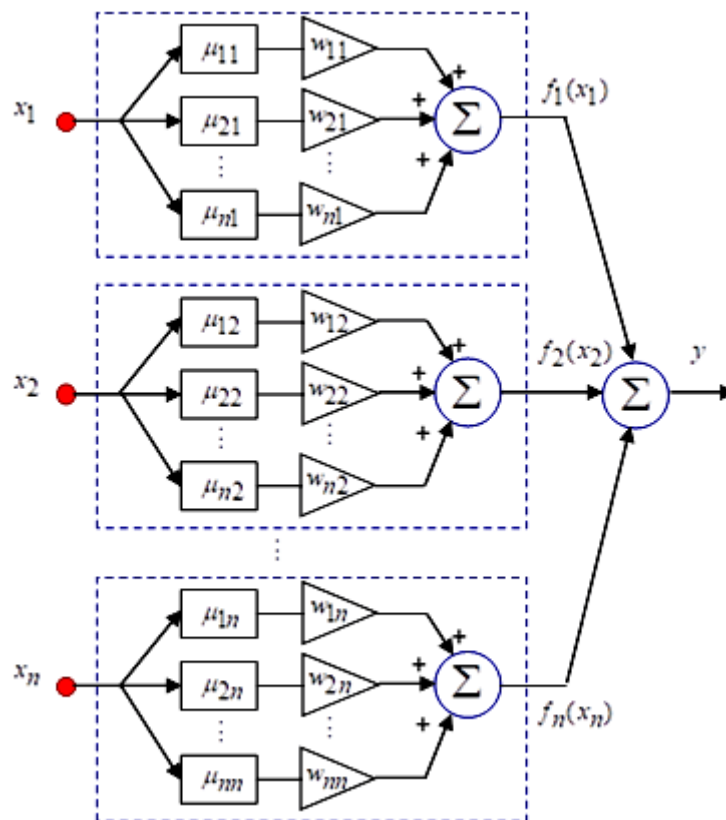
W celu opracowania modelu obiektu sterowania *OS2.2* przeprowadzono badania sieci neuronowych różniących się między sobą architekturą, metodą uczenia, wyglądem funkcji aktywacji, liczbą warstw ukrytych oraz liczbami neuronów w warstwach ukrytych. Najlepsze wyniki (tabela 1) były otrzymane przy użyciu sieci neuronowej o następniej architekturze: 3 neurony w pierwszej warstwie ukrytej z sigmoidalnymi funkcjami aktywacji, 1 neuron w drugiej warstwie ukrytej z liniową funkcją aktywacji, metoda uczenia – regularyzacja Bayesa, funkcja błędu – sumą kwadratów odchyleń między wartością zadaną a wyjściem sieci.

Obecnie, oprócz klasycznych sieci neuronowych, dynamicznie rozwijają się sieci hybrydowe, w szczególności, rozmyte sieci neuronowe. Rozmyte sieci neuronowe lub hybrydowe sieci przeznaczone są do połączenia w sobie zalet sieci neuronowych i rozmytych systemów wnioskujących [3]. Z jednej strony, pozwalają one na tworzenie i przedstawianie modeli systemów w postaci reguł rozmytych produkcji, posiadających prostotę i jasność wizualnej interpretacji. Z drugiej strony, do tworzenia reguł rozmytych produkcji wykorzystywane są metody sieci neuronowych, co jest wygodnym i mniej pracochłonnym procesem. W ostatnim czasie aparat hybrydowych sieci neuronowych jest uznawany przez specjalistów, jako jeden z najbardziej obiecujących dla rozwiązania słabo lub źle ustrukturyzowanych problemów stosowanej analizy systemowej. Główną wadą adaptacyjnych sieci neuronowo-rozmytych jest ich duża objętość i niska szybkość zbieżności algorytmów uczenia, co wymaga dużych objętościowo zbiorów danych uczących [4, 5, 6]. W celu wyeliminowania powyższych wad systemów neuronowo-rozmytych japońscy naukowcy Yamakawa T., Uchino E., Miki T., Kusanagi H. wprowadzili neo-fuzzy neuron, podobny w architekturze do  $n$ -wejściowego formalnego neuronu [7, 8]. Jego struktura jest pokazana na rysunku 3.

Zamiast zwykłych synaptycznych wag, neo-fuzzy neuron zawiera nieliniowe synapsy  $NS_i$ ,  $i=1, 2, \dots, n$ , utworzone zestawem trójkątnych symetrycznych funkcji przynależności  $\mu_{ji}$ ,  $j=1, 2, \dots, m$ , równomiernie rozmieszczonych na przedziale  $[0, 1]$ , z których każda związana jest ze swoją własną nastawianą wagą  $w_{ji}$ . Reakcja wyjściowa neo-fuzzy neuronu na wejściowy wektor danych  $x(k) = (x_1(k), x_2(k), \dots, x_n(k))^T$ ,  $k=1, 2, \dots, N$  może być przedstawiona w postaci:

$$y(k) = \sum_{i=1}^n f_i(x_i(k)) = \sum_{i=1}^n \sum_{j=1}^{m_i} \mu_{ji}(x_i(k)) \cdot w_{ji}(k), \quad (2)$$

gdzie:  $w_{ji}(k)$  – aktualna wartość synaptycznej wagi, która jest nastawiana w chwili czasu  $k$  przy  $j$ -ej funkcji przynależności  $i$ -go składnika sygnału wejściowego.



Rys. 3. Struktura neo-fuzzy neuronu

Jako kryterium uczenia się neo-fuzzy neuronu użyto błędu średniokwadratowego:

$$E(k) = \frac{1}{2} (d(k) - y(k))^2 = \frac{1}{2} e^2(k) = \frac{1}{2} (d(k) - \sum_{i=1}^n \sum_{j=1}^{m_i} \mu_{ji}(x_i(k)) \cdot w_{ji})^2, \quad (3)$$

minimalizacja którego prowadzi do algorytmu uczenia:

$$w_{ji}(k+1) = w_{ji}(k) + \eta \cdot e(k) \cdot \mu_{ji}(x_i(k)), \quad (4)$$

gdzie:  $d(k)$  – zewnętrzny uczący sygnał;  $\eta$  – parametr kroku poszukiwania, który wybiera się empirycznie i określa szybkość zbieżności procesu uczenia się. Każda zmienna sieci (1) jest podzielona na 6 równych przedziałów z trójkątnymi funkcjami przynależności, które spełniają podziały Ruspini (5):

$$\sum_{j=1}^{m_i} \mu_{ji}(x_i(k)) = 1, \quad i = 1, 2, \dots, n, \quad (5)$$

Znaczenie funkcji przynależności zmiennej  $x_i$  przy tym wyznaczamy z zależności:

$$\mu_{ji} = \begin{cases} \frac{x_i - c_{j-1,i}}{c_{ji} - c_{j-1,i}}, & x \in [c_{j-1,i}, c_{ji}], \\ \frac{c_{j+1,i} - x_i}{c_{j+1,i} - c_{ji}}, & x \in [c_{ji}, c_{j+1,i}], \\ 0 - \text{w innych przypadkach.} \end{cases} \quad (6)$$

Wyniki działania sieci neuronowej o architekturze 5-3-1, Logsig-Purelin i neo-fuzzy sieci do prognozowania ciśnienia ssącego w różnych warstwach gleby przedstawiono w tabeli 1.

Tabela 1

Wyniki działania sieci neuronowej o architekturze 5-3-1, Logsig-Purelin i neo-fuzzy sieci do prognozowania ciśnienia ssącego w różnych warstwach gleby

Warstwa gleby $h$ , cm	Odchylenie standardowe, m H <sub>2</sub> O			
	sieć neuronowa Logsig-Purelin		neo-fuzzy sieć	
	uczenie	testowanie	uczenie	testowanie
0-10	1,438	1,207	0,827	1,036
10-20	2,057	1,647	0,625	0,696
30-40	1,210	0,852	0,309	0,282

Alternatywną metodą jest przedstawienie modelu matematycznego nienasyconej strefy gleby w formie równania różniczkowego, opisującego przepływ wody w glebie (równanie Richardsa) (7):

$$\frac{\partial \theta}{\partial \tau} = \frac{\partial}{\partial z} \left[ k(\theta) \frac{\partial \psi}{\partial z} - k(\theta) \right] - I_{\theta}, \quad (7)$$

gdzie:  $\theta$  – wilgotność gleby, m<sup>3</sup> / m<sup>3</sup>;

$k = k(z, \theta)$  – przewodność hydrauliczna, m/dobę;

$\psi = \psi(z, \theta)$  – potencjał wody glebowej, m H<sub>2</sub>O;

$I_{\theta}$  – człon upustowy, umożliwiający uwzględnienie poboru wody z gleby przez system korzeniowy roślin, m<sup>3</sup>/dobę;

$z$  – zmienna przestrzenna, m;

$\tau$  – czas, doba.

Przybliżone rozwiązania równania (7) otrzymano metodą Newtona–Raphsona za pomocą oprogramowania SWAP [9]. Wyniki modelowania przepływu wody w glebie dla danych eksperymentalnych z Rówieńskiej rolniczej stacji badawczej przedstawiono w tabeli 2.

Tabela 2

Wyniki modelowania zmiany ciśnienia ssącego w różnych warstwach gleby za pomocą oprogramowania SWAP

Warstwa gleby $h$ , cm	Liczba punktów	Odchylenie standardowe, m H <sub>2</sub> O
0-10	38	1,77
10-20		1,68
30-40		1,01

Modelowanie przepływu wody w glebie metodą Newtona–Raphsona zapewnia dostateczną dokładność wyników tylko przy nieznaczących wahaniach ciśnienia ssącego, gdyż w trybach bardziej dynamicznych dokładność pogarsza się i wyznaczana zostaje tylko pewna średnia wartość.

Analizując wyniki przeprowadzonych badań, stwierdzono, że opracowane modele na podstawie neo-fuzzy sieci do prognozowania ciśnienia ssącego zapewniają wyższą dokładność w porównaniu do wielowarstwowych jednokierunkowych sieci neuronowych, mają prostszą architekturę, co skutkuje uproszczeniem ich praktycznej realizacji i zwiększeniem szybkości uczenia.

#### 4. Inteligentna metoda sterowania wilgotnością gleby

Zadaniem zewnętrznego, wiodącego, regulatora ZSS wilgotności gleby  $R_w$  (rys. 2) jest wyznaczenie wartości PWG, która musi być stabilizowana na modułowej działce SON w ciągu okresu obliczeniowego w celu zapewnienia określonej wartości ciśnienia ssącego gleby, biorąc pod uwagę zmienne parametry meteorologiczne. W tym celu zaproponowano przedstawić go w postaci sztucznej sieci neuronowej:

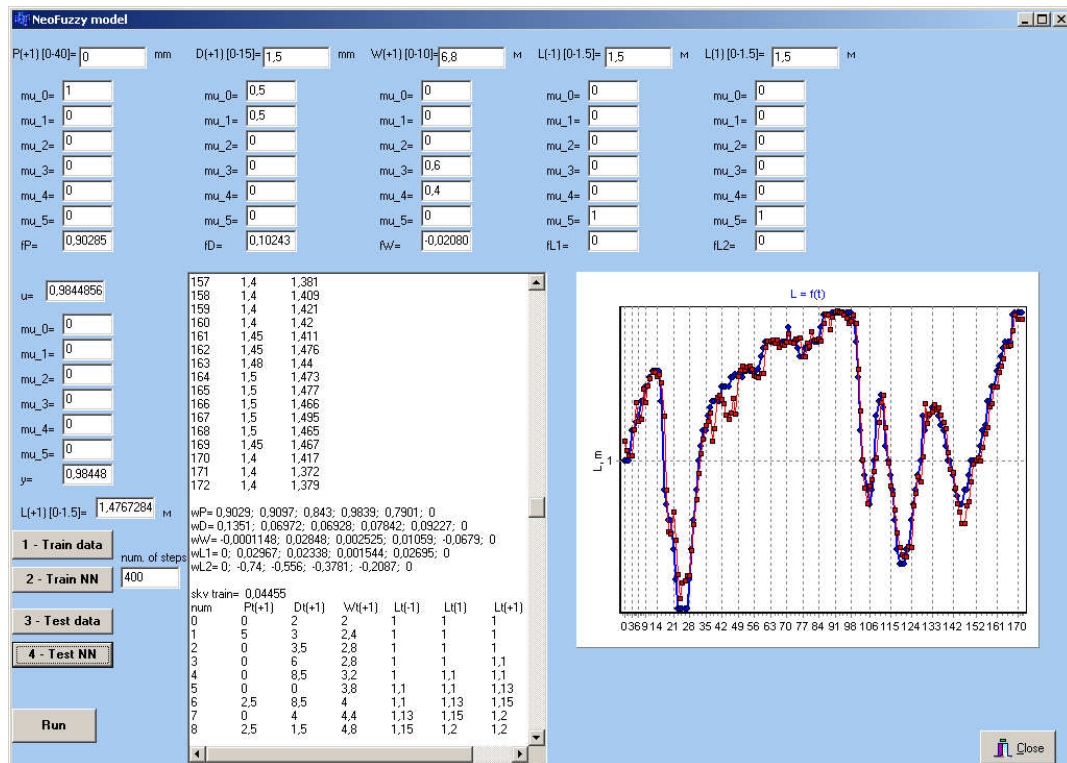
$$L_{k+1}^h = NN(P_{k+1}, D_{k+1}, L_{k-1}, L_k, W_{k+1}^h), \quad (8)$$

gdzie parametrami wejściowymi są opady  $P$  (mm), deficyt wilgotności powietrza  $D$  (mbar), ciśnienie ssące  $W^h$  (m) w określonej warstwie gleby  $h$ . Wyjściowym parametrem jest poziom wód gruntowych  $L$  od powierzchni terenu (m),  $NN(\ )$  – transformacja, wykonywana siecią neuronową,  $k$  – bieżący krok.

Badania przeprowadzono na bazie Rówieńskiej rolniczej stacji badawczej. Do tworzenia neuroregulatora były wykorzystane neo-fuzzy sieci (8).

Oprogramowanie do uczenia i testowania neo-fuzzy regulatorów do wyznaczania PGW zostało opracowane w języku C++. Przykładowe okno programu pokazane jest na rysunku 4. W tabeli 3 są pokazane odchylenia standardowe, uzyskane w procedurach uczenia i testowania modeli dla różnych warstw gleby w porównaniu z danymi eksperymentalnymi.





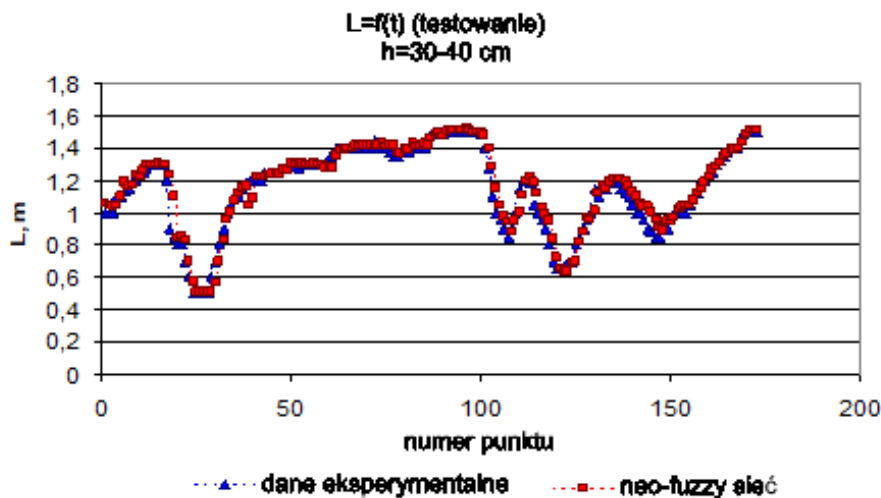
Rys. 4. Okno programu do uczenia i testowania neo-fuzzy sieci

Tabela 3

Wyniki działania neo-fuzzy regulatora do wyznaczania PWG

Warstwa gleby $h$ , cm	Liczba punktów	Odchylenie standardowe, m	
		uczenie	testowanie
0-10	173	0,048	0,055
10-20		0,051	0,059
30-40		0,055	0,066

Wyniki działania neo-fuzzy regulatora do wyznaczania PWG, dla zapewnienia zadanego ciśnienia ssącego gleby w warstwie  $h=30\div 40$  cm, przedstawiono na rysunku 5.



Rys. 5. Wyniki działania neo-fuzzy regulatora

Na podstawie wyników działania neo-fuzzy sieci, maksymalna wartość odchylenia standardowego wynosi 0,066 m. Przyrost lub spadek PWG o 0,07 m powoduje odpowiednio spadek lub wzrost ciśnienia ssącego gleby o (0,06-0,2) m H<sub>2</sub>O. Wzrost ciśnienia ssącego gleby o  $\pm 0,2$  m H<sub>2</sub>O według krzywej retencyjności wodnej odpowiada przyrostowi objętościowej wilgotności gleby  $\pm(0,5-1)\%$  w granicach zakresu roboczego. Przy sterowaniu ciśnieniem ssącym (wilgotnością) gleby wystarczy zapewnić dokładność  $\pm 5\%$  wilgotności objętościowej.

## 5. Podsumowanie

W pracy przedstawiono zautomatyzowany system sterowania wilgotnością gleby w uprawach roślin rolniczych, oparty o inteligentne metody sterowania i nowoczesne techniczne środki automatyki. Opracowane oprogramowanie do prognozowania ciśnienia ssącego gleby na podstawie neo-fuzzy sieci jest uniwersalne i może być stosowane do różnych SON z nawadnianiem wglębnym.

Wdrożenie zaproponowanego systemu pozwala zapewnić niezbędną dokładność sterowania przy jednoczesnym oszczędzaniu wody i energii, funkcjonowanie systemu sterowania w różnych trybach (automatyczny, ręczny, zdalny), poprawić efektywność i niezawodność SON.

## LITERATURA

1. Pastushenko V., Matus S., Stetsenko A. Patent. Ukraina, nr 26737. Regulator wilgotności warstwy korzeniowej gruntu : Int. Cl. G05D 22/00. Zgłosz. nr u200703637 z 02.04.2007. Opubl. 10.10.2007.
2. Matus S., Pastushenko V., Chervinko V. Patent. Ukraina, nr 8038. Tensiometer with automatic refilling : Int. Cl. G01N 9/00. Zgłosz. nr u200500073 z 04.01.2005. Opubl. 15.07.2005.
3. Ahmad M. Ibrahim: Fuzzy Logic for Embedded Systems Applications. Elsevier, Amsterdam 2004, 293 p.
4. Ding L.: The new Paradigm of Knowledge Engineering by Soft Computing. World Scientific, Sinaapore 2001, 374 p.
5. Jang J.-Sh. R., Sun Ch.-T., Mizutani E.: Neuro-Fuzzy and Soft Computing. Prentice Hall, Upper Saddle River, NJ 1997, 514 p.
6. Sigeru O., Khalid M., Yusof R.: Neuro-Control and its Applications. Springer-Verlag, London 1996, 272 p.
7. Yamakawa T., Uchino E., Miki T., Kusanagi H.: A neo-fuzzy neuron and its applications to system identification and prediction of the system. Proc. 2nd Int. Conf. on Fuzzy Logic and Neural Networks "IIZUKA – 92", Iizuka, Japan, 1992, p. 477-483.
8. Miki T., Yamakawa T.: Analog implementation of neo-fuzzy neuron and its onboarding learning. In: Computational Intelligence and Application. Ed. by N.S. Mastorakis. WSES Press, Piraeus 1999, p. 144-149.
9. Oficjalna strona projektu SWAP <http://www.swap.alterra.nl/> (dostęp 20.05.2018).