# CZASOPISMO INŻYNIERII LĄDOWEJ, ŚRODOWISKA I ARCHITEKTURY JOURNAL OF CIVIL ENGINEERING, ENVIRONMENT AND ARCHITECTURE

JCEEA, t. XXXII, z. 62 (1/15), styczeń-marzec 2015, s. 43-64

Jacek DAWIDOWICZ<sup>1</sup>

# OCENA ŚREDNIC PRZEWODÓW WODOCIĄGOWYCH ZA POMOCĄ SIECI NEURONOWYCH KOHONENA

Projektowanie systemu dystrybucji wody nieodłącznie wiąże się z wykonaniem obliczeń, których celem jest m.in. wyznaczenie natężenia przepływów przez poszczególne przewody oraz dobór średnic z zachowaniem odpowiednich prędkości przepływu. W obliczeniach systemów dystrybucji wody od wielu lat stosuje się technikę komputerową. Zwiększająca się moc obliczeniowa komputerów samoistnie nie rozwiąże złożonych problemów. Dopiero zastosowanie zaawansowanych metod obliczeniowych pozwoli usprawnić proces obliczeniowy i poprawić jakość rozwiązań. Obecnie daży się do stworzenia programów obliczeniowych, które bedzie charakteryzować pewien stopień kreatywności, co powinno ułatwić użytkownikom podejmowanie decyzji na różnych etapach realizacji zadania i poprawić jakość rozwiązań. Wydaje się, że klasyczne algorytmy o sformalizowanym przebiegu można uzupełnić znacznie bardziej zaawansowanymi technikami obliczeniowymi, w tym modelowaniem za pomocą sztucznych sieci neuronowych. W niniejszej pracy rozpatrzono możliwość zastosowania sztucznych sieci neuronowych Kohonena do oceny średnic przewodów wodociągowych. Opisano metodykę budowy zbioru danych do uczenia sieci neuronowych, metodykę procesu uczenia sieci oraz zestawiono przeanalizowane warianty sieci Kohonena. Omówiono dobór danych wejściowych oraz struktury sieci Kohonena. Uzyskane wyniki pozwalają wnioskować, że te sieci neuronowe mogłyby być uzupełnieniem tradycyjnych metod obliczeniowych. Zaletą tego rozwiązania jest mapa topologiczna, która w sposób graficzny pokazuje położenie danej średnicy względem innych średnic w zależności od parametrów opisujących odcinek obliczeniowy. Dodatkowy moduł programu komputerowego wykorzystujący sieć neuronową pozwoli zaakceptować przyjętą do obliczeń lub dokonać korekty średnicy przewodu wodociągoweg0.

Slowa kluczowe: system dystrybucji wody, obliczenia hydrauliczne, sztuczna inteligencja, sieci neuronowe Kohonena, weryfikacja wyników obliczeń

<sup>&</sup>lt;sup>1</sup> Jacek Dawidowicz, Politechnika Białostocka, 15-351 Białystok, ul. Wiejska 45A, tel. 85 7469649, j.dawidowicz@pb.edu.pl

# 1. Wprowadzenie

System zaopatrzenia w wodę jest zbudowany z wielu współpracujących ze sobą elementów. Najważniejszym z nich ze względu na koszty inwestycyjne i eksploatacyjne jest bez wątpienia system dystrybucji wody, którego prawidłowe zaprojektowanie jest niezwykle istotne, gdyż ma wpływ na funkcjonowanie całego układu przez wiele lat. Projektowanie systemu dystrybucji wody nieodłącznie wiąże się z wykonaniem obliczeń, których celem jest m.in. wyznaczenie natężenia przepływów przez poszczególne przewody oraz dobór średnic z zachowaniem odpowiednich prędkości przepływu.

W obliczeniach systemów dystrybucji wody od wielu lat stosuje się technikę komputerową. Pierwsze programy komputerowe pojawiły się w II połowie XX wieku [1, 7, 10, 18]. Od tamtego czasu nastąpił widoczny postęp w możliwościach technicznych i udogodnieniach, jakie posiadają najnowsze programy do obliczeń systemów dystrybucji wody [11, 20, 21, 23], które coraz częściej korzystają z możliwości GIS [16, 26, 32] oraz CAD [34]. Nie zmienia to jednak faktu, że poprawne wykonanie obliczeń wymaga dobrej znajomości zagadnień teoretycznych, będących podstawą algorytmów stosowanych w programach obliczeniowych, wnikliwej oceny uzyskanych wyników oraz poprawności zastosowanych rozwiązań. Nie ma i zapewne nigdy nie będzie programów, które wyręczałyby projektanta z tych zadań. Obecnie dąży się do stworzenia programów obliczeniowych, które będzie charakteryzować pewien stopień kreatywności, co powinno ułatwić użytkownikom podejmowanie decyzji na różnych etapach realizacji zadania i poprawić jakość rozwiązań.

Zwiększająca się moc obliczeniowa komputerów samoistnie nie rozwiąże złożonych problemów. W tym celu należy wprowadzić odpowiednie metody obliczeniowe, które pozwolą uzyskać właściwe efekty. Wydaje się, że klasyczne algorytmy o sformalizowanym przebiegu można obecnie uzupełnić znacznie bardziej zaawansowanymi technikami obliczeniowymi. W ostatnich latach ma się do czynienia z burzliwym rozwojem metod obliczeniowych, które można nazwać metodami inteligencji obliczeniowej (ang. *computational intelligence*, CI) [14, 24]. Termin ten obejmuje takie metody, jak sztuczne sieci neuronowe, algorytmy ewolucyjne, systemy rozmyte, systemy ekspertowe. Metody te znajdują również coraz częstsze zastosowanie w zagadnieniach związanych z zaopatrzeniem w wodę, umożliwiając usprawnienie lub wprowadzenie obliczeń i analiz numerycznych do wielu nowych problemów.

# 2. Zastosowanie sieci neuronowych w symulacji i obliczeniach hydraulicznych systemów dystrybucji wody

Sztuczne sieci neuronowe coraz częściej znajdują zastosowanie w symulacji i obliczeniach hydraulicznych systemów dystrybucji wody. W literaturze można znaleźć propozycje wykorzystania sztucznych sieci neuronowych do wspomagania tarowania modeli symulacyjnych. Tarowanie modelu jest złożonym procesem dopasowywania danych wejściowych i jego parametrów, aż do poprawnego odwzorowania warunków działania systemu wodociągowego. W pracy [17] opisano algorytm genetyczny współpracujący ze sztuczną siecią neuronową, mający na celu usprawnienie procesu tarowania modelu systemu dystrybucji wody. Natomiast w publikacji [25] opisano proces tarowania modelu oparty na metodzie prób i błędów w doborze parametrów, uzupełniony o techniki optymalizacyjne i sztucznej inteligencji, w tym sztuczne sieci neuronowe.

Podczas symulacji hydraulicznych systemów dystrybucji wody są obliczane straty ciśnienia w poszczególnych przewodach wodociągowych, m.in. za pomocą wzoru Darcy'ego-Weisbacha. Wymaga on obliczenia, najczęściej metodą iteracyjną, współczynnika oporów liniowych. W pracy [27] zaprezentowano nieiteracyjną metodę obliczania tego współczynnika za pomocą sztucznej sieci neuronowej, która pozwala skrócić czas obliczeń. Inne podejście zakładające zastosowanie sztucznych sieci neuronowych zamieszczono w pracy [4].

Moduły obliczeniowe oparte na sztucznych sieciach neuronowych wprowadzono również do metod symulacyjnych wykorzystywanych w sterowaniu sieciami wodociągowymi w czasie rzeczywistym. Zadaniem obliczeń neuronowych jest w tym przypadku uproszczenie modelu obliczeniowego i przyspieszenie obliczeń [3, 31, 35, 36]. W pracy [2] jako cel obliczeń symulacyjnych przyjęto optymalizację ciśnienia w poszczególnych węzłach sieci z uwzględnieniem prognozowanego zapotrzebowania na wodę. Modyfikacja ciśnienia jest realizowana przez odpowiednie ustawienie zaworów regulacyjnych na sieci. Biorąc pod uwagę wszystkie parametry ustawienia zaworów oraz prawa zachowania masy i energii uzyskuje się bardzo złożone układy równań nieliniowych modelujących sieci wodociągowe, których rozwiązanie wymaga znacznej mocy obliczeniowej komputerów i czasu. Do optymalizacji nastawy zaworów regulacyjnych opracowano sztuczną sieć neuronową. Zagadnienie sterowania siecią przy różnym ustawieniu zaworów regulacyjnych z zastosowaniem sieci neuronowych omówiono również w pracach [8, 9, 33].

W pracach [5, 6] poruszono zagadnienie weryfikacji średnic przewodów wodociągowych za pomocą sztucznych sieci neuronowych typu perceptron wielowarstwowy. Przeprowadzono doświadczenia mające na celu określenie struktury sieci neuronowej, ustalenie wymaganych zmiennych wejściowych oraz ich wpływu na wynik końcowy. W niniejszej pracy do tego zadania zastosowano sieci neuronowe Kohonena.

## 3. Sieci Kohonena

#### 3.1. Struktura sieci Kohonena

W latach 50. XX w. po raz pierwszy przedstawiono ideę systemu samoorganizującego się, tzn. takiego, który zmienia swoją strukturę na podstawie informacji docierającej do niego z otoczenia [28]. Pojęcie samoorganizacji na grunt sztucznych sieci neuronowych przeniósł Kohonen, który zaproponował sieć, nazywając ją samoorganizującym odwzorowaniem (ang. SOM-Self-Organizing Map) lub samoorganizującym odwzorowaniem cech (ang. SOFM-Self-Organizing Feature Map). Obecnie jest to (z różnymi modyfikacjami) najbardziej rozpowszechniony typ sieci samoorganizującej, nazywanej od swojego wynalazcy siecią Kohonena [12, 13].

Sieci Kohonena są używane do klasyfikacji bezwzorcowej, czyli są dostępne wyłącznie dane wejściowe. Na etapie uczenia sieci nie są znane docelowe wartości wyjściowe przykładów uczących. Sieci Kohonena mają na celu wyłonienie z pewnej populacji, opisanej wielowymiarowym wektorem danych  $\mathbf{X} = [\mathbf{x}_1,$  $x_2, ..., x_i, ..., x_N$ <sup>T</sup>, możliwie jednorodnych grup (skupień) pod względem rozważanych cech. Sieci tego typu składają się z dwóch warstw: wejściowej i wyjściowej. Na rysunku 1. pokazano sieć dwuwymiarową, natomiast na rys. 2. sieć jednowymiarową. Neurony warstwy wejściowej (i = 1, ..., N) służą wyłacznie do wprowadzania danych do sieci, nie wykonując przy tym żadnego przetwarzania. W warstwie wyjściowej sieci znajdują się neurony radialne, stąd jest ona nazywana warstwą radialną. Poszczególne neurony radialne są połączone ze wszystkimi wejściami, a do każdego połaczenia jest przypisana waga. Zbiór wszystkich wag połączeń dla każdego neuronu radialnego tworzy wektor wag W  $= [w_1, w_2, \dots, w_i, \dots, w_N]^T$ , tzw. wektor wzorcowy (ang. prototype vector, codebook vector). Liczba neuronów w warstwie wyjściowej jest określana przez projektanta sieci. Neurony w warstwie wyjściowej nie są ze sobą połączone, nie przesyłają między sobą informacji, lecz są związane relacją sąsiedztwa mającą wpływ na sposób uczenia neuronów.



Rys. 1. Schemat przykładowej dwuwymiarowej sieci Kohonena dla N = 2

Fig. 1. Diagram of an exemplary two-dimensional Kohonen network for N = 2



Rys. 2. Schemat przykładowej jednowymiarowej sieci Kohonena dla N = 2

Fig. 2. Diagram of an exemplary one-dimensional Kohonen network for  ${\sf N}=2$ 

#### 3.2. Model neuronu radialnego

W warstwie wyjściowej sieci Kohonena znajdują się neurony radialne (rys. 3.). Neuron tego typu realizuje funkcję zmieniającą się radialnie wokół ustalonego "centrum" **C** w wielowymiarowej przestrzeni  $\mathbf{R}^{N}$ , gdzie **N** odpowiada liczbie składowych wektora wejściowego **X**. *Funkcja radialna* przyjmuje wartości niezerowe tylko w otoczeniu "centrum", w odległości opisanej przez wartość progową neuronu **b**. Wartość progowa neuronu **b** reprezentuje promień, czyli zadane maksymalne odchylenie, powyżej którego odległość jest uważana za tak dużą, że sygnał wyjściowy przyjmuje wartości bliskie zeru. W związku z tym neuron radialny reprezentuje *hipersferę* (hiperkulę) dokonującą podziału kołowego przestrzeni  $\mathbf{R}^{N}$  wokół punktu **C**. Funkcje takie oznacza się ogólnie wzorem [13, 19]:

$$\varphi \| \mathbf{X} - \mathbf{C} \| \tag{1}$$

Współrzędne "centrum" C neuronu radialnego przestrzeni  $\mathbf{R}^{N}$  są przechowywane w jego wektorze wag W:

$$\mathbf{C} = \mathbf{W} = \begin{bmatrix} \mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_i, \dots, \mathbf{w}_N \end{bmatrix}^{\mathrm{T}}$$
(2)

Natomiast wektor X oznacza kolejne dane wejściowe do neuronu:

$$\mathbf{X} = \begin{bmatrix} x_1, x_2, ..., x_i, ..., x_N \end{bmatrix}^{\mathrm{T}}$$
(3)

Zakładając, że wektory **X** i **C** opisują dwa punkty leżące w wielowymiarowej przestrzeni  $\mathbf{R}^{N}$ , neuron radialny w pierwszej kolejności oblicza odległość  $\mathbf{r}$ pomiędzy wektorami **X** i **C** według przyjętej miary. Do obliczania odległości używa się najczęściej miary euklidesowej:

47

$$\mathbf{r} = \left\| \mathbf{X} - \mathbf{C} \right\| = \sqrt{\sum_{i=1}^{N} (\mathbf{x}_i - \mathbf{w}_i)}$$
(4)

Punkt **C** jest ustalony, natomiast punkt **X** jest zmienny, gdyż oznacza kolejne wektory wejściowe. Wartość wyjściowa *y* neuronu radialnego jest wyznaczana na podstawie odległości *r* za pomocą jednej z tzw. *funkcji radialnych*. Jedną z nich jest funkcja Gaussa w kształcie dzwonu, której kształt reguluje parametr  $\sigma$ nazywany szerokością (parametrem gładkości lub spłaszczenia):

$$\phi(\mathbf{r}) = \exp\left(-\frac{\mathbf{r}^2}{2\sigma^2}\right)$$
(5)  

$$\mathbf{x}_{\mathbf{x}} \overset{\mathbf{w}}{\mathbf{y}} \overset{\mathbf{v}}{\mathbf{y}} \overset{\mathbf{v}}{\mathbf{y}}} \overset{\mathbf{v}}{\mathbf{v}} \overset{\mathbf{$$

Fig. 3. Radial neuron diagram

#### 3.3. Uczenie sieci Kohonena

Sieci Kohonena są uczone za pomocą algorytmu pracującego w trybie bez nadzoru (uczenie samoorganizujące, uczenie bez nauczyciela) (ang. *unsupervised learning*), w którym nie są wykorzystywane wartości wyjściowe d danych uczących. W przypadku sieci Kohonena ma się do czynienia z tak zwanym uczeniem konkurencyjnym (ang. *competitive learning*). Uczenie sieci odbywa się poprzez wielokrotne pokazywanie przykładów danych uczących w postaci wektora X i modyfikacje wag neuronów wyjściowych W. W sieci są prezentowane kolejne dane wejściowe, bez informacji, jaki sygnał wyjściowy ma wygenerować sieć dla określonego wektora uczącego. Przyjmuje się, że sygnał wejściowy należy do jednej spośród kilku klas, lecz poszukiwane klasy nie są znane, a sieć samodzielnie dąży do ich wykrycia. Podobne sygnały wejściowe powinny być rozpoznawane jako należące do tej samej klasy. W ten sposób sieć Kohonena próbuje ustalić strukturę danych i występujące w nich skupienia przykładów uczących [13, 19].

Podczas uczenia sieci Kohonena wszystkie neurony warstwy wyjściowej w t-tym kroku uczenia otrzymują ten sam sygnał wejściowy, opisany wektorem  $\mathbf{X}^{(t)}$ . Po każdej t-tej prezentacji są obliczane odległości według przyjętej miary pomiędzy bieżącym wektorem  $\mathbf{X}^{(t)}$  i centrami  $\mathbf{C} = \mathbf{W}_{\mathbf{m}}^{(t)}$  wszystkich neuronów radialnych warstwy wyjściowej. Następnie zostaje wybrany neuron w warstwie wyjściowej, którego "centrum"  $\mathbf{C}$  jest najbliżej położone wektora  $\mathbf{X}^{(t)}$ , nazywany neuronem "zwycięzcą" (ang. *the Best-Matching Unit, BMU, "winner"*). "Zwycięzca" (neuron *w*-ty) spełnia zatem relację:

$$d(\mathbf{X}^{(t)}, \mathbf{W}_{w}^{(t)}) = \min_{1 \le m \le M} d(\mathbf{X}^{(t)}, \mathbf{W}_{m}^{(t)})$$
(6)

gdzie: m – indeks neuronu w warstwie wyjściowej, M – liczba neuronów w warstwie wyjściowej sieci (m = 1,..., M),  $d(\mathbf{X}^{(t)}, \mathbf{W}_{\mathbf{m}}^{(t)})$  – odległość w sensie wybranej metryki.

W celu wyboru neuronu "zwycięzcy" należy zdefiniować miarę (metrykę), według której będzie mierzona odległość między wejściowym wektorem  $\mathbf{X}^{(t)}$ a wektorami wag  $\mathbf{W}_{\mathbf{m}}^{(t)}$  poszczególnych neuronów warstwy wyjściowej. Obecnie w samoorganizujących się mapach Kohonena najczęściej jest stosowana metryka euklidesowa według wzoru (4).

Po ustaleniu neuronu "zwycięzcy" następuje proces modyfikacji wag tego jednego neuronu lub ewentualnie dodatkowo neuronów leżących w jego sąsiedztwie, tak by zbliżyć je do wartości odpowiednich składowych aktualnego wektora wejściowego  $\mathbf{X}^{(t)}$ . W skrajnej formie uczenia konkurencyjnego uczony jest tylko neuron "zwycięzca" – w tym wypadku mówi się o strategii uczenia "zwycięzca bierze wszystko" (ang. *Winner Takes All*, WTA). Inna strategia "zwycięzca bierze większość" (ang. *Winner Takes Most*, WTM) polega na tym, że są modyfikowane wagi neuronów również z otoczenia "zwycięzcy". Z reguły modyfikacja jest zależna od odległości sąsiada od "zwycięzcy" opisanej funkcją sąsiedztwa i odległość ta zmniejsza się z czasem uczenia.

Neuron "zwycięzca" oraz wszystkie neurony znajdujące się w obszarze sąsiedztwa podlegają adaptacji, zmieniając swoje wektory wag, zbliżając je do wektora wejściowego  $\mathbf{X}^{(t)}$ zgodnie z *regulą Kohonena* [13, 19]:

$$\mathbf{W}_{m}^{(t+1)} = \mathbf{W}_{m}^{(t)} + \eta_{m}^{(t)} \mathbf{h}_{wm}^{(t)} [\mathbf{X}^{(t)} - \mathbf{W}_{m}^{(t)}]$$
(7)

gdzie:  $\eta_m^{(t)}$  – współczynnik uczenia *m*-tego neuronu z sąsiedztwa w *t*-tej chwili mieszczący się w przedziale  $0 < \eta_m^{(t)} < 1$ ,  $h_{wm}^{(t)}$  – funkcja sąsiedztwa względem *w*-tego wygrywającego neuronu.

Sąsiedztwo jest bardzo ważnym elementem w uczeniu sieci Kohonena, gdyż – dokonując zmian wag nie tylko "zwycięzcy", lecz sąsiadujących z nim neuronów – sieć tworzy pewne obszary w warstwie wyjściowej, do których są przypisane podobne do siebie przykłady danych.

Ponieważ jednokrotna prezentacja zbioru wszystkich wektorów uczących z reguły nie zapewni zadowalających efektów, należy je wielokrotnie powtarzać.

Każda prezentacja całego zbioru przykładów uczących jest nazywana epoką uczenia.

W sieciach Kohonena w danych uczących nie ma wartości zadanej *d* dla wektora wejściowego **X**, stąd nie można obliczyć błędu pomiędzy wartością docelową a uzyskaną na wyjściu w określonym momencie uczenia. W związku z tym do oceny funkcjonowania sieci przyjmuje się błąd rozumiany jako odległość wektora wag zwycięskiego neuronu  $W_w^{(t)}$  od wektora wejściowego  $X^{(t)}$ . Funkcja błędu jest określona jako średnia arytmetyczna tak zdefiniowanej wartości, liczona dla całego zbioru uczącego. Z zastosowaniem normy euklidesowej oraz T w wektorach wejściowych błąd ten nazywany *błędem kwantyzacji* lub *błędem Kohonena* jest wyrażony wzorem [13, 19]:

$$E = \frac{1}{T} \sum_{t=1}^{T} \left\| \mathbf{X}^{(t)} - \mathbf{W}_{w}^{(t)} \right\|^{2}$$
(8)

Po wytrenowaniu sieci Kohonena poszczególnym neuronom można przypisać, jeśli są znane, odpowiednie etykiety klas. Przypisania etykiet klas dokonuje się za pomocą algorytmu K-L najbliższych sąsiadów, w którym danemu neuronowi przypisuje się etykietę na podstawie etykiet K najbliższych mu przypadków uczących. Warunkiem jest jednak, aby co najmniej L z K sąsiadów miało tę samą klasę, w przeciwnym wypadku etykieta neuronu będzie "nieznana" [22, 29]. Dopiero wtedy neurony radialne moga działać jako klasyfikatory. Zakłada się, że każdy sygnał wejściowy należy do jednej z kilku klas i wartość wyjściowa sieci identyfikuje klasę, do której należy dany sygnał. Po przeprowadzeniu procesu uczenia każdy neuron radialny warstwy wyjściowej, a ściślej wektor jego wag (tzw. wektor wzorcowy), staje się wzorcem ("centrum") grupy bliskich sobie sygnałów wejściowych. Po przypisaniu do poszczególnych neuronów warstwy wyjściowej odpowiadających im etykiet (nazw) poszczególnych klas uzyskuje sie tzw. mape topologiczna (rys. 7.). Mapa topologiczna pozwala w sposób graficzny określić położenie w warstwie wyjściowej neuronów opisujących poszczególne klasy, ich sasiedztwo oraz występowanie skupień. W przypadku wytrenowanej sieci oczekuje się, że podobne sygnały wejściowe powinny wywoływać zbliżone odpowiedzi sieci, stąd rozmieszczenie neuronów reprezentujacych podobne klasy powinno być zbliżone na mapie topologicznej, tworząc pewne grupy.

### 4. Sieć Kohonena do oceny średnic przewodów wodociągowych

#### 4.1. Zbiór przykładów uczących

Zastosowanie metody sztucznych sieci neuronowych wymaga sporządzenia zbioru danych z odpowiednią liczbą przykładów uczących. Poprawność funk-

cjonowania uzyskanej sieci neuronowej w znacznym stopniu jest uzależniona od jakości zbioru danych uczących.

W celu sporządzenia zbioru przykładów uczących sieci neuronowe w niniejszej pracy wykonano obliczenia systemów dystrybucji wody, wykorzystując informacje o 33 istniejących średnich i małych systemach wodociągowych. Ze względu na znaczną liczbę danych opracowano procedurę przekształcania wyników obliczeń dla poszczególnych odcinków do odpowiedniego formatu i ich zapisywania w zbiorze przykładów uczących. Obliczenia wykonano dla różnych wartości współczynnika chropowatości bezwzględnej *k*. Na podstawie wyników obliczeń hydraulicznych dla godziny maksymalnego poboru wody Q<sub>hmax</sub> uzyskano 13923 przykładów uczących. Każdy wariant obliczeniowy był sprawdzany i korygowany w przypadku nieprawidłowości obliczeniowych. Dokonując weryfikacji uzyskanych wyników symulacji, w pierwszej kolejności sprawdzano ograniczenie ciśnienia w węzłach:

$$H_{\min} \le H_i \le H_{\max}, \qquad i = 1, \dots, N_w \tag{9}$$

oraz ograniczenia prędkości przepływu na poszczególnych odcinkach:

$$V_{\min} \le V_i \le V_{\max}, \qquad i = 1, \dots, N_k \tag{10}$$

Następnie dokonano oceny średnic i strat ciśnienia na poszczególnych odcinkach obliczeniowych systemu dystrybucji wody. Niniejszy etap miał na celu doprowadzenie do poprawnego rozkładu ciśnienia w systemie dystrybucji wody i zapobieżenie nieuzasadnionemu spadkowi linii ciśnienia. Po każdej korekcie danych obliczenia były wykonywane ponownie, aż do uzyskania poprawnego rozwiązania (rys. 4.). Dopiero wówczas wyniki obliczeń były zapisywane w zbiorze uczącym. Obliczenia hydrauliczne wykonano przy następujących założeniach:

- zastosowano rury ciśnieniowe z polietylenu PE100 szeregu SDR17 (PN-EN 12201-2:2011) dla średnic do DN225 oraz rury z żeliwa sferoidalnego (PN-EN 545:2010) dla średnic wyższych,
- przyjęto średnice wewnętrzne przewodów wodociągowych,
- przyjęto minimalną średnicę przewodu DN90,
- przyjęto maksymalną średnicę przewodu DN500,
- przyjęto maksymalną długość odcinków obliczeniowych 1000 m dla tranzytu oraz 450 m dla przewodów magistralnych i rozdzielczych,
- obliczenia dla sieci pierścieniowych wykonano metodą Crossa,
- przyjęto zakres współczynników chropowatości k = 0,05÷3,5 mm,
- współczynnik oporów liniowych λ obliczano według wzoru Colebrooka-White'a,
- przyjęto, że odcinki obliczeniowe mogą być przewodami o równomiernym wydatku.

W zbiorze danych uczących zostały zapisane następujące parametry odcinków obliczeniowych:

- przepływ początkowy na odcinku Q<sub>p</sub>,
- wydatek odcinkowy q<sub>odc</sub>,
- przepływ końcowy na odcinku Q<sub>k</sub>,
- długość odcinka L,
- współczynnik chropowatości bezwzględnej k,
- wysokość strat ciśnienia na odcinku obliczeniowym  $\Delta h$ ,
- średnica nominalna SR (w przypadku sieci Kohonena niewykorzystywana w procesie uczenia, lecz etykietowania mapy topologicznej).



Rys. 4. Schemat procesu sporządzenia zbioru przykładów uczących do oceny średnic przewodów

Fig. 4. Diagram of the process of preparing a set of learning examples to assess pipe diameters

## 4.2. Metodyka uczenia sieci Kohonena do oceny średnic przewodów wodociągowych

Przeprowadzono badania mające na celu przeanalizowanie możliwości zastosowania sieci Kohonena do oceny średnic przewodów systemu dystrybucji wody. Ponieważ sieci tego typu są używane do klasyfikacji bezwzorcowej, zbiór danych podawanych do uczenia sieci będzie zawierał wyłącznie wektor danych wejściowych  $\mathbf{X} = [x_1, x_2, ..., x_i, ..., x_N]^T$ . Przyjmuje się, że sygnał wejściowy należy do jednej spośród kilku klas, lecz poszukiwane klasy nie są znane, a sieć samodzielnie dąży do ich wykrycia. Jeśli są dostępne właściwe wartości klas dla przypadków uczących, to po uczeniu sieci Kohonena można przypisać skupieniom przykładów uczących etykiety opisujące klasy.

Zastosowano uczenie sekwencyjne, tzn. przykłady uczące są prezentowane sieci wielokrotnie. Jednokrotna prezentacja zbioru wszystkich wektorów uczących jest nazywana epoka uczenia sieci neuronowej. Przykłady uczące w każdej epoce są prezentowane w kolejności losowej. Po prezentacji każdego przykładu uczącego jest wybierany neuron "zwycięzca" według zależności (6). Neuron "zwycięzca" oraz neurony znajdujące się w obszarze sąsiedztwa podlegają adaptacji, zmieniajac swoje wektory wag, zbliżajac je do wektora wejściowego  $\mathbf{X}^{(t)}$ zgodnie z regułą Kohonena (7). W procesie uczenia neuronów po wyborze neuronu zwycieskiego przyjęto sasiedztwo Gaussa według funkcji (5) ze zmieniajacym się promieniem. Powszechnie stosowaną strategią jest stopniowe zmniejszanie współczynnika uczenia n i równoczesne stopniowe zaweżanie sasiedztwa. W uczeniu sieci Kohonena wyróżnia się dwa etapy. Pierwszy etap polega na uczeniu przy znacznej wartości współczynnika uczenia i szerokim sąsiedztwie. Przyjęto  $\eta = 0.1$  zmniejszające się do  $\eta = 0.01$  oraz sąsiedztwo zmieniające się od 3 do 1 sąsiedniego neuronu. Na tym etapie przeprowadzono uczenie 1000 epok. Na drugim etapie uczeniu podlegały wyłącznie sąsiednie neurony lub tylko neuron zwycięzca. Na końcowym etapie procesu uczenia aktualizacji podlegały jedynie wagi neuronu zwycięzcy przy bardzo małej wartości współczynnika uczenia  $\eta = 0.001$ . Na drugim etapie wykonano 50000 epok uczenia.

W przypadku uczenia sieci Kohonena bardzo ważne jest skalowanie danych – jeżeli jedna ze zmiennych mieści się w zakresie [0...1000], jak na przykład długość odcinków *L*, a inna w zakresie [0...1], to ta pierwsza prawie całkowicie dominuje w organizacji neuronów na mapie topologicznej sieci Kohonena. Spowodowane jest to znacznie większym wpływem zmiennej o szerokim zakresie na wartość odległości, szczególnie gdy stosuje się miarę Euklidesową. W związku z tym zmienne wejściowe powinny być znormalizowane. Zastosowano normalizację polegającą na obliczaniu długości jednostkowej. Ten sposób normalizacji wywodzi się z geometrycznej interpretacji danych. Poszczególne zmienne wejściowe sieci neuronowej są traktowane jako składowe wektora, które są skalowane tak, aby długość całego wektora była równa 1,0.

Sieci Kohonena mogą zawierać w warstwie wyjściowej od kilkunastu do kilku tysięcy neuronów. Podstawowym zadaniem w konstruowaniu tego typu sieci jest ustalenie liczby neuronów pozwalających na poprawne odwzorowanie wszystkich skupień w danych odpowiadających klasom. Ważny też jest wybór topologii warstwy wyjściowej, gdyż od tego zależy czytelność uzyskiwanych informacji.

Badane problemy mogą być opisane dużą liczbą zmiennych, co znacznie komplikuje dobór struktury sieci neuronowej i proces uczenia. Z tego powodu korzystnie jest dokonać wyboru najbardziej odpowiednich zmiennych. Dobór zmiennych wejściowych należy przeprowadzić wraz z konstruowaniem sieci neuronowej, gdyż nie wiadomo, który zestaw spośród wszystkich dostępnych zmiennych wejściowych jest tak naprawdę użyteczny. Poszczególne składowe wektora wejściowego  $\mathbf{X} = [x_1, x_2, ..., x_i, ..., x_N]^T$  mogą mieć różny wpływ na wartość sygnałów wyjściowych sieci. Metodą stosowaną do przypisania stopnia ważności poszczególnym składowym wektora wejściowego jest tzw. *analiza wrażliwości*. Ważność każdej składowej jest mierzona jej wpływem na błąd wyjściowy. Analiza wrażliwości pozwala wskazać zmienne, które bez straty jakości funkcjonowania sieci mogą być pominięte. Analiza wrażliwości wykazuje, o ile zwiększy się błąd sieci, odrzucając konkretną zmienną. Podstawową miarą wrażliwości sieci na określoną zmienną jest *iloraz błędów*:

$$ILB_{i} = \frac{E_{i}}{E}$$
(11)

Błąd  $\mathbf{E}_i$  oblicza się dla wyuczonej sieci neuronowej z pominięciem zmiennej "i" wektora zmiennych wejściowych **X**. Błąd **E** jest to błąd sieci neuronowej dla wszystkich zmiennych stosowanych w procesie uczenia sieci. Im większy jest błąd po odrzuceniu zmiennej w stosunku do błędu dla wszystkich zmiennych, tym bardziej wrażliwa jest sieć na brak tej zmiennej. Duża wartość ilorazu wskazuje na bardzo ważną zmienną. W zestawieniach tabelarycznych w dalszej części pracy używano skróconego określenia "Iloraz".

W przypadku zadania klasyfikacji sieć neuronowa powinna dokonać przydziału przykładów opisanych za pomocą składowych wektora wejściowego do jednej z klas. W przypadku sieci Kohonena oceny jakości klasyfikacji można dokonać dopiero po przypisaniu klas do poszczególnych neuronów warstwy wyjściowej. Podstawą oceny klasyfikatora jest *lączny błąd klasyfikowania* (ang. *overall error rate*) zdefiniowany jako [15, 30]:

$$\varepsilon_{\rm ov} = \frac{n_{\rm bl}}{n_{\rm cal}} \tag{12}$$

Inną miarą jest *trafność klasyfikowania* określona jako uzupełnienie do jedynki łącznego błędu klasyfikowania, czyli:

$$\eta_{\rm ov} = 1 - \varepsilon_{\rm ov} = 1 - \frac{n_{\rm bl}}{n_{\rm cal}} = \frac{n_{\rm popr}}{n_{\rm cal}}$$
(13)

Trafność klasyfikowania w dalszej części pracy jest podawana oddzielnie dla zbioru uczącego i testowego w tabelach zawierających opis sporządzonych sieci neuronowych. Trafność klasyfikowania wyrażona w procentach nazywa się *dokładnością klasyfikowania* (ang. *classification accuracy*). Im większa wartość dokładności klasyfikowania, tym lepszy klasyfikator.

Szczegółową ocenę pomyłek sieci klasyfikacyjnej w przydziale przykładów do różnych klas umożliwia tzw. *macierz pomyłek* (ang. *confusion matrix*) [15]. Jest to macierz kwadratowa – w jej wierszach są podawane informacje, do których klas w rzeczywistości należą poszczególne przykłady, natomiast w kolumnach, do których klas zaliczył poszczególne przykłady klasyfikator. Na przekątnej są umieszczone przykłady poprawnie sklasyfikowane, a poza przekątną nieprawidłowo. Przykłady leżące poza przekątną wskazują jednocześnie, do której klasy zostały niepoprawnie zakwalifikowane.

W programie STATISTICA Neural Networks w macierzy pomyłek w górnych wierszach są dodatkowo podawane informacje zbiorcze na temat klasyfikacji przykładów z każdej klasy. Znaczenie poszczególnych wierszy w części ogólnej jest następujące [22]:

- Razem (ang. Total) liczba wszystkich przypadków w danej klasie,
- Poprawnie (ang. Correct) liczba przypadków, które należą do danej klasy i zostały poprawnie zaklasyfikowane,
- Blędnie (ang. Wrong) liczba przypadków, które należą do danej klasy, a zostały błędnie zaklasyfikowane do innych klas,
- Nieokreślone (ang. Unknow) liczba przypadków, które należą do danej klasy, a nie zostały sklasyfikowane do żadnej klasy.

#### 4.3. Przegląd przetestowanych rozwiązań sieci Kohonena do oceny średnic przewodów wodociągowych

W pierwszej kolejności przeprowadzono uczenie sieci Kohonena w postaci łańcucha składającego się z 10 neuronów w warstwie wyjściowej. Każdy neuron w warstwie wyjściowej powinien odpowiadać średnicy nominalnej. W tym wypadku na etapie uczenia nie można przypisać poszczególnym neuronom odpowiednich średnic, gdyż jest stosowana metoda bez nauczyciela. Uczenie to miało na celu sprawdzenie, czy sieć automatycznie przypisze wektory wejściowe odpowiadające poszczególnym średnicom rurociągów do kolejnych neuronów warstwy wyjściowej. Przyjęto zbiór zmiennych wejściowych L, Q<sub>p</sub>, q<sub>odc</sub>, Q<sub>k</sub>, k. Schemat tej sieci przedstawiono na rys. 5. Wynik uczenia sieci w postaci łańcucha był niezadowalający (tab. 1., poz. 1.).

Następnie utworzono sieci Kohonena o siatce kwadratowej 10 na 10, 15 na 15 oraz 20 na 20 neuronów w warstwie wyjściowej. Zastosowano ten sam zbiór zmiennych wejściowych, jak dla sieci jednowymiarowej. Wyniki uczenia dla tych sieci zamieszczono w tab. 1. Analizę wrażliwości zmiennych wejściowych dla sieci Kohonena zamieszczono w tab. 2. Wyniki wskazują, że w przypadku tego rodzaju sieci istotne są dwie zmienne  $Q_p$  i  $Q_k$ .





Fig. 5. Diagram of a one-dimensional Kohonen network to assess pipe diameters

Tabela 1. Sieci neuronowe Kohonena do oceny średnic przewodów (5 zmiennych wejściowych) Table 1. Kohonen neural networks to assess the pipe size (5 input variables)

Dane podstawowe sieci neuronowych Liczba wejść: 5 Zmienne wejściowe: L, Q <sub>p</sub> , q <sub>odc</sub> , Q <sub>k</sub> , k Zmienna wyjściowa: brak (klasyfikacja bezwzorcowa) Funkcja warstwy wyjściowej: miara Euklidesowa wg (4) Funkcja błędu: Kohonena wg (8)										
Nr sieci	Liczba neuronów ieciLiczba neuronów w warstwie wejściowejLiczba neuronów w warstwie wyjściowejBłąd na zbiorze uczącymBłąd na zbiorze testowymTrafność klasyfikowania na zbiorze uczącymTrafność klasyfikowania na zbiorze testowym									
1	5	10 (10 x 1)	0,210393	0,2090614	0,001436	0,001675				
2	5	100 (10 x 10)	0,0857	0,08404	0,1953846	0,1809478				
3	5	225 (15 x 15)	0,06057	0,05871	0,3802051	0,362853				
4	5	400 (20 x 20)	0,04815	0,04718	0,4781538	0,4511728				

Przeprowadzono uczenie sieci z dwoma zmiennymi wejściowymi  $Q_p$  i  $Q_k$ , które zostały opisane w tab. 3. Analiza wrażliwości dla tych zmiennych wykazała, że są bardzo istotne w funkcjonowaniu sieci (tab. 4.). Schemat sieci Kohonena w postaci siatki prostokątnej 10 x 10 (sieć z tab. 3., poz. 1.) pokazano na rys. 6. Tabela 2. Analiza wrażliwości zmiennych wejściowych sieci z tab. 1.

Nr sieci	Rodzaj	Parametr oceny	Zmienna wejściowa sieci Kohonena							
z tab. 1.	danych	wrażliwości zmiennych	L	Q <sub>p</sub>	q <sub>odc</sub>	$\mathbf{Q}_{\mathbf{k}}$	k			
	71.1	ranga	5	2	3	1	4			
1 Zbiór uczący	Zbior	błąd E <sub>i</sub>	0,191012	0,323536	0,202395	0,32396	0,20023			
	uczący	iloraz	0,907883	1,53777	0,961987	1,53977	0,95169			
2 Zbió ucząc	71.14	ranga	4	2	5	1	3			
	ZDIOF	błąd E <sub>i</sub>	0,07702	0,27052	0,06907	0,27080	0,08325			
	uczący	iloraz	0,89878	3,15671	0,805988	3,16013	0,97152			
		ranga	3	2	5	1	4			
3	ZDIOT	błąd e <sub>i</sub>	0,05226	0,26451	0,04887	0,26467	0,04952			
	uczący	iloraz	0,86283	4,36696	0,806770	4,36960	0,81753			
	71.14	ranga	3	2	4	1	5			
4	ZDIOP UCZACY	błąd e <sub>i</sub>	0,04266	0,26252	0,04186	0,26278	0,04051			
	uczący	iloraz	0,88604	5,45249	0,86949	5,45767	0,84138			

Table 2. A sensitivity analysis of the input network variables of Table 1

Tabela 3. Sieci neuronowe Kohonena do oceny średnic przewodów (2 zmienne wejściowe) Table 3. Kohonen neural networks to assess the pipe size (2 input variables)

Dane podstawowe sieci neuronowych Liczba wejść: 2 Zmienne wejściowe: Q <sub>p</sub> , Q <sub>k</sub> Zmienna wyjściowa: brak (klasyfikacja bezwzorcowa) Funkcja warstwy wyjściowej: miara Euklidesowa wg (4)									
Nr sieci	Nr sieciLiczba neuronówLiczba neuronówBląd neuronówTrafność klasyfikowania na zbiorze testowymTrafność klasyfikowania na zbiorze uczącym								
1	2	100 (10x10)	0,01997	0,0222	0,8285128	0,831738			
2	2	225 (15x15)	0,01161	0,01303	0,8953846	0,898277			
3	2	400 (20x20)	0,004524	0,005345	0,9368205	0,94136			
4	2	625 (25x25)	0,003046	0,003473	0,9365128	0,935376			
5	2	900 (30x30)	0,002189	0,002556	0,9758974	0,971757			
6	2	1225 (35x35)	0,001694	0,001897	0,9775385	0,969603			

Nr sieci	Rodzaj	Parametr oceny	Zmienna wejściowa sieci Kohonena				
z tab. 3.	podzbioru danych	wrażliwości zmiennych	Qp	Q <sub>k</sub>			
	Thián	ranga	2	1			
1	ZUIU	błąd E <sub>i</sub>	0,170222	0,170607			
	uczący	iloraz	8,521812	8,541101			
	Thića	ranga	2	1			
2	uczący	błąd E <sub>i</sub>	0,169709	0,170355			
		iloraz	14,61186	14,66749			
	Zbiór	ranga	2	1			
3		błąd E <sub>i</sub>	0,159892	0,170369			
	uczący	iloraz	35,34562	37,66153			
	Thián	ranga	2	1			
4	uczący	błąd E <sub>i</sub>	0,159735	0,170198			
		iloraz	52,44516	55,88043			
	7hián	ranga	2	1			
5	ZDIOF	błąd E <sub>i</sub>	0,159684	0,169645			
	uczący	iloraz	72,94723	77,49774			
	Thián	ranga	2	1			
6	ZUIOF	błąd E <sub>i</sub>	0,157999	0,169806			
	uczący	iloraz	93,25175	100,2203			

Tabela 4. Analiza wrażliwości zmiennych wejściowych sieci neuronowych z tab. 3. Table 4. A sensitivity analysis of the input network variables of Table 3



Rys. 6. Schemat sieci Kohonena do oceny średnic przewodów Fig. 6. Kohonen network diagram to assess the pipe diameters

Do neuronów warstwy wyjściowej sporządzonej sieci Kohonena przypisano etykiety poszczególnych średnic rurociągów, określając w ten sposób ich znaczenie. W sieci Kohonena występuje prawidłowość mówiąca, że bliskość sygnałów w przestrzeni wejść sieci oznacza podobieństwo sąsiednich obiektów na mapie topologicznej opisywanych tymi sygnałami. W związku z tym neurony opisujące te same średnice leżą obok siebie w grupach i stopniowo przechodzą w średnice sąsiednie z typoszeregu. Przykładową mapę topologiczną sieci Kohonena z tab. 3., poz.1 pokazano na rys. 7.

DN300	■DN300	■DN300	■DN350	■DN350	■DN400	■DN400	■DN450	⊡DN500	⊡DN500
DN300	■DN300	■DN300	■DN300	■DN350	■DN350	■DN400	■DN450	⊡DN450	⊡DN500
■DN250	■DN250	🔳 DN300	■DN300	🔳 DN350	■DN350	■DN400	■DN450	⊡DN450	⊡DN450
■DN250	■DN250	■DN250	■DN300	🔳 DN350	■DN350	■DN400	■DN450	■DN450	⊡DN450
■DN225	■DN225	■DN250	■DN250	■DN300	■DN350	■DN350	■DN400	■DN400	■DN400
■DN225	■DN225	■DN225	■DN225	■DN250	■DN300	■DN350	■DN400	■DN400	■DN400
■DN160	■DN225	■DN225	■DN225	■DN250	■DN250	■DN350	■DN350	■DN350	■DN350
■DN110	■DN160	■DN160	■DN160	■DN225	■DN250	■DN300	■DN350	■DN350	■DN350
DN90	■DN110	■DN110	■DN160	■DN160	■DN225	■DN250	■DN300	■DN350	■DN350
DN90	■DN110	■DN110	■DN160	■DN160	■DN225	■DN250	■DN300	■DN350	■DN350

Rys. 7. Przykładowa mapa topologiczna do oceny średnic rurociągów

Fig. 7. An example of a topological map to assess the pipe diameters

## 4.4. Szczegółowy opis sieci Kohonena do oceny średnic przewodów wodociągowych

W wyniku uczenia sieci neuronowych typu Kohonena wybrano strukturę o 2 neuronach w warstwie wejściowej oraz 900 neuronach w warstwie wyjściowej, uporządkowanych na kwadratowej siatce o szerokości 30 na 30 neuronów (tab. 3., poz. 5.). Na wejściu sieci są podawane wartości przepływu początkowego w gałęzi  $Q_p$  [l/s] oraz przepływu końcowego  $Q_k$  [l/s].

Uruchomienie sieci Kohonena dla podzbioru uczącego i testowego, po przypisaniu do poszczególnych neuronów etykiet opisujących średnice przewodów, pozwoliło ocenić poprawność uzyskiwanych klasyfikacji. Wyniki zamieszczone w tab. 5. i 6. wskazują na pewną liczbę niepoprawnych klasyfikacji, stanowiących jednak niewielki procent wszystkich danych. Trafność klasyfiTabela 5. Wyniki klasyfikacji średnic rurociągów wodociągowych z użyciem sieci Kohonena dla podzbioru uczącego

Table 5. Classification results of water-supply pipe diameters using Kohonen network for learning subset

	DN 90	DN 110	DN 160	DN 225	DN 250	DN 300	DN 350	DN 400	DN 450	DN 500
Razem	1265	1426	1353	1071	702	977	1020	927	622	387
Poprawnie	1239	1323	1297	1046	699	974	1017	919	622	379
Błędnie	26	103	56	25	3	3	3	8	0	8
Nieokreślone	0	0	0	0	0	0	0	0	0	0
DN90	1239	100	0	0	0	0	0	0	0	0
DN110	26	1323	56	0	0	0	0	0	0	0
DN160	0	3	1297	25	0	0	0	0	0	0
DN225	0	0	0	1046	2	0	0	0	0	0
DN250	0	0	0	0	699	3	0	0	0	0
DN300	0	0	0	0	1	974	2	0	0	0
DN350	0	0	0	0	0	0	1017	8	0	0
DN400	0	0	0	0	0	0	1	919	0	0
DN450	0	0	0	0	0	0	0	0	622	8
DN500	0	0	0	0	0	0	0	0	0	379

Tabela 6. Wyniki klasyfikacji średnic rurociągów wodociągowych z użyciem sieci Kohonena dla podzbioru testowego

Table 6. Classification results of water-supply pipe diameters using Kohonen network for testing subset

	<b>DN 90</b>	DN 110	DN 160	DN 225	DN 250	DN 300	DN 350	DN 400	DN 450	DN 500
Razem	568	598	535	457	299	428	462	419	248	164
Poprawnie	558	555	510	448	293	424	457	409	247	159
Błędnie	10	43	25	9	4	3	2	9	0	3
Nieokreślone	0	0	0	0	2	1	3	1	1	2
DN90	558	39	0	0	0	0	0	0	0	0
DN110	10	555	22	0	0	0	0	0	0	0
DN160	0	4	510	9	0	0	0	0	0	0
DN225	0	0	3	448	1	0	0	0	0	0
DN250	0	0	0	0	293	2	0	0	0	0
DN300	0	0	0	0	3	424	2	0	0	0
DN350	0	0	0	0	0	1	457	9	0	0
DN400	0	0	0	0	0	0	0	409	0	0
DN450	0	0	0	0	0	0	0	0	247	3
DN500	0	0	0	0	0	0	0	0	0	159

kacji dla zbioru uczącego wynosi 0,9758974, natomiast dla zbioru testowego 0,9717568.

## 5. Podsumowanie

Wzrastające wymagania w zakresie obliczeń systemów dystrybucji wody prowadzą do poszukiwania coraz nowszych metod, które pozwolą usprawnić proces obliczeniowy oraz wprowadzić elementy inteligentnego wspomagania. Pomimo intensywnie rozwijających się metod inteligencji obliczeniowej dotychczas znajdują one zastosowanie w bardzo niewielkim zakresie w zagadnieniach obliczeń dystrybucji wody. W niniejszej pracy przedstawiono sztuczne sieci neuronowe Kohonena do oceny średnic przewodów wodociągowych. Uzyskane wyniki pozwalają wnioskować, że analizowane sieci neuronowe mogłyby być uzupełnieniem tradycyjnych metod obliczeniowych. Zaletą tego rozwiązania jest mapa topologiczna, która metodą graficzną pokazuje położenie danej średnicy względem innych średnic w zależności od parametrów opisujących odcinek obliczeniowy.

Sztuczne sieci neuronowe mogą być przydatnym narzędziem, gdyż wymagają znacznego zasobu wiedzy i oprogramowania specjalistycznego jedynie na etapie tworzenia i weryfikacji, a później mogą być stosowane praktycznie przez każdego użytkownika komputera.

#### Literatura

- [1] Adams R.W.: Distribution analysis by electronic computer. Institute of Water Engineers, vol. 15, 1961, pp. 415-428.
- [2] Bargiela A.: High performance neural optimization for real time pressure control. Proc. of High Performance Computing Conference HPC Asia'95, Chap. AL34, 1995, pp. 1-8.
- [3] Damas M., Salmeròn M., Ortega J.: ANNs and GAs for predictive controlling of water supply networks. Proc. of the IEEE-INNS-ENNS International Joint Conference on Neural Networks, vol. 4, 2000, pp. 365-372.
- [4] Dawidowicz J.: Obliczanie współczynnika strat liniowych  $\lambda$  za pomocą sztucznych sieci neuronowych. Ekonomia i Środowisko, nr 4, 2013, s. 177-186.
- [5] Dawidowicz J.: Regresja przy użyciu sztucznych sieci neuronowych do analizy średnic przewodów wodociągowych. Mat. VI Szkoły Komputerowego wspomagania projektowania, wytwarzania i eksploatacji. Wojskowa Akademia Techniczna, Warszawa-Jurata 2002, s. 117-124.
- [6] Dawidowicz J.: Zastosowanie sztucznych sieci neuronowych do analizy średnic przewodów w systemach dystrybucji wody. Mat. IV Konferencji Naukowo-Technicznej "Nowe Technologie w sieciach i instalacjach wodociągowych i kanalizacyjnych". Politechnika Śląska, Ustroń 2002, s. 47-59.
- [7] Epp R., Fowler A.G.: Efficient code for steady state flows in networks. Journal of the Hydraulics Division, ASCE, vol. 96, no. HY1, 1970, pp. 43-56.

- [8] Haytham A., Kwamura A., Jinno K.: Analysis of motor valve operations in Fukuoka City water supply network using self-organizing map. Memoirs of the Faculty of Engineering, vol. 64. Kyushu University, Fukuoka, Japan 2004, pp. 63-77.
- [9] Haytham A., Kwamura A., Jinno K.: Applications of artificial neural networks for optimal pressure regulation in supervisory water distribution networks. Memoirs of the Faculty of Engineering, vol. 65. Kyushu University, Fukuoka, Japan 2005, pp. 29-51.
- [10] Hoag L.N., Weinberg G.: Pipeline network analysis by electronic digital computer. Journal of the American Water Works Association, ASCE, vol. 49, no. 5, 1957, pp. 517-524.
- [11] Knapik K.: Dynamiczne modele w badaniach sieci wodociągowych. Wydaw. Politechniki Krakowskiej, Kraków 2000.
- [12] Kohonen T.: Self-organizing maps. Springer Series in Information Sciences, vol. 30, 2001 (3rd extended ed.).
- [13] Kohonen T.: The self-organizing map. Proc. of the IEEE, vol. 78, no. 9, 1990, pp. 1464-1480.
- [14] Konar A.: Computational intelligence: Principles, techniques and applications, Springer-Verlag, 2005.
- [15] Krawiec K., Stefanowski J.: Uczenie maszynowe i sieci neuronowe. Wydaw. Politechniki Poznańskiej, Poznań 2004.
- [16] Kwietniewski M.: GIS w wodociągach i kanalizacji. Wydawnictwo Naukowe PWN, Warszawa 2013.
- [17] Lingireddy S., Ormsbee L.E.: Neural networks in optimal calibration of water distribution systems, [in:] Artificial Neural Networks for Civil Engineers: Advanced Features and Applications, Flood I. (ed.), Kartam N. ASCE, 1998, pp. 53-76.
- [18] Ormsbee L.E.: The history of water distribution network analysis: The computer age. Proc. of the 8th Annual Water Distribution Systems Analysis Symposium, ASCE, 27-30 August, Cincinnati, Ohio, USA 2006, pp. 1-6.
- [19] Osowski S.: Sieci neuronowe do przetwarzania informacji. Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa 2000.
- [20] Pipe 2010. Water Utility Modeling: A comprehensive guide to hydraulic and water quality modeling of drinking water systems using Pipe2010. KYPipe, http://kypipe.com (dostęp: 20.02.2015 r.).
- [21] Pipe Flow Expert 2010 User Guide, WEB: http://www.pipeflow.co.uk (dostęp: 20.02.2015 r.).
- [22] Przewodnik problemowy. STATISTICA Neural Networks PL. StatSoft Inc., 2001.
- [23] Rossman L.A.: EPANET 2. User's manual, EPA/600/R-00/057. National Risk Management Research Laboratory. U.S. Environmental Protection Agency, USA 2000.
- [24] Rutkowski L.: Metody i techniki sztucznej inteligencji. Inteligencja obliczeniowa. Wydawnictwo Naukowe PAN, Warszawa 2009.
- [25] Saldarriaga J., Gómez R., Salas D.: Artificial intelligence methods applicability on water distribution networks calibration. Critical Transitions in Water and Environmental Resources Management, 2004, pp.1-11.
- [26] Shamsi U.M.: GIS applications for water, wastewater, and stormwater systems. CRC PressINC, Taylor & Francis Group, New York 2005.

- [27] Shayya W.H., Sablani S.S.: An artificial neural network for non-iterative calculation of the friction factor in pipeline flow. Computers and Electronics in Agriculture, vol. 21, no. 3, 1998, pp. 219-228.
- [28] Skubalska-Rafajłowicz E.: Samoorganizujące sieci neuronowe, [w:] Biocybernetyka i inżynieria biomedyczna 2000, Nałęcz M., Duch W., Korbicz J., Rutkowski L., Tadeusiewicz R. (eds.), t. 6. Sieci Neuronowe. Polska Akademia Nauk, Warszawa 2000, s. 179-226.
- [29] STATISTICA Neural Networks. StatSoft Inc., 1998.
- [30] Stefanowski J.: Algorytmy indukcji reguł decyzyjnych w odkrywaniu wiedzy. Wydawnictwo Politechniki Poznańskiej, Seria Rozprawy nr 361, Poznań 2001.
- [31] Świercz M.: Using neural networks to simplify mathematical models of water distribution networks. A case study. Proc. of the First International Symposium on Mathematical Models in Automation and Robotics. Wydawnictwo Uczelniane Politechniki Szczecińskiej, Szczecin 1994, pp. 72-77.
- [32] Taher S.A., Labadie J.W.: Optimal design of water-distribution networks with GIS. Journal of Water Resources Planning and Management, ASCE, vol. 122, no. 4, 1996, pp. 301-311.
- [33] Van den Boogaard H.F., Kruisbrink A.C.H.: Hybrid modeling by integrating neural networks and numerical models hydraulic engineering. Proc. of the 2<sup>nd</sup> International Conference on Hydroinformatics, vol. 2, 1996, pp. 471-477.
- [34] Walski M.T., Chase D.V., Savic D.A., Grayman W.M., Beckwith S., Koelle E.: Advanced water distribution modeling and management. Haestad Methods Solution Center, Haestead Press, 2003.
- [35] Xu C., Bouchart F., Goulter I.C.: Neural networks for hydraulic analysis of water distribution systems. Proc. of the Innovation in Computer Methods for Civil and Structural Engineering. Civl-Comp Press, Cambridge 1997, pp. 129-136.
- [36] Yongchao L., Wending L.: Water supply system of telemeter and remote control based on neural fuzzy control technique. Proc. of the 5th International Symposium on Test and Measurement Conference ITSM 2003, pp. 1269-1272.

### THE EVALUATION OF WATER PIPE DIAMETERS USING KOHONEN NEURAL NETWORKS

Summary

Designing water distribution systems is inherently linked to the implementation of calculations whose aim is, among others, to determine flow rates for individual pipes and choose diameters with appropriate flow velocity. In the calculations for water distribution systems, computer technology has been used for many years. Increasing computing power will not, however, solve the complex problems by itself. Only the application of advanced computational methods is able to genuinely enhance the computational process and improve the quality of the used solutions. Currently, the goal is to develop such computer programs that would feature a certain degree of creativity, which should help users make decisions at different stages of performing the task, and improve the quality of the used solutions. It appears that traditional algorithms with a formalized pattern can now be replaced by more sophisticated computational techniques, including modeling with the use of artificial neural networks. The following paper examines the possibility of applying Kohonen artificial neural networks (also known as self-organizing maps) to evaluate the diameter of water pipes. The study describes the construction methodology behind the data set for neural

network learning and network learning process methodology, also summarizing the analyzed variants of Kohonen networks. The paper then goes on to discuss the selection of input data and the Kohonen network structure. The obtained results allow to conclude that these neural networks could complement the traditional methods of calculation. The advantage of this solution is the topological map which graphically shows the location of a given diameter with respect to the other diameters, depending on the parameters describing the calculation section. The additional module of a computer program, based on a neural network, will help approve, or revise, the adopted water pipe diameter.

**Keywords:** water distribution system, hydraulic calculations, artificial intelligence, Kohonen neural networks, verification of calculation results

Przesłano do redakcji: 11.12.2014 r. Przyjęto do druku: 28.03.2015 r.

DOI: 10.7862/rb.2015.4