

Raport Badawczy
Research Report

RB/20/2013

**Algorytmy detekcji
i lokalizacji wycieków
w sieciach wodociągowych**

J. Studziński, I. Rojek

Instytut Badań Systemowych
Polska Akademia Nauk

Systems Research Institute
Polish Academy of Sciences



POLSKA AKADEMIA NAUK

Instytut Badań Systemowych

ul. Newelska 6

01-447 Warszawa

tel.: (+48) (22) 3810100

fax: (+48) (22) 3810105

Kierownik Zakładu zgłaszający pracę:
Prof. nadzw. dr hab. inż. Jan Studziński

Warszawa 2013

**Algorytmy detekcji i lokalizacji wycieków w sieciach
wodociągowych**

Jan Studziński, Izabela Rojek

Warszawa 2013

Spis treści

1. Wstęp	4
2. Sieci neuronowe.....	4
2.1. Sieci jednokierunkowe wielowarstwowe typu MLP	5
2.2. Sieć neuronowa samoorganizująca się Kohonena [20]	12
2.3. Podsumowanie sieci neuronowych użytych do eksperymentów	22
3. Eksperymenty dotyczące tworzenia algorytmów lokalizacji awarii w sieci wodociągowej	22
3.1. Stan obecny	22
3.2. Analiza lokalizacji awarii przy wykorzystaniu sieci neuronowej.....	23
3.2.1. Algorytm lokalizacji awarii sieci wodociągowej.....	23
3.2.2. Wyznaczenie punktów wrażliwych sieci wodociągowej przy użyciu algorytmu do planowania systemu monitoringu	24
3.2.3. Wykonanie obliczeń hydraulicznych sieci, dla zadanego poziomu obciążenia, za pomocą wybranego modelu hydraulicznego	24
3.2.4. Tworzenie klasyfikatora	28
4. Utworzenie i wybór najlepszego klasyfikatora lokalizującego punkty pomiarowe najbliższej awarii w postaci wybranych sieci neuronowych	34
4.1. Utworzenie i wybór najlepszego klasyfikatora w postaci sieci neuronowych typu MLP	35
4.2. Utworzenie i wybór najlepszego klasyfikatora w postaci sieci neuronowych Kohonena	43
5. Utworzenie i wybór najlepszego klasyfikatora lokalizującego awarie w węźle dla 10 punktów pomiarowych.....	51
5.1. Utworzenie i wybór najlepszego klasyfikatora w postaci sieci typu MLP.....	51
5.2. Utworzenie i wybór najlepszego klasyfikatora w postaci sieci Kohonena	59
5.3. Porównanie najlepszych sieci neuronowych MLP i Kohonena dla pliku z danymi oryginalnymi, poprawionymi i poprawionymi bez powtórzeń kolumn.....	65
6. Utworzenie i wybór najlepszego klasyfikatora lokalizującego awarie w węźle dla 20 punktów pomiarowych.....	66
6.1. Utworzenie i wybór najlepszego klasyfikatora w postaci sieci typu MLP.....	66
6.2. Utworzenie i wybór najlepszego klasyfikatora w postaci sieci Kohonena.....	73
6.3. Analiza wyników sieci neuronowych typu MLP i Kohonena dla pliku z danymi oryginalnymi	76
6.4. Utworzenie i wybór najlepszego klasyfikatora lokalizującego awarie w postaci sieci neuronowych typu MLP dla pliku zmodyfikowanego z usuniętymi 2 kolumnami (usunięta kolumna pp2 i pp7)	78
6.5. Utworzenie i wybór najlepszego klasyfikatora lokalizującego awarie w postaci sieci neuronowych typu Kohonena dla pliku zmodyfikowanego z usuniętymi 2 kolumnami (usunięta kolumna pp2 i pp7)	81

6.6. Analiza wyników sieci neuronowych typu MLP i Kohonena dla pliku z danymi zmodyfikowanymi bez powtórzeń.....	82
6.7. Porównanie wyników dla danych oryginalnych i zmodyfikowanych dla sieci MLP i Kohonena.....	83
6.8. Dane oryginalne – sieci MLP i Kohonena.....	86
7. Podsumowanie wyników dla sieci neuronowych dla 10 i 20 punktów pomiarowych z danymi oryginalnymi i zmodyfikowanymi dla sieci MLP i Kohonena.....	88
8. Zmodyfikowane sieci Kohonena.....	91
Literatura.....	91

4. Utworzenie i wybór najlepszego klasyfikatora lokalizującego punkty pomiarowe najbliższej awarii w postaci wybranych sieci neuronowych

Modele lokalizacji punktów pomiarowych najbliższej awarii sieci są tworzone przy wykorzystaniu sieci neuronowych typu MLP oraz Kohonena.

W ramach prowadzonych badań zostały wykonane eksperymenty z różnymi sieciami neuronowymi. Pierwszy etap badań został wykonany z wykorzystaniem 10 punktów pomiarowych oraz 36 węzłów sieci wodociągowej, w których symulowano awarie. Cała sieć wodociągowa zawierała 390 węzłów. W drugim etapie zwiększono liczbę punktów pomiarowych do 20 i węzłów do 44.

Dla 10 punktów pomiarowych przygotowałam różne sytuacje awaryjne dla różnych węzłów. W ten sposób powstało 38 przykładów sytuacji awaryjnych i w normie. Następnie 8 razy powieliłam te przykłady ($8 \times 38 = 304$), gdyż w przypadku uczenia sieci neuronowych należy mieć powtarzalność przykładów w pliku z danymi. Podobnie zrobiłam dla 20 punktów pomiarowych. Tylko tutaj powstało 45 przykładów sytuacji awaryjnych i w normie. Następnie 8 razy powieliłam te przykłady ($8 \times 45 = 360$).

Struktura plików danych do uczenia, testowania i walidacji jest taka sama, czyli wejścia sieci zawierają przepływy wody w wybranych węzłach sieci wodociągowej (36 wejść dla 10 punktów pomiarowych, 44 wejść dla 20 punktów pomiarowych). Wyjście sieci wskazuje 1 punkt pomiarowy, który jest najbardziej wrażliwy na awarię. Jeśli przyjmiemy 100% przykładów to plik uczący zawiera 70% przykładów, plik testowy 15%, a plik walidacyjny kolejne 15%.

Plik uczący służy do uczenia sieci neuronowej.

Plik testowy pozwala zweryfikować jak sieć się nauczyła.

Natomiast dobrze jest użyć jeszcze jednego pliku walidacyjnego. Podobnie jak w przypadku danych testowych, danych walidacyjnych nie używa się w procesie uczenia sieci, natomiast po zakończeniu uczenia oblicza się błąd sieci dla tych danych. Jeśli błąd walidacyjny nie odbiega znacznie od błędu testowego, to można uznać, że sieć dobrze generalizuje strukturę danych i będzie dobrze działać dla zupełnie nowych danych (dla których nie policzymy już błędów, gdyż nie będziemy mieli wartości zmiennej wyjściowej).

Struktura pliku dla 10 punktów pomiarowych została pokazana na rys. 11. Omówienie struktury pliku jest pod rysunkiem.

18	19	20	21	22	23	24	25	26	27	28	29	30	31	32	33	34	35	36	37
1195	216	1375	1673	1963	2046	2158	2186	2447	2740	2779	3028	6144	3587	3696	4138	4181	4250	4411	Punkt_pom
-11,73	-7,57	-5,76	-7,1	-7,82	-8,45	-5,74	4,2	-4,83	-5,04	-94,46	-2,71	-2,79	-3,1	-8,43	-6,31	-2,2	-1,69	-4,76	0
-11,73	-7,57	-5,76	-7,1	-7,82	-8,45	-5,74	4,2	-4,83	-5,04	-94,46	-2,71	-2,79	-3,1	-8,43	-6,31	-2,2	-1,69	-4,76	1
-11,73	-7,57	-5,76	-7,1	-7,82	-8,45	-5,74	4,2	-4,83	-5,04	-94,46	-2,71	-2,79	-3,1	-8,43	-6,31	-2,2	-1,69	-4,76	3
-11,73	-7,57	-5,76	-7,1	-7,82	-8,45	-5,74	4,2	-4,83	-5,04	-94,46	-2,71	-2,79	-3,1	-8,43	-6,31	-2,2	-1,69	-4,76	8
-11,73	-7,57	-5,76	-7,1	-7,82	-8,45	-5,74	4,2	-4,83	-5,04	-94,46	-2,71	-2,79	-3,1	-8,43	-6,31	-2,2	-1,69	-4,76	3
-11,73	-7,57	-5,76	-7,1	-7,82	-8,45	-5,74	4,2	-4,83	-5,04	-94,46	-2,71	-2,79	-3,1	-8,43	-6,31	-2,2	-1,69	-4,76	8
-11,73	-7,57	-5,76	-7,1	-7,82	-8,45	-5,74	4,2	-4,83	-5,04	-94,46	-2,71	-2,79	-3,1	-8,43	-6,31	-2,2	-1,69	-4,76	8
-11,73	-7,57	-5,76	-7,1	-7,82	-8,45	-5,74	4,2	-4,83	-5,04	-94,46	-2,71	-2,79	-3,1	-8,43	-6,31	-2,2	-1,69	-4,76	8
-11,73	-7,57	-5,76	-7,1	-7,82	-8,45	-5,74	4,2	-4,83	-5,04	-94,46	-2,71	-2,79	-3,1	-8,43	-6,31	-2,2	-1,69	-4,76	3
-11,73	-7,57	-5,76	-7,1	-7,82	-8,45	-5,74	4,2	-4,83	-5,04	-94,46	-2,71	-2,79	-3,1	-8,43	-6,31	-2,2	-1,69	-4,76	8
-11,73	-7,57	-5,76	-7,1	-7,82	-8,45	-5,74	4,2	-4,83	-5,04	-94,46	-2,71	-2,79	-3,1	-8,43	-6,31	-2,2	-1,69	-4,76	3
-11,73	-7,57	-5,76	-7,1	-7,82	-8,45	-5,74	4,2	-4,83	-5,04	-94,46	-2,71	-2,79	-3,1	-8,43	-6,31	-2,2	-1,69	-4,76	8
-11,73	-7,57	-5,76	-7,1	-7,82	-8,45	-5,74	4,2	-4,83	-5,04	-94,46	-2,71	-2,79	-3,1	-8,43	-6,31	-2,2	-1,69	-4,76	9
-11,73	-7,57	-5,76	-7,1	-7,82	-8,45	-5,74	4,2	-4,83	-5,04	-94,46	-2,71	-2,79	-3,1	-8,43	-6,31	-2,2	-1,69	-4,76	3
-11,73	-7,57	-5,76	-7,1	-7,82	-8,45	-5,74	4,2	-4,83	-5,04	-94,46	-2,71	-2,79	-3,1	-8,43	-6,31	-2,2	-1,69	-4,76	3
-55,73	-7,57	-5,76	-7,1	-7,82	-8,45	-5,74	4,2	-4,83	-5,04	-94,46	-2,71	-2,79	-3,1	-8,43	-6,31	-2,2	-1,69	-4,76	3

Rys. 11. Fragment danych pliku uczącego sieci neuronową (10 punktów pomiarowych)

Ostatnia kolumna (punkt_pom) jest wyjściem sieci. Podane są numery punktów pomiarowych, wartość 0 oznacza normę, a np. 3 oznacza, że punkt pomiarowy 3 jest najbardziej wrażliwy na awarię.

Pozostałe kolumny to wejścia sieci neuronowej. Np. 18 to jest numer kolumny, a 1195 jest to numer węzła. Wartość -11,73 to jest norma, a wartość -55,73 jest awarią.

4.1. Utworzenie i wybór najlepszego klasyfikatora w postaci sieci neuronowych typu MLP

Modele sieci zostały utworzone przy wykorzystaniu sieci neuronowych typu MLP. Sieci MLP niezmiennie są najbardziej rozpowszechnionymi i uniwersalnymi sieciami neuronowymi stosowanymi do rozwiązywania różnych problemów.

Eksperymenty związane z tworzeniem modeli sieci neuronowych typu MLP były parametryzowane dwoma parametrami: liczbą neuronów w warstwie ukrytej oraz liczbą epok uczących. W eksperymencie parametr liczba neuronów w warstwie ukrytej przyjmował wartości od 5 do 25, natomiast drugi parametr liczba epok uczących przyjmował wartości: 200, 500 i 1000. Po zakończeniu każdego eksperymentu, przeprowadzone były testy, które dostarczały informacji na temat błędnie zakwalifikowanych decyzji. Liczba neuronów w warstwie ukrytej została dobrana eksperymentalnie. Wejścia sieci zawierają przepływy wody w wybranych węzłach sieci wodociągowej (36 wejść dla 10 punktów pomiarowych, 44 wejść dla 20 punktów pomiarowych). Wyjście sieci wskazuje punkt pomiarowy, który lokalizuje awarię.

Na rys. 11 pokazano fragment danych, które posłużyły jako wejścia i wyjście sieci neuronowych. Wejścia sieci stanowią węzły sieci wodociągowej, natomiast wyjściem jest numer punktu pomiarowego.

Sieć MLP ma strukturę jednokierunkową (*feedforward*): sygnał przepływa w nim tylko w jednym kierunku - od wejść, poprzez kolejne neurony ukryte, osiągając ostatecznie neurony wyjściowe. Jednak architektura sieci nie do końca określa jej cechy, ważne są też funkcje

aktywacji odpowiedzialne za transmisję sygnału z wcześniejszych neuronów, którą określa konkretna zależność matematyczna.

Wybór funkcji aktywacji ma duży wpływ na działanie sieci.

Neurony wejściowe zwykle nie mają w ogóle funkcji aktywacji (mają funkcję *identycznościową*, nie dokonującą żadnych zmian sygnału). Sygnały z nich są natomiast "konbinowane" razem poprzez ważenie (wagami neuronów warstwy ukrytej) i przekazywane dalej do następných neuronów (ukrytych).

W przypadku neuronów w warstwie ukrytej **funkcja aktywacji** jest typu liniowa, logistyczna, Tanh (tangens hiperboliczny) lub wykładnicza. **Funkcją aktywacji** neuronów wyjściowych jest funkcja liniowa, Tanh lub Softmax.

Funkcja liniowa. Jako funkcja aktywacji w tym przypadku wykorzystywana jest funkcja liniowa. Po wybraniu tej funkcji, poziom aktywacji jest bezpośrednio przekazywany na wyjście. Zakres nieści się $(-\infty, +\infty)$.

Funkcja tangens hiperboliczny (Tanh) jest funkcją symetryczną, S-kształtną, z wartościami wyjściowymi mieszczącymi się w przedziale $(-1, 1)$. Z uwagi na symetrię funkcji tanh, często działa ona lepiej niż funkcja logistyczna.

$$\frac{e^a - e^{-a}}{e^a + e^{-a}}$$

(4.1)

Funkcja logistyczna. Jako funkcja aktywacji w tym przypadku wykorzystywana jest funkcja logistyczna sigmoidalna. Funkcja ta jest krzywą S-kształtną (sigmoidalną), o wartościach wyjściowych z przedziału $(0,1)$.

$$\frac{1}{1 + e^{-a}}$$

(4.2)

Funkcja wykładnicza. Jako funkcja aktywacji w tym przypadku wykorzystywana jest funkcja wykładnicza.

$$e^{-a}$$

(4.3)

Funkcja Softmax. Jako funkcja aktywacji zostanie wykorzystana funkcja o postaci:

$$\frac{\exp(a_i)}{\sum \exp(a_i)} \quad (4.4)$$

Funkcja błędu jest używana do oceny aktualnej jakości sieci w procesie jej uczenia. Jest ona miarą zgodności predykcji sieci z zadaną wartością. Jest to kryterium stopu.

Używana jest ona do wyznaczenia wielkości niezbędnych zmian wag neuronów w każdej iteracji. Funkcja błędu to parametr algorytmu uczącego sprawdzającego postępy i oceniającego, co trzeba jeszcze poprawić.

Funkcje błędu używane przy uczeniu sieci neuronowych powinny dawać jakąś miarę odległości predykcji od rzeczywistej wartości, w danym punkcie przestrzeni zmiennych wejściowych. Naturalne jest więc użycie jako funkcji błędu sumy kwadratów różnic (*Sum Of Squares*):

$$E_{\text{SOS}} = \sum_{i=1}^N (y_i - t_i)^2 \quad (4.5)$$

N to liczba przykładów (par wejście-wyjście) używanych do uczenia, y_i oznacza predykcję sieci (wyjście sieci), a t_i jest "rzeczywistą" wartością (wyjście wg danych), dla i -tego przypadku. Im większe są różnice tym większy będzie błąd i tym większej korekty wymaga sieć.

Funkcja błędów w postaci sumy kwadratów pierwotnie używana była do problemów regresyjnych, używa się jej jednak również przy klasyfikacji.

Nie mniej jednak prawdziwy klasyfikator neuronowy musi mieć inną funkcję błędu, jest to *entropia wzajemna*.

Funkcja błędu w postaci entropii wzajemnej (*Cross Entropy*) ma następującą postać

$$E_{\text{CE}} = -\sum_{i=1}^N t_i \ln \left(\frac{y_i}{t_i} \right) \quad (4.6)$$

Zakłada się tu, że zmienna wyjściowa podlega rozkładowi wielomianowemu, w przeciwieństwie do poprzedniej sytuacji sumy kwadratów, gdzie zmienna wyjściowa miała rozkład normalny.

Sieci neuronowe są narzędziem z gruntu nieliniowym, uczonym z reguły przez algorytmy iteracyjne. Najczęściej zalecanymi algorytmami są *BFGS* (Broyden-Fletcher-Goldfarb-Shanno) i *Skalowane gradienty sprzężone* (*Scaled Conjugate Gradient*).

Algorytmy te są znacznie lepsze od dawniej stosowanych algorytmów takich jak metoda *najszybszego spadku*, mają one jednak duże wymagania co do pamięci komputera i szybkości obliczeń. Algorytm BFGS (Broyden-Fletcher-Goldfarb-Shanno) (lub Quasi-Newtona) jest silnym algorytmem drugiego rzędu o szybkiej zbieżności, lecz wymaga dużej

pamięci. W sumie jednak wymagają one mniej iteracji w procesie uczenia, gdyż są szybciej zbieżne, mając bardziej zaawansowany mechanizm poszukiwawczy.

Błąd dla danych uczących z każdym epoką maleje, natomiast błąd dla niezależnych danych testowych w pewnym momencie zaczyna rosnąć i jest to najwyższy czas by zaprzestać dalszego uczenia sieci. Jest parę sposobów walki z nadmiernym dopasowaniem (*overfitting*) sieci do danych uczących, których celem jest otrzymanie sieci z należycie zgeneralizowaną wiedzą o danych.

Podstawową metodą jest użycie niezależnych danych testowych. Dane testowe to zbiór przykładów, które nigdy nie były używane do uczenia danej sieci. Są one natomiast używane, poprzez badanie dokładności predykcji, do oceny postępów sieci w coraz lepszym modelowaniu zależności wejście-wyjście, w miarę uczenia sieci. Większość prac dotyczących oceny skuteczności modelowania za pomocą sieci skupia się na wykorzystaniu danych testowych. Sieć neuronowa, w procesie uczenia optymalizowana jest w stosunku do danych uczących. Niezależne testy prowadzone są by nie dopuścić do nadmiernego dopasowania, czyli *przeuczenia* sieci. Dostatecznie wczesne zatrzymanie procesu uczenia sieci zapobiega nadmiernemu dopasowaniu i maksymalizuje stopień generalizacji.

W ostatecznym rachunku dane testowe jednak były wykorzystane w procesie uczenia sieci. Dlatego, czasami wskazane jest użycie jeszcze jednego, nowego zestawu danych do sprawdzenia dokładności sieci, dane takie nazywamy *walidacyjnymi*. Podobnie jak w przypadku danych testowych, danych walidacyjnych nie używa się w procesie uczenia sieci, natomiast po zakończeniu uczenia oblicza się błąd sieci dla tych danych. Jeśli błąd walidacyjny nie odbiega znacznie od błędu testowego, to można uznać, że sieć dobrze generalizuje strukturę danych i będzie dobrze działać (jak tylko jest to możliwe) dla zupełnie nowych danych (dla których nie policzymy już błędu, gdyż nie będziemy mieli wartości zmiennej wyjściowej).

Tabela 1 ilustruje parametry opisujące eksperymenty dla różnych struktur sieci MLP w przypadku 10 punktów pomiarowych. Jakość wyrażona jest w %.

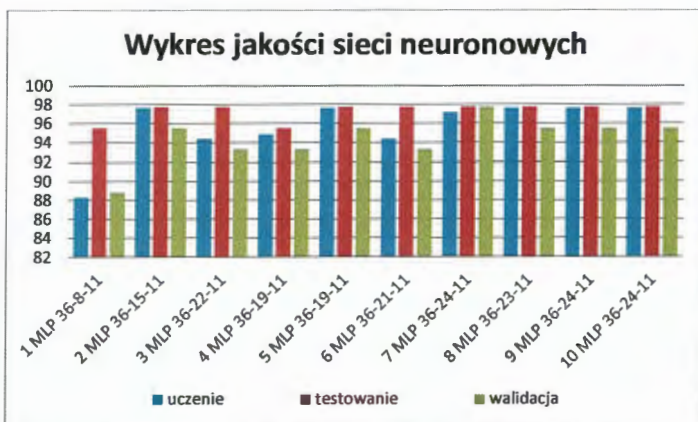
Tabela 1. Struktury sieci typu MLP

Id	Nazwa sieci	Jakość uczenia	Jakość testowania	Jakość walidacji	Średnia jakość sieci (%)	Algorytm uczenia	Funkcja błędu	Aktywacja (ukryte)	Aktywacja (wyjściowe)
1	MLP 36-8-1	88,32	95,56	88,89	90,92	BFGS 25	Entropia	Logistyczna	Softmax
2	MLP 36-15-1	97,66	97,78	95,56	97,00	BFGS 22	Entropia	Liniowa	Softmax
3	MLP 36-22-1	94,39	97,78	93,33	95,17	BFGS 33	Entropia	Tanh	Softmax
4	MLP 36-19-11	94,86	95,56	93,33	94,58	BFGS 33	Entropia	Wykładnicza	Softmax
5	MLP 36-19-1	97,66	97,78	95,56	97,00	BFGS 15	Entropia	Liniowa	Softmax
6	MLP 36-21-11	94,39	97,78	93,33	95,17	BFGS 52	SOS	Logistyczna	Tanh
7	MLP 36-24-1	97,20	97,78	97,78	97,58	BFGS 44	Entropia	Tanh	Softmax
8	MLP 36-23-1	97,66	97,78	95,56	97,00	BFGS 19	Entropia	Liniowa	Softmax
9	MLP 36-24-1	97,66	97,78	95,56	97,00	BFGS 64	SOS	Wykładnicza	Liniowa
1	MLP 36-	97,66	97,78	95,56	97,00	BFGS 36	SOS	Wykładnicza	Liniowa

0	24-1							
---	------	--	--	--	--	--	--	--

Wybrana została najlepsza sieć typu MLP o strukturze 36 wejść – 24 neurony w warstwie ukrytej – 1 wyjście. Jakość uczenia to 97,20%, jakość testowania – 97,78%, jakość walidacji – 97,78%. Jeśli jakość walidacji nie odbiega od jakości testowania (w tym przypadku są one sobie równe) to sieć dobrze generalizuje strukturę danych i będzie dobrze działać dla zupełnie nowych danych. Średnia jakość sieci wyniosła 97,58%. Choć ważniejsza jest jakość walidacji, która jest najwyższa i tak powinniśmy określać jakość sieci. Do nauki sieci został wybrany algorytm uczenia BFGS, który daje najszybsze efekty uczenia sieci. Liczba cykli uczenia sieci wyniosła 44. Jako funkcji błędu do oceny sieci w procesie uczenia użyto entropii. Do aktywacji neuronów w warstwie ukrytej użyto Tanh (tangens hiperboliczny), a do aktywacji neuronów w warstwie wyjściowej użyto funkcji Softmax.

Na rysunku 12 pokazano wykres jakości sieci neuronowych typu MLP dla 10 punktów pomiarowych. Jakość wyrażona jest w %.



Rys. 12. Wykres jakości sieci neuronowych typu MLP – 10 punktów pomiarowych

Tabela 2 pokazuje działanie sieci neuronowych dla nowych danych podanych na wejście sieci. Sprawdzenie działania sieci następuje poprzez porównanie danych na wyjściu sieci ze wzorem podanym w ostatniej kolumnie tabeli. W przedostatnim wierszu podane jest podsumowanie tego porównania. Np. sieć 2, 7 i 8 po podaniu na wejście nowych danych w 100% dobrze podała wyniki, czyli który węzeł pomiarowy wskazuje awarię.

Tabela 2 pokazuje przewidywania dla nowych danych testujących działanie sieci typu MLP

Przewidywania dla nowych danych

Lp.	1 MLP 36-8-1	2 MLP 36-15-1	3 MLP 36-22-1	4 MLP 36-19-1	5 MLP 36-19-1	6 MLP 36-21-1	7 MLP 36-24-1	8 MLP 36-23-1	9 MLP 36-24-1	10 MLP 36-24-1	wzór
1	0	0	0	0	8	3	0	0	3	3	0
2	3	3	3	3	3	3	3	3	3	3	3
3	8	8	8	8	8	8	8	8	8	8	8
4	2	9	9	9	9	8	9	9	9	9	9
5	4	4	4	4	4	4	4	4	4	4	4
6	6	6	6	6	6	6	6	6	6	6	6
7	6	7	9	7	7	7	7	7	7	7	7
8	2	10	10	1	10	10	10	10	10	9	10
9	5	5	5	5	5	5	5	5	5	5	5
10	4	4	4	4	4	4	4	4	4	4	4
11	1	1	1	1	1	1	1	1	1	1	1
12	2	2	2	2	2	2	2	2	2	2	2
Liczba poprawnych klasyfikacji	9	12	11	11	11	10	12	12	11	10	
Liczba błędnych klasyfikacji	3	0	1	1	1	2	0	0	1	2	

Analizując wyniki z tabeli 2 widać, że sieć 2, 7 i 8 zaklasyfikowała nowe wartości w 100%. Jednak porównując jakość walidacji tych sieci najlepszą z nich jest sieć nr 7, gdyż tylko dla niej jakość walidacji nie odbiega zasadniczo od jakości testowania. To może wynikać od zastosowanej funkcji aktywacji w warstwie ukrytej, którą jest funkcja Tanh, a nie liniowa.

Natomiast tabela 3 opisuje eksperymenty dla różnych struktur sieci MLP w przypadku 20 punktów pomiarowych. Jakość wyrażona jest w %.

Id	Nazwa sieci	Jakość uczenia	Jakość testowania	Jakość walidacji	Średnia jakość sieci (%)	Algorytm uczenia	Funkcja błędu	Aktywacja (ukryte)	Aktywacja (wyjściowe)
1	MLP 44-23-1	97,22	100,00	98,15	98,46	BFGS 83	SOS	Tanh	Tanh
2	MLP 44-	97,22	100,00	98,15	98,46	BFGS 57	SOS	Liniowa	Liniowa

	25-1								
3	MLP 44-18-1	100,00	100,00	100,00	100,00	BFGS 119	SOS	Tanh	Tanh
4	MLP 44-23-1	100,00	100,00	100,00	100,00	BFGS 23	Entropia	Liniowa	Softmax
5	MLP 44-21-1	98,02	96,30	98,15	97,49	BFGS 104	SOS	Wykładnicza	Liniowa
6	MLP 44-18-1	87,70	85,19	83,33	85,41	BFGS 38	Entropia	Logistyczna	Softmax
7	MLP 44-19-1	90,08	88,89	83,33	87,43	BFGS 118	SOS	Logistyczna	Tanh
8	MLP 44-24-1	80,56	75,93	81,48	79,32	BFGS 47	Entropia	Logistyczna	Softmax
9	MLP 44-8-1	85,32	79,63	85,19	83,38	BFGS 36	Entropia	Liniowa	Softmax
10	MLP 44-8-1	93,65	90,74	94,44	92,95	BFGS 53	Entropia	Tanh	Softmax

Wybrane zostały dwie najlepsze sieci typu MLP o następującej strukturze:

- 44 wejścia – 18 neuronów w warstwie ukrytej – 1 wyjście
- 44 wejścia – 23 neurony w warstwie ukrytej – 1 wyjście.

Jakość uczenia dla obu to 100,00%, jakość testowania – 100,00%, jakość walidacji – 100,00%. Jeśli jakość walidacji nie odbiega od jakości testowania (w tym przypadku są one sobie równe) to sieć dobrze generalizuje strukturę danych i będzie dobrze działać dla zupełnie nowych danych. Średnia jakość sieci wyniosła 100,00%.


Do nauki sieci został wybrany algorytm uczenia BFGS, który daje najszybsze efekty uczenia sieci. Liczba cykli uczenia sieci w przypadku pierwszej sieci wyniosła 119, a drugiej 23.

Różnica w liczbie cykli uczenia wiąże się z wyborem różnych funkcji błędu (SOS i entropii). Entropia jest typową funkcją błędu dla problemów klasyfikacji.

Do aktywacji neuronów w warstwie ukrytej dla pierwszej sieci użyto Tanh (tangens hiperboliczny), a dla drugiej liniowej.

Natomiast do aktywacji neuronów w warstwie wyjściowej użyto kolejno funkcji Tanh i Softmax.

Na rysunku 13 pokazano wykres jakości sieci neuronowych typu MLP dla 20 punktów pomiarowych. Jakość wyrażona jest w %.



Rys. 13. Wykres jakości sieci neuronowych typu MLP – 20 punktów pomiarowych

Tabela 4 pokazuje działanie sieci neuronowych dla nowych danych podanych na wejście sieci. Sprawdzenie działania sieci następuje poprzez porównanie danych na wyjściu sieci ze wzorem podanym w ostatniej kolumnie tabeli. W przedostatnim wierszu podane jest podsumowanie tego porównania. Np. sieć 3 i 4 po podaniu na wejście nowych danych w 100% dobrze podała wyniki, czyli który węzeł pomiarowy wskazuje awarię.

Tabela 4 pokazuje przewidywania dla nowych danych testujących działanie sieci typu MLP

Przewidywania dla nowych danych											
Lp.	1 MLP 44-23-1	2 MLP 44-25-1	3 MLP 44-18-1	4 MLP 44-23-1	5 MLP 44-21-1	6 MLP 44-18-1	7 MLP 44-19-1	8 MLP 44-24-1	9 MLP 44-8-1	10 MLP 44-8-1	wzór
1	4	4	0	0	0	0	11	0	0	0	0
2	3	3	3	3	3	3	3	3	3	3	3
3	8	8	8	8	8	8	8	8	8	8	8
4	15	15	15	15	15	19	15	15	15	15	15
5	11	11	11	11	11	11	11	11	11	11	11
6	13	13	13	13	13	13	13	13	13	20	13
7	4	4	4	4	4	4	4	4	4	20	4
8	16	16	16	16	16	16	16	16	16	16	16
9	12	12	12	12	12	2	12	12	12	12	12
10	7	7	7	7	7	15	7	13	1	7	7
11	9	9	9	9	9	9	7	13	6	9	9

12	20	20	20	20	20	20	20	0	20	20	20
13	1	1	1	1	1	2	1	13	1	13	1
14	2	2	2	2	0	2	2	15	0	2	2
15	17	17	17	17	17	15	5	13	17	17	17
16	5	5	5	5	5	10	5	15	16	5	5
17	6	6	6	6	6	19	6	13	6	14	6
18	14	14	14	14	14	2	10	13	6	14	14
19	18	18	18	18	18	2	19	15	18	14	18
20	19	19	19	19	19	19	19	13	7	19	19
21	10	10	10	10	0	10	10	13	0	10	10
22	13	13	13	13	13	13	13	13	0	1	13
Liczba poprawnych klasyfikacji	21	21	22	22	20	13	17	10	14	16	
Liczba błędnych klasyfikacji	1	1	0	0	2	9	5	12	8	6	

Analizując wyniki z tabeli 4 widać, że sieć 3 i 4 zaklasyfikowała nowe wartości w 100%. Jakość walidacji tych sieci jest taka sama i równa jakości testowania.

Podsumowanie sieci MLP

Najlepszą siecią MLP dla 10 punktów pomiarowych okazały się sieci MLP 36-15-11 z funkcją błędów liczoną przy pomocy entropii, liniową funkcją aktywacji w warstwie ukrytej i funkcją aktywacji Softmax w warstwie wyjściowej, MLP 36-24-11 z funkcją błędów liczoną przy pomocy entropii, funkcją aktywacji Tanh w warstwie ukrytej i funkcją aktywacji Softmax w warstwie wyjściowej oraz MLP 36-23-11 z funkcją błędów liczoną przy pomocy entropii, liniową funkcją aktywacji w warstwie ukrytej i funkcją aktywacji Softmax w warstwie wyjściowej.

Natomiast dla 20 punktów pomiarowych sieć MLP 44-18-21 z funkcją błędów liczoną przy pomocy SOS, funkcją aktywacji Tanh w warstwie ukrytej i funkcją aktywacji Tanh w warstwie wyjściowej oraz MLP 44-23-21 z funkcją błędów liczoną przy pomocy entropii, liniową funkcją aktywacji w warstwie ukrytej i funkcją aktywacji Softmax w warstwie wyjściowej.

4.2. Utworzenie i wybór najlepszego klasyfikatora w postaci sieci neuronowych Kohonena

Eksperymenty związane z tworzeniem modeli sieci neuronowych typu Kohonena były parametryzowane dwoma parametrami: liczbą neuronów w warstwie topologicznej oraz

liczbą epok uczących. W eksperymencie parametr 'liczba neuronów w warstwie topologicznej' przyjmował wartości 2x8, 5x5, 10x10, natomiast drugi parametr 'liczba epok uczących' przyjmował wartości od 1000 do 20000. Po zakończeniu każdego eksperymentu, przeprowadzone były testy, które dostarczały informacji na temat błędnie zakwalifikowanych decyzji. Liczba neuronów w warstwie topologicznej została dobrana eksperymentalnie. Wejścia sieci zawierają przepływy wody (w normie i awaryjne) w wybranych węzłach sieci wodociągowej oraz punkt pomiarowy (najbardziej wrażliwy). W tej sieci nie ma wyjścia. Mamy 37 wejść do sieci dla 10 punktów pomiarowych oraz 45 wejść dla 20 punktów pomiarowych (37 wejść dla 10 punktów pomiarowych pozwala określić lokalizację awarii w punktach pomiarowych poprzez wybrane przez mnie węzły, w których symuluję awarię. To samo w przypadku 20 punktów pomiarowych, ale tutaj trzeba było określić 45 węzłów).

Na rys. 14 pokazano fragment danych, które posłużyły jako wejścia sieci neuronowych.

24	25	26	27	28	29	30	31	32	33	34	35	36	37
2156	2186	2447	2740	2779	3028	6144	3587	3596	4138	4181	4250	4411	Punkt_pom
-5.74	-4.2	-4.83	-5.04	-94.46	-2.71	-2.79	-3.1	-8.43	-6.31	-2.2	-1.69	-4.76	PPP003
-5.74	-4.2	-4.83	-5.04	-94.46	-2.71	-2.79	-3.1	-8.43	-6.31	-2.2	-1.69	-4.76	PPP003
-5.74	-4.2	-4.83	-5.04	-94.46	-2.71	-2.79	-3.1	-8.43	-6.31	-2.2	-1.69	-4.76	PPP003
-5.74	-4.2	-4.83	-5.04	-94.46	-2.71	-2.79	-3.1	-8.43	-6.31	-2.2	-1.69	-4.76	PPP003
-5.74	-4.2	-4.83	-5.04	-94.46	-2.71	-2.79	-3.1	-8.43	-6.31	-2.2	-1.69	-4.76	PPP004
-5.74	-4.2	-4.83	-5.04	-94.46	-2.71	-2.79	-3.1	-8.43	-6.31	-2.2	-1.69	-4.76	PPP004
-5.74	-4.2	-4.83	-5.04	-94.46	-2.71	-2.79	-3.1	-8.43	-6.31	-2.2	-1.69	-4.76	PPP004
-25.74	-4.2	-4.83	-5.04	-94.46	-2.71	-2.79	-3.1	-8.43	-6.31	-2.2	-1.69	-4.76	PPP004
-5.74	-20.2	-4.83	-5.04	-94.46	-2.71	-2.79	-3.1	-8.43	-6.31	-2.2	-1.69	-4.76	PPP006
-5.74	-4.2	-20.83	-5.04	-94.46	-2.71	-2.79	-3.1	-8.43	-6.31	-2.2	-1.69	-4.76	PPP006
-5.74	-4.2	-4.83	-25.04	-94.46	-2.71	-2.79	-3.1	-8.43	-6.31	-2.2	-1.69	-4.76	PPP007
-5.74	-4.2	-4.83	-5.04	-470.46	-2.71	-2.79	-3.1	-8.43	-6.31	-2.2	-1.69	-4.76	PPP010
-5.74	-4.2	-4.83	-5.04	-94.46	-10.71	-2.79	-3.1	-8.43	-6.31	-2.2	-1.69	-4.76	PPP004
-5.74	-4.2	-4.83	-5.04	-94.46	-2.71	-10.79	-3.1	-8.43	-6.31	-2.2	-1.69	-4.76	PPP004
-5.74	-4.2	-4.83	-5.04	-94.46	-2.71	-2.79	-15.1	-8.43	-6.31	-2.2	-1.69	-4.76	PPP005
-5.74	-4.2	-4.83	-5.04	-94.46	-2.71	-2.79	-3.1	-40.43	-6.31	-2.2	-1.69	-4.76	PPP004
-5.74	-4.2	-4.83	-5.04	-94.46	-2.71	-2.79	-3.1	-8.43	-30.31	-2.2	-1.69	-4.76	PPP001
-5.74	-4.2	-4.83	-5.04	-94.46	-2.71	-2.79	-3.1	-8.43	-6.31	-10.2	-1.69	-4.76	PPP005
-5.74	-4.2	-4.83	-5.04	-94.46	-2.71	-2.79	-3.1	-8.43	-6.31	-2.2	-1.69	-4.76	PPP003
-5.74	-4.2	-4.83	-5.04	-94.46	-2.71	-2.79	-3.1	-8.43	-6.31	-2.2	-5.69	-4.76	PPP001
-5.74	-4.2	-4.83	-5.04	-94.46	-2.71	-2.79	-3.1	-8.43	-6.31	-2.2	-1.69	-20.76	PPP002
-5.74	-4.2	-4.83	-5.04	-94.46	-2.71	-2.79	-3.1	-8.43	-6.31	-2.2	-1.69	-4.76	

Rys. 14. Fragment danych pliku uczącego sieci neuronowej Kohonena

Plik uczący zawiera 70% przykładów, plik testowy 15%, a plik walidacyjny kolejne 15%. Liczba przykładów wyniosła w pierwszym przypadku dla 10 punktów pomiarowych 304 przykłady, a w drugim 360.

Dla 10 punktów pomiarowych przygotowałam różne sytuacje awaryjne dla różnych węzłów. W ten sposób powstało 38 przykładów sytuacji awaryjnych i w normie. Następnie 8 razy powieliłam te przykłady (8x38=304), gdyż w przypadku uczenia sieci neuronowych należy mieć powtarzalność przykładów w pliku z danymi. Podobnie zrobiłam dla 20 punktów pomiarowych. Tylko tutaj powstało 45 przykładów sytuacji awaryjnych i w normie. Następnie 8 razy powieliłam te przykłady (8x45=360).

Tabela 5 ilustruje parametry opisujące eksperymenty dla różnych struktur sieci Kohonena w przypadku 10 punktów pomiarowych. Przy nazwie algorytmu uczenia występuje liczba cykli uczenia.

Tabela 5. Parametry struktur sieci Kohonena dla 10 punktów pomiarowych

Id	Nazwa sieci	Jakość uczenia	Jakość testowania	Jakość walidacji	Średnia jakość sieci (%)	Algorytm uczenia
1	SOFM 37-16	81,94	14,30	7,49	34,58	Kohonena 1000
2	SOFM 37-16	18,07	14,30	7,49	13,29	Kohonena 10000
3	SOFM 37-16	18,07	14,30	7,49	13,29	Kohonena 15000
4	SOFM 37-16	20,02	20,94	12,00	17,65	Kohonena 20000
5	SOFM 37-25	20,32	17,10	12,97	16,80	Kohonena 1000
6	SOFM 37-25	26,32	21,02	21,75	23,03	Kohonena 10000
7	SOFM 37-25	30,61	28,59	28,36	29,19	Kohonena 15000
8	SOFM 37-25	18,86	21,67	14,87	18,47	Kohonena 20000
9	SOFM 37-100	80,89	79,77	83,47	81,38	Kohonena 1000
10	SOFM 37-100	82,77	76,28	78,10	79,05	Kohonena 10000
11	SOFM 37-100	74,17	79,41	78,92	77,50	Kohonena 15000
12	SOFM 37-100	83,12	73,60	79,79	78,83	Kohonena 20000

Wybrane zostały dwie najlepsze sieci Kohonena o następującej strukturze:

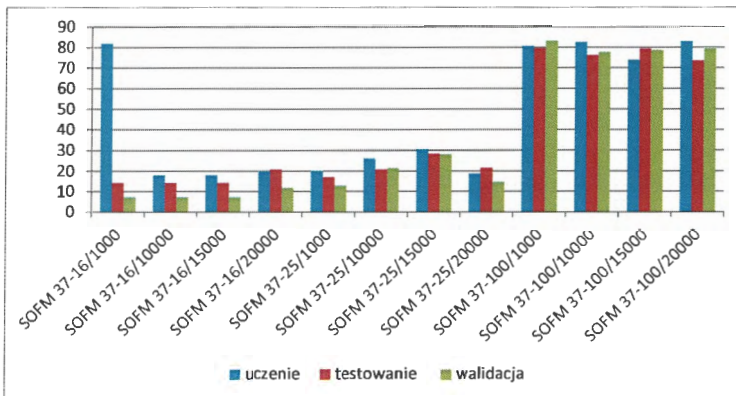
- 37 wejść – 10x10 neuronów tworzących topologię sieci
- 37 wejść – 10x10 neuronów tworzących topologię sieci.

Struktura obu sieci jest taka sama, jednak inaczej wyglądał proces uczenia. W przypadku pierwszej sieci liczba cykli uczenia wyniosła 1000, a w drugim 10 000.

Analizując jakość uczenia widzimy w drugiej sieci efekt przeuczenia. Porównując sieci pod względem jakości testowania i walidacji pierwsza sieć jest lepsza – ta, która uczona była mniejszą liczbę razy. Zwiększanie liczby cykli prowadziło do coraz gorszych wyników.

Przy takiej liczbie wejść topologia sieci też musi składać się z odpowiedniej liczby neuronów, dlatego sieci o mniejszym rozmiarze topologii są dużo gorsze.

Na rysunku 15 pokazano wykres jakości sieci neuronowych Kohonena dla 10 punktów pomiarowych. Jakość wyrażona jest w %.



Rys. 15. Wykres jakości sieci neuronowych Kohonena – 10 punktów pomiarowych

Tabela 6 pokazuje przewidywania dla nowych danych testujących działanie sieci typu Kohonena dla 10 punktów pomiarowych.

Tabela 6 pokazuje działanie sieci neuronowych dla nowych danych podanych na wejście sieci. Sprawdzenie działania sieci następuje poprzez porównanie danych na wyjściu sieci ze wzorem podanym w ostatniej kolumnie tabeli. W przedostatnim wierszu podane jest podsumowanie tego porównania. Np. sieć 9 i 10 po podaniu na wejście nowych danych w 83,33% dobrze podała wyniki, czyli który węzeł pomiarowy wskazuje awarię.

Przewidywania dla nowych danych													
Lp.	SOFM 37-16/1000	SOFM 37-16/10000	SOFM 37-16/15000	SOFM 37-16/20000	SOFM 37-25/1000	SOFM 37-25/10000	SOFM 37-25/15000	SOFM 37-25/20000	SOFM 37-100/1000	SOFM 37-100/10000	SOFM 37-100/15000	SOFM 37-100/20000	wzór
1	1	2	6	3	9	0	9	9	0	0	0	0	0
2	3	3	3	3	3	3	3	3	3	3	3	3	3
3	8	8	8	8	8	8	8	8	8	8	8	8	8
4	3	7	6	5	0	6	0	0	9	6	4	6	9
5	4	4	4	4	4	4	4	6	4	4	9	4	4
6	6	6	6	6	6	9	6	4	7	9	7	9	6
7	6	5	0	1	7	7	7	10	6	7	6	7	7
8	8	9	9	2	1	10	10	7	10	10	5	2	10
9	4	3	2	7	2	2	5	2	5	5	10	5	5
10	4	4	4	4	4	4	4	5	4	4	2	4	4
11	5	2	5	0	5	1	2	1	1	1	1	1	1
12	7	8	7	9	10	5	1	3	2	2	4	10	2
Liczba poprawnych klasyfikacji	5	5	5	5	5	8	8	3	10	10	4	8	

Liczba poprawnych klasyfikacji w %	41,67	41,67	41,67	41,67	41,67	66,67	66,67	25,00	83,33	83,33	33,33	66,67
Liczba błędnych klasyfikacji	7	7	7	7	7	4	4	9	2	2	8	4

Analizując wyniki z tabeli 6 widać, że sieć 9 i 10 zaklasyfikowała nowe wartości w 83,33%. Jednak porównując jakość testowania i walidacji tych sieci najlepszą z nich jest sieć nr 9. To, że w przypadku nowych danych pokazały obie tę samą skuteczność może z tego wynikać, że nowe dane mogły w dużym stopniu przypominać wzorzec.

Tabela 7 ilustruje parametry opisujące eksperymenty dla różnych struktur sieci Kohonena w przypadku 20 punktów pomiarowych.

Id	Nazwa sieci	Jakość uczenia	Jakość testowania	Jakość walidacji	Średnia jakość sieci (%)	Algorytm uczenia
1	SOFM 45-16	3,67	10,78	4,60	6,35	Kohonena 1000
2	SOFM 45-16	3,67	10,77	4,60	6,35	Kohonena 10000
3	SOFM 45-16	3,67	10,77	4,60	6,35	Kohonena 15000
4	SOFM 45-16	0,10	8,41	6,90	5,14	Kohonena 20000
5	SOFM 45-25	8,51	1,26	5,68	5,15	Kohonena 1000
6	SOFM 45-25	3,37	4,09	10,13	5,86	Kohonena 10000
7	SOFM 45-25	9,79	4,75	4,76	6,43	Kohonena 15000
8	SOFM 45-25	1,61	2,90	3,51	2,67	Kohonena 20000
9	SOFM 45-100	71,19	66,38	70,71	69,43	Kohonena 1000
10	SOFM 45-100	61,70	61,54	59,42	60,89	Kohonena 10000
11	SOFM 45-100	69,11	68,11	62,54	66,59	Kohonena 15000
12	SOFM 45-100	69,45	67,63	61,62	66,23	Kohonena 20000
13	SOFM 45-225	97,38	99,19	97,90	98,16	Kohonena 1000

Wybrane zostały dwie najlepsze sieci Kohonena o następującej strukturze:

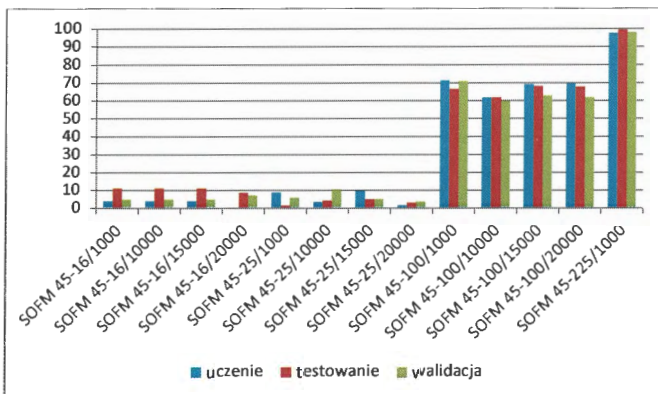
- 45 wejść – 10x10 neuronów tworzących topologię sieci
- 45 wejść – 25x25 neuronów tworzących topologię sieci.

Struktury obu sieci w zasadniczy sposób się różnią. Przy takim wzroście wejść w sieci niezbędna staje się większa topologia tej sieci. Wzrosła ona do 225 neuronów.

Wtedy dopiero się wykazała się bardzo dobrą jakością: uczenia (97,38%), testowania (99,19%) oraz walidacji (97,90%).

Przy takiej liczbie wejść topologia sieci też musi składać się z odpowiedniej liczby neuronów, dlatego sieci o mniejszym rozmiarze topologii są dużo gorsze.

Na rysunku 16 pokazano wykres błędów sieci neuronowych typu Kohonena dla 20 punktów pomiarowych.



Rys. 16. Wykres błędów sieci neuronowych Kohonena – 20 punktów pomiarowych

Tabela 8 pokazuje przewidywania dla nowych danych testujących działanie sieci typu Kohonena dla 20 punktów pomiarowych

Tabela 8 pokazuje działanie sieci neuronowych dla nowych danych podanych na wejście sieci. Sprawdzenie działania sieci następuje poprzez porównanie danych na wyjściu sieci ze wzorem podanym w ostatniej kolumnie tabeli. W przedostatnim wierszu podane jest podsumowanie tego porównania. Np. sieć 11 po podaniu na wejście nowych danych w 77,27% dobrze podała wyniki, czyli który węzeł pomiarowy wskazuje awarię, a sieć 13 w 100%.

Lp.	SOFM 45-16/1000	SOFM 45-16/10000	SOFM 45-16/15000	SOFM 45-16/20000	SOFM 45-25/1000	SOFM 45-25/10000	SOFM 45-25/15000	SOFM 45-25/20000	SOFM 45-100/1000	SOFM 45-100/10000	SOFM 45-100/15000	SOFM 45-100/20000	SOFM 45-225/1000	wzór
-----	-----------------	------------------	------------------	------------------	-----------------	------------------	------------------	------------------	------------------	-------------------	-------------------	-------------------	------------------	------

1	13	13	13	13	15	15	15	15	0	0	0	0	0	0
2	3	3	3	3	3	3	3	3	3	3	3	3	3	3
3	8	8	8	8	8	8	8	8	8	8	8	8	8	8
4	15	15	15	15	0	0	0	0	15	7	15	9	15	15
5	11	11	11	11	11	11	11	13	11	11	11	11	11	11
6	0	0	0	0	12	16	16	11	13	13	13	13	13	13
7	4	4	4	4	4	4	4	4	4	4	4	4	4	4
8	16	16	16	12	16	13	13	12	16	16	16	16	16	16
9	7	7	7	16	13	7	7	16	12	12	12	12	12	12
10	12	12	12	9	7	12	12	20	7	15	7	7	7	7
11	1	1	1	7	1	1	1	9	9	20	9	15	9	9
12	20	20	20	1	20	20	20	7	20	9	20	20	20	20
13	9	9	9	20	9	9	9	2	2	1	1	1	1	1
14	17	17	17	17	17	2	17	1	1	2	2	2	2	2
15	2	2	2	2	2	5	2	17	17	5	17	5	17	17
16	6	6	6	6	6	17	6	6	6	17	6	17	5	5
17	5	5	5	5	5	14	5	5	5	14	5	18	6	6
18	18	18	18	18	18	6	18	18	14	6	19	14	14	14
19	14	14	14	14	14	19	14	14	19	19	18	6	18	18
20	10	10	10	10	10	18	10	10	18	18	14	10	19	19
21	19	19	19	19	19	13	19	19	9	8	9	19	10	10
22	11	11	11	11	11	10	11	11	13	13	13	13	13	13
Liczba poprawnych klasyfikacji w %	31,82	31,82	31,82	22,73	31,82	27,27	22,73	18,18	68,18	50,00	77,27	63,64	100,00	
Liczba poprawnych klasyfikacji	7	7	7	5	7	6	5	4	15	11	17	14	22	
Liczba błędnych klasyfikacji	15	15	15	17	15	16	17	18	7	11	5	8	0	

Analizując wyniki z tabeli 8 widać, że sieć 13 zaklasyfikowała nowe wartości w 100,00%. Wynika to z dużo większej topologii sieci (25x25).

Podsumowanie sieci MLP i Kohonena do lokalizacji najbardziej wrażliwego punktu pomiarowego na awarię (tab. 9).

Tabela 9 pokazuje porównanie MLP i Kohonena.

Lp.	Nazwa sieci	Liczba punktów pomiarowych	Jakość klasyfikacji [%]
1	MLP 36-24-1	10	97,58
2	MLP 44-18-1	20	100,00
3	MLP 44-23-1	20	100,00
4	SOFM 37-100/1000	10	81,38
5	SOFM 45-225/1000	20	98,16

Sieci MLP miały krótki czas uczenia oraz dawały najlepszą klasyfikację.

Sieci Kohonena są zupełnie innej klasy sieciami neuronowymi. Należą do grupy sieci z uczeniem nienadzorowanym. W literaturze można otrzymać dobre rozwiązania wielu problemów technicznych. Jednak w przypadku lokalizacji awarii w sieci wodociągowej okazało się nieco gorsze od sieci MLP.

W przypadku sieci MLP sieć musi nauczyć się związku istniejącego między wejściem i wyjściem (ten związek my musimy podać). Natomiast sieć Kohonena musi sama wykryć i wykorzystać w procesie uczenia cechy zawarte w sposób ukryty w danych. Nie ma zdefiniowanego sygnału wyjściowego, oczekiwanego jako pożądana i oczekiwana reakcja sieci [26]. Sieć Kohonena próbuje nauczyć się struktury danych.

Sieci Kohonena są bardziej złożone ze względu na swoją strukturę oraz proces nauki. Potrzeba dużo większej liczby neuronów w topologii sieci, ale ich ogromną zaletą jest to, że uczą się same, czyli nie trzeba dawać im wskazówek i wzorców. Możemy ich nie znać.

Szczegóły dotyczące poszczególnych sieci są opisane przy określonych tabelach.

Sieci Kohonena wymagają więcej czasu na proces uczenia. Dlatego jeśli sieci MLP spełniają nasze oczekiwania i otrzymujemy dobre lub bardzo dobre wyniki klasyfikacji to należy zastosować sieci MLP do rozwiązania problemu.

Zgodnie z ogólną zasadą stosowaną w nauce, która głosi, że w przypadku gdy istnieje możliwość wyboru pomiędzy modelem prostym i bardziej złożonym, należy zawsze preferować model prostszy - o ile oczywiście ten drugi nie dopasowuje się znacząco lepiej do posiadanych danych [26].

