

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

6. Utworzenie i wybór najlepszego klasyfikatora lokalizującego awarie w węzle dla 20 punktów pomiarowych

6.1. Utworzenie i wybór najlepszego klasyfikatora w postaci sieci typu MLP

6.1. 1. Utworzenie i wybór najlepszego klasyfikatora w postaci sieci neuronowych typu MLP dla pliku oryginalnego danych z powtórzonymi kolumnami (pp2 taka sama jak pp1 oraz pp7 taka sama jak pp6)

Modele lokalizacji awarii 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 30, 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 punkty pomiarowe na sieci wodociągowej (20 wejść dla 20 punktów pomiarowych od pp1 do pp20). Wyjście sieci wskazuje węzeł, który lokalizuje awarię.

W tabeli 25 pokazano fragment danych, które posłużyły jako wejścia i wyjście sieci neuronowych (20 wejść i 1 wyjście).

Tabela 25. Fragment danych uczących – plik oryginalny z powtórzonymi kolumnami

pp1	pp2	pp3	pp4	pp5	pp6	pp7	pp8	pp9	pp10	pp11	pp12	pp13	pp14	pp15	pp16	pp17	pp18	pp19	pp20	wzet
-0.066	-0.066	0.588	-0.708	0.035	0.166	0.166	2.655	0.886	-0.886	-2.594	3.098	-4.64	2.244	0.676	-0.472	1.866	-0.658	1.746	1.072	w0
-0.053	-0.053	-2.026	-0.275	0.043	0.134	0.134	1.043	2.023	-2.023	-1.715	4.7	-3.687	1.107	1.152	-0.576	1.853	-0.577	2.893	1.062	w0103
-0.053	-0.053	-2.024	-0.275	0.043	0.134	0.134	1.034	2.028	-2.028	-1.716	4.699	-3.104	1.101	1.151	-0.576	1.853	-0.576	2.899	1.062	w0130
-0.053	-0.053	-2.049	-0.284	0.043	0.133	0.133	6.034	1.772	-1.772	-1.646	4.716	-5.053	1.388	1.194	-0.554	1.853	-0.643	2.821	1.062	w0119
-0.053	-0.049	-2.701	-0.113	0.046	0.123	0.123	5.513	2.442	-2.442	-1.373	5.193	-2.282	0.688	1.901	-0.615	1.849	-0.46	3.902	1.045	w0352
-0.025	-0.025	-5.327	0.802	0.061	0.058	0.058	13.202	3.733	-3.733	0.112	8.28	-5.946	-0.603	2.378	-0.747	1.825	-0.034	4.593	1.105	w0259
-0.057	-0.057	-1.287	-0.48	0.041	0.144	0.144	4.881	1.467	-1.467	-2	4.208	-4.911	1.663	1.095	-0.525	1.857	-0.72	2.327	1.079	w0385
-0.03	-0.03	-4.873	0.612	0.058	0.072	0.072	12	3.4	-3.4	-0.128	7.613	-5.798	-0.27	2.207	-0.713	1.83	-0.16	4.26	1.101	w0302
-0.053	-0.055	-2.022	-0.275	0.043	0.134	0.134	1.02	2.039	-2.039	-1.717	4.697	-4.605	1.091	1.15	-0.577	1.853	-0.573	2.899	1.062	w0353
-0.056	-0.058	-0.483	-0.455	0.04	0.146	0.146	4.082	1.281	-1.281	-0.737	3.749	-4.844	1.849	3.474	-0.508	1.858	-0.766	2.141	1.078	w0375
0.021	0.021	-9.867	3.442	0.089	-0.076	-0.076	-6.426	7.975	-7.975	3.89	11.507	-8.019	-4.845	3.15	-1.225	1.779	1.216	0.895	1.139	w0488
-0.053	-0.053	-0.217	-0.263	0.043	0.133	0.133	3.889	1.404	-1.404	1.867	3.708	-4.908	1.716	-2.84	-0.519	1.853	-0.736	2.264	1.062	w0528
-0.036	-0.036	-4.998	0.394	0.055	0.088	0.088	-1.047	3.685	-3.685	-0.443	6.815	-6.031	-0.555	1.723	-0.742	1.836	-0.052	4.545	1.096	w0616
-0.031	-0.031	-0.92	0.378	0.058	0.075	0.075	5.202	2.179	-2.179	3.746	4.735	-5.296	0.957	-4.396	-0.582	1.831	-0.528	5.033	1.1	w0872
-0.02	-0.02	-5.827	0.975	0.064	0.045	0.045	-2.716	4.42	-4.42	0.279	6.821	-6.571	-1.29	2.129	-0.819	1.82	0.228	5.26	1.108	w0811
-0.011	-0.011	-6.755	1.903	0.07	0.019	0.019	-3.494	9.932	-9.932	0.966	9.590	16.093	-6.802	2.867	2.948	1.811	1.475	10.792	1.115	w0801
-0.058	-0.068	1.023	-0.497	0.041	0.145	0.145	2.729	1.109	-1.109	-5.738	2.552	-4.756	2.021	0.997	-0.682	1.858	-0.807	1.969	1.079	w0206
-0.049	-0.049	1.461	0.187	0.045	0.017	0.017	2.704	1.011	-1.011	-3.249	2.476	-4.705	2.119	0.694	-0.484	1.849	-0.829	1.871	1.064	w0173
-0.018	-0.018	-6.043	1.053	0.066	0.059	0.059	-2.817	6.883	-6.883	0.431	9.023	6.028	-3.753	2.187	19.168	1.828	0.94	7.743	1.11	w1195

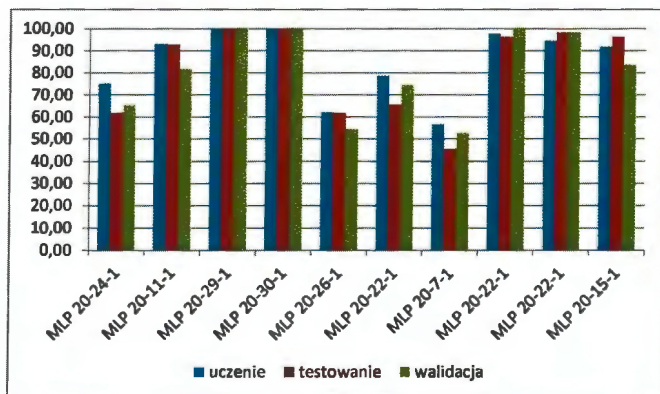
Plik uczący zawiera 70% przykładów, plik testowy 15%, a plik walidacyjny kolejne 15%. Liczba przykładów wyniosła dla 20 punktów pomiarowych 368 (45 wartości różnych węzłów sieci wodociągowej z awarią +1 wartość w normie bez awarii) x 8powtórzeń = 368).

Tabela 26 ilustruje parametry opisujące eksperymenty dla różnych struktur sieci MLP w przypadku 20 punktów pomiarowych. Jakość wyrażona jest w %.

Tabela 26

Id	Nazwa sieci	Jakość uczenia	Jakość testowania	Jakość walidacji	Algorytm uczenia	Funkcja błędu	Aktywacja (ukryte)	Aktywacja (wyjściowe)	Jakość sieci w %
1	MLP 20-24-1	75,19	61,82	65,45	BFGS 151	SOS	Logistyczna	Liniowa	67,49
2	MLP 20-11-1	93,02	92,73	81,82	BFGS 52	Entropia	Tanh	Softmax	89,19
3	MLP 20-29-1	100,00	100,00	100,00	BFGS 38	Entropia	Tanh	Softmax	100,00
4	MLP 20-30-1	100,00	100,00	100,00	BFGS 64	Entropia	Logistyczna	Softmax	100,00
5	MLP 20-26-1	62,02	61,82	54,55	BFGS 230	SOS	Wykładnicza	Wykładnicza	59,46
6	MLP 20-22-1	78,68	65,45	74,55	BFGS 71	SOS	Tanh	Logistyczna	72,89
7	MLP 20-7-1	56,59	45,45	52,73	BFGS 62	Entropia	Logistyczna	Softmax	51,59
8	MLP 20-22-1	97,67	96,36	100,00	BFGS 30	Entropia	Tanh	Softmax	98,01
9	MLP 20-22-1	94,57	98,18	98,18	BFGS 67	Entropia	Logistyczna	Softmax	96,98
10	MLP 20-15-1	91,86	96,36	83,64	BFGS 63	Entropia	Logistyczna	Softmax	90,62

Na rysunku 25 pokazano wykres jakości sieci neuronowych typu MLP dla 20 punktów pomiarowych. Jakość wyrażona jest w %.



Rys. 25. Wykres jakości sieci neuronowych typu MLP – 20 punktów pomiarowych dla pliku z danymi oryginalnymi z powtórzonymi kolumnami

Najlepszą siecią okazała się sieć MLP 20-29-45 (100%) oraz MLP 20-30-45 (100%) oraz MLP 20-22-45 (98,01%) z funkcją błędów liczoną przy pomocy entropii, funkcją aktywacji Tanh lub Logistyczną w warstwie ukrytej i funkcją aktywacji Softmax w warstwie wyjściowej. W przypadku funkcji aktywacji logistycznej sieć neuronowa uczona była dłużej (64 iteracje).

6.1. 2. Utworzenie i wybór najlepszego klasyfikatora w postaci sieci neuronowych typu MLP dla pliku oryginalnego danych bez powtórzeń (usunięta kolumna pp2 i pp7)

Eksperymenty wykonano z takimi samymi parametrami sieci MLP jak w punkcie 1. Zmieniono plik uczący, który w tych eksperymentach zawiera 18 kolumn wejściowych i 1 wyjściową (tab. 27).

Plik uczący zawiera 70% przykładów, plik testowy 15%, a plik walidacyjny kolejne 15%. Liczba przykładów wyniosła dla 20 punktów pomiarowych 368.

Tabela 27. Fragment danych uczących – plik oryginalny bez powtórzonych kolumn


pp1	pp3	pp4	pp5	pp6	pp8	pp9	pp10	pp11	pp12	pp13	pp14	pp15	pp16	pp17	pp18	pp19	pp20	węzeł
-0,066	0,588	-0,768	0,035	0,166	2,655	0,886	-0,886	-2,594	3,098	-4,64	2,244	0,676	-0,472	1,866	-0,858	1,746	1,072	w0
-0,053	-2,026	-0,275	0,043	0,134	1,043	2,023	-2,023	-1,715	4,7	-3,687	1,107	1,152	-0,576	1,853	-0,577	2,883	1,082	w0103
-0,053	-2,024	-0,275	0,043	0,134	1,034	2,029	-2,029	-1,716	4,699	-3,104	1,101	1,151	-0,576	1,853	-0,576	2,889	1,082	w0130
-0,053	-2,049	-0,264	0,043	0,133	6,034	1,772	-1,772	-1,646	4,716	-5,053	1,358	1,294	-0,554	1,853	-0,643	2,632	1,082	w0213
-0,053	-2,701	-0,113	0,046	0,123	0,513	2,442	-2,442	-1,373	5,193	-2,282	0,688	1,301	-0,615	1,849	-0,46	3,302	1,085	w0252
-0,025	-5,327	0,802	0,061	0,058	13,202	3,733	-3,733	0,112	8,28	-5,946	-0,603	2,378	-0,747	1,825	-0,034	4,593	1,105	w0259
-0,057	-1,287	-0,43	0,041	0,144	4,881	1,467	-1,467	-2	4,208	-4,911	1,663	1,095	-0,525	1,857	-0,72	2,327	1,079	w0265
-0,03	-4,873	0,612	0,058	0,072	12	3,4	-3,4	-0,128	7,613	-5,798	-0,27	2,207	-0,713	1,83	-0,16	4,26	1,101	w0302
-0,053	-2,022	-0,275	0,043	0,134	1,02	2,039	-2,039	-1,717	4,697	-4,405	1,091	1,15	-0,577	1,853	-0,573	2,899	1,082	w0353
-0,058	-0,483	-0,455	0,04	0,146	4,082	1,281	-1,281	-0,737	3,749	-4,844	1,849	-3,474	-0,508	1,858	-0,766	2,141	1,078	w0375
0,021	-9,867	2,442	0,089	-0,076	-6,426	7,975	-7,975	3,89	11,507	-8,019	-4,845	3,15	-1,225	1,779	1,216	8,835	1,139	w0488
-0,053	-0,217	-0,263	0,043	0,133	3,889	1,404	-1,404	1,867	3,708	-4,908	1,726	-2,84	-0,519	1,853	-0,736	2,264	1,082	w0528
-0,036	-4,398	0,394	0,055	0,088	-1,047	3,685	-3,685	-0,443	6,815	-6,031	-0,555	1,723	-0,742	1,836	-0,052	4,545	1,096	w0616
-0,031	-0,92	0,573	0,058	0,075	5,202	2,173	-2,173	9,746	4,735	-3,296	0,957	-6,396	-0,592	1,831	-0,536	3,033	1,1	w0673
-0,02	-5,827	0,975	0,064	0,045	-2,726	4,42	-4,42	0,279	8,821	-6,371	-1,29	2,129	-0,819	1,82	0,228	5,28	1,108	w0811
-0,011	-6,755	1,303	0,07	0,019	-3,494	9,932	-9,932	0,966	9,598	16,092	-6,802	2,367	2,946	1,811	1,675	10,792	1,115	w0901
-0,058	1,023	-0,437	0,041	0,145	2,729	1,109	-1,109	-5,738	2,552	-4,756	2,021	0,597	-0,492	1,858	-0,807	1,969	1,079	w1026
-0,049	1,461	0,187	0,045	0,017	2,704	1,011	-1,011	-3,249	2,476	-4,705	2,119	0,694	-0,484	1,849	-0,829	1,871	1,084	w1073
-0,018	-6,043	1,053	0,066	0,039	-2,817	6,883	-6,883	0,431	9,023	6,928	-3,753	2,187	19,168	1,818	0,94	7,743	1,11	w1195

Tabela 28 ilustruje parametry opisujące eksperymenty dla różnych struktur sieci MLP w przypadku 20 punktów pomiarowych. Jakość wyrażona jest w %.

Tabela 28

Id	Nazwa sieci	Jakość uczenia	Jakość testowania	Jakość walidacji	Algorytm uczenia	Funkcja błędu	Aktywacja (ukryte)	Aktywacja (wyjściowe)	Jakość sieci w %
1	MLP 18-26-1	54,26	61,82	47,27	BFGS 17	Entropia	Liniowa	Softmax	54,45
2	MLP 18-15-1	97,29	100,00	98,18	BFGS 65	Entropia	Tanh	Softmax	98,49
3	MLP 18-28-1	100,00	100,00	100,00	BFGS 39	Entropia	Tanh	Softmax	100,00
4	MLP 18-29-1	74,42	56,36	60,00	BFGS 142	SOS	Wykładnicza	Tanh	63,59
5	MLP 18-28-1	54,65	47,27	45,45	BFGS 154	SOS	Liniowa	Liniowa	49,13
6	MLP 18-11-1	55,04	56,36	63,64	BFGS 167	SOS	Wykładnicza	Wykładnicza	58,35
7	MLP 18-30-1	77,91	63,64	65,45	BFGS 174	SOS	Tanh	Tanh	69,00
8	MLP 18-5-1	68,60	63,64	50,91	BFGS 62	Entropia	Tanh	Softmax	61,05
9	MLP 18-19-1	63,57	50,91	58,18	BFGS 18	Entropia	Liniowa	Softmax	57,55
10	MLP 18-10-1	98,06	94,55	100,00	BFGS 201	SOS	Logistyczna	Wykładnicza	97,54

Na rysunku 26 pokazano wykres jakości sieci neuronowych typu MLP dla 20 punktów pomiarowych. Jakość wyrażona jest w %.



Rys.26. Wykres jakości sieci neuronowych typu MLP – 20 punktów pomiarowych dla pliku z danymi oryginalnymi bez powtórzonych kolumn

Najlepszą siecią okazała się sieć MLP 18-28-45 (100%) oraz MLP 18-15-45 (98,49%) z funkcją błędów liczoną przy pomocy entropii, funkcją aktywacji Tanh w warstwie ukrytej i funkcją aktywacji Softmax w warstwie wyjściowej. W przypadku mniejszej liczby neuronów w warstwie ukrytej należało dłużej uczyć sieć MLP (64 iteracje) oraz wykazała się ona mniejszą jakością.

6.1. 3. Porównanie klasyfikatorów lokalizujących awarie w postaci sieci neuronowych typu MLP dla pliku oryginalnego z powtórzeniami i bez powtórzeń

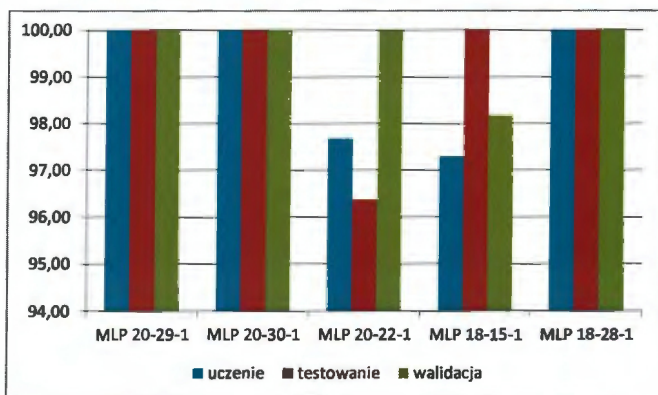
Tabela 29 ilustruje parametry porównywanych klasyfikatorów .

Tabela 29

Id	Nazwa sieci	Jakość uczenia	Jakość testowania	Jakość walidacji	Algorytm uczenia	Funkcja błędu	Aktywacja (ukryte)	Aktywacja (wyjściowe)	Jakość sieci w %
Sieci neuronowe MLP dla pliku z powtórzonymi kolumnami									
3	MLP 20-29-1	100,00	100,00	100,00	BFGS 38	Entropia	Tanh	Softmax	100,00
4	MLP 20-30-1	100,00	100,00	100,00	BFGS 64	Entropia	Logistyczna	Softmax	100,00
8	MLP 20-22-1	97,67	96,36	100,00	BFGS 30	Entropia	Tanh	Softmax	98,01
Sieci neuronowe MLP dla pliku bez powtórzonych kolumn									
2	MLP 18-15-1	97,29	100,00	98,18	BFGS 65	Entropia	Tanh	Softmax	98,49
3	MLP 18-28-1	100,00	100,00	100,00	BFGS 39	Entropia	Tanh	Softmax	100,00

Porównanie otrzymanych sieci neuronowych dla danych oryginalnych z wszystkimi 20 kolumnami i dla danych oryginalnych z usuniętymi 2 kolumnami wykazało, że otrzymane wyniki są porównywalne. Najlepsze klasyfikatory mają porównywalną liczbę neuronów w warstwie ukrytej z funkcją błędów liczoną przy pomocy entropii, funkcją aktywacji Tanh w warstwie ukrytej i funkcją aktywacji Softmax w warstwie wyjściowej. Jedna sieć MLP 20-30-45 ma funkcję aktywacji logistyczną w warstwie ukrytej, jednak ta sieć musiała być dłużej uczona (BFGS 64 iteracje). Natomiast dla sieci MLP 20-29-45 i MLP 18-28-45 z funkcją aktywacji w warstwie ukrytej Tanh wystarczyły 38 i 39 iteracje. We wszystkich trzech sieciach widać porównywalną liczbę neuronów w warstwie ukrytej (29, 30, 28).

Na rysunku 27 pokazano wykres jakości sieci neuronowych typu MLP.



Rys. 27. Wykres jakości sieci neuronowych typu MLP – 20 punktów pomiarowych

6.2. Utworzenie i wybór najlepszego klasyfikatora w postaci sieci Kohonena

6.2. 1. Utworzenie i wybór najlepszego klasyfikatora w postaci sieci neuronowych Kohonena dla pliku oryginalnego danych z powtórzonymi kolumnami (pp2 taka sama jak pp1 oraz pp7 taka sama jak pp6)

Sieci Kohonena realizują uczenie nienadzorowane. Ich zadaniem jest automatyczne wykrycie regularności w zbiorze przykładów uczących. Z punktu widzenia analizy danych realizują one zadanie grupowania (analizy skupień).

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 punkty pomiarowe na sieci wodociągowej oraz węzeł na który wskazują punkty pomiarowe. W tej sieci nie ma wyjścia.

Wykorzystano plik uczący z tab. 25. Wszystkie kolumny są wejściami sieci Kohonena (21 kolumn).

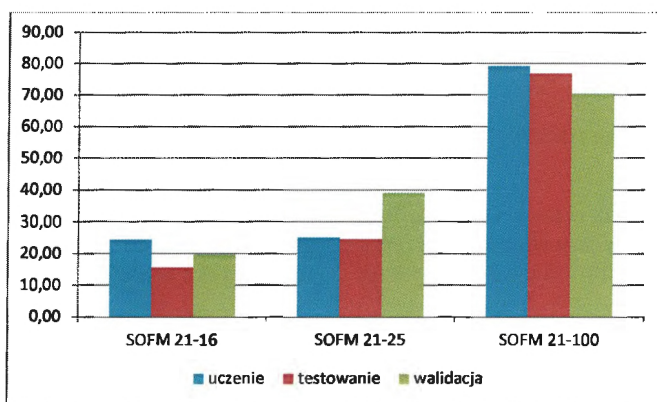
Plik uczący zawiera 70% przykładów, plik testowy 15%, a plik walidacyjny kolejne 15%. Liczba przykładów wyniosła dla 20 punktów pomiarowych 368.

Tabela 30 ilustruje parametry opisujące eksperymenty dla różnych struktur sieci Kohonena w przypadku 20 punktów pomiarowych.

Tabela 30

Id	Nazwa sieci	Jakość uczenia	Jakość testowania	Jakość walidacji	Algorytm uczenia	Jakość sieci w %
1	SOFM 21-16	24,40	15,66	19,81	Kohonena 1000	19,96
2	SOFM 21-25	25,22	24,66	39,10	Kohonena 1000	29,66
3	SOFM 21-100	79,22	76,84	70,48	Kohonena 1000	75,51

Na rysunku 28 pokazano wykres błędu sieci neuronowych typu Kohonena dla 20 punktów pomiarowych.



Rys. 28. Wykres błędów sieci neuronowych Kohonena – 20 punktów pomiarowych (Plik danych oryginalny z powtórzeniami)

Najlepszą siecią okazała się sieć SOFM 21-100 (75,51%) o liczbie neuronów 100 w warstwie topologicznej (10x10) przy liczbie epok uczących 1000. Dla 21 wejść potrzebna jest dużo większa topologia sieci.

6.2. 2. Utworzenie i wybór najlepszego klasyfikatora w postaci sieci neuronowych Kohonena dla pliku oryginalnego danych bez powtórzeń (usunięta kolumna pp2 i pp7)

Eksperymenty wykonano z takimi samymi parametrami sieci Kohonena jak w punkcie 4. Zmieniono plik uczący, który w tych eksperymentach zawiera 19 kolumn wejściowych. Wykorzystano plik uczący z tab. 27.

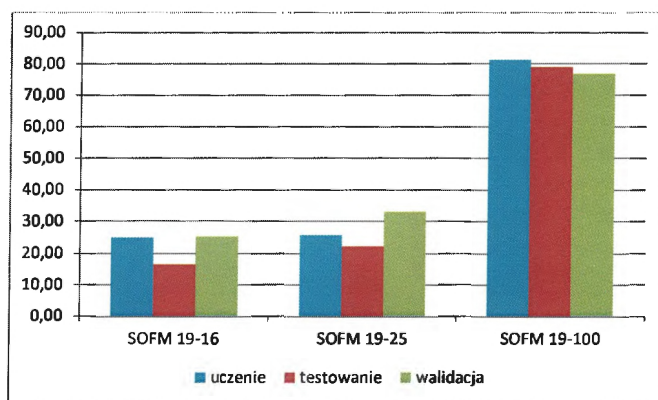
Plik uczący zawiera 70% przykładów, plik testowy 15%, a plik walidacyjny kolejne 15%. Liczba przykładów wyniosła dla 20 punktów pomiarowych 368.

Tabela 31 ilustruje parametry opisujące eksperymenty dla różnych struktur sieci Kohonena w przypadku 20 punktów pomiarowych dla pliku uczącego z usuniętymi kolumnami, które się powtarzały.

Tabela 31

Id	Nazwa sieci	Jakość uczenia	Jakość testowania	Jakość walidacji	Algorytm uczenia	Jakość sieci w %
1	SOFM 19-16	25,09	16,49	25,26	Kohonena 1000	22,28
2	SOFM 19-25	25,67	22,27	32,92	Kohonena 1000	26,95
3	SOFM 19-100	81,07	78,84	76,63	Kohonena 1000	78,85

Na rysunku 29 pokazano wykres błędów sieci neuronowych typu Kohonena dla 20 punktów pomiarowych dla pliku uczącego bez powtórzeń.



Rys. 29. Wykres błędów sieci neuronowych Kohonena – 20 punktów pomiarowych (Plik danych oryginalny bez powtórzeń)

Najlepszą siecią okazała się sieć SOFM 19-100 (78,85%) o liczbie neuronów 100 w warstwie topologicznej (10x10) przy liczbie epok uczących 1000. Przy tej samej topologii (10x10) i mniejszej liczbie wejść (19) poprawiła się jakość sieci.

6.2. 3. Porównanie klasyfikatorów lokalizujących awarie w postaci sieci neuronowych Kohonena dla pliku oryginalnego z powtórzeniami i bez powtórzeń

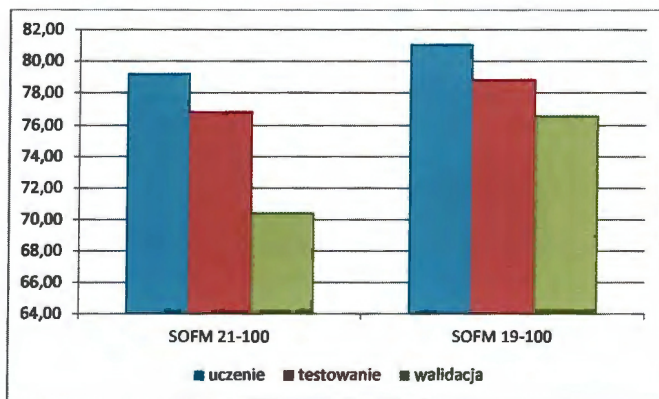
Tabela 32 ilustruje parametry porównywanych klasyfikatorów.

Tabela 32

Id	Nazwa sieci	Jakość uczenia	Jakość testowania	Jakość walidacji	Algorytm uczenia	Jakość sieci w %
Sieć neuronowa Kohonena dla pliku z powtórzonymi kolumnami						
3	SOFM 21-100	79,22	76,84	70,48	Kohonena 1000	75,51
Sieć neuronowa Kohonena dla pliku bez powtórzonych kolumn						
3	SOFM 19-100	81,07	78,84	76,63	Kohonena 1000	78,85

Porównanie otrzymanych sieci neuronowych dla danych oryginalnych z wszystkimi 20 kolumnami i dla danych oryginalnych z usuniętymi 2 kolumnami wykazało, że otrzymane wyniki są porównywalne. Najlepsze klasyfikatory mają porównywalne błędy uczenia, testowania i walidacji. Algorytm uczenia wykonany był z liczbą 1000 iteracji, a jakość uczenia różni się o 3,34%. Lepszym klasyfikatorem okazała się sieć neuronowa uczona plikiem bez powtórzeń.

Na rysunku 30 pokazano wykres błędów sieci neuronowych typu Kohonen.



Rys. 30. Wykres błędów sieci neuronowych typu Kohonen – 20 punktów pomiarowych

6.3. Analiza wyników sieci neuronowych typu MLP i Kohonena dla pliku z danymi oryginalnymi

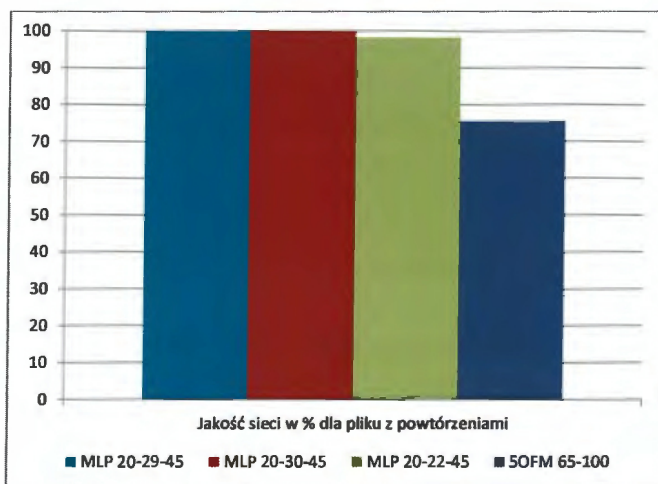
6.3.1. Dane oryginalne z powtórzeniami

Tabela 33 ilustruje parametry opisujące eksperymenty dla różnych struktur sieci MLP i Kohonena w przypadku 20 punktów pomiarowych dla pliku danych oryginalnego z powtórzeniami. Jakość wyrażona jest w %.

Tabela 33

Id	Nazwa sieci	Jakość sieci w %
1	MLP 20-29-1	100,00
2	MLP 20-30-1	100,00
3	MLP 20-22-1	98,01
4	SOFM 21-100	75,51

Na rysunku 31 pokazano wykres jakości sieci neuronowych typu MLP i Kohonen dla pliku z powtórzeniami.



Rys. 31. Wykres jakości sieci neuronowych typu MLP i Kohonen

Najlepszą siecią okazała się sieć typu MLP 20-29-45 (100%) oraz MLP 20-30-45 (100%).

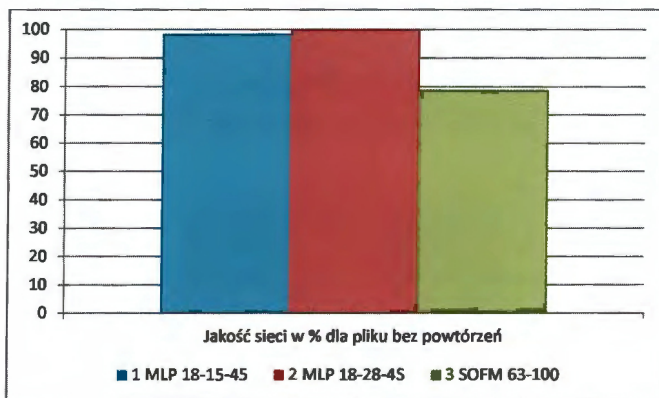
6.3.2. Dane oryginalne bez powtórzeń

Tabela 34 ilustruje parametry opisujące eksperymenty dla różnych struktur sieci MLP i Kohonena w przypadku 20 punktów pomiarowych dla pliku danych oryginalnego bez powtórzeń. Jakość wyrażona jest w %.

Tabela 34

Id	Nazwa sieci	Jakość sieci w %
1	MLP 18-15-45	98,49
2	MLP 18-28-45	100,00
3	SOFM 19-100	78,85

Na rysunku 32 pokazano wykres jakości sieci neuronowych typu MLP i Kohonen dla pliku bez powtórzeń.



Rys. 32. Wykres jakości sieci neuronowych typu MLP i Kohonen

Najlepszą siecią okazała się sieć typu MLP 18-28-45 (100%).

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)

Eksperymenty wykonano z takimi samymi parametrami sieci MLP jak w punkcie 6.1. Zmodyfikowano wartości pliku uczącego oraz usunięto dwie powtarzające się kolumny (tab. 35).

Plik uczący zawiera 70% przykładów, plik testowy 15%, a plik walidacyjny kolejne 15%. Liczba przykładów wyniosła dla 20 punktów pomiarowych 368.

Tabela 35. Fragment danych uczących z pliku zmodyfikowanego bez powtórzonych kolumn


pp1	pp3	pp4	pp5	pp6	pp8	pp9	pp10	pp11	pp12	pp13	pp14	pp15	pp16	pp17	pp18	pp19	pp20	ważel	
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0 w0
-0,013	2,614	-0,493	-0,008	0,032	1,612	-1,137	1,137	-0,879	-1,602	-0,953	1,137	-0,476	0,104	0,013	-0,281	-1,137	-0,01	w0103	
-0,013	2,612	-0,493	-0,008	0,032	1,621	-1,143	1,143	-0,878	-1,601	-1,536	1,143	-0,475	0,104	0,013	-0,282	-1,143	-0,01	w0130	
-0,013	2,637	-0,504	-0,008	0,033	-3,379	-0,886	0,886	-0,948	-1,618	0,413	0,886	-0,618	0,082	0,013	-0,215	-0,886	-0,01	w0213	
-0,013	3,289	-0,655	-0,011	0,043	2,142	-1,356	1,356	-1,221	-2,095	-2,358	1,356	-0,625	0,143	0,017	-0,398	-1,356	-0,013	w0252	
-0,041	5,915	-1,57	-0,026	0,108	-10,547	-2,847	2,847	-2,706	-5,182	1,306	2,847	-1,702	0,275	0,041	-0,824	-2,847	-0,033	w0259	
-0,009	1,875	-0,338	-0,006	0,022	-2,226	-0,581	0,581	-0,594	-1,11	0,271	0,581	-0,419	0,053	0,009	-0,138	-0,581	-0,007	w0265	
-0,036	5,461	-1,38	-0,023	0,094	-9,345	-2,514	2,514	-2,466	-4,515	1,158	2,514	-1,531	0,241	0,036	-0,698	-2,514	-0,023	w0302	
-0,013	2,61	-0,493	-0,008	0,032	1,635	-1,153	1,153	-0,877	-1,599	-0,235	1,153	-0,474	0,105	0,013	-0,285	-1,153	-0,01	w0353	
-0,008	1,071	-0,313	-0,005	0,02	-1,427	-0,395	0,395	-1,857	-0,651	0,204	0,395	4,15	0,036	0,008	-0,092	-0,395	-0,006	w0375	
-0,087	10,455	-3,21	-0,054	0,242	9,081	-7,089	7,089	-6,484	-8,409	3,379	7,089	-2,474	0,753	0,087	-2,074	-7,089	-0,067	w0488	
-0,013	0,805	-0,305	-0,008	0,033	-1,234	-0,518	0,518	-4,461	-0,61	0,268	0,518	3,516	0,047	0,013	-0,122	-0,518	-0,01	w0528	
-0,03	4,986	-1,162	-0,02	0,078	3,702	-2,799	2,799	-2,151	-3,717	1,391	2,799	-1,047	0,27	0,03	-0,806	-2,799	-0,024	w0616	
-0,035	1,508	-1,341	-0,023	0,091	-2,547	-1,287	1,287	-12,34	-1,637	0,656	1,287	7,072	0,12	0,035	-0,322	-1,287	-0,028	w0673	
-0,046	6,415	-1,743	-0,029	0,121	5,381	-3,334	3,334	-2,873	-5,723	1,731	3,334	-1,453	0,347	0,046	-1,086	-3,334	-0,036	w0811	
-0,055	7,343	-2,071	-0,035	0,147	6,149	-9,046	9,046	-3,56	-6,5	-20,732	9,046	-1,891	-3,418	0,055	-2,533	-9,046	-0,043	w0901	
-0,008	-0,435	-0,331	-0,006	0,021	-0,074	-0,223	0,223	3,144	0,546	0,116	0,223	0,079	0,02	0,008	-0,051	-0,223	-0,007	w1026	
-0,017	-0,673	-0,955	-0,01	0,149	-0,049	-0,125	0,125	0,655	0,622	0,065	0,125	-0,018	0,012	0,017	-0,029	-0,125	-0,012	w1073	
-0,048	6,631	-1,821	-0,031	0,127	5,472	-5,997	5,997	-3,025	-5,925	-11,568	5,997	-1,511	-19,64	0,048	-1,798	-5,997	-0,038	w1195	
-0,031	3,5	-1,185	-0,02	0,08	0,123	-1,31	1,31	-2,283	-4,518	0,666	1,31	-0,464	0,122	0,031	-0,328	-1,31	-0,025	w1216	

Tabela 36 ilustruje parametry opisujące eksperymenty dla różnych struktur sieci MLP w przypadku 20 punktów pomiarowych. Jakość wyrażona jest w %.

Tabela 36

Id	Nazwa sieci	Jakość uczenia	Jakość testowania	Jakość walidacji	Algorytm uczenia	Funkcja błędu	Aktywacja (ukryte)	Aktywacja (wyjściowe)	Jakość sieci w %
1	MLP 18-30-1	44,57	47,27	49,09	BFGS 9	Entropia	Liniowa	Softmax	46,98
2	MLP 18-30-1	80,62	70,91	74,55	BFGS 245	SOS	Wykładnicza	Liniowa	75,36
3	MLP 18-22-1	48,45	36,36	56,36	BFGS 149	SOS	Liniowa	Liniowa	47,06
4	MLP 18-17-1	77,13	78,18	69,09	BFGS 128	SOS	Tanh	Wykładnicza	74,80
5	MLP 18-30-1	100,00	100,00	100,00	BFGS 40	Entropia	Tanh	Softmax	100,00
6	MLP 18-30-1	66,28	49,09	61,82	BFGS 73	SOS	Logistyczna	Logistyczna	59,06
7	MLP 18-11-1	63,95	60,00	47,27	BFGS 18	Entropia	Liniowa	Softmax	57,08
8	MLP 18-14-1	58,14	40,00	50,91	BFGS 156	SOS	Wykładnicza	Tanh	49,68
9	MLP 18-14-1	98,06	98,18	96,36	BFGS 48	Entropia	Tanh	Softmax	97,54
10	MLP 18-5-1	65,12	45,45	56,36	BFGS 48	Entropia	Tanh	Softmax	55,64

Na rysunku 33 pokazano wykres jakości sieci neuronowych typu MLP dla 20 punktów pomiarowych. Jakość wyrażona jest w %.



Rys. 33. Wykres jakości sieci neuronowych typu MLP – 20 punktów pomiarowych dla pliku z danymi zmodyfikowanymi bez powtórzonych kolumn

Najlepszą siecią okazała się sieć MLP 18-30-45 (100%) oraz MLP 18-14-45 (97,54%) z funkcją błędów liczoną przy pomocy entropii, funkcją aktywacji Tanh w warstwie ukrytej i funkcją aktywacji Softmax w warstwie wyjściowej. Istnieje zależność między liczbą neuronów w warstwie ukrytej a liczbą iteracji uczenia. Im większa liczba neuronów w warstwie ukrytej tym mniejsza liczba iteracji.

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)

Eksperymenty wykonano z takimi samymi parametrami sieci Kohonena jak w punkcie 6.2. Zmieniono plik uczący, który w tych eksperymentach zawiera 19 kolumn wejściowych. Wykorzystano plik uczący z tab. 27.


Plik uczący zawiera 70% przykładów, plik testowy 15%, a plik walidacyjny kolejne 15%. Liczba przykładów wyniosła dla 20 punktów pomiarowych 368.

Tabela 37 ilustruje parametry opisujące eksperymenty dla różnych struktur sieci Kohonena w przypadku 20 punktów pomiarowych dla pliku uczącego z usuniętymi kolumnami, które się powtarzały.

Tabela 37

Id	Nazwa sieci	Jakość uczenia	Jakość testowania	Jakość walidacji	Algorytm uczenia	Jakość sieci w %
1	SOFM 19-16	26,88	21,09	19,44	Kohonena 1000	22,47
2	SOFM 19-25	35,95	38,85	45,96	Kohonena 1000	40,25
3	SOFM 19-100	73,11	70,57	68,40	Kohonena 1000	70,69

Na rysunku 34 pokazano wykres błędu sieci neuronowych typu Kohonena dla 20 punktów pomiarowych dla pliku uczącego bez powtórzeń.



Rys. 34. Wykres błędów sieci neuronowych Kohonena – 20 punktów pomiarowych (Plik danych zmodyfikowanych bez powtórzeń)

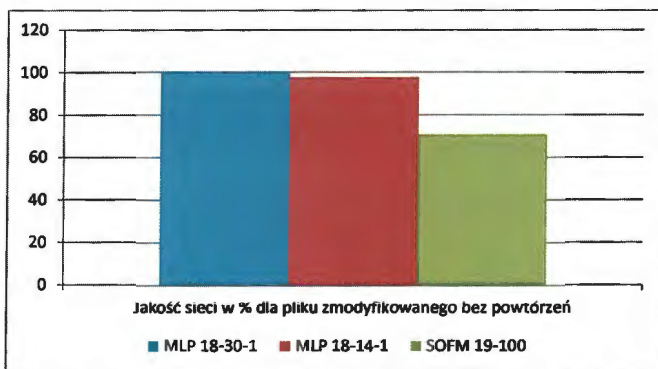
6.6. Analiza wyników sieci neuronowych typu MLP i Kohonena dla pliku z danymi zmodyfikowanymi bez powtórzeń

Tabela 38 ilustruje parametry opisujące eksperymenty dla różnych struktur sieci MLP i Kohonena w przypadku 20 punktów pomiarowych dla pliku danych zmodyfikowanego bez powtórzeń. Jakość wyrażona jest w %.

Tabela 38

Id	Nazwa sieci	Jakość sieci w %
1	MLP 18-30-1	100,00
2	MLP 18-14-1	97,54
3	SOFM 19-100	70,69

Na rysunku 35 pokazano wykres jakości sieci neuronowych typu MLP i Kohonen dla pliku bez powtórzeń.



Rys. 35. Wykres jakości sieci neuronowych typu MLP i Kohonen

Najlepszą siecią okazała się sieć typu MLP 18-30-45 (100%).

6.7. Porównanie wyników dla danych oryginalnych i zmodyfikowanych dla sieci MLP i Kohonena

6.7.1. Dane oryginalne i zmodyfikowane – sieci MLP

Tabela 39 ilustruje parametry porównywanych klasyfikatorów w postaci sieci MLP dla pliku oryginalnego z powtórzeniami i bez oraz pliku zmodyfikowanego bez powtórzeń.

Tabela 39

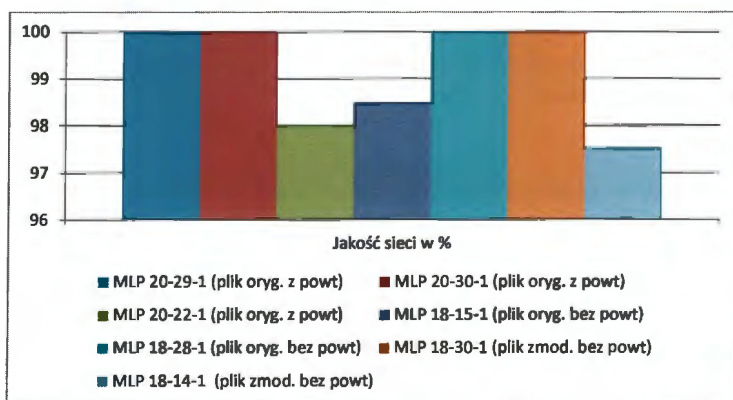
Id	Nazwa sieci	Jakość uczenia	Jakość testowania	Jakość walidacji	Algorytm uczenia	Funkcja błędu	Aktywacja (ukryte)	Aktywacja (wyjściowe)	Jakość sieci w %
Sieci neuronowe MLP dla pliku oryginalnego z powtórzonymi kolumnami									
3	MLP 20-29-1	100,00	100,00	100,00	BFGS 38	Entropia	Tanh	Softmax	100,00
4	MLP 20-30-1	100,00	100,00	100,00	BFGS 64	Entropia	Logistyczna	Softmax	100,00
8	MLP 20-22-1	97,67	96,36	100,00	BFGS 30	Entropia	Tanh	Softmax	98,01
Sieci neuronowe MLP dla pliku oryginalnego bez powtórzonych kolumn									
2	MLP 18-15-1	97,29	100,00	98,18	BFGS 65	Entropia	Tanh	Softmax	98,49
3	MLP 18-28-1	100,00	100,00	100,00	BFGS 39	Entropia	Tanh	Softmax	100,00
Sieci neuronowe MLP dla pliku zmodyfikowanego bez powtórzonych kolumn									
5	MLP 18-30-1	100,00	100,00	100,00	BFGS 40	Entropia	Tanh	Softmax	100,00

9	MLP 18-14-1	98,06	98,18	96,36	BFGS 48	Entropia	Tanh	Softmax	97,54
---	-------------	-------	-------	-------	---------	----------	------	---------	-------

Porównanie otrzymanych sieci neuronowych dla danych oryginalnych z wszystkimi 20 kolumnami i dla danych oryginalnych z usuniętymi 2 kolumnami oraz dla pliku zmodyfikowanego bez powtórzeń wykazało, że otrzymane wyniki są porównywalne.

Najlepsze klasyfikatory mają porównywalną liczbę neuronów w warstwie ukrytej (29, 30, 28, 30) z funkcją błędów liczoną przy pomocy entropii, funkcją aktywacji Tanh w warstwie ukrytej i funkcją aktywacji Softmax w warstwie wyjściowej. Jedną sieć MLP 20-30-45 dla pliku oryginalnego z powtórzonymi kolumnami ma funkcję aktywacji logistyczną w warstwie ukrytej, jednak ta sieć musiała być dłużej uczona aż 64 iteracje. Natomiast sieci MLP 20-29-45, MLP 18-28-45 i MLP 18-30-45 z funkcją aktywacji w warstwie ukrytej Tanh (BFGS 38, 39 i 40 iteracji).

Na rysunku 36 pokazano wykres jakości sieci neuronowych typu MLP.



Rys. 36. Wykres jakości sieci neuronowych typu MLP – 20 punktów pomiarowych

Najlepszą siecią okazała się sieć MLP 20-29-45 (plik oryginalny z powtórzeniami), MLP 20-30-45 (plik oryginalny z powtórzeniami), MLP 18-28-45 (plik oryginalny bez powtórzeń) oraz MLP 18-30-45 (plik zmodyfikowany bez powtórzeń). Każda z nich dała jakość uczenia 100% (uczenia, testowania i walidacji).

6.7.2. Dane oryginalne i zmodyfikowane – sieci Kohonena

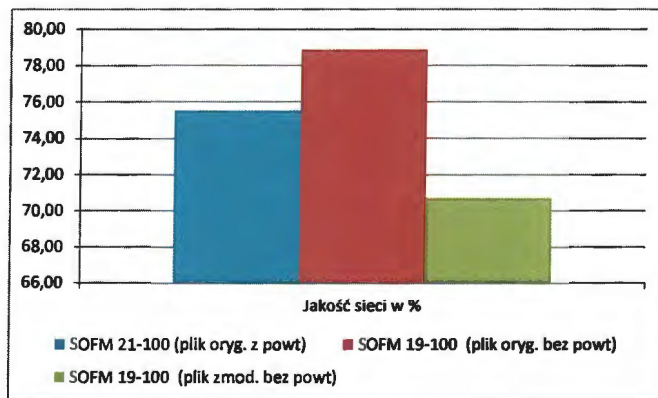
Tabela 40 ilustruje parametry porównywanych klasyfikatorów w postaci sieci Kohonena dla pliku oryginalnego z powtórzeniami i bez oraz pliku zmodyfikowanego bez powtórzeń.

Tabela 40

Id	Nazwa sieci	Jakość uczenia	Jakość testowania	Jakość walidacji	Algorytm uczenia	Jakość sieci w %
Sieć neuronowa Kohonena dla pliku oryginalnego z powtórzonymi kolumnami						
1	SOFM 21-100	79,22	76,84	70,48	Kohonena 1000	75,51
Sieć neuronowa Kohonena dla pliku oryginalnego bez powtórzonych kolumn						
2	SOFM 19-100	81,07	78,84	76,63	Kohonena 1000	78,85
Sieć neuronowa Kohonena dla pliku zmodyfikowanego bez powtórzonych kolumn						
3	SOFM 19-100	73,11	70,57	68,40	Kohonena 1000	70,69

Porównanie otrzymanych sieci neuronowych dla danych oryginalnych z wszystkimi 20 kolumnami i dla danych oryginalnych z usuniętymi 2 kolumnami oraz dla pliku zmodyfikowanego bez powtórzeń wykazało, że otrzymane wyniki różnią się kilkoma procentami. Są to sieci o architekturze 10x10, uczone algorytmem Kohonena z liczbą 1000 iteracji.

Na rysunku 37 pokazano wykres jakości sieci neuronowych typu Kohonen.



Rys. 37. Wykres błędów sieci neuronowych typu Kohonen – 20 punktów pomiarowych

Najlepszym klasyfikatorem okazała się sieć Kohonena nauczona danymi z pliku oryginalnymi bez powtórzonych kolumn (78,85%). Wykorzystano dane oryginalne bez powtórzonych kolumn.

6.8. Dane oryginalne – sieci MLP i Kohonena

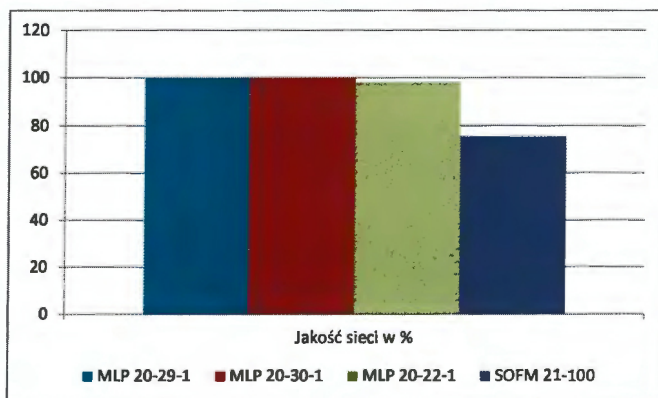
6.8.1. Dane oryginalne z powtórzeniami

Tabela 41 ilustruje parametry opisujące eksperymenty dla różnych struktur sieci MLP i Kohonena w przypadku 20 punktów pomiarowych dla pliku danych oryginalnego z powtórzeniami. Jakość wyrażona jest w %.

Tabela 41

Id	Nazwa sieci	Jakość sieci w %
1	MLP 20-29-1	100,00
2	MLP 20-30-1	100,00
3	MLP 20-22-1	98,01
4	SOFM 21-100	75,51

Na rysunku 38 pokazano wykres jakości sieci neuronowych typu MLP i Kohonen dla pliku z powtórzeniami.



Rys. 38. Wykres jakości sieci neuronowych typu MLP i Kohonen

Najlepszą siecią okazała się sieć typu MLP. Najlepsze klasyfikatory mają porównywalną liczbę neuronów w warstwie ukrytej z funkcją błędów liczoną przy pomocy entropii i funkcją aktywacji Softmax w warstwie wyjściowej (sieci MLP 20-29-45 i MLP 20-30-45). Sieci różnią się jedynie funkcją aktywacji w warstwie ukrytej (Tanh i logistyczna). Funkcja logistyczna wymaga dłuższego czasu uczenia sieci neuronowej.

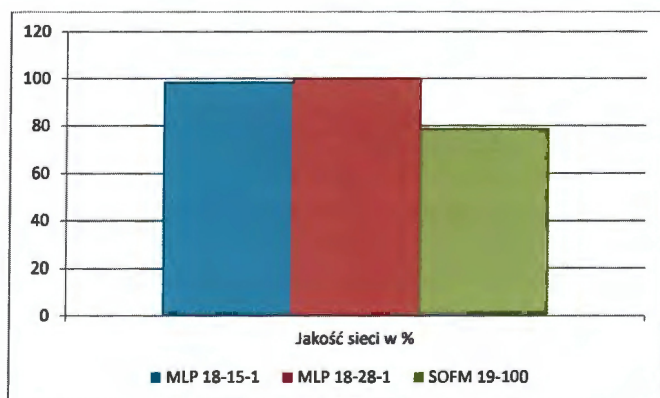
6.8.2. Dane oryginalne bez powtórzeń

Tabela 42 ilustruje parametry opisujące eksperymenty dla różnych struktur sieci MLP i Kohonena w przypadku 20 punktów pomiarowych dla pliku danych oryginalnego bez powtórzeń. Jakość wyrażona jest w %.

Tabela 42

Id	Nazwa sieci	Jakość sieci w %
1	MLP 18-15-1	98,49
2	MLP 18-28-1	100,00
3	SOFM 19-100	78,85

Na rysunku 39 pokazano wykres jakości sieci neuronowych typu MLP i Kohonen dla pliku bez powtórzeń.



Rys. 39. Wykres jakości sieci neuronowych typu MLP i Kohonen

Najlepszą siecią okazała się sieć typu MLP (MLP 18-28-45), z liczbą 28 neuronów w warstwie ukrytej, z funkcją błędów liczoną przy pomocy entropii, funkcją aktywacji w warstwie ukrytej Tanh i funkcją aktywacji Softmax w warstwie wyjściowej.

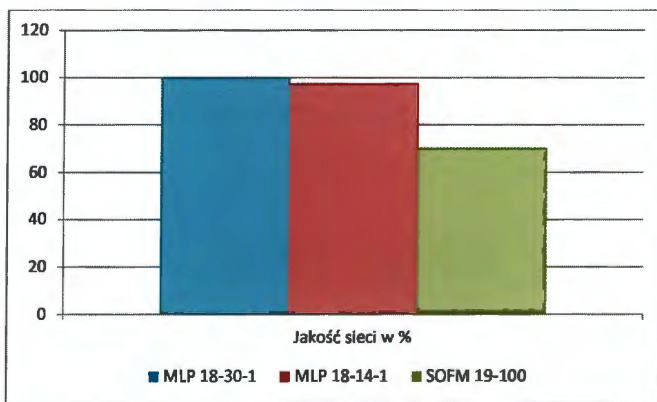
6.8.3. Dane zmodyfikowane – sieci MLP i Kohonena

Tabela 43 ilustruje parametry opisujące eksperymenty dla różnych struktur sieci MLP i Kohonena w przypadku 20 punktów pomiarowych dla pliku danych zmodyfikowanego bez powtórzeń. Jakość wyrażona jest w %.

Tabela 43

Id	Nazwa sieci	Jakość sieci w %
1	MLP 18-30-1	100,00
2	MLP 18-14-1	97,54
3	SOFM 19-100	70,69

Na rysunku 40 pokazano wykres jakości sieci neuronowych typu MLP i Kohonen dla pliku zmodyfikowanego bez powtórzeń.



Rys. 40. Wykres jakości sieci neuronowych typu MLP i Kohonen

Najlepszą siecią okazała się sieć typu MLP (MLP 18-30-45), z liczbą 30 neuronów w warstwie ukrytej, z funkcją błędów liczoną przy pomocy entropii, funkcją aktywacji w warstwie ukrytej Tanh i funkcją aktywacji Softmax.


7. Podsumowanie wyników dla sieci neuronowych dla 10 i 20 punktów pomiarowych z danymi oryginalnymi i zmodyfikowanymi dla sieci MLP i Kohonena

Tabela 44 ilustruje parametry opisujące eksperymenty dla różnych struktur sieci MLP i Kohonena w przypadku 10 oraz 20 punktów pomiarowych dla pliku danych oryginalnego, poprawionego i poprawionego bez powtórzeń. Jakość wyrażona jest w %.

Tabela 44

Id	Nazwa sieci	Jakość sieci w %	Plik danych
1	MLP 10-23-1	85,80	Oryginalny, 10pp
2	MLP 10-24-1	83,63	Poprawiony, 10pp
3	MLP 7-19-1	86,84	Poprawiony bez powtórzeń, 10pp
4	MLP 20-29-1	100,00	Oryginalny z powtórzeniami, 20pp
5	MLP 18-28-1	100,00	Oryginalny bez powtórzeń, 20pp
6	MLP 18-30-1	100,00	Zmodyfikowany bez powtórzeń, 20pp
7	SOFM 11-100	77,68	Oryginalny, 10pp
8	SOFM 11-100	83,90	Poprawiony, 10pp
9	SOFM 8-100	85,44	poprawiony bez powtórzeń, 10pp
10	SOFM 21-100	75,51	Oryginalny z powtórzeniami, 20pp
11	SOFM 21-100	78,85	Oryginalny bez powtórzeń, 20pp
12	SOFM 19-100	70,69	Zmodyfikowany bez powtórzeń, 20pp

Na rysunku 41 pokazano wykres jakości sieci neuronowych typu MLP i Kohonen.



Rys. 41. Wykres jakości sieci neuronowych typu MLP i Kohonen

Porównując sieci neuronowe dla 10 i 20 punktów pomiarowych tabela 19 i rysunek 20 pokazuje, że liczba wejść sieci neuronowych, czyli liczba punktów pomiarowych wpływa na jakość sieci neuronowych. Sieci neuronowe dla 20 punktów pomiarowych są dokładniejsze.

Dla założonych parametrów sieci neuronowych (określona struktura, wartości błędu, rodzaj funkcji aktywacji warstwy wejściowej, ukrytej i wyjściowej) najlepszymi klasyfikatorami okazały się sieci MLP.

8. Zmodyfikowane sieci Kohonena

W celu zwiększenia jakości sieci Kohonena zwiększono znacznie liczbę neuronów w warstwie topologicznej sieci. W pierwszym przypadku do 225 (15x15), a w drugim do 400 (20x20).

Sieć Kohonena uzyskała jakość w 100% dla pliku oryginalnego z powtórzeniami już dla 225 neuronów w warstwie topologicznej. W przypadku pliku oryginalnego bez powtórzeń i zmodyfikowanego bez powtórzeń dopiero przy 400 neuronach. Uzyskanie takiej jakości wymagało wielokrotnie dłuższego uczenia sieci Kohonena niż sieci MLP. Tabela 45 pokazuje podsumowanie sieci Kohonena z dużo większą liczbą neuronów w warstwie topologicznej sieci.

Tabela 45

Lp.	Nazwa sieci	Jakość w %	Plik uczący
1	SOFM 21-225	100,00	Plik oryginalny z powtórzeniami
2	SOFM 21-400	100,00	Plik oryginalny z powtórzeniami
3	SOFM 19-225	96,95	Plik oryginalny bez powtórzeń
4	SOFM 19-400	100,00	Plik oryginalny bez powtórzeń
5	SOFM 19-225	95,37	Plik zmodyfikowany bez powtórzeń
6	SOFM 19-400	100,00	Plik zmodyfikowany bez powtórzeń

Cytując za prof. R. Tadeusiewiczem, że: „Ogólna zasada stosowana w nauce 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” należy wybrać sieci MLP.

Literatura

1. Cichosz P., Systemy uczące się, WNT, Warszawa, 2000.
2. Farmani R., Ingeduld P., Savic D., Walters G., Svitak Z., Berka J.: *Real-time modeling of a major water supply system*. International Conference on Computing and Control for the Water Industry N°8, Exeter, ROYAUME-UNI, vol. 160, no 2, str. 103-108, 2007.
3. Hand D., Manilla H., Smith P., Eksploracja danych, WNT, Warszawa, 2005.

4. Korbicz J., Kościelny J.M., Kowalczyk Z., Cholewa W. (Eds.): *Fault Diagnosis*. Springer, 2004.
5. Krawiec K., Stefanowski J., *Uczenie maszynowe i sieci neuronowe*, wydawnictwo Politechniki Poznańskiej, Poznań, 2004.
6. Larose D. T., *Odkrywanie wiedzy z danych. Wprowadzenie do eksploracji danych*, PWN, Warszawa, 2006.
7. Nałęcz M. (red.): *Biocybernetyka i inżynieria biomedyczna, Sieci neuronowe*, tom 6, Akademicka Oficyna Wydawnicza EXIT, Warszawa, 2000.
8. Osowski S.: *Sieci neuronowe w ujęciu algorytmicznym*, WNT, Warszawa, 1996.
9. Mielczarewicz W.: *Obliczanie systemów zaopatrzenia w wodę*. Arkady, Warszawa 2000.
10. Rojek I.: Model neuronowy do prognozowania poboru wody w sieci wodociągowej, *Studia i Materiały Polskiego Stowarzyszenia Zarządzania Wiedzą*, Tom 10, Bydgoszcz, s. 173-180, 2007.
11. Rojek I., *Wspomaganie procesów podejmowania decyzji i sterowania w systemach o różnej skali złożoności z udziałem metod sztucznej inteligencji*. wydawnictwo Uniwersytetu Kazimierza Wielkiego, 212 stron, Bydgoszcz 2010.
12. Rutkowska D., Piliński M., Rutkowski L., *Sieci neuronowe, algorytmy genetyczne i logika rozmyta*, WN PWN, Warszawa, 1997.
13. Statistica – dokumentacja programu (dane dot. dokumentacji) - Podręcznik elektroniczny *STATISTICA* w programie
14. Straubel R., Holznagel B.: Mehrkriteriale Optimierung fuer Palnung und Steuerung von Trink- und Abwasser-Verbundsystemen. *Wasser-Abwasser*, 140, Nr. 3, 1999, 191-196.
15. Studziński J.: *Optymalizacja i zarządzanie operacyjne miejskimi sieciami wodociągowymi*. Wykład habilitacyjny, IBS PAN, Warszawa, 2005.
16. Studziński J. : *Zastosowanie danych z monitoringu w systemie zarządzania miejską siecią wodociągową*. Studia i Materiały Polskiego Stowarzyszenia Zarządzania Wiedzą, Tom 8, Bydgoszcz, s. 154-164, 2007.
17. Studziński J.: *Innowacje XXI wieku – nowoczesne techniki informacyjne wspomaganie zarządzania w przedsiębiorstwach sieciowych*. W: *Innowacyjne Mazowsze* (A. Straszak, red.) Wyd. SWPW w Płocku, Płock 2010.
18. Studziński J., Bogdan L.: *Informatyczny system wspomaganie decyzji do zarządzania, sterowania operacyjnego i planowania miejskiego systemu wodno-ściekowego*. W: Studziński J., Drelichowi L., Hryniewicz O. (Red.): *Rozwój i zastosowania metod ilościowych i technik informatycznych wspomagających procesy decyzyjne*, Instytut Badań Systemowych Polska Akademia Nauk, Badania Systemowe 49, Warszawa 2006.
19. Tadeusiewicz R.: *Sieci neuronowe*, Akademicka Oficyna Wydawnicza RM, Warszawa, 1993.
20. Tadeusiewicz R. i in.: *Odkrywanie właściwości sieci neuronowych przy użyciu programów w języku C#*, Polska Akademia Umiejętności, Kraków, 2007.
21. Wyczółkowski R., Moczulski W.: *Concept of intelligent monitoring of local water supply system*. *Materials of AI-METH 2005 – Artificial Intelligence Methods*. November 16-18, 2005, Gliwice.
22. Wyczółkowski R., Wysogład B.: *An optimization of heuristic model of water supply network*. *Computer Assisted Mechanics and Engineering Science, CAMES*, no 14, str. 767–776, 2007.

23. Zieliński S.: *Inteligentne systemy w zarządzaniu, Teoria i praktyka*, PWN, Warszawa, 2000.
24. Rojek I., Studziński J.: *Algorytmy lokalizacji awarii w sieci wodociągowej przy użyciu sieci neuronowych*. *Studia i Materiały Polskiego Stowarzyszenia Zarządzania Wiedzą*, Tom 8, Bydgoszcz 2011, 146-156.
25. Haykin, S., *Neural Networks. A Comprehensive Foundation*. Macmillan, New York, NY., 1994
26. Lula P., Tadeusiewicz R., *Wprowadzenie do sieci neuronowych*, StatSoft, 2001

the 1990s, the number of people with a mental health problem has increased in the UK (Mental Health Act 1983, 1990).

There is a growing awareness of the need to improve the lives of people with mental health problems. The Department of Health (1999) has set out a strategy for mental health care in the UK, which includes a commitment to improve the lives of people with mental health problems.

The aim of this paper is to describe the development of a self-help manual for people with mental health problems.

The paper is organized as follows. First, we describe the development of the manual. Then, we describe the manual and the manual's content.

Finally, we discuss the manual's development and the manual's content.

Development

The manual was developed as part of a research project funded by the Department of Health. The project was designed to develop a self-help manual for people with mental health problems.

The manual was developed by a team of researchers, including a psychologist, a social worker, and a mental health nurse.

The manual was developed over a period of 18 months. The manual's development was guided by the following principles:

The manual should be easy to read and understand. The manual should be written in plain English.

The manual should be written in a way that is respectful and dignifying. The manual should be written in a way that is empowering.

The manual should be written in a way that is relevant to the needs of people with mental health problems. The manual should be written in a way that is accessible.

The manual should be written in a way that is culturally sensitive. The manual should be written in a way that is inclusive.

The manual should be written in a way that is evidence-based. The manual should be written in a way that is practical.

The manual should be written in a way that is user-friendly. The manual should be written in a way that is engaging.

The manual should be written in a way that is clear and concise. The manual should be written in a way that is easy to use.

The manual should be written in a way that is relevant to the needs of people with mental health problems. The manual should be written in a way that is accessible.

The manual should be written in a way that is culturally sensitive. The manual should be written in a way that is inclusive.

The manual should be written in a way that is evidence-based. The manual should be written in a way that is practical.

The manual should be written in a way that is user-friendly. The manual should be written in a way that is engaging.

The manual should be written in a way that is clear and concise. The manual should be written in a way that is easy to use.

The manual should be written in a way that is relevant to the needs of people with mental health problems. The manual should be written in a way that is accessible.

The manual should be written in a way that is culturally sensitive. The manual should be written in a way that is inclusive.

The manual should be written in a way that is evidence-based. The manual should be written in a way that is practical.