

Jerzy TCHÓRZEWSKI\*  
Maciej PYTEL\*\*

## MODELOWANIE NEURONALNE ROZWOJU SYSTEMU ELEKTROENERGETYCZNEGO. CZĘŚĆ 2. MODELE SYSTEMU IEEE RTS

W pracy zamieszczono wybrane wyniki badań dotyczące modelowania neuralnego rozwoju systemu elektroenergetycznego na bazie danych testowych IEEE RTS 96., m.in.: sposób tworzenia macierzy danych wejściowych oraz wyjściowych, sposób doboru parametrów sieci, itp. W wyniku projektowania i uczenia SSN uzyskano modele rozwoju SEE, które poddano badaniom wrażliwości m.in. na zmianę liczby warstw ukrytych oraz liczby neuronów w warstwie.

SŁOWA KLUCZOWE: sztuczne sieci neuronowe, dane testowe IEEE RTS, rozwój systemu elektroenergetycznego, środowisko MATLABA i Simulinka, badanie wrażliwości

### 1. BAZA DANYCH TESTOWYCH IEEE RTS

Istnieją różne metody modelowania, m.in.: analityczne, identyfikacyjne, neuronalne, ewolucyjne, rozmyte, itp. [2, 5-7]. W niniejszej pracy do modelowania wykorzystano metodę modelowania neuronalnego polegającą na projektowaniu i uczeniu sztucznej sieci neuronowej (SSN) modelu rozwoju systemu elektroenergetycznego (SEE lub system EE). Dobór architektury SSN oraz metody jej uczenia w rozważanym przypadku zależały od natury rozwoju systemu EE. W celu przeprowadzenia eksperymentów badawczych przygotowano dane uczące i testujące na bazie danych liczbowych pierwszego obszaru systemu testowego IEEE RTS 96<sup>1</sup>, który zbudowany jest z 73 węzłów, 120 gałęzi oraz 96 jednostek wytwórczych, o łącznej mocy 10 215 MW [1, 3, 6]. Jako wielkości wejściowe przyjęto:  $u_1$  – długość linii elektroenergetycznej [km],  $u_2$  – częstość zakłóceń trwałych [1/h],  $u_3$  - czas trwania zakłócenia trwałego [h],  $u_4$  – częstość zakłóceń przemijających [1/h],  $u_5$  – impedancja

<sup>1</sup> System RTS w swojej początkowej wersji (RTS 79) składał się tylko z jednego obszaru. W roku 1986 jego dane uzupełniono w wyniku czego powstał system RTS 79/86, posiadał on 38 gałęzi i 24 węzły. System ten jednak był zbyt słabo rozbudowany, z tych przyczyn podjęto decyzję o opracowaniu nowszej wersji systemu, która nosi nazwę RTS 96.

\* Uniwersytet Przyrodniczo-Humanistyczny w Siedlcach.

\*\* Koło Naukowe Informatyków GENBIT, UPH w Siedlcach.

gałęzi  $[\Omega]$ ,  $u_6$  – impedancja gałęzi  $[\Omega]$ ,  $u_7$  – susceptancja bocznika (składowa bierna admitancji bocznika)  $[S]$ ,  $u_8$  – obciążalność znamionowa ciągła  $[MVA]$ ,  $u_9$  – obciążalność awaryjna długotrwała  $[MVA]$ ,  $u_{10}$  – obciążalność awaryjna krótkotrwała  $[MVA]$ ,  $u_{11}$  – moc jednostki wytwórczej  $[MW]$ ,  $u_{12}$  – generowana moc czynna  $[MW]$ ,  $u_{13}$  – generowana moc bierna  $[MVA]$ ,  $u_{14}$  – maksymalne ograniczenie mocy biernej  $[MVA]$ ,  $u_{15}$  – minimalne ograniczenie mocy biernej  $[MVA]$ ,  $u_{16}$  – napięcie zadane w węźle generatorowym  $[kV]$ .

Natomiast jako wielkości wyjściowe przyjęto:  $y_1$  – obciążenie czynne  $[MW]$ ,  $y_2$  – obciążenie bierna  $[MVA]$  oraz  $y_3$  – napięcie znamionowe  $[kV]$ . Przy budowie schematu połączeń każdego węzła generacyjnego oraz węzła odbiorczego, parametry węzłów bilansujących występujących pomiędzy węzłem generacyjnym i węzłem odbiorczym oraz parametry węzła początkowego i końcowego traktowano jako parametry wspólne - rys. 1.

Ilość węzłów	Nr	Z węzła	Do węzła	$L$		$D_{gr}$		$R$		$X$		$B$		$Con$		$LTE$		$STE$		Nr węzła	Typ jednostki wytwórczej	$P_c$	$P_g$	$P_{max}$	$P_{min}$	$U_s$	Obciążenie		Napięcie znamionowe $[kV]$	
				$[km]$	$[1/a]$	$[H]$	$[1/a]$	$[pU]$	$[pU]$	$[pU]$	$[pU]$	$[MVA]$	$[MVA]$	$[MVA]$	$[MVA]$	$[MW]$	$[MVar]$	$[MVar]$	$[MVar]$								$[MVar]$	$[MW]$		$[MVar]$
		104	105	35,41	0,33	10	1,2	0,022	0,065	0,023	175	208	220	101	48	43	7,05	20	12,5	1,05										
		105	110	37,01	0,34	10	1,2	0,023	0,088	0,024	175	208	220																	
		106	110	25,75	0,33	35	0	0,014	0,061	2,459	175	193	200																	
3	28	101	105	38,17	1	18,333333	2,4	0,059	0,234	2,506	175	208	213,3333	101	48	43	7,05	20	12,5	1,05	136	28	138							

Rys. 1. Przykład opracowania parametrów na potrzeby uczenia SSN modełu rozwoju SEE. Oznaczenia w tekście. Źródło: [1, 3, 4, 6-7]

Sumowano ze sobą długości wszystkich połączeń między węzłami składających się na cały węzeł generacyjno-odbiorczy, a pozostałe parametry uśredniano biorąc pod uwagę liczbę węzłów składających się na dane połączenie. Przygotowane dane poddano normalizacji i jako dwie macierze (tzw. pary trenujące) zostały zaimportowane do przestrzeni roboczej Workspace.

## 2. PROJEKTOWANIE I UCZENIE SSN

Projektowanie SSN przeprowadzono z wykorzystaniem programu Neural Network Toolbox (NNT). Przyjęto 16 wielkości wejściowych oraz 3 wielkości wyjściowe. Dysponowano 60 parami danych trenujących. W przestrzeni roboczej były to macierze o strukturze  $16 \times 60$  (macierz wielkości wejściowych) oraz macierz o strukturze  $3 \times 60$  (macierz wielkości wyjściowych) – tabela 1.

Dobrano do eksperymentu dwie struktury SSN, to jest: Cascade-Forward Backpropagation oraz Feed Forward Backpropagation, wykorzystujące metodę wstecznej propagacji błędów.


Tabela 1. Dane wejściowe oraz dane wyjściowe do uczenia SSN. Źródło [4]

Lp	L	λ <sub>e</sub>	D <sub>er</sub>	λ <sub>i</sub>	R	X	B	Com	LITE	SITE	Typ referencyjny wytwórczej	P <sub>o</sub>	Q <sub>o</sub>	Q <sup>min</sup>	V <sub>s</sub>	Lp	Oczyszczania		Napięcie znamionowe [kV]	
																	Δ <sub>AV</sub>	Δ <sub>AV</sub>		
1	24.14	0.34	11	0.04	0.022	0.045	600	400	600	400	625	400	400	108.2	200	1.05	1	Δ <sub>AV</sub>	128	230
2	28.97	0.35	11	0.4	0.003	0.026	0.056	600	400	625	400	400	108.2	200	1.05	2	Δ <sub>AV</sub>	128	230	
3	89.81	0.61	10	2.9	0.055	0.211	0.057	175	208	220	48	43	7.05	20	12.5	1.095	3	Δ <sub>AV</sub>	128	138
4	36.41	0.33	10	1.2	0.022	0.085	0.023	175	208	220	48	43	7.05	20	12.5	1.095	4	Δ <sub>AV</sub>	128	138
5	53.11	0.39	10	1.7	0.033	0.127	0.034	175	208	220	34	43	3.5	20	12.5	1.095	5	Δ <sub>AV</sub>	128	138
6	4.83	0.24	10	0	0.003	0.014	0.461	175	193	200	34	43	3.5	20	12.5	1.095	6	Δ <sub>AV</sub>	128	138
7	4.83	0.24	10	0	0.003	0.014	0.461	175	193	200	34	43	3.5	20	12.5	1.095	7	Δ <sub>AV</sub>	128	138
8	30.42	0.82	10	2.6	0.025	0.182	0.026	175	208	220	34	43	3.5	20	12.5	1.095	8	Δ <sub>AV</sub>	128	138
9	30.42	0.82	10	2.6	0.025	0.182	0.026	175	208	220	34	43	3.5	20	12.5	1.095	9	Δ <sub>AV</sub>	128	138
10	54.72	0.41	11	0.8	0.005	0.045	0.103	600	600	625	400	400	108.2	200	1.05	10	Δ <sub>AV</sub>	128	230	
11	49.45	0.38	11	0.7	0.005	0.059	0.082	600	600	625	400	400	108.2	200	1.05	11	Δ <sub>AV</sub>	128	230	
12	26.75	0.3	10	0.8	0.016	0.091	0.017	175	208	220	100	80	17.2	60	0	1.025	12	Δ <sub>AV</sub>	128	138
13	90.55	0.49	11	1.5	0.011	0.037	0.182	600	600	625	220	220	45.12	103.333	41.66667	1.05	13	Δ <sub>AV</sub>	128	230
14	72.42	0.67	10	2.492943201	0.045009	0.1728858	0.047029	175	208	220	48	43	7.05	20	12.5	1.095	14	Δ <sub>AV</sub>	128	138
15	146.45	0.89	11	2.2	0.037	0.131	0.276	600	600	625	50	50	4.95	16	10	1.02	15	Δ <sub>AV</sub>	128	230
16	160.94	0.92	11	2.4	0.038	0.145	0.269	600	600	625	220	220	45.12	103.333	41.66667	1.05	16	Δ <sub>AV</sub>	128	230
17	48.06	0.67	11	0.6	0.005	0.034	0.085	600	600	625	155	155	25.22	80	50	1.072	17	Δ <sub>AV</sub>	128	230
18	48.06	0.67	11	0.6	0.005	0.034	0.085	600	600	625	155	155	25.22	80	50	1.072	18	Δ <sub>AV</sub>	128	230
19	68.5	0.72	11	3.06726684	0.038	0.052	0.129	600	600	625	220	220	45.12	103.333	41.66667	1.05	19	Δ <sub>AV</sub>	128	230
20	104.61	0.8	11	1.6	0.012	0.094	0.197	600	600	625	50	50	4.95	16	10	1.02	20	Δ <sub>AV</sub>	128	230
21	49.06	0.67	11	0.6	0.005	0.034	0.085	600	600	625	400	400	108.2	200	1.05	21	Δ <sub>AV</sub>	128	230	
22	53.11	0.42	369.5	0.8	0.008	0.132	0.1	460	555	612.5	197	95.1	40.7	80	0	1.02	22	Δ <sub>AV</sub>	128	138
23	53.11	0.42	369.5	0.8	0.008	0.132	0.1	460	555	612.5	197	95.1	40.7	80	0	1.02	23	Δ <sub>AV</sub>	128	138
24	57.94	0.43	389.5	0.9	0.009	0.136	0.109	450	555	612.5	35.83333	35.83333	0.008333	0.008333	8.33333	1.04	24	Δ <sub>AV</sub>	128	138
25	59.69	0.76	11	1.2	0.009	0.075	0.198	600	600	625	35.83333	35.83333	0.008333	0.008333	8.33333	1.04	25	Δ <sub>AV</sub>	128	138
26	83.69	0.76	11	1.2	0.009	0.075	0.198	600	600	625	400	400	137.4	200	50	1.05	26	Δ <sub>AV</sub>	128	138
27	83.69	0.76	11	1.2	0.009	0.075	0.198	600	600	625	400	400	137.4	200	50	1.05	27	Δ <sub>AV</sub>	128	138
28	20.76	0.61	18.83333333	2.5	0.009	0.335	2.138	175	208	220	48	43	7.05	20	12.5	1.095	28	Δ <sub>AV</sub>	128	138
29	146.45	0.84	263	3.8	0.064	0.347	0.166	358.3333	459.3333	481.6667	48	43	7.05	20	12.5	1.095	29	Δ <sub>AV</sub>	128	138
30	207.6	1.33	10	6.8	0.129	0.495	0.134	175	208	220	48	43	7.05	20	12.5	1.095	30	Δ <sub>AV</sub>	128	138
31	146.45	1.13	10	4.7	0.091	0.35	0.094	175	208	220	34	43	3.5	20	12.5	1.095	31	Δ <sub>AV</sub>	128	138
32	144.64	1.12	10	4.7	0.09	0.345	0.094	175	208	220	100	80	17.2	60	0	1.02	32	Δ <sub>AV</sub>	128	138
33	112.66	0.84	269.3333333	1.7	0.015	0.185	0.132	486.6667	570	616.6667	400	400	108.2	200	50	1.05	33	Δ <sub>AV</sub>	128	138
34	90.12	0.79	269.3333333	1.4	0.012	0.185	0.17	486.6667	570	616.6667	155	155	25.22	80	50	1.075	34	Δ <sub>AV</sub>	128	138
35	144.64	0.88	263	2.8	0.037	0.269	0.227	358.3333	459.3333	481.6667	220	220	45.12	103.333	41.66667	1.05	35	Δ <sub>AV</sub>	128	138
36	144.64	0.88	263	2.8	0.037	0.269	0.227	358.3333	459.3333	481.6667	220	220	45.12	103.333	41.66667	1.05	36	Δ <sub>AV</sub>	128	138
37	144.64	0.88	263	2.8	0.037	0.269	0.227	358.3333	459.3333	481.6667	220	220	45.12	103.333	41.66667	1.05	37	Δ <sub>AV</sub>	128	138
38	122.31	0.86	263	3.1	0.051	0.297	0.145	358.3333	459.3333	481.6667	197	95.1	40.7	80	0	1.02	38	Δ <sub>AV</sub>	128	138
39	78.86	0.75	271.3333333	0.8	0.022	0.195	2.559	358.3333	459.3333	481.6667	197	95.1	40.7	80	0	1.02	39	Δ <sub>AV</sub>	128	138
40	90.12	0.76	263	2.2	0.031	0.22	0.124	358.3333	459.3333	481.6667	197	95.1	40.7	80	0	1.02	40	Δ <sub>AV</sub>	128	138
41	137.6	1.44	11	2.2	0.016	0.144	0.26	600	600	625	400	400	137.4	200	50	1.05	41	Δ <sub>AV</sub>	128	230
42	113.46	1.39	11	1.8	0.013	0.102	0.134	600	600	625	220	220	45.12	103.333	41.66667	1.05	42	Δ <sub>AV</sub>	128	230
43	180.25	1.21	199.75	5.4	0.059	0.354	0.25	312.5	381.5	416.25	220	220	45.12	103.333	41.66667	1.05	43	Δ <sub>AV</sub>	128	138
44	191.51	1.3	199.75	5.4	0.059	0.462	0.19	312.5	381.5	416.25	197	95.1	40.7	80	0	1.02	44	Δ <sub>AV</sub>	128	138
45	188.05	1.18	199.75	5.9	0.059	0.386	0.192	312.5	381.5	416.25	197	95.1	40.7	80	0	1.02	45	Δ <sub>AV</sub>	128	138
46	188.05	1.18	199.75	5.9	0.059	0.386	0.192	312.5	381.5	416.25	197	95.1	40.7	80	0	1.02	46	Δ <sub>AV</sub>	128	138
47	191.51	1.31	199.75	5.3	0.064	0.462	0.189	312.5	381.5	416.25	48	43	7.05	20	12.5	1.095	47	Δ <sub>AV</sub>	128	138
48	138.4	0.93	389	4.5	0.059	0.498	0.089	287.5	359	410	48	43	7.05	20	12.5	1.095	48	Δ <sub>AV</sub>	128	138
49	251.06	1.69	11	3.8	0.029	0.225	0.479	600	600	625	155	155	25.22	80	50	1.075	49	Δ <sub>AV</sub>	128	230
50	251.06	1.69	11	3.8	0.029	0.225	0.479	600	600	625	155	155	25.22	80	50	1.075	50	Δ <sub>AV</sub>	128	230
51	142.31	1.22	313.6	3.2	0.047	0.381	0.229	395	486.6	534	35.83333	35.83333	0.008333	0.008333	8.33333	1.04	51	Δ <sub>AV</sub>	128	138
52	172.31	1.43	162.4	1.6	0.016	0.199	0.23	480	582	620	400	400	137.4	200	50	1.05	52	Δ <sub>AV</sub>	128	230
53	295.68	1.76	161.8	7.6	0.127	0.615	0.321	285	346.8	377	220	220	45.12	103.333	41.66667	1.05	53	Δ <sub>AV</sub>	128	138
54	295.68	1.76	161.8	7.6	0.127	0.615	0.321	285	346.8	377	220	220	45.12	103.333	41.66667	1.05	54	Δ <sub>AV</sub>	128	138
55	295.68	1.76	161.8	7.6	0.127	0.615	0.321	285	346.8	377	220	220	45.12	103.333	41.66667	1.05	55	Δ <sub>AV</sub>	128	138
56	394.68	2.11	134.2	10.7	0.186	0.841	0.382	246.6667	315.6667	350.3333	220	220	45.12	103.333	41.66667	1.05	56	Δ <sub>AV</sub>	128	138
57	394.68	2.11	134.2	10.7	0.186	0.841	0.382	246.6667	315.6667	350.3333	220	220	45.12	103.333	41.66667	1.05	57	Δ <sub>AV</sub>	128	138
58	394.68	2.11	134.2	10.7	0.186	0.841	0.382	246.6667	315.6667	350.3333	220	220	45.12	103.333	41.66667	1.05	58	Δ <sub>AV</sub>	128	138
59	394.68	2.11	134.2	10.7	0.186	0.841	0.382	246.6667	315.6667	350.3333	220	220	45.12	103.333	41.66667	1.05	59	Δ <sub>AV</sub>	128	138
60	223.7	1.89	136.6666667	5.9	0.102	0.508	0.239	320.8333	389	418.3333	34	43	3.5	20	12.5	1.095	60	Δ <sub>AV</sub>	128	138

W wyniku uczenia SSN o liczbie neuronów wejściowych oraz wyjściowych odpowiadającej liczbom wielkości macierzy uczącej wejściowej i macierzy wyjściowej otrzymano przebiegi jak na rys. 2. Błąd uczenia SSN (Train) spadł o jeden rząd wielkości po 6 epokach uczenia, a testowanie i walidacja niewiele poprawiły efekt uczenia. W celu zbadania wrażliwości uczenia SSN przeprowadzono eksperymenty związane ze zmianą takich parametrów jak np.: liczbę warstw ukrytych, liczbę neuronów w każdej warstwie ukrytej, funkcję aktywacji, regułę uczenia, itp. W wyniku uczenia otrzymano katalog modeli, spośród których wybrane modele zamieszczono w tabeli 1.

Najlepsze wyniki otrzymano w przypadku sieci neuronowej o strukturze z jedną warstwą ukrytą posiadającą 10 neuronów. W przypadku sieci neuronowych, którym jako dane uczące wejściowe, oraz dane uczące wyjściowe podawano dane przed normalizacją wyniki uczenia oraz wielkości popełnianych błędów były nie do przyjęcia.

Po zmianie danych uczących na dane poddane normalizacji proces uczenia okazał się dużo efektywniejszy, a błąd uczenia w przypadku niektórych SSN, które uczone były na danych znormalizowanych macierzach wielkości wejściowych i wyjściowych osiągał dokładność rzędu  $10^{-3}$ .

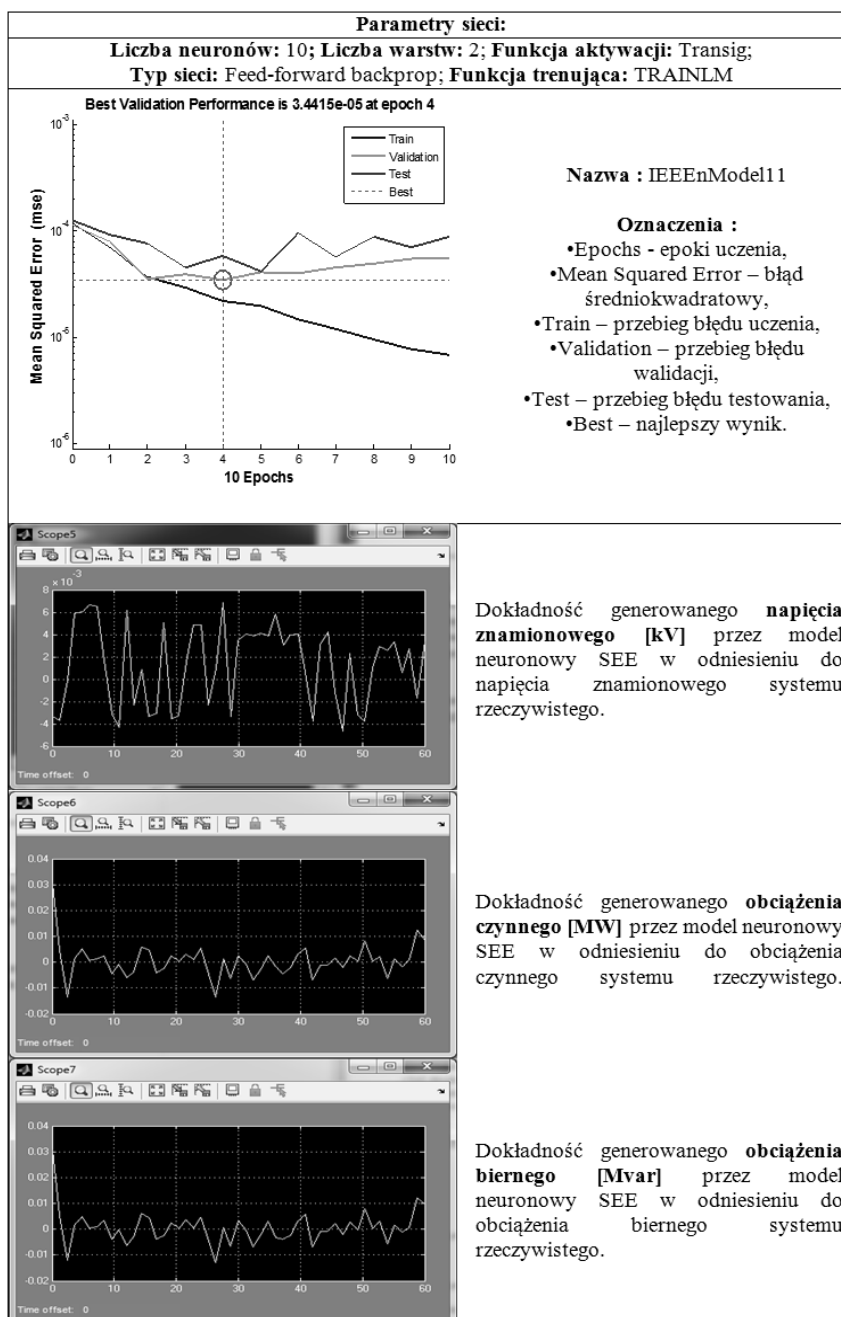


Rys. 2. Przykład przebiegu błędu uczenia, błędu testowania oraz błędu walidacji.

Oznaczenia: Epochs - epoki uczenia, Mean Squared Error – błąd średniokwadratowy, Train – przebieg błędu uczenia, Validation – przebieg błędu walidacji, Test – przebieg błędu testowania, Best – najlepszy wynik w tekście. Źródło: [4]

Przykłady SSN uczonych na danych poddanych normalizacji zamieszczono w tabeli 2.

Tabela 2. Parametry sieci, wykresy przebiegu uczenia, oraz wartości wyjściowe sieci po zestawieniu z wartościami wyjściowymi uczącymi. Źródło: [4]



### 3. UWAGI KOŃCOWE

Projektowanie i uczenie SSN wymaga ustalenia odpowiednio dobranych do modelowanego zjawiska wielkości wejściowych oraz wielkości wyjściowych, a także m.in. funkcji aktywacji i reguły uczenia SSN. W efekcie końcowym modelem neuronalnym jest model rozwoju SEE, na który składają się: sumator iloczynów macierzy wag i wielkości wejściowych oraz funkcja aktywacji o argumentach ww. sumatora. Badania wrażliwości modelu rozwoju wskazują na kierunki poprawy parametrów i struktury modelu. Szczególnie wrażliwy jest model na zmianę liczby warstw ukrytych oraz liczby neuronów w warstwie.

### LITERATURA

- [1] Billinton R., Jonnavithula S., A Test System for Teaching Overall Power System Reliability Assessment, IEEE Transactions on Power System, Vol.14, No 4/99.
- [2] Osowski S., Sieci neuronowe do przetwarzania informacji, OW PW. Warszawa 2000.
- [3] Paska J., Niezawodność systemów elektroenergetycznych, OW PW. Warszawa 2005.
- [4] Pytel M., Neuronowy model rozwoju systemu elektroenergetycznego i jego implementacja w środowisku MATLABA i Simulinka na przykładzie danych testowych IEEE RTS. Praca inżynierska napisana w Zakładzie Modelowania i Projektowania Systemów Informatycznych na Wydziale Nauk Ścisłych. UPH. Siedlce 2014.
- [5] Tadeusiewicz R., Sieci Neuronowe. AOW, Warszawa 1991.
- [6] Tchórzewski J., Roman P., Żurawski T., Modelowanie neuronalne rozwoju systemu elektroenergetycznego na bazie danych testowych IEEE RTS, Wiadomości Elektrotechniczne. Nr. 2/2014, NOT SIGMA.
- [7] Tchórzewski J., Model and Knowledge Maps of Electricity Market Using MATLAB and Neural Network Toolbox. Proceedings of IEEE European Energy Market. Xplore Belgia 2009

#### **NEURONAL MODELING OF POWER SYSTEM DEVELOPMENT. PART 2. MODELS OF IEEE RTS SYSTEM**

The paper presents selected results of research on the modeling of neural development of the power system test data based on the IEEE RTS 96, m.in. : how to create a matrix of data input and output, how to select the network parameters and the like. As a result of learning design and development of the ANN models were obtained SEE, which has been tested sensitivity among to change the number of hidden layers and the number of neurons in a layer.