

mgr inż. Krzysztof Siwek

**PROGNOZOWANIE OBCIĄŻEŃ W SYSTEMIE
ELEKTROENERGETYCZNYM PRZY
WYKORZYSTANIU SZTUCZNYCH SIECI
NEURONOWYCH**

Rozprawa doktorska

AUTOREFERAT

Wydział Elektryczny
Politechniki Warszawskiej

Promotor: prof. dr hab. inż. Stanisław Osowski

25 stycznia 2001

1. Cel i teza pracy

Głównym celem rozprawy jest opracowanie skutecznych metod krótkoterminowej prognozy godzinowego obciążenia Polskiego Systemu Elektroenergetycznego opartych na wykorzystaniu sztucznych sieci neuronowych. Dla osiągnięcia tego celu autor zaproponował różne odmiany rozwiązań wykorzystujące dwa rodzaje sieci neuronowych: perceptron wielowarstwowy oraz sieć samoorganizującą Kohonena. Opracowane zostały nieliniowe, neuronowe modele systemu elektroenergetycznego pozwalające na wykonanie prognozy krótkoterminowej obciążenia dobowego 24-godzinnego. Autor opracował metody uczenia takich sieci oraz zastosował je do rozwiązania zagadnień prognostycznych obciążeń systemu elektroenergetycznego. Wykonał ogromną liczbę symulacji numerycznych na danych dotyczących obciążeń Polskiego Systemu Elektroenergetycznego. Uzyskane wyniki badań potwierdzają następującą tezę pracy:

Sztuczne sieci neuronowe, zwłaszcza sieci wielowarstwowe i samoorganizujące zaproponowane w rozprawie, są efektywnym narzędziem dla celów krótkoterminowej prognozy dobowego obciążenia systemu elektroenergetycznego.

2. Przegląd zawartości rozprawy

Rozprawa liczy 122 strony i zawiera 6 rozdziałów i jeden dodatek.

Rozdział pierwszy zawiera krótki przegląd metod prognozowania obciążeń w systemach elektroenergetycznych, ze szczególnym naciskiem na metody prognozowania krótkoterminowego. Autor przedstawił metody klasyczne oparte na analizach statystycznych zmienności obciążeń, w tym metody deterministyczne, probabilistyczne i autoregresyjne. Zawarł również przegląd nowoczesnych metod, wykorzystujących sztuczne sieci neuronowe: wielowarstwowe typu perceptronowego, rekurencyjne, samoorganizujące i hybrydowe.

Rozdział drugi obejmuje omówienie sieci neuronowych stosowanych przez autora rozprawy do predykcji obciążeń. Zaprezentowane tu są sieci wielowarstwowe, samoorganizujące klasyczne (typu Kohonena) oraz samoorganizujące z wnioskowaniem rozmytym.

Rozdział trzeci poświęcony jest metodologii prognozowania krótkoterminowego przy wykorzystaniu sieci neuronowych. Zawiera analizę czynników wpływających na prognozę obciążeń w systemie elektroenergetycznym. W rozdziale tym omówione są dokładnie modele predykcji obciążeń z wykorzystaniem sieci neuronowych oraz wyszczególnione algorytmy postępowania przy sporządzaniu predykcji. Ostatni punkt rozdziału dotyczy analizy błędów prognozy.

W rozdziale piątym zaprezentowano wyniki przeprowadzonych przez autora symulacji komputerowych na rzeczywistych danych dotyczących obciążeń Polskiego Systemu Elektroenergetycznego z lat 1992-1997 oraz analizę porównawczą otrzymanych wyników z innymi, dostępnymi w literaturze światowej.

Rozdział szósty zawiera wnioski końcowe.

W dodatku mieści się dogłębna analiza statystyczna obciążeń Polskiego Systemu Elektroenergetycznego dla lat 1986-1997. Analiza taka ma na celu poznanie specyfiki przebiegów obciążeń w czasie oraz czynników kształtujących te przebiegi. Analizowane są czynniki kształtujące zmienność tych obciążeń w ciągu doby, tygodnia, miesiąca, sezonu i roku. Wyniki analiz wykorzystywane są przy sporządzaniu prognoz obciążeń.

3. Metody neuronowe prognozowania krótkoterminowego obciążeń w SEE

3.1. Analiza czynników wpływających na prognozę

Podstawowym problemem, który musi zostać rozwiązany jest ustalenie cech procesu, które mają decydujący wpływ na prognozę. Z analizy obciążeń polskiego systemu elektroenergetycznego wynika, że stan obciążenia z poprzednich godzin ma bardzo istotny wpływ na obciążenie w godzinie następnej. Zjawisko to ilustruje rysunek

Następnym czynnikiem godnym uwagi jest duża powtarzalność obciążeń godzinnych w bliskich sobie dniach. Stąd prognozując obciążenie na określoną godzinę trzeba brać pod uwagę obciążenia odpowiadające tej samej godzinie z dni poprzednich. Liczbę dni, które należy brać pod uwagę można określić w sposób doświadczalny, bądź przy użyciu metody wrażliwościowej.

Ważnym czynnikiem jest również typ dnia podlegającego prognozie. Wyróżnić można dwa modele typów dni: model „weekdays” i „weekend”, stosowane w prognozowaniu z użyciem perceptronu wielowarstwowego. W modelu „weekend” wyróżnia się jedynie 2 typy dni: dzień roboczy (od poniedziałku do piątku) i świąteczny (sobota, niedziela), które w wektorze danych wejściowych mogą być reprezentowane w postaci bitowej (0 lub 1) poprzez jeden węzeł wejściowy (tabela 1). W modelu „weekdays” rozróżnia się 4 typy dni, co wymaga zastosowania w kodowaniu dwóch węzłów wejściowych sieci neuronowych.

Tabela 1. Kodowanie typów dni

dzień tygodnia	model „weekdays”	model „weekend”
sobota	0 0	0
niedziela	0 1	0
poniedziałek	1 0	1
wtorek	1 1	1
środa	1 1	1
czwartek	1 1	1
piątek	1 1	1

Następnym czynnikiem, którego wpływ może być uwzględniony w prognozie to podział dnia na cztery strefy różniące się poziomem obciążenia systemu elektroenergetycznego: dolina nocna, szczyt ranny, dolina południowa oraz szczyt wieczorny. Wobec 4 rodzajów stref do ich zakodowania wymagane jest użycie również 2 węzłów sieci neuronowej.

Na wartości obciążenia SEE w dużym stopniu wpływają warunki klimatyczne, które są zdeterminowane głównie przez porę roku. Poziom obciążenia zmienia się od najwyższego w okresie zimy do najniższego w ciągu lata. Wprowadzić można zatem kolejny dwubitowy znacznik, opisujący przynależność danego dnia do odpowiedniej pory roku. Przyjęty sposób kodowania pory roku w postaci wartości 2-bitowych przedstawiono w tabeli 2. Czynnikiem ten można pominąć, gdy dane uczące zostaną pozbawione trendów wynikających z sezonowych i rocznych zmian poziomu obciążenia.

Tabela 2. Znacznik opisujący porę roku

pora roku	miesiące	znacznik
lato	czerwiec, lipiec, sierpień	0 0
wiosna	marzec, kwiecień, maj	0 1
zima	grudzień, styczeń, luty	1 1
jesień	wrzesień, październik, listopad	1 0

Dla zachowania porównywalności poszczególnych czynników branych pod uwagę przy prognozowaniu konieczna jest normalizacja danych dotyczących obciążenia (na przykład przez podzielenie danych przez wartość średnią lub maksymalną obciążeń występujących w bazie).

Wymiar wektora wejściowego cech jest zatem uzależniony od liczby czynników branych pod uwagę w procesie predykcji. Kolejność ustawienia poszczególnych wartości w wektorze jest dowolna. Autor przyjął zasadę, że pierwsze pozycje zajmują wartości opisujące symbolicznie czynniki związane z rodzajem dnia i godziną prognozy, a pozostałe - znormalizowane wartości odpowiednich obciążeń godzinnych.

Należy pamiętać, że zwiększenie wymiaru wektora wejściowego pociąga za sobą również zwiększenie liczby wag w sieci, co jest zjawiskiem niezbyt korzystnym z punktu widzenia maksymalizacji zdolności generalizacyjnych sieci neuronowej.

3.2. Prognoza obciążeń systemu przy wykorzystaniu sieci perceptronowej

W modelu tym zakłada się, że sieć neuronowa na podstawie informacji o obciążeniach w poprzednich dniach i godzinach jest w stanie określić z akceptowalną dokładnością obciążenie na następne kilka lub kilkadziesiąt godzin. Danymi pomocniczymi przy predykcji są typ dnia, znacznik pory roku oraz szczytu obciążenia.

Na podstawie wielu badań wstępnych ustalono, że wektor wejściowy (wektor cech procesu) podawany na wejście sieci perceptronowej będzie zawierał następujące czynniki:

- pozycja pierwsza lub dwie pierwsze, w zależności od wybranej opcji (model „weekdays” lub „weekend”), określają typ dnia,
- kolejne dwie pozycje określają porę roku odpowiadającą dnu, dla którego obliczana jest prognoza,
- następne dwie pozycje zajmować mogą oznaczenia stref obciążeń; przy braku podziału dnia na strefy pozycje te nie występują,
- pozostałe pozycje zajmują wartości znormalizowane obciążeń odpowiadające obciążeniom godzinnym z przeszłości uwzględnianym w prognozie.

Przy prognozowaniu obciążenia na godzinę h w dniu D , kolejność obciążeń godzinnych w wektorze x jest następująca: $p(D, h-1), p(D, h-2), \dots, p(D, h-g), p(D-1, h), p(D-1, h-1), \dots, p(D-1, h-g), \dots, p(D-d, h), p(D-d, h-1), \dots, p(D-d, h-g)$. Wartość d oznacza liczbę dni wstecz, a g – liczbę godzin wstecz uwzględnianych przy prognozie. Prognozowane obciążenie można zatem opisać ogólną zależnością nieliniową:


$$p(D, h) = f(\mathbf{W}, r, u, s, p(D, h-1), \dots, p(D, h-g), p(D-1, h), p(D-1, h-1), \dots, p(D-1, h-g), \dots, p(D-d, h), p(D-d, h-1), \dots, p(D-d, h-g))$$

w której \mathbf{W} oznacza wektor wag całej sieci neuronowej, r – symbol typu dnia, u – znacznik pory roku oraz s – znacznik szczytu obciążenia.

Wektor zadany sygnałów wyjściowych \mathbf{d} , konieczny przy uczeniu z nauczycielem, zawiera wartości obciążeń w kolejnych godzinach, których dotyczy prognoza. Liczba neuronów wyjściowych jest więc równa liczbie godzin, dla których obliczana jest prognoza. Przy prognozie na jedną godzinę naprzód oznacza to 1 neuron wyjściowy w sieci, przy prognozie 24-godzinnej mamy 24 neurony w warstwie wyjściowej. Każdy neuron wyjściowy reprezentuje obciążenie o określonej (kolejnej) godzinie dnia. Wszystkie neurony w warstwie wyjściowej posiadają liniową funkcję aktywacji, umożliwiającą najłatwiejsze dopasowanie sygnału wyjściowego neuronu do wartości zadanej.

Rysunek 1 przedstawia schematycznie sieć MLP do predykcji obciążeń na 24 godziny naprzód. Przedstawiona sieć posiada 2 warstwy ukryte. W warstwie wejściowej zaznaczono węzły, na które podawane są znaczniki typu dnia, pory roku i szczytu obciążenia. Pozostałe węzły odpowiadają znormalizowanym danym obciążenia w poprzednich dniach i godzinach w opisanej wcześniej kolejności.

Ważnym problemem w uczeniu sieci jest przygotowanie danych uczących i testujących (sprawdzających) dla sieci. Baza danych dotyczących obciążenia systemu elektroenergetycznego z przeszłości jest bardzo obszerna. Wykorzystanie wszystkich danych z bazy jest niecelowe, gdyż niepotrzebnie wydłużyłoby proces uczenia, utrudniając go i zwiększając prawdopodobieństwa utknięcia w minimum lokalnym.



Rysunek 1. Sieć MLP do predykcji obciążeń

W wyniku analizy problemu zastosowano w uczeniu wybrane dane dotyczące obciążeń systemu z lat 1994-1996 ograniczając się do około 1/4 danych z każdego roku, przy czym wybrane dane dotyczyły wszystkich pór roku (wiosna, lato, jesień, zima). Dane z roku 1997 (ostatniego z dostępnej bazy danych) pozostawiono wyłącznie do testowania zdolności generalizacyjnych sieci neuronowej. Pozostałe dane z lat 1986-1996 uczestniczyły również w testowaniu sieci.

Dobór liczby warstw ukrytych i neuronów w tych warstwach przeprowadzono równolegle dwiema drogami. Przede wszystkim przeprowadzono szereg prób z różnymi sieciami i wybrano też najmniejszymi błędami generalizacji. Następnie wykorzystane zostały procedury wrażliwościowe OBD pozwalające zredukować liczbę wag w zastosowanej sieci i zmniejszyć błąd generalizacji jeszcze bardziej. W przypadku wyeliminowania wszystkich połączeń wagowych dochodzących do któregoś z neuronów w warstwie ukrytej, usuwano ten neuron z sieci.

3.3. Prognoza obciążeń PSE przy wykorzystaniu sieci samoorganizujących

3.3.1. Model predykcji obciążeń elektroenergetycznych z zastosowaniem sieci samoorganizującej

Zadaniem sieci samoorganizującej w tym rozwiązaniu jest rozpoznawanie charakterystyk obciążeń godzinnych, odpowiadających różnym porom roku. Każdy dzień roku posiada swoją specyfikę obciążenia godzinnego, która w niewielkim tylko stopniu zmienia się z roku na rok. Obciążenia dni należących do tej samej pory roku i reprezentujących ten sam typ różnią się minimalnie, zwykle o wartość stałą wynikającą z trendu ogólnego. Tworzą one zatem klastry, które mogą być reprezentowane poprzez wagi jednego neuronu. Aby uniezależnić się od trendu, wynikającego z ogólnego rozwoju kraju, w metodzie tej konieczne jest uwzględnienie jedynie części zmiennej po odjęciu wartości średniej i uwzględnieniu wariancji danych.

Przy oznaczeniu wartości średniej obciążenia systemu w j -tym dniu przez $P_m(j)$ a jego wariancji przez $\sigma^2(j)$, definiuje się tak zwany profil godzinny dnia j -tego w postaci

$$p(j,h) = \frac{P(j,h) - P_m(j)}{\sigma^2(j)}$$

dla $h=1,2,\dots,24$, w którym $P(j,h)$ oznacza rzeczywisty pobór mocy w systemie elektroenergetycznym w j -tym dniu o godzinie h . Wartości $p(j,h)$ tworzą wektory obciążeń profilowych dnia, $\mathbf{p}_j = [p(j,1), p(j,2), \dots, p(j,24)]$.

Dla każdego dnia w roku występującego w bazie danych tworzy się wektor profilowy według powyższego wzoru. Zbiór wszystkich wektorów profilowych podzielony zostaje następnie na część uczącą i testującą. Podobnie jak w przypadku sieci perceptronowej w uczeniu wykorzystano jedynie część bazy danych, pozostawiając pozostałe dane do etapu testowania.

Użyta w rozwiązaniu sieć samoorganizująca zawierała 100 neuronów, w związku z tym poszczególne wektory były w procesie uczenia przypisywane do jednego ze 100 klastrów. Oznacza to, że w wyniku uczenia każdy neuron poprzez swoje wagi reprezentuje obciążenia profilowe średnio 3 dni z roku z bazy uczącej. W przypadku uczenia przeprowadzanego z użyciem algorytmów, w których istotna jest topologia, neurony sieci ułożone były w węzłach kwadratowej lub heksagonalnej siatki o wymiarach 10×10 . Taka liczba neuronów wybrana została w wyniku przeprowadzenia wielu eksperymentów numerycznych metodą prób i błędów.

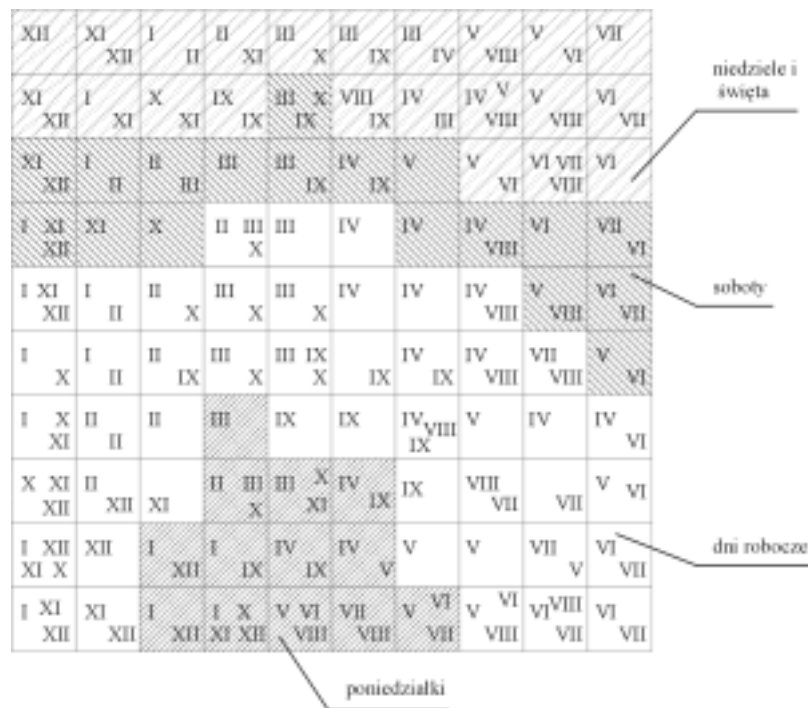
Na etapie uczenia na wejście sieci samoorganizującej podawany jest zbiór wektorów ze zbioru uczącego. Proces samoorganizacji powoduje samoczynne grupowanie danych i przypisanie każdemu klastrowi jednego neuronu sieci, którego wagi najlepiej dopasowane są do uśrednionych wektorów danych uczących (profilu) tworzących klastery. Neuron ten jest reprezentantem określonej klasy. Mechanizm sąsiedztwa zapewnia ponadto, że sąsiednie neurony mają zbliżone charakterystyki profilowe. Rysunek 2 przedstawia wektory wagowe neuronów wybranych sieci samoorganizujących, wytrenowanych przy użyciu algorytmu Kohonena.



topologia typu prostokątnego

Rysunek 2. Charakterystyki profilowe neuronów

Należy zauważyć, że podobieństwo wag neuronów leżących blisko siebie wynika z mechanizmu sąsiedztwa. Oznacza to, że ten sam dzień roku w różnych latach, przy drobnych różnicach w obciążeniach godzinnych może być reprezentowany przez różne neurony położone blisko siebie i tworzące rodzaj klastrów. Otrzymana w ten sposób mapa rozkładu klas obciążeń dla wybranej sieci przedstawiona jest na rysunku 3.



Rysunek 3. Mapa rozkładu obciążeń rocznych systemu

Na mapie rozkładu obciążeń wyraźnie wyodrębnić można zwarte obszary odpowiadające dniom świątecznym (niedziele i święta oraz soboty) i dniom roboczym ze szczególnym wyróżnieniem poniedziałków. Zaobserwować można również inną ciekawą własność związaną z porami roku. Przejście od miesięcy zimowych zajmujących górę mapy do miesięcy letnich na jej dole, odbywa się płynnie poprzez miesiące wiosenne i jesienne, przy czym poszczególne podobszary sąsiadują ze sobą. Własność ta dotyczy zarówno dni świątecznych jak i roboczych.

Na podstawie mapy rozkładów tworzone są tablice przynależności każdego dnia w roku do określonej klasy, z zaznaczeniem liczby wystąpień danego typu dnia w określonej klasie (na przykład w tabeli 3 pokazana jest przynależność wtorków w miesiącu lipcu do poszczególnych klas).

Tabela 3. Tablica przynależności wybranego dnia

miesiąc	rodzaj dnia	klasa	liczba wystąpień
lipiec	wtorek	59	2
lipiec	wtorek	78	1
lipiec	wtorek	79	3
lipiec	wtorek	89	4
lipiec	wtorek	90	7
lipiec	wtorek	99	6
lipiec	wtorek	100	4

Przy zastosowaniu algorytmu uczenia typu WTM wszystkie klasy przynależności występujące w tabeli 3 sąsiadują ze sobą (rysunek 3) i mają zbliżone wektory profilowe (rysunek 2). W celu wyznaczenia przewidywanego obciążenia aktualnego dnia w danym miesiącu (w przykładzie wtorku z lipca) przyjmuje się uśrednione wartości wag neuronów tworzących klasy, do których przynależał w przeszłości dany typ dnia. Algorytm uśredniania może przyjmować różną postać, w zależności od przyjętej metodyki obliczania średniej ważonej.

3.3.2. Algorytm prognozowania profili obciążeń przy zastosowaniu wnioskowania klasycznego

Jeżeli liczbę wystąpień i -tej klasy odpowiadającej j -temu dniu oznaczy się w postaci k_{ji} a odpowiadające tej klasie wektory wag neuronów przez \mathbf{w}_i , to przewidywany wektor profilowy obliczyć można według wzoru

$$\mathbf{p}_j = \frac{\sum_{i=1}^n k_{ij} \mathbf{w}_i}{\sum_{i=1}^n k_{ij}}$$

Symbol n oznacza liczbę klas, do których przynależał w przeszłości dany typ dnia.

3.3.3. Algorytm prognozowania profili obciążeń przy zastosowaniu wnioskowania rozmytego

W metodzie tej wektor profilowy oblicza się na podstawie znajomości sygnałów wyjściowych neuronu zwycięzcy i pewnej ograniczonej liczby q neuronów (w praktyce $4 \div 8$) z jego sąsiedztwa. Sygnały te przekształcane są według wzoru

$$y_i = e^{-\alpha(u_w - u_i)^2}$$

gdzie u_w jest wartością odpowiedzi neuronu zwycięzcy, u_i – wartością odpowiedzi neuronów z sąsiedztwa zwycięzcy a α – współczynnikiem decydującym o wpływie neuronów z sąsiedztwa zwycięzcy na prognozę (w implementacjach praktycznych współczynnik ten był dobierany z przedziału $0.2 \div 10$). Dla zwycięzcy wartość y_i jest równa 1, dla pozostałych neuronów otrzymuje się wartości malejące wraz z odległością wektora ich wag od zwycięzcy.

Następnie definiuje się znormalizowaną funkcję przynależności wektora wejściowego \mathbf{x} do i -tego neuronu według wzoru:

$$\mu_i = \frac{y_i}{\sum_{i=1}^q y_i}$$

Ostatecznie prognozowany wektor profilowy dla dnia j -tego określa się z zależności uwzględniającej nie tylko zwycięzców ale również q najbliższych sąsiadów przegrywających konkurencję

$$\mathbf{p}_j = \frac{\sum_{i=1}^n \sum_{k=1}^q \mu_{ij} \mathbf{w}_i}{\sum_{k=1}^q \mu_{ij}}$$

Taki sposób prognozy profili jest wprawdzie bardziej złożony, ale lepiej odzwierciedla rozmyty charakter obciążenia i pozwala uzyskać wyższą dokładność prognozy.

3.3.4. Algorytmy prognozowania wartości średniej i wariancji obciążenia dziennego

Po wyznaczeniu prognozy obciążenia profilowego należy określić rzeczywiste obciążenie systemu w poszczególnych godzinach podlegających prognozie. Działanie to jest odwrotne do przedstawionego we wzorze (4.1) i dla dnia j -tego o godzinie h może być opisane zależnością

$$\hat{P}(j, h) = \hat{\sigma}^2 \cdot \hat{p}(j, h) + \hat{P}_m(j)$$

w której wielkości z daszkami oznaczają prognozę danej wielkości. Oznacza to konieczność dokonania prognozy dwu następnyc wielkości: średniego obciążenia w danym dniu – $P_m(j)$ oraz odpowiadającej mu wariancji – $\sigma^2(j)$. Autor pracy opracował i zastosował pięć metod obliczania tych wartości, z których najbardziej efektywną okazała się metoda wykorzystująca perceptron wielowarstwowy. Koncepcja rozwiązania neuronowego oparta jest na wykorzystaniu elementów prognozy obciążenia 24-godzinnego z użyciem sieci wielowarstwowej opisanej powyżej.

Przeprowadzając podobne rozumowanie dla wartości średniej i wariancji obciążenia można zauważyć, że wartość średnia (wariancja) obciążenia w dniu d w roku y zależy od wartości średniej (wariancji) obciążenia w dniach i latach poprzednich, od typu dnia oraz od dodatkowych znaczników opisujących porę roku. Zależności takie można zapisać w postaci równań nieliniowych


- dla wartości średniej

$$\hat{P}_m(d, y) = f(\mathbf{W}, r, u, P_m(d, y-1), \dots, P_m(d, y-Y), P_m(d-1, y), \dots, P_m(d-1, y-Y), \dots, P_m(d-D, y-1), \dots, P_m(d-D, y-Y))$$

- dla wariancji obciążenia

$$\hat{\sigma}^2(d, y) = f(\mathbf{W}, r, u, \sigma^2(d, y-1), \dots, \sigma^2(d, y-Y), \sigma^2(d-1, y), \dots, \sigma^2(d-1, y-Y), \dots, \sigma^2(d-D, y-1), \dots, \sigma^2(d-D, y-Y))$$

przy oznaczeniu przez \mathbf{W} wektora wag całej sieci neuronowej, r symbolu typu dnia oraz przez u znacznika pory roku. Przykładowa sieć neuronowa implementująca powyższy sposób prognozy przedstawiona jest na rysunku 4.



Rysunek 4. Sieć MLP do predykcji wartości średniej i wariancji obciążenia

Autor rozprawy przeprowadził szereg eksperymentów numerycznych z różnymi strukturami sieci neuronowych o różnych postaciach wektora wejściowego. Spośród wszystkich

przetestowanych sieci wybrano ostatecznie po jednej sieci najlepiej realizujących estymację wartości średniej i wariancji obciążenia. Są to sieci:

- o strukturze 23-13-1 z uwzględnieniem 4 typów dni i 4 pór roku dla predykcji wartości P_m oraz
- o strukturze 27-16-1 z uwzględnieniem 4 typów dni i 4 pór roku dla predykcji wartości σ^2 .

Tabela 4. Błędy estymacji wartości P_m i σ^2 metodą neuronową po przeprowadzeniu dodatkowej procedury redukcji struktury

typ danych	okres prognozy	\hat{P}_m		$\hat{\sigma}^2$	
		MAPE [%]	MAX [%]	MAPE [%]	MAX [%]
	1992	1.6074	6.1153	4.1312	22.2468
	1993	1.8744	9.6214	4.4362	25.9536
uczące	1994	1.9445	11.2510	4.5409	27.0891
	1995	1.9430	11.1233	4.7147	43.5849
	1996	1.7717	12.1463	4.2380	18.9967
testujące	1997	1.6964	8.3279	3.9122	20.2637
wszystkie	1992-1997	1.8062	12.1463	4.3289	43.5849

Tabela 4 pokazuje uzyskane błędy MAPE i MAX prognozy wartości średniej i wariancji poszczególnych dni w roku w latach 1992-1997.

4. Wyniki badań symulacyjnych

W rozdziale tym zaprezentowane będą wyniki badań symulacyjnych oraz ich analiza, dotyczące opisanych w poprzednich rozdziałach metod predykcji krótkoterminowej obciążenia Polskiego Systemu Elektroenergetycznego. System prognozy oparty na sieci wielowarstwowej ze względu na jej specyfikę, nadaje się do prognozy tylko na bieżąco. Rozwiązanie wykorzystujące sieć samoorganizującą, w tym z wnioskowaniem rozmytym jest bardziej uniwersalne, umożliwiające predykcję 24-godzinną z dowolnym wyprzedzeniem w skali roku. Metoda wykorzystująca wnioskowanie rozmyte jest całkowicie nowatorska. Autor rozprawy nie spotkał w literaturze światowej podobnego rozwiązania. Główna uwaga w badaniach została skupiona na problematyce prognozy krótkoterminowej na 24 godziny naprzód. Przedstawione poniżej wyniki dotyczą tego typu prognozy.

4.1. Wyniki prognoz obciążeń PSE przy wykorzystaniu sieci perceptronowej

Najlepsze rezultaty uzyskano dla sieci perceptronowej o strukturze 23-20-15-24 (23 elementowy wektor wejściowy, 2 warstwy ukryte o odpowiednio 20 i 15 neuronach posiadających sigmoidalną funkcję aktywacji oraz warstwa wyjściowa zawierająca 24 neurony z liniową funkcją aktywacji). Wektor wejściowy (*d3g4s*) odpowiadający tej sieci uwzględniał dane obciążenia z 3 dni i 4 godzin wstecz, 2-bitowy znacznik szczytu oraz 2-bitowy znacznik typu dnia (4 typy dnia). Sieć trenowana była na wybranych losowo danych z lat 1992-1996 (około 1/4 danych z każdego roku). Danymi testującymi były wszystkie dane obciążenia z 1997 roku oraz pozostałe, nie wykorzystane w uczeniu dane z lat wcześniejszych.

Tabela 5 przedstawia uzyskane wartości błędów MAPE i MAXP dla wyselekcjonowanej struktury sieci. Osiągnięte rezultaty nie są w pełni satysfakcjonujące. Szczególnie niepożądany jest pewien wzrost błędów MAPE i MAE dla danych testujących w stosunku do danych uczących (z

3.29% do 3.34% dla danych z lat 1992-1996). Nie do przyjęcia jest również wysoka wartość błędu maksymalnego (ponad 47%). Konieczna było regularyzacja sieci polegająca na zastosowaniu procedur polepszających generalizację. W opisywanym przypadku najlepsze rezultaty dała procedura OBD. Rysunek 5 przedstawia wynik zastosowania procedury OBD dla omawianej sieci, w postaci znacznego uproszczenia jej struktury.

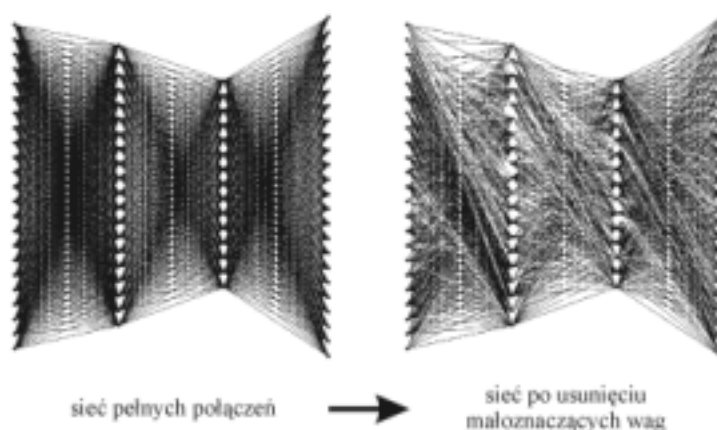
Tabela 5. Błędy prognozy 24-godzinnej uzyskane przy użyciu sieci wielowarstwowej

typ danych	okres prognozy	MAPE [%]	MAE [MW]	MAX [%]	MAXP [MW]
uczące	1992	3.5467	517.45	47.8875	7652.22
	1993	3.4852	508.38	44.4301	6544.63
	1994	3.2334	497.97	33.6711	6331.11
	1995	3.1113	482.93	32.1223	6210.91
	1996	3.1068	479.75	32.0132	6201.43
	1992-1996	3.2967	497.30	47.8875	7652.22
testujące	1997	3.6112	525.33	47.2251	7543.44
wszystkie	1992-1997	3.3491	501.97	47.8875	7652.22

Tabela 6. Błędy prognozy 24-godzinnej uzyskane przy użyciu sieci wielowarstwowej po zastosowaniu procedury OBD


typ danych	okres prognozy	MAPE [%]	MAE [MW]	MAXP [%]	MAX [MW]
uczące	1992	3.5344	516.88	27.0546	3823.91
	1993	3.4922	504.08	28.8013	4501.12
	1994	3.2237	492.99	27.0786	4275.76
	1995	3.1109	481.97	28.1368	4434.57
	1996	2.9997	463.23	26.5987	4268.18
	1992-1996	3.2722	491.83	28.8013	4501.12
testujące	1997	2.9924	458.77	29.0896	4456.61
wszystkie	1992-1997	3.2256	486.32	29.0896	4501.12

W wyniku regularyzacji z pierwotnej sieci zawierającej 59 neuronów i 1179 połączeń wagowych usunięto 179 wagi, czyli nieco ponad 15% wszystkich wag.




Rysunek 5. Przebieg procedury OBD dla sieci MLP

W tabeli 6 przedstawiono uzyskane wyniki prognozy 24-godzinnej po redukcji sieci. W wyniku działania procedury OBD uzyskano zmniejszenie wartości błędu MAPE o 0.6% (względna poprawa o około 15%) dla danych testujących z roku 1997, co odpowiada około 66 MW błędu MAE. W przypadku lat 1992-1996 spadek wartości błędu MAPE jest nieco mniejszy (z 3.35% na 3.22%). Spadek wartości błędów maksymalnych był jeszcze większy z 47% na 29% czyli niemal dwukrotnie – o około 3100 MW. Przedstawione tu wyniki potwierdzają skuteczność działania procedury OBD w poprawie zdolności generalizacyjnych sieci neuronowych, polepszając ich zdolności predykcyjne. Dla uzyskania dalszej poprawy wyników prognozy w dalszej części pracy przedstawione zostaną inne rozwiązania oparte na sieci samoorganizującej i wyniki badań uzyskane przy ich zastosowaniu.




Rysunek 6. Wykres błędów godzinnych MAPE prognozy przeprowadzonej przy użyciu wyselekcjonowanej sieci MLP dla lat 1996 i 1997

Rysunek 6 przedstawia błędy godzinne prognozy dla lat 1996 i 1997. Z analizy wykresów wynika, że maksymalne błędy zdarzają się stosunkowo rzadko i dotyczą głównie dni świątecznych (Wielkanoc, 3 Maja). Zauważyć można również wzrost wartości błędów względnych w miesiącach o małym obciążeniu (lato) i spadek w miesiącach o obciążeniu dużym (zima).



Rysunek 7. Rozkład błędów przy prognozowaniu 24-godzinnym z wykorzystaniem sieci MLP

Rysunek 7 przedstawia rozkład procentowy błędów prognozy. Prawie 60% stanowią błędy o małej wartości, poniżej 2.5%. Zdecydowana większość (prawie 90%) błędów MAPE ma wartość mniejszą niż 5%.




Rysunek 8. Zestawienie prognoz 24-godzinnych przy zmieniającej się godzinie startowej prognozy

W sieci MLP możliwe jest prognozowanie wielogodzinne startujące z dowolnej godziny dnia. Można więc prognozować obciążenia 24-godzinne dnia D startując z dowolnej godziny np. z 1^{00} , 6^{00} , 18^{00} , itd. Przy takim podejściu składowe prognoz dziennych dokonywane co godzinę powtarzają się 24-krotnie. Dokładność prognozy o określonej godzinie zależy od wielu czynników i niekoniecznie maleje w miarę przybliżania się godziny startowej prognozy do godziny, na którą dokonywane jest prognozowanie.


Przypadek taki ilustruje rysunek 8 pokazujący błędy prognozy na kolejne 24 godziny przy zmieniającej się godzinie startowej. Prostokątem o białym wypełnieniu oznaczona jest wartość błędu MAPE dla godziny 3^{00} wybranego losowo dnia.

Początek osi OX poszczególnych wykresów przesunięty jest względem poprzedniego o 1 godzinę. W związku z tym pozycja pierwsza (zaznaczona białym prostokątem) na ostatnim wykresie odpowiada pozycji 2 w wykresie przedostatnim itp. Dokładności uzyskanej prognozy godzinnej dokonywanej przy różnych godzinach startowych są różne. W rozwiązaniach praktycznych celowe jest określenie godziny początkowej prognozy, dla której uzyskiwany błąd jest jak najmniejszy.



Rysunek 9. Zależność uzyskiwanego błędu prognozy od początkowej godziny prognozy dla sieci MLP w latach 1996 i 1997

Rysunek 9 przedstawia zależność uzyskiwanego błędu prognozy od godziny startowej prognozy dla PSE w latach 1996 i 1997. Okazuje się, że prognozę 24-godzinną w tych latach najlepiej jest obliczać startując z godziny 1⁰⁰. Wyjaśnieniem tego faktu jest stosunkowo duża stabilność obciążenia w godzinach nocnych, stabilizująca prognozę dla pozostałych godzin.



Rysunek 10. Błędy prognozy przypadające na poszczególne dni tygodnia w latach 1996 i 1997

Na rysunku 10 przedstawione jest zestawienie błędów prognozy przypadających na poszczególne dni tygodnia dla danych uczących (rok 1996) i testujących (1997). Dla danych testujących błąd MAPE popełniany przy predykcji obciążenia w dni robocze jest o około 20% mniejszy niż błąd prognozy w niedziele i dni świąteczne. Powodem jest większa względna zmienność obciążenia świątecznego. Najlepszą dokładność prognozy uzyskuje się dla dni w środku tygodnia (wtorek, środa). Błąd popełniany przy prognozie obciążenia w poniedziałki i soboty ma zbliżoną wartość.

4.2. Wyniki prognoz obciążeń PSE przy wykorzystaniu sieci samoorganizującej

Autor pracy przeprowadził szereg eksperymentów numerycznych dotyczących zastosowania sieci samoorganizującej do predykcji krótkoterminowej (24-godzinnej) przy użyciu sieci samoorganizującej typu Kohonena.

Danymi uczącymi były wektory profilowe obciążenia z lat 1995 i 1996. W wyniku uczenia tworzona jest mapa przynależności poszczególnych dni w roku do neuronów sieci (mapa rozkładu klas obciążeń). Prognoza wartości średnich i wariancji obciążenia w poszczególnych dniach roku dokonywana była przy wykorzystaniu perceptronu wielowarstwowego.

4.2.1. Rozwiązanie oparte na wnioskowaniu klasycznym

Po utworzeniu tablic przynależności przeprowadzone zostały obliczenia profili obciążeń w poszczególnych dniach według reguły wnioskowania klasycznego. Tabela 7 przedstawia uzyskane wyniki prognozy profili obciążenia w postaci błędów MAPE i MAX. Ze względu na dużą zmienność przebiegu profili otrzymane rezultaty należy uznać za bardzo dobre. Należy również pamiętać o tym, że prognoza ta obliczana jest na dowolny dzień roku. Mimo stosunkowo dużej wartości występujących sporadycznie błędów maksymalnych (sięgających niemal 50%) wartość błędu MAPE jest niska i zawiera się w granicach do ok. 3.8%.

Kolejnym etapem prognozowania jest obliczenie właściwej prognozy na podstawie predykcji profili oraz estymacji wartości obciążenia średniego (P_m) i wariancji obciążenia (σ^2).

Autor zaproponował i zbadał skuteczność działania pięciu metod prognozy wartości średniej i wariancji obciążenia. Z opisanych w rozprawie metod estymacji P_m i σ^2 wykorzystano wyniki

najskuteczniejszej metody neuronowej, ograniczając się jednocześnie do prognozy na bieżąco (z wyprzedzeniem 24-godzinnym).


Tabela 7. Wyniki predykcji profili obciążenia uzyskane przy użyciu sieci samoorganizującej o wnioskowaniu klasycznym

typ danych	okres prognozy	MAPE [%]	MAX [%]
uczące	1992	3.6543	45.1654
	1993	3.6314	46.9843
	1994	3.7983	47.3567
	1995	3.7577	49.5639
	1996	3.7330	49.2214
	1992-1996	3.7149	49.5639
testujące	1997	3.5430	43.4951
wszystkie	1992-1997	3.6863	49.5939

Tabela 8. Wyniki predykcji obciążeń PSE uzyskane przy użyciu sieci samoorganizującej o wnioskowaniu klasycznym


typ danych	okres prognozy	MAPE [%]	MAE [MW]	MAXP [%]	MAX [MW]
uczące	1992	2.7542	512.07	35.1231	4131.22
	1993	2.6321	501.42	28.7422	3952.73
	1994	2.4572	483.21	27.5727	3900.01
	1995	2.5101	488.19	29.9797	3940.82
	1996	2.7799	515.29	38.1536	3638.16
	1992-1996	2.6267	500.04	38.1536	4131.22
testujące	1997	2.3649	474.04	18.1048	4198.86
wszystkie	1992-1997	2.5831	495.70	38.1536	4198.86

Tabela 8 przedstawia uzyskane wyniki dotyczące właściwego prognozowania obciążeń 24-godzinnych PSE. Błąd MAPE na poziomie 2.36% dla danych testujących z roku 1997 należy uznać za bardzo dobry.




Rysunek 11. Rozkład błędów przy prognozowaniu 24 godzinnym z wykorzystaniem sieci samoorganizującej o wnioskowaniu klasycznym

Przedstawiony na rysunku 11 rozkład procentowy błędów prognozy pokazuje znikomo mały udział błędów prognozy o wartości powyżej 5%.



Rysunek 12. Błędy prognozy wykonanej przy użyciu sieci samoorganizującej o wnioskowaniu klasycznym przypadające na poszczególne dni tygodnia w latach 1996 i 1997

Rysunek 12 przedstawia wykres średnich błędów prognozy obciążenia przypadających na poszczególne dni tygodnia dla roku 1996 i 1997. Dla danych uczących i testujących błędy MAPE w dni robocze są na poziomie 2%, wartość błędu wzrasta do niemal 3% dla sobót i do ponad 5% dla dni świątecznych.



Rysunek 13. Uśrednione błędy prognozy wykonanej przy użyciu sieci samoorganizującej o wnioskowaniu klasycznym przypadające na poszczególne godziny doby

Kolejny rysunek, 13 przedstawia błędy prognozy przypadające na poszczególne godziny doby w ciągu roku. Widać z niego, że prognoza jest bardzo dobra dla godzin, gdzie występują niewielkie zmiany obciążeń (dolina nocna i godziny przedpołudniowe); wzrost błędów obserwuje się w szczycie wieczornym, kiedy następują gwałtowne zmiany obciążenia systemu.

4.2.2. Rozwiązanie oparte na wnioskowaniu rozmytym

Rozwiązanie wykorzystuje wytrenowaną wcześniej sieć samoorganizującą, zastosowaną do prognozowania profili obciążeń przy pomocy wnioskowania klasycznego. Prawidłowość wyboru sieci o tych samych parametrach, trenowanej w taki sam sposób, przy wykorzystaniu tych samych danych uczących i testujących została potwierdzona szeregiem przeprowadzonych eksperymentów numerycznych.

W prognozowaniu wykorzystane zostały utworzone poprzednio tablice przynależności kolejnych dni roku do wszystkich neuronów sieci, na których podstawie obliczono w ten sam sposób co w poprzednim rozwiązaniu, prognozę profili obciążeń.


Tabela 9. Wyniki predykcji profili obciążenia uzyskane przy użyciu sieci samoorganizującej o wnioskowaniu rozmytym

typ danych	okres prognozy	MAPE [%]	MAX [%]
uczące	1992	3.5223	46.3222
	1993	3.5107	46.2317
	1994	3.7012	47.0155
	1995	3.6821	48.8820
	1996	3.6654	48.6482
	1992-1996	3.6163	48.8820
testujące	1997	3.4767	41.9502
wszystkie	1992-1997	3.5931	48.8820

Tabela 10. Wyniki predykcji obciążenia PSE uzyskanej przy użyciu sieci samoorganizującej o wnioskowaniu rozmytym


typ danych	okres prognozy	MAPE [%]	MAE [MW]	MAXP [%]	MAX [MW]
uczące	1992	2.6111	341.22	31.2231	4011.12
	1993	2.4655	333.84	26.0121	3821.44
	1994	2.4310	310.13	23.9722	3700.01
	1995	2.4722	322.72	25.9991	3792.29
	1996	2.7569	420.98	35.6073	4214.49
	1992-1996	2.5473	345.78	35.6073	4214.49
testujące	1997	2.3384	373.08	19.1269	3554.70
wszystkie	1992-1997	2.5125	351.16	35.6073	4214.49

Tabela 9 przedstawia wyniki predykcji profili obciążeń PSE dla poszczególnych lat w postaci błędów MAPE i MAX. Wyniki te są lepsze od uzyskanych przy zastosowaniu wnioskowania klasycznego.



Rysunek 14. Wykres błędów predykcji obciążenia PSE uzyskanej przy użyciu sieci samoorganizującej o wnioskowaniu rozmytym

W tabelicy 10 przedstawiono wyniki predykcji pełnych obciążeń PSE przy wykorzystaniu sieci samoorganizującej o wnioskowaniu rozmytym. Osiągnięty błąd MAPE o wartości 2.34% dla danych testujących należy uznać za bardzo dobry i jest najlepszy ze wszystkich uzyskanych w badaniach. Wartość błędu MAE około 370 MW również świadczy o dobrej dokładności omawianej metody predykcji.



Rysunek 15. Przykłady prognozy wykonanej przy użyciu sieci samoorganizującej o wnioskowaniu rozmytym

Na rys. 15 przedstawiono porównanie profili prognozy 24-godzinnej z wartościami rzeczywistymi dla 4 wybranych dni w roku. Linia ciągła oznacza rzeczywiste obciążenie systemu, a kropkowana prognozę obciążenia wygenerowaną przez sieć neuronową. Należy zauważyć, że nawet w dni, gdy błąd prognozy ma dużą wartość (szczególnie dni świąteczne: Wigilia Bożego Narodzenia, Sylwester itp.) tendencja ogólna prognozy pokrywa się z przebiegiem obciążenia rzeczywistego.

4.3. Analiza porównawcza uzyskanych wyników prognozy

W tabeli 11 przedstawiono porównanie najlepszych uzyskanych wyników krótkoterminowego prognozowania obciążeń na 24 godziny naprzód w Polskim Systemie Elektroenergetycznym w postaci błędów MAPE, MAE, MAXP oraz MAX. Porównanie to prezentowane jest dla roku 1997, będącego wyłącznie rokiem testującym. Wyniki dotyczą prognozowania przy zastosowaniu sieci perceptronowej (MLP), sieci samoorganizującej Kohonena (SOM) oraz sieci samoorganizującej z wnioskowaniem rozmytym (FSOM).


Tabela 11. Porównanie błędów predykcji wykonanej przy użyciu omówionych sieci neuronowych dla roku 1997

typ sieci	MAPE [%]	MAE [MW]	MAXP [%]	MAX [MW]
MLP	2.9924	458.77	29.0896	4456.61
SOM	2.3649	474.04	18.1048	4198.86
FSOM	2.3384	373.08	19.1269	3554.70

Z porównania uzyskanych wyników wynika niezbita przewaga sieci samoorganizujących, zarówno klasycznej Kohonena jak i sieci o wnioskowaniu rozmytym, nad siecią perceptronową. Różnica 0.6% (błąd MAPE) w stosunku do poziomu 2.33% dla sieci FSOM oznacza ponad 25% względną przewagę najlepszego rozwiązania nad najslabszym. Rozwiązanie bazujące na samoorganizacji neuronów stosuje rozbitcie prognozy na 3 etapy: predykcja 24-godzinne go profilu obciążenia oraz wartości średniej i wariacji dla danego dnia. Taka metodyka postępowania uniezależnia w dużej mierze prognozę od ogólnego trendu. Wynikiem było znaczne zwiększenie dokładności prognozy. Próba zastosowania podobnej techniki prognozowania w odniesieniu do perceptronu wielowarstwowego nie pozwoliła jednak na polepszenie otrzymanych rezultatów.

Najbardziej istotnym wskaźnikiem mówiącym o przydatności prognozy w praktyce jest wartość błędu MAPE. Uzyskane przez autora rozprawy wartości 2.99% dla sieci perceptronowej i 2.34% dla najlepszej sieci samoorganizującej należy uznać za bardzo dobre.


Maksymalne błędy procentowe prognozy dla sieci perceptronowej sięgają wartości około 29%. Wartości błędów maksymalnych dla sieci samoorganizujących są jeszcze mniejsze i pozostają na poziomie 18-19%. Są to zwykle krótkotrwałe przekłamania, które w sposób istotny nie wpływają na ogólną wartość błędu MAPE. Źródła tych przekłamań mogą być różne: załamania pogodowe, gwałtowne zmiany zapotrzebowania na energię spowodowane nieoczekiwanymi wydarzeniami itp.



Rysunek 16. Porównanie prognozy przeprowadzonej przy użyciu metod omówionych w rozprawie w wybranych, charakterystycznych dniach w roku.

Oznaczenia linii: obciążenie rzeczywiste – linia ciągła, charakterystyki wygenerowane przez sieci: MLP – przerywana z kropkami, SOM – przerywana, FSOM – kropkowana

Na rys. 16 przedstawiono porównanie prognozy 24-godzinnej obliczonej przy użyciu metod omówionych w rozprawie dla wybranych 4 dni należących do testującej bazy danych. Pokazane są rzeczywiste 24-godzinne charakterystyki profilowe obciążenia PSE w wybranych dniach (linia ciągła) oraz przewidywane charakterystyki obliczone przy użyciu sieci perceptronowej (linia przerywana z kropkami), sieci samoorganizujących z wnioskowaniem klasycznym (przerywana) oraz rozmytym (linia kropkowana).



Rysunek 17. Porównanie wartości błędu MAPE i MAXP w poszczególnych latach dla badanych sieci neuronowych

Należy zauważyć, że generowane charakterystyki, dla każdego dnia prognozy, zachowują kształt oryginalnego obciążenia, różniąc się zwykle nieznacznie wartościami obciążenia szczególnie w godzinach o największych poziomach obciążenia (szczyty obciążeń) i w porach gwałtownych zmian obciążenia. Dla dni świątecznych o nietypowych charakterystykach obciążenia można zauważyć nieco większą rozbieżność charakterystyk obliczonych z rzeczywistymi.

Często rozbieżności te powodowane są jedynie obciążeniem estymatora dla tych dni i wydają się być łatwe do skorygowania. Na rysunkach trudno jest odnaleźć różnice w charakterystykach

generowanych przez obie sieci samoorganizujące, choć istnieją one i w sensie wartości statystycznych przedstawione były w tabeli 11.

Rysunek 17 przedstawia graficzne zestawienie wartości błędów MAPE i MAXP dla poszczególnych lat prognozy. W każdym roku widoczna jest znaczna przewaga skuteczności sieci samoorganizujących nad siecią perceptronową.

Na tle przedstawionych tu wyników szczególnie pozytywnie przedstawia się prognoza dotycząca roku 1997. Dla wszystkich rodzajów sieci błąd średni przyjmuje wartość najmniejszą, pomimo, że dane dotyczące tego roku były wyłączone z uczenia. Niższy poziom błędów dla roku 1997 wynikał z większego udziału w tym roku dni o stabilnych, typowych charakterystykach obciążenia, co mogło być spowodowane zarówno zachodzącą stabilizacją zmian gospodarczych kraju w tym roku, jak również (być może) łagodniejszą, bez gwałtownych załamań pogodowych, zimą.

5. Wnioski końcowe

Proces prognozowania obciążeń godzinnych systemu elektroenergetycznego stanowi niełatwe zadanie predykcji szeregów czasowych. Jak zostało pokazane w rozdziale drugim poprzez analizę statystyczną danych z przeszłości, zmienność obciążenia z godziny na godzinę może być bardzo duża i podlegać wahaniom w sposób stochastyczny w zależności od zmienności pogody lub innych czynników. Charakter zmienności obciążenia jest poza tym uzależniony w sposób trudny do uwzględnienia w modelowaniu, od wielu innych elementów, stanowiących o specyfice obciążenia systemu (pora dnia, pora roku, typ dnia, warunki pogodowe, stopień rozwoju kraju, itp.). Niektóre z tych czynników, np. związane z gwałtownymi załamaniami pogody są typu losowego, niemożliwego do przewidzenia z góry.

Złożoność problemu powoduje, że atrakcyjne stają się metody modelowania typu „black box”, w których rezygnuje się z dokładnej analizy wpływu poszczególnych czynników, zastępując je poprzez model uniwersalny podejmujący decyzję prognostyczną na podstawie statystycznych cech procesu, uznanych za najważniejsze dla prognozy.

Takim narzędziem zastosowanym w pracy są sztuczne sieci neuronowe, w szczególności sieć perceptronu wielowarstwowego oraz sieć samoorganizująca Kohonena. W pierwszym przypadku wykorzystuje się bezpośrednio cechy dobrego aproksymatora globalnego jakim jest perceptron wielowarstwowy. W drugim korzysta się z własności grupowania danych przez sieć samoorganizującą. Oba rozwiązania różnią się zasadniczo między sobą zarówno co do struktury sieci, metod uczenia jak i metodyki zastosowanej w prognozowaniu. Wyniki badań uzyskane przy pomocy obu rodzajów sieci neuronowych, przedstawione w rozdziale piątym są zadawalające. Błąd MAPE prognozy w skali kraju niewiele przewyższa 2%. Błędy maksymalne, popełniane zwykle dla niewielkiej liczby danych, są również mocno ograniczone (poniżej 20%).

Interesujący jest fakt, że najlepsze wyniki prognozy otrzymuje się przy zastosowaniu stosunkowo mało znanej i rzadko stosowanej w prognozowaniu sieci o samoorganizacji rozmytej, stanowiącej oryginalny dorobek autora rozprawy. Przewyższa ona w sposób znaczący najbardziej popularną sieć perceptronową pod względem uzyskanych dokładności prognozy zarówno w sensie błędu MAPE jak i błędu maksymalnego.

Bogate wyniki badań symulacyjnych, przeprowadzonych przez autora rozprawy w sposób wszechstronny i obiektywny przedstawiły możliwości predycyjne sieci neuronowych oraz ich ograniczenia. Prezentując zalety omawianych rozwiązań, nie należy jednocześnie umniejszać znaczenia klasycznych, sprawdzonych już w praktyce, sposobów prognozowania. Zdaniem autora rozprawy oba podejścia są komplementarne i należy postrzegać je raczej jako uzupełniające się, a nie wykluczające się wzajemnie.

Wydaje się, że jakkolwiek w pracy ograniczono się do prognozy obciążeń dla całego systemu elektroenergetycznego kraju, opracowane metody mogą być z powodzeniem zaadoptowane do potrzeb prognozowania obciążeń na poziomie okręgu lub zakładu energetycznego. Model systemu

jest uniwersalny i jednocześnie otwarty na inne cechy procesu, takie jak na przykład temperatura, zachmurzenie, układ frontów atmosferycznych, wiatr, które z powodzeniem mogą być uwzględnione dla małego obszaru kraju. Co więcej, biorąc pod uwagę możliwość uwzględnienia dodatkowych czynników wpływających na prognozę, można spodziewać się polepszenia jej wyników. Ze względu na niedostępność danych liczbowych dla małego obszaru kraju, nie było możliwe przeprowadzenie tego typu badań.

Badania symulacyjne przeprowadzone w pracy dotyczyły prognozy krótkoterminowej z wyprzedzeniem 24-godzinnym. Należy jednak zauważyć, że najlepsza z prezentowanych metod, wykorzystująca sieć samoorganizującą, jest metodą ogólną, dopuszczającą prognozę z dowolnym wyprzedzeniem czasowym (np. tygodniowym, miesięcznym, rocznym itp.). Prognoza profili w tej metodzie nie zależy w ogóle od daty prognozy. Jedyne wartości średnia i wariancja są uzależnione od powiązań z najbliższą przeszłością, stąd przy prognozowaniu z dużym wyprzedzeniem czasowym należy się liczyć z nieco zwiększonym błędem prognozy.

Dane jakimi dysponował autor pracy nie zawierają wskaźników temperaturowych, gdyż zmienność temperatury na obszarze kraju jest znaczna, zwłaszcza zimą. Są one w sposób niejawni zawarte w rozkładzie obciążeń godzinnych. Wydaje się, że odzwierciedlenie temperatur poprzez aktualny rozkład obciążeń jest dobre jedynie w stanach stacjonarnych, gdy zmiany temperatur są małe i powolne. W przypadku gwałtownych zmian inercja wnoszona przez uzależnienie predykcji od poprzednich stanów (z poprzednich godzin i dni) nie pozwala na szybką zmianę prognozy, w efekcie czego mogą powstać znaczne błędy chwilowe. Wprowadzenie dodatkowej cechy uwzględnianej w prognozowaniu dotyczącej aktualnej pogody (temperatury bądź informacji o zachmurzeniu) mogłoby, zdaniem autora, zmniejszyć wartości maksymalne błędów, zwłaszcza w okresach trudnych dla prognozowania, a więc jesienią i zimą.

Za najważniejsze osiągnięcia w pracy autor uważa:

- Opracowanie oryginalnej i efektywnej metody neuronowej predykcji szeregów czasowych, z zastosowaniem do krótkoterminowej prognozy obciążeń w systemie elektroenergetycznym.
- Opracowanie koncepcji (i jej implementację w postaci programów komputerowych) krótkoterminowego prognozowania obciążeń SEE przy wykorzystaniu preceptronu wielowarstwowego i sieci samoorganizujących Kohonena (z wnioskowaniem klasycznym i rozmytym).
- Twórczą analizę statystyczną obciążeń PSE, prowadzącą do selekcji najbardziej istotnych z punktu widzenia prognozowania cech procesu.
- Wybór optymalnych struktur sieci neuronowych oraz postaci wektorów wejściowych (cech procesu) najlepiej realizujących zadanie prognozowania obciążeń w PSE.
- Przeprowadzenie ogromnej liczby eksperymentów numerycznych testujących proponowane metody prognozy i porównanie ich ze sobą. Wynikiem analizy porównawczej jest potwierdzenie skuteczności działania sieci neuronowych w prognozowaniu obciążeń.