

**Prace
Instytut Ekonometrii**

MICHAŁ BERNARDELLI

**ZASTOSOWANIE SIECI NEURONOWYCH
DO PROGNOZOWANIA CEN ENERGII NA
PODSTAWIE RYNKU BILANSOWEGO
ENERGII**

Opracowanie w ramach badania własnego
Nr badania: 03/E/0012/10

Kierownik badania:
Michał Bernardelli

**Szkoła Główna Handlowa
Kolegium Analiz Ekonomicznych
Warszawa 2010**



Spis treści

1	Wprowadzenie	3
2	Rynek energii elektrycznej w Polsce	4
2.1	Rynek Bilansujący (RB)	5
2.2	Cena rozliczeniowa odchylenia (CRO)	6
2.3	Wstępny plan koordynacyjny dobowy (WPKD)	9
3	Sieci neuronowe	11
3.1	Konstrukcja sztucznej sieci neuronowej	11
3.2	Zastosowania sztucznych sieci neuronowych	16
4	Prognoza CRO z użyciem sieci neuronowych	17
4.1	Opis algorytmów	17
4.2	Prognoza i analiza błędów	19
4.3	Porównanie algorytmów	22
	Spis literatury	26

Streszczenie

Część istniejących algorytmów prognozowania ze względu na olbrzymią ilość danych jest mało efektywnych pod względem czasowym, inne poprzez ograniczenie liczby danych wejściowych są mało dokładne. Celem badania było zastosowanie alternatywnych algorytmów prognozowania oraz porównanie ich działania z aktualnie dostępnymi algorytmami obliczającymi cenę rozliczeniową odchylenia. Oprócz implementacji zaprojektowanych algorytmów, integralną częścią badania była analiza ekonometryczna wyników uzyskanych na podstawie danych historycznych udostępnianych przez Operatora Systemu Przemysłowego.

Wyniki przeprowadzonych symulacji numerycznych okazały się bardzo obiecujące, gdyż uzyskano prognozy porównywalne jakościowo z jakością prognoz algorytmów opartych na modelach SARIMA oraz wykorzystujących oferty bilansujące. Istotną zaletą okazał się być czas działania przedstawionych algorytmów operujących na sieciach neuronowych. Był on kilka rzędów wielkości lepszy od najszybszych opisanych do tej pory algorytmów.

1 Wprowadzenie

Rynek Bilansujący (RB) jest rynkowym mechanizmem służącym do bieżącego bilansowania zapotrzebowania na energię elektryczną i wytwarzania tej energii w Krajowym Systemie Elektroenergetycznym (KSE). Operator Systemu Przemysłowego (OSP) administrując RB na podstawie składanych przez użytkowników ofert wyznacza Cenę Rozliczeniową Odchylenia (CRO). Udostępniane są dane dotyczące cen i ilości energii na RB w granulacji godzinowej. Ze względu na specyfikę rynku elektrycznego, związaną m.in. z trudnościami z magazynowaniem energii elektrycznej, mamy do czynienia z dużą dynamiką szeregów CRO. Jest ona trudna do przewidzenia nawet w okresie krótkoterminowym. Dokładniejsze prognozy na podstawie danych historycznych pozwalają na określenie lepszej strategii działania z punktu widzenia użytkowników RB.

Zadanie prognozowania zapotrzebowania energii elektrycznej zostało dość dobrze zbadane i opisane w literaturze. Stosunkowo mało jednak dostępnych jest materiałów na temat prognozowania cen energii elektrycznej na Rynku Bilansującym. Związane jest to z pewnością z faktem, iż rozpoczęta pod koniec ubiegłego stulecia transformacja na rynku energii elektrycznej w Polsce wciąż trwa, a zasady obowiązujące w systemie elektroenergetycznym są stale modyfikowane. Opisane do tej pory w literaturze algorytmy prognozowania CRO wymagają dużej mocy obliczeniowej. Relatywnie długi czas obliczeń i wyniki o średnim względnym błędzie na poziomie 8% (patrz [1]) świadczą o potrzebie dalszych badań w tym zakresie. W pracy przedstawione są alternatywne algorytmy prognozowania CRO oparte na sieciach neuronowych. Symulacje numeryczne pokazują, iż algorytmy te działają z porównywalną do istniejących algorytmów dokładnością, ale szybkość ich działania jest niewspółmiernie lepsza.

W rozdziale drugim omówiona została ogólna struktura rynku energii elektrycznej w Polsce, ze szczególnym uwzględnieniem roli Rynku Bilansującego. Przedstawione zostały w nim również definicje i opisy podstawowych z punktu widzenia konstruowanych algorytmów pojęć, takich jak cena rozliczeniowa odchylenia czy wstępny plan koordynacyjny dobowy. Rozdział trzeci poświęcony jest krótkiemu omówieniu sztucznych sieci neuronowych i ich najpowszechniejszych zastosowań. W ostatnim, czwartym rozdziale przedstawiona została konstrukcja algorytmów prognozowania opartych na sieciach neuronowych oraz wyniki i analiza przeprowadzonych eksperymentów nu-

merycznych, wraz z porównaniem z dostępnymi w literaturze ([1] i [2]) algorytmami prognozowania CRO.

2 Rynek energii elektrycznej w Polsce

Energia elektryczna stanowi podstawowy towar na rynkach współczesnego świata. Charakteryzuje się ona szeregiem czynników niespotykanych w innych dostępnych na rynkach produktach. Przede wszystkim magazynowanie energii elektrycznej jest na tyle trudne i nieopłacalne, iż w praktyce można przyjąć, iż nie ma takiej możliwości. Oznacza to, że w każdym momencie ilość wytwarzanej energii musi być równa ilości energii zużywanej. Wymaga to bardzo rozbudowanej i efektywnej sieci linii oraz stacji elektroenergetycznych. Ogół urządzeń w Polsce służących do wytwarzania, przesyłu i rozdziału energii elektrycznej nazywany jest *Krajowym Systemem Elektroenergetycznym* (KSE). Sieci przesyłowe najwyższych napięć w Polsce, wchodzące w skład KSE, należą i są nadzorowane przez *Polskie Sieci Elektroenergetyczne Operator S.A.*, zwane dalej *Operatorem Systemu Przesyłowego* – w skrócie OSP. Głównym zadaniem OSP jest świadczenie usług przesyłania energii elektrycznej, przy zachowaniu wymaganych kryteriów bezpieczeństwa pracy Krajowego Systemu Elektroenergetycznego.

Podstawowym założeniem współczesnego rynku energii elektrycznej w Polsce jest oddzielenie dostaw energii od samej energii jako produktu. Takie podejście umożliwia osobną wycenę produktu i usługi jego dostarczenia, a w konsekwencji wprowadzenie zasad konkurencji zarówno w obszarze produkcji, jak i dystrybucji energii, przy jednoczesnym zachowaniu kontroli państwa zapewniającej niezawodne działanie Krajowego Systemu Elektroenergetycznego. Rozpoczęta w 1997 roku w Polsce transformacja rynku energii elektrycznej wprowadziła model, który należy do grupy modeli zdecentralizowanych i opiera się na trzech segmentach (patrz [6]):

1. *kontraktowym*, w którym obrotu dokonuje się w formie kontraktów dwustronnych zawieranych bezpośrednio między dostawcą i odbiorcą,
2. *giełdowym*, w którym obrót następuje w formie transakcji i kontraktów zawieranych na giełdzie energii lub za jej pośrednictwem oraz przy pomocy operatorów handlowo-technicznych,

3. *bilansującym*, w którym operator systemu przesyłowego bilansuje różnicę pomiędzy podażą a bieżącym popytem na energię elektryczną, korzystając z ofert bilansujących.

Uczestnictwo w dwóch pierwszych segmentach jest nieobowiązkowe, natomiast udział w segmencie trzecim jest obligatoryjny. Obowiązek ten uzasadniony jest koniecznością rozliczenia różnicy pomiędzy wielkością energii elektrycznej faktycznie sprzedanej lub pobranej a wielkością zakontraktowaną przez uczestników rynku. Dokładne prognozowanie rzeczywistego zapotrzebowania na energię elektryczną z uwzględnieniem dużej zmienności tej wielkości, strat energii, awarii i usterek KSE oraz szeregu innych czynników, jest praktycznie niemożliwe. Stąd transakcje zawarte w ramach segmentu kontraktowego lub giełdowego muszą zostać finalnie rozliczone poprzez segment bilansujący, to jest na *Rynku Bilansującym* (w skrócie RB).

2.1 Rynek Bilansujący (RB)

Operator Systemu Przesyłowego zarządza Rynkiem Bilansującym Energii w sposób zapewniający równoprawne traktowanie wszystkich uczestników rynku. W ramach RB rozliczane są niezbilansowania wynikające z różnicy pomiędzy ilością energii z przyjętych do realizacji kontraktów oraz rzeczywistą ilością dostarczonej energii. Rozliczenia te są z oczywistych względów wykonywane z opóźnieniem. OSP w ramach obowiązujących w Polsce przepisów (patrz [4]) obliguje uczestników do zakupu niedoboru lub do sprzedaży nadwyżki energii na RB. Cena za wytwarzanie energii elektrycznej (CO, porównaj [4, str. 139]) jest określana dla poszczególnych pasm wytwarzania i przesyłu energii elektrycznej dla każdej z dwudziestu czterech godzin doby. Istnieje wiele różnych cen stosowanych w zależności od zaistniałej sytuacji, np. cena rozliczeniowa sprzedaży energii z rynku bilansującego (CRO_S), cena rozliczeniowa zakupu energii na rynek bilansujący (CRO_Z) czy cena rozliczeniowa awarii (CRA). Kluczową rolę pełni jednak *cena rozliczeniowa odchylenia* (CRO). Jest ona ustalana na podstawie ofert bilansujących składanych przez uczestników RB. Dokładniejszy opis ofert bilansujących oraz mechanizmu ustalania CRO przedstawiony jest w następnym podrozdziale.

Operator Systemu Przemysłowego z założenia ma być zarządcą Krajowego Systemu Elektroenergetycznego, a Rynku Bilansującego w szczególności. Aby zapewnić

uczestnikom sprawiedliwy dostęp do RB oraz równe na nim prawa, OSP zobowiązane jest do publikowania informacji o funkcjonowaniu RB. Do udostępnianych na stronach OSP, a mianowicie *www.pse-operator.pl*, danych należą między innymi zapotrzebowanie mocy KSE, informacje o cenach i produkcji energii, a nawet całe oferty bilansujące. Na ich podstawie uczestnicy RB mogą prognozować wielkości potrzebne im do podjęcia optymalnych z ich punktu widzenia działań na RB.


2.2 Cena rozliczeniowa odchylenia (CRO)

Ceną, po której uczestnicy RB są zobligowani do dokonania zakupu lub sprzedaży energii w przypadku złego zbilansowania transakcji w segmentach kontraktowym i giełdowym, nazywa się ceną rozliczeniową odchylenia. CRO jest najwyższą ceną oferty bilansującej, która zapewnia zbilansowanie KSE zgodne z planowanym na daną godzinę zapotrzebowaniem energetycznym. OSP publikuje na swoich stronach archiwalne dane CRO. Dane o granulacji godzinowej udostępniane są z dwudniowym opóźnieniem, czyli w konkretnym dniu dostępne są z przedwczoraj i dni wcześniejszych. Przykładowy godzinowy szereg CRO przedstawiony jest na rysunku 1, natomiast dobowy raport z funkcjonowania Krajowego Systemu Elektroenergetycznego i Rynku Bilansującego przedstawiający ceny rozliczeniowe na dzień 1 października 2010r. podany jest w tabeli 1. Poniżej przedstawione są użyte w tabeli skróty:

- CRR – cena rozliczeniowa energii elektrycznej dostępnej w ramach operacyjnej rezerwy mocy,
- CRO – cena rozliczeniowa odchylenia,
- CROs – cena rozliczeniowa odchylenia sprzedaży,
- CROz – cena rozliczeniowa odchylenia zakupu.

Oferty bilansujące, na podstawie których ustalana jest CRO, zgłaszane są przez uczestników RB w danym dniu na każdą godzinę dnia następnego. Oferta taka składa się z par liczb: OFC i OFE, gdzie:

- OFC – cena ofertowa dla pasma podawana w zł/MWh,



Rysunek 1: Godzinowy szereg CRO w okresie od 15 lutego 2009r. do 15 czerwca 2009r. na podstawie danych ze strony OSP.

- OFE - moc netto oferowana w paśmie podawana w MW.

Cena ofertowa nie może być mniejsza od 70zł/MWh i nie może być większa od 1500zł/MWh (patrz [4, str. 91]). Przykładowy fragment oferty bilansowej przedstawiony jest w tabeli 2.

Mechanizm ustalenia CRO na podstawie ofert bilansowych na daną godzinę polega na uszeregowaniu pasma ofert według ich cen: od najmniejszej do największej, a następnie na wybraniu najwyższej takiej ceny ofertowej, która zapewni zbilansowanie planowanego popytu i podaży energii elektrycznej. Przykład krzywej ofertowej i wyznaczania na jej podstawie ceny rozliczeniowej odchylenia podany jest na rysunku 2.

Godzina	CRR [zł/MWh]	CRO [zł/MWh]	CROs [zł/MWh]	CROz [zł/MWh]
1	186,33	180,00	180,00	180,00
2	185,73	180,43	180,43	180,43
3	185,53	180,67	180,67	180,67
4	185,53	160,00	160,00	160,00
5	185,53	160,00	160,00	160,00
6	189,00	185,53	185,53	185,53
7	213,00	198,36	198,36	198,36
8	400,00	199,89	199,89	199,89
9	406,67	216,00	216,00	216,00
10	413,33	225,83	225,83	225,83
11	413,33	253,61	253,61	253,61
12	413,33	235,83	235,83	235,83
13	413,33	233,33	233,33	233,33
14	413,33	223,33	223,33	223,33
15	406,67	214,33	214,33	214,33
16	406,67	214,00	214,00	214,00
17	406,67	210,00	210,00	210,00
18	420,00	205,39	205,39	205,39
19	420,00	211,83	211,83	211,83
20	406,67	253,61	253,61	253,61
21	297,43	213,89	213,89	213,89
22	217,00	195,33	195,33	195,33
23	210,11	195,33	195,33	195,33
24	196,87	180,00	180,00	180,00

Tablica 1: Dobowy raport z funkcjonowania Krajowego Systemu Elektroenergetycznego i Rynku Bilansującego przedstawiający ceny rozliczeniowe na dzień 1 października 2010r. na podstawie danych ze strony OSP.

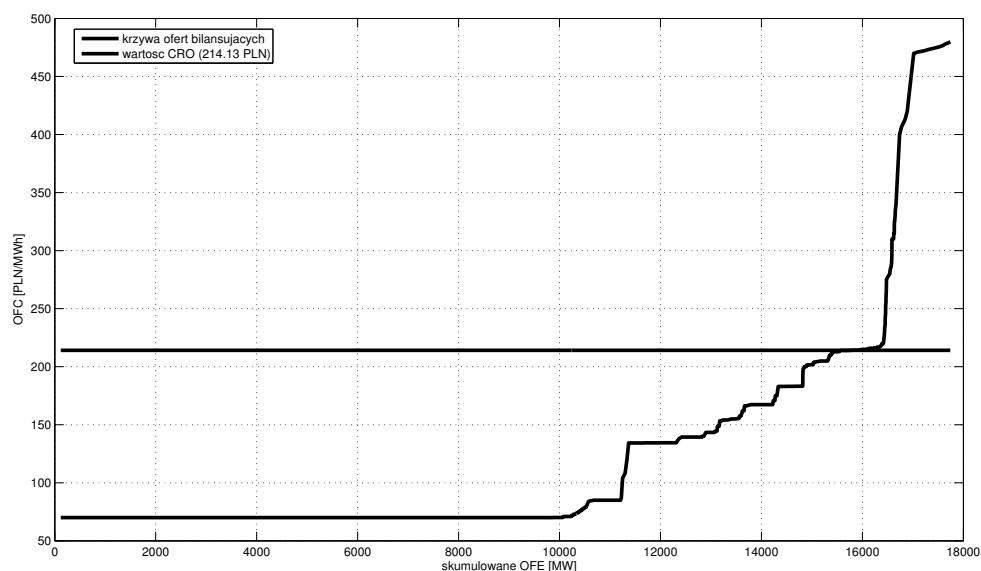
OFC [zł/MWh]	OFE [MW]
183,20	36,000
190,00	2,000
193,00	1,000
193,85	1,000
197,69	2,000
200,20	31,000
200,20	38,000
201,33	2,000
201,54	1,000
201,89	131,000
203,00	1,000
203,89	6,000
204,89	140,000

Tablica 2: Fragment oferty bilansującej złożonej na godzinę 15 dnia 1.10.2010r. na podstawie danych ze strony OSP.

2.3 Wstępny plan koordynacyjny dobowy (WPKD)

W ramach dobowych raportów z funkcjonowania Krajowego Systemu Elektroenergetycznego i Rynku Bilansującego Operator Systemu Przemysłowego publikuje również szereg innych wielkości, m.in.

- zapotrzebowanie mocy KSE w granulacji co 15 minut; dostępne są dane archiwalne z dwudniowym opóźnieniem,
- *Plan Koordynacyjny Dobowy* (PKD) w granulacji godzinowej; zawiera prognozę zapotrzebowania na moc KSE na następny dzień,
- *Wstępny Plan Koordynacyjny Dobowy* (WPKD) w granulacji godzinowej; zawiera prognozę zapotrzebowania na moc KSE na dwie doby naprzód,
- *Bilans Techniczno Handlowy Dobowy* (BTHD) w granulacji godzinowej; zawiera



Rysunek 2: Pasma ofert bilansujących na godzinę 15 dnia 1.10.2010r. wraz z wyznaczoną CRO na podstawie danych ze strony OSP.

prognozę zapotrzebowania na moc KSE na 3, 4, 5, 6, 7, 8 i 9 dób naprzód.

Z punktu widzenia prognozowania CRO szczególnie istotny jest szereg WPKD, gdyż dane obu tych szeregów udostępniane w tym samym czasie przez OSP dotyczą tego samego przedziału czasowego. Szczegółową analizę szeregu CRO można znaleźć w pracy [1]. W pracy tej wykorzystano także ścisłą zależność szeregów CRO i WPKD do budowy algorytmów prognozowania CRO. Podstawową zaletą wykorzystania szeregu WPKD jest automatyczne uwzględnienie w prognozie zapotrzebowania na moc KSE planowych świąt, dłuższych weekendów lecz również innych sytuacji, w których występuje uzasadnione podejrzenie odstępstwa od sezonowej i okresowej struktury szeregu WPKD. Takie zaburzenia mają bezpośrednie przełożenie na wartości szeregu CRO, stąd zasadnym wydaje się włączenie do prognozowania cen rozliczeniowych odchylenia nie tylko szeregu CRO, lecz także szeregu WPKD.

3 Sieci neuronowe

Sztuczne sieci neuronowe stanowią próbę symulacji działania ludzkiego mózgu. Podstawową jednostką biologicznego układu nerwowego jest neuron. Ludzki rdzeń kręgowy składa się przeciętnie z miliarda neuronów¹, natomiast mózg ludzki średnio ze stu miliardów neuronów². Neurony są ze sobą połączone za pomocą tak zwanych synaps, a przesyłanie informacji polega na pobieraniu impulsów od jednych neuronów i przekazaniu ich dalej poprzez wypustki zwane aksonami.

Sztuczne neurony są logicznymi odpowiednikami biologicznych neuronów. Rolę synaps, które decydują o sile połączenia, odgrywają liczby zwane wagami połączenia. Każdy neuron pobiera sygnały od wszystkich połączonych z nim neuronów, przemnaża przez odpowiednie wagi, otrzymane wartości sumuje, a uzyskaną wartość przekształca odpowiednią funkcją (tak zwaną *funkcją aktywacji*), po czym nadaje sygnał wyjściowy. Poprzez ustawienie neuronów w konkretną strukturę otrzymujemy sztuczną sieć neuronową. Najczęściej stosuje się sieci warstwowe, tak zwane perceptrony. Są to sieci, w których neurony podzielone są na warstwy, przy czym każdy neuron jest połączony ze wszystkimi neuronami z warstwy poprzedniej. Pierwsza warstwa nazywana jest warstwą *wejściową*, ostatnia – *wyjściową*, a pozostałe – warstwami *ukrytymi*. Schemat przykładowej sieci warstwowej pokazany jest na rysunku 3. Liczba warstw ukrytych może być dowolna, ale zwiększenie liczby warstw wpływa wydatnie na spadek szybkości działania sieci i związany z tym wzrost czasu obliczeń.

3.1 Konstrukcja sztucznej sieci neuronowej


Podczas konstrukcji sztucznej sieci neuronowej można wydzielić następujące etapy:

Etap I

Wybór struktury sieci neuronowej, to jest określenie liczby warstw, liczby neuronów w każdej warstwie oraz postać funkcji aktywacji.

¹Za J. W. Kalat – *Biological Psychology*, 6th Edition, 1998r., str. 24

²Za R. W. Williams, K. Herrup – *The Annual Review of Neuroscience* 11, 1988r., str. 423-453; ostatnia korekta z 28 września 2001r.



Rysunek 3: Schemat budowy przykładowej trzywarstwowej sztucznej sieci neuronowej.

Etap II

Dobór parametrów uczenia sieci neuronowej, takich jak liczba epok, dopuszczalny błąd czy krok uczenia.

Etap III

Wybór metody uczenia sieci neuronowej wraz z przeprowadzeniem samego procesu uczenia się na podstawie odpowiednio dobranych danych treningowych.

Etap IV

Sprawdzenie działania sieci neuronowej na odpowiednio dobranych danych testowych.

Każdy z wymienionych etapów jest istotny i nie można go pominąć. Poniżej przedstawiona jest krótka charakterystyka poszczególnych etapów. Dokładniejszych informacji na temat konstruowania i działania sztucznych sieci neuronowych można się dowiedzieć z wielu dostępnych książek czy publikacji, w szczególności z [7].

Etap I

Ze względu na czas działania pożądanym jest aby sieć miała jak najmniej warstw oraz neuronów w każdej warstwie. Z drugiej strony zwiększenie liczby neuronów lub warstw może wpłynąć pozytywnie na efektywność sieci. Odpowiednie zbalansowanie tych dwóch wykluczających się rzeczy jest niezwykle trudne do uzyskania, ale w praktyce rzadko spotyka się sieci mające więcej niż dwie warstwy ukryte.

Przy projektowaniu sieci trzeba również wziąć pod uwagę czy badane zagadnienie jest liniowe, czy też nosi cechy nieliniowości. Wiąże się z tym wybór odpowiedniej funkcji aktywacji. Funkcja ta, przekształcająca w każdym z neuronów wyliczoną sumę na sygnał końcowy, może być bowiem funkcją liniową, skokową, ale również sigmoidalną lub tangesoidalną. Jej wybór zależy od projektanta sieci i zależy od problemu, który ma ona rozwiązać. Dla problemów liniowych odpowiednia jest liniowa funkcja aktywacji – w programie Matlab nazwana *purelin*. Dla problemów nieliniowych dobór funkcji aktywacji uzależniony jest między innymi od obszaru zmienności analizowanych danych wejściowych. Jeżeli badane wartości są dodatnie, to dobrym rozwiązaniem jest na ogół funkcja sigmoidalna (*logsig* w programie Matlab), dla danych przyjmujących również wartości ujemne lepszy pomysłem na ogół okazuje się tangens hiperboliczny (w Matlab oznaczany przez *tansig*). Funkcję aktywacji dobiera się osobno dla każdej warstwy neuronów. Nieodpowiedni jej wybór może powodować problemy z uczeniem się sieci³ oraz jej dobrym działaniem na danych faktycznych, wyraźnie różnych od danych treningowych.

Etap II

Konstrukcja sztucznej sieci neuronowej wymaga doboru szeregu parametrów istotnych z punktu widzenia umiejętności uczenia się. Do podstawowych parametrów należą:

- *Liczba epok*, czyli liczba iteracji, w których optymalizowane są wagi sieci. Zbyt mała liczba epok implikuje niewystarczający czas do nauczenia się poprawnego rozwiązywania problemu, natomiast zbyt duża liczba może oznaczać, że sieć stanie się zbyt wrażliwa i zacznie interpretować (niepoprawnie) nawet niewielkie zaburzenia danych. Dodatkowo liczba epok ma bezpośredni związek z czasem uczenia się. Zwykle można empirycznie wyznaczyć moment, począwszy od któ-

³A dokładniej ze zbieżnością algorytmów uczących.

rego następuje już niewielka poprawa w uczeniu się lub nawet jej brak.

- *Dopuszczalny błąd sieci* najczęściej wyrażony w postaci średniego błędu kwadratowego (MSE). Jest to wartość, po osiągnięciu której algorytm uczenia sieci przerywa uczenie przyjmując, iż sieć została poprawnie wytrenowana na dostarczonych do nauki danych. Często sieć nie jest w stanie, nawet mimo znacznego zwiększenia liczby epok, osiągnąć zadanego poziomu błędu. Można wówczas użyć innego algorytmu uczenia lub zmienić całą strukturę sieci neuronowej. Należy jednak pamiętać, iż zbyt rygorystycznie określony dopuszczalny błąd sieci może nie zostać osiągnięty dla żadnej sieci neuronowej. Po prostu takie podejście do rozwiązania rozpatrywanego problemu może nie być właściwe, albo żądanie tak dużej dokładności rozwiązania mało realistyczne.
- *Krok uczenia się sieci* jest wielkością zmian wag neuronów w każdym kolejnym kroku uczenia. Wybór zbyt dużego kroku może spowodować problemy z uczeniem się sieci, a krok zbyt mały powodować wydłużenie czasu obliczeń oraz jej nadwrażliwość.
- *Czas uczenia się* uzależniony jest od liczby warstw sieci, liczby neuronów w każdej z warstw oraz od ilości danych treningowych. Może on rosnać nawet wykładniczo względem wymienionych parametrów. Dobór odpowiedniego algorytmu uczącego oraz stosowne wypośrodkowanie pomiędzy dokładnością uzyskanych rozwiązań oraz czasem uczenia się sieci jest kluczowe z punktu widzenia sensowności stosowania sztucznej sieci neuronowej do rozwiązania danego problemu. W ekstremalnych przypadkach może się bowiem okazać, że czas działania sieci przekracza limit czasowy wyznaczony na uzyskanie rozwiązania.

Etap III

Nauka sieci na podstawie danego zbioru danych treningowych sprowadza się do zastosowania jednego z wielu dostępnych algorytmów zmieniających w określony sposób poszczególne wagi połączeń między neuronami. Zwykle stosowane są metody optymalizacyjne lub estymacji statystycznej. Większość znanych algorytmów minimalizuje błąd średniokwadratowy i opiera się w mniejszym lub większym stopniu na metodach

gradientowych (patrz np. [3]). Metody te charakteryzują się stosunkowo dużą szybkością działania, wysoką skutecznością oraz niewielkim kosztem pamięciowym. Lista wielu stosowanych algorytmów uczenia sieci neuronowych wraz z opisami dostępna jest w dokumentacji *Neural Network Toolbox*, będącym dodatkiem do programu *Matlab & Simulink* firmy MathWorks. Dokumentacja dostępna jest również on-line na stronie *www.mathworks.com*.

Jednym z najpopularniejszych i jednocześnie najbardziej skutecznych algorytmów uczenia sieci jest *algorytm wstecznej propagacji błędów* (ang. *backpropagation*). Opiera się on na odwrotnym kierunku propagacji błędów, to jest uczenia sieci poczynając od warstwy wyjściowej do wejściowej. Dokładny jego opis można znaleźć np. w [7, str. 59]. Dostępnych jest wiele modyfikacji tego algorytmu. Jedną z nich stanowi stworzony w 1992 roku przez Martina Riedmüllera i Heinricha Brauna adaptacyjny algorytm znany pod nazwą *resilient backpropagation*, w skrócie Rprop. W programie Matlab zaimplementowany został w postaci funkcji *trainrp*.

W wielowarstwowych sztucznych sieciach neuronowych często, szczególnie w warstwach ukrytych, stosowane są sigmoidalne funkcje aktywacji. Przykładem takiej funkcji jest funkcja logistyczna

$$f(x) = \frac{a}{1 + be^{-cx}}.$$

Wartość pochodnej tej funkcji dla dużych argumentów jest bliska zeru. W przypadku algorytmów uczących wykorzystujących metody gradientowe może to zatem prowadzić do bardzo wolnego uczenia się sieci. Zaletą algorytmu *resilient backpropagation* jest wyeliminowanie tego efektu, poprzez uzależnienie zmiany wag tylko od znaku pochodnej, a nie jej wielkości. Dokładny opis algorytmu Rprop można znaleźć w pracy [5].

Etap IV

Procedura uczenia sieci na danych treningowych ma za zadanie dobranie optymalnych wag połączeń między neuronami. W praktyce oznacza to, że tak skonstruowana sieć dobrze działa dla przykładów ze zbioru treningowego. Nadrzędnym celem jest takie dobranie wag, aby sieć generowała niewielkie błędy również dla danych spoza zbioru treningowego. Dlatego tak ważne przy tworzeniu sztucznych sieci neuronowych jest wyodrębnienie, rozłącznego ze zbiorem treningowym, zbioru testowego. Dopiero wyniki działania sieci dla danych testowych mogą wskazywać na użyteczność bądź nie-

przydatność zbudowanej sieci neuronowej. Ostatecznym sprawdzianem działania sieci jest jednak dopiero jej poprawne działanie na danych rzeczywistych.

3.2 Zastosowania sztucznych sieci neuronowych

Nie sposób wymienić wszystkie zastosowania sieci neuronowych. Są one wykorzystywane w różnych dziedzinach nauki i życia. Wymienić można (por. [7, str. 13-18]) między innymi następujące obszary ich zastosowania:

- diagnostyka układów elektronicznych,
- badania psychiatryczne i analiza badań medycznych,
- prognozy giełdowe, marketingowe i gospodarcze,
- rozwiązywanie zagadnień optymalizacyjnych,
- interpretacja badań biologicznych,
- klasyfikacja, analiza i kojarzenie danych,
- filtracja sygnałów i analiza spektralna,
- podejmowanie decyzji i sterowanie procesami przemysłowymi.

Z ciekawszych zastosowań można wymienić również:

- poszukiwania ropy naftowej,
- typowania na wyścigach konnych,
- filtrowanie spamu w poczcie elektronicznej,
- kontrola bagażu na lotniskach w celu wykrycia ewentualnych materiałów wybuchowych (system SNOOPE działający z prędkością około 10 bagaży na minutę),
- analiza sygnałów sonarowych (np. wykrywanie obiektów podwodnych),
- systemy automatycznego czytania znaków oraz synteza mowy.

Z pewnością jednym z najważniejszych kierunków zastosowań sztucznych sieci neuronowych jest zagadnienie predykcji. Pozwalają one bowiem automatycznie prognozować wyłącznie na podstawie danych empirycznych, bez znajomości zależności pomiędzy danymi wejściowymi i wyjściowymi. Stanowią tym samym alternatywę dla klasycznych sposobów modelowania matematycznego czy ekonometrycznego zjawisk o dużym stopniu skomplikowania, trudnoprzewidywalnych lub charakteryzujących się wysoką zmiennością. Sieci neuronowe z powodzeniem stosowane są do oceny zdolności kredytowej podmiotów gospodarczych, prognozowania wskaźników giełdowych czy budowy portfela inwestycyjnego.

4 Prognoza CRO z użyciem sieci neuronowych

W rozdziale tym podana jest konstrukcja dwóch sieci neuronowych i ich zastosowanie do prognozowania wartości cen rozliczeniowych odchylenia. Pierwszy z algorytmów dokonuje godzinowej predykcji CRO na podstawie wartości szeregu CRO z okresu o trzy doby wcześniejszego, drugi natomiast dodatkowo wykorzystuje wartości szeregu WPKD. Wybór okresu jest uwarunkowany danymi archiwalnymi dostarczonymi przez Operatora Systemu Przemysłowego (patrz informacje w podrozdziałach 2.2 i 2.3).

4.1 Opis algorytmów

Pierwsza z zaprojektowanych sztucznych sieci neuronowych ma za zadanie na podstawie danych wartości CRO z doby $n - 2$ wyznaczyć w granulacji godzinowej prognozę CRO na dobę $n + 1$. Druga z sieci liczy predykcję CRO z doby $n + 1$ na podstawie wartości szeregów CRO i WPKD z doby $n - 2$. Ze względu na przedział czasowy prognozy mamy zatem do czynienia z prognozami krótkoterminowymi. Przedstawienie konstrukcji obu sieci oprzemy na czterech etapach opisanych w podrozdziale 3.1.

Etap I

Pierwsza z sieci składa się z dwóch warstw zawierających po 24 neurony każda. Liczba neuronów odpowiada liczbie godzin, na jakie tworzona ma być prognoza. Jako

funkcji aktywacji w każdej z warstw użyto funkcji logistycznej danej wzorem:

$$\text{logsig}(n) = \frac{1}{1 + e^{-n}}.$$

Druga z sieci jest bardziej rozbudowana. Składa się co prawda również z dwóch warstw, ale w pierwszej warstwie (wejściowej) znajduje się 48 neuronów, a warstwa wyjściowa zawiera 24 neurony. Na wejście tak zaprojektowana sieć neuronowa otrzymuje 24 wartości godzinowe CRO i 24 wartości godzinowe szeregu WPKD – w sumie 48 neuronów.

Etap II


Dla obu sieci liczba epok została ustalona na 1000, dopuszczalny błąd sieci na 10^{-4} , zaś krok uczenia przyjęto równy 0.05. Rysunek 4 demonstruje proces uczenia pierwszej z sieci dla dziesięciokrotnie większej liczby epok. Wynika z niego wyraźnie, iż granica zbieżności zastosowanego algorytmu uczenia sieci jest większa od zadanego dopuszczalnego błędu sieci i jest równa około 10^{-3} . Oznacza to, iż zwiększanie liczby epok powyżej pewnej wielkości (z wykresu wielkość ta jest równa około 3000-4000) prowadzi do niewielkiej już tylko poprawy działania sieci, a na pewno osiągnięty zysk jest niewspółmierny do poniesionego kosztu w postaci czasu obliczeń. Maksymalny dopuszczalny czas uczenia ustalony arbitralnie na pięć minut, nie miał w tym przypadku większego znaczenia, gdyż przy takiej wielkości sieci oraz licznosci wybranego zbioru treningowego uczenie sieci trwało raptem od kilku do kilkudziesięciu sekund.

Etap III

Ze względu na zastosowane funkcje aktywacji (funkcja sigmoidalna) oraz szybkość działania, do nauki sieci użyto algorytmu resilient backpropagation (patrz podroz. 3.1). Do zbioru treningowego zaliczono godzinowe wartości szeregu CRO z okresu od 2 stycznia 2009 roku do 24 czerwca tego samego roku. W przypadku drugiej z sieci dodatkowo dołączone zostały w postaci danych wejściowych wartości szeregu WPKD z tego samego okresu. Poprawne predykcje, czyli dane wyjściowe dla sieci neuronowej były przesuniętymi o trzy dni danymi wejściowymi, czyli szeregiem CRO z okresu 5 stycznia do 27 czerwca 2009 roku.

Etap IV

Zbiór testujący składał się z dwudziestu czterech godzin jedenastu dni, to jest prognoz na dni od 28 czerwca do 8 lipca 2009 roku.




Rysunek 4: Proces uczenia dwuwarstwowej sieci neuronowej złożonej z 24 neuronów w każdej z warstw, dla 10000 epok, kroku uczenia 0.05 oraz dopuszczalnego błędu sieci 10^{-4} .


4.2 Prognoza i analiza błędów

Obie sieci neuronowe zostały zaimplementowane w programie *Matlab & Simulink* firmy MathWorks z wykorzystaniem dodatku *Neural Network Toolbox*. Ze względu na niedeterminizm działania algorytmu resilient backpropagation przejawiający się w losowo inicjalizowanych wagach sieci, procedury uczenia i testowania powtórzone zostały 100 razy, a uzyskane wyniki uśrednione.


W celu zbadania odpowiedzi sieci na uczenie wyznaczony został średni błąd względny dla danych treningowych. W przypadku pierwszej z sieci wyniósł on 8,70%, a w przypadku drugiej sieci tylko 7,75%. Porównanie wyników działania sieci na przykładowym okresie należącym do zbioru treningowego z rzeczywistymi wartościami CRO przedstawione jest na rysunkach 5 i 7. Histogramy błędów tych wyników znajdują się na rysunkach 6 i 8.




Rysunek 5: Odpowiedź sieci na uczenie na przykładzie miesiąca danych treningowych (kwiecień 2009r.). Obliczenia wykonane przez dwuwarstwową sieć neuronową złożoną z 24 neuronów w każdej z warstw.



Rysunek 6: Histogram błędów odpowiedzi na uczenie na przykładzie miesiąca danych treningowych (kwiecień 2009r.) z dopasowaną gęstością rozkładu normalnego. Obliczenia wykonane przez dwuwarstwową sieć neuronową złożoną z 24 neuronów w każdej z warstw.



Rysunek 7: Odpowiedź sieci na uczenie na przykładzie miesiąca danych treningowych (kwiecień 2009r.). Obliczenia wykonane przez dwuwarstwową sieć neuronową złożoną z 48 neuronów w warstwie wejściowej i 24 neuronów w warstwie wyjściowej.



Rysunek 8: Histogram błędów odpowiedzi na uczenie na przykładzie miesiąca danych treningowych (kwiecień 2009r.) z dopasowaną gęstością rozkładu normalnego. Obliczenia wykonane przez dwuwarstwową sieć neuronową złożoną z 48 neuronów w warstwie wejściowej i 24 neuronów w warstwie wyjściowej.

Jak podkreślono w podrozdziale 3.1 istotniejszym wskaźnikiem dokładności działania sieci neuronowej jest jej zachowanie na danych testowych, różnych od danych treningowych. Obliczony średni błąd względny prognozy w tym przypadku dla obu sieci wyniósł odpowiednio 9,17% oraz 8,62%. Porównanie wyznaczonych prognoz dla przykładowego tygodnia należącego do zbioru testowego z rzeczywistymi wartościami CRO przedstawione jest na rysunkach 9 i 11. Histogramy błędu tych prognoz znajdują się na rysunkach 10 i 12.


W ramach symulacji numerycznej mierzony był również czas uczenia się sieci neuronowych. Wyniki okazały się nadzwyczaj optymistyczne, gdyż po uśrednieniu czas dla pierwszej z sieci wyniósł 4,75 sekundy, zaś dla sieci drugiej 8,30 sekundy. Sam czas prognozy dla dwudziestu czterech godzin jednego dnia jest tak krótki, że aż trudny do zmierzenia. Dla każdej z dwóch sieci jest on bowiem rzędu 10^{-5} - 10^{-4} sekundy.

Warto zwrócić uwagę, iż zwiększając liczbę epok do np. 10000, wydłuży się co prawda do 83,32 sekund czas uczenia drugiej z sieci, ale za to średnie błędy względne wyników działania tej sieci dla zbioru treningowego i testowego poprawią się do odpowiednio 6,24% i 7,72%.


4.3 Porównanie algorytmów

Szereg cen rozliczeniowych odchylenia charakteryzuje się dużą zmiennością, ale jego dokładniejsza analiza (patrz [1]) pokazuje dobową cykliczność oraz tygodniową okresowość. Do prognozowania CRO można zatem wykorzystać klasyczne modele ekonometryczne uwzględniające sezonowość, np. SARIMA. Jak pokazują eksperymenty numeryczne z pracy [1] uzyskane prognozy charakteryzują się średnim względnym błędem godzinowym na poziomie 8%. Czas działania zastosowanych tam algorytmów CROS₂₄ i CROS₇ jest jednak stosunkowo długi i oscyluje w granicy godziny. Pod tym względem konkurencyjny pod względem czasu działania wydaje się przedstawiony w pracy [2] algorytm CROBIL. Obliczenia tym algorytmem skracają się do około minuty bez pogorszenia średniego błędu względnego.


Oba przedstawione w niniejszym opracowaniu algorytmy oparte na sieciach neuronowych dają porównywalne jakościowo prognozy z jakością prognoz algorytmów CROS₂₄, CROS₇ i CROBIL. Lepsza pod tym względem wydaje się sztuczna sieć neuro-




Rysunek 9: Szereg CRO i jego prognoza na dni 2-8 lipca 2009r. obliczona przez dwuwarstwową sieć neuronową złożoną z 24 neuronów w każdej z warstw.



Rysunek 10: Histogram błędu prognozy CRO na dni 2-8 lipca 2009r. z dopasowaną gęstością rozkładu normalnego. Prognoza obliczona przez dwuwarstwową sieć neuronową złożoną z 24 neuronów w każdej z warstw.



Rysunek 11: Szereg CRO i jego prognoza na dni 2-8 lipca 2009r. obliczona przez dwuwarstwową sieć neuronową złożoną z 48 neuronów w warstwie wejściowej i 24 neuronów w warstwie wyjściowej.



Rysunek 12: Histogram błędu prognozy CRO na dni 2-8 lipca 2009r. z dopasowaną gęstością rozkładu normalnego. Prognoza obliczona przez dwuwarstwową sieć neuronową złożoną z 48 neuronów w warstwie wejściowej i 24 neuronów w warstwie wyjściowej.

nowa wykorzystująca jako dane wejściowe wartości zarówno szeregu CRO, jak i szeregu WPKD. Uzasadnienie tego faktu wiąże się z wykorzystaniem szeregu WPKD jako szeregu sterującego dla szeregu CRO, co opisane zostało dokładniej w podrozdziale 2.3. Istotną z punktu widzenia praktycznego różnicą jest jednak czas działania algorytmów. O ile w przypadku algorytmów opartych o modele SARIMA czas prognozowania liczymy w godzinach, zaś w przypadku algorytmu wykorzystującego oferty bilansujące w minutach, o tyle dla algorytmów opartych o sieci neuronowe mamy do czynienia z ułamkami sekundy. Nawet gdybyśmy byli zmuszeni każdorazowo tworzyć sieci, to i tak czas działania całego algorytmu ograniczyłby się do kilku sekund.

Dostępnych jest wiele możliwości rozbudowy skonstruowanych sieci neuronowych. Warto rozważyć uogólnienia polegające m.in. na:

- zwiększeniu liczby warstw,
- użyciu innych funkcji aktywacji i/lub algorytmów uczących,
- zwiększeniu liczby neuronów w warstwach.

Szczególnie obiecująco wygląda ostatnia z wymienionych opcji. Uwzględnienie bowiem danych historycznych szeregów CRO i WPKD z okresu dłuższego niż jeden dzień, mające bezpośrednie przełożenie na zwiększenie liczby neuronów w warstwie wejściowej, powinno poprawić jakość prognozy. Należy przy tym pamiętać, aby zysk z ograniczenia błędu predykcji nie zwiększył w znaczącym stopniu kosztu obliczeniowego nowych algorytmów. Kluczowe wydaje się zachowanie odpowiedniej równowagi pomiędzy szybkością działania a dokładnością algorytmów prognozujących ceny rozliczeniowe odchylenia. Biorąc jednak pod uwagę dotychczasowe symulacje związane z sieciami neuronowymi, można optymistycznie spoglądać na wykorzystanie ich jako narzędzia do prognozowania w kontekście kierunku dalszych badań.

Literatura

- [1] M. Kozakiewicz, M. Kwas:
Prognozowanie cen energii elektrycznej na rynku bilansującym z wykorzystaniem modeli SARIMA, Zeszyty Kolegium Analiz Ekonomicznych SGH, 2010r. Artykuł przyjęty do recenzji.
- [2] M. Kozakiewicz, M. Kwas:
Prognozowanie cen energii elektrycznej na rynku bilansującym z wykorzystaniem ofert bilansujących, Opracowanie w ramach badania statutowego, 2010r.
- [3] J. Nocedal, S. J. Wright:
Numerical Optimization, Springer, 1999r.
- [4] Polskie Sieci Elektroenergetyczne Operator S.A.:
Instrukcja ruchu i eksploatacji sieci przesyłowej. Bilansowanie systemu i zarządzanie ograniczeniami systemowymi. Wersja 1.0, 21.07.2010r.
- [5] M. Riedmiller, H. Braun:
A Direct Adaptive Method for Faster Backpropagation Learning: The RPROP Algorithm, Proceedings of the IEEE International Conference on Neural Networks (ICNN), San Francisco, 1993r., str. 586-591
- [6] L. Szczygieł:
Jaki model rynku energii?, Urząd Regulacji Energetyki, seria wydawnicza „Biblioteka Regulatora”, 2001r.
- [7] R. Tadusiewicz:
Sieci neuronowe, Akademicka Oficyna Wydawnicza RM, Warszawa 1993r.