

Anna MANOWSKA
Politechnika Śląska
Wydział Górnictwa i Geologii
Katedra Zarządzania i Inżynierii Bezpieczeństwa

PROGNOZOWANIE WIELKOŚCI SPRZEDAŻY WĘGLA KAMIENNEGO Z WYKORZYSTANIEM SZTUCZNEJ INTELIGENCJI

Streszczenie. W artykule omówiono nowoczesne metody prognozowania, które służą ograniczeniu ryzyka związanego z niepewnością i niepełną wiedzą o przyszłości. Zasyulowano proces sprzedaży węgla kamiennego z wykorzystaniem dwóch metod: statystycznej oraz sztucznej inteligencji. Prognozę wielkości sprzedaży węgla kamiennego wykonano, aby zaprezentować najbardziej prawdopodobne drogi rozwoju tego procesu lub aby pokazać najbardziej prawdopodobny poziom sprzedaży. W artykule pokazano również wady i zalety każdego z zastosowanych rozwiązań.

FORECASTING THE QUANTITIES OF COAL SALES BY EMPLOYING ARTIFICIAL NEURAL NETWORKS

Summary. The following paper discusses modern methods of forecasting, which are used to reduce the risks associated with the uncertainty and the incomplete knowledge of the future. The coal sales process was simulated by means of two methods: statistical model and artificial neural networks. The forecast of coal sales volumes was made to present the most probable development paths of the process as well as to show the most likely level of sales. The study also shows the advantages and disadvantages of each of the applied solutions.

1. Wprowadzenie

Transformacja rynku węgla kamiennego rozpoczęta w latach 90. spowodowała znaczne zmniejszenie energochłonności procesów produkcyjnych i produktów, przy zachowaniu dużych wahań zapotrzebowania na węgiel kamienny w okresie rocznym (węgiel w znacznej

części jest produktem sezonowym). Niezbędne zatem staje się określenie zdolności frontu eksploatacyjnego, która zaspokoi coraz niższe, ale dalej zmienne zapotrzebowanie na węgiel kamienny. Kwestia ta ma również istotne znaczenie w analizie i ocenie bezpieczeństwa energetycznego kraju. Można założyć, że analiza wielkości sprzedaży węgla w przyjętych przedziałach czasowych umożliwi opracowanie modelu wielkości sprzedaży, aby na podstawie tego modelu prognozować wielkość wydobycia w przyjętym horyzoncie czasowym. Celem naukowym jest opracowanie takich prognoz sprzedaży, których wyniki prognozowane są na tyle wiarygodne, że mogą wspomagać planowanie wydobycia w zakładzie górniczym. Celem utylitarnym jest wypracowanie metod, które umożliwią odnowę frontu eksploatacyjnego, tak aby zdolności wydobywcze były dostosowane do możliwości sprzedaży.

W procesie planowania ważne miejsce zajmują metody prognozowania, które informują „planistę”, jaka prawdopodobnie będzie chłonność rynku węglowego przy zachowaniu dotychczasowych strategii rozwoju gospodarczego. Do tworzenia strategii rozwoju gospodarki krajowej niezbędne staje się wykorzystanie matematycznych metod prognozowania. To uzasadnia podjęcie prac badawczych, związanych z wypracowaniem metod i technik prognostycznych, związanych z opracowaniem modelu wielkości sprzedaży węgla kamiennego, dzięki któremu można prognozować wiarygodne wielkości.

Transformacje systemu gospodarczego, otwarcie się Polski na świat spowodowały, że na rynku węglowym po stronie oferentów węgla pojawiły się jednostki gospodarcze handlujące węglem krajowym i z importu, a po stronie odbiorców – jednostki gospodarcze specjalizujące się w handlu węglem. Łatwy dostęp do innych surowców energetycznych (ropa, gaz itp.) to główne przyczyny nadprodukcji węgla. Przemysł wydobywczy wymusza stosowanie zaawansowanych technik rozpoznania potencjalnych możliwości sprzedaży węgla, analiz elastyczności popytu względem ceny, ocen zachowania się konkurentów i reakcji odbiorców na ich zachowania¹.

Z analizy literaturowej oraz dostępnych prognoz na rynku światowym wynika, że prognozy zużycia i sprzedaży węgla kamiennego opierają się głównie na modelach ekonometrycznych, z wyjątkiem prognoz Agencji Rynku Energii SA, które zostały opracowane na metodach ekstrapolacji trendów. Modele, jakie skonstruowano opierały się na kompleksowej symulacji struktury energetycznej i zachowaniu odbiorców końcowych (model end-use), a także modelu prognozy Agencji Rynku Energii SA – model ENPEP.

Prognozy te charakteryzowały się tym, że zmienna poszukiwana (sprzedaż węgla kamiennego) była określona na podstawie historycznych przebiegów czasowych funkcji wielu zmiennych objaśniających, takich jak liczba gospodarstw domowych, ceny paliw,

¹ Kowalik S., Przybyła H.: Metody szacowania wpływu strategii zarządzania na dochód ze sprzedaży węgla. „Wiadomości Górnicze”, nr 10, Kraków 2000, s. 424.

nowe technologie itp. Jednakże dla tych prognoz zachodzi konieczność przewidywania wielkości objaśniających, co znacznie wpływa na ich wiarygodność. Dodatkowym utrudnieniem jest uwzględnienie mechanizmu polityki energetycznej, która wpływa na zachowanie się zmiennych objaśniających.

2. Proces prognozowania

Wiele pozycji literaturowych jest poświęconych teorii prognozy. Można wymienić niektóre spośród nich: G.E.P. Box i G.M. Jenkins (1970), S. Makridakis i S.C. Wheelwright (1979, 1983), M. West i J. Harrison (1989), A. Zeliaś (1996), Z. Pawłowski (1969). Teoria prognozy jest dziedziną rozwijaną i coraz powszechniej stosowaną. Najliczniej są prezentowane prace z zakresu ekonometrii, w których metody prognozy zostały wykorzystane do rozwiązania między innymi zagadnień dotyczących prognozy gospodarki.²

Od najdawniejszych czasów ludzie interesowali się swoją przyszłością, a prognoza była kojarzona ściśle z jej przewidywaniem. Zainteresowanie tym, co może się wydarzyć jest oczywiste. Każdy przecież chciałby mieć wpływ na swój (i nie tylko) los – móc przynajmniej w niewielkim stopniu nim sterować³.

W dobrze zarządzanym przedsiębiorstwie dzisiaj pracuje się na sukcesy jutra, niestety wiedza o przyszłości jest niepełna i niepewna. Tę niepewność, a także ryzyko z tym związane można ograniczyć prowadząc badania nad przyszłością, w których szczególne miejsce zajmuje prognozowanie.⁴

Prognozowanie to proces, którego celem jest przewidywanie przyszłości z użyciem metod naukowych. Prognoza danego zjawiska to wskazanie najbardziej prawdopodobnej drogi rozwoju lub poziomu tego zjawiska (np. jaka wielkość wydobycia będzie z jednej ściany w kolejnych latach lub jaki będzie wzrost temperatury w przodkach wydobywczych wraz ze wzrostem głębokości eksploatacji) opierając się na zdobytej wiedzy, dotychczasowym przebiegu zjawiska, oraz wiedzy o obecnym stanie tego zjawiska.

W prognozowaniu często używa się oszacowania, a więc wypowiedzi o przyszłości, a wypowiedzi te uzyskuje się przez sądy ekspertów, szczególnie dotyczy to zjawisk czy procesów bez historii. Prognoza dotyczy parametrów, których dokładnych wielkości nie określono.

² Kurzeja J.: Sekwencyjna prognoza energii sejsmicznej generowanej eksploatacją pokładu węgla. Prace naukowe Głównego Instytutu Górnictwa, Katowice 2005, s. 25.

³ Ibidem.

⁴ Przybyła H.: Przedsiębiorstwo i jego otoczenie, [w:] Dźwigoł H. (red.): Restrukturyzacja przedsiębiorstwa w warunkach gospodarki rynkowej. Instytut Promocji Małych i Średnich Przedsiębiorstw PROMOTOR, Katowice-Chorzów 2004

W prognozowaniu często wykorzystuje się wiedzę, doświadczenie i intuicję zespołu badawczego, natomiast w przypadku, kiedy zjawisko ma swoją historię to również tę historię.

Wypowiedzi na temat przyszłości – przewidywania przyszłości – można podzielić jak na rys. 1.



Rys. 1. Schemat przewidywania przyszłości

Fig. 1. Scheme of forecasting the future

Źródło: Opracowanie własne na podstawie: Cieślak M.: Prognozowanie gospodarcze. PWN, Warszawa 1997.

Przyjmuje się zatem, że prognozowanie to działanie racjonalne posługujące się metodami naukowymi oraz, że odnosi się do określonej, zazwyczaj niezbyt odległej przyszłości.

Prognoza zatem jest budowana z wykorzystaniem nauki, odnosi się do nieodległej przyszłości, jest empirycznie weryfikowalna, jest określona z dużym prawdopodobieństwem.

Do głównych funkcji prognozy zalicza się:

- wspomaganie podjęcia decyzji mikro- i makroekonomicznych (prognoza zalecająca);
- wspomaganie podjęcia działań aktywizujących lub przeciwstawiających się;
- poinformowanie o mogących nastąpić zmianach, skutkach działań.

Konstruowanie prognozy jest wskazane, gdy:

- horyzont czasowy jest krótki,
- zmiany prognozowanej wielkości są powolne,
- prognozowane wielkości mają głównie autonomiczny charakter, mało zależą od arbitralnych decyzji,
- jest duża inercja (bezwładność) prognozowanej zmiennej.

W niniejszym opracowaniu przedmiotem badania była wielkość sprzedaży węgla kamiennego, a do oszacowania przyszłych wielkości tej sprzedaży wykorzystano dwie metody: statystyczną oraz sztucznej sieci neuronowej. Dane, które użyto w prognozie uzyskano z opracowań Agencji Rozwoju Przemysłu SA Oddział w Katowicach. W budowie modelu wykorzystano miesięczną wielkość sprzedaży węgla kamiennego, wyrażoną w tys. Mg, począwszy od stycznia 1995 roku do 2008 roku. Pozostałe dane, tzn. od 2009 roku do 2010 roku wykorzystano do testowania modelu.

3. Wykorzystanie metod statystycznych w prognozowaniu

W analizie statystycznej szacowanie i przewidywanie należą do dziedziny wnioskowania statystycznego. Wnioskowanie statystyczne składa się z metod szacowania i testowania hipotez o cechach populacji, na podstawie informacji zawartych w próbce⁵.

Tabela 1

Dane statystyczne wielkości sprzedaży węgla kamiennego

Lata	styczeń	lut	marzec	kwiecień	maj	czerwiec	lipiec	sierpień	wrzesień	październik	listopad	grudzień
1995	11732	10686	10925,1	9950,8	9815,3	10597,7	10043,6	11393,3	11215,2	9718,6	12936,9	12359,5
1996	12504	10902	12188,8	11004	9847	9119,2	10870,2	10793,1	11366,2	12589,4	11113,7	11003,1
1997	12580	11378	10725,4	11036	9709,9	10854,5	10004,5	10289,7	11639,8	11650,4	10873,2	11820,6
1998	6679,1	8648	8577,6	8337,6	8643,6	9287,9	10079,1	9416,3	10948	10566,2	11162,5	11942,8
1999	8923,4	8748	9262,4	8311,2	8193	8319	8021,9	9327,7	9735,8	9329	9515,8	11156,1
2000	7094,7	8496	9680,5	7491,1	7243,8	7836,4	7989,1	8558,6	9029,1	9282,5	9405,8	8887,6
2001	8629,1	8157	8838,7	7694,3	7966,7	7690,8	8382	8153,2	8192,3	9634,7	9445	8990,8
2002	8187,7	8069	8479,3	7550,7	7081,8	7487,2	8463,4	8483,6	8893,3	9611,3	8813,1	8824,1
2003	9155,5	8155	8132,7	7036,7	7105,2	6881,5	7947,5	7424,1	9050,4	9861,9	8696,6	9078,2
2004	7096,9	8096	9158,1	7888,6	7261,1	7545,8	7948,4	8110,8	8878,7	8960,8	8649,3	9153,6
2005	7059,6	7175	8204,4	7300,9	6925,1	7631,9	7217,6	7786,9	8646,5	8916,3	8610,7	8660,2
2006	7980,1	8035	9061,8	6815,4	7462,9	7068	7244,5	7895,8	7965,9	8504,3	8213,8	7143,6
2007	7796,5	7170	7752,1	6699,3	6775,2	6464	6539,8	7018,4	7324,1	8606	7857,4	6688,2
2008	7585,8	7006	6757,2	7418,3	6621,7	6844,8	7234,3	6279,9	7048,8	7686,2	6402,2	6075,9
2009	5574,2	5327	5717,6	4779,1	4835,2	4924,1	5424,5	5535,5	6555	6428,6	6568,2	5930,3
2010	5252,7	5619	6167,1	5219,7	4986,1	5609,6	5948,9	5848,6	6237,5	6360,8	6553	5667,3

Źródło: opracowanie własne.

W tabeli 1 zestawiono wielkości sprzedaży węgla kamiennego, a elementy tej tabeli tworzą macierz Y o 16 wierszach i 12 kolumnach, gdzie wiersze tabeli odpowiadają kolejnym latom od 1995 do 2010 roku ($i = 1 \dots 16$), a kolumny odpowiadają kolejnym miesiącom od stycznia do grudnia ($j = 1 \dots 12$). Odwołanie do elementów macierzy Y następuje przez zastosowanie symbolu „ y_{ij} ”.

$$Y = \begin{bmatrix} y_{1,1} & \dots & y_{1,12} \\ \vdots & \ddots & \vdots \\ y_{16,1} & \dots & y_{16,12} \end{bmatrix} \quad (1)$$

Wykonując jednowymiarową analizę, macierz Y została przekształcona na ciąg czasowy $\{y_c(t)\}$, (gdzie t przyjmuje wartości od 1 do 192, kolejne miesiące badanego okresu czasowego) przepisując kolejne kolumny macierzy Y . Ciąg czasowy ma postać:

$$y_c = \{y_1, y_2, y_3, \dots, y_{192}\}, \quad (2)$$

gdzie:

$$\begin{aligned} y_c(1) &= y_{1,1}, \\ y_c(2) &= y_{2,1}, \\ \vdots y_c(t) &= y_{i,j}, \\ y_c(192) &= y_{12,16}. \end{aligned}$$

⁵ Larose D.T.: Odkrywanie wiedzy z danych. Wprowadzenie do eksploracji danych. PWN, Warszawa 2006, s. 72.

Jednowymiarową analizę wykonano dla ciągu czasowego wielkości sprzedaży węgla kamiennego $\{y_c(t)\}$ obliczając miary środka i rozpiętości.

Średnia, która została wyliczona jest średnią arytmetyczną wartości przyjmowanych przez zmienną $y_c(t)$ i wynosi⁶:

$$\bar{y} = \frac{\sum_{t=1}^n y_c(t)}{n} = \frac{1}{192} \sum_{t=1}^{192} y_c(t) = 8409,4 \text{ tys. Mg} \quad (3)$$

Mediana została wyliczona jako wartość środkowa, gdy wartości są ułożone w porządku rosnącym. Rozpatrywany ciąg czasowy $\{y_c(t)\}$ został przekształcony na $\{y_c'(t)\}$ poprzez sortowanie w porządku rosnącym. Ponieważ liczebność ciągu czasowego $\{y_c'(t)\}$ jest liczbą parzystą $n = 192$, mediana została wyliczona jako wartość środkowa obserwacji o indeksach „t” równych odpowiednio: $\frac{n}{2} = \frac{192}{2} = 96$ oraz $\frac{n}{2} + 1 = \frac{192}{2} + 1 = 97$

$$\text{mediana} = \frac{y_{96} + y_{97}}{2} = 8198,7 \text{ tys. Mg} \quad (4)$$

Znacząca różnica między średnią arytmetyczną a medianą wynika stąd, że w ciągu czasowym wielkości sprzedaży węgla kamiennego występują wartości skrajne, które zawiły wartość średniej arytmetycznej. Wartości skrajne występują w latach 1995, 1996, 1997. Sprzedaż w tych latach była wyższa od wielkości sprzedaży węgla kamiennego w latach następnych. Spadek sprzedaży, który nastąpił po 1997 roku był wynikiem obniżenia sprzedaży do energetyki zawodowej, do koksowni oraz do pozostałych odbiorców krajowych. Świadczy to o gwałtownym, trudnym do przewidzenia, jeżeli opiera się na trendach z lat poprzednich, załamaniu się sprzedaży węgla kamiennego na rynku krajowym.

Odchylenie standardowe jest również wrażliwe na obecność punktów oddalonych, gdyż we wzorze występuje kwadrat odległości⁷:

$$s = \sqrt{\frac{\sum_{t=1}^n (y_c(t) - \bar{y})^2}{n}} = \sqrt{\frac{\sum_{t=1}^{192} (y_c(t) - 8409,4)^2}{192}} = 1795,2 \text{ tys. Mg} \quad (5)$$

Odchylenie standardowe stanowi 21% wartości średniej dla rozważanego ciągu czasowego $\{y_c(t)\}$. Oznacza to, że średnio o 21% miesięczne wartości sprzedaży węgla kamiennego różnią się od wartości średniej, czyli o 1795 tys. Mg.

Ze względu na fakt, że próbka jest podzbiorem populacji, oszacowana wartość średniej różni się od rzeczywistej wartości, czyli jest obarczona błędem próbkowania $|\bar{x} - \mu|$, który


⁶ Kowalik S.: Wybrane zagadnienia z matematyki. Wykłady dla doktorantów. Wydawnictwo Politechniki Śląskiej, Gliwice 2002, s. 144.

⁷ Larose D.T.: op.cit., s. 71.

z definicji jest odległością pomiędzy średnią arytmetyczną obserwowanej próbki a nieznaną średnią populacji, czyli dla rozważań błąd próbkowania wynosi $|8409,4 - \mu|$.

3.1. Budowa prognozy z wykorzystaniem metody statystycznej

Do prognozowania wielkości sprzedaży węgla kamiennego na rynku krajowym wykorzystano dane historyczne od 1995 roku do 2010 roku.



Rys. 2. Rzeczywisty przebieg wielkości sprzedaży węgla kamiennego na rynku krajowym

Fig. 2. Diagram of quantities of coal sold on the Polish market

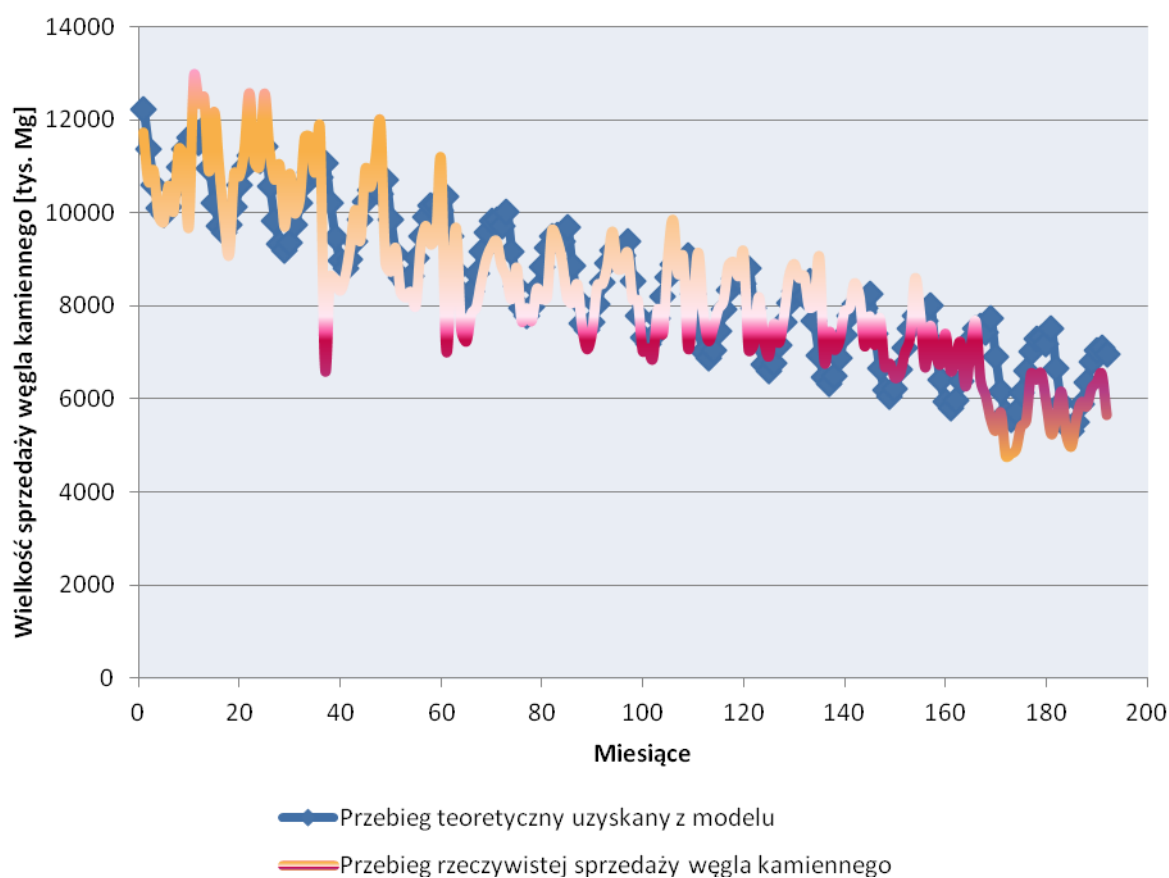
Źródło: Opracowanie własne.

W rozważanym ciągu czasowym można zauważyć tendencję malejącą – sprzedaż zmniejszyła się z poziomu 11000 tys. Mg w 2005 roku – do poziomu ok. 6000 tys. Mg w 2010 roku. Analizując tendencję rynku energetycznego należy zaznaczyć, że w 95% bezpieczeństwo energetyczne Polski jest zapewnione właśnie przez ten surowiec, a przemiany restrukturyzacyjne potwierdzają, że nie nastąpi zmniejszenie zużycia tego nośnika energetycznego. Zauważalny spadek jest głównie wynikiem dostosowania wydobycia do aktualnych potrzeb odbiorców, zmniejszeniem eksportu oraz wprowadzeniem importowanego węgla na krajowy rynek. Dodatkowymi atutami przewagi tego nośnika energetycznego nad innymi, takimi jak ropa naftowa, gaz ziemny, są jego niska cena, dostępność oraz procesy produkowania węgla „czystego”, dostosowanego do wymogów Unii Europejskiej odnośnie emisji zanieczyszczeń do atmosfery.

W metodzie statystycznej szczególną uwagę skupiono na sezonowości sprzedaży, dostosowując model do widocznego, cyklicznego przebiegu, z malejącymi oscylacjami. Najlepszym modelem, ze wszystkich zbudowanych okazał się model inercyjny rzędu pierwszego, o postaci:

$$y_t = 11315 \cdot e^{-0,003t} + 1800 \cdot \sin(2 \cdot \Pi / 12 \cdot t + 2,02) \cdot e^{-t/12} \quad (6)$$

Z tak opracowanego modelu udało się uzyskać średni względny błąd *ex post* 15%. Wartości teoretyczne w odniesieniu do wartości rzeczywistych przedstawiono na wykresie.



Rys. 3. Prognoza wielkości sprzedaży z użyciem metody statystycznej

Fig. 3. Forecast of sales by the use of statistical method

Źródło: Opracowanie własne.

4. Wykorzystanie sztucznych sieci neuronowych w prognozowaniu

4.1. Charakterystyka sieci neuronowych

Sieci neuronowe jako obiekt badań stanowią bardzo uproszczony model rzeczywistego systemu. Składają się one z połączonych ze sobą obiektów, umownie zwanych neuronami.

Istotną cechą sieci takich elementów jest możliwość uczenia się, tj. modyfikowania parametrów charakteryzujących poszczególne neurony w taki sposób, by zwiększyć efektywność sieci przy rozwiązywaniu określonego typu zadań.

Sieci neuronowe mogą być bardzo skuteczne jako narzędzia obliczeniowe w rozwiązywaniu takich zadań, z którymi typowe komputery i typowe programy sobie nie radzą. Do głównych zalet należy:

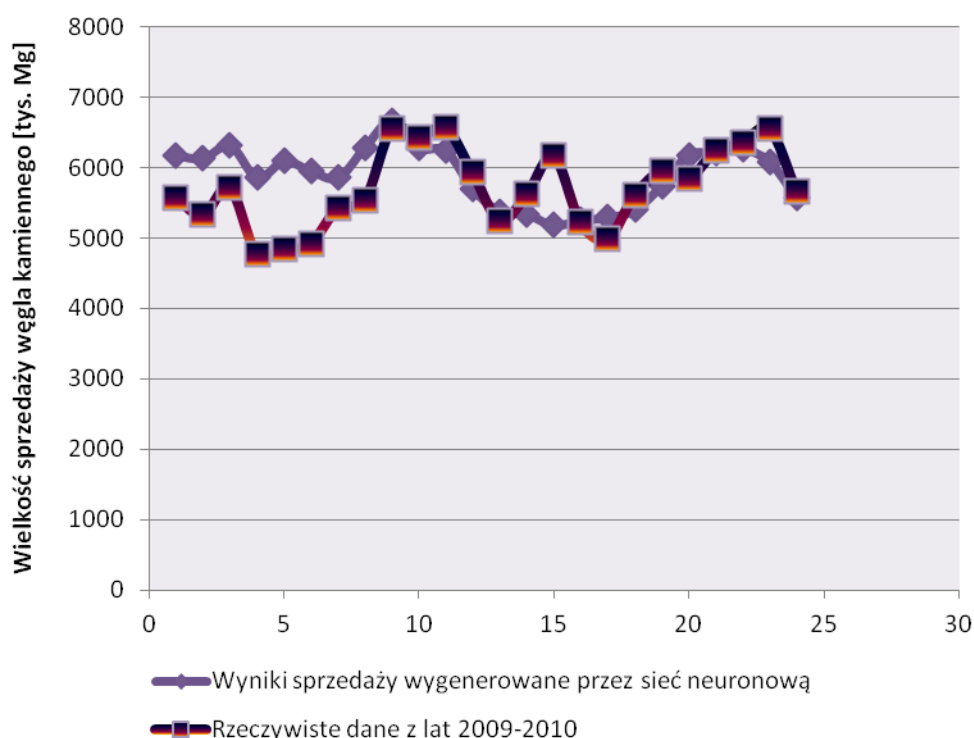
- równoległe wykonywanie obliczeń, w związku z czym szybkość pracy sieci neuronowych może znacznie przewyższać szybkość obliczeń sekwencyjnych,
- możliwość uzyskania rozwiązania problemu z pominięciem etapu konstruowania algorytmu.

Sieci nie trzeba programować. Istnieją metody uczenia pozwalające uzyskać ich celowe i skuteczne działanie nawet w sytuacji, kiedy twórca nie zna algorytmu, według którego można rozwiązać postawione zadanie. Sieć działa zawsze jako całość i poszczególne jej elementy mają wkład w realizację wszystkich czynności, które sieć realizuje. Jedną z konsekwencji takiego działania sieci jest jej zdolność do poprawnego działania, nawet po uszkodzeniu znacznej części elementów wchodzących w jej skład.

Topologia sieci powinna wynikać z rodzaju zadania, jakie jest stawiane przed nią. Decyzje dotyczące struktury sieci nie wpływają na jej zachowanie w stopniu decydującym. Zachowanie jej w zasadniczy sposób zależy od metody jej uczenia. Sieci neuronowe mogą całą swoją wiedzę zyskiwać wyłącznie w trakcie nauki i nie muszą mieć z góry zadanej, dopasowanej do stawianych im zadań, jakiegokolwiek precyzyjnie określonej struktury. Sieć musi jednak mieć wystarczający stopień złożoności, żeby w jej strukturze w toku uczenia można było uzyskać potrzebne połączenia i struktury.

4.2. Budowa prognozy z wykorzystaniem sztucznej sieci neuronowej

Do wyznaczenia przyszłej wielkości sprzedaży wykorzystano również sieć neuronową, zbudowaną w dodatku Simulink oprogramowania MATLAB wersja 7.0. W opracowaniach dotyczących budowy sieci neuronowych brak jest wskazania metod, którymi należy się posługiwać, aby zbudować poprawną strukturę sieci neuronowej. W pracy badawczej zaproponowano algorytm optymalizujący błąd średniokwadratowy, na podstawie którego dobierana jest liczba neuronów w warstwie. Strukturę sieci neuronowej stworzono empirycznie. Model neuronu był projektowany do predykcji miesięcznej wartości następnej. Zastosowano wielowarstwowy model sieci z jedną warstwą ukrytą. Zbudowana sieć była uczona z nauczycielem na danych statystycznych z lat 1995 – 2008. Pozostałe dwa lata – 2009, 2010 – pozostawiono na testowanie sieci. Najlepszą funkcją aktywacji okazała się funkcja liniowa, w poszczególnych warstwach uczono 12 neuronów. Wartość wag dobrano doświadczalnie, a ich aktualizacja następowała przy użyciu metody najmniejszych kwadratów. Wyniki teoretyczne, jakie uzyskano przedstawiono na wykresie (rys. 4).




Rys. 4. Prognoza wielkości sprzedaży z użyciem ANN

Fig. 4. Forecast of largeness of sale with using ANN

Źródło: Opracowanie własne.

Wykres wielkości sprzedaży węgla kamiennego jest taki sam, jak w metodzie statystycznej, natomiast wykres prognozy znacznie się różni. Przy zastosowaniu sztucznej sieci neuronowej prognoza jest zadowalająco dopasowana do przebiegu rzeczywistego. Dopasowanie to jest korzystniejsze niż prognoza uzyskana metodą statystyczną, należy jednak dalej poszukiwać innej struktury sieci lub zbudować system polimorficzny. Jest wysoce prawdopodobne, że prognozy oparte na sieci neuronowej będą obarczone coraz mniejszym błędem, z uwagi na fakt, że w metodach opartych na sztucznej inteligencji pozwala się sieci na samodoskonalenie. Fakt ten jest istotny przy budowie prognoz długoterminowych. Należy jednak zaznaczyć, że model rzeczywisty, z jakim mamy do czynienia, jest bardzo trudny do prognozowania, jest to ciąg losowy, o czym świadczy współczynnik autokorelacji na poziomie 0,5, czego wynikiem jest trudność opisu przebiegu formułą matematyczną. Wykres błędu przedstawiony poniżej (rys. 5) także znacznie różni się od wykresu z metody statystycznej. Przede wszystkim różnica polega na tym, że maksymalna wartość błędu zmniejszyła się i nie przekracza 20%. Największe skoki błędu zaobserwowano w początkowym okresie danych przeznaczonych do weryfikacji modelu, wrzesień 2009 roku. Pokazuje to, że model jest dosyć dobrze dopasowany. W pozostałych miesiącach błąd oscyluje w granicach 5%.



Rys. 5. Wykres błędu prognozy

Fig. 5. Diagram of forecast error

Źródło: Opracowanie własne.

Należy pamiętać, że sieć uczy się na przykładach. Jeżeli zaobserwowano istotne zmiany w kształtowaniu się prognozowanego szeregu w stosunku do przeszłości, to sieć neuronowa będzie mieć problem trafnie je klasyfikować. W takiej sytuacji należy wytrenować sieć na nowym, poszerzonym zbiorze danych lub zmniejszyć dane wyrównując poziom sprzedaży do poziomu uzyskanego po restrukturyzacji. Nie ma sensu badania zdolności sieci neuronowej w dłuższym horyzoncie czasowym – daleko wybiegającym poza okres uwzględniony w zbiorze danych uczących, ponieważ wymogi budowy struktury sieci nie pozwolą zbudować dobrego modelu na małym zbiorze danych. Z tak opracowanego modelu można założyć przyszłe parametry procesu eksploatacyjnego, jak obciążenie ściany, szybkość odnowy frontu eksploatacyjnego, szybkość robót przygotowawczych.

5. Wnioski

Do prognozowania można użyć wiedzy, doświadczenia i intuicji ekspertów, metod statystycznych jak również sztucznej inteligencji.

W prognozowaniu spotyka się dwa zasadnicze problemy: pierwszy z nich to brak informacji na temat danego zjawiska bądź też informacja jest nieprecyzyjna, a drugi problem to nadmiar informacji, wynikający ze złożoności zdarzenia. Skomplikowane algorytmy matematyczne powodują wzrost zaangażowania technologii informatycznej, co owocuje szybkim postępem technicznym. Z jednej strony łatwość dostępu do metod rozwiązywania problemów, a z drugiej brak czasu na poszukiwanie rozwiązań powoduje, że obecnie klasyczne metody prognozowania nie znajdują zastosowania. Większość tych ograniczeń nie jest przeszkodą dla metod prognozowania opartych na sztucznej inteligencji. Jednakże znajdują się obszary ograniczonej stosowalności podstawowych technik inteligentnych, gdyż nie spełniają one kryteriów uniwersalnej, kompleksowej metody analizy.

Uzyskane w pracy badawczej prognozy przy użyciu sieci neuronowej charakteryzują się mniejszym błędem *ex post* o około 8%, w porównaniu do zbudowanego modelu statystycznego, co umożliwi opracowanie wysoko prawdopodobnych prognoz krótkoterminowych. Można założyć również, że w miarę pozyskiwania nowych informacji sztuczne sieci neuronowe umożliwią prognozowanie długoterminowe.

Bibliografia

1. Cieślak M.: Prognozowanie gospodarcze. PWN, Warszawa 1997.
2. Manowska A.: Prognozowanie wielkości sprzedaży węgla kamiennego dla grupy kopalń. Praca doktorska, Gliwice 2010.
3. Radosiński E.: Inteligentne techniki hybrydowe w analizie ekonomicznej. Politechnika Wrocławska, Wrocław 1998.
4. Przybyła H.: Przedsiębiorstwo i jego otoczenie, [w:] Dźwigoł H. (red.): Restrukturyzacja przedsiębiorstwa w warunkach gospodarki rynkowej. Instytut Promocji Małych i Średnich Przedsiębiorstw PROMOTOR, Katowice-Chorzów 2004.
5. Larose D.T.: Odkrywanie wiedzy z danych. Wprowadzenie do eksploracji danych. PWN, Warszawa 2006.
6. Kowalik S., Przybyła H.: Metody szacowania wpływu strategii zarządzania na dochód ze sprzedaży węgla. „Wiadomości Górnicze”, nr 10, Kraków 2000.
7. Kurzeja J.: Sekwencyjna prognoza energii sejsmicznej generowanej eksploatacją pokładu węgla. Prace naukowe Głównego Instytutu Górnictwa, Katowice 2005.
8. Kowalik S.: Wybrane zagadnienia z matematyki. Wykłady dla doktorantów. Wydawnictwo Politechniki Śląskiej, Gliwice 2002.

Abstract

Forecasting may involve the application of knowledge, experience and intuition of experts, as well as the statistical methods or artificial intelligence. Two fundamental problems occur in forecasting: the first one is the lack of information on a given phenomenon, or the information is inaccurate, and the other problem is information overload resulting from the complexity of the event. Complex mathematical algorithms require the increase of the involvement of information technology, which entails rapid changes in technology. Easy access to troubleshooting methods and, on the other hand, the lack of time to search for solutions cause the problems with applying classical methods of forecasting. Most of these restrictions are not an obstacle for forecasting methods based on artificial intelligence. However, there are limited areas of applicability of the basic intelligent techniques, because they do not meet the criteria for universal, comprehensive methods of analysis.