

Krzysztof Koszela, Piotr Boniecki, Jerzy Weres
Instytut Inżynierii Rolniczej
Akademia Rolnicza w Poznaniu

OCENA EFEKTYWNOŚCI NEURONOWEGO PROGNOZOWANIA W OPARCIU O WYBRANE METODY NA PRZYKŁADZIE DYSTRYBUCJI PRODUKTÓW ROLNICZYCH

Streszczenie

Prognozowanie staje się bardzo ważnym etapem w każdej działalności. W przypadku dystrybucji produktów rolniczych mamy do czynienia z szeregiem złożonych bodźców, które przekładają się na wynik końcowy. Natomiast jakość tych prognoz ma ogromne znaczenie na kolejne etapy w łańcuchu produkcyjno-dystrybucyjnym. Sieci neuronowe są bardzo wysublimowaną techniką modelowania, zdolną odwzorować bardzo złożone funkcje. Modelowanie z wykorzystaniem sztucznych sieci neuronowych stosuje się wówczas, gdy nie jest znany dokładny opis matematyczny rozpatrywanego zjawiska, natomiast dobrze określone są jego wejścia i wyjścia. Sztuczna sieć neuronowa potrafi nauczyć się rozpoznawać analizowany problem, dając szybko odpowiedź na zmieniające się parametry wejściowe procesu. W pracy przedstawiono porównanie dwóch metod neuronowego modelowania sprzedaży wybranego produktu.

Słowa kluczowe: sztuczna inteligencja, sztuczne sieci neuronowe, prognozowanie, szeregi czasowe

Wprowadzenie

Badania naukowe mające na celu zrozumienie praw rządzących naszym umysłem, czy też skonstruowaniem czegoś podobnego do ludzkiego mózgu, trwają już od wielu lat. Sztuczną inteligencją zajmują się specjaliści i naukowcy z wielu dziedzin nauki. W badaniach nad sztuczną inteligencją możemy wyróżnić dwa główne kierunki. Pierwszy z nich abstrahuje od budowy ludzkiego mózgu, lecz opiera się na funkcjach przez niego realizowanych. Kierunkiem tym są właśnie systemy ekspertowe, które coraz częściej znajdują zastosowanie w wielu obszarach gospodarki

(przemysł, medycyna, rolnictwo, finanse itp.). Drugim podejściem, coraz bardziej popularnym w ostatnim czasie, są próby modelowania ludzkiego mózgu. Większość naukowców swe badania skupia na jego strukturze a nie na funkcjach. Takimi systemami są m.in. sztuczne sieci neuronowe [Stateczny, Praczyk 2002]. W ostatnich latach obserwujemy gwałtowne zainteresowanie tymi systemami. Nie jest to wynik zbiegu okoliczności czy rezultat chwilowej mody. Ich rozwój jest możliwy dzięki szybkiemu postępowi techniki komputerowej, która umożliwia zapamiętywanie coraz większej liczby danych, a także coraz szybsze ich przetwarzanie. Sieci neuronowe są potęgę zawdzięczają temu, że są po prostu wygodnym narzędziem, przydatnym do realizacji bardzo wielu różnych praktycznych zadań. Ich zastosowanie z pełnym powodzeniem realizowane jest w takich dziedzinach jak medycyna, zastosowania inżynierskie, fizyka, a w ostatnim czasie coraz częściej w rolnictwie. W rzeczywistości tych zastosowań może być zdecydowanie więcej, ponieważ mogą być stosowane wszędzie tam, gdzie pojawiają się problemy związane z przetwarzaniem i analizą danych, z ich predykcją, klasyfikacją czy też sterowaniem. Zalety sieci neuronowych, jak już wspomniano wcześniej, nie ograniczają się jedynie do tego, że umożliwiają one swobodne i łatwe tworzenie modeli nieliniowych. Sieci umożliwiają także kontrolę nad złożonym problemem wielowymiarowości, który przy stosowaniu innych metod znacząco utrudnia próby modelowania funkcji nieliniowych z dużą liczbą zmiennych niezależnych [Kosiński 2002].

Popularność sieci neuronowych wynika również w dużej mierze z ich specyficznych właściwości, których nie mają inne metody przetwarzania danych, a mianowicie:

- z równoległego przetwarzania funkcji,
- ze zdolności do uogólniania wiedzy,
- ze zdolności do uczenia się,
- ze zdolności do adaptacji i samoorganizacji.

Do najważniejszych zadań realizowanych przez modele neuronowe możemy zaliczyć:

- a) predykcję, czyli przewidywanie określonych danych wyjściowych na podstawie pewnych danych wejściowych, często także po ustaleniu związków łączących dane wyjściowe z wejściowymi. Szczególną zaletą sieci neuronowych jako narzędzia prognozującego jest fakt, że sieć w procesie uczenia może nabyć zdolność przewidywania sygnałów wyjściowych bez konieczności stawiania w sposób jawny hipotez o naturze związku pomiędzy danymi wejściowymi i przewidywanymi wynikami,

- b) klasyfikację i rozpoznawanie, czyli przypisywanie do odpowiednich klas różnych obrazów wejściowych,
- c) optymalizację, polegającą na poszukiwaniu rozwiązań prowadzących do optymalnych decyzji,
- d) analizę danych, polegającą na poszukiwaniu związków między danymi wejściowymi,
- e) filtrację sygnałów, polegającą na usuwaniu szumów, usuwaniu błędów systematycznych i redukcji informacji.

Celem pracy było wytworzenie, w oparciu o sztuczne sieci neuronowe, modeli neuronowych do predykcji poziomu sprzedaży wybranych produktów rolno-spożywczych. Celem utylitarnym natomiast była ocena wygenerowanych modeli pod względem ich efektywności w praktyce. W artykule omówiono otrzymane wyniki oraz przedstawiono wnioski odnośnie dalszych udoskonaleń proponowanych metod.

Metoda badawcza

Omówione wcześniej właściwości sieci neuronowych, jak również znane z literatury modele struktur sieciowych pozwalają na uzasadnione ich zastosowanie do prognozowania. Głównym celem pracy było sprawdzenie możliwości i skuteczności wytworzonych modeli neuronowych, które realizowano w oparciu o dwie metody. Pierwszą z nich było wytworzenie modeli neuronowych, w których wszystkie przypadki wejściowe były rozpatrywane jako zmienne niezależne. Modelowanie to odbywało się w oparciu o kilka rodzajów sieci, takich jak sieci radialne i perceptrony wielowarstwowe. Drugą metodą polegała na rozpatrywaniu danych wejściowych jako zmienne zależne. Proces analizy odbywał się przy użyciu szeregów czasowych również z wykorzystaniem sieci radialnych i perceptronów wielowarstwowych.

Wiadomym jest fakt, że procesy sprzedaży mają bardzo złożony charakter, trudne jest zatem wykonanie poprawnej prognozy. Na cały rynek oddziałuje szereg różnorodnych bodźców o charakterze makro- i mikroekonomicznym. Niektóre czynniki determinują zachowanie się danego rynku sprzedaży, inne są natomiast zakłóceniami. Szeregi czasowe charakteryzują się dużym udziałem składników deterministycznych i są łatwiejsze do prognozowania. Celem analizy szeregów czasowych jest ustalenie prognozy przyszłych wartości pewnej zmiennej (o wartościach zmieniających się w czasie). Najczęściej dążymy do wyznaczenia prognozy korzystając

z wcześniejszych wartości tej samej zmiennej, której wartość ma być przewidywana lub innych zmiennych, o których sądzimy, że mają wpływ na badaną zmienną.

Zwykle prognozowana zmienna jest ciągła, tak więc prognozowanie szeregów czasowych jest zwykle specjalizowaną formą regresji.

Do symulacji SSN użyto danych pozyskanych dzięki uprzejmości firmy Ziółopez, które były odzwierciedleniem rzeczywistej sprzedaży wybranego produktu w latach 1997–2004 w ujęciu miesięcznym.

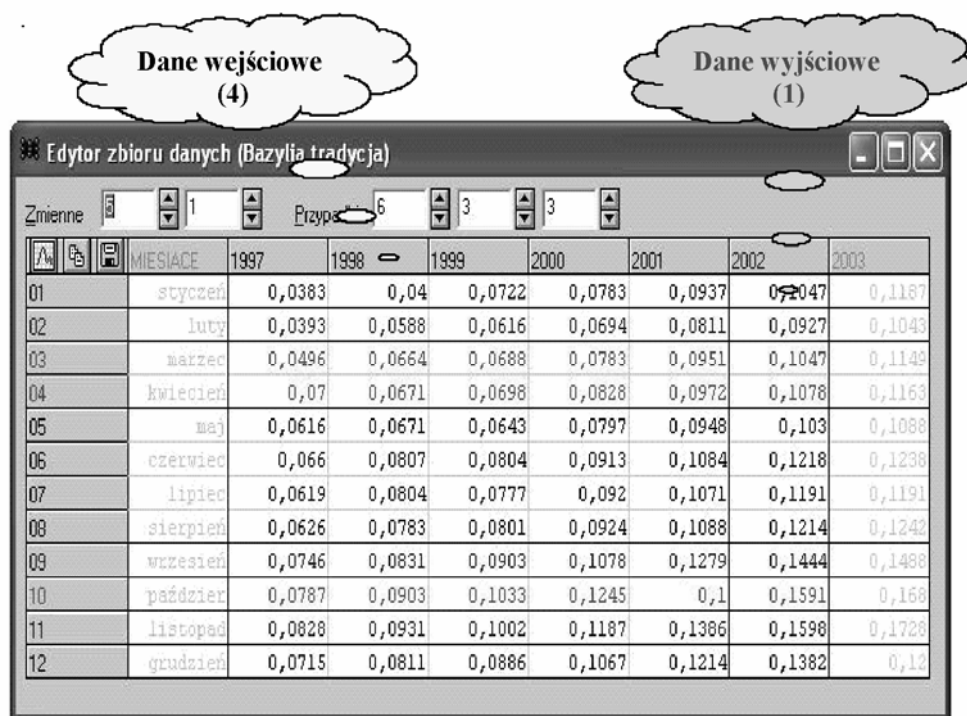
Zastosowanie różnych metod wytwarzania sieci neuronowych

Do zaprojektowania sztucznej sieci neuronowej zastosowano programowy symulator STATISTICA Neural Networks v. 4,0 firmy StatSoft Polska. Głównym problemem, z jakim borykają się wszyscy eksperymetatorzy zajmujący się stosowaniem sieci neuronowych do konkretnych zadań, jest odpowiednie przeprowadzenie procesu uczenia. Ogólnie można tu wskazać występowanie następujących problemów:

- dobór odpowiedniej wielkości zbioru uczącego, a następnie opracowanie metody mieszania danych podczas procesu uczenia,
- określenie wielkości współczynników uczenia i momentum,
- zdefiniowanie czasu uczenia, a tym samym wypracowanie kryteriów pozwalających na ocenę procesu uczenia [Tadeusiewicz 2001].

Symulacje dokonywane były na wielu topologiach sieci o zróżnicowanej liczbie neuronów. W pierwszej fazie dokonano modelowania metodą pierwszą, czyli wszystkie dane były rozpatrywane jako zmienne niezależne. Zbiór danych przedstawia rysunek 1.

Dokonano wyboru najlepszej sieci - był nią perceptron wielowarstwowy, który poddano procesowi uczenia. Proces nauki perceptronu przebiegał w oparciu o metodę uczenia z nauczycielem. Dobór wszystkich czynników, takich jak techniki uczenia oraz metody i czas poprzedzony był wieloma doświadczeniami i próbami. Najlepiej nadającymi się technikami do treningu sieci okazały się algorytmy: wstecznej propagacji błędów, quasi-newtona oraz Levenberga–Marquardta. Wszystkie wyniki, jakie otrzymano, czyli charakterystyka sieci i statystyki regresyjne, przedstawiono na rysunku 3.



Rys. 1. Edytor zbioru danych dla bazylii (metoda pierwsza)

Fig. 1. Data set editor for basil (first method)

Kolejnym krokiem było modelowanie metodą drugą, gdzie wszystkie przypadki rozpatrywane są jako zmienne zależne. Zbiór danych przedstawia rys. 2. Najlepszą siecią okazał się perceptron wielowarstwowy z ośmioma neuronami w warstwie ukrytej. Proces uczenia odbywał się również z wykorzystaniem algorytmów. Otrzymane statystyki i charakterystykę przedstawiono na rysunku 3.

Po zakończeniu procesu uczenia dokonano sprawdzenia efektywności otrzymanych sieci neuronowych. Weryfikacji dokonano poprzez generowanie prognozy i porównywanie wyników ze sprzedażą lat 2003 i 2004 do kwietnia włącznie. Wyższą jakość przetwarzania, czyli zgodność wyników otrzymanych z predykcji w odniesieniu do sprzedaży rzeczywistej, otrzymano dla metody drugiej, czyli z modelowaniem przy zastosowaniu szeregów czasowych. Średni błąd procentowy w skali roku wyniósł 5%. Pozytywny rezultat odnotowano również dla drugiej metody, jednak średni błąd procentowy w skali roku był wyższy i wyniósł 14%.

Zmienne	Przypadki	DATA	ILOŚĆ
1	42	02-sty	0,1047
1	21	02-lut	0,0927
1	21	02-mar	0,1047
1	21	02-kwi	0,1078
1	21	02-maj	0,103
1	21	02-cze	0,1218
1	21	02-lip	0,1191
1	21	02-sie	0,1214
1	21	02-wrz	0,1444
1	21	02-paź	0,1591
1	21	02-lis	0,1598
1	21	02-gru	0,1382
1	21	03-sty	0,1187
1	21	03-lut	0,1043
1	21	03-mar	0,1149
1	21	03-kwi	0,1163
1	21	03-maj	0,1088
1	21	03-cze	0,1238
1	21	03-lip	0,1191
1	21	03-sie	0,1242
1	21	03-wrz	0,1488
1	21	03-paź	0,168
1	21	03-lis	0,1728
1	21	03-gru	0,12

Rys. 2. Edytor zbioru danych dla bazylii (metoda druga)

Fig. 2. Data set editor for basil (second method)

CHARAKTERYSTYKA SIECI	TYP SIECI	Iloraz odchylenia	Korelacja	Błąd uczący	Błąd testowy	Błąd walidacyjny
Perceptron wielowarstwowy (1)	MLP	0,1012608	0,9953881	0,0018	0,0104	0,0017
Perceptron wielowarstwowy (Szereg czasowy)(2)	MLP	0,09612	0,9997672	0,0007	0,0081	0,0009

Rys. 3. Statystyki regresyjne i jakościowe dla otrzymanych sieci

Fig. 3. Regressive and qualitative statistics for the networks obtained

Uwagi końcowe i wnioski

1. Opracowane i pozytywnie zweryfikowane neuronowe modele prognoz sprzedaży wybranych płodów rolnych potwierdziły sformułowany na wstępie pracy postulat, dotyczący możliwości efektywnego wykorzystania sztucznych sieci neuronowych do rozwiązywania postawionych zadań.
2. Wykorzystane narzędzie symulacyjne pozwala na wytworzenie efektywnych modeli neuronowych, opisujących proces dystrybucji wybranych produktów rolniczych.
3. Potwierdzono, że sztuczne sieci neuronowe stanowią skuteczne wsparcie w procesie podejmowania decyzji dotyczących planowania produkcji oraz sprzedaży.
4. Najlepsze wyniki zapewniła sztuczna sieć neuronowa typu perceptron wielowarstwowy uczona z wykorzystaniem szeregów czasowych.
5. Otrzymane proste topologie sieci MLP charakteryzują się dużą szybkością działania, ale generowane przez nie wyniki obarczone są pewnymi błędami. Skłania to do dalszych poszukiwań bardziej adekwatnych struktur sztucznych sieci neuronowych.

Bibliografia

- Bubnicki Z. 1990. Wstęp do systemów ekspertowych, Państwowe Wydawnictwo Naukowe, Warszawa.
- Chromiec J., Strzemieczna E. 1995. Sztuczna inteligencja. Metody konstrukcji i analizy systemów eksperckich, Akademicka Oficyna Wydawnicza PLJ, Warszawa.
- Duch W., Korbicz J., Rutkowski L., Tadeusiewicz R. 2000. Sieci neuronowe. Akademicka Oficyna Wydawnicza EXIT, Warszawa.
- Kosiński R. 2002. Sztuczne sieci neuronowe. WNT, Warszawa.
- Minsky, M. S. 1969. Papert „Perceptrons”, MIT Press, Cambridge.
- Mulawka Jan 1996. Systemy ekspertowe, Wydawnictwo Naukowe- Techniczne, Warszawa.
- Osowski S. 1996. Sieci neuronowe w ujęciu algorytmicznym. WNT, Warszawa.

Osowski S. 2000. Sieci neuronowe do przetwarzania informacji. Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa.

Stateczny A. Praczyk T. 2002. Sztuczne sieci neuronowe w rozpoznawaniu obiektów morskich. Gdańskie Towarzystwo Naukowe, Gdynia.

Tadeusiewicz R. 1993. Sieci neuronowe. Akademicka Oficyna Wydawnicza, Warszawa.

Żurada J., Barski M. 1996. Sztuczne sieci neuronowe. Wydawnictwo Naukowe PWN, Warszawa.

**ASSESSMENT OF EFFECTIVENESS
OF THE NEURAL PREDICTION BASED
ON SELECTED METHODS EXEMPLIFIED BY DISTRIBUTION
OF AGRICULTURAL PRODUCTS**

Summary

Prediction becomes a very important stage in many activities. In case of distributing agricultural products we deal with a number of stimuli which consequently transform into the end effect. It is clear that the quality of those predictions has a great influence on subsequent stages in the production and distribution chain. Neural networks are a sophisticated technique of modeling capable of reflecting very complex functions. Modeling using artificial neural networks is used when exact mathematical description of investigated phenomenon is not known but its inputs and outputs are well defined. Artificial neural network can learn to recognize the problem analyzed giving an answer to changing input parameters. In the paper two methods of neural modeling of a chosen agricultural product distribution were presented.

Key words: artificial intelligence, artificial neural networks, prediction, time series