



## SZTUCZNA INTELIGENCJA WE WSPOMAGANIU PROCESU PROGNOZOWANIA W PRZEDSIĘBIORSTWIE

*Tadeusz A. Grzeszczyk, Politechnika Warszawska,  
Instytut Organizacji Systemów Produkcyjnych*

Autor bada zintegrowane systemy sztucznej inteligencji, m.in. służące wspomaganie procesu prognozowania w przedsiębiorstwie. Zgodnie z przyjętymi założeniami systemy te powinny umożliwiać zastosowanie zróżnicowanych, komplementarnych metod do analizy ilościowych i jakościowych parametrów. W artykule rozważa się możliwość wykorzystania sieci neuronowej do modelowania szeregu czasowego oraz do integracji wyników takiej analizy ilościowej z atrybutami decyzyjnymi wyznaczanymi z bazy wiedzy zawierającej ekspercką ocenę jakościową. Atrybuty decyzyjne wynikające z analizy jakościowych informacji zapisanych w bazie wiedzy mogą modyfikować prognozy ilościowe z punktu widzenia trudnych do ilościowego opisu czynników. Uzyskane w wyniku integracji prognozy kombinowane są dokładniejsze niż prognozy ilościowe wyznaczone za pomocą pojedynczych sieci neuronowych.

### Wprowadzenie

Jak wiadomo, do prognozowania (predykcji, przewidywania) najczęściej wykorzystuje się, znane od wielu lat i bardzo rozpowszechnione, metody statystyczne [Dittmann 2004]. Niekiedy prognozy są oparte na opiniach doświadczonych i obdarzonych dużą intuicją ekspertów. Oba te podejścia nie gwarantują jednak minimalizacji błędów prognozy. Niekiedy, zależnie od potrzeb, stosuje się większą liczbę zróżnicowanych metod, zaliczanych do jednej lub obu wymienionych rodzajów. W efekcie ostateczna prognoza jest najczęściej wyznaczana jako średnia prosta lub średnia ważona prognoz cząstkowych (tzw. prognoza kombinowana).

W procesie prognozowania mogą być przydatne instrumenty sztucznej inteligencji. Sztuczna inteligencja stanowi dziedzinę informatyki, której przedmiotem jest zarówno poszukiwanie nowych dziedzin zastosowań komputerów, jak również nowych metod ich programowania oraz nowych metod rozwiązywania zadań przez komputery [Stefanowicz 1993]. Wśród narzędzi analiz szeregów czasowych znajdują się m.in. sztuczne sieci neuronowe (ang. *artificial neural network*), np.: [Duch, Korbicz, Rutkowski, Tadeusiewicz 2000], [Witkowska 2002]. Eksperymentatorzy posługujący się pojedynczymi sieciami neuronowymi, w wielu doświadczeniach, uzyskują efekty lepsze niż w przypadku



zastosowania innych metod statystycznych. Występują jednak badania, które dowodzą, że niekiedy walory tych ostatnich metod przeważają nad korzyściami, wynikającymi z zastosowania pojedynczych sieci neuronowych (np. [Tang, Almeida, Fishwick 1991]). Nie ulega wątpliwości, że wszystkie wymienione wyżej rodzaje metod nie sprawdzają się, gdy występują różne nietypowe sytuacje, np. w przypadku podjęcia dużej kampanii reklamowej, promocji określonego towaru lub usługi itp.

Jednym z możliwych rozwiązań tego problemu może być formułowanie prognoz w oparciu o zarówno ilościowe, jak i jakościowe metody prognozowania. Celowe jest wykorzystywanie zintegrowanych (zespolonych) metod prognozowania, bazujących na ilościowych analizach danych historycznych oraz na subiektywnych ocenach ekspertów (przedsiębiorców). Atrybuty decyzyjne wynikające z analizy jakościowych informacji zapisanych w bazie wiedzy mogą modyfikować prognozy ilościowe z punktu widzenia trudnych do ilościowego opisu czynników. Uzyskane w wyniku integracji prognozy kombinowane są zwykle dokładniejsze niż prognozy ilościowe.

W przypadku (tworzonych dla różnych zastosowań) metod zintegrowanych (hybrydowych) łączy się różne podejścia tak, aby funkcjonowały w jednym spójnym systemie, np. [Lingras 1998], [Sankar, Polkowski, Skowron 2004], [Szczuka 1998], [Kuo 2001]. Umiejętna integracja kilku metod, w celu stworzenia jednej zintegrowanej metody prognozowania, pozwala na przejmowanie najlepszych cech pojedynczych systemów oraz na eliminowanie ich wad.

Autor zdecydował się na badanie zespolonych systemów równoległych, które charakteryzują się niezależnym działaniem wchodzących w jego skład różnych podsystemów, wśród których mogą występować podsystemy analizy zarówno ilościowej, jak i jakościowej. Dużą zaletą zespolonych systemów (zarówno szeregowych, jak i równoległych) jest możliwość kolejnej indywidualnej realizacji stosunkowo prostych podsystemów. Umożliwia to łatwiejszą realizację w porównaniu z systemami hybrydowymi (w których nie można wyodrębnić podsystemów funkcjonujących tylko w jeden określony sposób).

Stosowanie zespolonych systemów równoległych pozwala na równoległą analizę danych pochodzących z niezależnych od siebie źródeł. Źródła te mogą mieć również odmienny charakter, tzn. ilościowy i jakościowy. W rozpatrywanym przykładzie wyniki ilościowe oznaczają konkretne wartości sprzedaży. Natomiast jakościowa analiza może się opierać np. na opiniach ekspertów.

Dzięki równoległemu połączeniu obu podsystemów można wykorzystywać dwie, nawet całkowicie różne, metody analizy, np. sieci neuronowe oraz metodę wykorzystującą teorię zbiorów przybliżonych (szerzej na ten temat w pracach: [Grzeszczyk 2000, 2005]). Końcowy wynik uzyskuje się w procesie integracji wyników dwóch podsystemów. W najprostszym przypadku proces integracji może polegać na wyznaczeniu średniej ważonej ilościowych wyników obu podsystemów. Dotyczyć to jednak może wyłącznie podsystemów analizy ilościowej. W rozpatrywanym przypadku zdecydowano się na użycie sieci neuronowej. Jest to niezbędne, ponieważ integrowane wyniki mają różny charakter. Z jednej strony bowiem jest to konkretna ilościowa prognoza. Z drugiej natomiast występują wartości jakościowych atrybutów decyzyjnych korygujących (modyfikujących) wyniki ilościowe. Te jakościowe atrybuty są istotne tylko w nietypowych przypadkach (np. wystę-



powania promocji sprzedaży). Natomiast w sytuacjach typowych wynik analizy ilościowej jest wystarczający dla konstruowania prognoz, bez konieczności dokonywania korekt.

Autor badał modele prognostyczne zbudowane na bazie różnego rodzaju sieci. Do porównywania ze sobą wyników uzyskanych za pomocą stworzonych modeli, zbudowanych przy wykorzystaniu pojedynczych sieci neuronowych oraz otrzymanych na wyjściu zespolonego systemu prognostycznego, stosował (oprócz jakościowych zestawień w postaci wykresów) ilościowe parametry zapewniające obiektywną konfrontację uzyskanych rezultatów. Do wykorzystanych w badaniach ilościowych miar jakości modeli neuronowych należały między innymi: statystyki regresyjne, błąd średniokwadratowy oraz średnie błędy względne, prognoz jedno- i pięciodniowych. Prognozy pozorne, wyznaczone za pomocą zintegrowanego systemu predykcji, charakteryzowały się znacznie mniejszymi błędami w porównaniu z błędami występującymi dla predykcji obliczanych przy użyciu pojedynczych sieci neuronowych. Uzyskane rezultaty eksperymentów potwierdziły przypuszczenia autora o możliwości oraz celowości zastosowania zintegrowanych metod sztucznej inteligencji w procesie prognozowania w przedsiębiorstwie.

Celem prowadzonych badań jest poszukiwanie zintegrowanych metod krótkookresowego prognozowania w przedsiębiorstwie, bardziej efektywnych od pojedynczych sieci neuronowych. W szczególności eksperymenty dotyczą integracji wyników neuronowej analizy ilościowej z atrybutami decyzyjnymi eksperckiej oceny jakościowej uzyskanymi przy zastosowaniu metody zbiorów przybliżonych. W artykule krótko scharakteryzowano wyniki badań sieci neuronowych wykorzystywanych do ilościowej analizy szeregów czasowych oraz do łączenia (kombinacji) prognoz budowanych metodami ilościowymi z atrybutami decyzyjnymi wynikającymi z analizy wiedzy eksperckiej zapisanej w regułowej bazie wiedzy.

Autor ograniczył rozważania do związanej charakterystyki pojedynczych sieci neuronowych wykorzystywanych do modelowania szeregów czasowych oraz oceny możliwości zastosowania sieci neuronowych do budowy prognoz kombinowanych. Szczegółowe wyniki badań metody zbiorów przybliżonych mogącej być instrumentem służącym do zapisywania doświadczeń praktyków i ekspertów w formie reguł decyzyjnych opartych na materiałach empirycznych i umożliwiając stosunkowo łatwe przetwarzanie jakościowych informacji zaprezentowano w [Grzeszczyk 2005]. Teoria zbiorów przybliżonych została zaproponowana w pracy [Pawlak 1982]. Za pomocą algorytmów, wynikających z tej teorii, można zbudować regułową bazę wiedzy uwzględniającą ważne zależności między atrybutami warunkowymi a decyzyjnymi. Te ostatnie pozwalają uwzględniać wpływ czynników nietypowych dla danego systemu pominiętych w analizie ilościowej, a silnie wpływających na prognozowaną wielkość (np. sprzedaż) w stosunkowo krótkim okresie.

## Neuronowe modelowanie szeregu czasowego

W procesie prognozowania szeregu czasowego może być zastosowana dowolna sieć neuronowa, akceptująca na wejściu wektory o wartościach rzeczywistych oraz wytwarzająca na wyjściu również sygnał o wartościach rzeczywistych.


W badaniach zastosowano następujące rodzaje sieci:

- ♦ liniowe,
- ♦ jednokierunkowe trójwarstwowe (inaczej: perceptrony) – MLP (ang. *Multilayer Perceptron*),
- ♦ o radialnych funkcjach bazowych – RBF (ang. *Radial Basis Function*),
- ♦ realizujące regresję uogólnioną – GRNN (ang. *Generalized Regression Neural Networks*).

Najprostsza struktura sieci neuronowej ma tylko jedno wyjście oraz jedno albo więcej wejść. Niezależnie od typu sieci liczba neuronów wejściowych i wyjściowych jest jednaka dla danych warunków. Zazwyczaj warstwa wyjściowa składa się z jednego neuronu (odpowiadającego zmiennej objaśnianej). Liczba neuronów w warstwie wejściowej wynika z przyjętego tzw. rzędu prognozy, czyli liczby analizowanych zjawisk poprzedzających prognozę. Wątpliwości związane z wyborem architektury dotyczą tylko warstw ukrytych sieci (tzn. liczby tych warstw oraz liczby neuronów występujących w tych warstwach).

Do określania rzędu szeregu czasowego (czyli liczby neuronów wejściowych) wykorzystywano algorytm genetyczny. Analizowano za jego pomocą różne chromosomy (o długości równej maksymalnej liczbie zmiennych objaśniających), uzyskując w efekcie liczbę wejść sieci neuronowych wykorzystywanych do predykcji.

Dla sieci liniowych nie ma potrzeby określania architektury sieci, ponieważ nie występuje w ich przypadku warstwa ukryta. Sieci typu RBF oraz GRNN mają ściśle określoną liczbę warstw. RBF ma zawsze trzy warstwy, a GRNN odpowiednio składa się z czterech warstw. Perceptrony mogą być zbudowane praktycznie z dowolnej liczby warstw.



Rys. 1. Prognozowanie szeregu czasowego (źródło: [Masters 1996])

Zastosowane w badaniach ilościowe prognozowanie polega na określaniu wartości jednowymiarowego szeregu czasowego. Schematycznie przedstawiono to na rys. 1. Zobrazowano przykładowe wykorzystanie sześciu kolejnych punktów szeregu czasowego – aby w efekcie uzyskać kolejny, dotychczas niewiadomy. Sieć neuronowa powinna najpierw



zgrupować wiedzę na etapie nauki. W kolejnym etapie, w oparciu o zgromadzoną wiedzę, może być wykorzystywana do rozwiązywania zadań prognostycznych. Proces uczenia się sieci przeprowadza się metodą licznych prób. Każda z nich obejmuje siedem punktów, tzn. począwszy od punktu bieżącego (opóźnienie zero), następnie obejmuje pięć punktów odwzorowujących stan z przeszłości (opóźnienie od jednego do pięciu) oraz kończąca na prognozowanym punkcie z przyszłości.

Po przygotowaniu (wstępnej analizie) danych, zaprojektowaniu architektury sieci i po jej nauczaniu należy dokonać oceny stworzonego modelu szeregu czasowego. Ewaluacji modeli predykcyjnych jest poświęcony następny punkt.

## Ocena neuronowych modeli prognostycznych

Jakościowej oceny neuronowych modeli predykcyjnych można dokonać, porównując wykresy: rzeczywisty i prognozowany. Jest to często spotykana w literaturze metoda prezentacji wyników badań. Jednak dopiero ilościowe metody oceny modeli neuronowych umożliwiają formułowanie bardziej obiektywnych wniosków.

Zasadniczo ocenę modeli neuronowych przeprowadza się dwuetapowo. W pierwszej fazie, po skonstruowaniu nauczonych sieci, do ich oceny zalecane są [Statsoft 2001] tzw. statystyki regresyjne. W drugiej fazie, po nauczaniu sieci, przeprowadza się proces prognozowania. Uzyskuje się zatem, oprócz wartości rzeczywistych, także predykcje zmiennej wyjściowej modelu. Pozwala to na wyznaczenie błędów *ex post*.

Do statystyk regresyjnych, służących do oceny modeli, po nauczaniu sieci, należą m.in. następujące parametry:

- ◆ średnia (arytmetyczna) wyznaczona na podstawie rzeczywistych wartości prognozowanej wielkości,
- ◆ odchylenie standardowe, obliczone dla rzeczywistych danych,
- ◆ średni błąd – przeciętna wartość różnic między wartościami prognozowanymi i rzeczywistymi,
- ◆ standardowe odchylenie błędów dla zmiennej prognozowanej,
- ◆ średni błąd bezwzględny (średnia z wartości bezwzględnych różnic, wartości przewidywanych przez model oraz wartości rzeczywistych),
- ◆ iloraz odchyłeń standardowych – iloraz standardowego odchylenia błędów i odchylenia standardowego rzeczywistych danych (obu parametrów określonych wyżej),
- ◆ korelacja (właściwie standardowy współczynnik korelacji R Pearsona) – wyznaczony dla wartości rzeczywistych i wartości przewidywanych.

Największe znaczenie dla oceny jakości modeli neuronowych mają: iloraz odchyłeń standardowych oraz korelacja wartości rzeczywistych i prognozowanych. Ten pierwszy parametr dla stworzonych modeli powinien przyjmować wartości rzędu 0,1...0,2. Iloraz odchyłeń o wartości bliskiej zeru świadczy o dobrej jakości opracowanego modelu. Jeżeli

jest on większy od jedności (lub jej bliski), to zaprojektowany model można odrzucić. Trudno jest wyrokować w przypadku ilorazu odchyłeń na poziomie z przedziału: 0,3...0,7. Ostatecznie jakość modelu zależy bowiem od uzyskanych błędów *ex post*, a ściślej mówiąc od tego, czy są one do zaakceptowania w danym przypadku.

Korelacja wartości rzeczywistych i prognozowanych przyjmuje wartości z przedziału od 0 do 1. Najlepiej jest, gdy jest ona zbliżona do jedności (im bliżej, tym lepiej).

Dokładniejszy opis i definicje podanych wyżej parametrów statystycznych (uwzględniający specyfikę pakietu komputerowego *STATISTICA* firmy Statsoft) można znaleźć np. w [Statsoft 2001], [<http://www.statsoft.com/textbook/glosr.html>]. Jeżeli ten zestaw uniwersalnych mierników okaże się dla badacza niewystarczający może na własny użytek, określić inne parametry statystyczne.

Dla lepszej oceny jakości uzyskanego modelu wyżej określone parametry regresyjne należy wyznaczać osobno dla wszystkich podzbiorów uzyskanych z podziału całkowitego zbioru danych. Porównywanie ich ze sobą daje dodatkowe informacje o skonstruowanych modelach (zobacz dalszą część tego punktu).

Z wcześniejszych rozważań dotyczących weryfikacji przeprowadzonej prognozy wynika, że w przypadku wyznaczania predykcji szeregów czasowych właściwym miernikiem, określającym jakość modelu prognostycznego, są błędy typu *ex post*. Do ich wyliczenia trzeba dysponować parami wartości: rzeczywistych i wyznaczonych za pomocą danego modelu. Do najczęściej stosowanych miar jakości modeli neuronowych można zaliczyć [Lula 2000]:

- ◆ sumę kwadratów reszt (ang. *Sum Squares Error*) –  $SSE = \sum_{t=1}^n (x_t - x_t^*)^2$ ,
- ◆ błąd średniokwadratowy (ang. *Mean Squares Error*) –  $MSE = SSE/n$ ,
- ◆ pierwiastek z błędów średniokwadratowych (ang. *Root Mean Squares Error*) –  $RMSE = \sqrt{MSE}$ .

Powyżej określone miary jakości błędów predykcyjnych modeli neuronowych zostały wykorzystane w fazie eksperymentów. Podczas tych badań zbiór danych empirycznych był dzielony na trzy podzbiory: uczący, walidacyjny oraz testowy. Porównania błędów, wyznaczonych dla poszczególnych podzbiorów, dawało dopiero pewną informację o jakości opracowanych modeli. Wartości błędów SSE (sumy kwadratów reszt) najczęściej wykorzystywano w procesie uczenia sieci, do bieżącej weryfikacji jakości tworzonego modelu. Wartość SSE dla zbioru walidacyjnego zapewniała natomiast najczęściej informację o właściwym momencie do przerwania procesu uczenia sieci. Wzrost błędów dla podzbioru walidacyjnego oznaczał bowiem z reguły spadek możliwości sieci do uogólniania nabytej wiedzy (wzrost prawdopodobieństwa ryzyka wystąpienia tzw. przeuczenia sieci). Podzbiór testowy gwarantował końcowe badania potwierdzające praktyczną użyteczność (bądź jej brak) dla danego modelu neuronowego.



Ważnymi parametrami służącymi do ilościowej oceny neuronowych modeli predykcyjnych są względne i bezwzględne błędy prognoz. W przypadku postawy pasywnej (charakterystycznej dla analizy szeregów czasowych) typowym rozwiązaniem jest weryfikacja prognozy za pomocą błędów *ex post*. Poniżej przedstawiono zależności służące do wyznaczania tego typu błędów [Dittmann 2004].

We wzorach przyjęto następujące oznaczenia:

$x_t$  – rzeczywista wartość zmiennej prognozowanej  $X$  w momencie  $t$ ,

$x_t^*$  – prognoza zmiennej  $X$  w momencie  $t$ ,

$n$  – numer ostatniej obserwacji zmiennej prognozowanej,

$T$  – numer ostatniego momentu, dla którego była wyznaczana prognoza (horyzont prognozy).

1. Bezwzględny błąd prognozy *ex post* dla momentu  $t$ :

$$\Delta_t^* = x_t - x_t^*.$$

2. Względny błąd prognozy *ex post* dla momentu  $t$ :

$$\delta_t^* = \frac{x_t - x_t^*}{x_t} 100\%.$$

3. Średni względny błąd prognoz *ex post* dla momentów  $n+1, \dots, T$ :

$$\delta^* = \frac{1}{T-n} \sum_{t=n+1}^T \frac{|x_t - x_t^*|}{x_t} 100\%.$$

Przyjęcie analizy błędów *ex post* jest równoznaczne z oczywistym stwierdzeniem, że wszelkie oceny trafności prognoz są związane z porównywaniem wartości przewidywanej z rzeczywistą. W badaniach wyznaczano bardzo użyteczne w praktyce tzw. prognozy pozorne (lub próbne). Błędy *ex post* obliczone dla prognoz pozornych pozwalają na ocenę wybranej metody prognozowania oraz na jej weryfikację.

Więcej informacji na temat sieci neuronowych, ich modelowania i zastosowań można znaleźć w obszernej literaturze: np. [Azoff 1994], [Duch, Korbicz, Rutkowski, Tadeusiewicz 2000], [Lula 1999], [McNelis 2005], [Tadeusiewicz 1993], [Zhang 2004] i innych.

## Badania wybranych metod prognozowania

Empiryczną weryfikację przydatności wybranych metod prognozowania przeprowadzono na podstawie rzeczywistych danych dużego przedsiębiorstwa handlowego. Dane te były uformowane w szereg czasowy, opisujący wolumen dziennej sprzedaży jednego produktu przez okres około jednego roku. W badanym okresie przedsiębiorstwo kilka razy



realizowało różnego rodzaju akcje promocyjne i reklamowe, które silnie oddziaływały na wielkość jego sprzedaży.

W procesie weryfikacji (zarówno podsystemu ilościowego, jak i podsystemu integrującego prognozę ilościową z jakościowymi atrybutami decyzyjnymi) zastosowano program *STATISTICA Sieci Neuronowe* opracowany przez firmę Statsoft. Program ten wybrano, gdyż jest odpowiednim narzędziem do rozwiązywania zarówno problemów klasyfikacyjnych, dla których zmienna wyjściowa jest wartością nominalną – jak również do analizy problemów regresyjnych, gdzie na wyjściu znajduje się ciągła zmienna liczbowa. Badane przez autora szeregi czasowe są szczególnym przypadkiem zagadnień regresyjnych. W związku z tym – przy użyciu programu *STATISTICA Sieci Neuronowe* – budowano modele sieci do rozwiązywania problemów tego typu. Bardzo pomocna przy przeprowadzaniu badań była starannie i zrozumiale przygotowana dokumentacja [Statsoft 2001].

W przypadku neuronowego prognozowania szeregu czasowego wyznaczano przewidywane wartości zmiennej prognozowanej na podstawie określonej liczby wartości poprzedzających. Do podstawowych problemów z tym związanych należało więc:

- ◆ wstępna analiza danych,
- ◆ określenie horyzontu prognozy,
- ◆ wybór liczby wartości poprzedzających predykcję,
- ◆ określenie typu sieci,
- ◆ wybranie struktury sieci (tzn. ilości warstw oraz liczby neuronów w tych warstwach),
- ◆ uczenie, walidacja oraz testowanie sieci,
- ◆ ocena zastosowanego modelu,
- ◆ podjęcie decyzji o zakończeniu konstruowania modelu bądź o dalszym poszukiwaniu lepszych rozwiązań.

Badania przeprowadzono dla dwóch wartości horyzontów prognozy: jednego oraz pięciu dni. Przewidywania dla jednodniowego horyzontu prognozy umożliwiły wstępną orientację odnośnie jakości opracowanego modelu. Predykcje pięciodniowe, ze względu na efekt kumulowania się błędów prognoz, wyraźnie określały, czy z uwagi na wielkość osiągniętego ostatecznie średniego błędu prognoz dany model jest użyteczny w praktyce.

Wybór liczby wartości, poprzedzających predykcję, dokonywany był doświadczalnie, aż do uzyskania najmniejszych wartości błędów prognoz. Podjęto również próby wykorzystania do tego celu algorytmu genetycznego.

W badaniach uwzględniono cztery typy sieci: liniowe, MLP, RBF oraz GRNN. Użycie sieci liniowych, będących analogią do liniowej funkcji regresji, stanowiło dogodny punkt odniesienia dla dalszych analiz szeregu czasowego z użyciem innych, bardziej złożonych modeli. Z kolei na perceptrony trójwarstwowe autor zdecydował się ze względu na ich uniwersalne możliwości, prostotę zastosowania oraz duże prawdopodobieństwo uzyskania sensownych rezultatów. Pozostałe typy sieci zastosowano w poszukiwaniu lepszego

rozwiązania. Nie było bowiem przesłanek sugerujących ich odrzucenie, a ewentualne korzyści (np. krótki czas uczenia) zachęcały do eksperymentów.

Liczba neuronów w warstwie wejściowej wynikała z przyjętej liczby wartości poprzedzających predykcję. Ze względu na charakter rozwiązywanego problemu, tzn. prognozowanie jednowymiarowego szeregu czasowego, w warstwie wyjściowej każdej sieci znajdował się jeden neuron. Struktury zastosowanych sieci wynikały z zasad ich funkcjonowania (dla sieci liniowej - dwie, dla sieci RBF - trzy, natomiast dla sieci GRNN - cztery). W przypadku sieci MLP zdecydowano, że nie będą badane sieci o większej złożoności niż trzy warstwy. W większości zagadnień praktycznych perceptron trzywarstwowy zapewnia bowiem wystarczające dobre wyniki, a zwiększanie złożoności sieci pociągałoby za sobą wydłużanie czasu uczenia oraz zwiększanie ryzyka tzw. przeuczenia itp.

Do badań empirycznych dobrano podziały na podzbiory danych: uczący, walidacyjny i testowy. Skutkowało to uzyskiwaniem dobrych rezultatów np. dobrą generalizacją wiedzy oraz względnie małymi błędami prognoz.

Do weryfikacji opracowanych modeli neuronowych wykorzystywano statystyki regresyjne oraz analizę błędów scharakteryzowaną w poprzednim punkcie.

W ramach wstępnych eksperymentów przeprowadzono badania związane z opracowywaniem modeli do weryfikacji przydatności do predykcji szeregu czasowego pojedynczych sieci neuronowych. Wszystkie badane i oceniane pod kątem rozwiązywania zagadnień regresyjnych modele charakteryzowały się złymi parametrami dla badanego w pracy szeregu czasowego (szczegóły [Grzeszczyk 2005]). Stanowi to wstępne potwierdzenie założenia badawczego o braku możliwości wyznaczania predykcji dla szeregu czasowego (jeżeli występują nietypowe zjawiska – w tym przypadku promocja) za pomocą pojedynczych sieci neuronowych realizujących wyłącznie analizę ilościową.

Tabela 1. Statystyki regresyjne oraz błędy charakteryzujące pojedynczą sieć neuronową typu MLP (6–10–1) dla prognoz jedno- i pięciodniowych (źródło: badania własne).

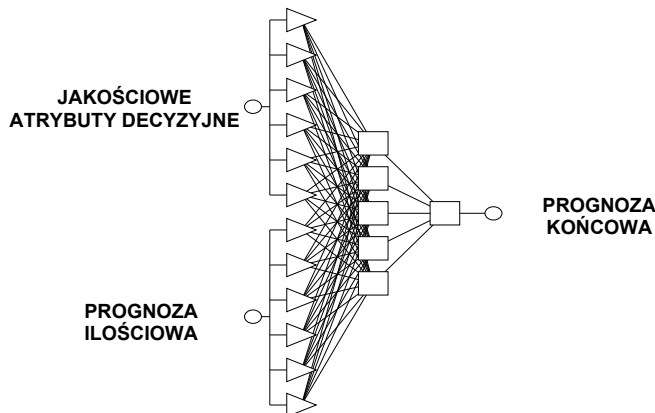
	Prognozy jednodniowe	Prognozy pięciodniowe
Średnia	12,79744	13,60029
Odch. std.	6,129125	5,894798
Średni błąd	0,5265765	-0,089419
Odch. Błędu	3,294956	5,260516
Śr. bł. bezwz.	2,323691	4,218117
Iloraz odch.	0,53759	0,8923998
Korelacja	0,8432271	0,464079
RMSE	3,295	5,186
MSE	10,86	26,89
SSE	423,54	941,15
Średni błąd względny	28,77%	35,62%

Ostateczne wykazanie słuszności przyjętych założeń może jednak być dokonane po wyznaczeniu konkretnych wartości prognoz pozornych oraz obliczeniu błędów (czyli przeprowadzeniu weryfikacji przeprowadzonej prognozy). Wielkości tych błędów (tabela 1) po zestawieniu ich z błędami uzyskanymi dla prognoz realizowanych za pomocą konkurencyjnej metody zintegrowanej (zespolonej – równoległej), stanowiły podstawę do formułowania wniosków oraz podsumowań.

Z przedstawionych wyników badań widać, że w pewnych przypadkach jest niecelowe zastosowanie do prognozowania szeregu czasowego pojedynczych sieci neuronowych (realizujących wyłącznie analizę ilościową).

Parametry regresyjne, uzyskane dla sieci MLP (rys. 2.) wykorzystywanej w procesie integracji wyników ilościowych oraz wartości wynikających z analizy jakościowej, zaprezentowano w tabeli 2 oraz 3.

Zgromadzone w tabeli 2 wyniki są, tak jak w przypadku wszystkich przeprowadzonych badań, podzielone na trzy części odpowiadające odpowiednim podzbiорom danych wykorzystywanych w procesie tworzenia modelu. Zbliżone wartości parametrów zapisane w trzech kolumnach świadczą o dobrej zdolności tej sieci zarówno do aproksymacji (zobacz wyniki dla podzbioru uczącego) jak i generalizacji (zbiór walidacyjny i testowy).



Rys. 2. Schemat sieci integracyjnej (MLP 12 – 5 – 1) wykorzystanej do predykcji zespolonej (źródło: badania własne)

Przynależność do poszczególnych podzbiorów została wybrana drogą losowania. Wartości średnie (wyliczone jako średnie arytmetyczne dla tych trzech podzbiorów) mają podobne wartości. Można zatem mieć zaufanie do uzyskanych wyników (trzy podzbiory są porównywalne).

Średni błąd bezwzględny został wyznaczony (w przeciwieństwie do powyżej opisanego błędu) przy obliczaniu wartości bezwzględnych z różnic między wartościami teoretycznymi (danymi) a wartościami uzyskanymi na wyjściu modelu. Stosunkowo niewielkie

średnie (rzędu 1,2 ... 1,4) wyznaczone z modułów różnic dobrze świadczą o opracowanym modelu.

Tabela 2. Parametry regresyjne podsystemu integracyjnego po procesach: uczenia, walidacji oraz testowania (źródło: badania własne).

	Uc. VAR1	Wa. VAR1	Te. VAR1
Średnia	13,0763	14,02207	13,43357
Odch. std.	5,214087	6,293788	5,715262
Średni błąd	0,2244212	-0,1436	0,2999298
Odch. błędu	1,642225	1,889649	1,855863
Śr. bł. bezwz.	1,279551	1,486854	1,43317
Iloraz odch.	0,3149592	0,3002403	0,3247205
Korelacja	0,949176	0,9549971	0,9470425

Odchylenie standardowe (pierwiastek z wariancji) również wyznaczono dla wartości rzeczywistych pochodzących z trzech podzbiorów. Samo w sobie nie stanowi ono miernika istotnie charakteryzującego opracowany model. Zostało jednak wykorzystane w dalszych obliczeniach.

Średni błąd (różnic) między wartościami rzeczywistymi i wyznaczonymi za pomocą modelu ma stosunkowo małą wartość (rzędu 0,2 dla podzbiorów: uczącego i testowego). Z tych różnic wartości nie obliczano wartości bezwzględnych. Z tego wynika ujemna wartość tego parametru dla podzbioru walidacyjnego.

Odchylenia standardowe szeregów błędów (rzędu 1,6...1,8) świadczą o niedużym odchyleniu się wartości błędów od średniej. Ten parametr jest istotny z punktu widzenia wyznaczania ważnego miernika modelu - ilorazu odchyień.

Ostatnie dwa parametry (z tabeli 2) ostatecznie potwierdzają dobrą jakość stworzonego modelu MLP. Iloraz odchyień standardowych (błędów i danych) dla trzech podzbiorów – z dokładnością do pierwszego miejsca po przecinku – osiągnęły tę samą (małą) wartość 0,3. Odchylenie standardowe danych (występujące w mianowniku ilorazu) jest określone dla danych podlegających analizie. Stosunkowo mała wartość ilorazu świadczy zatem o niedużej wartości odchylenia standardowego błędów (znajdującego się w liczniku ilorazu) w relacji do odchylenia danych rzeczywistych. Uznano tę wartość ilorazu za zadowalającą.

Współczynniki korelacji między wartościami rzeczywistymi i wyznaczonymi za pomocą modelu MLP dla trzech podzbiorów osiągnęły bardzo dobre wartości (rzędu 0,95).

Parametry zapisane w tabeli 2 stanowiły podstawę do podjęcia decyzji o kontynuowaniu eksperymentów z modelem MLP (12 – 5 – 1). W tabeli 3 zaprezentowane zostały parametry związane z obliczeniami przeprowadzonymi dla zbioru danych zarezerwowanych dla wyznaczania prognoz pozornych.

Tabela 3. Statystyki regresyjne dla sieci integracyjnej (źródło: badania własne).

	Prognozy jednodniowe	Prognozy pięciodniowe
Średnia	12,79744	13,60029
Odch. std.	6,129125	5,894798
Średni błąd	-0,0007616	-1,209961
Odch. błędu	0,865924	1,301256
Śr. bł. bezwz.	0,6961551	1,501071
Iloraz odch.	0,1412802	0,2207464
Korelacja	0,9899777	0,9756788
RMSE	0,8548	1,763
MSE	0,73	3,12
SSE	28,47	109,2
Średni błąd względny	7,47%	11,47%

Opracowany wcześniej model MLP zastosowano do wyznaczania prognoz pozornych z dwoma horyzontami: jedno- i pięciodniowymi. Podstawowy parametr (tzn. iloraz odchyleń standardowych błędów i danych) świadczący o jakości zastosowanego modelu osiągnął zadowalające wartości. Dla prognoz jednodniowych uzyskano wartość rzędu 0,1, natomiast dla pięciodniowych rzędu 0,2. Korelacja na poziomie 0,9 też dobrze świadczy o zastosowanym modelu.

Ostatnim miernikiem (tabela 3) potwierdzającym użyteczność zaproponowanej metody zespolonego prognozowania jest średni błąd względny prognoz. Uzyskane wartości (dla prognoz jedno- i pięciodniowych, odpowiednio: 7,47% oraz 11,47%) są dla analizowanego szeregu czasowego zadowalające.

## Podsumowanie

Przedstawione badania empiryczne potwierdziły trafność założeń odnośnie konieczności stosowania w pewnych przypadkach zintegrowanych metod sztucznej inteligencji, zamiast prostych pojedynczych sieci neuronowych realizujących ilościową analizę szeregów czasowych. Opracowane i zastosowane modele pojedynczych sieci neuronowych okazały się nieprzydatne do prognozowania wybranego szeregu czasowego. Stwierdzono natomiast, że wybrany model, wykorzystujący pojedynczą sieć neuronową, jest użyteczny jako podsystem analizy ilościowej zintegrowanej (zespolonej) metody prognozowania.

Wprowadzony podział zbioru danych na trzy podzbiory pozwalał na zwiększenie prawdopodobieństwa eliminacji modeli źle generalizujących posiadaną wiedzę. Można było zmniejszyć ryzyko przypadkowości w doborze sieci sprawnie funkcjonujących dla wszystkich trzech podzbiorów. Nie można mieć pewności, że zastosowanie innych (nieuwzględnionych w badaniach) typów sieci będzie prowadzić do lepszych lub gorszych rezultatów. Jednoznacznie nie stwierdzono, że zastosowano optymalne architektury bada-



nych typów sieci. Było to zresztą zadanie niemożliwe do ustalenia. Nie istnieją obecnie bowiem algorytmy doboru struktur sieci gwarantujące brak innych, lepszych rozwiązań. Przy doborze liczby neuronów występujących w poszczególnych warstwach potwierdziła swoją przydatność metoda prób i błędów.

Zastosowanie algorytmu genetycznego do doboru liczby neuronów w warstwie wejściowej okazało się mniej przydatne w relacji do wyników uzyskanych w sposób intuicyjny.

Opracowane oraz wybrane modele potwierdziły swoją przydatność do późniejszych zastosowań predykcyjnych.

Wybrany przez autora program *STATISTICA Sieci Neuronowe* firmy Statsoft jest sprawnym narzędziem do symulowania sieci neuronowych. Umożliwia niewątpliwie szybkie tworzenie wielu modeli o różnych zastosowaniach. Poważny problem stanowi zawsze odpowiednie przygotowanie danych wejściowych oraz wybór właściwej metody postępowania, prowadzącej do opracowania modeli o akceptowanych parametrach.

Stwierdzono, że na etapie tworzenia modeli neuronowych do oceny uzyskanych rezultatów projektowych zupełnie wystarczające są parametry regresyjne. Ocena modeli jest możliwa przez porównywanie wartości tych parametrów dla różnych zbiorów. Niekoniecznie bowiem najmniejsze błędy, występujące dla zbioru uczącego, przesądają o wyborze danego modelu. Ważne są również parametry uzyskiwane dla pozostałych podzbiorów danych.

Wyniki eksperymentów można uznać za wiarygodne, ponieważ przeprowadzono badania dla różnych horyzontów czasowych (prognoz jedno- i pięciodniowych). Potwierdzono założenie badawcze, ponieważ w przypadku modelu zbudowanego na bazie pojedynczej sieci neuronowej (MLP o strukturze: 6 – 10 – 1) średnie błędy względne dla dwóch horyzontów predykcji (odpowiednio: 28,77% oraz 35,62%) wskazywały na nikłą praktyczną przydatność opracowanego modelu. Obliczenia wykonane dla podzbioru zarezerwowanego dla wyznaczania prognoz pozornych za pomocą nowej zespolonej metody prognozowania charakteryzowały się znacznie mniejszymi wartościami błędów. Dla predykcji jednodniowych i pięciodniowych wartości średnich błędów względnych (wynoszących odpowiednio: 7,47% oraz 11,47%) wskazywały na praktyczną użyteczność opracowanej metody prognozowania zintegrowanego.

Uzyskane wartości średnich błędów względnych mogą stanowić pewną wskazówkę odnośnie doboru metod prognozowania związanych z sieciami neuronowymi (lub szerzej sztuczną inteligencją). Modele zbudowane na bazie pojedynczej sieci neuronowej (realizujące wyłącznie analizę ilościową) nie są praktycznie użyteczne w przypadku występowania nietypowych (oraz krótkotrwałych) wydarzeń silnie wpływających na prognozowane wartości. Należy wtedy niewątpliwie stosować bardziej złożone metody predykcji, które np. w sposób jakościowy uwzględniają wpływ tych nietypowych przypadków.



## Bibliografia

1. Azoff E. M. [1994], *Neural Network Time Series Forecasting of Financial Markets*, Wiley, Chichester.
2. Dittmann P. [2004], *Prognozowanie w przedsiębiorstwie. Metody i ich zastosowanie*, Oficyna Ekonomiczna, Kraków.
3. Duch W., Korbicz J., Rutkowski L., Tadeusiewicz R. [2000], *Sieci neuronowe, Biocybernetyka i inżynieria biomedyczna 2000*, PAN, Akademicka Oficyna Wydawnicza EXIT, Warszawa.
4. Grzeszczyk T. A. [2000], *Rough Sales Forecasting System*, W: *Informations Systems – Research, Teaching and Practice*, Proceedings of the 5th UKAIS Conference University of Wales Institute, Editors: Paul Beynon-Davies, Michael D. Williams, Ian Beeson, Cardiff.
5. Grzeszczyk T. A. [2005], *Artificial Intelligence Applied for Forecasting in Enterprise Decision Support*, Publishing House of Institute of Production Systems Organization, Warsaw University of Technology, Warsaw.
6. Kuo R. J. [2001], *A Sales Forecasting System Based on Fuzzy Neural Network with Initial Weights Generated by Genetic Algorithm*, *European Journal of Operational Research*, vol. 129, no. 3, March 2001, Elsevier, Netherlands.
7. Lingras P. [1998], *Applications of Rough Patterns, Rough Sets in Knowledge Discovery 2* (Eds. L. Polkowski and A. Skowron), Physica-Verlag, Heidelberg, New York.
8. Lula P. [1999] *Jednokierunkowe sieci neuronowe w modelowaniu zjawisk ekonomicznych*, Wydawnictwo Akademii Ekonomicznej w Krakowie, Kraków.
9. Lula P. [2000], *Ocena modeli neuronowych wykorzystywanych w zagadnieniach modelowania i prognozowania*, W: *Prace naukowe AE we Wrocławiu* (red. K. Jajuga, M. Walesiak), Nr 874, *Taksonomia 7, Klasyfikacja i analiza danych, Teoria i zastosowania*, Wrocław.
10. Masters T. [1996], *Sieci neuronowe w praktyce. Programowanie w języku C++*, WNT, Warszawa.
11. McNelis P. D. [2005], *Neural Networks in Finance: Gaining Predictive Edge in the Market*, Academic Press Advanced Finance Series, Elsevier Academic Press, USA.
12. Pawlak Z. [1982], *Rough sets*, *International Journal of Computer and Information Sciences*. 11/1982.
13. Sankar K. P., Polkowski L., Skowron A. (eds.) [2004], *Rough-Neural Computing: Techniques for Computing with Words*, Springer-Verlag, Berlin Heidelberg New York.
14. Statsoft. [www.statsoft.com/textbook/glosr.html](http://www.statsoft.com/textbook/glosr.html).
15. Statsoft [2001], *Opis do programu STATISTICA Neural Networks 4.0 PL*, Opracowanie dla Statsoft: R. Tadeusiewicz, P. Lula. Kraków.
16. Stefanowicz B. [1993], *Metody sztucznej inteligencji i systemy eksperckie*, Monografie i opracowania, SGH, Warszawa.



17. Szczuka M. S. [1998], Rough Sets and Artificial Neural Networks, Applications of Rough Patterns, Rough Sets in Knowledge Discovery 2 (Eds. L. Polkowski and A. Skowron), Physica-Verlag, Heidelberg, New York, 1998.
18. Tadeusiewicz R. [1993], Sieci neuronowe, Akademicka Oficyna Wydawnicza RM, Warszawa.
19. Tang Z., Almeida C., Fishwick P. A. [1991], Times series forecasting using neural networks vs. Box-Jenkins methodology, Simulations Councils, Nov.
20. Witkowska D. [2002], Sztuczne sieci neuronowe i metody statystyczne. Wybrane zagadnienia finansowe, Wydawnictwo C.H.Beck, Warszawa.
21. Zhang G. P. [2004], Neural Networks in Business Forecasting, IRM Press, Hershey PA.