


Prognozowanie w zarządzaniu firmą



Redaktorzy naukowi
Paweł Dittmann
Aleksandra Szpulak



Wydawnictwo Uniwersytetu Ekonomicznego we Wrocławiu
Wrocław 2011

Senacka Komisja Wydawnicza

Zdzisław Pisz (przewodniczący),

Andrzej Bąk, Krzysztof Jajuga, Andrzej Matysiak, Waldemar Podgórski,

Mieczysław Przybyła, Aniela Styś, Stanisław Urban

Recenzenci

Włodzimierz Szkutnik, Jan Zawadzki

Redakcja wydawnicza

Barbara Majewska

Redakcja techniczna i korekta

Barbara Łopusiewicz

Skład i łamanie

Comp-rajt

Projekt okładki

Beata Dębska

Kopiowanie i powielanie w jakiegokolwiek formie
wymaga pisemnej zgody Wydawcy

© Copyright by Uniwersytet Ekonomiczny we Wrocławiu
Wrocław 2011

ISSN 1899-3192

ISBN 978-83-7695-141-6

Druk: Drukarnia TOTEM

Spis treści

Wstęp	7
Agnieszka Przybylska-Mazur: Optymalne zasady polityki pieniężnej w prognozowaniu wskaźnika inflacji	9
Alicja Wolny-Dominiak: Zmodyfikowana regresja Poissona dla danych ubezpieczeniowych z dużą liczbą zer	21
Andrzej Gajda: Doświadczenia i metody pozyskiwania danych eksperckich na potrzeby badań z wykorzystaniem metod foresight	30
Anna Gondek: Prognozy rozwoju gospodarczego Polski z użyciem metody analogii przestrzenno-czasowych	41
Bartosz Lawędziak: Sekurytyzacja papierów wartościowych opartych na hipotece odwrotnej	50
Filip Chybalski: Prakseologiczne aspekty prognozowania	59
Ireneusz Kuroпка, Paweł Lenczewski: Możliwość zastosowania modeli ekonometrycznych do prognozowania w przedsiębiorstwie Brenntag Polska	69
Jacek Szandula: Wyszukiwanie formacji w kursach giełdowych przy użyciu metod klasyfikacji danych	82
Joanna Perzyńska: Zastosowanie sztucznych sieci neuronowych do wyznaczania nieliniowych prognoz kombinowanych	94
Konstancja Poradowska, Tomasz Szkutnik, Mirosław Wójciak: Scenariusze rozwoju wybranych technologii oszczędności energii w życiu codziennym	102
Maciej Oesterreich: Wykorzystanie pakietu statystycznego R w prognozowaniu na podstawie danych w postaci szeregów czasowych z wahaniami sezonowymi	113
Marcin Błażejowski, Paweł Kufel, Tadeusz Kufel: Algorytm zgodnego modelowania i prognozowania procesów ekonomicznych jako pakiet funkcji <i>Congruent Specification</i> programu Gretl	125
Marcin Błażejowski: Stacjonarność szeregów czasowych o wysokiej częstotliwości obserwowania – implementacja testu stacjonarności Dickeya w programie Gretl	137
Mirosław Wójciak: Wpływ czynników i zdarzeń kluczowych na rozwój nowych technologii – wybrane metody korygowania prognoz na przykładzie technologii energooszczędnych	149
Monika Dyduch: Grupowanie produktów strukturyzowanych	159
Piotr Bernat: Planowanie działalności przedsiębiorstwa wspomagane prognozowaniem	170

Roman Pawlukowicz: Informacje prognostyczne w rynkowych sposobach wyceny nieruchomości – identyfikacja i pozyskiwanie	182
Wojciech Zatoń: Uwarunkowania psychologiczne w prognozowaniu	189

Summaries

Agnieszka Przybylska-Mazur: Optimal monetary policy rules in forecasting of inflation rate	20
Alicja Wolny-Dominiak: Zero-inflated Poisson Model for insurance data with a large number of zeros	29
Andrzej Gajda: Experience and methods of data collection from experts for research using foresight methods	40
Anna Gondek: Economic growth forecasts for Poland using the time-space analogy method	49
Bartosz Lawędziak: Securitization of survivor bonds based on the reverse mortgage	58
Filip Chybalski: Praxiological aspects of forecasting	68
Ireneusz Kuropka, Paweł Lenczewski: Econometric models usage feasibility in Brenntag Poland forecasting	81
Jacek Szandula: Searching for technical analysis formations in stock prices with the use of cluster analysis methods	93
Joanna Perzyńska: Application of artificial neural networks to build the nonlinear combined forecasts	101
Konstancja Poradowska, Tomasz Szkutnik, Mirosław Wójciak: The scenarios of development of selected technologies related to energy saving in everyday life	112
Maciej Oesterreich: The R application in forecasting unsystematic lacks in seasonal time series	124
Marcin Błażejowski, Paweł Kufel, Tadeusz Kufel: Congruent modelling and forecasting algorithm as function package Congruent Specification in GRETL	136
Marcin Błażejowski: Stationarity of high-frequency time series – implementation of Dickey’s stationarity test in GRETL	148
Mirosław Wójciak: The influence of key and events factors on the development of new technologies – selected methods of forecast correction on the example of energy-saving technologies	158
Monika Dyduch: Ranking of structured products	169
Piotr Bernat: Forecasting assisted business management planning	181
Roman Pawlukowicz: Prognostic data in market ways of property valuation – identification and acquisition	188
Wojciech Zatoń: Psychological aspects of forecasting	199

Joanna Perzyńska

Zachodniopomorski Uniwersytet Technologiczny w Szczecinie

ZASTOSOWANIE SZTUCZNYCH SIECI NEURONOWYCH DO WYZNACZANIA NIELINIOWYCH PROGNOZ KOMBINOWANYCH

Streszczenie: W artykule przedstawiono zastosowanie sztucznych sieci neuronowych do budowy nieliniowych prognoz kombinowanych. Ilustracją rozważań o charakterze teoretycznym jest przykład empiryczny, w którym prognozy indywidualne oraz kombinowane wyznaczono dla zmiennej ekonomicznej wykazującej wahania sezonowe. Dokładność nieliniowych prognoz kombinowanych porównano z dokładnością ich prognoz składowych oraz liniowych prognoz kombinowanych.

Słowa kluczowe: prognozowanie ekonometryczne, prognozy kombinowane, sztuczne sieci neuronowe.

1. Wstęp

Metody wyznaczania prognoz kombinowanych jako liniowych kombinacji prognoz indywidualnych zakładają istnienie liniowego związku pomiędzy prognozami składowymi i prognozowaną zmienną. Jednak nie w każdym przypadku związek ten musi być liniowy i wówczas większą dokładność niż liniowa prognoza kombinowana może mieć nieliniowa prognoza kombinowana.

Nieliniowe związki występujące między prognozami indywidualnymi i prognozowaną zmienną można aproksymować za pomocą sztucznych sieci neuronowych zawierających neurony z nieliniową funkcją aktywacji (zob. [Liu i in. 1996; Donaldson, Kamstra 1996]). W szczególności wprowadzenie do perceptronu wielowarstwowego już jednej warstwy neuronów ukrytych o nieliniowych funkcjach aktywacji pozwala modelować funkcje o niemal dowolnej złożoności [Hornik i in. 1989].

W artykule zostanie przedstawiona metoda budowy nieliniowych prognoz kombinowanych, wykorzystująca sztuczne sieci neuronowe. W toku badań empirycznych zweryfikowana zostanie hipoteza mówiąca, że otrzymane w ten sposób

nieliniowe prognozy kombinowane charakteryzują się większą dokładnością niż ich prognozy składowe oraz liniowe prognozy kombinowane.

2. Metody badawcze

Niech $f_{1T}, f_{2T}, \dots, f_{mT}$ będą różnymi prognozami indywidualnymi wartości zmiennej Y w okresie T . Nieliniowa prognoza kombinowana wartości y_T ma postać:

$$f_{cT} = \psi(f_{1T}, f_{2T}, \dots, f_{mT}), \quad (1)$$

gdzie: f_{cT} – prognoza kombinowana,

ψ – funkcja nieliniowa,

$f_{1T}, f_{2T}, \dots, f_{mT}$ – indywidualne prognozy składowe ($m \geq 2$).

W celu wyznaczenia prognozy (1) skonstruowana zostanie jednokierunkowa sztuczna sieć neuronowa posiadająca co najmniej trzy warstwy: warstwę wejściową zawierającą m neuronów służących do wprowadzania m prognoz składowych, co najmniej jedną warstwę ukrytą zawierającą p neuronów o nieliniowych funkcjach aktywacji φ_j ($j = 1, 2, \dots, p$) oraz warstwę wyjściową zawierającą jeden neuron z liniową funkcją aktywacji φ wyznaczającą wartość prognozy kombinowanej (1). Ogólną strukturę perceptronu trójwarstwowego stosowanego do wyznaczenia nieliniowej prognozy kombinowanej przedstawiono na rysunku 1.

Sieć przedstawiona na rysunku 1 posiada jedną warstwę neuronów ukrytych, jeżeli jest to konieczne warstw ukrytych może być więcej, należy jednak zwrócić uwagę, że najczęściej wystarczające jest zastosowanie sieci o mniej rozbudowanej strukturze. Jako funkcje aktywacji neuronów warstw ukrytych można wykorzystać funkcje sigmoidalne, wykładnicze i inne funkcje nieliniowe. W zależności od własności użytej funkcji aktywacji wartości wejściowe i wyjściowe sieci mogą podlegać przekształceniom w procesach pre- i postprocessingu.

Wagi połączeń neuronów kolejnych warstw skonstruowanej sieci $w_{ij}, w_j^{(2)}$ ($i = 1, 2, \dots, m$), ich obciążenia $w_{0j}, w_0^{(2)}$ oraz parametry funkcji aktywacji są jednocześnie parametrami nieliniowej funkcji ψ wyrażającej związek pomiędzy m prognozami indywidualnymi oraz prognozą kombinowaną, szacowane są one w procesie uczenia sieci z nauczycielem (dla $t < T$).


W celach porównawczych wyznaczone zostaną również liniowe prognozy kombinowane, będące liniowymi kombinacjami m prognoz indywidualnych o postaci:

$$f_{cT} = \sum_{i=1}^m \lambda_i f_{iT}, \quad (2)$$

gdzie:

$$\sum_{i=1}^m \lambda_i = 1, \quad (3)$$

w których wagi λ_i zostaną wyznaczone za pomocą metody regresji (NERLS), liniowych sztucznych sieci neuronowych (IANN) oraz średniej arytmetycznej (AM).



Rys. 1. Ogólna struktura perceptronu trójwarstwowego, stosowanego do wyznaczenia nieliniowej prognozy kombinowanej

Źródło: opracowanie własne.

3. Materiał badawczy

Modelowaniu predyktywnemu i prognozowaniu poddano kształtowanie się kosztów produkcji elementów budowlanych w przedsiębiorstwa A w ujęciu miesięcznym (K). Zmienne objaśniające stanowiły zmienne SP oraz PR przedstawiające odpowiednio sprzedaż oraz produkcję elementów budowlanych w tym samym oddziale. Dane statystyczne zaczerpnięto z Banku Danych Katedry Zastosowań Matematyki w Ekonomii.

Badana zmienna charakteryzuje się występowaniem wyraźnego trendu oraz wahań sezonowych. W tabeli 1 przedstawiono oceny wskaźników sezonowości zmiennej K, wyznaczone przy założeniu multiplikatywnego charakteru wahań sezonowych.

Tabela 1. Oceny wskaźników sezonowości zmiennej K

Miesiąc	Wskaźnik sezonowości [%]	Miesiąc	Wskaźnik sezonowości [%]
I	76,31	VII	108,67
II	68,54	VIII	115,14
III	87,83	IX	120,28
IV	92,58	X	124,24
V	96,12	XI	110,57
VI	106,44	XII	93,28

Źródło: obliczenia własne.

Wyznaczone oceny wskaźników sezonowości zmiennej K wykazują znaczne różnicowanie – różnica między wartością maksymalną i minimalną wynosi 55,7 punktu procentowego. Zmienna K charakteryzuje się silnym natężeniem sezonowości, swoje maksimum sezonowe osiąga w październiku, a minimum w lutym.

4. Prezentacja i ocena wyników badań

W procesie modelowania predyktywnego zmiennej K wykorzystano klasyczne (MK) i hierarchiczne (H) modele szeregu czasowego, modele przyczynowo-opisowe (P), hierarchiczne modele przyczynowo-opisowe (PH), modele Holta-Wintersa (HWin) oraz sztuczne sieci neuronowe (ANN). Okres estymacyjny obejmował 48 obserwacji.

Do dalszych badań wybrano sześć modeli o najlepszych własnościach predykcyjnych oszacowanych różnymi metodami: MK12tp, H62tp, Ptp/SP, PH26tp/SP, HWin17 oraz ANN/SP (gdzie: t – trend liniowy, s – stałe parametry przy zmiennej objaśniającej, p – periodyczny składnik sezonowy). Wyznaczone na ich podstawie prognozy *ex post* (odpowiednio: f_{1t} , f_{2t} , f_{3t} , f_{4t} , f_{5t} , f_{6t}) na 12 kolejnych okresów ($t = 49, 50, \dots, 60$) stanowiły prognozy składowe prognoz kombinowanych określonych wzorami (1) i (2) dla $m = 2, 3, \dots, 6$. Średnie absolutne błędy procentowe prognoz składowych zestawiono w tabeli 2.

Tabela 2. Błędy prognoz składowych

Prognoza składowa	MAPE [%]	Prognoza składowa	MAPE [%]
f_{1t}	13,04	f_{4t}	5,62
f_{2t}	13,49	f_{5t}	7,60
f_{3t}	5,42	f_{6t}	8,83

Źródło: obliczenia własne.

Dla każdej kombinacji m prognoz składowych wyznaczono nieliniową prognozę kombinowaną z wykorzystaniem nieliniowych sztucznych sieci neuronowych (nANN)

oraz trzy liniowe prognozy kombinowane z wagami otrzymanymi na podstawie metody regresji (NERLS), liniowych sztucznych sieci neuronowych (IANN) oraz średniej arytmetycznej prostej (AM). W metodzie średniej arytmetycznej przyjęto wagi równe, natomiast do oszacowania parametrów prognoz kombinowanych (współczynników kombinacji liniowych lub wag sieci) pozostałymi metodami wykorzystano wartości teoretyczne modeli indywidualnych, na podstawie których wyznaczono prognozy składowe oraz realizacje prognozowanej zmiennej w okresie estymacyjnym.

Parametry sztucznych sieci neuronowych wyznaczono w procesie uczenia z nauczycielem. Struktura sieci liniowych jest z góry określona (zob. [Perzyńska 2010]) – zawierają one $m-1$ neuronów wejściowych oraz jeden neuron wyjściowy z tożsamościową funkcją aktywacji, zatem podczas uczenia szacowane były tylko wagi połączeń obu warstw. W przypadku sieci nieliniowych należało dodatkowo wyznaczyć liczbę warstw ukrytych (WU) oraz ich neuronów (NU). W tym celu dla każdej kombinacji prognoz składowych skonstruowano i nauczono od kilku do kilkunastu sieci nieliniowych o różnych rozmiarach, spośród których wybrano jedną (o najlepszej jakości) i przy jej wykorzystaniu wyznaczono nieliniową prognozę kombinowaną.

Do oceny jakości sieci posłużyły wartości następujących mierników:

- błąd RMSE, który pozwala określić zdolności sieci do aproksymacji i generalizacji (w przypadku, gdy wartości błędów RMSE na zbiorach: uczącym (U), walidacyjnym (W) i testowym (T) różnią się zasadniczo, oznacza to, że sieć nie nabyła zdolności do generalizacji, a jedynie dopasowała się do danych uczących);
- iloraz odchyleń standardowych obliczonych dla błędów popełnianych przez sieć i wzorcowych wartości zmiennej wyjściowej (przyjmuje się, że jego wartość równa lub większa od 0,7 dyskwalifikuje model neuronowy);
- współczynnik korelacji liniowej Pearsona (ρ) pomiędzy wartościami wyjściowymi wyznaczonymi przez sieć i odpowiadającymi im wzorcowymi wartościami wyjściowymi.

Dla wszystkich kombinacji prognoz składowych najlepszą jakość nieliniowych sieci neuronowych uzyskano dla perceptronów trzywarstwowych, o niewielkiej liczbie neuronów ukrytych z logistyczną funkcją aktywacji. W przypadkach, w których jakość sieci nie była zadowalająca, zwiększenie liczby warstw nie poprawiło wyników – uzyskano to jedynie dzięki nieznacznemu zwiększeniu liczby neuronów ukrytych drugiej warstwy. W tabeli 3 przedstawiono charakterystyki modeli neuronowych, na podstawie których wyznaczono nieliniowe prognozy kombinowane.

Analizując informacje zawarte w tabeli 3, można zauważyć, że w kilku przypadkach uzyskano sieci złej jakości – o wartościach ilorazów odchyleń standardowych równych lub większych od 0,7 i jednocześnie małych wartościach współczynników korelacji oraz dużych różnicach pomiędzy wartościami błędów RMSE wyznaczonych na zbiorach: uczącym, walidacyjnym i testowym. Można oczekiwać, że prognozy kombinowane wyznaczone na podstawie tych modeli będą obciążone dużymi błędami.

Tabela 3. Charakterystyki modeli sztucznych sieci neuronowych wykorzystanych do wyznaczenia nieliniowych prognoz kombinowanych

Prognozy składowe	NU	RMSE			Iloraz odchyłeń standardowych			ρ			Prognozy składowe	NU	RMSE			Iloraz odchyłeń standardowych			ρ		
		U	W	T	U	W	T	U	W	T			U	W	T	U	W	T	U	W	T
$f_{1t}-f_{2t}$	1	452	405	491	0,35	0,33	0,34	0,87	0,88	0,89	$f_{2t}-f_{4t}-f_{6t}$	1	317	292	163	0,25	0,22	0,16	0,90	0,91	0,94
$f_{1t}-f_{3t}$	1	318	118	210	0,34	0,18	0,29	0,90	0,98	0,91	$f_{2t}-f_{3t}-f_{6t}$	1	384	239	401	0,34	0,20	0,40	0,83	0,92	0,79
$f_{1t}-f_{4t}$	1	253	120	310	0,22	0,12	0,21	0,94	0,99	0,90	$f_{3t}-f_{4t}-f_{5t}$	2	371	255	380	0,77	0,45	0,79	0,76	0,80	0,71
$f_{1t}-f_{5t}$	2	399	183	406	0,67	0,14	0,71	0,87	0,94	0,79	$f_{3t}-f_{4t}-f_{6t}$	1	350	272	352	0,27	0,17	0,28	0,85	0,94	0,85
$f_{1t}-f_{6t}$	1	384	292	397	0,30	0,21	0,33	0,81	0,82	0,80	$f_{3t}-f_{5t}-f_{6t}$	1	310	308	312	0,26	0,25	0,26	0,89	0,89	0,88
$f_{2t}-f_{3t}$	1	231	276	179	0,16	0,18	0,16	0,90	0,92	0,98	$f_{4t}-f_{5t}-f_{6t}$	1	362	245	334	0,32	0,21	0,30	0,87	0,94	0,86
$f_{2t}-f_{4t}$	1	332	136	360	0,23	0,12	0,19	0,88	0,99	0,89	$f_{1t}-f_{2t}-f_{3t}-f_{4t}$	2	385	246	387	0,31	0,21	0,29	0,92	0,96	0,92
$f_{2t}-f_{5t}$	2	215	574	601	0,42	0,70	0,82	0,91	0,78	0,65	$f_{1t}-f_{2t}-f_{3t}-f_{5t}$	2	286	255	317	0,24	0,20	0,27	0,92	0,95	0,91
$f_{2t}-f_{6t}$	1	426	306	270	0,26	0,34	0,17	0,86	0,95	0,99	$f_{1t}-f_{2t}-f_{3t}-f_{6t}$	2	369	292	428	0,29	0,20	0,35	0,86	0,93	0,77
$f_{3t}-f_{4t}$	2	443	263	387	0,78	0,69	0,71	0,60	0,70	0,67	$f_{1t}-f_{2t}-f_{4t}-f_{5t}$	2	383	322	444	0,37	0,30	0,44	0,82	0,84	0,76
$f_{3t}-f_{5t}$	1	353	242	320	0,31	0,10	0,17	0,85	0,90	0,85	$f_{1t}-f_{2t}-f_{4t}-f_{6t}$	2	258	253	249	0,22	0,22	0,18	0,91	0,91	0,90
$f_{3t}-f_{6t}$	1	432	296	300	0,26	0,25	0,20	0,86	0,97	0,93	$f_{1t}-f_{2t}-f_{5t}-f_{6t}$	2	347	236	266	0,25	0,21	0,20	0,88	0,90	0,89
$f_{4t}-f_{5t}$	1	268	238	412	0,22	0,19	0,35	0,93	0,97	0,87	$f_{1t}-f_{3t}-f_{4t}-f_{5t}$	2	437	351	447	0,33	0,23	0,37	0,75	0,88	0,73
$f_{4t}-f_{6t}$	1	305	155	318	0,22	0,09	0,31	0,83	0,98	0,85	$f_{1t}-f_{3t}-f_{4t}-f_{6t}$	2	362	239	363	0,23	0,19	0,25	0,86	0,93	0,84
$f_{5t}-f_{6t}$	1	399	283	200	0,25	0,27	0,27	0,85	0,89	0,90	$f_{1t}-f_{3t}-f_{5t}-f_{6t}$	2	397	239	403	0,25	0,20	0,28	0,89	0,91	0,82
$f_{1t}-f_{2t}-f_{3t}$	1	357	219	337	0,32	0,21	0,32	0,87	0,93	0,86	$f_{1t}-f_{2t}-f_{3t}-f_{6t}$	2	321	217	421	0,24	0,18	0,31	0,90	0,99	0,85
$f_{1t}-f_{2t}-f_{4t}$	1	356	219	296	0,31	0,24	0,30	0,88	0,90	0,88	$f_{2t}-f_{3t}-f_{4t}-f_{5t}$	2	390	334	400	0,23	0,22	0,28	0,93	0,85	0,80
$f_{1t}-f_{2t}-f_{5t}$	2	206	499	609	0,21	0,73	0,81	0,90	0,78	0,66	$f_{2t}-f_{3t}-f_{4t}-f_{6t}$	2	368	232	425	0,23	0,18	0,33	0,94	0,97	0,87
$f_{1t}-f_{2t}-f_{6t}$	1	310	105	282	0,29	0,10	0,26	0,90	0,98	0,92	$f_{2t}-f_{3t}-f_{5t}-f_{6t}$	2	477	431	504	0,37	0,31	0,41	0,89	0,92	0,80
$f_{1t}-f_{3t}-f_{4t}$	1	398	103	371	0,34	0,09	0,34	0,88	0,99	0,85	$f_{2t}-f_{4t}-f_{5t}-f_{6t}$	2	453	422	530	0,31	0,29	0,44	0,84	0,90	0,78
$f_{1t}-f_{3t}-f_{5t}$	1	376	102	355	0,30	0,11	0,29	0,87	0,96	0,89	$f_{3t}-f_{4t}-f_{5t}-f_{6t}$	2	488	307	592	0,36	0,33	0,45	0,84	0,89	0,70
$f_{1t}-f_{3t}-f_{6t}$	1	277	235	386	0,21	0,19	0,30	0,93	0,95	0,86	$f_{1t}-f_{2t}-f_{3t}-f_{4t}-f_{5t}$	2	227	284	252	0,17	0,20	0,19	0,93	0,90	0,92
$f_{1t}-f_{4t}-f_{5t}$	1	309	234	373	0,28	0,20	0,27	0,90	0,97	0,90	$f_{1t}-f_{2t}-f_{3t}-f_{4t}-f_{6t}$	2	315	319	129	0,25	0,25	0,08	0,99	0,97	0,99
$f_{1t}-f_{4t}-f_{6t}$	1	328	134	169	0,27	0,14	0,23	0,91	0,99	0,93	$f_{1t}-f_{2t}-f_{3t}-f_{5t}-f_{6t}$	2	326	276	318	0,29	0,24	0,35	0,89	0,91	0,87
$f_{1t}-f_{5t}-f_{6t}$	1	266	232	372	0,20	0,18	0,37	0,95	0,98	0,90	$f_{1t}-f_{2t}-f_{4t}-f_{5t}-f_{6t}$	2	318	273	389	0,28	0,26	0,33	0,90	0,92	0,88
$f_{2t}-f_{3t}-f_{4t}$	1	345	231	377	0,19	0,15	0,20	0,96	0,97	0,91	$f_{1t}-f_{3t}-f_{4t}-f_{5t}-f_{6t}$	2	334	268	295	0,28	0,23	0,30	0,89	0,89	0,86
$f_{2t}-f_{3t}-f_{5t}$	1	418	339	223	0,27	0,24	0,20	0,89	0,90	0,92	$f_{2t}-f_{3t}-f_{4t}-f_{5t}-f_{6t}$	2	345	203	343	0,21	0,14	0,28	0,89	0,99	0,97
$f_{2t}-f_{3t}-f_{6t}$	1	410	331	175	0,36	0,23	0,17	0,81	0,90	0,95	$f_{1t}-f_{2t}-f_{3t}-f_{4t}-f_{5t}-f_{6t}$	3	331	258	342	0,39	0,23	0,42	0,85	0,91	0,87
$f_{2t}-f_{4t}-f_{5t}$	1	332	258	381	0,28	0,19	0,30	0,87	0,93	0,86											

Źródło: obliczenia własne.

Średnie absolutne błędy procentowe prognoz kombinowanych uzyskane za pomocą wszystkich czterech metod zestawiono w tabeli 4. Pogrubionym drukiem wyróżniono błędy tych prognoz kombinowanych, które są nie większe od najmniejszego z błędów ich prognoz składowych.

Tabela 4. Średnie absolutne błędy procentowe prognoz kombinowanych

Prognozy składowe	MAPE [%]				Prognozy składowe	MAPE [%]			
	AM	NERLS	IANN	nANN		AM	NERLS	IANN	nANN
$f_{1t}-f_{2t}$	13,07	13,04	13,27	12,70	$f_{2t}-f_{4t}-f_{6t}$	6,72	5,62	5,20	5,32
$f_{1t}-f_{3t}$	8,98	5,42	5,07	4,73	$f_{2t}-f_{5t}-f_{6t}$	7,15	6,27	5,80	5,69
$f_{1t}-f_{4t}$	8,94	6,41	5,11	5,03	$f_{3t}-f_{4t}-f_{5t}$	5,53	5,41	5,34	5,45
$f_{1t}-f_{5t}$	10,10	12,86	9,70	9,21	$f_{3t}-f_{4t}-f_{6t}$	4,19	5,42	4,97	5,07
$f_{1t}-f_{6t}$	7,41	7,58	7,42	6,12	$f_{3t}-f_{5t}-f_{6t}$	4,76	5,41	5,23	4,97
$f_{2t}-f_{3t}$	9,08	5,42	5,39	4,45	$f_{4t}-f_{5t}-f_{6t}$	4,72	5,61	5,51	5,00
$f_{2t}-f_{4t}$	9,20	5,62	4,43	4,73	$f_{1t}-f_{2t}-f_{3t}-f_{4t}$	8,90	5,42	5,41	5,13
$f_{2t}-f_{5t}$	9,88	13,22	10,44	9,79	$f_{1t}-f_{2t}-f_{3t}-f_{5t}$	9,23	5,41	5,27	5,21
$f_{2t}-f_{6t}$	7,49	7,03	5,88	6,16	$f_{1t}-f_{2t}-f_{3t}-f_{6t}$	8,07	5,42	4,99	4,90
$f_{3t}-f_{4t}$	5,30	5,42	5,30	5,52	$f_{1t}-f_{2t}-f_{4t}-f_{5t}$	9,24	6,41	5,63	5,28
$f_{3t}-f_{5t}$	5,98	5,41	5,46	5,31	$f_{1t}-f_{2t}-f_{4t}-f_{6t}$	8,05	6,29	5,66	5,49
$f_{3t}-f_{6t}$	4,16	5,42	4,40	4,12	$f_{1t}-f_{2t}-f_{5t}-f_{6t}$	8,35	6,97	6,76	7,32
$f_{4t}-f_{5t}$	5,91	5,62	5,46	5,20	$f_{1t}-f_{3t}-f_{4t}-f_{5t}$	7,33	5,41	5,34	5,40
$f_{4t}-f_{6t}$	3,99	5,62	4,23	4,49	$f_{1t}-f_{3t}-f_{4t}-f_{6t}$	6,13	5,42	4,97	5,02
$f_{5t}-f_{6t}$	5,61	5,78	5,61	5,60	$f_{1t}-f_{3t}-f_{5t}-f_{6t}$	6,55	5,41	5,19	5,26
$f_{1t}-f_{2t}-f_{3t}$	10,32	5,42	5,41	5,17	$f_{1t}-f_{4t}-f_{5t}-f_{6t}$	6,52	6,22	5,48	5,45
$f_{1t}-f_{2t}-f_{4t}$	10,34	6,41	5,60	5,43	$f_{2t}-f_{3t}-f_{4t}-f_{5t}$	7,16	5,41	5,23	5,10
$f_{1t}-f_{2t}-f_{5t}$	10,83	12,86	11,42	9,01	$f_{2t}-f_{3t}-f_{4t}-f_{6t}$	6,30	5,42	4,90	4,93
$f_{1t}-f_{2t}-f_{6t}$	9,04	7,58	7,12	6,90	$f_{2t}-f_{3t}-f_{5t}-f_{6t}$	6,59	5,41	5,01	5,38
$f_{1t}-f_{3t}-f_{4t}$	7,66	5,42	5,13	4,78	$f_{2t}-f_{4t}-f_{5t}-f_{6t}$	6,56	5,61	4,88	5,59
$f_{1t}-f_{3t}-f_{5t}$	8,26	5,41	5,19	4,92	$f_{3t}-f_{4t}-f_{5t}-f_{6t}$	4,76	5,41	4,74	5,37
$f_{1t}-f_{3t}-f_{6t}$	6,58	5,42	4,78	4,23	$f_{1t}-f_{2t}-f_{3t}-f_{4t}-f_{5t}$	8,27	5,41	5,30	5,36
$f_{1t}-f_{4t}-f_{5t}$	8,22	6,41	5,60	5,48	$f_{1t}-f_{2t}-f_{3t}-f_{4t}-f_{6t}$	7,50	5,42	4,99	5,13
$f_{1t}-f_{4t}-f_{6t}$	6,53	6,29	4,99	4,72	$f_{1t}-f_{2t}-f_{3t}-f_{5t}-f_{6t}$	7,66	5,41	5,40	5,28
$f_{1t}-f_{5t}-f_{6t}$	7,10	6,97	6,53	6,20	$f_{1t}-f_{2t}-f_{4t}-f_{5t}-f_{6t}$	7,64	6,22	5,65	5,31
$f_{2t}-f_{3t}-f_{4t}$	7,77	5,42	5,41	5,32	$f_{1t}-f_{3t}-f_{4t}-f_{5t}-f_{6t}$	6,21	5,41	5,22	5,21
$f_{2t}-f_{3t}-f_{5t}$	8,12	5,41	4,69	5,02	$f_{2t}-f_{3t}-f_{4t}-f_{5t}-f_{6t}$	6,24	5,41	5,10	4,97
$f_{2t}-f_{3t}-f_{6t}$	6,70	5,42	4,92	4,99	$f_{1t}-f_{2t}-f_{3t}-f_{4t}-f_{5t}-f_{6t}$	7,19	5,41	4,93	4,98
$f_{2t}-f_{4t}-f_{5t}$	8,04	5,61	4,89	5,13					

Źródło: obliczenia własne.

Porównując dokładność prognoz kombinowanych wyznaczonych wszystkimi czterema metodami, można zauważyć, że najlepsze wyniki uzyskano dla nieliniowych prognoz kombinowanych otrzymanych przy wykorzystaniu sztucznych sieci neuronowych. Odsetek nieliniowych prognoz kombinowanych o błędach nie większych od najmniejszego z błędów ich prognoz składowych wynosi 91,2%. Analizując informa-

cje przedstawione w tabelach 3 i 4, można zauważyć, że w przypadkach, w których nieliniowe prognozy kombinowane obciążone są większym błędem niż najlepsza z ich prognoz składowych, zastosowane sieci neuronowe mają złą jakość.

Wśród liniowych prognoz kombinowanych największą dokładnością charakteryzują się prognozy z wagami wyznaczonymi za pomocą liniowych sieci neuronowych – w 87,7% przypadków ich błędy nie przekraczają minimalnych błędów prognoz składowych. Dla metody regresji odsetek ten wynosi 80,7%, najmniejszą wartość (21,1%) przyjmuje dla metody średniej arytmetycznej prostej.

Dokładność prognoz kombinowanych utworzonych za pomocą metod NERLS, IANN oraz nANN jest najmniejsza dla kombinacji par prognoz indywidualnych. Wraz ze zwiększaniem liczby prognoz składowych w kombinacji wzrasta również jej dokładność. Najmniej dokładne okazały się te prognozy kombinowane, w skład których wchodzi prognozy indywidualne wyznaczone metodą Holta-Wintersa. Włączenie do tych kombinacji prognoz indywidualnych, otrzymanych za pomocą sztucznych sieci neuronowych, lub modeli przyczynowo-opisowych znacznie zwiększa ich dokładność.

Przeprowadzone badania empiryczne potwierdziły przydatność sztucznych sieci neuronowych do wyznaczania nieliniowych prognoz kombinowanych pod warunkiem otrzymania modelu neuronowego o dobrej jakości – w takich przypadkach okazały się one bardzo precyzyjnym narzędziem, generując prognozy o większej dokładności niż ich prognozy składowe, wyznaczone na podstawie modeli indywidualnych, oraz liniowe prognozy kombinowane.

Literatura

- Donaldson R., Kamstra M., *Forecast combining with neural networks*, „Journal of Forecasting” 1996, vol. 15.
- Hornik K., Stinchcombe M., White H., *Multilayer feedforward networks are universal approximators*, „Neural Networks” 1989, vol. 2.
- Liu B., Shi S., i Xu L., *Improving the accuracy of nonlinear combined forecasting using neural networks*, „Expert Systems with Applications” 1996, vol. 16.
- Perzyńska J., *Budowa prognoz kombinowanych z wykorzystaniem sztucznych sieci neuronowych*, Prace Naukowe Uniwersytetu Ekonomicznego we Wrocławiu nr 103, Wrocław 2010.

APPLICATION OF ARTIFICIAL NEURAL NETWORKS TO BUILD THE NONLINEAR COMBINED FORECASTS

Summary: The paper presents an application of artificial neural networks to build the nonlinear combined forecasts. The empirical example in which individual and combined forecasts are calculated for the economic variable with seasonal fluctuations is the illustration of theoretical considerations. The accuracy of nonlinear combined forecasts is compared with the accuracy of their component forecasts and linear combined forecasts.