

Aleksandra Matuszewska¹, Dorota Witkowska²

¹ Instytut Zarządzania PŁ, ² Katedra Ekonometrii i Informatyki SGGW

e-mail: almat@mail.p.lodz.pl; dwitkowska@mors.sggw.waw.pl

ANALIZA ZMIAN KURSU EURO/DOLAR: MODEL VAR I PERCEPTRON WIELOWARSTWOWY

Streszczenie: W analizach finansowych szeregów czasowych stosuje się często metody wielowymiarowego opisu zjawisk, takie jak na przykład modele wektorowej autoregresji (VAR). Alternatywnym do modeli VAR narzędziem badania mogą być jednokierunkowe sztuczne sieci neuronowe, do których należy perceptron wielowarstwowy (MLP). W pracy przedstawiono rezultaty wykorzystania modeli VAR i MLP do opisu zmian w szeregu kursu euro/dolar oraz tych zmiennych z rynku finansowego, które wpływają na badany kurs oraz ulegają zmianom pod wpływem kursu. Efektywność obu metod oceniono na podstawie dokładności wyznaczonych prognoz.

Słowa kluczowe: modele VAR, perceptron wielowarstwowy, kurs walutowy.

WPROWADZENIE

Postępujące procesy globalizacyjne powodują, że coraz więcej podmiotów gospodarczych jest uzależnionych od relacji występujących na rynku walutowym. Dlatego wiele z nich stara się zabezpieczyć przed negatywnymi skutkami zmian kursów walutowych. W tym celu stosowane są różne narzędzia wspomagające zarządzanie ryzykiem kursowym. Ważnym elementem w analizie ryzyka walutowego jest identyfikacja czynników ryzyka, ich analiza, a następnie wykorzystanie zdobytej wiedzy do wyboru narzędzi zabezpieczających. W ostatnich latach obserwuje się tendencje do stosowania tak zwanej wielowymiarowej analizy ryzyka. Polega ona na tym, że oprócz analizy pojedynczych czynników ryzyka, bada się też relacje pomiędzy nimi. Wykrywanie zależności między różnymi czynnikami ryzyka pozwala podmiotom gospodarczym na stosowanie bardziej zaawansowanych i skuteczniejszych metod zabezpieczania się przed ryzykiem (walutowym).

Kursy walutowe ulegają wahaniom pod wpływem zmian zachodzących w jego otoczeniu. Jednym z elementów analizy ryzyka może być badanie zależności pomiędzy kursami walut a innymi czynnikami, które mogą mieć charakter jednokierunkowy lub dwukierunkowy. Jednokierunkowy charakter relacji polega na tym, że albo kurs walutowy wpływa na dany czynnik, albo dany czynnik powoduje zmiany kursu walutowego. Z dwukierunkowa relacja występuje

wtedy, gdy jednocześnie kurs walutowy i analizowany czynnik wpływają na siebie nawzajem.

Do opisu relacji dwukierunkowych można wykorzystać modele wektorowej autoregresji (VAR - *Vector AutoRegression*). Modele VAR są dość wygodnym, „ateoretycznym” narzędziem w badaniu zależności na rynkach finansowych, bowiem przy ich konstrukcji nie wymaga się zgodności modelu z teorią ekonomii.

W analizach danych finansowych, jako alternatywne narzędzie do modeli statystycznych, stosuje się również sztuczne sieci neuronowe. Sztuczne sieci neuronowe (SSN) są modelami adaptacyjnymi o złożonej budowie. Atrakcyjność aplikacyjna sieci neuronowych wynika z kilku powodów. Po pierwsze, nie są potrzebne żadne założenia dotyczące natury rozkładu danych, których weryfikacja w przypadku danych finansowych jest niezwykle trudna. Po drugie SSN są modelami nieliniowymi, są zatem adekwatne do analizy szeregów finansowych, które są z natury nieliniowe i dynamiczne. Po trzecie, sieci neuronowe pozwalają wyznaczyć rozwiązanie nawet w przypadku, kiedy dane są niekompletne (por. [Witkowska 2002] s. 97).

Celem badań jest zastosowanie modeli VAR i SSN do analizy zmian kursu euro/dolar i wybranych czynników, które charakteryzują się wzajemnym dwustronnym oddziaływaniem.

MODEL VAR I PERCEPTRON WIELOWARSTWOWY

W badaniach dotyczących analizy danych ekonomicznych, prowadzonych w latach sześćdziesiątych i siedemdziesiątych dowiedziono, że nie zawsze wielorównaniowe strukturalne modele ekonometryczne są w stanie dawać lepsze rezultaty niż modele naiwne [Charemza, Deadman 1997, s. 21]. Na bazie powstałej krytyki do analizy danych ekonomicznych zaproponowano model VAR [Sims 1980].

Jak sama nazwa wskazuje, model VAR jest wielorównaniowym liniowym modelem o strukturze autoregresyjnej. Jest on wykorzystywany do analizy zmiennych stacjonarnych. W przypadku gdy dane są niestacjonarne, do opisu zależności stosuje się przekształcony VAR do postaci wektorowego modelu korekty błędem (VEC). Do modelu VAR dołącza się również tzw. zmienne deterministyczne (por. np. [Kusideł 2000], s. 15). Postać modelu VAR zapisuje się następująco:

$$\mathbf{Y}_t = \mathbf{A}_0 \mathbf{D}_t + \sum_{i=1}^p \mathbf{A}_i \mathbf{Y}_{t-i} + \boldsymbol{\varepsilon}_t \quad (1)$$

gdzie: \mathbf{Y}_t – macierz obserwacji dla K -zmiennych objaśnianych (K – jest jednocześnie liczbą równań w modelu VAR); t – numer obserwacji $t = 1, 2, \dots, T$; \mathbf{Y}_{t-p} – macierz obserwacji dla K -zmiennych objaśniających opóźnionych

w stosunku do zmiennej objaśnianej o p okresów; \mathbf{D}_t – macierz obserwacji dla deterministycznych składników równania, takich jak wyraz wolny, zmienna czasowa, zmienne zero-jedynkowe; \mathbf{A}_i – macierz parametrów, dla $i = 0, 1, \dots, p$; $\boldsymbol{\varepsilon}_t$ – wektor stacjonarnych zakłóceń losowych.

Sztuczne sieci neuronowe (SSN) są atrakcyjnym narzędziem w analizie danych finansowych [Azoff 1994], [Gately 1999], [Lula 1999], [Witkowska 2002], [Kaashoek, van Dijk 2000]. Cechami, które odróżniają sieci neuronowe od typowych statystycznych narzędzi są (por. [Witkowska 2002], s. 2, [Lula 1999], s. 13):

- zdolność do uczenia się przez co sieć potrafi nauczyć się prawidłowych reakcji na określony zespół bodźców (tj. może aproksymować dowolny typ zależności),
- umiejętność generalizacji, zdobytej w fazie uczenia, wiedzy,
- odporność na uszkodzenia (sieć działa poprawnie nawet wtedy gdy jest uszkodzona).

Rozwiązywanie zadań za pomocą sieci można podzielić na trzy etapy:

1. budowa sieci (tj. specyfikacja modelu),
2. uczenie sieci (czyli estymacja parametrów modelu) i
3. generalizacja wyników trenowania sieci (czyli ekstrapolacja modelu poza próbę estymacyjną, co może sprowadzić się np. do prognozowania).

Sztuczna sieć neuronowa składa się z określonej liczby połączonych ze sobą neuronów, które są elementami przetwarzającymi informacje ([Duch (red.) 2000], [Witkowska 2002]). Każdy neuron przetwarza skończoną liczbę sygnałów wejściowych x_i , $i = 1, \dots, n$ na jedno wyjście y , co można zapisać jako:

$$y = \varphi(e) = \varphi\left(\sum_{i=0}^n w_i x_i\right) \quad (2)$$

gdzie: x_i - wejścia (wartości wejściowe) neuronu dla $i = 1, 2, \dots, n$, $x_0 \equiv 0$, w_i - wagi (tj. parametry modelu, które należy oszacować w trakcie tzw. procesu trenowania), e - pobudzenia neuronu, $\varphi(e)$ - funkcję aktywacji (przejścia) neuronu, y - wyjście neuronu.

Postać funkcji aktywacji silnie wpływa na sposób przetwarzania informacji przez neuron. Najbardziej popularne są funkcje ([Witkowska 2002], s. 4-5): tożsamościowa, progowa, signum lub funkcje sigmoidalne postaci:

- logistyczna: $\varphi(e) = \frac{1}{1 + \exp(-\beta e)}$,
- tangens hiperboliczny: $\varphi(e) = \tanh(\beta e) = \frac{\exp(\beta e) - \exp(-\beta e)}{\exp(\beta e) + \exp(-\beta e)}$.

Najczęściej sztuczne sieci neuronowe mają budowę warstwową. Wyróżnia się trzy rodzaje warstw: wejściową, wyjściową oraz ukryte. Neurony w warstwie wejściowej przetwarzają pojedyncze sygnały wejściowe (zmienne objaśniające). Neurony w warstwie wyjściowej dostarczają ostatecznie przetworzone wartości sygnałów wyjściowych, które podlegają interpretacji (zmienne objaśniane). Neurony w warstwie ukrytej przetwarzają sygnały wyjściowe z neuronów z poprzedzającej warstwy (którą może być warstwa wejściowa) i własny sygnał wyjściowy przekazują do następnej warstwy (którą może być warstwa wyjściowa). Ze względu na sposoby połączeń pomiędzy neuronami, sieci mogą być różnie zaprojektowane, a co za tym idzie mogą rozwiązywać różne problemy.

W zagadnieniach regresyjnych najczęściej wykorzystywane są sieci jednokierunkowe (por. [Lula 1999], s. 9), w których informacje są przetwarzane jednokierunkowo – od warstwy wejściowej do wyjściowej. Najbardziej popularną siecią jest perceptron wielowarstwowy (*MultiLayer Perceptron* – MLP), który składa się z trzech lub więcej warstw neuronów.

Trenowanie sieci polega na oszacowaniu parametrów (tj. wag) modelu nieliniowego. Najczęściej wykorzystywane są do tego celu algorytmy: wstecznej propagacji błędów, gradientów sprzężonych, quasi-Newtona i Levenberga-Marquardta. Wytrenowane sieci ocenia się za pomocą znanych miar dokładności dopasowania oraz – jeśli ich charakterystyki są zadowalające – można je wykorzystać do prognozowania.

OCENA MODELI

Po otrzymaniu wartości teoretycznych z modeli VAR oraz sieci MLP należy dokonać oceny uzyskanych wyników. Jednym z kryteriów może być kryterium AIC (kryterium informacyjne Akaike), które wyznacza się z następującego wzoru:

$$AIC = -2 \cdot \frac{l}{T} + \frac{2s}{T} \quad (3)$$

gdzie: s – liczba szacowanych parametrów w modelu, T – liczba obserwacji, l – wartość logarytmu funkcji wiarygodności, którą dla pojedynczego równania wyznacza się jako:

$$l = -\frac{T}{2} \left[1 + \ln(2\pi) + \ln\left(\frac{1}{T} \sum_{t=1}^T e_t^2\right) \right] \quad (4)$$

gdzie dla obserwacji t : e_t^2 – reszta w modelu: $e_t = y_t - \hat{y}_t$, \hat{y}_t – wartość teoretyczna, y_t – wartość empiryczna.

Dla modelu VAR wartość logarytmu funkcji wiarygodności można obliczyć ze wzoru:

$$l = -\frac{T}{2} \left\{ K[1 + \ln(2\pi)] + \ln(|\hat{\Omega}|) \right\} \quad (5)$$

gdzie: $|\hat{\Omega}| = \det\left(\frac{1}{T-s}\Sigma_\varepsilon\right)$, K – liczba równań w modelu VAR, Σ_ε – macierz wariancji-kowariancji dla składników losowych modelu (1).

Oceny jakości modelu można dokonać na podstawie wartości błędów *ex post* (por. [Welfe 2003], s. 231-237):

- względny średni błąd absolutny:

$$MAPE = \frac{1}{T} \sum_{t=1}^T \left| \frac{y_t - \hat{y}_t}{y_t} \right| \quad (6)$$

- względny błąd średniokwadratowy:

$$RASE = \frac{1}{T} \sum_{t=1}^T \left(\frac{y_t - \hat{y}_t}{y_t} \right)^2 \quad (7)$$

- skorygowany względny średni błąd absolutny:

$$MAPE^* = \frac{\sum_{t=1}^T |y_t - \hat{y}_t|}{\sum_{t=1}^T |y_t|} \quad (8)$$

- skorygowany względny błąd średniokwadratowy:

$$RASE^* = \sqrt{\frac{\sum_{t=1}^T (y_t - \hat{y}_t)^2}{\sum_{t=1}^T y_t^2}} \quad (9)$$

Błędy tej postaci, liczone dla próby estymacyjnej są błędami dopasowania, natomiast liczone dla danych spoza próby estymacyjnej są błędami prognoz *ex post*. Im mniejsza wartość błędów średnich tym model zostanie lepiej oceniony.

Innymi miarami, które można wykorzystać do oceny modelu są mierniki zgodności odwzorowania zmian *in plus* oraz *in minus*. Wykorzystanie takich miar pozwala stwierdzić, czy przy zastosowaniu danego modelu można dobrze opisać kierunki zmian w szeregu. Najprostszą miarą jest następująca statystyka:

$$S = \frac{\sum_{t=1}^T s_t}{T} \quad (10)$$

gdzie: $s_t = \begin{cases} 1 & \text{gdy } (y_t \geq 0 \text{ i } \hat{y}_t \geq 0) \text{ lub } (y_t \leq 0 \text{ i } \hat{y}_t \leq 0) \\ 0 & \text{gdy } (y_t > 0 \text{ i } \hat{y}_t < 0) \text{ lub } (y_t < 0 \text{ i } \hat{y}_t > 0) \end{cases}$

OPIS EKSPERYMENTÓW

Zbudowano dwurównaniowe modele VAR, które wykorzystano do zbadania relacji pomiędzy kursem euro/dolar a zmienną, która jednocześnie wpływa na zmiany kursu tej pary walut, jak też ulega wahaniom pod wpływem kursu euro/dolar (relacja $X \leftrightarrow Y$). Kurs euro/dolar oznaczmy przez Y , a pozostałe zmienne - przez X . Czynniki, oznaczone jako zmienna X , wybrano na podstawie wyników testu przyczynowości Grangera. Długość maksymalnego opóźnienia w modelu VAR ustalono za pomocą kryterium AIC. Listę zmiennych uwzględnionych w badaniu oraz rząd maksymalnych opóźnień przedstawiono w tab. 1.

Tabela 1. Zależności przyczynowe wykryte na bazie testu przyczynowości Grangera przy uwzględnieniu kursu euro/dolar dla zmiennej w postaci dziennych logarytmicznych stóp zwrotu (relacja $X \leftrightarrow Y$ z kursem euro/dolar)

LP	Zmienna X	Opis
1	eur_index (2)	Indeks dla notowań kursów uwzględniających euro
2	usd_index (2)	Indeks dla notowań kursów uwzględniających dolara amerykańskiego
3	chf_index (2)	Indeks dla notowań kursów uwzględniających franka szwajcarskiego
4	eur_gbp (2)	Kurs euro/ funt brytyjski
5	gbp_index (3)	Indeks dla notowań kursów uwzględniających funta brytyjskiego
6	Hangseng (1)	Indeks giełdy w Hong Kongu – Hang Seng
7	Gold (4)	Notowania kontraktów futures na złoto
8	chf_usd_fut (5)	Notowania kontraktów futures wystawionych na kurs frank szw./dolar

Źródło. Opracowanie własne. W nawiasach obok zmiennej podano wartość opóźnienia zmiennych w modelu VAR.

Zastosowanie modeli VAR wymaga, aby szeregi zmiennych były szeregami stacjonarnymi. Z tego względu wszystkie szeregi zostały przetransformowane do postaci logarytmicznych stóp zwrotu.

$$y_{dt} = \ln \left(\frac{Y_{dt}}{Y_{dt-1}} \right) \quad (11)$$

gdzie: Y_{dt} – dzienne notowania kursu zamknięcia dla analizowanego waloru w okresie t , Y_{dt-1} – opóźnione o jeden dzień notowania kursu zamknięcia.

Analizy przeprowadzono w oparciu o dane dzienne z okresu od 04.01.1999 r. do 05.12.2003 r. Podział podstawowej próby był następujący: ostatnie 50 obserwacji stanowiło próbę prognostyczną w modelach VAR a dla MLP - próbę testową. Natomiast pozostałe obserwacje tworzyły próbę estymacyjną w modelach VAR a dla MLP – próbę uczącą. Prognozy szacowano na jeden okres do przodu.

Sieci MLP zawierały trzy warstw. Liczba neuronów w warstwie wejściowej była równa liczbie zmiennych objaśniających¹ w modelach VAR, natomiast liczba neuronów w warstwie wyjściowej wynosiła dwa (tj. tyle co liczba zmiennych objaśnianych w modelach VAR). Liczbę neuronów w warstwie ukrytej ustalono na poziomie $2N+1$, gdzie N jest liczbą neuronów w warstwie wejściowej (por. [Azoff 1994], s. 50). Wykorzystano dwie postacie funkcji aktywacji: logistyczną (w sieci MLP1) i tangens hiperboliczny (w sieci MLP2). Do uczenia sieci zastosowano algorytm wstecznej propagacji błędów.

WYNIKI EKSPERYMENTÓW

Ocenę jakości modeli VAR i sieci MLP przeprowadzono zarówno dla próby estymacyjnej (zbioru uczącego), jak i dla próby prognostycznej (zbioru testowego). Dla pierwszej próby policzono wartość kryterium AIC, błędy dopasowania $MAPE^*$ i $RASE^*$ oraz S .

Tabela 2. Wyniki dla pary zmiennych euro/dolar – eur_index

eur_index		AIC	MAPE*	RASE*	S	MAPE	RASE
Próba estymacyjna Równanie dla zm. euro/dolar	VAR	-7,2877	0,9350	0,9340	0,59	$4,88 \cdot 10^{-3}$	$6,30 \cdot 10^{-3}$
	MLP1	-7,2683	0,9424	0,9432	0,59	$4,92 \cdot 10^{-3}$	$6,37 \cdot 10^{-3}$
	MLP2	-7,2874	0,9348	0,9342	0,59	$4,88 \cdot 10^{-3}$	$6,31 \cdot 10^{-3}$
Próba estymacyjna Równanie dla zm. eur_index	VAR	-8,1603	0,973	0,9708	0,59	$3,14 \cdot 10^{-3}$	$4,08 \cdot 10^{-3}$
	MLP1	-8,16	0,9734	0,971	0,59	$3,14 \cdot 10^{-3}$	$4,08 \cdot 10^{-3}$
	MLP2	-8,1605	0,9732	0,9707	0,58	$3,14 \cdot 10^{-3}$	$4,07 \cdot 10^{-3}$
Próba estymacyjna Cały model	VAR	-16,5174	0,9495	0,9445	0,49	$4,01 \cdot 10^{-3}$	$5,31 \cdot 10^{-3}$
	MLP1	-5,4546	0,9543	0,9912	0,47	$4,03 \cdot 10^{-3}$	$5,34 \cdot 10^{-3}$
	MLP2	-5,5174	0,9495	0,9445	0,48	$4,01 \cdot 10^{-3}$	$5,31 \cdot 10^{-3}$
Próba testowa Równanie dla zm. euro/dolar	VAR	---	0,9607	0,9941	0,6	$5,49 \cdot 10^{-3}$	$7,00 \cdot 10^{-3}$
	MLP1	---	0,9653	0,9903	0,6	$5,51 \cdot 10^{-3}$	$6,97 \cdot 10^{-3}$
	MLP2	---	0,9625	0,9927	0,62	$5,50 \cdot 10^{-3}$	$6,99 \cdot 10^{-3}$
Próba testowa Równanie dla zm. eur_index	VAR	---	0,9639	0,9981	0,64	$3,61 \cdot 10^{-3}$	$4,57 \cdot 10^{-3}$
	MLP1	---	0,962	0,9935	0,6	$3,61 \cdot 10^{-3}$	$4,55 \cdot 10^{-3}$
	MLP2	---	0,9693	0,9985	0,62	$3,63 \cdot 10^{-3}$	$4,58 \cdot 10^{-3}$
Próba testowa Cały model	VAR	---	0,9619	0,9953	0,52	$4,55 \cdot 10^{-3}$	$5,91 \cdot 10^{-3}$
	MLP1	---	0,964	0,9912	0,46	$4,56 \cdot 10^{-3}$	$5,89 \cdot 10^{-3}$
	MLP2	---	0,9652	0,9945	0,5	$4,57 \cdot 10^{-3}$	$5,91 \cdot 10^{-3}$

Źródło. Opracowanie własne.

¹ Listy zmiennych wejściowych i wyjściowych sieci neuronowych są takie same jak listy zmiennych odpowiednio: objaśniających i objaśnianych w modelu VAR.

Dla próby prognostycznej obliczono błędy prognoz *ex post* *MAPE** i *RASE** oraz *S*. Błędy zostały wyznaczone dla każdej zmiennej osobno oraz łącznie dla obu zmiennych (tj. jeden błąd dla całego modelu). W tym drugim przypadku, błędy *MAPE** i *RASE** były liczone w taki sposób, że za wartości \hat{y}_t przyjęto wszystkie wyznaczone wartości teoretyczne, a za y_t przyjęto wartości empiryczne zmiennych objaśnianych. W przypadku błędu *S* za zgodną zmianę uznano taką, kiedy kierunki zmian obu wartości wyjściowych z modelu pokrywały się z rzeczywistymi zmianami. We wszystkich przypadkach wartości logarymicznych stóp zwrotu przeliczono na poziomy (ceny badanych instrumentów) oraz obliczono dla nich wartości błędów *MAPE* i *RASE*. Spośród wszystkich analizowanych modeli, najmniejsze wartości średnich błędów (6) – (9) oraz największe wartości miernika zgodności zmian *S* (10) otrzymano dla trzech modeli, w których za zmienną *X* przyjęto jedną ze zmiennych:

1. indeks notowań kursów uwzględniających euro: *eur_index*,
2. notowania kontraktów futures wystawionych na kurs frank szwajcarski/dolar amerykański: *chf_usd_fut*,
3. indeks notowań kursów uwzględniających funta brytyjskiego: *gbp_index*.

Tabela 3. Wyniki dla pary zmiennych euro/dolar – kontrakty futures wystawione na kurs *chf/usd* (*chf_usd_fut*).

<i>chf_usd_fut</i>		AIC	MAPE*	RASE*	S	MAPE	RASE
Próba estymacyjna Równanie dla zm. euro/dolar	VAR	-7,4142	0,8673	0,8785	0,56	4,52*10 ⁻³	5,92*10 ⁻³
	MLP1	-7,3985	0,8778	0,8854	0,29	4,57*10 ⁻³	5,96*10 ⁻³
	MLP2	-7,4071	0,8764	0,8816	0,56	4,56*10 ⁻³	5,94*10 ⁻³
Próba estymacyjna Równanie dla zm. <i>chf_usd_fut</i>	VAR	-7,1239	0,9968	0,9971	0,57	5,29*10 ⁻³	6,85*10 ⁻³
	MLP1	-7,1156	1,0022	1,0013	0,56	3,17*10 ⁻³	4,13*10 ⁻³
	MLP2	-7,1205	0,9992	0,9988	0,57	3,22*10 ⁻³	4,19*10 ⁻³
Próba estymacyjna Cały model	VAR	-15,0465	0,9326	0,9971	0,32	4,90*10 ⁻³	6,40*10 ⁻³
	MLP1	-5,5912	0,9405	0,9405	0,16	3,87*10 ⁻³	5,13*10 ⁻³
	MLP2	-5,6229	0,9384	0,9734	0,31	3,89*10 ⁻³	5,14*10 ⁻³
Próba testowa Równanie dla zm. euro/dolar	VAR	---	0,9495	0,9631	0,62	5,43*10 ⁻³	6,78*10 ⁻³
	MLP1	---	0,9296	0,9515	0,36	5,31*10 ⁻³	6,70*10 ⁻³
	MLP2	---	0,9461	0,9513	0,62	5,40*10 ⁻³	6,70*10 ⁻³
Próba testowa Równanie dla zm. <i>chf_usd_fut</i>	VAR	---	0,9933	0,9974	0,52	5,97*10 ⁻³	7,73*10 ⁻³
	MLP1	---	0,9811	0,9880	0,62	3,71*10 ⁻³	4,48*10 ⁻³
	MLP2	---	0,9795	0,9913	0,56	3,76*10 ⁻³	4,62*10 ⁻³
Próba testowa Cały model	VAR	---	0,9720	0,9820	0,32	5,70*10 ⁻³	7,27*10 ⁻³
	MLP1	---	0,9560	0,9717	0,22	4,51*10 ⁻³	5,70*10 ⁻³
	MLP2	---	0,9632	0,9734	0,36	4,58*10 ⁻³	5,75*10 ⁻³

Źródło. Opracowanie własne.

W tabelach 2 i 3 przedstawiono wybrane wyniki uzyskane dla dwóch pierwszych modeli. W próbie estymacyjnej (uczącej) najlepszy wyniki dla zmiennej euro/dolar otrzymano z modelu, gdzie za zmienną X przyjęto *chf_usd_fut* (tab. 3). W tym przypadku wszystkie wartości błędów są najmniejsze, a zgodność kierunków zmian – największa (68%). Najlepszym modelem dla zmiennej X okazał się model ze zmienną *eur_index*. W tym przypadku również otrzymano najmniejsze wartości średnich błędów dopasowania oraz największą zgodność kierunków zmian (59%). Najmniejsze błędy *MAPE** i *RASE** liczone dla całego modelu otrzymano dla modelu ze zmienną *chf_usd_fut*. Natomiast największą zgodność kierunków zmian (49%) w przypadku modelu ze zmienną *eur_index* (tab. 2). W próbie testowej dla zmiennej euro/dolar w modelach ze zmiennymi *chf_usd_fut*, *eur_index* oraz *gbp_index* otrzymano największą zgodność kierunków zmian (62%). Średnie błędy *MAPE** i *RASE** najmniejsze były dla modelu ze zmienną *chf_usd_fut*. Dla zmiennej X najlepszą zgodność kierunków zmian uzyskano dla modelu ze zmienną *eur_index* (64%), a najmniejsze błędy: *MAPE** - dla zmiennej *eur_index*, *RASE** - dla zmiennej *chf_usd_fut*. Jakość całego modelu w odniesieniu do przewidywania obu zmiennych najlepsza była dla modelu ze zmienną *eur_index* (zgodność kierunków zmian 52%), a najmniejsze średnie błędy *MAPE** i *RASE** uzyskano dla modelu ze zmienną *chf_usd_fut*.

PODSUMOWANIE

Celem przedstawionych badań była analiza zmian kursu euro/dolar i wybranych czynników, które charakteryzują się wzajemnym dwustronnym oddziaływaniem. W badaniach wykorzystano dwurównaniowe modele VAR i sztuczne sieci neuronowe SSN o dwóch neuronach w warstwie wyjściowej. Innymi słowy przeprowadzona analiza dotyczyła zastosowania modeli liniowych VAR i modeli nieliniowych tj. perceptronów wielowarstwowych MLP1 i MPL2. Spośród 24 oszacowanych modeli najlepsze wyniki uzyskano dla modeli, w których wybranym czynnikiem (tj. zmienną X) jest jedna ze zmiennych *eur_index*, *gbp_index*, *chf_usd_fut*.

Biorąc pod uwagę kryterium najmniejszych błędów *MAPE** i *RASE** (jak też *MAPE* i *RASE*) należy stwierdzić, że zmiany kursu euro/dolar były najlepiej objaśnianie oraz prognozowane przez model ze zmienną: notowania kontraktów futures, wystawionych na kurs frank szwajcarski/dolar amerykański *chf_usd_fut*. Analizując kryterium zgodności kierunków zmian, najlepszym okazał się model ze zmienną: indeks notowań kursów uwzględniających euro *eur_index* (dla próby estymacyjnej) oraz modele ze zmiennymi *eur_index*, *gbp_index*, *chf_usd_fut* (dla próby testowej). Warto również odnieść się do obu klas modeli, które zostały wykorzystane w badaniach. Z przeprowadzonych analiz wynika, że o ile w przypadku próby estymacyjnej (uczącej) modele VAR mają nieco lepsze

charakterystyki, to dla próby prognostycznej (testowej) sieci neuronowe można uznać za modele, które w większości przypadków lepiej sobie radzą z przewidywaniem przyszłych wartości.

LITERATURA

- Azoff E.M. (1994) *Neural Network Time Series Forecasting of Financial Markets*, Wiley, Chichester
- Sims C.A. (1980) *Macroeconomics and Reality*, *Econometrica*, Vol. 48, str. 1-48
- Charemza W., Deadman D.F. (1997) *Nowa ekonometria*, PWE, Warszawa
- Duch W., Korbicz J., Rutkowski L., Tadeusiewicz R. (2000) *Biocybernetyka i inżynieria biomedyczna*, Tom 6: *Sieci Neuronowe*, Akademicka Oficyna Wydawnicza EXIT, Warszawa
- EViews 4 User Guide (2001) *Quantitative Micro Software LLC*
- Gately E. (1999) *Sieci neuronowe. Prognozowanie finansowe i projektowanie systemów transakcyjnych*, WIG PRESS, Warszawa 1999
- Kaashoek J.F., van Dijk H.K. (2000) *Neural Networks as Econometric Tool*, maszynopis, *Econometric Institute Rapport EI2000 - 31A*, Erasmus University Rotterdam
- Kusideł E. (2000) *Modele wektorowo-autoregresyjne VAR. Metodologia i zastosowania*, w: Suhecki B. [red.]: *Dane panelowe i modelowanie wielowymiarowe w badaniach ekonomicznych*, tom 3, Absolwent, Łódź
- Lula P. (1999) *Jednokierunkowe sieci neuronowe w modelowaniu zjawisk ekonomicznych*, Wydawnictwo Akademii Ekonomicznej w Krakowie, Kraków.
- Witkowska D. (2005) *Podstawy ekonometrii i teorii prognozowania*, Oficyna Ekonomiczna, Kraków
- Witkowska D. (2002) *Sztuczne sieci neuronowe i metody statystyczne*, C.H.Beck, Warszawa

The Euro/ Dollar Exchange Rate Analysis: VAR Model and Multilayer Perceptron

Summary: In the financial time series analysis one often recommends the application of the multidimensional methods such as the vector autoregression model – VAR, that was proposed by Sims in 1980. The feedforward artificial neural networks, especially multilayer perceptron – MLP, can be considered as an alternative, for VAR model, tool. In the paper we discuss the results of the euro/dollar time series investigation that is provided employing VAR and MLP models. The efficiency of both methods is evaluated in terms of ex-post errors. The source of the analysed series is REUTERS data base from the 4th of January 1999 till the 5th of December 2003. In our investigation we consider the euro/dollar exchange rate and selected financial instrument time series. The models are constructed for the euro/dollar exchange rate that is transformed into daily logarithmic rate of returns.

Key words: VAR model, multilayer perceptron, euro/dollar exchange rate