

Jerzy Stelmach

Uniwersytet Ekonomiczny we Wrocławiu

ZASTOSOWANIE MODELU WEKTOROWEJ AUTOREGRESJI DO PROGNOZOWANIA KURSU WALUTOWEGO

Streszczenie: Prognozowanie kursów walutowych należy do trudnych, a jednocześnie bardzo ważnych zagadnień z zakresu nauk ekonomicznych. W artykule podjęto próbę opracowania prognoz kursu walutowego EUR/PLN na podstawie dynamicznego modelu wektorowej autoregresji. Uzyskane wyniki przemawiają na rzecz aprecjacji polskiej waluty w stosunku do euro w przyjętym okresie prognozy.

Słowa kluczowe: kurs walutowy, model wektorowej autoregresji, prognozowanie.

1. Wstęp

Kursy walutowe odgrywają podstawową rolę w funkcjonowaniu systemów ekonomicznych i stanowią jeden z najważniejszych instrumentów rynku finansowego. W sferze realnej ich oddziaływanie obejmuje bezpośrednio sektor handlu zagranicznego, podczas gdy w sferze nominalnej kluczowe jest sprzężenie zwrotne zachodzące pomiędzy kursami i poziomem cen. W ramach analizy rynków finansowych uwagę należy skoncentrować na wpływie zmian kursów walutowych na szeroko rozumiany majątek podmiotów gospodarczych.

Współzależność systemów gospodarczych sprawia, że dokonanie oceny wpływu na gospodarkę tendencji obserwowanych na rynkach walutowych jest niemożliwe bez wykorzystania zawansowanych metod ekonometrycznych. Analizę krótkookresową należy prowadzić w ramach metodologii ARCH. Rozważenie dłuższych horyzontów decyzyjnych jest natomiast możliwe dzięki wykorzystaniu metod wektorowej autoregresji i kointegracji, zapewniających poprawne modelowanie i prognozowanie tendencji w długim okresie¹.

Celem artykułu jest próba sporządzenia prognoz kursu walutowego EUR/PLN na podstawie dynamicznego modelu wektorowej autoregresji. Kurs ten wybrano ze względu na kilka czynników; są nimi: planowane przyjęcie przez Polskę wspólnej waluty europejskiej, zmniejszenie się roli dolara amerykańskiego jako waluty

¹ Por. praca [Brzeszczyński, Kelm 2002].

światowej, coraz bliższa współpraca gospodarcza Polski z innymi krajami Unii Europejskiej.

W badaniach empirycznych jako źródeł danych dotyczących Polski użyto miesięcznych biuletynów informacyjnych Narodowego Banku Polskiego. Ze względu na makroekonomiczny charakter modelowanych relacji przyjęto miesięczną częstotliwość danych, badaniem zaś objęto okres od stycznia 1999 r. do września 2007 r., co pozwala na dysponowanie próbą złożoną ze 105. obserwacji.

2. Makroekonomiczne determinanty kursu walutowego

Kurs walutowy może ulegać znacznym wahaniom. W pewnej mierze przyczyny tej zmienności można wytłumaczyć. Służą do tego tradycyjne, makroekonomiczne determinanty kursu walutowego. Należą do nich tempo wzrostu gospodarczego, poziom realnej stopy procentowej oraz tempo wzrostu cen.

Szybsze tempo rozwoju gospodarczego w danym kraju przekłada się na wzrost importu, a w konsekwencji – na wzrost popytu na walutę obcą. Można się zatem spodziewać deprecjacji waluty krajowej. Z kolei wyższa realna stopa procentowa oznacza większy zwrot z kapitału zainwestowanego w danym kraju, zwiększający popyt na krajową walutę, co prowadzi do jej aprecjacji. Wyższy poziom trzeciego czynnika fundamentalnego, czyli inflacji sprawia, że towary krajowe stają się relatywnie coraz mniej konkurencyjne cenowo względem towarów zagranicznych. Zwiększa to popyt na towary i usługi zagraniczne, co powoduje wzrost popytu na walutę zagraniczną i ostatecznie prowadzi do deprecjacji waluty krajowej. W tym samym czasie spadający popyt zagraniczny na towary krajowe skutkuje dalszą deprecjacją waluty krajowej.

Przedstawiony mechanizm kształtowania się kursu walutowego jest schematyczny i ma wiele ograniczeń. Działa on przede wszystkim wtedy, gdy wprowadzenie założenia *ceteris paribus* znajduje uzasadnienie. W dłuższym okresie występują również inne zjawiska, które mogą zmieniać atrakcyjność cenową bądź inwestycyjną kraju. Działają również czynniki podażowe powodujące, że mimo wzrostu produktu krajowego, nie musi dochodzić do zwiększenia importu. Duże znaczenie ma również stan finansów publicznych kraju, ponieważ duże zadłużenie osłabia zaufanie do waluty. Istotny jest także stan bilansu płatniczego. Duży deficyt w handlu zagranicznym sprzyja spadkowi kursu, nadwyżka natomiast sprzyja jego wzrostowi. Kluczową kwestią są jednak różnego rodzaju oczekiwania. Praktyka pokazuje, że psychologia rynku walutowego jest bardzo złożona – często do znacznych wahań kursu dochodzi w oderwaniu od czynników fundamentalnych, które omówiono wcześniej. Co więcej, rynek walutowy to nie tylko transakcje na rynku kasowym, lecz również handel opierający się na kontraktach terminowych. Kwestie oczekiwań, gry spekulacyjnej oraz rozciągnięcie zawarcia kontraktu i aktualnej dostawy w czasie sprawiają, że tradycyjne determinanty kursu walutowego są uproszczonym

spojrzeniem na rzeczywistość i nie zawsze pozwalają na wyciągnięcie właściwych wniosków.

3. Model wektorowej autoregresji

W celu sporządzenia prognoz *ex ante* kursu walutowego zostanie zbudowany model wektorowej autoregresji (*Vector Autoregression Model* – VAR). Model ten stanowi najbardziej ogólną reprezentację zależności dynamicznych występujących w modelowanym systemie. Składa się on z regresji każdej zmiennej bieżącej (nieopóźnionej) modelu względem wszystkich zmiennych modelu opóźnionych o pewną liczbę okresów, na parametry zaś nie zostały nałożone warunki poboczne, a więc model VAR dla m zmiennych można zapisać jako (por. [Charemza, Deadman 1997]):

$$\mathbf{Z}_t = \sum_{i=1}^k \mathbf{A}_i \mathbf{Z}_{t-i} + \boldsymbol{\varepsilon}_t, \quad (1)$$

gdzie: \mathbf{Z}_t – wektor nieopóźnionych wartości wszystkich m zmiennych modelu w okresie t ,

\mathbf{A}_i – macierze parametrów modelu, $\dim(\mathbf{A}_i) = [m, m]$,

$\boldsymbol{\varepsilon}_t$ – wektor składników losowych, o których zwykle zakłada się, że są skorelowane ze sobą dla tego samego okresu, ale nie wykazują autokorelacji, tak więc macierz kowariancji jest niediagonalna, poza tym $\boldsymbol{\varepsilon}_t$ ma wielowymiarowy rozkład normalny,

k – maksymalna wielkość opóźnienia.

Ponieważ model VAR ma po prawej stronie tylko zmienne opóźnione, i zmienne te z definicji są nieskorelowane ze składnikiem losowym (przy zakładanym braku autokorelacji), to można go oszacować w sposób zgodny, równanie po równaniu, metodą najmniejszych kwadratów. Często poszczególne równania ogólnego modelu wektorowej autoregresji są uzupełniane dodatkowym zestawem składowych deterministycznych, takich jak wyraz wolny, trend deterministyczny i sezonowe zmienne zero-jedynkowe. Ważnym zagadnieniem w metodologii VAR jest wybór długości opóźnienia k . W artykule w tym celu zostaną wykorzystane standardowe statystyczne kryteria informacyjne.

Korzyści z zastosowania modelu wektorowej autoregresji wynikają stąd, iż nie wyklucza się w nim żadnego sprzężenia między zmiennymi. Odnosi się to także do związków międzyokresowych – VAR obejmuje mechanizmy formułowania oczekiwań i mechanizmy adaptacyjne, jeżeli w modelu występują wszystkie zmienne uwzględniane w tych procesach. Drugim aspektem uzasadniającym wykorzystanie modelu VAR jest jego niewielka wrażliwość na zagrożenia akcentowane w ramach krytyki Lucasa.

Na podstawie przesłanek teoretycznych skonstruowany zostanie wielorównaniowy model VAR uwzględniający pięć zmiennych makroekonomicznych: kurs

walutowy EUR/PLN, podaż pieniądza M3, WIBOR 1M, produkcję sprzedaną przemysłu (PSP) oraz wskaźnik inflacji PPI. Procedurę specyfikacji modelu VAR bezwzględnie należy poprzedzić zbadaniem pewnych własności danych, a mianowicie stacjonarności oraz kointegracji.

Dla pięciu analizowanych zmiennych wyniki badania² stacjonarności przedstawia tab. 1. Na tej podstawie należy stwierdzić niestacjonarność wszystkich zmiennych na każdym z trzech rozważanych poziomów istotności.

Tabela 1. Wyniki testu ADF dla poziomów wybranych zmiennych

Zmienna	Wartość statystyki testowej	Wartości krytyczne testu ADF			Wniosek
		$\alpha = 0,01$	$\alpha = 0,05$	$\alpha = 0,1$	
Kurs EUR/PLN	-1,5987	-3,49	-2,89	-2,58	szereg niestacjonarny
Podaż pieniądza M3	1,6725				szereg niestacjonarny
WIBOR 1M	-1,4002				szereg niestacjonarny
PSP	-2,4932				szereg niestacjonarny
PPI	-0,6169				szereg niestacjonarny

Źródło: obliczenia własne.

Wniosek ten potwierdzają wyniki badania testem ADF dla pierwszych różnic zmiennych zamieszczone w tab. 2. W tym przypadku obliczone statystyki testowe są mniejsze od wartości krytycznych testu, co wskazuje na stacjonarność szeregów pierwszych przyrostów zmiennych.

Tabela 2. Wyniki testu ADF dla pierwszych różnic wybranych zmiennych

Zmienna	Wartość statystyki testowej	Wartości krytyczne testu ADF			Wniosek
		$\alpha = 0,01$	$\alpha = 0,05$	$\alpha = 0,1$	
Kurs EUR/PLN	-7,0489	-3,49	-2,89	-2,58	szereg stacjonarny
Podaż pieniądza M3	-9,0399				szereg stacjonarny
WIBOR 1M	-4,5781				szereg stacjonarny
PSP	-11,3998				szereg stacjonarny
PPI	-3,5287				szereg stacjonarny

Źródło: obliczenia własne.

W celu weryfikacji występowania zjawiska kointegracji³ została przeprowadzona procedura Johansena przy założeniu czterech opóźnień i obecności wyrazu wolnego w równaniu kointegrującym. Zastosowano dwa rodzaje testów rzędu ko-

² Wszystkie obliczenia oraz wykresy wykonano za pomocą pakietu komputerowego Eviews.

³ Formalne definicje kointegracji można znaleźć np. w pracy: [Charemza, Deadman 1997].

integracji: test śladu oraz test maksymalnej wartości własnej. Obydwa należą do rodziny testów ilorazu wiarygodności. W przypadku przedstawionych w tab. 3 testów śladu i maksymalnej wartości własnej wyniki jednoznacznie wskazują na istnienie dwóch relacji kointegrujących na poziomie istotności 5% między pięcioma badanymi zmiennymi. Liczba niezależnych relacji kointegrujących wskazuje, ilu zmiennych endogenicznych należy się spodziewać w systemie długookresowym, chociaż nie precyzuje, jakie to będą zmienne.

Tabela 3. Wyniki testu rzędu kointegracji Johansena

Hipoteza: Liczba relacji kointegrujących	Wartość własna	Statystyka śladu	0,05 Wartość krytyczna	<i>p-value</i> **
Test śladu				
Brak*	0,360366	99,52710	69,81889	0,0000
Co najwyżej jedna*	0,258232	54,84116	47,85613	0,0096
Co najwyżej dwie	0,151588	24,96934	29,79707	0,1625
Co najwyżej trzy	0,058018	8,530465	15,49471	0,4106
Co najwyżej cztery	0,025212	2,553551	3,841466	0,1100
Test maksymalnej wartości własnej				
Brak*	0,360366	44,68595	33,87687	0,0018
Co najwyżej jedna *	0,258232	29,87182	27,58434	0,0250
Co najwyżej dwie	0,151588	16,43888	21,13162	0,2002
Co najwyżej trzy	0,058018	5,976915	14,26460	0,6162
Co najwyżej cztery	0,025212	2,553551	3,841466	0,1100

* Odrzucenie hipotezy przy poziomie istotności 0,05.

** Wartości *p-value* według pracy [MacKinnon, Haug, Michelis 1999].

Źródło: obliczenia własne.

Po empirycznym stwierdzeniu niestacjonarności zmiennych oraz występowania zjawiska kointegracji istnieją dwie możliwości specyfikacji odpowiedniego modelu wektorowej autoregresji: bezwarunkowy model wektorowej autoregresji oraz wektorowy model korekty błędem (*Vector Error Correction Model* – VECM). W przypadku bezwarunkowego modelu VAR nie nakłada się żadnych dodatkowych ograniczeń na parametry lub ich kombinacje. W układach VECM dokonuje się kombinacji zarówno zaburzeń fundamentalnych o charakterze długookresowym, jak i zależności krótkookresowych. Cechą modeli VECM jest występowanie w charakterze zmiennej objaśniającej opóźnionej o jeden okres odchylenia rzeczywistej wartości

zmiennej objaśnianej od tej, która wynika z relacji długookresowej. Odchylenie to stanowi miarę „błędu równowagi” popełnionego w poprzednim okresie.

Jednoznaczność wyboru między dwiema alternatywnymi specyfikacjami – VAR czy VECM – pozostaje kwestią nierozwiązaną i dyskusyjną. Konieczność nakładania dodatkowych restrykcji kointegracyjnych w modelach VECM w żaden sposób nie gwarantuje rzetelności oszacowań, interpretacji i wnioskowania (por. [Faust, Leeper 1997]). Ponadto nie istnieją przekonujące dowody na to, że modele VECM dostarczają lepszych prognoz od bezwarunkowych modeli VAR. Praca [Naka, Tufte 1997] pokazuje, iż modele VAR i VECM cechują się podobnymi własnościami prognostycznymi. Obszerne uzasadnienie stosowania bezwarunkowych modeli VAR podano również w trzech pracach: [Clements, Hendry 1995; Engle, Yoo 1987; Hoffman, Rasche 1996]. Biorąc to pod uwagę oraz łatwość dokonywania obliczeń, do dalszych analiz wybrano bezwarunkowy model VAR z wykorzystaniem poziomów zmiennych o postaci danej wzorem (1).

Kolejnym krokiem specyfikacji modelu VAR jest ustalenie wartości maksymalnego opóźnienia zmiennych oznaczonego jako k . Wartość ta została wybrana na podstawie analizy pięciu kryteriów, a wyniki procedury przedstawia tab. 4. Cztery kryteria (LR, FPE, AIC, HQ) z pięciu obliczonych kryteriów wskazują na opóźnienie $k = 2$, dlatego też w modelu VAR zostaną uwzględnione dwa opóźnienia.

Tabela 4. Ustalenie wartości maksymalnego opóźnienia

Opóźnienie	LR	FPE	AIC	SC	HQ
0	NA	1,70e+10	37,74405	37,87431	37,79677
1	1303,393	26622,15	24,37816	25,15971*	24,69447
2	84,22407*	17101,28*	23,93182*	25,36467	24,51172*
3	33,51306	19098,05	24,03286	26,11700	24,87635
4	27,18519	22721,60	24,18874	26,92417	25,29582
5	27,40503	26638,26	24,31841	27,70513	25,68907

* Rząd opóźnienia sugerowany przez dane kryterium.

LR – zmodyfikowana statystyka testowa ilorazu wiarygodności, FPE – błąd predykcji, SC – kryterium informacyjne Schwarza, AIC – kryterium informacyjne Akaikiego, HQ – kryterium informacyjne Hannana-Quinna.

Źródło: obliczenia własne.

Ostateczną specyfikację bezwarunkowego modelu VAR dla pięciu zmiennych, na podstawie którego będą dokonywane prognozy kursu walutowego, można przedstawić zwięźle w postaci macierzowej, która jest zgodna ze wzorem (1):

$$\begin{bmatrix} KURS_t \\ M3_t \\ WIBOR_t \\ PSP_t \\ PPI_t \end{bmatrix} = \begin{bmatrix} a_{01} \\ a_{02} \\ a_{03} \\ a_{04} \\ a_{05} \end{bmatrix} + \begin{bmatrix} a_{1,1} & a_{2,1} & a_{3,1} & a_{4,1} & a_{5,1} \\ a_{6,1} & a_{7,1} & a_{8,1} & a_{9,1} & a_{10,1} \\ a_{11,1} & a_{12,1} & a_{13,1} & a_{14,1} & a_{15,1} \\ a_{16,1} & a_{17,1} & a_{18,1} & a_{19,1} & a_{20,1} \\ a_{21,1} & a_{22,1} & a_{23,1} & a_{24,1} & a_{25,1} \end{bmatrix} \begin{bmatrix} KURS_{t-1} \\ M3_{t-1} \\ WIBOR_{t-1} \\ PSP_{t-1} \\ PPI_{t-1} \end{bmatrix} + \\
 + \begin{bmatrix} a_{1,2} & a_{2,2} & a_{3,2} & a_{4,2} & a_{5,2} \\ a_{6,2} & a_{7,2} & a_{8,2} & a_{9,2} & a_{10,2} \\ a_{11,2} & a_{12,2} & a_{13,2} & a_{14,2} & a_{15,2} \\ a_{16,2} & a_{17,2} & a_{18,2} & a_{19,2} & a_{20,2} \\ a_{21,2} & a_{22,2} & a_{23,2} & a_{24,2} & a_{25,2} \end{bmatrix} \begin{bmatrix} KURS_{t-2} \\ M3_{t-2} \\ WIBOR_{t-2} \\ PSP_{t-2} \\ PPI_{t-2} \end{bmatrix} + \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \varepsilon_3 \\ \varepsilon_4 \\ \varepsilon_5 \end{bmatrix}, \quad (2)$$

- gdzie: $a_{01} \dots a_{05}$ – wyrazy wolne w poszczególnych równaniach modelu,
 $a_{1,1} \dots a_{25,1}$ – parametry strukturalne modelu przy zmiennych opóźnionych o jeden okres,
 $a_{1,2} \dots a_{25,2}$ – parametry strukturalne modelu przy zmiennych opóźnionych o dwa okresy,
 $KURS_t$ – średni miesięczny kurs EUR/PLN kwotowany przez NBP,
 $M3_t$ – podaż pieniądza w Polsce (agregat M3) wyrażona w euro w miesiącu t ,
 $WIBOR_t$ – średnia miesięczna stopa procentowa rynku międzybankowego WIBOR 1M,
 PSP_t – wyrównana sezonowo produkcja sprzedana przemysłu w cenach stałych w miesiącu t ,
 PPI_t – wskaźnik cen produkcyjnych PPI w Polsce w miesiącu t ,
 $\varepsilon_1 \dots \varepsilon_5$ – składniki losowe w poszczególnych równaniach modelu.

Model (2) składa się z pięciu równań, a każde równanie zawiera 11 parametrów. Wyniki oszacowań parametrów i zestaw miar diagnostycznych przedstawia tab. 5.

Nie wszystkie wyestymowane parametry są statystycznie istotne, nie wszystkie również mają interpretację zgodną z teorią ekonomii. Taka sytuacja nie powinna jednak podważać wiarygodności modelu, ponieważ ogólna ocena modelu na podstawie statystyk diagnostycznych zawartych w tab. 5 wypada korzystnie. Wszystkie równania charakteryzują się wysokimi współczynnikami determinacji, co oznacza, że stopień dopasowania do danych empirycznych jest dobry. Skorygowane współczynniki determinacji potwierdzają ten wniosek. Wartości statystyki testowej Fishera-Snedecora przemawiają na rzecz odrzucenia hipotezy zerowej o łącznej nieistotności parametrów strukturalnych dla wszystkich pięciu modeli. Współczynniki zmienności losowej definiowane jako iloraz błędu regresji do średniej arytmetycznej zmiennej objaśnianej wskazują na nieistotny stopień zmienności losowej.

Tabela 5. Wyniki estymacji modelu VAR*

	KURS	M3	WIBOR	PSP	PPI
KURS(-1)	1,332385 [8,72459]	-11413,42 [-3,10309]	2,213838 [1,83315]	18,52584 [2,36907]	1,517000 [1,40498]
KURS(-2)	-0,615137 [-3,85634]	16168,77 [4,20866]	-2,246782 [-1,78116]	-11,31714 [-1,38556]	-1,921213 [-1,70353]
M3(-1)	7,37E-06 [1,18273]	0,520201 [3,46434]	5,32E-05 [1,07856]	0,000224 [0,70319]	6,15E-05 [1,39612]
M3(-2)	-1,13E-05 [-1,75377]	0,568573 [3,66791]	-5,33E-05 [-1,04738]	-0,000164 [-0,49739]	-7,97E-05 [-1,75241]
WIBOR(-1)	0,000540 [0,04107]	20,41164 [0,06442]	0,912841 [8,77433]	-0,188984 [-0,28054]	-0,011398 [-0,12254]
WIBOR(-2)	-0,014130 [-1,07017]	204,0207 [0,64157]	0,060742 [0,58175]	0,279807 [0,41386]	0,004174 [0,04471]
PSP(-1)	0,001286 [0,61600]	-0,014410 [-0,00029]	0,017003 [1,03017]	0,212600 [1,98926]	0,041153 [2,78874]
PSP(-2)	0,001120 [0,53556]	-7,819284 [-0,15524]	-0,014161 [-0,85627]	0,359882 [3,36059]	0,022786 [1,54104]
PPI(-1)	-0,007668 [-0,52917]	-266,2639 [-0,76292]	0,090640 [0,79098]	0,683258 [0,92082]	1,237275 [2,0765]
PPI(-2)	0,009183 [0,67945]	344,5659 [1,05857]	0,021034 [0,19681]	-0,715114 [-1,03334]	-0,372231 [-3,89551]
Wyraz wolny	1,197321 [2,98437]	-35292,83 [-3,65251]	-11,59306 [-3,65408]	13,61266 [0,66263]	10,37520 [3,65770]
Wsp. determinacji	0,942616	0,993591	0,988653	0,616953	0,967639
Skor. wsp. determinacji	0,936378	0,992895	0,987419	0,575318	0,964121
Suma kwadratów reszt	0,554601	3,22E+08	34,68208	1454,156	27,72315
Błąd stand. regresji	0,077642	1869,966	0,613986	3,975682	0,548943
Statystyka F	151,1231	1426,351	801,5731	14,81796	275,0892
Wsp. zmienności losowej	1,92%	2,10%	3,71%	6,51%	0,53%
Średnia arytmetyczna zm. zależnej	4,052840	89153,05	9,438539	107,0971	103,4786
Odch. stand. zm. zależnej	0,307818	22184,15	5,474043	6,100698	2,898061

* W nawiasach kwadratowych pod oszacowaniami parametrów podano wartości statystyk testowych *t*-Studenta.

Źródło: obliczenia własne.

Dodatkowo przeprowadzono diagnostykę pierwiastków wielomianu charakterystycznego, która ma na celu zbadanie warunku stabilności modelu VAR. Warunek ten mówi, że model VAR jest stabilny wtedy, gdy wszystkie pierwiastki wielomianu

leżą wewnątrz koła jednostkowego, tzn. ich wartości bezwzględne są mniejsze od 1. Wyniki procedury testowej przedstawia tab. 6.

Tabela 6. Sprawdzenie warunku stabilności modelu VAR

Pierwiastek	Wartość bezwzględna
1,013455	1,013455
0,936149 – 0,081017i	0,939648
0,936149 + 0,081017i	0,939648
0,706185	0,706185
0,628517 – 0,290272i	0,692309
0,628517 + 0,290272i	0,692309
–0,476861	0,476861
–0,335405	0,335405
0,303327	0,303327
–0,124731	0,124731

Źródło: obliczenia własne.

Wyniki wskazują, iż jeden z obliczonych modułów pierwiastków jest większy od jedynki. Oznacza to niespełnienie warunku stabilności modelu. Jednakże taki wniosek nie umniejsza ogólnej pozytywnej oceny modelu z kilku przyczyn. Po pierwsze tylko jeden z dziesięciu modułów jest większy od jedynki, a wartość 1,013 tylko nieznacznie przekracza liczbę jeden. Po drugie próby respecyfikacji modelu (zmiana liczby opóźnień), które są standardową procedurą rozwiązywania problemu braku stabilności, nie przyniosły skutku. Po trzecie niestabilność modelu VAR zaburza tylko niektóre wnioski, a dokładniej – oszacowania błędów standardowych w analizie impulsowej, która ze względu na odmienny cel konstrukcji modelu nie będzie tutaj wykonywana.

W celu analizy dynamiki modelu bada się odpowiedzi systemu na określone szoki czy zaburzenia. Dokonuje się tego na podstawie dwóch technik: dekompozycji wariancji i funkcji reakcji na impuls. Dekompozycja wariancji rozdziela zmienność zawartą w zmiennych endogenicznych na poszczególne szoki oraz dostarcza informacji na temat relatywnego znaczenia poszczególnych zaburzeń w ogólnej wariancji określonej zmiennej z modelu VAR. Wyjaśnia ona, jaki udział w objaśnianiu wariancji danej zmiennej mają inne zmienne. Natomiast funkcja reakcji na impuls pokazuje wpływ jednostkowego zaburzenia składnika losowego na bieżące oraz przyszłe wartości zmiennych endogenicznych. Jednak, tak jak już wspomniano, ze względu na niestabilność modelu analiza reakcji na impuls nie zostanie przeprowadzona. Stąd z powodu braku metodycznych przeciwwskazań wykonana zostanie

jedynie dekompozycja wariancji. Wyniki tej procedury przedstawia tab. 7. Prezentowane wyniki ograniczono jedynie do dekompozycji dla zmiennej *KURS*, ponieważ właśnie ta zmienna stanowi główny punkt zainteresowania w artykule.

Tabela 7. Dekompozycja wariancji kursu walutowego

Okres	KURS	M3	PSP	WIBOR	PPI
1	100,0000	0,000000	0,000000	0,000000	0,000000
2	99,22866	0,540327	0,128232	5,79E-05	0,102726
3	98,78342	0,378050	0,344893	0,266534	0,227108
4	97,71559	0,403275	0,431043	1,228994	0,221101
5	95,53349	0,831908	0,457450	2,976978	0,200178
6	92,34409	1,701440	0,437644	5,322942	0,193885
7	88,52073	2,961452	0,420250	7,913507	0,184065
8	84,39559	4,505136	0,474822	10,43072	0,193729
9	80,11067	6,228061	0,693932	12,66102	0,306312
10	75,68381	8,032765	1,180662	14,49029	0,612473
11	71,12712	9,828831	2,017552	15,87339	1,153111
12	66,51018	11,53461	3,240143	16,81441	1,900656

Źródło: obliczenia własne.

Z tabeli 7. wynika, że w krótkim okresie (do około połowy roku) zdecydowana większość zmienności błędu prognozy kursu walutowego wynika z jego własnych zaburzeń. Przykładowo w piątym okresie (w tym przypadku – miesiąc) aż 95,5% zmienności kursu wyjaśnia jego własna zmienność. Wraz z upływem czasu na zmienność kursu coraz większy wpływ mają podaż pieniądza i stopa WIBOR, które w 12. miesiącu tłumaczą odpowiednio 11,5 i 16,8% błędu kursu walutowego. Należy zwrócić uwagę na niewielki udział zaburzenia PPI w wariancji predykcji kursu walutowego (1,9% w 12. miesiącu). Można to zinterpretować tak, że kurs walutowy dosyć wyraźnie reaguje na zaburzenia ze strony polityki monetarnej i jej instrumentów (M3, WIBOR), natomiast niewielki wpływ mają tu procesy inflacyjne. Dodatkowo należy zauważyć, że relatywnie największy wpływ spośród analizowanych zmiennych na wariancję kursu walutowego ma stopa procentowa rynku międzybankowego WIBOR 1M, co jest zgodne z intuicją ekonomiczną.


4. Prognozy kursu walutowego

Przeprowadzona procedura polegająca na specyfikacji, estymacji, diagnostyce i analizie własności dynamicznych modelu wektorowej autoregresji uprawnia do zastosowania modelu danego wzorem (2) w celach prognostycznych. Dodatkowo założono:

- stabilność relacji strukturalnych w czasie, co oznacza, że zarówno postać analityczna modelu, jak i wartości ocen jego parametrów nie ulegną zmianie w przedziale czasu, dla którego wyznacza się prognozę,
- stabilność rozkładu składnika losowego umożliwiającą ocenę błędu prognozy.

Przyjęcie tych założeń określa sposób sporządzenia prognozy i ocenę jej jakości. Stanowi to akceptację pasywnej postawy prognostycznej i może być stosowane przy budowie prognoz dotyczących takiego przedziału czasu, w którym oczekuje się nie tylko zmian ilościowych, ale i niewielkich zmian jakościowych w kształtowaniu się kursu walutowego.

Prognozy na podstawie modelu VAR wykonane zostaną za pomocą metod dynamicznej symulacji stochastycznej z wykorzystaniem algorytmu numerycznego Broydena. Zaletą takiej metody jest możliwość dokonywania prognoz *ex ante* bez znajomości zmiennych egzogenicznych w okresie prognozy, ponieważ ich wartości są określane wewnątrz modelu. Wynik takiej procedury symulacji, którą *de facto* uznaje się za prognozę, na podstawie modelu VAR zdefiniowanego wzorem (2) przedstawia rys. 1. Rysunek przedstawia prognozy kursu i wartości rzeczywiste w okresie dziesięcioletnim: od stycznia 1999 r. do grudnia 2008 r. Ostatnią war-



Rys. 1. Prognozy kursu EUR/PLN wraz z wartościami rzeczywistymi: lata 1999-2008


Źródło: obliczenia własne.

tością rzeczywistą jest wartość dla października 2007 r., dlatego też w końcowej części wykresu ten szereg jest krótszy. Stosunkowo duże rozbieżności między prognozami a obserwacjami wynikają z faktu, że okres prognozy obejmuje całe dziesięciolecie, przy czym prognozy te mają charakter *ex ante*, ponieważ bazują jedynie na wewnętrznej dynamice modelu. Jest to cena, jaką należy zapłacić za możliwość prognozowania w obliczu braku prognoz zmiennych objaśniających. Równocześnie przy dokonywaniu porównań nie należy kierować się jedynie wzrokową analizą wskazującą na znaczne odchylenie, lecz powinno się brać pod uwagę skalę zmienności. Przykładowo maksymalne odchylenie prognozy od realizacji wynosi jedynie 0,9. Ponadto w okresie od około połowy 2005 r. można zauważyć znaczne zbliżenie się szeregów prognoz i realizacji, co oznacza coraz mniejsze błędy prognozy. Prognozy kursu EUR/PLN na rok 2008 wskazują na dalszą aprecjację polskiej waluty względem euro, a dokładne wartości liczbowe przedstawia tab. 8.

Tabela 8. Wartości liczbowe prognoz kursu EUR/PLN

Miesiąc	04.2008	06.2008	08.2008	10.2008	12.2008
Prognoza EUR/PLN	3,69	3,69	3,68	3,67	3,65

Źródło: obliczenia własne.



Rys. 2. Wykres błędów standardowych prognoz

Źródło: obliczenia własne.

Na podstawie danych zgromadzonych do września 2007 r. włącznie oraz przy braku istotnych zaburzeń strukturalnych i utrzymaniu poczynionych wcześniej założeń na koniec 2008 r. kurs EUR/PLN powinien kształtować się na poziomie 3,65,

a prognoza średniorocznej wartości kursu to 3,68. Należy zaznaczyć, iż w prognozowaniu tak skomplikowanych i zmiennych zjawisk, jakimi są kursy walutowe, większą uwagę należy zwracać nie na konkretne wartości liczbowe prognoz, lecz na prognozę ogólnej tendencji rozwojowej modelowanego zjawiska. Uchwycenie trendu i wzorca zmian pozwala na trafniejsze antycypowanie zjawisk mogących wystąpić w przyszłości i lepsze przygotowanie się na nie.

W celu weryfikacji jakości prognoz uzyskanych z modelu VAR na podstawie technik symulacyjnych obliczono błędy standardowe. Przedstawia je rys. 2, na podstawie którego należy stwierdzić, że po początkowym okresie (1999-2000) szybkiego wzrostu wartości błędów od około roku 2001 następuje stabilizacja błędów na średnim poziomie ok. 0,35. Stabilny poziom błędów utrzymuje się do końca okresu objętego prognozą. Takie kształtowanie się błędów świadczy pozytywnie o jakości prognoz, a sama wielkość błędów jest mała w odniesieniu do wartości prognoz kursu walutowego. Brak systematycznego i ciągłego wzrostu wartości błędów oznacza, iż wartość prognostyczna modelu oraz wiarygodność prognoz nie ulegają pogorszeniu wraz z upływem czasu.

5. Podsumowanie

Kształtowanie się kursów walutowych powiązane jest z dużą liczbą innych zjawisk gospodarczych, a także politycznych, społecznych, psychologicznych sprawiających, że prognozy kursów walut są niepewne, lecz jednocześnie są akceptowalne i użyteczne, ponieważ redukują niepewność co do przyszłego stanu gospodarki. Ponadto otrzymane prognozy należy uznać za weryfikowalne empirycznie, odnoszące się do określonej przyszłości, sformułowane z wykorzystaniem dorobku nauki, a więc spełniające wszystkie cechy racjonalnych przewidywań naukowych, określonych w pracy [Cieślak 1997].

Uzyskane prognozy długookresowe nie wykluczają i nie blokują możliwości analizy krótkookresowej, np. na bazie dziennej. Jest tak, ponieważ poprawne wyznaczenie tendencji w długim okresie jest warunkiem właściwej oceny kierunku zmian krótkookresowych.

Literatura

- Brzeszczyński J., Kelm R., *Ekonometryczne modele rynków finansowych. Modele kursów giełdowych i kursów walutowych*, WIG-Press, Warszawa 2002.
- Charemza W., Deadman D.F., *Nowa ekonometria*, PWE, Warszawa 1997.
- Cieślak M. (red.), *Prognozowanie gospodarcze. Metody i zastosowania*, Wydawnictwo Naukowe PWN, Warszawa 1997.
- Clements M., Hendry D., *Forecasting in cointegrated systems*, "Journal of Applied Econometrics" 1995, vol. 10, s. 127-146.
- Dickey D.A., Fuller W.A., *Distribution of the estimators for autoregressive time series with unit root*, "Journal of the American Statistical Association" 1979, vol. 74, s. 427-431.

- Engle R., Yoo B., *Forecasting and testing in co-integrated systems*, "Journal of Econometrics 1987", vol. 35 (1), s. 143-159.
- Faust J., Leeper E., *When do long-run identifying restrictions give reliable results*, "Journal of Business and Economic Statistics" 1997, vol. 15 (3), s. 345-353.
- Hoffman D., Rasche R., *Assessing forecast performance in a cointegrated system*, "Journal of Applied Econometrics" 1996, vol. 11 (5), s. 495-517.
- MacKinnon J., Haug A., Michelis L., *Numerical distribution functions of likelihood ratio tests for cointegration*, "Journal of Applied Econometrics" 1999, vol. 14 (5), s. 563-577.
- Naka A., Tufte D., *Examining impulse response functions in cointegrated systems*, "Applied Economics" 1997, vol. 29 (12), s. 1593-1603.

AN APPLICATION OF THE VECTOR AUTOREGRESSION MODEL TO EXCHANGE RATE FORECASTING

Summary: Exchange rate forecasting belongs to the most difficult and, at the same time, the most important economic questions. In this paper we estimate and examine dynamic vector autoregression model in order to calculate exchange rate forecasts for EUR/PLN rate. The results of empirical analysis indicate that one can expect an appreciation of Polish currency in the nearest future.