

PAWEŁ BARANOWSKI, MAŁGORZATA MAZUREK, MACIEJ NOWAKOWSKI, MAREK RACZKO

CZY DEZAGREGACJA INDEKSU CEN POPRAWIA PROGNOZY POLSKIEJ INFLACJI?¹

1. WPROWADZENIE

Celem opracowania jest weryfikacja metod prognozowania inflacji w Polsce. W oparciu o prognozy bezwarunkowe zbadana zostanie możliwość poprawy ich trafności dzięki wykorzystaniu 12 subindeksów cen dóbr i usług konsumpcyjnych (CPI).

Stawiamy hipotezę, iż **agregacja prognoz subindeksów cen (komponentów CPI) polepsza trafność prognoz inflacji.**

Nieliczne, jak dotąd, próby weryfikacji powyższej hipotezy nie przynoszą jednoznacznego rozstrzygnięcia tego problemu. Próby weryfikacji tej hipotezy dla Polski nie są nam znane.

Prognozy dla poszczególnych komponentów wyznaczmy za pomocą modeli autoregresji (AR), średniej ruchomej (MA), wektorowej autoregresji (VAR) oraz autoregresji progowej (TAR). Na podstawie prognoz *out-of-sample* sięgających 1, 2 i 3 kwartały naprzód porównamy prognozy inflacji wyznaczone na podstawie komponentów z bezpośrednimi prognozami agregatu.

Struktura opracowania jest następująca. W sekcji pierwszej przedstawiamy koncepcję łączenia i agregacji prognoz oraz motywację dla podjęcia badań. W drugiej części prezentujemy dane statystyczne. W kolejnej części opisano zastosowaną metodologię wyznaczania i oceny prognoz. Następnie przedstawiono rezultaty badania oraz wnioski.

2. MOTYWACJA ORAZ DOTYCHCZASOWE BADANIA

Koncepcja łączenia prognoz, polegająca na wyznaczeniu średniej z różnych prognoz tego samego szeregu jest znana w ekonometrii już od końca lat 60. XX wieku [4]. W literaturze ([17], [28]) wymienia się następujące zalety prognoz łączonych:

– proces generowania danych zmiennej prognozowanej może być złożony, przez co pojedyncze metody wyjaśniają jedynie jego niewielką część. Formułowanie prognoz w oparciu o różne modele jest zatem jednym ze sposobów rozszerzenia specyfikacji modelu (zarówno jeśli chodzi o zakres zmiennych objaśniających, jak i specyfikację dynamiczną),

¹ Wstępna wersja opracowania została zaprezentowana w kwietniu 2009 r. na seminarium Instytutu Ekonomicznego NBP. Dziękujemy uczestnikom tego seminarium za cenne uwagi.

– często występuje zamienność pomiędzy stopniem objaśnienia (wewnątrz próby) a odpornością modelu na zmiany strukturalne. W obliczu trudności z identyfikacją takiej zmiany na etapie formułowania prognoz, średnia prognoza z różnych metod może stanowić kompromis między dopasowaniem a odpornością,

– wykorzystanie różnych informacji w poszczególnych prognozach zazwyczaj sprawia, że średnia z prognoz ma niższą wariancję,

– średnia ważona z poszczególnych prognoz może również pełnić rolę korekty wyrazu wolnego, dzięki czemu prognoza łączona będzie nieobciążona.

Celowość wyznaczania tego typu prognoz była przedmiotem wielu badań, także dla gospodarki polskiej (por. np. [14], [15]).

Nieco innym podejściem do łączenia prognoz jest agregacja prognoz sformułowanych względem zmiennych o niższym stopniu agregacji. Najczęściej agregacja ta przebiega w wymiarze przestrzennym lub sektorowym. Ze względu na cel badania skoncentrujemy się na agregacji sektorowej².

Analizy cen jednostkowych oraz badania ankietowe przedsiębiorstw wskazują, że mechanizmy kształtowania cen są bardzo zróżnicowane w obrębie poszczególnych sektorów ([11], [19]). Podobnych wniosków dostarczają szacunki parametrów nowokeynesistowskiej krzywej Phillipsa dla 20 sektorów przemysłu [21].

Teoria ekonomii również dostarcza uzasadnienia dla zróżnicowania procesów generujących dynamikę cen w różnych sektorach gospodarki. Przede wszystkim różny może być mechanizm powstawania ceny danego dobra. Teoria aukcji w dość dobitny sposób pokazuje jak w zależności od zastosowanego mechanizmu aukcyjnego może zależeć cena dobra (np. cena wyznaczona poprzez aukcję angielską a cena wyznaczona poprzez aukcję Vickereya). Kolejnym czynnikiem z kategorii mechanizmu kształtowania się cen może być zagadnienie asymetrii informacji [1]. W bardziej klasycznych podejściach sposób ustalania ceny przez rynek zależy od stopnia zmonopolizowania rynku, zaczynając od doskonałej konkurencji (ceny równe kosztom krańcowym), poprzez konkurencję monopolistyczną czy oligopole, a kończąc na pełnym monopolu (cena maksymalizująca zysk). Mechanizm powstawania ceny jest szczególnie blisko związany z dynamiką cen, na przykład inaczej przebiegnie dostosowanie cenowe w różnych przypadkach monopolu. Co więcej szczególną rolę odgrywają tu sztywności nominalne, takie jak koszty menu [5] czy też brak możliwości ciągłego dostosowania cen (*staggered prices* – zob. [7]). Z pewnością różne sektory gospodarki charakteryzują się różnym stopniem zmonopolizowania rynku, a także różnymi sztywnościami.

Z punktu widzenia modeli przedstawionych w niniejszym artykule, istotna wydaje się kwestia, czy inflacja jest pchana kosztami (*cost-push*) czy ciągnięta popytem (*demand pulled*). W przypadku sektorów, w których przeważa pierwszy czynnik, pomocne przy modelowaniu może być uwzględnienie dynamiki wynagrodzeń w danym sektorze, natomiast w przypadku zmiany ceny indukowanej poprzez zmianę popytu przydatne może okazać się zastosowanie ogólnej dynamiki płac w gospodarce.

Poszczególne sektory gospodarki mogą charakteryzować się także różnym stopniem „globalizacji”, a mianowicie zależnością ceny danego dobra od cen globalnych. Z pewnością takim sektorem może być sektor transportowy, gdzie ceny benzyny są

² Przykładem przestrzennej agregacji prognoz inflacji jest np. praca [24].

indeksowane do cen baryłki ropy na globalnych rynkach. W tym przypadku istnieje również problem separowalności rynku zbytu. Nawet jeśli dobro jest międzynarodowe, a rynek jest separowalny to producent może zdecydować się na tzw. *pricing-to-market*, co również nie pozostanie bez wpływu na dynamikę ceny danego sektora.

Na koniec, jednym z najważniejszych czynników, który należy uwzględnić przy modelowaniu inflacji jest kwestia sezonowości, która może być szczególnie ważna w przypadku żywności lub turystyki. Ponadto w każdym przypadku wzorzec sezonowości może być różny.

Należy zauważyć, iż w przypadku modeli AR, MA, VAR i TAR użytych w niniejszym opracowaniu nie wprowadzamy bezpośrednio w użycie żadnej z teorii ekonomicznych uzasadniających zróżnicowanie sektorowe cen. Jednakże można domniemywać, iż w przypadku znacząco różniących się procesów opisujących zachowanie się poszczególnych subindeksów, zagregowany indeks powinien być reprezentowany przez bardzo skomplikowany proces. W takim przypadku szacowany model dla agregatu może nadmiernie upraszczać „prawdziwy” mechanizm, a przez to generować znaczące błędy prognozy.

Na podstawie powyższych rozważań można postawić hipotezę, że wyznaczenie osobnych prognoz dla poszczególnych komponentów (subindeksów cen), a następnie ich agregacja, mogłyby poprawić jakość prognoz zagregowanego indeksu. Dodajmy, że w badaniu nie modelujemy zależności pomiędzy subindeksami. Od strony teoretycznej istnienie takich zależności jest bardzo prawdopodobne (choćby wpływ subindeksu „transport” na inne subindeksy), jednak ze względu na stosunkowo krótkie szeregi czasowe pełne uwzględnienie tych zależności nie wydaje się obecnie możliwe.

W pracy [23] wskazuje się, na przykładzie szerokiej klasy modeli, iż od strony teoretycznej celowość zastosowania danych zdezagregowanych w celu wyznaczenia prognoz agregatu nie jest jednoznaczna. Ze względu na nieprecyzyjne oszacowanie parametrów przewaga modeli opartych o dane zagregowane może być widoczna zwłaszcza w krótkich próbach, a także w sytuacji gdy proces generujący dane jest zbliżony dla wszystkich komponentów agregatu.

Najczęściej metodologię tę stosowano jedynie w odniesieniu do jednego lub dwóch komponentów o największej zmienności (np. cen paliw lub żywności) oraz inflacji bazowej z wyłączeniem tych komponentów. Tego typu podejście jest popularne w modelach stosowanych przez banki centralne (np. w Polsce model NECMOD, zob. [6]), zaś w wersji uwzględniającej dodatkowo ceny kontrolowane [27].

Szersze ujęcia sektorowej agregacji prognoz zastosowano w kilku najnowszych badaniach.

W pracy [18] porównano prognozy inflacji HICP dla strefy euro wyznaczone w oparciu o 5 subindeksów cen (energii, usług, żywności przetworzonej i nieprzetworzonej oraz dóbr nieżywnościowych). Autorka zastosowała dane miesięczne. Prognozy wyznaczono w oparciu o modele AR oraz VAR z różnymi zestawami zmiennych. Wbrew przypuszczeniom, zastosowanie prognozy z komponentów nie poprawiło trafności prognoz HICP.

Zbliżone badania przeprowadzono dla Holandii oraz strefy euro [26]. Podobnie jak w poprzednio omówionym badaniu, autorzy zastosowali dane miesięczne w podziale na 5 głównych subindeksów. Otrzymane rezultaty wskazywały, iż prognoza z komponentów

jest istotnie lepsza od prognozy wyznaczonej na podstawie danych zagregowanych (dla Holandii jedynie dla prognoz o horyzoncie nie dłuższym niż 7 miesięcy).

W pracy [2] podjęto to zagadnienie dla inflacji w USA. Zastosowano dane miesięczne zdezagregowane na 3 komponenty (dobra trwałego użytku, pozostałe dobra i usługi). W odróżnieniu od cytowanych powyżej prac, zamiast modeli AR lub VAR zastosowali model korekty błędem (ECM) z opóźnieniami sięgającymi co najmniej horyzontowi prognozy, dzięki czemu możliwe było wyznaczenie prognoz bezwarunkowych. Badanie to wskazuje, iż agregacja prognoz komponentów pozwala poprawić jakość prognoz dynamiki cen.

3. DANE

Jak już wspomniano, postawioną hipotezę weryfikujemy dla kwartalnej inflacji wyrażonej za pomocą indeksu cen dóbr i usług konsumpcyjnych (CPI) w Polsce. W tym celu wykorzystamy dane kwartalne, począwszy od I kwartału 1999 r. do IV kwartału 2008 r. (40 obserwacji). W miarę dostępności porównywalnych szeregów (tj. dla 3 subindeksów oraz indeksu zagregowanego) wykorzystamy próbę dłuższą, rozpoczynającą się od I kwartału 1998 r.

Wykorzystane metody prognozowania są adekwatne dla szeregów stacjonarnych. Przeprowadzone testy wskazują, że kwartalna stopa inflacji oraz inne zmienne użyte do badania są stacjonarne (zob. załącznik 1). Na stacjonarność stopy inflacji wskazują także rezultaty wielu najnowszych badań (np. [3], [9], [25]). Co więcej, argumentu na rzecz stacjonarności inflacji dostarczają także rozważania teoretyczne. W krajach stosujących strategię bezpośredniego celu inflacyjnego prowadzących skuteczną politykę pieniężną, odchylenia inflacji od celu nie będą trwałe a co za tym idzie inflacja będzie stacjonarna³.

Pozostałymi zmiennymi zastosowanymi do badania były: tempo wzrostu wynagrodzeń (przeciętnych oraz w podziale na 8 sektorów) oraz luka PKB – wyznaczona jako odchylenie logarytmu produktu krajowego brutto od liniowego trendu deterministycznego.

Szczegółowe zestawienie subindeksów cen oraz odpowiadających im wynagrodzeń w poszczególnych sektorach zaprezentowano w załącznikach.

4. METODOLOGIA

Prognozy dla poszczególnych komponentów wyznaczono za pomocą modeli autoregresji (AR), modeli średniej ruchomej (MA), wektorowej autoregresji (VAR) oraz autoregresji progowej (TAR).

³ Wnioski te potwierdzają badania [13]. Z kolei w pracy [16] stwierdza się zmiany stopnia zintegrowania inflacji, także na początku lat 80. inflacja w Wielkiej Brytanii oraz USA stała się stacjonarna. Z tego względu sądzimy, że zmiana próby może w znacznym stopniu tłumaczyć różnice wniosków co do stacjonarności inflacji w stosunku do wcześniejszych badań dla Polski (np. [20]).

W modelach tych, ze względu na potencjalnie istotną nieobjaśnioną sezonowość badanych szeregów dopuszczono możliwość występowania deterministycznej sezonowości (wyrażonej za pomocą zmiennych zero-jedynkowych).

Użyte modele, odpowiednio AR i MA miały zatem następującą postać:

$$\text{AR}(s): \pi_{(i),t} = \alpha_0 + \sum_{j=1}^S \alpha_j \pi_{(i),t-j} + \mathbf{c}_1 [z_{1t} \ z_{2t} \ z_{3t}]' + \varepsilon_t \quad (1)$$

$$\text{MA}(q): \pi_{(i),t} = \alpha_0 + \mathbf{c}_1 [z_{1t} \ z_{2t} \ z_{3t}]' + \varepsilon_t + \sum_{k=1}^Q \beta_k \varepsilon_{t-k}, \quad (2)$$

gdzie:

$\pi_{(i),t}$ – łańcuchowy indeks cen dla i -tej grupy dóbr i usług,

z_{1t}, z_{2t}, z_{3t} – zmienne zero-jedynkowe, przyjmujące wartość jednostkową odpowiednio w 1, 2 i 3 kwartale każdego roku,

$\alpha_0, \alpha_1, \dots, \mathbf{c}_1$ – parametry strukturalne (\mathbf{c}_1 – wektor wierszowy parametrów strukturalnych związanych ze zmiennymi zero-jedynkowymi).

Modele VAR miały następującą postać:

$$\text{VAR}(s): \mathbf{y}_{(i),t} = \mathbf{c}_0 + \sum_{j=1}^S \mathbf{A}_j \mathbf{y}_{(i),t-j} + \mathbf{C}_1 [z_{1t} \ z_{2t} \ z_{3t}]' + \varepsilon_t \quad (3)$$

gdzie:

$\mathbf{y}_{(i),t} = [\pi_{(i),t} \ w_{(i),t} \ xgap_t]'$ – wektor zmiennych endogenicznych (w którego skład wchodzi odpowiednio: łańcuchowy indeks cen dla i -tej grupy dóbr i usług, tempo wzrostu wynagrodzeń w sektorze odpowiadającym i -tej grupie dóbr i usług oraz luka PKB)⁴,

$\mathbf{c}_0, \mathbf{C}_1, \mathbf{A}_j$ – macierze parametrów strukturalnych,

ε_t – wektor składników losowych.

Modele TAR miały następującą postać⁵:

$$\begin{aligned} \text{TAR}(s): \pi_{(i),t} = \alpha_0 + \sum_{j=1}^S \alpha_j \pi_{(i),t-j} + \alpha_{TR} \gamma_t \pi_{(i),t-1} + \mathbf{C}_1 [z_{1t} \ z_{2t} \ z_{3t}]' + \varepsilon_t \\ \gamma_t = \begin{cases} 1 & \text{dla } \pi_{(i),t-1} \geq TR \\ 0 & \text{dla } \pi_{(i),t-1} < TR \end{cases} \end{aligned} \quad (4)$$

gdzie:

α_{TR} – parametr strukturalny,

TR – wielkość tzw. proggu (parametr strukturalny podlegający szacowaniu).

Na podstawie modeli od (1) do (4) wyznaczono prognozy o horyzoncie $h = 1, 2$ lub 3 kwartały, dla okresu weryfikacji (*out-of-sample*) obejmującego okres od III kwartału

⁴ Indeks cen oraz tempo wzrostu wynagrodzeń obliczano w stosunku do poprzedniego kwartału ($t/t-1$).

⁵ Poszerzenie zbioru modeli prognostycznych o modele progowe zaproponowała K. Hertel. Do oszacowania wielkości proggu zastosowaliśmy algorytm zaproponowany przez Chena (zob. [12]). Ze względu na krótką próbę zmniejszono zakres dopuszczalnych wartości proggu (tj. 25 do 75 percentyl, zamiast 15 do 85).

2006 r. do IV kwartału 2008 r. (10 kwartałów). Próba w oparciu, o którą estymowano parametry stopniowo rosła (*recursive sample, expanding window*)⁶.

W estymowanych modelach AR, MA, VAR i TAR w każdej podpróbie dokonywano wyboru⁷:

– rzędu opóźnień (w modelach AR – od zera⁸ do pięciu, MA – od jednego do pięciu, VAR – od jednego do trzech, TAR – od jednego do dwóch) – na podstawie kryterium Schwarz⁹,

– uwzględnienia lub nieuwzględnienia w modelu sezonowości (zmiennych zero-jedynkowych).

Kierując się stopniem objaśnienia w próbie, w modelach VAR dla każdego indeksu dokonano również wyboru miernika wynagrodzeń, zgodnie z wcześniejszymi rozważaniami (specyficzne dla danego sektora, przeciętne albo w sektorze przedsiębiorstw).

Prognozy poszczególnych 12 subindeksów (komponentów) zagregowano do indeksu CPI używając wag stosowanych przez GUS (różnych dla poszczególnych lat):

$$\hat{\pi}_t = \sum_{i=1}^{12} w_{(i),t} \hat{\pi}_{(i),t} \quad (5)$$

gdzie:

$\hat{\pi}_t, \hat{\pi}_{(i),t}$ – prognozy odpowiednio: inflacji CPI oraz i -go subindeksu CPI,

$w_{(i),t}$ – wagi GUS przypisane poszczególnym subindeksom.

Tak otrzymane prognozy porównano z analogicznymi prognozami wyznaczonymi za pomocą modelu na podstawie danych zagregowanych (stopa inflacji CPI, tempo wzrostu wynagrodzeń przeciętnych oraz luka PKB).

5. REZULTATY

Początkowo analizie poddano błędy prognoz poszczególnych subindeksów. Dla prognoz 10 subindeksów za pomocą modeli AR błędy te kształtowały się na poziomie nieprzekraczającym 1,5 pkt procentowego (zob. załącznik 2). W przypadku modeli VAR oraz MA, rezultat taki otrzymano dla 9 subindeksów (zob. załączniki 3 i 4).

Największe błędy prognoz odnotowano dla komponentów: „transport”, „łączność” oraz „rekreacja i kultura”. Dlatego też podjęto próby poprawy prognoz tych subindeksów. Ze względu na znaczny udział podatków pośrednich w cenie paliw, będących najistotniejszym komponentem indeksu cen usług transportowych, dołączono do modelu VAR zmienną egzogeniczną – względną zmianę stawek akcyzy na benzynę bezołowiową. Próbowano także uwzględnić dynamikę cen ropy naftowej (wyrażoną w złotych), wprowadzoną z opóźnieniem równym horyzontowi prognozy (ze względu

⁶ W celu zbadania wrażliwości wyników, równoległe przedstawiamy błędy w okresie weryfikacji od II kwartału 2005 do IV kwartału 2008 (15 kwartałów).

⁷ Szczegółowe rezultaty w tym zakresie przedstawia załącznik.

⁸ Przez model AR(0) rozumiemy model, w którym występuje jedynie stała.

⁹ H. Lütkepohl ([22], s. 154-157) wskazuje, że w krótkich próbach zastosowanie kryterium Schwarz przynosi relatywnie najniższe błędy prognoz.


na potrzebę wyznaczenia prognoz bezwarunkowych). Zabiegi te nie poprawiły błędów prognoz w okresie weryfikacji. W przypadku prognoz subindeksu „łączność” w oparciu o modele VAR dobre rezultaty przyniosło skrócenie okresu estymacji (jak sądzimy ze względu na znaczny udział cen kontrolowanych we wcześniejszym okresie).

Tak wyznaczone prognozy komponentów zagregowano. W efekcie otrzymano prognozy inflacji CPI, które zostały porównane z prognozami sformułowanymi na podstawie danych zagregowanych.

Porównań dokonano dla inflacji wyrażonej w ujęciu rocznym (w stosunku do analogicznego kwartału roku poprzedniego). W tym celu wszystkie prognozy tożsamościowo przekształcono do indeksu $t/t - 4$ (o podstawie analogiczny okres roku poprzedniego), przyjmując wartości z kwartałów będących w próbie jako dane. Przykładowo, tak rozumiana prognoza o horyzoncie 2 kwartałów została wyznaczona następująco:

$$\hat{\pi}_{t+2}^{\text{roczna}} = (1 + \hat{\pi}_{t+2}^{\text{kwart}})(1 + \hat{\pi}_{t+1}^{\text{kwart}})(1 + \pi_t^{\text{kwart}})(1 + \pi_{t-1}^{\text{kwart}}) - 1. \quad (6)$$


Rysunki 1-4 przedstawiają porównanie prognoz inflacji na 2 kwartały naprzód sformułowanych na podstawie komponentów i danych zagregowanych.




Rysunek 1. Prognozy za pomocą modeli AR ($h = 2$ kwartały)¹⁰

Źródło: opracowanie własne.


¹⁰ Końcówka „komp.” oznacza prognozę wyznaczoną na podstawie subindeksów (komponentów).

Rysunek 2. Prognozy za pomocą modeli MA ($h = 2$ kwartały)

Źródło: opracowanie własne.

Rysunek 3. Prognozy za pomocą modeli VAR ($h = 2$ kwartały)

Źródło: opracowanie własne.

Rysunek 4. Prognozy za pomocą modeli TAR ($h = 2$ kwartały)

Źródło: opracowanie własne.

Dla tych prognoz, jak również prognoz z modeli opartych o dane zagregowane, wyznaczono błędy *RMSFE* (pierwiastek średniokwadratowego błędu prognoz). Wyniki w tym zakresie przedstawia tabela 1.

Tabela 1

Porównanie błędów *RMSFE* poszczególnych prognoz (p. proc.)

	II.05 – IV.08 (15 obs.)			III.06 – IV.08 (10 obs.)		
	$h = 1$	$h = 2$	$h = 3$	$h = 1$	$h = 2$	$h = 3$
AR	0,48	1,23	1,71	0,44	0,79	0,96
AR komp.	0,48	0,90	1,21	0,45	0,73	0,96
MA	0,64	1,08	1,45	0,63	0,79	1,02
MA komp.	0,60	1,04	1,41	0,41	0,54	0,72
VAR	0,68	0,97	1,09	0,69	1,03	1,24
VAR komp.	0,59	0,84	0,92	0,59	0,91	1,03
TAR	0,58	1,10	1,87	0,51	0,78	0,86
TAR komp.	0,70	0,94	1,37	0,71	0,79	1,13

Źródło: opracowanie własne.

Dodatkowo, zastosowano test Diebolda-Mariano (zob. [10]), którym testowano czy różnice błędów średniokwadratowych są istotne statystycznie, tj. następujący zestaw hipotez:

$$H_0: E(MSE_A - MSE_B) = 0 \quad (7)$$

$$H_1: E(MSE_A - MSE_B) \neq 0 \quad (8)$$

gdzie:

MSE_A , MSE_B – błędy średniokwadratowe, odpowiednio: prognoz A i B,
 E – operator wartości oczekiwanej.

Wyniki przedstawiamy w tabeli 2.

Tabela 2

Porównanie prognoz za pomocą testu Diebolda-Mariano (pogrubioną czcionką przedstawiono wartości statystyk testowych, zaś kursywą – empiryczny poziom istotności)

	II.05 – IV.08 (15 obs.)			III.06 – IV.08 (10 obs.)		
	<i>h</i> = 1	<i>h</i> = 2	<i>h</i> = 3	<i>h</i> = 1	<i>h</i> = 2	<i>h</i> = 3
AR vs. AR komp.	0,254 <i>(p = 0,799)</i>	-1,245 <i>(p = 0,213)</i>	-1,294 <i>(p = 0,196)</i>	0,217 <i>(p = 0,828)</i>	-0,477 <i>(p = 0,634)</i>	-0,019 <i>(p = 0,985)</i>
MA vs. MA komp.	0,369 <i>(p = 0,712)</i>	0,415 <i>(p = 0,679)</i>	0,323 <i>(p = 0,747)</i>	3,061 <i>(p = 0,002)</i>	2,838 <i>(p = 0,005)</i>	2,953 <i>(p = 0,003)</i>
VAR vs. VAR komp.	-3,482 <i>(p = 0,001)</i>	-2,717 <i>(p = 0,007)</i>	-1,571 <i>(p = 0,115)</i>	-2,224 <i>(p = 0,026)</i>	-1,708 <i>(p = 0,088)</i>	-1,613 <i>(p = 0,107)</i>
TAR vs. TAR komp.	0,931 <i>(p = 0,352)</i>	-0,977 <i>(p = 0,329)</i>	0,932 <i>(p = 0,352)</i>	0,893 <i>(p = 0,372)</i>	0,122 <i>(p = 0,903)</i>	1,882 <i>(p = 0,061)</i>

Uwaga: w nawiasach podano empiryczny poziom istotności.

Źródło: opracowanie własne.

Rezultaty przedstawione w tabeli 1 oraz 2 pozwalają wyciągnąć następujące wnioski¹¹:

– w przypadku modeli wektorowej autoregresji (VAR) prognozowanie komponentów jest zasadne i pozwala poprawić skuteczność prognoz CPI (choć w przypadku prognoz na 3 kwartały naprzód rezultaty są „na granicy statystycznej istotności”),

– w przypadku modeli autoregresyjnych (AR) i progowo-autoregresyjnych (TAR) prognozowanie komponentów nie pozwala na poprawę skuteczności prognoz,

¹¹ Ze względu na krótką próbę stosujemy 10% poziom istotności.

– w modelach średniej ruchomej (MA) nie otrzymano jednoznacznych wniosków w zakresie celowości prognozowania komponentów (wyniki są wrażliwe na zmianę próby),

– wydaje się, że w miarę zwiększania horyzontu prognoz, modele VAR prognozują lepiej w porównaniu z modelami AR, MA i TAR¹².

Interesujące byłoby porównanie otrzymanych prognoz z łączoną prognozą analityków (reprezentujących banki oraz organizacje progностyczne¹³). Jedną z organizacji, które takie dane publikuje jest Consensus Economics (www.consensuseconomics.com), skąd zaczerpnięto do naszego badania. Dostępne szeregi dotyczą jedynie prognoz formułowanych na koniec roku. Po wydłużeniu okresu weryfikacji prognoz wyznaczanych w niniejszym opracowaniu otrzymano zaledwie pięć „wspólnych” obserwacji¹⁴, przez co możliwości porównania prognoz są bardzo ograniczone. Mimo tych zastrzeżeń takie porównanie prezentujemy w tabeli 3.

Tabela 3

Błędy *RMSFE* wybranych prognoz a błędy łączonej prognozy analityków banków i organizacji progностycznych (p. proc.)

	$h = 1$	$h = 2$	$h = 3$
AR komp.	0,61	0,49	1,49
VAR komp.	0,58	0,63	1,56
Łączona prognoza analityków	0,88	0,89	1,30

Źródło: opracowanie własne.

Jak wynika z tabeli 3, wielkości błędów prognoz są porównywalne. Pamiętając o utrudnionym wnioskowaniu, możemy stwierdzić, iż trafność wyznaczonych przez nas prognoz jest porównywalna z łączoną prognozą analityków¹⁵.

Dodatkowo wyznaczono prognozy w oparciu o model na podstawie danych zagregowanych z alternatywnym zestawem zmiennych, odpowiadającym teorii nowej ekonomii keynesistowskiej, tj. stopa inflacji CPI, krótkookresowa stopa procentowa (WIBOR 1M) i luka PKB. Niestety, nie poprawiło to trafności prognoz.

¹² Jednakże różnice między tymi prognozami (w sensie testu Diebolda-Mariano) nie zawsze są istotne statystycznie.

¹³ Taka prognoza bywa określana mianem „konsensusowej”, zwłaszcza wśród praktyków gospodarczych. W środowisku naukowców opinie na temat stosowania takiej nazwy są jednak podzielone.

¹⁴ Tj. IV kwartał odpowiednio lat: 2004, 2005, 2006, 2007 i 2008.

¹⁵ Ponadto wydaje się, że przewaga prognoz analityków dla horyzontu 3 kwartałów wynika głównie z szoku cenowego wynikającego z akcesji do Unii Europejskiej.

6. PODSUMOWANIE

W opracowaniu porównano zagregowane prognozy 12 subindeksów CPI z bezpośrednią prognozą agregatu. Prognozy te wyznaczono w oparciu o dane kwartalne dla Polski.

Otrzymane wyniki nie pozwalają jednoznacznie rozstrzygnąć, czy zastosowanie danych zdezagregowanych jest celowe. Okazuje się bowiem, że dla modeli AR i TAR dezagregacja nie pozwala zmniejszyć błędów prognoz, dla modeli MA nie otrzymano jednoznacznych wskazań testów, zaś dla VAR zmniejsza błędy prognoz.

Sądzymy, że ze względu na wysokie błędy prognoz niektórych subindeksów, możliwa byłaby dalsza poprawa trafności prognoz pod warunkiem zastosowania alternatywnych metod prognozowania (np. prognoz eksperckich czy uwzględnienia zmiany cen kontrolowanych).

W dalszych badaniach spróbujemy dokonać różnicowania luki produkcyjnej dla poszczególnych sektorów.

Uniwersytet Łódzki

LITERATURA

- [1] Akerlof G.A., [1970], *The Market for "Lemons": Quality Uncertainty and the Market Mechanism*, „Quarterly Journal of Economics”, Vol. 84, No. 3.
- [2] Aron J., Muelbauer J., [2008], *New methods for forecasting inflation and its sub-components: application to the USA*, „Department of Economics Discussion Paper”, No. 406, University of Oxford, <http://www.economics.ox.ac.uk>
- [3] Basher S., Westerlund J., [2008], *Is there really a unit root in the inflation rate? More evidence from panel data models*, „Applied Economics Letters”, Vol. 15.
- [4] Bates J., Granger C.W.J., [1969], *On comparing macroeconomic forecast using forecast encompassing test*, „Operational Research Quarterly”, Vol. 20.
- [5] Blanchard O.J., Kiyotaki N., [1987], *Monopolistic Competition and the Effects of Aggregate Demand*, „American Economic Review”, Vol. 77, No. 4.
- [6] Budnik K., Greszta M., Hulej M., Kolasa M., Murawski K., Rot M., Rybaczyk B., Tarnicka M., [2008], *NECMOD: Presentation of the new forecasting model*, NBP, www.nbp.pl
- [7] Calvo G., [1983], *Staggered Prices in a Utility Maximizing Framework*, „Journal of Monetary Economics”, Vol. 12, No. 3.
- [8] Cheung Y.-W., Lai K.S., [1995], *Lag Order and Critical Values of the Augmented Dickey-Fuller Test*, „Journal of Business and Economic Statistics”, Vol. 13, No. 3.
- [9] Chien-Chang L., Chun-Ping Ch., [2007], *Trend Stationary of Inflation Rates: Evidence from LM Unit Root Testing with a Long Span of Historical data*, „Applied Economics”, Vol. 39.
- [10] Diebold FX., Mariano R.S., [1995], *Comparing Predictive Accuracy*, „Journal of Business and Economic Statistics”, Vol. 13, No. 3.
- [11] Dhyne E., Alvarez L., Le Bihan H., Veronese G., Dias D., Hoffmann J., Jonker N., Lünemann P., Rumler F., Vilmunen J., [2006], *Price Changes in the Euro Area and the United States: Some Facts from Individual Consumer Price Data*, „Journal of Economic Perspectives”, Vol. 20, No. 2.
- [12] Enders W., [2004], *Applied Econometric Time Series*, John Wiley and Sons.
- [13] Gregoriou A., Kontonikas A., [2006], *Inflation targeting and the stationarity of inflation: new results from an ESTAR unit root test*, „Bulletin of Economic Research”, Vol. 58, No. 4.
- [14] Grajek M., [2002], *Prognozy łączone*, „Przegląd Statystyczny”, t. 49, nr 1.
- [15] Greszta M., Maciejewski W., [2005], *Kombinowanie prognoz gospodarki Polski*, „Gospodarka Narodowa”, nr 5-6.

- [16] Halunga A.G., Osborn D.R., Sensier M., [2009], *Changes in order of integration of US and UK inflation*, „Economic Letters”, Vol. 102, No. 1.
- [17] Hendry D.F., Clements M.P., [2004], *Pooling of forecasts*, „Econometrics Journal”, Vol. 7.
- [18] Hubrich K., [2005], *Forecasting euro area inflation: Does aggregating forecasts by HICP component improve forecast accuracy?*, „International Journal of Forecasting”, Vol. 21, No. 1.
- [19] Jankiewicz Z., Kołodziejczyk D., [2008], *Mechanizmy kształtowania cen w przedsiębiorstwach polskich na tle zachowań firm ze strefy euro*, „Bank i Kredyt”, luty.
- [20] Kokocińska M., Strzała K., [2007], *Zintegrowany system oceny aktywności przedsiębiorstw i prognozowania kategorii makroekonomicznych*, Wydawnictwo Akademii Ekonomicznej w Poznaniu, Poznań.
- [21] Leith C., Malley J., [2007], *A Sectoral Analysis of Price-Setting Behavior in U.S. Manufacturing Industries*, „Review of Economics and Statistics”, Vol. 89, No. 2.
- [22] Lütkepohl H., [2005], *New Introduction to Multiple Time Series Analysis*, Springer, Berlin etc.
- [23] Lütkepohl H., (2009), *Forecasting Aggregated Time Series Variables: A Survey*, EUI Working Paper, No. 17.
- [24] Marcellino M., Stock J.H., Watson M.W., [2003], *Macroeconomic forecasting in the Euro area: Country specific versus area-wide information*, „European Economic Review”, Vol. 47, No. 1.
- [25] Narayan P.K., Narayan S., [2008], *Is there a unit root in the inflation rate? New evidence from panel data models with multiple structural break*, „Applied Economics”, Vol. 40.
- [26] Reijer A., Vlaar P., [2006], *Forecasting inflation: An art as well as science*, „De Economist”, Vol. 154.
- [27] Sztaudynger J.J., [2002], *Prognozowanie cen*, [w:] Milo W. (red.), *Prognozowanie cen*, Wydawnictwo UŁ, Łódź.
- [28] Timmermann A., [2006], *Forecast combination*, [w:] Elliot G., Granger C.W.J., Timmermann A. (red.), *Handbook in Economic Forecasting*, Elsevier.

Praca wpłynęła do redakcji w październiku 2009 r.

CZY DEZAGREGACJA INDEKSU CEN POPRAWIA PROGNOZY POLSKIEJ INFLACJI?

Streszczenie

W dotychczasowych badaniach rozważa się celowość wykorzystania na cele prognostyczne danych o niższym stopniu agregacji (np. dla inflacji Hubrich, 2005; Reijer and Vlaar, 2006). W artykule badamy czy prognozowanie 12 subindeksów cen dóbr i usług konsumpcyjnych (komponentów inflacji), a następnie ich agregacja poprawia trafność prognozy inflacji.

Prognozy inflacji oraz jej poszczególnych komponentów wyznaczmy przy pomocy modeli autoregresji (AR), średniej ruchomej (MA), wektorowej autoregresji (VAR) oraz autoregresji progowej (TAR).

Otrzymane wyniki nie pozwalają jednoznacznie rozstrzygnąć postawionego problemu. Okazuje się, że dla modeli AR i TAR dezagregacja nie pozwala zmniejszyć błędów prognoz, dla modeli MA nie otrzymano jednoznacznych wskazań testów, zaś dla VAR zmniejsza błędy prognoz.

Słowa kluczowe: prognozowanie, inflacja, subindeksy cen, agregacja

FORECASTING INFLATION COMPONENTS – DOES IT HELP TO PREDICT POLISH INFLATION?

Summary

This paper examines whether forecasting CPI components improves CPI forecast. We exploit quarterly data for Poland, disaggregated into 12 components.

We follow methodology used in previous studies for Euro Area (Hubrich, 2005; Reijer and Vlaar, 2006). AR, MA, TAR and unrestricted VAR models are estimated using recursive sample and aggregated

into CPI. Using out-of-sample forecasts, these models are evaluated and compared to the benchmark -- equivalents for aggregate CPI.

The evidence is mixed. VAR component-forecast outperform benchmark. Contrary to VAR, for AR and TAR models we do not find substantial gain from using disaggregated data. Results for MA models are not robust. Moreover, it seems that results for AR- and VAR-based forecasts are comparable to consensus forecast.

Key words: forecasting, inflation, inflation components, sectoral aggregation, Poland

ZAŁĄCZNIKI

Załącznik 1. Testy stacjonarności

	Stopa inflacji CPI $t/t - 1$	Luka produkcyjna	Wynagrodzenia przeciętne tempo $t/t - 1$	Wynagrodzenia w sektorze przeds. tempo $t/t - 1$
ADF	-5,02	-4,66	-1,67	-8,05
Skł. deteminist., Opóźnień ($k - 1$)	Sezonowość, 0	Sezonowość, 0	Sezonowość, 5	Sezonowość, 0

Uwaga: Długość opóźnień testu została ustalona na podstawie kryterium Schwarza. Ze względu na stosunkowo krótką próbę wartości krytyczne ustalono w oparciu o wzór podany w pracy [8]. Dla przyjętego 10% poziomu istotności wynosiły one -2,605 (brak dodatkowych opóźnień) i -2,535 (5 dodatkowych opóźnień).

Źródło: opracowanie własne.

Załącznik 2. Modele AR ($h = 2$, dane kwartalne, okres weryfikacji 2006 III do 2008 IV)

Indeks cen	RMSFE	Opóźnienia	Sezonowość	Próba od
Żywność i napoje bezalk.	1,16 p.p.	0	Tak	I.1998
Alkohole i wyroby tytoniowe	1,37 p.p.	1	Tak	I.1998
Odzież i obuwie	0,52 p.p.	2-4	Tak	I.1998
Użytkowanie mieszkań i nośniki energii	1,06 p.p.	1-2	Tak	I.1999
Wyposażenie mieszkań	0,20 p.p.	1	Tak	I.1999
Zdrowie	0,42 p.p.	5	Nie	I.1998
Transport	3,40 p.p.	0-1	Tak	I.1999
Łączność	1,00 p.p.	5	Nie	I.1999
Rekreacja i kultura	1,69 p.p.	1-3	Tak	I.1999
Edukacja	0,56 p.p.	4-5	Nie	I.1999
Restauracje i hotele	0,44 p.p.	1	Nie	I.1999
Pozostałe	0,27 p.p.	3-4	Nie	I.1999

Źródło: opracowanie własne.

Załącznik 3. Modele MA ($h = 2$, dane kwartalne, okres weryfikacji 2006 III do 2008 IV)

Indeks cen	RMSFE	Opóźnienia	Sezonowość	Próba od
Żywność i napoje bezalk.	1,50 p.p.	1-5	Tak	I.1998
Alkohole i wyroby tytoniowe	1,17 p.p.	1-3	Tak	I.1998
Odzież i obuwie	0,65 p.p.	4-5	Tak	I.1998
Użytkowanie mieszkań i nośniki energii	1,01 p.p.	1-4	Tak	I.1999
Wyposażenie mieszkań	0,22 p.p.	3-5	Tak	I.1999
Zdrowie	0,87 p.p.	1-3	Nie	I.1998
Transport	3,96 p.p.	1-2	Nie	I.1999
Łączność	1,77 p.p.	3-5	Tak	I.1999
Rekreacja i kultura	1,97 p.p.	1-5	Tak	I.1999
Edukacja	0,90 p.p.	1-5	Tak	I.1999
Restauracje i hotele	0,28 p.p.	2-5	Tak	I.1999
Pozostałe	0,55 p.p.	2-5	Nie	I.1999

Uwaga: Dla subindeksu „zdrowie” ograniczono rząd opóźnień do maks. 3 (problemy ze zbieżnością).

Źródło: opracowanie własne.

Załącznik 4. Modele VAR ($h = 2$, dane kwartalne, okres weryfikacji 2006 III do 2008 IV)

Indeks cen	Płace	RMSFE	Opóźnienia	Sezonowość	Próba od
Żywność i napoje bezalk.	Sektor przedsiębior.	1,14 p.p.	1	Tak	I.1998
Alkohole i wyroby tytoniowe	Sektor przedsiębior.	1,01 p.p.	1	Tak	I.1998
Odzież i obuwie	Przeciętne	0,40 p.p.		Nie	I.1998
Użytkowanie mieszkań i nośniki energii	Sektor przedsiębior.	1,01 p.p.	1-3	Tak	I.1999
Wyposażenie mieszkań	Sektor przedsiębior.	0,30 p.p.	1-3	Tak	I.1999
Zdrowie	Przeciętne	0,62 p.p.	1	Tak	I.1998
Transport	Przeciętne	3,22 p.p.	3	Nie	I.1999
Łączność	Przeds. łączność	1,76 p.p.	1-2	Nie	I.2002
Rekreacja i kultura	Sektor przedsiębior.	1,61 p.p.	1-3	Nie	I.1999

cd. załącznika 4

Indeks cen	Płace	RMSFE	Opóźnienia	Sezonowość	Próba od
Edukacja	Przeciętne	0,93 p.p.	3	Tak	I.1999
Restauracje i hotele	Przeds. zakwaterowanie i gastronomia	0,40 p.p.	1	Nie	I.1999
Pozostałe	Przeciętne	0,81 p.p.	3	Nie	I.1999

Źródło: opracowanie własne.

Załącznik 5. Modele TAR ($h = 2$, dane kwartalne, okres weryfikacji 2006 III do 2008 IV)

Indeks cen	RMSFE	Opóźnienia	Sezonowość	Próba od
Żywność i napoje bezalk.	1,65 p.p.	2	Tak	I.1998
Alkohole i wyroby tytoniowe	1,69 p.p.	2	Tak	I.1998
Odzież i obuwie	0,96 p.p.	2	Tak	I.1998
Użytkowanie mieszkań i nośniki energii	1,43 p.p.	1-2	Tak	I.1999
Wyposażenie mieszkań	0,32 p.p.	2	Nie	I.1999
Zdrowie	1,01 p.p.	2	Tak	I.1998
Transport	2,29 p.p.	2	Nie	I.1999
Łączność	1,98 p.p.	2	Nie	I.1999
Rekreacja i kultura	3,61 p.p.	2	Nie	I.1999
Edukacja	0,96 p.p.	1-2	Tak	I.1999
Restauracje i hotele	0,49 p.p.	2	Nie	I.1999
Pozostałe	0,87 p.p.	1-2	Nie	I.1999

Źródło: opracowanie własne.