

Piotr Białowolski[‡], Tomasz Kuszewski[†], Bartosz Witkowski[†]

Bayesowskie uśrednianie klasycznych oszacowań w prognozowaniu wskaźników makroekonomicznych z użyciem danych z testów koniunktury*

Streszczenie

W niniejszej pracy przedstawiono kolejną wersję modelu dla prognozowania podstawowych wskaźników makroekonomicznych z wykorzystaniem danych z testów koniunktury. W pracach Białowolskiego, Kuszewskiego i Witkowskiego (2010a, 2010b, 2011, 2012a, 2012b) rozwijano metodykę budowy modeli dla prognozowania tempa zmian produktu krajowego brutto, stopy bezrobocia i wskaźnika cen towarów konsumpcyjnych. W zbiorze regresorów tych modeli, oprócz opóźnionych w czasie zmiennych endogenicznych, uwzględnia się wyłącznie wyniki różnych testów koniunktury.

Badanie dotyczy specyfikacji modelu prognostycznego metodą bayesowskiego uśredniania klasycznych oszacowań (*Bayesian averaging of classical estimates*, BACE). Przyjęte rozwiązanie umożliwia automatyzację procesu doboru postaci modelu. W kolejnym etapie postępowania jest rozważany wpływ sezonowości deterministycznej i stochastycznej szeregów czasowych na wynik procesu prognozowania. Zaproponowano intuicyjną procedurę uwzględniania obu rodzajów sezonowości w procesie prognozowania. Po zakończeniu procesu estymacji i doboru modeli weryfikowano ich możliwości prognostyczne.

Słowa kluczowe: bayesowskie uśrednianie klasycznych oszacowań, wyniki testów koniunktury, sezonowość, zautomatyzowane prognozowanie

Kod klasyfikacji JEL: C10, C83, E32, E37

[‡] Instytut Statystyki i Demografii, Szkoła Główna Handlowa w Warszawie

[†] Instytut Ekonometrii, Szkoła Główna Handlowa w Warszawie

* Niniejszy tekst jest poprawioną wersją referatu pt. *Bayesian averaging of classical estimates in forecasting macroeconomic indicators with using business survey data*, zgłoszonego na 31 konferencję CIRET w Wiedniu we wrześniu 2012 r.

Piotr Białowolski[‡], Tomasz Kuszewski[†], Bartosz Witkowski[†]

Bayesian Averaging of Classical Estimates in Forecasting Macroeconomic Indicators with Using Business Survey Data[#]

Abstract

This paper presents another version of model designed to forecast main macroeconomic indicators with the use of economic survey data. In previous papers (Białowolski, Kuszewski, Witkowski, 2010a, 2010b, 2011, 2012a, 2012b) methods for developing models used for forecasting GDP growth rate, unemployment rate and CPI were proposed. The set of regressors in those models included only lagged dependent variables and indices based on various survey data.

In this paper the specification of the forecasting model is selected with the use of Bayesian averaging of classical estimates (BACE). This algorithm enables an automatic process of selection of functional form of the model. Next the influence of deterministic and stochastic seasonality in time series on forecasting process is concerned. An intuitive procedure of applying and selecting among both types of seasonality in the forecasting process is discussed. Afterwards their forecasting capabilities are considered.

Keywords: bayesian averaging of classical estimates, survey data, seasonality, automatized forecasting

JEL classification: C10, C83, E32, E37

[‡] Institute of Statistics and Demography, Warsaw School of Economics

[†] Institute of Econometrics, Warsaw School of Economics

[#] The paper is a developed version of the paper presented at the 31st CIRET conference in Vienna in September 2012.

1. Wprowadzenie

Testy koniunktury są obecnie w wielu krajach standardowym sposobem badania zmian aktywności gospodarczej i zbierania informacji o spodziewanym, przyszłym kształcie procesów gospodarczych. Historia tych badań w Polsce sięga połowy lat osiemdziesiątych XX wieku i można się z nią zapoznać w pracy Adamowicz (2008). Wyniki badań koniunktury metodą testu otrzymuje się z większym wyprzedzeniem niż oceny zmian wartości analogicznych kategorii ekonomicznych w statystyce oficjalnej. Sensowność badania metodą testu koniunktury tkwi w założeniu, że ankietowany producent lub konsument, pytani o kształt i jakościową ocenę przebiegu procesów gospodarczych w przyszłości, udzielają odpowiedzi, które co prawda są wynikiem niesformalizowanego i niestrukturalizowanego sposobu rozumowania, bez użycia przemysłanych kalkulacji i metod analitycznych, ale w zamian za to są nasycone doświadczeniem biznesowym i życiowym ankietowanego. Tym samym uznaje się znaczącą rolę intuicji w poznaniu na wielu płaszczyznach procesów makroekonomicznych (Drabarek, 2006). Intuicja w zakresie procesów ekonomicznych jest tylko w części uwarunkowana zdobytą wiedzą. Procesy socjalizacji ekonomicznej, nabywania pojęć i wartości ekonomicznych są przedmiotem badań psychologii ekonomicznej (Tyszka, 2004).

Wynik testu koniunktury pochodzi jednocześnie od bardzo licznej grupy mikropodmiotów gospodarczych i jest otrzymany według bardzo prostej metodyki, która nie niesie za sobą niebezpieczeństwa zniekształcenia efektów poznawczych badania. Po wielu latach stosowania testy koniunktury i ich publikowane wyniki stają się stałym elementem rytuału komunikacyjnego w procesach społecznych. Wyniki testów koniunktury są współcześnie jednym z przejawów kształtowania się wiedzy wspólnej mikropodmiotów o stanie i przyszłości systemu ekonomicznego. Podobnie jak stykamy się z koncepcją wiedzy wspólnej jako jedną z teorii socjologicznych (Anuszevska, 2010), tak możemy mówić o wynikach testów koniunktury jako mierniku ekonomicznej mądrości zbiorowej producentów i konsumentów.

Wydaje się, iż istnieje analogia między analizą techniczną stosowaną na rynkach finansowych a ocenami wyrażanymi w testach koniunktury. Argumentem za stosowaniem analizy technicznej do przewidywania przyszłych stanów i zmian notowań papierów wartościowych jest hipoteza, że rynek jest mechanizmem dyskontującym przyszłość, a masowe zjawiska giełdowe wyprzedzają w czasie realne zjawiska makroekonomiczne. Można zaryzykować stwierdzenie, że opinie badanych w testach koniunktury

tworzą giełdę wymiany poglądów o przyszłym przebiegu procesów gospodarczych, mogą wyprzedzać zjawiska ekonomiczne i mogą dyskontować przeszłość.

Dane z testów koniunktury są szeroko stosowane w analizach ekonometrycznych prowadzących do prognozowania wartości najważniejszych wskaźników rozwoju gospodarczego. Wyczerpującego przeglądu istniejących podejść i modeli dokonano w opracowaniu Białowolskiego i in. (2009). Tutaj warto wspomnieć jedynie o próbach budowy ekonometrycznych modeli wielorównaniowych, zawierających jako regresory kategorie pochodzące z testów koniunktury. Do tej pory jedynym makroekonomicznym, wielorównaniowym modelem prognostycznym dla gospodarki Polski, w ramy którego wbudowane są wyniki testów koniunktury, jest model CLIMA zbudowany przez zespół kierowany przez M. Drozdowicz-Bieć (Białowolski i in., 2007 i 2008). Model ten opisuje cykliczne zmiany produktu krajowego, stopy bezrobocia i stopy inflacji, i został zbudowany z myślą o generowaniu średniookresowych prognoz wymienionych wielkości w ujęciu kwartalnym. Specyfikacja równań modelu oparta jest o podstawy teorii ekonomii, zaś wskaźniki koniunktury służą lepszemu dopasowaniu modelu do danych.

Celem pracy jest pokazanie, że możliwa jest konstrukcja rodziny modeli ekonometrycznych, do których regresory dobrano metodą bayesowskiego uśredniania klasycznych oszacowań (*Bayesian averaging of classical estimates*, BACE). Wykorzystuje się zbiór informacji pochodzących z testów koniunktury dla Polski i Niemiec – głównego handlowego partnera Polski. Oczekuje się przy tym, że wskaźniki koniunktury mają właściwości wyprzedzającego reagowania na zmiany w wartościach i relacjach podstawowych wskaźników makroekonomicznych, takich jak: dynamika PKB, wskaźnik inflacji oraz stopa bezrobocia. Jednym z rozważanych zagadnień jest zbadanie wpływu sezonowości szeregów czasowych na jakość dopasowania modeli ekonometrycznych i dokładność generowanych na podstawie tych modeli prognoz. Skonstruowane modele ekonometryczne opisujące polską gospodarkę w kolejnym kroku postępowania zostaną wykorzystane do wygenerowania krótkoterminowych, kwartalnych prognoz zmian produktu krajowego brutto, wskaźnika zmian cen towarów i usług konsumpcyjnych oraz stopy bezrobocia. Na zakończenie zostanie przeprowadzona dyskusja zasadności otrzymanych prognoz i ich porównanie z prognozami innych instytucji. Praca stanowi kontynuację prób skonstruowania automatycznego systemu generowania krótkoterminowych prognoz makroekonomicznych.

Praca składa się z następujących części. W części 2 przeprowadzono krótką dyskusję na temat prognozowania makroekonomicznego w czasie kryzysu ekonomicznego. W części trzeciej przedstawiono wykorzystywane do szacowania modeli ekonometrycznych dane i omówiono własności statystyczne przygotowanych szeregów czasowych. Część 4 zawiera opis zastosowanej metodologii BACE i jej modyfikacji na potrzeby niniejszej pracy. W części piątej zbadano dokładność dopasowania otrzymanych modeli prognostycznych, przeprowadzono analizę wpływu sezonowości szeregów czasowych i przyjętych sposobów jej modelowania na jakość prezentowanych prognoz. Otrzymane prognozy porównano z innymi aktualnie dostępnymi prognozami i zrealizowanymi wartościami wskaźników za 2 kwartały 2012 r. W części 6 zawarto sugestie co do dalszych kierunków badań.

2. Prognozowanie makroekonomiczne przed i po (?) kryzysie

Prognozowanie makroekonomiczne zostało poważnie dotknięte przez kryzys. W znacznej mierze odpowiedzialność za to ponosi niska jakość prognoz w okresie przed załamaniem koniunktury na początku tego okresu. Dobrze zostało to przedstawione w nowym wydaniu podręcznika do ekonomii autorstwa Blancharda (2011), w którym autor dokonuje przeglądu prognoz grupy amerykańskich ekonomistów tuż po tym, jak pojawiły się pierwsze oznaki kryzysu w grudniu 2007 r. Dzieli ich na dwie grupy. W grupie optymistów dominowały zdania o braku negatywnych symptomów z gospodarki oraz wskazania na możliwość neutralizacji negatywnych procesów zachodzących w gospodarce przez zastosowanie odpowiednich narzędzi polityki pieniężnej. Pesymiści argumentowali zaś, że załamanie może być na tyle silne, że jednorazowe działania ze strony FED mogą nie przynieść rezultatu. Pomimo że ich poglądy dotyczące krótkookresowych prognoz dla gospodarki USA były zróżnicowane, to zaledwie po dziewięciu miesiącach prognozy praktycznie w całości okazały się nietrafne. Według Blancharda, „nawet najwięksi pesymiści okazali się być zbyt optymistyczni”.

W znacznej mierze zawiodły również modele równowagi ogólnej klasy DSGE, które często stanowią podstawowe narzędzie formułowania prognoz przez ekonomistów. Zauważają to nawet sami autorzy tego typu analiz (por. np. Grabek i in., 2009). Podejrzewa się, że pomimo wewnętrznej spójności ekonomicznej tego typu modeli, zawarte w nich założenia są zbyt restrykcyjne i nie przystają do złożoności otaczającego nas świata. W związku z tym poszukuje się nowych kierunków rozwoju dla tego typu modeli. Główna oś badań skupia się na włączeniu do analizy sektora

finansowego, który w największym stopniu ponosi odpowiedzialność za ostatni kryzys. Rozbudowywanie tego typu modeli ma wiele zalet, w tym główną polegającą na lepszym zrozumieniu otoczenia gospodarczego, jednak wydaje się, że do pełnego zrozumienia gospodarki i lepszego prognozowania procesów potrzebujemy czegoś więcej.

Dalsze argumenty dotyczące słabości modeli w diagnozowaniu i ocenie siły oraz trwałości szoków można znaleźć w prezentacji z warsztatów dotyczących prognozowania przez banki centralne (Coenen, 2010). W opinii Coenena, szczególnie widoczny jest brak prawidłowego włączenia efektów związanych z rynkami finansowymi do modelowania procesów gospodarczych. Jednym z rozwiązań zasugerowanych przez niego jest włączenie systemów ważenia, które powinny eliminować z grupy modeli prognostycznych te, które nie prognozują trafnie. Dodatkowa sugestia dotyczy zwiększenia udziału danych pochodzących z badań koniunktury. Ten pogląd był już obecny przed kryzysem. Według Pesarana i Weale'a (2006), dane koniunktury stanowią dobry materiał do prognoz zarówno w przypadku kiedy mogą być wykorzystane samodzielnie, jak i wtedy gdy stanowią uzupełnienie dla modeli szeregów czasowych. W opracowaniach datowanych po 2008 roku przebija się on nawet częściej (np. Bańbura i in., 2010). Z wykorzystaniem zbioru danych z badania prowadzonego zgodnie z metodyką Komisji Europejskiej (podobnie, jak to ma miejsce w przypadku badania prowadzonego w IRG SGH) Bańbura i in. wskazują, iż włączenie danych z badań koniunktury prowadzi do znaczącej poprawy w prognozowaniu bieżących wartości (*nowcasting*) agregatów ekonomicznych, nim oficjalne wartości staną się ogólnodostępne.

Innym obszarem zainteresowania badaczy zajmujących się prognozami w okresie kryzysu jest modelowanie w czasach gorszej koniunktury. W wielu opracowaniach można znaleźć przykłady pokazujące, że zestaw zachowań gospodarki w okresie kryzysu znacząco różni się od tego, który jest obserwowany w okresie szybkiego wzrostu gospodarczego (np. Zarnovitz, 1992; Diebold i Rudebush, 1999). Pojawia się zatem potrzeba dalszego rozwoju modeli, które będą charakteryzowały się dobrymi własnościami prognostycznymi w okresie gorszej koniunktury. Zgodnie z wynikami badań, obecnie trwający kryzys w strefie euro spowodował przejście ze stanu, w którym wykorzystanie mocy produkcyjnych znajdowało się powyżej potencjału, do stanu, w którym wykorzystanie mocy produkcyjnych zeszło poniżej potencjału. Co więcej, ta zmiana nie pociągnęła za sobą znaczącego spadku stopy inflacji, która to pozostawała w znacznej mierze pod wpływem czynników zewnętrznych (Huček i in. 2010). W warunkach, w których niskie wykorzystanie

potencjału gospodarki współwystępuje z wysoką inflacją, standardowe modele mogą generować obciążone prognozy. W przypadku danych koniunktury mamy jednak do czynienia z dodatkową informacją związaną z wiedzą wspólną, która umożliwia prognozowanie w warunkach zmiennego otoczenia gospodarczego, gdyż zmiany strukturalne stają się częścią informacji, szerokodostępną dla podmiotów. Dobrze podsumowali to Beneš i in. (2010): „dodatkowa informacja pochodząca z danych o wysokiej częstotliwości może być kluczowa w trakcie kryzysu lub, bardziej ogólnie, w okresach wysokiej niepewności, kiedy to standardowe związki wbudowane w model tracą aktualność”.

Biorąc pod uwagę negatywne doświadczenia modelowania i prognozowania gospodarczego z ostatnich lat, można również przyjąć za Roubinim (2010) kategoryczną postawę, że systemy gospodarcze zmieniają się na tyle szybko, że nie ma możliwości włączenia tych zmian do teorii ekonomii, a nowa era wymaga po prostu zmiany w sposobie myślenia. Możliwe więc, że próba podążania z teorią za zmianami gospodarczymi jest skazana na niepowodzenie, jednak pozostawia to furtkę dla automatyzmu informacji pozyskiwanej bezpośrednio od uczestników życia gospodarczego. Ten sposób myślenia postanowiliśmy wykorzystać w niniejszym artykule, uciekając od analiz ekonomicznych procesów gospodarczych, a skupiając się na informacji niesionej przez dane z testu koniunktury.

3. Dane

Dla potrzeb budowy modelu prognostycznego zgromadzono kwartalne dane obejmujące lata 1996-2011. Dane o produkcie krajowym brutto, wskaźniku cen towarów i usług konsumpcyjnych (CPI) oraz stopie bezrobocia (UNE) wg BAEL pochodzą z publikacji Głównego Urzędu Statystycznego. Wartości dotyczące produktu krajowego brutto opracowano w dwóch wariantach. Jeden szereg czasowy, GDP, zawiera wskaźniki tempa zmian wyznaczone według zasady „analogiczny okres roku poprzedniego równy 100”, natomiast drugi, GDP_VOL, jest szeregiem niewyrównanych sezonowo kwartalnych wartości produktu krajowego brutto w cenach stałych (z 2005 r.) liczonych z wartości dla 2010 r. metodą nawiązania łańcuchowego wstecz dla lat 1996-2009 oraz wprzód dla roku 2011. Do przeliczenia użyto wspomnianych wcześniej wskaźników tempa zmian. Oba szeregi czasowe GDP oraz GDP_VOL zawierają zatem tę samą informację o wartościach zmiennej endogenicznej, ale ich własności statystyczne są odmienne.

Z założenia oprócz opóźnionych w czasie zmiennych endogenicznych, rolę zmiennych objaśniających w projektowanych modelach ekonometrycznych mają pełnić dane z testów koniunktury. Dane te są publikowane najczęściej jako dane miesięczne. Zgodnie z powszechnie stosowaną zasadą za wartości kwartalne przyjmuje się wartości testów koniunktury dla pierwszych miesięcy kolejnych kwartałów: stycznia, kwietnia, lipca i października.

Baza danych używanych w procesie szacowania parametrów modeli prognostycznych zawiera szeregi czasowe badań koniunktury prowadzonych przez Instytut Rozwoju Gospodarczego SGH w przemyśle, handlu, rolnictwie, budownictwie i dla gospodarstw domowych. Zgromadzono i wykorzystano również dane o wartościach indeksów publikowanych przez następujące instytucje: The Centre for European Economic Research (ZEW), Leibniz Institute for Economic Research at the University of Munich (Ifo Institute) oraz Bureau for Investments and Economic Cycles (BIEC). Ostatnim z szeregów czasowych jest szereg czasowy wartości wskaźnika menedżerów logistyki (PMITM) dla polskiego przemysłu.

Stosuje się następujące oznaczenia indeksów w szacowanych modelach ekonometrycznych:

zew_ies – wskaźnik nastrojów ekonomicznych ZEW,

ifo_bs – wskaźnik sytuacji ekonomicznej Ifo,

ifo_be – wskaźnik oczekiwań ekonomicznych Ifo,

biec_wwk – wskaźnik wyprzedzający koniunktury BIEC,

biec_wpi – wskaźnik przyszłej inflacji BIEC,

biec_wrp – wskaźnik rynku pracy BIEC,

biec_wd – wskaźnik dobrobytu BIEC,

pmi – wskaźnik menedżerów logistyki (PMITM) dla polskiego przemysłu,

ind_xxx - saldo odpowiedzi na pytanie „xxx” z badania IRG koniunktury w przemyśle (tabela 1),

hhs_xxx - saldo odpowiedzi na pytanie „xxx” z badania IRG koniunktury konsumenckiej (tabela 2).

trade - wartość testu IRG koniunktury w handlu,

agri - wartość testu IRG koniunktury w rolnictwie,

cons - wartość testu IRG koniunktury w budownictwie.

We wszystkich wymienionych szeregach czasowych pochodzących z testów koniunktury oprócz zew_ies przyjęto, że poziom wskaźnika równy 100 oznacza taki sam udział odpowiedzi pozytywnych i negatywnych na dane pytanie. Oznacza to, że wartości wskaźników oscylują wokół wartości 100, co zmniejsza ich zmienność. Przed przystąpieniem do badania

sezonowości od wartości wskaźników Ifo, BIEC i IRG odjęto stałą 100. Od wartości wskaźnika PMITM odjęto 50, ponieważ w jego przypadku, to właśnie ta wartość wyznaczała poziom neutralny. Przed wykonaniem tych operacji zmienność wartości wskaźników mierzona ilorazem odchylenia standardowego i średniej wahała się od 0,03 do 0,34. Po usunięciu wartości poziomów neutralnych zmienność wartości wskaźników znacznie się zwiększyła, co poprawia ich potencjalne możliwości opisu zmienności wartości zmiennych endogenicznych.

Tabela 1. Wybrane pytania z testu koniunktury w przemyśle

Symbol	Pytanie (ind_xxs – stan obecny, ind_xxf – oczekiwanie)
ind_q1	Produkcja
ind_q2	Zamówienia ogółem
ind_q3	Zamówienia eksportowe
ind_q4	Wielkość zapasów
ind_q5	Ceny produkowanych w przedsiębiorstwie wyrobów
ind_q6	Zatrudnienie
ind_q7	Sytuacja finansowa
ind_q8	Ogólna sytuacja gospodarki polskiej

Źródło: *Koniunktura w przemyśle*, Instytut Rozwoju Gospodarczego Szkoły Głównej Handlowej w Warszawie.

Po opisanym wyżej przygotowaniu wartości szeregów czasowych zbadano ich własności integracji i sezonowości. Do badania integracji użyto testów ADF i KPSS. Nie stwierdzono obecności w bazie danych szeregów czasowych o wyższym stopniu zintegrowania niż 1. Okazało się, iż w wielu wypadkach oba testy nie pozwalały wyciągnąć tego samego wniosku o danym szeregu. Dla zmiennych *biec_wwk*, *biec_wrp*, *biec_wd*, *ind_q4f*, *ind_q5s*, *ind_q5f*, *ind_q6s*, *ind_q6f*, *ind_q8s*, *hhs_q4*, *hhs_q5*, *hhs_q7*, *hhs_q8* diagnozy o stopniu zintegrowania szeregu czasowego wynikające z obu testów były odmienne. Można przyjąć, że szeregi czasowe sald odpowiedzi na pytania testu koniunktury dla sektora przemysłowego są szeregami czasowymi stacjonarnymi, czyli zintegrowanymi $I(0)$, natomiast szeregi czasowe odpowiedzi na pytania testu koniunktury gospodarstw domowych są szeregami czasowymi zintegrowanymi $I(1)$. Pozostałe szeregi czasowe są szeregami stacjonarnymi. Wobec powyższego zdecydowano nie różnicować wartości szeregów $I(1)$, ale badać własności statystyczne szeregów reszt szacowanych modeli.

Tabela 2. Pytania z testu koniunktury konsumentckiej

Symbol	Pytanie
hhs_q1	Ocena sytuacji finansowej gospodarstwa domowego w porównaniu do sytuacji sprzed 12 miesięcy
hhs_q2	Oczekiwanie co do stanu finansów gospodarstwa domowego w ciągu kolejnych 12 miesiącach
hhs_q3	Zmiana ogólnej sytuacji ekonomicznej Polski w ostatnich 12 miesiącach
hhs_q4	Oczekiwanie co do ogólnej sytuacji ekonomicznej Polski w ciągu kolejnych 12 miesiącach
hhs_q5	Porównanie kosztów utrzymania teraz i przed 12 miesiącami
hhs_q6	Oczekiwanie co do tempa zmian cen w ciągu kolejnych 12 miesiącach
hhs_q7	Oczekiwanie co do zmian bezrobocia w ciągu kolejnych 12 miesiącach
hhs_q8	Korzystne obecnie kupowanie dóbr trwałego użytku
hhs_q9	Prognoza wydatków na dobra trwałego użytku w horyzoncie 12 miesięcy w relacji do analogicznych wydatków w ciągu ostatnich 12 miesięcy
hhs_q10	Ocena oszczędności i klimatu do oszczędzania w kontekście sytuacji ekonomicznej kraju
hhs_q11	Możliwość zgromadzenia jakichkolwiek oszczędności w ciągu kolejnych 12 miesiącach
hhs_q12	Obecna sytuacja finansowa gospodarstwa domowego

Źródło: *Kondycja gospodarstw domowych*, Instytut Rozwoju Gospodarczego Szkoły Głównej Handlowej w Warszawie.

Kolejnym problemem jest spodziewana sezonowość szeregów czasowych z testów koniunktury. Sezonowość rozumiemy tutaj jako powtarzalne odchylenia wartości kwartalnych szeregu czasowego od trendu długookresowego. Obecnie – przez analogię do ustaleń ekonometrii szeregów czasowych co do występowania trendów deterministycznych i stochastycznych – wyróżnia się sezonowość deterministyczną i sezonowość stochastyczną. Zwykle za przyczyny pojawiania się odchyżeń przyjmuje się wpływ czynników pogodowych, kalendarzowych bądź wywoływanych przez otoczenie w systemie społecznym i ekonomicznym. W dużym uproszczeniu można powiedzieć, że sezonowość deterministyczną wywołują czynniki związane z naturalnym upływem czasu, a sezonowość stochastyczną – zmiany natężenia aktywności ekonomicznej (Nehrebecka

i Grudkowska, 2010). Uproszczenie tego wyjaśnienia wynika z wzajemnego nakładania się na siebie obu wymienionych grup czynników. Testowanie sezonowości deterministycznej w szeregu czasowym sprowadza się do oszacowania parametrów modelu trendu danego szeregu (liniowego albo nieliniowego) z dołączonymi zmiennymi 0-1, które mają za zadanie modelować odchylenia sezonowe. Jeśli chociaż jeden parametr przy zmiennej 0-1 ma wartość istotnie różną od zera, to możemy wnioskować o istnieniu sezonowości deterministycznej. Ustalenie istnienia sezonowości stochastycznej jest o wiele trudniejsze. W pakiecie Demetra+ (Grudkowska, 2011) jest przykładowo proponowana procedura sprowadzająca się do przeprowadzenia 4 testów statystycznych dla jednego szeregu czasowego. Jednocześnie przyznaje się, że większość dostępnych testów nie diagnozuje precyzyjnie istnienia sezonowości stochastycznej w szeregu czasowym. Należy podkreślić, iż przypadek rozpatrywany w niniejszej pracy jest dużo bardziej skomplikowany, ponieważ w planowanych modelach prognostycznych występować będzie wiele regresorów. Ich wzorce sezonowości będą wzajemnie na siebie oddziaływać i nakładać się. W tej sytuacji zdecydowano, że do badania sezonowości stochastycznej zostanie zastosowane proste podejście testowania dla modelu danego szeregu czasowego wartości parametru stojącego przy regresorze, którym jest wartość składowej szeregu opóźniona o cztery okresy (Enders, 1995).

Zbadano szeregi czasowe ze względu na obecność zarówno sezonowości deterministycznej jak i stochastycznej. W szeregach czasowych zmiennych *zew_ies*, *pmi*, *ifo_bs*, *ifo_be*, *biec_wwk*, *biec_wpi*, *biec_wrp*, *biec_wd* nie stwierdzono występowania sezonowości deterministycznej, natomiast nie wykluczono występowania sezonowości stochastycznej. We wszystkich szeregach czasowych danych IRG stwierdzono występowanie sezonowości deterministycznej oraz nie wykluczono występowania sezonowości stochastycznej. Wiadomo, że występowanie każdego z rodzajów sezonowości w szeregach czasowych ma wpływ na jakość możliwych do otrzymania prognoz (Franses i Löf, 1995). Z tego powodu podjęliśmy decyzję o uwzględnieniu problemu sezonowości dopiero w ostatecznych wersjach modeli prognostycznych.

4. Modele prognostyczne

4.1. Strategia modelowania

Głównym celem podjętego badania jest skonstruowanie modelu prognostycznego trzech głównych kwartalnych wskaźników sytuacji ekonomicznej: GDP (produkt krajowy brutto), CPI (indeks cen towarów i usług konsumpcyjnych) oraz UNE (stopa bezrobocia według BAEL).

Biorąc pod uwagę, iż nie ma jednolitej teorii makroekonomicznej (Okun, 1991) wskazującej na kolejność zależności przyczynowo-skutkowych między wymienionymi zmiennymi, zastosowano permutowanie równań w trzyczłonowym modelu z wymienionymi zmiennymi endogenicznymi. Procedurę opisano i zweryfikowano w pracy Białowolskiego, Kuszewskiego i Witkowskiego (2010a). Do redukcji zbioru regresorów używano częściowo zmodyfikowanej metody regresji krokowej według algorytmu *backward*. Zaproponowana procedura jest niekiedy krytykowana w literaturze przedmiotu, dlatego postanowiono udoskonalić metodę szacowania parametrów modeli prognostycznych.

W niniejszej pracy do doboru zmiennych objaśniających w modelu ekonometrycznym, wykorzystany został algorytm *Bayesian averaging of classical estimates* (BACE), zaproponowany przez Sala-i-Martina, Doppelhofera i Millera (2004), a następnie rozwijany przez Stadelmanna (2010). Ogólna zasada tego typu modeli jest następująca: niech Y oznacza regresanta, zaś $X = \{X_1, X_2, \dots, X_s\}$ oznacza s -elementowy zbiór potencjalnych zmiennych objaśniających. Przyjmując, że poszczególne zmienne objaśniające X_i , $i=1, \dots, s$, nie są współliniowe, oznacza to możliwość utworzenia $2^s - 1$ niepustych podzbiorów zbioru X . Dla każdego z tych podzbiorów możliwe jest oszacowanie modelu regresji. Metoda BACE opiera się na wyznaczeniu poszczególnych współczynników w ostatecznym modelu regresji ($\hat{\beta}_i$) jako średnich z oszacowań parametrów przy zmiennej objaśniającej X_i we wszystkich regresjach szacowanych przy użyciu klasycznego estymatora (autorzy zaproponowali użycie w tym celu KMNK). Nie są to jednak średnie arytmetyczne, a średnie ważone, zaś stosowane wagi są wprost proporcjonalne do „jakości” poszczególnych szacowanych regresji, mierzonej kryterium Schwarza. W odróżnieniu od „klasycznych” metod bayesowskich, rola założeń *a priori* jest minimalna; podejście BACE nie wymaga przyjmowania rozkładu *a priori* dla wszystkich parametrów, a jedynie wyspecyfikowania spodziewanej łącznej liczby zmiennych objaśniających w „prawidłowym” modelu (Próchniak i Witkowski, 2012).

Rozpatruje się model składający się z trzech równań. W każdym z równań bieżącą zmienną endogeniczną jest jedna ze zmiennych: GDP, CPI i UNE. Z doświadczenia wiadomo, że włączenie do odpowiednich równań opóźnionej zmiennej endogenicznej pozwala otrzymać lepszą jakość prognoz. Ponadto, w każdym z kolejnych równań modelu występuje bieżąca zmienna endogeniczna z poprzedniego równania (ze względu na właściwości statystyczne oszacowań włączono wartość teoretyczną

zmiennej bieżącej). Konstruuje się zatem model rekurencyjny. Niech Y_1 , Y_2 i Y_3 oznaczają wymienione wcześniej makrowskaźniki (GDP, CPI i UNE) uporządkowane w jeden z sześciu możliwych sposobów. Ogólna postać modelu jest następująca:

$$\begin{aligned} Y_{1,t} &= f_1(Y_{1,t-1}, M_1, \varepsilon_{1,t}) \\ Y_{2,t} &= f_2(Y_{2,t-1}, \hat{Y}_{1,t}, M_2, \varepsilon_{2,t}) \\ Y_{3,t} &= f_3(Y_{3,t-1}, \hat{Y}_{1,t}, \hat{Y}_{2,t}, M_3, \varepsilon_{3,t}), \end{aligned} \quad (1)$$

gdzie:

$Y_{i,t}$ – wartość i -tego makrowskaźnika (GDP, CPI, UNE) dla kwartału t , $i=1,2,3$,

$\hat{Y}_{i,t}$ – teoretyczna wartość i -tego makrowskaźnika (z i -tego równania modelu),

M_{it} – dane z testów koniunktury wybrane dla wyjaśniania zmienności i -tego makrowskaźnika,

$\varepsilon_{i,t}$ – składnik losowy w i -tym równaniu modelu,

f_i – funkcja liniowa w i -tym równaniu modelu.

Jak zauważono istnieje sześć różnych uporządkowań trzech zmiennych endogenicznych bieżących. Z wcześniejszych badań (Białowolski, Kuszewski i Witkowski, 2010a, 2011) wynika, iż jedno z uporządkowań gwarantuje prognozy o większej zgodności *ex post* niż pozostałe uporządkowania. Jest ono następujące: $Y_1 = \text{GDP}$, $Y_2 = \text{UNE}$ i $Y_3 = \text{CPI}$. Ponadto z góry zakłada się, iż dane z testów koniunktury występujące w kolejnych równaniach modelu są opóźnione o 3 kwartały. To założenie pozwala na wykonanie prognozy na 4 kwartały bez przyjmowania jakichkolwiek założeń odnośnie wartości zmiennych egzogenicznych. Model (1) przyjmuje teraz postać następującą:

$$\begin{aligned} GDP_{1,t} &= f_1(GDP_{1,t-1}, M_{1,t-3}, \varepsilon_{1,t}) \\ UNE_{2,t} &= f_2(UNE_{2,t-1}, \hat{GDP}_{1,t}, M_{2,t-3}, \varepsilon_{2,t}) \\ CPI_{3,t} &= f_3(CPI_{3,t-1}, \hat{GDP}_{1,t}, \hat{UNE}_{2,t}, M_{3,t-3}, \varepsilon_{3,t}). \end{aligned} \quad (2)$$

Proces szacowania parametrów i sprawdzanie właściwości statystycznych oszacowań i reszt zostały zrelacjonowane w pracach Białowolskiego, Kuszewskiego i Witkowskiego (2012a, 2012b).

4.2. Rezultaty estymacji – wybór zmiennych do modeli prognostycznych

Do estymacji parametrów użyto szeregów czasowych danych kwartalnych z lat 1996-2011. Procedurę obliczeniową metody BACE uruchamiano dwukrotnie, oddzielnie dla zmiennej GDP i oddzielnie dla zmiennej GDP_VOL. Dla każdego z dwóch typów modelu (2), różniących się zmienną opisującą produkt krajowy brutto, wybrano zestaw objaśniających zmienne endogeniczne danych z testów koniunktury. Syntetyczną informację o wynikach obliczeń zawiera tabela 3. Zawiera ona wartości prawdopodobieństw *a posteriori* dla poszczególnych zmiennych. Wartości prawdopodobieństw dla zmiennych wybranych do modeli prognostycznych są wytłuszczone. Wartości prawdopodobieństw zmiennych mogących powodować przybliżoną współliniowość w zbiorze zmiennych objaśniających danego równania są zaszarzone. Zmienne mogące powodować współliniowość muszą zostać usunięte z poszczególnych równań. W celu stwierdzenia właściwości otrzymanych oszacowań przeprowadzono niezbędne testy autokorelacji i stacjonarności.

Badanie BACE dwóch modeli dla trójek zmiennych endogenicznych (GDP, UNE, CPI oraz GDP_VOL, UNE, CPI) jednoznacznie określiło zestawy regresorów w poszczególnych równaniach. W kolejnym kroku zmierzającym do przygotowania narzędzi prognostycznych oszacowano powtórnie parametry modeli ze zidentyfikowanymi wcześniej regresorami i dodatkowym uwzględnieniem składników sezonowych w trzech wariantach: z deterministycznym składnikiem sezonowym modelowanym przez dodanie zmiennych 0-1 dla poszczególnych kwartałów, ze stochastycznym składnikiem sezonowym modelowanym przez proces MA(4) oraz jednocześnie z deterministycznym i stochastycznym składnikami sezonowymi dla każdej zmiennej. W tabelach 4-6 są prezentowane wyniki oszacowań równań dla poszczególnych zmiennych GDP, UNE, CPI.

W żadnym z trzech modeli, w którym próbowano uwzględnić sezonowość zmian zmiennej GDP, żadna ze zmiennych charakteryzujących tę sezonowość nie okazała się istotna statystycznie. Zauważmy, że wprowadzanie kolejnych specyfikacji dotyczących sezonowości nie zmienia znaków oszacowań parametrów i nie zmienia znacząco wartości tych oszacowań. Można zatem postawić hipotezę, że zmiany tempa wzrostu produktu krajowego brutto nie mają statystycznie istotnego charakteru sezonowego.

Tabela 3. Prawdopodobieństwa *a posteriori* włączenia zmiennych w równaniach modeli

Regresor X_k	Model dla GDP			Model dla GDP_VOL		
	GDP	UNE	CPI	GDP_VOL	UNE	CPI
zew_ies	0,529973	0,473289	0,570007	0,204261	0,289795	0,172322
pmi	0,143643	0,120608	0,144214	0,235723	0,343614	0,186498
ifo_bs	0,244707	0,046347	0,064009	0,087284	0,533400	0,197818
ifo_be	0,111710	0,147197	0,125835	0,362892	0,193616	0,094349
biec_wwk	0,092843	0,477494	0,036627	0,999998	0,999703	0,291972
biec_wpi	0,045370	0,754221	0,049681	0,377101	0,723594	0,168876
biec_wrp	0,186897	0,156539	0,284151	0,077910	0,150351	0,327932
biec_wd	0,324782	0,049047	0,084054	0,273071	0,136324	0,165020
ind_q1s	0,247212	0,973989	0,215227	0,877355	0,292578	0,274490
ind_q1f	0,179209	0,468517	0,25861	0,284972	0,307676	0,205343
ind_q2s	0,142753	0,059925	0,236697	0,213152	0,260536	0,238870
ind_q2f	0,447050	0,085075	0,115459	0,115784	0,316939	0,110308
ind_q3s	0,097127	0,204787	0,260067	0,255725	0,208179	0,327371
ind_q3f	0,071420	0,179672	0,268869	0,435574	0,123372	0,235761
ind_q4s	0,200863	0,109203	0,137070	0,127792	0,104256	0,068615
ind_q4f	0,194507	0,133494	0,068642	0,270591	0,062994	0,172786
ind_q5s	0,141234	0,170285	0,044506	0,135926	0,262133	0,205454
ind_q5f	0,341719	0,054075	0,127928	0,169695	0,112532	0,232022
ind_q6s	0,181444	0,514534	0,258962	0,058501	0,084833	0,229098
ind_q6f	0,073308	0,095002	0,267408	0,193924	0,286455	0,068994
ind_q7s	0,308216	0,980561	0,237513	0,523176	0,376295	0,187030
ind_q7f	0,335049	0,077684	0,339904	0,374239	0,301672	0,235311
ind_q8s	0,181177	0,455188	0,087633	0,282741	0,383942	0,165216
ind_q8f	0,358626	0,603194	0,073181	0,202558	0,622445	0,145072
ind_r	0,077118	0,099542	0,116935	0,163334	0,296612	0,164803
hhs_q1	0,254419	0,281131	0,038463	0,091679	0,083131	0,086198
hhs_q2	0,086899	0,239642	0,228539	0,608905	0,205476	0,215549
hhs_q3	0,043738	0,418542	0,055954	0,193661	0,292155	0,127054
hhs_q4	0,069227	0,056893	0,146240	0,315878	0,144906	0,157511
hhs_q5	0,043636	0,22991	0,270003	0,224784	0,180944	0,149217
hhs_q6	0,945867	0,137937	0,263677	0,146575	0,240750	0,220438
hhs_q7	0,038287	0,131539	0,228455	0,130678	0,164926	0,073209
hhs_q8	0,121711	0,436050	0,106511	0,703570	0,187004	0,341998
hhs_q9	0,258586	0,172663	0,302928	0,070369	0,730140	0,427353
hhs_q10	0,178904	0,157873	0,235332	0,263119	0,075909	0,178285
hhs_q11	0,162894	0,270946	0,183867	0,302393	0,215743	0,204204
hhs_q12	0,156168	0,183020	0,301902	0,068248	0,244099	0,191933
hhs	0,212643	0,028864	0,119975	0,292017	0,154258	0,099906
trade	0,108158	0,600264	0,217376	0,099199	0,330489	0,235338
agri	0,146806	0,999196	0,507167	0,279091	0,964015	0,667514
constr	0,138002	0,469658	0,079768	0,913880	0,105246	0,193564

Źródło: obliczenia własne.

Tabela 4. Oszacowania parametrów w równaniach objaśniających produkt krajowy brutto

Regresor	Modele			
	Bez sezonowości	Sezonowość deterministyczna	Sezonowość stochastyczna	Oba rodzaje sezonowości
GDP(- 1)	0.87099	0.85162	0.91933	0.89558
zew_ies	-0.00554	-0.00595	-0.00296	-0.00397
biec_wd	-0.01502	-0.01823	-0.00937	-0.01967
ind_q2f	-0.03630	-0.03892	-0.04256	-0.04436
ind_q5f	-0.00990	-0.01095	-0.01614	-0.01532
ind_q7s	-0.00133	0.01353	-0.00202	0.01520
ind_q8f	0.02008	0.01584	0.02659	0.02053
hhs_q1	-0.01207	-0.01505	-0.01538	-0.01487
hhs_q6	-0.04353	-0.04997	-0.04533	-0.05078
hhs_q9	0.01487	0.02028	0.01595	0.02100
const	3.21615	3.97296	3.06701	3.89963

Uwagi: jeśli nie zaznaczono inaczej, wszystkie regresory są opóźnione o 3 okresy.

Źródło: obliczenia własne.

Tabela 5. Oszacowania parametrów w równaniach objaśniających stopę bezrobocia

Regresor	Modele			
	Bez sezonowości	Sezonowość deterministyczna	Sezonowość stochastyczna	Oba rodzaje sezonowości
UNE(- 1)	0.92739	0.95250	0.93913	0.96021
GDP	-0.19378	-0.18612	-0.22500	-0.21489
zew_ies	-0.00325	-0.00174	-0.00136	-0.00120
biec_wpi	0.04949	0.04951	0.04399	0.04184
ind_q1s	0.04152	-0.00321	0.02138	-0.00322
ind_q7s	-0.06273	-0.02539	-0.04271	-0.02769
ind_q8f	0.02755	0.02526	0.02622	0.02589
trade	0.02128	0.01772	0.03317	0.02889
agri	-0.04430	-0.04260	-0.04535	-0.04511
constr	-0.01193	-0.00916	-0.01178	-0.00311
const	1.55463	1.08792	1.58558	1.01892

Uwagi: jeśli nie zaznaczono inaczej, wszystkie regresory są opóźnione o 3 okresy.

Źródło: obliczenia własne.

W każdym z trzech modeli, w których próbowano uwzględnić sezonowość zmian zmiennej UNE, istnieją istotnie statystycznie zmienne charakteryzujące tę sezonowość. Wprowadzanie kolejnych specyfikacji dotyczących sezonowości nie zmienia znaków oszacowań parametrów przy większości regresorów. Wyjątkiem jest zmienna *ind_q1s*. Stojące przy niej parametry mają w różnych modelach odmienne znaki. Dla większości regresorów modelowanie sezonowości nie zmienia drastycznie wartości oszacowań stojących przy nich parametrów. W konkluzji można postawić hipotezę, że zmiany wartości stopy bezrobocia mają charakter zmian sezonowych. Warto również zauważyć, iż wśród regresorów brak jest zmiennych charakteryzujących opinie gospodarstw domowych co do bieżącej i przyszłej koniunktury gospodarczej.

Tabela 5. Oszacowania parametrów w równaniach objaśniających stopę bezrobocia

Regresor	Modele			
	Bez sezonowości	Sezonowość deterministyczna	Sezonowość stochastyczna	Oba rodzaje sezonowości
CPI(- 1)	0.83816	0.85233	0.86764	0.84039
GDP	0.36635	0.36457	0.41948	0.28196
UNE	0.09501	0.05464	0.05638	0.05672
zew_ies	-0.00284	-0.00330	-0.00422	-0.00165
ind_q3f	-0.00396	0.00832	0.02927	0.01366
ind_q7f	0.01330	0.00230	-0.03800	-0.01461
hhs_q5	0.01982	0.01486	0.00583	0.01105
hhs_q6	0.00889	0.00943	0.03026	-0.00105
hhs_q9	0.01442	0.01119	0.01599	0.02219
hhs_q12	0.03610	0.03047	0.03885	0.03729
agri	-0.02242	-0.03466	-0.03189	-0.02299
const	-2.83184	-2.66463	-3.62635	-1.36974

Uwagi: jeśli nie zaznaczono inaczej, wszystkie regresory są opóźnione o 3 okresy.

Źródło: obliczenia własne.

Analiza oszacowań parametrów w każdym z trzech modeli, w których próbowano uwzględnić sezonowość zmian zmiennej CPI, pozwala stwierdzić, że tylko w modelu z sezonowością stochastyczną istnieją istotnie statystycznie zmienne charakteryzujące tę sezonowość. Wprowadzanie kolejnych specyfikacji dotyczących sezonowości nie zmienia znaków oszacowań parametrów przy większości regresorów. Wyjątkiem są zmienne *ind_q3f* oraz *ind_q7f*. Stojące przy nich parametry mają w różnych

modelach odmienne znaki. Tak jak w przypadku modeli zmiennej GDP oraz UNE dla większości regresorów modelowanie sezonowości nie zmienia drastycznie wartości oszacowań stojących przy nich parametrów. W modelach dla zmiennej CPI wyjątkiem jest wyraz wolny modelu. W konkluzji można postawić hipotezę, że zmiany wskaźnika inflacji mają charakter zmian sezonowych o sezonowości stochastycznej. Warto zauważyć, iż wśród regresorów znów pojawiły się zmienne charakteryzujące odczucia gospodarstw domowych.

We wszystkich rozpatrywanych modelach obecne były zawsze dwie zmienne *zew_ies* oraz *ind_q7*. Pierwsza z nich opisuje zmiany w koniunkturze gospodarki niemieckiej, a druga opinie przedsiębiorstw dotyczące ich sytuacji finansowej.

Nie omawiamy dalej modeli, w których modelowano wolumen produktu krajowego brutto w cenach stałych (GDP_VOL). Oszacowania tych modeli nie są zadowalające i należy sądzić, że prognozy generowane na ich podstawie będą charakteryzować się dużą niestabilnością.

5. Prognozowanie

Przed przystąpieniem do prognozowania zmiennych GDP, UNE i CPI porównamy dopasowanie modeli bez uwzględniania sezonowości i modeli, w których bierze się jej występowanie pod uwagę. Wyznamy wartości pierwiastka błędu średniokwadratowego (*root mean square error*, RMSE) dla kwartałów lat 2009-2011 oraz 2010-2011, traktując wartości teoretyczne zmiennych endogenicznych jako zrealizowane prognozy. Po zbadaniu statystycznej istotności deterministycznych oraz stochastycznych składników sezonowych oszacowano kolejny model prognostyczny nazwany końcowym (*Final*). W modelu zachowano poprzednio zidentyfikowane zbiory regresorów. Równanie zmiennej GDP było pozbawione składników sezonowych, w równaniu zmiennej UNE modelowano oba rodzaje sezonowości, a w równaniu zmiennej CPI uwzględniono tylko sezonowość stochastyczną.

Wartości RMSE są wyrażone w tych samych jednostkach miary co każda ze zmiennych endogenicznych. W naszym przypadku tymi jednostkami miary są punkty procentowe. Dopasowanie modeli do danych z przeszłości wydaje się być zadowalające. Przyglądając się wielkościom zamieszczonym w tabeli 7, widzimy, że uwzględnianie sezonowości nieznacznie poprawia ich dopasowanie do danych, czyli czyni bardziej prawdopodobnym wykonanie prognozy obciążonej mniejszym błędem. W modelu końcowym, w którym uwzględniono indywidualnie wykryte rodzaje sezonowości dla każdego równania, wartość błędu zmniejsza się

widocznie tylko dla zmiennej UNE. Jednocześnie widać, że przeciętne błędy dla okresu 2010-2011 są najczęściej mniejsze niż dla okresu 2009-2011. Może to być spowodowane dostosowaniem się modelu do zjawisk kryzysowych, które najsilniej oddziaływały na koniunkturę właśnie w końcu 2008 r. i w roku 2009.

Tabela 7. Wartości błędu średniokwadratowego w kwartałach 2009-2011 i 2010-2011

Regresant	Modele				Final
	Bez sezonowości	Sezonowość deterministyczna	Sezonowość stochastyczna	Oba rodzaje sezonowości	
Kwartały 2009-2011					
GDP	0,74	0,68	0,71	0,66	0,74
UNE	0,62	0,42	0,38	0,37	0,30
CPI	0,54	0,54	0,39	0,39	0,42
Kwartały 2010-2011					
GDP	0,54	0,52	0,57	0,56	0,54
UNE	0,59	0,42	0,25	0,30	0,20
CPI	0,53	0,58	0,37	0,39	0,42

Źródło: obliczenia własne.

Zgodnie z przyjętą zasadą w szacowanych modelach regresory z testów koniunktury są opóźnione w czasie o 3 kwartały. Ostatnim kwartałem, dla którego dysponujemy danymi, są: dla zmiennych GDP, UNE, CPI – ostatni kwartał 2011 r., a dla zmiennych, których wartości pochodzą z testów koniunktury, tj. dla Polski i Niemiec – pierwszy kwartał 2012 r. Wynika stąd, że wartości zmiennych endogenicznych dla okresu prognozy, czyli kwartałów 2012 r., można wygenerować z oszacowanych modeli bez przyjmowania jakichkolwiek dodatkowych założeń o wartościach regresorów w okresie prognozy. W tabeli 8 są prezentowane wartości zmiennych w okresie prognozy w dwóch punktowych wariantach. Pierwszy wariant prognozy są to wartości środków przedziałów dla modeli bez uwzględniania sezonowości, z uwzględnioną tylko sezonowością deterministyczną, z uwzględnioną wyłącznie sezonowością stochastyczną oraz z modelowanymi oboma typami sezonowości łącznie. Drugi wariant prognozy są to wartości zmiennych GDP, UNE i CPI otrzymane z modelu finalnego.

Tabela 8. Dwa warianty prognoz na kwartały 2012 r. oraz prognoza Instytutu Badań nad Gospodarką Rynkową

Kwartał	Środek przedziału prognoz			Z modelu finalnego			Prognozy IBnGR		
	GDP	UNE	CPI	GDP	UNE	CPI	GDP	UNEr	CPI
Q1	3,5	9,7 [10,0]	4,2	3,6	9,5	4,3	3,7	13,4 [13,3]	4,3
Q2	3,4	9,7 [9,5]	4,2	3,7	8,5	3,0	3,3	12,9 [11,9]	4,1
Q3	3,3	9,7 [9,3]	4,3	3,9	7,6	3,3	2,6	12,4 [11,8]	3,8
Q4	2,0	10,3 [9,7]	4,1	2,9	7,2	4,3	2,4	12,8 [12,5]	3,4

Uwagi: prognozy autorskie wykonane w dniach 5-10 marca 2012 r. Prognoza IBnGR opublikowana 1.02.2012 r.

Prognoza otrzymana z modelu finalnego jest dla polskiej gospodarki bardziej optymistyczna. Jej wartości można zestawić z opublikowanym 12 marca 2012 r. raportem Instytutu Ekonomicznego NBP o projekcji inflacji i wzrostu gospodarczego Polski na lata 2012-2014. Przewiduje się tam, że roczne tempo wzrostu wyniesie około 3 %, a inflacja ok. 4,1 %. Tym prognozom z kolei jest bliższy ten wariant prognozy, który otrzymano jako środek przedziału prognoz z 4 wymienionych wcześniej modeli.

Porównania wartości prognoz kwartalnych można dokonać z prognozą opublikowaną na początku lutego 2012 r. przez Instytut Badań nad Gospodarką Rynkową w periodycznie wydawanym opracowaniu „Stan i prognoza koniunktury gospodarczej”. Tempo wzrostu GDP w prognozie Instytutu ma – podobnie jak wykonanych prognozach – tendencję spadkową. Wielkości tego spadku różnią się jednak od naszych prognoz. Prognoza zmian inflacji jest różna od naszej. W wariancie środka przedziału prognoz inflacja utrzymuje się na dość wysokim ponad 4-procentowym poziomie. Odmiennie jest w wariancie prognozy otrzymanym z modelu, zmniejsza się bowiem znacznie w II kwartale, by potem znów wzrosnąć do poziomu z początku roku. W prognozie Instytutu inflacja ma stałą tendencję malejącą. Trudniej porównać prognozy stóp bezrobocia. Przypomnijmy, że w modelach konstruowanych w niniejszej pracy jest uwzględniana stopa bezrobocia wg BAEL, natomiast w prognozie Instytutu występuje stopa bezrobocia rejestrowanego według stanu na koniec okresu. Jedynym sposobem porównania wydaje się odniesienie do zmian tych samych wielkości w kolejnych kwartałach 2011 r. Wartości odpowiednich stóp bezrobocia umieszczono w kolumnach UNE i UNEr w nawiasach.

W momencie składania niniejszego opracowania do druku (koniec sierpnia 2012 r.) znane są już wartości prognozowanych wielkości za pierwsze dwa kwartały 2012 r.

Tabela 9. Zrealizowane wartości makrowskaźników

Kwartał	Realizacje			
	GDP	UNE	UNEr	CPI
Q1	3,5	10,5	13,3	4,1
Q2	2,4	9,9	12,4	4,0

Źródło: Główny Urząd Statystyczny, stan na 31.08. 2012 r.

Po porównaniu rzeczywistych wartości wskaźników z wartościami prognoz widać, że z dwóch wariantów prognoz punktowych, nazywanych umownie „środek przedziału prognoz”, oraz z modelu „finalnego” lepiej dopasowane do rzeczywistości w dwóch pierwszych kwartałach 2012 r. okazały się prognozy otrzymane jako wartości środków przedziałów dla modeli: bez uwzględniania sezonowości, z uwzględnioną tylko sezonowością deterministyczną, z uwzględnioną wyłącznie sezonowością stochastyczną i z modelowanymi obiema typami sezonowości łącznie. Dokładności prognoz dynamiki produktu krajowego brutto (GDP) oraz stopy bezrobocia wg BAEL (UNE) nie można uznać za zadowalającą. Szczególnie niepokoi różnica między prognozą a wartością wskaźnika zmian produktu krajowego brutto w II kwartale 2012 r. Wartości wskaźnika zmian cen towarów i usług konsumpcyjnych (CPI) prognozowane są z wystarczającą dokładnością. Warto zwrócić uwagę, że prognozy otrzymane przez Instytut Badań nad Gospodarką Rynkową na początku 2012 r. nie są dużo bardziej trafne. Podkreślimy na zakończenie, że generowanie prognoz z modeli prezentowanych w niniejszym opracowaniu może odbywać się automatycznie. Procesowi automatyzacji podlega sposób konstruowania ostatecznej wersji modeli prognostycznych, dobór wartości regresorów z okresu prognozy i samo wyznaczenie wartości makrowskaźników na przyszłe okresy.

6. Podsumowanie

Opracowanie jest kontynuacją prac autorów z lat 2010-2011. Konstruowany jest model prognostyczny dla trzech podstawowych wskaźników makroekonomicznych, takich jak tempo zmian produktu krajowego brutto, stopa bezrobocia i wskaźnik zmian towarów i usług. Zastosowaną do konstrukcji modelu metodologią jest *Bayesian averaging of classical estimates* z modyfikacjami niezbędnymi ze względu na specyficzne cechy modelu. Są nimi takie zasady konstrukcji, które umożliwiają prognozowanie wartości zmiennych endogenicznych bez

czynienia jakichkolwiek założeń co do wartości regresorów w okresie prognozy i zapewniają określoną sekwencję zależności między zmiennymi endogenicznymi. *Novum* w stosunku do poprzednich prac z tej serii jest również uwzględnienie aspektu sezonowości zmiennych zarówno egzogenicznych jak i endogenicznych. Otrzymane wyniki, mimo niezbyt trafnych prognoz, są obiecujące. Okazuje się, że uwzględnienie sezonowości zarówno typu deterministycznego jak i typu stochastycznego jest możliwe i poprawia dopasowanie modeli.

W kolejnych pracach w ramach tego projektu zostanie podjęty temat wpływu stopniowego „postarzania” przeszłych informacji na jakość szacowanych modeli i generowanych prognoz. Testowana będzie również przydatność prognostyczna innych wskaźników koniunktury niż dotychczas uwzględnianych w modelu. Wydaje się również celowe poddanie modelu testom przyczynowości.

Literatura

- Adamowicz E., *Koniunktura gospodarcza – 20 lat doświadczeń Instytutu Rozwoju Gospodarczego Szkoły Głównej Handlowej*, Oficyna Wydawnicza Szkoły Głównej Handlowej, Warszawa 2008
- Anuszewska I., *Sondaże – zwierciadło społeczeństwa. Rytuały komunikacyjne a kreowanie wiedzy wspólnej*, CeDeWu.pl Wydawnictwo Fachowe, Warszawa 2010
- Bañbura, M., Giannone D., Reichlin L., *Nowcasting*, Working Paper, nr 1275, Europejski Bank Centralny, Frankfurt 2010 (grudzień)
- Beneš, J., Clinton K., Johnson M., Laxton D., Matheson T., *Structural models in real-time*, IMF Working Paper, WP/10/56, Waszyngton 2010
- Białowolski P., Drozdowicz-Bieć M., Lada K., Pater R., Zwiernik P., Żochowski D., *Forecasting with composite coincident and leading indexes and the CLIMA model. The case of Poland*, Oficyna Wydawnicza SGH, Warszawa 2007
- Białowolski P., Drozdowicz-Bieć M., Lada K., Pater R., Zwiernik P., Żochowski D., *Forecasting with composite coincident and leading indexes and the CLIMA model*, 29 konferencja CIRET, Santiago de Chile 2008
- Białowolski P., Dudek S., Kuszewski T., Walczyk K., Witkowski B., *Modelowanie i prognozowanie makroproporcji gospodarczych z wykorzystaniem danych ilościowych i jakościowych*, materiał niepublikowany, opracowanie finansowane z grantu Rektora Szkoły Głównej Handlowej, Warszawa 2009

- Białowolski P., Kuszewski T., Witkowski B., *Business survey data in forecasting macroeconomic indicators with combined forecasts*, 30 konferencja CIRET, Nowy Jork 2010 (a)
- Białowolski P., Kuszewski T., Witkowski B., „Prognozy kombinowane wskaźników makroekonomicznych z użyciem danych z testów koniunktury”, w: *Współczesna ekonomia*, vol. 4, nr 4, 2010 (b), s. 41-58
- Białowolski P., Kuszewski T., Witkowski B., *Prognozy podstawowych wskaźników makroekonomicznych z użyciem danych z testów koniunktury*, „Modelowanie i prognozowanie gospodarki narodowej. Prace i materiały Wydziału Zarządzania Uniwersytetu Gdańskiego”, nr 4/8, 2011, s. 49-64
- Białowolski P., Kuszewski T., Witkowski B., *Prognozowanie podstawowych wskaźników makroekonomicznych w modelach konstruowanych metodą bayesowskiego uśredniania estymatorów klasycznych*, „Contemporary Economics”, vol. 6, nr 1, 2012 (a), s. 60-69
- Białowolski P., Kuszewski T., Witkowski B., *Bayesian averaging of classical estimates in forecasting macroeconomic indicators with using business survey data*, 31 konferencja CIRET, Wiedeń 2012 (b)
- Blanchard O., *Macroeconomics*, Pearson Education, 2011 (wydanie piąte)
- Coenen, G., *Central bank forecasting during the financial crisis*, warsztaty pt. *Central bank forecasting*, 14-15 października 2010
- Diebold, F.X., Rudebush G.D., *Business cycles: durations, dynamics and forecasting*, Princeton University Press, 1999
- Drabarek A., *Intuicja. Poznanie bezpośrednio*, Wydawnictwo Wyższej Szkoły Handlu i Prawa im. R. Łazarskiego, Warszawa 2006
- Enders W., *Applied econometric time series*, John Wiley & Sons, Nowy Jork 1995
- Franses P. H., Löf M., *On forecasting cointegrated seasonal time series*, Econometric Institute Report, Uniwersytet Erazma, Rotterdam 2000
- Grabek G., Kłos B., Koloch G., *SOEPL 2009 – Model DSGE małej otwartej gospodarki estymowany na polskich danych*, „Materiały i Studia NBP”, Zeszyt nr 251, NBP, Warszawa 2010
- Grudkowska S., *Demetra+. User manual*, NBP, Warszawa 2011
- Huček, J., Reľovský B., Široká J., *The impact of the global economic and financial crisis on the potential GDP*, http://www.nbs.sk/_img/Documents/PUBLIK/MU/potential_output_ENG.pdf, czytane 18.03.2012
- Kwartalne rachunki narodowe*, GUS, Warszawa 2012
- Lee, J., Rabanal P., Sandri D., *U.S. consumption after the 2008 crisis*, Międzynarodowy Fundusz Walutowy, Waszyngton 2010
- Moral-Benito, E., *Model averaging in economics*, Working Paper, 2011

- Nehrebecka N., Grudkowska S., *Metody analizy sezonowości stochastycznej w produkcji budowlano-montażowej*, „Wiadomości Statystyczne”, vol. 55, nr 1, 2010, s. 37-53
- Okun A.M., *Ceny i ilości. Analiza makroekonomiczna*, Wydawnictwo Naukowe PWN, Warszawa 1991
- Pesaran, M. H., Weale M., *Survey expectations*, w: *Handbook of economic forecasting*, tom 1, pr. zb. pod red. G. Elliota, C. Grangera, A. Timmermana, North-Holland, 2006
- Próchniak M., Witkowski B., *Real β -convergence of transition countries – Robust approach*, „Eastern European Economics”, przyjęte do druku, 2012
- Projekcja inflacji i wzrostu gospodarczego Narodowego Banku Polskiego na podstawie modelu NECMOD* (opublikowana 12.03.2012), Instytut Ekonomiczny NBP, Warszawa
- Roubini N., Mihm S., *Crisis economics: A crash course in the future of finance*, The Penguin Press, 2010
- Sala-i-Martin X., Doppelhofer G., Miller R., *Determinants of long-term growth: a bayesian averaging of classical estimates (BACE) approach*, „American Economic Review”, Vol. 94, 2004, s. 813-835
- Stadelmann D., *Which factors capitalize into house prices? A Bayesian averaging approach*, „Journal of Housing Economics”, vol. 19, nr 3 (wrzesień), 2010, s. 180-204
- Stan i prognoza koniunktury gospodarczej*, nr 73, luty 2012 r., Instytut Badań nad Gospodarką Rynkową, <http://www.inbngr.pl>, czytane 10.03.2012 r.
- Tyszka T. (red.), *Psychologia ekonomiczna*, Gdańskie Wydawnictwo Psychologiczne, Gdańsk 2004
- Zarnowitz, V., *Business cycles: theory, history, indicators and forecasting*, The University of Chicago Press, Chicago 1992