BANCA NAŢIONALĂ A ROMÂNIEI



CAIETE DE STUDII
Nr. 34

CAIETE DE STUDII
Nr. 34

Octombrie 2014

N o t ă

Opiniile prezentate în această lucrare aparţin în întregime autorilor şi nu implică sau angajează în vreun fel Banca Naţională a României.

Toate drepturile rezervate.
Reproducerea informaţiilor în scopuri educative şi necomerciale este permisă numai cu indicarea sursei.

ISSN 1584-0883 (versiune *online*)
ISSN 1584-0883 (versiune e-Pub)

ESTIMAREA ŞI PROGNOZA DINAMICII PIB ŞI ALE COMPONENTELOR PIB PRIN MODELUL CU FACTORI COMUNI DINAMICI. APLICAŢIE PENTRU ROMÂNIA

Andrei Tănase*

* Banca Naţională a României, Direcţia Modelare şi Prognoze Macroeconomice. Autorul apreciază comentariile colegilor din Banca Naţională a României ca fiind determinante în evoluţia proiectului. De asemenea, contribuţii importante au adus o serie de participanţi la „Colocviile de politică monetară“ – ediţia a IV-a, 2011, organizate de Banca Naţională a României, precum şi în urma discuţiilor în cadrul unor *workshop*-uri la care a fost prezentată metodologia: Deutsche Bundesbank 2011, EABCN 2012, EMMPA 2014. Eventualele erori rămase sunt responsabilitatea autorului.

Cuprins

Rezumat 7

1. Introducere 9

2. Modelele cu factori comuni: evoluţie 10

2.1. Modelul cu factori comuni statici 10

2.2. Modelul cu factori comuni dinamici şi estimarea prin metoda FHLR 13

2.2.1. Consideraţii generale privind estimarea modelului 14

2.2.2. Filtrul bidimensional BD, FHLR (2000) 16

2.2.3. Filtrul secvenţial SQ, FHLR (2005) 18

3. Aplicaţie empirică 19

3.1. Datele utilizate 19

3.2. Varianta statică a modelului cu factori comuni 21

3.3. Implementarea modelului cu factori comuni dinamici 23

3.4. Rezultatele exerciţiului de estimare 25

4. Concluzii 31

Bibliografie 32

Rezumat

Analiza activităţii economice pentru trimestrul curent presupune evidenţierea corelaţiei dinamicii PIB şi a componentelor PIB cu cea a unui set vast de indicatori economici, un plus de complexitate provenind din faptul că această corelaţie nu este mereu simultană. În cadrul unui model econometric clasic, introducerea unui număr mare de regresori pentru evaluarea PIB şi a componentelor PIB ridică o serie de probleme de parcimonie, precum testarea gradului de semnificativitate a coeficienţilor. Modelele cu factori comuni dinamici răspund necesităţii de modelare a unor variabile în prezenţa unui număr mare de regresori. Ipoteza care stă la baza modelului este aceea că evoluţia întregului set de variabile observate poate fi explicată suficient de bine de un număr redus de factori comuni. Odată estimaţi, factorii comuni joacă rolul de regresori pentru orice variabilă de interes.

În secţiunea empirică a acestei lucrări, estimăm şi prognozăm PIB real şi componentele PIB pentru trimestrul curent şi cel următor cu ajutorul modelului cu factori comuni dinamici. Metodologia de estimare a factorilor este cea propusă de autorii Forni, Hallin, Lippi şi Reichlin. Pentru PIB, valorile obţinute sunt interpretate ca indicatori *coincident*, respectiv *leading* pentru activitatea economică.

Cuvinte-cheie: estimarea şi prognoza PIB real, factori comuni dinamici

Coduri de clasificare JEL: E27, E58

1. Introducere

În studiul de faţă se estimează şi se prognozează creşterea trimestrială a produsului intern brut (PIB) real şi a componentelor PIB (consum individual efectiv al gospodăriilor populaţiei, formare brută de capital fix – FBCF, exporturi şi importuri)[1] pentru România prin modelul cu factori comuni dinamici. Metodologia de estimare a factorilor se bazează pe abordarea propusă de Forni et al. (2000 şi 2005).

Estimarea dinamicii PIB real pe parcursul trimestrului curent, înainte de publicarea oficială (la aproximativ două luni de la încheierea trimestrului), este importantă pentru completarea imaginii asupra economiei în ansamblu şi pentru stabilirea ipotezelor care stau la baza prognozei macroeconomice. În vederea estimării PIB, analiştii utilizează semnalele oferite pe parcursul trimestrului de o serie de indicatori corelaţi cu dinamica PIB, a căror frecvenţă de publicare este lunară sau zilnică. Exemple de asemenea indicatori sunt producţia industrială, indicatorii de încredere, agregatele monetare sau o serie de variabile financiare, precum cursul de schimb sau ratele dobânzilor.

Reprezentarea dinamicii PIB prin modele econometrice clasice cu număr mare de regresori ridică însă o serie de probleme de parcimonie, precum cele care privesc evaluarea bonităţii modelului sau testarea coeficienţilor, făcând astfel inoportună includerea simultană, în cadrul unui singur model, a tuturor indicatorilor care ar putea îmbogăţi setul informativ disponibil. Modelul cu factori comuni răspunde necesităţii estimării unei variabile, în particular PIB real, în prezenţa unui set numeros de regresori. Ipoteza de bază a acestui model este că evoluţia întregului set de variabile observate este explicată suficient de bine de un număr restrâns de factori comuni. Factorii comuni (ortogonali între ei, prin definiţie), odată estimaţi, sunt utilizaţi ca regresori pentru modelarea variabilelor de interes. Această abordare a fost promovată, în ordine cronologică, de autori precum Sargent şi Sims (1977), care au formalizat metodologia de construire a indicatorilor *coincident* şi *leading* pentru economia SUA de către National Bureau of Economic Research (NBER), Engle şi Watson (1981), Quah şi Sargent (1993) sau Forni şi Reichlin (1996), iar dintre contribuţiile cele mai recente menţionăm pe cele ale lui Forni et al. (2000 şi 2005), respectiv Stock şi Watson (2002).

Majoritatea lucrărilor menţionate mai sus urmăresc estimarea şi/sau prognoza PIB, valorile obţinute fiind interpretate ca indicatori *coincident*, respectiv *leading*, pentru activitatea economică. Printre studiile din ultimii ani care urmăresc estimarea unor variabile, precum PIB sau inflaţie, indicăm o serie de lucrări în cadrul Băncii Centrale Europene: Barhoumi K. et al. (2008), Angelini et al. (2008) şi Jakaitiene şi Dées (2009). În ultimele două lucrări menţionate sunt prezentate aplicaţii de estimare atât a PIB, cât şi a componentelor PIB sau a unor variabile macroeconomice, precum indici de preţuri sau producţia industrială. De asemenea, o serie de alţi autori care aplică modelul cu factori comuni pentru estimarea sau prognoza dinamicii PIB, cu rezultate satisfăcătoare din punct de vedere al preciziei de estimare, sunt Altissimo et al. (2006), Banerjee şi Marcellino (2006), Banerjee et al. (2005), Breitung şi Eickmeier (2005), Schumacher şi Breitung (2006) şi, mai recent, Hindrayanto et al. (2014). În particular, aceştia din urmă subliniază buna precizie a modelelor cu factori comuni în prognoza pe termen scurt a PIB pentru o serie de state membre ale zonei euro.

[1] Analiza empirică exclude modelarea componentei consumul colectiv efectiv al administraţiilor publice.

În aplicaţia empirică din această lucrare se preia metodologia de estimare a factorilor propusă de Forni et al. (FHLR 2000 şi 2005). Aceştia estimează factorii comuni prin metoda analizei componentelor principale extrase din matricea de densitate spectrală a seriilor, spre deosebire de varianta „clasică“ de extragere a componentelor prin intermediul matricei de covarianţă (de exemplu, în Stock şi Watson (SW), 2002). Utilizarea matricei de densitate spectrală în economie nu este tocmai recentă (a se vedea, de exemplu, studiul întreprins de Harvey (1975). În particular, în cazul estimării modelelor cu factori comuni, analiza spectrală aduce avantaje notabile atunci când influenţa factorilor comuni asupra variabilelor observate nu este omogenă, cu alte cuvinte factorii influenţează *lag*-urile variabilelor în manieră diferenţiată. Verificarea acestor condiţii pentru variabile economice este foarte probabilă, dat fiind caracterul anticipator al unor indicatori pentru activitatea economică. Mai mult, metoda FHLR presupune utilizarea filtrului Bartlett în estimarea corelaţiilor dintre variabile. Întrucât filtrul menţionat include un sistem de ponderi invers proporţionale cu distanţa temporală, acesta este potenţial mai precis decât metoda de estimare simplă a covarianţei; când seriile de date sunt scurte, diferenţele pot deveni semnificative.

Lucrarea este structurată în modul următor: în secţiunea 2 se prezintă modelul cu factori comuni, atât în varianta statică, cât şi în cea dinamică. Abordarea este preponderent teoretică, incluzând paralela dintre modelul cu factori comuni şi analiza componentelor principale. Aceasta din urmă facilitează înţelegerea metodologiei de estimare a modelelor cu factori comuni. Secţiunea 3 este dedicată aplicaţiei empirice, iar ultima secţiune conţine sumarul rezultatelor care relevă înglobarea rapidă a noilor evoluţii ale variabilelor observate în valorile estimate ale PIB şi ale componentelor sale.

2. Modelele cu factori comuni: evoluţie

În această secţiune se prezintă modelele cu factori comuni şi estimarea acestora, pornind de la varianta statică şi continuând cu cea dinamică. Atunci când numărul de factori „statici" este fixat ca fiind egal cu cel al variabilelor observate, modelul cu factori comuni este echivalent cu analiza componentelor principale. Această analiză constă în exprimarea variabilităţii observate într-un set de variabile ca sumă a variabilităţii unor componente principale neobservabile ortogonale. Pornind de la echivalenţa menţionată, analiza componentelor principale constituie o metodă de estimare a modelelor cu factori comuni[2].

2.1. Modelul cu factori comuni statici

Fie $\{X_{n,T}\} = \{x_{i,t}, i = 1 \ \ldots \ n, t = 1 \ \ldots \ T\}$ un set de variabile observate, unde n denotă numărul de variabile, iar T lungimea seriilor de date. Pentru simplitate, se consideră că variabilele sunt iniţial transformate, mediile acestora fiind egale cu zero. De asemenea, fie Σ_X matricea de covarianţă a datelor. Modelul cu factori comuni se construieşte pe următoarea ipoteză: un număr redus de $q << n$ factori comuni, neobservabili, explică într-o proporţie majoritară evoluţia variabilelor observate. Sub ipoteza unei relaţii liniare între variabilele observate şi factorii comuni, modelul poate fi scris astfel:

[2] O alternativă de estimare a factorilor comuni „statici" este metoda MLE (*Maximum Likelihood Estimation*) care pleacă de la formularea unei presupuneri distribuţionale asupra erorilor, de exemplu normalitatea acestora.

$$X_{[n \times T]} = \beta F_{[q \times T]} + \epsilon, \tag{1}$$

unde $\{F_{q,T}\} = \{f_{j,t}, j = 1 \ldots q, t = 1 \ldots T\}$ sunt factorii comuni, $\beta_{[n \times q]}$ sunt coeficienţii factorilor (*factor loadings*), iar $\epsilon_{[n \times T]}$ sunt erorile modelului, necorelate cu factorii. Condiţia necesară identificării factorilor este ortogonalitatea acestora. Factorii sunt standardizaţi (au media egală cu zero, iar varianţa este unitară). Considerând proprietăţile factorilor şi ale erorilor modelului, din ecuaţia (1) rezultă că varianţa datelor Σ_X poate fi descompusă în cea a factorilor (rescalaţi prin coeficienţi), respectiv cea a erorilor

$$\Sigma_X = \beta\beta' + \Sigma_\epsilon.$$

Echivalenţa cu analiza componentelor principale pentru *q = n*

Pentru $q = n$, modelul cu factori comuni este echivalent cu analiza componentelor principale. Aceasta constă în exprimarea varianţei seriilor observate $\{x_{i,t}, i = 1 \ldots n, t = 1 \ldots T\}$ ca sumă a varianţei unor componente principale ortogonale $\{r_{i,t}, i = 1 \ldots n, t = 1 \ldots T\}$

$$\sum_i^n Var(x_i) = \sum_i^n Var(r_i).$$

Derivarea componentelor principale se bazează pe următoarea proprietate a oricărei matrici simetrice Σ_X (a se vedea, de exemplu, Peracchi, 2001): date valorile proprii $\lambda_1 \geq \lambda_2 \geq \ldots \lambda_n$, atunci există o matrice P, astfel încât

$$\Sigma_X = P\, diag[\lambda_i] P' \text{ unde } P'P = I_n, \tag{2}$$

iar $P = \{P_i = (p_{i,1}, \ldots p_{i,n})', i = 1 \ldots n\}$ este setul de vectori proprii ortogonali ai Σ_X[3]. Astfel, Σ_X este proiectată pe un plan de vectori ortogonali $\{P_i\}$, rescalaţi de valorile proprii corespunzătoare $\{\lambda_i\}$. Conform Rezultatului 9.1 din Tsay (2005), componentele principale sunt egale cu proiecţia variabilelor pe planul de vectori proprii

$$r_i = \sum_{j=1}^n p_{i,j} \cdot x_j.$$

Varianţa componentelor proprii este $Var(r_i) = \lambda_i$, egalitate din care se calculează proporţia de varianţă a datelor explicată de fiecare componentă în parte:

$$\frac{Var(r_i)}{\sum_i^n Var(x_i)} = \frac{Var(r_i)}{\sum_i^n Var(r_i)} = \frac{\lambda_i}{\sum_i^n \lambda_i}.$$

Întrucât componentele principale sunt calculate în ordine descrescătoare a valorilor proprii:

[3] Perechile de vectori şi valorile proprii sunt determinate din ecuaţia caracteristică det $(\Sigma_X - \lambda I) = 0$.

$$[Var\,(r_1) = \lambda_1] \geq [Var\,(r_2) = \lambda_2] \geq \ldots \geq [Var\,(r_n) = \lambda_n],$$

primele q componente principale explică o proporţie din varianţa datelor egală cu

$$\frac{\sum_i^q Var\,(r_i)}{\sum_i^n Var\,(x_i)} = \frac{\sum_i^q Var\,(r_i)}{\sum_i^n Var\,(r_i)} = \frac{\sum_i^q \lambda_i}{\sum_i^n \lambda_i}.$$

De cele mai multe ori, variabilele observate sunt corelate între ele întrucât fac parte dintr-un sistem, această proporţie fiind mai mare de 50 la sută chiar pentru valori mici ale parametrului q (în caseta „Estimarea unui model cu factori comuni statici" este prezentat un exerciţiu de derivare a componentelor principale).

Estimarea factorilor cu primele *q* componente principale

După cum am menţionat mai sus, un număr redus de componente principale $q << n$, de exemplu 3 sau 4, este suficient pentru a explica o proporţie majoritară din Σ_X. Plecând de la echivalenţa, pentru $q = n$, dintre modelul cu factori comuni şi analiza componentelor principale, din relaţia (2) se obţin valori estimate pentru $[\hat{\beta}]_{n \times q}$ *(factor loadings)*

$$\hat{\beta} = (\hat{\beta}_1, \ldots, \hat{\beta}_q) = (\sqrt{\hat{\lambda}_1}\hat{p}_1, \ldots, \sqrt{\hat{\lambda}_q}\hat{p}_q).$$

Factorii sunt interpretaţi ca fiind componentele principale obţinute din matricea de covarianţă a datelor standardizate. Varianţa fiecărei variabile x_i este explicată de factorii comuni într-o proporţie de

$$c_i = \hat{\beta}_{i,1}^2 + \ldots \hat{\beta}_{i,q}^2, \qquad (3)$$

denumită *communality*; varianţa specifică fiecărei variabile este$(1 - c_i)$, denumită *uniqueness*.

Estimarea unui model cu factori comuni statici

În această casetă este prezentat un exerciţiu de estimare a modelului cu factori comuni prin analiza componentelor principale. Datele observate caracterizează economia românească în perioada 2000-2010. Evoluţia variabilelor, în număr de 15, este explicată în proporţie de aproximativ 70 la sută de primii 3 factori comuni, contribuţia cumulată a primilor doi dintre aceştia fiind mai mare de 50 la sută.

Variabilele sunt grupate conform factorului cu cel mai mare coeficient (în valoare absolută), cu alte cuvinte factorului care explică cel mai mare procent de varianţă (a se vedea formula (3)). Prima grupă include variabile *ouput* şi agregate monetare, iar coeficienţii asociaţi factorului dominant au semnul pozitiv. Cel de-al doilea factor explică atât dobânzile cât şi şomajul, iar cel de-al treilea factor este asociat exclusiv pieţei muncii. În cazul ultimelor două variabile, procentul de variabilitate explicat de factori este redus.

Conform analizei, primul factor poate fi interpretat ca variabilă latentă asociată activităţii economice (atât ca producţie, cât şi ca interacţiune cu unele agregate monetare), iar ceilalţi doi factori pot fi asociaţi condiţiilor monetare şi pieţei muncii.

Contribuţia factorilor la descopunerea varianţei pentru fiecare variabilă
Varianţa explicată de factori: F1: 38% F2: 18% F3: 9%

Variabilă	Factor 1	Factor 2	Factor 3	Total	*Uniqueness*
PIB	0,78	0,05	0,00	0,83	0,17
M1	0,77	0,07	0,06	0,90	0,10
Depozite O/N	0,72	0,04	0,04	0,80	0,20
PIB zona euro (16)	0,68	0,15	0,00	0,83	0,17
Importuri de bunuri intermediare	0,52	0,18	0,00	0,70	0,30
Productivitatea muncii	0,37	0,30	0,15	0,82	0,18
Numerar	0,35	0,18	0,06	0,58	0,42
Producţia industrială	0,30	0,10	0,16	0,56	0,44
Şomaj	0,03	0,82	0,06	0,91	0,09
Rata dobânzii - credite	0,05	0,63	0,28	0,95	0,05
ROBOR O/N	0,06	0,58	0,29	0,93	0,07
Număr angajaţi	0,28	0,16	0,40	0,84	0,16
Costul unitar cu forţa de muncă	0,00	0,21	0,26	0,47	0,53
Exporturi materii prime	0,14	0,01	0,15	0,30	0,70
Cheltuieli publice	0,00	0,04	0,00	0,04	0,96

2.2. Modelul cu factori comuni dinamici şi estimarea prin metoda FHLR

Modelele cu factori comuni dinamici reprezintă o extensie a modelului cu factori comuni statici. Caracterul dinamic al factorilor este dat de impunerea unei legi de mişcare pentru aceştia. Pentru specificaţia modelului, vom urmări notaţia lui Forni et al. (FHLR 2000 şi 2005).

Fie $\{X_{n,T}\} = \{x_{i,t}, i = 1 \ldots n, t = 1 \ldots T\}$ setul de variabile observate. Fiecare variabilă observată X_i este modelată ca sumă a componentei sale comune χ_i şi a unui şoc idiosincratic ξ_i. Componenta comună este proiecţia liniară a variabilei pe factorii comuni:

$$x_{i,t} = \chi_{i,t} + \xi_{i,t} \tag{4}$$

$$\chi_{i,t} = b_{i,1}(L)f_{1,t} + b_{i,2}(L)f_{2,t} + \ldots + b_{i,q}(L)f_{q,t}, \tag{5}$$

unde L este operatorul *lag*, iar $\{B_{q,T} = b_{i,j}(L), i = 1 \ldots n, j = 1 \ldots q\}$ este setul de coeficienţi aferenţi factorilor[4] (*time varying factor loadings*).

Prin structura sa, modelul cu factori comuni dinamici este analog modelelor *state-space*. Ecuaţia (4) este o ecuaţie de măsură pentru variabilele observate, iar (5) este o ecuaţie de tranziţie pentru componentele comune, neobservabile. Datorită acestei analogii, potenţialul modelului cu factori comuni dinamici de a fi utilizat în aplicaţiile de prognoză este ridicat.

2.2.1. Consideraţii generale privind estimarea modelului

Atât FHLR (2000 şi 2005), cât şi Stock şi Watson (2002) propun estimarea modelului cu factori comuni prin analiza componentelor principale. Deosebirea dintre cele două metodologii constă în sursa componentelor principale: SW au o abordare clasică, utilizând matricea de covarianţă, în timp ce FHLR extrag componentele din matricea de densitate spectrală. Din punct de vedere teoretic, cele două metode sunt echivalente (a se vedea caseta „Reprezentarea şi estimarea spectrului unei serii de timp" pentru dualitatea dintre matricea de densitate spectrală şi cea de covarianţă). Avantajul utilizării matricei de densitate spectrală constă în precizia mai mare de estimare când influenţa factorilor comuni asupra variabilelor nu este omogenă (factorii inflenţează diferenţiat *lag*-urile şi *lead*-urile variabilelor); de asemenea, filtrul nonparametric Bartlett cu ponderi inegale este preferabil atunci când seriile de date sunt relativ scurte.

Reprezentarea şi estimarea spectrului unei serii de timp

Analiza spectrală constă în reprezentarea unei serii de date Y_t ca sumă ponderată a funcţiilor ce reprezintă totalitatea ciclurilor posibile într-un arc de timp. Pentru formalizare, se utilizează funcţiile trigonometrice cos(ωt) şi sin(ωt), unde ω ia valori peste tot intervalul [0,π]:

$$Y_t = \mu + \int_0^{\pi} \alpha(\omega)\cos(\omega t)\mathrm{d}\omega + \int_0^{\pi} \delta(\omega)\sin(\omega t)\mathrm{d}\omega .$$

Astfel, analiza spectrală are ca aplicaţie directă estimarea ponderii unor serii cu ciclicitate standard (de exemplu, anuală) în descompunerea varianţei unor serii economice de interes, precum PIB. Acesta este specificul analizei efectelor sezoniere pentru seriile economice.

Urmărind Hamilton (1994) şi Harvey (1975), fie:

$$\gamma_Y(k) = E(Y_t - \mu)(Y_{t-k} - \mu)$$

funcţia de autocovarianţă de ordin k a unei serii Yt cu medie $E(Y_t) = \mu$. Funcţia de densitate spectrală este definită prin intermediul transformării Fourier plecând de la $\gamma_Y(k)$. O condiţie necesară este $\sum_{k=1}^{\infty} \gamma_Y(k) < \infty$. Dualitatea dintre funcţia de autocovarianţă şi cea spectrală constă în setul de definiţii:

[4] Coeficienţii îndeplinesc condiţii standard de scală, suma pătratelor acestora fiind finită.

$$f_Y(\omega) = \frac{1}{2\pi}\sum_{k=-\infty}^{\infty} \gamma_Y(k)\exp(-i\omega k) = \frac{1}{2\pi}\left(\gamma_Y(0) + 2\sum_{k=1}^{\infty}\gamma_Y(k)\cos(\omega k)\right)$$

şi (6)

$$\gamma_Y(k) = \int_{-\pi}^{\pi} f_Y(\omega)\cos(\omega k)\mathrm{d}\omega.$$

De notat că, întrucât cos() este o funcţie periodică, $f_Y(\omega)$ este, de asemenea, o funcţie periodică

$$f_Y(\omega) = f_Y(\omega + 2\pi k),\ \forall k \in \mathbb{Z}.$$

Interpretarea spectrului

Pentru $k = 0$, $\gamma_Y(0) = \int_{-\pi}^{\pi} f_Y(\omega)\mathrm{d}\omega$; cu alte cuvinte, aria determinată de spectrul unei serii este egală cu varianţa seriei. De asemenea, $\int_{-\omega}^{\omega} f_Y(\omega)\mathrm{d}\omega$ reprezintă varianţa seriei explicate de ciclurile cu frecvenţe mai mici decât sau egale cu ω.

Estimarea spectrului. Exemplu

Cea mai simplă metodă de estimare a funcţiei de densitate spectrală este periodograma. Mai exact

$$\hat{f}_Y(\omega) = \frac{1}{2\pi}\left(\hat{\gamma}_Y(0) + 2\sum_{k=1}^{T-1}\hat{\gamma}_Y(k)\cos(\omega k)\right).$$

Estimatorul de mai sus prezintă dezavantaje notabile. Cu cât k este mai mare, cu atât covarianţa este estimată mai puţin precis (distribuţia limită a estimatorului este χ^2). De asemenea, numărul de parametri creşte direct proporţional cu dimensiunea eşantionului. Ca alternativă, se consideră metodele parametrice (presupunerea unui proces de bază ARMA) sau cele nonparametrice. FHLR folosesc metoda nonparameterică *Bartlett kernel* în care $\hat{\gamma}_Y(k)$ primesc o pondere invers proporţională cu ordinul *k*

$$\hat{f}_Y(\omega) = \frac{1}{2\pi}\left(\hat{\gamma}_Y(0) + 2\sum_{k=1}^{M}\left(1 - \frac{k}{M+1}\right)\hat{\gamma}_Y(k)\cos(\omega k)\right)$$

Figura 1 ilustrează cei doi estimatori menţionaţi (periodograma şi filtrul Bartlett) ai funcţiei de densitate spectrală pentru un proces AR (1) simulat (panoul din partea stângă a figurii)

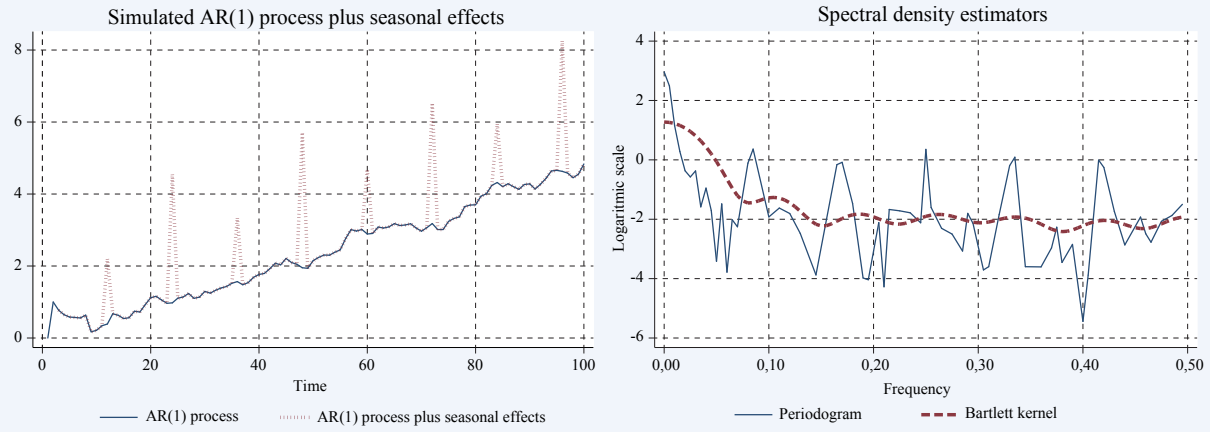
$$Y_t = 0.8 * Y_{t-1} + 0.01 * t + 0.1 * U_t,\ U \sim \mathcal{N}(0, 1),\ t = 1 \ldots 100,$$

la care se adaugă două efecte sezoniere independente cu manifestare o dată la 12, respectiv 24 de luni

$$s_{1,t} = 2 \cdot (0.75 + 0.25 \cdot U_{1,t}) \qquad s_{2,t} = 2 \cdot (0.75 + 0.25 \cdot U_{2,t}).$$

În panoul drept al figurii notăm valori ridicate ale funcţiei de densitate spectrală estimată la frecvenţa minimă, confirmând contribuţia ridicată a şocului U la varianţa seriei Y. Periodograma are valori ridicate pentru un număr mare de frecvenţe, ceea ce indică o estimare imprecisă a frecvenţelor asociate efectelor sezoniere de bază. Filtrul Bartlett este mai puţin variabil, iar efectele sezoniere sunt destul de vizibile (valori ridicate la frecvenţele $0{,}12 \cdot 2\pi$ şi $0{,}24 \cdot 2\pi$). De asemenea, filtrul indică o serie de alte frecvenţe (aproximativ $0{,}18 \cdot 2\pi$, $0{,}36 \cdot 2\pi$, $0{,}48 \cdot 2\pi$) cu importanţă relativ ridicată, reflectând efectul interacţiunii efectelor sezoniere de bază.

Figura 1: Periodograma şi filtrul Bartlett pentru seria $Y_t = 0{,}8 * Y_{t-1} + 0{,}01 * t + 0{,}1 * U, U \sim \mathcal{N}(0,1)$, la care se adaugă două efecte sezoniere (12, respectiv 24 de luni)



După cum am menţionat în introducere, o aplicaţie empirică des întâlnită pentru modelul cu factori comuni este estimarea şi prognoza dinamicii PIB. De exemplu, Forni et al. (2000) estimează componenta comună a PIB, interpretând-o ca indicator de conjunctură economică (indicator *coincident*). De asemenea, modelul este utilizat pentru prognoza componentei comune a PIB (a se vedea, de exemplu, SW (2002), FHLR (2005)), aceasta fiind interpretată ca indicator *leading* pentru economie. În aplicaţia empirică a acestei lucrări estimăm şi prognozăm componentele comune ale creşterii PIB trimestrial şi ale componentelor PIB pentru România, folosind serii de date cu diferite frecvenţe (trimestrială, lunară, zilnică) publicate în trimestrul curent.

FHLR şi SW estimează factorii comuni prin analiza componentelor principale extrase din matricea de densitate spectrală, respectiv cea de covarianţă. Componentele comune ale variabilelor sunt obţinute, în ambele metode, prin proiectarea acestora pe un filtru care grupează factorii comuni.

În restul secţiunii sunt prezentate cele două variante ale filtrului FHLR: filtrul bidimensional (BD) (propus în articolul FHLR (2000)) şi filtrul secvenţial (SQ) (propus în articolul FHLR (2005)), acesta din urmă având o precizie superioară în estimarea valorilor cele mai recente ale componentelor comune şi în previzionarea acestora.

2.2.2. Filtrul bidimensional BD, FHLR (2000)

Rescriem aici modelul cu factori comuni dinamici introdus în ecuaţiile (4) şi (5):

$$x_{i,t} = \chi_{i,t} + \xi_{i,t} = b_{i,1}(L)f_{1,t} + b_{i,2}(L)f_{2,t} + \ldots + b_{i,q}(L)f_{q,t} + \xi_{i,t} \qquad (7)$$

unde $\{X_{n,T}\} = \{x_{i,t}, i = 1 \ldots n, t = 1 \ldots T\}$ este setul de variabile, fiecare dintre acestea fiind reprezentată ca sumă între componenta comună $\chi_{i,t}$ şi un şoc specific $\xi_{i,t}$. La rândul lor, componentele comune $\{\chi_{i,t}, i = 1 \ldots n, t = 1 \ldots T\}$ sunt combinaţii liniare de q factori comuni ortogonali $\{f_{j,t}, j = 1 \ldots q, t = 1 \ldots T\}$, unde $q << n$.

Componentele comune $\chi_{i,t}$ sunt obţinute prin proiecţia variabilelor observate $X_{i,t}$ pe un filtru bidimensional care integrează cei q factori comuni dinamici. Generalizarea efectuată de FHLR (2000) faţă de modelele cu factori dinamici propuse iniţial de către Sargent şi Sims (şi Geweke) (1977) constă în relaxarea condiţiilor impuse şocurilor specifice, acestora fiindu-le permis un anumit grad de dependenţă temporală.

Pentru formalizare, notăm cu $\Sigma(\theta)_X$ matricea de densitate spectrală a datelor. Aceasta este formată din valorile funcţiei de densitate spectrală estimată în frecvenţele $\{\theta_1,...,\theta_{2M+1}\}$, echidistante în intervalul $[-\pi, \pi)$. De asemenea, fie $\{\lambda_j, \mathrm{p}_{nj}^T(\theta_h), j = 1 \ldots q\}$ setul de q valori şi vectorii proprii asociaţi, calculaţi la frecvenţa θ_h. Componentele estimate sunt:

$$\hat{\chi}_{i,t} = BD_i(L) X_{i,t}, \tag{8}$$

unde

$$BD_i(L) = \sum_{k=-M}^{M} K_{i,k} L^k, \tag{9}$$

$$K_{i,k} = \frac{1}{2M+1} \sum_{h=0}^{2M} K_i(\theta_h) \exp(ik\theta_h),$$

iar

$$K_i^T(\theta_h) = \tilde{p}_{1,i}^T(\theta_h)\mathrm{p}_1^T(\theta_h) + \ldots + \tilde{p}_{q,i}^T(\theta_h)\mathrm{p}_q^T(\theta_h)$$

integrează vectorii proprii ai $\Sigma(\theta)_X$, aplicându-le transformarea Fourier inversă (trecerea din domeniul frecvenţelor în cel temporal). În ecuaţiile de mai sus L^k este operatorul *lag* de ordin k, iar $\tilde{p}$ este complementul vectorului p. În ceea ce priveşte frecvenţele, acestea sunt fixate echidistant după formula

$$\theta_h = 2\pi h/(2M+1).$$

Densitatea spectrală este estimată nonparametric (metoda *Bartlett kernel*) considerând setul de perioade $\{(t-M)... t ... (t+M)\}$. Parametrul M este ales arbitrar, un posibil criteriu de urmat fiind frecvenţa datelor[5]. Precizăm că nu există restricţia ca numărul de perioade să fie egal cu cel de frecvenţe, această convenţie simplificând implementarea modelului.

[5] De exemplu, în cazul aplicaţiei empirice utilizăm date cu frecvenţă trimestrială şi fixăm $M = 4$.

Demonstrarea consistenţei primelor q componente principale pentru spaţiul factorilor comuni completează partea teoretică a lucrării FHLR (2000). Mai mult, consistenţa nu este afectată în cazul în care şocurile $\{\xi_{i,t}, i = 1...n, t = 1...T\}$ au un anumit grad de dependenţă temporală.

De asemenea, se demonstrează că fixarea *a priori* a unui număr q superior valorii optimale q^* (sub ipoteza cunoaşterii modelului adevărat) nu alterează semnificativ precizia estimării componentelor comune.

2.2.3. Filtrul secvenţial SQ, FHLR (2005)

Filtrul bidimensional BD are o precizie redusă în estimarea celor mai recente valori ale componentelor comune şi implicit în previzionarea acestora pentru o serie de perioade succesive $T + h$, $h > 0$. În FHLR (2005) se prezintă un filtru secvenţial (notat aici cu SQ) cu performanţe mai bune în previzionarea componentei comune, acesta preluând elemente atât din filtrul BD, cât şi din metoda propusă de Stock şi Watson (2002).

Stock şi Watson (2002) estimează factorii comuni prin analiza statică a componentelor principale extrase dintr-un set de M matrici de covarianţă $\Sigma_{t,t-s}$, unde $s = 0,..., M$. După extragerea primelor q componente principale statice din fiecare matrice de covarianţă corespunzătoare perioadelor s (în total sunt $r = q \cdot (M + 1)$ componente principale), se estimează un proces autoregresiv pentru coeficienţii factorilor (*factor loadings*). În final, variabilele observate sunt proiectate pe un filtru care grupează factorii comuni dinamici.

În vederea formalizării metodei propuse în FHLR (2005) pentru previzionarea variabilelor de interes, notăm cu $X_{i,T+h}$ valoarea variabilei X_i în perioada $(T + h)$. FHLR (2005) previzionează $X_{i,T+h}$ cu $\hat{\chi}_{i,T+h}$, componenta comună la momentul $(T + h)$.

Paşii urmaţi pentru obţinerea $\hat{\chi}_{i,T+h}$ sunt următorii:

- se estimează cele n componente comune prin filtrul BD,
- din matricea de covarianţă (corespunzător rescalată) a componentelor comune se extrage un set de q componente principale „generale” (factori comuni),
- se grupează vectorii proprii „generali” corespunzători acestor componente „generale” în filtrul SQ.

Formalizând,

$$\hat{\chi}_{i,T+h\,|\,T} = \sum_{i'=1}^{n} SQ^{h}_{n,ii'}\, x_{i'T}\,, \tag{10}$$

unde filtrul SQ, în versiunea generală *prediction* ($h \geq 0$), are forma

$$SQ^{h}_{n,ii'} = \Gamma^{\chi}_{nh} Z_n' \left(Z_n \Gamma^{T}_{n0} Z_n' \right)^{-1} Z_n\,,$$

unde $\Gamma^{\chi^T}_{nh}$ este matricea de covarianţă a componentelor comune pentru *lag*-ul de ordin h, iar

Z_n^T grupează vectorii proprii ai matricei alcătuite din blocurile ($\Gamma_{nh}^{\chi T} + \Gamma_{nh}^{\xi T}$, $\Gamma_{nh}^{\xi T}$), unde $\Gamma_{nh}^{\xi T}$ este matricea de covarianţă a şocurilor idiosincratice pentru *lag*-ul de ordin *h*.

Fixând $h = 0$, se obţine versiunea *in-sample* a filtrului SQ, care poate fi utilizat pentru estimarea valorilor contemporane ale componentelor:

$$\hat{\chi}_{i,T} = \sum_{i'=1}^{n} SQ_{n,ii'}^{0} \, x_{j,T} \, . \tag{11}$$

Astfel, componentele comune sunt combinaţii liniare ale factorilor comuni, aceştia din urmă fiind combinaţii liniare ale variabilelor observate. Forma de mai sus permite derivarea contribuţiilor fiecărei variabile (sau a unor grupe de variabile) la obţinerea valorilor estimate/prognozate.

3. Aplicaţie empirică

În această secţiune aplicăm filtrul FHLR SQ pentru a estima dinamica trimestrială a PIB şi a componentelor PIB pentru România. De asemenea, filtrul FHLR SQ este utilizat şi pentru a realiza prognozele de creştere trimestrială pentru perioda următoare. Valorile obţinute sunt denumite NTF (*Near Term Forecasts*) şi sunt obţinute prin estimarea şi prognozarea componentelor comune ale PIB şi ale componentelor PIB. Pentru PIB, în literatura de specialitate, valorile obţinute sunt interpretate ca indicatori *coincident*, respectiv *leading* pentru activitatea economică.

Aplicaţia este dezvoltată în limbajul de programare Matlab. Versiunea de bază a codurilor Matlab de implementare a filtrului este preluată de pe site-ul unuia dintre autori, http://personale.unimore.it/rubrica/dettaglio/forni/ . De asemenea, în aplicaţie se prezintă un exerciţiu de estimare a modelului cu factori comuni în versiunea statică, utilizând o comandă inclusă în limbajul Stata.

3.1. Datele utilizate

Setul de date cuprinde variabile macroeconomice şi financiare cuprinse în baza de date a Băncii Naţionale a României[6]. Seriile sunt disponibile cu frecvenţă zilnică, lunară sau trimestrială. Modelul este implementat pe date cu frecvenţă trimestrială. Seriile cu frecvenţă mai mare sunt transformate prin calcularea mediilor trimestriale (excepţie fac indicii de preţuri pentru care se consideră valoarea *end-of-period*). Pentru ultimul trimestru disponibil, media este calculată inclusiv dacă trimestrul este incomplet (doar prima lună sau primele două luni din trimestru sunt disponibile). Sub ipoteza menţinerii unei dinamici constante a variabilelor pentru restul trimestrului, această operaţiune permite utilizarea unui set informativ mai amplu în exerciţiul de estimare, având un rol similar celui al metodologiilor dezvoltate în modele de tip MIDAS (*mixed-data sampling*) sau *bridge equations* care permit utilizarea unor date cu frecvenţe diferite sau cu valori lipsă (a se vedea Marcellino şi Schumacher (2007) şi Angelini et al., 2008).

[6] Dintre sursele primare ale datelor respective, menţionăm INS, Eurostat, CE DG-ECFIN şi Bloomberg.

Tabelele 1 şi 2 prezintă variabilele utilizate în model. Primul tabel include grupa principală (BASE), formată din PIB şi componentele PIB, unii indici de preţuri şi o serie de variabile ce caracterizează mediul extern. Tabelul 2 cuprinde grupe suplimentare de variabile; acestea fac referire la balanţa de plăţi (inclusiv balanţa comercială) şi la poziţia investiţională, agregatele monetare, mediul financiar, piaţa muncii, cifra de afaceri în diferite sectoare, respectiv indicatorii de încredere. Selecţia variabilelor s-a efectuat în baza unora dintre lucrările enunţate în introducere (cu precădere Banerjee et al., 2005), precum şi a unei analize a coeficienţilor de corelaţie între variabile şi rata de creştere a PIB real. În total sunt 60 de variabile. După prezentarea codului, a denumirii şi a transformării variabilei înainte de introducerea în model, tabelele prezintă coeficientul de corelaţie contemporan între rata de creştere a PIB real cu fiecare variabilă inclusă în specificaţie ($\rho(0)$). De asemenea, în tabele se calculează coeficientul de corelaţie între variabila dependentă şi *lag*-ul variabilei explicative ($\rho(-1)$). Astfel, valori ridicate în cazul coeficientului $\rho(-1)$ pot sublinia caracterul anticipatoriu al unei variabile, acesta putând fi exemplul creşterii economice în zona euro, al agregatelor monetare, al cifrei de afaceri în comerţul auto sau al primei de risc. De asemenea, analiza evidenţiază o serie de variabile al căror coeficient de corelaţie cu rata de creştere a PIB este mic, indiferent de perioada considerată. Aceste serii sunt menţinute în aplicaţie pentru a asigura reprezentativitatea grupei de variabile de apartenenţă.

Modelul pentru PIB include toate variabilele enumerate în Tabelele 1 şi 2, în timp ce pentru estimarea şi prognoza componentelor PIB s-a efectuat o selecţie ulterioară a setului de variabile. Ultimele coloane ale tabelelor prezintă specificaţiile modelului cu factori comuni dinamici pentru fiecare componentă a PIB. Aceste specificaţii au fost stabilite pe baza relevanţei teoretice a variabilei şi a unei analize preliminare privind erorile de estimare în perioadele recente.

Datele primare sunt observate în intervalul 2000 T1 – 2012 T4 (52 de trimestre, *cut-off date* 21.01.2013). Acest interval cuprinde, cu indicaţie aproximativă, creşterea economică modestă din anii 2000-2002, creşterea susţinută din 2003-2007, respectiv perioada de contracţie a economiei, în paralel cu desfăşurarea crizei financiare internaţionale, şi creşterea economică moderată din anii 2011-2012 (cu rate de creştere trimestrială a PIB atât pozitive, cât şi negative). Numărul mare de variabile explicative pentru dinamicile PIB şi ale componentelor sale susţine alegerea modelului cu factori comuni dinamici. Mai mult, disponibilitatea seriilor pe o perioadă relativ scurtă ($n > T$) sprijină metodologia FHLR (relativ la alte metodologii de estimare a factorilor comuni), respectiv a metodei nonparametrice *Bartlett kernel*.

Variabilele sunt, în majoritatea cazurilor, ajustate sezonier (excepţie fac indicii de preţuri şi nivelul şomajului). Ulterior, seriile sunt transformate prin calcularea ratelor de creştere trimestrială[7]; acesta nu este cazul ratelor de dobândă, cotaţiilor OAS (*Option Adjusted Spread*) sau indicatorilor de încredere în economie. Pentru gradul de utilizare a capacităţilor de producţie s-a considerat diferenţa trimestrială. Transformarea variabilelor contribuie la asigurarea proprietăţii de staţionaritate a seriilor cuprinse în model, aceasta fiind una dintre ipotezele de bază ale acestuia. În final, variabilele transformate acoperă intervalul 2000 T2 – 2012 T4 (51 de observaţii).

[7] Seriile disponibile cu frecvenţă lunară sunt ajustate anterior calculării mediei trimestriale.

3.2. Varianta statică a modelului cu factori comuni

Analiza statică a componentelor principale este indicativă pentru capacitatea factorilor de a explica varianţa seriilor observate, având, de asemenea, un rol orientativ în selectarea numărului de factori dinamici. Analiza este efectuată pentru perioada 2005 T2 – 2012 T3, când toate variabilele sunt observate. Conform acestei analize, primii 3 factori explică o proporţie majoritară, de aproximativ 65 la sută din variabilitatea datelor. Cel de-al patrulea factor explică alte 5 procente din variabilitate. Urmărind aceste indicaţii, în aplicaţia empirică estimăm modelul cu factori comuni utilizând $q = 3$ factori, atât în varianta statică, cât şi în cea dinamică. Pentru estimarea în varianta statică, în Tabelul 3 se prezintă, pentru fiecare variabilă, procentul de varianţă explicată de primii 3 factori şi factorul cu cea mai mare contribuţie în explicarea varianţei. Gruparea conform factorului determinant permite o interpretare a factorilor neobservabili. Astfel, prima grupă de variabile caracterizează interacţiunea dintre *output* şi agregatele monetare şi variabilele financiare, a doua grupă caracterizează piaţa muncii, economia reală, mediul extern şi interacţiunea dintre acestea, iar în cea de-a 3-a grupă intră, alături de piaţa muncii, fluxurile de capital. În tabel se disting variabile precum cheltuieli publice sau inflaţia combustibililor, pentru care varianţa explicată este foarte redusă, în timp ce indicatorii de încredere sunt explicaţi aproape în totalitate de factorii comuni.

Tabelul 1: Grupa BASE de variabile, corelaţia acestora cu PIB real şi specificaţiile modelelor pentru componentele PIB

							Specificaţii			
Ind	**Cod**	**Denumire**	**Transf.**	**Obs.**	**ρ(-1)**	**ρ(0)**	**CH**	**GK**	**X**	**M**
1	y	Produsul Intern Brut	qoq, real	00T2-12T4(51)	0,7	1,0	-	-	-	-
Componentele PIB										
2	ch	Consum indiv. ef. g. pop. (CH)	qoq, real	00T2-12T4(51)	0,7	0,7	1	1	1	1
3	cpb	Consum guvernamental	qoq, real	00T2-12T4(51)	0,0	0,0	-	1	1	1
4	gk	FBCF (GK)	qoq, real	00T2-12T4(51)	0,6	0,7	1	1	1	1
5	m	Importuri (M)	qoq, real	00T2-12T4(51)	0,6	0,5	1	1	1	1
6	x	Exporturi (X)	qoq, real	00T2-12T4(51)	0,4	0,3	-	1	1	1
Indici de preţuri										
7	cpi-ua	Indice de preţuri total	qoq	00T2-12T4(51)	0,3	0,2	1	1	1	-
8	comb-ua	Indice de preţuri combustibil	qoq	00T2-12T4(51)	0,2	0,2	1	1	1	1
9	cpiad-ua	Indice de preţuri administrate	qoq	00T2-12T4(43)	0,3	0,3	1	1	-	-
10	flo-ua	Indice de preţuri volatile	qoq	00T2-12T4(43)	0,2	0,1	1	-	-	1
Mediul extern										
11	ea17y	PIB zona euro	qoq, real	00T2-12T4(51)	0,6	0,7	1	1	1	1
12	hicp	IAPC zona euro	qoq	00T2-12T4(51)	0,5	0,5	1	1	1	1
13	euib3	Euribor 3M	nivel, real	00T2-12T4(51)	0,0	0,1	1	1	1	1
14	uscpi	IPC SUA	qoq	00T2-12T4(51)	0,5	0,5	1	-	1	1
15	yindea17	Prod. ind. zona euro	qoq	00T2-12Q4(51)	0,5	0,5	-	1	1	1
16	esi-ea	Ind. încredere zona euro	nivel	00T2-12T4(51)	0,6	0,7	1	1	1	1

Tabelul 2: Grupele suplimentare de variabile, corelaţia acestora cu PIB real şi specificaţiile modelelor pentru componentele PIB

							Specificaţii			
Ind	**Cod**	**Denumire**	**Transf.**	**Obs.**	**ρ(-1)**	**ρ(0)**	**CH**	**GK**	**X**	**M**
BOP, Poz. invest.										
17	rem	Transf. curente din str.	qoq	00T2-12T4 (51)	0,2	0,1	1	1	1	1
18	bcom	Balanţa comercială	qoq	00T2-12T4 (51)	0,3	0,3	-	1	1	1
19	cab2y	Def. cont curent în PIB	nivel	00T4-12T4 (49)	0,0	-0,2	-	1	1	1
20	fdi	Investiţii străine dir. nete	qoq	00T2-12T4 (51)	-0,1	-0,1	1	1	1	1
21	extd	Datoria externă	qoq	05T1-12T3 (31)	0,5	0,4	-	1	1	1
22	xrm	Exporturi materii prime	qoq	00T2-12T3 (50)	0,1	0,2	-	-	1	-
23	xig	Exporturi bunuri interm.	qoq	00T2-12T3 (50)	0,5	0,4	-	-	1	-
24	xk	Exporturi bunuri de cap.	qoq	00T2-12T3 (50)	0,0	0,3	-	-	1	-
25	xc	Exporturi bunuri de cons.	qoq	00T2-12T3 (50)	0,1	0,1	-	-	1	-
26	mrm	Importuri materii prime	qoq	00T2-12T3 (50)	0,4	0,2	-	-	1	1
27	mig	Importuri bunuri interm.	qoq	00T2-12T3 (50)	0,4	0,5	-	1	1	1
28	mk	Importuri bunuri de cap.	qoq	00T2-12T3 (50)	0,5	0,6	-	1	1	1
29	mc	Importuri bunuri de cons.	qoq	00T2-12T3 (50)	0,5	0,6	1	-	-	1
Agregate monetare										
30	cash	Numerar în circulaţie	qoq, real	05T2-12T4 (31)	0,5	0,7	1	1	-	1
31	M1	M1, eop	qoq, real	05T2-12T4 (31)	0,6	0,8	1	1	1	1
32	M3	M3, eop	qoq, real	05T2-12T4 (31)	0,5	0,6	1	1	1	1
33	ds-on	Depozite overnight	qoq, real	05T2-12T4 (31)	0,6	0,7	1	1	-	1
34	cs-cp	Credit' sector privat (stoc)	qoq, real	05T2-12T4 (31)	0,5	0,7	1	1	-	1
Variabile financiare										
35	oas	Options adjusted spread	nivel	01T3-12T4 (46)	-0,6	-0,6	1	1	-	1
36	roboron	ROBOR overnight	nivel	00T2-12T4 (51)	0,2	0,2	1	-	1	1
37	i	Dobânda de ref. BNR	nivel, real	00T2-12T4 (51)	0,2	0.2	1	1	1	1
38	id	Dobândă dep. t. (stoc)	nivel, real	00T2-12T4 (51)	0,1	0,1	1	1	-	1
39	il	Dobândă credite (stoc)	nivel, real	00T2-12T4 (51)	0,2	0,2	1	1	1	1
40	s	Curs EUR/RON	qoq, real	00T2-12T4 (51)	-0,5	-0,3	1	1	1	1
Piaţa muncii										
41	em	Număr salariaţi în ec.	qoq	00T2-12T4 (51)	0,3	0,5	1	1	1	1
42	emi	Număr salariaţi în ind.	qoq	00T2-12T4 (51)	0,4	0,5	1	1	1	1
43	ulc	Costuri unit. f. muncă	qoq, real	00T2-12T4 (51)	0,0	0,1	-	1	1	-
44	ureg	Rata şomajului înreg.	nivel	00T2-12T4 (51)	0,2	0,1	1	1	-	1
45	wn	Salariu net în economie	qoq, real	00T2-12T4 (51)	0,2	0,4	1	1	1	1
46	wni	Salariu net în industrie	qoq, real	00T2-12T4 (51)	0,2	0,3	1	1	1	1
47	wg	Salariu brut în economie	qoq, real	00T2-12T4 (51)	0,2	0,3	1	1	1	1
48	yind	Producţia industrială	qoq, real	00T2-12T4 (51)	0,4	0,4	-	1	1	1
49	lwi	Prod. muncii în ind.	qoq, real	00T2-12T4 (51)	0,1	0,1	-	1	1	1
50	cu	Grad util. capac. prod.	dif q	00T2-12T4 (51)	0,2	0,3	-	1	1	1
Cifra de afaceri										
51	ca-servpop	C.a. în servicii pop.	qoq	00T2-12T4 (51)	0,3	0,3	1	1	-	1
52	caetxauto	C.a. în comerţ ex. auto	qoq	00T2-12T4 (51)	0,5	0,7	1	1	-	1
53	ca-fuels	C.a. în com. cu carb.	qoq	00T2-12T4 (51)	0,4	0,4	1	1	1	1
54	ca-auto	C.a. în com. auto-moto	qoq	00T2-12T4 (51)	0,6	0,6	1	1	1	1
Indicatori de încredere										
55	bs-esi-i	Ind. încr. în economie	nivel	00T2-12T4 (51)	0,6	0,7	1	1	1	-
56	bs-ici	Ind. încr. în industrie	nivel	00T2-12T4 (51)	0,6	0,7	-	1	1	1
57	bs-sci	Ind. încr. în servicii	nivel	02T3-12T4 (42)	0,6	0,7	1	1	1	-
58	bs-csmci	Ind. consumatorilor	nivel	01T3-12T4 (46)	0,4	0,6	1	-	-	1
59	bs-rci	Ind. încr. în comerţ	nivel	00T2-12T4 (51)	0,5	0,7	1	-	-	1
60	bs-cci-bal	Ind. încr. în construcţii	nivel	00T2-12T4 (51)	0,4	0,5	1	1	-	1

Tabelul 3: Varianţa explicată de primii 3 factori statici. Clasificarea este efectuată în funcţie de factorul cu cea mai mare contribuţie.

Variabila	Varianţa explicată	Factorul dominant	Variabila	Varianţa explicată	Factorul dominant
bs-esi-i	0,96	F1	ca-auto	0,69	F1
bs-cci-bal	0,95	F1	M3	0,69	F1
id	0,94	F1	yind	0,68	F2
bs-rci	0,94	F1	mc	0,66	F1
bs-ici	0,93	F1	ulc	0,66	F2
bs-sci	0,93	F1	lwi	0,63	F3
bs-csmci	0,93	F1	x	0,63	F2
emi	0,90	F3	hicp	0,63	F1
oas	0,90	F1	cash	0,62	F1
yindea17	0,88	F2	wg	0,60	F1
ea17y	0,87	F1	mrm	0,60	F2
euib3	0,87	F2	il	0,53	F3
gk	0,87	F1	wni	0,51	F1
m	0,86	F1	wn	0,50	F1
y	0,85	F1	xc	0,50	F2
i	0,85	F2	ca-fuels	0,49	F1
roboron	0,85	F2	uscpi	0,47	F1
cab2y	0,84	F2	xk	0,46	F3
em	0,84	F3	s	0,43	F1
M1	0,83	F1	bcom	0,42	F1
mk	0,82	F1	cu	0,33	F2
ds-on	0,81	F1	comb-ua	0,27	F2
cs-cp	0,80	F1	ca-servpop	0,19	F1
esi-ea	0,79	F1	fdi	0,10	F3
ureg	0,78	F2	xrm	0,10	F1
mig	0,78	F2	cpiad-ua	0,08	F1
xig	0,78	F2	rem	0,04	F1
extd	0,73	F1	cpb	0,02	F2
ch	0,73	F1	cpi-ua	0,02	F3
ca-retxauto	0,69	F1	flo-ua	0,01	F2

3.3. Implementarea modelului cu factori comuni dinamici

Urmând rezultatele estimării modelului în varianta statică, se fixează un număr de q = 3 factori comuni dinamici explicativi. Considerând un număr de $M = 4$ *lag*-uri (corespunzător unui an calendaristic), rezultă următoarea specificare a modelului:

$$y_t = b_1(L^4)f_{1,t} + b_2(L^4)f_{2,t} + b_3(L^4)f_{3,t} + \xi_{y,t}\,.$$

Numărul de frecvenţe (echidistante în intervalul $[0, 2\pi]$) considerate pentru estimarea densităţii spectrale este fixat, de asemenea, ca fiind egal cu 4. Fixarea unui număr de frecvenţe egal cu numărul de perioade se face din considerente de optimizare computaţională.

Exerciţiile de estimare şi prognoză sunt efectuate pe eşantioane de timp „în extindere” (*expanding*

windows). Eşantionul iniţial are $T_0 = 20$ trimestre, iar pentru fiecare exerciţiu succesiv se adaugă un trimestru. Numărul total de exerciţii este 32.

Pentru fiecare eşantion, variabilele sunt standardizate. Ulterior, în cadrul fiecărui exerciţiu, se estimează dinamica PIB pentru ultimul trimestru din eşantion (notat cu T) şi prognoza celui aferent trimestrului următor ($T + 1$) prin aplicarea filtrului SQ (ecuaţia (10)) cu $h = 0$, respectiv $h = 1$. Valorile obţinute sunt interpretate ca indicatori coincident, respectiv *leading*, denumirile alternative fiind de „estimări/prognoze pe termen scurt" (NTF). De exemplu, cu primul eşantion de date (2002 T1 – 2005 T1), se obţin indicatorii *coincident* pentru 2005 T1, respectiv *leading* pentru 2005 T2, în timp ce NTF pentru 2012 T4 şi 2013 T1 sunt obţinute cu eşantionul complet (2002 T1 – 2012 T4).

Standardizarea variabilelor este importantă întrucât NTF este determinat ca sumă dintre media proprie pe termen lung şi deviaţia de la media pe termen lung, unde respectiva deviaţie este calculată ca sumă a contribuţiilor fiecărei grupe de variabile din model. La rândul lor, contribuţiile variabilelor depind de deviaţiile acestora de la propriile medii pe termen lung.

În aplicaţie se utilizează ultimele date disponibile, cu toate revizuirile aduse seriilor până în 2012 T4. Pentru fiecare subinterval (eşantion) se replică cel mai recent calendar de publicare a datelor (corespunzător 2012 T4); astfel, întrucât la momentul *cut-off date* PIB şi componentele PIB sunt disponibile până în trimestrul ($T - 1$), în toate exerciţiile precedente se elimină ultimele valori pentru PIB şi componentele PIB. În mod similar, dacă unele variabile ar fi fost disponibile doar până în trimestrul ($T - 2$), aşa cum este cazul unor indicatori din balanţa de plăţi la începutul trimestrului curent, atunci se elimină ultimele două valori din seriile incluse în exerciţiul de estimare. Această metodă are rolul de replicare cât mai exactă a exerciţiilor anterioare şi contribuie la minimizarea erorilor de observare a seriilor pentru fiecare exerciţiu.

Întrucât factorii comuni pot fi estimaţi doar pe serii complete, valorile lipsă ale unor variabile sunt estimate înainte ca acestea să fie incluse în model. Metoda aleasă pentru estimarea valorilor lipsă este versiunea *in-sample* a filtrului SQ, având un rol similar celui al aplicaţiilor filtrului Kalman (a se vedea, de exemplu, modelul cu factori comuni dinamici MIDAS pentru date incomplete propus de Marcellino şi Schumacher, 2007). Aceeaşi metodă de estimare a valorilor lipsă se aplică şi dacă seria de date este disponibilă începând cu o dată ulterioară primului trimestru al anului 2000 (*backward estimation*): exemple de astfel de serii sunt agregatele monetare sau datoria externă (disponibile din 2005 T1), seria OAS (disponibilă din 2001 T3) sau indicatorul de încredere al consumatorilor (din 2001 T3) etc. Pentru estimarea factorilor, se consideră variabilele complete din eşantion. De asemenea, se impune ca seria să fie disponibilă pentru cel puţin 25 la sută din lungimea totală a eşantionului, în caz contrar aceasta fiind exclusă din modelul de estimare a NTF ale PIB şi ale componentelor PIB.

Construirea unui *fan-chart* prin metoda *bootstrap*

Pentru valorile *coincident* şi *leading* din ultimul exerciţiu (2012 T4), cu eşantionul complet de date, se construieşte un interval de încredere prin metoda *cyclical bootstrap* (a se vedea Davidson şi MacKinnon, 2003 şi Fitzenberger, 1998), metodă special concepută pentru aplicaţiile pe serii de timp.

Paşii pentru obţinerea fiecărei replici *bootstrap* (în total sunt $B = 100$ replici) sunt: (i) calcularea erorilor specifice pentru fiecare indicator (în cazul indicatorului *coincident* se utilizează ca eşantion intervalul 2005 T1 – 2012 T3, iar în cazul indicatorului *leading*, intervalul 2005 T2 – 2012 T3); (ii) extragerea aleatorie a unor blocuri de lungime fixă ($S = 4$) de erori specifice ε_t^b şi concatenarea acestora; (iii) construirea unor pseudoserii de valori observate $y_t^{b\star} = \hat{Y}_t + \varepsilon_t^b$; (iv) estimarea/ prognoza componentei comune înlocuind variabila y cu $y_t^{b\star}$ (doar după 2005 T2).

Erorile de prognoză sunt multiplicate cu un factor de incertitudine asimetric, metodă care permite formalizarea unui set de ipoteze expert:

$$Y_t^{h\star} = \hat{Y}_t + \lambda_1 * \mathbb{1}\{\varepsilon_t^b > 0\}\varepsilon_t^b + \lambda_2 * \mathbb{1}\{\varepsilon_t^b < 0\}\varepsilon_t^b ,$$

unde parametrii λ_1 şi λ_2 controlează magnitudinea erorilor pozitive, respectiv a celor negative. De exemplu, pentru indicatorul coincident, pot fi atribuite valori precum $\lambda_1 = 1/8$, $\lambda_2 = 1/5$, iar pentru indicatorul *leading*, $\lambda_1 = 1/6$, $\lambda_2 = 1/7$; în acest mod, scenariilor negative le poate fi conferită o probabilitate superioară de materializare pentru trimestrul curent, în timp ce pentru trimestrul succesiv, accentul este uşor mai ridicat pe scenariile pozitive.

3.4. Rezultatele exerciţiului de estimare

Explicarea variabilităţii datelor de către factorii comuni dinamici

Precizia de estimare a modelelor cu factori comuni dinamici depinde de gradul de reprezentativitate a variabilelor de către factorii comuni, cu alte cuvinte de capacitatea factorilor de a explica dinamica şi corelaţia dintre variabilele care compun setul de date analizat. Tabelul 4 prezintă, pentru fiecare variabilă de interes (PIB şi componentele PIB), procentul de variabilitate a seriilor din specificaţia respectivă explicată de factorii comuni dinamici pentru fiecare exerciţiu de estimare. De menţionat faptul că acest procent este calculat doar pentru exerciţiile în care sunt utilizate toate variabilele din specificaţia respectivă. Prima observaţie, valabilă pentru toate seturile de variabile, este aceea că gradul de reprezentativitate a variabilelor de către factorii comuni în perioadele recente este semnificativ mai mare decât cel aferent primelor exerciţii de estimare; astfel, pentru specificaţiile aferente modelelor pentru PIB sau consum, procentul de variabilitate explicată de factorii comuni se dublează, până la aproximativ 80 la sută. În cazul celorlalte componente, factorii comuni explică, chiar şi în cele mai recente exerciţii, o proporţie majoritară din variabilitatea datelor. Cea de-a doua observaţie este aceea că, începând cu trimestrele care marchează comprimarea severă a activităţii economice ca urmare a crizei financiare internaţionale (2008 T4, 2009 T1), capacitatea factorilor de explicare a variabilităţii datelor creşte notabil. Această ultimă observaţie poate reflecta creşterea corelaţiei dintre evoluţiile variabilelor în contextul desfăşurării recesiunii economice (*comovement*).

Gruparea NTF şi calcularea termenului rezidual DS+VS

Figurile 2-6 ilustrează NTF ale PIB şi ale componentelor PIB versus creşterile trimestriale efective (linia continuă), precum şi contribuţiile diferitelor grupe de variabile la determinarea NTF. Contribuţiile grupelor de variabile la NTF ilustrate sunt calculate prin derivarea elasticităţilor din

ecuaţia (10) şi însumarea contribuţiilor individuale ale grupelor de variabile explicative la deviaţia de la media pe termen lung a variabilei de interes.

Figura 7 reprezintă descompunerea ratei de creştere a PIB în termeni de contribuţii ale componentelor, respectiv a discrepanţei statistice cumulate cu variaţia stocurilor. Acest din urmă termen este calculat ca rezidual din relaţia în nivel

$$DSVS_t = \hat{Y}_t - \sum_{1}^{5} \hat{C}_t^i,$$

unde $\hat{C}^i$ reprezintă fiecare dintre cele 4 componente prognozate (consum individual efectiv al gospodăriilor populaţiei – CH, formare brută de capital fix – FBCF, exporturi şi importuri), respectiv componenta consum public[8]. Pentru consumul public, ca NTF, pe intervalul 2005 T1 – 2012 T3 s-au considerat creşterile efective, iar pentru 2012 T4 – 2013 T1 s-a considerat media creşterilor trimestriale din perioada 2000 T2 – 2012 T3, egală cu aproximativ 0,5 la sută.

Estimări aferente trimestrelor 2005 T1 – 2012 T3

Spre deosebire de ultimii 2 ani din intervalul analizat, perioada 2007-2010 se distinge printr-o variabilitate ridicată a activităţii economice, interval în care filtrul dinamic atenuează influenţa valorilor extreme. În cazul componentelor PIB, volatilitatea evoluţiilor acestora este mai accentuată, inclusiv în ultimii ani. De exemplu, pe parcursul anului 2012, în timp ce ratele de creştere a PIB au semn alternant şi sunt reduse ca magnitudine, atât FBCF, cât şi importurile manifestă rate de creştere semnificative, de semn pozitiv în primul caz, respectiv negativ în cel de-al doilea.

Până la sfârşitul anului 2008, corecţiile de la media pe termen lung au fost minore (acestea nu sunt ilustrate în grafice). În perioadele următoare, contribuţiile negative din partea variabilelor indică, pentru fiecare trimestru, corecţii negative semnificative din partea majorităţii grupelor de variabile, remarcându-se, pe parcursul anului 2009, cele aferente grupelor BASE, balanţa de plăţi, agregatele monetare şi indicatorii de încredere. În această perioadă de recesiune, scăderea consumului şi a schimburilor comerciale, concomitent cu reducerea volumului creditării s-au observat în paralel cu declinul încrederii consumatorilor şi a altor agenţi economici.

La sfârşitul anului 2009 şi în prima jumătate a anului 2010 apar semnale pozitive din partea pieţei muncii (în acest context, se observă dinamica trimestrială negativă a costului unitar cu forţa de muncă), a cifrei de afaceri (în special la începutul anului 2010) şi a variabilelor din grupa BASE (revigorarea exporturilor, politică monetară acomodativă în zona euro etc.). Corecţia în termeni de deficit de cont curent înregistrată în a doua jumătate a anului 2009 este asociată cu o serie de contribuţii negative la estimarea PIB din partea variabilelor din grupa balanţa de plăţi şi poziţia investiţională. În tot acest interval, contribuţia mediei standardizate (calculată pentru fiecare eşantion în parte) se reduce cu aproximativ 0,3 la sută.

[8] Această categorie se referă strict la consumul colectiv efectiv al administraţiilor publice, în timp ce consumul individual al administraţiilor publice este avut în vedere prin includerea acestei componente în consumul individual efectiv al gospodăriilor populaţiei.

Începând cu sfârşitul anului 2010, se observă semnale de îmbunătăţire pentru grupele de variabile BASE şi piaţa muncii şi industrie (reducerea şomajului înregistrat, creşteri ale producţiei industriale), ceea ce conduce la obţinerea unor NTF ale PIB cu semn pozitiv pe tot parcursul anului 2011. NTF pentru componentele PIB sunt, de asemenea, pozitive pe parcursul anului 2011. Seria de NTF pentru FBCF este inferioară celei efective (atât pe parcursul anului 2011, cât şi al anului 2012), aceste estimări fiind influenţate de evoluţiile dobânzii EURIBOR la 3 luni şi ale cererii externe, la care se adaugă decelerarea producţiei industriale şi creşterea şomajului.

Pentru 2012, valorile estimate ale PIB real sunt uşor pozitive în prima parte a anului, urmând a se atenua în cel de-al doilea semestru, contribuţii determinante în acest sens fiind cele din partea grupului de variabile monetare (evoluţii modeste ale creditării) şi a indicatorilor de încredere. NTF pentru ratele de creştere trimestrială a consumului pe parcursul anului 2012 sunt pozitive, în reducere la sfârşitul anului. La această evoluţie contribuie variabilele din grupa variabilelor monetare, a celor financiare (inclusiv cursul de schimb EUR/RON) şi indicatorii de încredere. Exporturile şi importurile, ale căror creşteri trimestriale sunt estimate a fi în general pozitive, sunt influenţate cu precădere de variabilele financiare (nivelul dobânzilor) şi de cele aferente pieţei muncii şi industriei (şomaj în reducere, producţie industrială în creştere uşoară).

Estimarea şi prognoza aferente exerciţiului 2012 Q4

Pentru ultimul exerciţiu (2012 T4) sunt prezentate atât prognoza dinamicii PIB şi a componentelor PIB pentru trimestrul 2013 T1, cât şi un set de intervale de incertitudine (obţinute prin metodologia *cyclical bootstrap*) pentru valoarea estimată şi cea prognozată ale PIB.

Dinamica PIB este prognozată ca fiind uşor negativă în trimestrul 2012 T4, respectiv uşor pozitivă în 2013 T1. Singura grupă de variabile care contribuie pozitiv este cea a variabilelor financiare, în timp ce grupa BASE, cea a variabilelor monetare şi cea a indicatorilor de încredere au contribuţii negative. În 2013 T1, consumul este prognozat a avea o dinamică uşor accelerată (pe baza unei contribuţii favorabile din partea variabilelor monetare şi a indicatorilor de încredere), FBCF a se diminua (indicatorul de încredere aferent şi cel de productivitate a muncii transmit semnale nefavorabile), iar exporturile şi importurile a manifesta uşoare reduceri pe parcursul trimestrului 2012 T4 şi reveniri în trimestrul 2013 T1, evoluţie determinantă de contribuţiile grupelor BASE şi balanţa de plăţi. Subliniem faptul că unele intervale de incertitudine sunt vizibil asimetrice în jurul NTF, ceea ce indică o probabilitate ridicată de poziţionare a NTF într-o zonă adiacentă: de exemplu, pentru FBCF, intervalul de încredere indică o probabilitate ridicată de creştere în 2012 T4, iar pentru exporturi, o probabilitate ridicată de comprimare pe parcursul trimestrului IV 2012.

În Figura 7 este prezentată o descompunere a NTF al PIB pe contribuţii estimate/prognozate ale componentelor. Se remarcă, pentru perioada 2009-2011, contribuţia estimată negativă a exporturilor nete (în condiţiile unor NTF sistematic mai mari pentru importuri decât cele pentru exporturi). FBCF şi consumul contribuie negativ înainte de anul 2011, semnul NTF fiind apoi preponderent pozitiv. Termenul rezidual (discrepanţă statistică plus variaţia stocurilor) are semn pozitiv până în anul 2011, iar pe parcursul anului 2012 are contribuţii negative. Ca magnitudine, termenul rezidual din NTF este comparabil cu cel observat în istoric; mai exact, contribuţia pe

intervalul 2005 T1 – 2012 T3 are o deviaţie standard egală cu 0,81 din cea calculată pe baza seriilor efective.

Indicatori de acurateţe a modelelor

Pentru a evalua precizia de estimare a modelului efectuăm o comparaţie cu un model *benchmark* AR (2) (similar unor lucrări precum Hindrayanto et al., 2014). Comparativ cu modelul *benchmark*, modelele cu factori comuni înregistrează valori ale RMSE mai mici, mai precis cu valori de aproximativ 0,85*RMSE(AR(2)) – pentru FBCF, consum şi exporturi, de circa 0,55*RMSE (AR(2)) – pentru importuri, iar pentru PIB de aproximativ 0,65*RMSE (AR(2)). Această evaluare reflectă capacitatea modelului cu factori comuni de a fructifica informaţia conţinută în indicatorii corelaţi, în paralel cu desfăşurarea crizei economice şi financiare internaţionale. O direcţie de dezvoltare ulterioară acestei analize presupune evaluarea şi prognoza PIB şi ale componentelor sale prin modele alternative de tip VAR, cu un număr însă redus de variabile explicative, sau prin modele ce implică metode de estimare Bayesiană a factorilor comuni.

Tabelul 4: Variabilitatea explicată de cei 3 factori dinamici pentru fiecare specificaţie a modelului

	Specificaţii				
Trim.	**PIB**	**Consum**	**FBCF**	**Exporturi**	**Importuri**
2006T4	0,35	0,38	0,56	0,54	0,63
2007T1	0,36	0,38	0,64	0,51	0,62
2007T2	0,30	0,34	0,71	0,47	0,63
2007T3	0,28	0,34	0,65	0,51	0,64
2007T4	0,29	0,32	0,62	0,47	0,64
2008T1	0,34	0,35	0,65	0,41	0,64
2008T2	0,34	0,34	0,62	0,42	0,61
2008T3	0,33	0,30	0,59	0,40	0,64
2008T4	0,46	0,36	0,53	0,54	0,71
2009T1	0,78	0,75	0,72	0,66	0,83
2009T2	0,81	0,77	0,81	0,57	0,82
2009T3	0,82	0,75	0,82	0,58	0,83
2009T4	0,82	0,76	0,83	0,57	0,83
2010T1	0,83	0,77	0,83	0,58	0,83
2010T2	0,83	0,77	0,81	0,59	0,83
2010T3	0,84	0,78	0,81	0,60	0,83
2010T4	0,84	0,78	0,82	0,60	0,84
2011T1	0,83	0,78	0,82	0,60	0,84
2011T2	0,83	0,78	0,82	0,61	0,84
2011T3	0,84	0,78	0,81	0,59	0,84
2011T4	0,83	0,78	0,80	0,59	0,84
2012T1	0,83	0,78	0,80	0,59	0,84
2012T2	0,84	0,78	0,79	0,59	0,84
2012T3	0,84	0,78	0,78	0,59	0,84
2012T4	0,84	0,78	0,78	0,59	0,84

Figura 2: NTF PIB real şi contribuţiile grupelor de variabile la deviaţiile acestora de la media pe termen lung a variabilei de interes

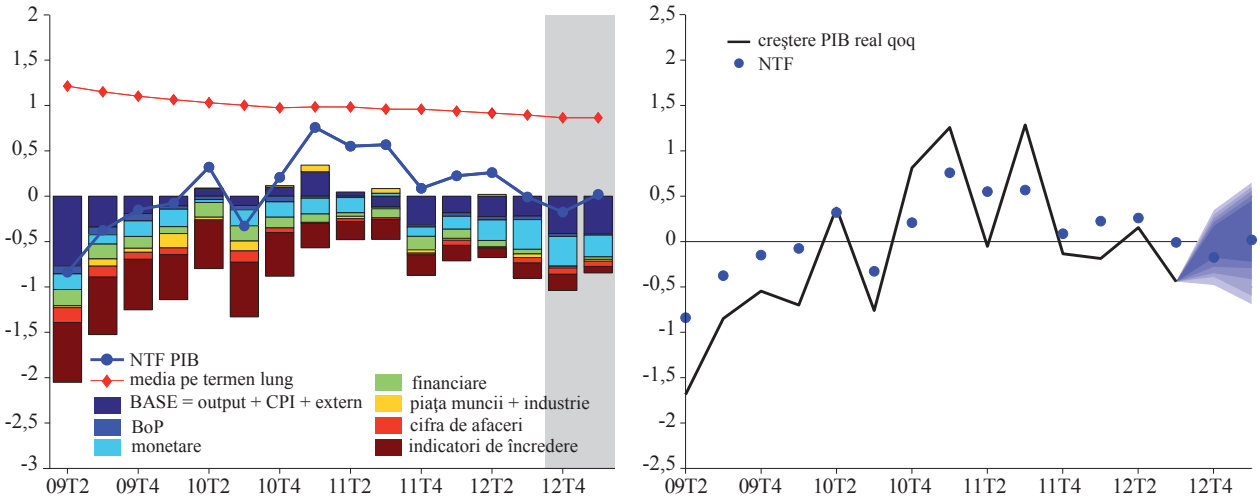


Figura 3: NTF consum individual efectiv al gospodăriilor populaţiei şi contribuţiile grupelor de variabile la deviaţiile acestora de la media pe termen lung a variabilei de interes

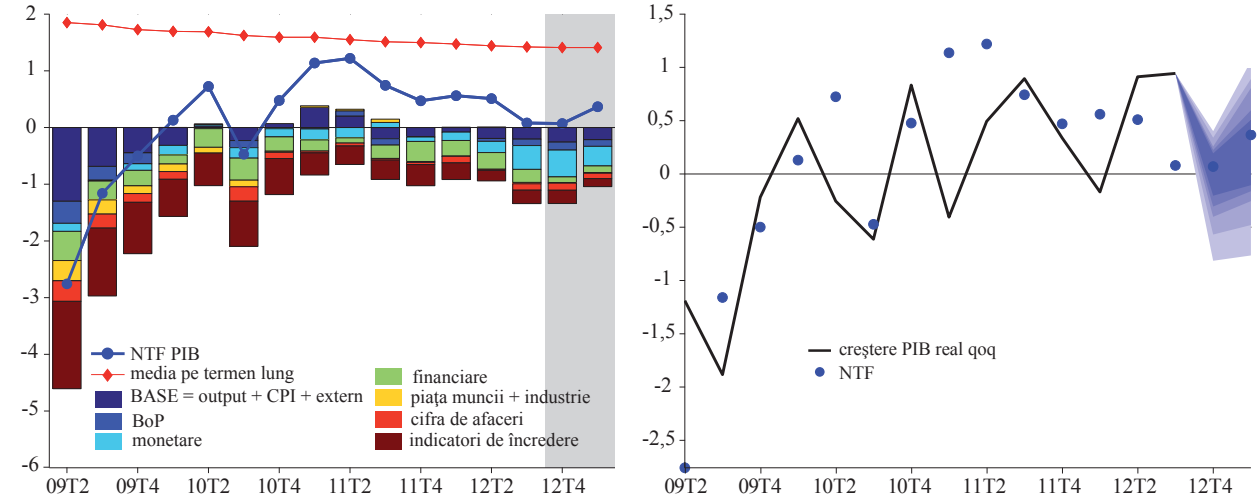


Figura 4: NTF FBCF şi contribuţiile grupelor de variabile la deviaţiile acestora de la media pe termen lung a variabilei de interes

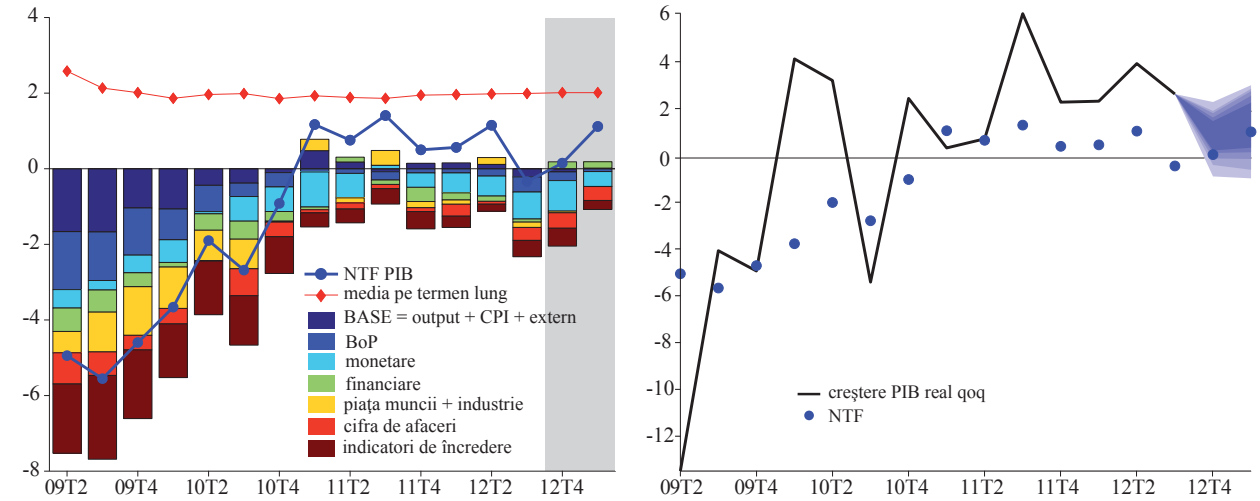


Figura 5: NTF exporturi şi contribuţiile grupelor de variabile la deviaţiile acestora de la media pe termen lung a variabilei de interes

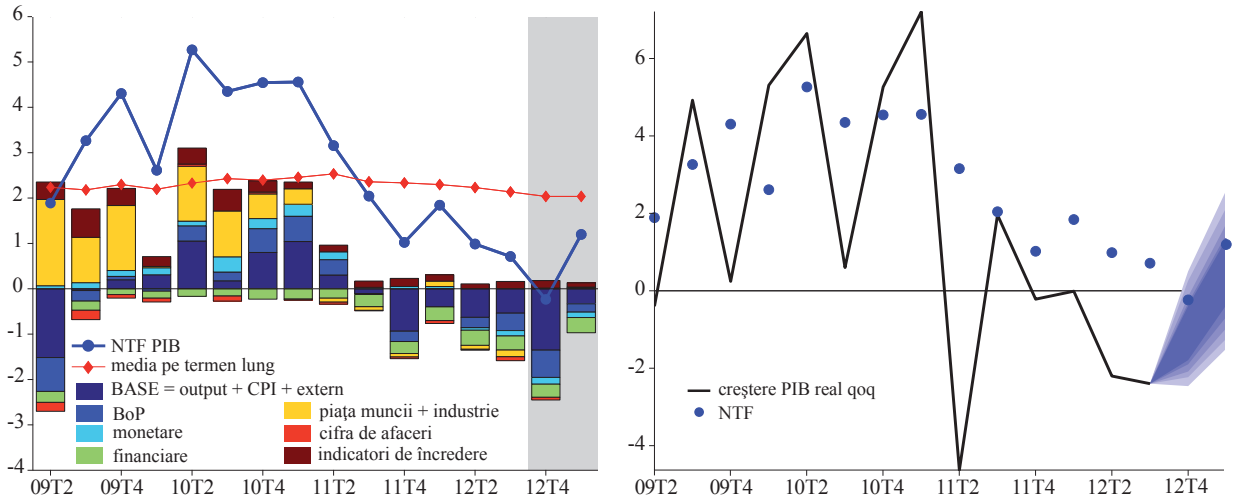


Figura 6: NTF importuri şi contribuţiile grupelor de variabile la deviaţiile acestora de la media pe termen lung a variabilei de interes

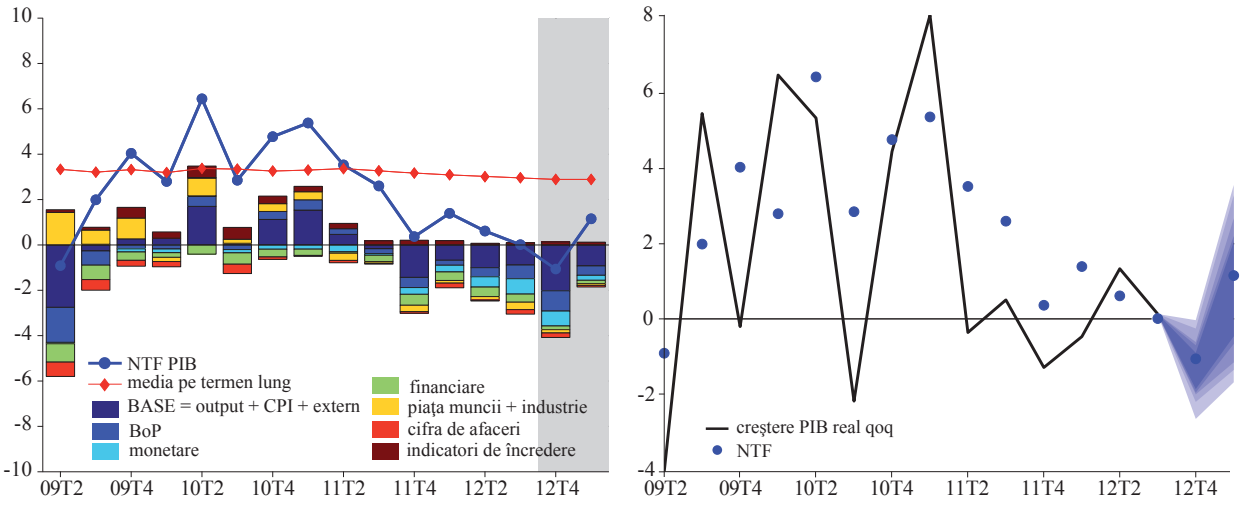
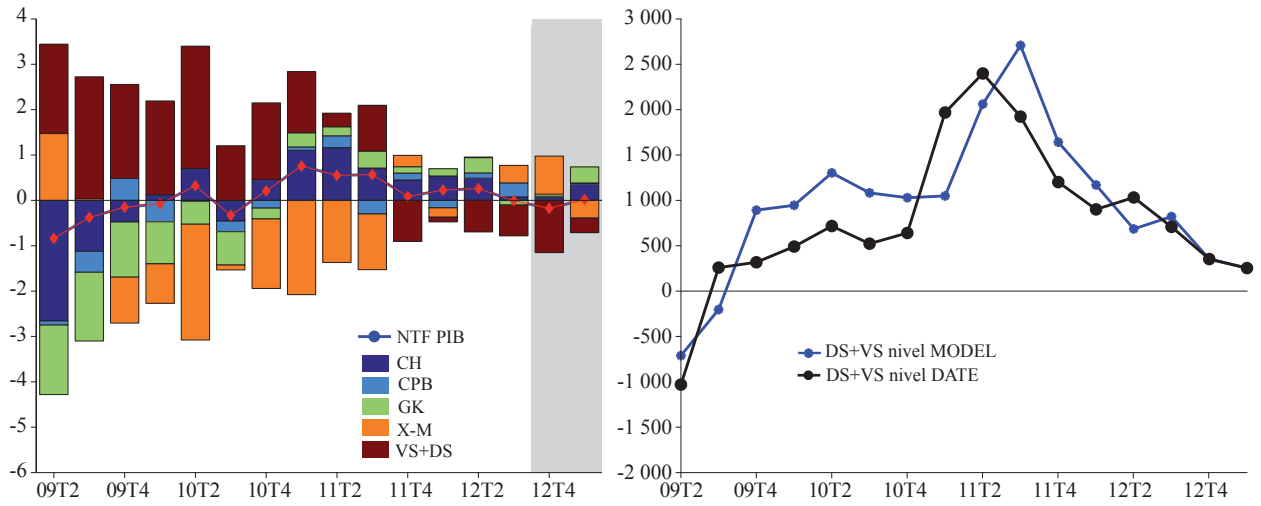


Figura 7: Descompunerea NTF PIB şi termenul (discrepanţa statistică + variaţia stocurilor)



4. Concluzii

Modelul cu factori comuni dinamici este utilizat în acest studiu pentru evaluarea şi prognoza PIB trimestrial şi ale componentelor PIB, aplicaţia empirică fiind construită pe un set numeros de variabile, disponibile cu diferite frecvenţe (serii publicate zilnic, lunar sau trimestrial). Dintre metodele de estimare a factorilor comuni propuse în literatura de specialitate, am preluat metoda autorilor Forni, Hallin, Lippi şi Reichlin (2000 şi 2005), din considerente legate de caracteristicile setului de date analizat: dimensiunea relativ scurtă a seriilor de date comparativ cu numărul de variabile incluse în model, respectiv posibilitatea modelării unor influenţe temporale diferenţiate ale factorilor asupra variabilelor, utile în prezenţa unor indicatori cu putere predictivă.

Rezultatele estimărilor relevă faptul că până în 2008 T3, deviaţiile estimărilor de la mediile pe termen lung au fost reduse. În paralel cu desfăşurarea recesiunii, descompunerea deviaţiilor semnificativ negative de la mediile pe termen lung subliniază importanţa variabilelor din grupele BASE (componente PIB, inflaţie, mediul extern), balanţa de plăţi şi poziţia investiţională, agregatele monetare şi indicatorii de încredere. De asemenea, trebuie subliniată creşterea considerabilă, în acest timp, a capacităţii factorilor de explicare a variabilităţii seriilor de date, valorile estimate înglobând astfel rapid noile informaţii referitoare la activitatea economică.

Bibliografie

Altissimo, F., Cristadoro, R., Forni, M., Lippi, M., Veronese, G. — *New Eurocoin: Tracking Economic Growth in Real Time*, CEPR, Discussion Paper 5633, 2006

Angelini, E., Bańbura, M., Gerhard, R. — *Estimating and Forecasting the Euro Area Monthly National Accounts from a Dynamic Factor Model*, ECB, WP 2008, p.953

Banerjee, A., Marcellino, M. — *Are there any Reliable Leading Indicators for US Inflation and GDP Growth?,* International Journal of Forecasting 22, pp. 137-151, 2006

Banerjee, A., Marcellino, M., Masten, I. — *Leading Indicators for Euro Area Inflation and GDP Growth?,* Research Paper, EABCN, 2005

Breitung, J., Eickmeier, S. — *Dynamic Factor Models*, Deutsche Bundesbank, DP 38, 2005

Barhoumi, K., Benk, S., Cristadoro, R., Reijer, A.D., Jakaitiene, A., Jelonek, P., Rua, A., Rnstler, G., Ruth, K., Nieuwenhuyze, C. — *Short-term Forecasting of GDP using Large Monthly Datasets. A Pseudo-real Time Forecast Evaluation Exercise,* ECB, OP 84, 2008

Davidson, R., MacKinnon, J.G. — *Econometric Theory and Methods*, Oxford University Press: NY, 2003

Engle, R., Watson, M.W. — *A One-Factor Multivariate Time Series Model of Metropolitan Wage Rates*, Journal of the American Statistical Association, 76, pp. 774-781, 1981

Fitzenberger, B. — *The Moving Blocks Bootstrap and Robust Inference for Linear Least Squares and Quantile Regressions*, Journal of Econometrics 82, pp. 235-287, 1998

Forni M., Reichlin L. — *Dynamic Common Factors in Large Cross-sections*, Empirical Economics, 82, pp. 27-42, 1996

Forni M., Hallin M., Lippi M., Reichlin L. — *The Generalized Dynamic-Factor Model: Identification and Estimation*, The Review of Economics and Statistics, 82, pp. 540-554, 2000

Forni M., Hallin M., Lippi M., Reichlin L — *The Generalized Dynamic-Factor Model One Sided Estimation and Forecasting*, Working Paper, 2003, versiune finală publicată în Journal of the American Statistical Association,100, pp. 830-840, 2005

Hamilton, J.D. — *Time Series Analysi*s, Princeton University Press: New Jersey, 1994

Harvey, A.C. — *Sepctral Analysis in Economic*s, The Statistician, 24, pp.1-36, 1975

Hindrayanto, I., Koopman, S.J., de Winter, J. — *Nowcasting and Forecasting Economic Growth in the Euro Area Using Principal Components*, DNB, Working Paper 415, 2014

Jakaitiene, A., Dées, S. — *Forecasting the World Economy in the Short Term,* ECB, WP 1059, 2009

Marcellino, M., Schumacher, C. — *Factor-MIDAS for Now- and Forecasting with Ragged-Edged Data: A Model Comparison for German GDP*, ECB, Discussion Paper 34, 2007

Peracchi, F. — *Econometrics*, Wiley: Chichester (UK), 2001

Quah, D., Sargent,T.J. — *A Dynamic Index Model for Large Cross Sections*, Business Cycles, Indicators and Forecasting, 1993

Sargent, T.J., Sims, C.A. — *Business Cycle Modeling without Pretending to Have Too Much a Priori Economic Theory*, Federal Reserve Bank of Minneapolis, Working Paper series, 1977

Schumacher, C., Breitung, J. — *Real-Time Forecasting of GDP Based on a Large Factor Model with Monthly and Quarterly Data*, Deutsche Bundesbank, Discussion Paper 33, 2006

Stock, J.H., Watson, M.W. — *Macroeconomic Forecasting Using Diffusion Indexes*, Journal of Business and Economic Statistics, 50, 2002

Forecasting Using Principal Components from a Large Number of Predictors, Journal of the American Statistical Association, 97, pp. 1167-1179, 2002

Tsay, R.S. — *Analysis of Financial Time Series*, Wiley: New Jersey, 2005.

