
Utilizarea modelelor macroeconomice în analiza PIB

Prof. univ. dr. Constantin ANGHELACHE (*actincon@yahoo.com*)

Academia de Studii Economice din București / Universitatea „Artifex” din București

Prof. univ. dr. Radu Titus MARINESCU (*radu_titus_marinescu@yahoo.com*)

Universitatea „Artifex” din București

Drd. Doina AVRAM (*doina.avram@gmail.com*)

Academia de Studii Economice din București

Ec. Ștefan Gabriel DUMBRAVĂ (*stefan.dumbrava@gmail.com*)

Abstract

În prezentarea și analiza acestui aspect, autorii au avut în vedere o serie de aspecte care au relevanță în cadrul analizelor macroeconomice. Cercetătorii, analiști, exprimă fără nici o rezervă faptul că o creștere sustenabilă a economiei naționale se realizează de principiu, prin creșterea investițiilor. În mod cert, aceasta se realizează prin aceea că noi investiții înseamnă noi societăți sau dezvoltarea societăților existente, apariția unor noi locuri de muncă, angajarea de noi salariați prin absorbție din populația neocupată sau prin absorbție de persoane aflate în șomaj, sporirea bazei de impozitare a salariilor care conduce la sporirea veniturilor la bugetul de stat consolidat, îmbunătățirea managementului, îmbunătățirea condițiilor de viață și multe altele. Acesta este un studiu pozitivist, realist, dar care nu ține seama de relațiile care trebuie să existe sau care există la un moment dat. De aceea, autorii și-au propus să evidențieze unele modele macroeconomice care se pot utiliza în analiza produsului intern brut precum și în analiza evoluției structurale a produsului intern brut. O prezentare teoretică este efectuată în sensul de a pune în evidență existența și perspectiva utilizării acestor modele economice făcându-se o trecere în revistă asupra aspectelor pe care le ridică utilizarea modelelor economice. În acest sens, se fac precizări privind modelul de regresie liniară simplă sau multiplă și se subliniază ipotezele pe care le ridică un model de regresie dar, în final se concluzionează că parametrii de regresie sunt cei care au semnificație statistică și dau consistență ipotezelor care se ridică pe seama acestora.

Cuvinte cheie: *model macroeconomic, PIB, model de regresie, analiză dinamică, indicatori statistici*

Clasificarea JEL: C50, C61, E01

Introducere

În studiul efectuat, autorii s-au concentrat pe unele aspecte care sunt semnificative din punct de vedere al analizei structurale a produsului intern brut. Se fac referiri concrete teoretice la modelele macroeconomice utilizabile, se prezintă apoi aspecte în legătură cu modelul de regresie liniară simplă și liniară multiplă, explică ipotezele care trebuie îndeplinite și în termeni generali se subliniază că parametrii de regresie cu semnificație statistică după testare sunt elemente consistente care pot conduce la o analiză și o interpretare judicioasă a situației economice supuse acestui tip de analiză. Referirile și modul în care sunt explicitate aspectele teoretice pe care le presupune utilizarea modelelor macroeconomice de analiză structurală a produsului intern brut considerăm că sunt suficiente și pe deplin edificatoare pentru cei care doresc să utilizeze aceste modele supuse ochiului avizat al cercetătorilor de către autori.

Literature review

Anghelache and Anghel (2017) au realizat un studiu al evoluției PIB din România pe baza datelor deflate. Anghelache, Partachi, Sacală and Ursache (2016) au analizat corelația dintre PIB și investiții străine directe. Anghelache et al (2007) au prezentat aspectele fundamentale ale analizei macroeconomice. Anghelache and Anghel (2016) au prezentat instrumentarul statistic utilizat în analizele economice. Anghelache (2013) a evidențiat modelele econometrice utilizate în analizele economice. Bardsen, Nymagen and Jansen (2005) au studiat utilizarea modelelor econometrice în modelarea macroeconomică. Dobrodolac (2011) au abordat aspecte ale importanței previziunii în procesul de luare a deciziilor. Guner, Ventura and Yi (2008) au studiat efectele macroeconomice ale politicilor adoptate. Koulakiotis, Lyroudi and Papasyriopoulos (2012) au analizat corelația dintre inflație și produsul intern brut în unele țări europene. Lucas (2003) a abordat o serie de aspecte referitoare la prioritățile macroeconomice. Lucas and Moll (2014) a studiat aspecte privind creșterea economică. Woodford (2010) a analizat rolul intermedierei financiare în analizele macroeconomice.

Metodologie, date, rezultate și discuții

Pentru a analiza impactul investițiilor străine directe asupra creșterii economice din România, am utilizat o serie de modele macroeconomice complexe.

În cercetarea efectuată, am folosit modele specifice activității de prognoză a evoluției unui sistem economic, modelul de regresie liniară simplă și multiplă.

Cu ajutorul acestor modele este posibilă determinarea valorii unor coeficienți în funcție de valorile înregistrate de alți indicatori macroeconomici considerați ca variabile în funcție de evoluția factorului timp.

În această analiză economică este necesar să se stabilească relația existentă între două sau mai multe variabile, utilizând în acest sens două tehnici specifice statisticii și anume:

- corelația - arată cât de puternică este legătura dintre variabilele analizate;
- regresia - explică și permite previzionarea valorii unuia dintre factori pe seama celui / celorlalți.

Astfel, obținem un factor (variabilă) care este factor determinant, cuprinzând celelalte influențe în variabila reziduu.

Modelul de regresie liniară simplu poate fi transcris, ca funcție matematică sub forma:

$$Y = f(x) + \varepsilon \quad (1)$$

În cadrul acestui model interdependența dintre y și x se poate scrie prin funcția:

$$y_i = b + a \cdot x_i + \varepsilon_i \quad (2)$$

în care:

y_i – variabila rezultativă;

x_i – variabila factorială;

ε_i – variabila reziduu.

În alegerea modelului de regresie liniară simplă se va ține seama de ipotezele econometrice corespunzătoare. Ipotezele modelului de regresie:

I1: seriile de date nu sunt afectate de erori de măsură;

I2: variabila reziduală are media zero;

I3: dispersia variabilei reziduale este invariantă în timp, adică are proprietatea de homoscedasticitate;

I4: reziduurile nu sunt autocorelate;

I5: variabila factorială (explicativă) nu este corelată cu variabila reziduală;

I6: erorile modelului sunt normal repartizate după o repartiție de medie zero și dispersie σ^2 .

• Unele aspecte privind funcția de regresie liniară

În modelarea statistică, analiza de regresie este un proces statistic pentru estimarea relațiilor dintre variabile care include mai multe tehnici pentru modelarea și analiza variabilelor, atunci când se pune accent pe corelația dintre două variabile. Analiza de regresie exprimă modul în care «variabila criteriu» se modifică în cazul în care variabila (x) prezintă o variație, în timp

ce celelalte variabile independente rămânând nemodificate. Cel mai frecvent, analiza de regresie estimează speranța condiționată a variabilei dependente când valoarea variabilelor independente este data - adică, valoarea medie a variabilei dependente atunci când variabilele independente sunt fixe.

Noțiunile și modelele prezentate în cadrul acestui capitol final au luat în considerare cercetările și aspectele teoretice și practice ale unor autori importanți din literatura de specialitate. În acest fel, modelarea econometrică este dezvoltată de Bardsen și alții (2005), dar și de alți autori. Granger și Haldrup (în 1997) dezvoltă elementele teoretice referitoare la sistemele cointegrate, cu rezultate extinse în lucrările publicate în continuarea acestora.

Cea mai timpurie formă de regresie a fost metoda celor mai mici pătrate, care a fost publicată de Legendre în anul 1805 și de Gauss în 1809.

Atât Legendre cât și Gauss, au aplicat această metodă pentru determinarea, din observațiile astronomice, a orbitelor corpurilor în jurul Soarelui (mai ales comete, dar de asemenea, mai târziu, planetele mai mici nou descoperite). Gauss a publicat o dezvoltare în continuare a teoriei celor mai mici pătrate în 1821, inclusiv o versiune a teoremei Gauss-Markov.

Termenul „regresie” a fost inventat de Francis Galton în secolul al XIX-lea pentru a descrie un fenomen biologic. Fenomenul studiat lua în analiză faptul că înălțimea descendenților populației înalte tinde să regreseze în jos spre o medie normală (un fenomen, de asemenea, cunoscut sub numele de regresie către medie). Pentru Galton, acest studiu al regresiei a avut numai această semnificație biologică, însă lucrarea lui a fost ulterior extinsă de către Udny Yule și Karl Pearson într-un context statistic mai amplu. În lucrarea lui Yule și Pearson, distribuția în comun a variabilelor de răspuns și explicative se presupune a fi de tip Gaussian. Această presupunere a fost slăbită de R. A. Fisher în lucrările sale din 1922 și 1925. Fisher a presupus că distribuția condiționată a variabilei de răspuns este de tip Gaussian, dar distribuția în comun nu trebuie să îndeplinească aceeași condiție. În acest sens, ipoteza Fisher este mai aproape de formularea din 1821 a lui Gauss.

Analiza de regresie este de asemenea de interes pentru a caracteriza variația variabilei dependente în jurul funcției de regresie care poate fi descrisă printr-o distribuție de probabilitate.

Analiza de regresie este utilizată pe scară largă pentru predicție și prognoză și de asemenea pentru a înțelege care dintre variabilele independente sunt legate de variabila dependentă, și de a explora formele acestor relații. În circumstanțe restrânse, analiza de regresie poate fi utilizată pentru a deduce relații cauzale între variabilele dependente și independente. Totuși, acest lucru poate duce la iluzii sau relații false, deci se recomandă prudență (de exemplu, corelația nu implică cauzalitate).

Au fost dezvoltate multe tehnici pentru efectuarea analizei de regresie; cele mai utilizate metode (regresie liniară și metoda celor mai mici pătrate) sunt metode parametrice, prin aceea că funcția de regresie este definită în termenii unui număr finit de parametri necunoscuți, care sunt estimați prin intermediul datelor. Regresiile neparametrice se referă la tehnici care permit funcției de regresie să se întindă într-un anumit set de funcții, care pot fi infinite-dimensionale.

Performanța metodelor de analiză de regresie în practică depinde de forma procesului generării datelor, respectiv de metoda de regresie utilizată. Deoarece adevărata formă a procesului de generare a datelor nu se cunoaște în general, analiza de regresie depinde adesea într-o oarecare măsură de a face presupuneri cu privire la acest proces. Aceste ipoteze pot fi uneori testate în cazul în care există o cantitate suficientă de date disponibile.

Modelele de regresie pentru predicție sunt adesea utile chiar și atunci când ipotezele sunt încălcate moderat, în sensul că acestea nu pot fi îndeplinite întotdeauna în mod optim. Cu toate acestea în multe aplicații, în special în cazul celor care fac referire la gradul de cauzalitate pe baza datelor de observație, metodele de regresie pot da rezultate înșelătoare.

Într-un sens mai restrâns analiza de regresie se poate referi în mod special la estimarea variabilelor de răspuns continue, spre deosebire de variabilele de răspuns discrete utilizate în clasificare (clasificarea este problema identificării cărui set de categorii (sub-populații) îi aparține o nouă observație, pe baza unui set de formare de date care conțin observații, a căror apartenență la o anumită categorie este cunoscută).

Metodele de regresie continuă să fie un domeniu de cercetare activă, în ultimele decenii dezvoltându-se noi metode de regresie robuste, regresii care implică răspunsuri corelate, cum ar fi curbele seriilor cronologice și de creștere, regresii în care predictorul (variabila independentă) sau variabilele de răspuns sunt curbe, imagini, grafice sau alte obiecte complexe de date, metode de regresie care presupun estimarea diferitelor tipuri de date lipsă, regresii neparametrice, metodele bayesiene de regresie, regresii în care variabilele predictor sunt măsurate cu eroare, regresii cu mai multe variabile predictor decât observațiile și inferență cauzală cu regresie.

- Modelele de regresie liniară implică următoarele variabile:
 - parametrii necunoscuți, notati cu β , cu valoarea scalară sau vectorială
 - variabilele independente, X .
 - variabila dependentă, Y .
 - toti ceilalți factori, care au acțiune întâmplătoare sau constantă asupra variabilei endogene, exprimați prin variabila reziduală ϵ .

În diverse domenii de aplicare sunt utilizate diferite terminologii în locul variabilelor dependente și independente.

Un model de regresie presupune raportarea variabilei dependente Y la o funcție de X (variabila independentă) și β (termenul liber).

$$Y \approx f(X, \beta) \quad (3)$$

Aproximarea este de obicei formalizată sub forma $E(Y|X) = f(X, \beta)$. Pentru a efectua o analiză de regresie trebuie specificată forma funcției f . Uneori, forma acestei funcții se bazează pe cunoștințe despre relația dintre Y și X ; în cazul în care nici o astfel de informație nu este disponibilă, alegem o formă flexibilă și convenabilă pentru funcția f .

Să presupunem acum că vectorul parametrilor necunoscut β este de lungime k . Pentru a putea efectua o analiză de regresie utilizatorul trebuie să furnizeze informații despre variabila dependentă Y :

- în cazul în care se observă punctele N date ale formei (Y, X) , unde $N < k$, cele mai multe abordări clasice ale analizei de regresie nu se pot realiza: deoarece sistemul de ecuații care definesc modelul de regresie este nedeterminat, nu există suficiente date pentru a-l determina pe β .

- dacă se observă exact $N = k$ puncte de date, iar funcția f este liniară, ecuațiile de tipul $Y = f(X, \beta)$ pot fi rezolvate concret. Acest lucru se reduce la rezolvarea unui set de N ecuații cu N necunoscute (elementele β), care are o soluție unică atâta timp cât X sunt liniar independente.

- cea mai comună situație este în cazul în care se observă $N > k$ puncte de date. În acest caz, există suficiente informații astfel încât să fie posibilă estimarea unei valori unice pentru β , iar modelul de regresie atunci când este aplicat poate fi privit ca un sistem în β supradeterminat.

În ultimul caz, analiza de regresie oferă instrumente pentru:

- găsirea unei soluții pentru parametrii necunoscuți β pentru a minimiza distanța dintre valorile măsurate și cele previzionate ale variabilei dependente Y (de asemenea cunoscută ca metoda celor mai mici pătrate).

- în anumite ipoteze statistice, analiza de regresie utilizează surplusul de informații pentru a furniza informații statistice cu privire la parametrii necunoscuți β și pentru a previziona valori ale variabilei dependente Y .

Când numărul de măsurători N , este mai mare decât numărul de parametri necunoscuți, k , și erorile de măsurare ei sunt distribuite normal, atunci excesul de informații conținute în $(N - k)$ măsurători este folosit pentru a face predicții statistice despre parametrii necunoscuți. Acest exces de informație este exprimat ca gradele de libertate ale regresiei.

• Ipotezele modelului liniar de regresie

Orice model de regresie se bazează pe o serie de ipoteze. În acest sens amintim:

- eșantionul este reprezentativ pentru populația pentru care se folosește inferența statistică.
- eroarea este o variabilă aleatoare cu o medie de zero, condiționată de variabilele explicative.
- variabilele independente sunt măsurate fără nici o eroare.
- variabilele independente (predictorii) sunt liniar independente, în sensul că orice predictor nu poate fi exprimat ca o combinație liniară a celorlalte variabile.
- erorile sunt necorelate, ceea ce înseamnă că matricea varianță-covarianță a erorilor este diagonală și fiecare element diferit de zero reprezintă variația erorii.
- varianța erorilor este constantă în observații (homoscedasticitate).

Acestea sunt condiții suficiente pentru estimarea parametrilor prin metoda celor mai mici pătrate; în mod particular, aceste ipoteze implică faptul că estimările parametrilor vor fi imparțiale, coerente și eficiente în clasa estimatorilor imparțiali liniari. Este important de remarcat faptul că datele reale satisfac rareori ipotezele, dar și în aceste situații metoda este utilizată chiar dacă ipotezele nu sunt adevărate. Rapoartele analizelor statistice includ de obicei analize ale testelor privind datele eșantionului și metodologia pentru alegerea adecvată și utilitatea modelului.

În regresia liniară, specificația modelului este aceea că variabila dependentă y_i este o combinație liniară a parametrilor (dar nu trebuie să fie liniară în variabilele independente). De exemplu, în regresie liniară simplă pentru modelarea a n puncte de date există o variabilă independentă: x_i și doi parametri, β_0 și β_1 :

$$\text{Ecuația dreptei de regresie: } y_i = a + bx_i + \varepsilon_i, i = 1, \dots, n. \quad (4)$$

În regresia liniară multiplă, considerăm cel puțin două variabile factoriale, respectiv funcții de variabile independente.

Adăugarea unui termen X_i^2 la regresia precedentă conduce la parabola:

$$y_i = a_0 + b_1x_1 + b_2x_2 + \varepsilon_i, i = 1, \dots, n. \quad (5)$$

Aceasta este de asemenea o regresie liniară; deși expresia de pe partea dreaptă este pătratică în x_i variabila independentă X_i , este liniară în parametrii a_0 , b_1 și b_2 . În ambele cazuri, ε_i este un termen de eroare, iar indicele i este atribuit fiecărei observații particulare. Întorcându-ne atenția asupra modelului liniar de regresie, având în vedere un eșantion aleatoriu din populație, estimăm parametrii populației și obținem modelul de regresie liniară:

$$\hat{Y}_i = \beta_0 + \beta_1 X_i \quad (6)$$

Valoarea reziduală, $e_i = Y_i - \hat{Y}_i$ este diferența dintre valoarea variabilei dependente previzionate de model $\hat{Y}_i$, și valoarea reală a variabilei dependente, Y_i . O metodă de estimare este metoda celor mai mici pătrate. Această metodă obține estimări ale parametrilor care minimizează suma pătratelor reziduurilor, SSE:

$$SSE = \sum_{i=1}^n e_i^2 \quad (7)$$

Reducerea la minimum a acestei ecuații are ca rezultat un set de ecuații normale, un set de ecuații simultane liniare în funcție de parametri, care sunt rezolvate pentru determinarea estimatorilor parametrilor β_0 și β_1 .

$$\beta_1 = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sum (x_i - \bar{x})^2} \quad (8)$$

În ipoteza în care termenul de eroare a populației are o variație constantă, estimarea acestei varianțe este dată de:

$$\sigma^2_\varepsilon = \frac{SSE}{n-2} \quad (9)$$

eroarea medie pătratică (MSE) a regresiei.

Numitorul este mărimea eșantionului redus cu numărul parametrilor modelului estimat la aceleași date, $(n-p)$ pentru regresorii p sau valoarea $(n-p-1)$ în cazul în care este utilizat termenul intercept; în acest caz $p = 1$, astfel încât numitorul este $(n-2)$.

• Parametrii de regresie și semnificația lor statistică

Odată ce modelul de regresie a fost construit, este importantă confirmarea potrivirii modelului și semnificația statistică a parametrilor estimați. Verificările utilizate în mod obișnuit includ modelele de testare a ipotezelor și a valorilor reziduale. Semnificație statistică poate fi verificată printr-un test F ca testare generală, urmat de testele-t pentru parametrii individuali.

Interpretări ale acestor teste de diagnostic se bazează în mod deosebit pe ipotezele modelului. Deși examinarea reziduurilor poate fi folosită pentru a invalida un model, rezultatele unui test t sau test F sunt uneori mai dificil de interpretat dacă ipotezele modelului sunt încălcate.

De exemplu, în cazul în care termenul de eroare nu are o distribuție normală, în cazul unei analize bazate pe un număr redus de parametri, acestia nu vor urmări distribuții normale și complică inferență. Cu toate acestea, în cazul utilizării eșantioanelor relativ mari se poate folosi teorema limită centrală, astfel încât testarea ipotezelor poate continua folosind aproximări asimptotice. Variabila de răspuns poate fi non-continuu („limitată” să acopere un subset de date ale regresiei liniare). Pentru variabilele binare, în cazul în

care se aplică analiza celor mai mici pătrate de regresie liniară, modelul este numit model de probabilitate liniar.

Modelele de regresie prezic o valoare a variabilei Y date fiind valorile cunoscute ale variabilelor X. Predicția în intervalul de valori în setul de date utilizat pentru modelul utilizat este cunoscut în mod informal sub denumirea de interpolare. Previziunea în afara acestui interval de date este cunoscut sub numele de extrapolare, care se bazează puternic pe ipotezele modelului de regresie.

Cu cât extrapolarea valorilor are loc în afara datelor existente, cu atât există șanse mari pentru ca modelul să eșueze din cauza diferențelor între ipoteze și datele din esantion sau valorile reale.

Se recomandă în general ca atunci când se efectuează o extrapolare, valoarea estimată a variabilei dependente să fie însoțită de un interval de predicție care reprezintă incertitudinea. Astfel de intervale de timp tind să se extindă rapid, cu cât valorile variabilei independente sunt deplasate în afara domeniului acoperit de datele observate.

Cu toate acestea, acest lucru nu acoperă complet erorile de modelare care pot apărea: în special, ipoteza unui forme particulare pentru relația dintre Y și X. O analiză de regresie efectuată în mod corect va include o evaluare a modului în care este compensată forma propusă ca model de datele observate, însă acest lucru este posibil doar în intervalul de valori disponibile ale variabilelor independente. Aceasta înseamnă că orice extrapolare este în mod particular relevantă dacă se bazează pe ipotezele făcute cu privire la forma structurală a relației de regresie. Cele mai bune practici recomandă ca alegerea unui model liniar în variabile sau liniar în parametri nu trebuie ales convențional, ci să se ia în considerare și să se exploateze toate cunoștințele disponibile pentru implementarea unui model de regresie. Implicațiile acestui pas de a alege o formă funcțională adecvată pentru regresie pot fi mari atunci când se ia decizia de extrapolare. La un nivel minim, se poate asigura că orice extrapolare rezultată dintr-un model potrivit este „realistă”.

Concluzii

Din studiul efectuat de autori se desprind concluzii teoretice importante în sensul că, o analiză pertinentă macroeconomică pe baza indicatorilor macroeconomici de rezultate a agregatelor dar și a evoluției factoriale a indicatorilor globali este posibilă prin utilizarea unor modele macroeconomice sau mai simplificat spus a unor modele statistico-econometrice utilizate la nivel macroeconomic. Aceste modele utilizate, prin luarea în considerare a unor serii de date suficient de lungi, a unor indicatori care sunt deflatați și aduși la nivelul prețurilor comparabile dau măriri

concrete, pe baza cărora se pot interpreta datele respective. De asemenea, pe baza acestor modele macroeconomice se pot efectua previziuni (prognoze), utilizând parametrii de regresie rezultați dintr-un studiu pe bază de date anterior obținute, extrapolate în timp pe perioada care face obiectul cercetării de previziune. O ultimă concluzie este aceea că studiul este mai larg făcând doar unele concretizări și aceasta conduce la faptul că se poate extinde și utiliza în oricare altă perspectivă în care variabilele supuse analizei cu ajutorul acestor modele macroeconomice trebuie mai întâi studiate, interpretate logic pentru a identifica perspectiva posibilității existenței unei corelații între acestea.

Bibliografie

1. Anghelache, C. and Anghel, M.G. (2017). Analysis of the evolution of the Gross Domestic Product of Romania using deflated data, *International Conference „Economic Experiences”*, The Romanian Foundation for Business Intelligence, Transilvania University of Braşov, The Romanian Academy, Braşov, 145-153
2. Anghelache, C., Partachi, I., Sacală, C. and Ursache, A. (2016). Using econometric models in the correlation between the evolution of the Gross Domestic Product and Foreign Direct Investments. *Romanian Statistical Review, Supplement*, 10, 124-129
3. Anghelache, C. (2013). *Elemente de econometrie teoretică*, Editura Artifex, Bucureşti
4. Anghelache, C. şi colaboratorii (2007). *Analiza macroeconomică: Sinteze şi studii de caz*, Editura Economică, Bucureşti
5. Anghelache, C. and Anghel, M.G. (2016). *Bazele statisticii economice. Concepte teoretice şi studii de caz*, Editura Economică, Bucureşti
6. Bardsen, G., Nymagen, R. and Jansen, E. (2005). *The Econometrics of Macroeconomic Modelling*, Oxford University Press
7. Dobrodolac, T. (2011). Forecasting by econometric models as support to management. *Perspectives of Innovations, Economics & Business*, 7 (1), 72-76
8. Guner, N., Ventura, G. and Yi, X. (2008). Macroeconomic Implications of Size-Dependent Policies. *Review of Economic Dynamics*, 11 (4), 721-744
9. Koulakiotis, A., Lyrouti, K. and Papasyriopoulos, N. (2012). Inflation, GDP and Causality for European Countries. *International Advances in Economic Research*, 18 (1), 53-62
10. Lucas, R.E. Jr. (2003). Macroeconomic Priorities. *American Economic Review*, 93 (1), 1-14
11. Lucas, R.E. and Moll, B. (2014). Knowledge Growth and the Allocation of Time, *Journal of Political Economy*, 122 (1), 1-51
12. Woodford, M. (2010). Financial Intermediation and Macroeconomic Analysis. *Journal of Economic Perspectives*, 24 (4), 21-44