

Prognoza seriilor cronologice cu metode tradiționale, econometrice și modificările lor

Pentru a analiza diverse procese economice, este nevoie de date statistice ce caracterizează procesele studiate și se desfășoară în timp sub formă de serii. Deseori, unele și aceleași serii se utilizează la soluționarea problemelor, diferite după conținut.

Una din problemele fundamentale ale politicii macroeconomice, inclusiv studierea parametrilor de bază, este construirea de modele ce ne oferă posibilitatea efectuării prognozei indicatorilor macroeconomici.

Prognoza macroeconomică este un instrument important în dirijarea și monitorizarea politicii economice.

În majoritatea cazurilor, prognozele economice acoperă o perioadă scurtă de timp. Prognozele exacte, pe o perioadă îndelungată de timp, se întâlnesc foarte rar. Doar o mică gamă de prognoze se poate identifica după intercalarea sursei, scopului, ipotezelor, datelor, modelelor și metodele utilizate, deși e greu de găsit o rețetă a prognozelor de tipul dat. Mai ales pentru că puțini analiști lasă modelele și metodele lor neschimbate pe o perioadă îndelungată de timp, deoarece caută îmbunătățiri și adaptări la tendințele noi ale economiei.

La analiza seriilor de timp, principala atenție se cere acordată descrierii și modelării structurii acestora. Scopul tipului dat de cercetări, ca de obicei, cuprinde mai mult decât doar modelarea. Deseori, modelul construit se utilizează la extrapolarea și prognoza seriilor de timp și, atunci, calitatea prognozei poate servi drept criteriu la alegerea câtorva modele alternative. În lucrarea [11], se analizează detaliat problema privind atribuirea unor indicatori concreți la tipul seriilor staționare față de trend – TS (trend stationary) sau la tipul seriilor cu trend stochastic, ce duce la seria staționării pe calea diferențierii de unu sau k -ori seriei – DS (difference stationary).

Aceste două tipuri de serii diferă prin faptul că TS elimină din seria respectivă a trendului ajungând la o serie staționară, iar în cazul seriilor DS, seriile rămân nestaționare după eliminarea componentei determinate deoarece conține trend stochastic.

Traietoriile seriilor TS și DS diferă considerabil una de alta. Seriile TS au linia trendului în calitate de o „linie centrală”, în preajma căreia se află traiectoria seriei. Aceasta se plasează când mai sus, când mai jos față de această linie, cu o frecvență destul de înaltă de schimb a poziției sus – jos. Seriile DS, în afară de trend (dacă el există), mai au așa-zisul trend stochastic, datorită căruia traiectoria seriei DS se află pentru timp îndelungat de-o parte față de trend (mai sus sau mai jos față de această linie), îndepărtându-se considerabil de ea. Așadar, linia

trendului pierde poziția de „linie centrală” în jurul căreia variază traiectoria procesului.

În seriile TS, influența acțiunilor de șoc se micșorează o dată cu trecerea timpului, iar în seriile DS această diminuare lipsește și fiecare șoc acționează în aceeași măsură asupra tuturor valorilor care urmează. De aceea, existența trendului stochastic poate necesita o politică economică pentru revenirea variabilei macroeconomice la tendința ei de lungă durată, iar, în cazul lipsei trendului stochastic, revenirea la tendința ei de lungă durată se produce datorită proprietăților din interiorul proceselor macroeconomice.

Modelele DS și TS, aparținând aceluiași serii de timp, pot duce la prognoze complet diferite. De aceea, decizia privind modelul care va fi aplicat este foarte importantă la efectuarea unei prognoze. În schimbul utilizării modelului implicit, se poate aplica criteriul rădăcinii unitare, ca instrument de diagnosticare la luarea deciziei.

Deseori, problemele legate de rădăcina unitară erau orientate spre incapacitatea rădăcinii unitare de a diferenția, în eșantioanele finale, ipoteza nulă despre existența rădăcinii unitare apropiate de alternativele staționare (vezi, de exemplu, [10]). Mult timp s-a afirmat că rădăcina procesului tinde spre unu, dar, totuși, e mai mică decât unu și atunci, calitatea prognozei se poate îmbunătăți utilizând modelul în diferențe, dar nu în niveluri [1]. În general, prezintă interes nu întrebarea dacă criteriul rădăcinii unitare determină modelul, ci întrebarea dacă aceste criterii aleg adevăratele modele care ne dau prognoze cât mai calitative.

Aprecierea calitativă a strategiilor, cum ar fi „întotdeauna de diferențiat”, „uneori de diferențiat” sau „niciodată de diferențiat”, bazate pe rezultatele testului preliminar la existența rădăcinii unitare, depinde, în general, de gradul de inerție a procesului real, de orizontul de prognoză, de mărimea extrasului și de particularitățile testului.

J. H. Stock și H. W. Watson în articolul [16] abordează câteva probleme, care se referă la prognoza seriilor macroeconomice.

1. Pot, oare, modelele neliniare ale seriilor de timp să dea prognoze în timp real, mai bune decât modelele liniare?
2. Se pot, oare, îmbunătăți prognozele pe o jumătate de an sau un an înainte, utilizând datele preliminare asupra inerției seriilor de timp la alegerea modelului de prognoză?

3. Pot, oare, unele combinații de prognoze să fie superioare, după exactitate, celor bazate pe o singură metodă, pentru tot spectrul seriilor de timp, și dacă da, atunci, în ce proporție trebuie să pondereze cele mai bune metode de prognoze?
4. Este, oare, câștigul de la aplicarea acestor metode mai complicate, în comparație cu prognozele simple, autoregresive, suficient pentru a motiva folosirea acestora și pentru analiștii care nu vor să-și asume riscul?

Pentru a răspunde acestor întrebări, în articol, se face un experiment corespunzător. În acest experiment, se face o comparație între diferite prognoze cu orizontul de o lună, șase sau douăsprezece luni, pentru 215 serii de timp, din economia SUA. Experimentul simulează aplicarea acestor metode în timp real, adică toate prognozele (inclusiv estimarea tuturor parametrilor, toate regulile de alegere a modelului, toate testele preliminare ș.a.) se bazează, exclusiv, pe observațiile efectuate, inclusiv până la data prognozei. Estimarea parametrilor, statisticilor pentru alegerea modelului optim, testele preliminare și ponderea lor în combinarea prognozelor se înnoiesc, pentru toate modelele, lunar, și aceste înnoiri statistice se utilizează la efectuarea prognozelor pentru următoarele luni.

Se analizează prognoze construite prin 49 de metode. Ele se numesc metode și nu modele, deoarece multe din aceste prognoze se bazează nu doar pe un singur model estimat, ci pe rezultatele alegerii unuia din mai multe modele, în urma testărilor preliminare sau aplicării criteriilor de alegere a modelelor. Modelele individuale, utilizate de aceste metode de prognoze, se numesc *modele primare* și autorul studiază în total 121. De exemplu, una din metodele de prognoză este autoregresia în niveluri cu componentă fixă și alegerea ordinului maxim al întârzierilor (ordinul modelului de autoregresie) în baza criteriului informațional Acaiche (AIC), de ordinul ce se modifică de la 0 la 12; în terminologia articolului, această metodă de prognoză combină informația de la 13 modele primare. Modelele primare se subîmpart în patru grupe: de autoregresie (AR), de nivelare exponențială (EX), de rețele neuronale artificiale (ANN), de autoregresie logică (LSTAR). De asemenea, în calitate de încă un „punct de referință” se ia „lipsa modificărilor”.

Se analizează și diferite proceduri de combinare a informației din aceste 49 metode de prognoză (proceduri de combinare a prognozelor). În lucrările [2,4], se demonstrează că media prognozelor pe diferite modele poate îmbunătăți calitatea prognozelor, pe când toate modelele sunt doar aproximații. Procedurile de combinare, vizate în articol, diferă după ponderea atribuită modelului cu cele mai bune calități la momentul dat, incluzând ponderi egale pentru toate prognozele, ponderea prognozelor în proporții inverse față de abaterea medie pătratică (MSE), utilizarea prognozelor medii și atribuirea ponderii acelei metode, care, la momentul dat, are cea mai

mică MSE simulată în regim real. Ultima procedură constă în simularea alegerii în regim real, în baza celor mai mici pătrate ale prognozei (PLS).

Markidakis et al. (vezi [7]) au cercetat calitatea metodelor cu o singură variabilă pe mai multe serii, inclusiv economice, și au ajuns la o concluzie privind aplicarea cu succes a nivelării exponențiale. Meese, Geveke (vezi [8]) au comparat diverse modele liniare, utilizând 150 de serii macroeconomice și au determinat faptul că, de obicei, lucrează bine modelele AR cu întârzieri lungi, determinate în baza AIC. De asemenea, ei au constatat că prin combinarea prognozelor liniare se îmbunătățește nesemnificativ calitatea acestora. Weigand, Gershenfeld (vezi [17]) au comparat modelele liniare cu o mulțime de modele neliniare. Chiar dacă ei au găsit dinamica neliniară în câteva serii de timp neeconomice, modelele de prognoză neliniară nu au fost destul de bune pentru seriile economice studiate de ei (cursul valutar).

Swanson, White (vezi [13, 14]) au comparat modelele cu mai multe variabile (ANN) cu modelele liniare vectoriale autoregresive și au ajuns la concluzia că autoregresiile vectoriale au, de obicei, abaterea medie pătratică (MSE) mai mică decât modelele ANN în timpul real simulat. În comparație cu lucrările menționate, lucrarea lui Stock J. H., Watson M. W. (vezi [16]) diferă prin utilizarea unui număr mare de serii cronologice macroeconomice, utilizarea unui număr mare de modele neliniare, studierea metodelor de testare la existența rădăcinii unitare și studierea intensivă a procedurilor de combinare a prognozelor.

Toate modelele în experimentul dat au forma:

$$y_{t+h} = f_i(Z_t; \theta_{ih}) + u_{it+h},$$

unde: y_t – seria pentru care se efectuează prognoza

h – orizontul de prognoză

i – indicele modelului de prognoză ($i=1, \dots, 121$),

θ_{ih} – vectorul parametrilor necunoscuți

u_{it} – eroare

Z_t – vectorul variabilelor predictorii.

De obicei, $Z_t = (y_t, \dots, y_{t-p}, \Delta y_t, \dots, \Delta y_{t-p}, I, t)$, unde p – lărgul maxim.

Toate prognozele, în totalitate, se efectuează prin metoda recursivă, adică prognoza mărimii y_{t+h} utilizează informația pentru momentul $1, 2, \dots, t$. Pentru prognoza lui y_{t+h} , valoarea vectorului parametrilor θ_{ih} se efectuează pe observațiile y_1, y_2, \dots, y_t . În toate modelele, vectorul parametrilor se verifică pe calea minimizării sumei pătratelor reziduuului prognozei cu h pași înainte.

De menționat că, de obicei, fiecare metodă de prognoză aplicată unei serii concrete ia valori diferite ale parametrilor la modificarea orizontului, adică prognoza pe h pași înainte nu se calculează ca iterația pentru h perioade înainte pentru modelul prognozei de un singur pas.

Pentru obținerea rezultatelor de bază, toate prognozele în lucrarea [16] „se scurtează” automat, astfel încât, dacă variația prognozei depășește după mărime absolută toate variațiile anterioare pentru seria dată, atunci se aplică prognoza „fără schimbări”. Un astfel de tip de corecție se utilizează pentru simularea implicării factorului uman, care lipsește în experimentul computerizat. Deoarece prognozele

în experimentul dat se înfăptuiesc automat, unele modele pot da (și dau în realitate) prognoze extremale puțin posibile. Algoritmul utilizat de «cioplire» poate fi înțeles ca o regulă practică, pe care analistul o poate folosi în timp real pentru depistarea problemei date și luarea deciziei corespunzătoare.

Pentru fiecare serie, se aplică trei tipuri de perioade: de start, în care se face estimarea primară a modelului; intermediară, în care se fac prognoze în baza a 121 de modele primare și 49 metode de pronosticare, dar fără utilizarea prognozelor combinate, și perioada de simulare a prognozelor în timp real, în care se obțin prognoze recursive cu toate modelele, metodele și procedurile de combinare.

Modele și metode de prognoză

Pentru a verifica ipoteza existenței rădăcinii unitare, există o mulțime de criterii. În lucrarea lui Stock [14], prin metoda Monte-Carlo, s-au cercetat modelele cu autoregresie prin testarea preliminară a existenței rădăcinii unitare. Stock a testat câteva metode cu diferite niveluri de semnificație și a hotărât că cea mai bună calitate a prognozei, pentru diferite valori ale rădăcinii cu autoregresie, o dă utilizarea criteriului DF-GLS [vezi [6]], cu nivel mic de semnificație. Respectiv, în lucrarea lui Stock Watson [15] se utilizează testul DF-GLS^u pentru diverse modele – cu constantă, dar fără trend și includerea liniară a trendului.

Concluziile principale, care se pot trage, sunt:

1. Chiar dacă pentru unele serii prognozele neliniare dau rezultate mai bune decât cele liniare, majoritatea metodelor de prognoză neliniară și toate metodele bazate pe rețele neuronale duc la prognoze care au o calitate mai joasă decât prognozele obținute prin metode liniare.
2. Îmbunătățirea prognozelor, pentru toate orizonturile de prognoză cercetate, favorizează verificarea și testarea preliminară a existenței rădăcinii unitare.
3. Combinarea prognozelor, obținute prin diverse metode, servește drept protecție față de erorile prea mari ale prognozelor și poate fi recomandată pentru utilizarea ei în practica de prognoză.
4. Dacă analistul preferă să utilizeze doar o metodă de prognoză, atunci, în cazul dat, se recomandă utilizarea modelului cu autoregresie cu testarea preliminară la existența rădăcinii unitare și alegerea gradului de autoregresie în baza datelor statistice.

Prof. univ. dr. Ion PÂRȚACHI
Academia de Studii Economice Chișinău

Bibliografie

1. BOX, J., JENKINS, G. *Time Series Analysis. Forecasting and Control*, Holden Day, 1976
2. BATES, J. M., GRANGER, C. W. J. *The Combination of Forecasts*, *Operation Research Quarterly*, 20/1969, p. 451-468
3. CLEMENTS, M. P., HENDRY, D. F. *Forecasting Non-Stationary Economic Time Series*. Cambridge, Massachusetts: The MIT Press, 2001
4. GRANGER, C. W. J., NEWBOLD, P. *Forecasting Economic Time Series*, Second Edition, New York, Academic Press, 1986
5. GRANGER, C.W. J., RAMANATHAN, R. *Improved Methods of Combining Forecasting*, *Journal of Forecasting* 3/1984, p. 197-204
6. ELLIOTT, G., ROTHENBERG, T. J., STOCK, J. H. *Efficient Tests for an Autoregressive Unit Root*, *Econometrica*, 64/1996, p. 813-836
7. MARKIDAKIS, S.A., ANDERSON, A., CARBONNE, R., FLIDES, R., HIBON, M., LEWANDOWSKI, R., NEWTON, J., PARSEN, E., WINKLER, R. *The Accuracy of Extrapolation (Time-Series) Methods: Results of a Forecasting Competition*, *Journal of Forecasting*, 1/1982, p. 111-153
8. MEESE, R., GEWEKE, J. *A Comparison of Autoregressive Univariate Forecasting Procedures for Macroeconomic Time Series*, *Journal of Business and Economic Statistics*, 2/1984, p. 191-200
9. PÂRȚACHI, I. *Aspecte conceptuale ale analizei seriilor de timp*, *Revista Drept, economie și informatică*, 5/2001, Galați, p. 13-18,
10. RUDEBUSCH, G. D. *The Uncertain Root in Real GNP*, *American Economic Review*, 83/1993, p. 264-272
11. С. СИНЕЛЬНИКОВ-МУРЫЛЕВ, С., ДРОБЫШЕВСКИЙ, В., НОСКО, Р., ЭНТОВ, А., ЮДИН *Эконометрический анализ динамических рядов основных макроэкономических показателей*, Институт экономики переходного периода, 2001

Management

- | | | | |
|----------------------------------|--|------------------------------------|--|
| 12. SWANSON, N. R.,
WHITE, H. | <i>A Model Selection Approach to Assessing the Information in Term Structure Using Linear Models and Artificial Neural Networks</i> , Journal of Business and Economic Statistics, 13/1995, p. 265-275 | 15. STOCK, J. H. | <i>VAR, Error Correction and Pretest Forecasts at Long Horizons</i> , Oxford Bulletin of Economics and Statistics, 58/1996, N4, p. 685-701 |
| 13. SWANSON, N. R.,
WHITE, H. | <i>Forecasting Economic Time Series Using Flexible versus Fixed Specification and Linear versus Nonlinear Econometric Models</i> , International Journal of Forecasting, 13/1997, N4, p. 439-461 | 16. STOCK, J. H.,
WATSON, M. W. | <i>A Comparison of Linear and Nonlinear Univariate Models for Forecasting Macroeconomic Time Series</i> , Journal of Business and Economic Statistics, 14/1996, N1, p. 11-30 |
| 14. SWANSON, N. R.,
WHITE, H. | <i>A Model Selection Approach to Real-Time Macroeconomic Forecasting Using Linear Models and Artificial Neural Networks</i> , Review of Economics and Statistics, 79/1997, p. 540-550 | 17. WEIGAND, A. S.,
GERSHENFELD | <i>Time Series prediction: Forecasting the Future and Understanding the Past</i> . Addison-Wesley for Santa Fe Institute: Reading, 1994 |