

Realaus Lietuvos ekonomikos augimo prognozavimas panaudojant neuroninius tinklus

Audronė JAKAITIENĖ, Minija TAMOŠIŪNAITĖ (VDU)

el. paštas: iiauja@vdu.lt, iimita@vdu.lt

1. Įvadas

Pagrindinis šalies ūkio būklę nusakantis rodiklis yra bendrasis vidaus produktas. Šio darbo tikslas yra prognozuoti Lietuvos bendrojo vidaus produkto (BVP), palyginamosiomis 2000 metų kainomis, pokyčius trumpu laikotarpiu, taikant dirbtinius neuroninius tinklus ir tiesinį autoregresinį laiko eilučių modelį bei atlikti jų palyginamąją analizę. Literatūroje BVP prognozavimui naudojami tiesiniai ir netiesiniai laiko eilučių metodai [2, 3], išankstinių rodiklių indeksas, sutampančių rodiklių indeksas [4], neuroniniai tinklai [9] ir kiti metodai.

Tradicinių ekonominių modelių kūrime pagrindinę vietą užima ekonominė logika, kuri dažnai nėra išlaikoma neuroninių tinklų modeliuose, kuriuose „juodos dėžės“ principu. Tačiau dėl galimybės pasiekti tikslesnių nei tradiciniais modeliais rezultatų, pastaraisiais metais neuroniniai tinklai tampa vis populiariesni ekonominiame modeliavime ir prognozavime [1, 2, 9]. Neuroninių tinklų pritaikymą Lietuvos ekonominių rodiklių prognozavimui autoriams pavyko rasti realizuotą finansiniams rodikliams. Šis darbas yra pirmas pritaikant neuroninius tinklus vienam iš svarbiausių Lietuvos makroekonominių rodiklių – BVP prognozavimui. Suprantama, kad dėl vidinės struktūros neskaidrumo vien neuroninių tinklų rezultatais BVP prognozavime nebūtų galima pasitikėti. Tačiau pademonstravus galimybę neuroniniu tinklu prognozuoti pakankamai tiksliai, modelio galimybių tyrimą makroekonominių rodiklių prognozavimo srityje vertėtų plėsti, o neuroninius tinklus naudoti kaip vieną iš BVP prognozavimo instrumentų.

2. BVP prognozavimo metodai

Prognozuosime realiojo BVP, apskaičiuoto gamybos metodu (palyginamosiomis 2000 m. kainomis), didėjimo tempus, palyginti su praėjusių metų atitinkamu ketvirčiu. Prognozavimas vykdomas analizuojant realųjį BVP pagal [2] atliktą sudalijimą į dvyliką sudėtinių dalių, kurios šiame tyrime tarnauja kaip endogeniniai, t.y., svarbūs vidinei modelio struktūrai kintamieji. Endogeninius kintamuosius žymėsime Y , o šiuos rodiklius formuojančiuosius tiesiogiai išmatuojamus rodiklius, vadinamus egzogeniniais, žymėsime X . Egzogeniniai rodikliai aprašantys endogeninius buvo parinkti pagal [2], papildžius juos kiekvienos dalies darbo rinkos rodikliais (vidutiniu atlyginimu bei sąlyginiu dirbančiųjų skaičiumi).

Realiojo BVP didėjimo tempas, palyginti su ankstesnių metų atitinkamu ketvirčiu, yra apskaičiuojamas kaip jį sukuriančių veiklų didėjimo tempų ir tų veiklų praėjusių metų atitinkamo ketvirčio svorių sandaugų suma, t.y.,

$$Y_t = \sum_{i=1}^{12} \alpha_{i(t-4)} Y_{it}, \quad (1)$$

kur Y_{it} – i -tosios realųjį BVP kuriančios veiklos augimo tempas laiko momentu t , o $\alpha_{i(t-4)}$ – i -tosios realųjį BVP kuriančios veiklos svoris laiko momentu $t - 4$, $t = 1, \dots, T$, kur T stebėjimų (ketvirčių) skaičius. Visų realųjį BVP kuriančių veiklų augimo tempai apskaičiuojami kaip svertinė egzogeninių rodiklių suma

$$Y_{it} = \sum_j \beta_{ij} X_{ijt} + \varepsilon_{it}, \quad (2)$$

kur kiekvienas X_{ijt} prognozuojamas pagal autoregresijos lygtį

$$X_{ijt} = f(1, t, X_{ij(t-1)}, X_{ij(t-2)}, \dots, X_{ij(t-p)}; \gamma) + u_{ijt}, \quad (3)$$

kur X_{ij} – egzogeninių rodiklių, aprašančių i -tąją veiklą augimo tempai, j perbėga skirtingus tą pačią veiklą aprašančių rodiklius, p – maksimalus lagų skaičius, ε ir u – tiesinės regresijos paklaidos, β ir γ – nežinomų parametru vektoriai.

Pirmojoje darbo dalyje būsimųjų egzogeninių reikšmių prognozavimui naudojama tiesinė funkcija f su lagų skaičiumi $p = 2$. Antrojoje darbo dalyje prognozavimui įvedami dirbtiniai neuroniniai tinklai. Neuroninių tinklų modelyje egzogeninių kintamųjų X_t regresiją (2) bei autoregresinį prognozavimą (3) pakeitėme endogeninių kintamųjų Y_{it} tiesioginiu autoregresiniu prognozavimu kai $p = 2$ (t.y., egzogeninių kintamųjų reikšmės šiame neuroninių tinklų modelyje apskritai nenaudojamos). Prognozavimui buvo sukurtas dvisluoksnis tinklas

$$Y_{it} = h\left(\sum_{k=1}^2 w_k f\left(\sum_{l=1}^2 v_{lk} U_l\right)\right), \quad (4)$$

kur h – tiesinė funkcija, $f(z) = \frac{1}{1+e^{-z}}$, v_{lk} , w_k – nežinomieji tinklo parametrai – vadinamieji svoriai, o regresorių vektorių U sudaro laiko eilutėje prieš einančių endogeninių kintamųjų reikšmės $U_1 = Y_{i(t-1)}$, $U_2 = Y_{i(t-2)}$. Neuroninis tinklas turi vieną paslėptąjį sluoksnį (vidinė suma kartu su funkcija f), o paslėptojo sluoksnio išėjimai sumuojami su svoriais w_k išėjimo sluoksnyje (išorinė suma).


Prognozavus atskirų endogeninių kintamųjų reikšmes pagal (4), bendras BVP įvertinamas kaip svertinė suma (1). Remiamasi dirbtinių neuroninių tinklų literatūroje keliamą prielaidą, kad apskaičiuojant daugelio tinklų rezultatų vidurkį gaunama stabilėsnė prognozuojančioji sistema [5, 7]. Panašus į (4) neuroninis tinklas palyginimui buvo taikomas tiesioginiam (nei endogeninių, nei egzogeninių rodiklių nenaudojančiam) autoregresiniam BVP laiko eilutės prognozavimui. Šiuo atveju regresorių vektorių U sudarė laiko eilutėje prieš einančios BVP reikšmės $U_1 = Y_{t-1}$, $U_2 = Y_{t-2}$.

Neuroniniai tinklai mokyti Levenberg-Marquardt metodu. Kadangi neuroninių tinklų mokymas yra daugiaekstremio optimizavimo uždavinys, kiekvienos eilutės mokymui naudota iki 10-ies atsitiktinių inicializacijų. Naujų inicializacijų generavimas buvo stabdomas, jei prognozavimo paklaida pasiekdavo duotą slenkstį, susijusį su laiko eilutės reikšmių absoliutiniu dydžiu.


3. Prognozavimo rezultatai ir jų aptarimas

Skaičiavimai vykdyti remiantis realiais Lietuvos BVP bei jo sudėtinių dalių ketvirtiniais duomenimis 1996–2002 metų laikotarpiu. Šiame straipsnyje pateikiami rezultatai, gauti naudojant 2000–2002 metų duomenis, atstovaujančius tą laikotarpį, kai Lietuvos ūkio vystymesi nebuvo didelių lūžių. Prognozuota iki 2003 metų pabaigos. Tiesiniai prognozavimo metodai taikyti įprastu ekonominėje analizėje būdu: jei kažkurios BVP sudėtinės dalys duotuoju laiko momentu jau žinomos – jos iškart naudojamos prognozei gauti pagal (1), (2) lygtis. Autoregresinis prognozavimas (3) taikomas tik prognozavimo momentu nežinomoms kintamųjų reikšmėms apskaičiuoti. Realiai, tiesinis autoregresinis prognozavimas taikytas tik vykdant prognozę 2003-ųjų metų II–IV ketvirčiui, o ankstesniųjų metų prognozės gautos naudojant išmatuotus einamojo ketvirčio egzogeninius rodiklius. Toks prognozavimo būdas leidžia gauti tikslesnius rezultatus, kai yra išmatuotų rodiklių, tačiau nesudaro prielaidų įvertinti galimas paklaidas, kai prognozuojame į priekį, kur jokie realūs rodikliai dar nėra žinomi. Realiojo BVP ir tiesinės prognozės palyginimas pateiktas 1 pav.

Neuroniniais tinklais grįstame modelyje visiems ketvirčiams (net ir tuo atveju kai egzogeniniai rodikliai žinomi) buvo naudojamas autoregresinis prognozavimas. Tokie skaičiavimai buvo vykdomi, siekiant geriau įvertinti neuroninių tinklų daromas prognozavimo klaidas. Pateikiami testo imtyje (slenkančiuoju testu) gauti rezultatai. Buvo



1 pav. Realus BVP (storesnė linija) ir jo tiesinės prognozės (plonesnė linija) palyginimas.



2 pav. Realus BVP (storesnė linija) ir prognozių į priekį neuroniniais tinklais, 1 žingsnį (vientisa linija), 2 žingsnius (punktyrinė linija) bei 3 žingsnius (punktyrinė-taškinė linija) palyginimas.

lyginamas tinklo gebėjimas prognozuoti 1, 2, 3 ir 4 ketvirčiais į priekį (2 pav.). Gautieji rezultatai turi atsitiktinę dalį, atsiradusią dėl atsitiktinių svorių inicializacijų, tačiau tokia komponentė beveik neišvengiama sudėtingame daugiaekstreminiame uždavinyje.

Lyginant tiesinę prognozę ir dirbtinių neuroninių tinklų BVP prognozę, matome, kad tiesiniu atveju labiau būdingi dideli nuokrypiai (prognozuojamas net 15 nuošimčių augimas šių metų IV ketvirčiui, kuris realiai nėra laukiamas, žr. 1 pav.). Tuo tarpu neuroniniai tinklai, nors ir įnešantys atsitiktinumą komponentę dėl inicializacijos netobulumo, linkę teikti artimesnę vidurkiui prognozę. Vertinant koreliacijos koeficientus tarp tikrosios BVP sekos ir neuroniniu tinklu prognozuotų sekų (testo imtyje), rasta, kad koreliacijos vidutinio stiprumo, kai prognozuojame 1 ar 2 ketvirčius į priekį, tačiau tampa artimos nuliui prognozuojant 3–4 ketvirčius į priekį. Autoregresiškai neuroniniu tinklu prognozuojant visą BVP (nenaudojant tarpinių endogeninių kintamųjų prognozių), gaunami panašūs rezultatai, kaip ir sumuojant BVP iš prognozuotų endogeninių kintamųjų.

Neuroniniai tinklai galėtų būti patrauklūs BVP prognozavimui dėl automatizuoto svarbių endogeninių kintamųjų sudarymo iš egzogeninių kintamųjų (paslėptojo sluoksnio išėjime, po funkcijos f (4) formulėje), tačiau tokio pobūdžio neuroninių tinklų analizei reikalingas didelis kiekis duomenų, kurių tik šiek tiek daugiau nei dešimtmetį gyvavęs Lietuvos ūkis neteikia.

4. Išvados

- Turint Lietuvos BVP ir jo sudedamųjų dalių duomenis tik nuo 1995 m., nei tiesiniai metodai, nei neuroniniai tinklai nepajėgūs tiksliai prognozuoti BVP. Šiame darbe apskaičiuotos prognozės gali tarnauti tik patariamuoju balsu prognozę darančiam ekspertui.

- Trūkstant duomenų, tiesiniai metodai labiau linkę duoti smarkiai nuo vidurkio nukrypusias prognozes, o neuroniniai tinklai su užsisotiniančiomis funkcijomis – aplink vidurkį svyruojančias prognozes.
- Tikslesnius BVP prognozavimo algoritmus būtų įmanoma sukurti tik turint didesnę kieki stebėjimų (pvz., ilgesnes stebimų duomenų eilutes).

Literatūra

- [1] T. Jagric, A nonlinear approach to forecasting with leading economic indicators, *Studies in Nonlinear Dynamics & Econometrics*, 7(2), 1135–1145 (2003).
- [2] A. Jakaitienė, Ž. Kalinauskas, Realaus Lietuvos ekonomikos augimo prognozavimas trumpam laikotarpiui, *Pinigų studijos*, VII(3), Lietuvos bankas (2003) (priimtas spausdinti).
- [3] J.H. Stock, M.W. Watson, A comparison of linear and nonlinear univariate models for forecasting macroeconomic time series, *NBER Working Paper No.6607*, June 1998.
- [4] P. Grasmann, F. Keereman, An indicator-based short-term forecast for quarterly GDP in the euro area, *Economic Papers*, 154, June 2001, European Commission, Brussels.
- [5] J. Kittler, M. Hatef, R.P.W. Duin, J. Matas, On Combining Classifiers, *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 20, 226–239 (1998).
- [6] D. Plikynas, L. Simanauskas, S. Būda, Vertybinių popierių kainų indeksų tyrimai naudojant dirbtinių neuroninių tinklų metodus, *Ekonomika*, 55–56 (2001).
- [7] S. Raudys, Combining the expert networks: a review, in: R. Sadykov (Ed.), *Proc. of the Int. Conf. on Neural Networks and Artificial Intelligence*, 2–5 Oct. Minsk (2001), pp. 81–91.
- [8] L. Simanauskas, D. Plikynas, Finansinio kapitalo rinkų dinamikos analizė naudojant šiuolaikinio dirbtinio intelekto sistemų metodus, *Ekonomika*, 61, 139–154 (2003).
- [9] G. Tkacz, S. Hu, *Forecasting GDP Growth Using Artificial Neural Networks*, Bank of Canada, Working Paper 99–3, January 1999.

Real Lithuanian economic growth forecasting using artificial neural networks

A. Jakaitienė, M. Tamošiūnaitė

Methods for forecasting of Lithuanian gross domestic product (GDP) are analyzed. Prognoses obtained by means of linear models and artificial neural networks are compared.