

ԱԼՎԱՐԴ ԽԱՌԱՏՅԱՆ

*տնտեսագիտության թեկնածու,
ԵՊՀ տնտեսագիտության մեջ մաթեմատիկական
մոդելավորման ամբիոնի դոցենտ
Էլ.փոստ՝ alvardkharatyan@yahoo.com*

ՍԻՐԱՆՈՒՇ ՍԱՐԳՍՅԱՆ

*ֆիզիկա-մաթեմատիկական գիտությունների թեկնածու,
ԵՊՀ ծրագրավորման և ինֆորմացիոն
տեխնոլոգիաների ամբիոնի դոցենտ
Էլ.փոստ՝ siranus@ysu.am*

ԱՆՆԱ ՀՈՎԱԿԻՄՅԱՆ

*ֆիզիկա-մաթեմատիկական գիտությունների թեկնածու,
ԵՊՀ ծրագրավորման և ինֆորմացիոն
տեխնոլոգիաների ամբիոնի դոցենտ
Էլ.փոստ՝ ahovakimyan@ysu.am*

**ԱՐՅԵՍՏԱԿԱՆ ՆԵՅՐՈՆԱՅԻՆ ՑԱՆՑԵՐԻ ԿԻՐԱՌՈՒՄԸ ՏՆՏԵՍԱ-ՄԱԹԵՄԱՏԻԿԱԿԱՆ
ՍՈՂԵԼԱՎՈՐՄԱՆ ՄԵՋ (ՀԴՈՒՄ ԳՆԱԾԻ ԿԱՆԽԱՏԵՍՄԱՆ ՕՐԻՆԱԿՈՎ)**

Ներածություն

Հայաստանի Հանրապետության Կենտրոնական բանկի կողմից վարվող դրամավարկային քաղաքականության գլխավոր նպատակը գների կայունության ապահովումն է: Այս նպատակն իրագործելու համար Կենտրոնական բանկը սահմանում է գնաճի նպատակային թիրախը: Գների կայունության ապահովմանը կենտրոնական բանկը նպաստում է երկարաժամկետ հատվածում կայուն տնտեսական աճին և բնակչության կենսամակարդակի բարձրացմանը: Այս պարագայում կարևորվում է գնաճի միտումների ճիշտ կանխատեսումը, որը կնպաստի արդյունավետ դրամավարկային քաղաքականության իրագործմանը:

Գնաճի կանխատեսման վերաբերյալ կան շատ աշխատանքներ: Որոշ հեղինակներ առաջարկում են գնաճի կանխատեսման համար կիրառել ագրեգացված առաջնորդող կան համընկնող ինդիկատորներ: Այդ մեթոդի էությունը հետևյալն է. տարբեր նակրոտնտեսական ժամանակային շարքերի հիման վրա կառուցվում են միասնական ագրեգացված ինդիկատորներ, որոնք կիրառվում են գնաճի դինամիկան կանխատեսելու համար: Մի շարք աշխատանքներում առաջարկվում է գնաճի կանխատեսումը իրականացնել բազմաչափ ռեգրեսիոն վերլուծության օգնությամբ՝ գնաճը կախվածության մեջ դնելով այլ նակրոտնտեսական ցուցանիշներից: Հեղինակների մեկ այլ խումբ առաջարկում է գնաճի կանխատեսումը իրականացնել գների ժամանակային շարքերի վերլուծության հիման վրա, հիմք ընդունելով վերջին հինգ տարիների միտումները: Վերլուծության հիմքում ընկած

է գնաճի ամսական շարքի տրոհումը ըստ տրենդի, սեզոնային և պատահական բաղադրատարրերի¹:

Գոյություն ունեցող աշխատանքներում բացակայում է գնաճի կանխատեսումը արհեստական նեյրոնային ցանցերի կիրառմամբ: Սույն հոդվածի նպատակն է.

- ներկայացնել արհեստական նեյրոցանցի էությունը, կիրառման առավելությունները որոշ տնտեսագիտական խնդիրներում,
- կանխատեսել ՀՀ գնաճի միտումները արհեստական նեյրոնային ցանցերի միջոցով,
- կառուցել գնաճի ժամանակային շարքի ARIMA և էքսպոնենցիալ հարթեցման մոդելները և կատարել կանխատեսում այդ մոդելների օգնությամբ,
- գնահատել կանխատեսումների արդյունքները:

Արհեստական նեյրոնային ցանցերը

Արհեստական նեյրոցանցերի (ԱՆՑ) ստեղծման գործում մեծ ներդրում ունի ամերիկացի նյարդաֆիզիոլոգ Ֆրենկ Ռոզենբլատը, որն առաջարկել է մարդու ընկալելու գործընթացը մոդելավորող կառուցվածքի սխեմա և այն անվանել «պերսեպտրոն»²: Ա. Բ. Բարսկին հիմնավորում է արհեստական նեյրոցանցերի, որպես կենսաբանական նեյրոնների նմանակների, ստեղծման անհրաժեշտությունը, ուշադրություն հրավիրելով գլխուղեղի տրամաբանական մոդելավորման գործընթացների վրա. բարդ տրամաբանական կառուցվածքների ստեղծման մեծ արագություն, գործողությունների զուգահեռ կատարում, գլխուղեղի տրամաբանական գործողությունների ալգորիթմի պարզություն, դժվար ֆորմալացվող խնդիրների լուծման հնարավորություն և այլն³:

Արհեստական նեյրոնային ցանցը հանդիսանում է արհեստական նեյրոնների ամբողջություն, որոնք միմյանց հետ կապված են սինապտիկ միացություններով: Նեյրոնների գործառույթը որոշվում է ցանցի կառուցվածքով և նեյրոնների միջև եղած կապերի բնույթով⁴: Գոյություն ունեն բազմաթիվ նեյրոցանցային կառուցվածքներ, որոնք միմյանցից տարբերվում են նեյրոնների և սինապտիկ կապերի (կշռային գործակիցների) քանակությամբ և տեղաբաշխվածությամբ: Առավել հայտնի կառուցվածքը բազմաշերտ պերսեպտրոնն է: Նրա շերտերի և նեյրոնների քանակը պայմանավորված է խնդրի դրվածքով:

Նեյրոնային ցանցերը ոչ թե ծրագրավորվում են այս բառի սովորական իմաստով, այլ ինքնաուսուցվող համակարգ են հանդիսանում: Ուսանելու հատկությունը ավանդական ալգորիթմների համեմատ նեյրոնային ցանցի կարևոր առավելություններից մեկն է: Ինքնաուսուցման ընթացքում ցանցը ընդունակ է

¹ Stu` Forecasting methods and formulas with Excel - <http://www.lokad.com/forecasting-methods-and-formulas-with-excel>; Methods for forecasting price. Personal Finance and Money - <http://money.stackexchange.com/questions/16187/methods-for-forecasting-price>; **Armstrong, J. S.** Selecting Forecasting Methods // Principles of Forecasting: A Handbook for Researchers and Practitioners (Ed. J. Scott Armstrong) / Kluwer, 2001.

² **Розенблатт Ф.**, Принципы нейродинамики: Перцептроны и теория механизмов мозга / М., 1962.

³ **Барский А. Б.**, Нейронные сети: распознавание, управление, принятие решений / Москва, 2004.

⁴ **Шитиков В. К., Розенберг Г. С., Зинченко Т. Д.**, Нейросетевое моделирование: многослойный перцептрон – <http://www.ievbran.ru/kiril/Library/Book1/content394/content394.htm>

դառնում բացահայտել *մուտքային և ելքային տվյալների միջև եղած թաքնված բարդ կախվածությունները*, ինչպես նաև կատարել ընդհանրացումներ: Դա նշանակում է, որ հաջող ուսուցման դեպքում ցանցը կարող է տալ ճիշտ արդյունքներ նույնիսկ ուսուցման հաջորդականությունում բացակայող, ոչ լրիվ, աղավաղված տվյալների դեպքում: Ուսանելուց հետո ցանցը կարող է կանխատեսել որոշակի հաջորդականության ապագա արժեքները ^{1,2}:

Նեյրոնային ցանցի օգտագործումն ունի ևս մի քանի առավելություններ: Դասական մեթոդներով կանխատեսումն օրվա մեջ օպերատիվ փոփոխվող ինֆորմացիայի դեպքում ոչ մասնագետի համար (վիճակագրության բնագավառի) կապված է որոշ դժվարությունների հետ ինչպես վերլուծության մեթոդն ընտրելու, այնպես էլ արդյունքների մեկնաբանման տեսանկյունից: Դա էական թերություն է, քանի որ կանխատեսման արագությունը նման դեպքերում շատ կարևոր է: Ի տարբերություն տեխնիկական անալիզի, նեյրոցանցը ընդունակ է գտնել տվյալ շարքի կանխատեսման համար *օպտիմալ ռազմավարություն*:

Ֆինանսական շուկայի տվյալների նեյրոցանցային վերլուծությունը, ի տարբերություն հայտնի մեթոդների, *չի ենթադրում մուտքային տեղեկատվության սահմանափակումներ*³:

Նեյրոնային ցանցի միջոցով կանխատեսման համակարգին կարելի է սովորեցնել բավական մեծ ծավալի տեղեկատվություն, որտեղ ցանցը կարող է հայտնաբերել կախվածություններ: Դա հնարավոր է կատարել տեղեկատվության մշակման այլ մեթոդների կիրառման դեպքում:

Երբ կանխատեսման խնդիրներ լուծելիս անհրաժեշտություն է առաջանում հաղթահարել տվյալների այնպիսի առանձնահատկությունների հետ կապված դժվարությունները, ինչպիսիք են *ոչ ստացիոնարությունը, ոչ լիարժեքությունը, բաշխման ֆունկցիայի անհայտ լինելը կամ վիճակագրական մեթոդների ոչ լիովին բավարար լինելը*, նախընտրելի է կատարել կանխատեսում ԱՆՑ միջոցով⁴:

Նեյրոցանցի կարևոր առանձնահատկությունը, որը վկայում է նրա լայն կիրառական հնարավորությունների և մեծ ներուժի մասին, կայանում է միաժամանակ բոլոր օղակներով (նեյրոններով) տեղեկատվության զուգահեռ մշակման մեջ, որը հնարավորություն է տալիս *արագացնել տեղեկատվության մշակման գործընթացը*: Նեյրոնային ցանցում կատարվում է տեղեկատվության արդյունավետ մշակում՝ պայմանավորված նեյրոհաշվարկների զուգահեռ իրականացմամբ:

Միջնեյրոնային կապերի մեծ թվաքանակի դեպքում *ցանցը սխալների հանդեպ ձեռք է բերում որոշակի կայունություն*:

¹ Солдатов О. П., Семенов В. В., Применение нейронных сетей для решения задач прогнозирования // Электронный научный журнал «Исследовано в России» - <http://zhurnal.gpi.ru/articles/2006/136.pdf>

² Laura E. Carter-Greaves. Time Series prediction with Feed-Forward Neural Networks <http://neuroph.sourceforge.net>

³ Rune Aamodt. Using Artificial Neural Networks to Forecast Financial Time Series / Oslo. 2010.

⁴ Տես՝ Gheyas I. A., Smith L. S., A Neural Network Approach to Time Series Forecasting // Proceedings of the World Congress on Engineering 2009. Vol.II, WCE 2009, July 1-3, 2009, London, U.K.; Крисилов В. А., Чумичкин К. В., Кондратюк А. В., Представление исходных данных в задачах нейросетевого прогнозирования // Конференция "Нейроинформатика 2003". – М.: научная сессия МИФИ, 2003, сс.184-191; Бакаев В. Н., Владимиров Н. В., Васильева Е. Ю., Методы обучения нейросистем (глава из электронного учебника) – http://zdo.vstu.edu.ru/umk/html/manual/L5_6.html

ՀՀ գնաճի կանխատեսումը արհեստական նեյրոնային ցանցի միջոցով

Ընդհանուր դեպքում խնդրի դրվածքը հետևյալն է: Դիցուք հայտնի են $\{x_t\}_{t=1}^T$ սկայար կամ վեկտորական ժամանակային շարքի արժեքները ժամանակի վերջավոր $t = 1 \dots T$ հատվածի վրա: x_{T+1}, x_{T+2} և այլ արժեքները որոշելու համար օգտագործվում է $x_{t+1} = f(x_t, \dots, x_{t-k+1})$ ռեկուրենտ


հարաբերությունը գտնելու մեթոդը, որտեղ k -ն այնպիսի թիվ է, որ ժամանակային շարքի k նախորդ արժեքները միանշանակ որոշում են շարքի հաջորդ արժեքը:

Կանխատեսման խնդրի լուծման նպատակով նեյրոնային ցանցի կառուցման գործընթացը ներառում է տվյալների նախնական մշակման, ուսուցման համար տվյալների նախապատրաստման, ցանցի կառուցվածքային և պարամետրական սինթեզի, ստուգիչ ընտրանքի վրա նեյրոնային ցանցի աշխատանքի կոռեկտության ստուգման և այդ ընտրանքի վրա կանխատեսման սխալի գնահատման փուլերը:

Տվյալների նախնական մշակումը ուղղված է ժամանակային շարքի ստացիոնարության ապահովմանը: ՀՀ գնաճի միտումների կանխատեսման նպատակով դիտարկվել է 1996-2013 թթ. ՀՀ սպառողական գների ինդեքսի (ՍԳԻ) դինամիկան ներկայացնող ժամանակային շարքը եռամսյակային կտրվածքով (տես՝ գծանկար 1-ը): Շարքը ստացիոնար չէ, որը ստուգվել է EViews ծրագրային փաթեթի կիրառմամբ՝ Դիկի-Ֆուլերի թեստի միջոցով: Առաջին կարգի տարբերությունները ($\Delta X_i = X_i - X_{i-1}$) ՍԳԻ ժամանակային շարքը դարձնում են ստացիոնար (տես՝ աղյուսակ 1-ը և գծանկար 2-ը):

Գծանկար 1

ՀՀ ՍԳԻ դինամիկան 1996-2013 թթ. եռամսյակային կտրվածքով¹



Աղյուսակ 1

¹ՀՀ Ազգային վիճակագրական ծառայության 1997-2013 թթ. Տարեգրքեր:

Առաջին կարգի տարբերություններով ԱԳԻ ժամանակային շարքի ստացիոնարության ստուգումը Դիկի-Ֆուլլերի թեստի միջոցով

ADF Test Statistic	-10.47475	1% Critical Value*	-3.5297
		5% Critical Value	-2.9048
		10% Critical Value	-2.5896

*MacKinnon critical values for rejection of hypothesis of a unit root.

Augmented Dickey-Fuller Test Equation

Dependent Variable: D(CPI,2)

Method: Least Squares

Date: 10/12/13 Time: 20:02

Sample(adjusted): 1997:1 2013:3

Included observations: 67 after adjusting endpoints

Variable	Coefficient	Std. Error	t-Statistic	Prob.
D(CPI(-1))	-2.488990	0.237618	-10.47475	0.0000
D(CPI(-1),2)	1.098148	0.145396	7.552795	0.0000
D(CPI(-2),2)	0.348763	0.110241	3.163636	0.0024
C	0.076541	0.366758	0.208696	0.8354
R-squared	0.810421	Mean dependent var		-0.062687
Adjusted R-squared	0.801394	S.D. dependent var		6.733000
S.E. of regression	3.000580	Akaike info criterion		5.093333
Sum squared resid	567.2193	Schwarz criterion		5.224957
Log likelihood	-166.6267	F-statistic		89.77186
Durbin-Watson stat	1.829901	Prob(F-statistic)		0.000000


Նեյրոնային ցանցի ուսուցման որակը և արագությունը բարելավելու համար անհրաժեշտ է մուտքային տվյալները ձևափոխել [-1,1] միջակայքի: Ընտրանքի i -րդ տարրի համար x ցուցանիշի արժեքի վերահաշվարկը $[a,b]$ միջակայքում իրականացվում է հետևյալ բանաձևով.

$$\tilde{x}_i = \frac{(x_i - x_{\min})(b - a)}{(x_{\max} - x_{\min})} + a$$

որտեղ x_{\min} -ը և x_{\max} -ը ցուցանիշի նվազագույն և առավելագույն ընտրանքային արժեքներն են:

Գծանկար 2

ՍԳԻ ստացիոնար ժամանակային շարքը



Ստացված բազմությունից առանձնացվում է երկու չհատվող ենթաբազմություն՝ ուսուցողական և ստուգող:

Ուսուցման փուլում ներդրմային ցանցը ուսուցողական ընտրանքի հիման վրա վերծանում է նպատակային ֆունկցիան, այսինքն լուծում է ինտերպոլյացիայի խնդիր:

Օգտագործման (կանխատեսման) փուլում կանխատեսվող արժեքը որոշելու նպատակով ներդրմային ցանցն օգտագործում է ստացված կախվածությունը՝ լուծում է էքստրապոլյացիայի խնդիր:

Ներդրմային ցանցի կառուցման փուլում իրականացվում է ցանցի ճարտարապետության և միջներդրմային կապերի ընտրությունը: ՀՀ ՍԳԻ ժամանակային շարքի հետազոտության արդյունքում որպես ներդրմային ցանցի տիպ ընտրվել է ցանց 30 մուտքով, գաղտնի շերտի 5 ներդրումով և մեկ ելքային ներդրումով (տես՝ գծանկար 3):

Ներդրմային ցանցի պարամետրական կարգավորումը կատարվում է ներդրման ցանցի ուսուցման գործընթացում, որի արդյունքում հաշվարկվում են սինապտիկ կշիռները: Ներդրմի մուտքային x_1, x_2, \dots, x_n տվյալները, կապերի w_1, w_2, \dots, w_n կշիռների միջոցով ձևափոխվում են գումարային S ազդանշանի, ելքային ազդանշանի արժեքը հաշվվում է ըստ f ակտիվացման ֆունկցիայի $Y = f(S)$: Առավել

հաճախ օգտագործվող ակտիվացման ֆունկցիան սիգմոիդային կամ լոգիստիկ կոչվող հետևյալ ֆունկցիան է.

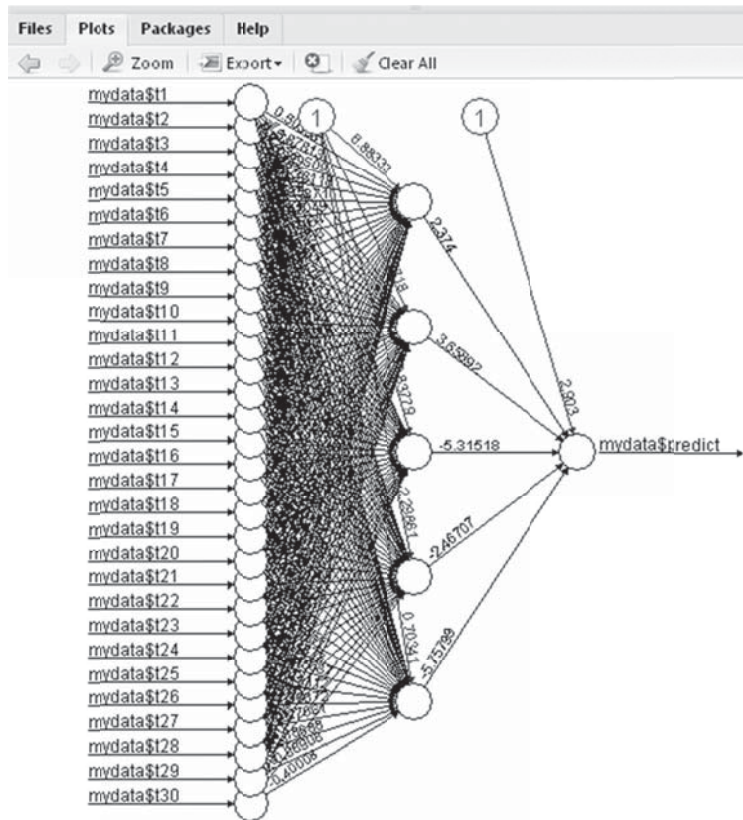
$$Y = \frac{1}{1 + e^{-x}}$$

Դրա հիմնական առավելությունը մյուս ակտիվացման ֆունկցիաների համեմատ ամբողջ առանցքի վրա դիֆերենցելիությունն է և պարզ տեսքի ածանցյալ ունենալը:

Ուսուցման նպատակը ցանցի սինապտիկ կշիռների այնպիսի ընտրությունն է, որոնք ցանցի իրական ելքը մոտեցնում են նպատակային ելքին: Հաշվարկվել է ելքային և նպատակային վեկտորների միջև սխալի չափը և կշռային գործակիցները համարվել են ուսուցման ընտրանքի յուրաքանչյուր զույգի համար: Ուսուցման գործընթացը կարելի է դիտարկել որպես օպտիմալացման խնդրի լուծում, որի նպատակը սինապտիկ գործակիցների արժեքների ընտրության միջոցով ուսուցանվող բազմության վրա սխալի ֆունկցիայի մինիմալացումն է: Ցանցի ուսուցման լավ արդյունքների մասին է վկայում գծանկար 4-ը:

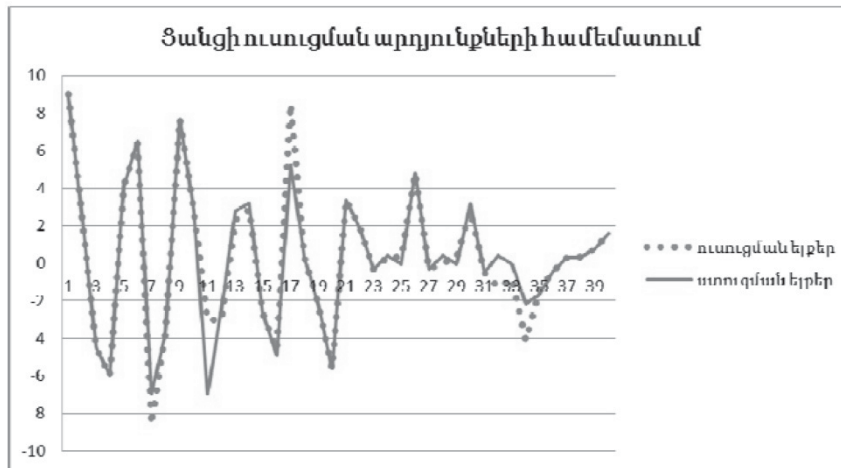
Գծանկար 3

ՍԳԻ կանխատեսման նպատակով կառուցված նեյրոնային ցանցի սխեման



Գծանկար 4

Ուսուցանված նեյրոնային ցանցի ստուգումը

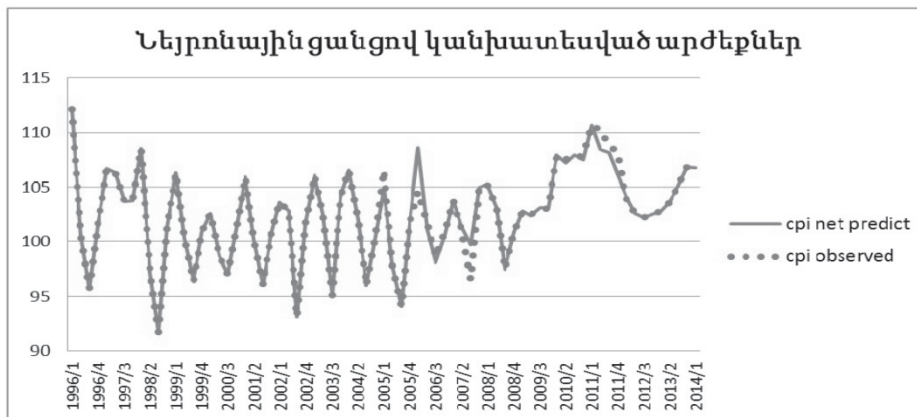


Կանխատեսման սխալի ստուգման փուլում ստուգիչ ընտրանքի համար ստացված սխալի արժեքի թույլատրելի սահմաններում գտնվելու դեպքում ցանցը համարվում է ուսուցանված և կարող է օգտագործվել կանխատեսման համար: Մեր օրինակում *ցանցի ուսուցման սխալանքի շեմը` threshold=0.01*: 40 ստուգիչ ընտրանքների համար ցանցի միջոցով ստացվել են գծանկար 4-ում բերված արդյունքները:

Արհեստական նեյրոնային ցանցի կիրառմամբ կատարված կանխատեսման արդյունքներն են՝ 2013 թ. չորրորդ եռամսյակի համար կանխատեսված արժեքը 105.4 է, իսկ 2014 թ. առաջին եռամսյակինը՝ 106,0: Արդյունքները ներկայացված են գծանկար 5-ում:

Գծանկար 5

Նեյրոնային ցանցով կանխատեսված արժեքներ (cpi արժեքներով)



ՍԳԻ ժամանակային շարքի կանխատեսումը ARIMA և էքսպոնենցիալ հարթեցման մոդելների կիրառմամբ

Չեռագուտվող ՍԳԻ շարքի վարքը ներկայացնող լավագույն մոդելը ARIMA(0,0,1)x(0,1,1)⁴ մոդելն է, որը ստացել ենք SPSS ծրագրային փաթեթի կիրառմամբ: Մոդելի համապատասխանության վիճակագրություններն են. Stationary R-squared =0.391; R-squared=0.497; Normalized BIC=2.302 (տես՝ աղյուսակ 2): Մոդելի գնահատված MA(1) և SMA(1) գործակիցները նշանակալի են (տես՝ աղյուսակ 3):

Աղյուսակ 2

ARIMA(0,0,1)x(0,1,1)⁴ մոդելի վիճակագրությունները

Model	Number of Predictors	Model Fit statistics			Ljung-Box Q(18)			Number of Outliers
		Stationary R-squared	R-squared	Normalized BIC	Statistics	DF	Sig.	
cpi-Model_1	0	.391	.497	2.302	10.375	16	.846	0

Աղյուսակ 3


ARIMA(0,0,1)x(0,1,1)⁴ մոդելի պարամետրերի գնահատականները

				Estimate	SE	t	Sig.
cpi-Model_1	cpi No Transfor- mation	MA Lag 1		-.495	.111	-4.455	.000
		Seasonal Difference	1				
		MA, Seasonal Lag 1		.593	.109	5.460	.000

Մնացորդները ներկայացնում են «սպիտակ աղմուկ» ստացիոնար գործընթաց, որի արժեքները ժամանակի ցանկացած ֆիքսված պահի բաշխված են նորմալ բաշխման օրենքի համաձայն 0 միջինով և σ^2 դիսպերսիայով. $\varepsilon \sim iid(0, \sigma^2)$: Դա երևում է մնացորդների շարքի կորելոգրամից (տես՝ գծանկար 6): ARIMA(0,0,1)x(0,1,1)⁴ մոդելի կանխատեսման արդյունքները ներկայացված են աղյուսակ 4-ում և գծանկար 8-ում:

Գծանկար 6

ARIMA(0,0,1)x(0,1,1)⁴ մոդելի մնացորդների ավտոկորելյացիան



Աղյուսակ 4

ARIMA մոդելի կանխատեսումները

Model		Q4 2013	Q1 2014
cpi-Model_1	Forecast	105.3	104.8
	UCL	111.0	111.2
	LCL	99.6	98.5

Գնաճի կանխատեսումը **էքսպոնենցիալ հարթեցման մոդելով** ARIMA մոդելի համեմատ տվել է ավելի լավ արդյունքներ՝ հարաբերականորեն փոքր Բայեզի ինֆորմացիոն չափանիշ և հարաբերականորեն մեծ դետերմինացիայի գործակից (տես՝ աղյուսակներ 2-ը և 5-ը): Մոդելի պարամետրերի գնահատականները վիճակագրորեն նշանակալի են (տես՝ աղյուսակ 6):

Աղյուսակ 5

էքսպոնենցիալ հարթեցման մոդելի վիճակագրությունները

Model	Number of Predictors	Model Fit statistics			Ljung-Box Q(18)			Number of Outliers
		Stationary R-squared	R-squared	Normalized BIC	Statistics	DF	Sig.	
cpi-Model_1	0	.448	.572	2.197	21.855	16	.148	0

Աղյուսակ 6

էքսպոնենցիալ հարթեցման մոդելի պարամետրերի գնահատականները

Model			Estimate	SE	t	Sig.
cpi-Model_1	No Transformation	Alpha (Level)	.562	.098	5.723	.000
		Delta (Season)	.692	.231	2.989	.004

ԱԳԻ վիճակագրական և էքսպոնենցիալ հարթեցման մեթոդով կանխատեսված արժեքների համադրումը ներկայացված է զծանկար 8-ում, իսկ էքսպոնենցիալ հարթեցման մոդելով կատարված կանխատեսումների արդյունքները՝ աղյուսակ 7-ում և զծանկար 7-ում:


Աղյուսակ 7

էքսպոնենցիալ հարթեցման մոդելի կանխատեսումները

Model		Q4 2013	Q1 2014
cpi-Model_1	Forecast	103.9	104.8
	UCL	109.6	111.3
	LCL	98.3	98.4

Զծանկար 7

ԱԳԻ ժամանակային շարքի վիճակագրական (Observed) և ARIMA(0,0,1)x(0,1,1)⁴ մոդելով կանխատեսված (Fit) արժեքների համադրումը¹



Եզրակացություն: Տնտեսական գործոնների դինամիկան ներկայացնող վիճակագրական տվյալները ժամանակային շարքեր են: Ժամանակային շարքերի կանխատեսման նպատակով կիրառվում են մի շարք մոդելներ, որոնցից յուրաքանչյուրը պահանջում է որոշակի նախնական պայմանների բավարարում: Այսպես, ARIMA(p, d, q) (Autoregressive Integrated Moving Average) մոդելների կիրառումը պահանջում է ստացիոնարության պայմանի բավարարում: ARIMA մո-


¹ 95 % վստահելիության վերին (UCL) ու ստորին սահմանները (LCL): Forecast-ը ներկայացնում է կանխատեսված արժեքները հաջորդ երկու եռամսյակների համար:

դելների ընդհանուր թերությունը մոդելի տիպն ընտրելու բարդությունն է, որը զգալիորեն մեծացնում է ժամանակային շարքերի վերլուծության և կանխատեսման գործընթացի մասնակիցների *սուբյեկտիվ ներդրումը*¹: Երկրաչափական լագերի կամ էքսպոնենցիալ հարթեցման մոդելներում ենթադրվում է, որ X փոփոխականի ազդեցությունը q ժամանակ անց չի ավարտվում, այլ անվերջ շարունակվում է, ժամանակի յուրաքանչյուր պահի նվազելով *նույն տոկոսով*:

Արհեստական նեյրոնային ցանցի ապարատը ենթադրում է մոդելի ձևավորման գործում *վերլուծաբանի նվազագույն մասնակցություն*, քանի որ ինքնաուսուցման ունակությունը բնորոշ է բոլոր նեյրոցանցային մոդելներին (ուսուցման ալգորիթմները կշռային գործակիցները հարմարեցնում են ներկայացված տվյալների կառուցվածքին):

Գծանկար 8

ՍԳԻ ժամանակային շարքի վիճակագրական (Observed) և էքսպոնենցիալ հարթեցման մոդելով կանխատեսված (Fit) արժեքները:



ՍԳԻ 2013 թ. չորրորդ եռամսյակի կանխատեսված արժեքը էքսպոնենցիալ հարթեցման մոդելով 103,9 է, ARIMA մոդելով՝ 105,3: 2014 թ. առաջին եռամսյակի արժեքի կանխատեսումների արդյունքները համընկել են՝ 104,8: Արհեստական նեյրոնային ցանցի կիրառմամբ կատարված կանխատեսման արդյունքներն են 105,4 և 106,0:

Կատարված վերլուծությունից երևում է, որ վերը ներկայացված մոդելների կանխատեսումների արդյունքները գրեթե համընկնում են: Կանխատեսման ճշտության գնահատականները *համադրելի են միայն* ARIMA և էքսպոնենցիալ հարթեցման մոդելների համար: Մոդելների համապատասխան վիճակագրու-

¹ Бокс Дж., Дженкинс Г., Анализ временных рядов. Прогноз и управление / М.: Мир, 1974; Бриллинджер Д. Временные ряды / М.: Мир, 1980.

թյունները հիմք են տալիս նախապատվությունը տալ էքսպոնենցիալ մոդելի կանխատեսմանը (տես՝ աղյուսակներ 2-ը և 5-ը):

Ցույց ենք տվել, որ արհեստական նեյրոնային ցանցի կիրառմամբ ստացված գծանկար 6-ը ներկայացնում է ՍԳԻ փաստացի և կանխատեսված տվյալների համընկնելու ավելի բարձր աստիճան, քան գծանկարներ 7-ը և 8-ը, որոնք ստացվել են ARIMA և էքսպոնենցիալ հարթեցման մոդելներով:

Այսպիսով, արհեստական նեյրոնային ցանցերը արդյունավետ միջոց են տնտեսական ցուցանիշների դինամիկան կանխատեսելու համար: ՀՀ գնաճի դինամիկան կանխատեսելու նպատակով կիրառվող մոդելների բազմազանությունը հնարավորություն կտա կենտրոնական բանկին ունենալ ընտրության ավելի մեծ հնարավորություն:

ԱՆՑ-ը կարող են օգտագործվել բոլոր այն բնագավառներում, որտեղ անհրաժեշտ է լուծել ապրոկսիմացիայի և ինտերպոլյացիայի, կերպարների ճանաչման և դասակարգման, կանխատեսման, գնահատման և կառավարման խնդիրներ:

ԱՄՓՈՓՈՒՄ

Հոդվածում քննարկվում է տնտեսական ցուցանիշների կանխատեսման համար նեյրոցանցի կիրառման հնարավորությունը և արդյունավետությունը: Համեմատվում են ժամանակային շարքերի վերլուծության ARIMA և էքսպոնենցիալ հարթեցման մոդելների կիրառմամբ և նեյրոցանցի օգտագործմամբ ստացված կանխատեսումների արդյունքները:

АННОТАЦИЯ

ХАРАТЯН А., САРКИСЯН С., ОВАКИМЯН А. – ПРИМЕНЕНИЕ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ В ЭКОНОМИКО-МАТЕМАТИЧЕСКОМ МОДЕЛИРОВАНИИ (НА ПРИМЕРЕ ПРОГНОЗИРОВАНИЯ ИНФЛЯЦИИ В РА)

В статье обсуждается возможность использования и эффективность нейронной сети для прогнозирования экономических показателей. Сопоставляются результаты прогнозирования, полученные с применением моделей ARIMA и экспоненциального сглаживания и с использованием нейронной сети, для анализа временных рядов.

SUMMARY

KHARATYAN A., SARGSYAN S., HOVAKIMYAN A. – THE USAGE OF ARTIFICIAL NEURAL NETWORKS IN ECONOMIC-MATHEMATICAL MODELING (ON THE EXAMPLE OF INFLATION FORESIGHT IN RA)

Authors discuss possibility and efficiency of artificial neural network application for economic indicators prediction and compare. Results of predictions using ARIMA, exponential smoothing models and an artificial neural network for time series analysis.