

Vertybinių popierių kainų indeksų tyrimai naudojant dirbtinių neuroninių tinklų metodus

Darius Plikynas

Doktorantas
Vilniaus universitetas
Teorinės ekonomikos katedra
Saulėtekio al. 9, II rūmai, 2040 Vilnius
Tel: (8 298) 2 94 65
El. paštas: d.plikynas@post.omnitel.net
www.omnitel.net/neuraleconom

Leonas Simanauskas

Profesorius socialinių mokslų
habilituotas daktaras
Vilniaus universitetas
Ekonominės informatikos katedra
Saulėtekio al. 9, II rūmai, 2040 Vilnius
Tel. (8 22) 36 62 92
El. paštas: leonas.simanauskas@ef.vu.lt

Sigitas Būda

Doktorantas
Matematikos ir informatikos institutas
Akademijos g. 4 Vilnius
Tel. (8 286) 2 98 46
El. paštas: s.buda@it.lt

Straipsnyje nagrinėjamos nacionalinės vertybinių popierių biržos (NVPB) indeksų autoregresinio, autoregresinio priežastinio ir priežastinio trendo modelių sudarymo ir jų pritaikymo, naudojant dirbtinių neuroninių tinklų (DNT) metodus, galimybes. Ištirtos dirbtinio neuroninio tinklo aproksimavimo ir prognozavimo galimybes, esant skirtingiems mokymo algoritmams, duomenų pateikimo būdams, neuroninio tinklo konfigūracijoms. DNT mokymas atliekamas remiantis praėjusių periodų atitinkamų nacionalinių indeksų vertėmis, šalies makroekonominį rodiklių bei kitų šalių vertybinių popierių kainų indeksų vertėmis. Tyrimo rezultatai lyginami su multidimensinės tiesinės regresijos rezultatais. Nustatytos optimalios dirbtinio neuroninio tinklo konfigūracijos, leidžiančios gauti geresnius NVPB kainų indeksų aproksimavimo ir prognozavimo rezultatus negu tiesinės regresijos metodu.

Įvadas

Investuojant vertybinių popierių rinkose finansinį kapitalą, svarbu numatyti finansų rinkų elgesį, nes nuo to priklauso gaunamas pelnas. Vertybinių popierių indeksai yra santykinis rodiklis, parodantis vertybinių popierių (VP) rinkų kitimo tendencijas, kurios tiriamos analizuojant ir prognozuojant indeksų kitimą. Tam yra sukurta įvai-

rių modelių, daugelis iš kurių remiasi technine arba fundamentine analize [1, p. 10]. Šio tyrimo pagrindinis tikslas – pasiūlyti kompleksinės analizės priemonės, kurios apima ne tik techninius istorinius indeksų pokyčius, bet ir fundamentinius makroekonominį šalies rodiklius bei kitų šalių vertybinių popierių indeksus. Parodoma, kaip su jų pagalba galima tiksliau prognozuoti vertybinių popierių rinkų indeksų kitimą. Tirtas

Lietuvos nacionalinės vertybių popierių biržos indeksų LITIN, LITIN-A ir LITIN-VVP kitimas [2, p. 2]. Nagrinėjami trys pagrindiniai tų indeksų kitimo trendo modeliai: autoregresinis, autoregresinis priežastinis ir priežastinis [3, p. 86]. Modelių pagrindas yra dirbtinio intelekto sistemos, realizuojamos naudojantis dirbtinių neuroninių tinklų metodais. Šių metodų pasirinkimą lėmė tai, kad, tiriant vertybių popierių rinkos elgesį, susiduriama su ekonominės informacijos trūkumu, per mažai išnagrinėtas, kai kurių procesų susiformavimo mechanizmas. Vertybių popierių rinkos indeksų kitimą lemia unikalūs, retai pasikartojantys reiškiniai. Tradiciniai statistinės analizės metodai neduoda norimo VP indeksų kitimo analizės ir prognozės tikslumo [3, p. 17; 4, p. 201], nes jie naudojami apibrėžtomis, nusistovėjusioms ir tipinėms ūkio situacijoms analizuoti.

Mokslinėje periodinėje literatūroje jau nuo XX amžiaus aštuontojo dešimtmečio pradžios pasirodė straipsnių apie tyrimus, kuriuose finansų rinkų analizei ir prognozei pradėti naudoti alternatyvūs dirbtinio intelekto metodai, t. y. žinių bazėmis grindžiamos ekspertinės sistemos, genetiniai algoritmai, neapibrėžtoji logika (angl. *fuzzy logic*), chaoso teorija ir dirbtiniai neuroniniai tinklai [4, p. 59]. Pastarųjų pasirinkimą šiame darbe lėmė jų netiesiškumas, lankstumas, nesudėtingas mokymas ir perspektyvūs ankstesni kitų autorių darbai [4, p. 159].

Neuroninių tinklų optimizavimo finansiniams uždaviniams spręsti taisyklės aprašo C. Klimasauskas [5, p. 45; 6]. Jų naudojimo finansinių sprendimų sistemose galimybes nagrinėja D. D. Hawley'as, J. D. Johnsonas, D. Raina [5, p. 25]. Neuroninių tinklų ir ekspertinių sistemų integruotus modelius nagrinėja D. Barkeris [5, p. 83]. Probleminių korporacijų diagnozavimo problemas tyrinėja P. K. Coatsas ir L. F. Fantas [5, p. 163]. Firmų bankrotų prognozės srityje pažymėtini W. Raghupathi, L. L. Schkade'o,

B. S. Raju [5, p. 227] bei R. L. Wilsono, R. Sharada darbai [5, p. 367]. Skolinimo rizikos įvertinimo srityje tyrinėjimus atliko S. Dutta ir S. Shekharas [5, p. 397], A. J. Surkanas ir J. C. Singletonas [5, p. 415], H. L. Jensonas [5, p. 453] ir kiti.

Atlikta daug tiriamųjų vertybių popierių rinkos analizės ir prognozės, naudojant dirbtinių neuroninių tinklų metodus, darbų. IBM kompanijos vertybių popierių kainų kitimo prognozę su DNT atliko H. White'as, jo teigimu, neuroniniai tinklai pasižymėjo ypač dinamišku elgesiu ir galimybe atlikti sudėtingus prognozavimo uždavinius [5, p. 469]. Daugiamatės diskriminanatinės analizės metodą su DNT metodu palygino Y. Yoon ir G. Swalesas [5, p. 483]. Jie tvirtina, kad DNT metodu galima ženkliai padidinti vertybių popierių kainos kitimo prognozę. T. Kimoto, K. Asakawa, M. Yoda ir M. Takeoka atliko kompleksinius techninės ir fundamentinės analizės tyrimus, kurių tikslas – vienam mėnesiui į ateitį numatyti tinkamiausia akcijų pirkimo ir pardavimo laiką. Autoriai naudojo *Fujitsu* korporacijos pasiūlytą kelių neuroninių tinklų sistemą ir realių akcijų pirkimo ir pardavimo būdu gavo daug didesnį pelną negu tradiciniais prognozavimo metodais [5, p. 497]. Y. Hiemstra ir C. Haefke'as palygino prekyvimo S&P500 akcijomis pelną, kai prognozuoti naudojami daugiasluoksniai DNT ir tiesinė regresija. Jie tvirtina esant stiprią DNT konfigūracijos ir gaunamų rezultatų priklausomybę, tačiau DNT metodu neabejotinai geriau surandamos netiesinės priklausomybės negu tiesinės regresijos metodu [5, p. 511]. Išvardyti ir daugelis kitų autorių darbų ir lėmė mūsų apsisprendimą indeksų kitimo analizei ir prognozei naudoti dirbtinių neuroninių tinklų metodus.

Tyrimo metodika

NVPB indeksų skaičiavimo metodika remiasi Tarptautinės finansų korporacijos (IFC) meto-

dologija [2; 6]. LITIN, LITIN-A ir LITIN-VVP kainų indeksų reikšmės skaičiuojamos pagal vidutinę svertinę prekybos sesijos kainą ir oficialius dienos kursus [6; 7].

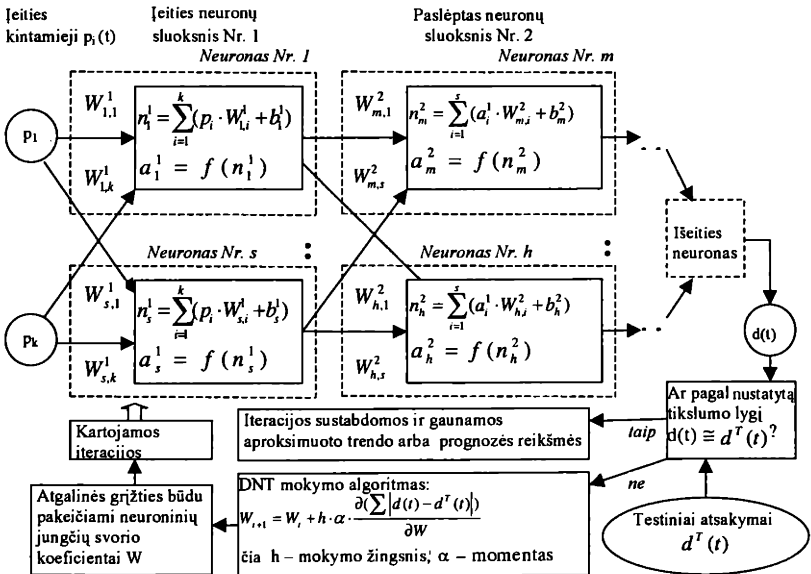
Formuojant naudotą dirbtinių neuroninių tinklų metodą, naudojantis kitų autorių atliktais indeksų kitimo tyrimais [4, p. 164; 5, p. 511], nustatytos pagrindinės sąlygos, kurias DNT metodas privalo tenkinti:

- 1) gerai aproksimuoti ir prognozuoti netiesiškumus, kurie būdingi indeksų kitimui;
- 2) jautriai reaguoti į unikalius, retai pasikartojančius ūkinius reiškinius;
- 3) turėti kompleksines integruotas fundamentines ir technines analizės priemones.

Literatūros [1; 3; 4; 5; 8] analizė parodė, kad kintamųjų sąveikai aprašyti nepakanka tiesinių

funkcijų, ir multidimensinis tiesinės regresijos modelis nėra optimalus. Naudojant tiesinius modelius negaunamas norimas VP indeksų kitimo analizės ir prognozės tikslumas [5, p. 231]. VP rinkos kainos indeksų kitimai nulemti retai pasikartojančių, nepastovių ir netipiškų veiksnių, todėl indeksų kitimo analizei pasirinktas netiesinis atgalinės grįžties (angl. *backpropagation*) dirbtinių neuroninių tinklų metodas. Dirbtinių neuroninių tinklų metodai tenkina visas tris išvardytas indeksų kitimo tyrimo metodams privatomas sąlygas.

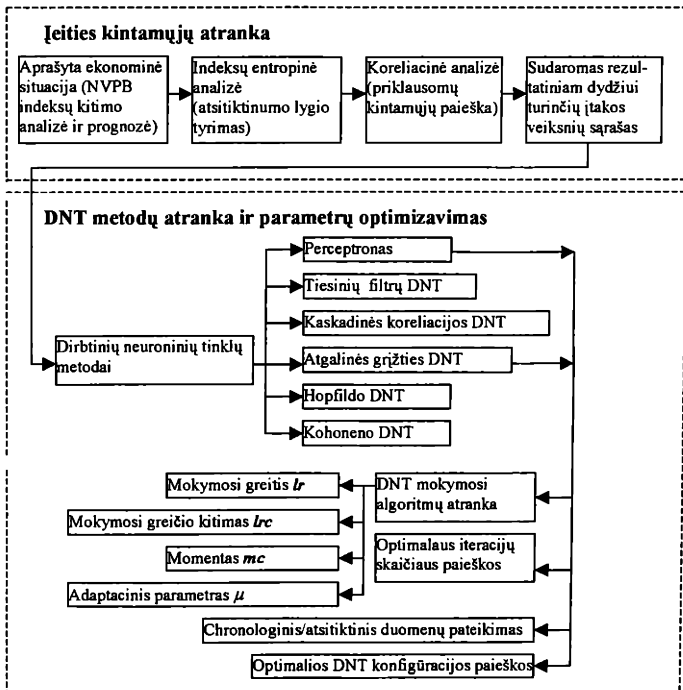
Dirbtinių neuroninių tinklų metodas remiasi 1 paveiksle pateikiama apibendrinta DNT schema. Modelio įeities kintamieji p (indeksų reikšmės ir makroekonominiai rodikliai $p_1 \dots p_k$) patenka į pirmąjį neuronų sluoksnį, kurį sudaro



1 pav. Tyrimams naudota bendra dirbtinio neuroninio tinklo schema

s neuronų. Kiekvienas neuronas turi savo įeities svorio koeficientus W , atlieka sumavimą (n funkcija) ir transformavimą (a funkcija) [5, p. 8], žr. 1 pav. Įeities kintamųjų ir atitinkamų svorio koeficientų reikšmės sudauginamos ir sumuojamos su nuokrypiais b (neurono keičiamas parametras). Gautos sumos yra transformuojamos naudojant pasirinktą transformavimo funkciją. Kiekvienas neuronų sluoksnis gali naudoti skirtingas transformavimo funkcijas. Neuroninio tinklo įeities vietoje yra išieities neuronas, turintis tiesinę transformavimo funkciją.

Kiekvienas neuronų sluoksnis turi savo svorio matricą W , nuokrypio vektorių b ir išieities matricą A . Daugiasluoksnių tinklų paskutinis sluoksnis yra išieities, o visi kiti – slepiamieji. Atgalinės grįžties neuroniniai tinklai mokosi, išieities neuro duomenis $d(t)$ sulygindami su tiksliniais (testiniais) duomenimis $d^T(t)$. Pradinėmis sąlygomis visų neuronų įeities svorio koeficientai („svoriai“) ir nuokrypiai yra nuliniai, o vėliau priklausomai nuo pasirinkto DNT modelio adaptuojami naudojant Delta taisyklę [5, p. 404]. Svoriai adaptuojami taip,



2 pav. Įeities kintamųjų ir DNT metodų atrankos bei parametrų optimizavimo struktūruota schema

kad būtų minimizuojamas tinklo išeities ir testinių duomenų skirtumas. Daugiasluoksniai tinklai yra pajėgūs atlikti įvairių funkcijų analizę ir prognozavimą [4, p. 160; 5, p. 7]. Pavyzdžiui, dviejų sluoksnių tinklas (kur pirmasis sluoksnis yra sigmoidinis, o antrasis – tiesinis) gali būti išmokytas aproksimuoti kiekvieną funkciją su baigtiniu trūkių skaičiumi.

Tyrimams naudotas ne etapinis, o paketinis (angl. *batch*) DNT mokymo būdas, kai svorių matrica adaptuojama po viso įeities vektorius duomenų perleidimo per DNT. Laikoma, kad visi įeities kintamieji yra tolydūs dydžiai, jie sunorminti. Tyrimams naudotos įvairios transformacijos ir mokymo funkcijos. Daugiausiai tyrimų atlikta su perceptroniniais atgalinės grįžties (angl. *backpropagation*) tinklais [11; 12]. Iteracijų skaičius, tinklo konfigūracijų, mokymo algoritmų, žingsnio paklaidų, priartėjimo momentų ir kitų optimalių tinklo parametrų radimas aprašomas tolesniuose skyriuose.

NVPB indeksų tyrimai atlikti naudojantis 1 paveiksle pateiktu apibendrintu DNT metodu. Tačiau norint neuroninius tinklus pritaikyti konkrečioms uždaviniais spręsti reikėjo sudaryti struktūruotą tyrimo schemą, iš kurios nuosekliai būtų matoma įeities kintamųjų ir DNT metodų atranka bei parametrų optimizavimas. Joje skiriami du pagrindiniai etapai (2 pav.). Remiantis šia schema aprašoma ir atliktų tyrimų eiga.

Įeities kintamųjų atranka

Aprašoma ekonominė situacija ir išskiriami svarbiausi ekonominiai veiksniai, lemiantys Lietuvos nacionalinės vertybinių popierių biržos kainų indeksų LITIN, LITIN-A ir LITIN-VVP kitimą. Tyrimo laikotarpis apėmė periodą nuo 1997 01 01 iki 2001 01 17. Indeksų kitimo kreivės pateikiamos 3 paveiksle. Daroma prielaida, kad minėtų indeksų kitimą bendru

atveju gali lemti tiek endogeniniai, tiek egzogeniniai veiksniai (4 pav.).

Santykinis matas, galintis parodyti esant indeksams darančių įtaką priklausomus kintamuosius, yra entropija (dydžio atsitiktinumo lygio indikatorius). Entropijos tyrimams pasirinkti šie vertybinių popierių kainos indeksai:

a) Lietuvos NVPB indeksai LITIN, LITIN-A ir LITIN-VVP,

b) JAV indeksai Dow Jones ir S&P500, ES indeksas EUREX/EURO, Rusijos indeksas RTS.

Atsitiktinio dydžio entropija H skaičiuojama [9, p. 99] taip:

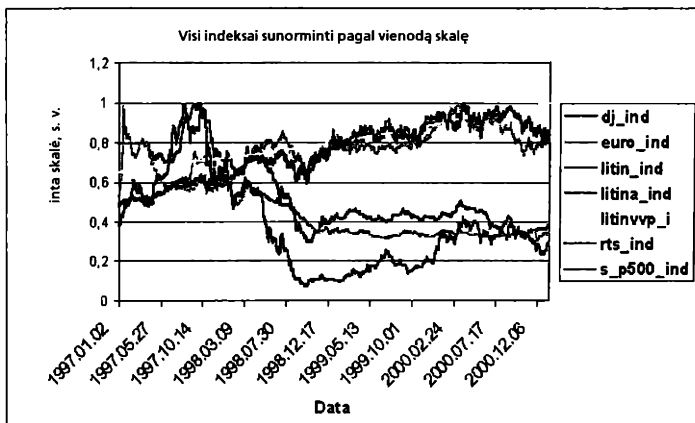
$$H = - \int_{t_1}^{t_2} p(t) * \ln p(t) * dt.$$

Entropija yra didžiausia, kai reikšmių tikimybės yra vienodos $p_1 = p_2 = \dots = p_n$ (tai reiškia, kad X yra atsitiktinis dydis), o mažiausia, kai vienos reikšmės tikimybė lygi 1, o kitų reikšmių tikimybės lygios 0 (tai reiškia, kad X nėra atsitiktinis dydis). Mūsų tyrimo sąlygomis kiekvienam indeksui nustatytos galimos maksimali H_{\max} ir minimali H_{\min} entropijos reikšmės, t. y. nustatomas leidžiamas kitimo intervalas. Tada nustatoma kiekvieno indekso entropija H . 1 lentelėje pateikiami atliktos indeksų entropijos analizės rezultatai.

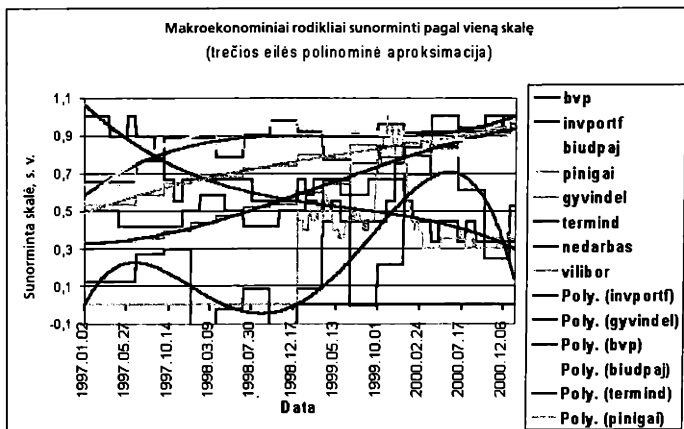
Atliktas indeksų entropijos tyrimas rodo, kad LITIN ir LITIN-A indeksams gali turėti įtakos egzogeniniai veiksniai, nes jiems būdingas mažesnis santykinis atsitiktinumo lygis negu kitiems tirtiems indeksams. Tolesnis tyrimo tikslas – išsiaiškinti tuos ekonominius veiksnius, kurie, lemdami Lietuvos LITIN indeksų kitimą, mažina pastarųjų atsitiktinumo lygį. Tai ypač aktualu finansų rinkų dalyviams, kurie nedaug padidinę prognozės tikslumą, gali gauti gerokai didesnę pelną [4, p. 497].

1 lentelė. Indeksų entropijos lygiai

Entropija	LITIN	LITIN-A	LITIN-VVP	RTS	S&P50
H_{max}	4,5	5,08	4,20	3,99	4,39
H_{min}	0	0	0	0	0
H	3,9	4,28	4,18	3,63	4,21
H (% pagal H_{max})	87	84	99	91	96



3 pav. Vertybinių popierių kainos indeksų kitimas nagrinėjamu periodu [7]



4 pav. Lietuvos makroekonominių rodiklių kitimas nagrinėjamu periodu [10]

Lietuvos VP indeksų kitimą lemančių egzogeninių veiksnių paieškai naudota koreliacinė analizė [9, p. 98]. Iš galimų makroekonominių veiksnių, atlikus pirminę koreliacinę analizę, atrinkti tik labiausiai NVPB indeksų kitimui turintys įtakos veiksniai, t. y.

a) šalies makroekonominiai rodikliai: BNP, nedarbo lygis, infliacija, tarpbankinių palūkanų norma, terminuotų indėlių norma, gyventojų indėliai, investicijų portfelis, biudžeto pajamos, pinigų masė M2;

b) kitų šalių kainų indeksai: JAV indeksai Dow Jones ir S&P500, ES indeksas EUREX/EURO, Rusijos indeksas RTS.

Indeksų koreliacijos tyrimų rezultatai pateikiami 2 lentelėje, o indeksų ir makroekonominių rodiklių koreliacijos tyrimai – 3 lentelėje.

Koreliaciniai tyrimai rodo, kad yra ryški pačių indeksų bei indeksų ir atitinkamų makroekonominių rodiklių koreliacija. Vadinasi, norint analizuoti ir prognozuoti NVPB indeksų LITIN, LITIN-A ir LITIN-VVP kitimą, būtina įskaityti pirmiau išvardytus egzogeninius veiksnius. Remiantis šia išvada tolesniais tyrimo etapais buvo sudaromi kompleksiniai analizės ir prognozės modeliai, kuriuose buvo įskaityti veiksniai, koreliuojantys su rezultatinu dydžiu.

DNT metodų atranka ir parametrų optimizavimas

Skirtingiems uždaviniams spręsti naudojami skirtingų klasių neuroniniai tinklai. Pavyzdžiui, autoregresinio trendo tyrimams naudojamas pats

2 lentelė. VP indeksų koreliacijos koeficientai

	LITIN	LITIN-A	LITIN-VVP	Dow Jones	EURO	RTS	S&P500
LITIN	X		-0,76	-0,72	-0,70	0,88	-0,75
LITIN-A		X	-0,84	-0,87	-0,84	0,74	-0,89
LITIN-VVP	-0,76	-0,84	X		0,83	-0,52	
Dow Jones	-0,72	-0,87		X		-0,53	
EURO	-0,70	-0,84	0,83		X	-0,60	
RTS	0,88	0,74	-0,52	-0,53	-0,60	X	-0,57
S&P500	-0,75	-0,89				-0,57	X

3 lentelė. VP indeksų ir makroekonominių rodiklių koreliacijos koeficientai

	BVP	termind	invportf	biudpaj	pinigai	gyvind	nedarbas	VILIBOR
LITIN	-0,61	0,71	-0,18	-0,40	-0,81	-0,78	-0,58	0,20
LITIN-A	-0,59	0,78	-0,31	-0,40	-0,87	-0,84	-0,67	-0,01
LITIN-VVP	0,67	-0,87	0,55	0,36				-0,39
Dow Jones	0,63	-0,86	0,56	0,47			0,84	-0,26
EURO	0,60	-0,79	0,46	0,52	0,85	0,83	0,72	-0,13
RTS	-0,50	0,55	0,03	-0,46	-0,61	-0,56	-0,31	-0,49

Žymėjimai:

$0,5 < k > 0,9$



$-0,9 < k < -0,5$



paprasčiausias neuroninis tinklas – perceptronas (angl. *perceptron*), nes šiuo atveju paslėptame sluoksnyje užtenka vieno vienintelio neurono, kuris veikia kaip multidimensinis tiesinis regresorius.

Visai kitokie reikalavimai keliami tinklams, naudojamiems modeliuoti autoregresinių priežastinių ir priežastinių vertybinių popierių indeksų kitimą. Naudojamas modelis privalo gerai aproksimuoti ir prognozuoti netiesiškumus, kurie būdingi indeksų kitimui; jautriai reaguoti į unikalius, retai pasikartojančius ūkiniui reiškinius; turėti kompleksines integruotas fundamentinės ir techninės analizės priemones. Konstruojant dirbtinius neuroninius tinklus, galinčius tenkinti pirmiau išvardytus reikalavimus, reikia atlikti DNT optimizavimą. Pagrindiniai šio proceso žingsniai:

- 1) efektyviausių DNT mokymo algoritmų radimas;
 - 2) tinklo mokymo optimalaus iteracijų skaičiaus radimas;
 - 3) optimalios duomenų pateikimo formos radimas;
 - 4) tinkamiausios DNT konfigūracijos radimas;
 - 5) tyrimų pasikartojimo patikrinimas.
- Toliau iš eilės aprašomas kiekvienas žingsnis.

Efektyviausių DNT mokymo algoritmų radimas

Viena iš pagrindinių DNT sudedamųjų dalių yra tinklo mokymo algoritmai. Jie lemia tinklo mokymosi greitį, tikslumą, patikimumą ir bendrą funkcionalumą. Yra sukurta kelios dešimtys skirtingų DNT mokymo algoritmų [11; 12; 13]. Atliekant tyrimą išbandyti šie pagrindiniai tinklo mokymo algoritmai:

- Gradientinio nusileidimo algoritmas (angl. *gradient descent*), žr. 5 pav.;
- Grupinio gradientinio momentinio nusileidimo algoritmas (angl. *batch gradient descent with momentum*);
- Kintamo mokymosi greičio algoritmas (angl. *variable learning rate*), žr. 6 pav.;
- Jungtinis gradientinis algoritmas (angl. *conjugate gradient*);
- Levenbergo-Marko algoritmas.

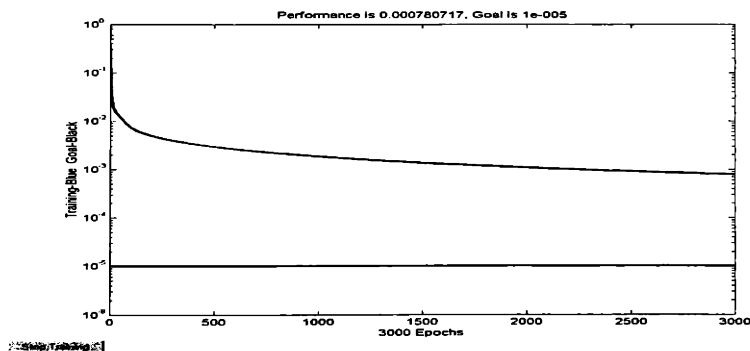
4 lentelėje pateikiami atgalinės grįžties DNT mokymo, naudojant skirtingus mokymo algoritmus, tyrimo rezultatai. Skirtingi algoritmai lyginami pagal vidutinį kvadratinį nuokrypį (VKN), R^2 determinacijos koeficientą, mokymo trukmę. DNT tyrimo rezultatai lyginami su tiesinės regresijos rezultatais. Neuroninio tinklo

4 lentelė. DNT mokymo etapo skirtingų mokymo algoritmų palyginimas tarpusavyje ir su tiesine regresija

Mokymo algoritmo pavadinimas (MatLab f-ja)	DNT		Tiesinė regresija		Mokymo laikas, min.
	VKN (mse)	R^2 statistika	VKN (mse)	R^2 statistika	
Grupinis gradientinis nusileidimas (traingd, lr = 1,2)	0,00078	0,9599	0,000088	0,9987	29
Grupinis gradientinis momentinis nusileidimas (traingdm, lr = 1,2, mc = 0,35)	0,00054	0,9641	0,000088	0,9987	31
Kintamo mokymosi greičio (traingda, lr = 0,9, lr_inc = 1,05, lr_dec = 0,7)	0,00043	0,9862	0,000088	0,9987	28
Jungtinis gradientinis (traincgf, f-ja srchcha)	0,000060	0,9984	0,000088	0,9987	63
Levenberg-Marquet (trainlm, 30 epochu)	0,000056	0,9981	0,000088	0,9987	23

5 lentelė. Testavimo etapo skirtingų DNT mokymo algoritmų palyginimas tarpusavyje ir su tiesine regresija

Mokymo algoritmo pavadinimas (MatLab f-ja)	DNT		Tiesinė regresija	
	VKN (mse)	R ² statistika	VKN (mse)	R ² statistika
Grupinis gradientinis nusileidimas (traingd, lr = 1,2)	0,0707	0,1979	0,0098	1,2117
Grupinis gradientinis momentinis nusileidimas (traingdm, lr = 1,2, mc = 0.35)	0,1098	1,8148	0,0098	1,2117
Kintamo mokymosi greičio (traingda, lr = 0.9, lr inc = 1,05, lr dec = 0,7)	0,0918	0,7182	0,0098	1,2117
Jungtinis gradientinis (traincgf, f-ja srchcha)	0,1278	2,4454	0,0098	1,2117
Levenberg-Marquet (trainlm, 30 epochų)	0,0545	1,6852	0,0098	1,2117

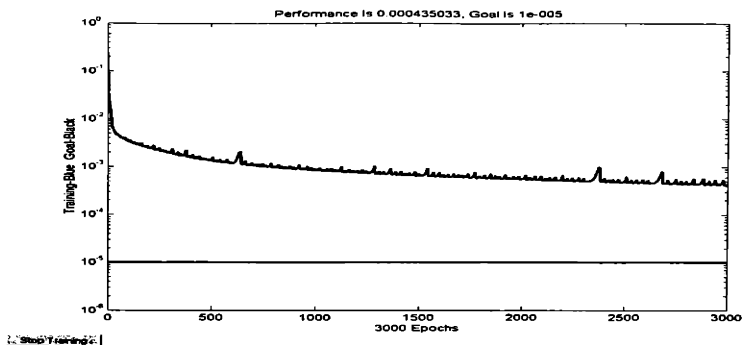


5 pav. DNT mokymo gradientinio nusileidimo funkcija (VKN lygio priklausomybė nuo mokymo iteracijų skaičiaus). Panaudotas grupinio gradientinio nusileidimo (traingd, lr = 1,2) DNT mokymo algoritmas. Autoregresinis priežastinis modelis

topologija parinkta pagal DNT konfigūracijos optimizavimo taisykles [5, p. 62; 6]. DNT testavimo etapo analogiški tyrimų duomenys pateikiami 5 lentelėje.

Į DNT įėjimus paduodami 23 įeities kintamieji (indeksų vertės, makroekonominiai rodikliai). Duomenys pateikiami chronologine tvarka. DNT mokymui pateikiama 997 duomenų eilutės periodu nuo 1997 01 01 iki 2000 12 01, o išmokyto tinklo testavimui pateikiama 28 duomenų eilutės periodu nuo

2000 12 01 iki 2001 01 17. Tinklas mokosi iki 3000 iteracijų. Tinklas nustoja mokytis, kai pasiekiamas nustatytas minimalus vidutinis kvadratinis nuokrypis (VKN), ribinis gradientas arba nustatytas maksimalus iteracijų neuronai, 15 paslėptame sluoksnyje ir vienas išėities. Transformacijos funkcijos netiesinės (logsigmoidinė transformacijos funkcija įėjime ir paslėptame sluoksnyje; tiesinė – išėjimo sluoksnyje).



6 pav. DNT mokymo gradientinio nusileidimo funkcija (VKN lygio priklausomybė nuo mokymo iteracijų skaičiaus). Panaudotas kintamo mokymosi greičio (traingda, $lr = 0,9$, $lr_inc = 1,05$, $lr_dec = 0,7$) DNT mokymo algoritmas. Autoregresinis priežastinis modelis

Tai gi efektyviausi DNT mokymo algoritmai yra jungtinis gradientinis bei Levenbergo-Marko. Tai algoritmai, naudojantys kvazi Niutono metodus. Jie tiksliausiai ir greičiausiai aproksimuoja funkciją (tiksliau negu tiesinė regresija) bei tiksliausiai prognozuoja.

Tinklo mokymo optimalaus iteracijų skaičiaus radimas

Teoriškai dirbtinis neuroninis tinklas gali mokytis be galo, t. y. be galo konverguoti į tikslo funkciją. Yra dvi pagrindinės priežastys, kurios praktiškai sustabdo konvergavimą: ribotas laikas ir persimokymas (angl. *overfitting*). Laiko problema iš dalies gali būti sprendžiama didinant kompiuterio pajėgumą, o persimokymas susijęs su neuroninių tinklų ypatumu: kuo ilgiau mokomas tinklas, tuo tiksliau jis sugeba aproksimuoti, tačiau blogėja jo prognozavimo tikslumas, t. y. tinklas visiškai „įsimena“ funkciją, prarasdamas galimybę numatyti jos kitimą (6 lentelė).

Optimalus iteracijų skaičius kiekvienam uždaviniui randamas bandymais [5, p. 415], nes

universalios taisyklės dažnai nepasiteisina. Tai labai apsunkina tyrimus ir reikia automatizavimo, naudojant specializuotas DNT tinklų sudarymo programas [5, p. 418].

Optimalios duomenų pateikimo formos radimas

Paprastai mokymo duomenys tinklui pateikiami atsitiktine tvarka. Tai pasiteisina, jeigu vyrauja daugybė finansinių duomenų trendo pokyčių, nes atsitiktine duomenų pateikimo tvarka apmokytas tinklas geriau išmoka aproksimuoti viso duomenų paketo mastu. Kai per visą duomenų intervalą vyrauja vienas arba keli pagrindiniai trendai, tai verta mokyti, duomenis pateikiant chronologine tvarka, nes tinklas įtraukia trendo kryptį į savo sprendinius.

7 lentelėje parodyti tinklo aproksimavimo ir prognozavimo rezultatai, kai įteiktas duomenys buvo pateikti atsitiktine tvarka. Palyginus 6 ir 7 lenteles (abiem atvejais vienodos tyrimo sąlygos, skiriasi tik duomenų pateikimo tvarka), akivaizdžiai matyti, kad aproksimavimas ir prognozavimas gerokai tikslesnis, kai duomenys

6 lentelė. DNT mokymo iteracijų skaičiaus įtakos LITIN kreivės aproksimavimo ir prognozavimo rezultatams tyrimas. Tyrimo rezultatai lyginami su tiesine regresija

Iteracijų skaičius	DNT		Tiesinė regresija		Mokymo laikas, min.
	VKN (mse)	R ² statistika	VKN (mse)	R ² statistika	
<i>Mokymo etapas</i>					
2	0,0014	0,8958	0,000088	0,9987	2
<i>Testavimo etapas</i>					
2	0,0168	0,7286	0,0098	1,2117	X
<i>Mokymo etapas</i>					
10	0,000097	1,0014	0,000088	0,9987	12
<i>Testavimo etapas</i>					
10	0,0313	1,2618	0,0098	1,2117	X
<i>Mokymo etapas</i>					
30	0,000056	0,9981	0,000088	0,9987	23
<i>Testavimo etapas</i>					
30	0,0545	1,6852	0,0098	1,2117	X

Pastaba. Panaudotas Levenbergo-Marko (trainlm) DNT mokymo algoritmas. Tinklo topologija 23 : 15 : 1.

7 lentelė. DNT mokymo ir testavimo, duomenis pateikiant atsitiktine tvarka, tyrimas

Iteracijų skaičius	DNT		Tiesinė regresija		Mokymo laikas, min.
	VKN (mse)	R ² statistika	VKN (mse)	R ² statistika	
<i>Mokymo etapas</i>					
2	0,0082	0,9551	0,000088	0,9987	2
<i>Testavimo etapas</i>					
2	0,0930	1,5199	0,0096	1,2450	X
<i>Mokymo etapas</i>					
10	0,000068	0,9972	0,000088	0,9987	12
<i>Testavimo etapas</i>					
10	0,0716	1,0295	0,0096	1,2450	X
<i>Mokymo etapas</i>					
30	0,000061	0,9984	0,000088	0,9987	23
<i>Testavimo etapas</i>					
30	0,1026	2,8544	0,0096	1,2450	X

Pastaba. Panaudotas Levenbergo-Marko (trainlm) DNT mokymo algoritmas. Tyrimo rezultatai lyginami su tiesine regresija. Tinklo topologija 23 : 15 : 1.

pateikiami chronologine tvarka. Vadinas, LITIN indekso kitimą lemia keli pagrindiniai trendai, kuriuos, duomenis pateikiant chronologine tvarka, tinklas sugeba išmokti ir numatyti.

Tinkamiausios DNT konfigūracijos radimas

Tyrimo rezultatai labai priklauso nuo pasirinktos tinklo konfigūracijos, t. y. nuo sluoksnių ir neuronų bei neuronų jungčių skaičiaus [5, p. 62;

8 lentelė. Skirtingų DNT konfigūracijų įtakos tinklo mokymo ir testavimo rezultatams tyrimas

Neuronų skaičius sluoksniuose	Mokymo etapas			Testavimo etapas	
	VKN (mse)	R ² statistika	Mokymo laikas, min.	VKN (mse)	R ² statistika
Tiesinė regresija	0,000088	0,9987		0,0098	1.2117
10 : 5 : 1	0,000087	0,9963	2	0,0441	0,5487
10 : 15 : 1	0,00012	1,0016	3	0,0166	1,0676
15 : 10 : 1	0,00011	0,9911	3	0,0095	1,2261
15 : 10 : 1 (20 iteracijų)	0,000057	0,9987	6	0,0308	1,6425
15 : 15 : 1	0,000074	0,9954	5	0,0348	1,4536
23 : 5 : 1	0,00013	0,9916	4	0,0398	0,7501
23 : 10 : 1	0,00010	0,9937	7	0,0240	1,1654
23 : 15 : 1	0,000097	1,0014	12	0,0313	1,2618
23 : 20 : 1	0,000086	0,9905	13	0,0188	1,4260
23 : 5 : 10 : 1	0,000095	0,9948	12	0,0574	1,5011
23 : 10 : 5 : 1	0,0012	1,0812	12	0,0146	0,8340

Pastaba. DNT mokymui naudojamas Levenbergo-Marko algoritmas. Kur nenurodyta kitaip, iteracijų skaičius lygus 10.

5, p. 602]. Bendru atveju, jeigu neuronų ir jų jungčių yra per mažai, gaunami prasti aproksimavimo rezultatai, o jei per daug, – prasti prognozės rezultatai. Daugelis autorių [4; 5; 8] pažymi stiprią optimalios tinklo konfigūracijos priklausomybę nuo kintamųjų skaičiaus, kintamųjų ryšių, duomenų kiekio. 8 lentelėje pateikiami tinkamiausios mūsų tyrimui (autoregresinio priežastinio ir priežastinio modelio duomenų struktūrai) tinklo konfigūracijos tyrimai.

Iš šios lentelės matome, kad esant 15 : 10 : 1 konfigūracijai (10 iteracijų), gaunami, palyginti su multidimensine tiesine regresija, geresni prognozės, o prastesni aproksimavimo rezultatai. Tuo tarpu, pavyzdžiui, esant 23 : 20 : 1 tinklo konfigūracijai, gaunami geresni aproksimavimo, bet prastesni prognozavimo rezultatai. Esant didesniai sluoksnių ar svorių skaičiui, nukentčia prognozavimo tikslumas, t. y. pasireiškia persimokymas [11]. Sudėtingėjant tinklo konfigūracijai ar didėjant bendram svorių skaičiui, sparčiai didėja procesoriaus darbo laikas, naudojami didesni kompiuterio resursai.

Tyrimai parodė sudėtingą ir nevienareikšmišką dirbtinių neuroninių tinklų konfigūracijos įtaką indeksų kitimo aproksimavimui ir prognozavimui.

Tyrimų kartotinumumas

Tiriant kiekvieną modelį labai svarbu nustatyti tyrimo rezultatų pasikartojimą [12; 13]. Tai parodo galimybę identiškoms tyrimo sąlygomis gauti tuos pačius rezultatus. 9 lentelėje pateikiami tyrimo rezultatų pasikartojimo tyrimai.

Mokymo etapu VKN kinta +/-40 proc., o determinacijos koeficientas +/-9 proc. nuo atitinkamo dydžio vidurkio, o testavimo etapu VKN kinta +/-25 proc., o determinacijos koeficientas +/-40 proc. Tai rodo, kad DNT mokymo ir testavimo rezultatai daug priklauso nuo pirminių svorių ir nuokrypių reikšmių. Pastebėta, kad rezultatų kartotinumumas žymiai padidėja esant didesniai iteracijų skaičiui, kai VKN ir determinacijos koeficientas konverguoja į savo stabilias reikšmes.

9 lentelė. DNT tyrimo rezultatų pasikartojimo tyrimas

Bandymo Nr.	Mokymo etapas			Testavimo etapas	
	VKN (mse)	R ² statistika	Mokymo laikas, min.	VKN (mse)	R ² statistika
Tiesinė regresija	0,0023	0,9658		0,3583	5,4228
1	0,0022	0,9098	2	0,1087	1,8546
2	0,0032	0,8983	2	0,1085	1,5174
3	0,0011	0,9400	2	0,1045	1,2823
4	0,00035	0,9908	2	0,0849	1,1094
5	0,0026	0,8486	2	0,1321	0,9702

Pastaba. DNT mokymui naudojamas Levenbergo-Marcko algoritmas. Tinklo konfigūracija 15 : 10 : 1. Mokymo iteracijų skaičius 10.

DNT metodų taikymas trendo modelių tyrimams

Atlikus įeities kintamųjų atranką, nustatyti veiksniai, labiausiai lemiantys Lietuvos vertybių popierių indeksų kitimą (2 ir 3 lentelės). Suradus optimalius DNT metodus ir jų parametrus (1, 2 paveikslai ir 4, 5, 6, 7, 8, 9 lentelės), buvo parengtos Lietuvos VP indeksų kitimo kompleksinės analizės priemonės, apimančios ne tik techninius istorinius indeksų pokyčius, bet ir fundamentinius makroekonominis rodiklius. Taigi buvo sudarytos, naudojant DNT metodus, reikalingos nacionalinės vertybių

popierių biržos indeksų autoregresinio, autoregresinio priežastinio ir priežastinio trendo modelių tyrimo prielaidos [3, p. 86]. Toliau trumpai išdėstomi tyrimų rezultatai.

Autoregresinis trendo modelis

Tai techninė [1, p. 10] indekso verčių kitimo analizės priemonė, nagrinėjanti tik techninių istorinių nagrinėjamo indekso vertės pokyčių poveikį. Pateikiami NVPB indeksų LITIN, LITIN-A ir LITIN-VVP kreivių aproksimavimo, naudojant patį paprasčiausią neuroninį tinklą – perceptroną, tyrimo rezultatai. Į percep-

10 lentelė. NVPB indeksų autoregresinio trendo tyrimas

	Vidutinis kvadratinis nuokrypis (mse*)	
	Perceptronas (DNT)	Tiesinė regresija**
LITIN	71,9	72,1
LITIN-A	612,3	635,9
LITIN-VVP	0,16	0,17

Pastabos. Perceptroniniame modelyje naudotas Levenberg-Marquet mokymo algoritmas; skaičiuojant vidutinį kvadratinį nuokrypį, indekso vertės nebuvo sunormintos į vienetą.

* VKN (angl. *mean square error*) skaičiuojama: $VKN = \frac{\sum_{i=1}^m (\bar{y}_i - \bar{y})^2}{m}$.

** Tiesinė regresija: $y = \sum_i \alpha_i \cdot x_i + \alpha_0$, čia x_1 – 1 dienos indekso vertė, x_2 – 3 d., x_3 – 5 d.


troną paduodami trys įėjimai: 1, 3 ir 5 dienų atitinkamo indekso reikšmės. Perceptrono mokymui pateikiama 1028 LITIN indekso reikšmės periodu nuo 1997 01 01 iki 2001 01 01. Perceptrono mokymas vykdomas iki 1000 iteracijų. Perceptroniniame modelyje papildomai kitų tinklo parametrų nustatinėti nereikia. Tyrimai atliekami naudojant MATLAB 6.0 v. Neural Network Toolbox programinę įrangą.

Iš 10 lentelės matome, kad netgi pačio paprasčiausio perceptrono atveju, kai neuro-niniame tinkle tėra du neuronai, tiesinės


regresijos metodas nusileidžia pagal vidutinį kvadratinį nuokrypį dirbtiniam neuroniniam tinklui (7, 8 ir 9 paveikslai).

Autoregresinis priežastinis trendo modelis


Tai kompleksinė [14, p. 10; 5, p. 497] indeksų kitimo analizės priemonė, apimanti ne tik techninius istorinius indekso vertės pokyčius, bet ir fundamentinius makroekonominius šalies rodiklius bei kitų šalių vertybinių popierių indeksus.



7 pav. LITIN indekso kitimo kreivės aproksimavimas naudojant dvisluksnį perceptroną



8 pav. LITIN-A indekso kitimo kreivės aproksimavimas naudojant dvisluksnį perceptroną



9 pav. LITIN-VVP indekso kitimo kreivės aproksimavimas naudojant dvisuoksnį perceptroną

Tiriamas LITIN indekso kitimo autoregresinis priežastinis trendo modelis. Į tinklo įėjimus paduodami 23 įeities kintamieji:

- 1) 1, 3 ir 5 dienų LITIN indeksų reikšmės,
- 2) LITIN-A ir LITIN-VVP reikšmės (einaimosios bei 1, 3 ir 5 dienų),
- 3) kitų šalių VP indeksų vertės (JAV – Dow Jones ir S&P, ES – EUREX/DAX, Rusijos – RTS),
- 4) makroekonominiai rodikliai (nedarbo lygis, infliacija, tarpbankinių palūkanų norma, terminuotų indėlių norma, gyventojų indėliai, investicijų portfelis, biudžeto pajamos, pinigų masė M2).

DNT mokymui pateikiamos 997 duomenų eilutės periodu nuo 1997 01 01 iki 2000 12 01, o išmokyto tinklo testavimui pateikiamos 28 duomenų eilutės nuo 2000 12 01 iki 2001 01 17. Tinklas mokomas iki 3000 iteracijų. Tinklas nustoja mokytis, kai pasiekiamas nustatytas minimalus vidutinis kvadratinis nuokrypis (VKN), ribinis gradientas arba nustatytas iteracijų skaičius. Tyrimai atliekami naudojant MATLAB 6.0 v. Neural Network Toolbox programinę įrangą.

Autoregresinio priežastinio trendo modelio veiksniai yra ne tik istorinės tiriamojo indekso vertės, bet ir kiti, koreliuojantys su nagrinėjamu indeksu (2 ir 3 lentelės) egzogeniniai kintamieji


[14]. Kadangi tiriamąjį rezultatinių dydį nusako daugiau jo kitimą lemiančių įeities kintamųjų, todėl toks modelis viena ar net dviem eilėmis tiksliau aproksimuoja LITIN indekso kitimą, palyginti su autoregresiniu trendo modeliu. Tai, pagal VKN palyginus aproksimavimo tikslumus, matyti iš 4 ir 10 lentelių. DNT metodų atrankos ir parametrų optimizavimo etapu dauguma tyrimų buvo atlikti naudojant pirmiau aprašytą autoregresinį priežastinį trendo modelį, todėl 4, 5, 6 ir 7 lentelės parodyti šio modelio tyrimų rezultatai, kurie stipriai priklauso nuo DNT parametrų. LITIN indekso kitimo kreivės aproksimavimo, naudojant autoregresinį priežastinį trendo modelį, rezultatai pavaizduoti 10, 11 ir 12 paveiksluose, o prognozavimo – 13, 14 ir 15 paveiksluose.

Priežastinis trendo modelis

Tai fundamentinė [1, p. 14; 15] indeksų kitimo analizės priemonė, apimanti tik fundamentinius makroekonominius šalies rodiklius bei kitų šalių vertybinių popierių indeksus.

Tiriamas LITIN indekso kitimo priežastinis trendo modelis. Į tinklo įėjimus paduodami 20 įeities kintamųjų:


- 5) LITIN-A ir LITIN-VVP reikšmės (einaimosios bei 1, 3 ir 5 dienų),




10 pav. LITIN indekso kėtimo kreivės aproksimavimas naudojant DNT (3000 iteracijų) ir tiesinę regresiją. Panaudotas grupinio gradientinio nusileidimo (traingd, lr = 1,2) DNT mokymo algoritmas. DNT konfigūracija 23 : 15 : 1




12 pav. LITIN indekso kėtimo kreivės aproksimavimas naudojant DNT ir tiesinę regresiją. Panaudotas Levenbergo-Markovo (trainlm, 30 iteracijų) DNT mokymo algoritmas. DNT konfigūracija 23 : 15 : 1




11 pav. LITIN indekso kėtimo kreivės aproksimavimas naudojant DNT (3000 iteracijų) ir tiesinę regresiją. Panaudotas jungtinis gradientinio nusileidimo (traincgf, f-ja srchcha) DNT mokymo algoritmas. DNT konfigūracija 23 : 15 : 1



13 pav. LITIN indekso kĕtimo prognozė (nuo 1 iki 32 dienu). Panaudotas grupinio gradientinio nusileidimo (traingd, lr = 1,2; 3000 iteracijų) DNT mokymo algoritmas. DNT konfigūracija 23 : 15 : 1



14 pav. LITIN indekso prognozė (nuo 1 iki 32 dienu). Panaudotas Levenbergo-Marکو DNT mokymo algoritmas (30 iteracijų). DNT konfigūracija 23 : 15 : 1



15 pav. LITIN indekso prognozė (nuo 1 iki 32 dienu). Panaudotas Levenbergo-Marکو (trainlm, 10 iteracijų) DNT mokymo algoritmas. DNT konfigūracija 15 : 10 : 1

6) kitų šalių VP indeksų vertės (JAV – Dow Jones ir S&P, ES – EUREX/DAX, Rusijos – RTS),

7) makroekonominiai rodikliai (nedarbo lygis, infliacija, tarpbankinių palūkanų norma, terminuotų indėlių norma, gyventojų indėliai, investicijų portfelis, biudžeto pajamos, pinigų masė M2).


Analogiškai kaip ir taikant autoregresinį priežastinio trendo modelį DNT mokymui pateikiamos 997 duomenų eilutės periodu nuo 1997 01 01 iki 2000 12 01, o išmokyto tinklo testavimui pateikiamos 28 duomenų eilutės periodu nuo 2000 12 01 iki 2001 01 17. Tinklas mokomas iki 3000 iteracijų. Tinklas nustoja mokytis, kai pasiekiamas nustatytas minimalus vidutinis kvadratinis nuokrypis (VKN), ribinis gradientas arba nustatytas iteracijų skaičius. Tyrimai atliekami naudojant MATLAB 6.0 v. Neural Network Toolbox programinę įrangą.

Priežastinio trendo modelio veiksniai yra tik egzogeniniai kintamieji [14]. Tokio modelio aproksimavimo ir prognozavimo galimybės labai priklauso nuo egzogeninių veiksnių ir


tiriamojo indekso koreliacijos. LITIN indekso stipri koreliacija su LITIN-A ($k=0,93$) indeksu, Rusijos RTS ($k = 0,88$) indeksu, pinigų masė M2 ($k = -0,81$), gyventojų indėliais ($k = -0,78$) bei terminuotais indėliais (2 ir 3 lentelės), todėl sukonstruotas priežastinis modelis gerai aproksimuoja ir prognozuoja LITIN indekso kitimą. Optimizuojant DNT metodų atranką ir parametrus dalis tyrimų buvo atlikti naudojant pirmiau aprašytą priežastinį trendo modelį, todėl 8 ir 9 lentelės rodo šio modelio tyrimų rezultatus, kurie stipriai priklauso nuo DNT parametrų. LITIN indekso kitimo kreivės aproksimavimo, naudojant priežastinį trendo modelį, rezultatai pavaizduoti 16, 17 ir 18 paveiksluose, o prognozavimo – 13, 14 ir 15 paveiksluose.

Išvados

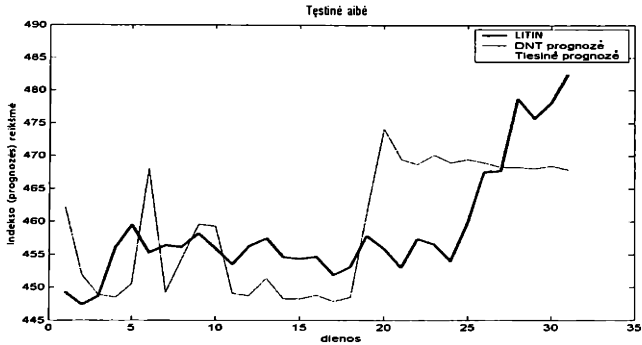
1. Nacionalinės vertybinių popierių biržos indeksų LITIN, LITIN-A ir LITIN-VVP kitimo analizei panaudotos kompleksinės analizės priemonės, apimančios ne tik techninius istorinius indeksų pokyčius, bet ir fundamentinius



16 pav. Priežastinio trendo modelio DNT mokymo VKN gradientinio nusileidimo funkcija (VKN lygio priklausomybė nuo mokymo iteracijų skaičiaus). DNT mokymui naudojamas Levenbergo-Marko algoritmas. Iteracijų skaičius 20, tinklo konfigūracija 15 : 5 : 1



17 pav. Priežastinio trendo modelio LITIN indekso kitimo kreivės aproksimavimas naudojant DNT. DNT mokymui naudojamas Levenbergo-Marko algoritmas. Iteracijų skaičius 20, tinklo konfigūracija 15 : 5 : 1



18 pav. Priežastinio trendo modelio LITIN indekso prognozė (nuo 1 iki 32 dienų), naudojant testinius duomenis. DNT mokymui naudojamas Levenbergo-Marko algoritmas. Iteracijų skaičius 20, tinklo konfigūracija 15 : 5 : 1

makroekonominis šalies rodiklis ir kitų šalių vertybinių popierių indeksus.

2. Konstruojamų modelių pagrindu pasirinktos dirbtinio intelekto sistemos, realizuojamos naudojantis dirbtinių neuroninių tinklų metodais, kuriems būdingi netiesiškumas, lankstumas, nesudėtingas mokymas. Nustaty-

tos pagrindinės sąlygos, kurias DNT metodas privalo tenkinti: gerai aproksimuoti ir prognozuoti netiesiškumus, kurie būdingi indeksų kitimui; jautriai reaguoti į unikalius, retai pasikartojančius ūkinius reiškinis; turėti kompleksines integruotas fundamentinės ir techninės analizės priemones.

3. VP rinkos kainos indeksų kitimai nulėmti retai pasikartojančių, nepastovių ir netipiskų veiksmų, todėl indeksų kitimo analizei pasirinktas netiesinis atgalinės grįžties (angl. *backpropagation*) dirbtinių neuroninių tinklų metodas, tenkinantis visas, pirmiau išvardytas, indeksų kitimo tyrimo metodams privalomas sąlygas. Sudaryta struktūruota tyrimo schema, kurioje nuosekliai matyti įėjties kintamųjų ir DNT metodų atranka bei parametrų optimizavimas.

4. Sukonstruoti dirbtiniai neuroniniai tinklai, galintys tenkinti pirmiau išvardytus reikalavimus. Tam tikslui atliktas DNT optimizavimas, apimantis tokius pagrindinius žingsnius: efektyviausių DNT mokymo algoritmų radimas, tinklo mokymo optimalaus iteracijų skaičiaus radimas, duomenų pateikimo optimalios formos radimas, tinkamiausios DNT konfigūracijos radimas, tyrimų pasikartojimo patikrinimas.

5. Atliktas NVPB indeksų entropijos tyrimas rodo, kad LITIN ir LITIN-A indeksai gali būti lemiami egzogeninių veiksmų, todėl jų paieškai buvo atlikta koreliacinė analizė ir rasti labiausiai NVPB indeksų kitimui turintys įtakos veiksniai: šalies makroekonominiai rodikliai, kitų šalių indeksai.

6. Naudojant DNT perceptrono (angl. *perceptron*) metodą, atlikti NVPB indeksų LITIN, LITIN-A ir LITIN-VVP autoregresinio trendo modelio tyrimai, kurie rodo, kad netgi paties pa-

prasčiausio perceptrono, kai neuroniniame tinkle tėra du neuronai, tiesinės regresijos metodas (aproksimuojant) nusileidžia pagal vidutinį kvadratinį nuokrypį dirbtiniam neuroniniam tinklui.

7. Naudojant DNT atgalinės grįžties (angl. *backpropagation*) metodą, atlikti autoregresinio priežastinio trendo modelio LITIN indekso aproksimavimo ir prognozavimo tyrimai, kai analizei naudotos ne tik istorinės indekso vertės, bet ir fundamentiniai makroekonominiai šalies rodikliai bei kitų šalių vertybinių popierių indeksai. Nustatyta, kad toks modelis viena ar net dviem eilėmis tiksliau aproksimuoja LITIN indekso kitimą, palyginti su autoregresiniu trendo modeliu, o prognozės rezultatai labai priklauso nuo DNT parametrų ir gali būti geresni negu atliekant tiesinę multidimensinę analizę.

8. Naudojant DNT atgalinės grįžties (angl. *backpropagation*) metodą, atlikti priežastinio trendo modelio LITIN indekso aproksimavimo ir prognozavimo tyrimai, kai analizei nenaudotos techninės istorinės LITIN indekso vertės. Nustatyta, kad tokio modelio aproksimavimo ir prognozavimo galimybės labai priklauso nuo egzogeninių veiksmų ir tiriamojo indekso koreliacijos, tačiau bendru atveju aproksimavimo ir prognozavimo tyrimo rezultatai nedaug nusileidžia autoregresinio priežastinio modelio rezultatams.

LITERATŪRA

1. Kancerovyčius G. Techninė analizė. Vilnius: Biznio mašinų kompanija, 1999. 138 p.

2. Plikynas D., Simanauskas L., Būda S. // Informacijos mokslai. 2001, Nr. 53, p. 176.

3. Martišius S. Ekonometrija ir prognozavimas. Vilnius: Vilniaus universiteto leidykla. 2000. 127 p.

4. Trippi R. R., Lee J. K. Artificial intelligence in finance & investing: state-of-the-art technologies for securities selection and portfolio management. Chicago: Irwin, 1996.

5. Trippi R. R., Turban E. Neural Networks in Finance and Investing. Chicago: Probus, 1993.

6. Indeksų skaičiavimo metodika (2001) // <http://www.nse.lt/beta/indeksuaskaiciavimas.htm>

7. Lietuvos nacionalinė vertybinių popierių birža [NVPB] (2001) // <http://www.nse.lt>

8. Klimasauskas C. Applying neural networks // PCAI Jan/Feb, 1991, pp. 30–33; Mar/Apr. 1991 pp. 27–34; May/June, 1991, pp. 20–24.

9. Čekanavičius V., Murauskas G. Statistika ir jos taikymai. Vilnius: TEV, 2000. T. I. 238 p.

10. Lietuvos statistikos departamentas. Lietuvos ekonominė ir socialinė raida. Vilnius, 2000.

11. Hecht D., Nielsen K. Neurocomputing. Reading, MA: Addison-Wesley, 1990.

12. Caudill M., Butler C. Understanding Neural Networks: Computer Explorations, Vols. 1 and 2. Cambridge, MA: the MIT Press, 1992.

13. Charalambous C. Conjugate gradient algorithm for efficient training of artificial neural networks. IEEE Proceedings, 1992, vol. 139, no. 3, pp. 301-310.

14. Steiner B. Key Market Concepts. Reuters: Pearson Education. London, 2001. 241 p.

15. Geralavičius V. Lietuvos ekonomika: pastarųjų metų pamokos // Ekonomika. 2000, Nr. 50.

RESEARCH OF STOCK EXCHANGE INDEXES BY USE OF ARTIFICIAL NEURAL NETWORKS METHODS

Darius Plikynas, Leonas Simanaukas, Sigitas Būda

Summary

The aim of this article is to inform about research, which was done by use of artificial neural networks [ANN] applications for prognoses of Lithuania National Stock Exchange indexes LITIN, LITIN-A, LITIN-VVP. Analysis for entropy shows the level of chance of the variations and correspondingly shows possibilities to find economic factors, which may influence Stock Exchange variations. Correlation analysis shows dependance between some Lithuania macroeconomic indicators, foreign exchange indexes and LITIN, LITIN-A, LITIN-VVP

indexes. It helps to include such indicators in to the autoregression, autoregression with the cause and cause prediction models. ANN learning is executed by weighted values of past period corresponding national indexes, by country's macroeconomic indicators (like GNP, unemployment, inflation, interest rates and so on) and by other country's Stock Exchange indexes (USA – Dow Jones and S&P; EU – Eurex, Russia – RTS). Comparison is made with the linear multidimensional regression method.

Įteikta 2001 m. rugsėjo mėn.