

RĪGAS TEHNISKĀ UNIVERSITĀTE
ELEKTRONIKAS UN TELEKOMUNIKĀCIJU FAKULTĀTE
TELEKOMUNIKĀCIJU INSTITŪTS

Irina KĻEVECKA

Doktora studiju programmas „Telekomunikāciju un datoru tīkli” doktorante

SAKARU TĪKLU NOSLODZES ĪSTERMIŅA PROGNOZĒŠANA
AR NEIRONU TĪKLIEM

Promocijas darba kopsavilkums

Zinātniskais vadītājs
Dr. sc. ing. J. LELIS

Rīga 2011

Kļevecka I. Sakaru tīklu noslodzes īstermiņa prognozēšana ar neironu tīkliem. Promocijas darba kopsavilkums.-R.:RTU, 2011.- 32 lpp.

Iespiests saskaņā ar ETF promocijas padomes „RTU P-08” 2011. gada 22. februāra lēmumu, protokols Nr.1



Šis darbs izstrādāts ar Eiropas Sociālā fonda atbalstu projektā «Atbalsts RTU doktora studiju īstenošanai».

**PROMOCIJAS DARBS
IZVIRZĪTS INŽENIERZINĀTŅU DOKTORA GRĀDA
IEGŪŠANAI RĪGAS TEHNISKAJĀ UNIVERSITĀTĒ**

Promocijas darbs inženierzinātņu doktora grāda iegūšanai tiek publiski aizstāvēts 2011.g. 9. jūnijā plkst. 15:00 Rīgas Tehniskās universitātes Elektronikas un telekomunikāciju fakultātē, Āzenes ielā 12, 210. auditorijā.

OFICIĀLIE RECENZENTI

Vadošais pētnieks, Dr. habil. sc. ing. V. Štrauss
Latvijas Universitātes Polimēru mehānikas institūts, Rīga, Latvija

Profesors, Dr. habil. sc. ing. M. L. Šneps-Šnepe
Ventspils Augstskola, Ventspils, Latvija

Profesore, Dr. sc. ing. I. Jackiva
Transporta un sakaru institūts, Rīga, Latvija

APSTIPRINĀJUMS

Apstiprinu, ka esmu izstrādājusi doto promocijas darbu, kas iesniegts izskatīšanai Rīgas Tehniskajā universitātē inženierzinātņu doktora grāda iegūšanai. Promocijas darbs nav iesniegts nevienā citā universitātē zinātniskā grāda iegūšanai.

Irina Kļevecka(Paraksts)

Datums:

Promocijas darbs ir uzrakstīts angļu valodā un sastāv no diviem sējumiem. Pirmais sējums satur ievadu, 4 nodaļas, secinājumus, literatūras sarakstu, 25 zīmējumus un ilustrācijas, kopā 174 lappuses. Otrais sējums satur 96 pielikumus, kopā 116 lappuses. Literatūras sarakstā ir 207 nosaukumi.

DARBA RAKSTUROJUMS

- **Tēmas aktualitāte**

Promocijas darba *tēma* ir sakaru tīklu noslodzes prognozēšana ar neironu tīkliem. *Prognozēšana* ir īpaša izpētes joma, kuras priekšmets ir parādības vai objekta attīstības perspektīvas nākotnē. Prognozēšanai ir jābūt cieši saistītai ar plānošanas jomu, jāvērtē attīstības potenciālos virzienus, un jāņem vērā plānu izpildīšanas vai neizpildīšanas sekas.

Prognozēšanas aspekts ir svarīgs moderno telekomunikāciju tīklu izstrādē, optimizācijā un rentabilitātes nodrošināšanā. Modernajiem telekomunikāciju tīkliem stratēģiskā skatījumā ir vajadzīga šādu parametru prognozēšana:

- 1) tīkla noslodze, kuru rada abonenti;
- 2) tīkla lietotāju / abonentu vai telefona līniju skaits;
- 3) valsts iedzīvotāju pieprasījums pēc telekomunikāciju tīklu pakalpojumiem.

Šie trīs parametri ir savstarpēji saistīti, un to prognožu ticamību nosaka ne tikai precīzas aprēķināšanas metodes, bet arī operatoram pieejamie resursi. Tomēr vislielāko interesi izraisa tīkla noslodzes, ko nosaka lietotāju uzvedība, īstermiņa attīstības prognozēšana, jo tā ir gan praktiski paveicama, gan sniedz teorētiskas atziņas.

Prognozēšanas uzdevuma svarīgums ir saistīts ar faktu, ka prognozes dati par tīkla caurlaides spēju ļauj iegūt papildu datus labākai tīkla pārvaldībai, t. i., algoritma radīšanai, kurš ļautu novērst sakaru kanālu pārslodzi. Veiksmīgas prognozes ļauj laikus plānot sistēmas jaudas attīstību un uzturēt prasīto pakalpojumu kvalitātes līmeni. Turklāt tīkla noslodzes īpašības tieši ietekmē gan sakaru operatora aprīkojuma kapitālizmaksas, gan gaidāmos ieņēmumus.

Pakešu komutācijas tīklu rašanās, kā arī tradicionālo telefona tīklu pārveidošana vairāku pakalpojumu sistēmās sniedz jaunas iespējas lietotājiem (abonentiem) viņu darbības jomās. Jāievēro, ka līdz ar to mainās ne tikai sakaru tīkla arhitektūra, bet arī tīkla noslodzes statistikas raksturs, kas ir saistīts ar pašlīdzības un stipras ilglaicīgās sakarības efektu izpausmi. Tas izraisa nepieciešamību meklēt jaunu pieeju sakaru tīklu stāvokļu analīzei un prognozēšanai. Tajā pašā laikā pakešu komutācijas tīklu dinamiskās uzvedības pētījumu jomā arvien plašāku atzinību gūst tāds sarežģīts nelineārais mehānisms kā *neironu tīkli*.

Ir bieži vien dzirdēts, ka *neironu tīkli ir vairāk māksla nekā zinātne*. Tas galvenokārt ir saistīts ar neironu tīklu izmantošanas funkcionālā algoritma trūkumu, ko kompensē ar tā dēvētā ekspertu novērtējuma aktīvu iesaistīšanu visos modeļu izvēles un verifikācijas posmos un kas pagaidām ierobežo prognozēšanas automatizācijas iespējas. Ir arī jāsaprot, ka atšķirībā no plaši lietotajām lineārajām laika rindu modelēšanas metodēm, neironu tīkli sākotnēji netika paredzēti prognozēšanas uzdevumu risināšanai.

Ir bijuši daudzi mēģinājumi lietot neironu tīklu principus gan telefona tīklu, gan IP tīklu noslodzes (kā arī IP tīklu lietotņu noslodzes) prognozēšanā. Tomēr lielākajā daļā šo mēģinājumu tika vairāk vai mazāk sekmīgi risināts triviālais laika rindas prognozēšanas uzdevums, neņemot vērā vispārīgo prognozēšanas teoriju un laika rindu teorijas statistiskos pamatus. Tāpēc, runājot par neironu tīklu izmantošanas *galvenajām problēmām* sakaru tīklu noslodzes prognozēšanā, jāpiemin šādi aspekti:

- nav skaidri zināms neironu tīklu izmantošanas algoritms laika rindu prognozēšanā;
- nav izstrādāta galīgā prognozēšanas modeļa izvēles metode un veikto prognožu kvalitātes novērtēšanas kritēriji.

• Pētījuma objekti

Promocijas darba praktiskā pētījuma objekti ir laika rindas, kuras apraksta:

- tradicionālā ķēžu komutācijas telefona tīkla noslodzi;
- pakešu komutācijas IP tīkla noslodzi.

Pakešu komutācijas tīkla mērījumi tika veikti transporta slānī.

Iegūtie dati tika transformēti tādā veidā, kas ir piemērots tālākai statistiskai analīzei un eksperimentālai prognozēšanas modeļa izvēlei.

• Pamatmērķis un uzdevumi

Promocijas darba pamatmērķis ir izzināt un risināt problēmas, kuras ir saistītas ar neironu tīklu izmantošanu laikrindu prognozēšanā un, pēc izmēģināšanas *ar reāliem datiem* un rezultātu salīdzināšanas, sniegt praktiskas rekomendācijas par efektīvāko neironu tīklu un statisko modeļu izmantošanu sakaru tīklu noslodzes prognozēšanā.

Promocijas darba pamatuzdevumi:

- 1) Rast funkcionālo neironu tīklu izmantošanas algoritmu, kas ir piemērots tīkla noslodzes prognozēšanas uzdevuma risināšanai un kas ļautu automatizēt optimāla risinājuma meklēšanas procesu un paaugstināt iegūto prognožu ticamību.
- 2) Sniegt rekomendācijas par operatīvo (līdz 24 stundām) un īstermiņa (līdz divām nedēļām) prognozēšanas modeļa izvēli, kā arī
 - prognozēšanas modeļa diagnostisko pārbaudi / verifikāciju;
 - prognožu konstruēšanu;
 - prognožu precizitātes novērtēšanu.
- 3) Radīt ķēžu komutācijas telefona tīkla un pakešu komutācijas IP tīkla *reālās noslodzes* dinamikas prognozes, lietojot neironu tīklus, novērtēt prognožu ticamību un salīdzināt tās ar prognozēm, kas iegūtas ar tradicionālajām lineārajām metodēm un „naivajām” prognozēm. Šī uzdevuma aktualitāte ir galvenokārt saistīta ar to, ka neironu tīklu modeļu izvēle un lietošanas sarežģītība ir radījusi zināmu pārlicību par to priekšrocībām prognozēšanas uzdevumu risināšanā. Tomēr nevienā no autorei zināmiem zinātniskajiem darbiem nav visaptveroša un analītiskā veidā salīdzināti rezultāti, kuri iegūti ar nelineāriem neironu tīkliem un vienkāršākām lineārajām statistiskajām metodēm.

• Tēzes

Aizstāvēšanai tiek izvirzītas tēzes, ka:

- izstrādātais neironu tīkla noregulēšanas algoritms ļauj automatizēt neironu tīkla risinājuma meklēšanas procesu un nodrošināt sakaru tīklu noslodzei ticamu operatīvo / īstermiņa prognozēšanu;
- neironu tīkli precizitātē pārspēj lineārās metodes reāla ķēžu komutācijas telefona tīkla noslodzes prognozēšanā, ja noslodzes mērījumi tiek veikti ar relatīvi maziem diskretizācijas intervāliem (piemēram, saskaņā ar ITU-T E.492. rekomendāciju – 15 minūtes);
- pakešu komutācijas Interneta tīklu noslodzes agregācijas un / vai diskretizācijas intervāla atbilstoša izvēle (parasti, virs dažām minūtēm) nodrošina iespēju iegūt ticamas operatīvās un īslaicīgās prognozes, lietojot ne tikai nelineāros neironu tīklus, bet arī klasiskas lineārās metodes.

- **Pētījuma pamatmetodes**

Lai risinātu iepriekšminētos uzdevumus, promocijas darbā tika lietotas šādas metodes.

- 1) *Neironu tīklu aparāts* – mākslīgā intelekta metode un universāls aproksimators, kurš ļauj atrast stohastisko procesu nelineārās sakarības.
- 2) *Autoregresīvais integrētā slīdošā vidējā modelis* (angļu valodā – autoregressive-integrated moving average, ARIMA) un *eksponenciālās izlīdzināšanas metode* – klasiskas metodes, kuras ir īpaši noderīgas īslaicīgo sakarību laika rindu modelēšanai un prognozēšanai.
- 3) *Spektrālā analīze* – ļauj novērtēt laika rindas periodiskās un kvaziperiodiskās sastāvdaļas, kā arī kalpo Hērsta koeficienta noteikšanai.
- 4) *Korelācijas analīze* – ļauj novērtēt savstarpējās attiecības starp laika rindas mērījumiem, kuras ir analizētas ar nobīdi laikā (t. i., autokorelācija), vai savstarpējās attiecības starp diviem procesiem (t. i., šķērskorelācija).
- 5) *Regresijas analīze* – ļauj atrast ticamāko modeli laika rindas trenda komponentei, ja tāda pastāv; tiek lietota arī Hērsta koeficienta novērtējumos.
- 6) *Neparametriskās statistikas aparāts* – tiek lietots, lai pārbaudītu hipotēzes par laika rindas stacionaritāti vai normalitāti, ja nav skaidri zināms procesa varbūtības sadalījums, kā arī ļauj identificēt statistiski nozīmīgas atšķirības starp prognozēm, kuras iegūtas ar dažādām metodēm.

- **Darba struktūra**

Promocijas darbs sastāv no diviem sējumiem. Pirmajā sējumā ir četras pamatnodaļas, kuras aplūko šādus aspektus:

1. *nodaļa* – sakaru tīklu noslodzes prognozēšanas pamataspekti un priekšnosacījumi.
2. *nodaļa* – modelēšanas un prognozēšanas metodes, kuras lietotas darba praktiskajā daļā – nelineārie neironu tīkli, autoregresīvais integrētā slīdošā vidējā modelis, eksponenciālās izlīdzināšanas metode un „naivās” metodes.
3. *nodaļa* – autores izstrādātais algoritms, kas domāts laika rindas īslaicīgas prognozēšanas uzdevuma risināšanai ar nelineārajiem neironu tīkliem.
4. *nodaļa* – praktisko pētījumu un iegūto rezultātu apraksts un analīze.

Pirmā sējuma kopējais apjoms ir 174 lappuses, un tas satur 25 attēlus un 11 tabulas. Citēto avotu saraksts satur 207 bibliogrāfiskos nosaukumus. Otrais sējums satur 96 pielikumus; tā kopējais apjoms ir 116 lappuses.

- **Darba novitāte**

Pamatuzdevumu izpildes rezultātā tika iegūti šādi oriģināli rezultāti:

Izmantojot matemātiskās statistikas metodes un neironu tīklu teoriju, tika izstrādāts detalizēts neironu tīkla noregulēšanas algoritms, kurš domāts sakaru tīklu noslodzes operatīvās un / vai īstermiņa prognozēšanas uzdevuma risināšanai.

Atšķirībā no klasiskās problēmas risināšanas shēmas ar neironu tīklu palīdzību (skat., piemēram, [9; 14; 53, 84. lpp.])) izstrādātais algoritms ļauj *automatizēt optimālā risinājuma meklēšanu* un ietver trīs principiāli jaunas procedūras:

- neironu tīkla apmācības procesā tiek izmantoti vairāki neironu tīkla svaru un sliekšņu inicializācijas cikli;

- starpposma modeļu izvēlēšanās metode, kurā ņem vērā atlikumu autokorelācijas līmeni un informācijas kritērija novērtējumu;
- galīgā prognozēšanas modeļa izvēlēšanās metode, kas pamatota ar sasniegto *ex ante* prognožu precizitāti.

Šādu procedūru iekļaušana klasiskajā algoritmā ļauj rast risinājumus efektīvāk un būtiski paaugstina iegūto prognožu kvalitāti un ticamību.

Neironu tīkli pieder pie tā saucamām *heiristiskajām* metodēm. Tas nozīmē, ka daudzi neironu tīklu parametri jāizvēlas ar mēģinājumu un kļūdu procedūrām, jo to noteikšana nepakļaujas precīziem matemātiskajiem noteikumiem. Iegūtais algoritms atspoguļo autores pieredzi un ņem vērā daudzu gadu reālo laikrindu praktiskos pētījumus. Tomēr zinātniskais pamats šādu procedūru iekļaušanai algoritmā ir neironu tīklu un laikrindu prognozēšanas teorētiskās atziņas.

Pirmo reizi ir veikta dziļāka statistiska analīze un vērtējums par reālu sakaru tīklu noslodzes prognozēm, kuras iegūtas ar nelineārajiem neironu tīkliem, tradicionālajām lineārajiem metodēm un „naivajām” metodēm.

Pēc iegūtajiem rezultātiem tika secināts, ka pakešu komutācijas tīkla noslodzes īstermiņa prognozēšanā var veiksmīgi izmantot ne tikai nelineāros neironu tīklus, bet arī tradicionālās lineārās metodes (ARIMA un eksponenciālās izlīdzināšanas modeļus). Darbā izanalizētās laika rindas var uzskatīt par tipiskām šādu sakaru tīklu noslodzes veidos. Tas nozīmē, ka klasisko lineāro metožu lietošana nodrošinās ticamus rezultātus arī daudzām citām laika rindām ar līdzīgām statistiskajām īpašībām.

• **Praktiskā vērtība**

Praktisko pētījumu rezultātus, attiecīgos algoritmus un rekomendācijas var lietot pakešu komutācijas tīklu jomā – gan transporta, gan lietojumslāņa noslodzes, kā arī tradicionālā telefona tīkla noslodzes operatīvo un īstermiņa prognožu veidošanā. Iegūtās prognozes var palīdzēt laikus plānot sakaru tīklu kanālu kapacitāti / caurlaides spēju, tādējādi nodrošinot gaidīto pakalpojumu kvalitāti (QoS).

Izstrādātie algoritmi un ieteikumi var būt derīgi arī citām reālām laika rindām ar līdzīgām statistiskajām īpašībām – piemēram, laika rindām, kuras apraksta enerģijas patēriņu vai ceļu satiksmes intensitāti.

• **Aprobācija**

Darbā izstrādātie algoritmi un rekomendācijas tika veiksmīgi lietotas, strādājot ar laika rindām, kas raksturo sakaru tīklu *reālās noslodzes* pārmaiņu dinamiku. Operatīvās un īstermiņa prognozes tika iegūtas korporatīvo klientu apkalpošanā specializējušās sabiedrības ar ierobežotu atbildību „Augstceltne” ķēžu komutācijas tīklam, kā arī bezmaksas elektroniskā pasta pakalpojumu sniegšanā specializējušās sabiedrības ar ierobežotu atbildību „INBOKSS” pakešu komutācijas tīklam.

Par promocijas darba rezultātiem tika ziņots starptautiskās zinātniskajās konferencēs:

- 1) 9th International Conference *Reliability and Statistics in Transportation and Communication* (RelStat'09), Rīga (Latvija), 2009. g. 21.-24. oktobris. Referāts – *Forecasting Network Traffic: A Comparison of Neural Networks and Linear Models*.
- 2) 50th International Scientific Conference of Riga Technical University, Rīga (Latvija), 2009. g. 12.-16. oktobris. Referāts – *An Advanced Algorithm for Forecasting Traffic Loads by Neural Networks*.

- 3) 28th Annual International Symposium on Forecasting, Nica (Francija), 2008. g. 22.-25. jūnijs. Referāts – *Preprocessing of Input Data of Neural Networks: The Case of Predicting Telecommunication Network Traffic*.

Citi ar darba tēmu saistītie autores ziņojumi starptautiskās zinātniskajās konferencēs:

- 4) 18th European Regional Conference of the International Telecommunications Society, Stambula (Turcija), 2007. g. 2.-5. septembris. Referāts – *Perspective Evaluation of the Electronic Communications Market in Latvia*.
- 5) 6th International Conference *Reliability and Statistics in Transportation and Communication* (RelStat'06), Rīga (Latvija), 2006. g. 25.-28. oktobris. Referāts – *Forecasting Methods and Long-term Evaluation of the Electronic Communications Market in Latvia*.
- 6) 17th European Regional Conference of the International Telecommunications Society, Amsterdama (Nīderlande), 2006. g. 22.-24. augusts. Referāts – *New Technologies and their Influence on the Universal Service Policy*.
- 7) 16th European Regional Conference of the International Telecommunications Society (ITS Europe 2005), Porto (Portugāle), 2005. g. 4.-6. septembris. Referāts – *The Necessity of Including Mobile Telephony in a Minimum Set of Universal Service*.
- 8) International Conference *Reliability and Statistics in Transportation and Communication* (RelStat'04), Rīga (Latvija), 2004. g. 14.-15. oktobris. Referāts – *Financial Risk of Providing the Universal Telecommunications Service in Latvia*.

Raksti zinātniskajos izdevumos un žurnālos:

- 1) Klevecka, I. "Forecasting Traffic Loads: Neural Networks vs. Linear Models." *Computer Modelling and New Technologies* 14.2. (2010): 20–28. [ISSN 1407-5806; Thomson Reuters Researcher ID]
- 2) Klevecka, I. "An Advanced Algorithm for Forecasting Traffic Loads by Neural Networks". *Scientific Journal of Riga Technical University (Series "Telecommunications and Electronics")* 9 (2009): 48-55. [ISSN 1407-8880; EBSCO Host, ProQuest, VINITI]
- 3) Klevecka, I., and J. Lelis. "Pre-Processing of Input Data of Neural Networks: The Case of Forecasting Telecommunication Network Traffic." Spec. issue of *Elektronikk: Telecommunications Forecasting* (in co-operation with International Institute of Forecasters) 104.3/4 (2008): 168-178. [ISSN 0085-7130; Thomson Reuters Researcher ID, ACM Digital Library]

Citēts darbos:

- Nikolov, V., and V. Bogdanov. "Integration of Neural Networks and Expert Systems for Time Series Prediction." *Proceedings of the 11th International Conference on Computer Systems and Technologies (CompSysTech'10)*. New York: ACM Press, 2010. 534-539. [ACM Digital Library].
- Chulaka Gunasekara, R., et. al. „Prophetia: Artificial Intelligence for TravelBox[®] Technology." *Advances in Computational Intelligence*. Eds. Wen Yu and Edgar N. Sanchez. Berlin: Springer-Verlag, 2009. 21-34. [Springer Link].

Raksti starptautisko konferenču tēžu krājumos:

- 4) Klevecka, I. "Forecasting Network Traffic: A Comparison of Neural Networks and Linear Models." *Abstracts of the 9th International Conference "Reliability and Statistics in Transportation and Communication" (RelStat'09)*. Oct. 2009, Riga, Latvia. Riga: Transport and Telecommunication Institute, 2009. 36. [ISBN 978-9984-818-22-1; Thomson Reuters Researcher ID].

- 5) Klevecka, I., and J. Lelis. „Preprocessing of Input Data of Neural Networks: The Case of Predicting Telecommunication Network Traffic.” *Program and Abstracts of the 28th Annual International Symposium on Forecasting*. June 2008, Nice, France. France: International Institute of Forecasters, 2008. 29. [ISSN 1997-4116; Thomson Reuters Researcher ID].

Citi ar darba tēmu saistītie raksti zinātniskajos izdevumos un žurnālos:

- 6) Klevecka, I., and J. Lelis. “Application of Extrapolation Methods to the Technology Diffusion Forecasting.” *Scientific Proceedings of Riga Technical University (Series "Telecommunications and Electronics")* 7 (2007): 52-59. [ISSN 1407-8880; ProQuest, VINITY].
- 7) Klevecka, I. and J. Lelis. “Financial Risk of Providing the Universal Telecommunications Service in Latvia.” *Transport and Telecommunication* 6.1 (2005):139-144. [ISSN 1407-6160; Thomson Reuters Researcher ID].

Citi ar darba tēmu saistītie raksti starptautisko konferenču rakstu krājumos:

- 8) Klevecka, I., and J. Lelis. “Perspective Evaluation of the Electronic Communications Market in Latvia.” *Proceedings of the 18th European Regional ITS Conference*. Sep. 2007, Istanbul, Turkey. Berlin: International Telecommunications Society, 2007. 1-37. CD-ROM. [Thomson Reuters Researcher ID].
- 9) Klevecka, I., and J. Lelis. “Forecasting Methods and Long-term Evaluation of the Electronic Communications Market in Latvia.” *Proceedings of the 6th International Conference “Reliability and Statistics in Transportation and Communication”*. Oct. 2006, Riga, Latvia. Riga: Transport and Telecommunication Institute, 2006. 37-45. [ISBN 9984-9865-9-4; Thomson Reuters Researcher ID].
- 10) Klevecka, I., J. Lelis, and J. Ulmanis. “The Necessity of Including Mobile Telephony in a Minimum Set of Universal Service.” *Papers of the 16th European Regional ITS Conference*. Sep. 2005, Porto, Portugal. Berlin: International Telecommunications Society, 2005. 1-13. CD-ROM. [Thomson Reuters Researcher ID].

Citi ar darba tēmu saistītie raksti starptautisko konferenču tēžu krājumos:

- 11) Klevecka, I., and J. Lelis. “Perspective Evaluation of the Electronic Communications Market in Latvia.” *Abstracts of the 18th European Regional ITS Conference*. Sep. 2007, Istanbul, Turkey. Berlin: International Telecommunications Society, 2007. 118-119. [Thomson Reuters Researcher ID].
- 12) Klevecka, I., J. Lelis, R. Bergmanis, and G. Macs. “New Technologies and their Influence on the Universal Service Policy.” *Abstract Booklet of the 17th European Regional ITS Conference*. Aug. 2006, Amsterdam, Netherlands. Berlin: International Telecommunications Society, 2006. 59-60. [ISBN 90-8559-205-4, Thomson Reuters Researcher ID].
- 13) Klevecka, I., J. Lelis, and J. Ulmanis. “The Necessity of Including Mobile Telephony in a Minimum Set of Universal Service.” *Abstracts of the 16th ITS European Regional Conference*. Sep. 2005, Porto, Portugal. Berlin: International Telecommunications Society, 2005. 16-17. [Thomson Reuters Researcher ID].
- 14) Klevecka, I., and J. Lelis. “Financial Risk of Providing the Universal Telecommunications Service in Latvia.” *Programme and Abstracts of the International Conference RelStat'04*. Oct. 2004, Riga, Latvia. Riga: Transport and Telecommunication Institute, 2004. 54. [ISBN 9984-668-76-2; Thomson Reuters Researcher ID].

DARBA APRAKSTS

1. NODAĻA. SAKARU TĪKLA NOSLODZES PROGNOZĒŠANAS PAMATASPEKTI

Promocijas darba pirmā nodaļa dod priekšstatu par laika rindu teorijas izmantošanas priekšnosacījumiem sakaru tīklu noslodzes prognozēšanā. Tiek piedāvāts īss laika rindu īpašību un ģenēzes apraksts, apskatītas pakešu komutācijas tīklu noslodzes prognozēšanas iespējas. Pirmā nodaļa arī sniedz apskatu par zinātniskajiem darbiem, kuri veltīti noslodzes prognozēšanai ar neironu tīklu palīdzību.

• Laika rindas jēdziens

Statistikās modelēšanas un prognozēšanas nolūkā tīkla noslodze, kuras mērījumi veikti noteiktos laika momentos, parasti tiek aplūkota laika rindas veidā. *Laika rinda* jeb *diskrētā laika parametra gadījumsprocess* ir gadījumsprocessa $X(t)$ novērojumu virkne $x(t_1), x(t_2), \dots, x(t_N)$, kura pierakstīta secīgos laika momentos $t_1, t_2, \dots, t_N$. Statistikajā analīzē N novērojumu virkni, kas veido laika rindu, bieži uzskata par *paraugkopu*, un šīs analīzes rezultātus vispārina uz daudz garāku *ģenerālkopu* ar iepriekšpieņemtu ticamības līmeni, kas ir tieši saistīts ar ergodiskuma jēdzienu. Laika rindas elementus parasti numurē saskaņā ar laika momentu, uz kuru tie attiecas (piemēram, x_1, x_2, x_3 , utt.). Tādējādi laika rindas elementu secība ir ļoti nozīmīga.

Ir jāpatur prātā, ka atšķirībā no gadījumlīkuma novērojumiem $x(1), x(2), \dots, x(N)$ laika rindas locekļi nav statistiski neatkarīgi [49, 780. lpp.]. Daudzas gadījumsizlases īpašības un statistiskās analīzes noteikumi neattiecas uz laika rindām, tāpēc nepieciešams meklēt īpašus risinājumus. No otras puses, laika rindas locekļu savstarpējā sakarība rada specifisku bāzi, no kuras iegūst analizētā rādītāja nezināmās vērtības $x(N+L)$ prognozes novērtējumu $\hat{x}(N+L)$, balstoties uz vēsturiskajiem novērojumiem $x(t_1), x(t_2), \dots, x(t_N)$, kur L – prognozēšanas horizonts.

Laika rindas *novērojumu ģenēze* attiecas uz pamatfaktoriem, kas veido laika rindas vērtības, to struktūru un klasifikāciju. Parasti izšķir četrus tādus faktorus un četras laika rindas sastāvdaļas [49, 781. lpp.; 52, 242. lpp.; 57, 354. lpp.]:

- 1) *Ilglaicīgie faktori*, kuri veido analizējamā lieluma $x(t)$ pārmaiņu dinamikas vispārīgo tendenci. Šo tendenci parasti apraksta ar monotonās determinētās funkcijas palīdzību un sauc par *trendfunkciju* jeb *trendu*.
- 2) *Sezonālie faktori*, kas nosaka tādas norises tīklā, kam piemīt regularitāte kādā laika periodā (mēneši, nedēļas, dienas utt.). Tā kā sezonālai funkcijai jābūt periodiskai (ar periodiem, kas iedalāmi „sezonās”), tās analītiskā izteiksme ietver harmonikas (trigonometriskās funkcijas).
- 3) *Cikliskie faktori* nosaka analizējamā lieluma $x(t)$ ilgākus relatīvās palielināšanās un samazināšanās periodus. Cikliskā komponente ietver ekonomisko, demogrāfisko un astronomisko norišu ciklus, kuriem ir dažādas amplitūdas un ilgums. Cikliskās sastāvdaļas periods parasti ir ilgāks par vienu gadu.
- 4) *Gadījumsfaktori* (neregulārie faktori) nosaka $x(t)$ elementu stohastisko dabu. Gadījumskomponente veidojas daudzu ārējo faktoru, kuri nav iesaistīti determinēto komponentu veidošanā, superpozīcijas rezultātā

Sakaru tīklu noslodzes determinētās komponentes var nosacīti iedalīt vairākās grupās [45, 44.lpp.; 19, 42.lpp.]:

- 1) *Diennakts cikls* – ir sen zināms, ka sigmoīdas veida modeļi (loģistiskais modelis, Gomperca modelis [22; 23], utt.) ir optimāli, lai aprakstītu noslodzes pārmaiņas un prognozētu tās attīstību diennakts laikā [58, 202. lpp.].

- 2) *Nedēļas cikls* – parasti raksturojams ar noslodzes samazināšanos brīvdienās un varētu tikt aprakstīts ar Furjē rindas nogriezni.
- 3) *Gada cikls* – uzskata, ka sakaru tīkla noslodzes līmenis ir augstāks mēneša sākumā, periodos, kas seko pēc svētku brīvdienām, un katra ceturkšņa sākumā.
- 4) *Lineārā tendence* – noslodzes līmenis pieaug ar katru gadu, ko veicina tehniskais progress un sociālekonomiskie faktori.

Ja izdotos pilnīgi identificēt laika rindas determinētās sastāvdaļas, tad atlikumi veidotu neregulāro, stohastisko komponenti. Jebkurš šīs komponentes novērojums sniedz tikai vienu variantu no daudziem iespējamiem, un tās aprakstīšanas, modelēšanas un prognozēšanas mērķiem der varbūtības teorijas metodes un paņēmieni.

- **Pakešu komutācijas tīklu caurlaides spējas prognozēšanas īpašības**

Sakaru kanāla caurlaides spēja ir viens no svarīgākajiem tīkla kvalitātes raksturošanas parametriem. Pakešu tīkla noslodzes prognozēšanā parasti lieto mērījumus, kuri veikti transporta slānī. Tādas laika rindas apraksta vai nu datu plūsmas pakešu skaitu, vai noslodzes līmeni baitos (pārraides ātrums), kurš iepriekš mērīts noteiktos laika intervālos.

Tīkla noslodzes prognozēšanu daļēji nosaka divas ITU-T rekomendācijas – E.506 [16] un E.507 [18]. Kaut gan šīs rekomendācijas attiecas uz ISDN tīklu noslodzes prognozēšanu, dažas no tajās minētajām prognozēšanas metodēm var attiecināt arī uz modernajiem sakaru tīkliem. Šādas metodes ir, piemēram, *autoregresīvais integrētā slīdošā vidējā modelis (ARIMA)*, kas sīki aprakstīts darbā [3], un eksponenciālās izlīdzināšanas metode [12].

Attīstoties IP tīkliem ir mainījies noslodzes raksturs, kas izpaužas *pašlīdzības* un *ilglaicīgās sakarības* statistisko efektu veidā [20, 150. lpp.; 28; 37; 41; 56, 53. lpp.]. Stiprāka procesa pēcdarbība parasti nodrošina ilgāku *horizontu*, kuram ir iespējams iegūt potenciāli ticamas prognozes. Tomēr tas ir arī šo procesu trūkums, jo piemērotākā modeļa, kurš ietvertu visas autokorelācijas starp laika rindas locekļiem, atrašana ir darbietilpīgs process [40].


Turklāt noslodzes prognozēšanā visai izplatīts ir *mīts*, ka pakešu komutācijas tīkliem nevar lietot tradicionālas prognozēšanas metodes un ka šādā gadījumā ir jāpievēršas sarežģītiem nelineārajiem mehānismiem, piemēram, neironu tīkliem.

Neironu tīkli, protams, piedāvā papildu iespējas nelineāro parādību un haotiskās uzvedības identifikācijā un modelēšanā. Pateicoties neironu tīklu lielajai pielāgojamībai, ar tiem var telpiski modelēt dažādas, pat strukturāli ļoti sarežģītas funkcijas. Tomēr lielākā daļa praktisko pētījumu, kuri vēltīti pakešu komutācijas tīklu noslodzes prognozēšanai, neņem vērā to, ka tās fraktālu raksturs ietekmē prognozēšanas rezultātus tikai tad, kad mērījumi tiek veikti ļoti lielā mērogā – ar agregācijas / diskretizācijas periodu no dažām milisekundēm līdz dažām minūtēm. Šo faktu apstiprina gan autores neatkarīgie pētījumi, gan secinājumi, kuri iekļauti virknē citu darbu [36, 39, 40].


Par šīs idejas ilustrāciju var noderēt 1. attēls, kurā ir parādīti reālā IP tīkla pārraides ātruma mērījumi atkarībā no agregācijas perioda. Pie 1 un 10 sekunžu gariem agregācijas periodiem tiek uzskatāmi novērota *stohastiskā pašlīdzība* [37]. Tomēr, palielinot agregācijas periodu līdz vienai minūtei un tālāk – līdz 5 minūtēm, noslodzes līkne būtiski izlīdzinās, tās dispersijas samazinās, un sāk parādīties determinētās komponentes (šajā gadījumā – sezonālās komponentes) izteikta ietekme.

No analīzes un prognozēšanas viedokļa, pārāk lielam laika rindas mērogam nav praktiskas nozīmes. Laika rindas noteikšanas un prognozēšanas statistiskā modeļa identifikācija būs apgrūtināta ne tikai saistībā ar spēcīgo autokorelāciju starp laika rindas attālajiem locekļiem, bet arī saistībā ar ietekmi, ko rada ārējie traucējumi un anomālas gadījuma vērtības, kuras neizbēgami iejaucas mērījumu rezultātos lielā laika mērogā. Ir nepieciešams arī paturēt prātā, ka, jo lielāks ir agregācijas / diskretizācijas periods, jo ilgāks ir potenciālais prognozēšanas horizonts. Respektīvi, laika rindai ar vienu sekundi garu periodu un laika rindai ar 24 stundas garu periodu, laika posms, kuram ir iespējams iegūt ticamas prognozes ar relatīvi zemu prognozēšanas kļūdu, ir atšķirīgs.

Kā tika parādīts promocijas darba praktiskajā nodaļā, laika rindas, kuras apraksta pakešu komutācijas tīkla noslodzi, un rindas, kuras apraksta tradicionālo balss sakaru noslodzi, ir līdzīgas pēc statistiskajām īpašībām. Tas ļauj intuitīvi pieņemt, ka, izvēloties piemērotu agregācijas intervālu, šo procesu aprakstīšanas un prognozēšanas metodes arī ir līdzīgas. Tas pierāda tādu klasisko lineāro metožu derīgumu, kuras tradicionāli jau lieto īstermiņa sakarību procesu modelēšanā un prognozēšanā.



1. att. Pakešu komutācijas tīkla reālās noslodzes mērījumi dažādos agregācijas periodos (autore attēls)



2. att. Statistiskie efekti, kas ir raksturīgi pakešu komutācijas tīklam, atkarībā no mērījumu laika mēroga [10, ar autores grozījumiem]

Pašlaik neironu tīklu lietošana reālā laika prognozēšanā ir stipri apgrūtināta savas darbietilpības dēļ. Laiku prasītu gan neironu tīkla arhitektūras izvēle un tās parametru eksperimentālā noteikšana, gan apmācības process. Tādēļ saskaņā ar ITU-T E.492 rekomendāciju [14], sakaru tīklu noslodzes mērīšanā ir ieteicams lietot agregāciju pa 15 minūšu un / vai vienas stundas gariem intervāliem. Šajā gadījumā par faktoriem, kuri nosaka *reālā* procesa struktūru un statistiskās īpašības, kļūst sezonālie efekti un monotoni trendi (tendences), kuri galvenokārt ir saistīti ar sakaru tīkla abonētu / lietotāju uzvedību un tehnoloģiskā progressa izpausmēm (sk. 2. att.).

Lielākā uzmanība promocijas darbā tika pievērsta neironu tīklu (daudzslāņu perceptronu) izmantošanai gan tradicionālā telefona tīkla, gan IP tīkla noslodzes prognozēšanā. Tomēr, balstoties uz „Okama asmens” principu – „izvēlies ekonomiskāko modeli!” –, ir nepieciešams salīdzināt prognozes, kuras iegūtas ar neironu tīklu palīdzību, ar tām, kuras iegūtas, lietojot vienkāršākas metodes. Darbā tika izmantots *autoregresīvais integrētā slīdošā vidējā modelis* (ARIMA) un *eksponenciālās*

izlīdzināšanas metode (kā tradicionālās metodes saskaņā ar ITU-T rekomendācijām), kā arī „naivās” metodes. Ja neironu tīkli nepārspēj citas metodes pēc prognožu kvalitātes, tad acīmredzot tālāka neironu tīklu izmantošana šo laika rindu prognozēšanā zaudē savu nozīmību.

2. NODAĻA. TĪKLU NOSLODZES PROGNOZĒŠANAS METODES

Promocijas darba otrajā nodaļā tiek aprakstītas sakaru tīkla noslodzes prognozēšanas metodes. Tās ir metodes, kuras tika lietotas darba praktiskajā daļā – nelineārie neironu tīkli (daudzslāņu perceptrons), sezonālais autoregresīvais integrētā slīdošā vidējā modelis (SARIMA), sezonālā eksponenciālā izlīdzināšana un „naivās” prognozēšanas metodes.

• Neironu tīkli

Neironu tīkls ir dinamiska sistēma, kas sastāv no ļoti daudziem savā starpā savienotiem elementāriem procesoriem un spēj ģenerēt izvadāmu informāciju kā atbildi uz ieejas iedarbību [53, 38.lpp.]. *Mākslīgo neironu tīklu* attīstība sākās 20. gadsimta sākumā, bet tikai 90. gados, kad dažas teorētiskās barjeras bija pārvarētas un skaitļošanas sistēmas kļuvušas pietiekami spēcīgas, neironu tīkli ieguva plašu atzinību. Kaut gan neironu tīklu mehānismu ir iespējams īstenot ātru aparatūrisku ierīču veidā (un tādas realizācijas reālajā dzīvē pastāv), tomēr lielākā daļa praktisko pētījumu tiek veikta, lietojot programmatūriskas simulācijas parastos datoros. Programmatūriskas simulācijas nodrošina lētu un pielāgojamu vidi modelēšanai, pētīšanai un testēšanai un ļauj risināt daudzus formālus uzdevumus [53, 35. lpp.]. Neironu tīkli ir ieguvuši atzinību arī telekomunikāciju jomā, kur tie palīdz risināt dažādas problēmas, kas saistītas ar komutācijas vadību, noslodzes pārvaldību, maršrutēšanu, kanālu iedalīšanu mobilo sakaru sistēmās u.c. [54, 60. lpp.].

Laika parametra iekļaušana neironu tīkla darbā ļauj ņemt vērā statistiskas variācijas dažādos procesos, kas tiek aprakstīti laika rindu veidā, piemēram – balss sakaru signāli, radara signāli, tirgus cenu svārstības, tīklu noslodzes procesi un daudzi citi. Diskusijas par laika lomu neironu tīklu aprēķinos ir iespējams atrast fundamentālajā darbā [7].


Analizētās rindas laika struktūra parasti tiek attēlota neironu tīkla struktūrā *netiešā veidā*, kur „statiskajam” neironu tīklam (mūsu gadījumā – daudzslāņu perceptronam) piemīt *dinamiskuma* īpašība [13, 636. lpp.]. Lai neironu tīkls būtu dinamisks, tam jāpiemīt atmiņai, kuru var iedalīt ilglaicīgajā un īslaicīgajā [35]. *Ilglaicīgā atmiņa* tiek integrēta neironu tīklā, ieviešot apmācību „ar skolotāju”, kad apmācības datu kopas informatīvais saturs glabājas (daļēji vai pilnā apjomā) tīkla sinapšu svaros. *Īslaicīgā atmiņa* parasti tiek integrēta neironu tīkla struktūrā ar *laika aiztures* elementiem, kurus var realizēt tīkla sinapšu līmenī vai ieejas mezglu slānī.

Tiek uzskatīts, ka laiciskajai apstrādei ir derīgi divi neironu tīklu tipi – *daudzslāņu perceptrons* (angļu valodā – *multilayer perceptron*) un *radiālo bāzes funkciju tīkli* (angļu valodā – *radial basis function network*). Vairāku iemeslu dēļ radiālo bāzes funkciju tīkli nav plaši ieviesti prognozēšanā¹. Tajā pašā laikā daudzi praktiski pētījumi ir pierādījuši, ka daudzslāņu perceptrons ļoti veiksmīgi risina attēlu pazīšanas, regresijas, funkciju aproksimācijas u.tml. uzdevumus. Tāpēc šā darba praktiskajos pētījumos tika lietots tieši šis neironu tīklu veids.


Daudzslāņu perceptrons parasti sastāv no daudziem sensoru elementiem (ieejas mezgliem jeb avota mezgliem), kuri veido ieejas slāni, viena vai vairākiem slēptajiem slāņiem, kuri satur rēķināšanas mezglus, un viena izejas slāņa. Daudzslāņu perceptrons tiek apmācīts saskaņā ar *kļūdu atpakaļgaitas izplatīšanas algoritmu* (angļu valodā – *error backpropagation algorithm*), kurš pieder pie apmācības

¹ Gan radiālo bāzes funkciju tīkls (RBF tīkls), gan daudzslāņu perceptrons pieder pie universālo aproksimatoru klases. Tādējādi vienmēr eksistē tāds RBF tīkls, kurš spēj imitēt daudzslāņu perceptronu, un pretēji. Daudzslāņu perceptrons nodrošina nelineāra attēla globālo aproksimāciju. Savukārt RBF tīkls rada lokālo aproksimāciju, piemērojot Gausa funkcijas. Tas ir daudzslāņu perceptrona popularitātes iemesls – ja skaitļošanas precizitāte ir līdzīga, nelineārā attēla aproksimācijai ar RBF tīkliem tomēr ir vajadzīgs vairāk brīvo parametru. Tas savukārt daudzkārt paildina laiku, kas ir nepieciešams pilnīgai RBF tīkla apmācībai salīdzinājumā ar daudzslāņu perceptronu [13, 293. lpp.].

algoritmu klases „ar skolotāju”. Šā algoritma pamatā ir *kļūdas korekcijas* noteikums (angļu valodā – error correction learning rule), kas prasa divus – tiešo un atpakaļejo – gājienus pa visiem tīkla slāņiem.



3. att. Nelineārais filtrs, kas radīts uz statiskā neironu tīkla pamata [13, 643. lpp.]



4. att. Tiešās izplatīšanas neironu tīkls ar laika aizturi ² [13, 644.lpp.;35]

Lai būtu iespējams pazīt tēlus laikā vai iegūt funkcijas aproksimāciju, ir nepieciešams veikt laikā mainīgo tēlu / paraugu apstrādi un ģenerēt atbildi katrā konkrētā laika momentā, kura ir atkarīga ne tikai no kārtējās vērtības, bet arī no dažām iepriekšējām vērtībām. 3. attēlā ir parādīts nelineārais filtrs, kurš veidots uz statiskā neironu tīkla pamata. Ir dots ieejas signāls, kurš sastāv no laika rindas kārtējās vērtības $x(t)$ un tās Ω iepriekšējām vērtībām $\{x(t-1), x(t-2), \dots, x(t-\Omega)\}$, kas glabājas Ω kārtas lineārās aiztures atmiņā (angļu valodā – delay line memory). Šajā gadījumā tīkla brīvie parametri tiek koriģēti ar mērķi minimizēt vidējo kvadrātisko kļūdu starp šī tīkla izejas signālu $y(t)$ un vēlamo tīkla atbildi $d(t)$. 3. attēlā parādīto struktūru var realizēt gan atsevišķa neirona veidā, gan arī neironu tīklu veidā.

Tiešās izplatīšanas neironu tīkls ar laika aizturi (angļu valodā – feed-forward time delayed neural network) ir parādīts 4. attēlā. Šāds tīkls ir jaudīgs nelineārais filtrs, kurš sastāv no atmiņas, kas veidota no aiztures līnijas ar Ω kārtas atzarojumiem, un daudzslāņu perceptrona. Šāda filtra apmācībai var lietot standarta kļūdas atpakaļgaitas izplatīšanas algoritmu. Laika momentā t „laika attēls” tiek pievadīts neironu tīkla ieejas slānim signāla vektora veidā:

$$x(t) = \{x(t), x(t-1), x(t-2), \dots, x(t-\Omega)\}^{N^{TR}}, \quad (1)$$

kur N^{TR} – apmācības paraugkopas attēlu skaits.

² Lai vienkāršotu tīkla attēlu, nobīdes līmeņi (sliekšņi) nav parādīti.

Izteiksmi (1) var uzskatīt par nelineārā filtra stāvokļa aprakstu laika momentā t . Viena apmācības *epoha* sastāv no secības stāvokļiem, kuru skaitu nosaka atmiņas kārtā Ω un apmācības paraugu skaits.

Pieņemot, ka daudzslāņu perceptronam ir viens slēptais slānis un viens neirons izejas slānī, nelineāra filtra izejas signāls tiek aprēķināts kā:

$$y(t) = j_2 \left(b_j + \sum_{j=1}^{m_1} w_j j_1 \left(\sum_{z=0}^{\Omega} w_{j,z} x_{t-z} + b_{j,z} \right) \right) \quad (2)$$

kur

j_1 – slēptā slāņa aktivizācijas funkcija;

j_2 – izejas slāņa aktivizācijas funkcija;

$w_{j,z}$ – j -tā slēptā neirona ζ -tās ieejas sinapšu svara koeficients;

w_j – izejas neirona j -tās ieejas sinapšu svars;

$b_{j,z}$ un b_j – nobīdes koeficienti (sliekšņi).

m_1 – slēpto neironu skaits;

Ω – lineārās aiztures atmiņas kārtā;

- **Autoregresīvais integrētā slīdošā vidējā modelis**

Autoregresijas procesi, slīdošā vidējā procesi un to kombinācijas ir lineāras, jo attiecības starp laika rindas elementiem un to kļūdām ir izteiktas ar lineāru operāciju palīdzību. Autoregresīvie slīdošā vidējā modeļi parādījušies pagājušā gadsimta 20. gados, bet plašu atzinību tie ieguva pēc Boksa un Dženkinsa grāmatas [3] izlaišanas, kurā viņi aprakstīja šo procesu izmantošanas metodiku laicrindu modelēšanā un prognozēšanā.

Izvēloties lineāro modeli sakaru tīklu noslodzes aprakstīšanai, ir svarīgi orientēties uz to sezonālo modifikāciju, kura paredzēta cikliska rakstura laicrindu modelēšanai. Nesezonālo modeļu lietošana sezonālajām laicrindām var likt izdarīt nepareizus secinājumus – ka lineārās metodes nevar lietot sakaru tīklu noslodzes īstermiņa prognozēšanā.

Vispārīgs laicrindas sezonālais autoregresīvais integrētā slīdošā vidējā modelis, ko sauc par *SARIMA* (p, d, q)(P, D, Q), tiek aprēķināts pēc formulas [3, 305. lpp.]:

$$f_p(B)\Phi_p(B^s)\nabla^d\nabla_s^D x_t = q_q(B)\Theta_q(B^s)e_t \quad (3)$$

kur

s – sezonālās komponentes periods;

p – autoregresijas operatora kārtā;

q – slīdošā vidējā operatora kārtā;

d – starpības kārtā;

P – sezonālā autoregresijas operatora kārtā;

Q – sezonālā slīdošā vidējā operatora kārtā;

D – sezonālās starpības kārtā;

∇ – starpības operators, $\nabla = \nabla_1 = 1 - B$;

∇_s – sezonālās starpības operators, $\nabla_s = 1 - B^s$;

$f(B)$ un $q(B)$ – attiecīgi, p un q pakāpju B polinomi, kuri atbilst stacionaritātes un apgriežamības nosacījumiem;

$\Phi(B^s), \Theta(B^s)$ – attiecīgi, P un Q pakāpju B^s polinomi, kuri atbilst stacionaritātes un apgriežamības nosacījumiem;

e_t – modeļa kļūdas (atlikumi), kas ir baltais troksnis.

Ja ir zināmi visi laikrindas novērojumi $x_t, x_{t-1}, \mathbf{K}$ līdz laika momentam t , tad prognoze $\hat{x}_t(L), L \geq 1$ ar minimālo vidējo kvadrātisko kļūdu ir lieluma x_{t+L} izlases matemātiskā cerība [3, 306.lpp.]:

$$\hat{x}_t(L) = [x_{t+L}] = E[x_{t+L} | q, \Theta, x_t, x_{t-1}, \mathbf{K}] \quad (4)$$

kur L – prognozēšanas periods (horizonts).

Bokss un Dženkinss pierādījuši, ka prognozi ar minimālo kvadrātisko kļūdu ir iespējams iegūt tieši no modeļa, kurš izteikts starpības vienādojuma veidā. Praktisko pētījumu gadījumā tāda pieeja ir visvienkāršākā un smalkākā. Piemēram, sezonālajam procesam ar $s = 12$ prognozi var izteikt šādi [3, 306. lpp]:

$$\hat{x}(L) = [x_{t+L}] = x_{t+L-1} + x_{t+L-12} - x_{t+L-13} + e_{t+1} - q e_{t+L-1} - \Theta e_{t+L-12} + q \Theta e_{t+L-13} \quad (5)$$

Pēc parametru θ un Θ vērtību ievietošanas vienādojumā (5) uzreiz iegūstam laika intervāla L prognozi ar minimālo kvadrātisko kļūdu, kura aprēķināta laika momentā t [3, 306. lpp].

Tiek pieņemts, ka visi parametri izteiksmē (5) ir precīzi un rindas novērojumi $x_t, x_{t-1}, \mathbf{K}$ ir zināmi pietiekami tālā pagātnē.

• Eksponenciālās izlīdzināšanas metode

Eksponenciālās izlīdzināšanas lineārā metode ļauj iegūt tādu procesa aprakstu, kur pēdējiem novērtējumiem tiek piešķirti lielāki svāri salīdzinājumā ar agrākajiem novērojumiem un svāri samazinās eksponenciāli.

Vispārīgā veidā eksponenciālās izlīdzināšanas modelis tiek aprakstīts kā:

$$S_t = S_{t-1} + a e_t \quad (6)$$

kur

S_t – laikrindas izlīdzinātais novērojums;

α – rindas līmeņa izlīdzināšanas koeficients;

e_t – modeļa kļūdas, $e_t = x_t - \hat{x}_{t-1}(1)$;

x_t – reālais novērojums laika momentā t ;

$\hat{x}_{t-1}(1)$ – viena soļa uz priekšu novērtētais novērojums, kas iegūts laika momentā $t - 1$.

Pastāv dažādi eksponenciālās izlīdzināšanas modeļi – pielāgoti nestacionārajām laikrindām ar lineārajām un nelineārajām tendencēm, kā arī sezonālās modifikācijas, kuras paredzētas *multiplikatīvās* un *aditīvās* sezonālītātes laikrindām. Eksponenciālās izlīdzināšanas modelis, kurš ir vispiemērotākais sakaru tīklu noslodzes modelēšanai un prognozēšanai, ir modelis ar *aditīvo* sezonālītāti un / vai lineāro tendenci. Laikrindas *aditīvā sezonālā komponente* un lineārā trenda komponente ir izteikta šādi [12]:

$$I_t = I_{t-s} + d(1-a)e_t \quad (7)$$

$$T_t = T_{t-1} + a g e_t \quad (8)$$

kur

I_t – sezonālās komponentes izlīdzinātais novērojums;

T_t – lineārā trenda izlīdzinātais novērojums;

δ – sezonālās komponentes izlīdzināšanas koeficients;

γ – lineārā trenda izlīdzināšanas koeficients.

Lai novērtētu modeli ar sezonālītāti un trendu, jālieto *dekompozīcijas* paņēmieni. Sezonālā komponente un trenda komponente tiek novērtēta katrā laika momentā savstarpēji neatkarīgi, lietojot parasto eksponenciālo izlīdzināšanu ar parametriem δ un γ .

Prognozēšanas periodam L laika rindas prognoze ar aditīvo sezonālītāti un lineāro trendu tiek noteikta pēc formulas [12]:

$$\hat{x}_t(L) = S_t + I_{t-s+L} + L \cdot T_t \quad (9)$$

kur $\hat{x}_t(L)$ - prognoze, kura iegūta prognozēšanas periodam L .

Eksponenciālās izlīdzināšanas modeļu pilnu klasifikāciju, kā arī rekomendācijas par modeļa parametru izvēli var atrast darbā [12].

- **„Naivās” prognozēšanas metodes**

Rezultātus, kuri iegūti ar dažādiem prognozēšanas modeļiem, ir nepieciešams salīdzināt ar tā saucamām „naivajām” prognozēm. „Naivo” prognozi ir iespējams konstruēt dažos veidos, no kuriem darbā tika lietotas divas.

- 1) Prognozēšanas horizonta L „naivā” prognoze ir laika rindas vidējās vērtības novērtējums [33]:

$$\hat{x}_t^a(L) = E[x_{t+L} | x_t, x_{t-1}, \mathbf{K}, x_1] = \hat{m} \text{ pie } L \geq 1 \quad (10)$$

- 2) „Naivās” prognozes sezonālā modifikācija, kura paredz, ka viena perioda uz priekšu vērsta prognoze ir vienāda ar laika rindas pēdējā vēsturiskā perioda analogisko novērojumu [44].

$$\hat{x}_t^b(L) = E[x_{t+L} | x_t, x_{t-s}, \mathbf{K}, x_1] = x_{t+L-s} \text{ pie } L \geq 1 \quad (11)$$

„Naivā” prognoze pat neprasa modeļa lietošanu, un to var izmantot kā etalonu. Ja naivās prognozes un prognozes, kuras iegūtas ar kāda prognozēšanas modeļa palīdzību, kvalitātes salīdzinājums neatklāj statistiski nozīmīgas atšķirības, tad acīmredzot modeļa izmantošana turpmāk nav vajadzīga.

3. NODAĻA. LAIKA RINDAS PROGNOZĒŠANAS UZDEVUMA RISINĀŠANAS ALGORITMS AR NEIRONU TĪKLIEM

Promocijas darba trešā nodaļa apraksta autores izstrādāto algoritmu, kas domāts laika rindas prognozēšanas uzdevuma risināšanai ar neironu tīkliem, un pievēršas tā inovatīvajiem aspektiem. Šī nodaļa arī izklāsta daudzslāņu perceptrona parametru noteikšanas metodes un sniedz rekomendācijas par dažiem praktiskiem algoritma realizācijas aspektiem, piemēram, par datu bāzes sagatavošanu, datu priekšapstrādi, prognožu iegūšanu un to kvalitātes novērtēšanu, utt.

Kā jau iepriekš tika minēts, atšķirībā no klasiskām lineārajām metodēm neironu tīklu aparāts sākotnēji netika paredzēts laika rindu modelēšanai un prognozēšanai. Prognozēšanas jomā neironu tīkli joprojām ir ļoti sarežģīts mehānisms, kas jau ir bieži kritizēts par ilgo modelēšanas laiku, stabila risinājuma iegūšanas un atkārtotības problemātiskumu, augstu pārmērīgas apmācības varbūtību, kā arī nepieciešamību vērtēt daudzus neironu tīkla parametrus eksperimentāli. Tāpat ir nepieciešams ņemt vērā, ka neironu tīkls ir jūtīgs pret ievaddatu kvalitāti [24, 27, 55].

Lai atvieglotu laika rindu modelēšanu un prognozēšanu, maksimāli automatizējot šo procesu un kompensējot problēmas, kas saistītas ar iegūstamā risinājuma nestabilitāti, darbā tika izstrādāts modificēts neironu tīkla lietošanas algoritms, kura pamata blokshēma ir parādīta 5. attēlā. Algoritms mērķtiecīgi risina operatīvo / īslaicīgo prognožu konstruēšanas uzdevumu un atšķirībā no klasiskajiem algoritmiem, kuri paredz neironu tīklu lietošanu konkrēta uzdevuma risināšanai (sk., piemēram, [9; 53, 84. lpp.]), ietver trīs procedūras:

- vairāku neironu tīkla svaru un sliekšņu inicializācijas ciklu lietošana neironu tīkla apmācībā;
- starpposma modeļu izvēles metode, kurā ņem vērā atlikumu autokorelācijas līmeni un informācijas kritērija novērtējumu;
- galīgā prognozēšanas modeļa izvēles metode, kurā ņem vērā *ex ante* prognožu kvalitāti.

Aplūkosim šo procedūru lietošanas nepieciešamības teorētisko pamatojumu.

• Vairāku neironu tīkla svaru inicializācijas ciklu lietošana neironu tīkla apmācībā

Pirms apmācības procesa sākuma visiem neironu tīkla sinapšu svāriem un sliekšņiem jāpiešķir sākumvērtības. Šīs procedūras mērķis ir atrast vislabāko sākotnējo tuvinājumu optimālajam risinājumam, tādējādi uzlabojot konverģenci un saīsinot tīkla apmācības laiku.


Ja sinapšu svāri iegūst lielas vērtības, tad neironi ātri sasniegs piesātinājumu. Šādā gadījumā kļūdu atpakaļgaitas izplatīšanas apmācības algoritma gradienti būs mazi, kas savukārt paildzinās apmācības procesu. Ja sinapšu svāriem piešķirtas pārāk mazas vērtības, algoritms darbosies lēni kļūdu virsmas koordinātu sākumā. Tas it īpaši raksturīgs antisimetriskajām aktivizācijas funkcijām, piemēram, hiperboliskajam tangensam.

Pēdējos divdesmit gados ir piedāvātas daudzas heuristiskas svaru inicializācijas metodes, kas ir apskatītas darba 3. nodaļā. Neskatoties uz to, šīs problēmas optimālais risinājums joprojām nav atrasts. Visizplatītākā inicializācijas metode (tās vienkāršības dēļ) ir izvēlēties svaru sākumvērtības izlases kārtībā no normāli vai vienmērīgi sadalīta mazu vērtību diapazona.

Neatkarīgi no inicializācijas metodes neironu tīklu apmācības veiksmi tieši ietekmē svaru un sliekšņu sākumvērtības. Tas ir saistīts ar apmācības algoritmu īpatnībām un ar faktu, ka neironu tīkla kļūdu virsmā var būt daži lokālie minimumi (sk. 6-a. att.). Līdz ar to, lai atrastu globālo minimumu, vienas un tās pašas arhitektūras tīkls jātrenē nemainīgos apstākļos daudzas reizes, mainot tikai sinapšu svaru sākumvērtības.

Neraugoties uz problēmām, kuras saistītas ar stabila risinājuma iegūšanu un atkārtotānu, vairākums pētnieku joprojām nepievērš šim jautājumam pietiekami lielu uzmanību. Literatūrā ir iespējams atrast atsauces uz 5 [21], 10 [42], 25 [25], 50 [8; 46], 100 [25] inicializācijas cikliem. Tomēr vairākumā praktisko pētījumu tika veikts tikai viens inicializācijas cikls, kas var radīt būtiski nepareizus priekšstatus par iegūto risinājumu.


6-b. attēlā ir parādīts piemērs, kurš raksturo gala risinājuma nestabilitāti un tā atkarību no svaru sākumvērtībām, kuras piešķirtas inicializācijas laikā. Šeit ir parādītas apmācības kļūdas, kuras tika iegūtas nemainīgās arhitektūras daudzslāņu perceptronam, trenējot to ar dažādām svaru un sliekšņu sākumvērtībām un nemainīgiem pārējiem apstākļiem. Ir viegli pamanīt, ka starpība starp minimālo un maksimālo apmācības kļūdu pie 100 inicializācijas cikliem ir lielāka par 25 %, kas varētu būt svarīgi prognozēšanas modeļa izvēlē.



Apzīmējumi

m_1 – neironu skaits tīkla slēptajā slānī
 K – slēpto neironu maksimālais skaits
 V – svaru inicializācijas ciklu maksimālais skaits
 IC – informācijas kritērijs
 LM – Lagranža reizinātāju tipa kritērijs (t.i., Broiša-Godfrija kritērijs)
 $p(LM)$ – LM tipa kritērija p -vērtība
 α – minimāli pieļaujamais nozīmīguma līmenis

5. att. Laika rindas prognozēšanas uzdevuma risināšanas algoritms ar neironu tīkliem



6. att. Vairāku sinapšu svaru inicializācijas ciklu lietošanas nepieciešamības ilustrācija: (a) vienkāršota kļūdu virsmas ilustrācija, kur ordinātu ass norāda uz kļūdas vērtību, kas raksturo vienu no neironu tīkla apmācības problēmām – dažu lokālo minimumu eksistēšanu; (b) reālā neironu tīkla apmācības kļūda (bez šķērspārbaudes izmantošanas) pie dažādām svaru un sliekšņu sākumvērtībām (autorens simulējums)³

Iniciālizācijas ciklu skaits parasti tiek izvēlēts brīvi un ir atkarīgs gan no risināmā uzdevuma sarežģītības, gan no tā, cik ilgu laiku pētnieks var atļauties iztērēt katra neironu tīkla arhitektūras trenēšanai.

- **Starpposma modeļu izvēles metode, kurā ņem vērā atlikumu autokorelācijas līmeni un informācijas kritērija novērtējumu**

Saskaņā ar autores izstrādāto algoritmu, starpposma modeļu izvēle no apmācītajiem tīkliem ir jāveic, ņemot vērā *atlikumu korelācijas* līmeni un *informācijas kritērija* rādītājus.

Modeļa vispārīgās prognozēšanas spējas (būtībā – laika rindas aproksimācijas kvalitāte) tradicionāli tiek vērtētas pēc korelācijas koeficienta R , kā arī pēc vairākiem citiem standarta parametriem, piemēram, pēc vidējās kvadrātiskās kļūdas MSE , vidējās absolūtās kļūdas MAE , standarta kļūdas $RMSE$ u.c. Tomēr šādi parametri nesniedz praktiski nekādu informāciju par izvēlēta prognozēšanas modeļa precizitāti un bieži tiek kritizēti par grūtībām, kuras saistītas ar parametru izmantošanu prognožu kvalitātes salīdzināšanā [4, 6, 26].

Visprecīzāko prognozēšanas modeļa kvalitātes raksturojumu var sniegt *atlikumu autokorelācijas* novērtējums. Modeļa atlikumi ir n starpības, kuras tiek aprēķinātas kā $e_t = x_t - \hat{x}_t$, $t = 1, 2, \mathbf{K}, n$, kur x_t – laika rindas faktiskais novērojums un $\hat{x}_t$ – novērtējums, kas iegūts ar prognozēšanas modeļa palīdzību [50, 94. lpp.]. No šīs definīcijas izriet, ka atlikumi ir starpības starp to, kas ir faktiski novērots, un to, kas ir novērtēts, lietojot statistisko modeli, t.i., tās ir vērtības, kuras nav iespējams izskaidrot ar izvēlēto prognozēšanas modeli. Tādējādi mēs varam apskatīt atlikumus e_t kā novērojamas kļūdas, ja modelis ir korekts.

Ja hipotēze par atlikumu autokorelācijas nenozīmīgu tiek pieņemta, tad atlikumi ir līdzīgi baltā trokšņa procesam un tālāka analīze neparādīs nozīmīgas sakarības. Klasiskajā regresijas analīzē atlikumu autokorelācijas testēšanai lieto Dērbina-Vatsona kritēriju [50, 245. lpp.]. Tomēr šis kritērijs nav piemērots atlikumu autokorelācijas testēšanai, ja regresors (t.i., faktorālā pazīme) ir atkarīgais mainīgais ar aizkavi [51, 256. lpp.]. Tā paša iemesla dēļ diagnostiskai atlikumu pārbaudei nedrīkst lietot Boksa-Pīrsa un Ljungas-Boksa [30] kritērijus, kaut gan pēdējais ir ticis plaši lietots un,

³ Kļūdu vērtības ir attēlotas to novērtēšanas hronoloģiskajā secībā, kā arī iekārtoti krītošajā secībā, lai atvieglotu to izklādes analīzi.

neskatoties uz teorētiska pamatojuma neesību, joprojām tiek iekļauts vairākumā statistisko un ekonometrisku programmatūras pakešu.

Šobrīd visticamāko autokorelācijas eksistences novērtējumu neironu tīklu, kā arī ARIMA modeļu atlikumos var sniegt spēcīgs Lagranža reizinātāju tipa kritērijs (angļu valodā - *Lagrange multiplier type test*) [34], kurš ir pazīstams arī kā Broiša-Godfrija kritērijs. Tas pieder pie klasiskajiem asimptotiskajiem testiem un kalpo jebkādas kārtas atlikumu autokorelācijas identificēšanai.

Savukārt informācijas kritērija izmantošana prognozēšanas modeļa izvēlē balstās uz vienu no galvenajiem prognozēšanas principiem – „izvēlies ekonomiskāko modeli!” („*Okama asmens*” princips). Saskaņā ar šo principu – ja pārējie apstākļi ir vienādi, tālākai prognozēšanai jāizvēlas modelis ar vismazāko brīvo parametru skaitu.

Prognozēšanas modeļa vidējiem kvadrātiskiem atlikumiem ir tendence samazināties līdz ar modeļa sarežģītības paaugstināšanu. Praksē, palielinot neironu tīkla brīvo parametru skaitu (kas ir saistīts ar jaunu slēpto neironu pievienošanu), ir iespējams atrast modeli, kurš radīs tādu aproksimācijas līkni, kas bezgalīgi precīzi atbilst vēsturiskajiem datiem. Šādu neironu tīklu īpašību izskaidro *teorēma par universālo aproksimatoru* [5; 15]. Tomēr tas nenožīmē, ka tādām tīklam ir laba *vispārīnāšanas spēja* – pārmērīgas apmācības efekta dēļ [13, 206.lpp.]. Turklāt pēc noteikta līmeņa sasniegšanas ieguvums aproksimācijas kvalitātē var būt nenožīmīgs, bet laiks, kurš iztērēts, lai atrastu brīvo parametru optimālās vērtības, var ietekmēt kopējo sistēmas veiktspēju. Tādēļ ir svarīgi meklēt līdzsvaru starp aproksimācijas līknes precizitāti un prognozēšanas modeļa statistisko sarežģītību.

Šo problēmu var risināt ar *informācijas kritēriju* palīdzību, kur statistika iekļauj sodu par nepietiekamu pielāgošanu un sodu par pārmērīgi lielu parametru skaitu. Divi vispopulārākie šāda veida kritēriji ir *Akaiķes informācijas kritērijs (AIC)* un *Beiza informācijas kritērijs (BIC)* [11, 38. lpp; 38, 373. lpp]:

$$AIC(l) = N_{ef} \ln \hat{s}_e^2 + 2l \quad (12)$$

$$BIC(l) = N_{ef} \ln \hat{s}_e^2 + 2l + l \ln(N_{ef}) \quad (13)$$

kur

N_{ef} – efektīvo novērojumu skaits;

l – modeļa brīvo parametru skaits;

$\hat{s}_e^2 = \frac{\sum_{t=1}^{N_{ef}} e_t^2}{N_{ef}}$ - atlikumu e_t^2 izlases dispersija.

Informācijas kritērijus novērtē katra apskatāmā modeļa specifikācijai. Salīdzinot divus modeļu tipus, priekšroka jādod specifikācijai ar mazāko kritērija vērtību. Respektīvi, Beiza kritērijs par liekiem parametriem soda vairāk, un parasti „izvēlas” mazāku parametru skaitu, t.i., ļoti „ekonomiskus” modeļus (angļu valodā – parsimonious models). Līdz ar to šo kritēriju bieži izmanto nelineāros modeļos, kur nenožīmīgs uzlabojums aproksimācijas kvalitātē varētu prasīt aprēķināt vairākus papildu parametrus.

Šajā darbā tika lietoti šie divi informācijas kritēriji, bet eksistē arī citi līdzīgi kritēriji, piemēram – Švarca Beiza kritērijs [38, 376. lpp.] un Hannana-Kvinna informācijas kritērijs [32, 86. lpp.].


- **Galīgā prognozēšanas modeļa izvēles metode, kurā ņem vērā *ex ante* prognožu kvalitāti**

Ja algoritma izpildīšanas laikā tiek atrasti modeļi, kas atbilst iepriekš definētajām prasībām, tad ir jāpārbauda to prognozēšanas spējas ar neatkarīgu testēšanas paraugkopu. Prognozi, kuras kvalitāti ir iespējams novērtēt pēc neatkarīgas testēšanas paraugkopas reālajiem datiem, tālāk sauksim par pseidoprognosi jeb *ex ante* prognozi. *Ex ante* prognozes iegūšanas un tās kvalitātes testēšanas nepieciešamība ir saistīta galvenokārt ar to, ka pat modelis ar nekorelētajiem atlikumiem, kurš

nodrošina relatīvi augstu aproksimācijas kvalitāti, var tikt „pārmērīgi apmācīts” ar vēsturiskajiem datiem.

Pieeja, kura ietver datu bāzes sadalīšanu divās neatkarīgās paraugkopās – bāzes paraugkopā un *ex ante* prognozēšanas (testēšanas) paraugkopā – ir guvusi plašu atzinību laiku rindu prognozēšanas praksē [31; 43], bet joprojām tiek reti lietota neironu tīklu gadījumā. *Bāzes* jeb *retrospektīvo paraugkopu* veido lielākā laika rindas daļa, un to lieto tieši modeļa izvēlei un testēšanai. Otrā, *ex ante prognozēšanas paraugkopa* netiek iesaistīta modeļa izvēlē un verifikācijā. Tiek aprēķinātas *ex ante* prognozes, kas nodrošina iespēju neatkarīgi un objektīvi novērtēt izvēlēto modeļa prognozēšanas īpašības un spējas.

Testēšanas paraugkopa *tradicionāli* tiek veidota no laika rindas *pēdējiem* novērojumiem. Tomēr pēdējiem vēsturiskiem datiem ir visstiprākā ietekme uz turpmāko reālās prognozes dinamiku un novirzi. Tie ir visvērtīgākie optimālā modeļa izvēlē, un to lietošana *ex ante* prognozēšanas paraugkopā bieži vien nav lietderīga.



7. att. Laika rindas hronoloģiskā sadalīšana bāzes un *ex ante* prognozēšanas paraugkopās (autore attēls)

Līdz ar to darba autore iesaka dalīt laika rindu bāzes un *ex ante* prognozēšanas paraugkopās saskaņā ar 7. attēlā parādīto shēmu. Šāda pieeja ļauj paaugstināt reālo prognožu kvalitāti, jo pēdējie vēsturiskie novērojumi tiek izmantoti nevis testēšanai, bet statistiskā modeļa izvēlei.

Ex ante prognozes precizitāte parasti tiek novērtēta pēc standarta aproksimācijas kvalitātes novērtēšanas parametriem. Šajā darbā tika izmantota vidējā absolūtā kļūda MAPE (angļu valodā – mean absolute percentage error), kuru nosaka pēc formulas [1, 347. lpp.]:

$$MAPE = \frac{\sum_{t=1}^L \left| \frac{x_t - \hat{x}_t}{x_t} \right|}{L} \cdot 100\% \quad (14)$$

kur L – *ex ante* prognozēšanas paraugkops izmērs (prognozēšanas horizonts).

MAPE – relatīvais parametrs, kurš nosaka aproksimācijas līknes vai prognozes atbilstību vēsturiskajiem datiem. Tas norāda, par cik procentiem teorētiskie līmeņi, kuri aprēķināti ar modeļa palīdzību, atšķiras no laikrindas faktiskajiem līmeņiem. Līdz ar to *MAPE* bieži lieto, lai salīdzinātu prognozes, kuras iegūtas ar dažādu metožu palīdzību.

Modeli, kurš nodrošina viszemāko *ex ante* prognozes kļūdu, pieņem par galīgo modeli, ko izmantos tālākai prognozēšanai reālajos apstākļos. Darbā [29] tiek norādīta šāda *MAPE* interpretācija prognozes precizitātes novērtēšanā: mazāk par 10 % – ļoti augsta precizitāte, 11-20 % – laba precizitāte, 21-50% – apmierinoša precizitāte, vairāk par 50% – zema precizitāte.

Tādējādi galīgā prognozēšanas modeļa izvēles pamatā ir dažu secīgu procedūru un testu rezultāti. Galīgais prognozēšanas modelis ir viens no modeļiem ar vismazāko informācijas kritērija rādītāju, nekorelētajiem atlikumiem un visaugstāko *ex ante* prognozes precizitāti.

4. NODAĻA. PRAKTISKĀ DAĻA

Promocijas darba ceturtajā nodaļā tiek sniegts praktisko pētījumu apraksts un iegūto rezultātu analīze.

Prognozēšanas metožu efektivitāte un izstrādātā algoritma veiktspēja tika pārbaudīta ar dažāda garuma un agregācijas pakāpes reālajām laika rindām. Divas darbā izpētītās datu paraugkopas raksturo tradicionālā telefona tīkla noslodzes intensitāti un IP tīkla izejošās starptautiskās noslodzes pārraides ātrumu. Ņemot vērā ITU-T E.492 rekomendāciju [17], noslodzes sākotnējie mērījumi tika vidējoti 15 minūšu un vienas stundas garos intervālos.

1. tabula

Analizēto laika rindu vispārīgs raksturojums

Tīkla veids	Noslodzes veids	Vidējošanas periods	Rindas apzīmējums	Laika periods	Bāzes paraugkopas izmērs	Ex ante prognozēšanas paraugkopas izmērs
IP tīkls	Izejošā starptautiskā noslodze	15 min.	A	2008. g. 12. maijs – 27. jūlijs (11 ned.)	9 ned. (6048 novēr.)	1–14 diennaktis
			B	2008. g. 12. maijs – 14. augusts (14 ned.)	12 ned. (8064 novēr.)	
		1 st.	C	2008. g. 12. maijs – 27. jūlijs (11 ned.)	9 ned. (1512 novēr.)	
			D	2008. g. 12. maijs – 14. augusts (14 ned.)	12 ned. (2016 novēr.)	
Telefona tīkls	Kopējā apkalpotā noslodze	15 min.	E	2007. g. 8. janvāris – 25. marts (11 ned.)	9 ned. (6048 novēr.)	1–14 diennaktis
			F	2007. g. 8. janvāris – 15. aprīlis (14 ned.)	12 ned. (8064 novēr.)	
			G	2007. g. 8. janvāris – 27. maijs (20 ned.)	18 ned. (12096 novēr.)	
		1 st.	H	2007. g. 8. janvāris – 25. marts (11 ned.)	9 ned. (1512 novēr.)	
			I	2007. g. 8. janvāris – 15. aprīlis (14 ned.)	12 ned. (2016 novēr.)	
			J	2007. g. 8. janvāris – 27. maijs (20 ned.)	18 ned. (3024 novēr.)	

Darbā tika izvirzīts arī uzdevums noskaidrot bāzes paraugkopas izmēra ietekmi un prognozēšanas perioda ietekmi uz prognožu precizitāti un efektivitāti. Bāzes paraugkopas laika periods ir 9, 12 un dažos gadījumos – 18 nedēļas. Kopējais darbā analizēto laika rindu skaits ir desmit.

Ex ante prognozēšanas periods (testēšanas paraugkopas izmērs) tika variēts no 1 līdz 14 dienām ar vienas dienas intervālu (t. i., prognozes tika iegūtas 1, 2, 3 utt. dienas uz priekšu).

Pamatinformācija par analizētajām laika rindām ir sniegta 1. tabulā. Analizēto laika rindu fragmenti ir parādīti 8. attēlā.

Pirms prognozēšanas modeļu izvēles procesa un prognožu konstruēšanas sākšanas katrai laika rindai tika novērtētas statistiskās īpašības. Attiecīgās procedūras ir:


- izlases raksturojumu (matemātiskās cerības, dispersijas, mediānas) novērtējumi;
- stacionaritātes pārbaude ar sērijas un inversijas kritērijiem [24; 49, 767. lpp.];
- autokorelācijas funkcijas novērtējumi;
- Hērsta koeficienta novērtējumi;
- periodiskās komponentes novērtējumi.

Laikrindām, kas apraksta telefona tīkla noslodzi, inversijas kritērija nulles hipotēze gan par vidējā, gan par dispersijas stacionaritāti tika pieņemta pie nozīmīguma līmeņa $\alpha=0,05$. Laikrindām, kas apraksta IP tīkla noslodzi, inversijas kritērijs identificēja dispersijas mainīgumu pie nozīmīguma līmeņa $\alpha=0,05$. Tomēr šī novirze nav liela, jo jau pie $\alpha=0,02$ hipotēze par dispersijas stacionaritāti tika pieņemta. Līdz ar to tika nolemts šīm laika rindām neizmantojot dispersijas izlīdzināšanas procedūras.

Autokorelācijas funkcijas analīze identificēja stipras korelācijas ne tikai starp novērojumiem, kas atrodas tuvu viens otram laika skalā, bet arī starp attāliem novērojumiem. Tas norāda uz procesa „ilgo vēsturi” un iespēju iegūt ticamas prognozes pat relatīvi attālai nākotnei. Par ilglaicīgo sakarību liecina arī Hērsta koeficients, kurš pārsniedz 0,5 visām analizētajām laika rindām. Tomēr laika rindu

prognozēšanā šis novērtējums ir indikatīvs un bieži tiek kritizēts. Ir arī jāpatur prātā, ka Hērsta koeficienta novērtējumu nav iespējams tieši integrēt prognozēšanas modelī.

IP tīkla noslodzes spektrālā analīze identificēja periodiskas komponentes ar 24 stundu un 7 dienu gariem periodiem. Telefona tīkla noslodzē tika izšķirtas 12 stundu, 24 stundu un 7 dienu garas periodiskas sezonālās komponentes.




8. att. Analizēto laikeru fragmenti

• Prognozēšanas metodes apraksts

Promocijas darba praktiskā pētījuma pamatuzdevums bija laika rindu statistisko īpašību novērtējums un tāda neironu tīkla konstruēšana, kurš, ņemot vērā tam norādīto laika rindas nogriezni, ir spējīgs iegūt ticamāko prognozi iepriekš noteiktam laika intervālam nākotnē.

Neironu tīkla izvēle un apmācība, kā arī *ex ante* prognožu iegūšana tika veikta saskaņā ar 5. attēlā parādīto algoritmu. Neironu tīkla, kas tika lietots darba praktiskajos pētījumos, vienkāršota shēma ir parādīta 9. attēlā. Neironu tīklu pamata parametri, kas bija nemainīgi visiem modeļiem apmācības procesā, ir apkopoti 2. tabulā.

Daudzslāņu perceptrona arhitektūra tika noteikta šādi. Saskaņā ar teorēmu par universālo aproksimatoru slēpto slāņu skaits visos neironu tīklos bija vienāds ar vienu. Ieejas neironu skaits tika noteikts ar Furjē analīzi atbilstoši periodiskās sastāvdaļas visgarākajam periodam. Visos tīklos tika lietots viens izejas neirons. Slēpto neironu skaits bija mainīgs – robežās no 1 līdz 10. Neironu tīkla arhitektūras noteikšanas adaptīvās metodes [2, 357. lpp.; 13, 250. lpp.] netika izmantotas. Katrai arhitektūrai tika lietota verifikācija un atlikumu diagnostiskā pārbaude. Kaut gan katras iespējamās arhitektūras testēšana ir darbietilpīgs process, tas nodrošina iespēju saglabāt eksperimenta tīrību.



9. att. Promocijas darba praktiskajos pētījumos lietotā neironu tīkla (daudzslāņu perceptrona) shēma

Svariem un sliekšņiem tika piešķirtas mazas sākumvērtības no vienmērīgi sadalītā vērtību diapazona ar gadījumskaitļu ģeneratora palīdzību. Katrai atsevišķai arhitektūrai svaru inicializācija ar tālāku neironu tīkla apmācību tika veikta 100 reizes.

2. tabula

Neironu tīkla specifikācija

Posms	Parametrs / Procedūra	Parametra vērtība / procedūras apraksts
Tīkla veida un topoloģijas izvēle	Tīkla veids	Pilnsaistes daudzslāņu perceptrons ar laika aizturi
	Slēpto slāņu skaits	1
	Izejas neironu skaits	1
	Aktivizācijas funkcija	Slēptais slānis – hiperboliskais tangenss; izejas slānis – lineārā funkcija
Apmācības parametru izvēle	Apmācības epohu (ciklu) skaits	600
	Apmācības algoritms	Kļūdu atgriezeniskās izplatīšanas algoritms (100 epohas) + saistīto gradientu algoritms (500 epohas)
	Kļūdas funkcijas veids	Vidējā kvadrātiskā kļūda
	Apmācības ātruma koeficients	0,1
	Inerces koeficients	0,3
	Svaru un sliekšņu inicializācijas veids	No vienmērīgi sadalīta skaitļu diapazona ar gadījumskaitļu ģeneratora palīdzību
	Svaru un sliekšņu inicializācijas ciklu skaits	100
Apmācības optimizācija	Pārmērīgas tīkla apmācības problēmas risināšanas veidi	Šķērspārbaude [13, 218.lpp.], svaru regulēšana [47]
	Šķērspārbaudes paraugkopu izmērs	proporcijā 3:1:1
	Tīkla apmācības apturēšanas kritērijs	Apmācības kļūda paliek nemainīga 50 epohu laikā
Aproksimācijas un prognožu precizitātes novērtējums	Aproksimācijas kvalitātes novērtēšanas kritēriji	R, MAE, RMSE, MAPE, AIC, BIC
	Atlikumu diagnostiskās pārbaudes kritēriji	Lagranža reizinātāju tipa kritērijs
	Prognožu kvalitātes novērtēšanas kritēriji	RMSE, MAE, MAPE, Dībolda-Mariano kritērijs [6]

Lai izvairītos no pārmērīgas apmācības efekta, tika lietots šķērspārbaudes princips [13]. Bāzes paraugkopa tika iedalīta apmācības, pārbaudes un verifikācijas apakškopās proporcijā 3:1:1, un datu piešķiršana katrai apakškopai tika patvaļīgi variēta katram tīkla apmācības ciklam. Šāda pieeja ļauj

izvairīties no „iestrēgšanas” vietējos minimumos un paaugstina sistēmas darba stabilitāti, jo globālā minimuma meklēšana notiek dažādos virzienos un nav tieši piesaistīta laikrindas vērtību konkrētai izlasei. Lai minimizētu tīkla pārmērīgas apmācības efektu, papildus tika lietota svaru regulēšanas metode [47], bet bez tālākas neironu un sinapšu saišu izslēgšanas

Pats neironu tīklu apmācības process tika veikts ar StatSoft programmatūras STATISTICA[®] 7.0 palīdzību. Apmācība tika paveikta divos secīgos posmos. Pirmajā posmā daudzslāņu perceptrons tika trenēts, lietojot klasisko *kļūdu atpakaļgaitas izplatīšanas algoritmu* 100 epohu laikā. Šāds īss un ļoti ātrs apmācības cikls parasti ļauj aptuveni iezīmēt globālā minimuma atrašanās vietu. Otrajā posmā neironu tīkls tika apmācīts ar *saistīto gradientu* (angļu valodā – conjugate gradients) metodi, kas attiecas uz otrās kārtas optimizācijas algoritmiem. Otrā posma maksimālais epohu skaits bija 500. Tomēr šajā gadījumā apmācība tika apturēta katru reizi, kad kļūda, strādājot ar pārbaudes apakškopu, palika nemainīga 50 secīgu epohu laikā. Tas liecināja par algoritma konvergenci vai tīkla pārmērīgas apmācības sākšanos.

Uz ievaddatiem tika attiecināta korekcija, kas saistīta ar gadījuma vērtībām (angļu valodā – outliers) un anomālajām parādībām, kuru cēlonis ir sakaru tīkla darba traucējumi un svētki jeb brīvdienas, kas iekrīt parastajās darbdiēnās. Pirms apmācības sākuma visi ieejas dati tika arī pārveidoti vērtību diapazonā $[-1, 1]$, pielietojot lineāro pārveidojumu.

Neironu tīklu prognozes tika salīdzinātas ar prognozēm, kuras iegūtas ar tādām tradicionālām lineārajām metodēm kā sezonālais autoregresīvais integrētā slīdošā vidējā modelis un sezonālās eksponenciālās izlīdzināšanas modelis, kā arī ar „naivajām” prognozēm. Lai identificētu statistiski nozīmīgas atšķirības starp šādām prognozēm, kuras iegūtas, izmantojot dažādus prognozēšanas intervālus, tika lietots Dībolda-Mariano kritērijs [6]. Tas ir neparametrisks tests, kurš ir izturīgs pret dažādām novirzēm no standarta pieņēmumiem par prognozes atlikumu īpašībām. Piemēram, prognozēšanas kļūdas drīkst neatbilst klasiskajiem kritērijiem, t. i., tās var būt nenormāli sadalītas, šķērskorelētas un autokorelētas, tām var būt vidējais, kas atšķirīgs no nulles utt.

• Rezultātu novērtēšana

Laika rindu aprakstošo statistisko modeļu izvēles rezultāti, to verifikācija un gala *ex ante* prognožu novērtēšanas rezultāti ir apkopoti darba otrajā sējumā. Katrai analizētajai laika rindai tika veiktas šādas pamata operācijas:

- izvēlējās daudzslāņu perceptrona, SARIMA un sezonālās eksponenciālās izlīdzināšanas modeļus un novērtēja laika rindas aproksimācijas precizitāti;
- veidoja dažādu metožu *ex ante* prognozes un novērtēja prognožu precizitāti;
- novērtēja statistiski nozīmīgas atšķirības precizitātē starp prognozēm, kuras iegūtas ar dažādu metožu palīdzību dažādos prognozēšanas intervālos.

Galīgās *ex ante* prognozes tika novērtētas, izmantojot standarta kvalitātes parametrus – *MAE*, *RMSE* un *MAPE*, no kuriem visraksturīgākais ir pēdējais (sk. 10. att.).


Neironu tīklu prognožu precizitātes novērtējums ar relatīvo kļūdu MAPE

(A)-(D) laika rindām, kas apraksta IP tīkla izejošo starptautisko noslodzi, *MAPE* novērtējumi praktiski nemainās vai lēni pieaug līdz ar prognozēšanas horizonta palielināšanu no 24 stundām līdz 14 dienām. Tas liecina par iespēju paplašināt prognozēšanas intervālu, kuram ir iespējams iegūt ticamas prognozes.

(E)-(G) laika rindām, kas apraksta telefona tīkla noslodzi, neironu tīklu *MAPE* novērtējumi līdz ar prognozēšanas horizonta paplašināšanu strauji palielinās un prognozēm, kuras iegūtas divas nedēļas uz priekšu, tie jau pārsniedz 30%. Tas liecina par maksimālā iespējamā prognozēšanas horizonta sasniegšanu. Savukārt stundas agregācijas (H)-(J) laika rindām, *MAPE* novērtējumi saglabājas praktiski nemainīgi vai pieauga minimāli līdz ar horizonta palielināšanu no 24 stundām līdz 14 dienām, tātad prognozēšanas horizontu varētu palielināt vēl vairāk.

(A) un (B) laika rindām statistisko modeļu *MAPE* novērtējumi bija 20-25%, kas liecina par apmierinošu iegūto prognožu kvalitāti. (C) un (D) laika rindām statistisko modeļu *MAPE* novērtējumi bija 10-15 % robežās, kas liecina par ļoti labiem prognozēšanas rezultātiem.

(E)-(G) laika rindu gadījumā neironu tīklu *MAPE* novērtējums bija 21-32%, kas apstiprina apmierinošu prognožu kvalitāti. Savukārt (H)-(J) laika rindām neironu tīklu *MAPE* novērtējums bija 14-21% robežās, kas liecina par ļoti labu iegūto prognožu precizitāti.



10. att. Neironu tīklu galīgo *ex ante* prognožu *MAPE* novērtējumi dažāda garuma un agregācijas pakāpes laikrindām: (a) atkarībā no prognozēšanas horizonta, (b) secīgiem 24 stundu gariem laika intervāliem⁴

Statistiski nozīmīgu atšķirību noteikšana iegūto prognožu precizitātē

Katras laika rindas galīgās *ex ante* prognozes, kuras iegūtas ar dažādu statistisko modeļu un neironu tīklu palīdzību, izskatās līdzīgi. Tāpat, balstoties tikai uz standarta kvalitātes novērtēšanas parametriem, ir grūti izvēlēties metodi tālākai prognozēšanai reālajos apstākļos. Līdz ar to īpašu interesi izraisa uzdevums identificēt statistiski nozīmīgas atšķirības starp prognozēm, kuras iegūtas ar dažādām metodēm, piemēram, ar nelineārajiem neironu tīkliem, *SARIMA* modeli, sezonālo eksponenciālo izlīdzināšanu un „naivajām” metodēm.

Ar Dībolda-Mariano kritēriju tika izpētītas *ex ante* prognozes, kuras iegūtas katrai laika rindai 24 stundas, 7 dienas un 14 dienas uz priekšu (sk. 3. tabulu). Pirmo prognožu grupu var uzskatīt par *operatīvajām* prognozēm, bet otro un trešo – par *īstermiņa* prognozēm. Rezultāti, kuri tika iegūti, pārbaudot nulles hipotēzi par statistiski nozīmīgo atšķirību trūkumu pie nozīmīguma līmeņa $\alpha = 0,05$, ir apkopoti 3. tabulā.

IP tīkla noslodzes prognozes, kuras iegūtas ar kādu lineāro metodi (*SARIMA* vai sezonālo eksponenciālo izlīdzināšanu), precizitātē nav vājākas par neironu tīklu prognozēm visos 12 analizētajos gadījumos. Divos no 12 analizētajiem gadījumiem neironu tīkla prognoze un sezonālā naivā prognoze ir arī statistiski ekvivalentas.

⁴ Lai izvairītos no nulles vērtību ietekmes, telefona tīkla noslodzes vidējās relatīvās kļūdas (*MAPE*) novērtējumi tika aprēķināti ar nobīdi pa ordinātas asi uz 0,5 Erl attālumu. Kaut gan šāda procedūra rada *MAPE* nelielus kropļojumus, tas dod iespēju novērtēt tās dinamiskās pārmaiņas dažādiem prognozēšanas horizontiem.

3. tabula

Galīgo *ex ante* prognožu, kas iegūtas ar neironu tīkliem, salīdzinājums ar prognozēm, kas iegūtas ar citām metodēm⁵

Prognozēšanas metode \ Laikrinda / prognozēšanas horizonts	A			B			C			D		
	24 st.	7 d.	14 d.	24 st.	7 d.	14 d.	24 st.	7 d.	14 d.	24 st.	7 d.	14 d.
SARIMA	↑	=	=	↑	=	=	↑	=	↑	=	=	=
Sezonālā eksponenciālā izlīdzināšana	=	↓	↓	=	↓	↓	=	↓	↓	↓	↓	↓
„Naivā” prognoze	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓
Sezonālā „naivā” prognoze	↓	↓	↓	↓	↓	↓	=	↓	=	↓	↓	↓

Prognozēšanas metode \ Laikrinda / prognozēšanas horizonts	E			F			G			H			I			J		
	24 st.	7 d.	14 d.	24 st.	7 d.	14 d.	24 st.	7 d.	14 d.	24 st.	7 d.	14 d.	24 st.	7 d.	14 d.	24 st.	7 d.	14 d.
SARIMA	=	=	=	=	↓	↓	=	↓	↓	=	=	=	=	=	=	=	=	=
Sez. eksponenciālā izlīdzināšana	=	=	=	=	↓	↓	=	↓	↓	=	=	=	=	=	=	=	=	=
„Naivā” prognoze	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓	↓
Sezonālā „naivā” prognoze	=	↓	↓	↓	↓	↓	↓	↓	↓	=	↓	↓	=	↓	↓	=	↓	↓

Apzīmējumi:

= prognoze, kura iegūta ar šo metodi, ir statistiski ekvivalenta prognozei, kura iegūta ar neironu tīklu;

↑ prognoze, kura iegūta ar šo metodi, precizitātē pārspēj prognozi, kura iegūta ar neironu tīklu;

↓ prognoze, kura iegūta ar šo metodi, precizitātes ziņā ir vājāka par prognozi, kura iegūta ar neironu tīklu.

Tradicionālā telefona tīkla noslodzes prognozes, kuras iegūtas ar neironu tīkliem, ir statistiski ekvivalentas prognozēm, kuras iegūtas ar lineārajām SARIMA un sezonālās eksponenciālās izlīdzināšanas metodēm, 14 gadījumos no 18 analizētajiem gadījumiem. Četros no 18 analizētajiem gadījumiem netika identificētas statistiski nozīmīgas atšķirības arī starp neironu tīklu prognozēm un sezonālajām naivajām prognozēm.

Agregācijas perioda ietekme uz prognozes precizitāti

Visu analizēto laika rindu gadījumos agregācijas perioda palielināšana ir ļāvusi paaugstināt iegūto prognožu ticamību (sk. 10. att.). Agregācijas perioda palielināšana no 15 minūtēm līdz vienai stundai ir samazinājusi *ex ante* prognožu *MAPE* novērtējumus vidēji par 10 %. Tas galvenokārt ir saistīts ar modeļa izvēles vienkāršojumu laika rindas dispersijas (novērojumu izkliedes diapazona) samazinājuma dēļ.

Bāzes paraugkopas izmēra ietekme uz prognozes precizitāti

Ne IP tīkla, ne telefona tīkla noslodzi aprakstošajām laika rindām bāzes paraugkopas izmēra palielināšana (t. i., analizēto paraugu skaita palielināšana) nav izraisījusi nozīmīgu prognožu kļūdu līmeņa samazināšanos. IP tīkla noslodzes gadījumā *MAPE* novērtējums ir nedaudz zemāks (D) rindai nekā (C) rindai, bet šī atšķirība nav nozīmīga. Telefona tīkla noslodzes gadījumā *MAPE* novērtējums ir zemāks (G) rindai nekā (E) un (F) rindām, bet arī šīs atšķirības ir nenoizīmīgas. Turpretim laika rindām, kas tika agregētas pa vienas stundas gariem intervāliem, bāzes paraugkopas palielināšana no 12 līdz 18 nedēļām, ir izraisījusi prognozēšanas kļūdas paaugstināšanos.

⁵ Statistiski nozīmīgo atšķirību identificējums ar Dībolda-Mariano kritēriju pie nulles hipotēzes nozīmīguma līmeņa $\alpha=0,05$.

GALVENIE SECINĀJUMI UN REKOMENDĀCIJAS

Promocijas darba gaitā tika sasniegts *pamatmērķis* – risināt problēmas, kas ir saistītas ar prognožu iegūšanu, ja lieto nelineāros neironu tīklus. Analizējot prognozēšanas modeļu izvēles gaitu un rezultātus, aproksimācijas precizitātes novērtējumus un prognožu kvalitātes novērtējumus dažādiem prognozēšanas intervāliem, ir iegūti šādi secinājumi un sniegtas tālāk aprakstītās praktiskās rekomendācijas par prognozēšanas metožu izmantojamību telekomunikāciju jomā.

Darbā izstrādātais neironu tīkla noregulēšanas algoritms sakaru tīklu noslodzes operatīvās un īstermiņa prognozēšanas uzdevuma risināšanai ļauj automatizēt risinājuma atrašanu ar minimālu eksperta vērtējumu un cilvēka darba iesaisti.

Tradicionāli neironu tīklu lietošana ir bijusi cieši saistīta ar eksperta vērtējumu iesaistīšanu visos posmos. Darbā izstrādātais algoritms ļauj ļoti lielā mērā samazināt cilvēka faktora ietekmi un rast tādus risinājumus, kuri sniedz ticamas prognozes ar minimālu kļūdu līmeni. Analizēto laika rindu *MAPE* novērtējumi ir diapazonā no 10 % (agregācija pa vienas stundas gariem intervāliem) līdz 30 % (agregācija pa 15 minūšu gariem intervāliem). Tas apstiprina iespēju lietot šādi atrastos modeļus arī reālos apstākļos. Kritērijus, kas algoritmā lietoti galīgā prognozēšanas modeļa izvēlei – vizuālā informācijas kritērija rādītāju un atlikumu autokorelācijas trūkumu saskaņā ar Lagranža reizinātāju tipa kritēriju – var veiksmīgi lietot arī lineāro prognozēšanas modeļu izvēles procesā.

Pašlīdzības un ilglaicīgās sakarības efektu ietekme uz laika rindām, kas apraksta pakešu komutācijas tīklu noslodzi, ir novērojama tikai ļoti lielā mērogā – parasti agregācijas periodos no dažām milisekundēm līdz dažām minūtēm.

No laika rindu analīzes un prognozēšanas viedokļa pārāk liela laika mēroga izvēlei nav praktiskas nozīmes. Laika rindu aprakstošā statistiskā modeļa izvēle tiks apgrūtināta ne tikai saistībā ar korelācijām starp attālajiem laika rindas locekļiem, bet arī gadījuma vērtību un ārējo traucējumu dēļ, kas nenovēršami iejaucas mērījumos lielā mērogā. Līdz ar to, ņemot vērā ITU-T E.492 rekomendāciju [17], sakaru tīklu noslodzes mērījumus ir ieteikts agregēt / diskretizēt pa 15 minūšu un / vai 1 stundas gariem periodiem. Tādā gadījumā par faktoriem, kuri nosaka reālā procesa statistisko struktūru, kļūst sezonālie efekti un monotono trendu komponentes, kas ir galvenokārt saistītas ar abonentu uzvedību un tehniskā progresa ietekmi.

Aggregācijas un diskretizācijas intervāla izvēle saskaņā ar ITU-T E.492 rekomendāciju nodrošina iespēju iegūt ticamas operatīvās un īstermiņa prognozes pakešu komutācijas IP tīkliem, lietojot klasiskas lineārās metodes.

Darbā izskatītās laika rindas ir *tipiskas* šādu tipu noslodzei un ietver gan diennakts, gan nedēļas ciklus. Tas nozīmē, ka arī daudzām citām laikrindām ar līdzīgiem agregācijas / diskretizācijas intervāliem un autokorelācijas struktūru ir iespējams iegūt ticamas operatīvās un īstermiņa prognozes, lietojot klasiskas lineārās metodes. Neironu tīklu izmantošana laikrindu prognozēšanā ir saistīta ar daudzu parametru izvēli un novērtēšanu un prasa laika resursus tīklu apmācībai. Laiks, kas ir nepieciešams laikrindas modelēšanai un tālākai prognozēšanai, lietojot neironu tīklus, daudzkārt pārsniedz laiku, kas ir nepieciešams ticamas prognozes iegūšanai ar lineāro metožu palīdzību. Tātad šis secinājums ir svarīgs prognozēšanai reālos sakaru operatora darba apstākļos.

Neironu tīkls ir spējīgs modelēt un prognozēt sezonālās laikrindas tiešajā veidā, bez iepriekšējas laikrindas dekompozīcijas.

Sezonālās neironu tīkla modelēšanas gadījumā vissvarīgākais aspekts ir atbilstoša izmēra izvēle ieejas „logam”, kuram jāatbilst laikrindas cikliskās sastāvdaļas lielākajam periodam.

Prognozējot sakaru tīklu noslodzi, kas ir izteikta laikrindu veidā ar periodiskajām sastāvdaļām, jāorientējas uz tādu lineāro modeļu kā ARIMA un eksponenciālās izlīdzināšanas sezonālajām modifikācijām.

Atšķirībā no sintezētajām laikrindām, kuras iegūtas ar tādiem formāliem modeļiem kā fraktālā Brauna kustība, reālie noslodzes mērījumi satur sezonālās un / vai cikliskās komponentes. Tāpat kā neironu tīklu gadījumā, tā arī lineāro modeļu optimālai izmantošanai ir ļoti svarīgi korekti identificēt sezonālās komponentes periodu.

- **Potenciālie turpmāko pētījumu virzieni**

Neironu tīkli ir viens no perspektīvākajiem laikrindu modelēšanas un prognozēšanas virzieniem. Turpmākajiem pētījumiem šajā jomā jābūt vēršotiem uz tādu metožu un algoritmu radīšanu, kas labi derētu prognozēšanai *reālajā laikā*, kura pašlaik ir stipri apgrūtināta nepietiekamās skaitļošanas jaudas dēļ.

Cits interesants matemātiskais virziens ir neironu tīklu *prognožu ticamības intervālu* konstruēšanai domātu ātru un precīzu metožu izstrādāšana. Šī problēma joprojām nav atrisināta, jo jāvērtē daudz dažādu parametru, no kuriem katrs dod savu ieguldījumu kopējā modeļa nenoteiktībā.

LITERATŪRA

1. Armstrong, J.S. *Long-Range Forecasting*. New York: John Wiley & Sons, 1985.
2. Bishop, C. *Neural Networks for Pattern Recognition*. Oxford University Press, 1995.
3. Box, G.E.P., and G.M. Jenkins. *Time Series Analysis: Forecasting and Control*. San Francisco: Holden-Day, Inc., 1970.
4. Clements, M.P., and D.F. Hendry. "On the Limitations of Comparing Mean Square Forecast Errors". *Journal of Forecasting* 12 (1993): 617-637.
5. Cybenko, G. "Approximation by Superpositions of Sigmoidal Function." *Mathematics of Control, Signals, and Systems* 2 (1989): 303-314.
6. Diebold, F.C., and R.S. Mariano. "Comparing Predictive Accuracy." *Journal of Business & Economic Statistics* 13.3 (July 1995): 253-263.
7. Elman, J.L. "Finding Structure in Time." *Cognitive Science* 14 (1990): 179-211.
8. Faraway, J., and C. Chatfield. "Time Series Forecasting with Neural Networks: A Comparative Study Using the Airline Data." *Applied Statistics* 47.2 (1998): 231-250.
9. Fildes, R., and K.-P. Liao. "The Accuracy of Procedural Approach to Specifying Feedforward Neural Networks for Forecasting." *Computers & Operations Research* 32.8 (August 2005): 2151-2169.
10. Fowler, T.B. "A Short Tutorial on Fractals and Internet Traffic." *The Telecommunications Review* 10 (1999): 1-15.
11. Franses, H.P., and D. van Dijk. *Nonlinear Time Series Models in Empirical Finance*. Cambridge University Press, 2000.
12. Gardner, E.S.Jr. "Exponential Smoothing: The State of Art." *Journal of Forecasting* 4 (1985): 1-28.
13. Haykin, S. *Neural Networks: A Comprehensive Foundation*. 2nd Ed. Prentice Hall, 1999.
14. Hill, T., M. O'Connor, and W. Remus. "Neural Network Models for Time Series Forecasts." *Management Science* 42.7 (Jul. 1996): 1082-1092.
15. Hornik, K. "Multilayer Feedforward Networks are Universal Approximators." *Neural Networks* 2 (1989): 359-366.
16. ITU-T (CCITT) Recommendation E.506 (rev.1). *Forecasting International Traffic*. Geneva, 1992.
17. ITU-T Recommendation E.492. *Traffic Reference Period (Telephone Network and ISDN. Quality of Service, Network Management and Traffic Engineering)*. ITU, 02/1996.
18. ITU-T Recommendation E.507. *Models for Forecasting International Traffic*. ITU, 1993 (1988).
19. Iversen, V. B. *Teletraffic Engineering and Networks Planning*. Technical University of Denmark, 2008.
20. Janevski, T. *Traffic Analysis and Design of Wireless IP Networks*. ARTECH HOUSE, INC., 2003.
21. Kaastra, I., and M. Boyd. "Designing a Neural Network for Forecasting Financial and Economic Time Series." *Neurocomputing* 10 (1996): 215-236.
22. Klevecka, I., and J. Lelis. "Application of Extrapolation Methods to the Technology Diffusion Forecasting." *Scientific Proceedings of Riga Technical University (Series "Telecommunications and Electronics ")* 7 (2007): 52-59.
23. Klevecka, I., and J. Lelis. "Perspective Evaluation of the Electronic Communications Market in Latvia." *Proceedings of the 18th European Regional ITS Conference*. Sep. 2007, Istanbul, Turkey. Berlin: International Telecommunications Society, 2007. 1-37. CD-ROM.
24. Klevecka, I., and J. Lelis. "Pre-Processing of Input Data of Neural Networks: The Case of Forecasting Telecommunication Network Traffic." Spec. issue of *Elektronika* 104.3/4 (2008): 168-178.
25. Kolen, P., and J.B. Pollack. "Back Propagation in Sensitive to Initial Conditions." *Proceedings of the Conference on Advances in Neural Information Processing Systems*. Nov. 1989, Denver, United States. San Francisco: The MIT Press, 1990. 860-867.
26. Kunst, R.M. *Testing for Relative Predictive Accuracy: A Critical Viewpoint*. Economics Series 130. Vienna: Institute for Advanced Studies (IHS), 2003.
27. LeCun, Y., L. Bottou, G.B. Orr, and K.-R. Müller. "Efficient BackProp." *Neural Networks: Tricks of the Trade*. Eds. G.B. Orr and K.-R. Müller. Berlin: Springer, 1998. 9-50.
28. Leland, W.E., M.S. Taqqu, W. Willinger, and D.V. Wilson. "On the Self-Similar Nature of Ethernet Traffic (Extended Version)." *IEEE/ACM Transactions on Networking* 2.1 (February 1994): 1-15.
29. Lewis, C.D. *Industrial and Business Forecasting Methods: A Practical Guide to Exponential Smoothing and Curve Fitting*. London: Butterworth Scientific, 1982.
30. Ljung, G.M., and G.E. Box. "On a Measure of Lack of Fit in Time Series Models." *Biometrika* 65 (1978): 297-303.
31. Makridakis, S., and R.L. Winkler. "Sampling Distributions of Post-sample Forecasting Errors." *Applied Statistics* 38.2 (1989): 331-342.
32. McNelis, P.D. *Neural Networks in Finance: Gaining Predictive Edge in the Market*. Elsevier Academic Press, 2005.
33. Meade, N. "Evidence for the Selection of Forecasting Methods." *Journal of Forecasting* 19 (2000): 515-535.

34. Medeiros, M.C., T. Teräsvirta, and G. Rech "Building Neural Network Models for Time Series: A Statistical Approach." *Journal of Forecasting* 25 (2006): 49-75.
35. Mozer, M. C. "Neural Network Architectures for Temporal Pattern Processing." *Time Series Prediction: Forecasting the Future and Understanding the Past*. Eds. A.S. Weigend and N. A. Gershenfeld. Perseus Book Publishing, 1993. 243-264.
36. Park, C., F. Hernandez-Campos, J.S. Marron, and F.D. Smith. "Long-Range Dependence in a Changing Traffic Mix." *Computer Networks* 48 (2005): 401-422.
37. Park, K., and W. Willinger. "Self-Similar Network Traffic: An Overview." *Self-Similar Network Traffic and Performance Evaluation*. Eds. K. Park, and W. Willinger. John Wiley & Sons, 2000. III-XLIX.
38. Priestley, M.B. *Spectral Analysis and Time Series*. London: Academic Press, 1981.
39. Ryu, B.K., and A. Elwalid. "The Importance of Long-Range Dependence of VBR Video Traffic in ATM Traffic Engineering: Myths and Realities." *ACM SIGCOMM Computer Communication Review* 26.4 (1996): 3-14.
40. Sang, A., and S.-q. Li. "A Predictability Analysis of Network Traffic." *Computer Networks* 39 (2002): 329-345.
41. Sheluhin, O.I., S.M. Smolskiy, and A.V. Osin. *Self-Similar Processes in Telecommunications*. John Wiley & Sons, 2007.
42. Tang, Z., and P.A. Fishwick. "Feedforward Neural Nets as Models for Time Series Forecasting" *ORSA Journal on Computing* 5.4 (Fall 1993): 374-385.
43. Tashman, L.J. "Out-of-Sample Tests of Forecasting Accuracy: An Analysis and Review." *International Journal of Forecasting* 16.4 (October 2000): 437-450.
44. Taylor, J.W., L.M. de Menezes, and P.E. McSharry. "A Comparison of Univariate Methods for Forecasting Electricity Demand up to a Day Ahead." *International Journal of Forecasting* 22 (2006): 1-16.
45. *Teletraffic Engineering Handbook*. ITU-D (Study Group 2, Question 16/2), June 2006.
46. Thimm, G., and E. Fiesler. *Optimal Setting of Weights, Learning Rate, and Gain*. IDIAP Research Report 97-04. Switzerland: IDIAP, 1997.
47. Weigend, A. S., D. E. Rumelhart, and B. A. Huberman. "Generalization by Weight-Elimination with Application to Forecasting." *Advances in Neural Information Processing Systems* 3. Eds. R.P.Lippmann, J. Moody, and D. S. Touretzky. San Mateo, CA: Morgan Kaufmann, 1991. 875-882.
48. Yaffe, R.A, and M. McGee. *Introduction to Time Series Analysis and Forecasting with Applications of SAS and SPSS*. Academic Press, 2000.
49. Айвазян С.А., Мхитарян В.С. Прикладная статистика и основы эконометрики. – М.: Издательское объединение «ЮНИТИ», 1998. – 1005с.
50. Дрейпер Н., Смит Г. Прикладной регрессионный анализ, 3-е изд.: Пер. с англ. – М.: Издательский дом «Вильямс», 2007. – 912с.
51. Канторович Г.Г. Анализ временных рядов // Экономический журнал ВШЭ. №1 2002, с.85-116.
52. Колемаев В.А., Калинина В.Н. Теория вероятностей и математическая статистика. – М.: ИНФРА-М, 1997.- 302с.
53. Комарцова Л., Максимов А. Нейрокомпьютеры: Учеб. пособие для вузов. - М.: Издательство МГТУ имени Н.Э. Баумана, 2002. – 320с.
54. Комашинский В.И., Смирнов Д.А. Нейронные сети и их применение в системах управления и связи. – М.: Горячая линия-Телеком, 2003. – 94с.
55. Крислов В., Чумичкин К., Конратюк А. Представление исходных данных в задачах нейросетевого программирования// V Всероссийская научно-техническая конференция "Нейроинформатика-2003": Сборник научных трудов. Ч. 1. - М: МИФИ, 2003, с 184-191.
56. Крылов В.В., Самохвалова С.С. Теория телетрафика и ее приложения. – Спб.: БХВ-Петербург, 2005. – 288с.
57. Тюрин Ю.Н., Макаров А.А. Статистический анализ данных на компьютере. – М.: ИНФРА, 1998. – 528с.
58. Шмертер Х., Белендорф Э. и др. Теория телетрафика. – М.: Связь, 1971. – 319с.