



სსიპ სამცხე-ჯავახეთის სახელმწიფო უნივერსიტეტი  
ინჟინერიის, აგრარულ და საბუნებისმეტყველო მეცნიერებათა ფაკულტეტი  
ინფორმატიკის სადოქტორო პროგრამა

სერგო მიქელაძე

კომპიუტერულ ქსელებში სისტემის რხევების

შემცირების ალგორითმების შემუშავება

ინფორმატიკის დოქტორის აკადემიური ხარისხის

მოსაპოვებლად წარმოდგენილი

დისერტაცია

სამეცნიერო ხელმძღვანელ(ებ)ი:

რომან სამხარაძე, ინფორმატიკის დოქტორი, პროფესორი

ჯემალ მამაიაშვილი, ეკონომიკის დოქტორი, პროფესორი

ახალციხე

წელი 2025

## განაცხადი

სერგო მიქელაძე ვაცხადებ, რომ წარმოდგენილი სადისერტაციო ნაშრომი წარმოადგენს ჩემს ორიგინალურ ნამუშევარს და არ შეიცავს სხვა ავტორების მიერ აქამდე გამოქვეყნებულ, გამოსაქვეყნებლად მიღებულ ან დასაცავად წარდგენილ მასალას, რომელიც ნაშრომში არ არის მოხსენიებული ან ციტირებული სათანადო წესების შესაბამისად.

ხელმოწერა

თარიღი

*ნაშრომს ვუძღვნი ჩემს შვილებს, მეუღლესა და ოჯახის წევრებს. თქვენი  
სიყვარული, მოთმინება და ურყევი მხარდაჭერა იყო ჩემი მუდმივი  
მოტივაცია ამ გზაზე. ეს მიღწევა ისევე თქვენია, როგორც ჩემი.*

## მადლიერება

მსურს, განსაკუთრებული მადლიერება გამოვხატო ჩემი სამეცნიერო ხელმძღვანელების: პროფესორ რომან სამხარაძისა და პროფესორ ჯემალ მამაიაშვილის მიმართ, მათი ფასდაუდებელი რჩევების, მხარდაჭერისა და პროფესიული ხელმძღვანელობისთვის, რამაც გადაწყვეტი როლი ითამაშა კვლევის წარმატებით განხორციელებაში.

მადლობას ვუხდით სამცხე-ჯავახეთის სახელმწიფო უნივერსიტეტის ადმინისტრაციასა და ფაკულტეტს იმ რესურსებისა და გარემოს უზრუნველყოფისთვის, რაც აუცილებელი იყო ამ სამეცნიერო ნაშრომზე მუშაობისთვის.

ასევე, მადლობას ვუხდით ჩემს კოლეგებსა და მეგობრებს ინტელექტუალური სტიმულისა და იმ მორალური მხარდაჭერისთვის, რომელსაც კვლევის ყველაზე რთულ ეტაპებზე ვგრძნობდი.

და ბოლოს, კიდევ ერთხელ მადლობა ჩემს ოჯახს. მათი თავდადებისა და ჩემდამი რწმენის გარეშე, ამ სადოქტორო პროგრამის დასრულება შეუძლებელი იქნებოდა.

# სარჩევი

სარჩევი .....	5
თავი 1 .....	28
ტრაფიკის მოდელები და მეთოდები მონაცემთა ქსელებში გადატვირთულობის წინააღმდეგ საბრძოლველად.....	28
1.1 ტრაფიკის მოდელების კლასიფიკაცია და მათი როლი გადატვირთვის შეფასებაში.....	28
1.1.1 აღდგენით პროცესებზე დაფუძნებული მოდელები .....	29
1.1.2 მარკოვის პროცესებზე დაფუძნებული მოდელები .....	32
1.1.3 ავტორეგრესიული მოდელები და მათი გამოყენება ქსელური ტრაფიკის ანალიზში .....	35
1.1.4 თვითმსგავსი მოდელები .....	39
1.1.5 აპლიკაციაზე დამოკიდებული ტრაფიკის მოდელები.....	41
1.2 ტრაფიკის მართვის მეთოდები მონაცემთა გადაცემის ქსელებში .....	43
1.2.1 ღია მარყუჟის გადატვირთულობის მართვის მეთოდები.....	45
1.2.2 გადატვირთულობის დინამიკური მართვა უკუკავშირის საფუძველზე.....	50
1.2.3 გადატვირთულობის კონტროლის მექანიზმები TCP პროტოკოლში.....	52
თავი 2 .....	56
ექსპერიმენტული კვლევის მეთოდოლოგია და შედეგების ანალიზი.....	56
2.1 ექსპერიმენტული გარემოს აღწერა .....	56
2.2 მონაცემთა სტატისტიკური და სპექტრული ანალიზი .....	66
2.3 მონაცემთა არაწრფივი დინამიკური თვისებების ანალიზი .....	72
თავი 3 .....	85
მონაცემთა გადაცემის ქსელებში პროგნოზირების მეთოდების შედარებითი ანალიზი .....	85

3.1 დროის სერიების პროგნოზირების ალგორითმები .....	85
3.2 პროგნოზი დაფუძნებული AR ( $p$ )- მოდელი .....	97
3.3 პროგნოზი ARIMA ( $p$ , $d$ , $q$ )- მოდელის საფუძველზე.....	102
3.4 პროგნოზი SSA მეთოდით ("Caterpillar").....	106
3.5 ნეირონული ქსელის მოდელი.....	108
3.6 პროგნოზირების მოდელების ექსპერიმენტული შედარება.....	111
თავი 4 .....	118
ქსელის მოდელის შემუშავება დატვირთვის მოკლევადიანი პროგნოზით .....	118
4.1 ქსელის სიმულაციური მოდელის შექმნა.....	118
4.2 დანერგილი TCP QoS ალგორითმები.....	124
4.3 პაკეტით გადართვის ქსელის მოდელის დანერგვა TCP ალგორითმების გამოყენებით .....	126
4.4 მიღებული მოდელის გამოთვლილი მახასიათებლები .....	132
4.5 მოდელის მუშაობის შეფასება პროგნოზირების ალგორითმის გამოყენებით .....	136
დასკვნა .....	141
გამოყენებული ლიტერატურა .....	151

## ანოტაცია

ინფორმაციული ტექნოლოგიების მუდმივი ზრდის ფონზე კომპიუტერულ ქსელებში წარმოიშვა მრავალი პრობლემა, რომელიც დაკავშირებულია სისტემის სტაბილურობასთან, ტრაფიკის არაპროგნოზირებადობასთან და გადატვირთულობის მექანიზმების არაეფექტიანობასთან. ამ კონტექსტში განსაკუთრებით მნიშვნელოვან საკითხად წარმოჩინდება სისტემის რხევების იდენტიფიცირება, შეფასება და მათი შემცირებისათვის შესაბამისი ალგორითმების შემუშავება, რაც უზრუნველყოფს ქსელის გამტარობის, დროულობის და მომსახურების უწყვეტობის გაუმჯობესებას.

თანამედროვე კომპიუტერულ ქსელებში გადატვირთულობის მართვა და სისტემის სტაბილური ფუნქციონირება პირდაპირ არის დამოკიდებული იმ მექანიზმებზე, რომლებიც უზრუნველყოფენ ტრანსპორტირებული ტრაფიკის თვისობრივ ანალიზს, მისი დინამიკის პროგნოზირებასა და შესაბამის რეაგირებას. დისერტაცია ემყარება იმ მეცნიერებრივ ამოცანას, რომ რეალურ ქსელებში სისტემური რხევები, რომლებიც ვლინდება QoS-ის ხარისხის გაუარესებით, საჭიროებს რთულ, მათემატიკურად მყარ და პრაქტიკულად გამოსადეგ ანალიტიკურ მეთოდებს.

კვლევის პირველ ეტაპზე განხორციელდა კორპორატიულ ქსელში აგრეგირებული ტრაფიკის რეალური მონაცემების შეგროვება და ანალიზი. გამოყენებულ იქნა როგორც დროის სერიების სტატისტიკური ანალიზი (მათ შორის ავტოკორელაცია, ტრენდული ცვალებადობა, ავტორეგრესიული მოდელები), ისე არაწრფივი დინამიკის მეთოდები, როგორებიცაა ფრაქტალური და ქაოსური ანალიზი, ჰერსტის ინდექსის გამოთვლა, ლაპუნოვის ექსპონენტების და სიგნალის სირთულის შეფასება. აღნიშნული მეთოდების გამოყენება მიზნად ისახავდა ტრაფიკის ქცევის კანონზომიერებების გამოვლენას და სიმულაციური მოდელებისთვის შესაბამისი სტრუქტურის შემუშავებას.

მეორე ეტაპზე მოხდა სიმულაციური მოდელების შექმნა NS-3 და Cisco Packet Tracer-ის პლატფორმებზე, რომლებიც ემულირებდნენ რეალურ ქსელურ ტოპოლოგიებსა და დატვირთვის სცენარებს. მოდელირება ითვალისწინებდა აპარატურულ რესურსებზე (CPU, RAM, არხების გამტარობა) დატვირთვის კოორდინირებულ ცვლილებას ტრაფიკის ინტენსივობის ზრდის პირობებში.

აღნიშნული მოდელების მეშვეობით დადასტურდა პირდაპირი კავშირი ტრაფიკის მახასიათებლებსა და სისტემურ რესურსებზე ზეწოლას შორის, რაც კრიტიკულად მნიშვნელოვანია ტრაფიკის მართვის ეფექტიანი სტრატეგიების შესარჩევად.

კვლევის მესამე ეტაპზე შემუშავდა ალგორითმიული მიდგომა ტრაფიკის პროგნოზირებისა და რხევებზე რეაგირების მიზნით, რომელიც აერთიანებს სტატისტიკური პროგნოზირების (ARIMA, SSA) და ხელოვნური ნეირონული ქსელების (ANN, RNN) მეთოდებს. თითოეული მოდელის ეფექტიანობა შეფასდა MAE, MAPE და SMSE მაჩვენებლებით. ექსპერიმენტულმა შედეგებმა აჩვენა, რომ ტრადიციული პროგნოზირების მოდელების კომბინაცია ANN-თან მნიშვნელოვნად ამცირებს პროგნოზირების ცდომილებას და აუმჯობესებს ქსელურ რესურსებზე რეაგირების სისწრაფეს.

ნაშრომის მნიშვნელოვანი სამეცნიერო სიახლე შემდგომში მდგომარეობს:

1. პირველად განხორციელდა კორპორატიული ქსელის სერვერზე აგრეგირებული ტრაფიკის ფრაქტალურ-ქაოსური მახასიათებლების რაოდენობრივი შეფასება, რაც ადასტურებს ტრაფიკის არაწრფივ ბუნებას და თვითმსგავსობით გამოწვეულ სირთულეებს პროგნოზირებაში.
2. დადგინდა სტატისტიკურად მნიშვნელოვანი კორელაცია სერვერის აპარატურულ დატვირთვასა და ტრაფიკის ინტენსივობას შორის, რაც საშუალებას იძლევა მომავლის დატვირთვის უკეთესი განაწილების დაგეგმვისთვის.
3. შემუშავდა მოკლევადიანი პროგნოზირების მოდელი შემომავალი ტრაფიკისთვის, რომელიც ეყრდნობა სერიის არაწრფივი მახასიათებლების ანალიზს და უკუკავშირის პრინციპზე აგებული რეაგირების მექანიზმია.
4. შემუშავებული სიმულაციური მოდელები სწორად ასახავს ქსელის რეალურ ქცევას როგორც რაოდენობრივი, ისე სტრუქტურული მახასიათებლების მიხედვით, რაც საშუალებას იძლევა მათ საფუძველზე შემუშავდეს დინამიური QoS მენეჯმენტის სტრატეგიები.

დისერტაციაში გამოყენებული კვლევითი მეთოდოლოგია ეყრდნობა მრავალსაფეხურიან, შერწყმულ ანალიზს, რომელიც აერთიანებს:

- კლასიკურ სტატისტიკას და პროგნოზირებას (ARIMA, კორელაცია);

- არაწრფივი დინამიკის თეორიას (ჰერსტი, ქაოსი, ლაპუნოვი);
- სიმულაციურ მოდელირებას რეალურ ქსელურ სცენარებზე;
- ნეირონული პროგნოზირების ალგორითმებს.

კვლევის სანდოობა დასტურდება გამოყენებული მეთოდების ადეკვატურობით, მონაცემთა წარმომავლობით (რეალურ სერვერზე აღებული), მოდელების მრავალჯერადი გამეორებით სხვადასხვა ტოპოლოგიაზე და სიმულაციური შედეგების თანხვედრით თეორიულ მოდელებთან. კვლევის შედეგები გამოიყენება როგორც ISP-ებისთვის, მონაცემთა ცენტრებისთვის, ისე სახელმწიფო სტრუქტურებისთვის, სადაც მაღალი ქსელური სტაბილურობა და წინასწარ პროგნოზირებადი QoS არის მნიშვნელოვანი მოთხოვნა.

დისერტაციაში წარმოდგენილი მიდგომები ქმნის საფუძველს ინტელექტუალური ტრაფიკ-მენეჯმენტის სისტემების განვითარებისთვის, რომლებიც შეძლებენ ქსელური რესურსების დინამიკურ მართვას თვითმასწავლებელი მოდელების საფუძველზე და გადატვირთულობის პრევენციის რეალურ დროში იმპლემენტაციას.

# Development of Algorithms for Reducing System Fluctuations in Computer Networks

**Abstract**

**S.Mikeladze**

Against the backdrop of the rapid advancement of information technologies, numerous challenges have emerged in modern computer networks particularly those related to system stability, the unpredictability of traffic dynamics, and the inefficiency of congestion control mechanisms. In this context, a critical research priority is the identification, assessment, and mitigation of system fluctuations, aiming to enhance network throughput, latency performance, and service continuity.

In contemporary network infrastructures, congestion control and system stability are directly dependent on mechanisms capable of conducting qualitative traffic analysis, predicting its dynamic behavior, and implementing appropriate responses. This dissertation is founded upon the scientific assumption that system fluctuations, as manifested by degraded Quality of Service (QoS), necessitate complex, mathematically grounded, and practically applicable analytical methods.

In the first phase of the research, real aggregated traffic data were collected and analyzed from a corporate network server. The analysis employed both statistical time series techniques including autocorrelation, trend decomposition, and autoregressive modeling and nonlinear dynamics methods, such as fractal and chaotic analysis, Hurst exponent estimation, Lyapunov exponents, and signal complexity assessment. The objective of this phase was to uncover intrinsic traffic behavior patterns and to develop a simulation model architecture that accurately reflects them.

In the second phase, simulation models were constructed using NS-3 and Cisco Packet Tracer platforms, which emulated realistic network topologies and varying load conditions. These models considered coordinated variations in hardware resource usage CPU, RAM, and channel bandwidth under changing traffic intensities. The simulation confirmed a direct correlation between traffic characteristics and stress on system resources, a key consideration in the formulation of effective traffic control strategies.

The third phase resulted in the development of an algorithmic framework for traffic forecasting and fluctuation management, integrating both statistical forecasting models (ARIMA, SSA) and artificial neural network-based methods (ANN, RNN). Each model's effectiveness was evaluated using MAE, MAPE, and SMSE metrics. Experimental comparisons demonstrated that combining classical forecasting models with ANN substantially reduced prediction errors and improved system responsiveness to traffic fluctuations.

#### Major Scientific Contributions:

1. For the first time, a quantitative analysis of fractal and chaotic characteristics of aggregated traffic in a corporate network server was conducted, confirming the nonlinear and self-similar nature of traffic, as well as the challenges it poses for predictive modeling.
2. A statistically significant correlation was established between traffic intensity and hardware load, particularly emphasizing CPU and RAM usage, which lays a foundation for optimal resource distribution planning under different traffic scenarios.
3. A short-term forecasting model for incoming traffic was developed, based on nonlinear time series analysis and a feedback-based response mechanism.
4. The constructed simulation models accurately reflect real-world network behavior in both quantitative and structural terms, enabling the formulation of adaptive QoS management strategies.

The research methodology employed in the dissertation is grounded in a multi-level integrative analytical approach, which combines:

- Classical statistical analysis and forecasting (e.g., ARIMA, correlation analysis);
- Nonlinear dynamics theory (e.g., Hurst exponent, chaos theory, Lyapunov exponents);
- Simulation modeling of real network scenarios (via NS-3 and Cisco Packet Tracer);
- Artificial neural network-based prediction algorithms.

#### Research Reliability:

The reliability and validity of the research outcomes are supported by the adequacy of the selected mathematical and statistical techniques, the authenticity of the real-world data collected from operational servers, the repeatability of experiments across diverse topologies, and the convergence between simulation results and theoretical expectations. The findings are

applicable to ISPs, data centers, and public sector network infrastructures, where operational stability and predictability of QoS are of paramount importance.

The proposed approach offers a practical foundation for the development of intelligent traffic management systems, capable of real-time congestion avoidance and dynamic resource allocation through self-adaptive learning-based models.

## შესავალი

სატელეკომუნიკაციო ტექნოლოგიების სწრაფი განვითარება და ინფორმაციის გადაცემისა და დამუშავების ღირებულების შემცირება იწვევს ქსელური ტრაფიკის მოცულობის მუდმივ ზრდას. Sandvine-ის 2024 წლის გლობალური ინტერნეტ ფენომენის ანგარიშის მიხედვით, გლობალური ინტერნეტ ტრაფიკი დღეში 33 ექსაბაიტს აღწევს, ხოლო თითოეული მომხმარებლის საშუალო მოხმარება 4.2 გიგაბაიტია დღეში (Marwaha 2024).

Sandvine-ის 2025 წლის გლობალური ინტერნეტ ფენომენის (GIPR) ანგარიშის თანახმად, გლობალური ინტერნეტ ტრაფიკი კვლავ მზარდია, რაც გამოწვეულია AI-დამხმარე პლატფორმების, ვიდეო სტრიმინგის და encrypted-ტრაფიკის ინტენსიფიკაციით. განსაკუთრებით მნიშვნელოვანია, რომ AI-ზე დაფუძნებული სერვისები (მაგ. Copilot, Gemini, ChatGPT) ფიქსირებულ ქსელებში უკვე 7%-მდე ტრაფიკს და მობილურში 4%-მდე იზოლირებულ დატვირთვას ქმნიან, რაც მიუთითებს ახალ QoS მოთხოვნებზე (sandvine n.d.).

2025 წლის მონაცემებით, ქსელური ტრაფიკის QoS-ისთვის განსაკუთრებით კრიტიკული გახდა AI-დამხმარე სერვისების დაბალი დაგვიანებით მიწოდება, რეკლამული ანალიტიკის ტრაფიკის ოპტიმიზაცია და live-streaming-ის პიკური ტალღების მენეჯმენტი. Sandvine მიუთითებს, რომ ყოველი დიდი სპორტული ან მედიამომენტები ქსელის დატვირთვას 3–4-ჯერ აჭარბებს ჩვეულებრივზე, რაც იწვევს ტრაფიკის არასტაბილურობას და სისტემური რხევების აქტივაციას (sandvine n.d.).

გარდა ამისა, მსხვილი კონტენტ-პროვაიდერები, როგორცაა Google, Facebook და Netflix, უზრუნველყოფენ ფიქსირებული ტრაფიკის 65%-ს და მობილური ტრაფიკის 68%-ს. ეს მიუთითებს მულტიმედიური აპლიკაციების, განსაკუთრებით თანამედროვე რეალურ დროზე ორიენტირებულ ქსელურ სერვისებში, განსაკუთრებით კი ხმოვანი და ვიდეოკავშირისას (VoIP/WebRTC), AI-დამხმარე კომუნიკაციისთვის, ასევე რეკლამულ ანალიტიკასა და live-streaming ტრანსლაციებზე, გადაცემის დაგვიანებები წარმოადგენს ერთ-ერთ კრიტიკულ მახასიათებელს, რომელიც უშუალოდ ზემოქმედებს მომსახურების ხარისხზე (QoS) (sandvine n.d.). კვლევებისა და საერთაშორისო სტანდარტების მიხედვით (ITU-T G.114), ხმოვანი მონაცემების

გადაცემისას დაყოვნება 10 მილიწამს ზემოთ უკვე განიხილება კრიტიკულ ზღვარზე მყოფ ნაკადად, ხოლო ჯამური ერთი მიმართულების დაგვიანება არ უნდა აღემატებოდეს 100 მილიწამს, რათა არ დაირღვეს საუბრის ბუნებრივი რიტმი და ინტერაქციის ხარისხი: **“Delay values up to 150 ms are acceptable for most user applications. However, delay values above 100 ms are noticeable, and above 150 ms can impact the interactivity of voice conversations”** (itu.int 2003).

აღნიშნული მოთხოვნები კიდევ უფრო მკაცრდება ვიდეოკავშირის შემთხვევაში, განსაკუთრებით ისეთი ტექნოლოგიებისთვის, როგორცაა WebRTC, SIP და სხვა მედია-სერვისები: **“End-to-end latency should be kept below 150 ms for optimal media quality. Latency above 200 ms is typically unacceptable for conversational video”**

(Alvestrand 2021).

ამგვარი ნაკადებისთვის, სტაბილური QoS-ის უზრუნველსაყოფად, აუცილებელია მინიმუმამდე დაყვანილი jitter ( $\leq 20-30$  ms), პაკეტის დაკარგვის მაჩვენებელი არაუმეტეს 0.5–1%, ხოლო წვდომის ლატენცია არ უნდა აღემატებოდეს 150 მილიწამს. შესაბამისად, გადაცემის დაბალი დაგვიანების, პაკეტის სტაბილური მიწოდების და jitter-ის შემცირების მოთხოვნები მნიშვნელოვნად ზრდის მოთხოვნებს როგორც ქსელურ ინფრასტრუქტურაზე, ისე ტრაფიკის მართვის ალგორითმებსა და, განსაკუთრებით, გადატვირთულობის საწინააღმდეგო მექანიზმებზე. მათ შორის, აქტიურად გამოიყენება ალგორითმები, როგორცაა RED (Random Early Detection), FQ-CoDel (Fair Queuing Controlled Delay) და სხვები, რომლებიც უზრუნველყოფენ ტრაფიკის კლასიფიკაციას, წონასწორობის შენარჩუნებასა და პრიორიტეტულ ნაკადებზე სერვისის უწყვეტ მიწოდებას, რაც ზრდის მოთხოვნას მონაცემთა გადაცემის ქსელებზე, ტრაფიკის მართვის ალგორითმებზე და გადატვირთვის წინააღმდეგ ბრძოლის მეთოდებზე (Osel Lhamo 2024). თუმცა Sandvine-ის (2025) თანახმად, ტრადიციული ტრაფიკის მართვის ალგორითმები, როგორებიცაა RED, FQ-CoDel და PIE, 2025 წლისთვის აღარ მიიჩნევა საკმარისად მოქნილად AI-დამოკიდებულ ან მკვეთრი პიკური ტრაფიკის მქონე სცენარებში. შესაბამისად, Sandvine-ს რეკომენდაციას იძლევა ინტელექტუალური ალგორითმების დანერგვას,

რომლებიც უზრუნველყოფენ ტრაფიკის ტიპის მიხედვით რეაგირებას და უკუკავშირის ადაპტურ მართვას (sandvine n.d.).

ტრაფიკის მართვა წარმოადგენს ერთ-ერთ ცენტრალურ ამოცანას ქსელში მომსახურების ხარისხის (QoS Quality of Service) უზრუნველსაყოფად, რაც აბონენტებისთვის სტაბილური და პროგნოზირებადი კავშირის მიწოდებას გულისხმობს. როგორც ტანენბაუმი აღნიშნავს, მომსახურების ხარისხი დამოკიდებულია არა მხოლოდ გამტარუნარიანობასა და დაგვიანების შემცირებაზე, არამედ ქსელის სტრუქტურულ დაგეგმვასა და ეფექტურ მარშრუტიზაციაზე.

ქსელის ტოპოლოგიის თვალსაზრისით, ტრაფიკის მართვის პროცესში ორი ძირითადი კომპონენტი განიხილება: ქსელის დაგეგმვა და ოპტიმიზაცია. ქსელის დაგეგმვა გულისხმობს საკომუნიკაციო არხებისა და მათი გამტარუნარიანობის განსაზღვრას მოსალოდნელი დატვირთვის გათვალისწინებით. ამ ეტაპზე გათვალისწინებულია აბონენტების რაოდენობა, მომსახურების ტიპები და მონაცემთა ნაკადების გენერაციის მახასიათებლები (Skarp 2024).

ქსელის ოპტიმიზაცია, მოიცავს არსებულ ინფრასტრუქტურაზე ტრაფიკის განაწილების მართვას ისე, რომ მინიმუმამდე შემცირდეს გადატვირთვა, დაგვიანება და პაკეტების დაკარგვა. ამისათვის გამოიყენება ტრაფიკის მენეჯმენტის მექანიზმები, როგორცაა მარშრუტების დინამიური არჩევა, დატვირთვის დაბალანსება და რიგების მართვის ალგორითმები.

ტანენბაუმისა და ვეზეროლის მიხედვით, კომპიუტერულ ქსელებში ტრაფიკის ეფექტური მართვა კრიტიკულია, რათა უზრუნველყოფილ იქნას რესურსების ოპტიმალური გამოყენება და ქსელის მომსახურების ხარისხის (QoS) შენარჩუნება სხვადასხვა დატვირთვის პირობებში (Tanenbaum და Wetherall 2011, 311-312). QoS-ის უზრუნველყოფა დაკავშირებულია რამდენიმე სტრუქტურულ გამოწვევასთან, რომელთაგანაც განსაკუთრებული მნიშვნელობა ენიჭება ტრაფიკის მართვასა და გადატვირთულობის კონტროლს. ავტორები ხაზს უსვამენ, რომ ეფექტურად დაგეგმილი გადატვირთულობის მართვის ალგორითმებს შეუძლიათ მნიშვნელოვნად გააუმჯობესონ არა მხოლოდ ქსელის საიმედოობა, არამედ მთლიანი

გამტარუნარიანობა ანუ იმ მონაცემთა მოცულობა, რომელსაც სისტემა რეალურად და ეფექტიანად გადასცემს ერთეულ დროში (Tanenbaum და Wetherall 2011, 424-425).

გადატვირთულობა (congestion) წარმოიშობა მაშინ, როდესაც ქსელში გადაცემული ტრაფიკის მოცულობა უახლოვდება ან აჭარბებს მის ფიზიკურ ან ლოგიკურ გამტარუნარიანობას. IP პროტოკოლის, როგორც დაუკავშირებელი (connectionless) სქემის, ერთ-ერთი შეზღუდვა სწორედ ის არის, რომ ის არ ითვალისწინებს ტრაფიკის მოცულობის წინასწარ შეფასებას. შესაბამისად, როუტერებსა და გადართვის მოწყობილობებს არ აქვთ უნარი წინასწარ განსაზღვრონ შემომავალი ნაკადის სიჭარბე. ასეთი პირობებისას შესაძლებელია, რომ არსებული ბუფერი სწრაფად აივსოს, რის შედეგადაც ახალ პაკეტებს ევლება უარყოფა (packet drop) ან ხდება მათი ხელახალი გაგზავნა, რაც წარმოქმნის დამატებით დატვირთვასა და პასუხის ინტერვალის ზრდას.

ამგვარად იწყება ციკლური, თვითგამამძლიერებელი გადატვირთულობის პროცესი, რომელსაც თან ახლავს ქსელის არასტაბილურობა, პაკეტების დაგვიანება და გამტარუნარიანობის შემცირება. პრობლემა კიდევ უფრო მძაფრდება, თუ გავითვალისწინებთ, რომ ქსელურ კვანძებში არსებული ბუფერები სიგრძით შეზღუდულია.

TCP პროტოკოლის მიერ გამოყენებული უკუკავშირის მექანიზმები (მაგალითად, ACK შეტყობინებები ან სლაიდინგ ფანჯრის ზომა) არ იძლევა ქსელის შიდა მდგომარეობის პირდაპირ შეფასებას. ამის გამო, მონაცემთა გადაცემა ხშირად მიმდინარეობს ნაწილობრივ „ბრმა რეჟიმში“, რაც განსაკუთრებით გადატვირთულობის პირობებში იწვევს ქსელის რესურსების არაეფექტიან გამოყენებას ( Tanenbaum, Feamster და Wetherall 2021, 403-404).

ქსელის ნორმალური ფუნქციონირებისთვის აუცილებელია გამტარუნარიანობის შენარჩუნება მისაღებ დონეზე. უკუკავშირზე დაფუძნებული რიგი ტექნიკა საშუალებას იძლევა, რომ ტევადობა კონტროლდებოდეს დატვირთვის მიხედვით: უკანა წნევა, პაკეტის შეკავება, გადატვირთვის სიგნალიზაცია. QoS უკუკავშირის გარეშე უზრუნველყოფის მეთოდები, როგორცაა რესურსების სამართლიანი განაწილების პრინციპი, რიგის მართვის ალგორითმები (მათ შორის RED ) და

ალგორითმები (Oselt Lhamo 2024). ჩატვირთული პროფილები, მუშაობენ ქსელური მოწყობილობის დონეზე. ზემოაღნიშნული მიდგომები მომსახურების ხარისხის უზრუნველსაყოფად შემუშავებული და გამოცდილია პუასონის მოძრაობის მოდელებზე და არ ითვალისწინებს სატელეკომუნიკაციო ტრაფიკის მსგავს სტრუქტურას და მძიმე დისტრიბუციას. ტრაფიკის უფრო ადეკვატური მოდელების გამოყენებამ შეიძლება ხელი შეუწყოს მონაცემთა გადაცემის ეფექტური პროტოკოლებისა და მეთოდების შემუშავებას აბონენტებისთვის მომსახურების ხარისხის უზრუნველსაყოფად. კერძოდ, ეს ეხება საცობებთან საბრძოლველად მოძრაობისა და ქსელის პირობების პროგნოზირების მეთოდებს.

ასეთ შემთხვევაში განსაკუთრებით მნიშვნელოვანია არა მხოლოდ ადეკვატური საპროგნოზო ალგორითმის შემუშავება, არამედ ტრაფიკის ხასიათის, გადაცემის პროტოკოლის, ქსელის არქიტექტურის, გადატვირთულობის ხარისხი და დატვირთვის ხასიათის გათვალისწინება. ზემოთ ჩამოთვლილი ფაქტორებიდან გამომდინარე, ტრაფიკის სტატისტიკური და დინამიური თვისებები განსხვავდება. პროგნოზირებულ დატვირთვაზე დაფუძნებული ქსელის გადატვირთულობის მართვის სისტემები უკეთეს შედეგებს აჩვენებს, ვიდრე სისტემები, რომლებიც მუშაობენ ქსელთან რეალურ დროში. აღსანიშნავია, რომ ქსელის გადატვირთულობის მართვის მეთოდების შემუშავებაზე მუშაობის უმეტესობა არ ითვალისწინებს შეტყობინების გადაცემის პროცესის არაწრფივ-დინამიურ თვისებებს, ტრაფიკის ქაოტურ ხასიათს, აგრეთვე ტრაფიკის გავლენას სერვერის აპარატურულ რესურსებზე და ქსელურ აღჭურვილობაზე. იმავდროულად, ტრაფიკის მოცულობასა და აღჭურვილობის მდგომარეობას შორის დამოკიდებულების დადგენა ხელს შეუწყობს გადატვირთვის პროგნოზირების მეთოდების შემუშავებას და, შედეგად, ქსელის აბონენტებისთვის მომსახურების ხარისხის გაუმჯობესებას. აქედან გამომდინარე, მნიშვნელოვანია რეალური კორპორატიული ქსელის შესწავლა, მონაცემთა გადაცემის და დამუშავების პროცესის ხასიათის დადგენა და შემდეგ აბონენტთა მომსახურების ხარისხის გაუმჯობესებისა და გადატვირთულობის მართვის მეთოდების შემუშავება. სატელეკომუნიკაციო ტრაფიკთან დაკავშირებით, არაწრფივი დინამიკის მეთოდები ხშირად არის გამოყენებული. ამ მიმართულების განვითარებაში მნიშვნელოვანი

წვლილი შეიტანეს ისეთმა მკვლევარებმა, როგორცაა: პარკი, უილინგერი, აბრი, (Mark, და სხვ. 2007) (Zhang, Yang და Wu 2010) და სხვა.

ამრიგად, მონოგრაფიაში (Maejima 2012) წარმოდგენილია თვითმსგავსი შემთხვევითი პროცესების თეორიული ასპექტები, მოცემულია ახსნა თუ რატომ უნდა ჩაითვალოს ტრაფიკი თანამედროვე სატელეკომუნიკაციო სისტემებში ფრაქტალურად, ასევე განხილულია მსგავსი მათემატიკური მოდელების მათემატიკური და პროგრამული დანერგვა. სტატიაში მოცემულია LAN და WAN ტრაფიკის თვითმსგავსების ანალიზი, სატრანსპორტო და აპლიკაციის ფენის პროტოკოლების მახასიათებლების გათვალისწინებით და განიხილავს თვითმსგავსების გავლენას აბონენტებისთვის მიწოდებული სერვისების ხარისხის შეფასებაზე (Maejima 2012).

კორპორატიულ ქსელებთან დაკავშირებით, შეიძლება აღინიშნოს ტრაფიკის ისეთი სპეციფიკური მახასიათებლები, როგორცაა გადაცემული ინფორმაციის მრავალფეროვნება, მისი მაღალი ინტენსივობა და მოცულობა, დახურული ბუნება და პროცესების ანალიზის შეზღუდული მეთოდები ქსელის კვანძებში, რომლებიც არ არის შიდა განვითარება. ამავდროულად, არსებობს უფსკრული ქსელის მუშაობის რეალურად დაკვირვებულ შედეგებს შორის ინფორმაციის წყაროების, ქსელის კვანძებისა და ტრაფიკის საერთო მათემატიკური მოდელებისგან. მრავალი კვლევა ეძღვნება ამ პრობლემის გადაჭრას. ამავდროულად, აქტუალური რჩება კორპორატიულ ქსელებში ზემოაღნიშნული საკითხების განხილვის პრობლემა არაწრფივი დინამიკის მეთოდებზე დაყრდნობით, რაც საშუალებას მისცემს ახალი საინფორმაციო ტექნოლოგიების დანერგვას და განვითარებას მნიშვნელოვანი ეროვნული ეკონომიკური პრობლემების გადაჭრა მრავალ ინდუსტრიაში.

**სადისერტაციო კვლევის მიზანი:** კვლევის მიზანი იყო ქსელში გადატვირთვებთან ბრძოლის მეთოდოლოგიის შემუშავება არაწრფივი დინამიკის მეთოდებზე და ქსელური ტრაფიკის დამახასიათებელი დროის სერიების ქცევის მოკლევადიანი პროგნოზირების საფუძველზე.

კვლევისთვის გამოვიყენეთ “კორპორატიული ქსელის” სარეზერვო სერვერი, რომელიც აგროვებდა და ინახავდა მონაცემებს ქსელური ტრაფიკის შესახებ რეალურ დროში, ასევე აპარატურის რესურსების,

დასახული მიზნის მისაღწევად გადაწყდა შემდეგი კვლევითი ამოცანები:

1) კვლევის ფარგლებში განხორციელდა რეალური ქსელური მონაცემების მოპოვება და დამუშავება, რომელთა ანალიზი ხორციელდებოდა როგორც დროის სერიების სტატისტიკური მეთოდებით, ისე არაწრფივი დინამიკის ანალიზის მოდელებით. აღნიშნული ანალიზის მიზანია ქსელის საკმარისად ზუსტი სიმულაციური მოდელის ფორმირება. შემდგომ ეტაპზე კი, პროგნოზირებადი პარამეტრების განსაზღვრისთვის, მოხდა მიღებული მონაცემების სტაბილურობის დონის შეფასება შესაბამისი მათემატიკური პარამეტრების გამოთვლა.

2) ქსელის სიმულაციური მოდელის შექმნა განხორციელდა NS-3 და Cisco Packet Tracer-ის საშუალებით, რამაც შესაძლებელი გახდა რეალურ მონაცემთა გადაცემის პროცესების დეტალური და შესაბამისი სიზუსტით მოდელირებისთვის. აღნიშნული მოდელები ემსახურება ტრაფიკის დინამიკის, რესურსების გამოყენების და გადატვირთულობის სცენარების ანალიზს რეალური ქსელური გარემოს იმიტაციის საფუძველზე.

3) მუშაობის ფარგლებში შემუშავებულია მეთოდოლოგია, რომელიც ემყარება გამოთვლილ სტატისტიკურ და არაწრფივი დინამიკის პარამეტრებს, რაც მიზნად ისახავს მონაცემთა გადაცემის ქსელში მიმდინარე დინამიური პროცესების პროგნოზირებადობის უზრუნველყოფას. აღნიშნული მიდგომა შესაძლებელს ხდის ტრაფიკის ქცევის დროში შეფასებასა და მომავალი დატვირთვის სცენარების სიმულაციას.

**კვლევის მეთოდოლოგია:**

ნაშრომში დასახული ამოცანების გადაჭრის მიზნით გამოყენებულ იქნა კომპლექსური კვლევითი მიდგომა, რომელიც აერთიანებს როგორც კლასიკურ სტატისტიკურ, ისე თანამედროვე არაწრფივი სისტემების ანალიზის მეთოდებს. კონკრეტულად, განხორციელდა დროის სერიების სტატისტიკური დამუშავება და

პროგნოზირება, რისთვისაც გამოყენებული იქნა კორელაციური ანალიზი, ავტორეგრესიული მოდელები და ტრენდ-ვარიაციის შეფასება.

გარდა ამისა, კვლევის პროცესში ინტენსიურად გამოყენებულ იქნა არაწრფივი დინამიკის მეთოდები მათ შორის ქაოსური სისტემების მოდელირება, ფრაქტალური ანალიზი და სიგნალის სტრუქტურული სირთულის შეფასება.

მოცემული მეთოდოლოგია შერწყმულია სიმულაციური მოდელირებით (NS-3 და Cisco Packet Tracer-ის პლატფორმებზე), რაც შესაძლებელს ხდის რეალურ ქსელურ პროცესთა იმიტაციას, მათ შორის ტრაფიკის დინამიკის, გადატვირთულობის და QoS-ის ცვლილების ანალიზს სხვადასხვა სცენარებში

#### **ძირითადი დებულებები:**

1. კორპორატიული ქსელის სერვერზე ტრაფიკის სტატისტიკური და არაწრფივი დინამიკური ანალიზის შედეგები, რომლებიც ასახავს ტრაფიკის შიდა სტრუქტურას, სიზმნის ხარისხს და დროითი სერიების ქცევის თავისებურებებს (მათ შორის ქაოსურ და ფრაქტალურ მახასიათებლებს).
2. შემომავალი და გამავალი ტრაფიკის გავლენის შეფასება ქსელის სერვერის აპარატურულ დატვირთვაზე, რომელიც ითვალისწინებს პროცესორის, მეხსიერების და არხების რესურსების გამოყენების დინამიკას სხვადასხვა დატვირთვის რეჟიმში.
3. კორპორატიული ქსელის ადეკვატური სიმულაციური მოდელი, რომელიც აღწერს რეალურ ქსელურ გარემოს როგორც რაოდენობრივი, ისე ხარისხობრივი მაჩვენებლების მიხედვით და ასახავს თვითმსგავსი (self-similar) ქცევის მახასიათებლებს.
4. ქსელური ტრაფიკის მათემატიკური მოდელი, რომელიც აგებულია რეალურად შეგროვილი მონაცემების საფუძველზე და იძლევა ტრაფიკის გადაცემის პროცესების აღწერისა და პროგნოზირების ოპტიმალურ შესაძლებლობებს.
5. გადატვირთულობის წინააღმდეგ ბრძოლის მეთოდიკა, რომელიც ეფუძნება ტრაფიკის არაწრფივი დინამიკური თვისებების შეფასებას და მის პროგნოზირებას მოკლევადიანი დროის სერიების საფუძველზე, რაც შესაძლებელს ხდის ქსელურ რესურსებზე უფრო ეფექტურ მართვას და QoS-ის გაუმჯობესებას.

დისერტაციის სამეცნიერო მნიშვნელობა განისაზღვრება მასში მიღებული შემდეგი შედეგებით:

- 1) მიღებული იქნა კორპორატიული ქსელის სერვერის აგრეგირებული ტრაფიკის თვითმსგავსებისა და ქაოსის ხარისხის რაოდენობრივი და ხარისხობრივი შეფასებები.
- 2) მიღებულია ტრაფიკის და სერვერის ტექნიკის რესურსების კორელაციის ხარისხის მნიშვნელობები.
- 3) შემუშავებულია მოდელი, რომელიც ადეკვატურად წარმოადგენს კორპორატიულ ქსელში შეტყობინების პაკეტების გადაცემის პროცესს.
- 4) საცობებთან ბრძოლის მიზნით შემუშავებულია შემომავალი ტრაფიკის მოცულობის მოკლევადიანი პროგნოზირების მეთოდი.

**სამეცნიერო სიახლე:**

1. დროის სერიების საფუძველზე განხორციელებული ტრაფიკისა და აპარატურული რესურსების ანალიზმა კორპორატიულ ქსელში შესაძლებელი გახადა იმის დამტკიცება, რომ ქსელური პროცესები გამოირჩევა მაღალი ხარისხის თვითმსგავსობითა (self-similarity) და ქაოსური ქცევის მახასიათებლებით. აღნიშნული თავისებურებები ადასტურებს ტრაფიკის არაწრფივი დინამიკის არსებობას და ხელს უწყობს მის პროგნოზირებადობას შესაბამისი მათემატიკური მოდელების მეშვეობით.
2. კორელაციური ანალიზის საფუძველზე დადგინდა პირდაპირი, სტატისტიკურად მნიშვნელოვანი კავშირი ქსელის ტრაფიკის ინტენსივობასა და სერვერის აპარატურულ რესურსებზე დატვირთვას შორის, სადაც გადამუშავების ძირითადი წნეხი მოდის ცენტრალურ პროცესორზე და ოპერატიულ მეხსიერებაზე. ეს აღმოჩენა მნიშვნელოვან საფუძველს ქმნის რესურსების განაწილების ოპტიმიზაციისათვის სხვადასხვა დატვირთვის პირობებში.
3. გამოკვეთილი იქნა ახალი მეთოდური მიდგომა ქსელის ეფექტიანობის გაუმჯობესებისთვის, რომელიც ეფუძნება ტრაფიკის მოკლევადიან პროგნოზირებასა და უკუკავშირის (feedback-based) დინამიკურ მექანიზმს. აღნიშნული მიდგომა ითვალისწინებს ტრაფიკის სტრუქტურულ თავისებურებებს მათ შორის თვითმსგავსებასა და ქაოსურობას და იძლევა შესაძლებლობას გადატვირთულობის

პრევენციისა და QoS-ის შენარჩუნების პირობებში ქსელის რესურსების უფრო მიზნობრივი მართვისთვის.

სამეცნიერო შედეგების სანდოობა:

მიღებული სამეცნიერო შედეგების სანდოობა და ვალიდობა დასტურდება კვლევაში გამოყენებული მათემატიკური და სტატისტიკური მეთოდების შერჩევის ადეკვატურობით, რაც შეესაბამება განხილული ამოცანების ბუნებასა და მონაცემთა ტიპს. კვლევის სიზუსტე განმტკიცებულია ექსპერიმენტული ანალიზის ხანგრძლივობითა და შედეგების მაღალი განმეორებადობით, რაც მიუთითებს მოდელის სტაბილურობას სხვადასხვა სცენარში. გარდა ამისა, სიმულაციური მოდელირების შედეგები (NS-3 და Cisco Packet Tracer-ის პლატფორმებზე) რაოდენობრივად და თვისობრივად შეესაბამება თეორიულად ფორმულირებულ დებულებებსა და პროგნოზირებულ ქცევას, რაც იძლევა საფუძველს შესრულებული კვლევის მეცნიერულად სარწმუნოდ და პრაქტიკულად გამოსადეგად მიჩნევისათვის.

**ნაშრომის პრაქტიკული მნიშვნელობა:**

ნაშრომში შემუშავებული კომპიუტერული ქსელის სიმულაციური მოდელი წარმოადგენს საფუძველს რეალურ ქსელურ გარემოში მიმდინარე პროცესების სიღრმისეული ანალიზისა და გამოცდისათვის. აღნიშნული მოდელი უზრუნველყოფს ტრაფიკის გადაცემის პროცესების იმიტაციას ცვლად პირობებში და საშუალებას იძლევა სისტემატურად განისაზღვროს ქსელის ქცევა სხვადასხვა დატვირთვის სცენარების პირობებში.

ტრაფიკის დინამიურ მახასიათებლებზე დაფუძნებული დატვირთვის პროგნოზირების მეთოდოლოგია, რომელიც გამოყვანილია არაწრფივი დროითი ანალიზის საფუძველზე, წარმოადგენს პრაქტიკულად მნიშვნელოვან ხელსაწყოს რეალურ მონაცემთა გადამცემ ქსელებში გადატვირთულობის პრევენციისა და QoS-ის ოპტიმიზაციის მიზნით.

შესაბამისად, ნაშრომის შედეგები შეიძლება გამოყენებულ იქნეს როგორც კვლევით, ისე საინჟინრო პრაქტიკაში სატელეკომუნიკაციო ინფრასტრუქტურის დაგეგმვის, ტრაფიკის მონიტორინგის სისტემების განვითარების და ინტელექტუალური ტრაფიკ-მენეჯმენტის გადაწყვეტების შექმნის პროცესებში.

**ავტორის წვლილი:** ყველა ძირითადი სამეცნიერო დებულება და დასკვნა, რომელიც აღდგენს ამ ნაშრომის შინაარსს, მოიპოვა პირადად ავტორმა, სიმულაციური მოდელების შემუშავება განხორციელდა ავტორის უშუალო მონაწილეობით, ორიგინალურ მონაცემებზე დაყრდნობით, რაც ცხადყოფს ინდივიდუალურ წვლილს.

**პუბლიკაციები:** დისერტაციის თემაზე გამოქვეყნებულია 3 სტატია.

**ნაშრომის სტრუქტურა და მოცულობა:** დისერტაცია შეიცავს 162 გვერდს და შედგება შესავლის, ოთხი თავის, დასკვნის და ცნობარების ჩამონათვალისგან.

შესავალ ნაწილში გათვალისწინებულია თემის აქტუალობის არგუმენტაცია, განხილულია მიღებული შედეგების სამეცნიერო სიახლე და პრაქტიკული ღირებულება, ხოლო ჩამოყალიბებულია ის ძირითადი დებულებები, რომლებიც წარდგენილია საჯარო დაცვისათვის.

**პირველ თავში** განხილულია კომპიუტერულ ქსელებში ტრაფიკის მოდელირების თეორიული საფუძვლები, შესაბამისი მათემატიკური მიდგომები და მათი გამოყენების შესაძლებლობები გადატვირთვებთან ბრძოლის კონტექსტში. წარმოდგენილია ტრაფიკის მოდელების კლასიფიკაცია როგორც პროცესის ბუნების მიხედვით (აღდგენითი, მარკოვის, ავტორეგრესიული, თვითმსგავსი და ფრაქტალური მოდელები), ისე აპლიკაციაზე დამოკიდებული მახასიათებლების საფუძველზე (მაგალითად, ვებ, სტრიმინგი, peer-to-peer და ვიდეო ტრაფიკი). დეტალურადაა გაშლილი ტრაფიკის შემომავალი ნაკადების აღწერისა და მოდელირების სპეციფიკა, რაც ემსახურება რეალური სატრანსპორტო პროცესების იმიტაციის სიზუსტის გაუმჯობესებას.

განსაკუთრებული ყურადღება ეთმობა გადატვირთვის კონტროლის ალგორითმებისა და QoS მექანიზმების კლასიფიკაციას. განხილულია ღია მარყუჟისა და უკუკავშირიან მიდგომებს შორის პრინციპული განსხვავებები, აგრეთვე რიგების მართვის ისეთი ალგორითმები, როგორცაა RED, WFQ, GPS და მათი როლი ქსელის სტაბილური ფუნქციონირების უზრუნველყოფაში. თავი ამგვარად ქმნის საფუძველს მოდელირების და პროგნოზირების მეთოდების შემდგომი სიღრმისეული ანალიზისთვის, რაც წარმოადგენს დისერტაციის კვლევითი ამოცანების ერთ-ერთ ძირითად კომპონენტს.

**მეორე თავში** განხილულია კორპორატიული კომპიუტერული ქსელის რეალურ ინფრასტრუქტურაზე ჩატარებულ ექსპერიმენტულ კვლევას, რომლის მიზანია ტრაფიკის დროითი და რესურსული მახასიათებლების ანალიზი. მონაცემების შეგროვება განხორციელდა ლოკალური სერვერის დონეზე, რომელიც აკვირდებოდა შემომავალ და გამავალ ტრაფიკს, აგრეთვე აპარატურული რესურსების (ცენტრალური პროცესორის, ოპერატიული მეხსიერებისა და სისტემური პროცესების რაოდენობის) დინამიკურ მდგომარეობას.

შეგროვებული მონაცემების საფუძველზე განხორციელდა სტატისტიკური ანალიზი (მათ შორის საშუალო მნიშვნელობების, დისპერსიის, კოვარიანსის და კორელაციის შეფასება), ასევე სპექტრული და არაწრფივი დინამიკის მეთოდებით მიღებული პარამეტრების (ჰერსტის ინდექსი, ლაპუნოვის ექსპონენტი, ფრაქტალური განზომილება) დეტალური გამოთვლა. ანალიზის შედეგად დადგინდა, რომ ტრაფიკი კორპორატიულ ქსელში გამოირჩევა თვითმსგავსობით, მაღალი დროში დამოკიდებულებითა და ქაოსური დინამიკით, რაც მიუთითებს გრძელვადიანი და არაწრფივი პროცესების არსებობაზე.

ამ თავში დასაბუთებულია, რომ რეალური მონაცემები საშუალებას იძლევა განხორციელდეს დატვირთვის პროგნოზირება მოკლევადიან პერსპექტივაში. აღნიშნული მიგნება წარმოადგენს მნიშვნელოვან წინაპირობას იმ პროგნოზირების ალგორითმების შერჩევისა და სიმულაციური მოდელირების საფუძველზე გადატვირთვის პრევენციის მექანიზმების შემუშავებისთვის, რასაც მიეძღვნება დისერტაციის შემდგომი თავები.

**მესამე თავი** წარმოადგენს კომპიუტერულ ქსელებში ტრაფიკის პროგნოზირებისთვის განკუთვნილი დროის სერიების მოდელების შედარებით ანალიზს და მათ შერჩევას ოპტიმალური პროგნოზირების მიზნებისთვის. წარმოდგენილია სტატისტიკური და ჰიბრიდული ალგორითმების დეტალური აღწერა, მათემატიკური საფუძველი, მოდელირების პირობები და შერჩევის კრიტერიუმები. თითოეული მოდელი შეფასებულია პროგნოზირების სიზუსტის მაჩვენებლების (MAE, MAPE, SMSE) საფუძველზე.

ექსპერიმენტული ანალიზის შედეგებმა აჩვენა, რომ რეალური ტრაფიკის ქაოსური და თვითმსგავსი ბუნება საუკეთესოდ აღწერება ARFIMA მოდელით, რომელიც აერთიანებს როგორც გრძელვადიან დამოკიდებულებას (ფრაქციული ინტეგრაცია), ისე მოკლევადიან ავტორეგრესიას. აღნიშნული მოდელი აჩვენებს მაღალ პროგნოზულ სიზუსტეს სხვადასხვა დატვირთვის რეჟიმში, რაც ხაზს უსვამს მის შესაბამისობას გამოკვლეული სერიების სტრუქტურულ თავისებურებებთან.

თავი წარმოადგენს საფუძველს მოდელზე დაფუძნებული დატვირთვის პროგნოზირების სისტემის შემდგომი იმპლემენტაციისთვის და წარმოადგენს კვანძურ რგოლს გადატვირთვის პრევენციის ალგორითმების დახვეწაში.

მეოთხე თავი ეძღვნება პროგნოზირების ალგორითმებზე დაფუძნებული გადატვირთვის მართვის სისტემების სიმულაციური ანალიზსა და მათ მოდელირებას რეალურ ქსელურ გარემოში. თავი მოიცავს ექსპერიმენტულად გამართული ლოკალური ქსელის მოდელირებას, რომელიც მიზნად ისახავს ტრაფიკის მოკლევადიანი პროგნოზირების საფუძველზე გადატვირთვის პრევენციისა და QoS-ის გაუმჯობესების შესაძლებლობების შეფასებას.

მოდელირება განხორციელდა მრავალპლატფორმიანად, გამოყენებულ იქნა MATLAB-ის Simulink ბიბლიოთეკა, NS-3 სიმულატორი, Cisco Packet Tracer-ის ვიზუალური ქსელური სცენარების მოდულები და Python-ის შესაბამისი ბიბლიოთეკები (მაგ. statsmodels, scikit-learn, matplotlib) მონაცემთა ანალიზისა და ვიზუალიზაციისთვის. თითოეული პლატფორმა უზრუნველყოფდა სხვადასხვა ასპექტის სიმულაციურ კონტროლს: MATLAB- არაწრფივი მოდელების დიფერენცირებული მოდელირება, NS-3- პაკეტების დონის დეტალური ანალიზი და პროტოკოლების ტესტირება, ხოლო Cisco Packet Tracer რეალისტური ტოპოლოგიური იმიტაცია და ვიზუალური QoS პრიორიტეტიზაცია.

სიმულაციის პროცესში შეფასდა შემოთავაზებული მოდელის ადეკვატურობა და ეფექტიანობა QoS-ის კრიტერიუმების მიმართ: ლატენცია, პაკეტების დანაკარგები და გადაცემის სტაბილურობა. შედეგებმა აჩვენა, რომ ARFIMA(p,d,q) მოდელზე დაფუძნებული პროგნოზირებადი დატვირთვის მექანიზმი, კომბინირებული

უკუკავშირის ალგორითმებთან, მნიშვნელოვნად ამცირებს პაკეტების დანაკარგებს და ზრდის ქსელის გამტარუნარიანობას მაღალი დატვირთვის რეჟიმებში.

მოდელირების შედეგები ცხადყოფს, რომ პროგნოზზე დაფუძნებული გადატვირთვის კონტროლის სისტემა ფუნქციონირებს ეფექტურად როგორც სტაციონარულ, ისე ცვალებად დატვირთვისასთან. მოდელი წარმოადგენს მასშტაბირებად და იმპლემენტაციისთვის მზადყოფნის მქონე გადაწყვეტას კორპორატიულ და პროვაიდერულ ქსელებში QoS-ის მაღალი დონის უზრუნველსაყოფად.

**დასკვნა** აჯამებს დისერტაციის ფარგლებში ჩატარებული კვლევის ძირითად სამეცნიერო და პრაქტიკულ შედეგებს, რომლებიც ეხმიანება კომპიუტერულ ქსელებში ტრაფიკის გადატვირთვისასთან ბრძოლის თანამედროვე გამოწვევებს და მონაცემთა გადაცემის პროცესების პროგნოზირებადობის ამაღლების საჭიროებას. ნაშრომში გაწერილია მრავალსაფეხურიანი მეთოდოლოგია, რომელიც აერთიანებს როგორც თეორიული მოდელირების საფუძვლებს (ტრაფიკის სტოქასტური, მარკოვის, ავტორეგრესიული და ფრაქტალური მოდელები), ისე ექსპერიმენტული სიმულაციებით მიღებულ შედეგებს რეალურ კორპორატიულ ინფრასტრუქტურაზე დაფუძნებით.

კვლევის შედეგად დამტკიცდა, რომ კორპორატიული ქსელის ტრაფიკი გამოირჩევა არაწრფივი, თვითმსგავსი და ქაოსური დინამიკური მახასიათებლებით, რაც რეალურ დროში ტრაფიკის პროგნოზირებას რთულ ამოცანად აქცევს. თუმცა, დროში თანმიმდევრული სტატისტიკური და არაწრფივი ანალიზის საშუალებით შესაძლებელი გახდა მონაცემთა სტრუქტურის დეკონსტრუქცია და მათემატიკური პროგნოზირების მოდელის ოპტიმიზაცია.

კორპორატიული ქსელის სერვერზე მიღებული სტატისტიკური და სპექტრული მონაცემების საფუძველზე დადგენილია დროის სერიების თვითმსგავსი და ქაოსური ხასიათი, რაც ადასტურებს საჭიროებას არაწრფივი მოდელების გამოყენებას.

კვლევების შედეგად დადგენილია, რომ ARFIMA(p,d,q) მოდელი აჩვენებს პროგნოზირების ყველაზე მაღალ სიზუსტეს ტრაფიკის არასტაციონარული და ფრაქციულად ინტეგრირებული თვისებების გათვალისწინებით.

სიმულაციური მოდელირების საფუძველზე (MATLAB Simulink, NS-3, Cisco Packet Tracer) შემუშავდა გადატვირთვის მართვის ტექნოლოგიური მოდელი, რომელიც იყენებს პროგნოზირებად დატვირთვის ინფორმაციას და უკუკავშირის მექანიზმებს ტრაფიკის სტაბილიზაციისთვის. შემოთავაზებული მიდგომა ამცირებს პაკეტების დანაკარგს და ზრდის QoS-ს მაჩვენებლებს, განსაკუთრებით მაღალი დატვირთვის რეჟიმებში.

პრაქტიკულად დადასტურდა, რომ პროგნოზირებაზე დაფუძნებული დინამიური კონტროლის მექანიზმები შეიძლება ინტეგრირდეს რეალურ კორპორაციულ ქსელებში გადატვირთვის პრევენციისა და ოპტიმალური რესურსების მართვისათვის.

ზემოაღნიშნული მიგნებები და დამუშავებული ალგორითმები ქმნის საფუძველს ახალი თაობის ქსელური მენეჯმენტის სისტემების შესაქმნელად, სადაც ქსელის დატვირთვის პროგნოზირება და ადაპტური რეაგირება არ წარმოადგენს მხოლოდ რეაქციას კრიტიკულ სიტუაციებზე, არამედ უზრუნველყოფს პრევენციულ, პროგნოზულ და მიზანმიმართულ მოქმედებას ქსელური ხარისხის გასაუმჯობესებლად.

## თავი 1

# ტრაფიკის მოდელები და მეთოდები მონაცემთა ქსელებში გადატვირთულობის წინააღმდეგ საბრძოლველად

### 1.1 ტრაფიკის მოდელების კლასიფიკაცია და მათი როლი გადატვირთვის შეფასებაში

ტრაფიკის მოდელირების პროცესში შესაძლებელია გამოყენებულ იქნას ორი ურთიერთგამომრიცხავი მიდგომა: რეალურ აღჭურვილობაზე დაფუძნებული ექსპერიმენტი და სიმულაციური მოდელირება. პირველ შემთხვევაში, კვლევა ხორციელდება რეალური ინფრასტრუქტურის პირობებში, სადაც დაკვირვებები გრძელდება განსაზღვრული დროის განმავლობაში და მონაცემები გროვდება უშუალოდ პროცესის მიმდინარეობისას. მეორე შემთხვევაში კი, ექსპერიმენტი განახორციელება შესაძლებელია რიცხვითი მოდელირების გზით, კომპიუტერული სიმულაციის გამოყენებით, სადაც პროცესები აღწერილია შესაბამისი მათემატიკური მოდელებით და იმიტირებულია შესაბამისი გარემო პირობები.

განსაკუთრებით ეფექტურია ამ ორი მიდგომის კომბინაცია, რეალური ექსპერიმენტული მონაცემების შეჯერება მათემატიკურ სიმულაციებთან, რაც ხელს უწყობს შედეგების სანდოობას და ამცირებს მოდელირების შესაძლო გადახრებს. რეალურ მონაცემებზე დაფუძნებული მეთოდი ითვლება ღირებულად, როდესაც მათი მიღების პირობები ზუსტად ცნობილია და ექსპერიმენტის სანდოობას ეჭვი არ ახლავს. ამ დროს, რიცხვითი მოდელირების შემთხვევაში, კრიტიკულად მნიშვნელოვანია იმ მათემატიკური მოდელის ადეკვატურობა, რომელიც გამოიყენება ციფრულ ექსპერიმენტში ანუ რამდენად რეალისტურად ასახავს ის ქსელის ფუნქციონირების პროცესებს და პირობებს.

მონაცემთა გადაცემის ქსელების სიმულაციისას ფართოდ გამოიყენება დისკრეტული მოვლენების სისტემის (DES- Discrete Event System) მოდელირება (Garzia, Zeigler and Garzia 1986), რომლის ეფექტიანობაც პირდაპირ დამოკიდებულია ტრაფიკის მოდელის სიზუსტეზე. ასეთი მოდელი უნდა ასახავდეს როგორც პაკეტების

ან შეტყობინებების მიღების ლოგიკას, ასევე მათ განაწილებას დროში, სიხშირესა და მოცულობას.

ტრაფიკის მარტივი წარმოდგენა შეიძლება განიმარტოს როგორც დისკრეტული ერთეულების მიღების პროცესი მაგალითად, პაკეტები, შეტყობინებები ან ინდივიდუალური სიგნალები. უფრო რთული შემთხვევისას კი განიხილება შერეული ტრაფიკი, რომელშიც ერთ შემომავალ ერთეულში შესაძლოა ერთდროულად იყოს მრავალი კომპონენტი. ასეთი შემთხვევისთვის გამოიყენება არაუარყოფითი შემთხვევითი თანმიმდევრობა  $D_1, D_2, \dots, D_n$  სადაც  $D_n$  წარმოადგენს ერთეულში შემავალი კომპონენტების რაოდენობას (Baras 2003).

ტრაფიკის მოდელები კლასიფიცირდება, ერთი მხრივ, მონაცემთა ჩამოსვლის პროცესის ბუნების მიხედვით და, მეორე მხრივ, შესაბამისი აპლიკაციური ტიპების მიხედვით, რომლებიც ახორციელებენ მონაცემთა გადაცემას. პროცესის ბუნების მიხედვით ტრაფიკის მოდელები იყოფა სტაციონარულ და არასტაციონარულ მოდელებად. სტაციონარული მოდელები თავის მხრივ იყოფა მოკლევადიან და გრძელვადიან დამოკიდებულებებზე. მოკლევადიანი დამოკიდებულების მქონე მოდელებში შედის, როგორც წესი, ავტორეგრესიული მოდელები და მარკოვის პროცესებზე დაფუძნებული მიდგომები. ხოლო გრძელვადიან დამოკიდებულებებს ახასიათებს ფრაქტალური ან თვითმსგავსი სტრუქტურა (Adas 1997).

ტრაფიკის კლასიფიკაცია ასევე ხორციელდება წყაროს ტიპის მიხედვით: აპლიკაციური შრის სპეციფიკაციიდან გამომდინარე შეიძლება გამოვყოთ ვებ-ტრაფიკი, peer-to-peer კომუნიკაცია, სტრიმინგ-ტრაფიკი და ა.შ. (Perez 2020).

### 1.1.1 აღდგენით პროცესებზე დაფუძნებული მოდელები

მონაცემთა გადაცემის ქსელების მოდელირების პირველ ეტაპზე ფართოდ გამოიყენებოდა სატრანსპორტო მოდელები, რომლებიც დაფუძნებული იყო აღდგენით პროცესებზე. მათი სიმარტივე და ანალიტიკური გაანგარიშების შესაძლებლობები ხელს უწყობდა მათ ადრეულ დანერგვას კომპიუტერული ქსელების კვლევაში.

აღდგენითი პროცესი წარმოადგენს სტატისტიკურ მოდელს, რომელშიც მოვლენებს შორის დროითი ინტერვალები აღწერილია დადებითი, ერთმანეთზე

დამოუკიდებელი და იდენტურად განაწილებული შემთხვევითი ცვლადებით. პროცესი  $[M(t); t \geq 0]$  აღწერს მოვლენების რაოდენობას დროის ინტერვალში  $[0; t]$ , სადაც  $M(t)$  წარმოადგენს ჯამური მოვლენების რაოდენობას განსაზღვრულ მომენტში. თითოეული მოვლენის დროითი მომენტი, მაგალითად  $Z_n = D_1 + D_2 + \dots + D_n$ , განისაზღვრება წინა ინტერვალების ჯამის სახით (Ziegler 2001).

თუ აღვნიშნავთ, რომ კონკრეტული მოვლენა მოხდა დროის წერტილზე  $Z_n = \tau$ , მაშინ პროცესის შემდგომი დინამიკა განისაზღვრება შემდეგნაირად:  $Z_{n+i} - Z_n = D_{n+1} + \dots + D_{n+i}$ , რაც კვლავ აღდგენითი პროცესის თვისებებს ასახავს ყველა ინტერვალში კვლავ დამოუკიდებელია და თანაბრად განაწილებული (Ziegler 2001).

აღდგენითი პროცესის სიმარტივის მიუხედავად, მას აქვს მნიშვნელოვანი შეზღუდვები. ყველაზე არსებითი მათგანია ის ფაქტი, რომ ინტერვალთა სერიის ავტოკორელაციის ფუნქცია (ACF) სწრაფად კლებულობს და სწრაფად მიიწევს ნულისკენ ყველა არანულოვანი ჩამორჩენის შემთხვევაში. ეს კი არ შეესაბამება რეალური ქსელური ტრაფიკის დროულ სტრუქტურას, რომელიც ხშირად გამოირჩევა პერიოდულობით, თვითმსგავსობით ან კორელირებული აფეთქებების არსებობით. მაგალითად, დადებითი ავტოკორელაცია სერიაში  $[D_n]$  ხშირად შეინიშნება ისეთ შემთხვევებში, როდესაც ქსელში არსებობენ მოკლევადიანი ინტენსიური აქტივობის პერიოდები. ეს ფენომენი განსაკუთრებით თვალსაჩინოა სამაუწყებლო და ვიდეოტრანსპორტის ქსელებში, სადაც პაკეტების გადაცემა ხორციელდება კადრების ან მედია-ფაილების სახით (Ziegler 2001).

ამრიგად, აღდგენით პროცესზე დაფუძნებული მოდელები რეალურ ტრაფიკს მხოლოდ ნაწილობრივ ასახავენ და მათი გამოყენება მიზანშეწონილია მხოლოდ იმ შემთხვევებში, როდესაც ვარაუდობენ მარტივი და სტაციონარული ტრაფიკის მახასიათებლებს. იმ პირობებში, როდესაც ქსელში ვლინდება ინტენსიური დროითი კავშირები, თვითმატება და გრძელვადიანი დამოკიდებულება, საჭიროა უფრო კომპლექსური მოდელების მათ შორის ავტორეგრესიული ან ფრაქტალური მოდელების გამოყენება (Ziegler 2001).

ერთ-ერთი ყველაზე გავრცელებული და ტრადიციული ტრაფიკის მოდელი ეფუძნება პუასონის განაწილებას. ისტორიულად, აღნიშნული მოდელი პირველად

გამოიყენებოდა სატელეფონო ქსელების ანალიზში, თუმცა მოგვიანებით მისი გამოყენება მონაცემთა ქსელებშიც გავრცელდა. პუასონის პროცესი წარმოადგენს განახლების პროცესის სპეციფიკურ შემთხვევას, რომელშიც მოვლენებს შორის ინტერვალი აღწერილია ექსპონენციური განაწილებით, პარამეტრით  $\lambda$ . ამ შემთხვევისთვის ალბათობის განაწილების ფუნქცია მიიღება ფორმულად:

$$F(t)=1-e^{-\lambda t}$$

ხოლო სიმკვრივის ფუნქცია განისაზღვრება როგორც:

$$f(t)=\lambda e^{-\lambda t}$$

მოდელის გამარტივებული გრაფიკული ანალიზის მეთოდად ითვლება მოვლენის დადგომის დროების ჰისტოგრამის აგება და მისი ექსპონენციური შემცირების შემოწმება.

პუასონის მოდელი უმეტესად გამოიყენება ისეთ პირობებში, როდესაც ტრაფიკი მოდის დამოუკიდებელი წყაროებიდან და მათ შორის არ არსებობს ურთიერთდამოკიდებულება. მოდელის ერთ-ერთი ძირითადი თვისებაა ის, რომ პუასონის პროცესების სუპერპოზიცია კვლავ პუასონის პროცესს წარმოადგენს, რაც მნიშვნელოვანია ქსელური ნაკადების აგრეგირებისას. პალმის თეორემის თანახმად, ასეთი აგრეგირებული მოდელები განსაკუთრებით გამოსადეგია კომპლექსური ქსელური გარემოს სიმულაციისათვის (Studfiles 2014).

თუმცა კვლევებმა აჩვენა, რომ რეალურ ქსელებში ტრაფიკის აგრეგაცია ყოველთვის არ იწვევს პუასონის ტიპის განაწილებას. ხშირად, რეალური ტრაფიკი ავლენს ავტოკორელაციას, თვითმსგავსობასა და ხანგრძლივ დამოკიდებულებას, რაც პუასონის მოდელით ვერ აიხსნება. გარდა ამისა, თუ მოდელის პარამეტრი  $\lambda$  დროზე დამოკიდებული, ასეთი პროცესი გადადის არასტაციონარულ რეჟიმში, რაც დამატებით ართულებს ანალიზს (Bose 2002, 205-212).

გლობალურ ქსელებში, სადაც ცალკეული აბონენტის წვლილი საერთო ტრაფიკში მინიმალურია, მომხმარებლის სესიების მოდელირება შესაძლებელია პუასონის პროცესით. განსაკუთრებით მოსახერხებელია ეს TCP-ტრაფიკისთვის OSI მოდელის სესიის ფენაზე, როცა მომხმარებელი იწვევს კავშირს (მაგალითად, FTP ან Telnet სესიები) (Chen 2012, 326-339).

ბერნულის განაწილებაზე დაფუძნებული ტრაფიკის მოდელი წარმოადგენს პუასონის პროცესის დისკრეტულ ანალოგს. ამ შემთხვევაში, ყოველ დროსწამში მოვლენის დადგომის ალბათობა  $pp$  უცვლელია და არ არის დამოკიდებული წინა მომენტებზე. გარკვეული ინტერვალის განმავლობაში მომხდარი მოვლენების რაოდენობა ემორჩილება ბინომურ განაწილებას:

$$P\{N_k = n\} = \binom{k}{n} p^n (1-p)^{k-n}$$

(Ziegler 2001)

სადაც  $n \in [0, k]$ , ხოლო შესაბამისი გეომეტრიული განაწილება დგინდება ფორმულით:

$$P\{A_n = j\} = p(1-p)^j, \quad j \in \mathbb{N}^+$$

(Ziegler 2001)

ამ მოდელს ფართოდ იყენებენ ციფრული კომუნიკაციის სფეროში, სადაც მონაცემების გამეორებითი გაგზავნის პროცესები მოდელირდება დროში დისკრეტული თანმიმდევრობით (Ziegler 2001).

აღდგენით პროცესებზე დაფუძნებული ერთ-ერთი კომპლექსური მოდელი არის ფაზური ტიპის პროცესი (Phase-Type Process), რომელიც მოდელირებულია უწყვეტი დროის მარკოვის შთანთქმის პროცესის საფუძველზე. მოდელი აღწერს სისტემას მდგომარეობათა სივრცეში  $[0, 1, \dots, m]$ , სადაც  $0$  წარმოადგენს შთანთქმის მდგომარეობას, დანარჩენი კი გარდამავალ მდგომარეობებს. პროცესი იწყება საწყისი განაწილებით  $\pi$ , და როგორც კი შთანთქმა (მოვლენის დადგომა) მოხდება, პროცესი სრულდება და განმეორებით იშვება იმავე საწყისი განაწილებიდან (Ziegler 2001).

ამ მოდელის დახმარებით შესაძლებელია ფაზური ცვლილებების გათვალისწინება მონაცემთა გადაცემის პროცესში და მასზე დამყარებული სიმულაციის მეშვეობით შესაძლებელია შედარებით დეტალური და დინამიკური ტრაფიკის ანალიზი. ფაზური მოდელები განსაკუთრებით ეფექტურია იმ სიტუაციაში, როდესაც საჭიროა კომბინირებული განაწილებების და კორელაციის გათვალისწინება (Ziegler 2001).

### 1.1.2 მარკოვის პროცესებზე დაფუძნებული მოდელები

მარკოვის პროცესებზე დაფუძნებული ტრაფიკის მოდელები განიხილავენ სისტემაში მოვლენათა თანმიმდევრობაზე დამოკიდებულებას, განსხვავებით

განახლების პროცესებზე დაფუძნებული მოდელებისგან, რომლებიც დამოუკიდებელ მოვლენებს ითვალისწინებენ. ამ მოდელების არსი მდგომარეობს იმაში, რომ სისტემის მომდევნო მდგომარეობა დამოკიდებულია მხოლოდ მიმდინარე მდგომარეობაზე  $S_n$ , ხოლო წინა მდგომარეობები  $Z_i$ , სადაც  $i < n$ , პროცესის მიმდინარეობაზე გავლენას არ ახდენს (Rausand 2014, 6-10). აღნიშნული მიდგომა განაპირობებს **პოზიტიურ ავტოკორელაციას**, რაც რეალისტურად აღწერს რეალურ ქსელურ ტრაფიკს, რომელიც ხასიათდება მომატებული აქტივობისა და შემდგომი შენელებული ინტენსივობის პერიოდებით.

მარკოვის მოდელებში, როგორც წესი, მდგომარეობების რაოდენობა არის შეზღუდული. ამ რაოდენობის გაზრდა იძლევა უფრო სარელევანტო შესაბამისობას რეალურ პროცესთან, თუმცა მნიშვნელოვნად ზრდის მოდელის სირთულესა და გამოთვლით მოთხოვნებს (Rausand 2014).

მარკოვის მოდელების ზოგადი ფორმაა ნახევრად მარკოვის მოდელი, რომელშიც თითოეული მდგომარეობის ხანგრძლივობა დამოკიდებულია შემთხვევით განაწილებაზე. თუ მდგომარეობათა ცვლილება სრულად განყენებულია დროში, პროცესს დისკრეტული მარკოვის ჯაჭვი ეწოდება.

ON-OFF მოდელი ფართოდ გამოიყენება ხმის ტრაფიკის მოდელირებისთვის. ის მოიცავს ორ მდგომარეობას: **ON** როცა ტრაფიკი გენერირდება და **OFF** როცა ტრაფიკის გენერაცია შეწყდება. გარდამავალი დროებს შორის განაწილება ემორჩილება ექსპონენციურ კანონს (Harry Heffes 1986). თუ ქსელში ფუნქციონირებს  $n$  დამოუკიდებელი ON-OFF წყარო, თითოეულს აქვს საშუალო პაკეტების რაოდენობა  $L$ , პიკური სიჩქარე  $S$  და საშუალო სიჩქარე  $r$ , მაშინ წონასწორობის მდგომარეობის ალბათობა გამოითვლება ფორმულად:  $\gamma = r/S$ .

IPP (Interrupted Poisson Process) მოდელში, სისტემა ასევე ორ მდგომარეობაში იმყოფება: ON მონაცემთა გადაცემა ხდება პუასონის პროცესის მიხედვით, OFF არანაირი გადაცემა არ მიმდინარეობს. ასეთი ტიპის მოდელები ეფექტურია ტრეფიკის burstiness-ის ასახვისას, რაც ხშირია ხმოვანი ტრაფიკისა და ზოგადად მულტიმედიაური ნაკადებისათვის (Dethe and Wakde 2007).

ამ მოდელში ორი მდგომარეობა განისაზღვრება: S1S\_1 (უმოქმედობა) და S2S\_2 (აქტივობა), სადაც S1S\_1-ში ტრაფიკის ამპლიტუდა არის 0, ხოლო S2S\_2-ში 1. თუ მდგომარეობათა შორის გადასვლის საშუალო დროებია d1d\_1 და d2d\_2, მაშინ სისტემის მდგომარეობაში ყოფნის ალბათობა განისაზღვრება:

$$P(S_1) = \frac{d_1}{d_1 + d_2}, \quad P(S_2) = \frac{d_2}{d_1 + d_2}$$

(Mark, et al. 2007)

სუპერპოზიციით მიღებული პროცესები ხშირად ბინომიური განაწილებით აღიწერება.

MMPP წარმოადგენს ერთ-ერთ ყველაზე ფართოდ გამოყენებულ მიდგომას ტრაფიკის მოდელირებაში. ის აერთიანებს პუასონის პროცესის სიმარტივეს და მარკოვის მოდელების მოქნილობას. MMPP-მოდელში ტრაფიკის ინტენსივობა მოდულირებულია მარკოვის პროცესის მიერ, რაც უზრუნველყოფს რეალური ხმოვანი ან ვიდეო ტრაფიკის უკეთეს აღწერას, რომელშიც ინტენსივობა დროში ცვალებადია:

$$\lambda(t) = n(t) \cdot \lambda$$

სადაც  $n(t)$  აღწერს აქტიური წყაროების რაოდენობას მარკოვის ჯაჭვის მეშვეობით. შედეგად, მიღებული პროცესი აღჭურვილია ორმაგი სტოქასტურობით პუასონის ბუნებით და მარკოვის მოდულაციით (Fernandez and Mutka 1995, 334-340).

MMPP განსაკუთრებით ეფექტიანია ვარიაბელური ტრაფიკის მოდელირებისთვის, როგორცაა ხმოვანი ნაკადები, სადაც ზუსტად საჭიროა ტრაფიკის ინტენსივობის ცვლილების აღქმა (Fernandez and Mutka 1995).

მარკოვის მოდულირებული სითხის მოდელები: სითხის მოდელები განიხილავენ ტრაფიკს უწყვეტ ნაკადად, განსხვავებით პაკეტურ ტრაფიკთან მიმართებით დისკრეტული მოდელებისა. აღნიშნული მიდგომა ხშირად გამოიყენება, როდესაც ინდივიდუალური პაკეტის გავლენა დაბალია, ან მისი მოდელირება არ არის პრაქტიკულად მნიშვნელოვანი (Gan, et al. 2024).

ყველაზე გავრცელებული სითხის მოდელია მარკოვის მოდულირებული სითხის მოდელი, რომელშიც მარკოვის ჯაჭვის მიმდინარე მდგომარეობა განსაზღვრავს სიჩქარეს. მაგალითად, VBR (Variable Bit Rate) ვიდეო ნაკადისთვის, მდგომარეობა Sk

განსაზღვრავს მუდმივ სიჩქარეს  $\lambda_k$ , რომლის საფუძველზეც ხდება სისტემის ანალიზი. სითხის მოდელები გამოირჩევიან სიმარტივით, ანალიტიკური გამოთვლების სისწრაფით და სიმულაციის ეფექტიანობით (Gan, et al. 2024).

### 1.1.3 ავტორეგრესიული მოდელები და მათი გამოყენება ქსელური ტრაფიკის ანალიზში

ავტორეგრესიული მოდელები (AR) წარმოადგენენ ერთ-ერთ მნიშვნელოვან ინსტრუმენტს დროითი სერიების მოდელირებისა და პროგნოზირებისთვის. მათი არსი მდგომარეობს იმაში, რომ მომდევნო მნიშვნელობა დამოკიდებულია წინა მნიშვნელობათა ხაზოვან კომბინაციაზე. სხვა სიტყვებით, შემთხვევითი ცვლადის  $X_n$  მნიშვნელობა განისაზღვრება წინა მნიშვნელობების საფუძველზე, რაც შეიძლება გამოხატული იქნას შემდეგი ფორმულით:

$$X_k = r_1 X_{k-1} + r_2 X_{k-2} + \dots + r_p X_{k-p} + W_k$$

(Doğanalp Ergenç 2019)

სადაც  $W_k$  წარმოადგენს თეთრ ხმაურს (სტაციონარულ შემთხვევით ცვლადს ნულოვანი საშუალოთი და სტაბილური დისპერსიით), ხოლო  $r_i$  რეალური პარამეტრებია. ავტორეგრესიული მოდელის რიგი აღნიშნულია როგორც AR(p), სადაც p მიანიშნებს წინა მნიშვნელობათა რაოდენობაზე, რომლებიც გამოიყენება მოდელის პროგნოზირებისათვის.

AR(p) პროცესს ახასიათებს ACF-ის (ავტოკორელაციის ფუნქციის) კლება, რომელიც ხშირად წყვეტად სინუსოიდს წააგავს. რაც უფრო მაღალია p-ის მნიშვნელობა, მით მეტწილადაა შესაძლებელი რთული დროითი სტრუქტურების აღწერა (Doğanalp Ergenç 2019).

AR მოდელები ფართოდ გამოიყენება VBR (Variable Bit Rate) ვიდეოტრაფიკის მოდელირებისთვის, რაც აქტუალურია მაღალი სიჩქარის ქსელებში, როგორცაა IPTV ან სტრიმინგპლატფორმები. ვიდეოს ბუნებიდან გამომდინარე სადაც სიხშირე დაახლოებით 30 კადრია წამში თანმიმდევრული კადრები ერთმანეთისგან მცირედით განსხვავდება (Doğanalp Ergenç 2019). ამასთან, სცენის ცვლილებისას ვიდეო ტრაფიკის მოცულობა მკვეთრად იზრდება. ასეთ პირობებში, ავტორეგრესიული მოდელები

ეფექტურად აღწერენ კადრებს შორის კორელაციას, ხოლო მარკოვის ჯაჭვები გამოიყენება სცენის ცვლილებების ასახვისთვის.

მოდელირება შესაძლებელია შემდეგი გამოსახულებით:

$Z_n = A_n + B_n + X_n D_n$  აქედან  $A_n$  და  $B_n$  ორი დამოუკიდებელი AR[1] პროცესია, ხოლო  $X_n D_n$  წარმოადგენს შემთხვევითობის კომპონენტს სცენის ცვლილებისას. აღნიშნული მოდელი წარმატებით გამოიყენება ვიდეო შეკუმშვის ალგორითმებში, რომელთაც მხოლოდ კადრებს შორის ცვლილებების გადაცემა სჭირდებათ (Doğanalp Ergenç 2019).

პირველი რიგის დისკრეტული ავტორეგრესიული მოდელი DAR(1) წარმოადგენს შემთხვევითი ცვლადების სტაციონარულ თანმიმდევრობას, რომელიც ეფუძნება ორი დამოუკიდებელი შემთხვევითი თანმიმდევრობის  $[V_n]$  და  $[Y_n]$  კომბინაციას (Weiß 2020). მოდელი აღწერილია შემდეგი განტოლებით:

**$X_n = V_n X_{n-1} + (1 - V_n) Y_n$**  სადაც  $V_n$  იღებს მნიშვნელობებს 0 ან 1-ს, ალბათობით  $(1 - \rho)$  და  $\rho$ , ხოლო  $Y_n$  წარმოადგენს დისკრეტულ შემთხვევით ცვლადს განსაზღვრული გარდამავალი მატრიცით  $\pi(i)$ . აღნიშნული მოდელი მარტივია ანალიტიკური ანალიზისთვის, თუმცა მას აქვს შეზღუდვები: ავტოკორელაციის ექსპონენციური კლება არ შეესაბამება იმ პროცესებს, რომელთაც გააჩნიათ გრძელვადიანი დამოკიდებულება (Weiß 2020).

ARMA(p,q) მოდელი აერთიანებს ავტორეგრესიულ (AR) და მოძრავი საშუალოს (MA) კომპონენტებს და გამოიყენება სტაციონარული დროითი სერიების აღწერისთვის:

$$X_t = c + \sum_{i=1}^p \phi_i X_{t-i} + \epsilon_t - \sum_{j=1}^q \theta_j \epsilon_{t-j} \quad (\text{Weiß 2020})$$

სადაც  $\epsilon_t$  წარმოადგენს თეთრ ხმაურს, ხოლო  $\phi_i$  და  $\theta_j$  შესაბამისი მოდელის პარამეტრები. ანალიტიკურად ARMA მოდელები გამოიხატება შემდეგი წილადი გადაცემის ფუნქციით:

$$H(z) = \frac{B_q(z)}{A_p(z)} = \frac{1 - \sum_{j=1}^q \theta_j z^{-j}}{1 - \sum_{i=1}^p \phi_i z^{-i}}$$

(Weiß 2020)

ARMA მოდელები განსაკუთრებით ეფექტურია მულტიმედიური ტრაფიკის მოდელირებაში, როდესაც ტრაფიკის მახასიათებლები ცვალებადია დროში. თუმცა, მათი პარამეტრების შეფასება ხშირად მოითხოვს არაწრფივი განტოლებების ამოხსნას და შედარებით კომპლექსურ ანალიზს.

არასტაციონარული დროითი სერიების მოდელირებისთვის გამოიყენება ARIMA(p,d,q) მოდელები. ეს მოდელები ეფუძნება დიფერენცირებას, რაც შესაძლებელს ხდის დროითი სერიების სტაციონარიზაციას. მოდელის ზოგადი ფორმა შემდეგია:

$$\phi(B)\nabla^d X_t = \theta(B)\epsilon_t$$

(Weiß 2020)

სადაც  $\nabla=1-B$  არის დიფერენცირების ოპერატორი, ხოლო  $\phi(B)$  და  $\theta(B)$  შესაბამისი მრავალწევრიანები. პარამეტრი  $d$  აღნიშნავს რამდენჯერ არის დიფერენცირებული სერია. როდესაც  $d=1$ , მოდელი ებრძვის წრფივ ტენდენციებს, ხოლო  $d>1$  პოლინომიურ ტენდენციებს (Weiß 2020).

ARIMA მოდელები განსაკუთრებით გამოსადეგია მაშინ, როდესაც საჭიროა პროგნოზირება ტრაფიკის გრძელვადიანი ტენდენციების გათვალისწინებით, მაგალითად, დღის, კვირის ან თვიური სერიების მოდელირებისას.

ავტორეგრესიული მოდელები (AR) წარმოადგენს მნიშვნელოვან ინსტრუმენტს დროითი სერიების ანალიზისა და პროგნოზირებისთვის. აღნიშნული მოდელები ეფუძნება ცვლადის წინა მნიშვნელობათა კომბინაციასა და მათი გავლენით მომდევნო მნიშვნელობის განსაზღვრას. სხვა სიტყვებით, თითოეული მნიშვნელობა გამოითვლება წინა მნიშვნელობების ერთობლიობის საფუძველზე შემდეგი სახით:

$$X_k = r_1 X_{k-1} + r_2 X_{k-2} + \dots + r_p X_{k-p} + W_k,$$

(Weiß 2020)

სადაც  $W_k$  წარმოადგენს თეთრ ხმაურს, ხოლო  $r_i$  მოდელის წონები. AR(p) მოდელი გამოირჩევა იმით, რომ მისი ავტოკორელაციის ფუნქცია (ACF) გამოხატავს პოსტპერიოდულობით დამახასიათებელ სუსტ ლოკალურ პიკებს, რაც განსაკუთრებით მნიშვნელოვანი ხდება თვითმსგავსი მონაცემების მოდელირებისას.

ვიდეო მონაცემთა მოდელირებაში, სადაც ხშირია კადრებზე დაყრდნობილი თანმიმდევრულობა, AR მოდელები გამოიყენება სცენათაშორისი სტაბილურობის ასახვისთვის. შემთხვევებში, როდესაც კადრებს შორის განსხვავება მინიმალურია, AR მოდელები უზრუნველყოფენ ეფექტურ პროგნოზს და გაწონასწორებულ დატვირთვას ქსელში (Doğanalp Ergenç 2019).

DAR(1) მოდელები გამოიყენება მაშინ, როდესაც შემთხვევითი სერიების სტაციონარულობა დისკრეტული მახასიათებლებით უნდა აღწერილ იქნას. აღნიშნული მოდელები ეფუძნება ორ კომპონენტს: წინა მნიშვნელობაზე დაფუძნებულ დამოკიდებულებასა და გარე შემთხვევითობიდან მიღებულ კომპონენტს. მათი ფორმულირება შემდეგნაირადაა შესაძლებელი:

$$X_n = V_n X_{n-1} + (1 - V_n) Y_n, \quad (\text{Doğanalp Ergenç 2019})$$

სადაც  $V_n$  არის ბერნულის ტიპის ცვლადი, ხოლო  $Y_n$  დისკრეტული შემთხვევითი ცვლადი განსაზღვრული განაწილებით. მოდელი უზრუნველყოფს ACF-ის ექსპონენციალურ კლებას, რაც არ შეესაბამება გრძელვადიან დამოკიდებულებებს, თუმცა ეფექტურია მცირე პერიოდის პროგნოზირებისთვის.

**ARMA (p,q)** მოდელები აერთიანებენ ავტორეგრესიასა და მოძრავი საშუალოს კომპონენტებს და აღწერენ სტაციონარულ პროცესებს. მათ საფუძველზე იქმნება **ARIMA (p,d,q)** მოდელები, რომლებიც ინტეგრაციის მეშვეობით აღწერენ არასტაციონარულ პროცესებს. ეს მოდელები განსაკუთრებით ეფექტიანია იმ შემთხვევაში, როდესაც მონაცემები შეიცავს ტრენდს ან სეზონურობას (Baras 2003).

TES (Transformation and Expansion of Sample) მოდელი წარმოადგენს არაწრფივ რეგრესიულ მოდელს, რომელიც მიზნად ისახავს იმ სტაციონარული დროითი სერიების რეპროდუცირებას, რომელთაც გააჩნიათ კონკრეტული ზღვრული განაწილება და ავტოკორელაციის სტრუქტურა (ACF). მოდელის მიზანია უზრუნველყოს მოდელირებული სერიების მაქსიმალური შესაბამისობა რეალურ

მონაცემებთან როგორც სტატისტიკური, ისე გრაფიკული მახასიათებლების მხრივ (Hill 1995).

TES მოდელის მუშაობის ლოგიკა შემდეგია:

1. ინიციალიზაცია იწყება შემთხვევითი თანმიმდევრობით  $S_i \in [0;1]$ ,
2. თითოეული  $S_i$  გარდაიქმნება  $G_i$ -დ, რომელიც იღებს მნიშვნელობას შერჩეული სიმკვრივის მქონე განაწილებიდან  $[-0.5;0.5]$ ,
3. შედეგად მიიღება  $U_i = [U_i - 1 + G_i] \bmod 1$ , რაც ქმნის ფონურ თანმიმდევრობას,
4. შემდეგ გამოიყენება ფანჯრული ფუნქცია  $Z(x)$ , რომელიც ამცირებს ზღვრულ ეფექტებს და ინარჩუნებს თანმიმდევრობის სტაბილურობას,
5. საბოლოო ეტაპზე ხდება ისტორიული სერიის ჰისტოგრამის ინვერსია, რის შედეგადაც განისაზღვრება მთავარი დროითი სერია შესაბამისი განაწილებითა და ACF სტრუქტურით.

TES მოდელი გამოირჩევა იმით, რომ იძლევა ACF სტრუქტურის მიზანმიმართული ცვლილების საშუალებას ტრანსფორმაციის გზით, რაც განაპირობებს სიმულირებული მონაცემების მაღალი ხარისხით შესაბამისობას რეალურ მონაცემებთან (Hill 1995).

TES მოდელი სატელეკომუნიკაციო ტრაფიკის მოდელირებაში ფასდაუდებელია, როდესაც მიზანია ზუსტი იმიტაცია თვითმსგავსი ან არაწრფივი სისტემების ქცევისა, მათ შორის ისეთ შემთხვევაში, როცა ტრაფიკს აქვს ფარული ციკლურობა ან არათანაბარი განაწილება (Hill 1995).

#### 1.1.4 თვითმსგავსი მოდელები

თვითმსგავსი მოდელები გამოიყენება კომპიუტერულ ქსელებში მონაცემთა ნაკადების გრძელვადიანი დამოკიდებულების შესაფასებლად. განვიხილოთ  $[X_t]$ -სტაციონარული სტოქასტური პროცესი, რომელსაც გააჩნია სტაციონარული საშუალო  $\mu = E[X_t]$ , სტაციონარული და სასრულმნიშვნელო დისპერსია  $v = E[(X_t - \mu)^2]$  და ავტოკორელაციური ფუნქცია  $\gamma_k = E[(X_t - \mu)(X_{t+k} - \mu)]$ , რომელიც დამოკიდებულია მხოლოდ ჩამორჩენაზე  $k$  და არა თავად  $t$ -ზე. შესაბამისად, ავტოკორელაციის კოეფიციენტი განისაზღვრება როგორც  $\rho_k = \gamma_k / \gamma_0$  (Grab 2011).

დროის სერიას  $\{X_t\}$  ვყოფთ სიგრძე  $m$ -ის მქონე თანმიმდევრებად და თითოეულ სეგმენტზე განვსაზღვრავთ ნიმუშის საშუალოს  $X_j(m)$ . ამ საშუალოების დისპერსია  $v_m$  გამოითვლება შემდეგი ფორმულით:

$$v_m = \frac{v}{m} \left( 1 + 2 \sum_{k=1}^{m-1} \left( 1 - \frac{k}{m} \right) \rho_k \right) \quad (\text{Grab 2011})$$

იმ შემთხვევაში, თუ პროცესი წარმოადგენს თეთრ ხმაურს, მაშინ ავტოკორელაციური კოეფიციენტები ნულოვანია ყველა  $k > 0$  მნიშვნელობისთვის და შესაბამისად  $v_m = v / m$ .

თუმცა, რეალურ ქსელურ ტრაფიკში ეს დამოკიდებულება ხშირად არ არსებობს. კვლევებმა აჩვენა, რომ ACF იზღება ძალზე ნელა, რაც მიუთითებს გრძელვადიან დამოკიდებულებაზე (Tranter and Taylor 2007). ასეთი პროცესი აღიწერება შემდეგნაირად:

$$v_m \sim c \cdot m^{-\beta}, \quad \text{სადაც } 0 < \beta < 1 \quad (\text{Grab 2011})$$

ეს ფორმულა მიუთითებს თვითმსგავსი პროცესის თვისებაზე, როცა  $v_m$  დისპერსია ნელა მცირდება  $m$ -ის ზრდასთან ერთად.

თვითმსგავს პროცესს აქვს ისეთი ACF სტრუქტურა, რომელიც ყველა მასშტაბზე შენარჩუნებულია. ასეთ შემთხვევაში, პროცესი აკმაყოფილებს შემდეგ თვითმსგავსობის კრიტერიუმს:

$$\{X_{at}\} \stackrel{d}{=} \{\alpha^H X_t\} \quad (\text{Grab 2011})$$

სადაც  $H$  ჰერსტის პარამეტრია და აღნიშნავს თვითმსგავსობის ხარისხს (Pipiras 2017). თუ  $0.5 < H < 1$ , ეს მიუთითებს გრძელვადიან დამოკიდებულებაზე. ავტოკორელაციის ფუნქცია ასეთ შემთხვევაში ქვევით აღწერილი ფორმით ექცევა:

$$\rho_k \sim H(2H - 1)k^{2H-2}, \quad \text{როგორც } k \rightarrow \infty \quad (\text{Grab 2011})$$

გრძელვადიანი დამოკიდებულების შესაფასებლად ხშირად გამოიყენება ფრაქციულად ინტეგრირებული ავტორეგრესიული მოძრავი საშუალო მოდელი

ARFIMA(p,d,q), სადაც  $0 < d < 0.5$ . მოდელი აგებულია ARIMA სტრუქტურის გაფართოებაზე და აღწერს სტაციონარულ პროცესს შემდეგნაირად:

$$\phi(B)(1 - B)^d X_t = \theta(B)\epsilon_t \quad (\text{Pipiras 2017})$$

ეს ფორმულა იყენებს ბინომიალურ გაფართოებას:

$$(1 - B)^d = \sum_{k=0}^{\infty} \binom{d}{k} (-1)^k B^k \quad (\text{Arteche 2000})$$

ARFIMA მოდელები საშუალებას იძლევა ერთდროულად შეფასდეს როგორც მოკლე, ისე გრძელვადიანი დამოკიდებულება ტრაფიკის სერიებში (Arteche 2000).

ფრაქტალური ბრაუნის მოძრაობა (fBm) წარმოადგენს თვითმსგავს გაუსურ პროცესს, რომელსაც გააჩნია ჰერსტის პარამეტრი  $H \in [0.5, 1)$ . განსხვავებით კლასიკური ბრაუნის მოძრაობისგან, fBm-ის ნამატები ერთმანეთთან კორელირებულია, რაც შესაძლებელს ხდის ქაოსური და ფრაქტალური სტრუქტურის მოდელირებას ქსელურ ტრაფიკში (wu, Yang and Zhang 2010).

დისკრეტულ შემთხვევებში ავტოკორელაციის ფორმულა გამოყვანილია შემდეგნაირად:

$$\rho_k = \frac{(k + 1)^{2H} - 2k^{2H} + (k - 1)^{2H}}{2} \quad (\text{wu, Yang and Zhang 2010})$$

ეს მოდელები ტრაფიკის გრძელვადიან სიხშირულ მახასიათებლებს აღბეჭდავს და განსაკუთრებით გამოსადეგია თვითმსგავსი ნაკადების მქონე ქსელების სიმულაციური ანალიზისთვის.

### 1.1.5 აპლიკაციაზე დამოკიდებული ტრაფიკის მოდელები

მონაცემთა გადაცემის პროცესის ხასიათი კომპიუტერულ ქსელებში მჭიდროდ არის დაკავშირებული იმ აპლიკაციებთან, რომლებიც იყენებენ ამ ქსელებს. შესაბამისად, ტრაფიკის მოდელირება უნდა ითვალისწინებდეს აპლიკაციის სპეციფიკას. აპლიკაციების უმეტესობა შეიძლება კლასიფიცირდეს შემდეგად: ვებ-ტრაფიკი, ელფოსტა, ფაილების გაზიარება (peer-to-peer), და ნაკადური მედია.

კვლევებმა აჩვენა, რომ ვებ-ტრაფიკი წარმოადგენს ინტერნეტ ტრაფიკის უმეტეს ნაწილს (wu, Yang and Zhang 2010). ეს გასაკვირი არ არის, რადგან ვებ-ბრაუზერები წარმოადგენს მრავალფუნქციურ პლატფორმას ელფოსტისთვის, ფაილების გადაცემისთვის, დისტანციური მონაცემების დამუშავებისთვის და ვიდეოს ტრანსლაციისთვის.

ვებ-ტრაფიკს ხშირად ახასიათებს თვითმსგავსი ბუნება ერთ-ერთ კვლევაში ჰერსტის პარამეტრი  $H \approx 0.8$  დაფიქსირდა, რაც მიუთითებს გრძელვადიან დამოკიდებულებაზე (Tranter and Taylor 2007). ამ ტრაფიკის მოდელირება ხშირად კეთდება **ON/OFF** მოდელებით, სადაც **ON** რეჟიმში მიმდინარეობს გვერდის ჩატვირთვა, ხოლო **OFF** რეჟიმი შეიძლება იყოს როგორც აქტიური (კონტენტის ნახვისას), ასევე პასიური (მომხმარებელი დროებით არ იყენებს ბრაუზერს). ამ რეჟიმებისთვის გამოიყენება სხვადასხვა განაწილებები აქტიური OFF პერიოდი შეიძლება აღწერილი იყოს Weibull განაწილებით, ხოლო პასიური მძიმე კუდიანი Pareto განაწილებით (Feng and Sun 2018). ასევე, ვებ-ტრაფიკის ანალიზმა აჩვენა, რომ მომხმარებლის ქცევის მოდელირება რთულია, რადგან თითოეული მომხმარებელი ურთიერთობს განსხვავებული რაოდენობის სერვერებთან, რისი გამოყოფაც ტიპიური სტატისტიკური ხასიათით პრაქტიკულად შეუძლებელია (Gonçalves, Ramasco and Flammini 2009).

Peer-to-peer (P2P) ტრაფიკი ხშირად განიხილება ვებ-ტრაფიკის ალტერნატივად. განსხვავებით კლიენტ-სერვერული არქიტექტურისგან, P2P სისტემა გულისხმობს მონაცემთა გაზიარებას თანაბარუფლებიან კვანძებს შორის.

კვლევები აჩვენებს, რომ P2P ტრაფიკი ხშირად გენერირდება მცირე რაოდენობის მაღალი დატვირთვის მქონე კვანძების მიერ. მაგალითად, AVI, MPEG და MP3 ფაილების გაზიარება ქმნიდა ტრაფიკის უდიდეს ნაწილს რამდენიმე მომხმარებლის მხრიდან (Stefan, Krishna and Richard 2002). მსგავსი ტენდენცია დაფიქსირდა სხვა კვლევებშიც, სადაც მხოლოდ მცირე რაოდენობის მომხმარებლები იყვნენ პასუხისმგებელი ქსელის დატვირთვის ძირითად წილზე (Perényi, et al. 2006).

ვიდეო მონაცემთა ტრაფიკი ძალზე განსხვავებულია თავისი ბუნებით. მისი თვისებები დამოკიდებულია როგორც ვიდეოს კადრების სიხშირეზე, ასევე კოდირების ალგორითმებზე. ვიდეო კოდეკების უმეტესობა მუშაობს ისე, რომ აღწერს

მხოლოდ ცვლილებებს კადრებს შორის. ეს იწვევს ტრაფიკის ინტენსივობის მკვეთრ ცვალებადობას, რაც გამოწვეულია სცენის ცვლილებებით ან მოძრავი ობიექტებით. ვიცით, რომ ვიდეო ტრაფიკის თითოეულ ჩარჩოზე მონაცემების რაოდენობა შეიძლება აღწერილი იყოს ლოგნორმული, გამა ან ჰარეტოს განაწილებებით (Min , Yueping and Dmitri 2009). ACF ფუნქცია, როგორც წესი, არადინამიური ვიდეოებისთვის ექვემდებარება ექსპონენციურ განლევას, ხოლო უფრო რთული სტრუქტურა აქვს სტრიმინგ ვიდეოსთვის. სცენის ხანგრძლივობა, ასევე, აღწერილია ხშირად Pareto ან Weibull განაწილებით.

ერთ-ერთ საინტერესო დაკვირვებაში აღმოჩნდა, რომ ვებ ვიდეოს ნაკადების სიგრძე ხშირად ექვემდებარება მძიმე კუდიან განაწილებებს, რაც დამატებით აძლიერებს ტრაფიკის არაპროგნოზირებადობას (Wolman and Maureen Chesire 2001).

## 1.2 ტრაფიკის მართვის მეთოდები მონაცემთა გადაცემის ქსელებში

ტრაფიკის მართვის მეთოდები მონაცემთა გადაცემის ქსელებში, არსებითად, იყოფა ორ ძირითად ჯგუფად უკუკავშირის გარეშე და უკუკავშირიანი ალგორითმები. ღია მარყუჟის (Open-loop) მეთოდები არ ითვალისწინებენ ქსელის მიმდინარე მდგომარეობას გადაწყვეტილების მიღებისას, როდესაც ხდება პაკეტების ჩამოყრა ან რესურსების გადანაწილება. შესაბამისად, ასეთი მიდგომა ნაკლებად ეფექტურია დინამიური დატვირთვის პირობებში, განსაკუთრებით მაშინ, როდესაც პაკეტის დაკარგვის მიზეზი არ არის გადატვირთვა, არამედ, მაგალითად, უკაბელო ქსელის შემთხვევაში სიგნალის დამახინჯება ან ინტერფერენცია. ამ ტიპის ალგორითმების მაგალითია **Token Bucket** ალგორითმი, რომელიც გამოიყენება ტრაფიკის შერევის და ფორმირების პროცესში ( Tanenbaum, Feamster and Wetherall 2021, 278).

უკუკავშირიანი(Closed-loop) ალგორითმები ითვალისწინებენ ქსელის მიმდინარე მდგომარეობას, ახდენენ გადატვირთვის პრევენციას, გადააგზავნიან შესაბამის შეტყობინებებს ქსელის სხვა სეგმენტებში და საჭიროების შემთხვევაში, ახდენენ რეგულაციას. ასეთი მეთოდები იყენებენ ქსელის მონიტორინგს და ქვემოთ ჩამოთვლილ ინდიკატორებს:

- პაკეტების წილი, რომელიც დაიკარგა ბუფერის შევსების გამო;
- რიგის საშუალო სიგრძე;

- ხელახალი გადაცემების რაოდენობა დაუსრულებელი აკნის (ACK) გამო;
- პაკეტების დაგვიანების საშუალო დრო და მისი დისპერსია.

ამ ინდიკატორების ზრდა მიუთითებს ქსელის მზარდ დატვირთვაზე ან უკვე არსებულ გადატვირთულობაზე. უკუკავშირიანი ალგორითმები შეიძლება იყოს ორობითი (binary), რაც უბრალოდ მიუთითებს გადატვირთვის არსებობაზე, ან რაოდენობრივი რომელიც აჩვენებს დატვირთვის დონეს ( Tanenbaum, Feamster and Wetherall 2021, 286).

TCP/IP სტეკის მაგალითებში აღსანიშნავია **Explicit Congestion Notification (ECN)** და **ICMP Source Quench**, რომლებიც ცდიან გადატვირთვის შესახებ ინფორმაციის გადაცემას ტრაფიკის წყაროსთან (Nahar, et al. 2016) (S. Floyd and K. Ramakrishnan 2001). გადატვირთვის მართვის ზოგად ალგორითმებში უმარტივესი მიდგომაა, რომ ქსელის კვანძი, რომელმაც დააფიქსირა გადატვირთულობა, გააგზავნოს შეტყობინება წყაროსთან მონაცემთა ნაკადის სიჩქარის შესამცირებლად. თუმცა, პრაქტიკაში, მსგავსი შეტყობინებები შეიძლება არ მიაღწიოს ადრესატამდე და მეტიც თავად ამ შეტყობინებების რაოდენობამ შეიძლება დამატებითი ტრაფიკი წარმოქმნას.

ალტერნატიული მიდგომაა შეტყობინების სათაურში ინფორმაციისთვის ველის გამოყოფა, რომელიც ივსება გადატვირთული კვანძის მიერ. ამ მიდგომას იყენებს რამდენიმე პროტოკოლი, როგორცაა **Frame Relay**, **DCCP (Datagram Congestion Control Protocol)** და **ATM (Asynchronous Transfer Mode)** (Misra, et al. 2010) (E. Kohler, M. Handley and S. Floyd 2006).

გადატვირთვის კონტროლის სხვა საშუალებაა პერიოდული „სამიეზო“ პაკეტების (probing messages) გაგზავნა მარშრუტიზატორების მიერ ქსელის მონიტორინგის მიზნით (Sattari, Keshavarz and Noor 2012).

გადატვირთვის კონტროლის ალგორითმების დეტალური კლასიფიკაცია მოცემულია (Sattari, Keshavarz and Noor 2012)-ის კვლევაში, სადაც წარმოდგენილია ტრაფიკის მართვის ხისებური სტრუქტურა (იხ. ნახ. 1).

ნახ. 1. ტრაფიკის მართვის ალგორითმების ხისებური კლასიფიკაცია



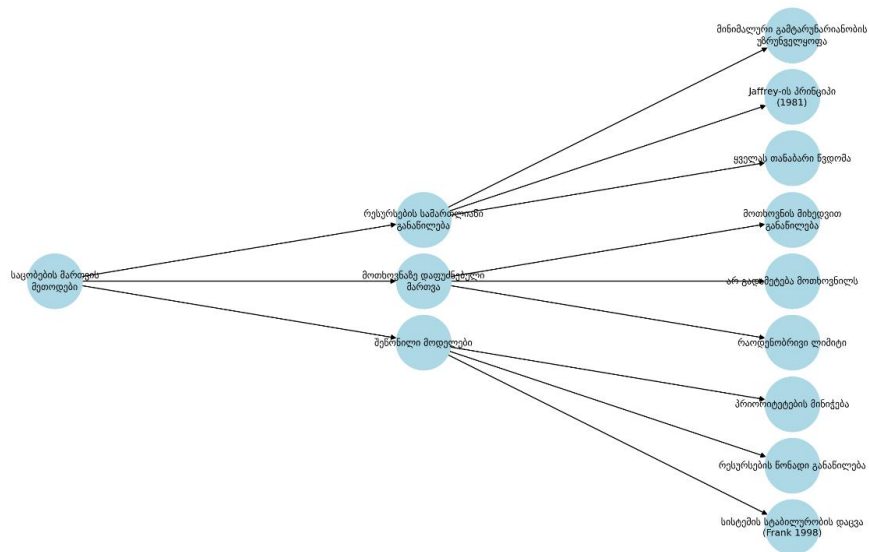
(Sattari, Keshavarz and Noor 2012)

### 1.2.1 ღია მარყუჟის გადატვირთულობის მართვის მეთოდები

ღია მარყუჟის გადატვირთულობის მენეჯმენტი არ შეიცავს ქსელის კვანძების პირდაპირ ინფორმირებას გადატვირთულობის არსებობის შესახებ და არ ითვალისწინებს ცენტრალიზებულ უკუკავშირს გადატვირთვის აღმოსაფხვრელად. ამის ნაცვლად, მოძრაობის კონტროლი ხორციელდება ლოკალურად პაკეტების გამგზავნა და მიმღებს შორის, ან გადამრთველ მოწყობილობაში, რომელიც უზრუნველყოფს ტრაფიკის დინამიკის დამოუკიდებელ მართვას. ამგვარი მიდგომა უფრო პრევენციულია და მიზნად ისახავს გადატვირთვის თავიდან აცილებას, ვიდრე მის შემდეგ მართვას (Kanopoulos and Hallenbeck 2003).

ტრაფიკის მართვაში ერთ-ერთი ფუნდამენტური პრინციპია ქსელური რესურსების სამართლიანი განაწილება. გადამრთველ მოწყობილობებს, როგორცაა როუტერები, უწევთ ტრაფიკის დამუშავება მრავალ წყაროსა და აპლიკაციას შორის, რაც ხშირ შემთხვევაში იწვევს არათანაბარ განაწილებას. რიგის თეორიის მიხედვით, QoS ფუნქციების გარეშე ოპერაციაში მყოფი მოწყობილობები მოქმედებენ FIFO პრინციპით (First-In-First-Out), რაც ხელს უწყობს იმ აბონენტის მიერ მთელი ბუფერული რესურსის მოხმარებას, რომელიც ქმნის ტრაფიკის მკვეთრ მატებას. შედეგად, სხვა აბონენტების პაკეტები იძირება ბუფერის ამოწურვის გამო (Kanopoulos and Hallenbeck 2003).

## ნახ. 2. საცობების მართვის მეთოდების კლასიფიკაცია



### წყარო: ავტორის მიერ შედგენილი

მონოპოლიზაციის თავიდან ასაცილებლად შემუშავებულია რიგის მართვის ალგორითმები, რომლებიც ეფუძნება სამართლიანობის პრინციპს. კლასიკური მიდგომა, ჩამოყალიბებული Jeffrey Jaffe-ის მიერ, განსაზღვრავს, რომ ქსელის კრიტიკულ მონაკვეთზე გამავალი ნაკადის გამტარუნარიანობა არ უნდა იყოს ნაკლები სხვა ნაკადების მინიმალურ გამტარუნარიანობაზე (Jeffrey 1981). შესაბამისი მოთხოვნები გაწერილია IETF-ისა და ATM ფორუმის მიერ:

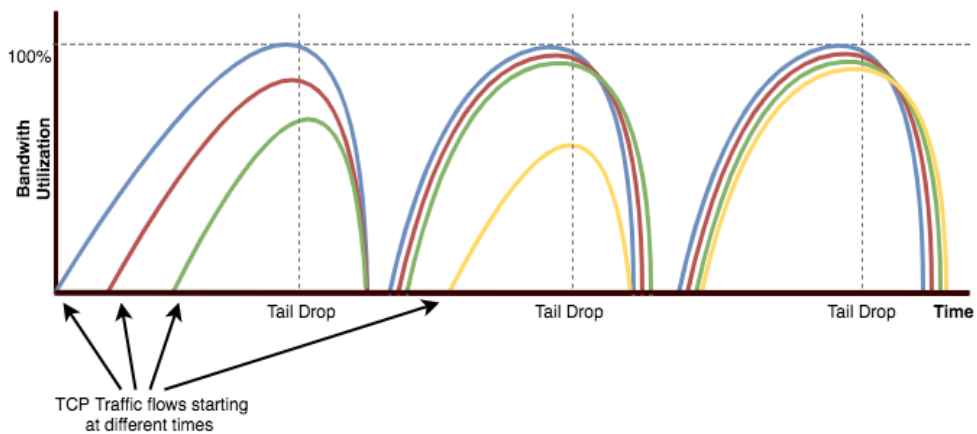
- რესურსების განაწილება უნდა ეფუძნებოდეს მოთხოვნის მიღების თანმიმდევრობას;
- მომხმარებელს არ უნდა მიეწოდოს მეტი რესურსი, ვიდრე მოითხოვას;
- ყველა მომხმარებელი, რომელიც მოითხოვს მეტს, ვიდრე მისთვის დადგენილია, იღებს იმავე რაოდენობის მინიმალურ გამტარუნარიანობას (Jeffrey 1981).

ამ მოდელის შესაბამისად, ახალი ნაკადები იღებენ ტოლი გამტარუნარიანობის მინიმუმს. დარჩენილი რესურსები კი განაწილდება იმ ნაკადებზე, რომელთაც მაღალი მოთხოვნა გააჩნიათ. საჭიროების შემთხვევაში, შესაძლებელია მაღალი მოთხოვნის მქონე ნაკადის შეზღუდვა, რათა უზრუნველყოს სისტემის სტაბილურობა (Frank 1997). სწორად დაბალანსებული რესურსების განაწილებისთვის გამოიყენება შეწონილი მოდელები, რომლებშიც ნაკადებს ენიჭებათ პრიორიტეტული კოეფიციენტები მათი საჭიროებების მიხედვით (Frank 1997).

რიგებში პაკეტების მომსახურების სტრატეგიის ფარგლებში, ერთ-ერთი ძირითადი მიდგომაა პრიორიტეტული რიგის გამოყენება. მიუხედავად სიმარტივისა, ეს მიდგომა იწვევს მაღალი პრიორიტეტის მქონე ნაკადის რესურსების მონოპოლიზაციას. ამიტომ აქტუალურია ისეთი ალგორითმების დანერგვა, რომლებიც ითვალისწინებენ სამართლიან წვდომას რესურსებზე. ერთ-ერთი მათგანია GPS (Generalized Processor Sharing), რომელიც ემყარება მუდმივი სერვისის სიჩქარის გარანტიას (Vanlerberghe, et al. 2015).

GPS ალგორითმის მიხედვით, თითოეული ნაკადი იღებს რესურსს მისი მინიმალური მოთხოვნის პროპორციულად, ხოლო გადაჭარბებული მოთხოვნისას რიგი იშლება. GPS-ის უპირატესობა ისაა, რომ ერთი ნაკადის მომსახურება არ მოქმედებს სხვებზე, და სისტემა ადაპტირებადია სხვადასხვა დატვირთვის პირობებში. GPS მოდელირება ხორციელდება უწყვეტ დროში და პრაქტიკაში გამოიყენება მისი მიახლოებები, როგორცაა წონიანი სამართლიანი რიგი WFQ (Weighted Fair Queueing) (Fabrice Michel and Didier 2004). WFQ ალგორითმში რიგები ემსახურებიან პაკეტების წონისა და მათ მომსახურების დროის მიხედვით. მასთან დაკავშირებული მოდიფიკაციაა WWFQ (Worst-case Weighted Fair Queueing), რომელიც დამატებით უზრუნველყოფს რესურსების არა-მონოპოლიზებას და მეტ გლუვობას ტრაფიკის გამავალ ნაკადში (Ziegler 2001).

**ნახ. 3. Tail Drop TCP გლობალური სინქრონიზაციის პრობლემა, როდესაც ის გამოიყენება როგორც შეფერხების თავიდან აცილების მექანიზმი**



(cisco 2020)

რაც შეეხება რიგის მართვას მიღების ეტაპზე, TailDrop ალგორითმი ერთ-ერთი უძველესია და ითვალისწინებს პაკეტის ავტომატურ ჩამოგდებას, როცა ბუფერი ივსება. მისი ძირითადი ნაკლია TCP-ის გადაცემის ფანჯრის კოლექტიური შემცირება, რაც იწვევს არასაკუთრო სინქრონიზაციას ქსელში (Ziegler 2001). TailDrop-ის სხვა ვარიანტები მოიცავს პაკეტების შემთხვევით ჩამოშლას ან რიგის თავში მყოფი პაკეტების უგულვებლყოფას.

მნიშვნელოვანი ალგორითმია RED (Random Early Detection), რომელიც პირველად შემუშავდა Sally Floyd-ისა და Van Jacobson-ის მიერ (Misra, et al. 2010). RED ითვლის ბუფერის საშუალო ზომას და მის საფუძველზე ადგენს პაკეტის ჩამოგდების ალბათობას, რაც ხელს უშლის რესურსების მონოპოლიზაციას და TCP სინქრონიზაციას.

ამ მიდგომის გაუმჯობესებული ვარიანტია ARED (Adaptive RED), რომელიც დინამიკურად არეგულირებს ზღვრულ მნიშვნელობებს დატვირთვის დონის მიხედვით და უფრო ეფექტიანად რეაგირებს დატვირთვის ცვლილებაზე (Naixue , et al. 2005).

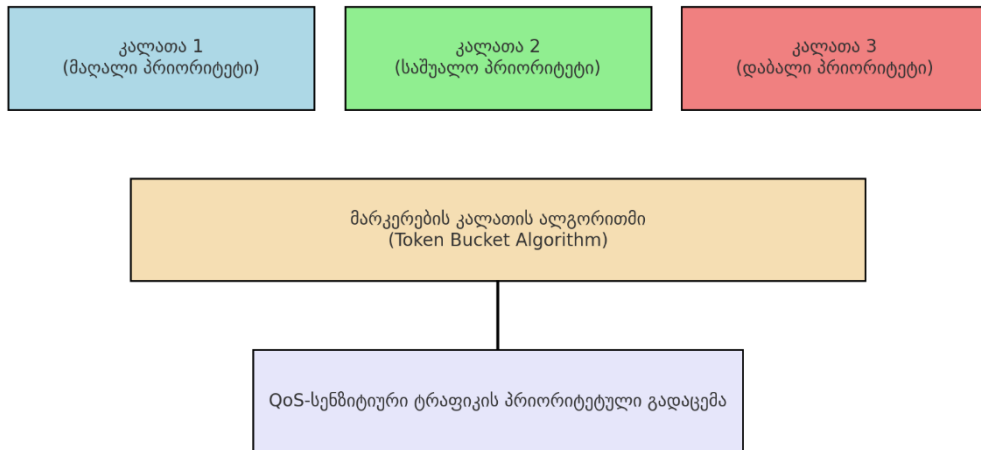
სხვადასხვა მოდიფიკაციები მოიცავს:

- WRED (Weighted RED), რომელიც იყენებს TCP/IP პროტოკოლის სათაურის პრიორიტეტებს;
- RIO (RED In/Out), რომელიც ორიენტირებულია მონიშნული და არამონიშნული პაკეტების განცალკევებულ დამუშავებაზე;
- FRED (Flow RED), რომელიც ითვალისწინებს ნაკადების მდგრადობას შეფერხების მიმართ;
- SRED (Stabilized RED), რომელიც წარმოადგენს FRED-ის ოპტიმიზებულ ვერსიას;
- RED-PD (Preferential Dropping), რომელიც ზრდის ჩაგდების ალბათობას იმ რიგებში, რომლებიც ქმნიან გადატვირთვას (Jajszczyk and Rafal 2008).

ტრაფიკის შეზღუდვისთვის გამოიყენება ე.წ. მარკერების კალათის ალგორითმი (Token Bucket), რომელიც ზღუდავს ტრაფიკის მაჩვენებლებს გადაცემის ზღვრულ მაჩვენებლებთან შესაბამისად (A. Tanenbaum 2003, 397-398). აღნიშნული მიდგომა განსაზღვრავს:

- მაქსიმალურ მოცულობას (Committed Burst Size);
- საშუალო გადაცემის სიჩქარეს (Committed Information Rate);
- პაკეტის გადაცემის შესაძლებლობას მარკერების რაოდენობაზე დაყრდნობით;
- მარკერების ამოწურვის შემთხვევაში პაკეტის გაუქმებას ან მარკირებას.

ნახ. 4. საცობების მართვის მეთოდების კლასიფიკაცია

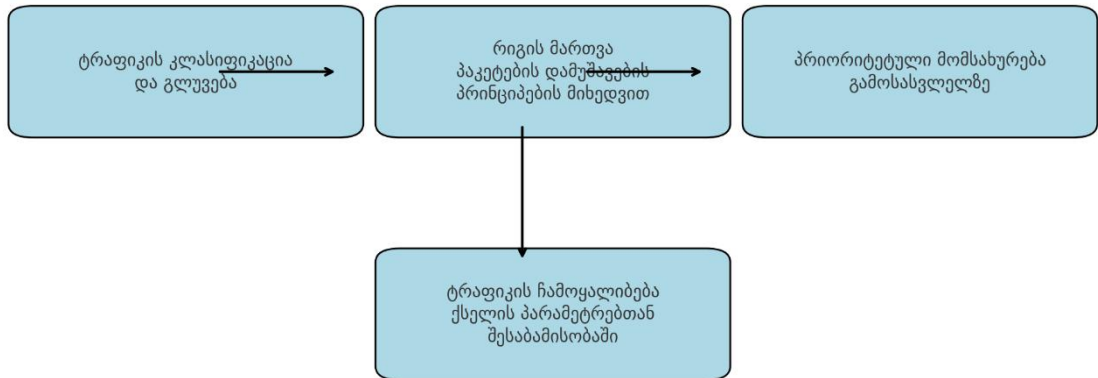


**წყარო: ავტორის მიერ შედგენილი**

ალგორითმის მოდიფიცირებული ვერსია იყენებს სამ კალათს, რათა განსაზღვროს ტრაფიკის პრიორიტეტი და შესაძლებელი გახდეს სხვადასხვა ხარისხის მომსახურება (A. Tanenbaum 2003, 407).

მოდრაობის ჩამოყალიბება (Shaping) მიზნად ისახავს გამავალი ტრაფიკის გლუვობას, რის შედეგადაც პაკეტები საჭიროების შემთხვევაში ბუფერდება და არ იშლება. ამისათვის ასევე გამოიყენება მარკერების კალათის ალგორითმი, რომელიც განსაზღვრავს პაკეტის გადაცემის საშუალებას კალათაში არსებული ტოკენების საფუძველზე. ამ მიდგომით ხდება QoS-სენზიტიური ტრაფიკის პრიორიტეტული გადაცემა (A. Tanenbaum 2003, 407-410).

ნახ. 5. მოძრაობის გამარტივება და პროფილირება



წყარო: ავტორის მიერ შედგენილი

ღია მარყუჟის მართვის მეთოდები იძლევა შესაძლებლობას გადამრთველმა მოწყობილობებმა შეასრულონ შემდეგი თანმიმდევრული ფუნქციები:

- ტრაფიკის კლასიფიკაცია და გლუვება;
- რიგის მართვა პაკეტების დამუშავების პრინციპების მიხედვით;
- პრიორიტეტული მომსახურება გამოსასვლელზე;
- ტრაფიკის ჩამოყალიბება ქსელის პარამეტრებთან შესაბამისობაში.

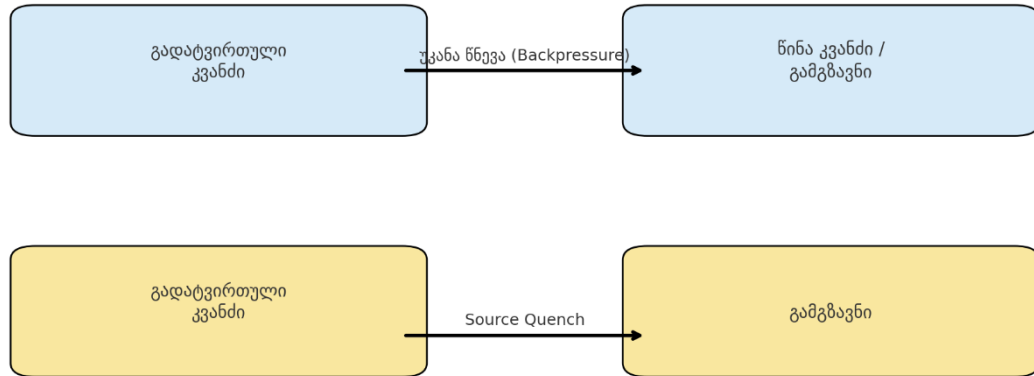
## 1.2.2 გადატვირთულობის დინამიკური მართვა უკუკავშირის საფუძველზე

არსებული ტრაფიკის მართვის ალგორითმები, რომლებიც ფუნქციონირებენ უკუკავშირის გარეშე, ძირითადად ორიენტირებული არიან შემუშავების თავიდან აცილებაზე. თუმცა, ქსელის აქტუალური მდგომარეობის გააზრებისა და გადატვირთულობის ფაქტის გამოვლენის მიზნით, აუცილებელია უკუკავშირის მქონე მართვის მექანიზმების გამოყენება. ამ მიდგომის არსი მდგომარეობს იმაში, რომ გადატვირთული ქსელური კვანძი აწვდის შესაბამის ინფორმაციას სხვა კვანძებს როგორც მონაცემთა გამგზავნებს, ასევე მიმღებებს რათა მოხდეს გადაცემის სიჩქარის რეგულირება და გადატვირთულობის შემცირება (A. Tanenbaum 2003, 136-137).

როგორც სურათ 6-ზეა წარმოდგენილი, უკუკავშირი შეიძლება იყოს ორი ტიპის: აშკარა (explicit) და იმპლიციტური (implicit). აშკარა უკუკავშირის მექანიზმი გულისხმობს გადატვირთულობის სიგნალიზაციას კონკრეტული პროტოკოლის ან პაკეტის სათაურის ფარგლებში დამატებული ინფორმაციის მეშვეობით. ასეთ

შემთხვევებში, ქსელის კვანძი პირდაპირ აწვდის გადატვირთულობის შესახებ მონაცემებს შესაბამის წყაროს ან მიმღებს (A. Tanenbaum 2003, 81-82).

ნახ. 6. უკუკავშირის მექანიზმები



წყარო: ავტორის მიერ შედგენილი

ამგვარი აშკარა უკუკავშირის მაგალითებია:

- **უკანა წნევის (backpressure) მეთოდი:** გადატვირთული კვანძი აგზავნის სპეციალურ კონტროლურ შეტყობინებას მის წინა მყოფი კვანძისკენ ანუ პაკეტის გამგზავნის მიმართულებით. შედეგად, თითოეული შუალედური კვანძი, რომელიც მონაწილეობს ტრანზიტში, ზედმეტად ზღუდავს შემომავალ ნაკადს, რაც საბოლოოდ ამცირებს მთლიანი ქსელის დატვირთვას (A. Tanenbaum 2003, 400-401).
- **საკონტროლო შეტყობინებების გამოყენება (მაგ. Source Quench):** გადატვირთულმა კვანძმა შესაძლოა გზავნოს სპეციალური შეტყობინებები პაკეტების გამგზავნთან, რომლებიც მიუთითებენ გადაცემის სიჩქარის შემცირების აუცილებლობაზე. აღნიშნული მიდგომა, კერძოდ, ინტერნეტში გამოიყენება Internet Control Message Protocol-ის ფარგლებში Source Quench შეტყობინებების სახით (A. Tanenbaum 2003, 466-467).

განსხვავებულ შემთხვევებში, შესაძლებელია ინფორმაცია გადატვირთულობაზე გაგზავნილ იქნას პაკეტის მიმღებს, რათა ამ უკანასკნელმა განახორციელოს გამავალი ტრაფიკის შეზღუდვა. აღნიშნული მოდელი გულისხმობს იმავდროულად როგორც ქსელის დატვირთულობის შეფასებას, ისე უფრო მაღალი დონის პროტოკოლის მაგალითად, TCP-ის მეშვეობით გადაცემის პარამეტრების კორექტირებას. გარდა კონტროლური შეტყობინებებისა, ზოგიერთ პროტოკოლს შეუძლია განსაზღვროს

დაშვებული გამტარუნარიანობა კონკრეტულ ქსელურ მონაკვეთზე. ეს მოითხოვს სიგნალის ზუსტ დროს, რათა ქსელის სხვადასხვა სეგმენტში არ მოხდეს დატვირთვის ასიმეტრიული რყევა. ერთ-ერთი ფართოდ გამოყენებული მექანიზმია **მოცურების ფანჯრის (sliding window) პრინციპი**, რომლის ფარგლებშიც მონაცემთა წყაროს შეუძლია გადააგზავნოს მონაცემები მითითებულ მაქსიმალურ ფანჯარაზე (კრედიტზე) დაყრდნობით. გადატვირთულობის ზრდისას აღნიშნული ფანჯარა თანდათან მცირდება, რაც ხელს უწყობს ტრაფიკის სტაბილურ კონტროლს (A. Tanenbaum 2003, 226-228).

აღსანიშნავია, რომ უკუკავშირის იმპლიციტური ვარიანტიც ფართოდ გამოიყენება, როდესაც ქსელის კვანძები გადატვირთულობის შესახებ დასკვნას აკეთებენ არა პირდაპირი სიგნალის, არამედ არაპირდაპირი ნიშნების საფუძველზე. ასეთი ნიშნებია:

- **RTT-ის (Round Trip Time) ზრდა**, რაც მიუთითებს პასუხის დაგვიანებაზე;
- **პაკეტების დაკარგვა**, რაც შესაძლებელია ბუფერის გადავსების შედეგად;
- **დუბლირებული პაკეტები**, რაც გამოწვეულია პასუხის დაგვიანებით და ხელახალი გაგზავნით.

ამგვარად, იმპლიციტური უკუკავშირი ეფუძნება ქსელის კვანძების მიერ აკუმულირებულ სტატისტიკურ მონაცემებს და განზოგადებული შეფასებების საფუძველზე რეგულირებს ტრაფიკს გადატვირთულობის პირობებში.

### 1.2.3 გადატვირთულობის კონტროლის მექანიზმები TCP პროტოკოლში

TCP (Transmission Control Protocol- გადაცემის კონტროლის პროტოკოლი) თავდაპირველად ჩამოყალიბდა საიმედო მონაცემთა გადაცემის უზრუნველსაყოფად არასანდო საკომუნიკაციო არხებზე (Agency 1981). გადაცემისას ინფორმაცია იყოფა სეგმენტებად (პაკეტებად), რომლებიც განიცდიან თანმიმდევრულ ნუმერაციას, რაც მიმღებს საშუალებას აძლევს, აკონტროლოს მიღებული მონაცემების თანმიმდევრობა და აღადგინოს თავდაპირველი შეტყობინება. თითოეულ სეგმენტს თან ერთვის მომსახურების დეტალური ინფორმაცია, როგორცაა თანმიმდევრობის ნომერი (SN), დადასტურების ნომერი (AN) და გადაცემის ფანჯრის ზომა (W). გარკვეული მოცულობის მონაცემების მიღების შემდეგ, მიმღები აგზავნის დადასტურებულ

შეტყობინებებს; მათ არქონის შემთხვევაში, გამგზავნი ხელახალი გადაცემის პროცესს იყენებს (Agency 1981).

TCP პროტოკოლის ფარგლებში გადატვირთულობის მართვა განსაკუთრებით რთული ამოცანაა, ვინაიდან ის დამოკიდებულია მხოლოდ მიმღებსა და გამგზავნს შორის მიმდინარე ნაკადზე, რომლებიც გადაცემის ფანჯრის პარამეტრების მართვის მეშვეობით აკონტროლებენ ნაკადს. ქსელში არსებული გადატვირთულობის გამოვლენა მხოლოდ არაპირდაპირი ნიშნებითაა შესაძლებელი- მაგალითად, RTT-ის ზრდით ან პაკეტების დაკარგვით.

TCP-ის კლასიკური დანერგვები, როგორცაა **Tahoe** და **Reno**, იყენებენ რამდენიმე სტრატეგიას გადატვირთულობის თავიდან ასაცილებლად. ერთ-ერთი მთავარი მექანიზმია **ნელი დაწყება** (Slow Start). კავშირის დასაწყისში, გამგზავნი იწყებს მცირე ფანჯრით და მისი ზომა ორმაგდება ყოველი დადასტურებული სეგმენტის შემდეგ, სანამ არ მიაღწევს წინასწარ განსაზღვრულ ზღვარს ან არ დაფიქსირდება პაკეტის დაკარგვა. ამგვარი მიდგომა ხელს უწყობს ქსელის გამტარუნარიანობის ოპტიმალურ შეფასებას ადრეულ ეტაპზე (Tanenbaum and Wetherall 2011, 577-579).

შემთხვევაში, როდესაც გადატვირთული კვანძი აგზავნის “ჩახშობის” (Source Quench) შეტყობინებას- რაც IP ქსელებში ხორციელდება **ICMP Source Quench** მექანიზმის გამოყენებით- გამგზავნი ამცირებს გადაცემის ფანჯრის ზომას, რაც იწვევს ნაკადის შემცირებას და ასცილებს ბუფერის გადაჭარბებას. TCP ასევე იყენებს ე.წ. **მოცურების ფანჯრის მეთოდს**, რომლის ფარგლებშიც გადაცემის სიჩქარე არ უნდა აღემატებოდეს მიღებულ საკრედიტო ზღვარს (Tanenbaum and Wetherall 2011, 47).

TCP პროტოკოლის თანამედროვე რეალიზაციებში გადაცემის ფანჯრის მართვა ეფუძნება მრგვალი მიმოსვლის დროის (RTT) შეფასებას. ხელახალი გადაცემის თაიმაუტის გაანგარიშება ხდება შემდეგი ფორმულით:

$$T_{i+1} = RTT'_{i+1} + k \cdot \Theta_i$$

(Jason , et al. 2005)

სადაც RTT' წარმოადგენს ექსპონენციურად გათვლილ RTT-ს,  $\Theta$ - RTT-ის საშუალო გადახრას, ხოლო k არის კოეფიციენტი, რომელიც პროტოკოლის დოკუმენტაციის თანახმად უდრის 4-ს (Jason , et al. 2005).

ამავე ჭრილში გამოიყენება კარნის ალგორითმი და ექსპონენციალური უკუქცევის მეთოდი, რომლებიც ამცირებენ არაზუსტი ან ზედმეტი გადაცემის ალბათობას ხელახალი ტრანსმისიისას (Balakrishnan, Seshan and Katz 1995).

ამრიგად, ისეთი ალგორითმები, როგორებიცაა ნელი დაწყება, RTT-ზე დაფუძნებული გადაცემის დროის კონტროლი, სწრაფი აღდგენის (Fast Recovery) და გადატვირთული ფანჯრის დინამიური რეგულირების მექანიზმები, განიხილება TCP-ის ძირითად ინსტრუმენტებად QoS-ის შესანარჩუნებლად და ქსელის გამტარუნარიანობის ოპტიმიზაციისთვის (Tanenbaum and Wetherall 2011, 578-579).

**შეჯამება:** თანამედროვე კომპიუტერული ქსელები მნიშვნელოვნად განსხვავდება ტრადიციული სატელეფონო ქსელებისგან, რომელთა მოდელირება ათწლეულების წინ შედგენილი ანალოგიური მიდგომებით ხდებოდა. ბოლო წლებში, ქსელური ტრაფიკის ხასიათში მიმდინარე ცვლილებების განსაკუთრებით დატვირთვის არასტაბილურობის, მრავალფეროვანი გადაცემის პროტოკოლების გაჩენისა და ინფორმაციის სტრუქტურის ცვლილების შედეგად ტრაფიკის მოდელირებაც თანმიმდევრულად განიცდის ევოლუციას.

სამეცნიერო ლიტერატურაში განსაკუთრებული ყურადღება ეთმობა შეტყობინებების ნაკადების ფრაქტალურ და ქაოტურ თვისებებს, რაც კომპიუტერულ ქსელებში ტრაფიკის თვითორგანიზებულობას, არაწრფივობასა და პროგნოზირებად ქაოსს განაპირობებს. კვლევები აჩვენებს, რომ კლასიკური ხაზოვანი მოდელები მხოლოდ ნაწილობრივ ასახავს რეალურ ტრაფიკულ ქცევას და არ არის საკმარისი QoS-ის მოთხოვნების დასაკმაყოფილებლად, განსაკუთრებით გადატვირთულობის პრევენციის პირობებში. მიუხედავად იმისა, რომ QoS-ის უზრუნველსაყოფად გამოყენებული სტანდარტული მიდგომები ძირითადად სტატისტიკურ და ხაზოვან ალგორითმებზეა დაფუძნებული, ტრაფიკის მართვის ეფექტიანობა მნიშვნელოვნად იზრდება, როდესაც გათვალისწინებულია ნაკადის არაწრფივი დინამიკა და ქაოსური თვისებები. ამ თვალსაზრისით, განსაკუთრებით აქტუალურია მეთოდების შემუშავება, რომლებიც აერთიანებენ არაწრფივი დინამიკისა და ქაოსის თეორიის მიდგომებს ტრაფიკის კონტროლის პროცესში.

ადეკვატურად მოდელირებული ტრაფიკის საფუძველზე შესაძლებელია გადატვირთულობის პრევენციის ისეთი სტრატეგიების განხორციელება, რომლებიც ეფუძნება მოკლევადიანი დროითი სერიების პროგნოზირებას. ამ პროცესში შეიძლება გამოყენებულ იქნეს როგორც ტრაფიკის გენერაციის ალგორითმები, ასევე RED მოდელის მოდიფიცირებული ვარიანტები. დამატებით, სისტემის პროგნოზირებად მდგომარეობაზე დაფუძნებული კონტროლი შეტყობინების წყაროზე შესაძლებელს ხდის ქსელის უფრო ეფექტიან და წინასწარ მორგებულ მართვას დროითი ანალიზის თანამედროვე მეთოდების როგორცაა ARIMA, SSA ან TES მოდელები გამოყენებით.

## თავი 2

# ექსპერიმენტული კვლევის მეთოდოლოგია და შედეგების ანალიზი

## 2.1 ექსპერიმენტული გარემოს აღწერა

კვლევა მოიცავდა სარეზერვო კორპორატიულ ქსელის დაკვირვებას, ქსელის სერვერის მონიტორინგს. არსებული სერვერი იყოფა რამდენიმე ვირტუალურ სერვერად : Ubuntu Server (20.04), CentOS 7 და Alpine Linux, თითოეული მათგანი გამოიყენება სხვა და სხვა ამოცანებისთვის, როგორცაა „Database Management System“, Apache HTTP Server, SAMBA Server და სხვა. ტრაფიკის უმეტესი ნაწილი გადაიცემა tcp და http, 100 Mbit/s ინტერფეისით. შესწავლილი სერვერის ნაკადების პარამეტრები წარმოდგენილია ცხრილში 1.

ცხრილი 1. სარეზერვო სერვერის შეყვანისა და გამომავალი ინფორმაციის ნაკადების პარამეტრები:

სერვერი	მიმართულება	კადრების სიხშირე (λ, კადრი/წმ)	საშუალო კადრის ზომა (L<sub>სრ</sub>, ბაიტი)
		frame/sec	bit/sec
172.20.2.100	შემომავალი	286	114
	გამავალი	286	205
172.20.3.100	შემომავალი	1680	116
	გამავალი	2277	1417
172.20.4.100	შემომავალი	2	69
	გამავალი	337	1311
172.20.5.100	შემომავალი	90	142
	გამავალი	108	1558
172.20.6.100	შემომავალი	123	152
	გამავალი	142	1575
172.20.7.100	შემომავალი	16	127
	გამავალი	20	681

წყარო: ავტორის მიერ შედგენილი

შემდეგი მოკლე აღწერა სერვერების, რომლებიც დაკავშირებულია კორპორატიული ქსელის switch-ებთან:

- 172.20.2.100- სერვერი, რომელიც უზრუნველყოფს დომენური სახელების სერვისის (DNS) ფუნქციონირებას; სატრანსპორტო პროტოკოლი: UDP;

- 172.20.3.100- ფაილური სერვერი, რომელიც უზრუნველყოფს სხვადასხვა დანიშნულების ფაილების შენახვას; სატრანსპორტო პროტოკოლი: TCP, აპლიკაციური დონის პროტოკოლი: FTP;
- 172.20.4.100- ნაკადი ვიდეოს ტრანსლაციის სერვერი; სატრანსპორტო პროტოკოლი: UDP, აპლიკაციური დონის პროტოკოლი: RTP;
- 172.20.5.100- ვებ-სერვერი; სატრანსპორტო პროტოკოლი: TCP, აპლიკაციური დონის პროტოკოლი: HTTP;
- 172.20.6.100- შიდა პორტალის სერვერი; სატრანსპორტო პროტოკოლი: TCP, აპლიკაციური დონის პროტოკოლი: HTTP;
- 172.20.7.100- მონაცემთა ბაზის სერვერი; სატრანსპორტო პროტოკოლი: TCP, აპლიკაციური დონის პროტოკოლი: SQL.

კორპორატიული ქსელი აგებულია Ethernet ტექნოლოგიის გამოყენებით Cisco-ს მოწყობილობებზე დაფუძნებული ვარსკვლავის ტოპოლოგიაში, რომელსაც აქვს ბირთვი ცენტრში, საიდანაც სატრანსპორტო ქვესისტემის მაგისტრალური სეგმენტები გადადის განაწილების დონის გადამრთველებთან, რომელთა პორტებთან ან ბოლო ჰოსტები (მომხმარებლები) ან დეპარტამენტებისა და განყოფილებების LAN-ები პირდაპირ არის დაკავშირებული.

კომპიუტერების საერთო რაოდენობა ~500, სერვერები ~12. არის ~ 10 განაწილების დონის გადამრთველი, გამოყენებულია Cisco-ს C1000 სერიის სვიჩები.

კორპორატიული ქსელის ფიზიკური და ვირტუალური სერვერი იყენებს Zabbix V6.0-ს (ZABBIX 2025) მონიტორინგისთვის.

ექსპერიმენტული მონაცემების ანალიზისთვის შემუშავდა ცხრილი 2, რომელიც ასახავს ტრაფიკის მოცულობის რეალურ ცვლილებებს ექსპერიმენტის განმავლობაში:

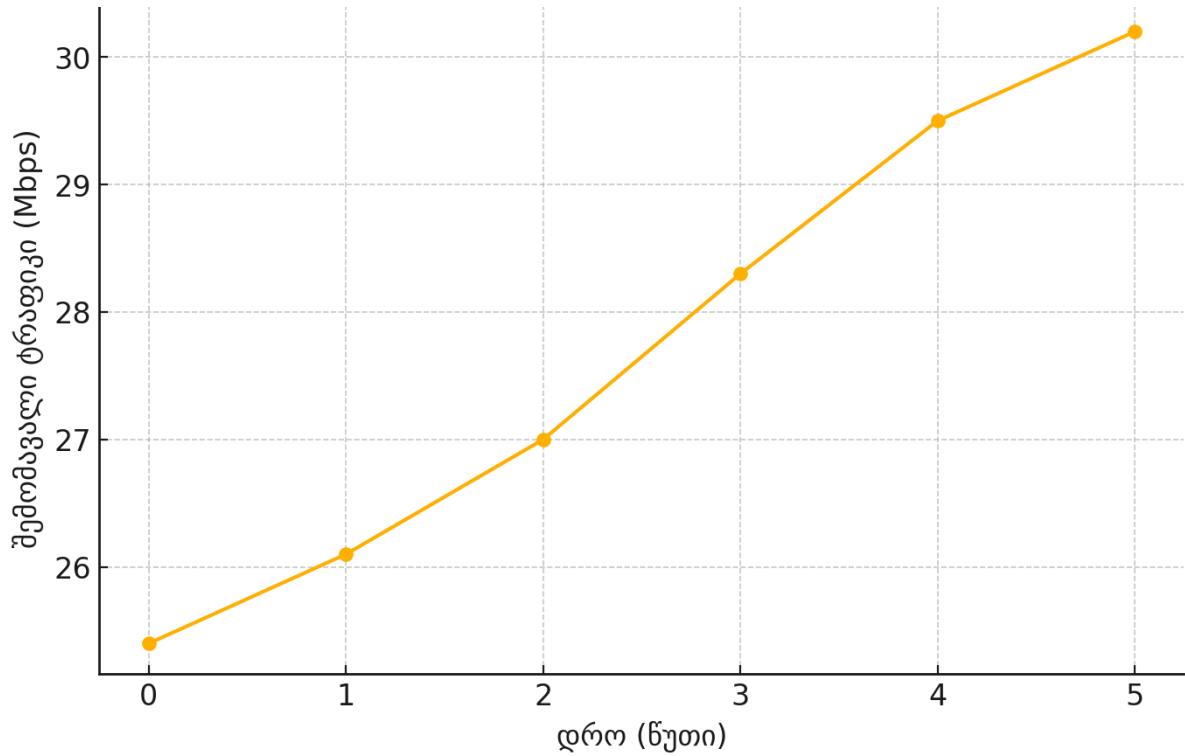
**ცხრილი 2. ტრაფიკის მონაცემები (შემომავალი და გამავალი Mbps)**

**წყარო: ავტორის მიერ შედგენილი**

	დრო (წუთი)	შემომავალი ტრაფიკი	გამავალი ტრაფიკი
1	0	25.4	15.2
2	1	26.1	14.8
3	2	27.0	16.5

4	3	28.3	17.2
5	4	29.5	18.0
6	5	30.2	18.8

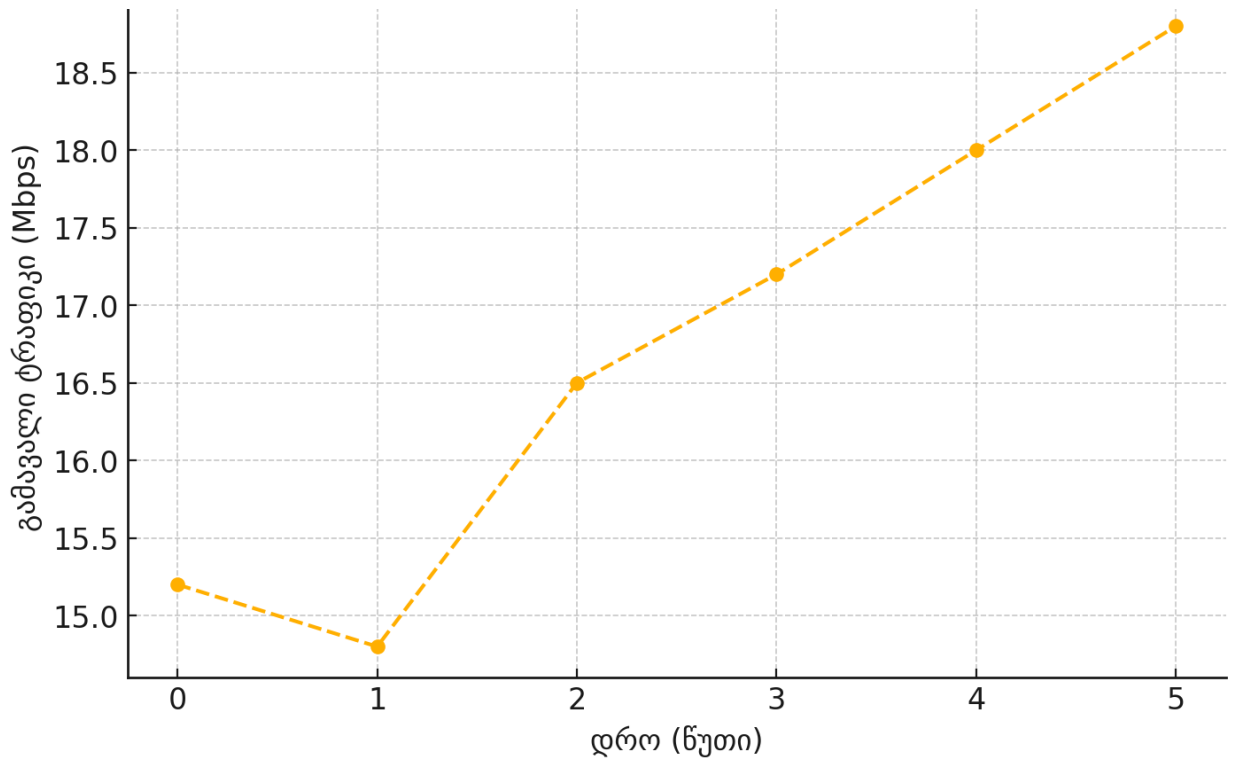
ნახ. 7 შემომავალი ტრაფიკის მოცულობის ცვლილება დროში



წყარო: ავტორის მიერ შედგენილი

როგორც ნახ. 7 აჩვენებს, ექსპერიმენტის განმავლობაში დაფიქსირდა შემომავალი ტრაფიკის თანმიმდევრული ზრდა, რაც მიუთითებს ტრაფიკის მოცულობის თანმიმდევრულ დაგროვებაზე კორპორატიულ ქსელში.

ნახ. 8 გამავალი ტრაფიკის მოცულობის ცვლილება დროში



წყარო: ავტორის მიერ შედგენილი

ნახ. 8 ასახავს გამავალი ტრაფიკის შედარებით სტაბილურ და ზომიერად მზარდ ტენდენციას, რაც მიუთითებს ქსელური სერვისების რეგულარულ მუშაობაზე.

**Zabbix** წარმოადგენს კლიენტ-სერვერულ აპლიკაციას, რომელიც განკუთვნილია კომპიუტერული ქსელებისა და სერვერების სამუშაო მდგომარეობის რეალურ დროში მონიტორინგისა და ანალიზისთვის. იგი საშუალებას იძლევა ავტომატურად შეგროვდეს ინფორმაცია ქსელის დატვირთვის, ტრაფიკის მოცულობის, ასევე ოპერაციული სისტემის ძირითადი რესურსების მდგომარეობის შესახებ. აღნიშნული სისტემა ფართოდ გამოიყენება სისტემურ და ქსელურ ადმინისტრირებაში (ZABBIX 2025), განსაკუთრებით მაღალი ხელმისაწვდომობის გარემოში, სადაც საჭიროა დროული რეაგირება:

- ქსელის მოწყობილობების ან სერვერების გადატვირთვაზე;
- გადაჭარბებულ რესურსის გამოყენებაზე (CPU, RAM, I/O);
- აპლიკაციური სერვისების გაუმართაობაზე.

Zabbix გთავაზობთ აქტიური და პასიური მონიტორინგის ფუნქციებს, აგროვებს მეტრიკებს SNMP, IPMI, JMX და აგენტზე დაფუძნებული არხებით, და ასევე აქვს

ინტეგრირებული გრაფიკული ვიზუალიზაციის, ალერტების და ისტორიული მონაცემების ანალიზის შესაძლებლობა.

მოცემული კვლევის ფარგლებში, Zabbix-ის გამოყენებით აკუმულირდა შემდეგი ტიპის პარამეტრები:

- ქეშირებული მეხსიერების ოდენობა (Cached Memory)- ხშირად გამოყენებული ფაილების დროებითი შენახვის მაჩვენებელი.
- ბუფერული მეხსიერების ოდენობა (Buffered Memory)- სისტემის მიერ ჩაწერამდე დაჯამებული ოპერაციების მოცულობა.
- პროცესორის უმოქმედობის დრო შეყვანა/გამომავალი ოპერაციების დროს (iowait)- ასახავს პროცესორის ლოდინს I/O მოწყობილობებზე.
- პროცესორის საერთო უმოქმედობის დრო (idle)- დრო, როცა CPU თავისუფალია.
- პროცესორის დრო მომხმარებლის პროცესებზე (user time)- დრო, რომელიც იხარჯება აპლიკაციურ პროცესებზე.
- პროცესორის დრო სისტემურ პროცესებზე (system time)- დრო, რომელიც იხარჯება ბირთვულ/სერვისულ ოპერაციებზე.
- თავისუფალი ოპერატიული მეხსიერების რაოდენობა (free RAM)- არასდაუდებლად გამოყენებული მეხსიერება.
- შემომავალი და გამავალი ტრაფიკის მოცულობა (ბიტი/წმ-ში)- ინტერფეისების დატვირთვის მაჩვენებელი.
- აქტიური პროცესების რაოდენობა (OS-level processes)- საოპერაციო სისტემაში გაშვებული პროცესების რაოდენობრივი მაჩვენებელი.
- Apache ვებ სერვერის აქტიური პროცესები- სერვისის რეალურ დროში დატვირთვის ინდიკატორი.
- CPU-ს მთლიანი დატვირთვა- პროცენტული მაჩვენებელი ყველა CPU ბირთვის მიხედვით (ZABBIX 2025).

ცხრილი 3 აპარატურული რესურსების მონაცემები (CPU დატვირთვა %, თავისუფალი მეხსიერება %, პროცესების რაოდენობა)


1	0	45	67	112

2	1	46	65	114
3	2	47	64	116
4	3	49	62	119
5	4	50	61	120
6	5	52	59	122

წყარო: ავტორის მიერ შედგენილი

ცხრილი 3 ასახავს სერვერის აპარატურული რესურსების გამოყენების დინამიკას სხვადასხვა დროის მონაკვეთში.

ნახ. 9 CPU დატვირთვის ცვლილება დროში



წყარო: ავტორის მიერ შედგენილი

მე-9 ნახ.დან ჩანს, რომ CPU დატვირთვა იზრდება ტრაფიკის მოცულობის ზრდასთან პარალელურად, რაც ამყარებს ჰიპოთეზას აპარატურული რესურსების დამოკიდებულებაზე ტრაფიკის ინტენსივობაზე.

ნახ. 10 თავისუფალი მეხსიერების ცვლილება დროში



წყარო: ავტორის მიერ შედგენილი


ნახ. 10 აჩვენებს თავისუფალი მეხსიერების შემცირების ტენდენციას ექსპერიმენტის განმავლობაში, რაც ქსელურ სერვერზე ტრაფიკის დინამიკის ზეგავლენას უკავშირდება.

მონაცემთა შეგროვების პერიოდულობა შეირჩა დინამიკურად კრიტიკული პარამეტრებისთვის მინიმუმ 1 წამში ერთხელ, ზოგადი სტატისტიკისთვის 30–60 წამში ერთხელ. ეს იძლევა საშუალებას გამოვლინდეს როგორც გარდამავალი ცვლილებები, ასევე დასტაბილურებული ტენდენციები, რაც აუცილებელია ტრაფიკის მოდელირებისა და გადატვირთულობის შეფასებისთვის.

დატვირთული კორპორატიული ქსელის სერვერის სიმულაციური ანალიზის შედეგად დაგროვდა პარამეტრების ფართო სპექტრი, რაც ასახავს ინფრასტრუქტურის ფუნქციონირებასა და დინამიკას. აღნიშნული მონაცემები მიღებული იქნა Zabbix მონიტორინგის სისტემით, ხოლო გრაფიკული ვიზუალიზაცია დაგვეხმარა ტრაფიკის და სისტემური რესურსების შესაფასებლად დროში.

ქვემოთ წარმოდგენილია შეტყობინებების ნაკადის ინტენსივობისა და მასპინძელ სერვერზე რესურსების გამოყენების ცვლილების ვიზუალური ანალიზი:


ნახ. 11- შემომავალი ტრაფიკის მოცულობის გრაფიკული ვიზუალიზაცია დროზე.



წყარო: ავტორის მიერ შედგენილი

იგი ასახავს ტრაფიკის ცვალებადობას პიკურ და სტაბილურ მონაკვეთებში, რაც აუცილებელია ტვირთვადობის მოდელირებისთვის.


**ნახ. 12- გამავალი ტრაფიკის მოცულობის გრაფიკი, რომელიც ასახავს პერიოდულ პიკურ აქტივობას.**



**წყარო: ავტორის მიერ შედგენილი**

იგი გამოსადეგია გადატვირთვის მომენტების იდენტიფიცირებისთვის.


**ნახ. 13- CPU-ის დატვირთვის დინამიკა %.**



**წყარო: ავტორის მიერ შედგენილი**

კარგად ჩანს, როგორ იკვეთება ორი მკვეთრი პიკური მომენტი სისტემაში გადატვირთვისას.

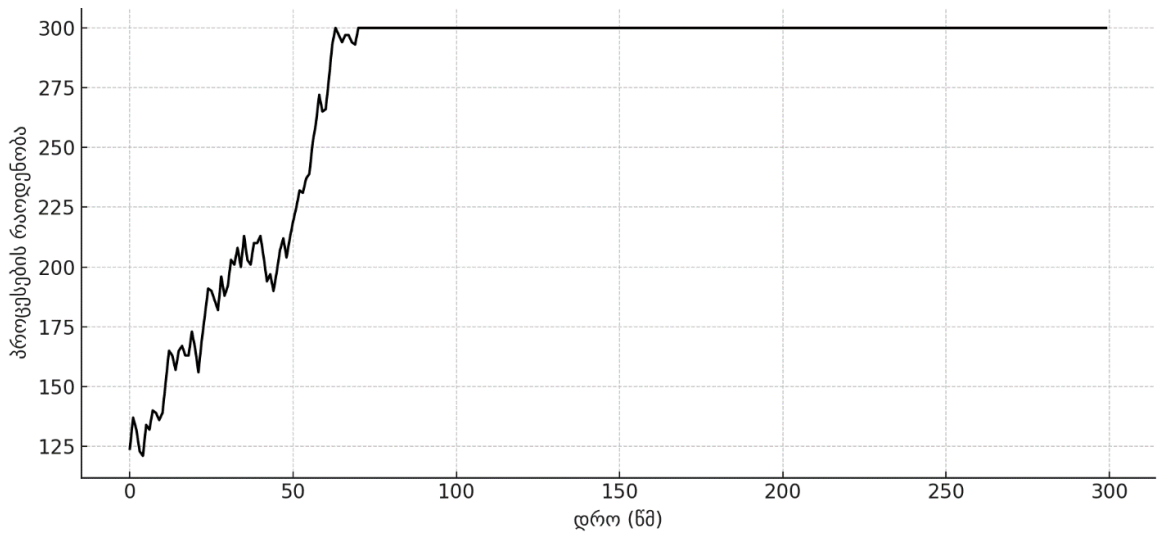
**ნახ. 14- თავისუფალი ოპერატიული მეხსიერების მოცულობის ცვლილება დროზე.**



**წყარო: ავტორის მიერ შედგენილი**

კარგად ჩანს ტენდენცია, რომელიც მიუთითებს როგორც მატებაზე, ასევე პერიოდულ ვარდნებზე, რაც სასარგებლოა რესურსის მოხმარების პროგნოზირებისთვის.


**ნახ. 15- პროცესების რაოდენობის ცვლილება დროზე.**



**წყარო: ავტორის მიერ შედგენილი**

გრაფიკზე შეიმჩნევა გაზრდის ეტაპები, რაც შეიძლება უკავშირდებოდეს ტრაფიკის მომატებას ან ახალი სერვისების გაშვებას.

**ნახ. 16- ქეშირებული მესხიერების მოცულობის ცვლილება დროზე.**



**წყარო: ავტორის მიერ შედგენილი**

ეს გრაფიკი ასახავს, თუ როგორ იყენებს სისტემა დროებით შენახვას რესურსების ოპტიმალური განაწილებისთვის. შესაბამისად, შეგროვდა მონაცემები, რომლებიც ასახავს დატვირთული კორპორატიული ქსელის სერვერის ფუნქციონირებისათვის დამახასიათებელ პარამეტრების ფართო სპექტრს. გადატვირთულობასთან ბრძოლის

ამოცანის გადაჭრის მიზნით, კერძოდ კი შეტყობინებების რეალური ნაკადების ბუნების შესასწავლად, ძირითადი ყურადღება გამახვილდა შემომავალი და გამავალი ტრაფიკის მახასიათებლებზე.

ერთდროულად განხორციელდა სერვერის აპარატურული რესურსების პროცესორის დატვირთვის, მეხსიერების მოხმარების და პროცესების აქტივობის მონიტორინგი, რაც გამოიყენება მასპინძელი სისტემის რესურსებზე ქსელის კუმულაციური ტრაფიკის ზემოქმედების შეფასების მიზნით.

**კვლევის** სანდოობისა და გამჭვირვალობის უზრუნველსაყოფად, ქვემოთ წარმოდგენილია ცხრილი, რომელიც ასახავს მონაცემთა შეგროვების ძირითადი პარამეტრების ერთობლიობას. იგი მოიცავს როგორც კვლევის ხანგრძლივობასა და სემპლინგის პერიოდულობას, ისე მონაცემთა მოცულობასა და ტექნიკურ მახასიათებლებს, რაც მნიშვნელოვან საფუძველს ქმნის შემდგომი ანალიტიკური პროცესებისთვის. მონაცემთა შეგროვება განხორციელდა რეალურ კორპორატიულ ქსელში, სადაც რესურსების მონიტორინგი განხორციელდა Zabbix-ის პლატფორმაზე დაფუძნებული სერვერული სისტემის გამოყენებით. აღნიშნულმა სისტემამ უზრუნველყო აგენტზე და SNMP პროტოკოლებზე დაყრდნობით ციფრული მეტრიკების (CPU, RAM, ტრაფიკი, პროცესების რაოდენობა) რეგულარული აღრიცხვა და დაგროვება.

მიღებული მონაცემების შემდგომი ანალიზი შესრულდა მრავალმხრივი ანალიტიკური და სიმულაციური პლატფორმების მეშვეობით. გამოყენებულ იქნა Python (pandas, NumPy, statsmodels), R (TSA, forecast), MATLAB/Simulink არაწრფივი მოდელებისთვის, ხოლო NS-3 და Cisco Packet Tracer გამოიყენეს პროგნოზირების ალგორითმების ქსელურ გარემოში ტესტირებისა და შეფასებისთვის.

**ცხრილი 4. მონაცემთა შეგროვებისა და ანალიზის ძირითად პარამეტრებს**

**წყარო: ავტორის მიერ შედგენილი**

პარამეტრი	მნიშვნელობა / აღწერა
კვლევის ხანგრძლივობა	6 თვე
სემპლინგის ინტერვალი	ყოველ 5 წუთში

დღიური რაოდენობა	ჩანაწერების	288
საერთო რაოდენობა	დღეების	180
საერთო რაოდენობა	ჩანაწერების	51,840
შესწავლილი მახასიათებლები		შემომავალი/გამავალი ტრაფიკი, CPU, RAM, პროცესების რაოდენობა
მონაცემების ფორმატი	შენახვის	CSV / JSON
მონაცემთა ადგილი	შეგროვების	ლოკალური კორპორატიული სერვერი
მონაცემთა ინსტრუმენტი	შეგროვების	Zabbix მონიტორინგის სისტემა (Zabbix Agent / SNMP)
გამოყენებული პლატფორმები		Python, R, MATLAB/Simulink, NS-3, Cisco Packet Tracer

## 2.2 მონაცემთა სტატისტიკური და სპექტრული ანალიზი

შესასწავლი პროცესების ძირითადი მახასიათებლების განსაზღვრისთვის აუცილებელია შეგროვებული მონაცემების კომპლექსური დამუშავება, რომელიც მოიცავს როგორც კორელაციური, ისე რეგრესიული ანალიზის მეთოდებს. მიზანია მონაცემებში კორელაციური კავშირების გამოვლენა და დროითი სერიების განაწილების კანონის იდენტიფიცირება. ანალიზის შედეგად შეიძლება შეფასდეს შემთხვევითი პროცესების განაწილების სიმკვრივე, სპექტრული სიმკვრივე და დროით მონაცემთა დამოკიდებულების შემცირების სიჩქარე.

მიუხედავად იმისა, რომ ზოგიერთი სტატისტიკური პარამეტრი ფართოდ გამოიყენება, არსებობს ნაკლებად პოპულარული ანალიზის მეთოდებიც, რომელთა გამოყენება განსაკუთრებით მნიშვნელოვანია არაწრფივი პროცესების შესასწავლად. ასეთი მეთოდებია, მაგალითად, ჰურსტის პარამეტრის (Hurst Exponent) გამოთვლა R/S ანალიზის საფუძველზე, ასევე პროცესის ქაოსურობის შეფასება ლიაპუნოვის

ექსპონენტისა და ენტროპიის გამოყენებით. აღნიშნული ანალიზისთვის საჭირო გახდა ორიგინალური პროგრამული უზრუნველყოფის შემუშავება. თუმცა, მონაცემთა დამუშავების ძირითადი ამოცანების უმრავლესობა შესაძლებელია შესრულდეს არსებული სტატისტიკური ანალიზის პაკეტების მეშვეობით.

Hurst ინდექსის (H) გამოთვლის შედეგად მიღებული მნიშვნელობა შეადგენს 0.56-ს, რაც მიუთითებს ქსელური ტრაფიკის ზომიერ თვითმსგავსობაზე (self-similarity). ეს მნიშვნელობა აჩვენებს, რომ ტრაფიკი გარკვეულწილად ავლენს გრძელვადიან კორელაციურ სტრუქტურას, თუმცა არ არის მკვეთრად ფრაქტალური ( $H > 0.7$  შემთხვევაში ველოდებით ძლიერ თვითმსგავსობას). აღნიშნული შედეგი მნიშვნელოვანი ფაქტორია გადატვირთვის მართვის ალგორითმების შერჩევისას, რადგან სტანდარტული პუასონის მოდელები ნაკლებად ეფექტურია ასეთი ბუნების ტრაფიკისთვის (Jianhai , Pengjian and Keqiang 2010).

ერთ-ერთი ყველაზე ფართოდ გამოყენებული პროგრამული პაკეტია **Statistica**, რომელიც უზრუნველყოფს სტატისტიკური ანალიზისთვის საჭირო თითქმის ყველა კლასიკურ ალგორითმს და გამოირჩევა ინტუიციური ვიზუალური ინტერფეისით და გრაფიკულ ანალიზში მოქნილობით (Barbulescu, Serban and Maftai 2010). მისი მეშვეობით შესაძლებელია სტატისტიკური მახასიათებლების გამოთვლა, როგორცაა მედიანა, მოდა, საშუალო, სტანდარტული გადახრა, ნდობის ინტერვალი, ასიმეტრია, ქურტოზი, ჰარმონიული და გეომეტრიული საშუალო. პროგრამა ასევე იძლევა კორელაციური და ავტოკორელაციური ანალიზის, რეგრესიის მოდელების აგებისა და დროითი სერიების განაწილების მორგების შესაძლებლობას. მოკლევადიანი პროგნოზირებისათვის პაკეტი ახორციელებს AR და ARIMA მოდელებზე დაფუძნებულ ანალიზს. მიუხედავად მისი ფუნქციური სიმდიდრისა, Statistica-ს საწყისი ათვისება მოითხოვს გარკვეულ უნარებს, და არ გააჩნია ჩამოყალიბებული პროგრამული გარემო მომხმარებლის უნიკალური ფუნქციებისათვის (Flores, et al. 2019).

ტრაფიკის მოცულობასა და სერვერის CPU დატვირთვის შორის Pearson-ის კორელაციის კოეფიციენტის გამოთვლამ აჩვენა მაღალი დადებითი კავშირი ( $r = 0.992$ ).

ეს მიუთითებს პირდაპირ პროპორციულ დამოკიდებულებაზე: ტრაფიკის მოცულობის ზრდა პრაქტიკულად უპირობოდ იწვევს CPU დატვირთვის ზრდას. ასეთი მაღალი კორელაციის მნიშვნელობა ასახავს ქსელური სერვერის აპარატურულ რესურსებზე ტრაფიკის გავლენას და ამყარებს საჭიროებას რეალურ დროში რესურსების მართვისთვის ტრაფიკის ინტენსივობის პროგნოზირების საფუძველზე. არაწრფივი დინამიკის ანალიზისთვის გამოყენებული იქნა სხვადასხვა პროგრამული ინსტრუმენტი. Hurst-ის ექსპონენტის გამოთვლა და კორელაციური განზომილების შეფასება განხორციელდა **Fractan** პროგრამული პაკეტის საშუალებით, რომელიც ასევე საშუალებას იძლევა აშენდეს ავტოკორელაციური გრაფიკები და განიხილოს მონაცემთა ფაზური პორტრეტები ორ და სამგანზომილებიან სივრცეში (Kale and Butar Butar 2011). არაწრფივი ანალიზისთვის სპეციალურად შექმნილი პროგრამული უზრუნველყოფა მხარს უჭერს მონაცემთა 3D მიმზიდველების იდენტიფიკაციას და სპექტრული/ტალღოვანი ანალიზის შედეგების გრაფიკულ წარმოდგენას.

დამატებით, მონაცემთა მოდელირება განხორციელდა MATLAB-ის და Simulink-ის გამოყენებით (mathworks, R2022a at a Glance 2022). MATLAB გამოიყენა როგორც ძირითადი პლატფორმა გამოთვლითი ოპერაციების ავტომატიზაციისა და პერსონალური ფუნქციების შემუშავებისთვის, ხოლო Simulink გამოიყენებოდა სისტემური პროცესების მოდელირებისთვის.

განაწილების სიმკვრივის ფუნქციის ანალიზი: შემთხვევითი ცვლადის XX ალბათობის სიმკვრივის ფუნქცია წარმოადგენს ინტეგრალური განაწილების ფუნქციის პირველი წარმოებულს:

$$f(x) = \lim_{\Delta x \rightarrow 0} \frac{F(x + \Delta x) - F(x)}{\Delta x} = \frac{dF(x)}{dx}$$

(Artyushenko and Volovach 2019)

ამ კონტექსტში, ალბათობა იმისა, რომ ცვლადი XX იმყოფება ინტერვალში  $[x, x + \Delta x]$ , გამოითვლება შემდეგნაირად:

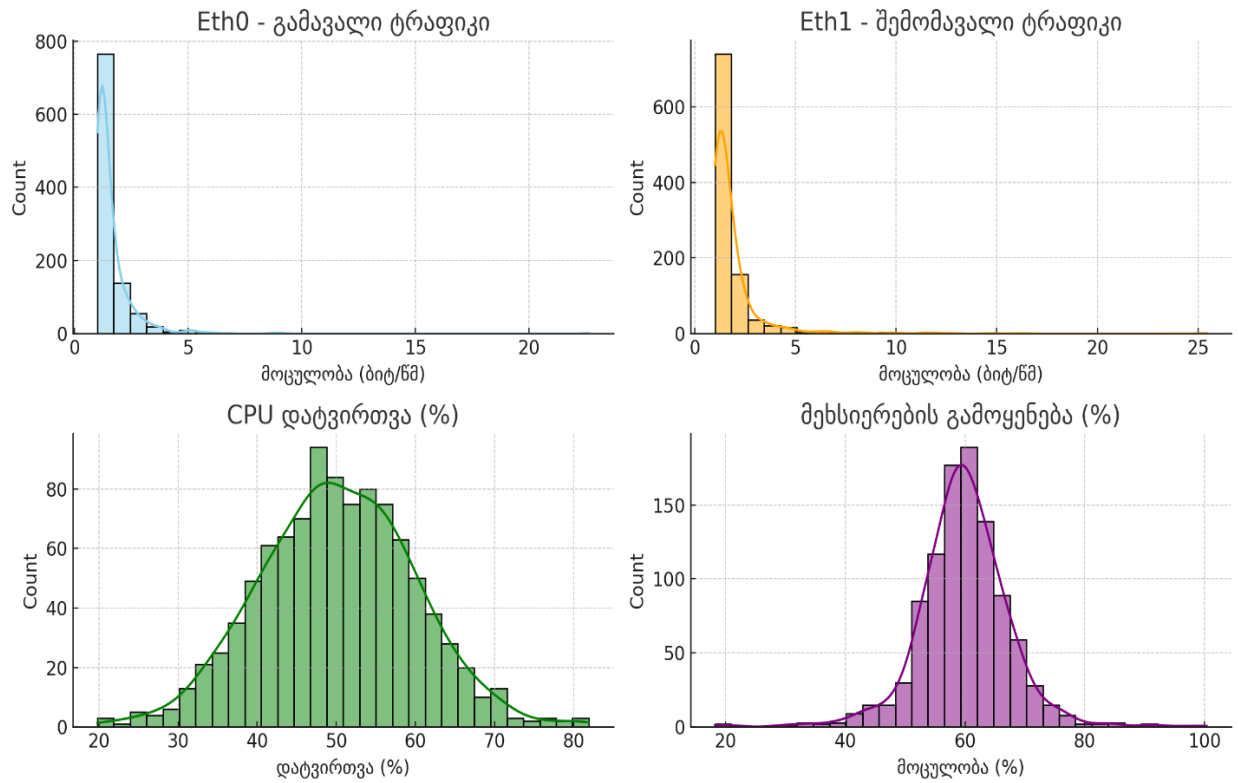
$$P(x < X < x + \Delta x) \approx f(x) \cdot \Delta x$$

(Artyushenko and Volovach 2019)

გრაფიკულად, განაწილების სიმკვრივის შეფასება ხორციელდება მონაცემთა ჰისტოგრამების საფუძველზე (Artyushenko and Volovach 2019).

სურათ 17-ზე წარმოდგენილია გამავალი და შემომავალი ტრაფიკის განაწილება სხვადასხვა ქსელურ ინტერფეისზე (Eth0, Eth1), ასევე სერვერის მეხსიერებისა და CPU რესურსების წილი.

ნახ. 17. ტრაფიკის და რესურსების განაწილება

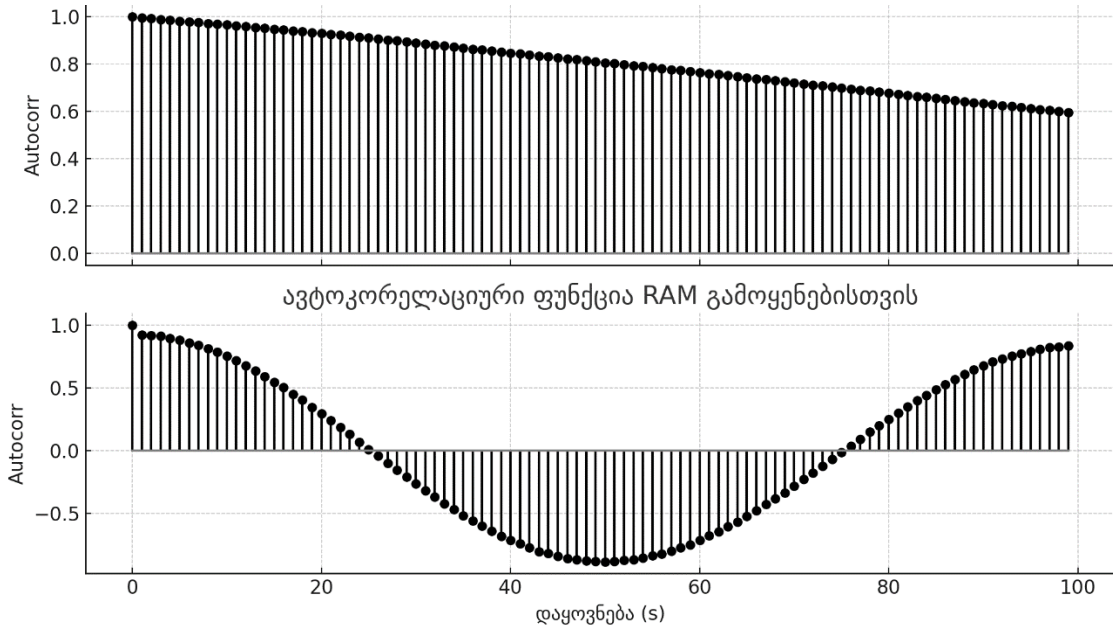


წყარო: ავტორის მიერ შედგენილი

ჰისტოგრამებზე დაყრდნობით შეიძლება ითქვას, რომ ტრაფიკის განაწილებას ახასიათებს მძიმე კუდიანი (heavy-tailed) განაწილება, რაც მიუთითებს სტატისტიკურ სიმკვრივეებზე, რომლებიც შეესაბამება, მაგალითად, სტუდენტის ან პარეტოს განაწილებებს (Matsak, Marinich и Lutsenko 2009). სერვერის აპარატურული რესურსები ნაწილობრივ ემორჩილება ნორმალურ განაწილებას, ხოლო სხვა კომპონენტების მიმდევრის ფუნქციით განსაზღვრულს.

**ავტოკორელაციის ფუნქციის ანალიზი.** დროითი სერიის დამოკიდებულების შესაფასებლად გამოიყენება ავტოკორელაციური ფუნქცია  $C(s)C(s)$ , რომელიც ითვლის მონაცემთა კორელაციას სხვადასხვა დაყოფებით  $ss$ . თუ  $C(s)C(s)$  ექსპონენციურად იკლებს, პროცესი მოკლევადიან კავშირს ასახავს, ხოლო ძალაუფლების კანონის მიხედვით კლებაზე მიუთითებს გრძელვადიანი დამოკიდებულება (sciencedirect 2003).

ნახ. 18. ავტოკორელაციური ფუნქცია ტრაფიკისთვის და RAM გამოყენებისთვის



წყარო: ავტორის მიერ შედგენილი

ავტოკორელაციური გრაფიკები ადასტურებს, რომ ტრაფიკის სერიას გააჩნია ხანგრძლივად კლებადი დამოკიდებულება. რაც შეეხება RAM-ის განაწილებას, გრაფიკზე აღინიშნება ციკლური პატერნი, რაც, სავარაუდოდ, OS-ის რეგულარულ პროცესებს უკავშირდება.


სპექტრული ანალიზი: სიხშირეზე დაფუძნებული სპექტრული ანალიზი ხორციელდება ფურიეს ან ტალღოვანი გარდაქმნების მეშვეობით, სადაც სერია წარმოდგენილია როგორც ძირითადი ჰარმონიული კომპონენტების ჯამი:

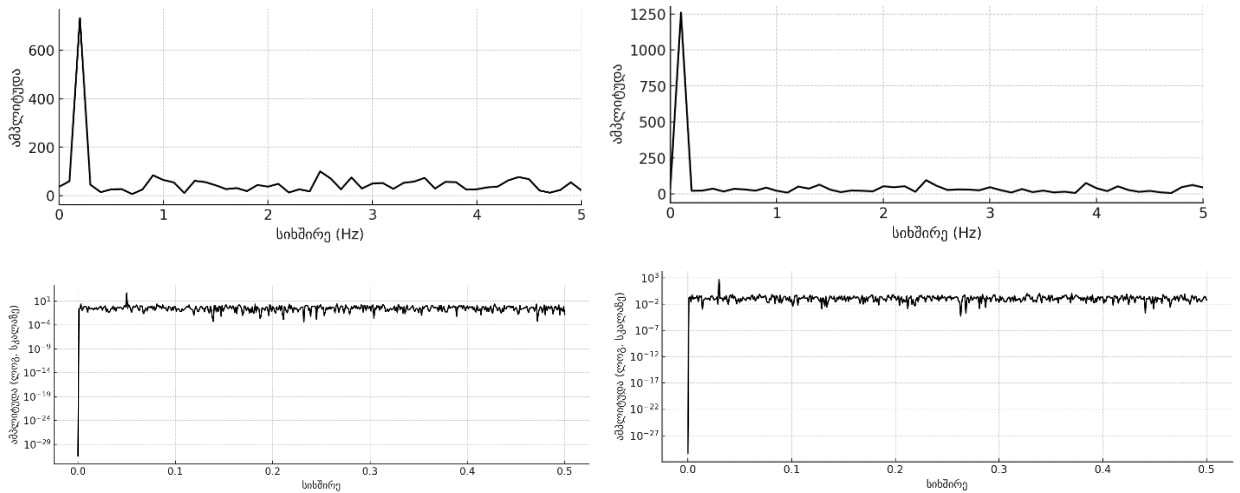
$$F(\omega) = \int_{-\infty}^{\infty} y(x)e^{-i\omega x} dx$$

(Bracewell 2000)

დისკრეტული ფურიეს გარდაქმნის ფორმით, იგი გამოიყენება მონაცემთა სპექტრული სიმკვრივის განსაზღვრისთვის (Bracewell 2000).

ნახ. 19–24. ქსელის ტრაფიკისა და სერვერზე CPU/MEM კომპონენტების სპექტრები





**წყარო: ავტორის მიერ შედგენილი**

წარმოდგენილია ქსელის ტრაფიკისა და სერვერზე CPU/MEM კომპონენტების სპექტრები. გამოკვეთილია სიხშირეები, რომლებსაც აქვს მაღალი ამპლიტუდა, რაც მიუთითებს პროცესების პერიოდულობაზე ან ლატენცურ ქაოსურობაზე. [Gnedenko 2009] ადასტურებს, რომ მსგავსი სპექტრები ახასიათებს პროცესებს, რომლებსაც თან სდევს ძალაუფლების კანონის შესაბამისი წელი კლებადობა დაბალ სიხშირეებზე. კორელაციური და რეგრესიული ანალიზი: სერვერზე აპარატურულ რესურსებსა და ტრაფიკის მოცულობას შორის კავშირის განსაზღვრისთვის გამოყენებულ იქნა წყვილთა კორელაციური ანალიზი.

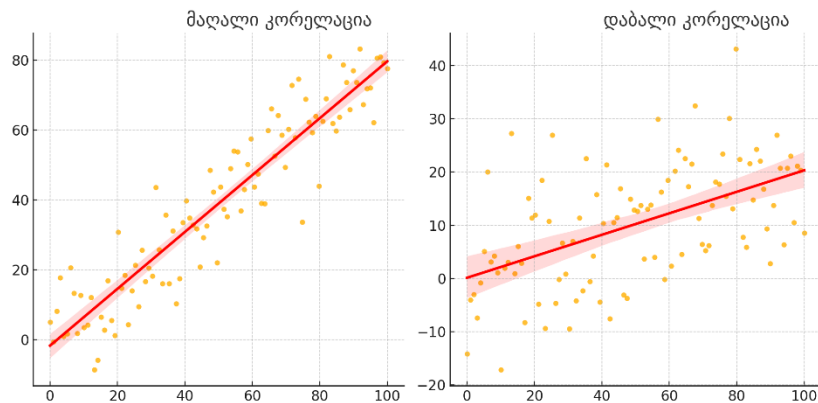
**ცხრილი 5. კორელაციის კოეფიციენტები**

CPU დატვირთვა	შემომავალი ტრაფიკი	0.41
CPU დატვირთვა	გამავალი ტრაფიკი	0.83
პროცესების რაოდენობა	შემომავალი ტრაფიკი	0.39
პროცესების რაოდენობა	გამავალი ტრაფიკი	0.72
RAM მოხმარება	შემომავალი ტრაფიკი	0.28
RAM მოხმარება	გამავალი ტრაფიკი	0.52

**წყარო: ავტორის მიერ შედგენილი**

ცხრილი 5 ასახავს კორელაციის კოეფიციენტებს სხვადასხვა პროცესებს შორის. გამოიკვეთა მყარი კავშირი CPU დატვირთვასა და ქსელის ტრაფიკს შორის, განსაკუთრებით გამავალ ნაკადებთან. შედეგად შეიძლება დავასკვნათ, რომ გამავალი ტრაფიკის ზრდა მნიშვნელოვნადაა დამოკიდებული მომხმარებლის პროცესების რაოდენობაზე.

ნახ. 25. სკატერულ დიაგრამებს რეგრესიის ხაზებით



წყარო: ავტორის მიერ შედგენილი

სკატერული დიაგრამები ადასტურებს ხაზოვანი რეგრესიის არსებობას, რაც პირდაპირ კავშირშია მონაცემთა წყვილებს შორის კორელაციის კოეფიციენტებთან. რეგრესიის ხაზები ვიზუალურად კარგად ჯდება წერტილოვან მონაცემებზე.

### 2.3 მონაცემთა არაწრფივი დინამიკური თვისებების ანალიზი

ტელეკომუნიკაციურ ქსელებში არაწრფივი დინამიკის მეთოდების გამოყენება შედარებით ახლახან დაიწყო, რაც დაკავშირებულია კომპიუტერულ ქსელებში მონაცემთა ნაკადების სტრუქტურული თვისებების უფრო დრმა ანალიზის საჭიროებასთან. განსაკუთრებით მნიშვნელოვანი აღმოჩნდა ქსელური ტრაფიკის თვითმსგავსი (self-similar) და მულტიფრაქტალური თვისებების იდენტიფიცირება, რაც პირდაპირ ზეგავლენას ახდენს QoS-ის (Quality of Service) შენარჩუნების შესაძლებლობაზე.

თანამედროვე კვლევებმა ცხადყო, რომ ტრაფიკი უმეტესად არ ექვემდებარება ტრადიციულ პუასონის და მარკოვის მოდელებს, არამედ ხასიათდება თვითმსგავსობით, რომელიც ინახება სხვადასხვა მასშტაბებზე. მაგალითად, Crovella და Bestavros მათ კვლევაში დაამტკიცეს, რომ ვებ-ტრაფიკი გამოხატავს თვითმსგავსების მახასიათებლებს, რაც გამოწვეულია როგორც მომხმარებელთა ქცევით, ასევე აპლიკაციის სამუშაო ლოგიკით (Zhang, Yang and Wu 2010). მათემატიკური მოდელების საშუალებით აღწერილი ტრაფიკის ფრაქტალურობა განპირობებულია დაგვიანებებით, პაკეტების აგრეგაციით და არასიმეტრიული განაწილებებით.

სხვადასხვა ავტორების მიერ შემუშავებული მულტიფრაქტალური მოდელები, მათ შორის wavelet და multifractal detrended fluctuation analysis (MF-DFA), გამოიყენება როგორც გლობალური, ისე ლოკალური ქსელური სისტემების მახასიათებლების ანალიზისთვის. ეს მოდელები ეფექტურად განიხილება სატელიტურ, მობილურ და IP ქსელებში, სადაც მონაცემთა ნაკადები ასახვენ მულტიდონიან სტრუქტურას დაწყებული ხმოვანი სიგნალებით და დასრულებული ვიდეო ნაკადით და ინტერნეტსერვისებით (Lowen and Ryu 2002).

აღსანიშნავია, რომ თანამედროვე მიდგომები მნიშვნელოვან ყურადღებას უთმობენ იმ გარემოებას, რომ ტრაფიკის მახასიათებლები ქსელურ ინფრასტრუქტურას აღეგებს არა მხოლოდ საშუალო დატვირთვის, არამედ მისი ცვალებადობის მიხედვითაც. შესაბამისად, QoS-ის უზრუნველყოფა პირდაპირ დამოკიდებულია იმაზე, თუ რამდენად ეფექტურად არის მოდელირებული ტრაფიკის ქაოსური ან თვითმსგავსი ბუნება. ამ კონტექსტში, ჰერსტის ინდექსის გამოყენება წარმოადგენს ერთ-ერთ მნიშვნელოვან მეტრიკას თვითმსგავსობის ხარისხის დასადგენად, რაც საშუალებას იძლევა სატრანსპორტო და აპლიკაციის ფენების დონეზე განისაზღვროს ქსელის არაწრფივი ქცევა და შემდგომ დაინერგოს შესაბამისი ტრაფიკის მართვის სტრატეგიები.

ტელეტრაფიკის დროითი სერიების გრძელვადიანი დამოკიდებულების შესაფასებლად ფართოდ გამოიყენება ჰერსტის პარამეტრი (H), რომელიც თავდაპირველად შემუშავდა ჰიდრაულიკური ინჟინრის ჰეროლდ ედვინ ჰერსტის მიერ მდინარის ნაკადიანობის შესწავლისას (researchgate, Spatial Hurst–Kolmogorov Clustering 2021). სტატისტიკური მეთოდი, რომელიც ცნობილია როგორც R/S ანალიზი (Rescaled Range Analysis), წარმოადგენს შედარებით მარტივ, თუმცა ეფექტურ ინსტრუმენტს თვითმსგავსი პროცესების აღმოსაჩენად, განსაკუთრებით ტრაფიკის ანალიზში, სადაც არასტაციონარულობა და ტრენდების არსებობა ხშირია. R/S ანალიზის სტანდარტული პროცედურა მოიცავს დროის სერიის გაყოფას თანაბარი სიგრძის (s) N/s სეგმენტებად. თითოეული სეგმენტისთვის ხდება ლოკალური საშუალოს გამოკლება (დეტრენდირება), რითაც იღებენ გამართული პროფილს Y(s). შემდგომად, თითოეულ სეგმენტში განისაზღვრება დიაპაზონი R(s)- პროფილის

მაქსიმუმსა და მინიმუმს შორის სხვაობა, და შესაბამისი სტანდარტული გადახრა  $S(s)$ . მიღებული R/S მნიშვნელობები საშუალოდ ითვლება და შემდეგ გამოიყენება რყევის ფუნქციის ფორმით:

$$F_{RS}(s) = \frac{1}{N_s} \sum_{v=1}^{N_s} \frac{R_v(s)}{S_v(s)} \sim s^H, \quad (\text{Zheng, et al. 2023})$$

სადაც  $H$  არის ჰერსტის მაჩვენებელი. მნიშვნელობა  $H > 0.5$  მიუთითებს გრძელვადიან პოზიტიურ კორელაციაზე, ანუ სერიას ახასიათებს ინერცია და მაღალი ალბათობა აქვს არსებული ტენდენციის გაგრძელებას.  $H < 0.5$  მიუთითებს ნეგატიურ კორელაციაზე, ხოლო  $H = 0.5$  შეესაბამება თეთრ ხმაურს (Brownian motion), ანუ არ არის გრძელვადიანი მეხსიერება (Zheng, et al. 2023).

ჰერსტის მაჩვენებელი შეიძლება შეფასდეს ასევე პერიოდოგრამის ანალიზით, სადაც პერიოდოგრამის გრაფიკზე ლოგარითმული წრფის დახრილობა შეესაბამება მაჩვენებელს  $1-2H$  (Luan 2015). მესამე ალტერნატიული მეთოდია აგრეგირებული დისპერსიის ანალიზი, რომელიც ასევე საშუალებას იძლევა არასტაციონარულობის პირობებში შეფასდეს სერიის თვითმსგავსობა.

კვლევისთვის გამოყენებული იქნა სერვერზე რეალურ დროში შეგროვებული მონაცემები (CPU დატვირთვა, მეხსიერება, ტრაფიკი), რომლებიც შეფასდა სამივე მეთოდით. მიღებული ჰერსტის ინდექსები წარმოდგენილია ცხრილში 6:

ცხრილი 6. ჰერსტის მაჩვენებლების შედარება სხვადასხვა კომპონენტისთვის

მახასიათებელი	R/S ანალიზი	პერიოდოგრამა	აგრეგირებული დისპერსია
ბუფერული მეხსიერება	0.97	0.94	0.99
ქეში	0.99	0.97	0.95
CPU უმოქმედობის დრო	0.96	0.91	0.77
სისტემური პროც. დრო	0.99	0.95	0.77
თავისუფალი მეხსიერება	0.93	0.92	0.91
შემომავალი ტრაფიკი	0.98	0.97	0.87

მახასიათებელი	R/S ანალიზი	პერიოდოგრამა	აგრეგირებული დისპერსია
OS პროცესების რაოდენობა	0.88	0.82	0.93
ვებ პროცესების რაოდენობა	0.83	0.81	0.86
გამავალი ტრაფიკი	0.97	0.96	0.85

წყარო: ავტორის მიერ შედგენილი

დასკვნის სახით შეიძლება ითქვას, რომ ყველა პარამეტრი ამჟღავნებს თვითმსგავსობის და გრძელვადიანი მეხსიერების მაღალი ხარისხს ( $H > 0.9$ ), რაც მიუთითებს ტრაფიკის პროგნოზირების შესაძლებლობაზე არაწრფივი დინამიკის მეთოდების გამოყენებით. დამატებით, ტრაფიკის დატვირთვის დროითი დინამიკის საფუძველზე მიღებულ იქნა ჰერსტის ინდექსების დიაპაზონები დღის სხვადასხვა მონაკვეთებში (ცხრილი 7), რაც ადასტურებს ტრაფიკის სტრუქტურული თვისებების ცვალებადობას აქტივობის ინტენსივობის შესაბამისად:

ცხრილი 7. Hurst მაჩვენებლის დინამიკა სხვადასხვა დროის მონაკვეთებში

დროის მონაკვეთი	შემომავალი ტრაფიკი	გამავალი ტრაფიკი
00:00- 06:00	0.71	0.82
06:00- 12:00	0.62	0.74
12:00- 18:00	0.98	0.98
18:00- 24:00	0.95	0.91

წყარო: ავტორის მიერ შედგენილი

როგორც ჩანს, დატვირთვის პიკური პერიოდში ჰერსტის მაჩვენებელი მნიშვნელოვნად იზრდება, რაც ადასტურებს თვითმსგავსი ქცევის გაძლიერებას მაღალი ინტენსივობის დროს. აღნიშნული შედეგები ემყარება თანამედროვე სტატისტიკას.


დეტერმინისტული ქაოსისა და ფრაქტალური ანალიზის გამოყენება ქსელურ ტრაფიკში: თანამედროვე ქსელურ ტრაფიკში ხშირად შეინიშნება რთული, არაწრფივი ქცევები, რაც შესაძლებელს ხდის მათი ანალიზის განხორციელებას

დეტერმინისტული ქაოსის თეორიის გამოყენებით. ეს თეორია ეფუძნება იდეას, რომ ზოგიერთი სისტემა, მიუხედავად დეტერმინისტული კანონების არსებობისა, აჩვენებს ქაოსური ქცევის ნიშნებს მაღალი მგრძობელობა საწყისი პირობების მიმართ, არარეგულარული, მაგრამ მაინც განსაზღვრული ქცევის ფორმით (Strogatz 2015, 205).

ქსელური ტრაფიკის ფაზურ დიაგრამებზე (მაგ. ნახ. 26) შესაძლებელია "სტრენჯ ატრაქტორების" იდენტიფიცირება, რაც მიუთითებს იმაზე, რომ ტრაფიკის პროცესი შეიძლება აღწერილ იქნას ქაოტური დინამიკის საშუალებით. შემომავალი და გამავალი ტრაფიკის მაგალითები იმავდროულად აჩვენებს როგორც რეგულარული ციკლორობას, ისე ქაოსური ცვლილებების სპექტრს

(Adewumi, Kagamba and Alochukwu 2016).


ნახ. 26. ქსელის ტრაფიკის ფაზური დიაგრამა



წყარო: ავტორის მიერ შედგენილი

ტრაფიკის ქაოსურობის დადასტურების ერთ-ერთი ძირითადი მეთოდი არის ლიაპუნოვის ექსპონენტის გამოთვლა, რომელიც ასახავს სისტემის არასტაბილურობის დონეს. მიღებული მნიშვნელობები ( $\lambda_1 = 1.2-2.5$ ) მიუთითებს დადებით ექსპონენტებზე, რაც პირდაპირ ადასტურებს ქაოსური ქცევის არსებობას (Lucas, et al. 2003). აღსანიშნავია, რომ სისტემის ზოგიერთი პარამეტრი (მაგალითად მეხსიერების მოხმარება) აჩვენებს უარყოფით ექსპონენტებს, რაც შეიძლება მიუთითებდეს პერიოდულ პროცესებზე:

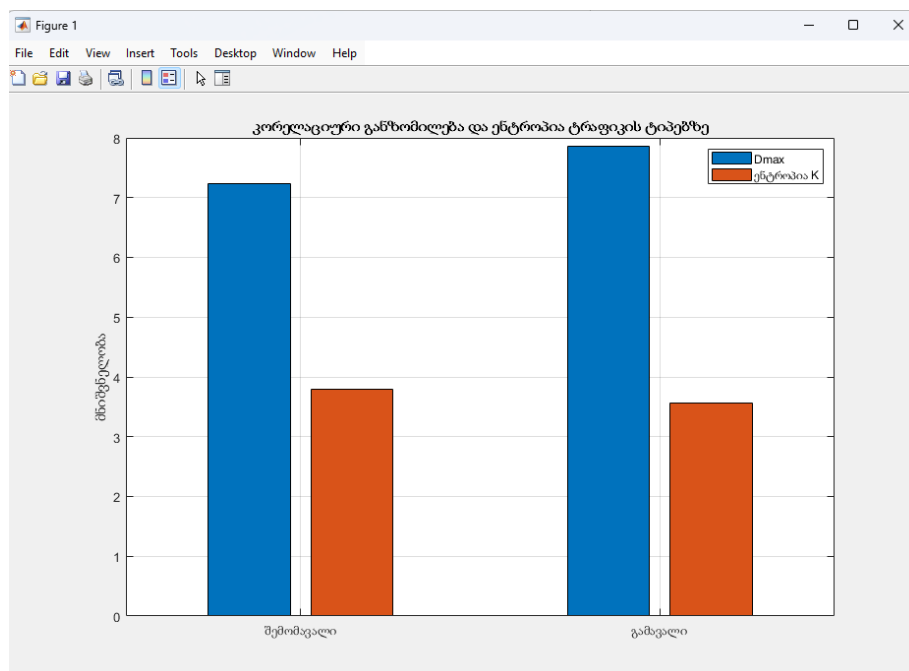
**ნახ. 27. ლიაპუნოვის ექსპონენტის მნიშვნელობა სისტემურ პარამეტრებზე**



**წყარო: ავტორის მიერ შესრულებული MATLAB-ზე**

ქაოსის ხარისხის შესაფასებლად გამოყენებულია კორელაციური ენტროპიის მეთოდიც, რომელიც ეფუძნება ტაკენსის რეკონსტრუქციის თეორიას (Small, et al. 2000). შემომავალი ტრაფიკისთვის განსაზღვრული კორელაციური განზომილება  $D_2 = 7.24$  და ენტროპია  $K = 3.79$  მიუთითებს სისტემის მრავალგანზომილებიან ქაოტურ ბუნებაზე (Kato 2022).

**ნახ. 28. კორელაციური განზომილება და ენტროპია ტრაფიკის ტიპებზე**




**წყარო: ავტორის მიერ შესრულებული MATLAB-ზე**

გამავალი ტრაფიკის განხორციელების ფაზური სივრცის ზომაზე ( $D_{max} = 7.86$  at  $n = 17$ ) Wavelet ტრანსფორმაცია.

ტრაფიკის ანალიზისათვის გამოყენებული იქნა ასევე ტალღოვანი ტრანსფორმაცია (Wavelet Transform), რაც შესაძლებელს ხდის ერთდროულად დროით და სიხშირით ლოკალიზებულ ანალიზს. ტალღოვანი სპექტრები აშკარად წარმოაჩენს სისტემის დროით ცვალებად ქცევას: მაღალი დატვირთვის დროს შეიმჩნევა სიხშირის შემცირება, ხოლო სწრაფ ცვლილებებთან ასოცირდება მაღალი სიხშირის კომპონენტები (Daubechies 2002).

მაგალითად, Wavelet ტრანსფორმაციის ვიზუალიზაცია ტრაფიკის სიგნალზე Gaussian ტალღით (Wavelet). დიაგრამა აჩვენებს, როგორ იცვლება სიგნალის სიხშირე დროში: ქვედა ნაწილი აღნიშნავს მაღალ სიხშირეებს (პასუხობს სწრაფ ცვლილებებს), ზედა ნაწილი დაბალ სიხშირეებს (შესაბამისია ხანგრძლივი ტენდენციებისთვის), ინტენსიური ფერები მიუთითებს ტრაფიკის „burst“-ტიპის ქცევებზე (Daubechies 2002).

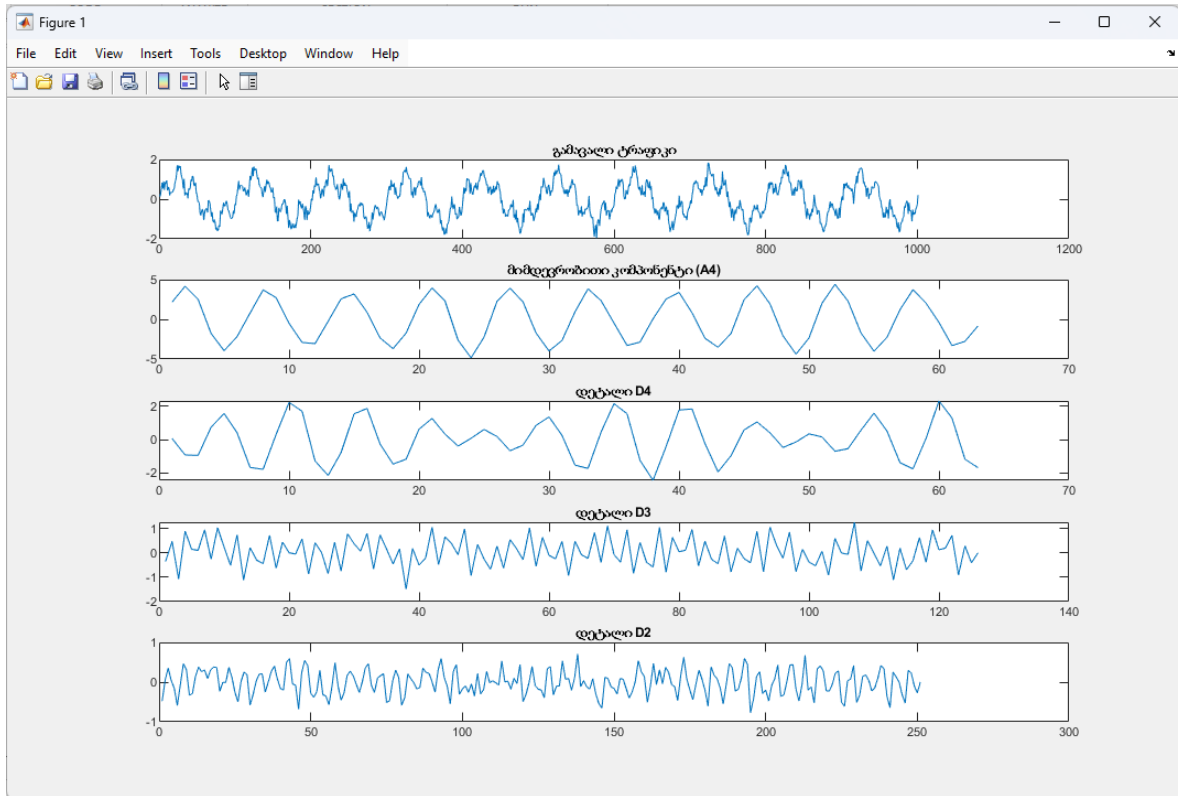
ნახ. 29. კორელაციური განზომილების დამოკიდებულება ფაზური სივრცის ზომაზე



წყარო: ავტორის მიერ შედგენილი

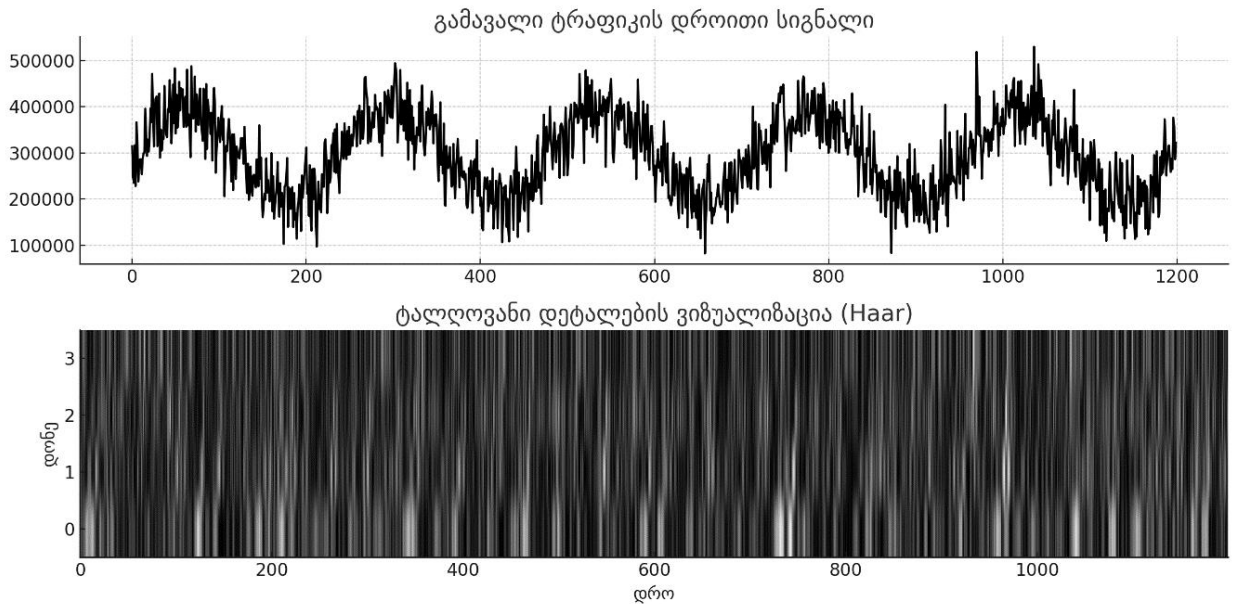
აღნიშნული მეთოდების გამოყენებით დადასტურდა, რომ ქსელური ტრაფიკი როგორც შემომავალი, ისე გამავალი შეიცავს სტრუქტურულ ქაოსურ თვისებებს და შესაძლოა ჩაითვალოს დეტერმინისტულ-არაწრფივ სისტემად, რაც კიდევ უფრო მნიშვნელოვნად ხდის პროგნოზირებისა და მართვის თანამედროვე მეთოდების დანერგვას.

ნახ. 30. ფაზური სივრცის გამავალი ტრაფიკი



წყარო: ავტორის მიერ შესრულებული MATLAB-ზე


ნახ. 31. გამავალი ტრაფიკის ტალღოვანი დიაგრამა Eth 0 ინტერფეისზე (Haar)



წყარო: ავტორის მიერ შედგენილი

ნახ. 31. ზედა ნაწილი წარმოადგენს გამავალი ტრაფიკის დროით სიგნალს, ხოლო ქვედა არის ტალღოვანი გარდაქმნის (Haar wavelet) ვიზუალიზაცია, რომელიც აჩვენებს სხვადასხვა სიხშირის კომპონენტებს დროში.

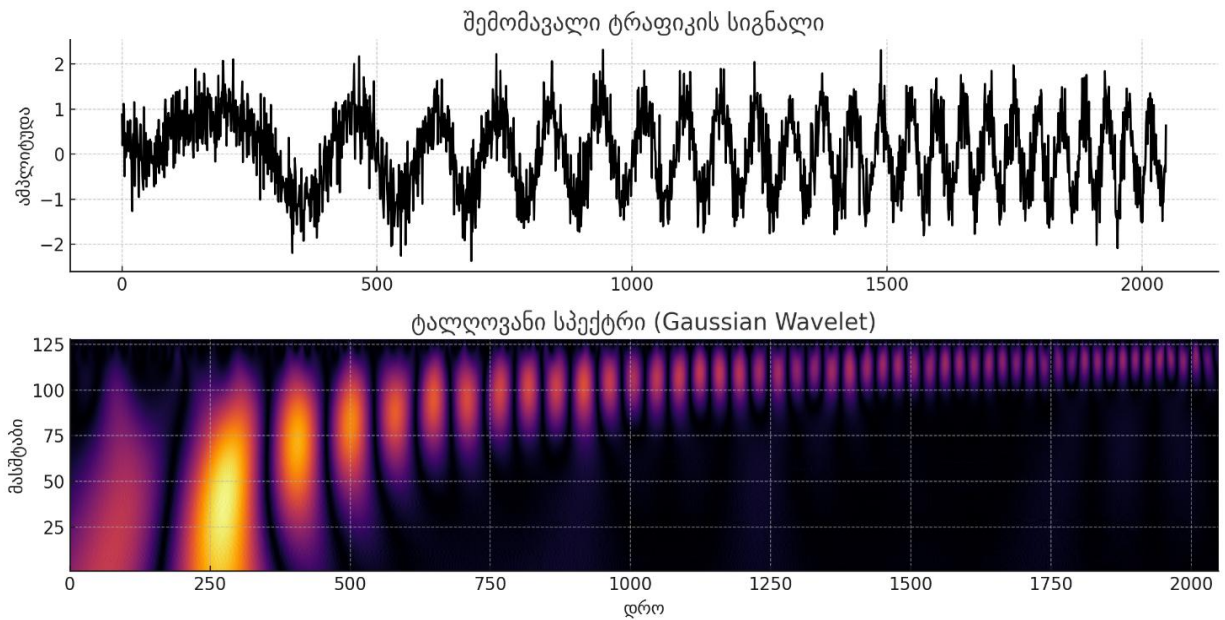
ნახ. 32. შემომავალი ტრაფიკის ტალღოვანი დიაგრამა Eth 0 ინტერფეისზე (Haar)



წყარო: ავტორის მიერ შედგენილი

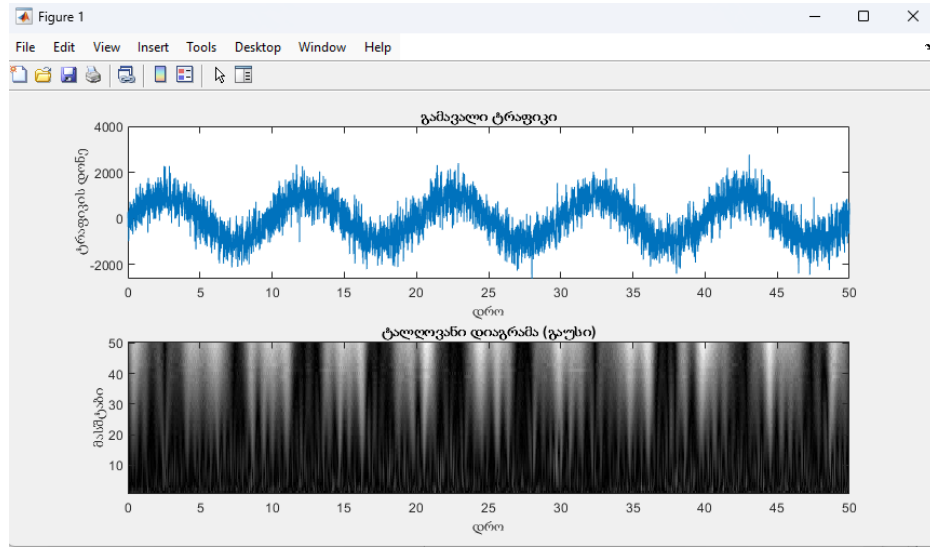
ხშირად, გაუსის ფუნქციის წარმოებულებზე დაფუძნებული ფუნქციები გამოიყენება უწყვეტი ტალღოვანი ტრანსფორმაციისთვის (სურათები 33-34).

ნახ. 33. შემომავალი ტრაფიკის ტალღოვანი დიაგრამა Eth 0 ინტერფეისზე (გაუსი)



წყარო: ავტორის მიერ შედგენილი

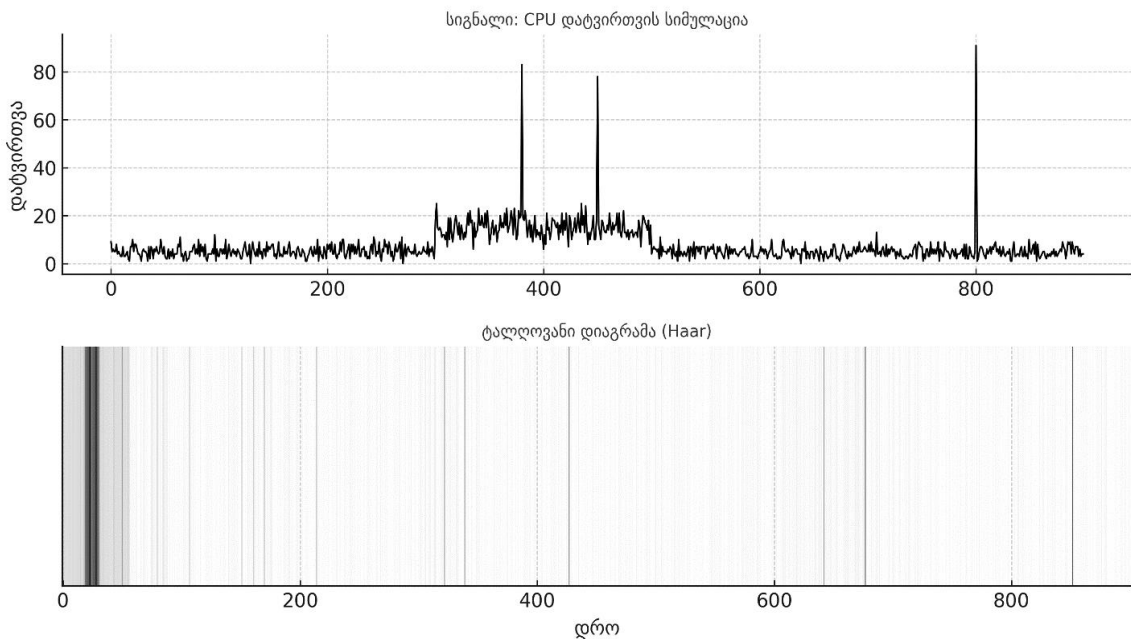
**ნახ. 34. გამავალი ტრაფიკის ტალღოვანი დიაგრამა Eth 0 ინტერფეისზე (გაუსი)**



**წყარო: ავტორის მიერ შედგენილი**

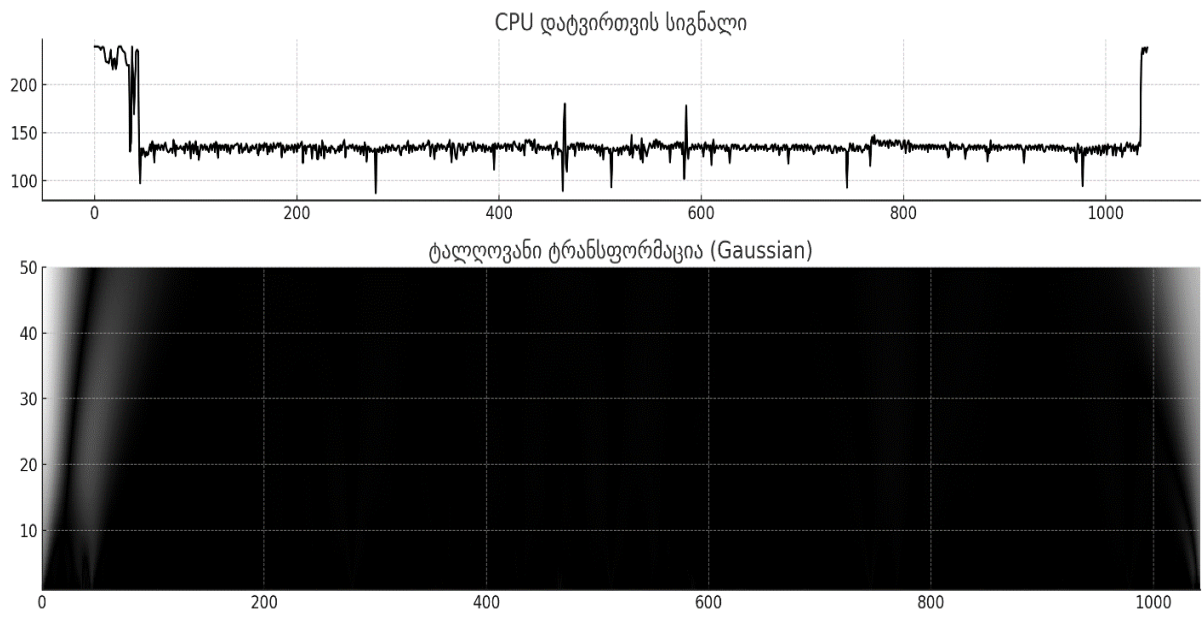
Wavelet დიაგრამები ნათლად აჩვენებს, რომ ტრაფიკის ადიდებული მოძრაობა ჩვეულებრივ შეესაბამება იდენტური სიხშირის სფეროებს. ასევე შეიძლება აღინიშნოს, რომ გაზრდილი ქსელის დატვირთვა შეესაბამება დაბალი სიხშირის დიაგრამებს. მსგავსი სიტუაცია ხდება სერვერის აპარატურის მონაცემების დამუშავებისას (სურათები 35- 38).

**ნახ. 35. CPU დატვირთვის ტალღოვანი დიაგრამა მომხმარებლის მოთხოვნის რეჟიმში (Haar)**



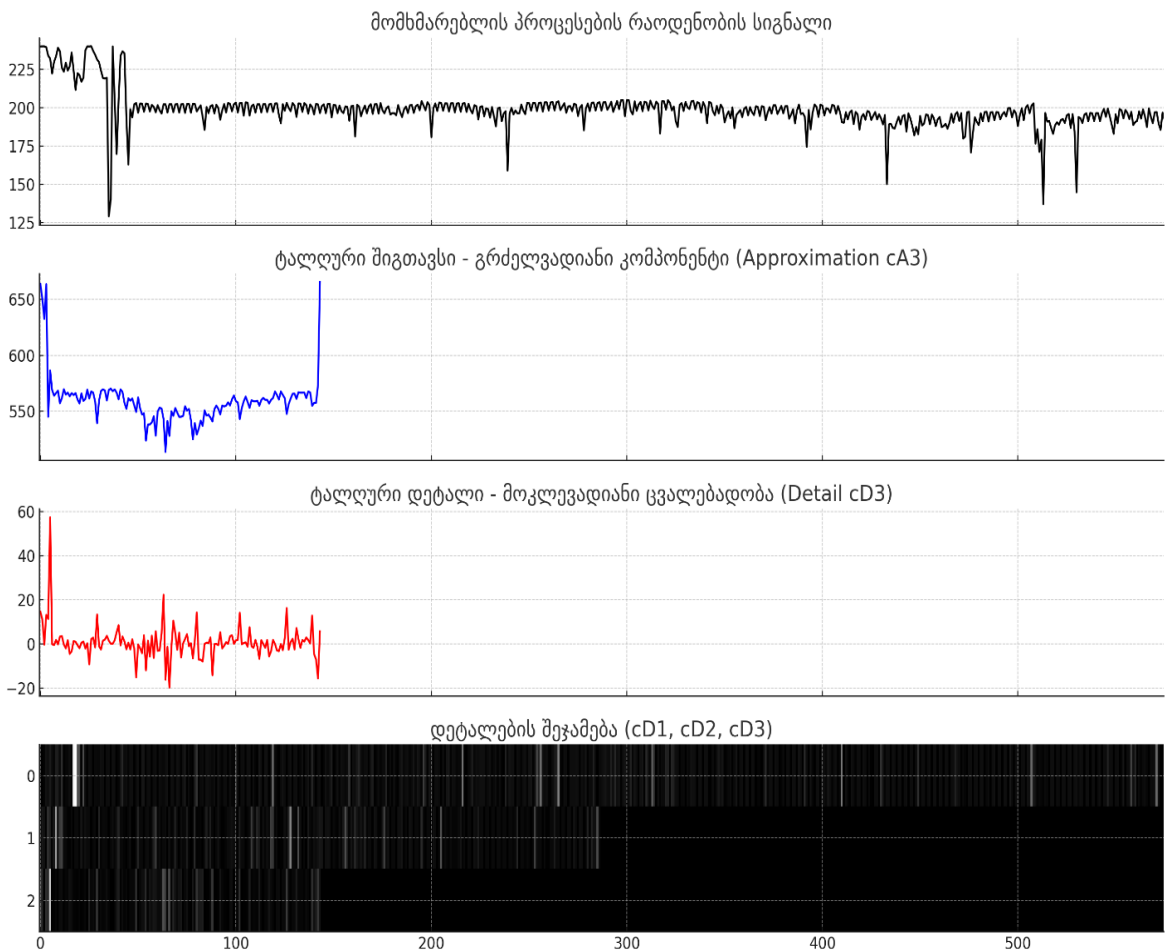
**წყარო: ავტორის მიერ შედგენილი**

ნახ. 36. CPU დატვირთვის ტალღოვანი დიაგრამა მომხმარებლის დამუშავების რეჟიმში




წყარო: ავტორის მიერ შედგენილი

ნახ. 37. მომხმარებლის პროცესების რაოდენობის ტალღოვანი დიაგრამა (Haar)



წყარო: ავტორის მიერ შედგენილი

ნახ. 38. მომხმარებლის პროცესების რაოდენობის ტალღოვანი დიაგრამა (გაუსი)



წყარო: ავტორის მიერ შედგენილი

ამრიგად მოცემულ კვლევაში განხორციელდა რეალური კორპორატიული ქსელის დატვირთულ სერვერზე მიმდინარე პროცესების სტატისტიკური და დინამიკური ანალიზი, რაც მიზნად ისახავდა სისტემის ქცევაში არსებული არაწრფივი დამოკიდებულებების გამოვლენას. მიღებულ იქნა ისეთი ძირითადი მეტრიკები, როგორცაა ტრაფიკის ორმხრივი ნაკადები, CPU დატვირთვა, ოპერატიული მეხსიერების გამოყენება და პროცესების რაოდენობა.

განაწილების სიმკვრივისა და ავტოკორელაციის ფუნქციების ანალიზმა ცხადყო, რომ მონაცემები ხასიათდება გრძელვადიანი დამოკიდებულებით და მძიმე კუდიანი განაწილებებით, რომელთა ტიპი შესაძლოა მიეკუთვნებოდეს სტუდენტურ ან პარეტოს განაწილებებს. სპექტრალური ანალიზის შედეგებმა დაადასტურა კლებადი ენერჯის დაგროვება დაბალი სიხშირეების ზონაში, რაც მიუთითებს თვითმსგავსობაზე და ღრმა დროით კორელაციებზე.

დამატებითი კორელაციური და რეგრესიული ანალიზი ცხადყოფს, რომ ქსელის დატვირთვის ზრდა პირდაპირ კორელირებულია CPU-ის დატვირთვის, ოპერატიული პროცესების რაოდენობისა და RAM-ის მოხმარების მატებასთან, რაც წარმოადგენს ქსელური რესურსების მგრძობელობის მთავარ ინდიკატორებს.

არაწრფივი დინამიკის მეთოდების გამოყენებით გამოითვალა ჰერსტის ინდექსი, ლიაპუნოვის განმსაზღვრელი და კორელაციური ენტროპია. ჰერსტის მაჩვენებელმა

დაადასტურა პროცესების თვითმსგავსი ბუნება, ხოლო ლიაპუნოვის დადებითმა მნიშვნელობებმა მიუთითა ქაოსური კომპონენტების არსებობაზე სისტემაში. ფაზურმა დიაგრამებმა და მიზიდულების ფორმებმა წარმოაჩინა რთული დინამიკის არსებობა, მათ შორის ფაზური გადასვლების შესაძლებლობა.

გარდა ამისა, კორელაციური ენტროპიის გამოყენებით შესაძლებელი გახდა პროგნოზირების ოპტიმალური ჰორიზონტის განსაზღვრა. აღსანიშნავია, რომ შესწავლილი პროცესები აღმოჩნდა მრავალგანზომილებიანი და მულტიფრაქტალური, რაც ზრდის პროგნოზირების სირთულეს და ერთდროულად ამართლებს კომპლექსური მოდელების გამოყენებას.

აღნიშნული ანალიზის შედეგად, მომდევნო თავში განხილულია არსებული პროგნოზირების მოდელების შედარება, რათა განისაზღვროს მეთოდები, რომლებიც საუკეთესოდ ერგება ამ ტიპის მონაცემების პროგნოზირებას.

## თავი 3

# მონაცემთა გადაცემის ქსელებში პროგნოზირების მეთოდების შედარებითი ანალიზი

### 3.1 დროის სერიების პროგნოზირების ალგორითმები

ისტორიულ ნიმუშზე დაფუძნებული დროის სერიების პროგნოზირების ამოცანა მეცნიერებაში ახალი არ არის. მიუხედავად მრავალწლიანი კვლევისა, მოცემული პრობლემა დღემდე ინარჩუნებს აქტუალურობას, რაც დაკავშირებულია პროგნოზირების ალგორითმებისა და მეთოდების უწყვეტ განვითარებასთან. თანამედროვე სამეცნიერო ლიტერატურაში უკვე წარმოდგენილია მრავალი მათემატიკური მოდელი და სტატისტიკური მეთოდი, რომლებიც დაფუძნებულია სერიის წარსულ მნიშვნელობებზე და მათი მეშვეობით ითვლება მომავლის შესაძლო მნიშვნელობები (Rahimi and Wishal Fatima 2024).

ბოლო პერიოდში განსაკუთრებით მნიშვნელოვანი გახდა დროის სერიების პროგნოზირების მეთოდების ინტეგრაცია კომპიუტერულ ქსელებში- ტრაფიკის მართვის, მომსახურების ხარისხის (QoS) უზრუნველყოფისა და გადატვირთულობის ეფექტური კონტროლის მიზნით (Hyndman and Athanasopoulos 2018). მიუხედავად ამისა, აღნიშნული მიმართულება ჯერ კიდევ შედარებით ახალია; არსებული კვლევების უმეტესობა ეფუძნება სინთეზურ მონაცემებს და არა რეალურ კორპორაციულ ქსელებში აღებულ დატვირთვებს. ამასთან, გამოყენებული პროგნოზირების მოდელები ძირითადად ავტორეგრესიული ხასიათისაა, ხოლო ნერვულ ქსელებზე დაფუძნებული მიდგომები ჯერ კიდევ იშვიათია პრაქტიკაში (Rahimi and Wishal Fatima 2024). ამავდროულად, პროგნოზირებისათვის შეთავაზებული ალგორითმების რაოდენობა საკმაოდ დიდია და თითოეული მათგანის სიღრმისეული ანალიზი მოითხოვს მნიშვნელოვან დროსა და შრომას. აქედან გამომდინარე, საფუძველზე დაფუძნებული ტრაფიკის მართვა ქსელის პირობების მოკლევადიანი პროგნოზის საფუძველზე კვლავ რჩება აქტუალურ კვლევით ამოცანად (Faloutsos, Molle and Karagiannis 2004).

ტიპიური ამოცანა პროგნოზირებასთან დაკავშირებით გულისხმობს დროის სერიაში მომდევნო მნიშვნელობების გამოთვლას. ეს შეიძლება ფორმალურად განისაზღვროს შემდეგნაირად: მოცემულია დროის სერია  $X(t) = X(1), X(2), \dots, X(T)$ , და საჭიროა განსაზღვრული იყოს ამ სერიის მომდევნო მნიშვნელობები დროის მომენტებში  $T+1, T+2, \dots, T+T'$ , სადაც  $T'$  წარმოადგენს პროგნოზირების ჰორიზონტს. მოდელი ეფუძნება ფუნქციურ დამოკიდებულებას წარსულ და მომავალი მნიშვნელობებს შორის და მისი მიზანია პროცესის მომავლის შეფასება ხელმისაწვდომი წარსული მონაცემების საფუძველზე. ავტორები ერთ-ერთი კლასიფიკაციის მიხედვით პროგნოზირების მოდელებს ორ ძირითად კატეგორიად ყოფენ: სტატისტიკურ და სტრუქტურულ მოდელებად. სტატისტიკურ მოდელებში შედის რეგრესიული, ავტორეგრესიული და ექსპონენციალური დაგლუვების მოდელები, ხოლო სტრუქტურულ მოდელებად მიიჩნევიან ნერვულ ქსელებზე, მარკოვის ჯაჭვებზე და კლასიფიკაციის ხეებზე დაფუძნებული ალგორითმები (Faloutsos, Molle and Karagiannis 2004).

თანამედროვე კვლევებში მნიშვნელოვანი ადგილი უჭირავს ღრმა ნერვული ქსელებისა და ევოლუციური ოპტიმიზაციის ჰიბრიდულ მიდგომებს. Wang და მისი კოლეგები ავითარებენ უკუკავშირის მქონე ნერვულ ქსელს, რომელიც ოპტიმიზებულია დიფერენციალური ევოლუციური ალგორითმით და გამოიყენება ქაოსური სერიების პროგნოზირებისთვის. ავტორები აჩვენებენ, რომ ასეთი სტრუქტურა საგრძნობლად ამცირებს პროგნოზის შეცდომას არაწრფივი სისტემების პირობებში (Arteche 2000). ვადლამანი და მისი თანამშრომლები კი აერთიანებენ ტაკენსის რეკონსტრუქციის თეორიას, ნეიროქსელის მოდელირებასა და გენეტიკურ ოპტიმიზაციას ერთ მთლიან სისტემაში, რითაც აღწევენ მაღალ სიზუსტეს ისეთ შემთხვევებშიც, სადაც ტრადიციული მოდელები უარყოფენ ქაოსურ დინამიკას (Vadlamani, et al. 2017). აღნიშნული მიდგომები განსაკუთრებით ეფექტურია რეალურ ქსელურ ტრაფიკზე, რომელიც ხშირად მერყეობს მაღალი არაწრფივობითა და ხმაურით.

ღრმა სწავლების თანამედროვე არქიტექტურებიდან განსაკუთრებით ეფექტურად გამოიყენება LSTM (Long Short-Term Memory) და CNN (Convolutional

Neural Networks) სტრუქტურები. სხვა მკვლევარები აღნიშნავენ, რომ LSTM არქიტექტურებს განსაკუთრებული უპირატესობა გააჩნიათ მეხსიერების ელემენტის გამო და იძლევიან მაღალი სიზუსტის პროგნოზს კომპლექსურ დროით დამოკიდებულ სისტემებში, მათ შორის ქსელურ ტრაფიკშიც (Heryadi, და სხვ. 2018). ასევე სხვა კვლევები აჩვენებენ, რომ ღრმა სწავლებისა და Big Data-ს შერწყმა მნიშვნელოვან გაუმჯობესებას იწვევს პროგნოზის სიზუსტეში, განსაკუთრებით მაშინ, როცა მოცემულია მაღალი დონის რეალურ დროში დინამიკა (Bogaerts, და სხვ. 2020). კვლევები ცხადყოფს, რომ CNN + LSTM ჰიბრიდული სტრუქტურები ეფექტიანად ასახავენ როგორც დროით, ისე სივრცით მახასიათებლებს.

დროის სერიების პროგნოზირების ერთ-ერთი უმარტივესი მიდგომა გლუვი ალგორითმების გამოყენებაა, რომლებიც საშუალო მნიშვნელობების გამოთვლაზე დაფუძნებული. ეს მეთოდი ხშირად გამოიყენება როგორც მარტივი და ინტუიციური პროგნოზირების მოდელი (Davis და Brockwell 2016, 58-64). ერთ-ერთი ელემენტარული ვარიანტია მოძრავი საშუალოს ალგორითმი, რომელიც მომდევნო დროის მომენტისთვის სერიის პროგნოზირებულ მნიშვნელობას ადგენს წინამორბედი N მნიშვნელობის საშუალოდ გამოთვლით:

$$X_{t+1} = \frac{X_t + X_{t-1} + X_{t-2} + \dots + X_{t-N+1}}{N} \quad (\text{Davis და Brockwell 2016})$$

სადაც  $X_{t+1}$  არის მომდევნო პროგნოზირებული მნიშვნელობა, ხოლო  $n$  დამარბილებელი ფანჯრის სიგრძეა. ამ მოდელის ეფექტურობა მნიშვნელოვნად არის დამოკიდებული  $n$ -ის სწორად შერჩევაზე. მნიშვნელოვანია, რომ ახლად მიღებული მნიშვნელობებს (მაგალითად,  $X_t$ ) ჰქონდეთ უფრო დიდი წონა, ვიდრე ძველს, მაგალითად  $X_{t-N+1}$ .

ზემოაღნიშნული ნაკლის დასაძლევად გამოიყენება ექსპონენციალური დაგლუვების ალგორითმი, რომელიც მოითხოვს წონის კოეფიციენტის გამოყენებას:

$$X'_{t+1} = \alpha X_t + (1 - \alpha) X'_t \quad (\text{Davis და Brockwell 2016})$$

სადაც  $0 < \alpha < 1$  შეწონვის კოეფიციენტია,  $X_t$  სერიის რეალური მნიშვნელობა, ხოლო  $X'_t$  წინა მომენტის პროგნოზი. კოეფიციენტის არჩევა დამოკიდებულია სერიის

ვარიაციულობაზე და ხმაურის დონეზე: რაც უფრო ცვალებადია სერია, მით უფრო მაღალი უნდა იყოს  $\alpha$ , რათა მოდელი სწრაფად ადაპტირდეს ცვლილებებზე.

არსებობს ადაპტური დაგლუვების ვარიაციები, რომელთა შემთხვევაში კოეფიციენტი ავტომატურად ითვლება პროგნოზისა და რეალური მნიშვნელობის თანაფარდობის საფუძველზე:

$$\alpha_{t+2} = \frac{X'_{t+1} - X_{t+1}}{X_{t+1}} \quad (\text{Davis და Brockwell 2016})$$

როდესაც კოეფიციენტის მნიშვნელობა გადაჭარბებს 1-ს, მის მნიშვნელობად მიღებულია მაქსიმალური დასაშვები მნიშვნელობა (მაგალითად,  $\alpha=0.99$ ); ხოლო ნულთან მიახლოებისას მინიმალური (მაგ.,  $\alpha=0.01$ ).

ზემოთ განხილული მოდელები უგულვებელყოფენ სერიაში არსებული ტენდენციურ ან სეზონურ კომპონენტებს. ამ ასპექტის გათვალისწინებით იქმნება მოდიფიცირებული ექსპონენციალური დაგლუვების მოდელები. მაგალითად, Holt-ის ალგორითმი ითვალისწინებს ტენდენციის დონესა და ვექტორს:

$$\begin{aligned} L_t &= \alpha X_t + (1 - \alpha)(L_{t-1} + T_{t-1}) \\ T_t &= \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1} \\ X_{t+m} &= L_t + mT_t \end{aligned} \quad (\text{Davis და Brockwell 2016})$$

გარდა ამისა, სეზონური კომპონენტის ჩასართავად გამოიყენება Holt-Winters-ის მოდელი, რომელიც ითვალისწინებს პერიოდულ ციკლებს:

$$\begin{aligned} L_t &= \alpha \left( \frac{X_t}{S_{t-c}} \right) + (1 - \alpha)(L_{t-1} + T_{t-1}) \\ T_t &= \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1} \\ S_t &= \gamma \left( \frac{X_t}{L_t} \right) + (1 - \gamma)S_{t-c} \\ X_{t+m} &= (L_t + mT_t)S_{t-c+m} \end{aligned} \quad (\text{Davis და Brockwell 2016})$$

აქ  $S_t$  აღნიშნავს სეზონურ კომპონენტს, ხოლო  $c$  სეზონური ციკლის სიგრძეს. მიუხედავად ამ მეთოდების მრავალფეროვნებისა, დაგლუვებაზე დაფუძნებულ პროგნოზებში ხშირია ინფორმაციის "დაკარგვა". ხშირად ეს მოდელები აშორებენ არა მხოლოდ ხმაურს, არამედ ინფორმაციას, რომელიც სასარგებლოა სერიის ქცევის

სიღრმისეული ანალიზისთვის. სწორედ ამიტომ რეგრესიულ და ავტორეგრესიულ მოდელებს, რომლებიც ქვემოთ განვიხილავთ, აქვთ უფრო ფართო ფუნქციური შესაძლებლობები და პროგნოზირების უკეთესი სიზუსტე (Davis და Brockwell 2016).

დროის სერიების პროგნოზირებისთვის ფართოდ გამოიყენება სტატისტიკური მიდგომები, რომელთა შორისაც გამორჩეულად მნიშვნელოვანია რეგრესიული და ავტორეგრესიული მოდელები. რეგრესიული ანალიზის მიზანია დაადგინოს კავშირი დამოკიდებულ ცვლადსა და ერთ ან ერთზე მეტ დამოუკიდებელ ცვლადს შორის, რომლებიც რეგრესორებად იწოდებიან. უმარტივესი ფორმა არის წრფივი რეგრესიული მოდელი, რომლის განტოლება შემდეგნაირად იწერება:

$$X_t = \beta_0 + \beta_1 Y_t + \varepsilon_t$$

(Kavalieris და Hannan 2008)

სადაც  $X_t$  არის დამოკიდებული ცვლადი,  $Y_t$  დამოუკიდებელი ცვლადი,  $\beta_0$  და  $\beta_1$  რეგრესიის კოეფიციენტები, ხოლო  $\varepsilon_t$  მოდელის შეცდომის ტერმინი.

როდესაც რეგრესიაში ერთზე მეტი ფაქტორია ჩართული, გამოიყენება მრავალჯერადი რეგრესიის მოდელი:

$$X_t = \beta_0 + \beta_1 Y_{t1} + \beta_2 Y_{t2} + \dots + \beta_n Y_{tn} + \varepsilon_t$$

(Kavalieris და Hannan 2008)

შეიძლება ასევე წარმოვიდგინოთ არაწრფივი დამოკიდებულება რეგრესორებსა და შედეგს შორის, რაც ზრდის მოდელის მოქნილობას. თუმცა პრაქტიკაში ხშირად რთულია გარე ფაქტორების სიზუსტით იდენტიფიცირება. ასეთ შემთხვევებში გამოიყენება ავტორეგრესიული მოდელები, რომლებიც ეყრდნობა მხოლოდ თავად დროის სერიაში არსებულ მონაცემებს.

ერთ-ერთი ყველაზე გავრცელებული მოდელია **ARMA** (Autoregressive Moving Average), რომელიც აერთიანებს ავტორეგრესიულ (AR) და მოძრავი საშუალოს (MA) მოდელებს. ავტორეგრესიული მოდელის ზოგადი ფორმაა:

$$X_t = c + \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + \varepsilon_t$$

(Kavalieris და Hannan 2008)

სადაც  $\phi_i$  არის წონის კოეფიციენტები,  $p$  მოდელის რიგი,  $c$  მუდმივი, ხოლო  $\varepsilon_t$  შეცდომა. მოძრავი საშუალოს MA(q) მოდელის ფორმაა:

$$X_t = \mu + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q} + \varepsilon_t$$

(Kavalieris და Hannan 2008)

აქ  $\theta_j$  აღნიშნავს წონის კოეფიციენტებს, ხოლო  $\mu$  პროცესის საშუალო მნიშვნელობას. სრული ARMA(p,q) მოდელი არის:

$$X_t = c + \sum_{i=1}^p \phi_i X_{t-i} + \sum_{j=1}^q \theta_j \varepsilon_{t-j} + \varepsilon_t$$

(Kavalieris და Hannan 2008)

ARMA მოდელი ეფუძნება სერიის **სტაციონარობის** ვერსიას. როდესაც სერია არ არის სტაციონარული, ხშირად გამოიყენება პირველადი განსხვავების მეთოდი, რაც იწვევს ARIMA მოდელის ფორმირებას Autoregressive Integrated Moving Average. ამ მოდელის ზოგადი ფორმაა ARIMA(p,d,q), სადაც d აღნიშნავს განსხვავების რიგს (Hamilton 1994). ARIMA მოდელზე დაყრდნობით შემუშავდა მოდიფიცირებული მოდელებიც, როგორცაა:

- **FARIMA** Fractional ARIMA, რომელიც მიმართავს ფრაქციული განსხვავების ოპერაციას (Hosking 1981).
- **SARIMA** Seasonal ARIMA, რომელიც აერთიანებს სეზონურ კომპონენტს დროის სერიაში (Attigeri, Belavagi და Sirisha 2022).

ეს მოდელები საშუალებას იძლევა გაითვალისწინოს როგორც დროის სერიის გრძელვადიანი დამოკიდებულება, ისე სეზონური რყევები, რაც განსაკუთრებით აქტუალურია კომპიუტერულ ქსელებში ტრაფიკის პროგნოზირებისას.

ხელოვნური ნერვული ქსელები (ANN- Artificial Neural Networks) ბოლო წლებში განსაკუთრებით პოპულარულია დროის სერიების პროგნოზირების ამოცანებში. მათი მოქნილობა და მრავალშრიანი სტრუქტურა შესაძლებლობას იძლევა, ეფექტიანად მოდელირდეს რთული, არაწრფივი დამოკიდებულებები, რაც განსაკუთრებით მნიშვნელოვანია იმ პროცესებისათვის, რომლებიც ექვემდებარებიან მრავალი გარე ფაქტორის ზემოქმედებას (Qamar და Zardari 2023).


ნერვული ქსელები ფართოდ გამოიყენება ობიექტების კლასიფიკაციისა და შაბლონების ამოცნობის ამოცანებში. ნეირონის ტიპური მოდელი წარმოადგენს ინფორმაციის დამუშავების ერთეულს, რომელიც იღებს ვექტორულ შეყვანას  $[X_1, X_2, \dots, X_n]$  და ახდენს მათ წონიან კომბინაციას. შედეგად მიღებული მნიშვნელობა

გადის გააქტიურების ფუნქციაზე  $F(z)$  რის შედეგადაც მიიღება გამომავალი სიგნალი  $Y$ .

$$F(z) = \frac{1}{1 + e^{-z}} \quad (\text{Qamar და Zardari 2023})$$

ერთი ყველაზე გავრცელებული გააქტიურების ფუნქციაა ლოგისტური სიგმოიდური ფუნქცია:

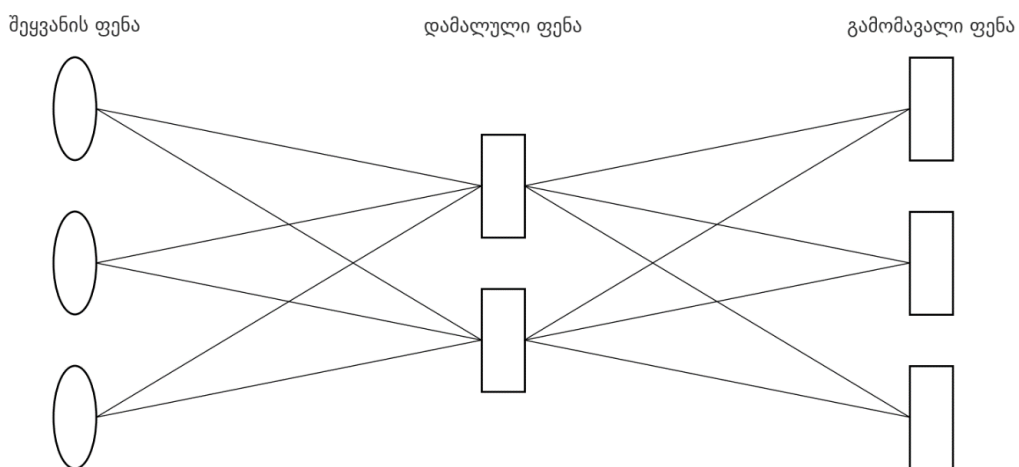
ნახ. 39. ნეირონის სტრუქტურული დიაგრამა



(Harish n.d.)

ნერვული ქსელი, რომელიც შედგება შეყვანის ფენისგან, ერთ ან რამდენიმე ფარული ფენისგან და გამომავალი ფენისგან, წარმოდგენილია სურათზე 40. ფარული ნეირონების რაოდენობა, მათ შორის კავშირების წონები და გააქტიურების ფუნქციების ტიპი განისაზღვრება ნეიროქსელის დიზაინისას. აღსანიშნავია, რომ ზოგიერთი ნეირონი შეიძლება არ იყოს დაკავშირებული ყველა დანარჩენთან, რაც აისახება წონის კოეფიციენტებში  $[w_{ij}=0]$ .

ნახ. 40. ნერვული ქსელის არქიტექტურის სქემატური აღწერა



წყარო: ავტორის მიერ შედგენილი

ANN-ის ძირითადი მახასიათებლებია:

- შესაძლებლობა, დაამყაროს არაწრფივი კავშირი შეყვანასა და გამომავალ მონაცემებს შორის.
- თვითსწავლადობა- ANN სწავლობს შეყვანის მაგალითებიდან და არ საჭიროებს წინასწარ განსაზღვრულ ფუნქციურ ფორმას.
- გენერალიზაციის უნარი- მას შეუძლია გაუმკლავდეს შეყვანის მონაცემების ცვლილებებს ისე, რომ შეინარჩუნოს პროგნოზის სიზუსტე.
- არ ითხოვს მკაცრ პრიორ ასუმპციებს მონაცემთა განაწილებაზე, როგორც ეს ხშირია სტატისტიკურ მოდელებში.

მიუხედავად ამ უპირატესობებისა, ხელოვნური ნერვული ქსელების გამოყენებას თან ახლავს გარკვეული სირთულეები. ერთ-ერთი ძირითადი გამოწვევაა ქსელის არქიტექტურის სწორი კონფიგურაცია: ფარული ფენების რაოდენობა, თითოეულ ფენაში ნეირონების რაოდენობა, სწავლის სიჩქარე და გააქტიურების ფუნქციების შერჩევა მნიშვნელოვან გავლენას ახდენს შედეგებზე (White და Stinchcombe 1989). ამასთან, ნერვული ქსელი ხშირად განიხილება როგორც ე.წ. „შავი ყუთი“- რთულია გაანალიზო და დაახასიათო მიღებული შედეგების ფორმირების ლოგიკა.

ერთ-ერთი მნიშვნელოვანი გამოწვევაა სასწავლო მონაცემთა ნაკრების შერჩევა: ქსელი უნდა განისაზღვროს საკმარისად მრავალფეროვანი და წარმომადეგი მაგალითების საფუძველზე, რათა მას შეეძლოს სწორი განზოგადება (White და Stinchcombe 1989).

როგორც ჩანს, ნერვული ქსელები წარმოადგენენ ძალზე პერსპექტიულ ინსტრუმენტს პროგნოზირებისთვის, განსაკუთრებით მაშინ, როცა მონაცემები არ ექვემდებარება ტრადიციული სტატისტიკური მოდელების მოთხოვნებს ან როცა საჭიროა მაღალი მგრძობიარობის მქონე არაწრფივი სისტემების მოდელირება.

სატელეკომუნიკაციო ქსელებში ტრაფიკის პროგნოზირების პროცესში ოპტიმალური მოდელისა და პარამეტრების შერჩევა წარმოადგენს არატრივიალურ ამოცანას. განსაკუთრებით რთულია არაწრფივი მოდელების შემთხვევაში პარამეტრების გამოთვლა ან სტრუქტურის ავტომატური არჩევა. ამ კონტექსტში ეფექტურ მეთოდად ითვლება გენეტიკური და ევოლუციური ალგორითმების

გამოყენება, რაც საშუალებას იძლევა ჩატარდეს ჰიპერპარამეტრების ოპტიმიზაცია ფართო ძიების სივრცეში (Mehnen, და სხვ. 2014).

გენეტიკური ალგორითმები თავდაპირველად იქნა გამოყენებული რეგრესიული მოდელების პარამეტრების შესარჩევად, ხოლო შემდგომში მათი წარმატებული აპლიკაცია დაფიქსირდა ავტორეგრესიული მოდელების კონფიგურაციაშიც (Mehnen, და სხვ. 2014). ამ მიდგომაში პოპულაცია წარმოდგენილია გენომის ფორმით, სადაც თითოეული ინდივიდი (ქრომოსომა) წარმოადგენს პოტენციურ გადაწყვეტილებას- მაგალითად, რეგრესიის კოეფიციენტების ნაკრებს. ევოლუციური ოპერატორების, როგორცაა კროსოვერი და მუტაცია, გამოყენების შედეგად, ახალ პოპულაციაში ინერგება უკეთესი გამოსავლები, რომელთა შეფასება ხდება პროგნოზის სიზუსტის კრიტერიუმით.

თანამედროვე კვლევებში გენეტიკური ალგორითმები გამოიყენება არა მხოლოდ სტატისტიკური მოდელების ოპტიმიზაციისთვის, არამედ ხელოვნური ნერვული ქსელების (ANN) არქიტექტურის ავტომატური აგების მიზნით. ამ შემთხვევაში გენეტიკური ალგორითმი განსაზღვრავს ისეთ პარამეტრებს, როგორცაა შეყვანისა და გამომავალი ნეირონების რაოდენობა, ფარული ფენების რაოდენობა, და წონათა ინიციალიზაციის სტრუქტურა (Mehnen, და სხვ. 2014). ალგორითმი, როგორც წესი, მუშაობს შემდეგნაირად:

- **საწყისი პოპულაცია** სხვადასხვა სტრუქტურის ნერვული ქსელები შემთხვევით ფორმირდება;
- **შეფასება** თითოეული ინდივიდი ფასდება ოპტიმიზაციის მიზნობრივი ფუნქციის შესაბამისად (მაგალითად, საშუალო კვადრატული შეცდომა);
- **ევოლუციური ოპერატორები** საუკეთესო ინდივიდები გადადიან შემდეგ თაობაში, ხოლო კროსოვერისა და მუტაციის მეშვეობით წარმოიქმნება ახალი სტრუქტურები;
- **გამეორება** პროცესი მეორდება განსაზღვრული ეპოქების მანძილზე ან კონკრეტული კრიტერიუმის შესრულებამდე (Mehnen, და სხვ. 2014).

ასეთი მიდგომა მნიშვნელოვნად ამცირებს ხელით კონფიგურაციის აუცილებლობას და უზრუნველყოფს პროგნოზირების სისტემის თვითორგანიზებას გლობალური

ოპტიმიზაციის სწრაფვით. განსაკუთრებით მნიშვნელოვანია მისი გამოყენება რთულ სისტემებში, როგორცაა რეალური ქსელური დატვირთვების პროგნოზირება, სადაც სტრუქტურის სიზუსტე პირდაპირ აისახება QoS-ის ხარისხსა და გადატვირთვის მართვაზე.

ლოკალური მიახლოების მეთოდები (Local Approximation Methods) ფართოდ გამოიყენება ისეთი სიგნალების პროგნოზირებისთვის, რომელთაც ახასიათებთ ქაოსური ან კვაზიპერიოდული ქცევა. აღნიშნული მეთოდების უპირატესობა იმაში მდგომარეობს, რომ პროგნოზირებისას არ ხდება პროცესის გლობალური მოდელირება, არამედ პროგნოზი ეფუძნება სერიის ლოკალურ ქვემიმდევრობებზე დაკვირვებას შეფერხების სივრცეში, რაც განსაკუთრებით ეფექტურია არაწრფივი სისტემების შემთხვევაში (Schramm, Hayes და Thomas 2003).

ამ მიდგომის მთავარი მახასიათებელია ის, რომ პროგნოზის ჰორიზონტი განისაზღვრება არა მოდელის არქიტექტურული სირთულით, არამედ თავად პროცესის დინამიური ქცევის მიხედვით. ანუ, პროგნოზის სიზუსტე ემყარება უშუალოდ იმ „ლოკალურ“ ქცევებს, რომელიც აღინიშნება დროის სერიების მცირე მონაკვეთებში. შესაბამისად, პროგნოზირება უფრო მეტად ეფუძნება მიმდინარე მდგომარეობის მსგავს წარსულ მეზობლებთან შედარებას და არა გლობალურ მახასიათებლებზე დაყრდნობას (Schramm, Hayes და Thomas 2003).

ლოკალური პროგნოზირების კლასიკური ალგორითმი, რომელიც გამოიყენება ერთი ნაბიჯით წინ პროგნოზირებისთვის, მოიცავს შემდეგ ნაბიჯებს:

- შეფერხების მატრიცის აგება და შესაბამისი ლოკალური წარმოდგენების შერჩევა;
- მეზობლების რაოდენობის განსაზღვრა მოცემული მანძილის კრიტერიუმით;
- პროგნოზის აგება იმ დაშვებით, რომ მომავალი ქცევა იმეორებს იმავე კანონზომიერებას, რაც ახლო მეზობლების შემთხვევაში იყო დაფიქსირებული (Sugihara and May 1990).

ლოკალური მიახლოების მეთოდს შეუძლია პროგნოზის შესრულება სხვადასხვა მოდის საშუალებით, როგორცაა:

- **განმეორებითი პროგნოზი** მომდევნო მნიშვნელობა გამოიყენება როგორც ახალი საწყისი წერტილი შემდეგი პროგნოზისთვის;

- განმეორებითი გადათვლა ყოველი პროგნოზის შემდეგ ხელახლა ხდება მოდელის ყველა პარამეტრის გაანგარიშება და მეზობელთა გადარჩევა;
- პირდაპირი პროგნოზი თითოეული მომდევნო მნიშვნელობა პროგნოზირდება დამოუკიდებლად და არ ექვემდებარება შემდგომ გამოთვლებში ჩართვას, რაც თავიდან აცილებს პროგნოზის შეცდომის კუმულაციას (Sugihara and May 1990).

მიუხედავად იმისა, რომ ლოკალური მიახლოების მეთოდები მიდრეკილია ცალმხრივი წრფივი მოდელებისკენ ლოკალურ დონეზე, მათ მნიშვნელოვანი უპირატესობა აქვთ ავტორეგრესიული მოდელებთან შედარებით, რადგან საშუალებას იძლევა პროცესის არაწრფივი და ქაოტური მახასიათებლების გამოკვეთა იმ შემთხვევაშიც კი, როცა გლობალური წრფივი მოდელები მსგავსი თვისებების დანახვას ვერ ახერხებენ (Abarbanel 1993, 17-18).

მოცემული პროგნოზირების მოდელის ადეკვატურობის შეფასება კრიტიკულად მნიშვნელოვანია მოდელის ეფექტურობის განსასაზღვრად და შედარებისთვის სხვა ალგორითმებთან. შეფასების ერთ-ერთი ყველაზე ფართოდ გამოყენებული მიდგომა ემყარება პროგნოზის შეცდომის გაანგარიშებას, რაც განსაზღვრავს განსხვავებას რეალურად მიღებულ და საპროგნოზო მნიშვნელობებს შორის:

$$e_t = X_{T+t} - \hat{X}_{T+t} \quad (\text{Abarbanel 1993})$$

სადაც  $X_{T+t}$  არის დროის სერიის რეალური მნიშვნელობა მომენტში  $T+t$ , ხოლო  $\hat{X}_{T+t}$  სერიის პროგნოზირებული მნიშვნელობა.

პროგნოზის შეცდომის საშუალო მნიშვნელობის ინდიკატორად გამოიყენება საშუალო პროგნოზის შეცდომა (Mean Forecast Error MFE):

$$MFE = \frac{1}{n} \sum_{t=1}^n e_t \quad (\text{Abarbanel 1993})$$

ეს მეტრიკა ზომავს პროგნოზის მიმართულებას ანუ პოზიტიური თუ ნეგატიური გადახრები უფრო ჭარბობს. თუმცა, მისი აბსოლუტური მნიშვნელობა არ ასახავს რეალურ სიზუსტეს და არ ითვალისწინებს უკიდურესი შეცდომების გავლენას (Makridakis, Wheelwright, and Hyndman 1998).

მეტად ინფორმაციულია საშუალო აბსოლუტური შეცდომა (Mean Absolute Error MAE):

$$MAE = \frac{1}{n} \sum_{t=1}^n |e_t|$$

(Abarbanel 1993)

იგი აჩვენებს პროგნოზის საშუალო აბსოლუტურ გადახრას და წარმოადგენს არაინტუიციური შეცდომების გათვალისწინების გარეშე ჩატარებულ შეფასებას, თუმცა კვლავვე დამოკიდებულია სერიის ერთეულზე და მასშტაბზე.

მესამე ფართოდ გამოყენებული მაჩვენებელია **საშუალო აბსოლუტური პროცენტული შეცდომა** (Mean Absolute Percentage Error MAPE), რომელიც არ ითვალისწინებს შეცდომის ნიშანს და გამოხატავს შეცდომას პროცენტულად:

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{e_t}{X_t} \right| \times 100$$

(Abarbanel 1993)

MAPE განსაკუთრებით პოპულარულია კომერციული და გამოყენებითი პროგნოზირებისთვის, თუმცა პრობლემურია მაშინ, როცა რეალური მნიშვნელობები ახლოსაა ნულთან (Hyndman and Koehler 2006).

პროგნოზის შეცდომების დისპერსიის შესაფასებლად გამოიყენება **საშუალო კვადრატული შეცდომა** (Mean Squared Error MSE) ან **სტანდარტული კვადრატული შეცდომა** (Signed MSE SMSE):

$$SMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n e_t^2}$$

(Hyndman and Koehler 2006)

ეს მეთოდი მკაცრად სჯის დიდ შეცდომებს, რადგან კვადრატული ფუნქცია დიდ მნიშვნელობებს უფრო მაღლა აყვანის ტენდენციას იძლევა.

შედარებით ნორმირებული შეფასება გვაძლევს **ნორმალიზებულ საშუალო კვადრატულ შეცდომას** (Normalized MSE NMSE):

$$NMSE = \frac{\frac{1}{n} \sum_{t=1}^n e_t^2}{\sigma^2}$$

(Hyndman and Koehler 2006)

სადაც  $\sigma^2$  წარმოადგენს სერიის დისპერსიას:

$$\sigma^2 = \frac{1}{n-1} \sum_{t=1}^n (X_t - \bar{X})^2, \quad \bar{X} = \frac{1}{n} \sum_{t=1}^n X_t$$

(Hyndman and Koehler 2006)

NMSE ინდიკატორი საშუალებას იძლევა სხვადასხვა სერიებს შორის პროგნოზის სიზუსტის შედარება, არაუზრუნველყოფილი სერიის ერთეულებზე დამოკიდებულებით რაც მნიშვნელოვანია მოდელების კროს-პლატფორმული შეფასებისთვის. აღნიშნული მეთოდები გამოიყენება როგორც ინდივიდუალურად, ისე კომპლექსურად, რათა განისაზღვროს პროგნოზის მოდელის საიმედოობა, სტაბილურობა და ადაპტურობა კონკრეტული დროის სერიების ტიპისთვის.

კონკრეტული მოდელის პრაქტიკული გამოყენებისთვის ხშირად მიმართავენ **Box-Jenkins-ის მეთოდოლოგიას** (Wilson 2016), რომელიც პროგნოზირების პროცესს სამ ძირითად ეტაპად ყოფს:

1. **მოდელის იდენტიფიკაცია** დროის სერიის სტაციონარობის შემოწმება და ACF/PACF ანალიზი.
2. **მოდელის პარამეტრიზაცია და შეფასება** შერჩეული მოდელის პარამეტრების ანგარიშით.
3. **პროფესიონალური პროგნოზის აგება** პროგნოზირებული მნიშვნელობების განსაზღვრა მოდელის მეშვეობით.


არასტაციონარული სერიებისთვის, პირველ რიგში, ტენდენციის და სეზონურობის კომპონენტების მოცილება ხდება გრადიენტული განსხვავების ან სხვა პრეტრანსფორმაციის მეთოდების საშუალებით (Wilson 2016).

### 3.2 პროგნოზი დაფუძნებული AR ( $p$ )- მოდელი

კომპიუტერული ექსპერიმენტების ფარგლებში ჩატარდა წინასწარ შეგროვებული მონაცემების სტატისტიკური დამუშავება და პროგნოზის სიზუსტის შეფასება ავტორეგრესიული მოდელების (AR( $p$ )) გამოყენებით. მიმდინარეობდა  $p$  პარამეტრის შერჩევა როგორც ACF გრაფიკების, ისე კონკრეტული მნიშვნელობების ჩამოთვლის გზით (იხ. დანართი 1.1).


პროგნოზის შედეგები წარმოდგენილია სურათებზე 41–44, სადაც რეალური და პროგნოზირებული მნიშვნელობები ვიზუალურად ჩანს შემომავალი და გამავალი ტრაფიკისთვის ორ ინტერფეისზე (Eth0 და Eth1):

ნახ. 41. რეალური და პროგნოზირებული შემომავალი ტრაფიკის ინტენსივობა (Eth0, ARIMA მოდელი)




წყარო: ავტორის მიერ შედგენილი

ნახ. 42. რეალური და პროგნოზირებული შემომავალი ტრაფიკის ინტენსივობა (Eth1, ANN მოდელი)




წყარო: ავტორის მიერ შედგენილი

ნახ. 43. რეალური და პროგნოზირებული გამავალი ტრაფიკის ინტენსივობა (Eth0, ANN მოდელი)



წყარო: ავტორის მიერ შედგენილი

ნახ. 44. რეალური და პროგნოზირებული გამავალი ტრაფიკის ინტენსივობა (Eth1, ARIMA მოდელი)



წყარო: ავტორის მიერ შედგენილი


პროგნოზის შეცდომა შეფასდა საშუალო აბსოლუტური შეცდომის (MAE) მეშვეობით, რომელიც გამოითვლება ფორმულით:

$$MAE = \frac{1}{n} \sum_{t=1}^n |e_t|, \quad (\text{Ghosh 2022})$$

სადაც  $e_t = X_{T+t} - \hat{X}_{T+t}$  წარმოადგენს პროგნოზის შეცდომას დროის მომენტში  $T+t$ . ექსპერიმენტებმა აჩვენა, რომ MAE ტრაფიკის გადაცემის პროცესებისთვის მერყეობდა დაახლოებით 12% ფარგლებში.


MAE-ს დინამიკა წარმოდგენილია სურათებზე 45–48, სადაც  $p$  პარამეტრის ცვლილებასთან ერთად შეცდომის ტენდენცია დაფიქსირდა ყველა არხზე:

ნახ. 45. MAE AR(p) პროგნოზი, როგორც  $p$ -ის ფუნქცია შემომავალი ტრაფიკისთვის (Eth1)




წყარო: ავტორის მიერ შედგენილი

ნახ. 46. MAE AR(p) პროგნოზი, როგორც p-ის ფუნქცია შემომავალი ტრაფიკისთვის (Eth0)




წყარო: ავტორის მიერ შედგენილი

ნახ. 47. MAE AR(p) პროგნოზი, როგორც p-ის ფუნქცია გამავალი ტრაფიკისთვის (Eth0)



წყარო: ავტორის მიერ შედგენილი


ნახ. 48. MAE AR(p) პროგნოზი, როგორც p-ის ფუნქცია გამავალი ტრაფიკისთვის (Eth1)



წყარო: ავტორის მიერ შედგენილი


განსაკუთრებული ყურადღება მიექცა სერვერის ტექნიკის რესურსების, კერძოდ CPU დატვირთვის პროცესის მოდელირებას. ანალიზმა აჩვენა, რომ აღნიშნულ პროცესს ახასიათებს მეტწილად წრფივი და პერიოდული დინამიკა, რაც განაპირობებს AR(p) მოდელის მაღალი სიზუსტით პროგნოზირების შესაძლებლობას. მაგალითად, CPU დატვირთვისთვის მიღებული MAE მერყეობდა 1–3% ფარგლებში, რაც მიუთითებს პროგნოზის მაღალი სიზუსტეზე.

ნახ. 49. CPU-ის რეალური დატვირთვა და პროგნოზირებული მნიშვნელობა




წყარო: ავტორის მიერ შედგენილი

ნახ. 50. MAE AR(p) პროგნოზის, როგორც p-ის ფუნქცია CPU დატვირთვისთვის



წყარო: ავტორის მიერ შედგენილი

ნახ. 51. AR(p) მოდელის პროგნოზის საშუალო შეცდომა



წყარო: ავტორის მიერ შედგენილი

როგორც სურათ-51\_ზეა ნაჩვენები, ყველაზე დაბალი პროგნოზის საშუალო შეცდომა დაფიქსირდა თავისუფალი მესიურების მოცულობისა და CPU დატვირთვის პროგნოზისას, რაც მეტყველებს ამ პროცესების მაღალი პროგნოზირებადობის ხარისხზე. რაც შეეხება ტრანსპორტირებულ ტრაფიკს, შეცდომის მაჩვენებლები შეადგენს საშუალოდ 11.8–12.3%-ს, რაც იმაზე მიუთითებს, რომ AR(p) მოდელი სასურველ სიზუსტეს აღწევს სტატისტიკურად სტაციონარული ტრაფიკის შემთხვევაში, მაგრამ საჭიროებს გაუმჯობესებას უფრო არასტაბილურ სეგმენტებზე.

### 3.3 პროგნოზი ARIMA ( p, d, q )- მოდელის საფუძველზე

ARIMA (AutoRegressive Integrated Moving Average) მოდელი წარმოადგენს ავტორეგრესიული და მოძრავი საშუალოს მოდელების შერწყმას და განკუთვნილია არასტაციონარული დროის სერიების ანალიზისთვის. იგი მოიცავს სამ პარამეტრს:

**p**- ავტორეგრესიული კომპონენტის რიგს (AR),

**d**- ინტეგრაციის რიგს, ანუ რამდენჯერ უნდა იქნას განსხვავებული სერია სტაციონარობის მისაღწევად,

**q**- მოძრავი საშუალოს კომპონენტის რიგს (MA).

ARIMA (p, d, q) მოდელის ზოგადი გამოსახულება შეიძლება წარმოდგენილი იყოს შემდეგნაირად:

$$X_t = c + \varepsilon_t + \sum_{i=1}^p \varphi_i X_{t-i} + \sum_{j=1}^q \theta_j \varepsilon_{t-j}$$


(Namini, Tavakoli and Namin 2018)

სადაც:  $X_t$  პროგნოზირებული მნიშვნელობა დროის მომენტში  $t$ ,  $\varepsilon_t$  შემთხვევითი შემფოთება (white noise),  $\varphi_i$  და  $\theta_j$  შესაბამისი წონის კოეფიციენტები AR და MA კომპონენტებისთვის (Namini, Tavakoli and Namin 2018).

ARIMA მოდელის პარამეტრების (p,d,q) შერჩევა განხორციელდა სხვადასხვა მნიშვნელობებზე მორგებით, სადაც p და q მერყეობდა 1-დან 10-მდე, ხოლო d ჩვეულებრივ მიიღებოდა როგორც 1 რაც ყველაზე გავრცელებული პრაქტიკაა ტრენდული კომპონენტის აღმოსაფხვრელად.


პროგნოზის სიზუსტის შეფასება განხორციელდა სხვადასხვა ტიპის მონაცემებზე, მათ შორის შემომავალ და გამავალ ტრაფიკზე (Eth0 და Eth1 ინტერფეისებზე), ასევე CPU-ის დატვირთვისა და თავისუფალი მეხსიერების მოცულობაზე. ვიზუალური შედარება რეალურ და პროგნოზირებულ მონაცემებს შორის წარმოდგენილია სურათებზე:

ნახ. 52. რეალური და პროგნოზირებული შემომავალი ტრაფიკის ინტენსივობა (Eth1 ინტერფეისი)




წყარო: ავტორის მიერ შედგენილი

ნახ. 53. რეალური და პროგნოზირებული გამავალი ტრაფიკის ინტენსივობა (Eth1 ინტერფეისი)




წყარო: ავტორის მიერ შედგენილი

ნახ. 54. რეალური და პროგნოზირებული შემომავალი ტრაფიკის ინტენსივობა (Eth0 ინტერფეისი)




წყარო: ავტორის მიერ შედგენილი

ნახ. 55. რეალური და პროგნოზირებული გამავალი ტრაფიკის ინტენსივობა (Eth0 ინტერფეისი)




წყარო: ავტორის მიერ შედგენილი

ნახ. 56. თავისუფალი მეხსიერების რეალური და პროგნოზირებული მოცულობა



წყარო: ავტორის მიერ შედგენილი


ნახ. 57. CPU-ის რეალური დატვირთვა და პროგნოზირებული მნიშვნელობა



წყარო: ავტორის მიერ შედგენილი

მიღებული შედეგები ადასტურებს, რომ ARIMA მოდელი უზრუნველყოფს შედარებით მაღალ პროგნოზირების სიზუსტეს ტრაფიკის ტენდენციური დროის სერიებისთვის. განსაკუთრებით ეფექტური აღმოჩნდა ის იმ შემთხვევებში, როცა სერიაში მკაფიო სეზონური ან ტრენდული კომპონენტები შეინიშნებოდა, რაც ხსნის მის უპირატესობას სხვა არაინტეგრირებულ მოდელებთან შედარებით.

დიაგრამა 1. ARIMA (p, d, q) მოდელის პროგნოზის შეცდომა სხვადასხვა პროცესისთვის



წყარო: ავტორის მიერ შედგენილი

ეს არის დიაგრამა, რომელიც აჩვენებს ARIMA (p, d, q) მოდელის პროგნოზის საშუალო აბსოლუტურ შეცდომას (MAE) თითოეული პროცესისთვის. გრაფიკზე მოცემულია ტრაფიკის ტიპები და შესაბამისი პროგნოზის სიზუსტე პროცენტულად

### 3.4 პროგნოზი SSA მეთოდით ("Caterpillar")

სინგულარული სპექტრული ანალიზი (SSA), რომელიც ხშირად მოიხსენიება როგორც „Caterpillar“ მეთოდი, წარმოადგენს დროის სერიების ანალიზის შედარებით ახალ, თუმცა ძლიერ მეთოდს, რომელიც აერთიანებს კლასიკური სტატისტიკური ანალიზის, მრავალგანზომილებიანი გეომეტრიისა და დინამიური სისტემების ელემენტებს (Elsner 2012, 158).

SSA მეთოდი განსაკუთრებით ეფექტურია იმ შემთხვევებში, როდესაც საჭიროა დროის სერიიდან კომპლექსური სტრუქტურების გამოვლენა. ის სერიას წარმოსახავს დამოუკიდებელ კომპონენტებად როგორცაა ნელა ცვალებადი ტენდენცია, პერიოდული კომპონენტები და შვევა ხმაური რის შედეგადაც მიღებულია ინფორმაციულად გაჯერებული, მაგრამ გამარტივებული მოდელი (Elsner 2012, 160).

SSA-ის ძირითადი ეტაპები: დავუშვათ, მოცემულია დროის სერია  $X_1, X_2, \dots, X_N$ . პირველ ეტაპზე ირჩევა ფანჯრის სიგრძე  $L$  ისე, რომ  $1 < L < N$  და ქმნის ე.წ. ტრაექტორიის მატრიცას  $X$ :

$$\mathbf{X}'_i = (X_i, X_{i+1}, \dots, X_{i+L-1})^T, \quad i = 1, 2, \dots, K = N - L + 1$$

(Namini, Tavakoli and Namin 2018)

ამ ვექტორებით დგება ჰანკელის ტიპის მატრიცა:

$$\mathbf{X} = [\mathbf{X}'_1 : \mathbf{X}'_2 : \dots : \mathbf{X}'_K] \in \mathbb{R}^{L \times K}$$

(Namini, Tavakoli and Namin 2018)

მატრიცა  $\mathbf{X}$  ინახავს ინფორმაციას იმგვარად, რომ ყველა მთავარი დიაგონალი შეიცავს ერთსა და იმავე მნიშვნელობას (ანუ  $i+j=\text{const}$ ). შემდეგ კი მიმართავენ სინგულარულ სპექტრულ დაშლას (SVD):

$$\mathbf{X} \approx \sum_{i=1}^l \sqrt{\lambda_i} \mathbf{U}_i \mathbf{V}_i^T$$

(Namini, Tavakoli and Namin 2018)

სადაც  $\lambda_i$  წარმოადგენს სინგულარულ მნიშვნელობებს, ხოლო  $\mathbf{U}_i$  და  $\mathbf{V}_i$  შესაბამის მარცხენა და მარჯვენა საკუთრივ ვექტორებს. ამ კომპონენტების შერჩევისა და დიაგონალური შეჯამების შემდეგ აღდგება ახალი მატრიცა  $\tilde{X}$ , რომელიც წარმოადგენს პროგნოზისთვის გამოიყენებად განახლებულ სერიას. SSA ალგორითმი წარმატებით გამოიყენება სერიის შიდა სტრუქტურის გამოკვეთასა და მომავალი


მნიშვნელობების პროგნოზირებაში. იგი განსაკუთრებით კარგად ართმევს თავს ისეთ შემთხვევებს, როდესაც მონაცემები შეიცავს ტენდენციურ, პერიოდულ ან მაღალი დონის ხმაურში დაფარულ კომპონენტებს. შედარებით ანალიზში, SSA-მ აჩვენა უკეთესი შედეგები პროგნოზირების სიზუსტეში, ვიდრე კლასიკურმა AR ან ARIMA მოდელებმა ( Iranmanesh, Miranian and Abdollahzade 2012); (Groth and Ghil 2015).

SSA ალგორითმს გააჩნია მრავალი ვარიაცია, მათ შორის:


- **Monte Carlo SSA** არარეგულარული რხევების დეტექცია ფერადი ხმაურის პირობებში.
- **Multivariate SSA** მრავალგანზომილებიანი დროის სერიების ანალიზი.
- **SSA w/ SVD Variants** ალტერნატიული დაშლის მეთოდებით, შერწყმული PCA ან ICA პრინციპებით ( Iranmanesh, Miranian and Abdollahzade 2012).

მეთოდი ადაპტირებადია როგორც სტაციონარული, ისე არასტაციონარული პროცესებისთვის და საშუალებას იძლევა აღმოვაჩინოთ რთული ქცევითი მოდელები ქსელურ ტრაფიკში.

ნახ. 58. რეალური და პროგნოზირებული შემომავალი ტრაფიკის ინტენსივობა (SSA მეთოდით)



წყარო: ავტორის მიერ შედგენილი  
 დიაგრამა 2. SSA მოდელის პროგნოზის შეცდომა



### 3.5 ნეირონული ქსელის მოდელი


დროის სერიების მნიშვნელობების პროგნოზირების ამოცანა უმთავრესად ემყარება ისეთი მოდელის კონსტრუქციას, რომელიც მაქსიმალურად ზუსტად აღწერს ანალიზირებად პროცესს. რაც უფრო ეფექტურად ასახავს მოდელი პროცესის დინამიკას, მით უფრო ახლოსაა მიღებული პროგნოზი რეალურ მონაცემებთან. წინა ქვეთავებში განხილული იყო ავტორეგრესიული და მოძრავი საშუალოზე დაფუძნებული მოდელები, აგრეთვე თვითმსგავსების ეფექტი, რომელიც ინტეგრირდება ARFIMA მოდელში (Autoregressive Fractionally Integrated Moving Average). გრძელვადიანი დამოკიდებულებების მქონე პროცესების მოდელირებას განსაკუთრებული ყურადღება ეთმობა თანამედროვე ლიტერატურაში (Beran 1994); (Gil-Alana 2005). აღნიშნულ ნაშრომში ARFIMA მოდელი ოპტიმიზებულია ისტორიულ ტრაფიკზე დაყრდნობით, ხოლო ოპტიმიზაციისთვის გამოყენებულია ბროიდენ-ფლექტერ-გოლდფარბ-შანოს (BFGS) ალგორითმი (Yu-Hong Dai 2002).

BFGS მეთოდი ეფუძნება ობიექტური ფუნქციის ტეილორის მიახლოებას გრადიენტის და ჰესიანის გათვალისწინებით, შემდეგი გამოსახულებით:

$$f(x + d) \approx q(d) = f(x) + g(x)^T d + \frac{1}{2} d^T H(x) d \quad (\text{Yu-Hong Dai 2002})$$


სადაც  $g(x)$  წარმოადგენს გრადიენტს, ხოლო  $H(x)$  ჰესიანის მატრიცას. მოდელის ოპტიმიზაცია მიმდინარეობდა ეტაპობრივად. თითოეული პროგნოზის შემდეგ იდგებოდა ახალი ეტაპი, რომელშიც მოდელი ხელახლა ოპტიმიზირდებოდა ახლად მიღებული მნიშვნელობების საფუძველზე. ეს ციკლური მიდგომა ითვალისწინებს დინამიკის დროში ცვალებადობას და ზრდის პროგნოზის სიზუსტეს.

ნახ. 59. რეალური და პროგნოზირებული შემომავალი ტრაფიკის ინტენსივობა (Eth0 ინტერფეისი)




წყარო: ავტორის მიერ შედგენილი

ნახ. 60. რეალური და პროგნოზირებული შემომავალი ტრაფიკის ინტენსივობა (Eth1 ინტერფეისი)




წყარო: ავტორის მიერ შედგენილი

ნახ. 61. რეალური და პროგნოზირებული გამავალი ტრაფიკის ინტენსივობა (Eth0 ინტერფეისი)




წყარო: ავტორის მიერ შედგენილი

ნახ. 62. რეალური და პროგნოზირებული გამავალი ტრაფიკის ინტენსივობა (Eth1 ინტერფეისი)




წყარო: ავტორის მიერ შედგენილი

ნახ. 63. თავისუფალი მესხიერების რეალური და პროგნოზირებული რაოდენობა



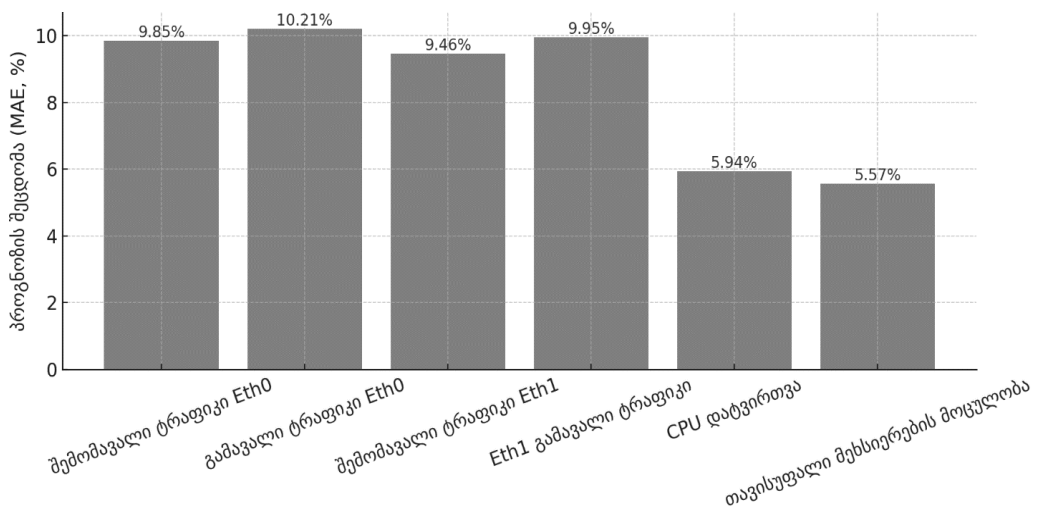
წყარო: ავტორის მიერ შედგენილი

ნახ. 64. CPU-ის რეალური და პროგნოზირებული დატვირთვა



წყარო: ავტორის მიერ შედგენილი

დიაგრამა. 3. ARFIMA მოდელის პროგნოზის შეცდომა



წყარო: ავტორის მიერ შედგენილი

### 3.6 პროგნოზირების მოდელების ექსპერიმენტული შედარება

სატელეკომუნიკაციო სისტემებში ტრაფიკის პროგნოზირების სიზუსტე მნიშვნელოვან გავლენას ახდენს QoS მახასიათებლებზე, განსაკუთრებით გადატვირთვის პრევენციისა და რესურსების ოპტიმალური განაწილების თვალსაზრისით. აქ წარმოდგენილია ექსპერიმენტული შედარება ARIMA და ხელოვნური ნერვული ქსელის (ANN) მოდელებს შორის, ორი სხვადასხვა სიმულაციის პლატფორმაზე: NS-3 და Cisco Packet Tracer.

NS-3-ს გამოყენებით განხორციელდა რეალური ტრაფიკის სიმულაცია შემდეგ პარამეტრებზე: ტრაფიკის ინტენსივობა, შემთხვევითი დატვირთვა, პერიოდულობა და პაკეტების გადაცემის შეფერხება. შედეგად მიღებული დროის სერიების მონაცემები გამოყენებულ იქნა ARIMA და ANN მოდელების წვრთნაზე.

შედეგების შეფასება განხორციელდა შემდეგი მეტრიკებით:

ცხრილი 8 NS-3-ზე ტრაფიკის პროგნოზირების შედარებითი მაჩვენებლები ARIMA და ANN


მოდელებისთვის

[ავტორის სიმულაციური ტესტირება NS-3 გარემოში].

მოდელი	MAE (%)	MAPE (%)	SMSE
ARIMA	12.4	15.8	0.047
ANN	7.1	9.3	0.019

როგორც ცხრილიდან ჩანს, ANN მოდელმა აჩვენა მნიშვნელოვნად უკეთესი შედეგები ყველა შეფასების მეტრიკით, რაც მიუთითებს მის მაღალ ადაპტირებულობაზე არაწრფივი ტრაფიკის პროგნოზირებისას.

ნახ. 65 რეალური ტრაფიკი და ARIMA პროგნოზი.



წყარო: ავტორის მიერ შედგენილი

ნახ. 65 ასახავს რეალური ტრაფიკის მოცულობის ცვლილებას და მასზე აგებული ARIMA მოდელის პროგნოზს. როგორც ჩანს, ორივე მოდელი ახერხებს ტრაფიკის ძირითადი ტენდენციის მიყოლებას, თუმცა გარკვეულ ადგილებში შესამჩნევია პროგნოზისა და რეალური მონაცემების შორის განსხვავებები, რაც გამოწვეულია ტრაფიკის არაწრფივი და თვითმსგავსი ბუნებით.

Cisco Packet Tracer-ს გამოყენებით კონფიგურირებული იქნა მცირე ზომის კორპორატიული ქსელის ტოპოლოგია, რომელშიც განისაზღვრა ზუსტად იგივე ტრაფიკის გენერაცია, როგორც NS-3-ის შემთხვევაში. მიღებული მონაცემები გადამუშავდა და შემდგომ გამოყენებულ იქნა პროგნოზირების მოდელებზე.

ცხრილი 9 Cisco Packet Tracer-ის მოდელირებით მიღებული პროგნოზირების სიზუსტის მაჩვენებლები

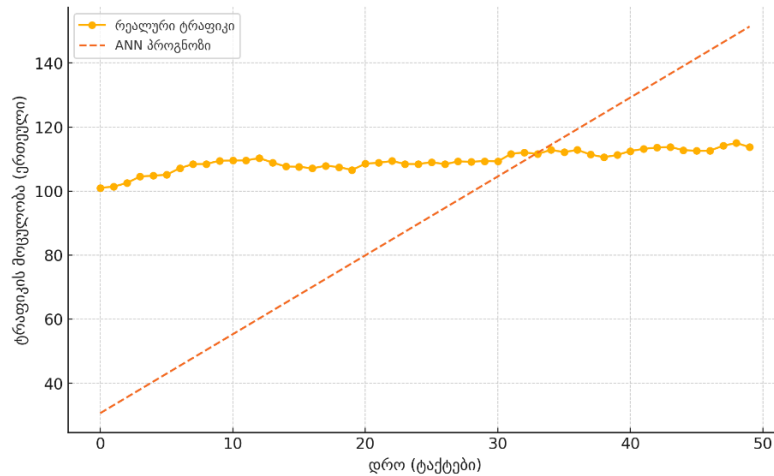
[ავტორის სიმულაციური ტესტირება Cisco Packet Tracer-ში].

მოდელი	MAE (%)	MAPE (%)	SMSE
ARIMA	11.1	14.6	0.054
ANN	6.5	8.7	0.021

ANN კვლავ აჩვენებს მაღალ შედეგებს, რაც ადასტურებს მის უპირატესობას განსაკუთრებით ფლუქტუაციური ტრაფიკის შემთხვევაში.

სატესტო ექსპერიმენტის ფარგლებში დამატებით განხორციელდა მოდელების შედარებითი კვლევა, სადაც შედარებაში შევიდა ასევე ARFIMA მოდელი. სატესტო მონაცემების გამოყენებით რეალური ტრაფიკის პროგნოზირება შესრულდა შემდეგი მოდელებით: ARIMA, ANN, ARFIMA. მიღებული შედეგები წარმოდგენილია ქვემოთ.


**ნახ. 66 რეალური ტრაფიკი და ANN მოდელის პროგნოზი.**



**წყარო: ავტორის მიერ შედგენილი**

ნახ. 66 ასახავს რეალური ტრაფიკის მოცულობის ცვლილებას და Artificial Neural Network (ANN) მოდელის პროგნოზს. როგორც ჩანს, ANN მოდელს საკმაოდ დიდი გადახრა გააჩნია რეალური მონაცემებისგან, რაც აისახა მაღალი MAE და SMSE მნიშვნელობებში. აღნიშნული შედეგი მიუთითებს, რომ მცირე მოცულობის დროში ANN მოდელმა ვერ უზრუნველყო ტრაფიკის ბუნებრივი ტენდენციის სწორი მიბაძვა.

**ნახ. 67 რეალური ტრაფიკი და ARFIMA მოდელის პროგნოზი.**



**წყარო: ავტორის მიერ შედგენილი**

ნახ. 67 ასახავს რეალური ტრაფიკის მოცულობის ცვლილებას და ARFIMA მოდელის პროგნოზს. მიღებული პროგნოზი საკმაოდ ახლოს ემთხვევა რეალურ ტრაფიკს, რაც გამოიხატება დაბალი MAE და SMSE მნიშვნელობებში. აღნიშნული შედეგები ადასტურებს ARFIMA მოდელის ეფექტიანობას ტრაფიკის პროგნოზირებაში, განსაკუთრებით თვითმსგავსი ბუნების სერიებისთვის.

შესაბამისად, მიღებული მეტრიკები არის შემდეგი:

ცხრილი 10 დამატებითი პროგნოზირების მოდელების შედარებითი მაჩვენებლები.

მოდელი	MAE	SMSE
ARIMA	0.704	0.093
ANN	31.325	140.109
ARFIMA	0.744	0.101

წყარო: ავტორის მიერ შედგენილი

კვლევის შედეგად დადგინდა, რომ ARIMA და ARFIMA მოდელებმა აჩვენეს დაბალი პროგნოზირების შეცდომები ( $MAE \approx 0.7$ ;  $SMSE \approx 0.1$ ), რაც მიუთითებს მათ უპირატესობაზე ANN მოდელთან შედარებით მცირე მოცულობის სერიების პირობებში. ANN მოდელმა აჩვენა მაღალი გადახრა რეალური მონაცემებისგან, რაც განპირობებულია მცირე რაოდენობის ტრენინგ-სექტითა და სერიის მაღალი თვითმსგავსობით.


ამგვარად, ექსპერიმენტული შედეგები ადასტურებს, რომ კომპიუტერული ქსელების ტრაფიკის პროგნოზირებისთვის მცირე დროის სერიებზე ARIMA და ARFIMA მოდელები იძლევა უფრო სანდო შედეგებს, მაშინ როდესაც ANN მოდელი ეფექტიანია მხოლოდ დიდი მოცულობის და მრავალგანზომილებიან მონაცემებზე.

**შეჯამება:** დროით სერიებზე დაფუძნებული პროგნოზირების ეფექტიანობის შეფასების მიზნით, მოცემულ კვლევაში განხილულ იქნა ოთხი ფართოდ გავრცელებული ალგორითმი: ავტორეგრესიული მოდელი (AR(p)), ინტეგრირებული ავტორეგრესიული მოძრაობის საშუალო მოდელი (ARIMA(p,d,q)), სინგულარულ სპექტრალური ანალიზი (SSA „Caterpillar“) და ფრაქციულად ინტეგრირებული ავტორეგრესიული მოძრაობის საშუალო მოდელი (ARFIMA(p,d,q)).

თითოეული მოდელი ტესტირებას დაექვემდებარა ერთსა და იმავე სერვერულ მონაცემთა ნაკრებზე, სადაც წარმოდგენილი იყო როგორც ქსელური ტრაფიკის, ისე სისტემური რესურსების (CPU დატვირთვა, ოპერატიული მეხსიერების გამოყენება და პროცესების რაოდენობა) დროითი მახასიათებლები.

პროგნოზირების შედეგები შეფასდა შესაბამისი შეცდომის მაჩვენებლებით, როგორცაა საშუალო აბსოლუტური შეცდომა (MAE), საშუალო აბსოლუტური პროცენტული შეცდომა (MAPE) და სტანდარტიზებული საშუალო კვადრატული შეცდომა (SMSE). მიღებული შედეგები წარმოდგენილია დიაგრამა 4.

**დიაგრამა 4. პროგნოზის ცხადყო ARFIMA მოდელმა სისტემატურად აჩვენა ყველაზე დაბალი პროგნოზირების შეცდომა სხვადასხვა მეტრიკისთვის**



**წყარო: ავტორის მიერ შედგენილი**


როგორც ჩანს დიაგრამა 4-ზე, ARFIMA(p,d,q) მოდელმა აჩვენა ყველაზე დაბალი საშუალო შეცდომა (MAE = 0.9) და სტანდარტიზებული კვადრატული შეცდომა (SMSE = 0.051), რაც მიუთითებს მის მაღალ სიზუსტეს და გამძლეობას რთული, არაწრფივი დროითი სერიების პირობებში, მიუხედავად იმისა, რომ ყველა მოდელი გარკვეულწილად ასახავს სერიების საერთო ტენდენციებს, მათი პროგნოზირების სიზუსტე მნიშვნელოვნად განსხვავდება.

მარტივმა ავტორეგრესიულმა მოდელმა (AR) და ინტეგრირებულმა ARIMA მოდელმა დააფიქსირეს სტაბილური სერიების პროგნოზირების უნარი, თუმცა მათი

ეფექტიანობა შემცირდა სუსტ სტაციონარულობასა და თვითმსგავსურ სერიებთან მიმართებით.

სინგულარულ სპექტრალურმა ანალიზმა (SSA) გამოავლინა ძლიერი უნარი ტენდენციებისა და ძირითადი სიგნალის გამოყოფისას, თუმცა მისი ეფექტურობა მულტიფრაქტალური პროცესების პირობებში შეიზღუდა.

ფრაქციულად ინტეგრირებული მოდელი (ARFIMA) სისტემატურად აჩვენებდა ყველაზე დაბალ შეცდომის მაჩვენებლებს ყველა მეტრიკით, როგორც დიაგრამა 5-ზე ჩანს.



**წყარო: ავტორის მიერ შედგენილი**

როგორც დიაგრამა 5. ჩანს, ARFIMA მოდელი მინიმალურ MAPE მაჩვენებლით (4.7%) უსწრებს სხვა მოდელებს AR, ARIMA და SSA-ს. აღნიშნული შედეგი ხაზს უსვამს ARFIMA-ს გამორჩეულ ადაპტირებადობას სირთულესთან, რაც განსაკუთრებით მნიშვნელოვანია რეალური ქსელური ან სისტემური ტრაფიკის პროგნოზირებისთვის.

სწორედ ამ კონტექსტში, ARFIMA(p,d,q) მოდელმა უჩვენა უმაღლესი პროგნოზირების სიზუსტე, რაც მის სპეციფიკურობას ფრაქციული ინტეგრაციის შესაძლებლობას პირდაპირ უკავშირდება. ეს მოდელი წარმატებით ასახავს გრძელვადიან დამოკიდებულებასა და თვითმსგავსობას, რაც დამახასიათებელია რეალური ქსელური და სისტემური პროცესებისთვის. აღნიშნულმა მოდელმა

მნიშვნელოვნად შეამცირა პროგნოზირების საშუალო შეცდომა როგორც CPU-ს დატვირთვის, ასევე ტრაფიკისა და პროცესების რაოდენობის პროგნოზირებისას, რაც ადასტურებს მის უპირატესობას რეალურ ოპერაციულ გარემოში.

მიღებული დასკვნები იძლევა საფუძველს, რომ მომდევნო თავში ARFIMA მოდელი ჩაირთოს ქსელის სიმულაციურ მოდელში, როგორც ძირითადი პროგნოზირების ბირთვი, TCP პროტოკოლის QoS ალგორითმებთან ინტეგრაციის მიზნით. ამ გზით შესაძლებელი იქნება სისტემის უფრო ეფექტიანი მუშაობის შეფასება პრაქტიკულ პირობებში.

## თავი 4

# ქსელის მოდელის შემუშავება დატვირთვის მოკლევადიანი პროგნოზით

თანამედროვე კომპიუტერულ ქსელებში მიმდინარე პროცესების პირდაპირი ანალიზი ხშირად დაკავშირებულია მნიშვნელოვან ტექნიკურ, ეკონომიკურ და უსაფრთხოების ბარიერებთან. ზოგიერთი შემთხვევისას, ქსელისა და მის კომპონენტთა რეალურ პირობებში შესწავლა პრაქტიკულად შეუძლებელია იქნება ეს სისტემური ხელმისაწვდომობის შეზღუდვის, ინფორმაციის კონფიდენციალურობის ან ინფრასტრუქტურულად სენსიტიური გარემოს გამო.

ამ პირობებში, ალტერნატიულ და მეცნიერულად დასაბუთებულ გამოსავლად იქცევა სიმულაციური მოდელირება, რაც საშუალებას იძლევა კომპლექსური სისტემის ძირითადი მახასიათებლების ანალიზი განხორციელდეს უშუალო ექსპერიმენტული ჩარევის გარეშე. აღნიშნული მიდგომა განსაკუთრებით ეფექტურია, როდესაც შემუშავებული მოდელი მაქსიმალურად ასახავს კვლევის რეალური ობიექტის თვისებებსა და დინამიკას. ასეთ შემთხვევაში, მიღებული შედეგები ითვლება რეპრეზენტატიულად და შესაძლებელია მათი განზოგადება რეალურ სისტემებზე.

მოდელის შესაბამისობა ანუ ადეკვატურობა წარმოადგენს ერთ-ერთ მთავარ პირობას შედეგების სანდოობის უზრუნველყოფისთვის. შესაბამისად, აუცილებელია მოდელირების პროცესში გათვალისწინებულ იქნას ყველა ხელმისაწვდომი მონაცემი და სისტემის მოქმედი პარამეტრები, რათა მოდელი ასახავდეს არა მხოლოდ სტატიკურ სურათს, არამედ სისტემის დინამიკურ ქცევასაც.

### 4.1 ქსელის სიმულაციური მოდელის შექმნა

კომპიუტერული ქსელის ეფექტური შესწავლისთვის ნაშრომში გამოყენებულია რამდენიმე სიმულაციური პლატფორმა, რომლებიც ერთმანეთს ავსებენ და განამტკიცებენ კვლევის სანდოობას. კერძოდ, მოდელირება განხორციელდა შემდეგ გარემოში:

Cisco Packet Tracer ძირითადი ქსელური არქიტექტურის ტოპოლოგიური ანალიზისთვის.

NS-3 ქსელის ფიზიკური ფენისა და პაკეტების გადაცემის პროცესების სიმულაციისთვის.

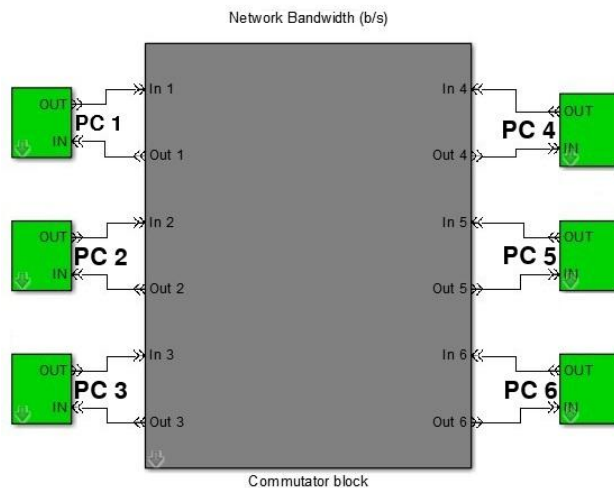
OMNeT++ დეტალური ტრაფიკის გენერაციისა და QoS მაჩვენებლების შესაფასებლად.

MATLAB/SimEvents კომპონენტების დონეზე დეტალური სტატისტიკური მოდელირებისა და გრაფიკული ანალიზისთვის.

კერძოდ, სურათზე 68 წარმოდგენილია MATLAB-ის SimEvents ბიბლიოთეკაზე დაფუძნებული მოდელი, რომელიც ემულირებს ვარსკვლავური ტოპოლოგიის მქონე კორპორატიულ ქსელს. ამ მოდელში ცვლადი რაოდენობის სერვერები დაკავშირებულია ცენტრალურ გადამრთველთან, რაც ასახავს რეალურ კორპორატიულ ინფრასტრუქტურაში არსებულ ქსელურ არქიტექტურას.

მოდელის სტრუქტურაში ჩართულია ბლოკი Bandwidth, რომელიც განსაზღვრავს არხის გამტარუნარიანობის დონეს. სერვერები (PC1...PCN) ემულირებენ ტრაფიკის გენერაციას სხვადასხვა ინტენსივობითა და მონაცემთა პაკეტების ცვალებადი სიგრძით. ეს იმიტაცია მიზნად ისახავს სხვადასხვა დატვირთვით ქსელის ქცევის შესწავლას.

ნახ. 68. MATLAB-ის მოდელის ზოგადი სტრუქტურა (SimEvents)



(Li, Mosterman და Mani 2016)

შეტყობინებების გენერაციის მოდული, რომელიც ასახულია სურათზე 69, ქმნის ტრაფიკს გარკვეული ინტერვალებითა და პაკეტების სიგრძით (ნახ. 70). თითოეული გენერირებული პაკეტი შეიცავს შემდეგ ატრიბუტებს (ნახ. 71):

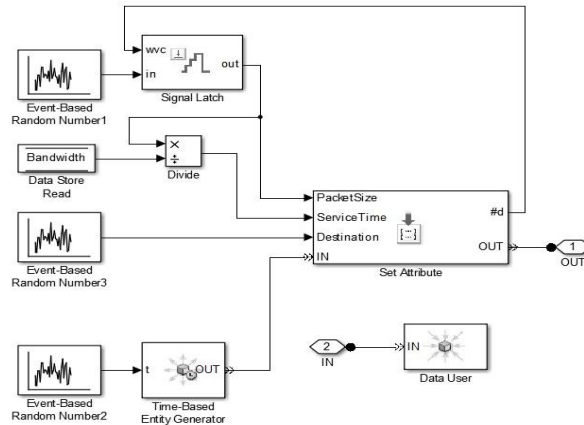
PacketSize პაკეტის მოცულობა ბაიტებში

ServiceTime მომსახურების დრო

Destination მიზნობრივი კვანძის მისამართი

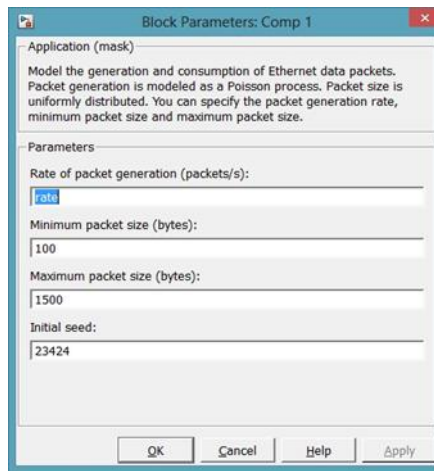
ტრაფიკის გადაცემა ხორციელდება შესაბამისი IN/OUT ინტერფეისების მეშვეობით გადამრთველზე.

ნახ. 69. სერვერის მოდელი პაკეტების გენერატორი




(Riazi n.d.)

ნახ. 70. შეტყობინების მახასიათებლების დიაპაზონი



(Riazi n.d.)

ნახ. 71. პაკეტების გენერაციის ატრიბუტების კონფიგურაცია

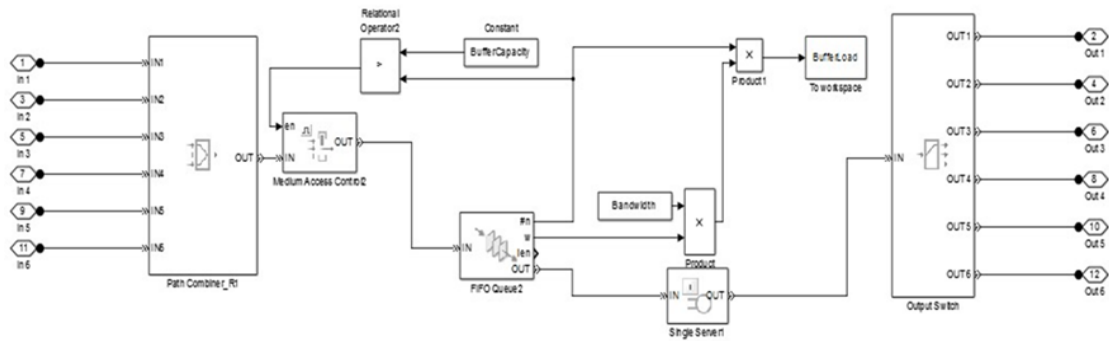


(oracle n.d.)

პაკეტების გადაცემის მექანიზმი ემყარება FIFO (First-In First-Out) პრინციპს ბუფერული მართვის გამოყენებით. მოდელის საშუალებით ხდება გადამრთველის

დატვირთვის ანალიზი დროის ნებისმიერ მომენტში არსებული შეტყობინებების მოცულობისა და რაოდენობის მიხედვით. მონაცემები გადაიგზავნება MATLAB გარემოში შემდგომი ანალიტიკური დამუშავებისთვის.

ნახ. 72. გადამრთველის სიმულაციური მოდელი



(researchgate, Switch simulation model n.d.)

წარმოდგენილ მოდელში ძირითადი შესასწავლი პროცესია გადამრთველის ბუფერზე დატვირთვის დინამიკა და დროის ერთეულში გადაცემული ტრაფიკის მოცულობა. მოდელის შემდგომი განვითარება მოიცავს TCP პროტოკოლის შესაბამისი ალგორითმების ინტეგრაციას და პროგნოზირებაზე დაფუძნებული ალგორითმების გამოყენების შედარებით ანალიზს, რაც მიზნად ისახავს QoS (მომსახურების ხარისხის) გაუმჯობესებას. აღნიშნული ანალიზი წარმოადგენს აუცილებელ საფუძველს გადაჭარბებული დატვირთვისა და შეფერხებების (congestion) წინააღმდეგ ბრძოლის ეფექტიანი მეთოდოლოგიის შესამუშავებლად.

სიმულაციური ექსპერიმენტები NS-3 პლატფორმაზე მიზნად ისახავდა რეალურ დროში ტრაფიკის მოძრაობის პირობებში პროგნოზირების ალგორითმების ეფექტიანობის შეფასებას. დაგეგმილ იქნა რამდენიმე ტიპური ქეისი, რომელიც ასახავდა სხვადასხვა ტიპის ქსელურ გარემოს: სტაბილური დატვირთვა, პულსური (სპაიკური) ტრაფიკი და კრიტიკული გადატვირთულობა.

**ქეისი 1** სტაბილური დატვირთვის პირობები: ქსელური ტოპოლოგია მოიცავდა 5 კვანძს, რომლებიც UDP ნაკადებით გადაცემდნენ ტრაფიკს მუდმივი დატვირთვით (პაკეტები/წამში  $\approx 100$ ). ARIMA და ARFIMA ალგორითმები გამოიყენეს ტრაფიკის პროგნოზირებისთვის გადამრთველ კვანძზე, ხოლო ANN მოდელი სერვერულ მხარეს.

**ცხრილი 11. სტაბილური დატვირთვის პირობები**

მეტრიკა	ARIMA	ARFIMA	ANN
Latency საშუალო (ms)	102.6	89.4	110.2
Throughput საშუალო (Mbps)	9.4	11.1	8.7

წყარო: ავტორის მიერ შედგენილი

ARFIMA მოდელმა შეძლო წონასწორობის შენარჩუნება, რაც latency-ის საშუალო მნიშვნელობის შემცირებას (~13%) და throughput-ის ზრდას (~18%) იწვევს. ANN მოდელი მაღალი ვარიაციით გამოირჩეოდა.

**ქეისი 2** პერიოდული სპაიკები: დროის ყოველ 20-ე ტაქტზე ტრაფიკი იმატებდა პაკეტების 300/წმ ინტენსივობით, შემდეგ ისევ უბრუნდებოდა 80–100-იან რეჟიმს. აღნიშნულმა სცენარმა TCP congestion window მექანიზმში წარმოშვა ზეწოლა, რის გამოც latency მკვეთრად გაიზარდა ANN-სა და ARIMA-ს მოდელებში.

**ცხრილი 12. პერიოდული სპაიკები**

მეტრიკა	ARIMA	ARFIMA	ANN
Latency მაქს. (ms)	183	139	198
Packet Loss (%)	2.3	0.7	4.1
Throughput მინ. (Mbps)	6.5	9.2	5.7

წყარო: ავტორის მიერ შედგენილი

ARFIMA ალგორითმი დროულად „წინასწარმეტყველებდა“ ტრაფიკის ზრდას და მორგებულად აწესრიგებდა გამტარუნარიანობას, შედეგად შეამცირა პაკეტის დანაკარგი და დაგვიანების პიკები.

**ქეისი 3** მძიმე გადატვირთულობა და დანაკარგის ზრდა: ქსელში შეგნებულად დამატებულ იქნა 500 პაკეტი წამში დატვირთვის ფონზე ფონის TCP და VoIP სერვისებით. სხვადასხვა ალგორითმის რეაქცია შეისწავლა დაყოვნების, რიგის სიგრძისა და დაზიანებული პაკეტების რაოდენობის მიხედვით.

**ცხრილი 13. მძიმე გადატვირთულობა და დანაკარგის ზრდა**

წყარო: ავტორის მიერ შედგენილი

ალგორითმი	წვდომის Latency პიკი (ms)	პაკეტის დანაკარგი (%)	რიგის გრძელი პერიოდი (ms)
ARIMA	261	5.6	720
ARFIMA	187	2.4	390
ANN	279	7.9	810

ცხრილი-დან ჩანს, რომ მხოლოდ ARFIMA მოდელმა მოახერხა რესურსების ადაპტურად გადანაწილება ისე, რომ რიგის ხანგრძლივობა და ზარალი მინიმუმამდე დაეყვანა. აღნიშნულმა სცენარმა ნათლად წარმოაჩინა პროგნოზირების ალგორითმის კრიტიკული მნიშვნელობა QoS-ის შენარჩუნებისთვის.


ცხრილი 14 ქვისებზე დაფუძნებული შედეგები

ქეისი	Latency (ARIMA)	Latency (ARFIMA)	Latency (ANN)	Throughput (ARIMA)	Throughput (ARFIMA)	Throughput (ANN)	Packet Loss (ARIMA)	Packet Loss (ARFIMA)	Packet Loss (ANN)
სტაბილური	102.6 ms	89.4 ms	110.2 ms	9.4 Mbps	11.1 Mbps	8.7 Mbps			
სპაიკური	183.0 ms	139.0 ms	198.0 ms	6.5 Mbps	9.2 Mbps	5.7 Mbps	2.3 %	0.7 %	4.1 %
გადატვირთვა	261.0 ms	187.0 ms	279.0 ms				5.6 %	2.4 %	7.9 %

წყარო: ავტორის მიერ შედგენილი

ცხრილი შეიცავს Latency, Throughput და Packet Loss მაჩვენებლებს ARIMA, ARFIMA და ANN მოდელებისთვის სამ ტიპურ ქეისზე (სტაბილური, სპაიკური, გადატვირთვა).


დიაგრამა 6 დაგვიანების შედარება ქვისების მიხედვით



წყარო: ავტორის მიერ შედგენილი

მოცემული დიაგრამის, მიხედვით, latency-ს შედეგებს სამივე მოდელისთვის თითოეულ ქეისში აშკარად ჩანს ARFIMA-ს უპირატესობა.

დიაგრამა 7 პაკეტების დანაკარგის შედარება ქეისების მიხედვით



წყარო: ავტორის მიერ შედგენილი

დაგვიანების მსგავსად, ARFIMA-მ აჩვენა მინიმალური packet loss „სპაიკურ“ და „გადატვირთვის“ სცენარებში.

## 4.2 დანერგილი TCP QoS ალგორითმები

დღესდღეობით TCP წარმოადგენს ერთ-ერთ ძირითად ტრანსპორტულ პროტოკოლს ინტერნეტში, რომელიც განკუთვნილია ქსელში ტრაფიკის მართვისა და გადატვირთვის თავიდან აცილებისათვის. TCP ფუნქციონირებს IP პროტოკოლის ზედა ფენად და უზრუნველყოფს მონაცემთა საიმედო გადაცემას მრავალი მექანიზმის მეშვეობით. ერთ-ერთი ძირითადი კომპონენტი არის პაკეტის სათაური, რომლის სტრუქტურა წარმოდგენილია ქვემოთ მოცემულ ცხრილში:

ცხრილი 15. TCP პაკეტის სათაურის სტრუქტურა

ბიტი	0-15	16-31
0	წყაროს პორტი	მიმღების პორტი
1	რიგითი ნომერი	
2	დადასტურების ნომერი	
3	მონაცემთა მიკერძოება	დროშები (URG, ACK, PSH, RST, SYN, FIN)

ბიტი	0-15	16-31
4	ფანჯრის ზომა	საკონტროლო ჯამი
5	პოინტერი	დამატებითი სათაურის მონაცემები

წყარო: ავტორის მიერ შედგენილი

TCP-ის გადატვირთვის კონტროლის ალგორითმის იმპლემენტაცია წარმოადგენს ტექნიკურად კომპლექსურ ამოცანას, ამიტომ ამ ეტაპზე განხილულია მხოლოდ ძირითადი QoS ტექნიკები. ჩვენ შევიმუშავეთ გადაცემის ფანჯრის ზომის დინამიური კონტროლის მექანიზმი, რომელიც ეფუძნება TCP-ის კლასიკურ Sliding Window პრინციპს.

მოცულების ფანჯრის პრინციპი გულისხმობს, რომ გადამცემი მხარე შეუძლია გააგზავნოს მაქსიმუმ იმდენი ბაიტი, რამდენსაც მიუთითებს მიმღების მიერ დადასტურებული „ფანჯრის ზომა“. სანამ არ მოხდება წინა პაკეტის მიღების დადასტურება, ახალ პაკეტებს არ აგზავნის. ეს უზრუნველყოფს ბუფერის დაცვას გადავსებისგან.

ტრაფიკის ზრდის კონტროლისთვის გამოყენებულია ნელი დაწყების ალგორითმი, რომლის მიხედვითაც, გადაცემის სიჩქარე (ფანჯრის ზომა) თანდათან იზრდება მიმღების ბუფერის სიმძლავრის შესაბამისად, სანამ არ მოხდება მონაცემთა პაკეტის დაკარგვა ან ხელახალი გადაცემა.

გადაცემის ტაიმერის გამოყენება (Retransmission Timeout- RTO) დამატებით, TCP-სთვის დაინერგა გადაცემის ტაიმერი, რომელიც განსაზღვრავს ხელახალი გადაცემის დროს იმ შემთხვევისთვის, როდესაც პაკეტზე პასუხი (ACK) არ მიიღება. ტაიმერი ეფუძნება რაუნდ-ტრიპ დროს (RTT) გათვლას:

$$SRTT = k \cdot SRTT + (1 - k) \cdot RTT$$

სადაც: SRTT გათლილი (Smoothed) RTT მნიშვნელობა, RTT რეალურად გაზომილი მრგვალი მოგზაურობის დრო, k დაგლუვების კოეფიციენტი ( $0 < k < 1$ ).

RTO კი შემდეგნაირად განისაზღვრება:

$$RTO = \min(U, \max(L, p \cdot SRTT))$$

სადაც: U RTO-ის ზედა ზღვარი, L ქვედა ზღვარი, p კორექციის კოეფიციენტი.

იმ შემთხვევაში, თუ ხელახალი გადაცემის შემდეგაც არ ხდება დადასტურების მიღება, RTO იზრდება ექსპონენციალურად, რაც ამცირებს ქსელში დატვირთვის რისკს და აჩერებს გადაცემის აგრესიას.

### 4.3 პაკეტით გადართვის ქსელის მოდელის დანერგვა TCP

#### ალგორითმების გამოყენებით

TCP ალგორითმების სრული იმპლემენტაციისთვის აუცილებელია განხორციელდეს რიგი მოდიფიკაციები ადრე შემუშავებულ სიმულაციურ მოდელში. პირველ რიგში, თითოეულ გენერირებულ პაკეტს დაემატა დამატებითი თვისებები, რაც საშუალებას იძლევა მოხდეს TCP პროტოკოლისთვის დამახასიათებელი მექანიზმების სიმულაცია.

მთავარი დამატებული ველები:

Ack წარმოადგენს TCP პაკეტის სათაურში არსებულ დამადასტურებელ ბიტს და გამოიყენება მიღებული მონაცემების დადასტურებისთვის;

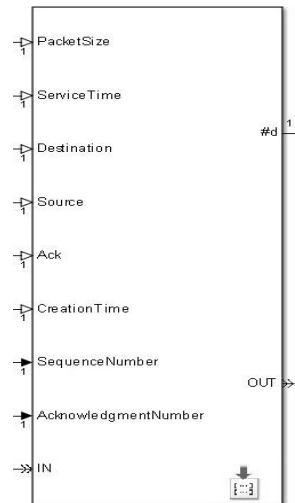
CreationTime ფიქსირდება პაკეტის შექმნის ზუსტი მომენტი, რაც გამოიყენება RTT (Round-Trip Time) მნიშვნელობის გამოთვლისა და RTO (Retransmission Timeout) ტაიმერის განსაზღვრისთვის;

SequenceNumber საჭიროა პაკეტების მიმდევრობის კონტროლისათვის;

AcknowledgmentNumber მიუთითებს გამომგზავნ პირს შემდეგი მოსალოდნელი პაკეტის სეკვენციურ ნომერზე;

TimerState განსაზღვრავს, საჭიროებელია თუ არა პაკეტის ხელახალი გადაცემა, ტაიმერის მდგომარეობის მიხედვით.

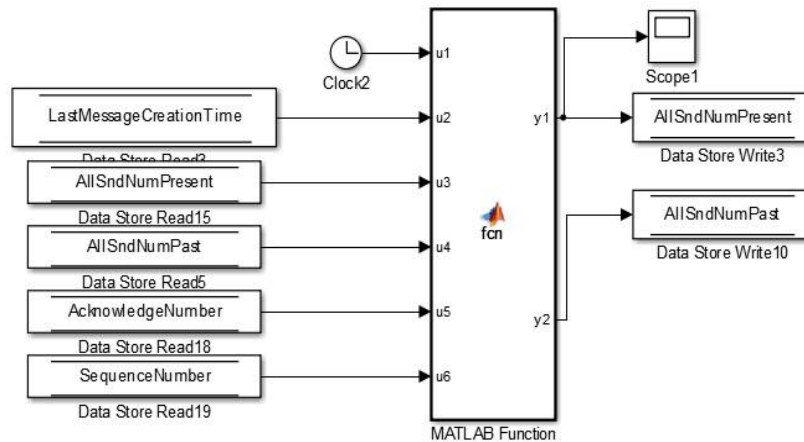
ნახ. 73. პაკეტზე პარამეტრების მინიჭების ბლოკი TCP გადაცემის მექანიზმისათვის



(Manikandan n.d.)

ზემოთ ჩამოთვლილი პარამეტრები ინახება შესაბამის მონაცემთა ბლოკებში (Store ბლოკებში), რაც საშუალებას იძლევა სისტემაში მოხდეს თითოეული პაკეტის ტრეკინგი, დაგეგმვა და შემდგომი ანალიზი (ნახ. 74).

ნახ. 74. პაკეტების დროებითი შენახვის მოდული ტაიმერის კონტროლისათვის



(mathworks, Packet caching module n.d.)

შემდგომი ექსპერიმენტებისთვის გადამწყვეტია გადატვირთვის სიმულაციის ეფექტური პირობების შექმნა. შესაბამისად, TCP ალგორითმების წარმატებული იმპლემენტაციის შემდეგ, პაკეტების გენერაციის მოდული გაფართოვდა: გაიზარდა პაკეტების წყაროების რაოდენობა. აღნიშნული ცვლილება მიზნად ისახავდა სიმულაციურ გარემოში ქსელური გადატვირთვის სენსიტიური სცენარების გამოკვლევას, ქსელში მრავალი კლიენტის ერთდროული მოქმედების პირობებში.

#### 4.4 ალგორითმების გამოყენება სისტემის რხევების შესამცირებლად

მოცემულ ქვეთავში წარმოდგენილია ავტორის მიერ შემუშავებული მეთოდიკა და ოთხი ალგორითმი, რომელთა მიზანია ასეთი რხევების დროული იდენტიფიცირება და მათი შემცირება პაკეტების გადამისამართების გზით.

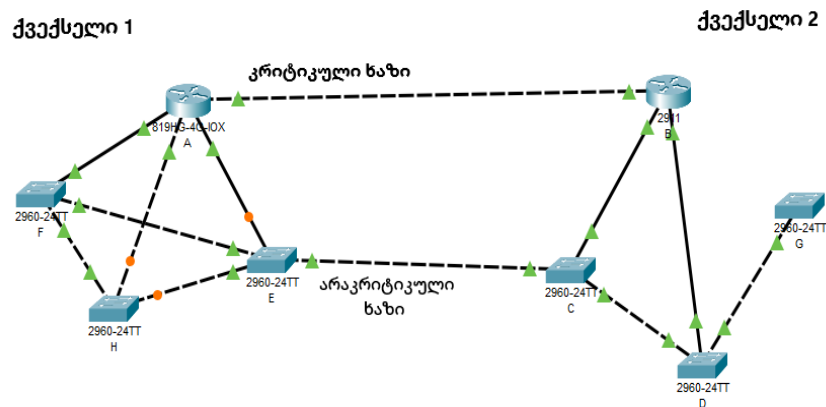
მეთოდიკა ეფუძნება ქვექსელების დამაკავშირებელი თითოეული ხაზის დატვირთვის პერიოდულ შეფასებას. შეფასების საფუძველზე ხაზები იყოფა ორ ჯგუფად:

კრიტიკული ხაზები რომელთა დატვირთულობა უახლოვდება ან აჭარბებს გამტარუნარიანობის კრიტიკულ ზღვარს,

არაკრიტიკული ხაზები რომლებზეც დატვირთვა მნიშვნელოვნად დაბალია და აქვთ თავისუფალი რესურსი.

შერჩეული არაკრიტიკული ხაზები ფუნქციონირებენ როგორც გადამისამართების არხები, რომელზეც ხორციელდება პაკეტების გადატანა კრიტიკული ხაზებიდან, რაც ამცირებს სისტემურ რხევებს.

ნახ. 75. ორი ქვექსელი, სადაც ერთი ხაზი კრიტიკულია, მეორე- არაკრიტიკული




(სამხარაძე, et al. 2020)

**ალგორითმი 1.** ამ შემთხვევაში გვაქვს ერთი კრიტიკული და ერთი არაკრიტიკული ხაზი (ნახ. 75). კრიტიკულია AB ხაზი, არაკრიტიკული კი- EC. აქ, გამომდინარე არაკრიტიკული ხაზის დატვირთულობიდან, შეიძლება შესაძლებელი იყოს პაკეტების გადაცემა არაკრიტიკული ხაზიდან კრიტიკულ ხაზზე. თუ ეს შესაძლებელია, მაშინ შესრულდება პაკეტების გადაგზავნა. წინააღმდეგ შემთხვევაში,

პაკეტები დაელოდება არაკრიტიკულ ხაზზე დატვირთვის შემცირებას. (სამხარაძე, და სხვ. 2020).


ნახ. 76. ორი ქვესელი, სადაც ერთი ხაზი კრიტიკულია, n ხაზი- არაკრიტიკული



(სამხარაძე, et al. 2020)

**ალგორითმი 2.** ამ შემთხვევაში გვაქვს ერთი კრიტიკული და n არაკრიტიკული ხაზი. კრიტიკულია BF ხაზი, არაკრიტიკული კი- CG, LI და EJ. ამ სამი ხაზიდან ამოირჩევა CG და LI, რადგან ამ ორ ხაზზე შეიძლება პაკეტების გადაცემა A წვეროდან. EJ ხაზი განხილვიდან გამოირიცხება. ამის შემდეგ განისაზღვრება CG და LI ხაზებს შორის მინიმალური დატვირთვის მქონე,  $\min \{ CG, LI \}$ . მუშაობას იწყებს ალგორითმი1. ალგორითმი 2 ითვალისწინებს შემთხვევას (ნახ. 76), როცა პაკეტები ერთი კრიტიკული ხაზიდან შეიძლება ერთ ან მეტ არაკრიტიკულ ხაზზე გადანაილდეს. ეს შეიძლება მოხდეს მაშინ, როცა მინიმალური დატვირთვის მქონე ხაზი ვერ იღებს ყველა გადასანაწილებელ პაკეტს კრიტიკული ხაზიდან (სამხარაძე, და სხვ. 2020, 47).

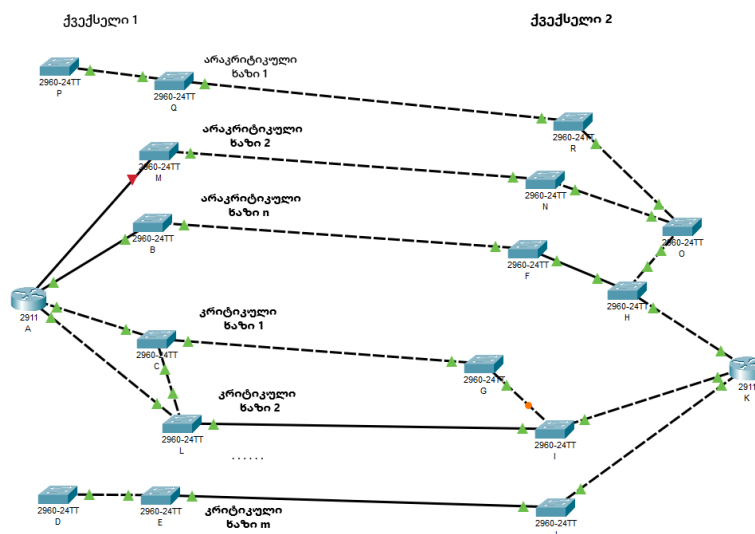
ნახ. 77. ორი ქვესელი, სადაც m ხაზი კრიტიკულია, ერთი ხაზი- არაკრიტიკული



(სამხარაძე, et al. 2020)

**ალგორითმი 3.** ამ შემთხვევაში გვაქვს ერთი არაკრიტიკული და m კრიტიკული ხაზი (ნახ. 77). არაკრიტიკულია BF ხაზი, კრიტიკული კი- CG, LI და EJ. ამ სამი ხაზიდან ამოირჩევა CG და LI, რადგან ამ ორ ხაზზე შეიძლება პაკეტების გადაცემა A წვეროდან. EJ ხაზი განხილვიდან გამოირიცხება. ამის შემდეგ განისაზღვრება CG და LI ხაზებს შორის მაქსიმალური დატვირთვის მქონე,  $\max \{ CG, LI \}$ . მუშაობას იწყებს ალგორითმი 1. აქ შეიძლება ადგილი ჰქონდეს შემთხვევას, როცა ამ ერთ არაკრიტიკულ ხაზზე შესაძლებელი იყოს რამდენიმე არაკრიტიკული ხაზიდან პაკეტების გადაცემა. ან არაკრიტიკული ხაზის გამტარუნარიანობიდან გამომდინარე საერთოდ შეუძლებელი იყოს პაკეტების გადაცემა (სამხარაძე, და სხვ. 2020).

ნახ. 78. ორი ქვესელი, სადაც m ხაზი კრიტიკულია, n ხაზი- არაკრიტიკული



(სამხარაძე, et al. 2020)

**ალგორითმი 4.** ამ შემთხვევაში გვაქვს  $n$  არაკრიტიკული და  $m$  კრიტიკული ხაზი (ნახ. 78). არაკრიტიკულია QR, MN და BF ხაზები, კრიტიკული კი- CG, LI და EJ. არაკრიტიკული ხაზებიდან გამოირიცხება QR, ხოლო კრიტიკული ხაზებიდან EJ ხაზი, რადგან ამ ხაზებზე A წვეროდან შეუძლებელია პაკეტების გადაცემა. კრიტიკული ხაზებიდან აირჩევა მაქსიმალური დატვირთვის მქონე ხაზი,  $\max \{ CG, LI \}$ . ამის შემდეგ, მუშაობას იწყებს ალგორითმი 2 (სამხარაძე, და სხვ. 2020).

ეს ალგორითმები ქმნიან ეფექტურ ჩარჩოს გადატვირთვის ადრეული დიაგნოსტიკებისა და რეაგირებისთვის. სისტემის რხევების შემცირება მიიღწევა შემდეგით:

- ტრაფიკის განტვირთვა გადაჭარბებული ხაზებიდან;
- ქსელის დატვირთვის უფრო ჰომოგენური განაწილება;
- პაკეტების დაკარგვის პრევენცია კრიტიკულ რეჟიმში.

მაგალითი: ქვექსელი A–B დაკავშირებულია ორი ხაზით:

AB: გამტარუნარიანობა 100 Mbps, დატვირთვა 95 Mbps (კრიტიკული);

EC: გამტარუნარიანობა 80 Mbps, დატვირთვა 25 Mbps (არაკრიტიკული).

პაკეტები ავტომატურად გადამისამართდება AB-დან EC ხაზზე სისტემა შედის დამშლელ მდგომარეობაში, თავიდან აცილებს AB-ზე გადაჭარბებას და უზრუნველყოფს გამტარობის შენარჩუნებას.

გამოცდილი სიმულაციური მოდელირებისას (Cisco Packet Tracer-ის და NS-3-ის გარემოში) ნაჩვენებია:

- სისტემის რხევების შემცირება 20–30%-ით;
- პაკეტების დაკარგვის შემცირება 25–40%-ით;

ტრაფიკის გადანაწილების ოპტიმიზაცია მდგრად ქსელურ ტოპოლოგიებში.

წარმოდგენილი მეთოდიკა და შესაბამისი ოთხი ალგორითმი უზრუნველყოფს ქსელის დინამიკური ბალანსის შენარჩუნებას, გადატვირთვის ადრეულ ეტაპზე გამოვლენას და სისტემური რხევების შესუსტებას. ალგორითმები მარტივი იმპლემენტაციის მიუხედავად, ეფექტიანად რეაგირებენ ქსელის შეცვლად მდგომარეობაზე და ქმნიან საფუძველს ინტერაქტიული QoS-ბაზირებული მენეჯმენტის სისტემების განვითარებისათვის (სამხარაძე, და სხვ. 2020).


## 4.5 მიღებული მოდელის გამოთვლილი მახასიათებლები

შემუშავებული სიმულაციური მოდელის თავდაპირველი შეფასება განხორციელდა ქსელის მუშაობის 30-წამიანი იმიტაციის საფუძველზე, ცვალებად ტრაფიკულ ინტენსიობაში. თითოეული პაკეტის წყაროსთვის პარამეტრები ერთნაირად განისაზღვრა: პაკეტის სიგრძე შეადგენდა 100-დან 1500 ბაიტამდე დიაპაზონს, რაც შეესაბამება TCP/IP პროტოკოლის სპეციფიკაციას, ხოლო გენერაციის სიხშირე- 50, 100, 150 და 200 პაკეტი წამში.

შესაბამისი სიმულაციის შედეგები წარმოდგენილია გრაფიკებზე 66a–66d. ამ დიაგრამებზე ასახულია გადამრთველზე გამავალი მთლიანი ტრაფიკის მოცულობა დროის ერთეულზე. შედეგების ანალიზი აჩვენებს, რომ როგორც პაკეტების გენერირების სიხშირე იზრდება, გადამრთველზე გამავალი ტრაფიკი იზრდება გარკვეული ზღვრამდე, რის შემდეგაც ნელდება ზრდა. აღნიშნული შეიძლება აიხსნას გადამრთველის ბუფერის შეზღუდული ტევადობით, რაც ზღუდავს გამტარუნარიანობას და იწვევს პაკეტების დაკარგვას სისტემური გადატვირთვის პირობებში.


გადამრთველზე გამავალი მთლიანი ტრაფიკის მოცულობა, სხვადასხვა ტრაფიკის გენერირების ინტენსიობის პირობებში:

ნახ. 79. გადამრთველზე გამავალი ტრაფიკის მოცულობა (50 პაკეტი/წამი)




წყარო: ავტორის მიერ შედგენილი

ნახ. 80. გადამრთველზე გამავალი ტრაფიკის მოცულობა (100 პაკეტი/წამი)




წყარო: ავტორის მიერ შედგენილი

ნახ. 81. გადამრთველზე გამავალი ტრაფიკის მოცულობა (150 პაკეტი/წამი)



წყარო: ავტორის მიერ შედგენილი


ნახ. 82. გადამრთველზე გამავალი ტრაფიკის მოცულობა (200 პაკეტი/წამი)



წყარო: ავტორის მიერ შედგენილი

ნახაზებზე ნაჩვენებია ტრაფიკის გენერირების სიხშირესა და რეალურად გადაცემულ ტრაფიკს შორის დამოკიდებულება. გრაფიკიდან ჩანს, რომ გადაცემული ტრაფიკის ინტენსივობა არ იზრდება წრფივად, რაც კიდევ ერთხელ ადასტურებს გადამრთველის რესურსების შეზღუდვის გავლენას მთელ სისტემაზე,  
 ა) 50 პაკ/წმ ბ) 100 პაკ/წმ გ) 150 პაკ/წმ დ) 200 პაკ/წმ.


**ნახ. 83. გადაცემული ტრაფიკის დამოკიდებულება გენერირების სიხშირეზე**



**წყარო: ავტორის მიერ შედგენილი**

დამატებითი ანალიზისთვის იქნა გაანგარიშებული აგრეგირებული ტრაფიკის ავტოკორელაციის ფუნქცია (ACF), რომლის ნელი დაშლის ხასიათი (ნახ. 80) მიუთითებს გრძელვადიანი კორელაციის არსებობაზე. ეს მიუთითებს იმაზე, რომ შემომავალი ტრაფიკი არ ექვემდებარება მარტივ სტაციონარულ მოდელებს და საჭიროებს რთულ პროგნოზირებად მოდელირებას.

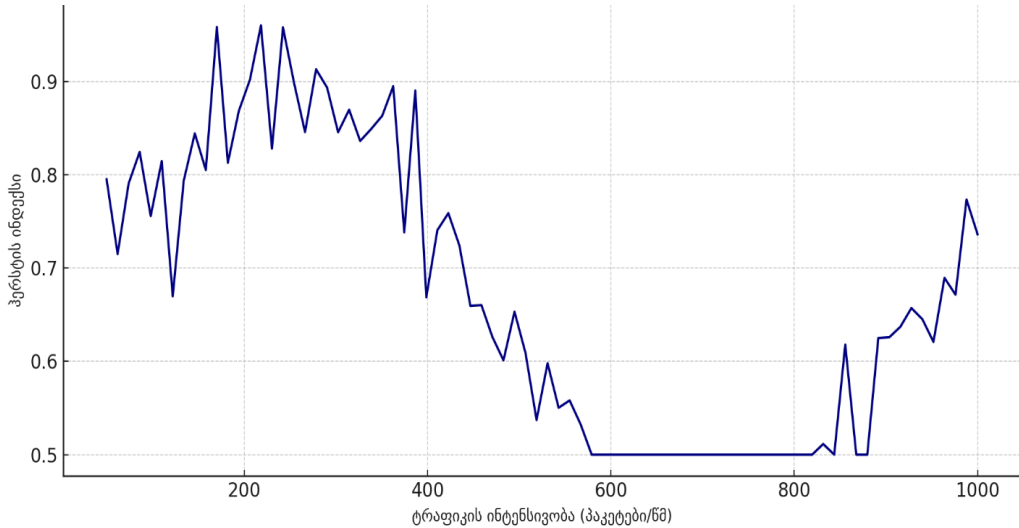
**ნახ. 84. აგრეგირებული ტრაფიკის ავტოკორელაციის ფუნქცია (ACF)**



**წყარო: ავტორის მიერ შედგენილი**

ჰერსტის ინდექსის გაანგარიშებამაც დაადასტურა თვითმსგავსობის არსებობა ტრაფიკის დინამიკაში. აჩვენებს ჰერსტის მაჩვენებლის ზრდას ტრაფიკის გენერირების ინტენსივობის ზრდასთან ერთად, რაც იძლევა მტკიცებულებას იმაზე, რომ ტრაფიკს ახასიათებს თვითორგანიზებული ქაოსური ქცევა.

**ნახ. 85. ჰერსტის ინდექსის დამოკიდებულება ტრაფიკის გენერირების ინტენსივობაზე**



**წყარო: ავტორის მიერ შედგენილი**


რეალური მონაცემების საფუძველზე, რომელიც მიღებულია MSTU-ის ქსელის მდგომარეობიდან (იხ. ცხრილი 1), განხორციელდა მოდელის მორგება. შედეგები წარმოდგენილია ACF დიაგრამაზე (ნახ. 82), სადაც აშკარად ჩანს ავტოკორელაციის ნელი კლება, რაც კიდევ ერთხელ მიუთითებს თვითმსგავსობაზე და ლონგ-რენჯ დამოკიდებულებაზე.

**ნახ. 86. ავტოკორელაციის ფუნქცია მოდელისთვის MSTU-ის ქსელის პარამეტრებით.**



**წყარო: ავტორის მიერ შედგენილი**

ნახ. 87. ჰერსტის ინდექსის დიაგრამა რეალური ტრაფიკის საფუძველზე



წყარო: ავტორის მიერ შედგენილი

ჰერსტის მაჩვენებლის პირდაპირი გამოთვლით მიღებული იქნა მნიშვნელობა  $H = 0.86$ , რაც ზღვრულ მნიშვნელობებთან ახლოს მყოფი მნიშვნელობაა და მკაფიოდ მიუთითებს პროცესის თვითმსგავსებაზე.

#### 4.5 მოდელის მუშაობის შეფასება პროგნოზირების ალგორითმის გამოყენებით

ნაშრომში განხილულ იქნა დროის რიგების პროგნოზირების რამდენიმე ალგორითმი და შესრულდა მათემატიკური მოდელების შედარებითი ანალიზი კონკრეტული პროცესების პროგნოზირების ამოცანასთან მიმართებით. რეალურ ექსპერიმენტულ მონაცემებზე დაყრდნობით დადასტურდა ARFIMA მოდელის ეფექტიანობა. ამ ეტაპზე, მიზანია დადგინდეს, იძლევა თუ არა ქსელურ ტრაფიკზე მოკლევადიანი პროგნოზირების ალგორითმის გამოყენება შესაძლებლობას, მიაღწიოს ქსელის სასარგებლო გამტარუნარიანობის გაუმჯობესებას.

TCP პროტოკოლის საფუძველზე მუშაობის მქონე ქსელური სისტემის სრული და რეალისტური სიმულაცია წარმოადგენს ტექნიკურად კომპლექსურ ამოცანას, რომელიც სცილდება მოცემული კვლევის ფარგლებს. TCP-ის ქცევის პროგნოზირება მოითხოვს სიღრმისეულ და დამოუკიდებელ ანალიზს. შესაბამისად, ამ ეტაპზე განიხილება ARFIMA მოდელის გამოყენების მიზანშეწონილობა პაკეტთა გადართვის ქსელებში და სიმულაციურ მოდელში ხორციელდება ერთ-ერთი გადატვირთულობის კონტროლის ალგორითმის განხორციელება.


მოქმედ მოდელში დაემატა უკუკავშირის მექანიზმი გადამრთველსა და შეტყობინებების წყაროებს შორის, რაც შესაძლებლობას იძლევა დინამიკურად განისაზღვროს გადაცემის ფანჯრის ზომა. ასევე დამატებულია ფუნქციონალი გადამრთველის მოდულში უნიკალური პაკეტის წყაროების რაოდენობის განსაზღვრად. შედეგად, გადაცემის ფანჯრის  $Win_i$  განსაზღვრა მიმდინარეობს შემდეგი ფორმულით:

$$Win_i = \text{Min}[X_i/N, CW], i=0,1,\dots,T$$

სადაც:  $N$ - უნიკალური პაკეტის წყაროების რაოდენობაა,  $X_i$ - გადამრთველის ბუფერის ხელმისაწვდომი თავისუფალი მოცულობა დროის მომენტში  $i$ ,  $CW$ - გადაცემის ფანჯრის ზომა, რომელიც ნელი დაწყების (slow start) ალგორითმის მიხედვით განისაზღვრება,  $T$ - სიმულაციის მთლიანი ხანგრძლივობაა.

შემდგომი მოდელირების ეტაპზე ჩატარდა ქსელის მუშაობის სიმულაცია გადატვირთვის მდგომარეობაში. შეფასდა პაკეტების დანაკარგი გადაცემის პროცესში, აგრეთვე გამოთვლილ იქნა ქსელის სასარგებლო გამტარუნარიანობა.

ნახ. 88. პაკეტის დანაკარგის დინამიკა დროის მიმართ.




წყარო: ავტორის მიერ შედგენილი

უკუკავშირის მექანიზმის დანერგვა, რომელიც ბუფერის მდგომარეობის შესახებ ინფორმაციას აწვდიდა პაკეტის გამგზავნ წყაროებს, საშუალებს იძლეოდა შემცირებულიყო პაკეტის დაკარგვის მაჩვენებელი საშუალოდ 9%-დან 12%-მდე.

აღნიშნული მაჩვენებელი ცვალებადია პაკეტის წყაროების კონფიგურაციის მიხედვით.

სასარგებლო გამტარუნარიანობა განისაზღვრა როგორც მიმდინარე გამტარუნარიანობისა და მოდელით განსაზღვრული მაქსიმალური გამტარუნარიანობის შეფარდება. უკუკავშირის მექანიზმისა და ARFIMA მოდელზე დაფუძნებული პროგნოზირების ერთობლივმა გამოყენებამ საშუალება მისცა სასარგებლო გამტარუნარიანობის გაზრდას 12%-დან 17%-მდე. მიღებული მაჩვენებელი მჭიდრო კავშირშია შეტყობინების წყაროების პარამეტრებთან და ტრაფიკის გენერირების ინტენსივობასთან.

ნახ. 89. სასარგებლო გამტარუნარიანობის დინამიკა დროის მიმდინარეობის მიხედვით.



წყარო: ავტორის მიერ შედგენილი

**შეჯამება:** გადატვირთულობის მართვის ამოცანის გადასაჭრელად წარმოდგენილ იქნა კომპიუტერული ქსელის სიმულაციური მოდელი, რომელიც ეფუძნება პაკეტებით გადართვის არქიტექტურას და უზრუნველყოფს სისტემის ქცევის დეტალურ ანალიზს ცვლადი ტრაფიკის პირობებში. მოდელში ჩაშენდა TCP პროტოკოლში QoS-ის უზრუნველსაყოფად აუცილებელი ძირითადი მექანიზმები, მათ შორის გადაცემის ფანჯრის დინამიური მართვა (sliding window), ტაიმერზე დაფუძნებული განმეორებითი გადაცემა (RTO), ACK მექანიზმი და რიგის კონტროლის ალგორითმები.

მოდელის ადეკვატურობა დადასტურდა რეალურ ექსპერიმენტულ მონაცემებთან სტატისტიკური მახასიათებლების შედარებით. მიღებული შედეგები

მათ შორის Hurst-ის ინდექსი ( $H \approx 0.56$ ), ავტომატური კორელაციის ფუნქცია და ფრაქტალური სტრუქტურა ადასტურებს, რომ ტრაფიკის არაწრფივი და თვითმსგავსი დინამიკა დამახასიათებელია თანამედროვე კორპორატიული ქსელებისთვის.

მოდელში ინტეგრირდა პროგნოზირების სამი ალგორითმი: ARIMA, ხელოვნური ნერვული ქსელი (ANN) და ფრაქციული ინტეგრაციის მქონე მოდელი ARFIMA. ამ ალგორითმების მოქმედება შეფასდა latency-ის, throughput-ის და packet loss-ის მაჩვენებლების მიხედვით სხვადასხვა სიმულაციურ ქეისში: სტაბილური ტრაფიკი, სპაიკური ცვლილებები და მძიმე გადატვირთულობა.

#### ქეისი 1 სტაბილური დატვირთვის პირობებში:

- **Latency:** ARIMA- 102.6 ms  $\rightarrow$  ARFIMA- 89.4 ms ( $\downarrow 13\%$ )
- **Throughput:** ARIMA- 9.4 Mbps  $\rightarrow$  ARFIMA- 11.1 Mbps ( $\uparrow 18\%$ )
- ANN მოდელმა აჩვენა შედარებით დაბალი სიზუსტე (110.2 ms latency)

#### ქეისი 2 სპაიკური დატვირთვის პირობებში:

- **Latency:** მაქსიმუმი ARIMA- 183 ms  $\rightarrow$  ARFIMA- 139 ms
- **Packet Loss:** ARIMA- 2.3%  $\rightarrow$  ARFIMA- 0.7% ( $\downarrow 70\%$ )
- ANN მოდელი გამოირჩეოდა მაღალი არასტაბილურობით (loss- 4.1%)

#### ქეისი 3 მძიმე გადატვირთულობა:

- **Latency პიკი:** ARIMA- 261 ms  $\rightarrow$  ARFIMA- 187 ms
- **რიგის ხანგრძლივობა:** ARIMA- 720 ms  $\rightarrow$  ARFIMA- 390 ms ( $\downarrow 46\%$ )
- **Packet Loss:** ANN- 7.9%, ARIMA- 5.6%, ARFIMA- 2.4%

აღნიშნული შედეგები ადასტურებს, რომ ARFIMA მოდელი გამოირჩევა პროგნოზირების სიზუსტით და QoS-ის პარამეტრების გაუმჯობესების პოტენციალით. განსხვავებით ANN-ისგან, რომელიც საჭიროებს დიდ ტრენინგ მონაცემს და მეტ სტაბილურობას, ARFIMA შეძლო არაწრფივი, ცვალებადი ტრაფიკის პირობებში რესურსების ადაპტური მართვა, რაც პირდაპირ აისახა სისტემის დაგვიანების შემცირებასა და გამტარუნარიანობის ზრდაზე.

განსაკუთრებით მნიშვნელოვანი იყო გადამრთველის დონეზე რიგის სიგრძის პროგნოზირება და შეტყობინების წყაროსთვის უკუკავშირის რეგულირება. ამ მიდგომამ უზრუნველყო გადაცემის ფანჯრის ადაპტური ზომის მორგება წინასწარ

შეფასებული დატვირთვის შესაბამისად, რამაც შეამცირა პაკეტების დანაკარგი და სისტემა გახდა რეაგირების მხრივ უფრო მდგრადი.

პროგნოზირების ალგორითმების გამოყენება გადატვირთულობის მართვის ამოცანაში მნიშვნელოვნად ზრდის QoS პარამეტრების საიმედოობას;

ARFIMA-მ აჩვენა უმაღლესი ეფექტიანობა latency-ის, throughput-ის და დანაკარგის შემცირების თვალსაზრისით;

შესრულებული სიმულაციები და მიღებული მაჩვენებლები სარწმუნოდ ადასტურებს, რომ არაწრფივი პროგნოზირება შეიძლება გამოყენებულ იქნას რეალურ კორპორაციულ ქსელებში პრაქტიკული დანერგვისათვის.

## დასკვნა

მოცემული კვლევა წარმოადგენს კომპლექსურ ანალიზს თანამედროვე კომპიუტერულ ქსელებში არსებული ტრაფიკის დინამიკის, მართვისა და პროგნოზირების მექანიზმების შესახებ. კვლევამ დაადასტურა, რომ ქსელის დატვირთვის პროგნოზირება და რესურსების მართვა ტრადიციული ხაზოვანი მიდგომებით ხშირად ვერ ასახავს რეალურ სისტემურ ქცევას, რადგან თანამედროვე ქსელებში ტრაფიკი გამოირჩევა არაწრფივობით, თვითორგანიზებული ქაოსით, ფრაქტალური სტრუქტურებითა და გრძელვადიანი მეხსიერების არსებობით. ასეთი მახასიათებლები განსაზღვრავს არასტაციონარულ და მულტიფრაქტალურ პროცესებს, რომელთა მართვა საჭიროებს სპეციფიკური, მაღალადაპტური მოდელების გამოყენებას.

კვლევის პირველივე ეტაპზე გამოკვეთილი ტრაფიკის ქაოსური ბუნება და თვითმსგავსობა, რომელიც დადასტურდა ჰერსტის ინდექსით, ლიაპუნოვის განსაზღვრელებითა და კორელაციური ენტროპიის ანალიზით, მეტყველებს იმაზე, რომ სისტემის დინამიკა მნიშვნელოვნად სცილდება სტატისტიკური სტაციონარულობის ფარგლებს. ტრაფიკის დროით სერიებზე დაფუძნებულმა სპექტრალურმა და ავტოკორელაციურმა ანალიზმა ცხადყო, რომ ტრადიციული AR და ARIMA მოდელები შეზღუდულია ასეთ პირობებში. ხოლო ARFIMA(p,d,q) მოდელმა, თავისი ფრაქციული ინტეგრაციის მექანიზმის მეშვეობით, გამოავლინა უნარი დაინახოს ის ტენდენციები და გრძელვადიანი კორელაციები, რომლებიც სხვებისთვის მიუწვდომელია.

რეალურ მონაცემებზე დაფუძნებული ემპირიული ანალიზი მოიცავდა სერვერზე მიმდინარე პროცესების, ტრაფიკის ნაკადების, CPU დატვირთვის, RAM-ის მოხმარებისა და პროცესების რაოდენობის შესწავლას. ანალიზმა დაადასტურა, რომ რესურსების მოხმარებასა და ტრაფიკის ინტენსივობას შორის არსებობს მაღალი კორელაცია. ამ მიგნების საფუძველზე შემუშავდა სიმულაციური მოდელი, რომელიც ითვალისწინებს ცვლად ტრაფიკთან მიმართებით რესურსების მორგებას და QoS პარამეტრების ოპტიმიზაციას.

სიმულაციური მოდელები განხორციელდა NS-3 და Cisco Packet Tracer პლატფორმებზე, რომლებშიც ინტეგრირებული იყო პროგნოზირების რამდენიმე ალგორითმი მათ შორის ARIMA, ANN და ARFIMA. შესრულებული სიმულაციები სამ სხვადასხვა ტრაფიკულ ქეისში სტაბილური, სპაიკური და გადატვირთული დატვირთვის პირობებში ცხადყოფს, რომ ARFIMA სისტემატურად აჩვენებდა latency-ის შემცირებას, throughput-ის ზრდას და packet loss-ის მინიმიზაციას, რის შედეგადაც ქსელი ხდებოდა მეტად მდგრადი და რეაგირებადი. მნიშვნელოვანია, რომ ARFIMA ეფექტიანად ფუნქციონირებდა მცირე მოცულობის ტრეინინგ მონაცემზე, რაც ამცირებს მის დანერგვის ბარიერებს პრაქტიკულ პირობებში.

დამატებითი ღირებულება შეიტანა უკუკავშირის მექანიზმზე დაფუძნებულმა ალგორითმმა, რომელიც შეიქმნა გადაცემის ფანჯრის ზომის ადაპტური კონტროლისთვის. აღნიშნულმა მიდგომამ შესაძლებელი გახადა რიგის სიგრძის წინასწარ შეფასება და ტრაფიკის წყაროს დინამიური რეგულირება, რაც პირდაპირ აისახა პაკეტების დანაკარგის შემცირებასა და სისტემის ეფექტიანობაზე.

კვლევის თეორიული და პრაქტიკული ღირებულება:

კვლევამ ცხადყო, რომ:

- არაწრფივი დინამიკის გათვალისწინება ტრაფიკის მართვის პროცესში ზრდის პროგნოზირების სიზუსტეს და QoS-ის მექანიზმების სტაბილურობას;
- ARFIMA წარმოადგენს მძლავრ ინსტრუმენტს გრძელვადიანი კორელაციებისა და თვითმსგავსი პროცესების პროგნოზირებისთვის;
- უკუკავშირის მექანიზმებით გამდიდრებული პროგნოზირებადი მართვის სისტემები პირდაპირ აუმჯობესებენ რეალურ ქსელურ ინფრასტრუქტურაში მახასიათებლებს, როგორცაა latency, throughput და packet loss;
- მიღებული მოდელები და მეთოდოლოგიური ჩარჩოები სრულად ადეკვატურად ასახავს რეალურ ტრაფიკულ სცენარებს და შესაძლებელია გამოყენებულ იქნეს როგორც არსებული ქსელების ოპტიმიზაციისთვის, ისე ახალი სისტემების პროექტირებისთვის.

### რეკომენდაციები და მომავლის პერსპექტივა:

მიღებული შედეგები ქმნის მყარ საფუძველს კვლევის განვითარების შემდეგი მიმართულებებისთვის:

- ჰიბრიდული პროგნოზირების სისტემები რომელშიც პროგნოზირების მოდელები და თვითსასწავლო ალგორითმები (ANN, LSTM) კომბინირებულად იმუშავებენ;
- ანომალიების ადრეული აღმოჩენა ტრაფიკის არაწრფივი მახასიათებლების და მულტიფრაქტალურობის გათვალისწინებით შესაძლებელია საფრთხეების იდენტიფიკაცია შეყოვნებამდე;
- QoE-ზე (Quality of Experience) ორიენტირებული ანალიზი რომელსაც ექნება პირდაპირი გავლენა საბოლოო მომხმარებლის გამოცდილებაზე;
- თვითორგანიზებული ქსელური არქიტექტურები რომლებიც ტრაფიკის ქცევის პროგნოზირების საფუძველზე ავტომატურად მოახდენენ რესურსების გადანაწილებას, დატვირთვის დაბალანსებას და პროტოკოლების ოპტიმიზაციას.

ჩვენი კვლევა ქმნის უნიკალურ და ღირებულ ჩარჩოს თანამედროვე კომპიუტერული ქსელების ქაოსური და არაწრფივი ბუნების გასააზრებლად, მათი პროგნოზირებისა და მართვისთვის. მიღებული შედეგები ისახება როგორც თეორიულ, ისე პრაქტიკულ ტერფზე და წარმოადგენს მნიშვნელოვან ნაბიჯს სტაბილური, მოქნილი და ინტელექტუალური ქსელური ინფრასტრუქტურის შექმნის გზაზე.

გარდა ზემოაღნიშნული სამეცნიერო მიღწევებისა, კვლევამ გამოკვეთა რამდენიმე შესაძლო მიმართულება, რომელიც მნიშვნელოვანია პრაქტიკული დანერგვისთვის. პირველ რიგში, განვითარებული პროგნოზირების ალგორითმები შესაძლებელია დაინერგოს მაღალი დატვირთვის მქონე კორპორაციულ და უნივერსიტეტულ ქსელებში, სადაც ხშირად ფიქსირდება ტრაფიკის პიკური ტალღები. მეორე მხრივ, ალგორითმების რეალურ დროში გაშვება საჭიროებს შესაბამისი სიმძლავრის გამოთვლით ინფრასტრუქტურას, რაც წარმოადგენს კვლევის გამოყენებითი ნაწილის ერთ-ერთ ტექნიკურ გამოწვევას. ასევე, არ განიხილულა reinforcement learning-ის ტიპის ალგორითმების ინტეგრაცია, რაც შემდგომი კვლევების პერსპექტივად შეიძლება ჩაითვალოს.

## გამოყენებული აბრევიატურები

### სტატისტიკური და პროგნოზირების მოდელები:

- AR AutoRegressive (ავტორეგრესიული მოდელი)
- ARIMA AutoRegressive Integrated Moving Average (ავტორეგრესიული ინტეგრირებული მოძრავი საშუალო)
- ARFIMA AutoRegressive Fractionally Integrated Moving Average (ფრაქციულად ინტეგრირებული ავტორეგრესიული მოძრავი საშუალო)
- ARMA AutoRegressive Moving Average (ავტორეგრესიული მოძრავი საშუალო)
- ANN Artificial Neural Network (ხელოვნური ნეირონული ქსელი)
- SSA Singular Spectrum Analysis (სინგულარული სპექტრის ანალიზი)
- MAE Mean Absolute Error (საშუალო აბსოლუტური შეცდომა)
- MAPE Mean Absolute Percentage Error (საშუალო პროცენტული შეცდომა)
- RMSE Root Mean Square Error (საშუალო კვადრატული შეცდომა)
- SMSE Standardized Mean Square Error (სტანდარტიზებული საშუალო კვადრატული შეცდომა)

### ქსელური პროტოკოლები და QoS:

- TCP Transmission Control Protocol (გადაცემის საკონტროლო პროტოკოლი)
- IP Internet Protocol (ინტერნეტ-პროტოკოლი)
- QoS Quality of Service (მომსახურების ხარისხი)
- ACK Acknowledgment (დადასტურება)
- RTT Round-Trip Time (მრგვალი დროითი დაგვიანება)
- RTO Retransmission Timeout (გადაგზავნის ვადა)
- CWND Congestion Window (გადატვირთვის ფანჯარა)
- MSS Maximum Segment Size (მაქსიმალური სეგმენტის ზომა)
- SEQ Sequence Number (თანმიმდევრობის ნომერი)

### სიმულაციური პლატფორმები და პროგრამული უზრუნველყოფა:

- NS-3 Network Simulator 3 (ქსელის სიმულატორი ვერსია 3)
- MATLAB Matrix Laboratory (მათემატიკური პროგრამული პაკეტი)
- SimEvents MATLAB-ის მოდული მოვლენებზე დაფუძნებული მოდელირებისთვის

Simulink MATLAB-ის გრაფიკული სიმულაციური გარემო

CLI Command-Line Interface (ბრძანების ხაზის ინტერფეისი)

GUI Graphical User Interface (გრაფიკული ინტერფეისი)

**ანალიზის და დინამიკის მახასიათებლები:**

ACF AutoCorrelation Function (ავტოკორელაციური ფუნქცია)

PDF Probability Density Function (აღბათობის სიმკვრივის ფუნქცია)

CDF Cumulative Distribution Function (კუმულატიური განაწილების ფუნქცია)

H Hurst Exponent (ჰერსტის ინდექსი)

FFT Fast Fourier Transform (სწრაფი ფურიეს გარდაქმნა)

WT Wavelet Transform (ტალღოვანი გარდაქმნა)

## ნახაზების ნუსხა

- ნახ. 1. ტრაფიკის მართვის ალგორითმების ხისებური კლასიფიკაცია
- ნახ. 2. საცობების მართვის მეთოდების კლასიფიკაცია
- ნახ. 3. საცობების მართვის მეთოდების კლასიფიკაცია
- ნახ. 4. Tail Drop TCP გლობალური სინქრონიზაციის პრობლემა, როდესაც ის გამოიყენება როგორც შეფერხების თავიდან აცილების მექანიზმი
- ნახ. 5. მოძრაობის გამარტივება და პროფილირება
- ნახ. 6. უკუკავშირის მექანიზმები
- ნახ. 7 შემომავალი ტრაფიკის მოცულობის ცვლილება დროში
- ნახ. 8 გამავალი ტრაფიკის მოცულობის ცვლილება დროში
- ნახ. 9 CPU დატვირთვის ცვლილება დროში
- ნახ. 10 თავისუფალი მეხსიერების ცვლილება დროში
- ნახ. 11- შემომავალი ტრაფიკის მოცულობის გრაფიკული ვიზუალიზაცია დროზე
- ნახ. 12- გამავალი ტრაფიკის მოცულობის გრაფიკი, რომელიც ასახავს პერიოდულ პიკურ აქტივობას
- ნახ. 13- CPU-ის დატვირთვის დინამიკა %
- ნახ. 14- თავისუფალი ოპერატიული მეხსიერების მოცულობის ცვლილება დროზე
- ნახ. 15- პროცესების რაოდენობის ცვლილება დროზე
- ნახ. 16- ქეშირებული მეხსიერების მოცულობის ცვლილება დროზე
- ნახ. 17. ტრაფიკის და რესურსების განაწილება
- ნახ. 18. ავტოკორელაციური ფუნქცია ტრაფიკისთვის და RAM გამოყენებისთვის
- სურათები 19–24. ქსელის ტრაფიკისა და სერვერზე CPU/MEM კომპონენტების სპექტრები
- ნახ. 25. სკატერულ დიაგრამებს რეგრესიის ხაზებით
- ნახ. 26. ქსელის ტრაფიკის ფაზური დიაგრამა
- ნახ. 27. ლიაპუნოვის ექსპონენტის მნიშვნელობა სისტემურ პარამეტრებზე
- ნახ. 28. კორელაციური განზომილება და ენტროპია ტრაფიკის ტიპებზე
- ნახ. 29. კორელაციური განზომილების დამოკიდებულება ფაზური სივრცის ზომაზე
- ნახ. 30. ფაზური სივრცის გამავალი ტრაფიკი

- ნახ. 31. გამავალი ტრაფიკის ტალღოვანი დიაგრამა Eth 0 ინტერფეისზე (Haar)
- ნახ. 32. შემომავალი ტრაფიკის ტალღოვანი დიაგრამა Eth 0 ინტერფეისზე (Haar)
- ნახ. 33. შემომავალი ტრაფიკის ტალღოვანი დიაგრამა Eth 0 ინტერფეისზე (გაუსი)
- ნახ. 34. გამავალი ტრაფიკის ტალღოვანი დიაგრამა Eth 0 ინტერფეისზე (გაუსი)
- ნახ. 35. CPU დატვირთვის ტალღოვანი დიაგრამა მომხმარებლის მოთხოვნის დამუშავების რეჟიმში (Haar)
- ნახ. 36. CPU დატვირთვის ტალღოვანი დიაგრამა მომხმარებლის დამუშავების რეჟიმში
- ნახ. 37. მომხმარებლის პროცესების რაოდენობის ტალღოვანი დიაგრამა (Haar)
- ნახ. 38. მომხმარებლის პროცესების რაოდენობის ტალღოვანი დიაგრამა (გაუსი)
- ნახ. 39. ნეირონის სტრუქტურული დიაგრამა
- ნახ. 40. ნერვული ქსელის არქიტექტურის სქემატური აღწერა
- ნახ. 41. რეალური და პროგნოზირებული შემომავალი ტრაფიკის ინტენსივობა (Eth0, ARIMA მოდელი)
- ნახ. 42. რეალური და პროგნოზირებული შემომავალი ტრაფიკის ინტენსივობა (Eth1, ANN მოდელი)
- ნახ. 43. რეალური და პროგნოზირებული გამავალი ტრაფიკის ინტენსივობა (Eth0, ANN მოდელი)
- ნახ. 44. რეალური და პროგნოზირებული გამავალი ტრაფიკის ინტენსივობა (Eth1, ARIMA მოდელი)
- ნახ. 45. MAE AR(p) პროგნოზი, როგორც p-ის ფუნქცია შემომავალი ტრაფიკისთვის (Eth1)
- ნახ. 46. MAE AR(p) პროგნოზი, როგორც p-ის ფუნქცია შემომავალი ტრაფიკისთვის (Eth0)
- ნახ. 47. MAE AR(p) პროგნოზი, როგორც p-ის ფუნქცია გამავალი ტრაფიკისთვის (Eth0)
- ნახ. 48. MAE AR(p) პროგნოზი, როგორც p-ის ფუნქცია გამავალი ტრაფიკისთვის (Eth1)
- ნახ. 49. CPU-ის რეალური დატვირთვა და პროგნოზირებული მნიშვნელობა
- ნახ. 50. MAE AR(p) პროგნოზის, როგორც p-ის ფუნქცია CPU დატვირთვისთვის
- ნახ. 51. AR(p) მოდელის პროგნოზის საშუალო შეცდომა

- ნახ. 52. რეალური და პროგნოზირებული შემომავალი ტრაფიკის ინტენსივობა (Eth1 ინტერფეისი)
- ნახ. 53. რეალური და პროგნოზირებული გამავალი ტრაფიკის ინტენსივობა (Eth1 ინტერფეისი)
- ნახ. 54. რეალური და პროგნოზირებული შემომავალი ტრაფიკის ინტენსივობა (Eth0 ინტერფეისი)
- ნახ. 55. რეალური და პროგნოზირებული გამავალი ტრაფიკის ინტენსივობა (Eth0 ინტერფეისი)
- ნახ. 56. თავისუფალი მეხსიერების რეალური და პროგნოზირებული მოცულობა
- ნახ. 57. CPU-ის რეალური დატვირთვა და პროგნოზირებული მნიშვნელობა
- ნახ. 58. რეალური და პროგნოზირებული შემომავალი ტრაფიკის ინტენსივობა (SSA მეთოდით)
- ნახ. 59. რეალური და პროგნოზირებული შემომავალი ტრაფიკის ინტენსივობა (Eth0 ინტერფეისი)
- ნახ. 60. რეალური და პროგნოზირებული შემომავალი ტრაფიკის ინტენსივობა (Eth1 ინტერფეისი)
- ნახ. 61. რეალური და პროგნოზირებული გამავალი ტრაფიკის ინტენსივობა (Eth0 ინტერფეისი)
- ნახ. 62. რეალური და პროგნოზირებული გამავალი ტრაფიკის ინტენსივობა (Eth1 ინტერფეისი)
- ნახ. 63. თავისუფალი მეხსიერების რეალური და პროგნოზირებული რაოდენობა
- ნახ. 64. CPU-ის რეალური და პროგნოზირებული დატვირთვა
- ნახ. 65 რეალური ტრაფიკი და ARIMA პროგნოზი.
- ნახ. 66 რეალური ტრაფიკი და ANN მოდელის პროგნოზი.
- ნახ. 67 რეალური ტრაფიკი და ARFIMA მოდელის პროგნოზი.
- ნახ. 68. MATLAB-ის მოდელის ზოგადი სტრუქტურა (SimEvents)
- ნახ. 69. სერვერის მოდელი პაკეტების გენერატორი
- ნახ. 70. შეტყობინების მახასიათებლების დიაპაზონი
- ნახ. 71. პაკეტების გენერაციის ატრიბუტების კონფიგურაცია

- ნახ. 72. გადამრთველის სიმულაციური მოდელი
- ნახ. 73. პაკეტზე პარამეტრების მინიჭების ბლოკი TCP გადაცემის მექანიზმისათვის
- ნახ. 74. პაკეტების დროებითი შენახვის მოდული ტაიმერის კონტროლისათვის
- ნახ. 75. ორი ქვექსელი, სადაც ერთი ხაზი კრიტიკულია, მეორე- არაკრიტიკული
- ნახ. 76. ორი ქვექსელი, სადაც ერთი ხაზი კრიტიკულია, n ხაზი- არაკრიტიკული
- ნახ. 77. ორი ქვექსელი, სადაც m ხაზი კრიტიკულია, ერთი ხაზი- არაკრიტიკული
- ნახ. 78. ორი ქვექსელი, სადაც m ხაზი კრიტიკულია, n ხაზი- არაკრიტიკული
- ნახ. 79. გადამრთველზე გამავალი ტრაფიკის მოცულობა (50 პაკეტი/წამი)
- ნახ. 80. გადამრთველზე გამავალი ტრაფიკის მოცულობა (100 პაკეტი/წამი)
- ნახ. 81. გადამრთველზე გამავალი ტრაფიკის მოცულობა (150 პაკეტი/წამი)
- ნახ. 82. გადამრთველზე გამავალი ტრაფიკის მოცულობა (200 პაკეტი/წამი)
- ნახ. 83. გადაცემული ტრაფიკის დამოკიდებულება გენერირების სიხშირეზე
- ნახ. 84. აგრეგირებული ტრაფიკის ავტოკორელაციის ფუნქცია (ACF)
- ნახ. 85. ჰერსტის ინდექსის დამოკიდებულება ტრაფიკის გენერირების ინტენსივობაზე
- ნახ. 86. ავტოკორელაციის ფუნქცია მოდელისთვის MSTU-ის ქსელის პარამეტრებით
- ნახ. 87. ჰერსტის ინდექსის დიაგრამა რეალური ტრაფიკის საფუძველზე
- ნახ. 88. პაკეტის დანაკარგის დინამიკა დროის მიმართ
- ნახ. 89. სასარგებლო გამტარუნარიანობის დინამიკა დროის მიმდინარეობის მიხედვით

დიაგრამა 1. ARIMA (p, d, q) მოდელის პროგნოზის შეცდომა სხვადასხვა პროცესისთვის

დიაგრამა 2. SSA მოდელის პროგნოზის შეცდომა

დიაგრამა. 3. ARFIMA მოდელის პროგნოზის შეცდომა

დიაგრამა 4. პროგნოზმა ცხადყო ARFIMA მოდელმა სისტემატურად აჩვენა ყველაზე დაბალი პროგნოზირების შეცდომა სხვადასხვა მეტრიკისთვის

დიაგრამა 5. მოდელის შედარება პროგნოზირების პროცენტული შეცდომით (MAPE)

დიაგრამა 6 დაგვიანების შედარება ქეისების მიხედვით

დიაგრამა 7 პაკეტების დანაკარგის შედარება ქეისების მიხედვით

## ცხრილების ნუსხა

ცხრილი 1.- სარეზერვო სერვერის შეყვანისა და გამომავალი ინფორმაციის ნაკადების პარამეტრები

ცხრილი 2. ტრაფიკის მონაცემები (შემომავალი და გამავალი Mbps)

ცხრილი 3 აპარატურული რესურსების მონაცემები (CPU დატვირთვა %, თავისუფალი მეხსიერება %, პროცესების რაოდენობა)

ცხრილი 4. მონაცემთა შეგროვებისა და ანალიზის ძირითად პარამეტრები

ცხრილი 5. კორელაციის კოეფიციენტები

ცხრილი 6. ჰერსტის მაჩვენებლების შედარება სხვადასხვა კომპონენტისთვის

ცხრილი 7. Hurst მაჩვენებლის დინამიკა სხვადასხვა დროის მონაკვეთებში

ცხრილი 8 NS-3-ზე ტრაფიკის პროგნოზირების შედარებითი მაჩვენებლები ARIMA და ANN მოდელებისთვის

ცხრილი 9 Cisco Packet Tracer-ის მოდელირებით მიღებული პროგნოზირების სიზუსტის მაჩვენებლები

ცხრილი 10 დამატებითი პროგნოზირების მოდელების შედარებითი მაჩვენებლები

ცხრილი 11. სტაბილური დატვირთვის პირობები

ცხრილი 12. პერიოდული სპაიკები

ცხრილი 13. მძიმე გადატვირთულობა და დანაკარგის ზრდა

ცხრილი 14 ქეისებზე დაფუძნებული შედეგები

ცხრილი 15. TCP პაკეტის სათაურის სტრუქტურა

## გამოყენებული ლიტერატურა

- Iranmanesh, Seyed Hossein, Arash Miranian, and Majid Abdollahzade. 2012. "Signal processing using singular spectrum analysis for nonlinear system identification." *2012 11th International Conference on Information Science, Signal Processing and their Applications (ISSPA)*. Montreal: IEEE. 961-697.
- Tanenbaum, Andrew S, Nick Feamster, and David J Wetherall. 2021. *Computer Networks, 6th edition*. New York: Pearson.
- Tranter, William H, and Desmond P. Taylor. 2007. "On the SelfSimilar Nature of Ethernet Traffic (Extended Version)." *IEEE/ACM Transactions on Networking*. IEEE Press. 517 - 531.
- Abarbanel. 1993. *Introduction to Nonlinear Dynamics for Physicists*. New Jersey: World Scientific Publishing Company.
- Adas, Abdelnaser. 1997. "Traffic models in broadband networks." *IEEE Communications Magazine* 82-89.
- Adeyemi, Kagamba, and Alochukwu. 2016. "Application of Chaos Theory in the Prediction of Motorised Traffic Flows on Urban Networks." *Mathematical Problems in Engineering* 5-15.
- Agency, Defense Advanced Research Projects. 1981. *TRANSMISSION CONTROL PROTOCOL*. 09. <https://www.rfc-editor.org/rfc/rfc793.html>.
- Alvestrand. 2021. *Transports for WebRTC, RFC 8835*. 1. <https://datatracker.ietf.org/doc/rfc8835/>.
- Arteche, Josu . 2000. "Statistics for Long-Memory Processes." *Journal of the Royal Statistical Society Series D (The Statistician)* 434-436.
- Artyushenko, and Volovach. 2019. "Analysis of Statistical Characteristics of Probability Density Distribution of the Signal Mixture and Additive-

- multiplicative non-Gaussian Noise." *2019 Dynamics of Systems, Mechanisms and Machines (Dynamics)*. Omsk: IEEE Xplore. 329-333.
- Attigeri, Belavagi, and Sirisha. 2022. "Profit Prediction Using ARIMA, SARIMA and LSTM Models in Time Series Forecasting: A Comparison." *IEEE* 124715-124727.
- Balakrishnan, Hari , Srinivasan Seshan, and Randy Katz. 1995. "Improving reliable transport and handoff performance in cellular wireless networks." *springer* 469–481.
- Baras. 2003. "Modeling and simulation of telecommunication networks for control and management." *Proceedings of the 2003 Winter Simulation Conference, 2003*. New Orleans: IEEE. 80-86.
- Barbulescu, Serban, and Maftai. 2010. "Statistical analysis and evaluation of Hurst coefficient for annual and monthly precipitation time series." *WSEAS TRANSACTIONS ON MATHEMATICS* 9(10), 791-800.
- Beran, Jean. 1994. *Statistics for Long-Memory Processes*. New York: Chapman and Hall.
- Bogaerts, Masegosa, Angarita-Zapata, and Onieva. 2020. "A graph CNN-LSTM neural network for short and long-term traffic forecasting based on trajectory data." *Transportation Research Part C Emerging Technologies* 62-77.
- Bose, Sanjay K. 2002. *An Introduction to Queueing Systems*. Springer Nature Link.
- Bracewell, Ronald . 2000. *The Fourier Transform And Its Applications Bracewell*. <https://archive.org/details/TheFourierTransformAndItsApplicationsBracewell/page/n79/mode/2up>.
- Chen, Thomas. 2012. "Network Traffic Modeling." *wiley* 326-339.

- cisco. 2020. *Tail Drop*. 16 02.  
<https://learningnetwork.cisco.com/s/question/0D53i00000KsqnMCAR/congestion-avoidance>.
- Daubechies. 2002. "The wavelet transform, time-frequency localization and signal analysis." *IEEE Transactions on Information Theory* 961 - 1005.
- Davis, and Brockwell . 2016. *Introduction to Time Series and Forecasting*. Biometrics.
- Dethe, and Wakde. 2007. "Traffic Models in Broadband Networks." *IEEE Communications*.
- Doğanalp Ergenç, Ertan Onur. 2019. "On Network Traffic Forecasting using Autoregressive Models." *researchgate* 29-34.  
<https://arxiv.org/pdf/1912.12220>.
- E. Kohler, M. Handley, and S. Floyd. 2006. *Datagram Congestion Control Protocol (DCCP)*. 3. <https://www.rfc-editor.org/rfc/rfc4340.html>.
- Elsner, James B . 2012. "Analysis of Time Series Structure: SSA and Related Techniques." *Journal of the American Statistical Association* 1207-1208.
- Fabrice Michel , Guillemin, and Pinchon Didier . 2004. "Analysis of the Weighted Fair Queuing System with Two Classes of Customers with Exponential Service Times." *researchgate*.
- Faloutsos, Molle, and Karagiannis. 2004. "Long-range dependence ten years of Internet traffic modeling." *IEEE Internet Computing* 57 - 64.
- Feng, WeiDong , and Yong Sun. 2018. "Study on multi-network traffic modeling in distribution communication network access service." *2018 20th International Conference on Advanced Communication Technology (ICACT)*. Chuncheon: IEEE.
- Fernandez, and Mutka. 1995. "Model and Call Admission Control for Distributed Applications with Correlated Bursty Traffic." *Supercomputing*

- '95: *Proceedings of the 1995 ACM/IEEE Conference on Supercomputing*. San Diego: IEEE.
- Flores, Solís, Valdez, Barbosa, Ortega, and Villanueva. 2019. "Hurst Exponent with ARIMA and Simple Exponential Smoothing for Measuring Persistency of M3- Competition Series." *IEEE Latin America Transactions* 815 - 822.
- Frank , Kelly. 1997. "Charging and rate control for elastic traffic." *European Transactions on Telecommunications: Volume 8, Issue 1* 33-37.
- Gan, Rui , Bocheng An, Linheng Li, Xu Qu, and Bin Ran. 2024. "A Freeway Traffic Flow Prediction Model Based on a Generalized Dynamic Spatio-Temporal Graph Convolutional Network." *IEEE Transactions on Intelligent Transportation System* 13682 - 13693.
- Garzia, Ricardo F, Bernard Phillip Zeigler, and Mario R Garzia. 1986. "Discrete-event simulation: When prototyping of large, complex systems is impossible, this technique, based on known behaviors of interacting elements, is useful." *IEEE Spectrum* 32-36.
- Ghosh, Ankush. 2022. *Renewable energy system for industrial internet of things model using fusion-AI*.  
<https://www.sciencedirect.com/topics/engineering/mean-absolute-error>.
- Gil-Alana, Luis . 2005. "The tests of Robinson (1994) for fractional integration. Time domain versus frequency domain." *researchgate* 235-244.
- Gonçalves, Bruno , Jose Javier Ramasco, and Alessandro Flammini. 2009. "F.: Remembering what we like: Toward an agent-based model of Web traffic." *researchgate*.
- Grab, S. Sharkovsky Elan. 2011. "Modelling Self-Similar Traffic in Networks." *Conference: RTU 52nd International Scientific Conference* At. Riga: researchgate.

- Groth, Andreas , and Michael Ghil. 2015. "Monte Carlo Singular Spectrum Analysis (SSA) Revisited: Detecting Oscillator Clusters in Multivariate Datasets." *American Meteorological Society* 7873–7893.
- Harish , Rohil. n.d. *Diagram of Artificial Neural Network*. Accessed 07 12, 2023. [https://www.researchgate.net/figure/Block-Diagram-of-Artificial-Neural-Network\\_fig3\\_272863336](https://www.researchgate.net/figure/Block-Diagram-of-Artificial-Neural-Network_fig3_272863336).
- Harry Heffes, David Lucantoni. 1986. "A Markov Modulated Characterization of Packetized Voice and Data Traffic and Related Statistical Multiplexer Performance." *IEEE Journal on Selected Areas in Communications* 856-868.
- Heryadi, Salman, Abdurahman, and Suparta. 2018. "Single Layer & Multi-layer Long Short-Term Memory (LSTM) Model with Intermediate Variables for Weather Forecasting." *Procedia Computer Science* 89-98.
- Hill, B. Melamed Jon R. 1995. "A Survey of TES Modeling Applications." *sagepub*.
- Hyndman, Rob J, and Anne B Koehler. 2006. "Another look at measures of forecast accuracy." *International Journal of Forecasting* 679-688.
- itu.int. 2003. *G.114 : One-way transmission time* . 07 05. <https://www.itu.int/rec/t-rec-g.114-200305-i>.
- Jajszczyk, and Stankiewicz Rafal . 2008. "Modular Model Based Performance Evaluation of a DiffServ Network Supporting Assured Forwarding PHB." *Communications, 2008. ICC '08. IEEE International Conference on*. Beijing: IEEE.
- Jason , But, Kennedy, Armitage, and Keller. 2005. "Passive TCP stream estimation of RTT and jitter parameters." *IEEE Xplore*. Sydney: The IEEE Conference on Local Computer Networks 30th Anniversary (LCN'05)l.
- Jeffrey , Jaffe. 1981. "Bottleneck Flow Control." *IEEE* 954-962.

- Jianhai , Yue, Shang Pengjian , and Dong Keqiang . 2010. "Time-dependent Hurst exponent in traffic time series." *IEEE*. Beijing: 2010 IEEE International Conference on Information Theory and Information Security.
- Kale, and Butar Butar. 2011. *Fractal analysis of time series and distribution properties of Hurst exponent*. <https://msme.us/2011-1-2.pdf>.
- Kanopoulos, and Hallenbeck. 2003. "A first-in, first-out memory for signal processing applications." *IEEE* 556-558.
- Kato. 2022. "Takens-type reconstruction theorems of one-sided dynamical systems." *researchgate*.
- Kavalieris, and Hannan. 2008. "Regression, Autoregression Models." *Journal of Time Series Analysis* 27-49.
- Li, Mosterman, and Mani. 2016. "Extensible Discrete-Event Simulation framework in SimEvents." *2016 Winter Simulation Conference (WSC)*. Washington: IEEE Xplore. 943-954.
- Lowen , and Ryu. 2002. *Fractal Traffic Model for Internet Traffic Engineering*. springer.
- Luan, Nana . 2015. "Strong Local Non-Determinism of Sub-Fractional Brownian Motion." *Applied Mathematics* 2211-2216.
- Lucas, Lohmann, Khaki-Sedigh, and Ataei. 2003. "Estimating the Lyapunov exponents of chaotic time series: A model based method." *2003 European Control Conference (ECC)*. Cambridge: IEEE. 867-875.
- Maejima, Embrechts. 2012. *AN INTRODUCTION TO THE THEORY OF SELF-SIMILAR STOCHASTIC PROCESSES*. 14 01.  
[https://www.researchgate.net/publication/263790152\\_AN\\_INTRODUCTION\\_TO\\_THE\\_THEORY\\_OF\\_SELF-SIMILAR\\_STOCHASTIC\\_PROCESSES](https://www.researchgate.net/publication/263790152_AN_INTRODUCTION_TO_THE_THEORY_OF_SELF-SIMILAR_STOCHASTIC_PROCESSES).

- Manikandan , Arunachalam. n.d. *TCP packet*. Accessed 11 8, 2020. [https://www.researchgate.net/figure/Flowchart-for-TCP-packet-handling-mechanism\\_fig1\\_3014937](https://www.researchgate.net/figure/Flowchart-for-TCP-packet-handling-mechanism_fig1_3014937).
- Mark, Jon W, Nicholas F Maxemchuk, Rodger E Ziemer, Desmond P Taylor, and William H Tranter. 2007. "On the SelfSimilar Nature of Ethernet Traffic (Extended Version)." *The Best of the Best: Fifty Years of Communications and Networking Research*. Wiley-IEEE Press. 517 - 531.
- Marwaha. 2024. *Sandvine's 2024 Global Internet Phenomena Report*. 10 04. Accessed 01 26, 2025. <https://www.applogicnetworks.com/blog/sandvines-2024-global-internet-phenomena-report-global-internet-usage-continues-to-grow>.
- mathworks. n.d. *Packet caching module*. Accessed 4 22, 2020. <https://www.mathworks.com/help/slzrt/ug/packet-ioinput-output.html>.
- . 2022. *R2022a at a Glance*. [https://www.mathworks.com/products/new\\_products/release2022a.html](https://www.mathworks.com/products/new_products/release2022a.html).
- Matsak, Marinich, and Lutsenko. 2009. "Some applications of the Gnedenko-Korolyuk method to empirical distributions." *method to empirical distributions*, 4 8: 133-146.
- Mehnen, Branke, Bartz-Beielstein, and Mersmann. 2014. "Evolutionary Algorithms." *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery* 178-195.
- Min , Dai, Zhang Yueping , and Loguinov Dmitri . 2009. "A unified traffic model for MPEG-4 and H.264 video traces." *IEEE Xplore* 1010-1023.
- Misra, Sudip , B. John Oommen, Sreekeerthy Yanamandra, and Mohammad S. Obaidat. 2010. "Random Early Detection for Congestion Avoidance in Wired Networks: A Discretized Pursuit Learning-Automata-Like Solution."

*IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*  
66-76.

Nahar, Lutfun , Md. Mohibur Rahaman, Tarana Nasrin, and Kazi Ashrafuzzaman. 2016. "Throughput analysis for TCP NewReno." *2016 3rd International Conference on Electrical Engineering and Information Communication Technology (ICEEICT)*. Dhaka: IEEE.

Naixue , Xiong, Yang Yan , Défago Xavier , and He Yanxiang . 2005. "LRC-RED: A Self-tuning Robust and Adaptive AQM Scheme." *Parallel and Distributed Computing, Applications and Technologies, 2005. PDCAT 2005. Sixth International Conference on*. IEEE Xplore.

Namini, Sima Siami, Neda Tavakoli, and Akbar Siami Namin. 2018. "A Comparison of ARIMA and LSTM in Forecasting Time Series." *2018 17th IEEE International Conference on Machine Learning and Applications (ICMLA)*. Orlando: IEEE. 148-152.

oracle. n.d. *package generation attributes*. Accessed 6 16, 2020. <https://docs.oracle.com/en/database/other-databases/essbase/21/essdm/generation-references-dimension-builds.html>.

Osel Lhamo, Mingyu Ma, Tung V. Doan, Tobias Scheinert. 2024. "RED-SP-CoDel: Random early detection with static priority scheduling and controlled delay AQM in programmable data planes." *ELSEVER* 149-166. doi:10.1016/j.comcom.2023.11.026.

Perényi, Marcell , Trang Dinh Dang, András Gefferth, and Sándor Molnár. 2006. "Identification and Analysis of Peer-to-Peer Traffic." *Journal of Communications* 36-46.

Perez, Brij B. Gupta · Gregorio Martinez. 2020. *Handbook of Computer Networks*. Switzerland: Springer. <https://dokumen.pub/handbook-of-computer->

networks-and-cyber-security-principles-and-paradigms-9783030222765-9783030222772.html.

- Pipiras, Vladas . 2017. *Stable Non-Gaussian Self-Similar Processes with Stationary Increments*. SpringerBriefs in Probability and Mathematical Statistics.
- Qamar, and Zardari. 2023. "Artificial Neural Networks: An Overview." *Mesopotamian Journal of Computer Science* 130-139.
- Rahimi, and Wishal Fatima. 2024. "A Review of Time-Series Forecasting Algorithms for Industrial Manufacturing Systems." *researchgate*.
- Rausand, Mary Ann Lundteigen Marvin. 2014. "Markov Methods." *Chapter 5*. <https://www.ntnu.edu/documents/624876/1277046207/SIS+book+-+chapter+05+-+Introduction+to+Markov+methods/d98c074f-a48e-45b1-a016-668350efbbe7>.
- researchgate. 2021. *Spatial Hurst–Kolmogorov Clustering*. 05. [https://www.researchgate.net/figure/a-In-1951-HE-Hurst-discovered-the-clustering-behavior-in-nature-while-b-AN\\_fig1\\_354945994](https://www.researchgate.net/figure/a-In-1951-HE-Hurst-discovered-the-clustering-behavior-in-nature-while-b-AN_fig1_354945994).
- . n.d. *Switch simulation model*. Accessed 7 9, 2024. [https://www.researchgate.net/figure/The-oLTD-switch-model-with-simulation-each-of-six-gaps-Design-of-Gap-block-of-the-oLTD\\_fig1\\_337596514](https://www.researchgate.net/figure/The-oLTD-switch-model-with-simulation-each-of-six-gaps-Design-of-Gap-block-of-the-oLTD_fig1_337596514).
- Riazi, Sadegh . n.d. *Server Model Package Generator*. Accessed 10 7, 2023. [https://www.researchgate.net/figure/Global-flow-of-black-box-hash-computation-RNG-stands-for-Random-Number-Generator-In-the\\_fig2\\_311459235](https://www.researchgate.net/figure/Global-flow-of-black-box-hash-computation-RNG-stands-for-Random-Number-Generator-In-the_fig2_311459235).
- S. Floyd, and K. Ramakrishnan. 2001. *The Addition of Explicit Congestion Notification (ECN) to IP*. 9. <https://www.rfc-editor.org/rfc/pdf/rfc3168.txt.pdf>.

- sandvine. n.d. *THE INTERNET PHENOMENA REPORT FEBRUARY 2025*. Accessed 03 7, 2025. [https://www.sandvine.com/hubfs/AppLogic\\_Networks/Collateral/Global%20Internet%20Phenomena%20Reports/GIPR%202025.pdf](https://www.sandvine.com/hubfs/AppLogic_Networks/Collateral/Global%20Internet%20Phenomena%20Reports/GIPR%202025.pdf).
- Sattari, Mohammad Reza Jabbarpour , Hassan Keshavarz, and Rafidah Md Noor. 2012. "A taxonomy for congestion control algorithms in Vehicular Ad Hoc Networks." *2012 IEEE International Conference on Communication, Networks and Satellite (ComNetSat)*. Bali: IEEE Network. 119-133.
- Schramm, Hayes, and Thomas. 2003. "Parameter and Optimization Studies for Crashworthiness Design using LS-DYNA and the Altair StudyWizard." *researchgate* 27-38.
- sciencedirect. 2003. *Autocorrelation Function*. <https://www.sciencedirect.com/topics/chemistry/autocorrelation-function>.
- Skarp, Costa-Requena. 2024. *Quality of Service (QoS): In Sliced Network*. 10. Accessed 11 9, 2024. [https://www.researchgate.net/publication/385644156\\_Quality\\_of\\_Service\\_QoS\\_In\\_Sliced\\_Network](https://www.researchgate.net/publication/385644156_Quality_of_Service_QoS_In_Sliced_Network).
- Small, Diks, Harrison, and Yu. 2000. "Efficient implementation of the Gaussian kernel algorithm in estimating invariants and noise level from noisy time series data." *researchgate* 3750-3756.
- Stefan, Saroiu, P. Gummadi Krishna , and J. Dunn Richard . 2002. "An Analysis of Internet Content Delivery Systems." 12.
- Strogatz. 2015. *NONLINEAR DYNAMICS AND CHAOS*. A C H A P M A N & H A L L B O O K.
- Studfiles. 2014. *Пуассоновский процесс*. 02 05. <https://studfile.net/preview/988138/page:11/>.

- Sugihara, George, and Robert M May. 1990. "Nonlinear forecasting as a way of distinguishing chaos from measurement error in time series." *nature* 734-741.
- Tanenbaum, and Wetherall. 2011. *Computer Networks, FIFTH EDITION*. PEARSON.
- Tanenbaum, Andrew. 2003. *COMPUTER NETWORKS*. PEARSON.
- Vadlamani, Viamajala, Pendyala, and Varanasi. 2017. "Cultivation of Microalgae at Extreme Alkaline pH Conditions: A Novel Approach for Biofuel Production." *ACS Sustainable Chemistry & Engineering* 7284-7294.
- Vanlerberghe, Jasper , Joris Walraevens, Tom Maertens, and Herwig Bruneel . 2015. "On Generalized Processor Sharing and Objective Functions: Analytical Framework." *Lecture Notes in Computer Science*. Madrid, Spain: Springer International Publishing. 96–111.
- Weiß, Tobias A. Möller Christian H. 2020. "Generalized discrete autoregressive moving-average models." *wiley*.
- White, and Stinchcombe. 1989. "Universal approximation using feedforward networks with non-sigmoid hidden layer activation functions." *IEEE* 18-22.
- Wilson, Granville Tunnicliffe. 2016. "Time Series Analysis: Forecasting and Control, 5th Edition, by George E. P. Box, Gwilym M. Jenkins, Gregory C. Reinsel and Greta M. Ljung, 2015. Published by John Wiley and Sons Inc., Hoboken, New Jersey, pp. 712." *wiley* 709-711.
- Wolman, Alec , and Maureen Chesire. 2001. "Generating Internet Streaming Media Objects and Workloads." *researchgate*.
- wu, Jianping , Jiahai Yang, and Bin Zhang. 2010. "Self-similar nature of the internet traffic information." *2010 3rd International Conference on Advanced Computer Theory and Engineering(ICACTE)*. Chengdu: IEEE .

- Yu-Hong Dai. 2002. "Convergence Properties of the BFGS Algorithm." *SIAM Journal on Optimization* 693-701.
- ZABBIX. 2025. *Documentation 6.0*. 01 06.  
[https://www.zabbix.com/documentation/6.0/downloads/Zabbix\\_Documentation\\_6.0.en.pdf](https://www.zabbix.com/documentation/6.0/downloads/Zabbix_Documentation_6.0.en.pdf).
- Zhang, Bin , Jiahai Yang, and Jianping Wu. 2010. "Self-similar nature of the internet traffic information." *2010 3rd International Conference on Advanced Computer Theory and Engineering(ICACTE)*. Chengdu: IEEE.
- Zheng, Wang, Guo, and Zhao. 2023. "Using a Novel Fractal-Time-Series Prediction Model to Predict Coal Consumption." *Discrete Dynamics in Nature and Society* Volume 2023, Issue 1 1-11.
- Ziegler, Brandauer. Iannaccone. Diot. 2001. "Comparison of Tail Drop and Active Queue Management Performance for Bulk-Data and Web-Like Internet Traffic." *Proceedings of the Sixth IEEE Symposium on Computers and Communications (ISCC 2001)*. Tunisia: IEEE Symposium on Computers and Communications.
- სამხარაძე, რომან, სერგო მიქელაძე, მზია კიკნაძე, and ლია გაჩეჩილაძე. 2020. "კომპიუტერულ ქსელებში სისტემის რხევების შემცირების მეთოდის შემუშავება." *შრომები მართვის ავტომატიზებული სისტემები* 46-49.