

საქართველოს ტექნიკური უნივერსიტეტი

ხელნაწერის უფლებით

ციური ქოროლიშვილი

„საფინანსო სისტემებში რისკების პროგნოზირება ხელოვნური  
ინტელექტის მეთოდების გამოყენებით“

დოქტორის აკადემიური ხარისხის მოსაპოვებლად  
წარდგენილი დისერტაციის

**ავტორეფერატი**

სადოქტორო პროგრამა „ინფორმატიკა“, შიფრი 0401

თბილისი

2015 წელი

სამუშაო შესრულებულია საქართველოს ტექნიკური უნივერსიტეტის ინფორმატიკისა და მართვის სისტემების ფაკულტეტის „მართვის ავტომატიზებული სისტემების (პროგრამული ინჟინერია)“ დეპარტამენტში

სამეცნიერო ხელმძღვანელი: ტექნიკურ მეცნიერებათა კანდიდატი,  
სრული პროფ. ბადრი მეფარიშვილი

რეცენზენტები:

სრული პროფ.

სრული პროფ.

დაცვა შედგება 2015 წლის ” -- ” -----,----- საათზე

საქართველოს ტექნიკური უნივერსიტეტის „ინფორმატიკისა და მართვის სისტემების“ ფაკულტეტის სადისერტაციო საბჭოს კოლეგიის სხდომაზე, კორპუსი -----, აუდიტორია -----

მისამართი: 0175, თბილისი, კოსტავას 77.

დისერტაციის გაცნობა შეიძლება სტუ-ს ბიბლიოთეკაში,

ხოლო ავტორეფერატის - სტუ-ს ვებგვერდზე

სადისერტაციო საბჭოს მდივანი,

სრული პროფ.

თინათინ კაიშაური

## ნაშრომის ზოგადი დახასიათება

**თემის აქტუალობა.** სადისერტაციო ნაშრომში განხილულია ერთ-ერთი აქტუალური საკითხი საფინანსო ბაზრის დინამიკის ბიზნეს პრობლემების, კერძოდ საფინანსო რისკების პროგნოზირება და მართვა.

თანამედროვე საფინანსო სისტემები ზოგადად წარმოადგენენ დიდი განზომილების მულტიაგენტურ სისტემებს, რომლებიც ხასიათდებიან მაღალი კონკურენტულობით, დინამიურობითა და სტოქასტურობით, რაც მოცემულ ეკონომიკურ გარემოში ბიზნეს-ორგანიზაციებისთვის განაპირობებს მართვის, კერძოდ გადაწყვეტილების მიღების პროცესის სირთულეს. კონკურენტულ საბაზრო პირობებში ბიზნეს-ორგანიზაციების საქმიანობას ყოველთვის თან ახლავს ამა თუ იმ ხარისხის საფინანსო რისკი, რომელიც წარმოიშობა სხვა ფინანსურ ინსტიტუტებთან ურთიერთობის პროცესში.

ასეთ რთულ და მუდმივად ცვალებადი საფინანსო ბაზრის პირობაზე, მსოფლიო ეკონომიკური პროცესების არასტაბილურობის ფონზე რეალური და ფინანსური დაბანდებების პორთფელის ჩამოყალიბებისას აუცილებელია მაქსიმალურად ზუსტად იყოს პროგნოზირებული ისეთი მაჩვენებლების თანაფარდობა, როგორცაა რისკი და შემოსავლიანობა.

არასტაბილურობის პირობებში რისკები კიდევ უფრო იზრდება, განსაკუთრებით კრიზისების პერიოდში. შედეგად, ერთ-ერთ ძირითად პრობლემას წარმოადგენს საფინანსო ბაზარზე კრიზისული სიტუაციების და ასევე მათთან დაკავშირებული რისკების წინასწარი განჭვრეტა. გარდა ამისა, რისკების ანალიზისა და მართვის დღემდე არსებული მეთოდები უკვე ვეღარ პასუხობენ მზარდ მოთხოვნებს თანამედროვე საფინანსო ბაზრის სირთულის პირობებში.

მოცემულ ნაშრომში საპრობლემო სფეროს შესწავლისა და პრობლემის სწორი ფორმულირების მიზნით განხილულია რისკების სახეობები, მათი ანალიზისა და შეფასების სხვადასხვა მეთოდები. მთავარი სირთულე მდგომარეობს იმაში, რომ თანამედროვე საფინანსო ბაზრის სპეციფიკიდან

გამომდინარე არ არსებობს რისკების მართვისადმი ერთიანი უნიკალური მიდგომა, რისკების მთელი სპექტრის ეფექტური მართვის თვალსაზრისით. შესაბამისად, რისკების ხარისხის შეფასებისა და პროგნოზირების მიზნით, იკვეთება ახალი, უფრო ეფექტური მეთოდების შემუშავებისა და იმპლემენტაციის აუცილებლობა.

რისკების შეფასების სიზუსტე განისაზღვრება საფინანსო ბაზრის დინამიკის პროგნოზირების მეთოდებისა და მათ საფუძველში ჩადებული მოდელების ადექვატურობით. რისკ-ფაქტორების გამოვლენის და შეფასების პროცედურები არასასურველი ხდომილობების დროული პრევენციის საშუალებას იძლევა.

**სამუშაოს მიზანი და ამოცანები:** პრობლემის დასმისა და გადაწყვეტის თვალსაზრისით, ნაშრომში განხილულია მრავალი ალგორითმი, მათ შორის ბიზნეს-ანალიტიკოსის მეთოდები, რომლებიც გამოიყენება თანამედროვე საფინანსო სისტემებში რისკების მართვისათვის. სადისერტაციო ნაშრომის კვლევის მიზანს წარმოადგენს რთული საფინანსო სისტემების ფინანსური რისკების ხარისხის შეფასების, მართვისა და პროგნოზირების ისეთი ალგორითმების შემუშავება, რომელიც გარკვეული პარამეტრებით გააუმჯობესებს არსებულ მიდგომებს. ამდენად, პროგნოზირების არსებული მეთოდების შესწავლის პარალელურად, აუცილებელია შემუშავდეს თანამედროვე მეცნიერულ ცოდნაზე, კერძოდ ხელოვნური ინტელექტის თეორიაზე დაფუძნებული ახალი მიდგომები.

**კვლევის ობიექტები.** ნაშრომის კვლევის ობიექტს წარმოადგენს საფინანსო სისტემებში რისკების კლასიფიკაციისა და თავისებურებათა შესწავლა, მათი პროგნოზირების არსებული მეთოდების მიმოხილვა და ეფექტურობის ანალიზი. აგრეთვე, ამ მეთოდების გაუმჯობესების თვალსაზრისით, ხელოვნური ინტელექტის ალგორითმების გამოყენების შესაძლებლობების შესწავლა.

**კვლევის მეთოდები.** ზუსტი მეთოდებისაგან განსხვავებით, მათემატიკური პროგრამირების ევოლუციური მეთოდები საშუალებას გვაძლევს

ვიპოვოთ ოპტიმალურთან ახლოს მდგომი ამონახსნები მისაღებ დროში. საფინანსო რისკების მართვის პროცესები შეიძლება განვიხილოთ მულტიაგენტური მოდელირების საფუძველზე, სადაც ხელოვნური ინტელექტის მეთოდების გამოყენება მნიშვნელოვნად ამაღლებს ეფექტურობას.

**მეცნიერული სიახლე.** სადისერტაციო ნაშრომში წარმოდგენილია რამდენიმე მეცნიერული სიახლე. კერძოდ, პროგნოზირების თვალსაზრისით, შემოთავაზებულია ხელოვნური ნეირონული ქსელების ერთ-ერთი სახესხვაობა, კოკონენის თვითორგანიზებადი რუკები - Self-Organizing Maps ( SOM), რომელიც იყენებს ქსელის არაკონტროლირებადი სწავლების მეთოდს ანუ განსწავლას მასწავლებლის გარეშე.

ხელოვნური ნეირონული ქსელის განსწავლის პროცესში აუცილებელ პირობას წარმოადგენს ე.წ. „გამარჯვებული ნეირონის“ განსაზღვრა, რომლის მიხედვითაც ხდება ნეირონული ქსელის კოეფიციენტების კორექტირება. კოკონენის ქსელი, მრავალშრიანი ნეირონული ქსელისგან განსხვავებით, შეიცავს მხოლოდ ორ შრეს: შემავალს და გამომავალს. ასეთი ქსელის გამოყენება ნაკარნახებია იმით, რომ მრავალგანზომილებიან ნეირონულ ქსელში დიდ სირთულეებთან არის დაკავშირებული რთული შინაგანი (ფარული შრეების) სტრუქტურის წარმოდგენა.

შემოთავაზებულია აგრეთვე მეორე სიახლე, კერძოდ განსწავლის პროცესში ე.წ. „გამარჯვებული ნეირონის“ განსაზღვრისთვის ნაწილაკთა გროვის ოპტიმიზაციის (PSO) ალგორითმის გამოყენება, რომლის უპირატესობას წარმოადგენს ოპტიმუმის პოვნის პარალელური პროცესი.

მესამე სიახლედ შეიძლება ჩაითვალოს ნაწილაკთა გროვის ოპტიმიზაციის (PSO) მოდიფიცირებული ალგორითმი, როგორც გლობალური ოპტიმუმის განსაზღვრის ახალი მიდგომა. მოცემულ ალგორითმში ჩვენ მიერ არის შემუშავებული ნაწილაკთა დინამიური კლასტერიზაციის ახლებური მიდგომა, კერძოდ, „ოქროს კვეთის“ გამოყენებით.

**შედეგების გამოყენების სფერო:** დისერტაციის შედეგებს აქვს პრაქტიკული ღირებულება, ვინაიდან ის შეიძლება გამოყენებულ იქნას სხვადასხვა ბიზნეს-ორგანიზაციებში, კერძოდ საინვესტიციო-საბანკო საქმიანობაში ფინანსური საგამოთვლო და საფინანსო რისკების შეფასების, მართვისა და პროგნოზირების პროცესებში.

**ნაშრომის აპრობაცია.** დისერტაციის ძირითადი შინაარსი მოხსენებული იყო ინფორმატიკისა და მართვის სისტემების ფაკულტეტის „მართვის ავტომატიზებული სისტემების კოლეგიის სამეცნიერო სემინარების სხდომებზე, ასევე მე-3-ე საერთაშორისო სამეცნიერო კონფერენციაზე კომპიუტინგი/ინფორმატიკა, განათლების მეცნიერებები, მასწავლებლის განათლება „საინფორმაციო სისტემებზე თავდასხმის ძიების ამოცანებში ხელოვნური ინტელექტის მეთოდების გამოყენება“, ბათუმი, 17-19 ოქტომბერი, 2014 წ.

**პუბლიკაციები.** დისერტაციის ძირითადი შედეგები გამოქვეყნებულია 7 სამეცნიერო ნაშრომში, რომელთა ჩამონათვალიც მოყვანილია ავტორეფერატის ბოლოს.

**ნაშრომის მოცულობა და სტრუქტურა.** სადისერტაციო ნაშრომი შედგება რეზიუმეს (ორ ენაზე), სარჩევის, შესავლის, ოთხი თავის, დასკვნისა და გამოყენებული ლიტერატურის ნუსხისაგან. ნაშრომის სრული მოცულობა შეადგენს ნაბეჭდი ტექსტის 134 გვერდს, ახლავს 5 ცხრილი, 54 ნახაზი, ლიტერატურის ნუსხა მოიცავს 53 ბიბლიოგრაფიულ წყაროს

## Abstract

In the Thesis Work “Risk Prediction in Financial Systems by Using the Methods of Artificial Intellect” we review one of the most actual issues among the business problems of financial market dynamics, particularly financial risk management and prediction.

The system of modern market is characterized with high dynamicity, increasing competition and orientation towards the customers. Under the competitive market conditions activities of business organizations is always accompanied by financial risks of this or that degree, which are formed in the process of relation with financial institutions.

Study of complex financial system requires methods of analyzing and modeling, involving and assessment of complex methodological system in the financial market domain of risk management. Risk management includes the system of actions allowing solving, assessing, and operatively and analytically processing of data, to make statistical analyze prediction and data analyzing. Management of financial risks in the financial domain may be considered to be multi-agent system. For this purpose in **present work** we review kinds of risks, as well as various methods of analyzing and assessment. Main complexity is in the fact that there is no unique method of approach for risk management on the condition of modern financial market, which is the most complex system of large dimension, from the point of effective management of entire spectra of information and risks, requiring respective processing and implementation of methods.

From the point of setting and solving the problem, we reviewed in the Work numbers of algorithms, which are the methods of modern business analyzing, for assessment and selection of effective methods of approaches of financial risk management. We consider it to be purposeful to review and analyze wide range of predictions. Herewith, parallel to the existed methods of prediction it is necessary to develop the methods based on the modern scientific knowledge, particularly the theory of artificial intellect, which is the subject of present Thesis Work.

**Target of research** of the Work is evolutionary methods and algorithms, such as genetic algorithms, genetic programming, Artificial Neural Networks, Self-Organizing Feature Map, Simulated Annealing, Ant Colony Technique, Imperialist Competitive Algorithm, Particle Swarm Optimization Method and etc.

Processes of financial risk management may be considered on the basis of multi-agent modeling, where using the methods of artificial intellect raises its effectiveness significantly. Different from the exact methods, evolutionary methods of mathematical programming allows us to find outcomes which are close to optimal one within reasonable terms. Evolutional algorithms are those of searching for the best estimated values, in which population individuals are used for the purpose of global learning of the problematic area, also for the purpose of finding

best local outcomes, which will be finally brought to the global optimization of the problematic area.

Modern method of approach of analysing and prediction of the financial market is artificial Neural Networks (ANN), which is multi-layer network structure of the neurons of single-kind elements. Most of the algorithms of studying neural networks are based on the interactive change of metho-synepsid shares, gradually reducing errors in processing the subject of studying neural network. Artificial Neural Network is the strong instrument of modeling; it is successfully used for solving unordinary problems.

We are purposed to process such evolutional algorithm, which will improve existed method of approach in particular parameter. We offer several modified algorithm. One of them is the kind of neural networks, Self-Organizing Feature Map (SOM), using the method of uncontrolled teaching of the network during which abundance of the target objects is made only of the values of included valuables and comparing of the neurons in the process of study doesn't take place with stages and the network learns understanding of the data structure.

Differing from the multi layer neuron network Self-Organizing Feature Map include only two layers: input and output. Interactive method of Self-Organizing Feature Maps is implemented in several stages; at each such stage they process only one from the teaching samples. Another evolutional algorithm developed in the Work is modern method of approach based on the Particle Swarm Optimization, using so-called weighing ratio.

**Innovation of the Method** – distinction from the classic algorithm of Particle Warm of classic algorithm begins in the process of interaction by selecting the method of reclustering.

Purpose of the algorithm is swarming of particles in global (entire searching area) or local (particular cluster) optimums of target function. To solve the task of risk prediction we offer using of Self-Organizing Feature Maps, in the process of studying of which it is necessary to determine so called Winning Neuron, for which modified algorithm of Particle Swarm Optimization Method was developed, as new method of approach for determining global optimum.

Provided calculations revealed that using of the processed method significantly reduce amount of the calculation operations, i.e. duration of implementation of prediction, giving rise to its efficiency. Herewith, this algorithm is absolutely new method of approach in the field of risk prediction and this result may be successfully used in the systems of financial market risk management, bringing us to final results: to reduce amount of calculations and respectively save time, which is one of the principal values of implementation of financial market risk prediction.

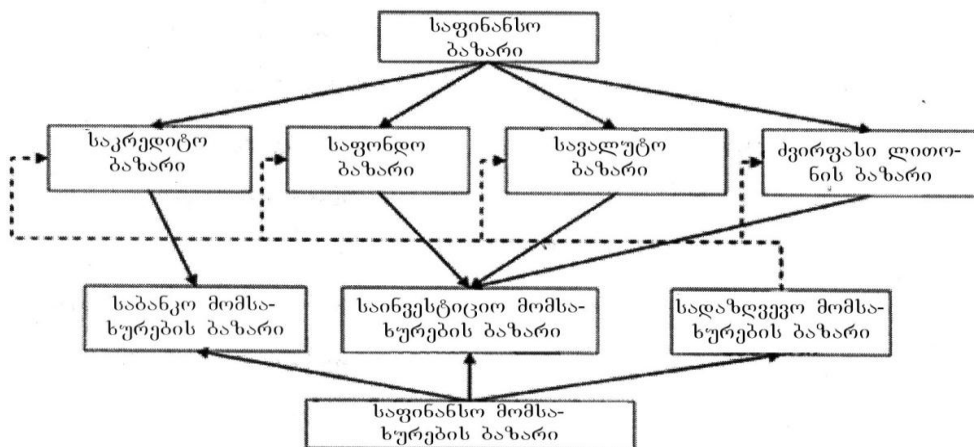


## დისერტაციის მოკლე შინაარსი

**შესავალში** გადმოცემულია დისერტაციის ზოგადი დახასიათება, თემის აქტუალობა, მიზანი და გადასაწყვეტი ამოცანები, სამეცნიერო სიახლე და პრაქტიკული ღირებულება. აგრეთვე ნაშრომის მოკლე შინაარსი თავების მიხედვით.

ნაშრომის **პირველ თავში** განხილულია საგნობრივი სფერო, კერძოდ, წარმოდგენილია საფინანსო ბაზრის არსი და რისკების კლასიფიკაცია. ამავე თავში მიმოხილულია რისკების მართვისა და შეფასების სხვადასხვა მეთოდები, პროგნოზირების არსი და ადგილი რისკ-მენეჯმენტის მართვის სისტემებში, პრობლემის არსებული ხერხებით გადაწყვეტის და ახალი მეთოდების ძებნის აუცილებლობის არგუმენტაცია.

ზოგადად საფინანსო ბაზარი შეიძლება განისაზღვროს როგორც მისი მონაწილეების ეკონომიკურ ურთიერთობათა ერთობლიობა კაპიტალის ფორმირებასთან, მხარდაჭერასა და მიმოქცევასთან დაკავშირებით. ფინანსური ბაზრის ცნების ქვეშ იგულისხმება კუპონური და კუპონგარეშე ობლიგაციების ბაზარი, აქციათა ბაზარი (საფონდო ბაზარი) და სავალუტო ბაზარი. ყველა ჩამოთვლილი ბაზარი ურთიერთდაკავშირებულია როგორც ერთიანი ფინანსური მექანიზმის ნაწილები, რომელშიც ფულადი სახსრები გადაედინება ერთი ბაზრიდან მეორეში. საფინანსო ბაზარი შედგება რიგი სექტორებისაგან (ნახ.1):



ნახ. 1. ფასიანი ქაღალდების ბაზარი. ფინანსური ბაზრები

როულ და მუდმივად ცვალებადი საფინანსო ბაზრის პირობაზე აუცილებელია მაქსიმალურად ზუსტად პროგნოზირებულ იქნას ისეთი მაჩვენებლების თანაფარდობა, როგორცაა რისკი და შემოსავლიანობა. რისკების ხარისხიანი მართვისთვის ეფექტურია განისაზღვროს რისკი და მისი კლასიფიკაცია.

რეალურ სამყაროში, რისკი არის ყველგან. **რისკი** – ეს არის წარმოშობილი დანაკარგი, ზარალი ალბათობა გეგმიური შემოსავლის, მოგების მიუღწევლობა. საფინანსო საქმიანობაში არსებული დანაკარგი შეიძლება დაიყოს მატერიალურ, შრომითი და ფინანსურ რისკებად.

ფინანსური რისკი – არის კომერციული რისკი. ფინანსური რისკები წარმოიშობა საწარმოს ფინანსურ ინსტიტუტებთან ურთიერთობის პროცესში; ბანკებთან, ფინანსებთან, ბირჟებთან, ინვესტორებთან, სადაზღვეო კომპანიებთან და სხვა. არსებობს რისკების გამომწვევი მრავალი მიზეზი, კერძოდ ფინანსური რისკების მიზეზი არის – ინფლაციის ფაქტორი, ბანკების სააღრიცხვო განაკვეთის ზრდა, ფასიანი ქაღალდების ღირებულების დაწევა და სხვა.

ფინანსურ რისკებს მიეკუთვნება საკრედიტო რისკები, პროცენტული რისკები, სავალუტო რისკები, დაუდევრობის, ფინანსური გამორჩენის (სარგებლიანობის) რისკები და სხვა.

როული საფინანსო სისტემის კვლევა საჭიროებს საფინანსო ბაზრის რისკების მართვასა და პროგნოზირებას. რისკ-ფაქტორების გამოვლენისა და შეფასების პროცედურები არასასურველი ხდომილობების თავიდან აცილების საშუალებას იძლევა. მათი ანალიზური დამუშავება მოიცავს რისკების შეფასებისა და რისკების შემცირების სხვადასხვა მეთოდებს.

რისკების შეფასების მეთოდებიდან შეგვიძლია გამოვყოთ რისკების ანალიზის ორი სახეობა–რაოდენობრივი და ხარისხობრივი.

**ხარისხობრივი** ანალიზი გვაძლევს საშუალებას განვსაზღვროთ რისკის პოტენციური მხარე და ფაქტორები, გამოვავლინოთ მისი შესაძლო სახეობები. რისკის ხარისხობრივი ანალიზის ამოცანა არის რისკის იმ წყაროსა და

მიზეზების, სამუშაოებისა და ეტაპების გამოვლენა, რომლის დროსაც წარმოიშობა რისკი.

რისკის **რაოდენობრივი** ანალიზის ეტაპზე გამოითვლება რისკის შემთხვევის დადგომის ალბათობის რიცხვითი მნიშვნელობები და მისგან გამოწვეული ზარალისა და მოგების მოცულობები. რაოდენობრივი ანალიზი მიმართულია იმისაკენ, რომ რისკები გამოვლინდეს რაოდენობრივად და მოხდეს მათი შედარება და ანალიზი.

რისკის შეფასების **სტატისტიკური** მეთოდის არსი მდგომარეობს მოგებისა და დანაკარგების სტატისტიკის შესწავლაში, რომელსაც ადგილი აქვს მოცემულ საწარმოში, რისკის გარემოების ალბათობის განსაზღვრისა და მისი სიდიდის დადგენის მიზნით. ფინანსური სისტემის სტრუქტურის დიდი ნაწილი მიმართულია რისკების მართვაზე. **ფინანსური რისკების მართვა**, ჩვენ, გვესმის როგორც რისკების ანალიზზე სისტემური მუშაობა და მისი მინიმუმზაციისათვის შესაბამისი ზომების მიღება. რისკების მართვის პროცესი შეიძლება დაიყოს 5 ეტაპად:

1) რისკის გამოვლენა, 2) რისკის შეფასება, 3) რისკის მართვის მიდგომების შერჩევა, 4) შერჩეული მიდგომების რეალიზაცია, 5) შედეგების შეფასება.

**რისკ-მენეჯმენტი** წარმოადგენს რისკის მართვის სისტემას, ეკონომიკური, ზუსტად კი ფინანსური ურთიერთობებისა, რომლებიც წარმოიქმნება სწორედ ამ მართვის პროცესში. რისკ-მენეჯმენტი ასრულებს განსაზღვრულ ფუნქციებს.

რისკ-მენეჯმენტში მართვის სუბიექტის ძირითად ფუნქციებს მიეკუთვნება: პროგნოზირება, ორგანიზაცია, რეგულირება, კოორდინაცია, სტიმულირება და კონტროლი. სადისერტაციო თემა ეძღვნება საფინანსო რისკების პროგნოზირების პრობლემატიკას.

**მეორე თავში** ფართოდაა მიმოხილული საფინანსო ბაზრის რისკების მართვისა და პროგნოზირების ამოცანის გადაწყვეტის სხვადასხვა მეთოდები. ფინანსური რისკის პროგნოზირების სტატისტიკური მეთოდები

მოიცავს თანამედროვე მათემატიკურ-სტატისტიკური მეთოდების შესწავლას, შემუშავებასა და გამოყენებას ობიექტური მონაცემების საფუძველზე.

ფინანსური რისკების ეკონომიკურ-სტატისტიკური შეფასების მეთოდები საკმაოდ ფართოა, ვინაიდან მოიცავს შეფასების განხორციელების სხვადასხვა ეკონომიკურ-სტატისტიკურ, ექსპერტულ და ანალოგიის მეთოდებს. კონკრეტული შეფასების მეთოდების შერჩევა განისაზღვრება საჭირო საინფორმაციო ბაზისა და მენეჯერთა კვალიფიკაციის დონის არსებობით.

ეკონომიკურ-სტატისტიკური მეთოდები წარმოადგენს ფინანსური რისკის დონის შეფასების ჩატარების საფუძველს. ასეთი შეფასების ძირითად საანგარიშო მაჩვენებელთა რიცხვს მიეკუთვნება:

ა) **ფინანსური რისკის დონე.** ამ მაჩვენებლის შეფასებით ხდება ეკონომიკურ-სტატისტიკური ალგორითმების დახასიათება.

ბ) **დისპერსია.** იგი ახასიათებს შესასწავლი მაჩვენებლის ცვალებადობის ხარისხს (მოცემულ შემთხვევაში – განხორციელებადი ფინანსური ოპერაციების მოსალოდნელ შემოსავალს) მის საშუალო სიდიდესთან მიმართებით.

**საშუალო კვადრატული (სტანდარტული) გადახრა.** ეს მაჩვენებელი ინდივიდუალური ფინანსური რისკის დონის შეფასებისას ყველაზე გავრცელებულია, როგორც დისპერსია განსაზღვრავს ცვალებადობის დონეს და მის საფუძველზეა აგებული.

**დროებითი მწკრივების** მეთოდებით შესაძლებელია პროგნოზირების ამოცანების წარმატებული გადაწყვეტა, რაც განპირობებულია დროებითი მწკრივის სტატისტიკური ანალიზის ძირითადი მიზნით, წარმოადგენს კვლევის საბოლოო გამოყენებითი მიზნების საფუძველს, პირველ რიგში დროებითი მწკრივის მოკლე და გრძელვადიანი პროგნოზის ამოცანების გადასაწყვეტად. დროებითი მწკრივები ასახავს სისტემის პარამეტრების ცვალებადობის ტენდენციას დროში.

ჩამოთვლილ მეთოდებთან ერთად, პროგნოზირებისათვის გამოიყენება რეგრესიული ალგორითმები. რეგრესიული მოდელების ასაგებად საჭიროა გვექონდეს დაკვირვებების მონაცემთა ბაზა. ადრინდელ დაკვირვებათა მნიშვნელობების ცხრილის მიხედვით შესაძლოა შეირჩეს (უმცირესი კვადრატების მეთოდი) რეგრესიის კოეფიციენტები, რომლითაც შემდგომ აიგება მოდელი.

**ბაიესის კლასიფიკაცია.** ბაიესის კლასიფიკაციამ ფართო გავრცელება ჰპოვა პრაქტიკაში. თავდაპირველად იგი გამოიყენებოდა ექსპერტთა ცოდნის ფორმალიზაციისათვის ექსპერტულ სისტემებში, ამჟამად კი გამოიყენება როგორც *Data Mining*-ის ერთ-ერთი მეთოდი. ე.წ. „მიამიტი“ კლასიფიკაცია ან მიამიტ-ბაიესის მიდგომა (*naive-bayes approach*) წარმოადგენს იმ მეთოდის მარტივ ვარიანტს, რომელიც გამოიყენება ბაიესის ქსელში. ამ მიდგომის შემთხვევაში წყდება კლასიფიკაციის ამოცანები, მეთოდის მუშაობის შედეგს კი წარმოადგენს ე.წ. „გამჭვირვალე მოდელები“.

რისკების შეფასებისათვის ფინანსურ ბაზრებზე გამოიყენება აგრეთვე **მონტე-კარლოს** მეთოდი, რომელიც შესაძლებელია განისაზღვროს როგორც შემთხვევითი სიდიდეების მოდელირების მეთოდი მათი გადანაწილების მახასიათებლების გამოთვლის მიზნით. მისი გამოყენება გამართლებულია პირველ რიგში იმ ამოცანების შემთხვევაში, რომლებშიც დასაშვებია თეორიული და ალბათური აღწერა.

ჩამოთვლილ მეთოდებს გააჩნია რიგი უარყოფითი მხარეები, მაგრამ მიუხედავად ამისა მათი მთავარი უპირატესობა მდგომარეობს იმაში, რომ დროის უმოკლეს ინტერვალში, საკმაოდ მარტივი მეთოდით შესაძლებელია სრული შეფასების მიღება სხვადასხვაგვარი ინსტრუმენტების დიდი რაოდენობით პორთფელების შემთხვევაში. რაც შეეხება მონტე-კარლოს მეთოდს, ეს არის მეტად მძლავრი მეთოდი, რომელსაც პრინციპში შეუძლია გაითვალისწინოს შესაძლო რისკების ფართო წრე, მათ შორის რა თქმაუნდა არაწრფივი ეფექტებიც.

თანამედროვე საფინანსო ბაზრის სისტემაში ფაქტობრივი აქტიური ექსპერიმენტების ჩატარება თითქმის შეუძლებელია. ამიტომ საფინანსო-საბაზრო რისკების ეფექტური ანალიზისა და მართვის თვალსაზრისით ერთ-ერთ პერსპექტიულ მიმართულებად განიხილება რეალური სისტემის იმიტაციური მოდელირებისა და ექსპერიმენტული მიდგომა.

იმიტაციური მოდელირება ამ ეტაპისთვის ეყრდნობა სამ ძირითად პარადიგმას – სისტემური დინამიკა - **System Dynamics (SD)**, დისკრეტულ-მოვლენითი - **Discrete Event Modeling (DEM)** და აგენტური მოდელირება (**ABM**). მათ შეესაბამება განსხვავებული ხარისხის აბსტრაქცია მოდელის შექმნის დროს, რაც განაპირობებს გამოვიყენოთ ესა თუ ის მიდგომა.

სისტემური დინამიკა და დისკრეტულ-მოვლენათა მოდელირება განიხილავს სისტემას ზემოდან ქვემოთ და მუშაობენ ე.წ. სისტემურ საფეხურზე.

აგენტზე დაფუძნებული მოდელირება ეს არის მიდგომა ქვემოდან ზემოთ. მოდელის შემქმნელი ყურადღებას მიმართავს ცალკეული ერთეულების ქცევაზე.

სისტემური დინამიკა გულისხმობს აბსტრაქციების მაღალ საფეხურს და გამოიყენება ძირითადად სტრატეგიული საფეხურის ამოცანებისათვის. დისკრეტულ-მოვლენათა მოდელირების მიდგომა გამოიყენება ძირითადად ოპერატიულ და ტაქტიკურ საფეხურზე. აგენტური მოდელის გამოყენების არჩევანი მოიცავს ნებისმიერი საფეხურის აბსტრაქციის ამოცანას.

საფინანსო ბაზრების მოდელირება საკმაოდ რთული პრობლემაა. თანამედროვე მიდგომა პარადიგმის ცვლილებით ხასიათდება. ამდენად საფინანსო ბაზარი განიხილება როგორც **მულტიაგენტური სისტემა – Multi-Agent Systems (MAS)**. მრავალაგენტური მოდელირება – სისტემების მოდელირების ახალი მიდგომა გამოიყენება დეცენტრალიზებული სისტემების გამოსაკვლევად. იგი ეფუძნება რეალური სამყაროს ცალკეულ აქტიურ კომპონენტებს, რომლებსაც **აგენტებს** უწოდებენ. აქტუალური ხდება ისეთი სისტემების ქცევის პროგნოზირება, განსაკუთრებით კრიზისების და კრი-

ტიკული სიტუაციების პირობებში, რათა მინიმიზებული იქნას საფინანსო რისკები.

**მესამე თავი** ეძღვნება საფინანსო რისკების პროგნოზირებაში ხელოვნური ინტელექტის მეთოდების, კერძოდ ევოლუციური ალგორითმების გამოყენების მიზანშეწონილობის განსაზღვრას. ევოლუციური მეთოდები გვაძლევს საშუალებას, ვიპოვოთ ოპტიმალურთან ახლოს მდგომი ამონახსნები მისაღებ დროში. ევოლუციური ალგორითმები არის საძიებო არეში მიახლოებითი საუკეთესო მნიშვნელობის ძიების ალგორითმები, რომლებიც გამოიყენება გლობალური ოპტიმიზაციის ამოცანებში. ევოლუციურ ალგორითმებში პოპულაციის ინდივიდები გამოიყენება საპრობლემო არის პარალელური შესწავლის მიზნით, ასევე ლოკალური საუკეთესო ამონახსნების ძიების მიზნით, რასაც საბოლოო ჯამში მივყავართ კონკრეტული საპრობლემო არის გლობალური ოპტიმიზაციისკენ.

რისკების პროგნოზირება გენეტიკური ალგორითმის – **Genetic Algorithms (GA)** მეთოდით დაფუძნებულია ბუნებრივი ევოლუციის პრინციპებზე, სადაც პოპულაციის ინდივიდები განუწყვეტლივ ცხოველქმედებენ, ვითარდებიან და იბრძვიან გადარჩენისთვის. ამ ბრძოლაში, უფრო ძლიერ და ადაპტირებად ინდივიდებს გადარჩენის მეტი შანსი აქვთ ვიდრე სუსტებს, შესაბამისად მათი შთამომავლობაც გენეტიკურად უფრო ძლიერი იქნება. მისი სიძლიერე იმაში მდგომარეობს რომ, იგი დიდი განზომილების მრავალექსტრემუმიანი და მრავალკრიტერიუმიანი ამოცანებისათვის ოპტიმუმის სწრაფი ძებნის შესაძლებლობას იძლევა, რაც მონაცემთა პარალელური დამუშავების გზით მიიღწევა.

რისკების პროგნოზირება შეიძლება აგრეთვე გენეტიკური პროგრამირების - **Genetic Programming (GP)** გამოყენებით, რადგან მას გაცილებით ფართო შესაძლებლობები აქვს. გენეტიკურ პროგრამირებაში ევოლუციას განიცდის კომპიუტერული პროგრამების პოპულაცია, რის შედეგადაც მიიღება ახალი პოპულაცია „უკეთესი“ პროგრამებით. გენეტიკური პროგრამირების მეთოდი უპირატესად გამოიყენება შემდეგ

შემთხვევებში: როდესაც კლასიკური მათემატიკური ანალიზი არ იძლევა ანალიტიკურ შედეგს; როდესაც კავშირი დამოუკიდებელ და დამოკიდებულ ცვლადებს შორის უცნობია, ან ერთობ საეჭვოა; როდესაც დაშვებულია მიახლოებითი ამონახსნი. როდესაც საქმე გვაქვს მონაცემთა დიდ მასივებთან და საჭიროა მათი დამუშავება, კლასიფიკაცია, ინტეგრირება და სხვ.

საფინანსო რისკების პროგნოზირების ამოცანების გადასაჭრელად დღესდღეობით ყველაზე ოპტიმალურად არის მიჩნეული ნეირონული ქსელების ალგორითმი. ხელოვნური ნეირონული ქსელი – **Artificial Neural Networks (ANN)** ადამიანის თავის ტვინის ფუნქციონირებაზე დაფუძნებული არაწრფივი სტრუქტურის იმიტაციური მოდელია. მისი ძირითადი შემადგენელი ნაწილები – ხელოვნური ნეირონები ბიოლოგიური ნეირონების ანალოგია.

ხელოვნური ნეირონული ქსელი წარმოადგენს მოდელირების მძლავრ ინსტრუმენტს, რადგან მას შეუძლია შეისწავლოს და დაამუშაოს არაზუსტი და დაზიანებული მონაცემები. ნეირონული ქსელების ტექნოლოგიების გამოყენებით ტექნიკური ანალიზისადმი მიდგომა სულ უფრო და უფრო აქტუალურდება 90-იანი წლების დასაწყისის შემდეგ, რადგან ის რიგი უპირატესობებით ხასიათდება.

ნეირონული ქსელის ანალიზი არ გულისხმობს რაიმე შეზღუდვას შემავალი ინფორმაციის ხასიათთან დაკავშირებით. ეს შესაძლოა იყოს როგორც მოცემული დროითი მწკრივის ინდიკატორები, ასევე მონაცემები სხვა საბაზრო ინსტრუმენტების ქცევების შესახებ. ამიტომ ნეირონული ქსელები აქტიურად იყენებენ სწორედ ინსტიტუციონალურ ინვესტორებს (მაგალითად, მსხვილი საპენსიო ფონდები), რომლებიც მუშაობენ მსხვილ პორტფელებთან, რომელთათვისაც განსაკუთრებულად მნიშვნელოვანია კორელაციები სხვადასხვა ბაზრებს შორის.

გარდა ზემოაღნიშნულისა, ტექნიკური ანალიზისგან განსხვავებით, რომელიც ზოგად რეკომენდაციებს ემყარება, ნეირონულ ქსელებს შესწევთ

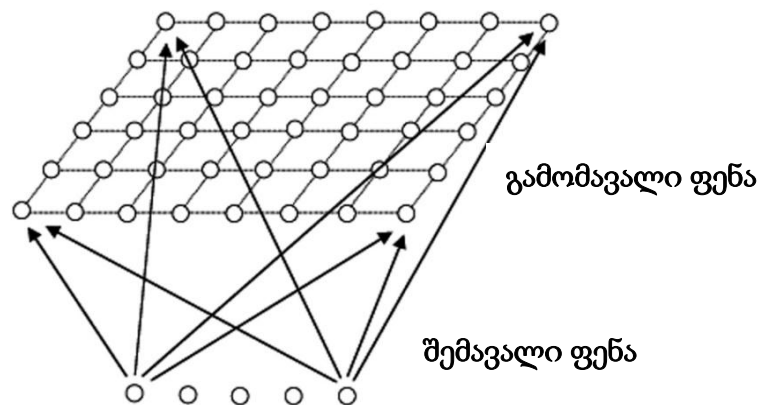


უნარი მოიძიონ მოცემული ინსტრუმენტისთვის ოპტიმალური ინდიკატორები და მათზე ააგონ მოცემული მწკრივისთვის პროგნოზირების ოპტიმალური სტრატეგია. უფრო მეტიც, ამ სტრატეგიებს შეუძლიათ იყვნენ ადაპტირე- ბუნნი და იცვლებოდნენ ბაზრებთან ერთად,

ANN-ს წარმატებით იყენებენ არაორდინალური პრობლემების გადასაწყვეტად. სტატისტიკის კუთხით ის გამოიყენება პროგნოზირებისა და კლასიფიკაციის ამოცანების მოდელირებისთვის.

ამავე თავში შემოთავაზებულია საფინანსო ბაზრის რისკების პროგნოზირების ამოცანის გადაწყვეტისადმი ახლებური მიდგომა ე.წ. კოჰონენის თვითორგანიზებადი რუკების ალგორითმის გამოყენება, რომელიც ნეირონული ქსელების ერთ-ერთი სახეობაა. ხელოვნური ნეირონული ქსელის შემთხვევაში განსწავლის პროცესმა შესაძლოა მოითხოვოს საკმაოდ დიდი დროითი რესურსები. დროის დანახარჯის შემცირების ერთ-ერთ ასეთ მეთოდს წარმოადგენს პარალელური გადამუშავების გამოყენება კოჰონენის თვითორგანიზებადი რუკების სწავლების ალგორითმში, რომლის დროსაც რამდენიმე დასამუშავებელი ელემენტი ერთდროულად მონაწილეობს წარმოებულ გამოთვლებში.

კოჰონენის თვითორგანიზებადი რუკები - **Self-Organizing Maps (SOM)** იყენებს ქსელის არაკონტროლირებადი სწავლების მეთოდს. კოჰონენის ქსელი მრავალშრიანი ნეირონული ქსელისგან განსხვავებით შეიცავს მხოლოდ ორ შრეს: შემავალს და გამომავალს (ნახ. 2).



ნახ. 2. კოჰონენის ქსელი

ამ ქსელის გამოყენება ნაკარნახებია იმით, რომ დიდ სირთულეებთან არის დაკავშირებული რთული სტრუქტურის წარმოდგენა მრავალგანზომილებიან ქსელში. კოჰონენის ქსელის სწავლების პროცესში ქსელს შესასვლელზე თანამიმდევრულად მიეწოდება მონაცემები, რის შემდეგაც ქსელი იწყებს გადაწყობას შემავალი მონაცემების კანონზომიერების მიხედვით და არა გამომავალი მონაცემების ეტალონის მიხედვით. სწავლების დროს, მონაცემების თანამიმდევრული გადაცემით ქსელის შესასვლელზე განისაზღვრება „გამარჯვებული ნეირონი“, რომელიც შემდეგში გამოიყენება მეზობელ ნეირონებში წონების განაწილების ცენტრად. ამ დროს სწავლების არსი შეცდომის მინიმიზაცია კი არ არის, არამედ შემავალ მონაცემებთან შესაბამისობაში ყოფნა.

**თვითშემსწავლელი რუკების ფუნქციონირების ალგორითმი** - წარმოადგენს მრავალგანზომილებიანი ვექტორების კლასტერიზაციის ერთ-ერთ ვარიანტს. თვითორგანიზებადი რუკის ალგორითმის თავისებურება მდგომარეობს იმაში, რომ მასში ყველა ნეირონი (კვანძები, კლასების ცენტრები) მოწესრიგებულია რომელიმე სტრუქტურაში (ძირითადად ორგანზომილებიან ბადეში). ამასთან, სწავლების მსვლელობისას მოდიფიცირდება არამარტო გამარჯვებული-ნეირონი, არამედ მისი მეზობლებიც, შედარებით მცირე დონით. თვითორგანიზებადი რუკა გულისხმობს ნეირონების მოწესრიგებული სტრუქტურის გამოყენებას. ძირითადად გამოიყენება ერთი ან ორგანზომილებიანი ბადეები. ამასთან, ყოველი ნეირონი წარმოადგენს  $n$ -განზომილებიან სვეტ-ვექტორს.

$$\omega = [\omega_1, \omega_2 \dots \omega_n]^T,$$


სადაც  $n$  განისაზღვრება საწყისი სივრცის განზომილები (შემავალ ვექტორთა განზომილებით).

ალგორითმის რეალიზაციისას წინასწარ არის ცნობილი ბადის კონფიგურაცია (მართკუთხედი ან ექვსკუთხედი), აგრეთვე ნეირონების რაოდენობა ქსელში. რუკის შესწავლის დაწყებამდე, საჭიროა ნეირონების წონითი კოეფიციენტების ინიციალიზირება. სწავლების ყოველ ბიჯზე

საწყის მონაცემთა კრებულიდან შემთხვევით ირჩევა ერთ-ერთი ვექტორი, ხოლო შემდეგ წარმოებს მასთან ყველაზე მიახლოებული ნეირონის კოეფიციენტების ვექტორის ძებნა. ამასთან ირჩევა გამარჯვებული-ნეირონი, რომელიც უფრო მეტად ჰგავს შემავალ ვექტორებს. მსგავსებაში, მოცემულ შემთხვევაში იგულისხმება ვექტორებს შორის მანძილი, რომელიც ძირითადად გამოითვლება ევკლიდეს სივრცეში. ამგვარად, თუ აღვნიშნავთ გამარჯვებულ ნეირონს  $c$  სიმბოლოთი მივიღებთ:

$$\|\chi - \omega_c\| = \min_i \|\chi - \omega_i\|$$

მას შემდეგ, რაც ნაპოვნია გამარჯვებული ნეირონი, ხორციელდება ნეიროქსელის წონების კორექტირება. ამასთან ვექტორი, რომელიც აღწერს გამარჯვებულ ნეირონს და ვექტორი, რომელიც აღწერს მის მეზობლებს ბადეში, გადაადგილდებიან შემავალი ვექტორის მიმართულებით. ეს ილუსტრირებულია (ნახ. 3) ორგანოზომილებიანი ვექტორისათვის.



ნახ. 3. გამარჯვებული ნეირონის და მისი მეზობლების წონების ქვეწყობა


შემავალი ვექტორის კოორდინატები აღნიშნულია ჯვარედინით, რუკის კვანძების კოორდინატები მოდიფიკაციის შემდეგ ასახულია ნაცრისფერი ფერით. ამასთან წონითი კოეფიციენტების მოდიფიკაციისათვის გამოიყენება ფორმულა:

$$\omega_i(t + 1) = \omega_i(t) + h_{ci}(t) * [\chi(t) - \omega(t)]$$

სადაც  $t$  აღნიშნავს დისკრეტულ დროს. ამასთან  $x(t)$  ვექტორი ირჩევა შემსწავლელი შერჩევიდან შემთხვევით  $t$  იტერაციაზე.  $h(t)$  ფუნქცია არის ნეირონების მეზობლობის ფუნქცია, რომელიც წარმოადგენს დროისა და მანძილის არამზარდ ფუნქციას გამარჯვებულ ნეირონსა და მეზობელ ნეირონებს შორის ბადეში. ამასთან, სწავლების მსვლელობისას მოდიფიცირდება არამარტო გამარჯვებული ნეირონი, არამედ მისი მეზობლებიც, შედარებით მცირე დონით.

აღნიშნული მიდგომის გამოყენება ერთის მხრივ შესაძლებელია საწყის და საბოლოო მონაცემთა კანონზომიერებების ძებნისა და ანალიზისთვის. ამავდროულად კოჰონენის მეთოდი უფრო ზოგადია იმ თვალსაზრისით, რომ ახორციელებს მრავალგანზომილებიანი შემავალი სივრცის გამოსახვას ორ განზომილებიან (იშვიათად ერთ განზომილებიან) გამავალ სივრცედ, ე.ი. ახდენს მონაცემთა შეკუმშვას. რაც საბოლოოდ აჩქარებს ალგორითმის შესრულებას.

თვითორგანიზებადი რუკების მოდელი (ნახ.4) მიეკუთვნება ნეირონული ქსელების კლასს, მასწავლებლის გარეშე შესწავლით.



ნახ. 4 თვითორგანიზებადი რუკების მუშაობის მოდელი

ამავე თავში წარმოდგენილია კოჰონენის რუკაზე გამარჯვებული ნეირონის გამოვლინების ალგორითმების მოკლე მიმოხილვა, როგორცაა: ამოწვის იმიტაციის ალგორითმი, იმპერიალისტური შეჯიბრებითი ალგორითმი და ნაწილაკების გროვის ოპტიმიზაციის მეთოდი.

იმპერიალისტური შეჯიბრებითი ალგორითმი – **Imperialist Competitive Algorithm (ICA)** ეფუძნება იმპერიალისტურ მეტოქეობას, სადაც ძლიერი სახელმწიფოები ქმნიან კოლონიებს და ამასთან ებრძვიან სხვა ძლიერ სახელმწიფოებს ძალაუფლებისთვის. ასეთი მეტოქეობის დროს ისინი უფრო ძლიერდებიან და ან კარგავენ ძალაუფლებას. იგი არის ახალი სოციო-პოლიტიკურად მოტივირებული გლობალური ძიების სტრატეგია, რომელიც თავიდანვე ერთ-ერთ ძლიერ ევოლუციურ ალგორითმად იქნა აღიარებული. იგი გამოიყენება ოპტიმიზაციის სხვადასხვა ამოცანების გადასაწყვეტად როგორც ცალკე ასევე სხვა ევოლუციურ ალგორითმებთან კომპოზიციაში. მაგალითად ფართოდ გამოიყენება სინაპსის წონების ოპტიმიზაციის მიზნით ხელოვნურ ნეირონულ ქსელებში (ANN), კლასტერიზაციის ამოცანებში k-Means ალგორითმთან ერთად (K-MICA), ასევე შემდეგი თაობის ვებ-ტექნოლოგიებში ინფორმაციის სემანტიკური ძებნისთვის (Semantic Web Searching) და ა.შ.

საფინანსო სისტემებში მართვის პროცესები შეიძლება განვიხილოთ მულტიაგენტური მოდელირების საფუძველზე. ამდენად, საფინანსო ბაზრის რისკების პროგნოზირების პრობლემის გადაწყვეტისათვის კოპონენის თვითორგანიზებად რუკაზე გამარჯვებული ნეირონის გამოვლინების თვალსაზრისით ზემოაღნიშნული ალგორითმებიდან მიზანშეწონილია ნაწილაკთა გროვის ოპტიმიზაციის მეთოდის გამოყენება.

ნაწილაკების გროვის ოპტიმიზაციის – **Particle Swarm Optimization (PSO)** ალგორითმის პოპულარობამ ბოლო წლებში მნიშვნელოვნად მოიმატა, რადგან PSO პოპულაციაზე დაფუძნებული ალგორითმია, რომელიც განეკუთვნება ევოლუციური ალგორითმების ოჯახს. ალგორითმში ამოცანის გადაწყვეტა ხდება გროვის ინდივიდების, რომელთაც ნაწილაკებს უწოდებენ, ერთდროული მოძრაობით და მათ შორის ურთიერთქმედებით.

ნაწილაკის მოძრაობა საძიებო არეში არის ნაკარნახები როგორც საკუთარი საუკეთესო პოზიციით, ასევე მთლიანი გროვის საუკეთესო

პოზიციით აღნიშნულ არეში. ნაწილაკის გადაადგილებისთვის აუცილებელი პირობაა საკუთარი პოზიციის და შესაბამისად მთელი გროვის პოზიციის გაუმჯობესება. გროვის მიზანია, საძიებო არეში გლობალური ოპტიმუმის მოძებნა, ეს კი მიიღწევა გროვის პოზიციის და ე.წ. ფიტნეს ფუნქციის მუდმივი ოპტიმიზაციის გზით.

PSO-ს პარადიგმების მიხედვით, საძიებო არეში მოძრავი გროვის ნებისმიერი ნაწილაკი წარმოადგენს ოპტიმიზაციის ამოცანის პოტენციურ ამონახსნს. ალგორითმის მიზანია ნაწილაკების შეგროვება მიზნობრივი ფუნქციის გლობალურ (მთელი საძიებო არე) ან ლოკალურ (კონკრეტული კლასტერი) ოპტიმუმებში.

ამდენად, ნაწილაკების გროვის ოპტიმიზაცია წარმოადგენს ხელოვნურ ნაწილაკთა პოპულაციაზე დაფუძნებულ სტოქასტიკურ-ვერისტიკულ მეთოდს, სადაც საძიებელ სივრცეში მიზნისკენ გადაადგილება ხდება თანამიმდევრულად, ევოლუციურად. მისი მოდელი შეიცავს ნაწილაკთა გროვას, რომლის პოპულაციის ინიციალიზაცია ანუ ნაწილაკთა საძიებელ სივრცეში „გაბნევა“ ხდება რანდომიზებულად. ნაწილაკების გროვის ოპტიმიზაციის ალგორითმში ამონახსნი მიიღება სწორედ ამ ინდივიდუალური აგენტების სიმრავლის იტერაციის შედეგად. მეთოდი არ იძლევა გადაწყვეტილების პოვნის 100% - იან გარანტიას. მიუხედავად ამისა, იგი მრავალი სხვადასხვა ამოცანების გადასაჭრელად გამოიყენება მისი სიმარტივის, ინტუიციურობის და პარალელურობის თვისების გამო.

**მეთოხე თავში** შემოთავაზებულია რისკების პროგნოზირების ამოცანის გადაწყვეტისათვის ნაწილაკთა გროვის ოპტიმიზაციის მოდიფიცირებული ალგორითმი, როგორც გლობალური ოპტიმუმის განსაზღვრის ახალი მიდგომა.

კოჰონენის თვითორგანიზებადი ქსელის განსწავლის პროცესში აუცილებელ პირობას წარმოადგენს ე.წ. „გამარჯვებული ნეირონის“ განსაზღვრა, რომლის მიხედვითაც ხდება ნეირონული ქსელის კოეფიციენტების კორექტირება. გამარჯვებული ნეირონის პოვნის ამოცანა შეიძლება განვიხილოთ

როგორც ოპტიმიზაციის ამოცანა, რომლის ეფექტური გადაწყვეტა შესაძლებელია ხელოვნური ინტელექტის მეთოდების, კერძოდ მულტი-აგენტური ევოლუციური ოპტიმიზაციის საფუძველზე. ნაშრომში წარმოდგენილია ახალი ალგორითმი ნაწილაკთა გროვის ოპტიმიზაციის (PSO) მეთოდის ბაზაზე. ნაწილაკის გადაადგილებისთვის აუცილებელი პირობაა საკუთარი პოზიციის და შესაბამისად მთელი გროვის პოზიციის გაუმჯობესება. გროვის მიზანია, საძიებო არეში ფიტნეს ფუნქციის გლობალური ოპტიმუმის მოძებნა რაც მიიღწევა ნეირონული ქსელის ე.წ. „წონითი კოეფიციენტების“ კორექტირებით და იტერაციულ პროცესში დინამიური რეკლასტერიზაციის მეთოდის არჩევით.

ალგორითმის მუშაობის სქემა შედგება რამდენიმე ბიჯისაგან:

**I. ინიციალიზაცია.** თითოეული ნაწილაკი შეიძლება დავახასიათოთ სამი თვისებით:

ა) პოზიცია  $p_k^i$  -  $i$ -ური ნაწილაკის პოზიცია  $k$ -ურ დროში ან ბიჯზე განისაზღვრება კოორდინატებით:

$$p_k^i = [x_k^i, y_k^i], \quad i=1,2,$$

ბ) სიჩქარე  $v_k^i$  - ნაწილაკები ოპტიმუმის ძიების პროცესში განუწყვეტლივ მოძრაობენ საძიებო არეში. მოძრაობა განისაზღვრება მიმდინარე კოორდინატებიდან სწორად განსაზღვრული მანძილით პოზიციის ცვლილებით.

გ) ფიტნეს ფუნქცია  $f(p_k^i)$  - განსაზღვრავს თუ რომელ ნაწილაკს აქვს საუკეთესო მნიშვნელობა გროვაში და ასევე ნაწილაკის საუკეთესო პოზიციას დროის ან იტერაციების მანძილზე.

ნაწილაკების გროვა შედგება ზემოთ აღწერილი ნაწილაკების სიმრავლისგან:

$$P_k = \{p_k^i\}, \quad i=1,2, \dots, N.$$

ინიციალიზაციის დროს უნდა განისაზღვროს საწყისი პარამეტრები: გროვის ზომა  $N$ , წონის პარამეტრები  $c_1, c_2$ , რომელთაც შემეცნებით და

სოციალურ პარამეტრებსაც უწოდებენ, საძიებო არის საზღვრები  $x_{min}$ ,  $x_{max}$ ,  $y_{min}$ ,  $y_{max}$ , ალგორითმის შეწყვეტის კრიტერიუმები  $G$ ,  $\mu$ .

თავდაპირველად  $k \leftarrow 0$ . ამის შემდეგ, უკვე განსაზღვრულ არეში, უნდა დავსვათ  $N$  რაოდენობის ნაწილაკი შემთხვევითად დაგენერირებულ პოზიციებზე.

$$p_0^i = p_{min} + rand(p_{max} - p_{min})$$


სადაც  $p_{min}$  და  $p_{max}$  არის საძიებო არის შესაბამისი მინიმალური და მაქსიმალური ლიმიტები.

შემდეგ გამოითვლება ფიტნეს ფუნქციის მნიშვნელობა თითოეული ნაწილაკისთვის და ინახება ნაწილაკის მუხსიერებაში. ნაწილაკის საუკეთესო პოზიცია ინიციალიზაციის ეტაპზე იქნება მიმდინარე პოზიცია  $p_0^i$ . და ბოლოს განისაზღვრება ყოველი ნაწილაკის საწყისი სიჩქარე, რომლითაც უნდა დაიწყოს მოძრაობა:

$$v_0^i = \frac{p_{min} + rand(p_{max} - p_{min})}{\Delta t}$$

**II. კლასტერიზაცია.** კლასტერიზაციისთვის აუცილებელია თითოეული ნაწილაკისთვის საწყის კოორდინატებში ფიტნეს ფუნქციის გამოთვლა. ფიტნეს ფუნქციის საფუძველზე, ანუ საუკეთესო პოზიციებზე ირჩევა  $M$  რაოდენობის ლიდერი ნაწილაკები, დანარჩენი ნაწილაკები კი ავტომატურად ხდებიან აუტსაიდერები (ნახ.5).

$$l_j = \{p_k^i\}, \quad j=1,2,\dots,M$$



ნახ.5: ლიდერების არჩევა

ლიდერების არჩევა შემდეგნაირად ხდება: იგება გრაფიკი, სადაც აბსცისთა ღერძზე განლაგდება ნაწილაკები ( $p$ ) ფიტნეს ფუნქციის მნიშვნე-



ლობათა კლუბადობის მიხედვით სორტირებული, ხოლო ორდინატთა ღერძზე გადაიზომება ნაწილაკთა შორის დისტანციები ( $d$ ). ვიმახსოვრებთ თითოეულ კოორდინატს ( $p$ ,  $d$ ), რომელიც შეესაბამება  $p$  ნაწილაკს  $d$  სხვაობით. კოორდინატთა სათავეში მოხვდება  $p_1$  ნაწილაკი ფიტნეს ფუნქციის მაქსიმალური მნიშვნელობით.

$$r_1 = r_{\max}; \quad r_i = f(p_i), \quad i=1,2, \dots, N. \quad d_i = r_{\max} - r_i$$

$$\bar{d} = \frac{\sum_{i=1}^N d_i}{N}; \quad \bar{d}_i = \frac{\sum_{i=1}^N d_i}{i}$$

ამის შემდეგ კოორდინატთა სათავედან აიგება ნაწილაკთა გამყოფი ე.წ. „რუბიკონის“ წრფე შემდეგი ფორმულით:

$$B = \frac{\sum_{i=1}^N r_i}{N(r_{\max} - r_N)}$$

წერტილები, რომლებიც მოხვდებიან აღნიშნული წრფის ქვემოთ გახდებიან ლიდერები, ხოლო შესაბამისად ზემოთ აუტსაიდერები:

$$p_i = \begin{cases} d_i \leq \bar{d}_i & \text{- leader} \\ \text{otherwise} & \text{- outsider} \end{cases}$$

ლიდერების მიხედვით K-Means ალგორითმის გამოყენებით ხდება მოცემული არის კლასტერიზაცია. ამასთან, ყოველ კლასტერში თითოეულ აუტსაიდერი ნაწილაკის ქცევა განიხილება მხოლოდ ლიდერ ნაწილაკთან მიმართებით. K-Means ალგორითმი საშუალებას იძლევა გადავანაწილოთ  $N$  აუტსაიდერი  $M$  ლიდერების სიმრავლეზე  $L = \{l_r\}$ ,  $r=1,2, \dots, M$ , ისე, რომ მინიმუმამდე დაიყვანოს კლასტერის წერტილების საერთო კვადრატული გადახრა კლასტერის ცენტრიდან, რომელიც ჩვენს შემთხვევაში ლიდერ ნაწილაკს შეესაბამება:

$$\arg \min_L = \sum_{l_c=1}^M \sum_{p_k^i \in L} \|p_k^i - p_k^j\|$$

**III. განახლება.** განახლება იტერაციული პროცესია, რომლის დროსაც ხდება ნაწილაკების სიჩქარისა და პოზიციისათვის ახალი მნიშვნელობების გამოთვლა, რაც, თავის მხრივ, დამოკიდებულია ნაწილაკის წინა იტერაციის

პარამეტრებზე (სიჩქარე, აჩქარება, პოზიცია), ნაწილაკის საუკეთესო პოზიციაზე და ამ ნაწილაკზე გროვის გავლენაზე.

$$v_{k+1}^i = wv_k^i + c_1 \text{rand} \frac{(p_k^l - p_k^i)}{\Delta t} + c_2 \text{rand} \frac{(p_k^g - p_k^i)}{\Delta t}$$

სადაც:  $w$  - არის ინერცია;

$p_k^l$  - ლოკალური(ნაწილაკის) საუკეთესო პოზიცია;

$p_k^g$  - გლობალური(გროვის) საუკეთესო პოზიცია;

$wv_k^i$  - მოძრაობა მიმდინარე იტერაციის დროს;

$\frac{(p_k^l - p_k^i)}{\Delta t}$  - ნაწილაკის გავლენის ფაქტორი;

$\frac{(p_k^g - p_k^i)}{\Delta t}$  - გროვის გავლენის ფაქტორი;

$c_1, c_2$  - შემეცნებითი და სოციალური პარამეტრები.

როგორც წესი  $c_1, c_2$ -არის კონსტანტები, რომლებიც ირჩევა ინიციალიზაციის ეტაპზე, მაგრამ ჩვენს მიდგომაში ეს პარამეტრები ყოველ იტერაციაზე ზუსტდება, რაც უფრო ეფექტურ შედეგს იძლევა სტანდარტულ მეთოდთან შედარებით:

$$c_1 = p_k^l/p_k^g, \quad c_2 = 1 - (p_k^l/p_k^g)$$

თუ ნაწილაკის წინა იტერაციის პოზიცია არ არის ვარგისი, მაშინ მიმდინარე იტერაციაზე ვანულებთ და მხედველობაში აღარ ვიღებთ წინა იტერაციის სიჩქარეს, შესაბამისად, ასეთ შემთხვევაში  $wv_k^i$ -პარამეტრი ფორმულიდან ამოვარდება. ნაწილაკის პოზიციის განახლება კი ხდება უკვე გამოთვლილი სიჩქარის ვექტორის დახმარებით:

$$p_{k+1}^i = p_k^i + v_{k+1}^i \Delta t$$


გროვის საუკეთესო პოზიცია განისაზღვრება ლიდერის საუკეთესო პოზიციით და დგინდება შემდეგნაირად:

$$l_{k+1}^r = p_{k+1}^g = [x_{k+1}^g, y_{k+1}^g], \quad r=1,2, \dots, M.$$

$$p_{k+1}^g = \begin{cases} p_{k+1}^i & \text{if } f(p_{k+1}^i) \leq f(p_k^g), \\ p_k^g & \text{Otherwise} \end{cases}$$

ამგვარად, თითოეულ იტერაციაზე, ნაწილაკების სიჩქარისა და პოზიციის განახლების შემდეგ, ხდება ნაწილაკების და გროვის საუკეთესო პოზიციების განახლება.

**IV. რეკლასტერიზაცია.** ამის შემდეგ ხდება „რუბიკონის“ წრფის დახრის შემცირება „ოქროს კვეთის“ პროპორციის მიხედვით, როდესაც  $B$  მცირდება 0,6183 - ჯერ, რაც იწვევს ლიდერთა ჯგუფის შეცვლა-შემცირებას და რეკლასტერიზაციას ანუ აუტსაიდერების გადანაწილებას ლიდერების ახალ სიმრავლეზე (ნახ.6).



ნახ.6: რეკლასტერიზაციით ლიდერების არჩევა

**V. ალგორითმის შეწყვეტის კრიტერიუმი.** ალგორითმის შეწყვეტის კრიტერიუმად ჩაითვლება მომენტი, როდესაც შესრულდება პირობა:

$$B = \frac{\sum_{i=1}^N r_i}{N(r_{\max} - r_N)} \leq \mu$$

სადაც:  $\mu$  - არის წინასწარ განსაზღვრული სიზუსტის მნიშვნელობა.

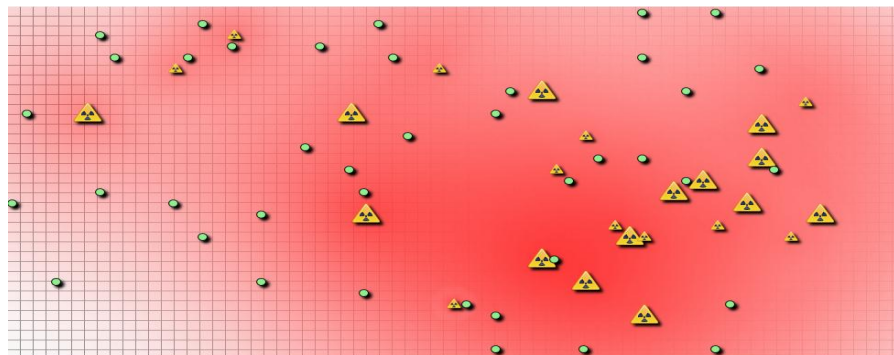
თუ კმაყოფილდება აღნიშნული პირობა, მაშინ ალგორითმი წყვეტს მუშაობას და გამოგვაქვს შედეგი. ამონახსნად ჩაითვლება მიღებული ლიდერთა ჯგუფის თითოეული ნაწილაკისთვის ფიტნეს ფუნქციების გასაშუალებული მნიშვნელობა. თუ პირობა არ დაკმაყოფილდა გადავდივართ IV ბიჯზე.

ამდენად, რისკების პროგნოზირების ამოცანის გადაწყვეტისათვის შემოთავაზებულია კოპონენის თვითორგანიზებადი ქსელის გამოყენება, რომლის განსწავლის პროცესში აუცილებელ პირობას წარმოადგენს ე.წ. „გამარჯვებული ნეირონის“ განსაზღვრა, რისთვისაც შემუშავებული იქნა

ნაწილაკთა გროვის ოპტიმიზაციის მოდიფიცირებული ალგორითმი, როგორც გლობალური ოპტიმუმის განსაზღვრის ახალი მიდგომა.

ამავე თავში განხილულია ნაწილაკთა გროვის ოპტიმიზაციის მოდიფიცირებული ალგორითმის მიხედვით ჩატარებული გამოთვლების შედეგები და ანალიზი. ჩვენი ალგორითმის მიხედვით ჩავატარეთ მრავალი გამოთვლითი ექსპერიმენტი. ოპტიმუმის მნიშვნელობა წინასწარ იყო შერჩეული. ასევე ექსპერიმენტის დროს განისაზღვრა საწყისი პარამეტრები, რომლებიც დაყვანილი სახით არის წარმოდგენილი.

ჩატარებულ იქნა ოცზე მეტი გამოთვლითი ექსპერიმენტი. თითოეული ექსპერიმენტის დროს მოცემულ საძიებო არეში რანდომიზებულად ხდებოდა  $N$  რაოდენობის ნაწილაკი შემთხვევით პოზიციებზე განლაგება (ნახ.7), რის შემდეგაც სრულდებოდა შემუშავებული ალგორითმი ზემოგანხილული ბიჯების მიხედვით.



ნახ.7: საწყისი მონაცემები

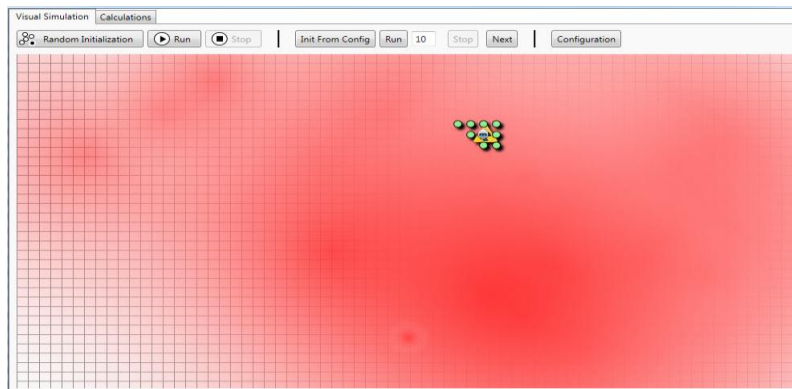
ძიების პროცესში თუ აღმოჩნდა ისე, რომ რომელიმე მიმდევარი ნაწილაკის პოზიცია უკეთესია ვიდრე ლიდერი ნაწილაკისა, მაშინ მიმდევარი ნაწილაკი ავტომატურად გახდება ლიდერი და პირიქით, ანუ ლიდერი იძენს მიმდევარის სტატუსს.

ყოველ იტერაციაზე ხდება ე.წ. „რუბიკონის“ წრფის დახრის შემცირება „ოქროს კვეთის“ პროპორციის მიხედვით და შედეგად ლიდერთა ჯგუფის შეცვლა-შემცირება ანუ რეკლასტერიზაცია, რაც იწვევს აუტსაიდერების გადანაწილებას ლიდერების ახალ სიმრავლეზე.

ალგორითმის შეწყვეტის კრიტერიუმის დაკმაყოფილების შემთხვევაში ექსპერიმენტი დასრულებულად ჩაითვლება. გამოდის მოცემული

ექსპერიმენტის შედეგები: ლიდერისა და მიმდევარ ნაწილაკთა საბოლოო გროვის ბიჯების რაოდენობა და სიზუსტე ანუ სხვაობა ოპტიუმის წინასწარ შერჩეულ მნიშვნელობასა და ლიდერის საბოლოო პოზიციას შორის, აგრეთვე მიმდევარ ნაწილაკთა საბოლოო გროვის საბოლოო პოზიციების საშუალო მნიშვნელობებს შორის. გამოითვლება ასევე მოცემული ექსპერიმენტის საშუალო სიზუსტეც.

(ნახ.8)-ზე მოცემულია ერთ-ერთი ექსპერიმენტის საბოლოო მდგომარეობა, სადაც ნათლად ჩანს ლიდერისა და მისი მიმდევარი გროვის პოზიციები (წრეები) წინასწარ შერჩეული ოპტიუმის (ყვითელი სამკუთხედი) მიმართ:



ნახ. 8: ლიდერი ნაწილაკი და მისი მიმდევარი გროვა

ჩატარებული ექსპერიმენტების სერიის საბოლოო შედეგები მოცემულია (ცხრილი 1)-ში:

ლიდერის ბიჯების საშუალო მნიშვნელობა	გროვის ბიჯების საშუალო მნიშვნელობა	ლიდერის სიზუსტის საშუალო მნიშვნელობა	ლიდერის სიზუსტის საშუალო მნიშვნელობა	საშუალო სიზუსტის საშუალო მნიშვნელობა
3.75	6.35	98.278	91.68649	97.45925

ცხრილი 1: საბოლოო შედეგები

გამოთვლითი ექსპერიმენტების სტატისტიკური შედეგები ცხადყოფენ შემუშავებული მოდიფიცირებული ალგორითმის მაღალ სიზუსტესა და კრებადობის შესახებ, რომლის დადგენაც წარმოდგენდა ჩვენი კვლევების მიზანს.

## დასკვნა

თანამედროვე საფინანსო ბაზარი, რომელიც წარმოადგენს დიდი განზომილების, ურთულეს სისტემას საინფორმაციო და რისკების მთელი სპექტრის ეფექტური მართვისა და პროგნოზირების თვალსაზრისით, საჭიროებს შესაბამისი მეთოდების შემუშავებასა და იმპლემენტაციას. რისკ-მენეჯმენტის ერთ-ერთ მთავარ ფუნქციას სწორედ პროგნოზირება შეადგენს.

ამდენად, სადისერტაციო ნაშრომში „საფინანსო სისტემებში რისკების პროგნოზირება ხელოვნური ინტელექტის მეთოდების გამოყენებით“, პროგნოზირების დღეს არსებული მეთოდების პარალელურად, შემუშავდა თანამედროვე მეცნიერულ ცოდნაზე, კერძოდ ხელოვნური ინტელექტის თეორიაზე დაფუძნებული ახალი მიდგომები, რაც წარმოადგენს მოცემული სადისერტაციო ნაშრომის მიზანს.

სადისერტაციო ნაშრომში წარმოდგენილია რამდენიმე მოდიფიცირებული ევოლუციური ალგორითმი. პირველ ალგორითმში შემუშავებული მეცნიერული სიახლე კერძოდ, პროგნოზირების თვალსაზრისით, შემოთავაზებულია ხელოვნური ნეირონული ქსელების ერთ-ერთი სახესხვაობა, კოჰონენის თვითორგანიზებადი რუკები - Self-Organizing Maps (SOM), რომელიც იყენებს ქსელის არაკონტროლირებადი სწავლების მეთოდს ანუ განსწავლას მასწავლებლის გარეშე.

ხელოვნური ნეირონული ქსელის განსწავლის პროცესში აუცილებელ პირობას წარმოადგენს ე.წ. „გამარჯვებული ნეირონის“ განსაზღვრა, რომლის მიხედვითაც ხდება ნეირონული ქსელის კოეფიციენტების კორექტირება. კოჰონენის ქსელი, მრავალშრიანი ნეირონული ქსელისგან განსხვავებით, შეიცავს მხოლოდ ორ შრეს: შემავალს და გამომავალს. ასეთი ქსელის გამოყენება ნაკარნახებია იმით, რომ მრავალგანზომილებიან ნეირონულ ქსელში დიდ სირთულეებთან არის დაკავშირებული რთული შინაგანი (ფარული შრეების) სტრუქტურის წარმოდგენა.

შემოთავაზებულია აგრეთვე მეორე სიახლე, კერძოდ განსწავლის პროცესში ე.წ. „გამარჯვებული ნეირონის“ განსაზღვრისთვის ნაწილაკთა გროვის ოპტიმიზაციის (PSO) ალგორითმის გამოყენება, რომლის უპირატესობას წარმოადგენს ოპტიმუმის პოვნის პარალელური პროცესი.

მესამე ალგორითმში სიახლედ შეიძლება ჩაითვალოს ნაწილაკთა გროვის ოპტიმიზაციის (PSO) მოდიფიცირებული ალგორითმი, როგორც გლობალური ოპტიმუმის განსაზღვრის ახალი მიდგომა. მოცემულ ალგორითმში ჩვენ მიერ არის შემუშავებული ნაწილაკთა დინამიური კლასტერიზაციის ახლებური მიდგომა, კერძოდ, „ოქროს კვების“ გამოყენებით.

ამდენად, გამოთვლითი ექსპერიმენტების სტატისტიკური შედეგები ცხადყოფენ შემუშავებული მოდიფიცირებული ალგორითმის მაღალ სიზუსტესა და კრებადობის შესახებ, რომლის დადგენაც წარმოადგენდა ჩვენი კვლევების მიზანს და დისერტაციის მიღწევას.

**დისერტაციის ირგვლივ გამოქვეყნებული ნაშრომების სია:**

1. Meparishvili B., **Koroglishvili C.**, Meishvili S. Financial risk management: a survey. Transactions. Georgian Technical University. AUTOMATED CONTROL SYSTEMS, №1(12), Tbilisi, 2012, pp. 180-184
2. **ქოროლიშვილი ც.** იმიტაციური მოდელირების გამოყენება საფინანსო რისკების მართვაში. სტუ მართვის ავტომატიზებული სისტემები №2(13), თბილისი, 2012, გვ. 165-170
3. Meparishvili B., **Qoroglishvili C.** Financial market forecast using artificial intelligence. Transactions. Georgian Technical University. AUTOMATED CONTROL SYSTEMS, №1(14), Tbilisi, 2013, pp. 158-163
4. Meparishvili B., **Qoroglishvili C.** New approach to global optimization based on pso. Transactions. Georgian Technical University. AUTOMATED CONTROL SYSTEMS, №1(17), Tbilisi, 2014, pp. 17-22
5. **ქოროლიშვილი ც.** ზოგიერთი ევოლუციური ალგორითმის გამოყენება რისკების პროგნოზირებაში. სტუ მართვის ავტომატიზებული სისტემები №2(18), თბილისი, 2014, გვ. 16-20
6. **ქოროლიშვილი ც.** ნაწილაკთა გროვის ოპტიმიზაციის მოდიფიცირებული ალგორითმი. ჟურნალი „ინტელექტი“, თბილისი, 2014, გვ. 78-81
7. ჯანელიძე გ., მეფარიშვილი ბ., **ქოროლიშვილი ც.** „საინფორმაციო სისტემებზე თავდასხმის ძიების ამოცანებში ხელოვნური ინტელექტის მეთოდების გამოყენება“. III საერთაშორისო-სამეცნიერო კონფერენცია. კომპიუტინგი/ინფორმატიკა, განათლების მეცნიერებები, მასწავლებლის განათლება, ბათუმი, 17-19 ოქტომბერი 2014.