

საქართველოს ტექნიკური უნივერსიტეტი

ციური ქოროლიშვილი

„საფინანსო სისტემებში რისკების პროგნოზირება ხელოვნური  
ინტელექტის მეთოდების გამოყენებით“

წარმოდგენილია დოქტორის აკადემიური ხარისხის მოსაპოვებლად

სადოქტორო პროგრამა „ინფორმატიკა“ შიფრი 0401

საქართველოს ტექნიკური უნივერსიტეტი

თბილისი, 0175, საქართველო

თებერვალი, 2015 წელი

საავტორო უფლება © 2015 წელი, ციური ქოროლიშვილი

თბილისი

2015 წელი

სამუშაო შესრულებულია საქართველოს ტექნიკურ უნივერსიტეტში  
ინფორმატიკისა და მართვის სისტემების ფაკულტეტი  
მართვის ავტომატიზებული სისტემების დეპარტამენტი

ხელმძღვანელი: პროფ. ბადრი მეფარიშვილი

რეცენზენტები: პროფ. გურამ ცერცვაძე  
ტმდ ოთარ ლაბაძე

დაცვა შედგება ----- წლის “-----“-----, ----- საათზე  
საქართველოს ტექნიკური უნივერსიტეტის -----  
----- ფაკულტეტის სადისერტაციო საბჭოს კოლეგიის  
სხდომაზე, კორპუსი -----, აუდიტორია -----  
მისამართი: 0175, თბილისი, კოსტავას 77

დისერტაციის გაცნობა შეიძლება სტუ-ს ბიბლიოთეკაში,  
ხოლო ავტორეფერატისა – ფაკულტეტის ვებგვერდზე

სადისერტაციო საბჭოს მდივანი პროფ. თინათინ კაიშაური

ავტორი: ციური ქოროლიშვილი

დასახელება: „საფინანსო სისტემებში რისკების პროგნოზირება ხელოვნური ინტელექტის მეთოდების გამოყენებით“

ფაკულტეტი: ინფორმატიკისა და მართვის სისტემები

ხარისხი: აკადემიური დოქტორი

სხდომა ჩატარდა:

ინდივიდუალური პროცნებების ან ინსტიტუტების მიერ შემომოყვანილი დასახელების დისერტაციის გაცნობის მიზნით მოთხოვნის შემთხვევაში მისი არაკომერციული მიზნებით კოპირებისა და გავრცელების უფლება მინიჭებული აქვს საქართველოს ტექნიკურ უნივერსიტეტს.

---

ავტორის ხელმოწერა

ავტორი ინარჩუნებს დანარჩენ საგამომცემლო უფლებებს და არც მთლიანი ნაშრომის და არც მისი ცალკეული კომპონენტების გადაბეჭდვა ან სხვა რაიმე მეთოდით რეპროდუქცია დაუშვებელია ავტორის წერილობითი ნებართვის გარეშე.

ავტორი ირწმუნება, რომ ნაშრომში გამოყენებული საავტორო უფლებებით დაცული მასალებზე მიღებულია შესაბამისი ნებართვა (გარდა იმ მცირე ზომის ციტატებისა, რომლებიც მოითხოვენ მხოლოდ სპეციფიურ მიმართებას ლიტერატურის ციტირებაში, როგორც ეს მიღებულია სამეცნიერო ნაშრომების შესრულებისას) და ყველა მათგანზე იღებს პასუხისმგებლობას.

## რეზიუმე

სადისერტაციო ნაშრომი, საფინანსო სისტემებში რისკების პროგნოზირება ხელოვნური ინტელექტის მეთოდების გამოყენებით, ეძღვნება საფინანსო ბაზრის რისკების მენეჯმენტის ერთ-ერთ აქტუალურ საკითხს, როგორცაა რისკების პროგნოზირება.

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. რთული საფინანსო სისტემის კვლევა საჭიროებს ანალიზისა და მოდელირების კომპლექსური მეთოდური სისტემის შემუშავებასა და იმპლემენტაციას რისკების მართვის სფეროში.

**მოცემულ ნაშრომში** განხილულია რისკების სახეობები, მათი ანალიზისა და შეფასების სხვადასხვა მეთოდები. მთავარი სირთულე მდგომარეობს იმაში, რომ არ არსებობს რაიმე უნიკალური მიდგომა რისკების მართვისთვის თანამედროვე საფინანსო ბაზრის პირობაზე, რომელიც თავის მხრივ წარმოადგენს დიდი განზომილების, ურთულეს სისტემას საინფორმაციო და რისკების მთელი სპექტრის ეფექტური მართვის თვალსაზრისით. ამდენად, ცხადი ხდება რისკების ხარისხის შეფასებისა და პროგნოზირებისათვის ახალი, უფრო ეფექტური მეთოდების შემუშავების აუცილებლობა და აქტუალობა.

პრობლემის დასმისა და გადაწყვეტის თვალსაზრისით, ნაშრომში განხილულია მრავალი ალგორითმი, რომელიც გამოიყენება თანამედროვე საფინანსო სისტემებში. მიზანშეწონილად მიგვაჩნია პროგნოზირების ფართო სპექტრის (სტატისტიკური, მონტე-კარლოსა და სხვა იმიტაციური მოდელირების) მეთოდების მიმოხილვა და ანალიზი, ხელოვნური ინტელექტის თანამედროვე მიღწევების (ხელოვნური ნეირონული ქსელების, ევოლუციური ალგორითმების და სხვ.) გათვალისწინებით. ამდენად, პროგნოზირების დღეს არსებული მეთოდების პარალელურად, აუცილებელია შემუშავდეს თანამედროვე მეცნიერულ ცოდნაზე, კერძოდ ხელოვნური ინტელექტის თეორიაზე დაფუძნებული მეთოდები, რაც წარმოადგენს მოცემული სადისერტაციო თემის საგანს.

ნაშრომის **კვლევის ობიექტს** წარმოადგენს ევოლუციური მეთოდები და ალგორითმები როგორცაა: გენეტიკური ალგორითმები, გენეტიკური პროგრამირება, ხელოვნური ნეირონული ქსელები, კოჰონენის თვითორგანიზებადი რუკა, „ამოწვის იმიტაციის“ ალგორითმი, „იმპერიალისტური შეჯიბრებითი“ ალგორითმი, ნაწილაკთა გროვის ოპტიმიზაციის მეთოდი და სხვ.

საფინანსო რისკების მართვის პროცესები შეიძლება განვიხილოთ მულტიაგენტური მოდელირების საფუძველზე, სადაც ხელოვნური ინტელექტის მეთოდების გამოყენება მნიშვნელოვნად ამაღლებს ეფექტურობას. ზუსტი მეთოდებისაგან განსხვავებით, მათემატიკური

პროგრამირების ევოლუციური მეთოდები გვაძლევს საშუალებას, ვიპოვოთ ოპტიმალურთან ახლოს მდგომი ამონახსნები მისაღებ დროში. ევოლუციური ალგორითმები არის საძიებო არეში მიახლოებითი საუკეთესო მნიშვნელობის ძიების ალგორითმები, რომელშიც პოპულაციის ინდივიდები გამოიყენება საპრობლემო არის გლობალური შესწავლის მიზნით, ასევე ლოკალური საუკეთესო ამონახსნების ძიების მიზნით, რასაც საბოლოოდ მივყავართ კონკრეტული საპრობლემო არის გლობალური ოპტიმიზაციისკენ.

ფინანსური ბაზრის ანალიზისა და პროგნოზირების თანამედროვე მიდგომას წარმოადგენს ხელოვნური ნეირონული ქსელები - Artificial Neural Networks (ANN), რომელიც არის ერთი ტიპის ელემენტების ნეირონების მრავალფენიანი ქსელური სტრუქტურა. ნეირონული ქსელების სწავლების ალგორითმების უმეტესობას საფუძვლად უდევს გრადიენტული ოპტიმიზაციის მეთოდი - სინაპსური წონების იტერაციული ცვლილება, რომელიც ნაბიჯ-ნაბიჯ ამცირებს ნეირონული ქსელის სწავლების საგნის დამუშავების ცდომილებას. ხელოვნური ნეირონული ქსელი წარმოადგენს მოდელირების მძლავრ ინსტრუმენტს, ANN-ს წარმატებით იყენებენ არაორდინალური პრობლემების გადასაწყვეტად.

ჩვენი მიზანია შევიმუშავოთ ისეთი ევოლუციური ალგორითმი, რომელიც რაიმე პარამეტრით გააუმჯობესებს არსებულ მიდგომას. ნაშრომში წარმოდგენილია რამდენიმე მოდიფიცირებული ალგორითმი. ერთი-ერთი არის ნეირონული ქსელების სახეობა, ე.წ. კოჰონენის თვითორგანიზებადი რუკები - Self-Organizing Maps (SOM), რომელიც იყენებს ქსელის არაკონტროლირებადი სწავლების მეთოდს, რომლის დროსაც, შესასწავლი ობიექტების სიმრავლე შედგენილია მხოლოდ შემავალი ცვლადების მნიშვნელობებისაგან და სწავლების პროცესში ნეირონებიდან გამომავალი მნიშვნელობების შედარება არ ხდება ეტალონურ მნიშვნელობებთან და ქსელი სწავლობს მონაცემთა სტრუქტურის გაგებას.

კოჰონენის ქსელი მრავალშრიანი ნეირონული ქსელისგან განსხვავებით შეიცავს მხოლოდ ორ შრეს: შემავალს და გამომავალს. კოჰონენის ალგორითმის იტერაციული პროცესი სრულდება რამდენიმე ეტაპად. თითოეულ ამ ეტაპზე მუშავდება მხოლოდ ერთი მაგალითი სასწავლო ნიმუშებიდან. ალგორითმის მუშაობის შედეგად, კლასტერის ცენტრი ექცევა იმ პოზიციაში რომელიც აკმაყოფილებს კლასტერიზაციის შესასწავლ მაგალითს, რომელთათვისაც მოცემული ნეირონი წარმოადგენს „გამარჯვებულს“. ქსელის შესწავლის შედეგად საჭიროა განისაზღვროს მეზობელი ნეირონების გარემოს, ე.ი. „გამარჯვებული“ ნეირონის ირგვლივ მიდამო (რამდენიმე ნეირონი, რომლებიც გარს ეკვრიან გამარჯვებულ ნეირონს). თვითორგანიზებადი რუკის ალგორითმის მთავარი განსხვავება არის ის, 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 რაოდენობით. აღნიშნული მიდგომის, გამოყენება შესაძლებელია საწყისი და საბოლოო მონაცემთა კანონზომიერებების ძებნისა და ანალიზისათვის. გარდა ამისა, ის ახორციელებს მრავალგანზომილებიანი შემავალი სივრცის გამოსახვას ორგანზომილებიან (ზოგჯერ ერთგანზომილებიან) გამომავალ სივრცედ, ე.ი. ახდენს მონაცემთა შეკუმშვას.

ნაშრომში შემუშავებულია კიდევ ერთი ევოლუციური ალგორითმი, რომელიც ეფუძნება ნაწილაკთა გროვის ოპტიმიზაციის ახლებურ მიდგომას, კერძოდ ე.წ. „წონითი კოეფიციენტების“ გამოყენებით.

**ამ მეთოდის სიახლეს** - წარმოადგენს ნაწილაკთა გროვის ოპტიმიზაციის კლასიკური ალგორითმის იტერაციულ პროცესში დინამიური რეკლასტერისაციის მიდგომის ჩართვა. 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. ალგორითმის საბოლოო მიზანია საძიებო არეში ფიტნეს ფუნქციის გლობალური ოპტიმუმის მოძებნა, კერძოდ, ნაწილაკების შეგროვება მიზნობრივი ფუნქციის გლობალურ (მთელი საძიებო არე) ან ლოკალურ (კონკრეტული კლასტერი) ოპტიმუმებში. რისკების პროგნოზირების ამოცანის გადაწყვეტისათვის შემოთავაზებულია კოჰონენის 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.

ჩატარებული გამოთვლითი ექსპერიმენტების სტატისტიკური შედეგები ცხადყოფენ შემუშავებული მოდიფიცირებული ალგორითმის მაღალი სიზუსტისა და კრებადობის შესახებ, რომლის დადგენაც წარმოადგენდა ჩვენი კვლევების მიზანს.

ამდენად, ეს ალგორითმი წარმოადგენს ახალ მიდგომას რისკების პროგნოზირების სფეროში და ეს შედეგი შესაძლებელია წარმატებით იქნას გამოყენებული საფინანსო ბაზრის რისკების მართვის სისტემებში, რითაც საბოლოოდ მიიღწევა მიზანი: შემცირდეს გამოთვლების რაოდენობა და შესაბამისად დაიზოგოს დრო, რომელიც საფინანსო ბაზრის რისკების პროგნოზირების შესრულების ერთ-ერთ ძირითად ღირებულებას წარმოადგენს.

## Summary

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 evolutionary 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 evolutionary 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.



## შინაარსი

შესავალი .....	14
<b>თავი 1. საფინანსო ბაზარი და რისკები.....</b>	<b>18</b>
1.1. ფინანსური ბაზარი. ობიექტის აღწერა.....	18
1.2. რისკების კლასიფიკაცია და შეფასების მეთოდები .....	22
1.3. რისკების მართვა .....	29
1.4. ამოცანის დასმა და გადაწყვეტის სქემა .....	33
<b>თავი 2. რისკების პროგნოზირების მეთოდების მოკლე მიმოხილვა .....</b>	<b>35</b>
2.1. სტატისტიკური მეთოდები .....	35
2.1.1. ფინანსური რისკების ეკონომიკურ-სტატისტიკური შეფასების მეთოდები: დონე და დისპერსია.....	36
2.1.2. დროებითი მწკრივების პროგნოზირების მეთოდები .....	39
2.1.3. შერბილებაზე დაფუძნებული პროგნოზირების მეთოდები .....	40
2.1.4. პროგნოზირების რეგრესიული მეთოდები.....	42
2.1.5. „უახლოესი მეზობლის“ ან მსჯელობათა სისტემის მეთოდი ანალოგიური შემთხვევების საფუძველზე.....	45
2.1.6. პროგნოზირების ამოცანის გადაწყვეტა .....	46
2.2. მონტე-კარლოს მეთოდი და მისი გამოყენება რისკების შეფასებისათვის ფინანსურ ბაზარზე.....	49
2.3. VAR მეთოდების განვითარება რისკების შეფასებისათვის ფინანსურ ბაზარზე.....	51
2.4. იმიტაციური მოდელირება რისკების მართვაში.....	57
2.5. საფინანსო ბაზარი როგორც მრავალაგენტური სისტემა .....	63
<b>თავი 3. ხელოვნური ინტელექტის მეთოდების მიმოხილვა.....</b>	<b>68</b>
3.1. ევოლუციური ალგორითმები.....	68
3.2. რისკების პროგნოზირება გენეტიკური ალგორითმი საფუძველზე.....	69
3.3. გენეტიკური პროგრამირება.....	74
3.4. ხელოვნური ნეირონული ქსელები ფინანსური რისკების პროგნოზირებისათვის.....	78
3.5. კოჰონენის თვითორგანიზებადი რუკა.....	85
3.6. კოჰონენის რუკაზე გამარჯვებული ნეირონის გამოვლინების ალგორითმების მოკლე მიმოხილვა.....	98
3.6.1. ამოწვის იმიტაციის ალგორითმი.....	98
3.6.2. იმპერიალისტური შეჯიბრებითი ალგორითმი.....	99
3.6.3. ნაწილაკების გროვის ოპტიმიზაციის მეთოდი.....	105
<b>თავი 4. ექსპერიმენტული კვლევა.....</b>	<b>114</b>
4.1. ნაწილაკების გროვის ოპტიმიზაციის მოდიფიცირებული ალგორითმი	114
4.2. გამოთვლების შედეგები და ანალიზი.....	120
დასკვნა .....	128
დანართი.....	130
ლიტერატურა.....	131

## ცხრილების ნუსხა

ცხრილი 4.1. (1-7)-ცდის შედეგები.....	124
ცხრილი 4.2. (8-13)-ცდის შედეგები.....	125
ცხრილი 4.3. (14-18)-ცდის შედეგები.....	126
ცხრილი 4.4. (19-20)-ცდის შედეგები.....	127
ცხრილი 4.5. საბოლოო შედეგი.....	127

## ნახაზების ნუსხა

ნახ. 1.1. ფინანსური ბაზრის სტრუქტურა.....	19
ნახ. 1.2. ფინანსურ ბაზრები .....	19
ნახ. 1.3. ფინანსური რისკების სისტემა.....	23
ნახ. 2.1. კლასების გაყოფა სწორი ხაზით.....	43
ნახ. 2.2. საყრდენი ვექტორების განსაზღვრისთვის.....	44
ნახ. 2.3. საყრდენი ვექტორები.....	44
ნახ. 2.4. სიმრავლის ობიექტების კლასიფიკაცია $K$ პარამეტრის სხვადასხვა მნიშვნელობისას.....	46
ნახ. 2.5. პროგნოზირების ამოცანის გადაწყვეტა $k$ პარამეტრის სხვადასხვა მნიშვნელობისას.....	47
ნახ. 2.6. VAR გამოთვლა.....	52
ნახ. 2.7. იმიტაციური მოდელირება.....	58
ნახ. 2.8. იმიტაციური მოდელირების გამოყენების სფეროები.....	58
ნახ. 2.9. სამი ხარისხის აბსტრაქცია.....	59
ნახ. 2.10. სისტემური დინამიკა.....	61
ნახ. 2.11. ინტელექტუალური აგენტი.....	64
ნახ. 3.1. გენეტიკური ალგორითმის მოქმედების ძირითადი ციკლი.....	71
ნახ. 3.2. გენეტიკური ალგორითმის ბლოკ-სქემა.....	74
ნახ. 3.3. გენეტიკური პროგრამირების ალგორითმის ბლოკ-სქემა.....	76
ნახ. 3.4. GP-ში შეჯვარება.....	77
ნახ. 3.5. GP-ში მუტაცია.....	77
ნახ. 3.6. ნეირონის მათემატიკური მოდელი.....	79
ნახ. 3.7. კავშირთა გლობალურობა ხელოვნურ ნეირონულ ქსელებში.....	79
ნახ. 3.8. ქსელის შესწავლა, როგორც ოპტიმიზაციის ამოცანა.....	80
ნახ. 3.9. ANN-ის მოდელის ტიპები.....	82
ნახ. 3.10. სხვადასხვა შემავალ გამოსახულებათა ნორმირების შედეგები..	85
ნახ. 3.11. კოჰონენის ქსელი.....	87
ნახ. 3.12. კოჰონენის რუკის მაგალითი.....	88
ნახ. 3.13. $i$ ნიშნის გაფერადება სამგანზომილებიან სივრცეში.....	89
ნახ. 3.14. ნეირონებში შემავალი ინფორმაციის რუკა.....	89

ნახ. 3.15. კლასტერი.....	90
ნახ. 3.16. გამარჯვებული ნეირონის და მისი მეზობლების წონების ქვეწყობა	92
ნახ. 3.17. თვითორგანიზებადი რუკების მუშაობის მოდელი.....	93
ნახ. 3.18. კოჰონენის გამარჯვებული ნეირონის ვექტორული ასახვა.....	95
ნახ. 3.19. ამოწვის იმიტაციის ალგორითმი.....	99
ნახ. 3.20. იმპერიების და კოლონიების გადანაწილების მაგალითი.....	101
ნახ. 3.21. კოლონიის გადაადგილება $x$ – ერთეულით.....	102
ნახ. 3.22. კოლონიისა და იმპერიალისტის როლების გაცვლა.....	102
ნახ. 3.23. იმპერიების პაექრობა კოლონიის დაპყრობის მიზნით.....	103
ნახ. 3.24. ICA– ს ბლოკ-სქემა.....	104
ნახ. 3.25. PSO-ს ტოპოლოგიის მაგალითები.....	106
ნახ. 3.26ა. შემთხვევითად განაწილებული ნაწილაკები.....	108
ნახ. 3.26ბ. გროვები ლიდერ ნაწილაკებთან.....	108
ნახ. 3.27. ლიდერების არჩევა.....	108
ნახ. 3.28. კლასტერიზაცია.....	109
ნახ. 3.29. გროვის მდგომარეობა $k$ -ურ ბიჯზე.....	111
ნახ. 3.30. ნაწილაკების შეჯგუფების ცენტრალური წერტილი.....	112
ნახ. 3.31. საბოლოო მდგომარეობა.....	113
ნახ. 4.1. ლიდერების არჩევა.....	116
ნახ. 4.2. რეკლასტერიზაციით ლიდერების არჩევა.....	119
ნახ. 4.3. საწყისი მონაცემები.....	120
ნახ. 4.4. კლასტერიზაცია. ....	121
ნახ. 4.5. გროვის მდგომარეობა $k$ -ურ.ბიჯზე.....	121
ნახ. 4.6.რეკლასტერიზაცია.....	122
ნახ. 4.7. მხოლოდ ლიდერი ნაწილაკი.....	122
ნახ. 4.8. ლიდერი ნაწილაკი და მისი მიმდევარი გროვა.....	123

## დისერტაციაში გამოყენებული აბრევიატურები

NYSE - New York Stock Exchange

AMEX - American Stock Exchange

SD - System Dynamics

DEM - Discrete Event Modeling

ABM - Agent Based Modeling

MAS - Multi-Agent Systems

GA - Genetic Algorithms

GP - Genetic Programming

ANN - Artificial Neural Networks

SOM - Self-Organizing Maps

SA - Simulated Annealing

ACO - Ant Colony Optimization

PSO - Particle Swarm Optimization

ICA -Imperialist Competitive Algorithm

VAR- Value At Risk

## შესავალი

**თემის აქტუალობა.** დღევანდელ არაპროგნოზირებულ ეკონომიკურ გარემოში საფინანსო ბაზრის სისტემა ხასიათდება მაღალი დინამიკურობით, მზარდი კონკურენციით და მომხმარებელზე ორიენტაციით. ასეთ გარემოში, ბიზნეს-ორგანიზაციებისთვის სულ უფრო რთული ხდება ფინანსურ ბაზარზე პოზიციების დამკვიდრება და არსებული ეკონომიკური მდგომარეობის შენარჩუნება. ნებისმიერი ბიზნეს-ორგანიზაციის მიზანია მიიღოს მაქსიმალური შემოსავალი მინიმალური კაპიტალის დანახარჯით.

თანამედროვე საბაზრო პირობებში შეუძლებელია გვერდი აუარო დანაკარგს. ბიზნეს-ორგანიზაციების საქმიანობა მუდმივ კავშირშია რისკებთან. არასტაბილურობის პირობებში კი რისკები იზრდება, განსაკუთრებით დიდია ისინი კრიზისების პერიოდში. შედეგად, ერთ-ერთ ძირითად აქტუალურ პრობლემას წარმოადგენს საფინანსო ბაზარზე სწრაფად და ხარისხიანად იქნას მიღებული კრიზისული სიტუაციებისა და ასევე მასთან დაკავშირებული რისკების წინასწარ განჭვრეტა.

რისკების შეფასების სიზუსტე განისაზღვრება მათი დინამიკის პროგნოზირების შესაძლებლობებით და ამ პროგნოზირების საფუძველში ჩადებული მოდელების ადექვატურობით. რთული საფინანსო სისტემების კვლევა საჭიროებს ანალიზისა და მოდელირების მეთოდების გამოყენებას საფინანსო ბაზრის რისკების შეფასებისა და პროგნოზირებისათვის.

რისკ-ფაქტორების გამოვლენისა და შეფასების პროცედურები არასასურველი ხდომილობების თავიდან აცილების საშუალებას იძლევა. მათი ანალიზური დამუშავება მოიცავს რისკების შეფასებისა და რისკების შემცირების სხვადასხვა მეთოდებს. ეს შეიძლება იყოს ერთ-ერთი ალტერნატივა, ან ამ ალტერნატივების კომბინაცია, რომლებიც განხილულია სადისერტაციო ნაშრომის თავებში.

ნაშრომის ძირითადი ტექსტი მოიცავს ოთხ თავს: **პირველ თავში** განხილულია პრობლემის აქტუალობა, საფინანსო ბაზრის არსი და რისკების კლასიფიკაცია. ამავე თავშია მიმოხილული რისკების მართვისა

და შეფასების სხვადასხვა მეთოდები, პროგნოზირების არსი და ადგილი რისკ-მენეჯმენტის მართვის სისტემებში, პრობლემის არსებული ხერხებით გადაწყვეტის და ახალი მეთოდების ძებნის აუცილებლობის არგუმენტაცია.

**მეორე თავში** დასმულია საფინანსო ბაზრის რისკების მართვისა და პროგნოზირების ამოცანის გადაწყვეტა სხვადასხვა მეთოდებით. ფინანსური რისკის პროგნოზირების სტატისტიკური მეთოდები მოიცავს თანამედროვე მათემატიკურ-სტატისტიკურ მეთოდების შესწავლას, შემუშავებასა და გამოყენებას ობიექტური მონაცემების საფუძველზე. პროგნოზირების ექსპერტული მეთოდების ალბათობით-სტატისტიკური მოდელირების თეორიისა და პრაქტიკის განვითარებას. რისკების შეფასებისა და პროგნოზირების მეთოდების შემუშავებასა და გამოყენებას კომბინირებული მეთოდების პირობებში ეკონომიკურ-მათემატიკური და ეკონომეტრიკულ მოდელებთან ერთად.

რადგან 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 ექსპერიმენტების მიდგომა რისკების მართვაში. რისკების პროგნოზირება მოდელების გამოყენებით მოიცავს მოდელის კონსტრუირებას პროცესებისა და ობიექტების წინასწარი შესწავლის საფუძველზე, მისი არსებითი ნიშნებისა და მახასიათებლების გამოყოფას, ექსპერიმენტულ ანალიზს, წინასწარი პროგნოზული გათვლის შედეგების შეპირისპირებას ობიექტის ან პროცესის მდგომარეობის ფაქტობრივ მონაცემებთან. იმიტაციური მოდელირების განხილვისას გამოყავით სამი ძირითადი მიდგომა: სისტემური დინამიკა, დისკრეტულ-მოვლენათა მოდელირება, აგენტზე დაფუძნებული მოდელირება.

რისკების პროგნოზირებისას საფინანსო ბაზარი განხილულია, როგორც მრავალაგენტური სისტემა. მრავალაგენტური მოდელირება – სისტემების

მოდელირების ახალი მიდგომა გამოიყენება დეცენტრალიზებული სისტემების გამოსაკვლევად. იგი ეფუძნება რეალური სამყაროს ცალკეულ აქტიურ კომპონენტებს, რომლებსაც აგენტებს უწოდებენ.

**მესამე თავში** წარმოდგენილია საფინანსო რისკების პროგნოზირება ხელოვნური ინტელექტის მეთოდების, კერძოდ ევოლუციური ალგორითმების გამოყენებით. ევოლუციური მეთოდები გვაძლევს საშუალებას, ვიპოვოთ ოპტიმალურთან ახლოს მდგომი ამონახსნები მისაღებ დროში. განხილული მეთოდების ანალიზის შემდეგ გაკეთდა დასკვნა, რომ ამ ტიპის ამოცანების გადასაჭრელად ყველაზე ოპტიმალურია ხელოვნური ნეირონული ქსელების ალგორითმი.

ნაშრომში წარმოდგენილია რამდენიმე მოდიფიცირებული ალგორითმი. რისკების პროგნოზირების ამოცანის გადაწყვეტისთვის ფართოდაა განხილული ნეირონული ქსელების სახეობა, კოჰონენის თვითორგანიზებადი რუკები - Self-Organizing Maps (SOM), რომელიც იყენებს ქსელის არაკონტროლირებადი სწავლების მეთოდს. კოჰონენის ქსელი მრავალშირიანი ნეირონული ქსელისგან განსხვავებით შეიცავს მხოლოდ ორ შრეს: შემავალს და გამომავალს. ამ ქსელის გამოყენება ნაკარნახებია იმით, რომ დიდ სირთულეებთან არის დაკავშირებული რთული სტრუქტურის წარმოდგენა მრავალგანზომილებიან ქსელში.

კოჰონენის ალგორითმის მუშაობის შედეგად, კლასტერის ცენტრი ექცევა იმ პოზიციაში რომელიც აკმაყოფილებს კლასტერიზაციის შესასწავლ მაგალითს, რომელთათვისაც მოცემული ნეირონი წარმოადგენს „გამარჯვებულს“. ამასთან, სწავლების მსვლელობისას მოდიფიცირდება არამარტო გამარჯვებული-ნეირონი, არამედ მისი მეზობლებიც, შედარებით მცირე დონით. აღნიშნული მიდგომის გამოყენება, ერთი მხრივ, შესაძლებელია საწყისი და საბოლოო მონაცემთა კანონზომიერებების ძებნისა და ანალიზისათვის, მეორე მხრივ, ახორციელებს მრავალგანზომილებიანი შემავალი სივრცის გამოსახვას ორ განზომილებიან (იშვიათად ერთ განზომილებიან) გამავალ სივრცედ, ე.ი. ახდენს მონაცემთა შეკუმშვას. რაც



საბოლოოდ აჩქარებს ალგორითმის შესრულებას. ამავე თავშია წარმოდგენილი კოჰონენის რუკაზე გამარჯვებული ნეირონის გამოვლინების ალგორითმების მოკლე მიმოხილვა, როგორებიცაა: ამოწვის იმიტაციის ალგორითმი, იმპერიალისტური შეჯიბრებითი ალგორითმი და ნაწილაკების გროვის ოპტიმიზაციის მეთოდი.

**მეთხე თავში** რისკების პროგნოზირების ამოცანის გადაწყვეტისათვის შემოთავაზებულია ნაწილაკთა გროვის ოპტიმიზაციის მოდიფიცირებული ალგორითმი, როგორც გლობალური ოპტიმუმის განსაზღვრის ახალი მიდგომა. 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 ფიტნეს ფუნქციის გლობალური ოპტიმუმის მოძებნა რაც მიიღწევა ნეირონული ქსელის ე.წ. „წონითი კოეფიციენტების“ კორექტირებით და იტერაციულ პროცესში რეკლასტერიზაციის მეთოდის არჩევით. ალგორითმის მიზანია ნაწილაკების შეგროვება მიზნობრივი ფუნქციის გლობალურ (მთელი საძიებო არე) ან ლოკალურ (კონკრეტული კლასტერი) ოპტიმუმებში. რისკების პროგნოზირების ამოცანის გადაწყვეტისათვის შემოთავაზებულია კოჰონენის 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.

დისერტაციის ბოლოს მოცემულია დასკვნა, დანართი და გამოყენებული ლიტერატურის ნუსხა.

## თავი 1. საფინანსო ბაზარი და რისკები

### 1.1. ფინანსური ბაზარი. ობიექტების აღწერა

ფინანსური ბაზრის არსი. ეკონომიკის ნორმალური განვითარებისათვის აუცილებელია ფიზიკური და იურიდიული პირების დროებითი თავისუფალი საშუალებების მობილიზაცია, მათი განაწილება და გადანაწილება კომერციულ საფუძველზე ეკონომიკის სხვადასხვა სექტორებს შორის. ეს პროცესები უნდა განხორციელდეს ფინანსურ ბაზრებზე [1].

ზოგადი სახით ფინანსური ბაზარი შეიძლება განისაზღვროს, როგორც მისი მონაწილეების ეკონომიკურ ურთიერთობათა ერთობლიობა კაპიტალის ფორმირებასთან, მხარდაჭერასა და მიმოქცევასთან დაკავშირებით. ფინანსური ბაზარის ცნების ქვეშ იგულისხმება კუპონური და კუპონგარეშე ობლიგაციების ბაზარი, აქციათა ბაზარი (საფონდო ბაზარი) და სავალუტო ბაზარი.


ფინანსური ბაზარები – ეს არის შუამავალთა ბაზრები ფულადი სახსრების პირველად მფლობელებსა და მათ საბოლოო მომხმარებლებს შორის. იმ ნაწილში, რომელშიც ფინანსური ბაზარი დაფუძნებულია ფულზე, როგორც კაპიტალზე, ის საფონდო ბაზარს წარმოადგენს და ამ სახით ფინანსური ბაზარის შემადგენელ ნაწილად გვევლინება [1].

ფინანსური ბაზარი შედგება რიგი სექტორებისაგან: საინვესტიციო, საკრედიტო, საფონდო, სადაზღვევო, სავალუტო (ნახ.1.1).

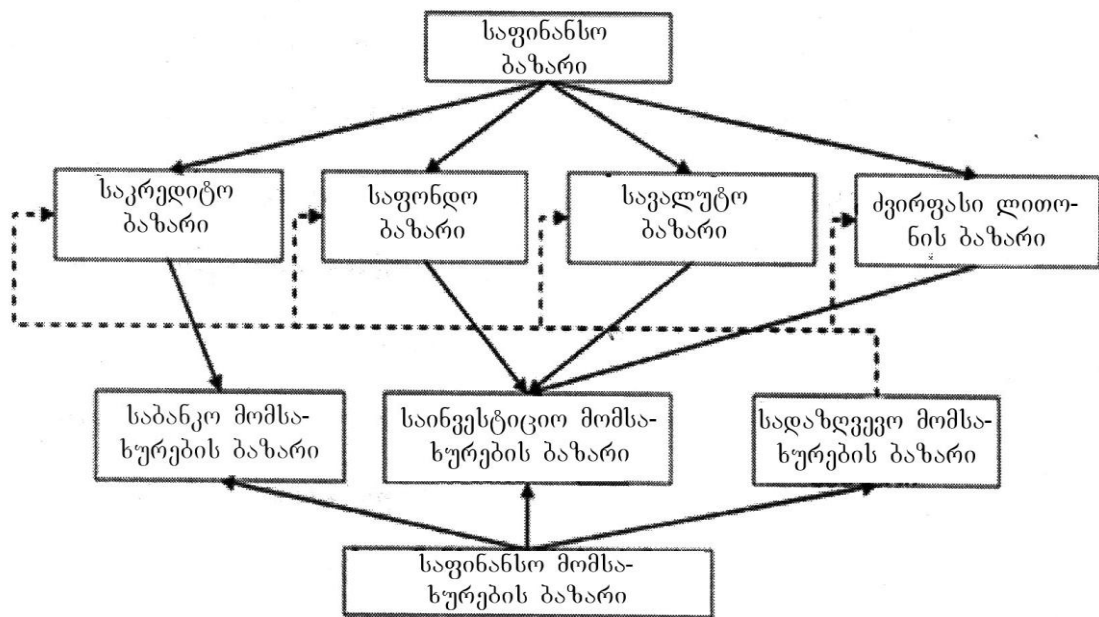
- საკრედიტო ბაზარი;
- სავალუტო ბაზარი;
- ფასიანი ქაღალდების ბაზარი (საფონდო ბაზარი);
- სადაზღვევო ბაზარი;
- ინვესტიციების ბაზარი.

ფინანსური ბაზრის არსი მდგომარეობს არამხოლოდ ფინანსური რესურსების გადანაწილებაში, არამედ უპირველეს ყოვლისა, ამ გადანაწილების მიმართულების განსაზღვრაში. სწორედ ფინანსურ ბაზარზე

განისაზღვრება ფულადი რესურსების გამოყენების მეტად ეფექტური სფეროები. ასეთი ფინანსური ბაზრის სტრუქტურა შესაძლოა წარმოდგენილ იქნეს შემდეგი სახით (ნახ. 1.2) [1,9]:



ნახ. 1.1. ფინანსური ბაზრის სტრუქტურა



ნახ. 1.2. ფინანსური ბაზრები

სადაც:

- **ფულადი ბაზარი** – ფინანსური ინსტრუმენტების (სავალუტო ვალდებულებების) მოკლევადიანი ბაზარი, 1 წლამდე მიმართვის ვადით.

- **კაპიტალების ბაზარი** – საშუალო (1-დან 3-5 წლამდე) და გრძელვადიანი აქტივების – აქციების, ობლიგაციების (1 წელზე მეტ ვადაში დაფარვით) და სესხების (1 წელზე მეტ ვადაში დაფარვით) ბაზარი.

- **საკრედიტო ბაზარი** – მოკლე, საშუალო და გრძელვადიანი სესხების ბაზარი. პრაქტიკაში მკაფიო ზღვარი მათ შორის არ არსებობს.

ფინანსური ბაზრის ფუნქციონირება გულსხმობს ისეთი ცნების შემოღებას, როგორცაა ეკონომიკის, მისი სექტორებისა და მათი ეკონომიკური საქმიანობის „ფინანსური მდგომარეობა“[1].

ფინანსურ ბაზარს ემსახურებიან ფინანსური შუამავლები, ანუ (იგივე) ორგანიზაციები, რომლებიც დებულობენ თანხას შესანახად გარკვეული პროცენტით ან აგროვებენ სხვა საბაზით, სთავაზობენ სესხს უფრო მაღალი პროცენტით იმ ფიზიკურ და იურიდიულ პირებს, რომლებიც საჭიროებენ ინვესტიციურ რესურსებს, აგრეთვე ისინი(ორგანიზაციები), რომლებიც ანაზღაურებენ სადაზღვევო პოლისს და პენსიებს. ფინანსური შუამავლები ფინანსური ბაზრის ძირითადი აგენტებია. ფინანსური შუამავლების რიცხვში უპირველეს ყოვლისა შედის ყველა ბანკი და საბანკო-საკრედიტო ორგანიზაცია (საკრედიტო კავშირები, კოოპერატივები, შემნახველი ასოციაციები, ურთიერთდაკრედიტების საზოგადოებები და სხვ. მსგავ.). გარდა საბანკო და საკრედიტო ორგანიზაციებისა, ფინანსური შუამავლების რიცხვში შედის აგრეთვე სადაზღვევო ორგანიზაციები, საპენსიო ფონდები, საინვესტიციო კომპანიები და სხვა.

**ფასიანი ქაღალდების ბაზრის სტრუქტურა და ფუნქციები.** ფინანსური ბაზარი შეიძლება იყოს [6]:

- პირველადი და მეორადი;
- ორგანიზებული და არაორგანიზებული;
- საბირჟო და არასაბირჟო (ბირჟის გარეთა);
- ტრადიციული და კომპიუტერული;
- სალარო („ქემ“) და სასწრაფო.

პირველადი ბაზარი უზრუნველყოფს ფასიანი ქაღალდის გამზებას მიმოქცევაში; ეს მისი პირველი გამოჩენაა ბაზარზე, ასე ვთქვათ, ფასიანი ქაღალდის „წარმოების“ სტადია.

მეორად ბაზარზე მიმოქცევა ადრე გამოშვებული ფასიანი ქაღალდები. მეორადი ბაზარი ესაა მოცემულ ქაღალდებთან ნებისმიერი ოპერაციების ერთობლიობა, რომელთა შედეგად ხდება მათზე საკუთრების უფლებების ერთი მფლობელისაგან მეორეზე მუდმივი გადასვლა.

საბირჟო ბაზარი ესაა ბაზარი, რომელზედაც ვაჭრობა აუქციონის ფორმით ხორციელდება, ვაჭრობებს სპეციალისტი უძღვება. ესაა, მაგალითად NYSE (New York Stock Exchange – ნიუ-ორკის საფონდო ბირჟა) და AMEX (American Stock Exchange – ამერიკის საფონდო ბირჟა).

არასაბირჟო (ბირჟის გარეთ) ბაზარზე ვაჭრობები ელექტრონული სისტემის მეშვეობით რეალიზდება; ვაჭრობებს მარკეტ-მეიქერები ხელმძღვანელობენ. ფასიანი ქაღალდების ბაზარი ორ ძირითად სპეციფიკურ ფუნქციას ასრულებს [7]:

1) ფულადი სახსრების გადანაწილება პასიური კაპიტალის მფლობელებისგან აქტიური კაპიტალის მფლობელებზე;

2) რისკების გადანაწილება ნებისმიერი საბაზრო აქტივების მფლობელებს შორის.

ორივე ფუნქცია დროის მოცემულ ფარგლებში ხორციელდება.

რისკების გადანაწილება ეს არის რისკისაგან დაცვის (დაზღვევის) ფუნქცია, ან უფრო სწორად, ჰეჯერების ფუნქცია. გარდა ამისა, ბაზარი ასრულებს [6]:

- საინფორმაციო ფუნქცია, ე.ი. აწარმოებს და მონაწილეებამდე მიაქვს საბაზრო ინფორმაცია ვაჭრობის ობიექტებსა და მისი მონაწილეების შესახებ.

- მარეგულირებელი ფუნქცია, ე.ი. ქმნის ვაჭრობის და მასში მონაწილეების წესებს, მონაწილეთა შორის დავების გადაწყვეტის წესს, ადგენს პრიორიტეტებს, კონტროლის ან მართველობის ორგანოებს და ა.შ.

**აქტიური საფინანსო ბაზარი.** განვიხილოთ საფინანსო ბაზრის არსი კონკრეტულად საინვესტიციო პროცესის კონტექსტში. ჩვენ გვინტერესებს, როგორ იღებს ინვესტორი გადაწყვეტილებას ფასიანი ქაღალდების, ობიექტების ინვესტირებისა და ვადების შერჩევისას, ასევე, ბაზრის ბუნებისა და ფუნქციონირების შესახებ რა წარმოდგენებით სარგებლობს, როგორ ინფორმაციას და რა სახით ამუშავებს საინვესტიციო გადაწყვეტილებების მიღების დროს [7].

**საფონდო ბაზრები** იმისთვის არსებობენ, რომ ერთად მოუყაროს თავი ფასიანი ქაღალდების გამყიდველებსა და მყიდველებს. **ფასიანი ქაღალდი** - (security) არის კანონიერად აღიარებული უფლების მტკიცებულება მომავალში შემოსავლის მიღების თაობაზე კონკრეტული პირობების საფუძველზე [4].

საინვესტიციო პროცესის საფუძველს შეადგენენ შემდეგი ეტაპები:

- 1) საინვესტიციო პოლიტიკის შერჩევა;
- 2) ფასიანი ქაღალდების ბაზრის ანალიზი;
- 3) ფასიანი ქაღალდების პორტფელის ფორმირება;
- 4) ფასიანი ქაღალდების გადახედვა;
- 5) ფასიანი ქაღალდების პორტფელის ეფექტურობის შეფასება.

## **1.2. რისკების კლასიფიკაცია და შეფასების მეთოდები**

დღევანდელ არაპროგნოზირებულ ეკონომიკურ გარემოში თანამედროვე საფინანსო ბაზრის სისტემა ხასიათდება მაღალი დინამიკურობით, მზარდი კონკურენციით, მომხმარებელზე ორიენტაციით და პროცესების გლობალიზაციით. რეალურ სამყაროში, რისკი არის ყველგან. ბიზნეს-ორგანიზაციების საქმიანობა მუდმივ კავშირშია რისკებთან.

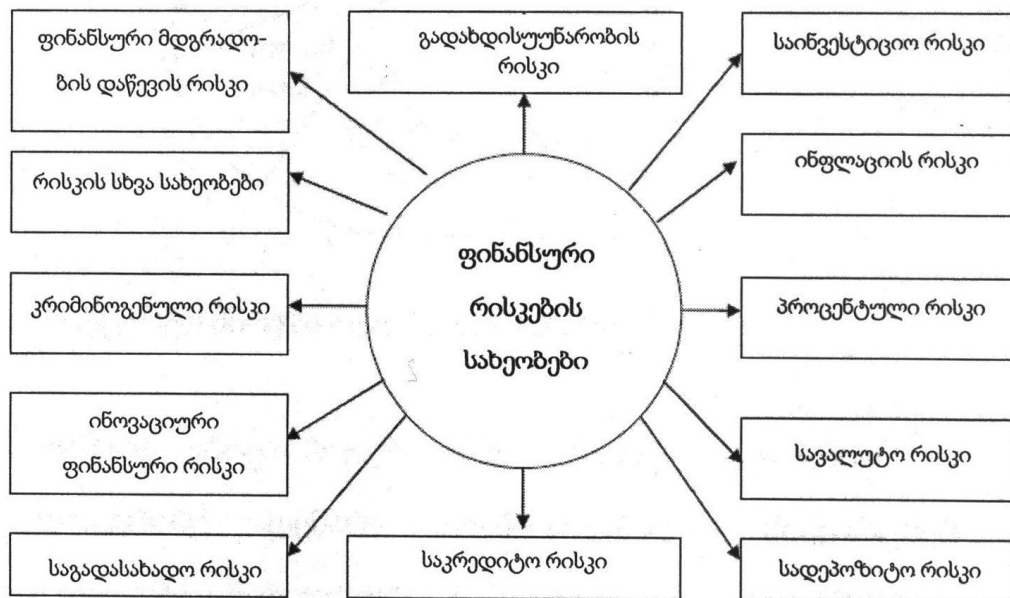
**ფინანსური რისკები:** რისკი – ეს არის წარმოშობილი დანაკარგი, ზარალი ალბათობა გეგმიური შემოსავლის, მოგების მიუღწევლობა. რისკი, როგორც არასასურველი ზემოქმედება რენტაბელობაზე, რამდენიმე სხვადასხვა წყაროების გაურკვევლობით. რისკების ხარისხიანი მართვისთვის

ეფექტურია განისაზღვროს რისკი და მისი კლასიფიკაცია. რისკის ზუსტი შეფასება მოითხოვს გაურკვეველი წყაროს აღმოჩენას და განსაზღვრას მისი ნეგატიური პოტენციალის ზეგავლენას მოგებაზე. რენტაბელობა ეხება როგორც გათვლას, აგრეთვე შეფასებას საბაზრო ღირებულების[3].

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[4].

ფინანსურ რისკებს მიეკუთვნება საკრედიტო რისკები, პროცენტული რისკები, სავალუტო რისკები, დაუდევრობის ფინანსური გამორჩენის (სარგებლიანობის) რისკები და სხვა (ნახ.1.3).



ნახ.1.3. ფინანსური რისკების სისტემა

მაგალითად, საწარმოს ფინანსური მდგრადობის რისკის შემცირება დაკავშირებულია კაპიტალის სტრუქტურის არასრულყოფასთან და

საშიშროების დონით, რისკის მოცემულ სახეობას უჭირავს წამყვანი როლი, რადგანაც იქმნება საწარმოს გაკოტრების საშიშროება.

საწარმოს ფულადი ნაკადის დადებითისა და უარყოფითის უბალანსობას დროში. თავისი ფინანსური შედეგებით რისკის აღნიშნული სახეობა საშიშთა რიცხვს მიეკუთვნება.

ინვესტიციური რისკისთვის დამახასიათებელია ფინანსური დანაკარგის წარმოშობის შესაძლებლობა საწარმოს საინვესტიციო საქმიანობის განხორციელების პროცესში.

ინფლაციური რისკი ხასიათდება კაპიტალის ღირებულების რეალური გაუფასურების შესაძლებლობით, აგრეთვე შემოსავლის მოლოდინით ფინანსური ოპერაციების განხორციელებსას ინფლაციის პირობებში.

საპროცენტო რისკი მდგომარეობს საპროცენტო განაკვეთის უწყვეტ ცვლილებაში ფინანსურ ბაზარზე. მოცემული რისკის წარმოშობის მიზეზებია:

ფინანსური ბაზრის კონიუნქტურის ცვლილება სახელმწიფო რეგულირების ზეგავლენით; თავისუფალი ფულადი რესურსების მიწოდების ზრდა ან კლება.

სავალუტო რისკი დამახასიათებელია იმ საწარმოთათვის, რომლებიც ეწევიან საგარეო ეკონომიკურ საქმიანობას. იგი ვლინდება გათვალისწინებული შემოსავლის ვერმიღებაში, უცხოური ვალუტის გაცვლითი კურსის უშუალო ზემოქმედების შედეგად, რომელიც გამოიყენება საწარმოს საგარეო ეკონომიკურ ოპერაციებში, ამ ოპერაციებისაგან მოსალოდნელი ფულადი ნაკადის შემთხვევაში [4,5].

სადეპოზიტო რისკი ასახავს სადეპოზიტო ანაბრების არდაბრუნების შესაძლებლობას. იგი დაკავშირებულია კომერციული ბანკის წარუმატებელ არჩევანსა და არასწორ შეფასებასთან საწარმოს სადეპოზიტო ოპერაციების განხორციელებისას.

საკრედიტო რისკს ადგილი აქვს საწარმოს ფინანსურ საქმიანობაში, მის მიერ მყიდველებისათვის საქონლის ან სამომხმარებლო კრედიტის შეთა-



ვაზების შემთხვევაში. მისი გამოვლენის ფორმაა გადაუხდელობის რისკი ან არადროული ანგარიშსწორება, საწარმოს მიერ კრედიტით გაცემული მზა პროდუქციისათვის.

საგადასახდო რისკს აქვს რიგი გამოვლინებები: ახალი ტიპის გადასახადებისა და მოსაკრებლების შემოტანის ალბათობა სამეურნეო საქმიანობის ცალკეული ასპექტების განხორციელებისას; მოქმედი გადასახადებისა და მოსაკრებლების ცალკეულ სახეობებზე განაკვეთის ზრდის შესაძლებლობა; ცალკეული სახის გადახდების განხორციელებისას ვადებისა და პირობების ცვლილებები; მოქმედი საშელავათო გადასახადების გაუქმების ალბათობა საწარმოს სამეურნეო საქმიანობის სფეროში.

ინოვაციური ფინანსური რისკი დაკავშირებულია ახალი ფინანსური ტექნოლოგიების დანერგავასთან.

კრიმინოგენული რისკი ვლინდება პარტნიორების მიერ ფიქტიური გაკოტრების აღიარებისას; საბუთების გაყალბებისას, რომელიც უზრუნველყოფს მხარეთა პირთა მიერ უკანონო ფულად მითვისებას .

**რისკების შეფასების მეთოდები.** 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 ხარისხობრივი ანალიზის ჯამური შედეგები, შესაბამისად წარმოადგენს ამოსავალ ინფორმაციას რაოდენობრივი ანალიზის ჩასატარებლად.

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 რაოდენობრივი ანალიზისას გამოიყენება [6,8]:

**ექსპერტული შეფასების მეთოდი** დაფუძნებულია ექსპერტ- სპეციალისტთა განზოგადებულ მოსაზრებებზე რისკის ალბათობის შესახებ. მხედველობაში იღებენ ინტუიციურ მახასიათებლებს, რომელიც ეფუძნება ყოველი ექსპერტის ცოდნასა და გამოცდილებას. ყოველ, ცალკე მომუშავე ექსპერტს წარედგინება შესაძლო რისკების ჩამონათვალი, რომ ვარაუდით შეაფასოს მათი დადგომის ალბათობა. შემდგომ კეთდება ექსპერტთა შეფასებების ანალიზი მათი ერთმანეთთან შეუსაბამობის გამო და უნდა დაექვემდებარონ შემდეგ წესს: მაქსიმალურად დასაშვები განსხვავება ორი ექსპერტის მოსაზრებათა შორის რისკის ნებისმიერ სახეობაში არ უნდა აღემატებოდეს 50, რაც თავის მხრივ აღმოფხვრის დაუშვებელ განსხვავებებს ექსპერტთა მიერ ცალკეული რისკის დადგომის ალბათობის შეფასებისას.

$$\max |a_i - b_i| \leq 50 ,$$

სადაც  $a, b$ -ორიდან თითოეული ექსპერტის შეფასების ვექტორებია. სამი ექსპერტის არსებობის შემთხვევაში, კეთდება სამი შეფასება: მოსაზრებათა წყვილად შეფასებისათვის 1-ისა და 3-ისა, 2-ისა და 3-ისა.

$i$  - შესაფასებელი რისკის სახეობაა.

ექსპერტული მეთოდები საშუალებას იძლევა სწრაფად, ზედმეტი შრომისა და დროის ხარჯვის გარეშე მივიღოთ მართვის გადაწყვეტილების მიღებისათვის საჭირო ინფორმაცია.

**ანალოგიის მეთოდი** გამოიყენება იმ შემთხვევაში, თუ რისკის შეფასების სხვა მეთოდები მიუღებელია. ასეთ დროს გამოიყენება რისკის შესახებ ანალოგიური პროექტებისა და გარიგებების მონაცემთა ბაზა.

**საწარმოს ფინანსური მდგრადობისა და გადახდისუნარიანობის შეფასების მეთოდი** საშუალებას იძლევა გათვალისწინებულ იქნეს გაკოტრების ალბათობა. კეთდება წლიური საბუღალტრო ანგარიშგების ანალიზი. შესაძლოა შეფასდეს საწარმოს გადახდისუნარიანობის დადგომის ალბათობა. გადახდისუნარიანობის ძირითადი კრიტერიუმებია მიმდინარე

ლიკვიდურობის კოეფიციენტი, საკუთარი სახსრებით უზრუნველყოფის კოეფიციენტი და გადახდისუნარიანობის აღდგენის კოეფიციენტი.

**ხარჯთა მიზანშეწონილობის მეთოდით** შესაძლებელია განისაზღვროს პროდუქციის გამოშვების ქვედა ზღვრული ოდენობა, რომლის დროსაც მოგება ნულის ტოლია. ყველა ხარჯი პროდუქციის წარმოებისა და რეალიზაციისათვის იყოფა ცვლად (მასალები, კომპლექტური ნაწარმი, ინსტრუმენტები, სახელფასო ანაზღაურება, სატრანსპორტო ხარჯები და ა.შ.) და მუდმივ (საამორტიზაციო გამოქვითვა, მმართველობითი ხარჯები, იჯარის გადასახადი, საკრედიტო პროცენტები და ა.შ.).

წარმოების კრიტიკული მოცულობა შეიძლება წარმოვიდგინოთ შემდეგი სახით:

$$V_{kp} = \frac{FC}{P - VC} \quad (1.1)$$

სადაც:  $V_{kp}$  - წარმოების კრიტიკული მოცულობა;

$P$  - პროდუქციის ერთეულის ფასი;

$FC$  - მუდმივი ხარჯები;

$VC$  - ცვლადი ხარჯები.

რაც უფრო მეტია განსხვავება წარმოების ფაქტობრივ და კრიტიკულ მოცულობებს შორის, მით უფრო მაღალია ფინანსური მდგრადობა.

**სტატისტიკური მეთოდის** არსი მდგომარეობს მოგებისა და დანაკარგების სტატისტიკის შესწავლაში, რომელსაც ადგილი აქვს მოცემულ ან ანალოგიურ საწარმოში, რისკის გარემოების ალბათობის განსაზღვრისა და მისი სიდიდის დადგენის მიზნით. რისკის დონე იზომება მოსალოდნელი საშუალო მნიშვნელობითა და შესაძლო შედეგის მერყეობით (ცვალებადობით). ამისთვის პრაქტიკაში გამოიყენება ორი ერთმანეთთან დაკავშირებული კრიტერიუმი: დისპერსია და საშუალო კვადრატული გადახრა [7].

დისპერსია წარმოადგენს საშუალოდ მოსალოდნელიდან არსებული შედეგების კვადრატული გადახრების საშუალო წონითს:

$$O^2 = \frac{\Sigma(a - \bar{a})^2 n}{\Sigma n} \quad (1.2)$$

სადაც:  $a$  - დაკვირვების ყველა შემთხვევისათვის მოსალოდნელი მნიშვნელობა;

$\bar{a}$ -საშუალო მოსალოდნელი მნიშვნელობა;

$n$ -დაკვირვების შემთხვევების რიცხვი (სიხშირე).

საშუალო კვადრატული გადახრა:

$$O^2 = \sqrt{\frac{\sum (a - \bar{a})^2 n}{\sum n}} \quad (1.3)$$

საშუალო კვადრატული გადახრა აღინიშნება იმავე ერთეულებში, რომლითაც იზომება ვარირების მაჩვენებელი. დისპერსია  $n$  საშუალო კვადრატული გადახრა აბსოლუტური ცვალებადობის ზომებია.

ანალიზისთვის ჩვეულებრივ გამოიყენება ვარიაციების კოეფიციენტი, საშუალო კვადრატული გადახრა საშუალო არითმეტიკულთან მიმართებაში, რომელიც აჩვენებს მიღებული მნიშვნელობების გადახრის ხარისხს:

$$V = \frac{\pm O}{a} \cdot 100\% \quad (1.4)$$

იგი იცვლება 0-დან 100%-მდე. რაც მეტია კოეფიციენტი, მით უფრო ძლიერია ცვალებადობა, რაც უფრო ნაკლებია კოეფიციენტი, მით უფრო მცირეა რისკის ფარდობითი მოცულობა[6].

არასასურველი შემთხვევის ალბათობის განსაზღვრის მეთოდები არსებობს არასასურველი შემთხვევის ალბათობის განსაზღვრის ორი მეთოდი: ობიექტური და სუბიექტური. ობიექტური მეთოდი ეფუძნება სიხშირის გამოთვლას, სადაც ესა თუ ის შედეგი მიღებულია ანალოგიურ პირობებში. ამ შემთხვევაში ალბათობის გათვლა ხდება ფაქტობრივი მონაცემების საფუძველზე შემდეგი ფორმულის მიხედვით:

$$P = \frac{n}{N} \quad (1.5)$$

სადაც:  $P$  - არის არასასურველი დასასრულის ალბათობა;

$n$  - მეწარმისთვის არასასურველი დასასრულის მქონე შემთხვევათა რიცხვი;

N - ანალოგიური შემთხვევების საერთო რიცხვი, როგორც წარმატებული, ასევე წარუმატებელი დასასრულით.

სუბიექტური ალბათობა არის განსაზღვრული შედეგის ვარაუდი. არასასურველი დასასრულის ალბათობის განსაზღვრის ეს მეთოდი ეფუძნება სპეციალისტის პირად გამოცდილებასა და მსჯელობას. მოცემულ შემთხვევაში წარსული გამოცდილებისა და ინტუიციის შესაბამისად, აუცილებელია შემთხვევათა ალბათობაზე რიცხობრივი ვარაუდის გაკეთება [7].

მაქსიმალურად შესაძლო ზარალის მოცულობისა და საკუთარი ფინანსური რესურსების მოცულობის თანაფარდობა წარმოადგენს რისკის ისეთ ხარისხს, რომელიც იწვევს გაკოტრებას. იგი იზომება რისკის კოეფიციენტის მეშვეობით:

$$K_p = \frac{Y_{\max}}{C_{\text{co6}}} \quad (1.6)$$

სადაც:  $K_p$  - რისკის კოეფიციენტი;

$Y_{\max}$  - ზარალის მაქსიმალურად შესაძლო (ჯამი) ოდენობა;

$C_{\text{co6}}$  - საკუთარი ფინანსური რესურსების მოცულობა, ზუსტად ცნობილი შემომავალი სახსრების გათვალისწინებით.

### 1.3. რისკების მართვა

ფინანსური სისტემის სტრუქტურის დიდი ნაწილი მომართულია რისკების მართვაზე. რისკების შეფასების სიზუსტე განისაზღვრება მათი დინამიკის პროგნოზირების შესაძლებლობებით და ამ პროგნოზირების საფუძველში ჩადებული მოდელების ადექვატურობით [2].

რთული საფინანსო სისტემების კვლევა საჭიროებს საფინანსო ბაზრის რისკების პროგნოზირებას. რისკ-ფაქტორების გამოვლენის და შეფასების პროცედურები არასასურველი ხდომილობების თავიდან აცილების საშუალებას იძლევა. მათი ანალიზური დამუშავება მოიცავს რისკების შეფასების და რისკების შემცირების სხვადასხვა მეთოდებს.

**ფინანსური რისკების მართვა** ჩვენ გვესმის როგორც რისკების ანალიზზე სისტემური მუშაობა და მისი მინიმიზაციისთვის 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. განასხვავებენ რისკ-მენეჯმენტის ორი ტიპის ფუნქციას [3]:

- 1) მართვის ობიექტის ფუნქციები;
- 2) მართვის სუბიექტის ფუნქციები.

მართვის ობიექტის ფუნქციებს რისკ-მენეჯმენტში მიეკუთვნება:

- რისკის გადაწყვეტა;
- სარისკო კაპიტალის ჩადება;
- რისკის სიდიდის შემცირებასთან დაკავშირებული სამუშაოები;
- რისკების დაზღვევის პროცესი;
- ეკონომიკური ურთიერთობები და კავშირები სამეურნეო პროცესის სუბიექტებს შორის .

მართვის სუბიექტის ფუნქციებს მენეჯმენტში მიეკუთვნება[2,3]:

**პროგნოზირება** ზოგადად-გარკვეული შემთხვევის წინასწარ განჭვრეტა. იგი რისკ-მენეჯმენტში წარმოადგენს ობიექტისა და მისი ცალკეული ნაწილების ფინანსური მდგომარეობის ცვლილებების პერსპექტივაში გადამუშავებას. პროგნოზირება-გარკვეული შემთხვევის წინასწარ განჭვრეტა, ის არ ისახავს ამოცანად უშუალოდ პრაქტიკაში განახორციელოს დამუშავებული პროგნოზები. პროგნოზირების თავისებურება მდგომარეობს აგრეთვე ფინანსური მაჩვენებლებისა და პარამეტრების აგებულების

ალტერნატიულობაში, რომელიც განსაზღვრავს ობიექტის მართვის ფინანსური მდგომარეობის განვითარების სხვადასხვა ვარიანტებს დასახული ტენდენციების საფუძველზე. რისკის დინამიკაში პროგნოზირება შესაძლოა განხორციელდეს როგორც წარსულის მომავალში ექსტრაპოლაციის საფუძველზე ცვლილების ტენდენციის ექსპერტული შეფასების გათვალისწინებით, აგრეთვე ცვლილებების პირდაპირი განჭვრეტის საფუძველზე. ეს ცვლილებები შესაძლოა წარმოიშვას მოულოდნელად. ამგვარი ცვლილებების განჭვრეტის საფუძველზე, მართვა მოითხოვს მენეჯერისაგან საბაზრო მექანიზმის გარკვეულ ალღოსა და ინტუიციის ქონას, აგრეთვე მოქნილი საგანგებო გადაწყვეტილებების გამოყენებას[7].

**ორგანიზაცია** რისკ-მენეჯმენტში წარმოადგენს ადამიანთა გაერთიანებას, რომლებიც ერთობლივად ახორციელებენ კაპიტალის სარისკო ჩადების პროგრამას გარკვეული წესებისა და პროცედურების საფუძველზე. ამ წესებსა და პროცედურებს მიეკუთვნება: მართვის ორგანოების შექმნა, მართვის აპარატის სტრუქტურის აგებულება, მმართველობით ქვედანაყოფებთან ურთიერთკავშირის დამყარება, ნორმების, ნორმატივების, მეთოდიკების შემუშავება და ა.შ.

**რეგულირება** რისკ-მენეჯმენტში წარმოადგენს მართვის ობიექტზე ზემოქმედებას, რომლის საშუალებითაც მიიღწევა ამ ობიექტის მდგრადობის მდგომარეობა მიცემული პარამეტრებიდან გადახრის შემთხვევაში. რეგულირება უმთავრესად მოიცავს წარმოქმნილი გადახრების აღმომფხვრელ მიმდინარე ღონისძიებებს.

**კოორდინაცია** რისკ-მენეჯმენტში წარმოადგენს რისკის მართვის სისტემის ყველა რგოლის, მართვის აპარატისა და სპეციალისტების შეთანხმებულ მუშაობას. კოორდინაცია უზრუნველყოფს მართვის ობიექტის, მართვის სუბიექტის, მართვის აპარატისა და ცალკეული მომუშავის კავშირის ერთიანობას [3,4].

**სტიმულირება** რისკ-მენეჯმენტში წარმოადგენს ფინანსური მენეჯერებისა და სხვა სპეციალისტების ინტერესის აღძვრას საკუთარი შრომის შედეგისადმი.

**კონტროლი** რისკ მენეჯმენტში წარმოადგენს ორგანიზაციის მუშაობის შემოწმებას რისკის ხარისხის შემცირების კუთხით. კონტროლის საშუალებით გროვდება ინფორმაცია მოქმედების პროგრამის შესრულების დონეზე, სარისკო კაპიტალის ჩადების შემოსავლიანობაზე, რისკისა და მოგების თანაფარდობაზე, რომლის საფუძველზეც ცვლილებები შედის ფინანსურ პროგრამებში, ფინანსური სამუშაოს ორგანიზაციაში, რისკ-მენეჯმენტის ორგანიზაციაში. კონტროლი ვარაუდობს იმ ღონისძიებათა შედეგების ანალიზს, რაც რისკის ხარისხის შემცირებასთან არის დაკავშირებული.

**რისკ-მენეჯმენტი (რისკების მართვის სისტემა).** რისკის მართვა შესაძლებელია, ესე იგი გამოყენებულ უნდა იქნეს სხვადასხვა ზომები, რომელიც გარკვეულ დონეზე საშუალებას იძლევა მოხდეს რისკის შემთხვევის დადგომის პროგნოზირება და მიღებულ იქნეს ზომები მის შესამცირებლად [4].

რისკ-მენეჯმენტი წარმოადგენს რისკის მართვის სისტემას, ეკონომიკური, ზუსტად კი ფინანსური ურთიერთობებისა, რომლებიც წარმოიქმნება სწორედ ამ მართვის პროცესში და მოიცავს მმართველობითი მოქმედების სტრატეგიასა და ტაქტიკას.

რისკ-მენეჯმენტი როგორც მართვის სისტემა შედგება ორი ქვესისტემისაგან:

- 1) მმართველი ქვესისტემა -ქვესისტემა რომელიც იმართება (მართვის ობიექტი);
- 2) მმართველი ქვესისტემა ( მართვის სუბიექტი).

**მართვის ობიექტი** არის სარისკო კაპიტალის ჩადება და ეკონომიკური ურთიერთობები მეურნე სუბიექტებს შორის რისკის რეალიზაციის პროცესში.

**მართვის სუბიექტი** – ხელმძღვანელთა ჯგუფი, რომელიც მიზანმიმართულად ახორციელებს მართვის ობიექტის ფუნქციონირებას. მოცემული პროცესი ხორციელდება მნიშვნელოვანი ინფორმაციის მუდმივი ცირკულაციით მართვის სუბიექტსა და ობიექტს შორის.



რისკ-მენეჯმენტის ამგვარი დაყოფის შესაბამისად გამოყოფენ ორი ტიპის ფუნქციას:

- 1) მართვის ობიექტის ფუნქციები;
- 2) მართვის სუბიექტის ფუნქციები.

მართვის ობიექტის ფუნქციებს მიეკუთვნება: რისკის გადაწყვეტის ორგანიზაცია, სარისკო კაპიტალის ჩადება, რისკის სიდიდის შემცირებასთან დაკავშირებული სამუშაოები, რისკების დაზღვევის პროცესი, ეკონომიკური ურთიერთობები და კავშირები სამეურნეო პროცესის სუბიექტებს შორის [3].

მართვის სუბიექტის ფუნქციებს მიეკუთვნება: პროგნოზირება, ორგანიზაცია, რეგულირება, კოორდინაცია, სტიმულირება და კონტროლი.

**რისკ-მენეჯმენტის ორგანიზაცია.** როგორც მართვის სისტემა, რისკ-მენეჯმენტი მოიცავს რისკის მიზნის გამომუშავების პროცესს და სარისკო კაპიტალის ჩადებას, შემთხვევის დადგომის განსაზღვრულ ალბათობებს, რისკის ხარისხისა და სიდიდის გამოვლენა, გარემო ვითარების ანალიზი, რისკის მართვის სტრატეგიის შერჩევა, რისკის შემცირების საშუალების არჩევა, რისკზე ზეგავლენის განხორციელება [8].

#### 1.4. ამოცანის დასმა და გადაწყვეტის სქემა

რისკი - ყოვლისმომცველი მოვლენა, რომელიც დამახასიათებელია ყველა მეურნე სუბიექტისთვის, რომლებიც ფუნქციონირებენ საბაზრო ურთიერთობების პირობებში.

მოცემულ ნაშრომში განხილულ იქნა რისკის სხვადასხვა სახეობები, რისკების ანალიზისა და შეფასების სხვადასხვა მეთოდები, გადაწყვეტილებათა მიღება არის ის, რის გარეშეც შეუძლებელია რისკების ეფექტური მართვა. რისკების მართვის მთავარი სირთულე მდგომარეობს იმაში, რომ არ არსებობს რაიმე „მზა“ რეცეპტი.

რისკის მართვა შესაძლებელია, ესე იგი გამოყენებულ უნდა იქნეს სხვადასხვა ზომები, რომელიც გარკვეულ დონეზე საშუალებას იძლევა

მოხდეს რისკის შემთხვევის დადგომის პროგნოზირება და მიღებულ იქნეს ზომები მის შესამცირებლად.

პროგნოზირება რისკ-მენეჯმენტში წარმოადგენს ობიექტისა და მისი ცალკეული ნაწილების ფინანსური მდგომარეობის ცვლილებების პერსპექტივაში გადამუშავებას. პროგნოზირება-გარკვეული შემთხვევის წინასწარ განჭვრეტა. ის არ ისახავს ამოცანად უშუალოდ პრაქტიკაში განახორციელოს დამუშავებული პროგნოზები. პროგნოზირების თავისებურება მდგომარეობს აგრეთვე ფინანსური მაჩვენებლებისა და პარამეტრების აგებული ალტერნატიულობაში, რომელიც განსაზღვრავს ობიექტის მართვის ფინანსური მდგომარეობის განვითარების სხვადასხვა ვარიანტებს დასახული ტენდენციების საფუძველზე.

თანამედროვე საფინანსო ბაზარი, რომელიც წარმოადგენს დიდი განზომილების, ურთულეს სისტემას საინფორმაციო და რისკების მთელი სპექტრის ეფექტური მართვის თვალსაზრისით, საჭიროებს ასევე შესაბამისად მეთოდების შემუშავებასა და იმპლემენტაციას.

პროგნოზირების დღეს არსებული მეთოდების პარალელურად, აუცილებელია შემუშავდეს თანამედროვე მეცნიერულ ცოდნაზე, კერძოდ ხელოვნური ინტელექტის თეორიაზე დაფუძნებული მეთოდები, რაც წარმოადგენს მოცემული სადისერტაციო თემის საგანს.

აქედან გამომდინარე, პრობლემის დასმისა და გადაწყვეტის თვალსაზრისით, მიზანშეწონილად მიგვაჩნია პროგნოზირების ფართო სპექტრის (სტატისტიკური, მონტე-კარლოსა თუ სხვა იმიტაციური მოდელირების) მეთოდების მიმოხილვა და ანალიზი, ხელოვნური ინტელექტის თანამედროვე მიღწევების (ხელოვნური ნეირონული ქსელების, ევოლუციური ალგორითმების და სხვ.) გათვალისწინებით.

დასასრულს, ჩვენს მიერ შემუშავებული მიდგომების, კვლევითი სამუშაოების წარმოდგენა და მათი შემოწმება იმიტაციური ექსპერიმენტების მეშვეობით.

## თავი 2. რისკების პროგნოზირების მეთოდების მოკლე მიმოხილვა

### 2.1. სტატისტიკური მეთოდები

პროგნოზირება – არის მომავლის წინასწარი განჭვრეტა, მასთან დაკავშირებული მიმდინარე ვარაუდებისა და დაგროვილი გამოცდილების საფუძველზე.

**ექსპერტული შეფასებების მეთოდი.** ამ მეთოდის არსი მდგომარეობს იმაში, რომ პროგნოზის საფუძველს წარმოადგენს ერთი სპეციალისტის ან სპეციალისტთა ჯგუფის მოსაზრება, რომელიც ეფუძნება პროფესიონალურ, მეცნიერულ და პრაქტიკულ გამოცდილებას.

**ექსტრაპოლაციის მეთოდი.** ექსტრაპოლაციის მთავარი იდეა-როგორც წარსულში, ასევე აწმყოში ჩამოყალიბებული საწარმოს განვითარების მდგრადი ტენდენციების შესწავლა და მათი მომავალში გადატანა.

**მოდელირების მეთოდები.** მოდელირება-მოდელის კონსტრუირება პროცესებისა და ობიექტების წინასწარი შესწავლის საფუძველზე, მისი არსებითი ნიშნებისა და მახასიათებლების გამოყოფა. პროგნოზირება, მოდელების გამოყენებით მოიცავს მის შემუშავებას, ექსპერიმენტულ ანალიზს, წინასწარი პროგნოზული გათვლის შედეგების შეპირისპირებას ობიექტის ან პროცესის მდგომარეობის ფაქტობრივ მონაცემებთან, მოდელის კორექტირებასა და დაზუსტებას [7].

**ეკონომიკური პროგნოზირების მეთოდი** (ეკონომიკური ანალიზი) მდგომარეობს იმაში, რომ რომელიმე ეკონომიკური მოვლენა ან პროცესი, რომელსაც ადგილი აქვს საწარმოში, იყოფა ორ ნაწილად, რომლის შემდგომაც დგინდება ამ ნაწილების ურთიერთკავშირი და გავლენა პროცესის მიმდინარეობასა და განვითარებაზე, აგრეთვე ერთმანეთზე. ასეთი პროცესის არსის გამოვლენა შესაძლებელია ანალიზის მეშვეობით. ასევე შესძლოა განისაზღვროს მისი ცვლილებების კანონზომიერება მომავალში, ყოველმხრივ შეფასდეს დასახული მიზნების მიღწევის გზები .

**საბალანსო მეთოდი.** აღნიშნული მეთოდი დაფუძნებულია ბალანსების შემუშავებაზე, რომელიც წარმოადგენს მაჩვენებელთა სისტემას, სადაც პირველი ნაწილი, რომელიც ახასიათებს რესურსებს მათი შემოსავლის წყაროს მიხედვით, ტოლია მეორესი, რომელიც ასახავს ხარჯების ყველა მიმართულებით განაწილებას.

**პროგნოზირების სტატისტიკური მეთოდები** მოიცავს თანამედროვე მათემატიკურ-სტატისტიკური პროგნოზირების მეთოდების შესწავლას, შემუშავებასა და გამოყენებას ობიექტური მონაცემების (მათ შორის უმცირესი კვადრატების არაპარამეტრული მეთოდების პროგნოზის სიზუსტის შეფასების, ადაპტური მეთოდების, ავტორეგრესიის მეთოდების და სხვ.) საფუძველზე, პროგნოზირების ექსპერტული მეთოდების ალბათობით-სტატისტიკური მოდელირების თეორიისა და პრაქტიკის განვითარებას, მათ შორის სუბიექტური ექსპერტული შეფასების ანალიზის მეთოდების სტატისტიკის არარიცხოვრივი მონაცემების საფუძველზე, რისკების შეაფასებისა და პროგნოზირების მეთოდების შემუშავებასა და გამოყენებას კომბინირებული მეთოდების პირობებში ეკონომიკურ-მათემატიკური და ეკონომეტრიკულ (როგორც მათემატიკურ-სტატისტიკური, ისე ექსპერტული) მოდელებთან ერთად [7].

### **2.1.1. ფინანსური რისკების ეკონომიკურ-სტატისტიკური შეფასების მეთოდები: დონე და დისპერსია**

**ფინანსური რისკის დონის შეფასების მეთოდოლოგიური ინსტრუმენტები** საკმაოდ ფართოა, ვინაიდან მოიცავს ისეთი 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.** იგი ახასიათებს ამ დონის შეფასების ზოგად ალგორითმს, რომელიც წარმოდგენილია შემდეგი ფორმულით:

$$YP = BP \times PII \quad (2.1)$$

სადაც: YP – შესაბამისი ფინანსური რისკის დონე;

BP – მოცემული ფინანსური რისკის წარმოქმნის ალბათობა;

PII – შესაძლო ფინანსური დანაკარგების ოდენობა მოცემული რისკის რეალიზაციისას.

პრაქტიკაში ამ ალგორითმის გამოყენებისას, შესაძლო ფინანსური დანაკარგების ოდენობა ჩვეულებრივ, გამოისახება აბსოლუტური ჯამით, ხოლო ფინანსური რისკის წარმოქმნის ალბათობა–ამ ალბათობის განზომილების ერთ–ერთი კოეფიციენტით (ვარიაციების კოეფიციენტით, ბეტა–კოეფიციენტით და სხვ.). შესაბამისად, მოცემული ალგორითმით, ფინანსური რისკის დონე მისი გაანგარიშებისას გამოსახული იქნება აბსოლუტური მაჩვენებლით, რაც არსებითად ამცირებს მისი შედარების ბაზას სხვა ალტერნატიული ვარიანტების განხილვისას[6].

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

$$\sigma^2 = \sum_{i=1}^n (R_i - \bar{R})^2 \times P_i \quad (2.2)$$

სადაც:  $\sigma^2$  – დისპერსია;

$R_i$  – განხილვადი ფინანსური ოპერაციის მოსალოდნელი შემოსავლის შესაძლო ვარიანტების კონკრეტული მნიშვნელობა;

$R$  – განხილვადი ფინანსური ოპერაციის საშუალო მოსალოდნელი შემოსავლის მნიშვნელობა;

$P_i$  – ფინანსური ოპერაციის მოსალოდნელი შემოსავლის ცალკეული ვარიანტების მიღების შესაძლო სიხშირე (ალბათობა);

$n$  – დაკვირვებათა რიცხვი.

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

$$\sigma = \sqrt{\sum_{i=1}^n (R_i - \bar{R})^2 \times P_i} \quad (2.3)$$

სადაც:  $\sigma$  – საშუალო კვადრატული (სტანდარტული) გადახრა;

$R_i$  – განხილვადი ფინანსური ოპერაციის მოსალოდნელი შემოსავლის შესაძლო ვარიანტების კონკრეტული მნიშვნელობა;

$R$  – განხილვადი ფინანსური ოპერაციის საშუალო მოსალოდნელი შემოსავლის მნიშვნელობა;

$P_i$  – ფინანსური ოპერაციის მოსალოდნელი შემოსავლის ცალკეული ვარიანტების მიღების შესაძლო სიხშირე (ალბათობა);

$n$  - დაკვირვებათა რიცხვი.

**ვარიაციის კოეფიციენტი.** იგი საშუალებას იძლევა განვსაზღვროთ რისკის დონე, თუ ფინანსური ოპერაციების განხორციელებისას, საშუალო მოსალოდნელი შემოსავლის მაჩვენებლები ერთმანეთისაგან გასხვავდება.

$$CV = \frac{\sigma}{R} \quad (2.4)$$

სადაც:  $CV$  – ვარიაციის კოეფიციენტი;

$\sigma$  – საშუალო კვადრატული (სტანდარტული) გადახრა;

$R$  – განხილვადი ფინანსური ოპერაციის საშუალო მოსალოდნელი შემოსავლის მნიშვნელობა.

**ბეტა-კოეფიციენტი და მისი გამოყენება ფინანსური რისკების დონის შეფასებისათვის.** იგი საშუალებას იძლევა შეფასდეს ინდივიდუალური ან პორტფელური სისტემატური ფინანსური რისკი ფინანსური ბაზრის რისკის დონესთან მიმართებაში მთლიანად. ეს მაჩვენებელი ჩვეულებრივ გამოიყენება ინვესტირების რისკის შეფასებისთვის ცალკეული ფასიანი ქაღალდების შემთხვევაში.

$$\beta = \frac{k \times \sigma_k}{\sigma_p} \quad (2.5)$$

სადაც:  $\beta$  –ბეტა–კოეფიციენტი;

$K$  – კორელაციის კოეფიციენტი (დონე) ფასიანი ქაღალდების ინდივიდუალური სახეობის (ან პორთფელისა ჯამში) შემოსავლის დონისა და მოცემული ჯგუფის საფონდო ინსტრუმენტების შემოსავლის საშუალო დონეს შორის ბაზარზე მთლიანად.

$\sigma_k$  – შემოსავლის საშუალო კვადრატული (სტანდარტული) გადახრა ფასიანი ქაღალდების ინდივიდუალური სახეობის (ან პორთფელისა ჯამში) მიხედვით;

$\sigma_p$  – შემოსავლის საშუალო კვადრატული (სტანდარტული) გადახრა საფონდო ბაზრის მიხედვით მთლიანად.

ცალკეული ფასიანი ქაღალდების ფინანსური რისკის დონე განი-საზღვრება ბეტა–კოეფიციენტის შემდეგი მნიშვნელობების საფუძველზე:

$\beta = 0$  – რისკი არ არსებობს;  $\beta = 1$  – საშუალო დონე;  $\beta > 1$  — მაღალი დონე;  $\beta < 1$ – დაბალი დონე.

### 2.1.2. დროებითი მწკრივების პროგნოზირების მეთოდები

დროებითი მწკრივების მეთოდები პროგნოზირების ამოცანების წარმატებული გადაწყვეტაა, 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, ამიტომ  $x$ -ი შემავალ პარამეტრს წარმოადგენს დროის მომენტიში. გამომავალი  $y$ -პარამეტრი კი არის მწკრივის დონე. დროთა განმავლობაში, მკვეთრად გამოხატული ცვლილებების არარსებობის შემთხვევაში, ზოგადი ტენდენცია ნარჩუნდება [7].

მწკრივის აღწერა შესაძლებელია შემდეგი სახის განტოლებით:

$$YT = F(t) + ET, \quad (2.6)$$

სადაც:  $F(t)$  – დროის დეტერმინირებული ფუნქცია;

ET – შემთხვევითი სიდიდე.

დროებით მწკრივებში ტარდება ტრენდის ანალიზისა და შერბილების ოპერაცია, რომელიც ასახავს ზოგიერთი ფაქტორის ზეგავლენას. ტრენდის აგებისათვის გამოიყენება უმცირეს კვადრატთა მეთოდის კრიტერიუმები.

არც თუ ისე დიდი ხნის წინ (გასული საუკუნის 80–ანი წლების შუა პერიოდამდე) არსებობდა დროებითი მწკრივების პროგნოზირების საყოველთაოდ აღიარებული რამდენიმე მეთოდი:

- ეკონომეტრიკული;
- რეგრესიული;
- ბოქსი–ჯენკინსის მეთოდები (ARIMA, ARMA).

დღესდღეობით შეგვიძლია დარწმუნებით ვთქვათ, რომ პროგნოზირებისას ნეირონული ქსელის გამოყენება იძლევა საგრძნობ უპირატესობას სხვა გაცილებით მარტივ სტატისტიკურ მეთოდებთან შედარებით[8].

### 2.1.3. შერბილებაზე დაფუძნებული პროგნოზირების მეთოდები

**პროგნოზირების „მიამიტი“ მოდელები.** „მიამიტი“ მოდელების შექმნისას ივარაუდება, რომ პროგნოზირებადი დროებითი მწკრივის რომელიმე ბოლო პერიოდი ყველზე კარგად აღწერს პროგნოზირებადი მწკრივის მომავალს, ამიტომაც ამ მოდელებში პროგნოზი, როგორც წესი წარმოადგენს მარტივ ფუნქციას, პროგნოზირებადი ცვლადი მნიშვნელობიდან უახლოეს წარსულში. ყველაზე მარტივ მოდელს წარმოადგენს

$$Y(t+1)=Y(t), \quad (2.7)$$

რაც შეესაბამება იმ ვარაუდს, რომ „ხვალ იქნება ისე, როგორც დღეს“.

ასეთი მოდელისაგან მაღალი სიზუსტის მოლოდინი არ გვაქვს, თუმცა შესაძლებელია ე.წ. „მიამიტი“ მოდელების აგება ცოტათი სხვაგვარად:

$$Y(t+1)=Y(t)+[Y(t)-Y(t-1)], \quad (2.8)$$



$$Y(t+1)=Y(t)*[Y(t)/Y(t-1)], \quad (2.9)$$

ასეთი საშუალებებით ჩვენ ვცდილობთ შესაძლო ტრენდებზე მოდელის მორგებას

$$Y(t+1)=Y(t-s), \quad (2.10)$$

ეს არის სეზონური ცვალებადობის გათვალისწინების მცდელობა.

**საშუალოები და მცოცავი საშუალოები.** ყველაზე მარტივ მოდელს, რომელიც ეფუძნება მარტივ გასაშუალოებას, წარმოადგენს:

$$Y(t+1)=(1/t)*[Y(t)+Y(t-1)+...+Y(1)], \quad (2.11)$$

ასეთი მოდელი რატომ უნდა უფრო მდგრადია ფლუქტუაციების მიმართ, რადგან მასში რბილდება შემთხვევითი აცდენები საშუალოსთან მიმართებაში. მიუხედავად ამისა, აღნიშნული მეთოდი იდეოლოგიურად ისეთივეა, როგორც „მიამიტი“ მოდელები და მისთვის თითქმის იგივე ნაკლოვანებებია დამახასიათებელი.

პროგნოზირებისთვის შესაძლებელია გამოყენებულ იქნეს მცოცავი საშუალო

$$Y(t+1)=(1/(T+1))*[Y(t)+Y(t-1)+...+Y(t-T)], \quad (2.12)$$

მისი არსი მდგომარეობს იმაში, რომ მოდელი ხედავს მხოლოდ უახლოეს წარსულს (დროის მიხედვით T ათვლებისა სიღრმეში) და პროგნოზს ადგენს მხოლოდ ამ მონაცემებზე დაყრდნობით.

პროგნოზირებისას ხშირად გამოიყენება ექსპონენციალური საშუალოების მეთოდი, რომელიც მუდმივად ადაპტირდება მონაცემებთან მიმართებაში ახალი მნიშვნელობების ხარჯზე. ფორმულა, რომელიც ამ მოდელს აღწერს ჩაიწერება შემდეგნაირად:

$$Y(t+1)=a*Y(t)+(1-a)*Y(t), \quad (2.13)$$

სადაც:  $Y(t+1)$  – დროის შემდგომი პერიოდის პროგნოზი;

$Y(t)$  – რეალური მნიშვნელობა t დროის მომენტში;

$^aY(t)$  – წარსულის პროგნოზი t დროის მომენტში;

a – შერბილების მუდმივა ( $0 \leq a \leq 1$ ).

ამ მეთოდში  $a$  არის შიდა პარამეტრი, რომელიც განსაზღვრავს პროგნოზის ადრინდელ მონაცემებზე დამოკიდებულებას, ამასთანავე მონაცემების ზეგავლენა პროგნოზზე ექსპონენციალურად მცირდება მონაცემთა „ზრდასთან“ ერთად. თუმცა ზემოთ აღწერილი მოდელები („მიამიტი“ ალგორითმები, მეთოდები, რომლებიც ეფუძნება საშუალოებს, მცოცავ საშუალოებს და ექსპონენციალურ შერბილებას) გამოიყენება არც თუ ისე რთულ სიტუაციებში პროგნოზირებისას.

#### 2.1.4. პროგნოზირების რეგრესიული მეთოდები

ზემოთ ჩამოთვლილ მეთოდებთან ერთად, პროგნოზირებისთვის გამოიყენება რეგრესიული ალგორითმები. არსებობს  $Y$  პროგნოზირებადი (დამოკიდებული) ცვლადი და წინასწარ შერჩეული  $X_1, X_2, \dots, X_N$  (დამოუკიდებელი ცვლადები) ცვლადების კომპლექტი, რომლებზეც დამოკიდებულია იგი. დამოუკიდებელი ცვლადების ბუნება შესაძლოა იყოს სხვა-სხვა. დავუშვათ,  $Y$  – არის რომელიმე პროდუქტის მოთხოვნის დონე შემდეგ თვეში, მაშინ დამოუკიდებელი ცვლადები შეიძლება იყოს ამავე პროდუქტზე მოთხოვნის დონე წინა და იმის წინა თვეში, რეკლამის ხარჯები, მოსახლეობის გადახდისუნარიანობის დონე, ეკონომიკური ვითარება, კონკურენტების საქმიანობა და სხვ.

მრავლობითი რეგრესიის მოდელი ზოგად შემთხვევებში გამოისახება შემდეგნაირად:

$$Y = F(X_1, X_2, \dots, X_N) + \varepsilon \quad (2.14)$$

წრფივი რეგრესიული მოდელის უფრო მარტივ შემთხვევაში, დამოკიდებული ცვლადობის დამოკიდებულება დამოუკიდებელზე შემდეგნაირია:

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_N X_N + \varepsilon \quad (2.15)$$


სადაც:  $\beta_0, \beta_1, \beta_2, \dots, \beta_N$  რეგრესიისთვის შესარჩევი კოეფიციენტებია;

$\varepsilon$  – ცდომილების კომპონენტი. ივარაუდება, რომ ყველა ცდომილება სწორად (ნორმალურად) განაწილებული და დამოუკიდებელია.

რეგრესიული მოდელების ასაგებად საჭიროა გვექონდეს დაკვირვებების მონაცემთა ბაზა. ადრინდელ დაკვირვებათა მნიშვნელობების ცხრილის მიხედვით შესაძლოა შეირჩეს (უმცირესი კვადრატების მეთოდი) რეგრესიის კოეფიციენტები, რომლითაც შემდგომ აიგება მოდელი. რეგრესიასთან მუშაობისას საჭიროა შემოწმდეს ნაპოვნი მოდელების ადეკვატურობა.

**საყრდენი ვექტორის მეთოდი** (*Support Vector Machine – SVM*) – მიეკუთვნება ზღვრული მეთოდების ჯგუფს. იგი განსაზღვრავს კლასებს სფეროების საზღვრების მიხედვით. მოცემული მეთოდის საშუალებით ხდება ბინარული კლასიფიკაციის ამოცანების გადაწყვეტა. აღნიშნული მეთოდის საფუძველია გადაწყვეტილებათა სიბრტყის ცნება[7].

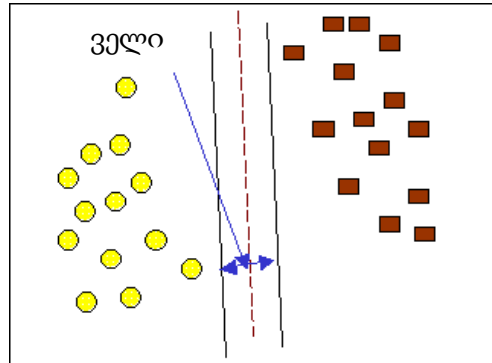
გადაწყვეტილების **სიბრტყე** (*plane*) ყოფს ობიექტებს სხვსდასხვა კლასთა მიკუთვნებულობის მიხედვით. (ნახ.2.1)-ზე მოყვანილია მაგალითი, სადაც მონაწილეობენ ორი ტიპის ობიექტები. გამყოფი ხაზი იძლევა საზღვარს, რომლის მარჯვნივ ყველა ობიექტი brown (ყავისფერია), ხოლო მარცხნივ yellow (ყვითელი). ახალი ობიექტი, რომელიც ხვდება მარჯვნივ, კლასიფიცირდება როგორც brown კლასის ობიექტი, ან yellow კლასის ობიექტი თუ იგი განლაგდა პირდაპირი გამყოფისაგან მარცხენა მხარეს. ამ შემთხვევაში ყოველი ობიექტი ხასიათდება ორი განზომილებით.




ნახ. 2.1. კლასების გაყოფა სწორი ხაზით

საყრდენი ვექტორების მეთოდის მიზანია – სიბრტყის პოვნა, რომელიც ყოფს ობიექტების ორ სიმრავლეს; ასეთი სიბრტყე ნაჩვენებია (ნახ. 2.2). ამ ნახაზზე მრავალი გამოსახულება გაყოფილია ორ კლასად: ყვითელი ობიექტები მიეკუთვნება A კლასს, ხოლო ყავისფერები B-კლასს.

ეს მეთოდი ეძებს იმ გამოსახულებებს, რომელიც მდებარეობს ორი კლასის შუა ზღვარზე, ანუ საყრდენი ვექტორები, ისინი გამოსახულია (ნახ. 2.3)-ზე.



ნახ. 2.2. საყრდენი ვექტორების განსაზღვრისთვის



ნახ. 2.3 საყრდენი ვექტორები

საყრდენი ვექტორები არის სიმრავლის ობიექტები, რომლებიც მდებარეობს სფეროების საზღვარზე. კარგი კლასიფიკაცია ითვლება იმ შემთხვევაში, თუ საზღვრებს შორის ადგილი (სფერო) ცარიელია (ნახ. 2.3.). ნაჩვენებია ხუთი ვექტორი, რომლებიც წარმოადგენენ საყრდენ ვექტორებს მოცემული სიმრავლისთვის [7].

კლასიფიკაციის საუკეთესო ფუნქცია არის ფუნქცია, რომლისთვისაც მოსალოდნელი რისკი მინიმალურია. ამ შემთხვევაში მოსალოდნელი რისკი აღნიშნავს კლასიფიკაციის ცდომილების მოსალოდნელ დონეს. აგებული მოდელის ცდომილების მოსალოდნელი დონის პირდაპირი შეფასება

შეუძლებელია, იგი შესაძლებელია ემპირიული რისკის შემთხვევაში. თუმცა გასათვალისწინებელია, რომ უკანასკნელის მინიმიზაცია ყოველთვის არ იწვევს, მოსალოდნელი რისკის მინიმიზაციას.

აღნიშნული მეთოდის ღირსება მდგომარეობს იმაში, რომ საყრდენი ვექტორების მეთოდით კლასიფიკაციისთვის, სხვა მეთოდებისაგან განსხვავებით, საკმარისია მონაცემთა მცირე ნაკრები. მოდელის სწორი მუშაობის შემთხვევაში, რომელიც აგებულია ტესტურ სიმრავლეზე, სრულიად შესაძლებელია მოცემული მეთოდის რეალურ მონაცემებზე მორგება. საყრდენი ვექტორების მეთოდი საშუალებას იძლევა [7, 8]:

- კლასიფიკაციის ფუნქციის მიღებისა მინიმალური ზედა შეფასებით (კლასიფიკაციის ცდომილების დონის).
- წრფივი კლასიფიკატორის გამოყენება არაწრფივთან მუშაობაში, სიმარტივის ეფექტურობასთან შერწყმით.

### 2.15. „უახლოესი მეზობლის“ ან მსჯელობათა სისტემის მეთოდი ანალოგიური შემთხვევების საფუძველზე

„უახლოესი მეზობლის“ მეთოდი მიეკუთვნება იმ მეთოდების კლასს, რომელთა მუშაობაც ეფუძნება მონაცემთა მეხსიარებაში შენახვას, შემდგომ ახალ ელემენტებთან შედარებისთვის. პროგნოზირებისთვის ახალი ჩანაწერის გამოვლენის შემთხვევაში, ვლინდება გადახრა ამ ჩანაწერსა და მსგავს მონაცემთა ნაკრებს შორის, და ყველაზე მეტად მსგავსი (ახლო მეზობელი) იდენტიფიცირდება.


ასეთი მიდგომის შემთხვევაში, გამოიყენება ტერმინი „K - უახლოესი მეზობელი“ ("k - nearest neighbour"). ტერმინი აღნიშნავს, რომ ირჩევა „K ზედა“ (უახლოესი) მეზობლების განხილვისთვის, როგორც „უახლოესი მეზობლების“ სიმრავლისა. რამდენადაც, ყოველთვის არ არის მოსახერხებელი ყველა მონაცემის შენახვა, ზოგჯერ ინახება „ტიპიური“ შემთხვევების სიმრავლე. ასეთ შემთხვევაში გამოიყენება ე.წ. მეთოდი ანალოგიის მიხედვით მსჯელობას (Case Based Reasoning, CBR), მსჯელობას რომელიც

დაფუძნებულია ანალოგიურ შემთხვევებზე, პრეცედენტების მიხედვით მსჯელობას [6].

**პრეცედენტი** – სიტუაციის აღწერა მოცემულ სიტუაციაში მისაღები მოქმედებების დეტალური მითითებით. დასკვნა, რომელიც კეთდება პრეცედენტების საფუძველზე, წარმოადგენს მონაცემთა ანალიზის ისეთ მეთოდს, რომელიც აკეთებს დასკვნებს.

აღნიშნული მეთოდი თავისი არსით მიეკუთვნება კატეგორიას „შესწავლა მასწავლებლის გარეშე“ ანუ არის იგივე „თვითნასწავლი“ ტექნოლოგია, რომლის საშუალებით პრეცედენტების ყოველი ბაზის მუშა მახასიათებლების მაგალითების დაგროვებით დროთა განმავლობაში უმჯობესდება. ამ მეთოდის საშუალებით წყდება კლასიფიკაციისა და რეგრესიის ამოცანები.

**ახალი ობიექტების კლასიფიკაციის ამოცანის გადაწყვეტა.** ეს ამოცანა სქემატურად გამოსახულია (ნახ.2.4.)-ზე. მაგალითები (ცნობილი ეგზემპლარები) აღნიშნულია ნიშნით "+" ან "-", რომლებიც განსაზღვრავენ რომელიმე კლასის მიკუთვნებას "+" ან "-", ხოლო ახალი ობიექტი, რომელიც საჭიროებს კლასიფიცირებას, აღნიშნულია წითელი წრით. ახალ ობიექტებს აგრეთვე უწოდებენ მოთხოვნის წერტილებს. ჩვენი მიზანი მდგომარეობს მოთხოვნის წერტილების გამომხატურების შეფასებაში (კლასიფიკაციაში), მათი უახლოესი მეზობლების სპეციალურად შერჩეული რიცხვის გამოყენებით. ე.ი. ჩვენ გვინდა გავარკვიოთ რომელ კლასს უნდა მივაკუთვნოთ მოთხოვნის წერტილი: როგორც "+" ნიშანი თუ "-".




ნახ. 2.4. სიმრავლის ობიექტების კლასიფიკაცია K პარამეტრის სხვადასხვა მნიშვნელობისას

### 2.1.6. პროგნოზირების ამოცანის გადაწყვეტა

განვიხილოთ  $K$  – უახლოესი მეზობლების მუშაობის პრინციპი რეგრესიის ამოცანის გადასაწყვეტად. რეგრესიული ამოცანები დაკავშირებულია დამოკიდებული ცვლადის მნიშვნელობის პროგნოზირებასთან მონაცემთა ნაკრების დამოუკიდებელი ცვლადების მნიშვნელობების მიხედვით.

განვიხილოთ გრაფიკი, რომელიც ნაჩვენებია (ნახ.2.5)-ზე. მასზე აღნიშნული წერტილების ნაკრები (მწვანე მართკუთხედები) მიღებულია ცვლადი დამოუკიდებლისა  $x$  და ცვლადი დამოკიდებულის  $y$  (წითელი ფერის მრუდი) კავშირების მიხედვით. მოცემულია მწვანე ობიექტების ნაკრები. ესე იგი (მაგალითების კრებული). ჩვენ გამოვიყენებთ  $K$  – უახლოესი მეზობლების მეთოდს  $x$  მოთხოვნის წერტილის ამოსავალის წინასწარ განჭვრეტისათვის მოცემული მაგალითების კრებულის მიხედვით (მწვანე მართკუთხედები).



ნახ. 2.5. პროგნოზირების ამოცანის გადაწყვეტა  $k$  პარამეტრის სხვადასხვა მნიშვნელობისას

პროგნოზირების ამოცანის გადაწყვეტა ხორციელდება ზემოთ აღწერილი მოქმედებების გადატანის გზით უახლოესი მეზობლების ნებისმიერი რიცხვის გამოყენების ისეთი სახით, რომ  $x$  მოთხოვნის

წერტილის  $y$  გამოსავალი გამოითვლება როგორც უახლოესი მეზობლების მოთხოვნის წერტილის გამოსავლების საშუალო არითმეტიკული მნიშვნელობა.

მონაცემთა კრებულის დამოუკიდებელი და დამოკიდებული ცვლადები შესაძლოა იყოს როგორც უწყვეტი, ასევე კატეგორიული. უწყვეტი დამოკიდებული ცვლადებისთვის ამოცანა განიხილება, როგორც პროგნოზირების ამოცანა, ხოლო დისკრეტული ცვლადებისთვის, როგორც კლასიფიკაციის ამოცანა.

წინასწარ განჭვრეტა პროგნოზირების ამოცანისას ხდება  $k$ -უახლოესი მეზობლების გამოსავლების გასაშუალოებით, ხოლო კლასიფიკაციის ამოცანის გადაწყვეტა ეფუძნება „ხმათა უმრავლესობის“ პრინციპს.

**ბაიესის კლასიფიკაცია** [7]. ბაიესის კლასიფიკაციამ ფართო გავრცელება ჰპოვა პრაქტიკაში. თავდაპირველად იგი გამოიყენებოდა ექსპერტთა ცოდნის ფორმალიზაციისთვის 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. „გამჭირვალე მოდელები“ [8].

„მიამიტი კლასიფიკაცია“ – კლასიფიკაციის საკმაოდ გამჭირვალე და გასაგები მეთოდი. „მიამიტი“ მას ეწოდება იმიტომ, რომ გამომდინარეობს ნიშნების ერთობლივი დამოუკიდებლობის ვარაუდიდან. კლასიფიკაციის სხვა მეთოდების უმრავლესობა ვარაუდობს იმას, რომ კლასიფიკაციის დაწყებამდე იმის ალბათობა რომ ობიექტი ეკუთვნის ამა თუ იმ კლასს, ერთნაირია; მაგრამ იგი ყოველთვის სწორი არ არის.



## 2.2. მონტე-კარლოს მეთოდი და მისი გამოყენება რისკების შეფასებისათვის ფინანსურ ბაზრებზე

მონტე-კარლოს მეთოდი შესაძლებელია განისაზღვროს როგორც შემთხვევითი სიდიდეების მოდელირების მეთოდი მათი გადანაწილების მახასიათებლების გამოთვლის მიზნით. მისი გამოყენება გამართლებულია პირველ რიგში იმ ამოცანების შემთხვევაში, რომლებიც უშვებენ თეორიულ-ალბათობის აღწერას.

**მონტე-კარლოს მეთოდის ზოგადი სქემა.** მონტე-კარლოს მეთოდის არსი მდგომარეობს შემდეგში: მოითხოვება რომელიმე შესწავლადი სიდიდის  $a$  მნიშვნელობა [10]. ამისათვის ირჩევა ისეთი  $x$  შემთხვევითი სიდიდე, რომლის მათემატიკური მოლოდინი  $a$ -ს ტოლია:

$$M(X)=a. \quad (2.16)$$

პრაქტიკულად კი ვიქცევით ასე: ვატარებთ  $n$  ცდებს, რის შედეგადაც ვღებულობთ  $x$ -ის  $n$  შესაძლო მნიშვნელობას, და ვთვლით მათ საშუალო არითმეტიკულს,

$$\bar{x} = \frac{\sum x_i}{n} \quad (2.17)$$

და ვიღებთ მათ  $a$  საპოვნი რიცხვის  $a^*$ -ის შეფასებისთვის (მიახლოებული მნიშვნელობისთვის)

$$a \approx a^* = \bar{x} \quad (2.18)$$

რამდენადაც, მონტე-კარლოს მეთოდი მოითხოვს დიდი რაოდენობით ცდების ჩატარებას, მას ხშირად უწოდებენ სტატისტიკური ცდების მეთოდს. ეს მეთოდი მიუთითებს იმაზე, როგორ მიზანშეწონილად შეირჩეს  $X$  შემთხვევითი სიდიდე, როგორ მოიძებნოს მისი შესაძლო მნიშვნელობები. კერძოდ, მუშავდება გამოყენებული შემთხვევითი სიდიდეების დისპერსიის შემცირების საშუალებები, რის შედეგადაც კლებულობს ცდომილება, რომელიც დასაშვებია საპოვნი  $a$  მათემატიკური მოლოდინის შეცვლისას,  $a^*$ -ს შეფასებით [10].

მონტე-კარლოს მეთოდის ცდომილების შეფასება. დავუშვათ,  $X$  შემთხვევითი სიდიდის  $a$  მათემატიკური მოლოდინის  $a^*$ -ის შეფასების მიაღებად, წარმოებულ იქნა დამოუკიდებელი ცდების  $n$  (გათამაშებულია  $X$ -ის შესაძლო მნიშვნელობების  $n$ ) და მათ მიხედვით ნაპოვნი იქნა არჩევითი საშუალო  $\bar{x}$ , რომელიც მიღებულია როგორც საპოვნი შეფასება:  $a^* = \bar{x}$ . აშკარაა, რომ თუ ცდას გავიმეორებთ, მივიღებთ  $X$ -ის სხვა შესაძლო მნიშვნელობებს, აქედან გამომდინარე სხვა საშუალოს, და შესაბამისად  $a^*$ -ს სხვა შეფასებას. ამიტომ ზუსტი მათემატიკური მოლოდინის შეფასებას ვერ მივიღებთ. ჩნდება კითხვა დასაშვები ცდომილების სიდიდესთან დაკავშირებით. შემოვიფარგლოთ მხოლოდ  $d$ -ს დასაშვები ცდომილების ზედა ზღვრის მოძიებით მოცემულ  $g$  ალბათობით (საიმედოობით):

$$P(|\bar{X} - a| \leq \delta) = g \quad (2.19)$$

ჩვენთვის საინტერესო ცდომილების ზედა  $d$  ზღვარი სხვა არაფერია, თუ არა მათემატიკური მოლოდინის „შეფასების სიზუსტე“ შერჩევითი საშუალოს მიხედვით, ნდობის ინტერვალების საშუალებით.

განვიხილოთ შემდეგი სამი შემთხვევა:

1.  $X$  შემთხვევითი სიდიდე განაწილებულია ნორმალურად და მისი საშუალო კვადრატული გადახრა  $d$  ცნობილია. ამ შემთხვევაში ცდომილების ზედა  $g$  ზღვარი საიმედოობით,

$$\delta = \frac{t \cdot \sigma}{\sqrt{n}} \quad (2.20)$$

სადაც:  $n$  - ცდების რიცხვია ( $X$  -ის გათამაშებული მნიშვნელობა);

$t$  - ლაპლასის ფუნქციის არგუმენტის მნიშვნელობა, რომლის დროსაც;

$$\Phi(t) = \frac{g}{2} \quad (2.21)$$

$s$  - არის  $X$ -ის ცნობილი საშუალო კვადრატული გადახრა.

2. X შემთხვევითი სიდიდე განაწილებულია ნორმალურად, სადაც მისი s-საშუალო კვადრატული გადახრა უცნობია. ამ შემთხვევაში ცდომილების ზედა g ზღვარი საიმედოობით

$$\delta = \frac{t_{\gamma} \cdot s}{\sqrt{n}} \quad (2.22)$$

სადაც: n - ცდების რიცხვია;

S – „შესწორებული“ საშუალო კვადრატული გადახრა;

$t_{\gamma}$ –ს პოულობენ ცხრილის მიხედვით.

3. X შემთხვევითი სიდიდე განაწილებულია წესისამებრ, ნორმალურისაგან განსხვავებით. ცდების დიდი რაოდენობის შემთხვევაში საიმედოობით ( $n > 30$ ), რომელიც დაახლოებით g–ს ტოლია, ცდომილების ზედა ზღვარი შეიძლება გამოითვალოს ფორმულით (2.20), თუ X შემთხვევითი სიდიდის s-საშუალო კვადრატული გადახრა ცნობილია; ხოლო თუ იგი არ არის ცნობილი, შეიძლება ჩანაცვლდეს (2.20) ფორმულაში მისი s შეფასება – „შესწორებული“ საშუალო კვადრატული გადახრა ან გამოვიყენოთ (2.22) ფორმულა. შევამჩნევთ, რომ რაც მეტია n, მით უფრო ნაკლებია განსხვავება ორივე ფორმულის მიერ მოცემულ შედეგებს შორის. ეს აიხსნება იმით, რომ  $n \rightarrow \infty$  სტიუდენტის განაწილება ისწრაფვის ნორმალურისაკენ.

### 2.3. VAR მეთოდების განვითარება რისკების შეფასებისათვის ფინანსურ ბაზრებზე

ფინანსური რისკების მართვის აუცილებლობის იდეა პირველად გაჩნდა 1990–იან წლებში ისეთი მსხვილი კომპანიების, როგორებიცაა Orange Country, Barings, Metallgesellschaft, Daiwa და სხვ [6]. საჭიროა მეთოდოლოგია რისკების გაზომვისთვის, რომელიც ფინანსურ ბაზრებზე განისაზღვრება როგორც მომავალი შემოსავლიანობის გაურკვეველობის დონე. ასეთი მიზნის შემთხვევაში, მნიშვნელოვანია წარმოქმნილი რისკის ბუნების გაგება. რისკის ნებისმიერი რიცხობრივი ნიშნელობის მიღებამდე, უნდა განისაზღვროს თუ რა რისკებთან გვაქვს საქმე, პრაქტიკაში მოდელის

სიზუსტესა და მისი რეალიზაციის სირთულეს შორის კომპრომისის აუცილებლობის გათვალისწინება.


**VAR**-ეს არის ფინანსური ინსტრუმენტების პორტფელის ღირებულების მაქსიმალური პოტენციური ცვლილების საზომი განსაზღვრული ალბათობით, მოცემული დროის ჰორიზონტზე. ზოგად შემთხვევაში, ამ სიდიდის მისაღებად საჭიროა 2 კითხვზე პასუხის გაცემა: 1) აქტივების რა მოცულობა იმყოფება პოტენციურად რისკის ქვეშ და 2) როგორია ეს რისკი რიცხობრივად.

პირველ შეკითხვაზე პასუხის გასაცემად, საჭიროა მოიძებნოს შესაფასებელი აქტივების საბაზრო ღირებულება ძირითად ვალუტაში (ბაზრის მიხედვით დაკალიბრება). რისკის რაოდენობრივ მაჩვენებელზე გადასვლა მოითხოვს იმის შეფასებას, თუ რა სიძლიერით არის შესაძლებელი საბაზრო ღირებულების ცვლილება. ფინანსებში რისკი განისაზღვრება, როგორც ისტორიული შემოსავლების საშუალო კვადრატული გადახრა საშუალო დონიდან, ფინანსური ცვლადების ცვლილებების შედეგად [6].

შემდგომში, იქიდან გამომდინარე, რომ ფინანსური ინსტრუმენტის ნორმიებული შემოსავლები  $r_t/\sigma$  განაწილებულია ნორმალურად საშუალო კვადრატული გადახრის ნაპოვნ მნიშვნელობასთან ერთად, 95% სანდოობის დონით, **VAR** გამოითვლება როგორც  $1.65\sigma$  (ნახ.2.6.).

**VaR** სტატისტიკა

დაკვირვებათა  $N$



**ნახ. 2.6. VAR გამოთვლა**

**VAR გამოთვლის მეთოდები:** Value at Risk გახდა ინვესტორისა და რისკ-მენეჯერის ინსტრუმენტთა ნაკრების მნიშვნელოვანი შემადგენელი ნაწილი, ვინაიდან იგი იძლევა რისკის რიცხოვრივ ზომას. შემუშავდა **VAR** შეფასების რამდენიმე მიდგომა, რომლებიც შეიძლება დაიყოს ორ ჯგუფად .

პირველი ჯგუფი იყენებს შეფასების ლოკალურ მეთოდებს. იგი ზომავს რისკს ღირებულების პირველადი განსაზღვრით დროის საწყის მომენტში, ხოლო შემდგომ იყენებს წარმოებულებს შესაძლო ცვლილების განსაზღვრისთვის. მეთოდების მეორე ჯგუფი გამოიყენებს ე.წ. სრულ შეფასებას. ეს მეთოდები ზომავენ რისკებს, შესაძლო სცენარების ფართო ნაკრებიდან თითოეულისათვის პორტფელის სრული გადაფასებით. სრული შეფასების მეთოდი შესაძლებელია რეალიზებულ იქნეს, მონტე-კარლოსა და ისტორიული მოდელირების მეთოდების მიხედვით[6].

**დელტა-ნორმალური შეფასება.** ლოკალური შეფასების მეთოდები ძირითადად ეფუძნება ვარაუდს შემოსავლების განაწილების ნორმალურობის შესახებ. ეს ვარაუდი განსაკუთრებით მოსახერხებელია, რადგან ამ შემთხვევაში ნორმალურად განაწილებული ცვლადების ჯამი, თვითონ წარმოადგენს ნორმალურად განაწილებულ სიდიდეს.

ამ მიდგომის განოყენებისას, აუცილებელია ინსტრუმენტის შერჩევა, რომლის ღირებულებაც დამოკიდებულია ერთადერთზე, რომელიც დევს რისკის ფაქტორის საფუძველში— $S$  საბაზო აქტივის ფასზე, რომელიც შედის პორტფელში.

$$V_0 = V(S_0) \quad (2.23)$$

განვსაზღვროთ  $\Delta_0$  როგორც პირველი რიგის კერძო წარმოებული, სხვაგვარად როგორც პორტფელის მგრძნობელობა აქტივის ფასის ცვლილებაზე. ფინანსურ ლიტერატურაში [3, 4] ამ წარმოებულს ეწოდება მოდიფიცირებული დურაცია ფიქსირებული შემოსავლიანი ინსტრუმენტების პორტფელისათვის ან დელტა დერივატივებისათვის [3, 5]. შესაბამისად, ღირებულების პოტენციური დანაკარგი  $dV$  გამოითვლება შემდეგი სახით:

$$dV = \frac{\partial V}{\partial S} \Big|_{V=V_0} dS = \Delta_0 dS \quad (2.24)$$

თუ შემოსავლების განაწილება ნორმალურია, პორთფელისათვის **VAR** მნიშვნელობა შესაძლოა მიღებულ იქნეს როგორც აქტივის ზომის (ოდენობის) წარმოება პორთფელის საბაზო აქტივის **VAR** ზე.

$$VaR = |\Delta_0| \times (\alpha \sigma S_0) \quad (2.25)$$

სადაც  $\alpha$  – არის კოეფიციენტი, რომელიც შეესაბამება მნიშვნელობის შესაბამის დონეს (1.65 – 95%-თვის და 2.32 – 99%-თვის) და  $\sigma$  – საბაზო აქტივის ღირებულების შესაძლო ცვლილებების საშუალო კვადრატული გადახრა. მეთოდის ეს სახეობა არის ანალიტიკური. ფიქსირებული შემოსავლიანი ფინანსური ინსტრუმენტისათვის, რისკის ფაქტორს წარმოადგენს  $\gamma$  შემოსავალი და ფარდობითობა ფასი/შემოსავალი. ამ შემთხვევაში, ინსტრუმენტის **VAR**-(სარისკო ღირებულება) მოიძებნება შედეგი სახით:

$$dV = -D_m V dy \quad (2.26)$$

$$VaR = \alpha \sigma D_m V \quad (2.27)$$

სადაც  $D_m$  – არის ობლიგაციის მოდიფიცირებული დურაცია.

**დელტა-გამა შეფასება.** დელტა-ნორმალური მიდგომის აშკარა დამატებას წარმოადგენს ტეილორის განლაგების უფრო მაღალი რიგის წარმოებულების განხილვა. მათი მეშვეობით შესაძლებელია აპროქსიმაციის სიზუსტის გაუმჯობესება:

$$dV(S, t) = \frac{\partial V}{\partial S} dS + \frac{\partial V}{\partial t} dt + \frac{1}{2} \frac{\partial^2 V}{\partial S^2} dS^2 + \dots \quad (2.28)$$

ან ფინანსური აღნიშვნების გამოყენება,

$$dV(S, t) = \Delta dS + \Theta dt + \frac{1}{2} \Gamma dS^2 + \dots \quad (2.29)$$

გარდაქმნების ანალოგიურად, რომლებიც იქნა წარმოებული დელტა-ნორმალური მიდგომის აღწერაში, შესაძლოა ფორმულის მიღება ფასი/შემოსავლის ფარდობისთვის, ობლიგაციებისთვის დელტა-გამა მეთოდის შეფასების ტერმინებში.

$$dV = -D_m V dy + \frac{1}{2} C V dy^2 + \dots \quad (2.30)$$

სადაც:  $D_m$  – მოდიფიცირებული დურაცია;

$C$  – მეორე რიგის წარმოებულის კოეფიციენტი, რომელიც კონვექციას წარმოადგენს.

ნორმალურობის ვარაუდისას, რისკის ღირებულებისათვის ანალიტიკური ფორმულა საკმაოდ მარტივია, აგრეთვე არაწრფივი ინსტრუმენტებისათვის (კერძოდ ოფციონების) და ფიქსირებული შემოსავლიანი ინსტრუმენტებისათვის.

$$VaR_{op} = |\Delta| \alpha \sigma - \frac{1}{2} \Gamma(\alpha \sigma)^2 \quad (2.31)$$

$$VaR_{fixed} = D_m \alpha \sigma V + \frac{1}{2} C(\alpha \sigma V)^2 \quad (2.32)$$

არსებობს აგრეთვე ანალიტიკური მეთოდების შემდგომი განვითარების დიდი რაოდენობა, რომლებიც კორექტირებას უკეთებენ VAR სარისკო ღირებულების მნიშვნელობას უფრო მაღალი რიგის წარმოებულების მნიშვნელობების შესაბამისად, მაგ. როგორცაა კორნიმ–ფიშერის მეთოდი. მაგრამ ეს მიდგომები ანიველირებს ანალიტიკური მეთოდების მთავარ უპირატესობას, უფრო მეტი გამოთვლითი რესურსების მოთხოვნით [10].

**(მონტე–კარლოს) სრული შეფასების მეთოდები.** ზოგიერთ შემთხვევაში აპროქსიმაციის მიდგომა ტეილორის მწკრივში განლაგებით, საერთოდ არ გამოდგება. ამ შემთხვევაში იყენებენ სრული შეფასების მეთოდს, რომელიც განიხილავს პორტფელის ღირებულებას შესაძლო საფასო ცვლილებების ფართო მნიშვნელობისათვის.

$$dV = V(S_1) - V(S_0) \quad (2.33)$$

$S_1$ –ის ახალი მნიშვნელობები შესაძლოა გენერირდეს მოდელირების სტატისტიკური მეთოდების საშუალებით. კერძოდ კი მონტე–კარლოს მეთოდის, რომელიც ეფუძნება შესაძლო დანამატების გადანაწილების აპრიორულ მოცემულობას.

$S_1$ –ის მიღების სხვა მეთოდი შეიძლება იყოს ისტორიული მოდელირების მეთოდი, რომელიც მხოლოდ ახდენს არც თუ ისე დიდი ხნის ისტორიული მნიშვნელობების გადარჩევას. კერძოდ, წარსულ მნიშვნელო-

ბებთან დაბრუნებით, იყენებს განსაზღვრულ საწონებს შემოსავლების ისტორიული მნიშვნელობის დროით მწკრივებთან. ეს მეთოდი ითვალისწინებს არც თუ ისე დიდი ხნის ისტორიული მნიშვნელობების გადანაწილების გამოყენებას.[11]

ორივე შემთხვევაში ფორმირდება პორტფელის ღირებულება მოცემულ თარიღზე, სრული შეფასების მეთოდის გამოყენებით. აღნიშნული მეთოდი პოტენციურად არის ყველაზე ზუსტი, ვინაიდან იგი ითვალისწინებს ყველა შესაძლო არაწრფივობას, და ყველა შესაძლო გადახდებს, რომლებიც ზოგჯერ უბრალოდ იგნორირდება, დელტა–ნორმალური მიდგომის შემთხვევაში.

**VAR** მიდგომა სრული შეფასების მეთოდი საკმაოდ მომთხოვნიარესურსების მიმართ, რადგანაც აუცილებელია პოზიციის საბაზრო ღირებულების სრული გათვლა საბაზისო აქტივების დიდი რაოდენობით შესაძლო ცვლილებებზე–რისკის ფაქტორებზე.

გამოთვლების მოთხოვნადი ინტენსივობის შემცირების მიზნით, ზოგჯერ გამოიყენება მონტე–კარლოს ქსელური მეთოდი.[10], როდესაც პორტფელის ღირებულების გამოთვლა ხდება მნიშვნელობის არა ყველა სიმრავლეზე, არამედ საკვანძო წერტილების გარკვეულ რაოდენობაზე[11].

ისტორიული მოდელირების მეთოდის მთავარი უპირატესობა მდგომარეობს იმაში, რომ დროის უმოკლეს ინტერვალში, საკმაოდ მარტივი მეთოდით შესაძლებელია სრული შეფასების მიღება სხვადასხვაგვარი ინსტრუმენტების დიდი რაოდენობით პორტფელების შემთხვევაში.

მეორე მხრივ, ისტორიული მოდელირების მეთოდს გააჩნია რიგი უარყოფითები. პირველი მდგომარეობს ისტორიული მონაცემების საკმაო რაოდენობის არსებობის აუცილებლობაში ფასების დინამიკის მიხედვით.

რაც შეეხება მონტე–კარლოს მეთოდს, ეს არის მეტად მძლავრი მეთოდი, რომელსაც პრინციპში შეუძლია გაითვალისწინოს შესაძლო რისკების ფართო წრე, მათ შორის რათქმაუნდა არაწრფივი ეფექტები. მონტე–კარლოს მეთოდით მოდელირება სრულად აღადგენს მონაცემთა



ალბათობის სიმკვრივეს და შესაძლოა გამოყენებულ იქნეს მოსალოდნელი დანაკარგების შემოწმებისთვის VAR გამოყენების შემდგომ.

მონტე-კარლოს მეთოდის მთავარი ნაკლია გამოთვლების დიდი დრო. დავუშვათ 1000 ფასიანი ქაღალდის პორტფელისთვის, რომელთაგან თითოეულისთვის გენერირდება 1000 დღიური მონაცემი, რიცხვთა მოდელირების საერთო ჯამი უკვე შეადგენს 106 [10].


მონტე-კარლოს მოდელირების მეთოდი, გარდა ამისა არის ყველაზე „ხარჯიანი“ ინფრასტრუქტურული და ინტელექტუალური მოთხოვნების მხრივ. ამ მეთოდის სხვა ნაკლი არის სტოქასტიკურ პროცესებზე დამოკიდებულება რისკის მოდელირებისას. სინამდვილეში, მონტე-კარლოს მეთოდი დამოკიდებულია განსაზღვრული სტოქასტიკური პროცესისაგან რისკის საბაზისო ფაქტორებისათვის, ისევე როგორც ფასწარმოქმნები ოფციონების ან იპოთეკური ინსტრუმენტებისათვის [11].

## 2.4. იმიტაციური მოდელირება რისკების მართვაში

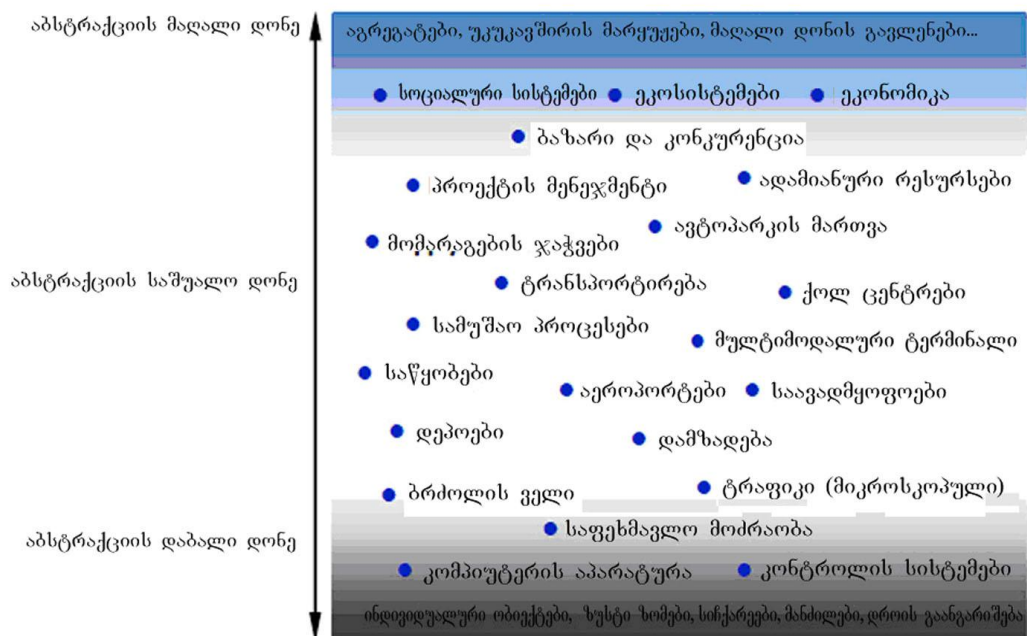
**იმიტაციური მოდელირება:** აბსტრაქციის დონეები, ძირითადი მიდგომები. თანამედროვე საფინანსო ბაზრის სისტემაში ფაქტობრივი აქტიური ექსპერიმენტების ჩატარება თითქმის შეუძლებელია. ამიტომ საფინანსო-საბაზრო რისკების ეფექტური ანალიზისა და მართვის თვალსაზრისით ერთ-ერთ პერსპექტიულ მიმართულებად განიხილება რეალური სისტემის იმიტაციური მოდელირებისა და ექსპერიმენტების მიდგომა (ნახ.2.7).

საპრობლემო სფეროს იმიტაციური მოდელირება წარმოადგენს ობიექტის ქცევის კომპიუტერული მოდელის სისტემის ალგორითმულ აღწერას. იმიტაციური მოდელი, როგორც წესი, იქმნება კვლევისთვის ანუ მასზე მრავალრიცხოვანი კომპიუტერული იმიტაციური ექსპერიმენტის ჩატარების მიზნით [20]. მათ შორის შედის იტერაციული პროცესი დამტკიცებული ან დამუშავებული ჰიპოთეზით, გამოყენებადი სისტემის აღწერისთვის. ასეთი მიდგომა საშუალებას იძლევა მივიღოთ ანალოგი

ექსპერიმენტის ეკონომიკაში, სოციოლოგიაში, ეკოლოგიაში, ამოცანის ამოხსნის დროს ოპტიმიზაციის და ბიზნესის დაგეგმვისას (ნახ. 2.8).



ნახ. 2.7. იმიტაციური მოდელირება




ნახ. 2.8 იმიტაციური მოდელირების გამოყენების სფეროები

იმიტაციური მოდელი შესაძლოა განვიხილოთ, როგორც წესების სიმრავლე, რომლებიც შეიძლება განისაზღვროს გარკვეული ბლოკ-სქემების, დიფერენციალური განტოლებების, დიაგრამების შემადგენლო-

ბით, ავტომატების, ქსელების სახით. იმიტაციური მოდელები, როგორც წესი, ნაკლებად ფორმალიზებულია, ვიდრე ანალიტიკური სისტემები, თუმცა აღიწერება რეალურთან მაქსიმალური მიახლოებით[20].

იმიტაციური მოდელირება ამ ეტაპისთვის ეყრდნობა სამ ძირითად პარადიგმას – **სისტემური დინამიკა, დისკრეტულ-მოვლენითი და აგენტური მოდელირება**. მათ შეესაბამება განსხვავებული ხარისხის აბსტრაქცია მოდელის შექმნის დროს, რაც განაპირობებს გამოვიყენოთ ესა თუ ის მიდგომა [17].

განირჩევა სამი ხარისხის აბსტრაქცია: მაღალი (სტრატეგიული), საშუალო (ტაქტიკური) და დაბალი (ოპერატიული) (ნახ.2.9) [13].



**ნახ. 2.9. სამი ხარისხის აბსტრაქცია**

დაბალ ხარისხზე ხდება მოდელირება ცალკეული ობიექტების ქცევის, მაგრამ ფიზიკური მოდელირებისაგან განსხვავებით, გამოიყენება არა ზუსტი ტრაექტორია და დრო, არამედ მათი საშუალო ან სტოქასტიკური მნიშვნელობა. ამ დონისთვის მიღებულია ამოიხსნას ამოცანები, დაკავშირებული საგზაო გადაადგილების, სატრანსპორტო, კომპიუტერული სისტემებით [20].

საშუალო ხარისხის აბსტრაქციაზე მოდელირება წარმოებს განრიგით, შეყოვნებით, სიმძლავრით და მყისიერებით, ფიზიკური გადაადგილება ამ დროს არ ანალიზირდება. აქ ხდება აბსტრაგირება ინდივიდუალური

თვისებების ობიექტის მოდელირებაზე (ხალხის, მანქანების, საქონლის) და ძირითადად განიხილება მათ ნაკადი. ამ ხარისხის მახასიათებელი ამოცანა არის სისტემა მასობრივი მომსახურების, მოდელები ბიზნეს პროცესების, ლოჯისტიკის.

მაღალი ხარისხის აბსტრაქციის მოდელირებისას, როგორც წესი თავისთავად არ არის ინდივიდუალური ობიექტი, არამედ ოპერირება ხდება მისი სიდიდის და მაჩვენებლის აგრეგირების. მოცემული ხარისხით მოდელირდება საბაზრო წონასწორობის პრობლემები, ქალაქის სოციალ-ეკონომიკური განვითარება, ეკოლოგიური პროცესები [22].

**იმიტაციური მოდელირების მეთოდების მიმოხილვა:** იმიტაციური მოდელირების განხილვისას შეიძლება გამოვყოთ სამი ძირითადი მიდგომა:

- სისტემური დინამიკა – System Dynamics (SD);
- დისკრეტულ-მოვლენათა მოდელირება – Discrete Event Modeling (DEM);
- აგენტზე დაფუძნებული მოდელირება – Agent Based Modeling (ABM).

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

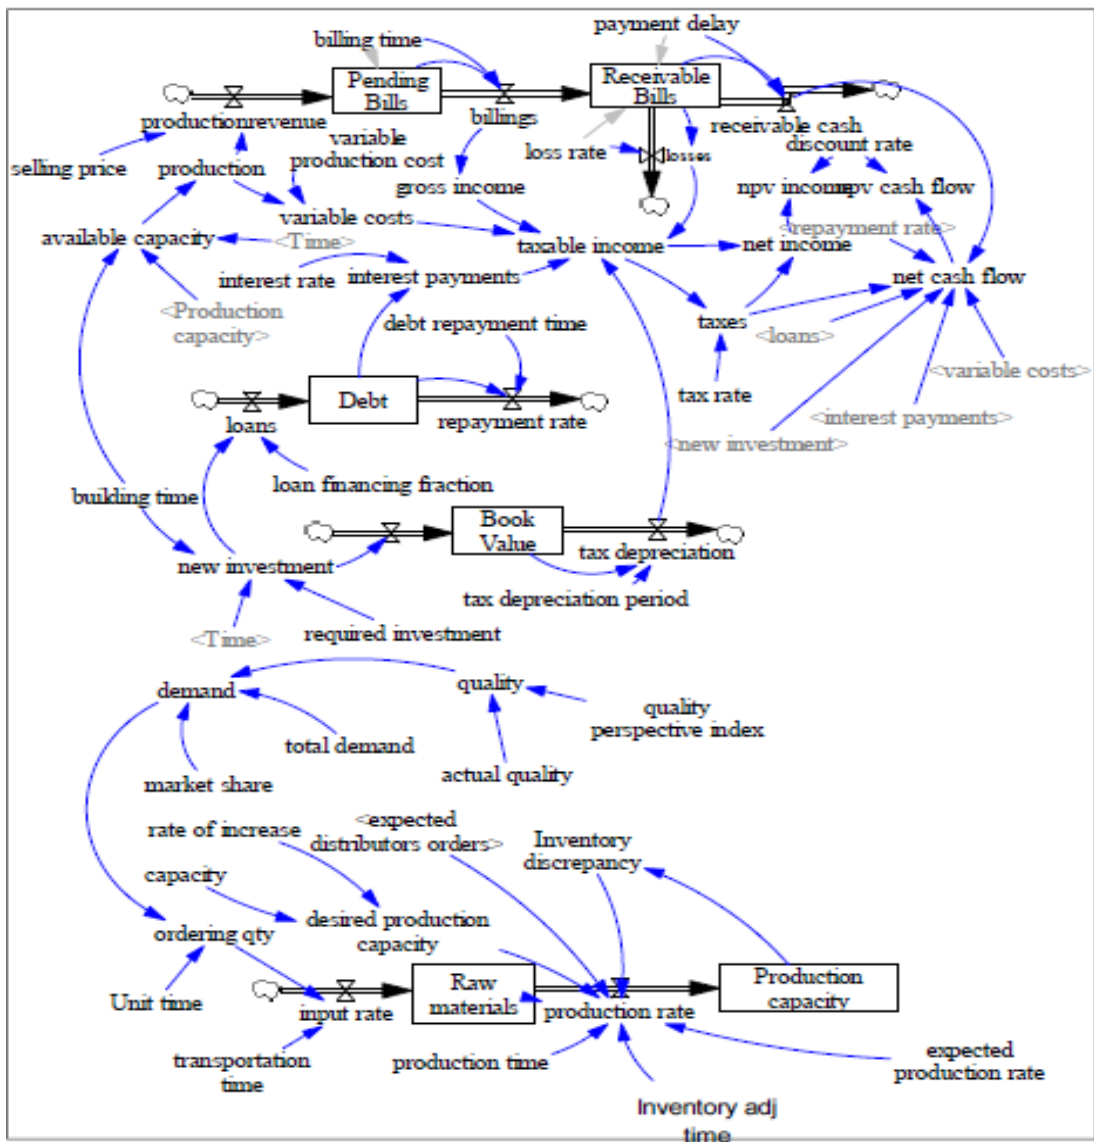
აგენტზე დაფუძნებული მოდელირება ეს არის მიდგომა ქვემოდან ზემოთ. მოდელის შემქმნელი ყურადღებას მიმართავს ცალკეული ერთეულების ქცევაზე[12].

სისტემური დინამიკა გულისხმობს აბსტრაქციების მაღალ საფეხურს და გამოიყენება ძირითადად სტრატეგიული საფეხურის ამოცანებისთვის.

დისკრეტულ-მოვლენათა მოდელირების მიდგომა გამოიყენება ძირითადად ოპერატიულ და ტაქტიკურ საფეხურზე. აგენტური მოდელის გამოყენების არჩევანი მოიცავს ნებისმიერი საფეხურის აბსტრაქციის ამოცანას [14]: აგენტს შეუძლია წარმოადგინოს საწარმო ბაზარზე, მყიდველი, პროექტი, იდეა, გადაადგილების საშუალება, ქვეითი, სამუშაო და ა.შ.

მოკლედ მიმოვიხილოთ თითოეული მათგანი.

სისტემური დინამიკა – System Dynamics (SD). სისტემური დინამიკა ძირითადად გამოიყენება ხანგრძლივ, სტრატეგიულ მოდელირებაში და იღებს აბსტრაქციის მაღალ საფეხურს [17]. ფორმალური თვალთახედვით სისტემური დინამიკური მოდელი წარმოადგენს დიფერენციალურ განტოლებათა (ალგებრის კერძო შემთხვევაში) სისტემას, რომლის სტრუქტურა განისაზღვრება ობიექტთა შორის ნაკადების არსებობით (ნახ.2.10).



ნახ. 2.10 სისტემური დინამიკა

დისკრეტულ-მოვლენათა მოდელირება – Discrete Event Modeling (DEM). დაბალი და საშუალო აბსტრაქციის ხარისხს შეესაბამება ისეთი მიდგომა როგორცაა დისკრეტულ-ხდომილობათა მოდელირება. ობიექ-

ტად შეიძლება წარმოდგენილი იყოს, როგორც ადამიანები, დეტალები, დოკუმენტები, შეტყობინებები [18]. მასში გამოყენებულია მყისიერი კონცეფცია, სადაც დროის ყოველი დისკრეტული მომენტი შეესაბამება გარკვეულ ხდომილობას ანუ რესურსების და ნაკადების დიაგრამების განსაზღვრულ მნიშვნელობას. აქედან გამომდინარე, ყველა ობიექტს გააჩნია უნივერსალური ლოგიკური ქცევა, რომელიც გამომუშავდება მთლიანობაში, წინასწარ ცნობილი ალგორითმით. ასეთი მოდელები პასუხობენ ინფორმაციის გენერაციას, გადამუშავებას და განადგურებას.

ამით აიხსნება დისკრეტულ-მოვლენათა მოდელირების დიდი პოპულარობა ისეთ სფეროში როგორცაა მასობრივი მომსახურების სისტემა, ბიზნეს პროცესები, წარმოება, ლოჯისტიკა, მედიცინა, ტრანსპორტი და სხვა. პროგრამული პროდუქტის ნაწილი გათვლილია გაცილებით დაბალი კლასის ამოცანებისთვის და შეიცავენ აბსტრაქტულ ელემენტებს, რომლებიც აღებულია კვლევათა არიდან.

**აგენტზე დაფუძნებული მოდელირება – Agent Based Modeling (ABM).** მესამე პარადიგმას წარმოადგენს აგენტური მოდელირება, რომელიც იკვლევს ცალკეული აგენტების ქცევას და მათ ზეგავლენას სისტემის ქცევაზე მთლიანობაში [23,24]. მიდგომის ფუნდამენტური ცნება – აგენტი არის ინდივიდუალიზებული აქტიური ობიექტი, რომელიც შეიძლება იყოს წარმოდგენილი როგორც ადამიანი, სატრანსპორტო საშუალება, კომპანია, დასახლებული პუნქტი და სხვ.

იმაზე დამოკიდებულებით, თუ როგორი ობიექტი წარმოადგენს აგენტს, მოდელი შეიძლება შეესაბამებოდეს მაღალი ხარისხის აბსტრაქციას (აგენტ-კომპანია, ქვეყანა), საშუალოს (აგენტ-სატრანსპორტო ერთეული), დაბალი (აგენტ-ცალკეული ადამიანი) ან დაითვალოს რამდენიმე ხარისხი. ამ თვალსაზრისით, მოცემული პარადიგმა უფრო უნივერსალურია [25].

## 2.5. საფინანსო ბაზარი როგორც მრავალაგენტური სისტემა

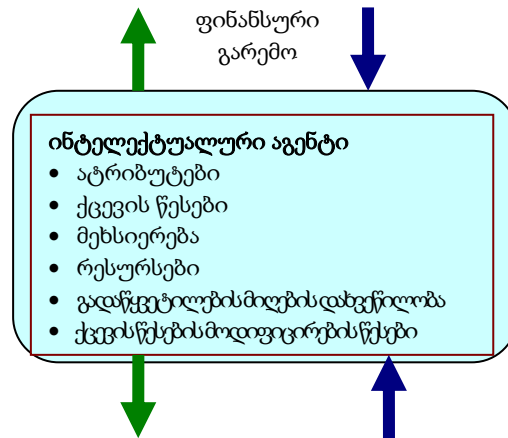
აგენტების კლასიფიკაცია და ქცევის ალგორითმი. საფინანსო ბაზრების მოდელირება საკმაოდ რთული პრობლემაა. კლასიკური სტატისტიკური მოდელი, რომელიც დაფუძნებულია ერგოდიულობის და სტაციონარულობის დაშვებაზე, გამოუსადეგარია ბაზრზე მომხდარი კრიზისების საანალიზოდ, ვინაიდან ასეთი არასტაციონალური დროითი მწკრივების სტატისტიკური თვისებები მოცემულ პირობებში განსხვავდება ჩვეულებრივისაგან [15].

ამდენად, თანამედროვე მიდგომა პარადიგმის ცვლილებით ხასიათდება, როდესაც საფინანსო ბაზრი განიხილება როგორც მულტიაგენტური სისტემა – Multi-Agent Systems (MAS). აქტუალური ხდება ისეთი სისტემების ქცევის პროგნოზირება, განსაკუთრებით კრიზისების და კრიტიკული სიტუაციების პირობებში, რათა მინიმიზებული იქნეს საფინანსო რისკები.

**მრავალაგენტური მოდელირება** – სისტემების მოდელირების ახალი მიდგომა გამოიყენება დეცენტრალიზებული სისტემების გამოსაკვლევად. იგი ეფუძნება რეალური სამყაროს ცალკეულ აქტიურ კომპონენტებს, რომლებიც **აგენტებს** წარმოადგენენ. ტერმინი მომდინარეობს ლათინური სიტყვიდან „agere“ - მოძრაობა [12].

ყოველი აგენტი ურთიერთმოქმედებს სხვა აგენტებთან, რომლებიც მისთვის წარმოქმნიან გარე გარემოს. ფუნქციონირების პროცესში აგენტს შეუძლია შეცვალოს, როგორც გარე გარემო, ისე – მისი ქცევა. ჩვეულებრივ, აგენტები აქტიური ობიექტების მოდელირების საშუალებას იძლევიან, რომლებიც რეაგირებენ თავისი გარემოს მოვლენებზე, ასევე კონკრეტულ ქმედებებს ახორციელებენ, პირდაპირი მიმართვის გარეშე. აგენტი წარმოადგენს მრავალაგენტური მოდელირების საკვანძო კონცეფციას. არ არსებობს საზოგადოდ აღიარებული განსაზღვრება, თუმცა სწავლულთა უმეტესობა ეთანხმება მ.ჯ. ვულრიჯისა და მ.ჯ. ჯინინგსის განსაზღვრებას: „აგენტი – ეს არის კომპიუტერული სისტემა, რომელიც თავსდება გარკვეულ გარემოში და შესწევს ამ გარემოში ავტონომიური ქმედებების უნარი,

რათა უზრუნველყოს მასში ჩადებული მიზნების მიღწევა, იყოს რეაქტიული, პროაქტიული და სოციალური“ [12].



ნახ. 2.11 ინტელექტუალური აგენტი

განირჩევა შემდეგი ტიპის აგენტები:

(ნახ.2.11)-ზე მოცემულია ინტელექტუალური აგენტები – პროგრამული ობიექტები, რომლებსაც შესწევთ ერთმანეთთან ინფორმაციის ურთიერთგაცვლისა და ანალიზის უნარი. ინტელექტუალურ აგენტებს უნდა შეეძლოთ გადაწყვეტილების მიღება სიტუაციის გაურკვევლობის პირობებში, და მოქმედება სრული ინფორმაციის არ არსებობის შემთხვევებში. როგორც წესი, აგენტები, უფრო ნასწავლები არიან, ვიდრე დაპროგრამებულები კონკრეტული სამუშაო შესასრულებლად. უფრო განვითარებულ აგენტებს შესწევთ უნარი ისწავლონ საკუთარ გამოცდილებაზე და იმოქმედონ შესაბამისად [19].

**ავტონომიური აგენტები** – ეს არის გამოთვლითი სისტემები, რომლებიც არსებობენ კომპლექსურ, დინამიურ გარემოში, აღიქვამენ ინფორმაციას და ავტონომიურად მოქმედებენ ამ გარემოში, ასრულებენ რა ამოცანების ერთობლიობას, რომლისთვისაც დაპროექტდნენ ისინი. პროგრამულ აგენტებს (**Software agents**) **software** – მუშაკებს ან **softbots** უწოდებენ.

**მოზილური აგენტები** გადაადგილდებიან ერთი სერვერიდან მეორეზე. მიზნები, რომლებითაც აგენტი გადაადგილდება ერთი ჰოსტიდან მეორეზე, შესაძლოა იმაში არსებობდეს, რომ ჰოსტი, რომელზედაც არის აგენტი,



მოცემული მომენტისათვის არ ფლობს მისთვის აუცილებელ რესურსებს. ამ დროს აგენტი ახდენს ჰოსტის იდენტიფიცირებას, რომელსაც გააჩნია მოთხოვნილი რესურსი, და მიგრაციით გადაადგილდება იქ, სადაც ახალი ჰოსტი აგენტს მისი რესურსების გამოყენების საშუალებას აძლევს.

**სოციალური აგენტები** ურთიერთმოქმედებენ სხვა აგენტებთან. ამგვარი ურთიერთობის რამოდენიმე ფორმა არსებობს, განსაზღვრული პროტოკოლის შესაბამისად შეტყობინებების გაცვლით დაწყებული, ჯგუფის განათლებით დამთავრებული, რომელიც მუშაობს საერთო მიზანზე. **პროტოკოლი** – ეს არის აგენტების ურთიერთმოქმედების ფორმის განსაზღვრება, ე.ი. შეტყობინებების თანამიმდევრობა, რომლებიც დიალოგს წარმოქმნიან[12].

**აგენტების თვისებები.** პროგრამული აგენტების ძირითად თვისებას წარმოადგენს ის, რომ ისინი *ავტონომიურები* არიან და ის , რომ ისინი შესაძლოა *განთავსდნენ გარემოში*. პირველი უნარი ნიშნავს იმას, რომ აგენტები დამოუკიდებელნი არიან და საკუთარ გადაწყვეტილებებს იღებენ. ამით განსხვავდებიან აგენტები ობიექტებისაგან. როდესაც ვიღებთ გადაწყვეტილებას მოხდეს დამოუკიდებელი ობიექტებისაგან სისტემის შექმნის შესახებ, სისტემა დეცენტრალიზებული ხდება.

ზემოთ თქმულზე დაყრდნობით, ჩვენ შეგვიძლია განვსაზღვროთ აგენტი, როგორც პროგრამული არსება, რომელიც[14]:

- იმყოფება გარემოში;
- ავტონომიურია – დამოუკიდებელია, ვერ კონტროლირდება გარედან;
- რეაქტიულია – რეაგირებს ცვლილებებზე გარემოში;
- პროაქტიულია – დაჟინებით მიაღწევს მიზანს;
- მოქნილია – აქვს მიზნების მიღწევის სხვადასხვა საშუალებები;
- სტაბილურია – აღდგება წარუმატებლობის შემდეგ;
- სოციალურია – ურთიერთმოქმედებს სხვა აგენტებთან.

**საფინანსო ბაზრების მულტიაგენტური მოდელირება.** საფინანსო ბაზრების კვლევის ერთ-ერთი ამოცანა მოდელის შემუშავებაში მდგომარეობს, რომელსაც უნარი შესწევს ახსნას და წინასწარ განსაზღვროს საბაზრო ფასების მოძრაობა. მიმდინარე მომენტისათვის ამ პრობლემის მოგვარების ორი ძირითადი მიდგომა არსებობს: ეკონომიკური და მიკროეკონომიკურ მრავალაგენტურ თეორიაზე დამყარებული. საფინანსო ბაზრის ქცევა ეკონომიკაში აღწერილია რაოდენობრივი ცვალებადობით. რაოდენობრივ ცვლადებს შორის ურთიერთობის შესასწავლად გამოიყენება მათემატიკური მოდელები და სტატისტიკური მეთოდები, როგორც არის ARIMA, ARCH, GARCH, რომლებიც საბაზრო ფასებისა და შემოსავლების განვითარების პროგნოზირების საშუალებას იძლევიან [14].

საფინანსო ბაზრების მოდელირება მიმდინარე მომენტისათვის სწრაფად მზარდ სფეროს წარმოადგენს ორი მთავარი მიზეზის განო:

- 1) საფინანსო ბაზრების ავტომატიზაციის სფეროს მოდელირებაში მზარდი რაოდენობის შრომების უზრუნველყოფის აუცილებლობა;
- 2) ტრადიციული გამოთვლითი მათემატიკის უუნარობა მოახდინოს ინვესტორების ქცევების შედეგების პროგნოზირება ფასების მოძრაობასთან დაკავშირებით.

საფინანსო ბაზრების სირთულე განსაზღვრავს მათემატიკური და კომპიუტერული ანალიზის სირთულეებს, ამიტომაც ჩნდება ინტერესი რეგულირებადი ექსპერიმენტის მიმართ, რომელიც მოგვცემდა სხვადასხვა პარამეტრების ვარიანტების შესაძლებლობისა და მათი ბაზრის ქცევაზე ზემოქმედების შეფასების საშუალებას[13].

მრავალაგენტური მიდგომის ეფექტურობა მდგომარეობს მის უნარში ექსპერიმენტულად შეისწავლოს განსხვავებული აგენტების დიდი პოპულაცია, ისევე, როგორც ქცევით მოდელებში, ის საშუალებას იძლევა გავითვალისწინოთ ტრეიდერების მიერ გადაწყვეტილების მიღების ფსიქოლოგიური თავისებურებანი.

საფინანსო ბაზრების მრავალაგენტური მოდელირებასთან დაკავშირებულია შემდეგი საკითხები:

- იმიტაციური მოდელის აგება მრავალაგენტური მიდგომის გამოყენებით თანამედროვე საფინანსო ბაზრის სტრუქტურისა და ფუნქციების, მისი მონაწილეების შემადგენლობისა და ურთიერთმოქმედების მეთოდების ანალიზის საფუძველზე. ამგვარი მოდელი მისი პარამეტრების ვარირების, ასევე ბაზრის ქცევისა და მისი მონაწილეების სტრატეგიების ეფექტურობის შეფასების საშუალებას მოგვცემდა;

- საფინანსო ბაზრების არსებული მეთოდებისა და მოდელების ანალიზი, რომელიც ეხება თანაბარი ფასების ფორმირებას, სააუქციონო ვაჭრობების ქცევებს, პორთფელის ფორმირებას; ქცევის ფორმალიზებული მოდელების შემუშავება იმ აგენტებისთვის, რომლებიც შედიან საინვესტიციო მოდელის შემადგენლობაში;

- მრავალაგენტური მოდელირების ენების ანალიზი;

- პროგრამული სისტემების შემუშავების, არსებული პროგრამული საშუალებების ანალიზი და პროგრამირებისთვის ამოცანის შემუშავება შერჩეული პროგრამული გარემოს ფარგლებში (Net Logo, AnyLogic, Java Agent Development Environment);

- ტრეიდინგის სტრატეგიების სხვადასხვა ვარიანტის განხილვა და ტრეიდერის მიერ მიღებულ შემოსვალზე შერჩეული სტრატეგიის გავლენის მოდელის შემოწმება და ბაზრის ცვალებადობა [14].

## თავი 3. ხელოვნური ინტელექტის მეთოდების მიმოხილვა

### 3.1 ევოლუციური ალგორითმები

ევოლუციური ალგორითმები წარმოადგენს ხელოვნური ინტელექტის ერთ–ერთ განყოფილებას. ხელოვნური ინტელექტის სისტემის აგებისას ძირითადი ყურადღება ეთმობა საწყისი მოდელის აგების წესებს, რომელთა მიხედვითაც შეიძლება შეიცვალოს იგი (განიცადოს ევოლუცია). ეს მოდელი აიგება სხვადასხვა მეთოდებით: მაგალითად ნეირონული ქსელებით ან ლოგიკური წესების ნაკრებით.

ზუსტი მეთოდებისაგან განსხვავებით, მათემატიკური პროგრამირების ევოლუციური მეთოდები გვამღევეს საშუალებას, ვიპოვოთ ოპტიმალურთან ახლოს მდგომი ამონახსნები მისაღებ დროში. სხვა ევრისტიკული მეთოდებისაგან განსხვავებით ხასიათდება მეტი უნივერსალურობით და ამდენად მეტი ხარისხით უახლოვდება ოპტიმალურ გადაწყვეტილებას.

ზოგადად ევოლუციური ალგორითმები, როგორც მეთოდოლოგიური კლასი, წარმოადგენენ პოპულაციაზე და მის ევოლუციაზე დამყარებულ ალგორითმებს, რომელთა საფუძველს ბუნებრივი ევოლუცია წარმოადგენს. ისინი იყენებენ ბიოლოგიური ევოლუციის ელემენტებს, როგორებიცაა: შეჯვარება–გამრავლება, მუტაცია, რეკომბინაცია, ბუნებრივი სელექცია და „სახეობაში ძლიერთა გადარჩენა“. ბიოლოგიური და ბუნებრივი პრინციპების გამოყენება ხელოვნურ სისტემებში XX საუკუნიდან დაიწყო, რაც მრავალი დიდი გამოგონების საფუძველი გახდა [27].

ევოლუციური ალგორითმები არის სამიეზო არეში მიახლოებითი საუკეთესო მნიშვნელობის ძიების ალგორითმები, რომლებიც გამოიყენება გლობალური ოპტიმიზაციის ამოცანებში. მათ ახასიათებთ სწავლისა და გადაწყვეტილების მიღების უნარი, ასევე ახალ გარემოსთან სწრაფი ადაპტაციის უნარი. ევოლუციურ ალგორითმებში პოპულაციის ინდივიდები გამოიყენება საპრობლემო არის პარალელური შესწავლის მიზნით, ასევე ლოკალური საუკეთესო ამონახსნების ძიების მიზნით, რაც საბოლოო

ჯამში მიყვართ კონკრეტული საპრობლემო არის გლობალური ოპტიმიზაციისკენ. ოპტიმიზაციის ალგორითმები იყოფა ორ ე.წ. „დეტერმინისტულ“ (Deterministic) და „ალბათურ“ (Probabilistic) ჯგუფად. დეტერმინისტული მოდელი გამოიყენება იმ შემთხვევაში, როდესაც ნათელი კავშირი არსებობს შემავალ პარამეტრებსა და შესაძლო ამონახსნებს შორის. წინააღმდეგ შემთხვევაში გამოიყენება ალბათური მოდელი [28].

ევოლუციური მეთოდები მიეკუთვნება სხვადასხვა ბიზნეს ამოცანების გადაჭრის ერთ-ერთ ეფექტურ საშუალებას. განვიხილოთ შემდეგი ევოლუციური ალგორითმები:

- გენეტიკური ალგორითმები – Genetic Algorithms (GA)
- გენეტიკური პროგრამირება – Genetic Programming (GP)
- ხელოვნური ნეირონული ქსელი – Artificial Neural Networks (ANN)
- კოპონენის თვითორგანიზებადი რუკა – Self-Organizing Maps (SOM)
- ამოწვის იმიტაციის ალგორითმი – Simulated annealing (SA)
- ჭიანჭველების კოლონიის მეთოდი – Ant Colony Optimization (ACO)
- იმპერიალისტური შეჯიბრებითი ალგორითმი – (ICA)
- ნაწილაკთა გროვის ოპტიმიზაციის მეთოდი – Particle Swarm Optimization (PSO)

### 3.2. რისკების პროგნოზირება გენეტიკური ალგორითმი საფუძველზე

გენეტიკური ალგორითმი – Genetic Algorithms (GA) 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.

პირველად ეს იდეა წარმოადგინა და დაამუშავა John Holland-მა 1975 წელს, ხოლო შემდეგში ფართო გამოყენება ჰპოვა სხვადასხვა მეცნიერების

მხრიდან ოპტიმიზაციის სხვადასხვა ამოცანებში. მისი სიძლიერე იმაში მდგომარეობს რომ, იგი დიდი განზომილების მრავალექსტრემუმიანი და მრავალკრიტერიუმიანი ამოცანებისათვის ოპტიუმის სწრაფი ძებნის შესაძლებლობას იძლევა, რასაც მონაცემთა პარალელური დამუშავების გზით მიიღწევა [29].

**გენეტიკური ალგორითმის კლასიკური მოდელი.** გენეტიკური ალგორითმი განიხილება როგორც ქრომოსომების ნაკრების ევოლუციის პროცესი გარკვეული წესების მიხედვით (მუტაციები და გადაკვეთები), ამასთან ქრომოსომა შედგება მონაკვეთებისაგან, რომელთაგანაც თითოეული შეესაბამება წონითი კოორდინატების განლაგების ორმაგ კოეფიციენტს განსაზღვრული სიზუსტით. ექსტრემუმთან მიახლოებისას შესაძლოა კოეფიციენთა რიცხვის გაზრდა.

გენეტიკურ ალგორითმებში მნიშვნელოვან ცნებად ითვლება გამოყენებითი ფუნქცია „ფიტნეს ფუნქციის“ (Fitness function), სხვაგვარად შეფასების ფუნქცია. ოპტიმიზაციის ამოცანებში გამოყენებითი ფუნქცია როგორც წესი, ოპტიმიზდება (უფრო ზუსტად მაქსიმიზდება) და ეწოდება სამიზნე ფუნქცია. გენეტიკური ალგორითმის ყოველ ინტეგრაციაზე, მოცემული პოპულაციის ყოველი ცალკეულის შეთვისება ფასდება გამოყენებითი ფუნქციის მეშვეობით.

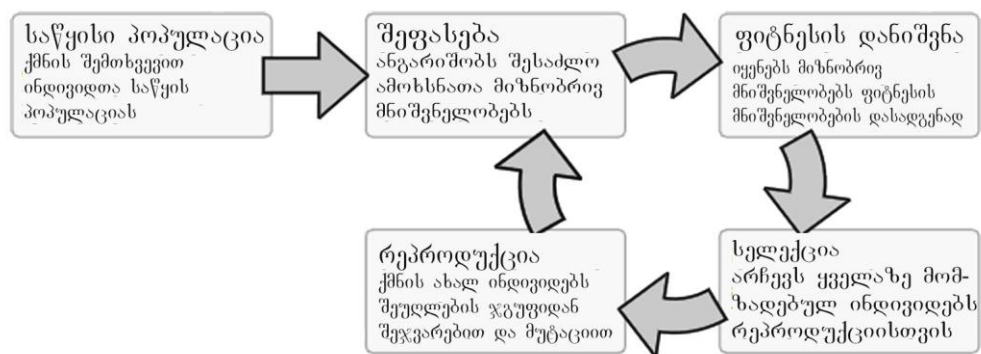
გენეტიკური ალგორითმი არის საძიებო არეში მიახლოებითი საუკეთესო მნიშვნელობის ძიების ალგორითმი, რომელიც იყენებს გენეტიკურ მოდელს თავისი ქმედების წასამართავად. თითოეული ამონახსნი ამ არეში წარმოდგენილია ქრომოსომის (გენების ერთობლიობის) სახით. ქრომოსომაში ამონახსნის კოდირების მეთოდის შერჩევა არის ალგორითმის აგების საწყისი ეტაპი. არსებონს კოდირების რამდენიმე მეთოდი:

- ორობითი კოდირება – ქრომოსომას წარმოადგენენ ფიქსირებული ზომის ბიტურ სტრიქონებად, ანუ გადაყავთ თვლის ორობით სისტემაში (ნულებით და ერთებით) და მათზე ატარებენ მარტივ ორობით ოპერაციებს როგორებიცაა NOT, OR, AND, XOR.

- ალფაბეტური და რიცხვითი კოდირება – ქრომოსომა წარმოდგენილია სიტყვების ან ნამდვილი რიცხვების სახით და მიღებულ სტრიქონებზე ხდება შესაბამისი ოპერაციები.

- ხისებრი სტრუქტურით კოდირება – თითოეული ქრომოსომა წარმოდგენილია ხის სტრუქტურის სახით. ეს კოდირება ძირითადად გენეტიკურ პროგრამირებაში (GP) გამოიყენება.[30, 31]

ალგორითმი შედგება რამდენიმე ძირითადი ბიჯისგან (ნახ. 3.1). განვიხილოთ თითოეული მათგანი.



ნახ. 3.1. გენეტიკური ალგორითმის მოქმედების ძირითადი ციკლი

1. **ინიციალიზაცია (Initialization).** გენეტიკური ალგორითმისათვის საწყისი პოპულაცია შემთხვევითად გენერირდება საძიებო არის შესაძლო ამონახსნებისაგან. პოპულაციის ზომა დამოკიდებულია კონკრეტულ ამოცანაზე, მაგრამ როგორც წესი შეიცავს რამდენიმე ასეულ ან ათას შესაძლო ამონახსნს (ქრომოსომას).

2. **ევოლუცია (Evolution) და „ფიტნეს ფუნქციის“ განსაზღვრა.** თითოეული ქრომოსომა ატარებს თავისი „ფიტნეს ფუნქციის“ (Fitness function) მნიშვნელობას, რომელიც განსაზღვრავს თუ რამდენად კარგ ამონახსნად ითვლება იგი შესაძლო ამონახსნთა სიმრავლეში, ანუ განსაზღვრავს ინდივიდის გენის სიმძლიერეს. რაც უფრო ძლიერია გენი მით უფრო დიდი შანსი აქვს გადარჩენის, ანუ სელექციის დროს ასეთი გენებისგან შემდგარი ინდივიდი დიდი ალბათობით მოხვდება არჩეულ ინდივიდებს შორის.

**3. სელექცია (*Selection*).** სელექცია (*Selection*) არის პროცესი როცა პოპულაციის ინდივიდები ირჩევა (ფიტნეს ფუნქციის გათვალისწინებით) რეპროდუქციისთვის ანუ შემდეგი თაობის პოპულაციის მისაღებად. სელექციის დროს გასათვალისწინებელია რამდენიმე მომენტი. პირველ რიგში, უნდა განისაზღვროს თუ რამდენი შთამომავალი უნდა შეიქმნას შემდეგი თაობისათვის, ასევე როგორ უნდა მოხდეს სელექციის დაბალანსება, რადგან ძალიან „მკაცრი“ სელექციის პროცესი გამოიწვევს მრავალფეროვნების შემცირებას გენებს შორის (ანუ მოხდება ყველა ძლიერი გენის არჩევა), რაც საჭიროა შემდეგი ცვლილებებისა და პროგრესირებისათვის, მეორე მხრივ კი ძალიან „სუსტი“ სელექცია ევოლუციის პროცესს შეანელებს. არსებობს სელექციის რამდენიმე მეთოდი [32]:

- „ფიტნეს-პროპორციული“ ან რულეტკის წესით სელექცია (*Fitness proportionate, Roulette-wheel selection*);
- „ბოლცმანის სელექცია“ (*Boltzmann Selection*);
- „სელექცია რანჟირებით“ (*Rank Selection*);
- „სელექცია ტურნირის წესით“ (*Tournament Selection*);
- „სელექცია დამრგვალების (ჩამოჭრის) წესით“ (*Truncation Selection*);
- „ამორჩევა მყარი წესით“ (*Steady-State Selection*);
- „ამორჩევა სტოქასტიკურ-უნივერსალური წესით“ (*Stochastic Universal Sampling*);

**4. რეპროდუქცია და პოპულაციის შეცვლა (*Reproduction*).** რეპროდუქცია (*Reproduction*) ნიშნავს შემდეგი თაობის პოპულაციის გენერაციას წინა თაობის ინდივიდებისაგან. შემდეგი თაობის გენერაცია ხდება გენეტიკური ოპერატორების დახმარებით. ეს იმას ნიშნავს, რომ შემდეგი თაობის ერთი წარმომადგენელი მიიღება წინა თაობის ერთ ან რამდენიმე წარმომადგენელს შორის კონკრეტული გენეტიკური ოპერაციის ჩატარებით. არსებობს რამდენიმე გენეტიკური ოპერატორი (მაგ: ინვერსია (*inversion*), გენის დუბლირება (*gene doubling*), გადაჯგუფება (*regrouping*), კოლონიზაცია (*colonization*), მიგრაცია (*migration*) და სხვა), მაგრამ მათ შორის ორი არის



ძირითადი და გამოიყენება გენეტიკური ალგორითმის კლასიკურ მოდელში. ესენია „შეჯვარება“(Crossover) და „მუტაცია“(Mutation) რეპროდუქციის შემდეგ წინა თაობის ჩანაცვლება ხდება ახალი თაობის პოპულაციით (Replacement) [33].

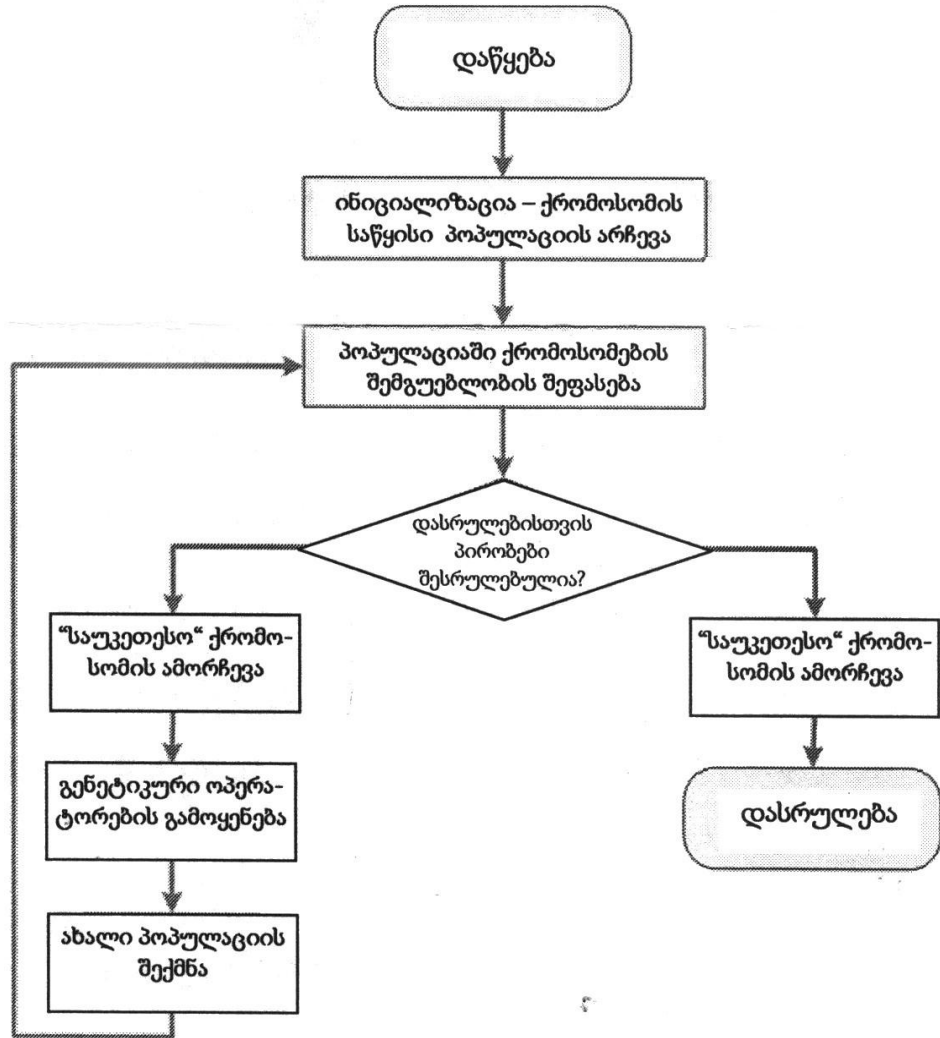
**5. ალგორითმის დასრულება (*Termination*).** ალგორითმი გრძელდება მანამ, სანამ „დასრულების პირობა“ არ შესრულდება, ანუ არ შესრულდება ჩამოთვლილთაგან ერთ-ერთი:

- ნაპოვნია პასუხი, რომელიც აკმაყოფილებს მინიმალურ კრიტერიუმებს;
- ალგორითმმა წინასწარ განსაზღვრული რეპროდუქციების რიცხვს გადააჭარბა;
- ალგორითმმა წინასწარ განსაზღვრულ „ბიუჯეტს“ (დრო/სხვა რესურსები) გადააჭარბა;
- შესაძლო ამონახსნის „ფიტნეს ფუნქციის“ მნიშვნელობამ მაქსიმუმს მიაღწია ან შემდეგი იტერაციების შედეგად აღარ უმჯობესდება [34, 35].

ალგორითმი ახდენს იმ პროცესების მოდელირებას პოპულაციებში, რომლებიც არსებითია განვითარებისთვის. გენეტიკური ალგორითმი მუშაობს „ცალკეულების“ ერთობლიობასთან–პოპულაციით, რომელთაგანაც თითოეული წარმოადგენს მოცემული პრობლემის გადაჭრის შესაძლებლობას. ყოველი ცალკეული იზომება თავისი „შეთვისებით“იმის მიხედვით, თუ რამდენად „კარგია“ მისი შესაბამისი ამოცანის გადაწყვეტა. წარმოებს დასაშვებ გადაწყვეტილებათა სრულიად ახალი პოპულაცია, წინა თაობის საუკეთესო წარმომადგენელთა შერჩევით, მათი გადაკვეთითა და ახალი ცალკეულების სიმრავლის მიღებით. ეს ახალი თაობა შეიცავს მახასიათებლების უფრო მაღალ ფარდობითობას, რომელიც გააჩნიათ წინა თაობის კარგ წევრებს.

ამგვარად, თაობიდან თაობაზე, კარგი მახასიათებლები ვრცელდება მთელ პოპულაციაზე. შედარებით შეთვისებულ ცალკეულთა გადაკვეთას მივყევართ იქამდე, რომ იკვლევა ძიების სივრცის მეტად პერსპექტიული

მონაკვეთები. საბოლოო ჯამში, პოპულაცია ემთხვევა ამოცანის ოპტიმალურ გადაწყვეტას. ძირითადი გენეტიკური ალგორითმის ბლოკ-სქემა მოცემულია (ნახ. 3.2).



ნახ. 3.2. გენეტიკური ალგორითმის ბლოკ-სქემა

### 3.3. გენეტიკური პროგრამირება

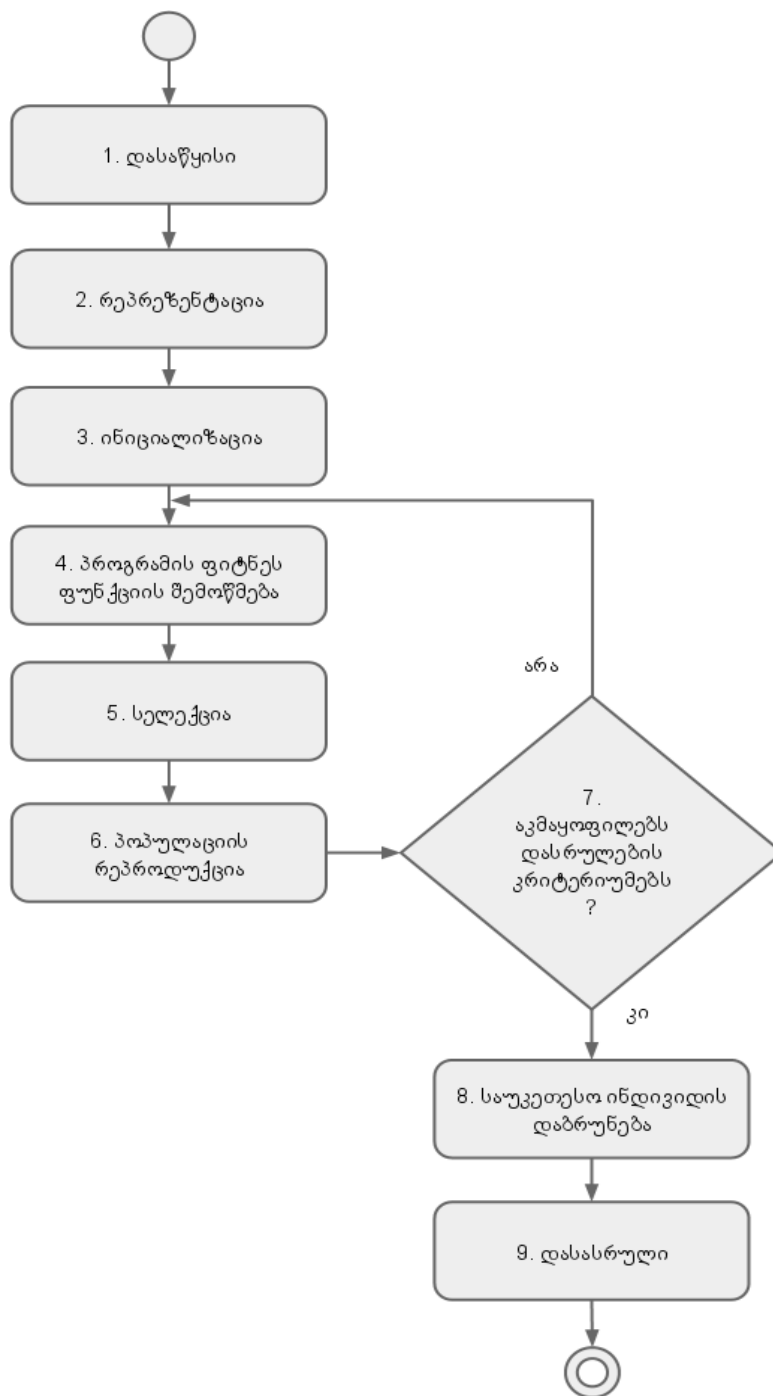
გენეტიკური პროგრამირება – **Genetic Programming (GP)** არის გენეტიკური ალგორითმის გაფართოებული ვარიანტი და ორიენტირებულია კომპიუტერული პროგრამების სივრცეში ოპტიმიზაციის ამოცანების ამოხსნისკენ. გენეტიკური პროგრამირების მიზანია ამოცანის გადასაწყვეტად უცნობი ალგორითმისთვის პროგრამის ავტომატური სინთეზი. მისი

დამფუძნებელია ჯ. კოზა (J. Koza 1992წ.). 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. გენეტიკური პროგრამირების ალგორითმის მოქმედების ბლოკ-სქემა მოცემულია (ნახ. 3.3) -ზე [36].

**1. რეპრეზენტაცია.** გენეტიკურ პროგრამირებაში გამოიყენება მონაცემთა წარმოდგენის ხისებრი სტრუქტურა. სადაც ცვლადები, კონსტანტები და არითმეტიკული ოპერაციები წარმოდგენილია ხის ფოთლების სახით. ცვლადებს და კონსტანტებს ტერმინალებს უწოდებენ, ხოლო არითმეტიკულ ოპერაციებს ფუნქციებს [37].

**2. ინიციალიზაცია.** სხვა ევოლუციური ალგორითმების მსგავსად გენეტიკურ პროგრამირებაშიც საწყისი პოპულაცია შემთხვევითად გენერირდება. არსებობს ინიციალიზაციის ორი მეთოდი „სრული“ (full) და „გაზრდის“ (grow). „სრული“ მეთოდის დროს ტერმინალები წარმოდგენილია ხის ერთ დონეზე რაც გარკვეულ შემთხვევაში შეზღუდვად კი შეიძლება ჩაითვალოს. „გაზრდის“ მეთოდის დროს კი ნებისმიერი დონის ხის ტოტის ასაგებად გამოიყენება როგორც ტერმინალი ასევე ფუნქცია, რაც მეტ თავისუფლებას იძლევა მონაცემების წარმოსადგენად [38].

**3. პროგრამის ფიტნეს ფუნქციის შემოწმება.** იმისათვის, რომ GP-მ განსაზღვროს თუ როგორ მუშაობს პროგრამა, ის უშვებს ამ პროგრამას და მიღებულ შედეგებს ადარებს ეტალონს. შემდეგ ეს შედარება ფასდება რიცხობრივი მნიშვნელობით რომელსაც „ფიტნეს“ მნიშვნელობა ჰქვია.




ნახ. 3.3. გენეტიკური პროგრამირების ალგორითმის ბლოკ-სქემა

**4. სელექცია.** „ფიტნეს“ მნიშვნელობაზე დაყრდნობით აირჩევა პროგრამების ჯგუფი რომლებიც რეპროდუქციისათვის გამოიყენება.


**5. პოპულაციის რეპროდუქცია.** გენეტიკური ოპერატორების „შეჯვარების“ და „მუტაციის“ გამოყენებით წინა ბიჯზე ალგორითმის მიერ არჩეული პოპულაციის ინდივიდებისაგან ყალიბდება ახალი თაობის

პოპულაცია. (ნახ.3.4)-ზე მოცემულია „შეჯვარების“ მაგალითი, ხოლო (ნახ.3.5)-ზე მოცემულია „მუტაციის“ სახესხვაობები [39].



მაქსიმალური სიღრმე

ნახ. 3.4. GP-ში შეჯვარება



მაქსიმალური სიღრმე

(a) სუბ-ხის შეცვლა

მაქსიმალური სიღრმე

(b) სუბ-ხის ჩანართები

მაქსიმალური სიღრმე

(c) სუბ-ხის მოცილება

ნახ. 3.5. GP-ში მუტაცია

**6. დასრულების პირობის შემოწმება.** მოწმდება ალგორითმის დასრულების წინასწარ განსაზღვრული პირობები (მისაღები ამონახსნი ნაპოვნია თუ არა, ახალი თაობის გენერაციის მაქსიმალურ რაოდენობას გადააჭარბა თუ არა და სხვა).

**7. დასასრული, საუკეთესო ინდივიდის დაბრუნება.** ამ ბიჯით ალგორითმი ასრულებს მუშაობას და აბრუნებს მის მიერ ნაპოვნ საუკეთესო ინდივიდს (პროგრამას), მაგრამ როგორც ზემოთ ავლნიშნეთ არ არსებობს გარანტია, რომ ალგორითმმა იპოვნა გლობალურად საუკეთესო ამონახსნი, არამედ უნდა ჩაითვალოს რომ ეს ამონახსნი არის ოპტიმალური (საუკეთესოსთან მიახლოებული).

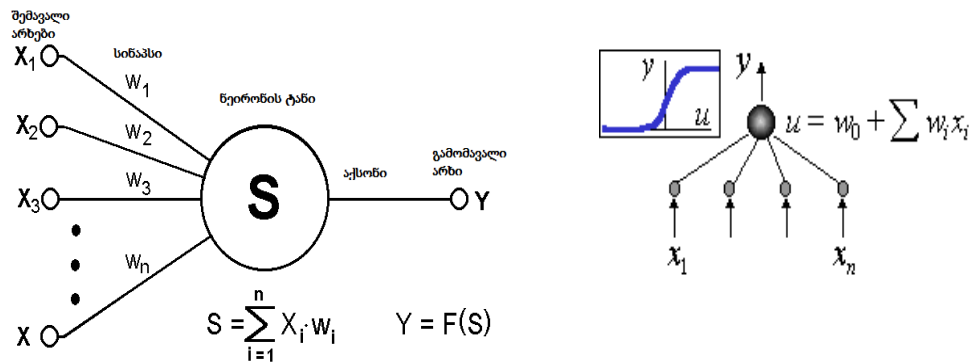
### 3.4. ხელოვნური ნეირონული ქსელები ფინანსური რისკების პროგნოზირებისათვის

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. ნეირონი იღებს იმპულსებს სხვა ნეირონების დენდრიტების მეშვეობით და გადასცემს სიგნალებს აქსონის მეშვეობით. დენდრიტების და აქსონების გადაბმის წერტილებში მდებარეობს სპეციალური წარმონაქმნი სინაპსი, რომელიც ზემოქმედებს იმპულსების სიდიდეზე. ხელოვნური ნეირონი, ისევე როგორ ბუნებრივი, შედგება სინაპსებისაგან, რომლებიც ნეირონის შესასვლელებს აკავშირებენ ბირთვთან, ნეირონის ბირთვი კი თავის მხრივ ახორციელებს შემომსვლელი სიგნალების დამუშავებას და გადაცემას სხვა ფენის ნეირონებთან [40, 41].

ხელოვნური ნეირონული ქსელი წარმოადგენს მოდელირების მძლავრ ინსტრუმენტს, რადგან მას შეუძლია შეისწავლოს და დაამუშავოს არაზუსტი და დაზიანებული მონაცემები. ANN-ს წარმატებით იყენებენ არაორდინალური პრობლემების გადასაწყვეტად ისეთ განსხვავებულ სფეროებში როგორებიცაა მედიცინა, ფინანსები, გეოლოგია, ინჟინერია, ფიზიკა და ბიოლოგია. სტატისტიკის კუთხით მას იყენებენ პროგნოზირებისა და კლასიფიკაციის ამოცანების მოდელირებისათვის. ANN-ის გამოყენებით შექმნეს ისეთი ალგორითმები როგორიცაა ტექსტის გამშიფრავი, ხმის ამომცნობი, სურათიდან გამოსახულების (ტექსტი, ადამიანის სახე, ან სხვა ობიექტი) გამშიფრავი და სხვა.

**ხელოვნური ნეირონის მათემატიკური მოდელი.** ავსოთ ნეირონის მათემატიკური მოდელი (შემდგომში მას ვუწოდებთ ნეირონს). ნეირონი არის მარტივი ავტომატი, რომელიც გარდაქმნის შემავალ სიგნალებს გამომავალ სიგნალებად (ნახ. 3.6).  $x_1, x_2, \dots, x_n$ , ძალის სიგნალები, სინაპსზე გასვლისას, გარდაიქმნებიან წრფივი სახით, ე.ი. ნეირონის სხეულთან

მიდის სიგნალები ძალებით,  $w_1 * x_1, w_2 * x_2, \dots, w_n * x_n$ , სადაც  $w_i$  - არის შესაბამისი სინაპსის წონა.




ნახ. 3.6. ნეირონის მათემატიკური მოდელი

მოსახერხებლობისთვის ნეირონს უმატებენ კიდევ ერთ შესასვლელ არხს, წონით  $w_0$ . ითვლება რომ ამ შესასვლელზე ყოველთვის მიეწოდება 1-ის ტოლი ძალის სიგნალი. ნეირონის ბირთვში ხდება სიგნალების გარდაქმნა შეჯამების გზით:

$$S = \sum_{i=0}^n w_i * x_i \quad (3.1)$$

შემდეგ, ამ ჯამს მიუყენდება რომელიმე  $f$  ფიქსირებული ფუნქცია და გამოსავალზე გამოდის  $Y=f(S)$  ძალის სიგნალი.


ნეირონული ქსელების არქიტექტურა მარტივი და ამასთანავე უნივერსალურია. კავშირების სპეციალიზაცია წარმოიქმნება მათი სწავლების ეტაპზე კონკრეტული მონაცემების ზეგავლენით (ნახ. 3.7).



ნახ. 3.7. კავშირთა გლობალურობა ხელოვნურ ნეირონულ ქსელებში

ტიპური ფორმალური ნეირონი აწარმოებს უმარტივეს ოპერაციას–ამრავლებს შემოსულ მონაცემებს თავის ლოკალურ წონებზე და ახორციელებს არაწრფივ გარდაქმნას მათ ჯამზე: აქტივაციის გამავალი ფუნქციის არაწრფივობა  $Y = f(S)$  პრინციპიალურია. არაწრფივობა არღვევს წრფივ სუპერპოზიციას და იწვევს იმას, რომ მთლიანი ქსელის შესაძლებლობები ბევრად აღემატება მისი შემადგენელი თითოეული ნეირონის შესაძლებლობებს.

**ხელოვნური ნეირონული ქსელების სწავლება:** თავდაპირველად, ცდომილების ფუნქცია, რომელიც აფასებს ქსელის მიმდინარე კონფიგურაციას, ხელოვნურ ნეირონულ ქსელს მიეწოდება გარედან იმის და მიხედვით, თუ რა მიზანს ემსახურება სწავლება. ამის შემდგომ, ქსელი თანდათან იწყებს თავისი კონფიგურაციის მოდიფიცირებას – ყველა თავისი სინაპსის წონების მდგომარეობის საფეხურებრივ მოდიფიკაციას ისეთი ფორმით, რომ მოხდეს ცდომილების ფუნქციის მნიშვნელობის მინიმიზირება. სწავლების პროცესში, ქსელი უფრო მეტად უმკლავდება მასზე დაკისრებულ ამოცანას. ეს პროცესი შესაძლოა წარმოვიდგინოთ, როგორც ცდომილების ფუნქციის  $E(w)$  მინიმუმის ძიების პროცესი, რომელიც დამოკიდებულია ქსელის ყველა სინაპსურ  $w$  წონებზე ( ნახ. 3.18).



ნახ. 3.8. ქსელის შესწავლა, როგორც ოპტიმიზაციის ამოცანა

დღესდღეობით ცნობილ სწავლების ალგორითმების უმეტესობას საფუძველად უდევს გრადიენტული ოპტიმიზაციის მეთოდი–სინაპსური წონების ინტერაციული ცვლილება, რომელიც თანდათანობით (ნაბიჯ–ნაბიჯ) ამცირებს ნეირონული ქსელის სწავლების საგნის დამუშავების



ცდომილებას. ამასთან, სინაპსის წონების შეცვლა ხდება შეცდომის ფუნქციის ლოკალური გრადიენტის გათვალისწინებით.


ამ გრადიენტის ძიების ეფექტურ მეთოდს წარმოადგენს ე.წ. ცდომილების უკუგავრცელების ალგორითმი (error back-propagation). განსხვავებები ქსელის სასურველ და ფაქტობრივ შედეგებს შორის, რომლებიც განისაზღვრება ნეირონების გამომავალ შრებზე, ქსელში ვრცელდება სიგნალების შემომავალი ნაკადების მიმართ. საბოლოოდ თითოეულ ნეირონს შეუძლია განსაზღვროს თავისი თითოეული წონის წილი ქსელის ჯამური შეცდომის ფუნქციის მნიშვნელობაში. იგი გამოითვლება აღნიშნული სხვაობისა და შესაბამისი შემომავალი სიგნალის მნიშვნელობის ნამრავლით. უმარტივესი სწავლების წესი მდგომარეობს გრადიენტულ ვარდნის (Gradient descent) მეთოდში. სინაპსური წონების ცვლილება პროპორციულია მისი წილის საერთო შეცდომის მნიშვნელობაში. ამდენად, ნეირონული ქსელების კავშირების ერთი და იგივე სტრუქტურა ეფექტურად გამოიყენება როგორც ქსელის ფუნქციონირებაში, ასევე სწავლებაში. ასეთი სტრუქტურა, შესაძლებლობას იძლევა გამოითვალოს მიზნობრივი ფუნქციის გრადიენტი თითქმის იმავე სისწრაფით როგორც თვით ეს ფუნქცია. ამასთანავე, გამოთვლები ორივე შემთხვევაში არის განაწილებული-თითოეული ნეირონი დამოუკიდებლად ახორციელებს გამოთვლებს, შემავალი ან გამომავალი არხიდან მიღებული სიგნალების მიხედვით.

მაშასადამე, სწავლების ალგორითმების უმეტესი ნაწილისთვის ძირითადი იდეა არის კონფიგურაციის არეში ლოკალური გრადიენტის გამოთვლა შეცდომის ფუნქციის უსწრაფესი ვარდნის ტრექტორიის არჩევითვის. მაგრამ, შეცდომის ფუნქციას შეიძლება ჰქონდეს მრავალი ლოკალური მინიმუმი, რომლებიც თავის მხრივ წარმოადგენენ სუბოპტიმალურ ამონახსნს. ასეთ შემთხვევაში, ქსელის კონფიგურაციის ცვლილების შეფერხების თავიდან ასაცილებლად, გრადიენტული მეთოდები მდიდრდება სტოქასტიკური ოპტიმიზაციის ელემენტებით. სწავლების იდეა-

ლურმა მეთოდმა სწრაფად უნდა იპოვოს ქსელის კონფიგურაციის გლობალური ოპტიმუმი.

### ხელოვნური ნეირონული ქსელის მოდელები

არსებობს ხელოვნური ნეირონული ქსელის მოდელის რამოდენიმე ტიპი, მაგრამ ორი მათგანი არის ყველაზე მეტად გამოყენებადი (ნახ.3.9).



ნახ. 3.9. ANN-ის მოდელის ტიპები

1. „პირდაპირი კავშირის“ (Feedforward) ქსელი (ნახ.3.9(a)) – ინფორმაციული ნაკადი არის ცალმხრივი და მიმართულია შემავალი დონიდან (input layer) გამომავალი დონისკენ (output layer). აქ არ არსებობს უკუკავშირები ან კავშირები თავის თავთან, ანუ ნებისმიერი დონიდან გამომავალი ინფორმაცია აღარ მოქმედებს იმავე ან მის წინა დონეზე და მიმართულია მომდევნო დონისაკენ.

2. „უკუკავშირის“ (Recurrent) ქსელი (ნახ.3.9(b)) – ამ ტიპის ქსელი პირდაპირი კავშირის ქსელისგან განსხვავდება იმით, რომ ამ შემთხვევაში არსებობს ერთი უკუკავშირი მაინც. ასეთ ქსელებში შეიძლება შეგვხვდეს კავშირი თავისთავთან, ანუ ნეირონიდან გამომავალი ინფორმაცია გადაეცემა ისევ ამ ნეირონს როგორც შემავალი ინფორმაცია.

**ფინანსური ბაზრების პროგნოზირების ამოცანის დასმა ხელოვნური ნეირონული ქსელების გამოყენებით.** პროგნოზირების ამოცანა ხელოვნური ნეირონული ქსელების გამოყენებით დაიყვანება მრავალგანზომილებიანი ფუნქციების აპროქსიმაციის ამოცანამდე, ე.ი. მრავალგანზომილებიანი გამოსახულების მიღებამდე. გამავალი ცვლადების ტიპების მიხედვით, ფუნქციების აპროქსიმაციამ შესაძლოა მიიღოს შემდეგი სახე: კლასი-

ფიკაციები ან რეგრესიები. ფინანსური ბაზრების პროგნოზირების ამოცანისას, შესაძლოა გამოვიყენოთ ორი მსხვილი ქვეამოცანა: მოდელის აგება, ნეირონული ქსელების შესწავლა, რომლებიც ახდენენ ამოცანის გადაწყვეტის რეალიზებას (ფაქტობრივად, გამოსახულების აპარატის აგება).

პროგნოზირების ამოცანის გადასაწყვეტად საჭიროა ვიპოვოთ: ისეთი ნეირონული ქსელი, რომელიც ყველაზე საუკეთესოდ ააგებდა გამოსახულებას  $F: x \Rightarrow y$ , რომელიც განაზოგადებს საფასო დინამიკის საფუძველზე ფორმირებული მაგალითების კრებულს  $\{x_i, y_i\}$ . ასეთი ნეირონული ქსელის ძიება ხორციელდება „შესწავლის“ ერთი ან ორი ალგორითმის მეშვეობით.

ნეირონული ქსელები მოდელირება ეფუძნება მხოლოდ საწყის მონაცემებს (დროით მწკრივებში). როგორც წესი, მოდელი იგება იმისათვის, რომ მოხდეს დროითი მწკრივის მნიშვნელობის წინასწარი განჭვრეტა ერთი სამიზნე ცვლადისათვის, თუმცა პრინციპში, მოდელს შეუძლია მნიშვნელობებისა და რამდენიმე ცვლადის (მაგ. აქციების შემოსავლები სხვადასხვა დროში წინასწარ) განჭვრეტა, თუ ქსელში დავამატებთ დამატებით გამავალ ელემენტებს. თუმცა ამასთან, კვლევები დროითი მწკრივების პროგნოზირების სფეროში, ქსელების საშუალებით, მოცემულ დროში გრძელდება და არანაირი სტანდარტული მეთოდები ჯერ გამომუშავებული არ არის. ნეირონულ ქსელში მრავალრიცხოვანი ფაქტორები ურთიერთქმედებენ საკმაოდ რთული სახით, და წარმატება მოაქვს მხოლოდ ევრისტიკულ მეთოდს.

**შემავალ მონაცემთა წარმოდგენა მიმდინარე საბაზრო სიტუაციის აღწერისათვის.** შემავალ გამოსახულებათა მიღების ქვეამოცანა, შემავალი სიმრავლის ფორმირებისათვის, დროითი მწკრივების პროგნოზირების ამოცანებში ხშირად გულისხმობს „ფანჯრების მეთოდის“ გამოყენებას. იგი მოიცავს ორი ფანჯრის  $W_i$  და  $W_o$  –ს ფიქსირებული  $n$  და  $m$  ზომების შესაბამისად გამოყენებას. აღნიშნულ ფანჯრებს რაღაც ბიჯით შეუძლიათ გადაადგილება ისტორიული მონაცემების დროითი მწკრივების მიხედვით,

პირველი ელემენტიდან დაწყებული და მათი დანიშნულებაა დროითი მწკრივის მონაცემებზე წვდომა, ამასთან პირველი ფანჯარა  $W_i$ , ასეთი მონაცემების მიღების შემდეგ, გადასცემს მათ ნეირონულ ქსელში შესასვლელად, ხოლო მეორე  $W_o$ –გასასვლელად.


ყოველ ნაბიჯზე მიღებული წყვილი  $W_i > W_o$  გამოიყენება როგორც შემსწავლელი ამონაკრების ელემენტი, (ამოსაცნობი გამოსახულება ან დაკვირვება). ყოველი შემდეგი ვექტორი გამოდის ფანჯრების  $W_i$  და  $W_o$ –ს ერთი ბიჯით მარჯვნივ გაწევის შემდეგ. ივარაუდება ფარული დამოკიდებულებების არსებობა დროით მწკრივებში, როგორც დაკვირვებათა სიმრავლეში. ნეირონული ქსელი, ამ დაკვირვებების შესწავლისას და შესაბამისად თავისი კოეფიციენტების აგებისას, ცდილობს ეს კანონზომიერებები ამოიღოს და მოახდინოს პროგნოზის საჭირო  $P$  ფუნქციის ფორმირება.

განვიხილოთ შემავალ გამოსახულებათა ფორმირების უმარტივესი საშუალება ხელოვნური ნეირონული ქსელების შესასწავლად. განხილვადი შემავალი ინფორმაციის სახეობის მუშაობისას მთავარ ცნებას წარმოადგენს „ფანჯარა“, („ჩაშვების სიღრმე“), ე.ი. დროის პერიოდების რაოდენობა, რომელიც ხვდება „გამოსახულებაში“ და ფორმირდება ქსელის შესასვლელთან. კურსების საათობრივ დინამიკასთან მუშაობისას, ფანჯარა  $n$  ზომით აღნიშნავს, რომ მკვლევარს აინტერესებს კურსის დინამიკა ბოლო  $n$  საათების განმავლობაში. იმისთვის, რომ ხელოვნურ ნეირონულ ქსელებმა იმუშაოს ასეთი ფანჯრის „გამოსახულებებთან“, ქსელის არქიტექტურის პროექტირებისას საჭიროა გამოიყოს შემავალი  $n$  ნეირონი.

შემავალ გამოსახულებათა ფორმირების მეთოდის მთავარი არსი მდგომარეობს შემდეგში: დავუშვათ, რომ ყოველი გამოსახულების მონაცემები განლაგებულია [Min..Max] დიაპაზონში, მაშინ ნორმირების ყველაზე მარტივი ხერხი იქნება

$$\tilde{x} = \frac{x - \text{Min}}{\text{Max} - \text{Min}} \quad (3.2)$$

ასეთი გარდაქმნის შემდეგ, ყოველი „გამოსახულება“, რომელიც შედგება  $n$  თანმიმდევრობითი ფასებისაგან, ნორმირდება ისე, რომ „გამოსახულების“ ყველა მნიშვნელობა განლაგებულია 0–დან 1–მდე ინტერვალით. ამასთან ნამდვილი მნიშვნელობები იკარგება და შემავალი ჩანაწერები განთავსდება ჰიპერკუბში  $[0,1]^n$  (ნახ.3.10).



ნახ. 3.10. სხვადასხვა შემავალ გამოსახულებათა ნორმირების შედეგები

ამგვარად, ფასის დინამიკის ნებისმიერ დონეზე, შემავალი ჩანაწერის გარდაქმნის ინვარიანტობა გარანტირებულია. ასეთი გადაკოდირება არ არის აზრს მოკლებული, რადგანაც ადამიანი–ტრეიდერი ჩვეულებრივ აფასებს დროითი მწკრივის მონაცემებს, მიღებული სტანდარტული საშუალებებით.

### 3.5 კოჰონენის თვითორგანიზებადი რუკა

კოჰონენის თვითორგანიზებადი რუკები - **Self-Organizing Maps (SOM)** არის ნეირონული ქსელების ერთ–ერთი სახეობა, თუმცა ისინი პრინციპიალურად განსხვავდებიან ზემოთ განხილულებისაგან, რადგანაც ის იყენებს ქსელის არაკონტროლირებადი სწავლების მეთოდს. ასეთი სწავლების მეთოდის დროს, შესასწავლი ობიექტების სიმრავლე შედგენილია მხოლოდ შემავალი ცვლადების მნიშვნელობებისაგან და სწავლების პროცესში ნეირონებიდან გამოავალი მნიშვნელობების შედარება არ ხდება ეტალონურ


მნიშვნელობებთან. შესაძლოა ითქვას, რომ ასეთი ქსელი სწავლობს მონაცემთა სტრუქტურის გაგებას [45].

თვითორგანიზებადი რუკების გამოყენება შესაძლებელია ისეთი ამოცანების გადასაწყვეტად, როგორცაა მოდელირება, პროგნოზირება, კანონზომიერებების და ურთიერთ დამოუკიდებელი ბლოკების აღმოჩენა მონაცემთა დიდ მასივში, ინფორმაციის შეკუმშვა და სხვა. აღნიშნულ ამოცანებში კოჰონენის რუკების დანიშნულებაა მონაცემთა ანალიზი, კლასიფიკაციის ამოცანის გადაწყვეტა მასწავლებლის გარეშე, ე.ი. კლასტერიზაციისა და ახალი ფენომენების აღმოჩენა.

**მონაცემთა ანალიზი და კლასიფიკაცია.** კოჰონენის ქსელს შეუძლია ამოიცნოს როგორც კლასტერები მონაცემებში, ასევე კლასების მსგავსება. ასე რომ, კოჰონენის ქსელს შეუძლია კლასიფიკაციის ამოცანის გადაჭრა, რა თქმა უნდა თუ მონაცემებში ამოცნობადია კლასები. ამ მეთოდის გამოყენება შეიძლება ისეთ კლასიფიკაციის ამოცანებშიც, სადაც კლასები წინასწარ მოცემულია. ამ დროს, უპირატესობა ის არის, რომ ქსელს შეუძლია დაადგინოს მსგავსება სხვადასხვა კლასებს შორის.

**ახალი ფენომენების აღმოჩენა.** როგორც ზემოთ ავლნიშნეთ, კოჰონენის ქსელს შეუძლია შესასწავლი მონაცემებიდან კლასტერების გამოყოფა (აღმოჩენა) და შესაბამისი მონაცემების განაწილება ამა თუ იმ კლასტერზე. ამ გადანაწილების შემდეგ, თუ ქსელი აღმოაჩენს კლასტერს, რომლის მონაცემები არ ჰგავს არც ერთს ცნობილი ნიმუშებიდან, მაშინ იგი ვერ მოახერხებს ამ მონაცემების კლასიფიცირებას, რაც თავის მხრივ წარმოადგენს ახალ ფენომენს.

**კოჰონენის ქსელის სწავლება.** კოჰონენის ქსელი, მრავალშრიანი ნეირონული ქსელისაგან განსხვავებით, ძალიან მარტივია. იგი შეიცავს მხოლოდ ორ შრეს: შემავალს და გამომავალს. რუკის ელემენტები განლაგებულნი არიან რომელიმე სივრცეში, როგორც წესი ორ განზომილებიანში (ნახ. 3.11).




**ნახ. 3.11. კოჰონენის ქსელი**

კოჰონენის ქსელი სწავლება ხდება მიმდევრობითი მიახლოების მეთოდით. ასეთი სწავლების პროცესში ქსელს შესასვლელზე მიეწოდება რაღაც მონაცემები, რის შემდეგაც ქსელი იწყებს გადაწყობას. გადაწყობა ხდება შემავალი მონაცემების კანონზომიერების მიხედვით და არა გამომავალი მონაცემების ეტალონის მიხედვით. სწავლების დროს, მონაცემების თანმიმდევრული გადაცემით ქსელის შესასვლელზე განისაზღვრება გამარჯვებული ნეირონი (ნეირონი, რომლის წონის სკალარული ნამრავლი შესასვლელზე მიწოდებულ ვექტორთან მინიმალურია), რომელიც შემდეგში გამოიყენება მეზობელ ნეირონებში წონების განაწილების ცენტრად. ქსელის ასეთი სწავლება განიხილება როგორც „შეჯიბრებითი“ სწავლება, ნეირონებსა და გამარჯვებულ ნეირონს შორის მანძილის მხედველობაში მიღებით. ამ დროს სწავლების არსი შეცდომის მინიმიზაცია კი არ არის, არამედ შესაბამისობაში ყოფნა შემავალ მონაცემებთან [45].

კოჰონენის ალგორითმის ინტერაციული მოდელი სრულდება რამოდენიმე ეტაპად. თითოეულ ამ ეტაპზე მუშავდება მხოლოდ ერთი მაგალითი სასწავლო ნიმუშებიდან. თითოეულ შემავალ სიგნალზე ქსელში სასურველი გამომავალი სიგნალი არ განისაზღვრება. ქსელში შემავალი სინაპსური წონების ვექტორების საკმარისი რაოდენობის გაჩენის შემდეგ მას შეუძლია განსაზღვროს კლასტერი. წონები ორგანიზებულია ისე, რომ ტოპოლოგიურად ახლო კვანძები მგრძობიარენი არიან მსგავს შემავალ სიგნალებთან.


ალგორითმის მუშაობის შედეგად, კლასტერის ცენტრი ექცევა იმ პოზიციაში რომელიც აკმაყოფილებს კლასტერიზაციის შესასწავლ მაგალითს, რომელისთვისაც მოცემული ნეირონი არის „გამარჯვებული“. ქსელის შესწავლის შედეგად საჭიროა განისაზღვროს ნეირონების მეზობლობის ზომა, ე.ი. გამარჯვებული–ნეირონის ირგვლივ მიდამო (რამდენიმე ნეირონი, რომლებიც გარს ეკვრიან გამარჯვებულ–ნეირონს). თვითორგანიზებადი რუკების მეთოდის უპირატესობა მდგომარეობს  $n$  განზომილებიანი სივრცის ორ განზომილებიანში გარდაქმნის შესაძლებლობაში. ორ განზომილებიანი ქსელის გამოყენება ნაკარნახებია იმით, რომ დიდ სირთულეებთან არის დაკავშირებული რთული სტრუქტურის წარმოდგენა მრავალგანზომილებიან ქსელში. მონაცემთა ასეთი სტრუქტურით წარმოდგენის დროს ადვილია განისაზღვროს დამოკიდებულების არსებობა/არარსებობა შემავალ მონაცემებს შორის. კოჰონენის ნეირონულ რუკებს განათავსებენ ორ განზომილებიანი მატრიცის სახით და აფერადებენ ამ მატრიცას ნეირონების მიერ გაანალიზებული პარამეტრების წონის (მნიშვნელობის) მიხედვით. კოჰონენის რუკის მაგალითი მოყვანილია (ნახ.3.12). ნეირონები რუკაზე გამოსახულია უჯრედების სახით და მიგნებადია კოორდინატებით.



ნახ. 3.12. კოჰონენის რუკის მაგალითი

(ნახ.3.13)-ზე მოყვანილია გაფერადების  $i$  ნიშანი სამგანზომილებიანი წარმოდგენით. როგორც ვხედავთ, მუქი ლურჯი მონაკვეთები რუკაზე შეესაბამება მაჩვენებლების უმცირეს მნიშვნელობებს, წითლები – უდიდესს.






ნახ. 3.13.  $i$  ნიშნის გაფერადება სამგანზომილებიან სივრცეში

ალგორითმის მუშაობის შედეგად ვლერულობთ შემდეგ რუკებს:

- ნეირონებზე შემავალი ინფორმაციის რუკა;
- ნეირონებიდან გამომავალი ინფორმაციის რუკა;
- სპეციალური რუკები.

ყოველი რუკის კოორდინატები განსაზღვრავენ ერთი ნეირონის მდებარეობას [46].

**ნეირონებზე შემავალი ინფორმაციის რუკა.** ნეირონების წონები რეგულირდება შემავალი მონაცემების მნიშვნელობებით და ასახვენ მათ შინაგან სტრუქტურას. ყოველი შემავალი სიგნალისთვის იხატება დამოუკიდებელი რუკა, რომელიც გაფერადებულია კონკრეტული ნეირონის წონის მნიშვნელობის მიხედვით. მონაცემთა ანალიზისთვის ერთდროულად გამოიყენება შემავლების რამდენიმე (როგორც წესი 3) ასეთი რუკა (ნახ. 3.14).




ნახ. 3.14. ნეირონებში შემავალი ინფორმაციის რუკა

ერთ–ერთ რუკაზე გამოყოფენ წინასწარ განსაზღვრული ფერის მონაკვეთს, ეს ნიშნავს, რომ შესაბამის შემავალ ნიშნებს აქვთ დაახლოებით

ერთნაირი მნიშვნელობები. ფერების გავრცელება ამ რეგიონში დარდება სხვა რუკებს მსგავსი თუ განსხვავებული თვისებების დასადგენად.

**ნეირონებიდან გამომავალი ინფორმაციის რუკა.** ნეირონების გამომავალი ინფორმაციის რუკაზე პროექტირდება შესწავლილი შემავალი მონაცემების ურთიერთგანლაგება. ნეირონები გამომავალი ინფორმაციის ერთნაირი მნიშვნელობებით ქმნიან კლასტერს – ჩაკეტილ რეგიონს რუკაზე (ნახ. 3.15).



ნახ. 3.15. კლასტერი

**სპეციალური რუკები.** ეს არის კლასტერების რუკა, დაშორებების მატრიცა, დაცემის სიმკვრივის მატრიცა და სხვა რუკები, რომლებიც აღწერენ (ახასიათებენ) კოჰონენის ქსელის სწავლების შედეგად მიღებულ კლასტერებს.

მნიშვნელოვანია, რომ ზემოთ აღწერილ ყველა რუკას შორის არსებობს ურთიერთკავშირი, რადგან ყველა ეს რუკა არის სხვადასხვა შეფერილობა ერთი და იგივე ნეირონის. თითოეულ მაგალითს შესწავლის სიმრავლიდან გააჩნია ერთი და იგივე განლაგება ზემოთ აღწერილ თითოეულ რუკაზე [42].

**თვითშემსწავლელი რუკების ფუნქციონირების ალგორითმი** - წარმოადგენს მრავალგანზომილებიანი ვექტორების კლასტერიზაციის ერთ-ერთ ვარიანტს. ასეთი ალგორითმების მაგალითად შესაძლოა გამოდგეს k-უახლოესი საშუალოების ალგორითმი (c-means). თვითორგანიზებადი რუკის ალგორითმის მთავარი განსხვავება არის ის, 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.

$$\omega = [\omega_1, \omega_2 \dots \omega_n]^T, \quad (3.3)$$


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

ალგორითმის რეალიზაციისას წინასწარ იძლევა ბადის კონფიგურაცია (მართკუთხედი ან ექვსკუთხედი), აგრეთვე ნეირონების რაოდენობა ქსელში. ზოგიერთი წყარო გვიჩვენებს რუკაზე გამოვიყენოთ ნეირონების მაქსიმალური რაოდენობა. იმ შემთხვევაში, როდესაც რუკის ზომა შეადგენს ათეულობით ათას ნეირონს, რუკის შესასწავლად საჭირო დრო არის საკმაოდ დიდი პრაქტიკული ამოცანების გადასწყვეტად. ამგვარად, საჭიროა მივადწიოთ დასაშვებ კომპრომისს, კვანძების რაოდენობის შერჩევას. რუკის შესწავლის დაწყებამდე, საჭიროა ნეირონების წონითი კოეფიციენტების ინიციალიზირება [46].

**თვითორგანიზებადი რუკების სწავლება.** სწავლება შედგება ვექტორების კორექციის თანმიმდევრობისაგან, რომლებიც წარმოადგენენ ნეირონებს. სწავლების ყოველ ბიჯზე საწყისი მონაცემთა კრებულიდან შემთხვევით ირჩევა ერთ–ერთი ვექტორი, ხოლო შემდეგ წარმოებს ყველაზე მეტად მისი მსგავსი ნეირონის კოეფიციენტების ვექტორის ძებნა. ამასთან ირჩევა გამარჯვებული–ნეირონი, რომელიც უფრო მეტად ჰგავს შემავლების ვექტორს. მსგავსებაში, მოცემულ შემთხვევაში იგულისხმება ვექტორებს შორის მანძილი, რომელიც ძირითადად გამოითვლება ევკლიდეს სივრცეში. ამგვარად, თუ აღვნიშნავთ გამარჯვებულ ნეირონს როგორც  $c$ , მივიღებთ:

$$\|\chi - \omega_c\| = \min_i \|\chi - \omega_i\| \quad (3.4)$$

მას შემდეგ რაც ნაპოვნია გამარჯვებული- ნეირონი, ხორცილედება ნეიროქსელის წონების კორექტირება. ამასთან ვექტორი, რომელიც აღწერს გამარჯვებულ-ნეირონს და ვექტორი, რომელიც აღწერს მის მეზობლებს ბადეში, გადაადგილდებიან შემავალი ვექტორის მიმართულებით. ეს ილუსტრირებულია (ნახ. 3.16) ორგანზომილებიანი ვექტორისათვის[47].



ნახ. 3.16. გამარჯვებული ნეირონის და მისი მეზობლების წონების ქვეწყოზა

შემავალი ვექტორის კოორდინატები აღნიშნულია ჯვარედინით, რუკის კვანძების კოორდინატები მოდიფიკაციის შემდეგ ასახულია ნაცრისფერი ფერით. ბადის ხედი მოდიფიკაციის შემდგომ გამოსახულია შტრიხული ხაზებით. ამასთან წონითი კოეფიციენტების მოდიფიკაციისათვის გამოიყენება ფორმულა:


$$\omega_i(t + 1) = \omega_i(t) + h_{ci}(t) * [\chi(t) - \omega(t)] \quad (3.5)$$

სადაც  $t$  აღნიშნავს ეპოქის ნომერს (დისკრეტული დრო). ამასთან  $x(t)$  ვექტორი ირჩევა შემსწავლელი შერჩევიდან შემთხვევით  $t$ -ს იტერაციაზე.  $h(t)$  ფუნქცია არის ნეირონების მეზობლობის ფუნქცია, რომელიც წარმოადგენს დროისა და მანძილის არამზარდ ფუნქციას გამარჯვებულ-ნეირონსა და მეზობელ ნეირონებს შორის ბადეში.

რადგანაც თვითორგანიზებადი რუკის ალგორითმი მასში აერთიანებს ორ ძირითად მიმართულებას- ვექტორული კვანტირება და პროექტირება, ამიტომ მოცემული მეთოდის გამოყენება შესაძლებელია საწყისი და საბოლოო მონაცემთა კანონზომიერებების ძებნისა და ანალიზისათვის.

ამასთან, მიღებული რუკა შესაძლებელია იყოს გამოსახული, მას შემდეგ, რაც ნეირონები განლაგდება რუკაზე.

კოჰონენის მეთოდი ნეირობიოლოგიურ თავისებურებებზე არ კონცენტრირდება და უფრო ზოგადია იმ გაგებით, რომ ახორციელებს მრავალგანზომილებიანი შემავალი სივრცის გამოსახვას ორ განზომილებიან (იშვიათად ერთ განზომილებიან) გამავალ სივრცედ, ე.ი. ახდენს მონაცემთა შეკუმშვას.



ნახ. 3.17. თვითორგანიზებადი რუკების მუშაობის მოდელი

თვითორგანიზებადი რუკების მოდელი (ნახ.3.17) მიეკუთვნება ნეირონული ქსელების კლასს, მასწავლებლის გარეშე შესწავლით. თვითორგანიზებადი რუკების შესწავლის კლასიკური ალგორითმი გამოიყურება შემდეგი სახით [47]:

1. **ინიციალიზაცია.** თავდაპირველად შემთხვევითი მნიშვნელობებით ინიციალიზდება სინაპტიკური წონების საწყისი ვექტორები,

$$w_i = \{w_{i1}, w_{i2}, \dots, w_{is}\},$$

სადაც  $s$ -შემავალი ვექტორის განზომილება.

2. **ქვეშერჩევა.** შემავალი სივრციდან ვექტორის  $x = \{x_1, x_2, \dots, x_s\}$  შერჩევა გარკვეული ალბათობით. ვექტორი წარმოადგენს აგზნებას, რომელიც გამოიყენება ნეირონების ბადის შემთხვევაში.

**3. მაქსიმალური მსგავსების ძიება.** წარმოებს მეტად შესაფერისი (გამარჯვებული) ნეირონის  $c(x)$ , ძიება, ევკლიდეს მანძილის მინიმუმის კრიტერიუმის გამოყენებით:

$$c(x) = \arg \min_j \|x - w_j\| \quad (3.6)$$

**4. კორექცია.** ნეირონების წონების კორექტირება, რომელიც შედის  $h(d,t)$  გამარჯვებული-ვექტორის მიდამოში, წარმოებს შემდეგი ფორმულის მიხედვით ( $i$  ნეირონის  $j$  წონისათვის)

$$w_j(t+1) = w_j(t) + a_i(t)h(d,t)(x_j - w_{ij}(t)) \quad (3.7)$$

სადაც  $a(t)$  - შესწავლის სისწრაფის კოეფიციენტი, რომელიც დამოკიდებულია დროზე. იგი ღებულობს გადაწყვეტილებებს 0-დან 1-მდე მონაკვეთში.  $a$ -ს მნიშვნელობა უნდა შემცირდეს თანდათან, თუმცა არ არსებობს განსაზღვრული კანონი, რომლის მიხედვითაც უნდა მოხდეს კლება. ჩვენს შემთხვევაში, სწავლების სიჩქარის კოეფიციენტი გამოითვლება როგორც:

$$a_i = a_U \exp^{-\frac{i}{\mu}} \quad (3.8)$$

სადაც:  $i$  - იტერაციის ნომერი;

$t$  - შემსწავლელი ალგორითმის იტერაციის საერთო რაოდენობა.

მიდამოს ფუნქციის შემთხვევაში, გამოიყენება გაუსის მიდამოს ფუნქცია,

$$h(d,t) = \begin{cases} 0, & \text{თუ } d \geq \sigma(t) \\ e^{-\frac{d}{2\sigma(t)}}, & \text{თუ } d < \sigma(t) \end{cases} \quad (3.9)$$

$$\sigma(t) = \sigma_U \wedge e^{-\frac{i}{\mu}} \quad (3.10)$$

სადაც:  $d$ -მანძილი კოორდინატულ ბადეზე მიმდინარე ნეირონსა და გამარჯვებულ-ნეირონს შორის;

$\sigma_U$  - კონსტანტა,


$$\mu = \frac{n}{\log_{10}(\sigma_U)} \quad (3.11)$$

სადაც  $n$  - იტერაციების მაქსიმალური რაოდენობა.

**5. გაგრძელება.** ამ ეტაპზე ხდება ბიჯი 2-თან დაბრუნება, გამოთვლები გრძელდება მანამ, სანამ ნიშნების რუკაზე არ შეწყდება შესამჩნევი ცვლილები.

ხელოვნური ნეირონული ქსელის შესწავლა შესაძლოა იყოს საკმაოდ ხარჯიანი დროის მხრივ. დროის დანახარჯის შემცირების ერთ-ერთ ასეთ მეთოდს წარმოადგენს პარალელური გადამუშავების გამოყენება, რომლის დროსაც რამდენიმე დასამუშავებელი ელემენტი ერთდროულად მონაწილეობს წარმოებულ გამოთვლებში.

**კოჰონენის შრის შესწავლა: წონითი კოეფიციენტების მომართვა.** კოჰონენის ნეირონული ქსელის სწავლების არსი მდგომარეობს წონების ისეთ ქვეწყობაში, რომლის დროსაც ახლო შემავალი ვექტორები გაააქტიურებენ კოჰონენის ერთსა და იმავე ნეირონს. კოჰონენის შრის შესწავლა წარმოადგენს თვითშესწავლას, რომელიც მიმდინარეობს მასწავლებლის გარეშე. რთულია წინასწარ ვთქვათ, კოჰონენის კონკრეტულად რომელი ნეირონი გააქტიურდება მოცემული შემავალი ვექტორით. განსწავლის პროცესისასგან საჭიროა, რომ შესწავლის შედეგად გამოირჩეოდეს განსხვავებული შემავალი ვექტორები.



**ნახ. 3.18. კოჰონენის გამარჯვებული ნეირონის ვექტორული ასახვა**

კოჰონენის შრის შესწავლისას, შესავალს მიეწოდება შემავალი ვექტორი და გამოითვლება სკალარული წარმოებულები წონების ვექტორებთან ერთად, რომლებიც დაკავშირებულია კოჰონენის ყველა ნეირონთან. სკალარული წარმოების მაქსიმალური მნიშვნელობის ნეირონი ცხადდება

„გამარჯვებულად“ და მისი წონები კორექტირდება (ნახ.3.18)-ზე ეს პროცესი გეომეტრიულად ნაჩვენებია ორგანოზომილებიანი სახით ( $\vec{W}_C$  - ძველი წონითი კოეფიციენტების ვექტორი,  $\vec{W}_H$  - ახალი წონითი კოეფიციენტების ვექტორი). ჯერ იძებნება  $\vec{X} - \vec{W}_C$  ვექტორი, ამისათვის ხდება  $\vec{W}_C$  - ბოლოდან,  $\vec{X}$  - ბოლოში ჩამოჭრა. შემდგომ ეს ვექტორი მოკლდება მისი გამრავლებით სკალარულ  $\beta$  სიდიდეზე, მცირე ერთეულს, რომლის შედეგადაც მიიღება ცვლილების ვექტორი  $\vec{N} = (\vec{X} - \vec{W}_C)$ . საბოლოოდ ახალი წონითი ვექტორი  $\vec{W}_H$  წარმოადგენს მონაკვეთს, რომელიც მიმართულია კოორდინატთა საწყისიდან,  $\vec{N}$  ვექტორის ბოლომდე. აქედან შესაძლებელია იმის დანახვა, რომ შესწავლის ეფექტი მდგომარეობს წონითი ვექტორის ბრუნვაში შემავალი ვექტორის მიმართულებით, მისი სიგრძის არსებითი შეცვლის გარეშე.

ცვლადი  $\beta$  -წარმოადგენს შესწავლის სიჩქარის კოეფიციენტს, რომელიც თავიდან ჩვეულებრივ ტოლია 0,7 და თანდათან მცირდება შესწავლის პროცესში. ეს საშუაებას იძლევა გაკეთდეს დიდი საწყისი ბიჯები, სწრაფი ზედაპირული შესწავლისათვის და მცირე ბიჯები საბოლოო სიდიდესთან მისვლისას.

კოჰონენის ყოველ ნეირონთან რომ ასოცირდებოდეს ერთი შემავალი ვექტორი, მაშინ კოჰონენის შრე შესწავლილი იქნებოდა წონის ერთჯერადი გამოთვლით. გამარჯვებული-ნეირონის წონები გაუტოლდებოდა შემსწავლელი ვექტორების კომპონენტებს. როგორც წესი, შემსწავლელი სიმრავლე მოიცავს ბევრ მსგავს შემავალ ვექტორს და ქსელს უნდა შეეძლოს კოჰონენის ერთი და იგივე ნეირონის აქტივირება, თითოეული მათგანი-სათვის. ასეთ შემთხვევაში, ამ ნეირონის წონები უნდა მიიღებოდეს შემავალი ვექტორების გასაშუალოებით, რომლებმაც უნდა მოახდინონ მისი აქტივირება.  $\beta$  სიდიდის თანდათან კლება, ამცირებს ყოველი შემსწავლელი ბიჯის გავლენას, ასე რომ საბოლოო მნიშვნელობა იქნება შემავალი ვექტორების საშუალო სიდიდე, რომელზეც ხდება შესწავლა. ამგვარად,



წონები, რომლებიც ასოცირდება ნეირონთან (რომლებიც წარმოქმნიან კლასის ე.წ. „ბირთვს“), მიიღებენ შემავალი ვექტორების „ცენტრის“ ახლო მნიშვნელობას, რომლისთვისაც მოცემული ნეირონი არის „გამარჯვებული“.

მაშასადამე, კოჰონენის შრის სწავლების კლასიკური ალგორითმი გამოიყურება შემდეგი სახით:

- ზოგიერთ წონით კოეფიციენტზე საწყისი მნიშვნელობების მინიჭება. ნეირონულ ქსელებთან მუშაობისას საყოველთაოდ მიღებულ პრაქტიკად ითვლება, წონებზე მცირე შემთხვევითი მნიშვნელობების მინიჭება.

- ნეირონული ქსელის შესავალს მიეწოდოს  $\vec{x}_i$  ვექტორი შემსწავლელი  $X$  სიმრავლიდან.

- კოჰონენის შრის გასავლის გათვლა და  $k$  „გამარჯვებული“ ნეირონის განსაზღვრა, ე.ი. მაქსიმალური გასავლის ნეირონი.

- მოხდეს „გამარჯვებული“ ნეირონის წონების კორექტირება შემდეგი ფორმულით:

$$\vec{W}_k = \vec{W}_k + \beta(\vec{x}_i - \vec{W}_k) \quad (3.12)$$

სადაც:  $\beta$  - შესწავლის სიჩქარის კოეფიციენტი.

წონების კორექცია ჩაწერილია ვექტორული გამოსახვის სახით. ხშირად იყენებენ ცხრილს შესწავლით, როდესაც  $\beta = \beta(t)$  მონოტონურად მცირდება. მოთხოვნები  $\beta(t)$  მიმართ იგივეა, რაც მრავალშრიანი პერცეპტრონის შემთხვევაში.

წონები კორექტირდება ისე, რომ წონების ვექტორი უახლოვდება მიმდინარე შემავალ ვექტორს. შესწავლის სიჩქარის კოეფიციენტი მართავს კლასის (წონების ვექტორის) ბირთვის სწრაფ მიახლოებას შემავალ ვექტორთან. ალგორითმი სრულდება მანამ, სანამ წონები არ შეწყვეტენ ცვლილებას.

### 3.6 კოჰონენის რუკაზე გამარჯვებული ნეირონის გამოვლინების ალგორითმების მოკლე მიმოხილვა 3.6.1. ამოწვის იმიტაციის ალგორითმი

ამოწვის იმიტაციის ალგორითმი – **Simulated annealing (SA)** არის ზოგადი ალგორითმული მეთოდი, გლობალური ოპტიმიზაციის და განსაკუთრებით დისკრეტული და კომბინატორული ოპტიმიზაციის ამოცანების ამოსახსნელად. მისი ერთ-ერთი მაგალითია მონტე – კარლოს მეთოდი.

ალგორითმი დაფუძნებულია ფიზიკური პროცესის იმიტაციაზე, რომელსაც ადგილი აქვს ნივთიერების კრისტალიზაციისას ანუ მისი თხევადი მდგომარეობიდან მყარ მდგომარეობაში გადასვლის დროს, ასევე მეტალების გამოწვის დროს. გამოწვის დროს ატომები განლაგდებიან კრისტალურ მესერში, თუმცა ჯერ კიდევ დასაშვებია ცალკეული ატომების გადასვლა ერთი უჯრედიდან მეორეში. მიღებულია რომ ეს პროცესი მიმდინარეობს მუდმივად კლებადი ტემპერატურის ვითარებაში. ატომის გადასვლა ერთი უჯრედიდან მეორეში ხდება რაღაც ალბათობით და ეს ალბათობაც მცირდება ტემპერატურის შემცირებასთან ერთად. მყარი კრისტალური მესერი შეესაბამება ატომის მინიმალურ ენერგიას, ამდენად ატომი ან გადადის უფრო დაბალი დონის ენერგიის მდგომარეობაში ან რჩება ადგილზე.

ასეთი პროცესისის მოდელირების დასახმარებლად იძებნება ისეთი წერტილი ან წერტილთა სიმრავლე, რომელზეც მიიღწევა მინიმუმი შემდეგი რიცხვითი ფუნქციის  $F(\bar{x})$  სადაც  $\bar{x} = (x_1, \dots, x_m) \in X$ . შემოგვყავს წერტილების მიმდევრობა  $\bar{x}_0, \bar{x}_1, \dots, \bar{x}_n$  სივრცეში  $X$ . ალგორითმი პოულობს მომდევნო წერტილს დაწყებულს  $\bar{x}_0$ , რომელიც არის მიახლოების დასაწყისი. ალგორითმი ჩერდება  $\bar{x}_n$  წერტილის მიახლოებისთანავე.

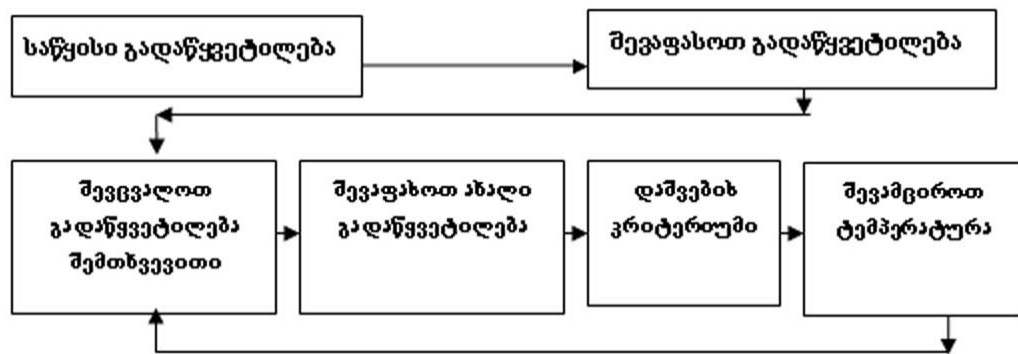
წერტილი  $\bar{x}_{i+1}$  ალგორითმის მიხედვით მიიღება წერტილის  $\bar{x}_i$  -ის საფუძველზე შემდეგი გზით. წერტილისთვის  $\bar{x}_i$  გამოიყენება ოპერატორი  $A$ , რომელიც შემთხვევითი არჩევით შეარჩევს შესაბამის წერტილს, რის შედეგადაც მიიღება ახალი წერტილი  $\bar{x}^*$ . წერტილი  $\bar{x}^*$  გადაიქცევა

წერტილად  $\bar{x}_{i+1}$  ალბათობით  $P(\bar{x}^*, \bar{x}_{i+1})$  რომელიც გამოითვლება გიბსის განაწილების შესაბამისად

$$P(\bar{x}^* \rightarrow \bar{x}_{i+1} | \bar{x}_i) = \begin{cases} 1, & F(\bar{x}^*) - F(\bar{x}_i) < 0 \\ \exp\left(-\frac{F(\bar{x}^*) - F(\bar{x}_i)}{Q_i}\right), & F(\bar{x}^*) - F(\bar{x}_i) \geq 0 \end{cases} \quad (3.13)$$

სადაც  $Q_i > 0$  არის კლებადი წარმოებულის ელემენტი, რომელიც მიისწრაფვის ნულისაკენ. კლებადობის სიჩქარე და კლებდობის წესს არეგულირებს სურვილის მიხედვით ალგორითმის შემქმნელი.

ამოწვის იმიტაციის ალგორითმი [44] მსგავსია გრადიენტული დადაბლების მეთოდის. თუმცა შუალედური წერტილის შემთხვევითი არჩევის ხარჯზე მისი მოხვედრა ლოკალურ მინიმუმში ხდება უფრო იშვიათად, ვიდრე გრადიენტულ დადაბლების მეთოდში. ამოწვის იმიტაციის ალგორითმი არ იძლევა ფუნქციის მინიმუმის მოძებნის გარანტიას, მაგრამ  $X$  სივრცეში შემთხვევითი წერტილის გენერაციის სწორი პოლიტიკის არჩევის შედეგად, როგორც წესი, ხდება საწყისი მიახლოების გაუმჯობესება. ამოწვის იმიტაციის ალგორითმის ბლოკ-სქემას აქვს შემდეგი სახე (ნახ. 3.19):



ნახ. 3.19. ამოწვის იმიტაციის ალგორითმი

### 3.6.2. იმპერიალისტური შეჯიბრებითი ალგორითმი

იმპერიალისტური შეჯიბრებითი ალგორითმი – Imperialist Competitive Algorithm (ICA) ეფუძნება იმპერიალისტურ მეტოქეობას, სადაც ძლიერი სახელმწიფოები ქმნიან კოლონიებს სხვადასხვა ტერიტორიებზე და ამასთან ებრძვიან სხვა ძლიერ სახელმწიფოებს ძალაუფლებისთვის. ასეთი

მეტოქეობის დროს ისინი უფრო ძლიერდებიან და ან კარგავენ ძალა-უფლებას. აღნიშნულ მეთოდს 2007 წელს საფუძველი ჩაუყარა ორმა ირანელმა მეცნიერმა Esmaeil და Caro-მ. იგი არის ახალი სოციო-პოლიტიკურად მოტივირებული გლობალური ძიების სტრატეგია, რომელიც თავიდანვე ერთ-ერთი ძლიერ ევოლუციურ ალგორითმად იქნა აღიარებული. იგი გამოიყენება სხვადასხვა ოპტიმიზაციის ამოცანების გადასაწყვეტად როგორც ცალკე ასევე სხვა ევოლუციურ ალგორითმებთან კომპოზიციად. 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 ძიებისთვის (Semantic Web Searching) და ა.შ.

განვიხილოთ ტერმინოლოგია, რომელიც პირობითად ასახავს ალგორითმის არსს:

- ქვეყანა – სახელმწიფო, რომელიც მონაწილეობს იმპერიალისტურ პაექრობაში როგორც კოლონია ან როგორც იმპერია.
- იმპერია – სახელმწიფო, რომელიც ებრძვის სხვა სახელმწიფოებს კოლონიების მართვის უფლების მოსაპოვებლად.
- კოლონია – სახელმწიფო, რომელიც მოხვედრილია იმპერიის მართველობის ქვეშ.
- ქვეყნის ძალა (სიძლიერე) – ქვეყნის ხელსაყრელი მდგომარეობა სხვა ქვეყნებთან შედარებით. მათემატიკური თვალსაზრისით ეს ნიშნავს ფუნქციის ოპტიმალური მნიშვნელობასთან სიახლოვეს [48].

**მეთოდის აღწერა:** თავდაპირველად ხდება ქვეყნების  $N_{pop}$  – ზომის პოპულაციის გენერირება. შემდეგ ამ პოპულაციიდან ირჩევა  $N_{imp}$  – რაოდენობის ყველაზე ძლიერი ქვეყნები იმპერიების შესაქმნელად. დარჩენილი  $N_{col}$  ქვეყნები კი გახდებიან იმპერიის კოლონიები. კოლონიების იმპერიებზე გადანაწილება ხდება იმპერიების სიძლიერის (ძალის) პროპორციულად. იმპერიის სიძლიერის გამოსათვლელად უნდა შემოვიტანოთ იმპერიის ნორმალიზებული წონა

$$C_n = c_n - \max_i \{c_i\} \quad (3.14)$$


სადაც:  $C_n$  არის  $n$ -ური იმპერიის წონა. მას შემდეგ რაც ცნობილია იმპერიის ნორმალიზებული წონა შეგვიძლია გამოვთვალოთ მისი ნორმალიზებული ძალა:

$$P_n = \frac{C_n}{\sum_{i=1}^{N_{imp}} C_i} \quad (3.15)$$

საწყის ეტაპზე იმპერიის ძალა განსაზღვრავს მისი კოლონიების პორციას მთელი პოპულაციიდან. შესაბამისად, იმპერიის კოლონიების რაოდენობა ინიციალიზაციის დროს იქნება:

$$N \cdot C_n = \text{round}\{p_n \cdot N_{col}\} \quad (3.16)$$

(ნახ.3.20)-ზე მოცემულია იმპერიების და კოლონიების გადანაწილების მაგალითი. სურათზე ჩანს, რომ რაც უფრო ძლიერია იმპერია მით მეტი კოლონია ერგო ინიციალიზაციის შემდეგ.




ნახ. 3.20. იმპერიების და კოლონიების გადანაწილების მაგალითი

კოლონიების გადანაწილების შემდეგ, რადგან მათაც გააჩნიათ გარკვეული ძალა, ამიტომ შეიცვლება იმპერიების სიძლიერე. შედეგად იმპერიის მთლიანი ძალა იქნება იმპერიის ძალას დამატებული თავისი კოლონიების პროცენტული ძალა:

$$\text{power}_n = \text{cost}(\text{imperialists}_n) + \varepsilon \text{mean}\{\text{cost}(\text{colonies of empires}_n)\} \quad (3.17)$$

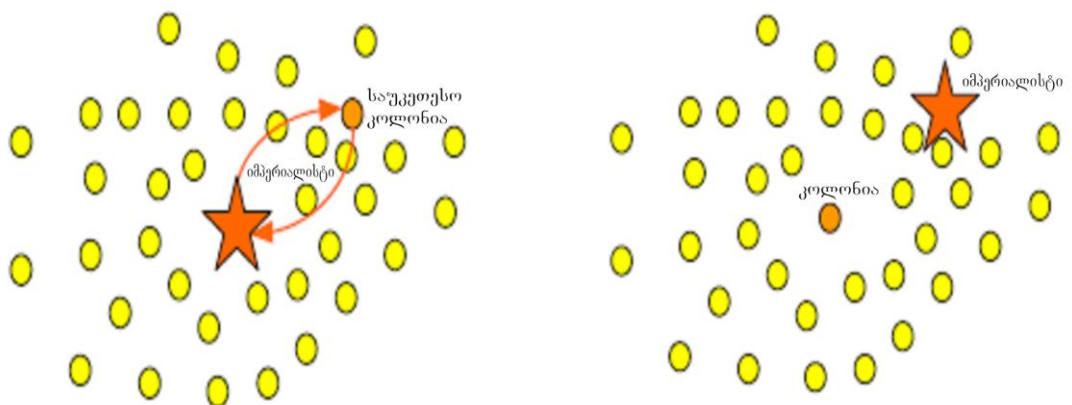
მოდელის ინიციალიზაციის შემდეგ იწყება ალგორითმის შემდეგი ეტაპი. იმპერიები იწყებენ ბრძოლას ერთმანეთში რათა დაიპყრონ მეტი კოლონიები. ეს ფაქტი მოდელირებულია კოლონიების მოძრაობაში თავიანთი იმპერიალისტის მიმართ. (ნახ.3.21)-ზე ნაჩვენებია კოლონიის გადაადგილება  $x$  – ერთეულით. გადაადგილება არის ვექტორი რომელიც მიმართულია იმპერიალისტისკენ.



ნახ. 3.21. კოლონიის გადაადგილება  $x$  – ერთეულით


$x$  არის შემთხვევითი რიცხვი რომელიც მნიშვნელობას:  $x \sim U(0, \beta \times d)$ , სადაც  $d$  არის მანძილი კოლონიასა და იმპერიალისტს შორის,  $\beta$  კი არის რიცხვი ყოველთვის მეტი ერთზე –  $\beta > 1$ .

კოლონიის იმპერიალისტისკენ მოძრაობის დროს შეიძლება კოლონია მოხვდეს ისეთ პოზიციაში როცა მისი წონა აღემატება იმპერიალისტის წონას. ასეთ შემთხვევაში კოლონია და იმპერიალისტი ცვლიან როლებს და კოლონია ხდება იმპერიალისტი და პირიქით (ნახ.3.22).



ნახ. 3.22. კოლონიისა და იმპერიალისტის როლების გაცვლა

როგორც ზემოთ ავლინებთ ალგორითმი დაფუძნებულია იმპერიების პაექრობაზე. იმპერიები ცდილობენ დაეუფლონ სხვა იმპერიების კოლონიებს. ამ პაექრობის შედეგად სუსტი იმპერიები კიდევ უფრო სუსტდება, ხოლო ძლიერები კიდევ უფრო ძლიერდება. პაექრობა მოდელირებულია შემდეგნაირად: ირჩევა ყველაზე სუსტი იმპერიის ყველაზე სუსტი კოლონია და იწყება ბრძოლა ამ კოლონიის დასაპყრობად. ალგორითმის მიხედვით არ არის აუცილებელი რომ ყველაზე ძლიერმა იმპერიამ დაიპყროს აღნიშნული კოლონია, მაგრამ რა თქმა უნდა ამისი შანსი დიდია. (ნახ. 3.23)-ზე მოცემულია იმპერიების პაექრობა კოლონიის დაპყრობის მიზნით.



ნახ. 3.23. იმპერიების პაექრობა კოლონიის დაპყრობის მიზნით

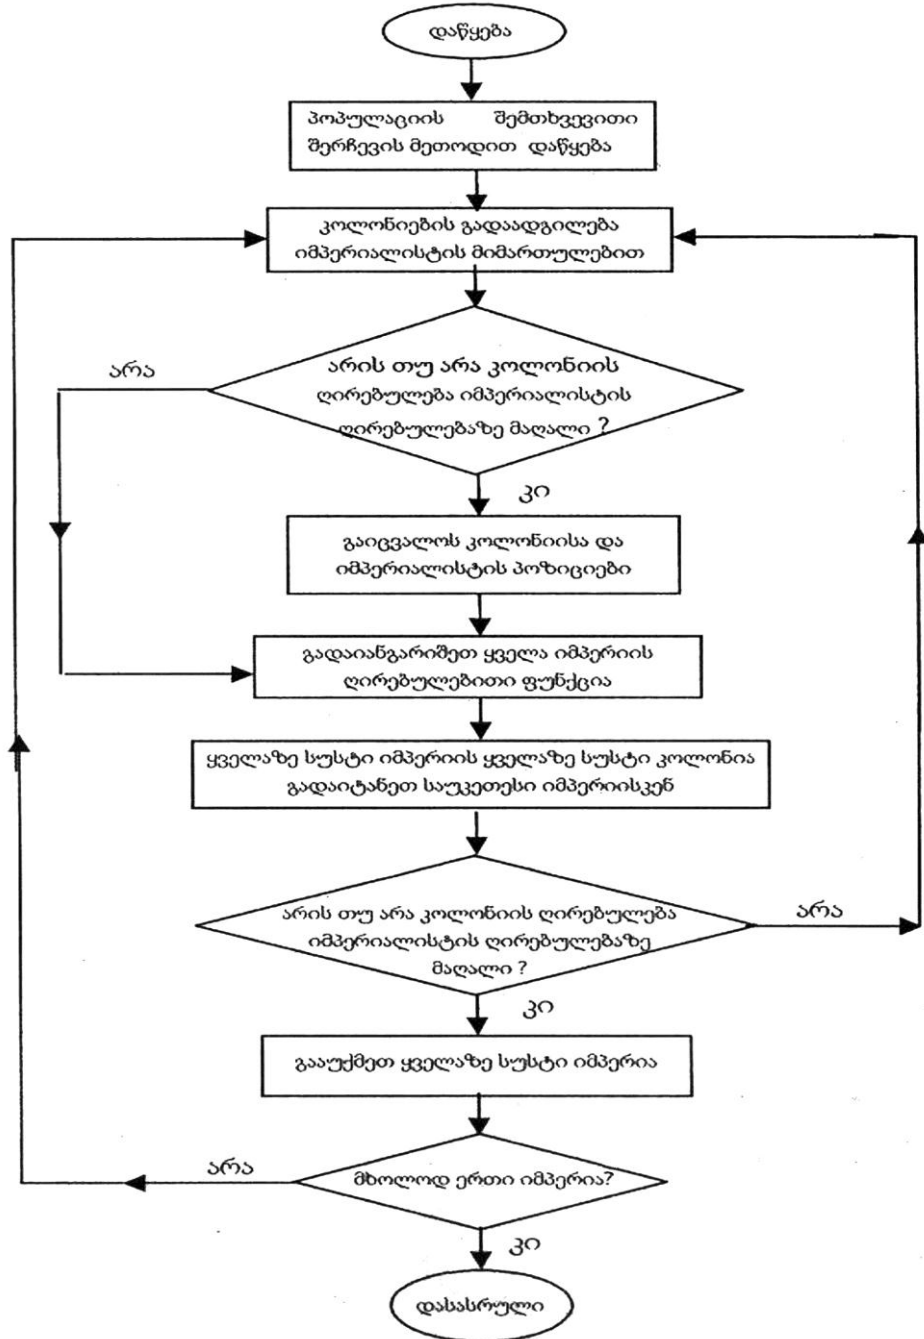
იმის დასადგენად თუ რომელი იმპერია მიითვისებს აღნიშნულ კოლონიას, თითოეული იმპერიისთვის უნდა გამოითვალოს ალბათობა ნორმალიზებულ საერთო ძალაზე დაყრდნობით.

$$N.T.C._n = T.C._n = \max\{T.C._i\} \quad (3.18)$$

სადაც  $T.C._n$  და  $N.T.C._n$  არის n-ური იმპერიის საერთო და საერთო ნორმალიზებული წონები. ალბათობა იმისა რომ კონკრეტული იმპერია დაიპყრობს კოლონიას გამოითვლება ფორმულით:



$$P_{p_n} = \frac{N.T.C._n}{\sum_{i=1}^{N_{mp}} N.T.C._i} \quad (3.19)$$



ნახ.3.24. ICA –ს ბლოკ-სქემა

სუსტი იმპერიებისგან კოლონიების მითვისების პროცესი გრძელდება იქამდე სანამ იმპერიაში არ დარჩება მარტო იმპერიალისტი. ამის შემდეგ კი იმპერია წყვეტს არსებობას. ამგვარად ალგორითმის მუშაობის პროცესში



მუდმივად ხდება სუსტი იმპერიების ჩაყლაპვა და პროცესი იქამდე გრძელდება სანამ ერთი ყველაზე ძლიერი იმპერია არ დარჩება. ალგორითმის მუშაობის მთლიანი პროცესის ძირითადი ბიჯები მოცემულია ბლოკ-სქემის სახით (ნახ. 3.24) – ზე [48].

#### 3.6.4. ნაწილაკების გროვის ოპტიმიზაციის მეთოდი

საფინანსო რისკების მართვის პროცესები შეიძლება განვიხილოთ მულტიაგენტური მოდელირების საფუძველზე, სადაც ხელოვნური ინტელექტის მეთოდების გამოყენება მნიშვნელოვნად ამაღლებს ეფექტურობას. განვიხილოთ ახალი მიდგომა საფინანსო ბაზრის ანალიზისა და პროგნოზირებისათვის ნაწილაკთა გროვის მეთოდის ბაზაზე. გროვის ინტელექტი არის კვლევის ახალი მეთოდი, რომელიც ჯერჯერობით ჩანასახის სტადიაში იმყოფება ხელოვნური ინტელექტის სხვა მეთოდებთან შედარებით.

ნაწილაკების გროვის ოპტიმიზაციის – **Particle Swarm Optimization (PSO)** ალგორითმის პოპულარობამ ბოლო წლებში თანდათან მოიმატა. PSO არის პოპულაციაზე დაფუძნებული ალგორითმი, რომელიც განეკუთვნება ევოლუციური ალგორითმების ოჯახს, მაგრამ სხვა ევოლუციური ალგორითმებისგან განსხვავებით მისი ინდივიდების ევოლუცია შეცვლილია საძიებო არეში მიზნისკენ მოძრაობით. ალგორითმში ამოცანის გადაწყვეტა ხდება გროვის ინდივიდების, რომელთაც ნაწილაკებს უწოდებენ, მოძრაობით და მათ შორის ურთიერთქმედებით [50].

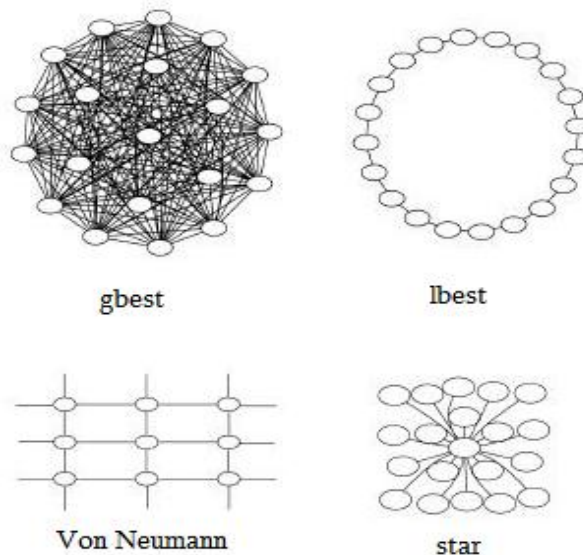
ნაწილაკის მოძრაობა საძიებო არეში არის ნაკარნახები როგორც საკუთარი საუკეთესო პოზიციით, ასევე მთლიანი გროვის საუკეთესო პოზიციით აღნიშნულ არეში. ნაწილაკის გადაადგილებისთვის აუცილებელი პირობაა საკუთარი პოზიციის და შესაბამისად მთელი გროვის პოზიციის გაუმჯობესება. გროვის მიზანია, საძიებო არეში გლობალური ოპტიმუმის მოძებნა, ეს კი მიიღწევა გროვის პოზიციის და ფიტნეს ფუნქციის, მუდმივი ოპტიმიზაციის გზით. მეთოდი არ იძლევა

გადაწყვეტილების პოვნის 100%-იან გარანტიას. მიუხედავად ამისა, იგი მრავალი სხადასხვა ამოცანების გადასაჭრელად გამოიყენება მისი სიმარტივის, ინტუიციურობის და პარარელუბადი თვისების გამო [51]. ამ ამოცანების მაგალითებია: ხელოვნური ნეირონული ქსელის ტრეინინგი (სწავლება) [52], სტატიკური თუ დინამიური ფუნქციების ოპტიმიზაცია [53], მულტიმოდალური ოპტიმიზაცია, მონაცემების კლასტერიზაცია და სხვა.

ნაწილაკების გროვა აღიწერება რამდენიმე ძირითადი პარამეტრით. ესენია:

- გროვის ზომა ( $S$ )
- სიჩქარე ( $v_{max}$ )
- ინერცია ( $w$ )
- $c1$  და  $c2$  კონსტანტები
- ტოპოლოგია (gbest, lbest, star, Von Neumann)

(ნახ.3.25)-ზე მოცემულია ნაწილაკების გროვის ოპტიმიზაციის ყველაზე ხშირად გამოყენებადი ტოპოლოგიები.



ნახ. 3.25. PSO-ს ტოპოლოგიის მაგალითები

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. ალგორითმის მუშაობის სქემა მოიცავს რამდენიმე ბიჯს:

**1. ინიციალიზაცია.** თითოეულ ნაწილაკს სამი თვისება გააჩნია:

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

$$p_k^i = [x_k^i, y_k^i], \quad i=1,2, \dots, N \quad (3.20)$$

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

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:

$$P_k = \{p_k^i\}, \quad i=1,2, \dots, N. \quad (3.21)$$

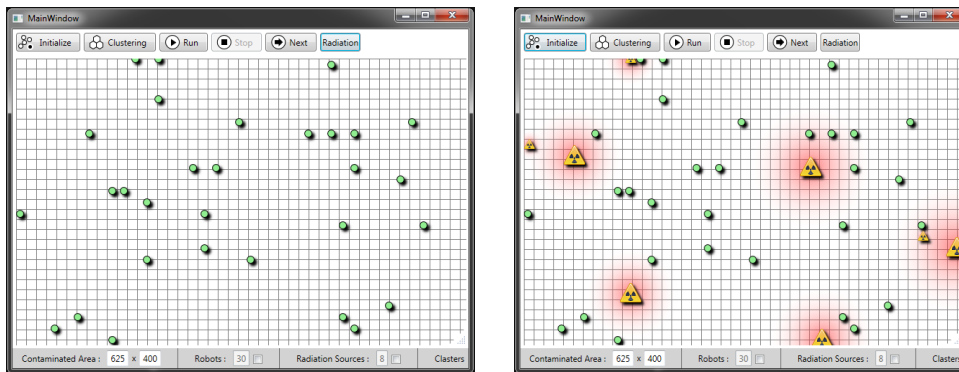
ინიციალიზაციის დროს უნდა განისაზღვროს საწყისი პარამეტრები: გროვის ზომა  $N$ , წონის პარამეტრები  $c_1, c_2$ , რომელთაც შემეცნებით და სოციალურ პარამეტრებსაც უწოდებენ, საძიებო არის საზღვრები  $x_{min}, x_{max}, y_{min}, y_{max}$ , ალგორითმის შეწყვეტის კრიტერიუმები  $G, \mu$ . თავდაპირველად  $k \leftarrow 0$ . ამის შემდეგ, უკვე განსაზღვრულ არეში, უნდა დავსვათ  $N$  რაოდენობის ნაწილაკი შემთხვევითად დაგენერირებულ პოზიციებზე (ნახ. 3.26).

$$p_0^i = p_{min} + rand(p_{max} - p_{min}) \quad (3.22)$$

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

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

$$V_0^i = \frac{p_{\min} + rand(p_{\max} - p_{\min})}{\Delta t} \quad (3.23)$$




ნახ.3.26.

ა) შემთხვევითად განაწილებული ნაწილაკები      ბ) გროვები ლიდერ ნაწილაკებთან

2. 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 აუთსაიდერები (ნახ.3.27).

$$l_j = \{p_k^i\}, \quad j=1,2, \dots, M. \quad (3.24)$$



ნახ.3.27. ლიდერების არჩევა

ლიდერების არჩევა შემდეგნაირად ხდება: იგება გრაფიკი, სადაც აბსცისთა ღერძზე განლაგდება ნაწილაკები (p) დალაგებული ფიტნეს ფუნქციის მნიშვნელობათა კლებადობით მიხედვით, ხოლო ორდინატთა ღერძზე გადაიზომება ნაწილაკთა შორის დისტანციები (d). ვიმახსოვრებთ თითოეული კოორდინატს (p, d), რომელიც შეესაბამება p ნაწილაკს d სხვაობით. რა თქმა უნდა, კოორდინატთა სათავეში მოხვდება p<sub>1</sub> ნაწილაკი ფიტნეს ფუნქციის მაქსიმალური მნიშვნელობი

$$r_1 = r_{max}; \quad r_i = f(p_i); \quad i=1,2, \dots, N. \quad d_i = r_{max} - r_i \quad (3.25)$$

$$\bar{d} = \frac{\sum_{i=1}^N d_i}{N}; \quad \bar{d}_i = \frac{\sum_{i=1}^N d_i}{i} \quad (3.26)$$

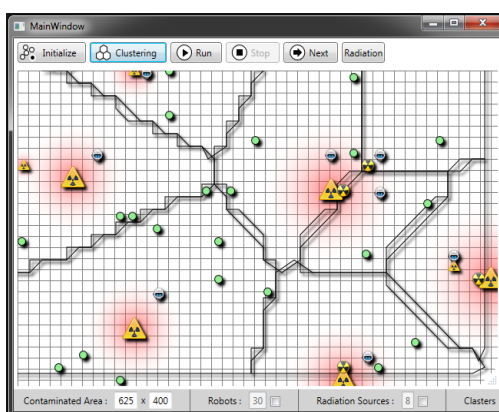
ამის შემდეგ კოორდინატთა სათავიდან აიგება წრფე შემდეგი ფორმულით:

$$\tan \alpha = \frac{\sum_{i=1}^N r_i}{N(r_{max} - r_N)} \quad (3.27)$$

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

$$p_i = \begin{cases} d_i \leq \bar{d}_i & \text{- leader} \\ \text{otherwise} & \text{- outsider} \end{cases} \quad (3.28)$$

ლიდერების მიხედვით K-Means ალგორითმის გამოყენებით ხდება მოცემული არის კლასტერიზაცია (ნახ. 3.28). თითოეულ კლასტერში ნაწილაკებს შორის ურთიერთობის ფორმა „star“ - ტოპოლოგიით გვაქვს განსაზღვრული. ანუ თითოეულ აუტსაიდერ ნაწილაკს კავშირი აქვს მხოლოდ ლიდერ ნაწილაკთან.



ნახ. 3.28. კლასტერიზაცია

K-Means საშუალებას იძლევა გადავანაწილოთ  $N$  აუტსაიდერი  $M$  ლიდერების სიმრავლეზე  $L = \{l_r\}$ ,  $r=1,2, \dots, M$ , იგი ცდილობს მინიმუმამდე დაიყვანოს კლასტერის წერტილების საერთო კვადრატული გადახრა კლასტერის ცენტრიდან, რომელიც ჩვენს შემთხვევაში ლიდერ ნაწილაკს შეესაბამება:

$$\arg \min_L = \sum_{l_c=1}^M \sum_{P_k^i \in L} \|p_k^i - p_k^j\|^2 \quad (3.29)$$

**3. განახლება.** განახლება იტერაციული პროცესია და მოიცავს ნაწილაკის სიჩქარისა და პოზიციის განახლებას, ასევე ნაწილაკისა და გროვის მახსიერების განახლებას. მნიშვნელოვანია ის ფაქტი, რომ თითოეული იტერაცია ხდება კლასტერის ფარგლებში და დამოკიდებულია მხოლოდ ამ კლასტერის თვისებებსა და მის პოპულაციაზე. განახლების სიჩქარის განახლება, თავის მხრივ დამოკიდებულია ნაწილაკის წინა იტერაციის მოძრაობის თვისებებზე (სიჩქარე, აჩქარება, პოზიცია), ნაწილაკის საუკეთესო პოზიციაზე და ამ ნაწილაკზე გროვის გავლენაზე.

$$v_{k+1}^i = wv_k^i + c_1 \text{rand} \frac{(p_k^l - p_k^i)}{\Delta t} + c_2 \text{rand} \frac{(p_k^g - p_k^i)}{\Delta t} \quad (3.30)$$

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:

$$c_1 = p_k^l / p_k^g, \quad c_1 = 1 - (p_k^l / p_k^g) \quad (3.31)$$

თუ ნაწილაკის წინა იტერაციის პოზიცია არ იყო ვარგისი, მაშინ მიმდინარე იტერაციაზე ვანულებთ და მხედველობაში აღარ ვიღებთ წინა იტერაციის სიჩქარეს, შესაბამისად, ასეთ შემთხვევაში  $wv_k^l$  - პარამეტრი ფორმულიდან ამოვარდება.

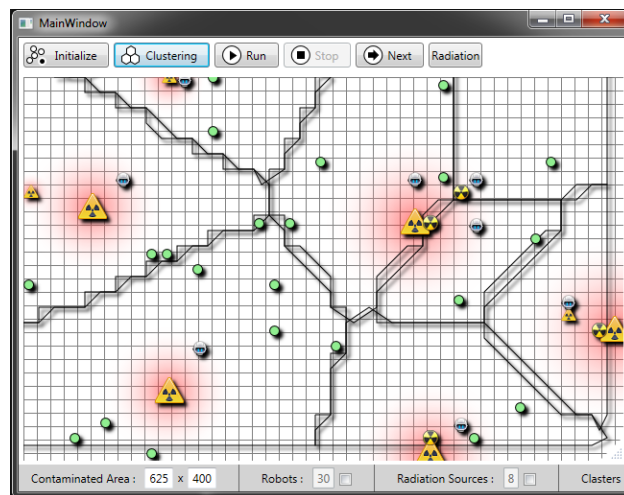
ნაწილაკის პოზიციის განახლება კი ხდება უკვე გამოთვლილი სიჩქარის ვექტორის დახმარებით:

$$p_{k+1}^i = p_k^i + v_{k+1}^i \Delta t \quad (3.32)$$

თითოეულ იტერაციაზე, ნაწილაკების სიჩქარისა და პოზიციის განახლების შემდეგ, ხდება ნაწილაკების და გროვის საუკეთესო პოზიციების განახლება (ნახ.3.29). გროვის საუკეთესო პოზიცია განისაზღვრება ლიდერის საუკეთესო პოზიციით და დგინდება შემდეგნაირად:

$$l_{k+1}^r = p_{k+1}^g = [x_{k+1}^g, y_{k+1}^g], \quad r=1,2, \dots, M. \quad (3.33)$$

$$p_{k+1}^g = \begin{cases} p_{k+1}^i & \text{if } f(p_{k+1}^i) \leq f(p_k^g), \\ p_k^g & \text{Otherwise} \end{cases} \quad (3.34)$$



ნახ. 3.29. გროვის მდგომარეობა  $k$ -ურ ბიჯზე

4. ალგორითმის შეწყვეტის კრიტერიუმი. ალგორითმის შეწყვეტის კრიტერიუმი შედგება რამდენიმე კომპონენტისგან, ესენია:

ა) გამოითვლება მოძრაობისას რამდენად აუმჯობესებს ლიდერი საუკეთესო პოზიციას:

$$d_{k+1} = |f(p_{k+1}^g) - f(p_k^g)| \leq \mu \quad (3.35)$$


სადაც  $\mu$  - არის წინასწარ განსაზღვრული ბიჯი.

ბ) გამოითვლება კლასტერში ნაწილაკების შეჯგუფების ხარისხი ლიდერი ნაწილაკის მიმართ:

$$D = \frac{1}{N} \sum_{i=1}^N \sqrt{|p_k^i - p_k^j|^2} \leq G \quad (3.36)$$

სადაც,  $p_{k+1}^c$  - არის შეჯგუფების ცენტრალური წერტილი (ნახ.3.30).

$$p_{k+1}^c = \frac{1}{Q} \sum_{i=1}^Q \sqrt{|p_{k+1}^c - p_{k+1}^i|^2}, \quad i \neq j \quad (3.37)$$



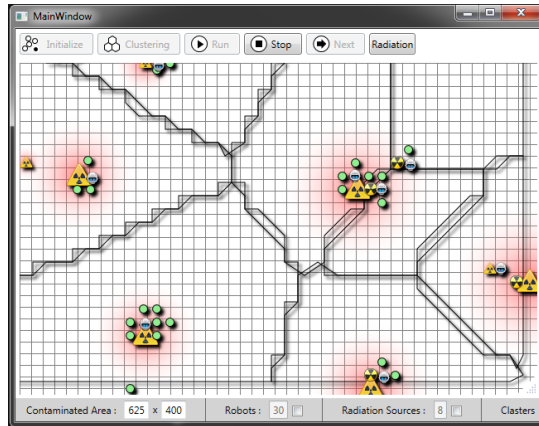
ნახ.3.30. ნაწილაკების შეჯგუფების ცენტრალური წერტილი

გ) და ბოლოს გამოითვლება ამ კომპონენტების ფუნქციის მნიშვნელობა:

$$S = d_{k+1} + D \Rightarrow \min \quad (3.38)$$

თუ კმაყოფილდება აღნიშნული პირობა, მაშინ ალგორითმი წყვეტს მუშაობას და გამოგვავს შედეგი (ნახ. 3.31), თუ არა გადავდივართ მე-3 ბიჯზე.





ნახ. 3.31. საბოლოო მდგომარეობა

ამოცანა მდგომარეობს იმაში, რომ ჩვენ შევძლოთ საფინანსო ბაზრის პროგნოზირება და რისკების მართვა, ამითვის კი ამოსავალ წერტილად ავიღეთ ნაწილაკების გროვის ოპტიმიზაციის მეთოდი. დასმული ამოცანის გადასაჭრელად PSO ალგორითმი შეძლებს სწრაფად მოძებნოს ოპტიმალური შედეგი საფინანსო ბაზრის პირობების შეცვლის შემდეგაც კი.

## თავი 4. ექსპერიმენტული კვლევა

### 4.1. ნაწილაკთა გროვის ოპტიმიზაციის მოდიფიცირებული ალგორითმი

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 მულტიაგენტური ევოლუციური ოპტიმიზაციის საფუძველზე. ნაშრომში წარმოდგენილია ახალი ალგორითმი ნაწილაკთა გროვის ოპტიმიზაციის (PSO) მეთოდის ბაზაზე.

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 ფიტნეს ფუნქციის გლობალური ოპტიმუმის მოძებნა.

PSO-ს პარადიგმების შესაბამისად, 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.

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:

$$p_k^i = [x_k^i y_k^i], \quad i=1,2, \quad (4.1)$$

ბ) სიჩქარე  $v_k^i$ -ნაწილაკები ოპტიუმის 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:

$$P_k = \{p_k^i\}, \quad i=1,2, \dots, N. \quad (4.2)$$

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.

$$p_0^i = p_{min} + rand(p_{max} - p_{min}) \quad (4.3)$$

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


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

$$v_0^i = \frac{p_{min} + rand(p_{max} - p_{min})}{\Delta t} \quad (4.4)$$

**II. კლასტერიზაცია.** კლასტერიზაციისთვის აუცილებელია თითოეული ნაწილაკისთვის საწყისი კოორდინატებში ფიტნეს ფუნქციის გამოთვლა.

ფიტნეს ფუნქციის საფუძველზე, ანუ საუკეთესო პოზიციებზე ირჩევა M რაოდენობის ლიდერი ნაწილაკები, დანარჩენი ნაწილაკები კი ავტომატურად ხდებიან აუტსაიდერები (ნახ. 4.1).

$$l_j = \{p_k^i\}, \quad j=1,2,\dots,M \quad (4.5)$$



ნახ. 4.1. ლიდერების არჩევა

ლიდერების არჩევა შემდეგნაირად ხდება: იგება გრაფიკი, სადაც აბსცისთა ღერძზე განლაგდება ნაწილაკები (p) ფიტნეს ფუნქციის მნიშვნელობათა კლებადობის მიხედვით სორტირებული, ხოლო ორდინატთა ღერძზე გადაიზომება ნაწილაკთა შორის დისტანციები (d). ვიმახსოვრებთ თითოეული კოორდინატს (p, d), რომელიც შეესაბამება p ნაწილაკს d სხვაობით. კოორდინატთა სათავეში მოხვდება **p<sub>1</sub>** ნაწილაკი ფიტნეს ფუნქციის მაქსიმალური მნიშვნელობით.

$$r_1 = r_{max}; \quad r_i = f(p_i), \quad i=1,2, \dots,N. \quad d_i = r_{max} - r_i \quad (4.6)$$

$$\bar{d} = \frac{\sum_{i=1}^N d_i}{N}; \quad \bar{d}_i = \frac{\sum_{i=1}^N d_i}{i} \quad (4.7)$$

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

$$B = \frac{\sum_{i=1}^N r_i}{N(r_{\max} - r_N)} \quad (4.8)$$

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

$$p_i \equiv \begin{cases} d_i \leq \bar{d}_i & \text{- leader} \\ \text{otherwise} & \text{- outsider} \end{cases} \quad (4.9)$$

ლიდერების მიხედვით K-Means ალგორითმის გამოყენებით ხდება მოცემული არის კლასტერიზაცია. ამასთან, ყოველ კლასტერში თითოეულ აუტსაიდერი ნაწილაკის ქცევა განიხილება მხოლოდ ლიდერ ნაწილაკთან მიმართებაში. 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:

$$\arg \min_L \sum_{l_c=1}^M \sum_{p_k^i \in L} \|p_k^i - p_k^j\| \quad (4.10)$$

**III. განახლება.** განახლება იტერაციული პროცესია და ნიშნავს ნაწილაკების სიჩქარისა და პოზიციისათვის ახალი მნიშვნელობების გამოთვლას, რაც, თავის მხრივ დამოკიდებულია ნაწილაკის წინა იტერაციის პარამეტრებზე (სიჩქარე, აჩქარება, პოზიცია), ნაწილაკის საუკეთესო პოზიციაზე და ამ ნაწილაკზე გროვის გავლენაზე.

$$v_{k+1}^i = wv_k^i + c_1 \text{rand} \frac{(p_k^l - p_k^i)}{\Delta t} + c_2 \text{rand} \frac{(p_k^g - p_k^i)}{\Delta t} \quad (4.11)$$

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:

$$c_1 = p_k^l / p_k^g, \quad c_2 = 1 - (p_k^l / p_k^g) \quad (4.12)$$

თუ ნაწილაკის წინა იტერაციის პოზიცია არ იყო 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:

$$p_{k+1}^i = p_k^i + v_{k+1}^i \Delta t \quad (4.13)$$


გროვის საუკეთესო პოზიცია განისაზღვრება ლიდერის საუკეთესო პოზიციით და დგინდება შემდეგნაირად:

$$l_{k+1}^r = p_{k+1}^g = [x_{k+1}^g, y_{k+1}^g], \quad r = 1, 2, \dots, M. \quad (4.14)$$

$$p_{k+1}^g = \begin{cases} p_{k+1}^i & \text{if } f(p_{k+1}^i) \leq f(p_k^g), \\ p_k^g & \text{Otherwise} \end{cases} \quad (4.15)$$

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 ანუ რეკლასტერიზაციას და აუტსაიდერების გადანაწილებას ლიდერების ახალ სიმრავლეზე (ნახ. 4.2).



ნახ. 4.2. რეკლასტერიზაციით ლიდერების არჩევა

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

$$B = \frac{\sum_{i=1}^N r_i}{N(r_{\max} - r_N)} \leq \mu \quad (4.16)$$

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 არა გადავდივართ IV ბიჯზე.

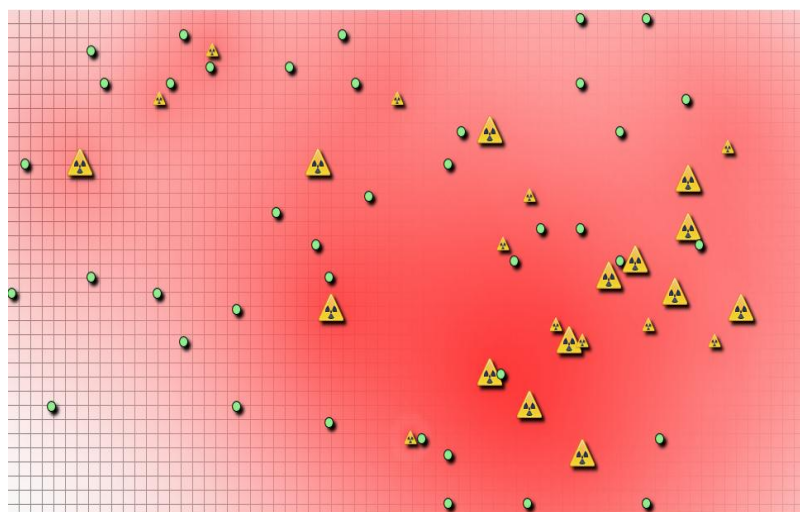
ამდენად, რისკების პროგნოზირების ამოცანის გადაწყვეტისათვის შემოთავაზებულია კოპონენის თვითორგანიზებადი ქსელის გამოყენება, რომლის განსწავლის პროცესში აუცილებელ პირობას წარმოადგენს ე.წ. „გამარჯვებული ნეირონის“ განსაზღვრა, რისთვისაც შემუშავებული იქნა ნაწილაკთა გროვის ოპტიმიზაციის მოდიფიცირებული ალგორითმი, როგორც გლობალური ოპტიმუმის განსაზღვრის ახალი მიდგომა.

## 4.2. გამოთვლების შედეგები და ანალიზი

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

ექსპერიმენტის დროს უნდა განისაზღვროს საწყისი პარამეტრები, რომლებიც დაყვანილი სახით არის წარმოდგენილი: გროვის ზომა  $N$ , წონის პარამეტრები  $c_1$ ,  $c_2$ , და 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 (ნახ.4.3).



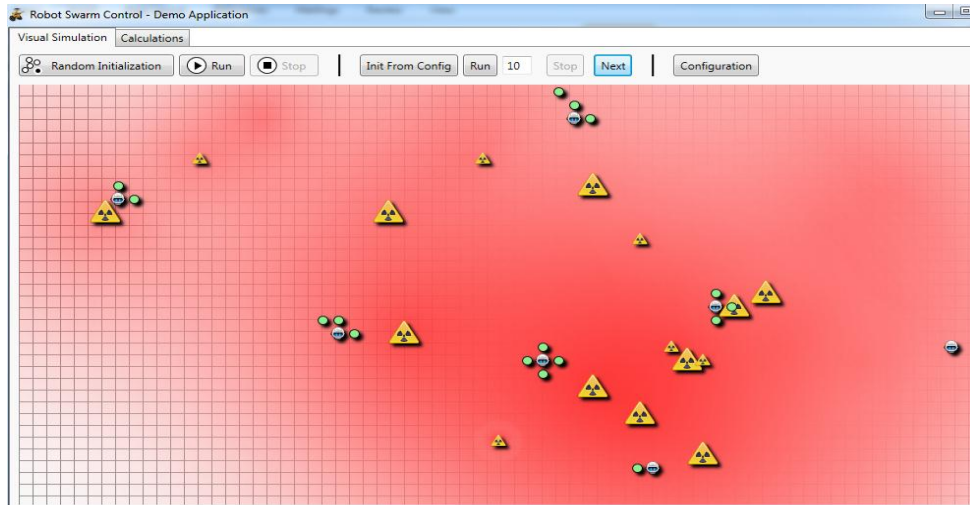
ნახ. 4.3. საწყისი მონაცემები

ალგორითმის მუშაობის სქემა მოიცავს რამდენიმე ბიჯს :

ნაწილაკები ოპტიმუმის ძიების პროცესში განუწყვეტლივ მოძრაობენ საძიებო არეში. მოძრაობა განისაზღვრება მიმდინარე კოორდინატებიდან სწორად განსაზღვრული მანძილით პოზიციის ცვლილებით. კლასტერიზაციისთვის აუცილებელია თითოეული ნაწილაკისთვის საწყის კოორდინატებში ფიტნეს ფუნქციის გამოთვლა. ფიტნეს ფუნქციის საფუძველზე, ანუ

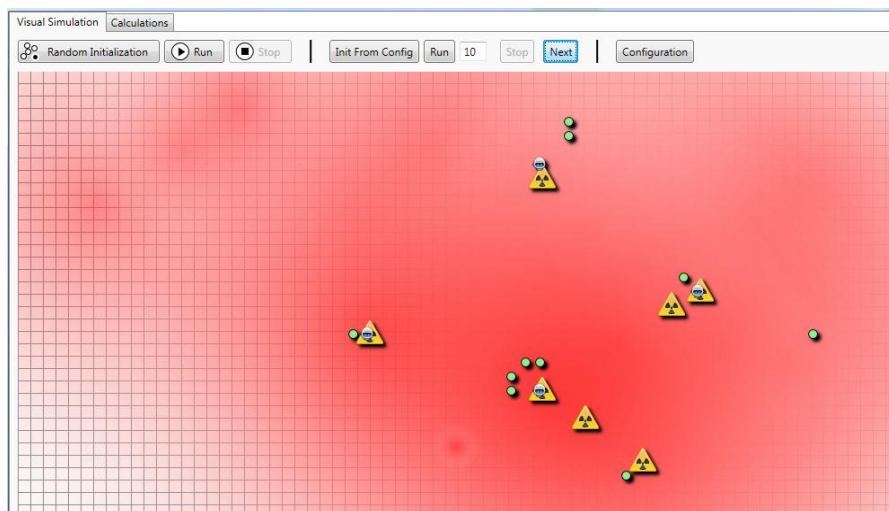


საუკეთესო პოზიციებზე ირჩევა  $M$  რაოდენობის ლიდერი ნაწილაკები, დანარჩენი ნაწილაკები კი ავტომატურად ხდებიან აუტსაიდერები (ნახ.4 4).



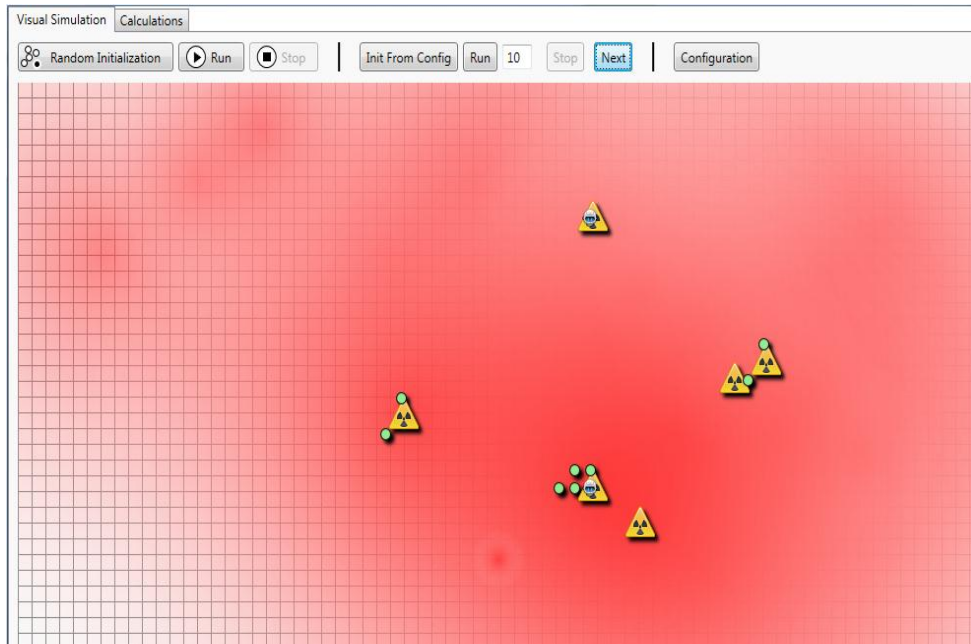
ნახ. 4.4. კლასტერიზაცია

ძიების პროცესში, თუ აღმოჩნდა ისე, რომ რომელიმე მიმდევარი ნაწილაკის პოზიცია უკეთესია ვიდრე ლიდერი ნაწილაკის, მაშინ მიმდევარი ნაწილაკი ავტომატურად გახდება ლიდერი და პირიქით (ნახ. 4.5).



ნახ.4.5. გროვის მდგომარეობა  $k$ -ურ ბიჯზე

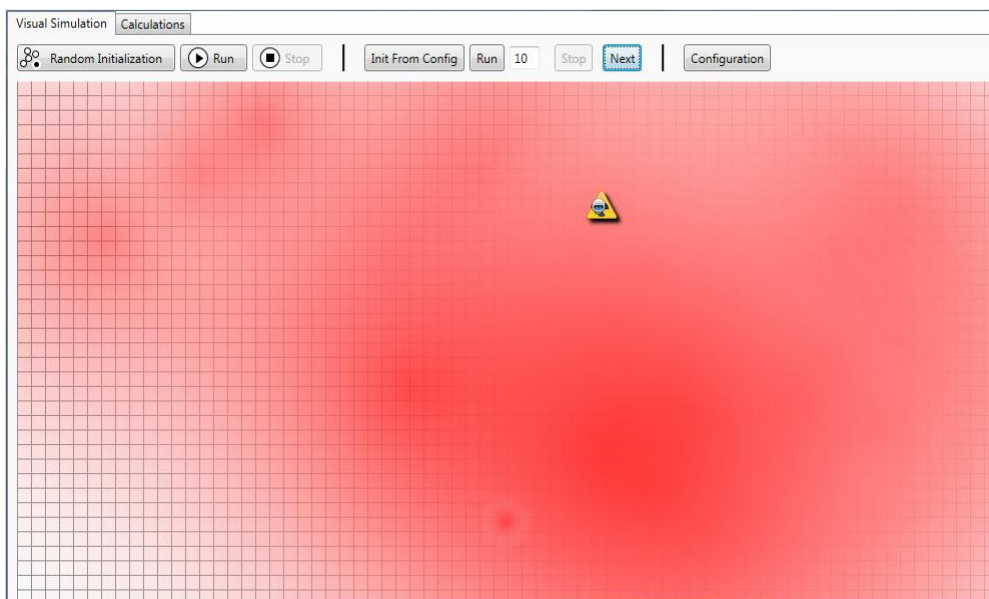
ამის შემდეგ ხდება ლიდერთა ჯგუფის შეცვლა-შემცირება ანუ რეკლასტერიზაცია და აუტსაიდერების გადანაწილება ლიდერების ახალ სიმრავლეზე (ნახ. 4.6).



ნახ. 4.6. რეკლასტერიზაცია

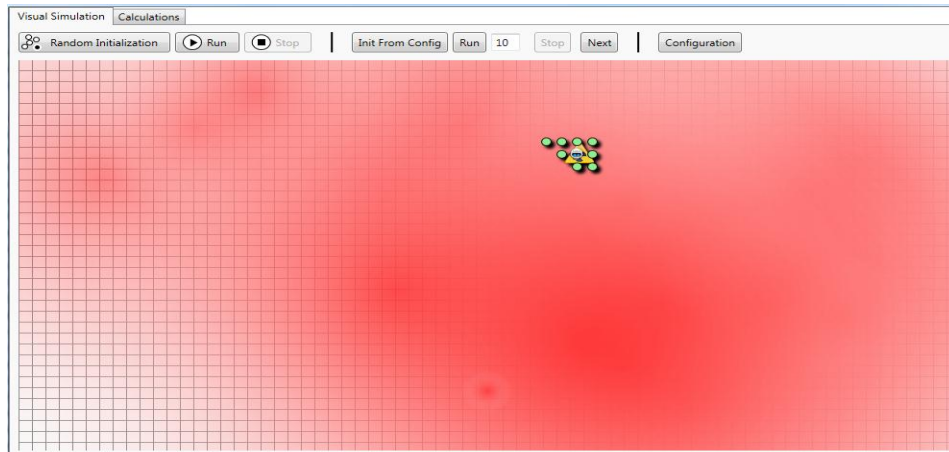
ახალი მიდგომით რეკლასტერიზაციის შედეგად მივიღეთ საბოლოო შედეგი. (ნახ.4.7) -ზე და (ნახ.4.8) -ზე მოცეწულია ორი განსხვავებული საბოლოო მდგომარეობა:

1. მხოლოდ ლიდერი ნაწილაკი;
2. ლიდერი ნაწილაკი და მისი მიმდევარი გროვა.



ნახ. 4.7. მხოლოდ ლიდერი ნაწილაკი

## ან საბოლოო შედეგს შეიძლება ასეთი სახეს ჰქონდეს



ნახ. 4.8. ლიდერი ნაწილაკი და მისი მიმდევარი გროვა

ჩვენი ალგორითმის მიხედვით ჩავატარეთ მრავალი ცდა, სადაც შევიტანეთ საწყისი მონაცემები დაყვანილი სახით და გამოვიყენეთ ლიდერი ნაწილაკისადმი ახალი მიდგომა. თითოეული ჩატარებული ცდის შემდეგ გამოვითვალეთ მოცემული ლიდერი ნაწილაკის ფიტნეს ფუნქციის მნიშვნელობა. ასევე დავითვალეთ გროვის თითოეული ნაწილაკისთვის ფიტნეს ფუნქციის მნიშვნელობები და მათი საშუალო მნიშვნელობა.

ამდენად, ალგორითმის მიხედვით ამონახსნად ჩაითვლება მიღებული ლიდერთა გროვის თითოეული ნაწილაკისთვის ფიტნეს ფუნქციების გასაშუალებული მნიშვნელობა.

ყოველი ჩატარებული ცდისთვის ავაგეთ შესაბამისი ცხრილი. ექსპერიმენტის საფუძველზე, მიღებული შედეგები წარმოდგენილია ქვემოთ მოცემულ ცხრილებში.

ცდა №	ნაწილაკი №	ფიტნეს ფუნქციის სიზუსტე	ლიდერის ბიჯები	გროვის ბიჯები	ლიდერის ფიტნეს ფუნქციის სიზუსტე	გროვის ფიტნეს ფუნქციის სიზუსტე	ფიტნეს ფუნქციის საშუალო სიზუსტე
1	24	99.08	2		99.08		98.565
	13	98.05		4		98.05	
	33	98.05					
	18	98.05					
2	4	99.08	3		99.08		98.31
	9	98.05		7		97.54	
	15	97.03					
3	39	99.08	2		99.08		98.06
	38	97.03		10		97.04	
	9	98.05					
	19	97.03					
	20	98.05					
	25	97.03					
	8	98.05					
	3	97.03					
4	10	99.08	6		99.08		98.055
	2	97.03		6		97.03	
5	3	99.08	2		99.08		98.18875
	17	98.05		7		97.2975	
	8	98.05					
	10	98.05					
	36	95.04					
6	7	99.08	5	5	99.08	–	99.08
7	40	99.08	3		99.08		98.055
	29	97.03		3		97.03	

ცხრილი 4.1. (1- 7) - ცდის შედეგები

ცდა №	ნაწილაკი №	ფიტნეს ფუნქციის სიზუსტე	ლიდერის ბიჯები	გროვის ბიჯები	ლიდერის ფიტნეს ფუნქციის სიზუსტე	გროვის ფიტნეს ფუნქციის სიზუსტე	ფიტნეს ფუნქციის საშუალო სიზუსტე
8	14	99.08	2		99.08		97.78714
	7	97.03		8		96.49428	
	26	98.05					
	5	97.03					
	9	98.05					
	6	97.03					
	10	98.05					
	22	90.22					
9	28	99.08	6				99.08
	25	98.05		7		97.54	
	24	97.03					
10	17	99.08	7		99.08		98.565
	39	98.05		8		98.05	
	20	98.05					
11	4	99.08	5		99.08		98.565
	37	98.05		7		98.05	
	31	98.05					
	10	98.05					
12	14	99.08	3		99.08		98.259
	10	97.03		7		97.438	
	28	98.05					
	8	97.03					
	12	98.05					
	40	97.03					
13	34	99.08	5		99.08		98.31
	4	98.05		7		97.54	

ცხრილი 4.2. (8- 13) - ცდის შედეგები

ცდა №	ნაწილაკი №	ფიტნეს ფუნქციის სიზუსტე	ლიდერის ბიჯები	გროვის ბიჯები	ლიდერის ფიტნეს ფუნქციის სიზუსტე	გროვის ფიტნეს ფუნქციის სიზუსტე	ფიტნეს ფუნქციის საშუალო სიზუსტე
14	10	99.08	3		99.08		97.578
	27	98.05		5		96.076	
	28	97.03					
	3	98.05					
	24	97.03					
	20	90.22					
15	36	99.08	5				99.08
	24	98.05		7		97.71	
	4	98.05					
	26	97.03					
16	12	99.08	4				91.06
	10	90.11		9		89.8775	
	8	90.11					
	16	89.18					
	30	90.11					
17	24	99.08	3				99.08
	4	98.05		4		97.244	
	10	98.05					
	28	97.03					
	18	98.05					
	16	95.04					
18	21	99.08	2				99.08
	25	98.05		4		95.795	
	15	97.03					
	3	94.05					
	39	94.05					

ცხრილი 4.3. (14-18) - ცდის შედეგები

ცდა №	ნაწილაკი №	ფიტნეს ფუნქციის სიზუსტე	ლიდერის ბიჯები	გროვის ბიჯები	ლიდერის ფიტნეს ფუნქციის სიზუსტე	გროვის ფიტნეს ფუნქციის სიზუსტე	ფიტნეს ფუნქციის საშუალო სიზუსტე
19	21	91.06	4		91.06		90.46875
	9	90.11		5		89.8775	
	20	90.11					
	39	89.18					
	8	90.11					
20	36	99.08	3		99.08		98.565
	23	98.05		7		98.05	
	21	98.05					
	19	98.05					

ცხრილი 4.4. (19-20) ცდის შედეგები

ჩატარებული ცდების საბოლოო შედეგების მისაღებად გამოვთვალეთ ლიდერი ნაწილაკების ფიტნეს ფუნქციის საშუალო მნიშვნელობა, ასევე დავითვალეთ ლიდერთა გროვების ფიტნეს ფუნქციის საშუალო მნიშვნელობა, და მათი გასაშუალებული მნიშვნელობა. ეს შედეგები წარმოდგენილია (ცხრილი 4.5.)-ში.

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

ცხრილი 4.5. საბოლოო შედეგები

ამდენად, გამოთვლების შედეგებმა დაადასტურა მიღებულ ნაწილაკებში ფიტნეს ფუნქციის გაუმჯობესება, რაც წარმოდგენს ჩვენი ნაშრომის მიზანს.

## დასკვნა

სადისერტაციო ნაშრომში „საფინანსო სისტემებში რისკების პროგნოზირება ხელოვნური ინტელექტის მეთოდების გამოყენებით“, ჩვენ განვიხილეთ საფინანსო სისტემის რისკების პროგნოზირების და მართვის სხვადასხვა სახის ალგორითმები, რომელიც პრაქტიკაში თავიდან იყო შემოთავაზებული პრობლემის გადასაწყვეტად. ნაჩვენებია ამ მეთოდების როგორც პოზიტიური ასევე ნეგატიური მხარეები. საკმაო ლიტერატურის გადამუშავების შედეგად მივედით დასკვნამდე, რომ პროგნოზირების ამოცანები გაცილებით უკეთ იხსნება ევოლუციური ალგორითმის მეშვეობით.

თანამედროვე საბაზრო ურთიერთობაში რისკების მართვას უნდა ჰქონდეს თავისი სტრატეგია და ტაქტიკა. ფინანსური რისკების მათვის ეფექტურობისთვის აუცილებელია სამეცნიერო კვლევებზე დაყრდნობა. ამ მიზნით დისერტაციაში შემუშავებულია ორი ევოლუციური ალგორითმი. პირველი ალგორითმი აგებულია ხელოვნური ნეირონული ქსელის პრინციპზე. ერთ-ერთი არის კოჰონენის თვითორგანიზებადი რუკები, რომელიც იყენებს ქსელის არაკონტროლირებადი სწავლების მეთოდს. ამ ქსელის გამოყენება ნაკარნახებია იმით, რომ დიდ სირთულეებთან არის დაკავშირებული რთული სტრუქტურის წარმოდგენა მრავალგანზომილებიან ქსელში. ქსელის განსწავლის პროცესში აუცილებელ პირობას წარმოადგენს ე.წ. „გამარჯვებული ნეირონის“ განსაზღვრა. ამასთან, სწავლების მსვლელობისას მოდიფიცირდება არამარტო გამარჯვებული ნეირონი, არამედ მისი მეზობლებიც, შედარებით მცირე დონით. აღნიშნული მიდგომის გამოყენება, ერთი მხრივ, შესაძლებელია საწყისი და საბოლოო მონაცემთა კანონზომიერებების ძებნისა და ანალიზისთვის, მეორე მხრივ, ახორციელებს მრავალგანზომილებიანი შემავალი სივრცის გამოსახვას ორ განზომილებიან (იშვიათად ერთ განზომილებიან) გამავალ სივრცედ, ე.ი. ახდენს მონაცემთა შეკუმშვას. რაც საბოლოოდ აჩქარებს ალგორითმის შესრულების პროცესს.



მეორე ალგორითმი, სადაც გამოვიყენეთ ლიდერი ნაწილაკის ძენბი-სადმი ახლებური მიდგომა ე.წ. „წონითი კოეფიციენტების” გამოყენებით არის ნაწილაკთა გროვის ოპტიმიზაციის მოდიფიცირებული ალგორითმი, როგორც გლობალური ოპტიმუმის განსაზღვრის ახალი მიდგომა, ნაწილაკის მოძრაობა საძიებო არეში არის ნაკარნახები როგორც საკუთარი საუკეთესო პოზიციით, ასევე მთლიანი გროვის საუკეთესო პოზიციით აღნიშნულ არეში. ნაწილაკის გადაადგილებისათვის 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.

ამდენად, ეს ნამუშევარი მოტივირებულია იდებით გამოითვალოს რისკები ფინანსურ ბაზარზე, რომელიც შეიძლება რეალიზებულია უწყვეტ ნაწილაკთა ნაკრებით ფინანსური ბაზრის სასაწყობე მონაცემთა ბაზაში. ექსპერიმენტის მიზნით, ჩატარებული მრავალი ცდების საფუძველზე და გამოთვლების შედეგებით დადასტურდა მიღებულ ნაწილაკებზე ფიტნეს ფუნქციის გაუმჯობესება, რაც წარმოადგენს ჩვენი ნაშრომის მიზანს შემცირდეს გამოთვლების რაოდენობა და შესაბამისად დაიზოგოს დრო, რომელიც საფინანსო ბაზრის რისკების პროგნოზირების შესრულების ერთ-ერთ ძირითად ღირებულებას წარმოადგენს და დისერტაციის მიღწევას.

## დანართი

საწყისი მონაცემები ნაწილაკთა გროვის ოპტიმიზაციის მოდიფიცირებული ალგორითმის, ლიდერი ნაწილაკის ძენბისადმი

Coordinate X	Coordinate Y	Polution Measure R
12	6	18.47
24	10	68.31
6	10	68.31
16	3	33.45
30	6	40.5
43	21	71.27
46	17	63.68
48	16	91.06
52	14	65.21
55	9	35.93
56	19	87.43
38	15	39.42
40	12	9.86
37	8	99.08
66	17	80.61
54	21	14.58
44	21	14.58
52	11	64.58
49	20	22.19
51	18	71.07
44	28	84.24
42	20	54.29
40	25	82.29
37	23	97.33
31	27	4.9
25	19	89.33

X  Y  R

## გამოყენებული ლიტერატურის ნუსხა

1. Калмыкова Л.И. Фундаментальный анализ финансовых рынков /Л.И. Калмыкова – СПб.: Питер, 2005. (Серия «Школа валютных трейдеров»)
2. Гончаренко Л.П., Филин С.А. Риск-менеджмент. Изд.Кн. Рус. М., 2010.
3. Ермасова Н.Б., Риск-менеджмент организации. Изд. Дашков и Ло, М., 2010.
4. Bansal, A. Kauffman, R.J. Mark, R.M. Peters, E. “Financial risk and financial Risk Management Technology,” Information & Management (1993), 24, 267-281 North-Holland Center for Digital Economy Research Stern School of Business Working Paper IS-93-23
5. Наговицин А.Г., Иванов В.В. Валютный курс. Факторы. Динамика. Прогнозирование. - М.: Инфра-М, 1995. - 176 с.
6. Балабанов И. Т. Финансовый менеджмент: Учебник.-Москва. Финансы и статистика, 1994.
7. Аржеповский СВ. Статистические методы прогнозирования:учеб.пособ./ СВ. Аржеповский, И.Н.Молчанов.- Ростов-на-Дону: РГЭУ «РИНХ», 2001.
8. Kervalishvili, P.,Meparishvili B.,Meparishvili T. New Approach of Intelligent Techniques toFinancial Risk Management. SynEnergy Forum (S.E.F.) -2 The conf. for Intern. Synergy in Energy, Environement, Tourism and Info.Technology. Spetses, Greece 24-26 Sep., 2009
9. Кидуэлл Д.С., Петерсон Р.Л., Блэкуэлл Д.У. Финансовые институты, рынки и деньги. – СПб.:Питер, 2001. – 752 с.
10. Boyle, P., M. Broadie, and P. Glasserman. “Monte Carlo Methods for Security Pricing.” Monte Carlo Methods for Security Pricing 21 (1997), 1267-1321.
11. Dupire, B. Monte Carlo: Methodologies and Applications for Pricing and Risk Management. London: Risk Books (1998). One article in particular that gives an excellent overall survey.
12. Борщев А.В. Практическое агентное моделирование и его место в арсенале аналитика / А.В. Борщев // Экспонента PRO. – 2004. - № 3-4 (7-8). – С. 38-47.
13. Щербаков А.В. Мультиагентное имитационное моделирование/ А.В. Щербаков//Международная научно-практическая конференция «Теория активных систем – 2005». – 2005. – С. 164-168
14. Щербаков А.В. Мультиагентное имитационное моделирование активной маркетинговой системы/ А.В.Щербаков // Труды международной научно-практической конференции (16-18 ноября 2005 г., Москва, Россия), под ред. В.Н. Буркова, Д.А. Новикова. – МОСКВА – 2005. – Секция 3. – С. 164-168
15. Johnson P. E. Agent- Based Modeling: What I learned from the Artificial Stock Market // Social Science Computer Review. – 2002. № 20. – Issue 2. – Pages 174-186
16. Markovic, I; and Pereira, A.C. Towards a Formal Framework for Reuse in Business Process Modeling. In Workshop on Advances in Semantics for Web services (semantics4ws), in conjunction with BPM '07, Brisbane, Australia. 2007

17. Борщев А. От системной динамики и традиционного ИМ – к практическим агентным моделям: причины, технология, инструменты. – Электрон. Дан. – режим доступа: [www.gpss.ru/paper/borshevarc.pdf](http://www.gpss.ru/paper/borshevarc.pdf),с.3
18. Сидоренко В.Н. Системная динамика. М.: ТЕИС, 1998
19. General software and toolkits. Agent-Based Computational Economics (ACE) and Complex Adaptive Ststems (CAS). - Электрон. Дан. – режим доступа: [www.ecoon.iastate.Edu/tesfatsi/acecode.htm](http://www.ecoon.iastate.Edu/tesfatsi/acecode.htm)
20. Ярыгин О. Н. Имитационное моделирование производственной деятельности предприятия – Тольятти: зд-во ТГУ, 2011- 138с
21. 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
22. ქოროლიძევილი ც. იმიტაციური მოდელირების გამოყენება საფინანსო რისკების მართვაში. სტუ მართვის ავტომატიზებული სისტემები №2(13), თბილისი, 2012, გვ. 165-170
23. Zimmermann H.G., Neuneier R., Grothmann R. and Tietz Ch.: Market Modeling based on Cognitive Agents, submitted to the International Conference on Artificial Neural Networks (ICANN), August 2002, University of Madrid, forthcoming
24. Macal C.M., North M.J. Agent-based Modeling and Simulation: Desktop ABMS. *Proceedings of the 2007 Win-ter Simulation Conference*. S. G. Henderson, B. Biller, M.-H. Hsieh, J. Shortle, J. D. Tew, and R. R. Barton, eds. Washington, DC, 2007. pp. 95-106
25. Holland J.H., Miller J.H. Artificial Adaptive Agents in Economic Theory. *The American Economic Review*, Vol.1. 1991. 365-370 pp.
26. Meparishvili B. New approach to evolutionary algorithms. ERA-5 Proceedings The Contribution Of Information Technology Science, Economy, Society and Education. T.E.I. of PIREAUS
27. Xinjie Yu, Mitsuo Gen. *Introduction to Evolutionary Algorithms*. London: Springer, 2010, pp 6-8
28. Weise T. *Global Optimization Algorithms - Theory and Application*. 2009, pp. 141-142.
29. Sivanandam S.N., Deepa S.N. *Introduction to Genetic Algorithms*. Berlin, Heidelberg: Springer, 2008, pp 15-16.
30. Sivanandam S.N., Deepa S.N. *Introduction to Genetic Algorithms*. Berlin, Heidelberg: Springer, 2008, pp 29-31.
31. Mitchell Melanie. *An Introduction to Genetic Algorithms*. London, England: Cambridge, Massachusetts, 1999, pp 117-118
32. Mitchell Melanie. *An Introduction to Genetic Algorithms*. London, England: Cambridge, Massachusetts, 1999, pp 124-128
33. Mitchell Melanie. *An Introduction to Genetic Algorithms*. London, England: Cambridge, Massachusetts, 1999, pp 128-130

34. [http://en.wikipedia.org/wiki/Genetic\\_algorithm](http://en.wikipedia.org/wiki/Genetic_algorithm), უკანასკნელად იქნა გადამოწმებული - 20.06.2011
35. <http://www.obitko.com/tutorials/genetic-algorithms/index.php>, უკანასკნელად იქნა გადამოწმებული - 20.06.2011
36. [http://en.wikipedia.org/wiki/Genetic\\_programming](http://en.wikipedia.org/wiki/Genetic_programming), უკანასკნელად იქნა გადამოწმებული - 20.06.2011
37. [http://en.wikipedia.org/wiki/Genetic\\_programming#Representation](http://en.wikipedia.org/wiki/Genetic_programming#Representation), უკანასკნელად იქნა გადამოწმებული - 20.06.2011
38. <http://cswww.essex.ac.uk/staff/poli/gp-field-guide/22InitialisingthePopulation.html#dx1-79>, უკანასკნელად იქნა გადამოწმებული - 20.06.2011
39. Weise T. Global Optimization Algorithms - Theory and Application. 2009, pp 162-165
40. Girish Kumar Jha. ARTIFICIAL NEURAL NETWORKS AND ITS APPLICATIONS. Delhi, 9 p.
41. Girish Kumar Jha. ARTIFICIAL NEURAL NETWORKS. Delhi: Indian Agricultural Research Institute, 10 p.
42. <http://bug.kpi.ua/stud/work/RGR/DATAMINING/neuralnetskhohonencards.html>, უკანასკნელად იქნა გადამოწმებული - 13.06.2014.
43. <http://www.emeraldinsight.com/journals.htm?articleid=1740598>, უკანასკნელად იქნა გადამოწმებული - 13.06.2014.
44. Джонс М.Т. Программирование искусственного интеллекта в приложениях, М., ДМК-пресс, 2004
45. Kervalishvili P.; Meparishvili B.; and Janelidze G. (2009) "Self-organization modelling of Multi-Agent Systems". SynEnergy Forum (S.E.F.) - The conference for International Synergy in Energy, Environment, Tourism and Information Technology. Spetses, Greece.
46. ET-Map – "A testbed of 110,000 Internet homepages from the entertainment section of Yahoo! Was gathered by an Internet Spider. An automatic indexing algorithm was applied to the homepages and a... multi-layered Kohonen SOM [was] created," <http://ai.eller.arizona.edu/research/dl/etspace.htm>.
47. Egge98J. Eggermont, "Rule - Extraction and Learning in the BP-SOM Architecture," Leiden University, Internal Report IR-98-16 (Masters Thesis) August 1998
48. A. M. Jasour, E. Atashpaz, C. Lucas, "Vehicle Fuzzy Controller Design Using Imperialist Competitive Algorithm", Second First Iranian Joint Congress on Fuzzy and Intelligent Systems, Tehran, Iran, 2008.

49. E. Atashpaz-Gargari and C. Lucas, "Imperialist Competitive Algorithm: An Algorithm for Optimization Inspired by Imperialistic Competition", IEEE Congress on Evolutionary Computation (CEC2007). pp 4661-4667, 2007.
50. K.E. Parsopoulos, M. N. Vrahatis. "Particle swarm optimization and intelligence: advances and applications". Published in the United States of America by Information Science Reference. Hershey, New York, ISBN 978-1-61520-666-7, 2009.
51. Meparishvili B., Koroglishvili C. Financial market forecast using artificial intelligence. Transactions. Georgian Technical University. AUTOMATED CONTROL SYSTEMS, №1(14), Tbilisi, 2013, pp. 158-163
52. Meparishvili B., Koroglishvili C. New approach to global optimization based on pso. Transactions. Georgian Technical University. AUTOMATED CONTROL SYSTEMS, №1(17), Tbilisi, 2014, pp. 17-22.
53. Schutte, J.F., Reinbolt, J.A., Fregly, B.J. Haftka, R.T., George, A.D., "Parallel Global Optimisation with the Particle Swarm Algorithm," International Journal of Numerical Methods in Engineering, 61, 2004.