

საქართველოს ტექნიკური უნივერსიტეტი

ხელნაწერის უფლებით

პეტრე პეტაშვილი

კოლექტიური ინტელექტის მეთოდების გამოყენება მულტი-  
რობოტული სისტემების მართვაში

დოქტორის აკადემიური ხარისხის მოსაპოვებლად  
წარდგენილი დისერტაციის

ავტორეფერატი

სადოქტორო პროგრამა „ინფორმატიკა“ შიფრი 0401

თბილისი

2016 წელი

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

ხელმძღვანელი: პროფ. ბადრი მეფარიშვილი

რეცენზენტები: -----  
-----

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

## სადისერტაციო ნაშრომის ზოგადი დახასიათება

### საგნობრივი სფერო. კვლევის აქტუალურობა და მნიშვნელობა

საგნობრივ სფეროს წარმოადგენს ტექნოგენური კატასტროფებით გამოწვეული დაბინძურებული გარემო, რომლის მონიტორინგი შეადგენს ძალიან რთულ და ამასთანავე მნიშვნელოვან პრობლემას. რადიაციით გარემოს ძლიერი დაბინძურებით გამოწვეულმა შედეგებმა, განსაკუთრებით ატომური ენერგეტიკის და სამხედრო სფეროებში, წარმოშვა მზარდი მოთხოვნა ისეთ საშუალებებზე, რომელიც უზრუნველყოფს დაბინძურების წყაროების ავტომატიზებულ მონიტორინგს, განსაზღვრავს რადიაქტიული წყაროების გამოსხივების, მომწამლედი გაზების და ა.შ. ადამიანისთვის უსაფრთხო ზღვრებს. დღესდღეობით, არსებობს საჭიროება მაღალი სიზუსტისა და მგრძობელობის მქონე მოწყობილობებზე დაბინძურების წყაროებისა და საშიში ზონების აღმოჩენა-გაზომვის თვალსაზრისით.

მეორეს მხრივ, ადაპტური ოპტიმიზაციის აუცილებლობა გამომდინარეობს გარემოს არასტაციონალურობიდან, როდესაც მიზნობრივი ფუნქციის განაწილების ლანდშაფტი დინამიურად იცვლება. დასმული ამოცანის გადასაჭრელად საჭიროა მონიტორინგი განხორციელდეს განაწილებული მულტი-რობოტული ქსელიდან გარემოზე ინფორმაციის უწყვეტად შეკრების გზით. მულტი-რობოტული სისტემა არის ავტონომიური მოწყობილობების (რობოტების) რეკონფიგურირებადი სტრუქტურის ქსელი, რომელსაც შეუძლია მონიტორინგი გაუწიოს გარემო პირობების ცვალებადობას. გარემოზე ინფორმაციის შეგროვება ხდება მობილური უკაბელო სენსორებით. ჩვენ განვიხილავთ რადიაციის სენსორს, როგორც არხს გარემოსა და ავტომატურ მონიტორინგის სისტემას შორის. ეფექტური სენსორების და სენსორული სისტემების (ქსელების) განვითარებით და ამასთან ერთად, ხელოვნური ინტელექტის გამოყენებით, მიიღწევა საჭირო ინფორმაციის შეგროვება-დამუშავება და განგაშის ფუნქციის რეალიზება. ასეთ სისტემებს მრავალი ფუნქცია შეიძლება

ჰქონდეთ, მაგ: გარემოს ფიზიკური და ეკოლოგიური მონიტორინგი, ცოცხალი სამყაროს გარემოს მონიტორინგი (ფლორისა და ფაუნის სახეობების განსაზღვრა და მათი ქცევის შესწავლა), სეისმური აქტივობების დაკვირვება, სამხედრო დაზვერვა და სხვა.

პრობლემები, რომლებიც დაკავშირებულია უპილოტო მიწისზედა ტრანსპორტის ქცევის მოდელირებასა და მართვაზე, დაფუძნებულს კოლექტიური ინტელექტის ახალ მიდგომებზე, წარმოადგენს ამ კვლევების მთავარ საგანს.

კვლევა ეფუძნება ხელოვნური ინტელექტის მეთოდების ფართო სპექტრს, ისეთ თანამედროვე მეთოდებს, როგორცაა: ნაწილაკთა გროვის ოპტიმიზაცია, ჭიანჭველების კოლონიის ოპტიმიზაცია, კოლექტიური ქცევის მათემატიკური მოდელირება და მრავალმიზნობრივი მართვა ენტროპიაზე დაფუძნებული მეტრიკის ბაზაზე.

### **კვლევის მიზანი**

კვლევის მთავარ მიზანს წარმოადგენს თანამედროვე ხელოვნური ინტელექტის თეორიის - მულტი-აგენტური სისტემების ქცევის მოდელირების შესახებ, გარკვეული წარმოდგენების განვითარება კოლექტიური ინტელექტის ჩათვლით და მიღწეული შედეგების დანერგვა უპილოტო მიწისზედა ტრანსპორტის (Unmanned Ground Vehicle systems - UGVs) სისტემებში, რომელიც იქმნება ავტონომიური რობოტების ჯგუფის სახით საგანგებო სიტუაციებში სხვადასხვა ოპერაციათა მხარდაჭერისათვის. უპილოტო მიწისზედა ტრანსპორტის სისტემის გამოყენება სხვადასხვა მრავალჯერადი დავალების შესრულებისას კოოპერაციის, კოორდინაციისა და მოქნილი კოლაბორაციის საშუალებას იძლევა. რობოტული ჯგუფისათვის, დავალების შესრულების ფარგლებში სტრუქტურული თუ ფუნქციური გადაწყობის მეშვეობით, უპილოტო მიწისზედა ტრანსპორტს შეუძლია უზრუნველყოს გარემო ფაქტორებისაგან სავარაუდო საშიშროების თავიდან არიდება ან მისი შემცირება.

ჩვენი მიზანია ხელოვნური ინტელექტის მეთოდებზე, განსაკუთრებით, გროვის ქცევის მოდელირებისა და კოლექტიური ინტელექტის კონცეფციაზე დაფუძნებული ახალი მიდგომების შემუშავება - ფიზიკური თუ გარემო რისკების მონიტორინგისა და შეფასების, რობოტების ჯგუფის ადაპტური მართვის (მათ შორის, უპილოტო მიწისზედა ტრანსპორტის სისტემის), განუსაზღვრელ პირობებში ნავიგაციის, საგანგებო სიტუაციებში სამაშველო თუ სხვა ოპერაციათა მხარდაჭერის, ასევე აგრესიულ თუ მტრულ გარემოში სამხედრო ამოცანების შესრულების თვალსაზრისით.

### **კვლევის სიახლე**

კვლევის მთავარ სიახლეს წარმოადგენს სოციალური სისტემების კოლექტიურ ქცევებთან დაკავშირებული სამეცნიერო კონცეფციების შემუშავება და განვითარება. მრავალმიზნობრივი ევოლუციური ალგორითმები (გენეტიკური ალგორითმები, ნაწილაკთა გროვის ოპტიმიზაცია, ჭიანჭველების კოლონიის ოპტიმიზაცია და სხვ.), აგრეთვე პარალელური გამოთვლების მიდგომები და გადაწყვეტილების მიღების თანამედროვე პროცედურები ეფუძნება მულტი-აგენტური მოდელირებისა და დისკრეტულ ხდომილობათა მოდელირების მეთოდებს. ჩვენს მიერ შემუშავებული მიდგომები შეიძლება განვიხილოთ როგორც ახალი საინჟინრო გამოთვლითი პარადიგმა, რომელიც ემყარება დინამიური სისტემებისათვის დამახასიათებელ ენტროპიისა და სინერჯის ცნებებს. თუ განვიხილავთ რთულ სისტემას, როგორც ინტერაქტულ, მულტი-აგენტურ ჰეტეროგენულ ქაოტურ სისტემას მრავალგანზომილებიანი, რთული იერარქიული სტრუქტურით, მაშინ მისი მოდელირება წარმოადგენს ურთულეს პრობლემას. ეს განპირობებულია ადამიანის, როგორც არაწრფივი და არამკაფიო ფაქტორის არსებობით, რაც შესაბამისად დაკავშირებულია ქცევის თავისუფლების მეტად მაღალ ხარისხთან. მოცემულ კონტექსტში გროვის მოდელის აგება და მისი ოპტიმიზაცია შესაძლებელია ენტროპიის მინიმიზაციის კრიტერიუმის მიხედვით.

## კვლევის შედეგები

ჩვენ შევიმუშავეთ მულტი-რობოტული სისტემის მართვის ახლებური მიდგომა. ამისთვის გამოვიყენეთ კოლექტიური ინტელექტის მეთოდები, კერძოდ, ნაწილაკების გროვის ოპტიმიზაციის მეთოდი (PSO). ჩვენი მიდგომა, ორიგინალი მიდგომისგან განსხვავებით, გლობალური ოპტიმუმთან ერთად პოულობს ლოკალურ ოპტიმუმებსაც.

ალგორითმი არის იტერაციული და შედეგა რამდენიმე ბიჯისგან: ინიციალიზაცია, კლასტერიზაცია, განახლება, კლასტერების შეერთება (არააუცილებელი ბიჯი) და დასრულების კრიტერიუმის შემოწმება.

სივრცულად განაწილებული მულტი-რობოტული სისტემის ქცევა რობოტების ინდივიდუალური, ავტონომიური ქმედებებით არის განპირობებული. სამიზნე არეში ნაწილაკების მოძრაობა განისაზღვრება მათი საუკეთესო პოზიციით, რომელიც ამავედროულად მთლიანი სისტემის საუკეთესო პოზიციასაც განაპირობებს.

მიდგომაში შემოტანილია ლიდერი და აუტოსაიდერი რობოტების ცნებები და მათი შერჩევის კრიტერიუმები. აღსანიშნავია, რომ ალგორითმის მუშაობის პროცესში შესაძლებელია რობოტების როლების შეცვლა, ანუ ლიდერი რობოტი შეიძლება გახდეს აუტოსაიდერი და პირიქით.

დიდი ინფორმაციის სწრაფად დამუშავების მიზნით მოვახდინეთ სამიზნე არის კლასტერიზაცია. კლასტერიზაცია წარმოადგენს დიდ მონაცემთა სწრაფად მოპოვებისა და დამუშავების მძლავრ მექანიზმს. კლასტერიზაციას ვახდენთ ლიდერი რობოტებისა და K-Means ალგორითმის გამოყენებით.

კლასიკური ოპტიმიზაციის ალგორითმებისგან განსხვავებით, ჩვენს ალგორითმში დინამიურად გამოითვლება ალგორითმის დასრულების კრიტერიუმები. იგი დამოკიდებულია გროვის მდგომარეობასა და მოთხოვნილ სიზუსტეზე. პარამეტრების დინამიურად შერჩევა უმეტეს შემთხვევაში უფრო ეფექტურს ხდის ჩვენს ალგორითმს, რადგან ორი

ურთიერთ საწინააღმდეგო ცნებიდან - დრო და სიზუსტე, საჭიროა დაბალანსება და კომპრომისზე წასვლა.

## სადისერტაციო ნაშრომის მოკლე შინაარსი

სადისერტაციო ნაშრომი შედგება შვიდი თავისგან:

**პირველ თავში** მოცემულია ლიტერატურის მიმოხილვა - არსებული წარმოდგენების და მოდელების განხილვა და ანალიზი, მკვლევარების ნაშრომები, მოსაზრებები და შეფასებები.

**მეორე თავში** აღწერილია საგნობრივი სფერო, კვლევის აქტუალურობა და მნიშვნელობა, კვლევის მიზანი და სიახლე. ასევე, აღწერილია მულტი-რობოტული სისტემა და მისი ოპტიმიზაციის ამოცანები, როგორც ჩვენი კვლევის მთავარი ინსტუმენტი.

*მულტი-რობოტული სისტემები.* ხელოვნური ინტელექტის ერთ-ერთ უახლეს მიმართულებას წარმოადგენს *მულტი-აგენტური სისტემების (მას) მეთოდი*, რომელიც განიხილება როგორც გადაწყვეტილების მიღების ეფექტური საშუალება ცალკეული თუ ერთობლივი მიზნების მისაღწევად. ზოგადად, აგენტი არის რაიმე მიზნით აღჭურვილი ობიექტი (არსება), კონკრეტულად ამ სისტემისთვის კი, იგი წარმოადგენს მოაზროვნე, გადაწყვეტილების მიმღებ და მის შემსრულებელ ობიექტს, რომელიც გამოიყენება სხვადასხვა რთული ამოცანების გადასაწყვეტად მოცემულ გარემოში. გროვა კი, თავის მხრივ, წარმოადგენს საერთო მიზნით გაერთიანებული აგენტების სიმრავლეს. მულტი-აგენტური სისტემები გამოიყენება ისეთი ამოცანების გადასაწყვეტად რომელთა ამოხსნაც ძალიან რთულია ან შეუძლებელია ერთი აგენტის მიერ. აღნიშნული სისტემები შედგება ავტონომიური აგენტებისგან, რომლებსაც არ გააჩნიათ სისტემის გლობალური ცოდნა და საერთო მიზნის მიღწევისთვის ოპერირებენ შეზღუდული ცოდნით და შესაძლებლობებით. სისტემა დაფუძნებულია

კოლექტიური ინტელექტის მეთოდებზე, რომელიც თავის მხრივ ეფუძნება ბიოლოგიური არსებების კოლექტიური ქცევის თვისებას.

მულტი-რობოტული სისტემა არის მულტი-აგენტური სისტემა, რომელიც შედგება ფიზიკური აგენტ-რობოტებისგან. იგი მთლიანად იზიარებს მას-ის მიდგომებსა და კონცეფციებს და მათ განიხილავს ფიზიკური რობოტების ჭრილში.


**მესამე თავში** მოცემულია ოპტიმიზაციის ამოცანის ფორმალიზაცია, ასევე, შემოტანილია ენტოპიის და სინერჯიის ცნებები, როგორც სისტემის ქაოტურობის ზომა და განხილულია მონაცემთა კლასტერიზაციის ზოგადი და ჩვენს მიერ გამოყენებული მიდგომები.

*ოპტიმიზაციის ამოცანა.* ჩვენი სამყაროს ერთ-ერთი ფუნდამენტური პრინციპი არის ოპტიმალური მდგომარეობის ძიება. ის ემყარება ფიზიკის კანონებს, იწყება მიკრო სამყაროდან (ატომი) და მთავრდება მაკრო სამყაროში. ზუსტად იგივე წესებით და მიზნებით ხელმძღვანელობს ბიოლოგიური პრინციპი „ძლიერის გადარჩენა“ (survival of the fittest), რომელიც ბიოლოგიურ ევოლუციასთან ერთად იძენს გარემო პირობებთან უკეთ ადაპტირების უნარს. აქ, ლოკალურ ოპტიმუმს წარმოადგენს გარემოსთან კარგად შეგუებული სახეობები, რომლებიც დომინირებენ სხვა სახეობებზე მოცემულ გარემოში. ეს მიდგომები, როგორც ყველა მნიშვნელოვანი, ზოგადი და აბსტრაქტული რამ სამყაროში, აღიწერება მათემატიკური მოდელით. გლობალური ოპტიმიზაცია არის მეთოდი, რომელიც ორიენტირებულია ოპტიმიზაციის ამოცანების გადაწყვეტაზე და ამ მიზნით, იგი იყენებს აღნიშნულ მათემატიკურ მოდელს და რიცხვით ანალიზს. მისი მიზანია იპოვოს საუკეთესო  $x^*$  ელემენტი  $X$  სიმრავლიდან შემდეგ კრიტერიუმებზე დაყრდნობით  $F = \{f_1, f_2 \dots f_n\}$ . ეს კრიტერიუმები წარმოადგენილია მათემატიკური ფუნქციების საშუალებით და მათ ეწოდებათ „მიზნობრივი ფუნქციები“ (Objective functions).



*ენტროპია მულტი-აგენტურ სისტემებში.* სადისერტაციო ნაშრომში ჩვენ განვიხილავთ მობილური სენსორული ჯგუფის ქცევის ხარისხის შეფასების რამდენიმე კრიტერიუმს, როგორებიცაა მოწესრიგებულობა (სინერგია) და მოუწესრიგებლობა (ენტროპია), ოპტიმიზაციის კუთხით. ეს პარამეტრები დაგვეხმარება შევაფასოთ ჯგუფის ქცევის წარმადობის ხარისხი. სისტემის ნებისმიერი ქმედება შეიძლება აღიწეროს როგორც ერთი მდგომარეობიდან მეორეში გადასვლა, რაც მჭიდროდ არის დაკავშირებული ენტროპიის ცვლილებასთან. თერმოდინამიკურ სისტემებში ენტროპია ასოცირდება მოწესრიგებულობის, მოუწესრიგებლობის, ან/და ქაოსის რაოდენობასთან (ხარისხთან). მოუწესრიგებლობა შეიძლება წარმოვიდგინოთ, როგორც დეზორიენტირებული აგენტის ქმედების ვექტორი. ამ საკითხთან მიმართებაში ჩვენ გვანტერესებს რობოტების გროვის ინდივიდების ერთობლივი ქმედება, რომელიც უზრუნველყოფს მთლიანი სისტემის საერთო მიზნისკენ სწრაფვას. რეალურ სისტემებში დიდი მნიშვნელობა ენიჭება გროვის ზომას (რაც ფინანსურ ხარჯებთან არის დაკავშირებული), გროვის მიერ მოხმარებულ ენერგიას და დროს. აღნიშნული პარამეტრების სწორად შერჩევით შესაძლებელია დასმული ამოცანის ოპტიმალური გადაწყვეტა მივიღოთ. ენტროპიის, რიგის და საშუალო კუთხური სიჩქარის პარამეტრების შემოტანით სისტემაში, შეიძლება განისაზღვროს ჯგუფის პოზიციური განლაგება და ენერგიის მოხმარება. ენერგიის მოხმარების განსაზღვრისათვის ზოგიერთ შემთხვევაში ასევე გამოიყენება დამატებითი პარამეტრი - გადაადგილების საშუალო სიჩქარე.

*კლასტერიზაცია.* კლასტერიზაცია არის მონაცემების დაჯგუფება (დაყოფა) ობიექტების მსგავსობის მიხედვით, რომლის ევოლუციური პროცესი წარმოდგენილია სურათი 1-ზე. თითოეული ჯგუფი, ანუ კლასტერი, შეიცავს მსგავს ობიექტებს ჯგუფის შიგნით და სხვა ჯგუფებისგან განსხვავებულ ობიექტებს.



სურათი 1. კლასტერიზაციის ევოლუციური პროცესი

კლასტერული ანალიზის როლი მნიშვნელოვანია სხვადასხვა სფეროში, ინჟინერია (მანქანური სწავლება, ხელოვნური ინტელექტი, გამოსახულების ამოცნობა), კომპიუტერული მეცნიერებები (ინფორმაციის ძიება ინტერნეტში, ტექსტური და გრაფიკული მონაცემების მოძიება-ფრაგმენტაცია), მედიცინა, საბუნებისმეტყველო და სოციალური მეცნიერებები. ასევე აქტუალურია სტატისტიკაში, გრაფთა თეორიაში, ხელოვნურ ნეირონულ ქსელებში, ევოლუციურ გამოთვლებსა და სხვა ოპტიმიზაციის ამოცანებში.

**მეოთხე თავში** განხილულია ევოლუციური ალგორითმები, მათი ისტორიული განვითარება, აგებისა და გამოყენების ხერხები. აღნიშნულ თავში განსაკუთრებული ყურადღება ეთმობა PSO-ს, რადგან სწორედ ამ მიდგომას ვიყენებთ მულტი-რობოტული სისტემის მართვაში.

**ევოლუციური ალგორითმები.** ცოცხალი ორგანიზმების ქცევების ანალიზის საფუძველზე შეიქმნა მეთოდების მთელი კლასი, რომელსაც ხელოვნური ინტელექტი (AI) უწოდეს. მასში გაერთიანებულია მრავალი ოპტიმიზაციის ალგორითმი, რომელთაც გააჩნიათ სწავლისა და გადაწყვეტილების მიღების უნარი. ბუნებრივ ევოლუციას და ახალ გარემოსთან ადაპტაციას ეს ალგორითმები განიხილავენ, როგორც სწავლის პროცესს და პრინციპი „სახეობაში ძლიერთა გადარჩენა“ (survival of the fittest), გამოიყენება ალგორითმის მიერ ოპტიმიზაციისა და სასურველი შედეგის მიღებისათვის. სწორედ ასეთ ალგორითმებს უწოდებენ ევოლუციურ ალგორითმებს (EA). ევოლუციური ალგორითმები არის პოპულაციაზე დაფუძნებული ალგორითმები და ისინი იყენებენ ბიოლოგიური

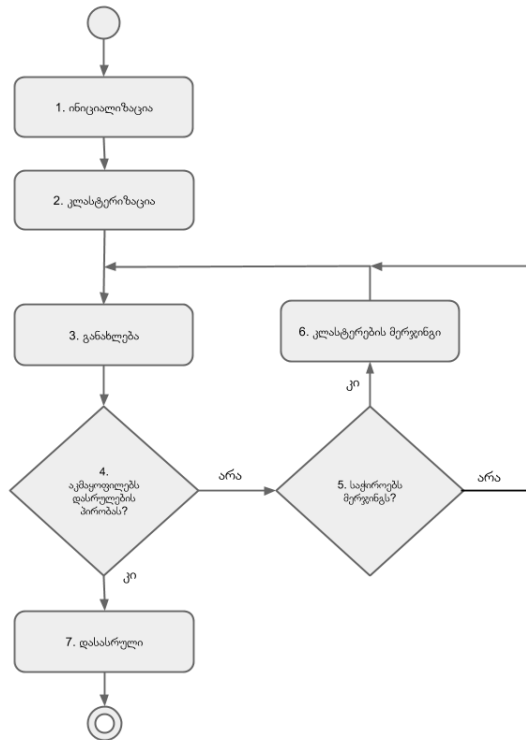
ევოლუციის ელემენტებს, როგორებიცაა: გამრავლება, მუტაცია, რეკომბინაცია, ბუნებრივი სელექცია და „სახეობაში ძლიერთა გადარჩენა“. EA-პოპულაციის ინდივიდებს იყენებს საპრობლემო არის პარალელური შესწავლის მიზნით. თითოეული ინდივიდი წარმოადგენს საპრობლემო არის შესაძლო ამონახსნს, ამიტომ ოპტიმალური ამონახსნის მისაღებად ხდება ძლიერი და სუსტი ინდივიდების გადარჩევა.

**მეხუთე და მეექვსე თავებში** განხილულია მულტი-რობოტული სისტემის მართვის ახლებური, ჩვენს მიერ შემუშავებული მიდგომა. დეტალურად არის აღწერილი მართვის ალგორითმის თითოეული ბიჯი, ამ ბიჯების შესრულების პირობები და ალგორითმის დასრულების კრიტერიუმები. ასევე, მოცემულია ჩვენი მიდგომის და კლასიკურ მეთოდების შედარებითი ანალიზი. აღწერილია ჩვენს მიერ ჩატარებული ექსპერიმენტი და წარმოდგენილია მიღებული შედეგების შეფასება და ანალიზი.

ქვემოთ მოყვანილია მულტი-რობოტული სისტემების მართვის ახლებური მიდგომა.

### **მულტი-რობოტული სისტემის მართვის ახლებური მიდგომა**

PSO-ს პარადიგმების მიხედვით, საძიებო არეში მოძრავი გროვის ნებისმიერი ნაწილაკი წარმოადგენს ოპტიმიზაციის ამოცანის პოცენციურ ამონახსნს. ალგორითმის მიზანია ნაწილაკების შეგროვება მიზნობრივი ფუნქციის გლობალურ (მთელი საძიებო არე) და ლოკალურ (კონკრეტული კლასტერი) ოპტიმუმებში. ალგორითმის მუშაობის სქემა მოიცავს რამდენიმე ბიჯს (სურათი 2):



სურათი 2. სენსორული რობოტების ჯგუფის მართვის ბლოკ-სქემა

### ინიციალიზაცია

თითოეულ ნაწილაკს სამი თვისება გააჩნია:

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

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

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:

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

ინიციალიზაციის დროს უნდა განისაზღვროს საწყისი პარამეტრები: გროვის ზომა  $N$ , წონის პარამეტრები  $c_1$ ,  $c_2$ , რომელთაც შემეცნებით და სოციალურ პარამეტრებსაც უწოდებენ, საძიებო არის საზღვრები  $x_{min}$ ,  $x_{max}$ ,  $y_{min}$ ,  $y_{max}$  და ალგორითმის შეწყვეტის კრიტერიუმები  $G$ ,  $\mu$ . რა თქმა უნდა, თავდაპირველად  $k=0$ . ამის შემდეგ, წინასწარ განსაზღვრულ არეში, უნდა დავსვათ  $N$  რაოდენობის ნაწილაკი შემთხვევითად დაგენერირებულ პოზიციებზე (სურათი 3).

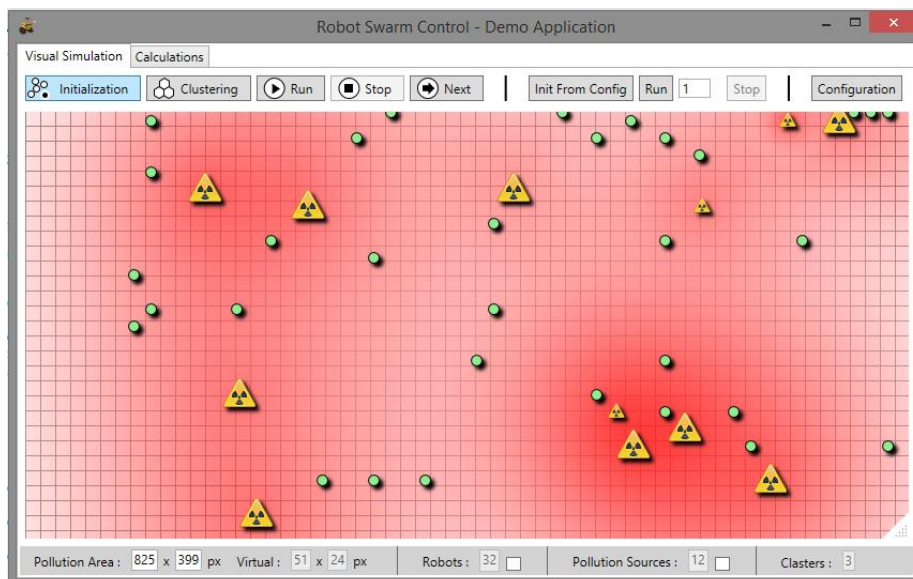
$$p_0^i = p_{min} + rand(p_{max} - p_{min}). \quad (3)$$

სადაც,  $p_{min}$  და  $p_{max}$  წარმოადგენს საძიებო არის შესაბამის მინიმალურ და მაქსიმალურ ლიმიტებს.

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

$$v_0^i = \frac{p_{min} + rand(p_{max} - p_{min})}{\Delta t} \quad (4)$$


ქვემოთ თანდართულ სურათი 3 - ზე წარმოდგენილია ნაწილაკების გროვის ინიციალიზაციის პროცესის გრაფიკული გამოსახულება.



სურათი 3. შემთხვევითად განაწილებული ნაწილაკები რადიაციის წყაროებთან

 - რობოტი;

 - რადიაციის წყარო;


 - წითელი ფონი სურათზე აღნიშნავს რადიაციის გავრცელების არეალს.

### **კლასტერიზაცია**

როგორც ზემოთ აღვნიშნეთ, მიზნობრივი ფუნქციის ლანდშაფტის ზონებად დაყოფისა და ლოკალური ექსტრემუმების პოვნის ამოცანის გადაწყვეტა ნიშნავს კლასტერული ანალიზის ჩატარებას, რაც ასევე შეიძლება იქნას გამოყენებული პროგნოზირებისთვის და სწორი გადაწყვეტილების მიღებისათვის. ეს კი საჭიროებს მრავალი სხვადასხვა სახის მონაცემების სწრაფი და ავტომატიზებული კლასტერიზაციის მექანიზმს. კლასიკური კლასტერიზაციის მეთოდებით კი ამ დონის ოპტიმიზაცია შეუძლებელია. ბიო-ინსპირირებული ოჯახის ალგორითმებმა, კერძოდ კოლექტიურ ინტელექტზე დაფუძნებულმა მეთოდებმა, უკეთესი შედეგი აჩვენეს ბევრ კლასიკურ მეთოდებთან შედარებით.

კლასტერიზაციისთვის აუცილებელია თითოეული ნაწილაკისთვის საწყის კოორდინატებში ფიტნეს ფუნქციის გამოთვლა. ფიტნეს ფუნქციის საფუძველზე, ანუ საუკეთესო პოზიციებზე, ირჩევა  $M$  რაოდენობის ლიდერი ნაწილაკები, დანარჩენი წაილაკები კი ავტომატურად ხდებიან აუთსაიდერები (სურათი 4).

$$l_j = \{p_k^j\}, j = 1, 2, \dots, M. \quad (5)$$



სურათი 4. ლიდერების არჩევა

ლიდერების არჩევა შემდეგნაირად ხდება: იგება გრაფიკი, სადაც აბსცისთა ღერძზე განლაგდება ნაწილაკები ( $p$ ) დალაგებული რადიაციის დონის კლებადობის მიხედვით, ხოლო ორდინატთა ღერძზე გადაიზომება რადიაციის დონეებს შორის დისტანციები ( $d$ ). ვიმახსოვრებთ თითოეულ კოორდინატს ( $p, d$ ), რომელიც შეესაბამება  $p$  ნაწილაკს  $d$  რადიაციის დონის სხვაობით. რა თქმა უნდა, კოორდინატთა სათავეში მოხვდება  $p_1$  ნაწილაკი რადიაციის მაქსიმალური დონით.

$$r_1 = r_{max}; \quad r_i = f(p_i), \quad i = 1, 2, \dots, N. \quad (6)$$

$$d_i = r_{max} - r_i \quad (7)$$

$$\bar{d} = \frac{\sum_{i=1}^N d_i}{N}; \quad \bar{d}_i = \frac{\sum d_i}{i} \quad (8)$$

ამის შემდეგ, კოორდინატთა სათავიდან აიგება წრფე, შემდეგი ფორმულით:

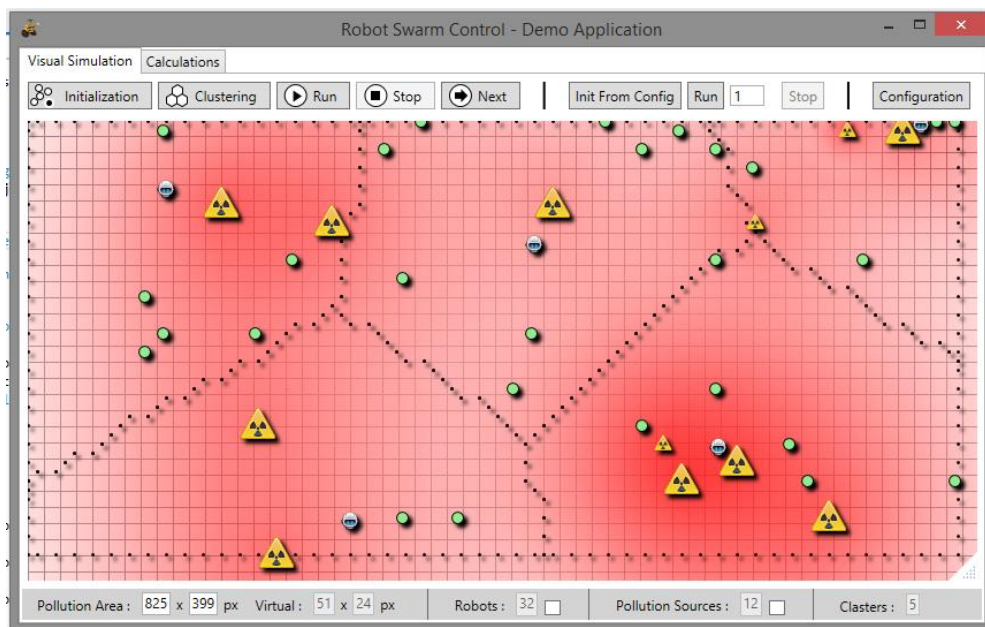
$$\tan \alpha = \frac{\sum_{i=1}^N r_i}{N(r_{max} - r_N)} \quad (9)$$

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



$$p_i \equiv \begin{cases} d_i \leq \bar{d}_i & - \text{leader} \\ \text{otherwise} & - \text{outsider} \end{cases} \quad (10)$$

მას შემდეგ, რაც მოხდება ლიდერების არჩევა, გადავდივართ კლასტერების ფორმირებაზე. კლასტერიზაცია ხდება K-Means ალგორითმის გამოყენებით. კერძოდ, კლასტერის ცენტროიდებად ვირჩევთ ლიდერ ნაწილაკებს და ამ ცენტროიდებიდან აუტსაიდერ ნაწილაკებამდე მანძილების ანალიზით ხდება კლასტერებში აუტსაიდერების განაწილება (სურათი 5). K-Means ალგორითმისგან განსხვავებით, ჩვენს მიდგომაში კლასტერის ცენტრების დინამიური ცვლილება არ ხდება. თითოეულ კლასტერში ნაწილაკებს შორის ურთიერთობის ფორმა „star“ - ტოპოლოგიით გვაქვს განსაზღვრული. ანუ, თითოეულ აუტსაიდერ ნაწილაკს კავშირი აქვს მხოლოდ ლიდერ ნაწილაკთან.

სურათი 5 - ზე გრაფიკულად გამოსახულია ლიდერი რობოტების არჩევისა და კლასტერების ფორმირების მაგალითი. სურათზე პუნქტირით შემოსაზღვრული რეგიონები წარმოადგენენ კლასტერებს.



სურათი 5. კლასტერიზაცია

-  - ლიდერი რობოტი;
-  - აუტსაიდერი რობოტი;





- რადიაციის წყარო;



- წითელი ფონი სურათზე აღნიშნავს რადიაციის გავრცელების არეალს.

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

$$\underset{L}{\operatorname{argmin}} = \sum_{l=1}^M \sum_{p_k^i \in L} \|p_k^i - p_k^l\|^2 \quad (11)$$

### განახლება

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

$$v_{k+1}^l = wv_k^l + c_1 \operatorname{rand} \frac{(p_k^l - p_k^i)}{\Delta t} + c_2 \operatorname{rand} \frac{(p_k^g - p_k^i)}{\Delta t} \quad (12)$$

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 შვენს მიდგომაში ეს პარამეტრები ყოველ იტერაციაზე ზუსტდება, რაც უფრო ეფექტურ შედეგს იძლევა სტანდარტულ მეთოდთან შედარებით:

$$c_1 = p_k^l / p_k^i, \quad c_2 = 1 - c_1. \quad (13)$$

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:

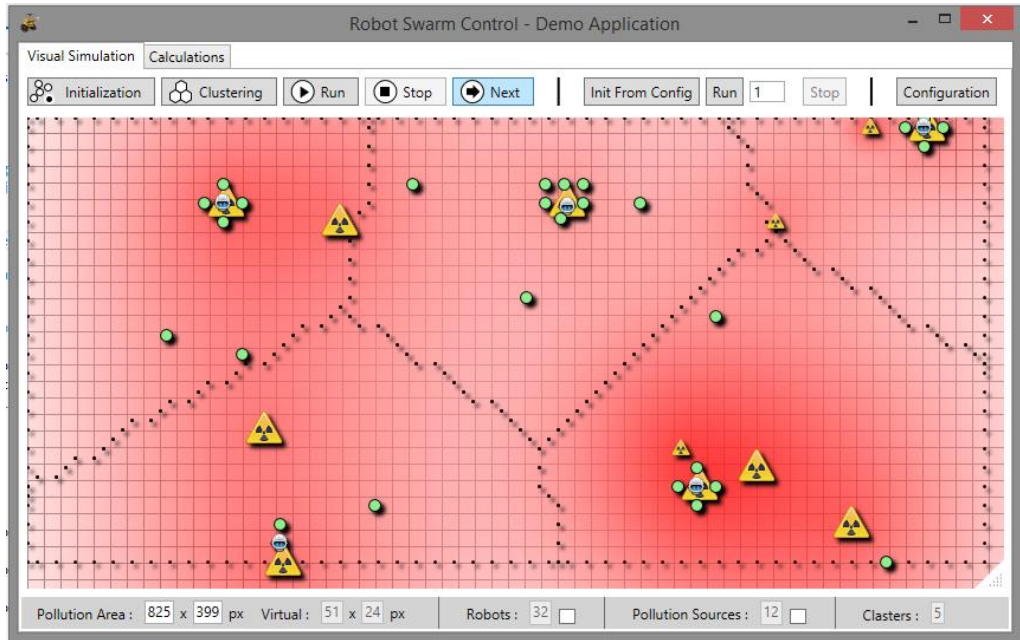
$$p_{k+1}^i = p_k^i + v_{k+1}^i \Delta t \quad (14)$$

თითოეულ იტერაციაზე, ნაწილაკების სიჩქარისა და პოზიციის განახლების შემდეგ, ხდება ნაწილაკების და გროვის საუკეთესო პოზიციების განახლება. გროვის საუკეთესო პოზიცია განისაზღვრება ლიდერების საუკეთესო პოზიციებით და დგინდება შემდეგნაირად:

$$l_{k+1}^r = p_{k+1}^g = [x_{k+1}^g, y_{k+1}^g], \quad r = 1, 2, \dots, M. \quad (15)$$

$$p_{k+1}^g \equiv \begin{cases} p_{k+1}^i & \text{if } f(p_{k+1}^i) \leq f(p_k^g), \\ p_k^g & \text{Otherwise} \end{cases} \quad (16)$$

სურათი 6 - ზე გრაფიკულად გამოსახულია რობოტების განლაგება და გროვის მდგომარეობა  $k$ -ურ ბიჯზე.



სურათი 6. გროვის მდგომარეობა  $k$ -ურ ბიჯზე

### კლასტერების გაერთიანება

კლასტერების გაერთიანება არ არის აუცილებელი პროცესი და ხდება მხოლოდ იმ შემთხვევაში, როცა ლიდერი ნაწილაკი იმყოფება კლასტერის საზღვარზე და გადაადგილების შემდეგი ბიჯის ლოკაცია ეკუთვნის მეორე კლასტერს. კლასტერების გაერთიანების შემდეგ ახალ კლასტერში ხდება ახალი ლიდერის არჩევა და ყველა ნაწილაკისათვის - „განახლება“ ბიჯის გამეორება.

### ალგორითმის შეწყვეტა

ალგორითმის შემოწმება შეწყვეტის კრიტერიუმებზე ხორციელდება რამდენიმე ეტაპით:

**I ეტაპზე** დგინდება მოძრაობისას რამდენად აუმჯობესებს ლიდერი საუკეთესო პოზიციას:

$$\partial_{k+1} = |f(\mathbf{p}_{k+1}^g) - f(\mathbf{p}_k^g)| \leq \mu \quad (17)$$


სადაც,  $\mu$  - არის წინასწარ განსაზღვრული ბიჯი.

**II ეტაპზე** დგინდება ლიდერი რობოტის მიმართ კლასტერში ნაწილაკების შეჯგუფების ხარისხი:

$$D = \frac{1}{N} \sum_{l=1}^N \sqrt{|p_k^i - p_k^j|^2} \leq G \quad (18)$$

სადაც,  $p_{k+1}^c$ - არის შეჯგუფების ცენტრალური წერტილი (სურათი 7).

$$p_{k+1}^c = \frac{1}{Q} \sum_{l=1}^Q \sqrt{|p_{k+1}^c - p_{k+1}^i|^2}, \quad i \neq j. \quad (19)$$

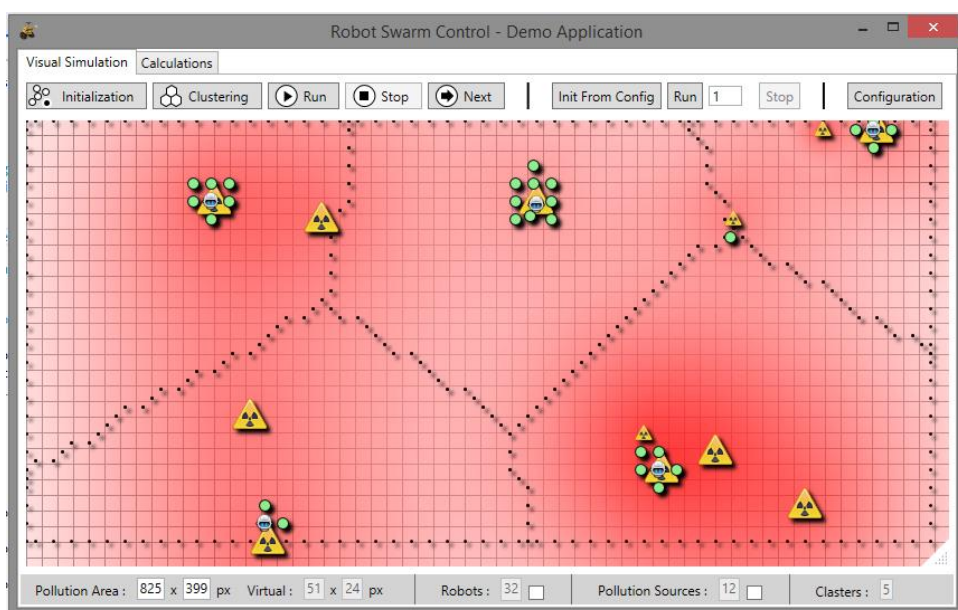


სურათი 7. შეჯგუფების ცენტრალური წერტილი

III ბოლო ეტაპზე დგინდება აღნიშნული კომპონენტების ფუნქციის მნიშვნელობა:

$$S = \theta_{k+1} + D \Rightarrow \min. \quad (20)$$

იმ შემთხვევაში, თუ, კმაყოფილდება ზემოთ აღწერილი კრიტერიუმი, მაშინ ალგორითმი წყვეტს მუშაობას და გამოგვაქვს შედეგი (სურათი 8), წინააღმდეგ შემთხვევაში ალგორითმი იწყებს ახალ იტერაციას „განახლება“ ბიჯზე გადასვლით.



სურათი 8. საბოლოო მდგომარეობა

## ახლებური მიდგომის უპირატესობები

კლასიკური PSO-თან შედარებით ჩვენს ალგორითმს აქვს რამდენიმე უპირატესობა:

**დინამიური პარამეტრები** - კლასიკურ მიდგომაში გროვის პარამეტრები ინიციალიზაციის შემდეგ არ იცვლება, ამიტომ ძალზე მნიშვნელოვანია ყველა პარამეტრის საფუძვლიანად შერჩევა. ჩვენს მოდელში კი, პარამეტრების დიდი ნაწილი დინამიურად გამოითვლება იტერაციების და გროვის მდგომარეობის მიხედვით.


**გროვის ზომა** - რობოტების ოპტიმალური რაოდენობის დასადგენად ჩვენ მოვახდინეთ კონფლიქტური კრიტერიუმების (რაოდენობრივი შეზღუდვა, ენერგო შეზღუდვა და დრო) ოპტიმიზაცია და აღნიშნული შეზღუდვების გათვალისწინებით შევიმუშავეთ რაოდენობის დინამიურად დადგენის ფორმულა.

**კლასტერიზაცია/გაერთიანება** - ალგორითმში შემოთავაზებულია კლასტერიზაციის ჩვენებური მიდგომა, კერძოდ - კლასტერის ცენტროიდების არჩევა. ამისათვის შემოტანილია ლიდერი და აუთსაიდერი რობოტების ცნებები და აღწერილია ლიდერების შერჩევის კრიტერიუმები.

ალგორითმში კლასტერიზაცია, ისევე როგორც კლასტერების გაერთიანება, ხდება საძიებო არის ნაწილაკების სტატუსის მიხედვით. შესაბამისად, ძიება ხდება არა მთელ არეალზე, არამედ თითოეული კლასტერის შიგნით, რაც გვაძლევს ოპტიმუმების სწრაფად პოვნის საშუალებას, ალგორითმის შესრულების პროცესს ხდის მარტივად დაპარალელებადს და მოიხმარს ნაკლებ მანქანურ რესურსს განაწილებულ სისტემებში.


**ტოპოლოგია** - ალგორითმში გამოყენებულია კლასიკური PSO-ს ტოპოლოგიებიდან ორის ნაზავი. კერძოდ, კლასტერებში რობოტებს შორის კავშირი განისაზღვრება „Star“ ტოპოლოგიით, ხოლო თავის მხრივ, კლასტერები ქმნიან „lBest“ ტოპოლოგიას, რაც აადვილებს კომუნიკაციას და

ასევე, ზოგავს მეხსიერების და მონაცემთა გაცვლის ქსელურ რესურსებს (სურათი 9).



სურათი 9. ალგორითმში გამოყენებული ტოპოლოგიის სქემა

მრავალმიზნობრივი ოპტიმიზაცია - ალგორითმში ხდება რამდენიმე კონფლიქტური კრიტერიუმების ოპტიმიზაცია, ასევე კლასიკური ნაწილაკების გროვის ოპტიმიზაციისგან (PSO) განსხვავებით, გლობალური ოპტიუმის გარდა ალგორითმი პოულობს ლოკალურ ოპტიუმებსაც (იხ. სურათი 10).



სურათი 10. საძიებო არის ლოკალური და გლობალური ოპტიუმები

მეშვიდე თავი მოიცავს ნაშრომის დასკვნას.

## დასკვნა

სადისერტაციო ნაშრომში „კოლექტიური ინტელექტის მეთოდების გამოყენება მულტი-რობოტული სისტემების მართვაში“, ჩვენ დავსვით საკმაოდ აქტუალური ამოცანა, მიმოვიხილეთ მისი გადაჭრის არსებული მეთოდები, ვაჩვენეთ პრობლემური მხარეები და წარმოვადგინეთ ჩვენი მიდგომა, რომელიც ვთვლით, რომ უფრო ოპტიმალურია და უმეტეს შემთხვევებში უკეთეს შედეგს იძლევა.

ალგორითმის პრაქტიკული გამოყენება შესაძლებლობას იძლევა, განხორციელდეს გარემოს დაბინძურების, განსაკუთრებით ატომური ენერგეტიკით, მონიტორინგი, რაც მიიღწევა მობილური, უკაბელო სენსორული ქსელიდან ინფორმაციის უწყვეტად მიღებით და ამ ინფორმაციის შეგროვება-დამუშავებით.

საკმაო ლიტერატურის გადამუშავების შედეგად მივედით დასკვნამდე, რომ ასეთი სახის ამოცანებისთვის უკეთესია გამოვიყენოთ ევოლუციური ალგორითმებით მართვადი მულტი-რობოტული სისტემა. ჩვენ განვსაზღვრეთ ამ სისტემის პარამეტრები და შევიმუშავეთ მისი მართვის სტრატეგიები.

ნაშრომში განხილულია რამდენიმე ევოლუციური ალგორითმი, რომელთაგან ამოსავალ წერტილად ავიღეთ ნაწილაკების გროვის ოპტიმიზაციის მეთოდები. ნაშრომში წარმოვადგინეთ PSO-ზე დაფუძნებული ადაპტური ალგორითმი, რომელიც ორიგინალი მიდგომისგან განსხვავებით გლობალურ ოპტიმუმთან ერთად პოულობს ლოკალურ ოპტიმუმებსაც. ალგორითმში პატარ-პატარა ამოცანების გადასაწყვეტად კი მოვიშველიეთ ეფექტური და კარგად ნაცნობი კლასტერიზაციის, მოძრაობისა და ენერჯის დაზოგვის ალგორითმები. ჩვენ გვჯერა და ჩვენს მიერ ჩატარებულმა ექსპერიმენტის შედეგებმაც ცხადყო, რომ ჩვენს მიერ შემუშავებულ ალგორითმს შეუძლია სწრაფად მოძებნოს ოპტიმალური შედეგი გარემო პირობების მუდმივად ცვლილების დროსაც კი.

ნაშრომის ექსპერიმენტულ ნაწილში მოცემულია ნაწილაკთა გროვის ოპტიმიზაციის მოდიფიცირებული ალგორითმის ექსპერიმენტის შედეგები და ანალიზი. გამოთვლების შედეგებით დადასტურდა ნაწილაკებზე და კლასტერების შიგნით ფიტნეს ფუნქციის გაუმჯობესება, რაც ავტომატურად ნიშნავს იტერაციების რაოდენობის და დროის დაზოგვას. ექსპერიმენტების შედეგებმა ცხადყო შემუშავებული ალგორითმის ეფექტურობა, მაღალი სიზუსტე და კრებადობა, კლასიკურ მეთოდებთან შედარებით, რაც იყო ჩვენი კვლევის მიზანი და წარმოადგენს დისერტაციის მიღწევას.



## გამოქვეყნებული ნაშრომების სია

1. B.Mefarishvili, P.Petashvili, G.Goderdzishvili. PSO Based Approach to Robot Swarm Control. SENSERA - INTERNATIONAL CONFERENCE. NANOSENSORY SYSTEMS AND NANOMATERIALS, Georgia, Tbilisi, 2013, pp 44-45.
2. B.Mefarishvili, P.Petashvili. ONE APPROACH TO ROBOT SWARM CONTROL. GEORGIAN ENGINEERING NEWS, № 2 (70), 2014, pp 16-20, ISSN 1512-0287.
3. B.Mefarishvili, P.Petashvili, G.Janelidze. ENTROPY-BASED METRICS IN ROBOT SWARM CONTROL. GTU, Transactions, Automated Control Systems, № 2 (18), Tbilisi 2014, pp 7-10, ISSN 1512-3979, EISSN 1512-2174.
4. პ.პეტაშვილი. მონაცემთა კლასტერიზაცია ნაწილაკთა გროვის მეთოდის გამოყენებით. სტუ, შრომები, მართვის ავტომატიზებული სისტემები, № 2 (20), თბილისი 2015წ. გვ.85-89, ISSN 1512-3979, EISSN 1512-2174.
5. B.Mefarishvili, P.Petashvili, G.Janelidze. MULTI-ROBOT CONTROL ALGORITHM FOR MAPPING THE RADIATION AREAS. международная научно-техническая конференция. автоматический контроль и автоматизация производственных процессов, г. Минск 2015 г. стр. 97-101.

## Abstract

The subject of the present paper is one of modern directions of the artificial intelligence – the development of collective intelligence methods and their application for the monitoring of the environmental pollution caused by technogenic disasters, what is important and at the same time, very complex issue. Heavy effects of radiation pollution, especially in the nuclear power and military sectors, have created an increasing demand on instruments that can facilitate to the identification and automatic monitoring of pollution sources, and the establishment of safe areas in case of radiation, chemical and other hazards. Nowadays, the high precision and sensitive equipment that enable detection and monitoring of pollution sources and hazardous zones is demanded.

Necessity of Adaptive Optimization is caused by instability of the environment itself, where change in the distribution area of the Objective Function is dynamic. A Multi-Robot network should be used for a continuous environmental monitoring in order to solve the above defined problem. The Multi-Robot System can be interpreted as a network of autonomous, reconfigurable objects (robots), which are capable to monitor environmental changes.

The present research is based on a wide range of modern methods of the Artificial Intelligence (AI) such as: Evolutionary Algorithms (EAs) and Collective Intelligence, Mathematical Modelling of Collective Behaviour and entropy metrics in multi-objective management.

Evolutionary Algorithms represent models of a natural population and its evolution, where population inhabitants, through their continuous evolution (generation of new population from their predecessors with help of evolutionary operators and the fitness function of individuals), are striving to a desired objective. The distinctive feature of Evolutionary Algorithms is that they can achieve optimal results in any combination of solution candidates. Therefore, future development of Evolutionary Algorithms looks to be promising for effective solution of variety of practical issues.

The Multi-Agent System (MAS) is one of the modern approaches of the Artificial Intelligence, and it can be considered as an effective decision-making tool in the achievement of individual and combined (complex) goals. The paper is based on the Multi-Robot approach being a single case of MAS, which uses mobile robots as its agents.

The main novelty of the research is the introduction of ‘Collective Behaviour of Social Systems’-based concepts in the Multi-Agent Systems approach. Our approaches can be considered as a new computing paradigm, which is based on the Entropy and Synergy concepts relevant to the Dynamic Systems. If we consider a complex system as an interactive, multi-agent heterogeneous chaotic system with multidimensional, compound hierarchical structure, then, creation of the relevant model becomes a complicated issue. The modelling of a complex system, which is interactive, multi-agent heterogeneous, chaotic, multidimensional, with compound hierarchical structure, is an overwhelming task. This is due to the human being, as

a non-linear and uncertain factor, which is characterised with a high degree of freedom of behaviour. In this context, the swarm model can be build and optimized through the minimization of the entropy.

Our goal is the elaboration of new approaches based on artificial intelligence methods - especially swarm behaviour modelling and collective intelligence concept - to be applied in environmental monitoring and risks assessment, adaptive management of the robot swarm (pilotless ground transport system among others), navigation in uncertain conditions, support of emergency response operations and military operations in hostile environment. We have elaborated an innovative approach towards the Multi-Robot system management. The approach is based on the Collective Intelligence, and in particular the Particle Swarm Optimization (PSO) method. Versus to the original algorithm, which can cope only with the global optimum, the proposed one is capable to find both global and local optimums.

The algorithm is iterative and consists of several steps: initialization, clustering, updating, clusters merging (optional) and checking against algorithm completion criteria.

The behaviour of spatial multi-robot system is determined by autonomous actions of individual robots. The movement of elements in the search area is determined by their best possible positions, which on its turn determines the best possible position of the whole system.

For optimal solution of the problem we have introduced the concept of 'Leader' and 'Outsider' robots, and their selection criteria. It should be noted that robots can change their roles during the algorithm processing, i.e. a 'Leader' robot can become 'Outsider' and vice versa.

Further, search area has been clustered to speed-up large-scale data processing. Clustering is acknowledged powerful tool for prompt data mining and processing. We used 'Leader' robots and K-Means algorithms for clustering.

Different from traditional one, our algorithm dynamically computes completion criteria. They depend on a state of the swarm and requested accuracy. In the most cases, the dynamic selection of completion criteria makes our algorithm much more effective, as the logic is based on the balancing of two conflicting parameters such are time and accuracy, and finding of acceptable trade-off in this process.

We do believe, that our algorithm is capable to promptly find an optimal solution even in continuously changing environmental conditions.

Our computations proved that the proposed algorithm substantially reduces the number processing operations, and thus enables to save time and resources. The analysis of the outcomes demonstrated that our algorithm is more effective and accurate than conventional methods. This is what we consider to be the main achievement of our research and the work.