ივ. ჯავახიშვილის სახელობის თბილისის სახელმწიფო უნივერსიტეტი

ხელნაწერის უფლებით

ოგანეზოვი ალექსი

ნეირონული ქსელების გამოყენება სახეთა გამოცნობის ამოცანებში

05.13.11. – გამოთვლითი მანქანების, სისტემების, კომპლექსებისა და ქსელების მათემატიკური და პროგრამული უზრუნველყოფა.

ფიზიკა-მათემატიკის მეცნიერებათა კანდიდატის
სამეცნიერო ხარისხის მოსაპოვებლად წარდგენილი დისერტაციის

ა ვ ტ ო რ ე ფ ე რ ა ტ ი

თბილისი
2006

სადისერტაციო ნაშრომი შესრულებულია ივ. ჯავახიშვილის სახელობის თბილისის სახელმწიფო უნივერსიტეტში.

სამეცნიერო ხელმძღვანელი: **ქოჩლაძე ზურაბი**,
ტექნიკურ მეცნიერებათა კანდიდატი, დოცენტი

ოფიციალური ოპონენტები: **მელაძე ჰამლეტი**,
ფიზიკა-მათემატიკის მეცნიერებათა დოქტორი, პროფესორი

სიხარულიძე ანა,
ფიზიკა-მათემატიკის მეცნიერებათა კანდიდატი

დისერტაციის დაცვა შედგება 2006 წლის 22 დეკემბერს 2006 წ. 14^{00} საათზე ივ. ჯავახიშვილის სახელობის თბილისის სახელმწიფო უნივერსტეტის Ph.M.01.08 №8 სადისერტაციო საბჭოს სხდომაზე. მისამართი: 0043, თბილისი, უნივერსიტეტის ქ. №2, თსუ ი. ვეკუას სახელობის გამოყენებითი მათემატიკის ინსტიტუტი.

დისერტაციის გაცნობა შესაძლებელია ივ. ჯავახიშვილის სახელობის თბილისის სახელმწიფო უნივერსიტეტის ბიბლიოთეკაში. მისამართი: 0043, თბილისი, უნივერსიტეტის ქ. №2.

ავტორეფერატი დაიგზავნა 2006 წლის 20 ნოემბერს 2006 წ.

სადისერტაციო საბჭოს სწავლული მდივანი,
ფიზიკა-მათემატიკის მეცნიერებათა დოქტორი,
პროფესორი /თ. თადუმაძე/

შრომის საერთო დახასიათება.

თემის აქტუალობა. კიბერნეტიკული მეცნიერების ერთერთი ყველაზე აქტუალური და განვითარებადი ტენდენცია ხელოვნური ინტელექტია, რომელშიც გამოირჩევა ორი ძირითადი მიმართულება:

- სიმბოლური (სემიოტური, დამავალი), რომელიც დაფუძნებულია ადამიანის აზროვნების მაღალი დონის პროცესების მოდელირებაზე და ცოდნის გამოყენებაზე;
- ნეიროკიბერნეტიკული (ნეიროქსელური, აღმავალი), რომელიც დაფუძნებულია ტვინის ცალკეული დაბალდონიანი სტრუქტურების (ნეირონების) მოდელირებაზე.

ხელოვნური ინტელექტის ძირითადი ამოცანაა ინტელექტუალური კომპიუტერული სისტემების აგება, რომლებსაც გააჩნიათ არაფორმალიზებული ამოცანების ამოხსნის ეფექტიანობის დონე, რომელიც შესადარია ადამიანის შესაძლებლობებთან ან აღემატება მათ. ნეიროკომპიუტერების შექმნა და ადაპტური ნეირონული ქსელების მოდელირება განიხილება როგორც ყველაზე მნიშვნელოვანი მიმართულება ხელოვნური ინტელექტის მრავალი პრობლემების გადაწყვეტაში.

ამ მიმართულებით გამოკვლევების აქტუალურობა დადასტურებულია სხვადასხვა გამოყენების სიმრავლით, მაგალითად:

მეტყველების და გამოსახულებების გამოცნობის პროცესების ავტომატიზაცია, მათემატიკური თეორემების დამტკიცება, ტექსტის მიხედვით მეტყველების ხელოვნური სინთეზი, საექსპერტო სისტემების შექმნა, ფუნქციონალების აპროქსიმაცია, ტექსტის სამანქანო თარგმნა, საბირჟო ბაზრის ფინანსური მაჩვენებლების პროგნოზი, ბიზნეს პროცესების მართვა, ნეირონული თვითსწავლებადი სისტემების შექმნა და ბევრი რამ სხვა.

ხელოვნური ინტელექტის არეში ერთერთი ამჟამინდელი აქტუალური საკითხია გამოსახულების გამოცნობის პრობლემა პრინციპიალურად ახალი მეთოდების გამოყენებით, რომლებიც იყენებენ ხელოვნურ თვითორგანიზებადი ნეირონულ ქსელებს, ხელნაწერი და ბეჭდვითი ინფორმაციის ელექტრონულ ფორმაში გარდაქმნის განსახორციელებლად. საქართველოში ყველაზე აქტუალური პრობლემაა ქართული ანბანის შრიფტის გამოცნობა.

სამუშაოს მიზანი. მოცემული სამუშაოს მიზანია ხელოვნური მატრიცული-თვითორგანიზებადი ნეირონული ქსელის დაპროექტება და პროგრამული განხორციელებების მოდელირება ნებისმიერი სიმბოლური გამოსახულებების გამოცნობისთვის (კერძოდ, ციფრების, ლათინური და ქართული ანბანების სიმბოლოების), აგრეთვე კლასიფიკაციის მაღალი შედეგის მიღწევა რეცეპტორების მატრიცის მინიმალური შესაძლებელი გარჩევისას და მონაცემთა ბაზის სიმბოლური ელემენტების ყოველი ნაკრებიდან გამოსახულებების წარმომადგენლების მინიმალური რაოდენებით.

კვლევის მეთოდები. ნაშრომში გამოყენებულია ხელოვნურ თვითორგანიზებადი ნეირონული ქსელების მონაცემთა ბაზის გრაფიკული მასივებისთვიხ გამოცნობის პროცესის მასწავლებლის გარეშე გამოყენებით, უკუგავრცელების ალგორითმები, ზონდების მეთოდი, ალბათობის თეორია და სტატისტიკური ანალიზი, კოდირების/დეკოდირების და დისკრეტული სისტემების თეორია, კონცეპტუალური ანალიზი, სიმრავლეების და ობიექტების კლასტერიზაციის/კატეგორიზაციის თეორია, ალგორითმიზაციის მეთოდები, Access-თვის VBA-ში კომპიუტერული მოდელირების მეთოდები და MS Excel-საფუძველზე სტატისტიკური ცხრილები და აგრეთვე ობიექტ-ორიენტირებული პროგრამირება (ოოპ) Object Pascal-ენაზე - Rapid Application Development (RAD) Borland Delphi გარსის არეში.

ნაშრომის სამეცნიერო სიახლე. არსებული კლასიფიკაციის ალგორითმები ძირითადად იყენებენ გამოსახულებათა ამოცნობის არაადაპტიურ ალგორითმებს, რომლებიც მუშაობენ გარკვეულ საბეჭდ შრიფტებისათვის. სტანდარტული გამოსახულებისგან უმნიშვნელო გადახრას მოჰყვება ამოცნობის დაბალი შედეგები. ჩატარებული გამოკვლევევების საფუძველზე წამოყენებულია გამოსახულებათა ამოცნობის ახალი და ეფექტური მეთოდები ხელოვნური ნეირონული ქსელის მასწავლებლის გარეშე (ხნქ) მეშვეობით არამარტო ნაბეჭდის, არამედ ხელნაწერი სიმბოლოებისთვის, კერძოდ ქართული და ლათინური ასოებისთვის და არაბული ციფრებისთვის, რაც არსებითად გაზრდის გამოსახულებათა ამოცნობის კოეფიციენტს. სამეცნიერო სიახლე მდგომარეობს მეთოდიკის ფორმულირებაში და ახალი ალგორითმის შექმნაში (ხნქ)-ს მასწავლებლის გარეშე და გრაფიკული ინფორმაციის ალბათურ-სტატისტიკური ანალიზის გამოყენებით. v/h-ზონდების, კონგრუენტული, დივერსიული, პასიური და ნეიტრალური მასების ცნებები იყო შემოყვანილი; ეს მასები წარმოადგენს ნეირონული ქსელის წონის სხვადასხვა კატეგორიებს და აგრეთვე მატრიცების სხვადასხვა სახეობებს: შემჯამებელი, კონგრუენტული, დივერსიული, პასიური და სიმბიოზური. ახალი მეთოდიკის საფუძველზე

ფორმულირებულია მასების სიმბიოზის ჰიპოტეზა ვიზუალური ობიექტების ამა თუ იმ კლასისათვის გამოსახულების კუთვნილების განსაზღვრებისთვის.

ნაშრომის პრაქტიკული და თეორიული ღირებულება. პრაქტიკულად ახალი ნეირონული სქემის აგების საფუძველზე და ალბათურ-სტატისტიკური მეთოდების გამოყენებით მიღებულია ამოცნობის მაღალი შედეგები არამარტო ნაბეჭდის, არამედ ხელნაწერი გამოსახულებებისთვის. სიმბოლოების ნაკრების ხარისხოვანი გამოკვლევისთვის ჩვეულებრივად გამოიყენება ეტალონური სიმბოლოები, მაგალითად, ნომინალური რაოდენობით 1000 ეგზემპლარი და მატრიცის გარჩევითუნარიანობით 120x160 წერტილებით. იმის გათვალისწინებით, რომ, მაგალითად, თუ ჩვენ გვაქვს საქმე სიმბოლოების 69 ნაირსახეობასთან და წერტილოვანი შეღებვის ამთვისებელი მატრიცის 25%-იან აქტიობასთან, გვექნება 331200000 (აქტიური შეღებილი წერტილების 331,2 მილიონი). ახალი მეთოდის ძირითადი ღირებულებაა ის, რომ გრაფიკული ინფორმაციის გამოკვლევისთვის საჭირო ნაკრების ბაზის შემცირების მიუხედავად ჩვენ ვიღებთ უფრო მაღალხარისხოვან შედეგს, ე. ი. შეყვანილი ეტალონური გამოსახულების მინიმალური რაოდენობისას სახელდობრ სულ 40 პროტოტიპი ყოველი სიმბოლოსათვის, რომლებიც შეყვანილია მონაცემთა ბაზაში, და რეცეპტორების მინიმალურად შესაძლებელი მატრიცისას გარჩევითუნარიანობით 12x16 წერტილებით ვიღებთ 132480 წერტილებს, რაც 331067520 წერტილებით ნაკლებია იმისი, რაც დაგვჭირდებოდა გამოსახულებების შეყვანისთვის და ინფორმაციული დამუშავებისთვის. ნაკრების მონაცემთა ბაზის არსებითი შემცირება ამ შემთხვევაში 99,96%-ით და ობიექტების ამოცნობის ეფექტურობის გაზრდა წარმოადგენს ახალი მეთოდის დიდ პრაქტიკულ ღირებულებას.

გამოკვლევის შედეგების რეალიზაცია. გამოკვლევების შედეგები შეთავაზებულია დანერგვისთვის ი. ჯავახიშვილის სახ. თბილისის სახელმწიფო უნივერსიტეტის კიბერნეტიკის კათედრაზე.

ნაშრომის აპრობაცია. სადისერტაციო ნაშრომის ძირითადი დებულებები და შედეგები მოხსენებული იქნა ი. ჯავახიშვილის სახ. თბილისის სახელმწიფო უნივერსიტეტის მათემატიკური კიბერნეტიკის კათედრის სემინარებზე, ეკონომიკის, სტატისტიკის და ინფორმატიკის მოსკოვის სახელმწიფო უნივერსიტეტის კონფერენციებზე.

პუბლიკაციები. დისერტაციის ძირითადი შედეგები ავტორეფერატში მოყვანილი 8 პუბლიკაციების სიაშია. თანაავტორობით დაწერილ ნაშრომებში სამეცნიერო შედეგები მიღებულია დისერტანტის აქტიური მონაწილეობით.

ნაშრომის შინაარსი.

შესავალში დისერტაციის თემის აქტუალობაა დასაბუთებული, კერძოდ გამოსახულებების ამოცნობის ამოხსნა ინფორმაციის დამუშავების ალტერნატული ტექნოლოგიის ხელოვნური ნეირონული ქსელების (ხნქ) გამოყენებით, ფორმულირებულია ნაშრომის მიზანი, გამოკვლევის მეთოდები, სამეცნიერო სიახლე და პრაქტიკული ღირებულება, მოცემულია დისერტაციის მოკლე შინაარსი თავების მიხედვით.

პირველ თავში განიხილება ნეირობიოლოგიის საკითხები, კერძოდ მოცემულია ტვინის აგებულობის და სტრუქტურის ზოგადი ცნება, ბიოლოგიური ნეირონის, მისი შემადგენელი ელემენტების (აქსონები, სინაპსები, დენდრიტები), მისი უჯრედების ტიპები, სინაპტური სიმძლავრე, ნეირონული ქსელები და მათი მუშაობის პრინციპები, გატარებულია ანალოგია კომპიუტერსა და ადამიანის ტვინის შორის. გადმოცემულია ხელოვნური ნეირონის წონების სააქტივაციო ფუნქციების (სიგმოიდალური, ლოგისტიკის, და ჰიპერბოლური ტანგენსისა), ზღვრული სიდიდის, გაძლიერების კოეფიციენტების ცნებები; აგრეთვე განხილულია ერთფენოვანი და მრავალფენოვანი ხელოვნური ნეირონული ქსელები; ქსელების არქიტექტურა და თვისებები შეცდომის უკუგავრცელებით (Error Backpropagation), ნეირონული ქსელები ჰებბის პირდაპირი ნაკადიანი ქსელების (Feedforward), კოხონენის უმასწავლებლო სწავლის ალგორითმი და ამ მეთოდზე დაფუძნებული განსაკუთრებული ტიპის ნეირონული ქსელები – ეგრეთ წოდებული თვითორგანიზებადი სტრუქტურები სინაპსების შეწყობით – Selforganizing Feature Maps (SOM), ჰოპფილდის ერთფენოვანი ქსელები და ჰემმინგის ორფენოვანი ქსელები ასოციატური მეხსიერებით და აგრეთვე სწავლების ფორმალური ალგორითმები.

დისერტაციის მეორე თავში განხილულია ინფორმაციის აღქმის რეცეპტორული სტრუქტურა, გამოსახულების ამოცნობის სწავლების პრობლემა, კომპაქტურობის ჰიპოტეზა და ადაპტაციის ცნება. მოყვანილია ზონდების მეთოდი და გამოსახულებების გარდაქმნა ციფრულ კოდში. განხილულია ალგორითმული აგებები და ხელოვნური ნეირონული ქსელების სწავლების პროცესი მასწავლებლით და უმასწავლებლოდ. მოცემულია სახეების ამოცნობის ალგორითმები,

კერძოდ, მკვეთი სიბრტყვეების ალგორითმი, ალგორითმი, რომელიც დაფუძნებულია პოტენციალების მეთოდზე. განხილულია უიდროუ-ჰოფის სწავლების მეთოდი და კოხონენის გამოკვლევები თვითორგანიზებად სტრუქტურებზე. აღწერილია შემადგენელი ელემენტები (R/S/A) და როზენბლატის პერცეპტრონის ინტეგრალური მოწყობილობა, გაანალიზებულია პერცეპტრონის მუშაობა, რომელიც ეყრდნობა ტვინის სტრუქტურის და მხედველობითი აპარატის პრინციპებს, და მისი სახეების ამოცნობისთვის გამოყენება. მოყვანილია აგრეთვე სქემოტექნიკა და გამბის ამომცნობის მანქანა. შევეხეთ აგრეთვე პერცეპტრონული წარმოდგენის საკითხებს, მრავალფენოვანი პერცეპტრონების პოტენციალსა და ფუნქციის "ან გამორიცხვის" პრობლემას.

მესამე თავში განხილულია ხელოვნური ნეირონული ქსელების სახეების ამოცნობისთვის მოდელირების საკითხები, პრობლემები, რომლებიც წარმოიშვება ამ დროს. არის სახეების მონაცემთა ბაზის ნაკრების საკმარისობა, ეტალონური შემადგენლების ხარისხი და პრობლემების გადაწყვეტის ეტაპები, კერძოდ, დაჯგუფების, სეკვესტირების, ასოციირების ოპერაციები. აღწერილია რეცეპტორების მატრიცა, ჩატარებულია სტატისტიკური მაჩვენებლების, წონების ჯამების და მატრიცის ალბათობების, გასაშუალებული მნივნელობების და მატრიცის წონების მედიანების გაანგარიშება და აგრეთვე წერტილების რაოდენობის ანალიზი, რომლებსაც გააჩნიათ აქტიური შეღებილი წერტილების) გამოჩენის ალბათობები დიაპაზონებიდან [0,00], [0,00 – 0,25], [0,25 – 0,50], [0,50 – 0,75], [0,75 – 1,00], [1,00], ყოველი სიმბოლური სახის მახასიათებლების გამოჩენისთვის. აგრეთვე აგებულია გამოსახულების ზონდების ვერტიკალური და ჰორიზონტალური შემადგენლების დამოკიდებულების გრაფიკები, წერტილოვანი წონების ხაზობრივი გრაფიკი ყოველი სახისთვის წერტილოვანი ალბათობების 3D-სვეტიანი დიაგრამები, აღწერილია პირველი და მეორე დონის წონების წერტილოვანი ინტერპოლაციის ახალი მეთოდი პოტენციალების მეთოდის საფუძველზე. შექმნილია ყოველი სიმბოლოს გასაშუალებული კონტურები და აგებულია გამოსახულების დამუშავების თვითსწავლებადი ნეირონული ქსელი ამოცნობის და კრებადობის მაჩვენებლების გაუმჯობესებისთვის. შემუშავებულია ნეირონული თვითორგანიზებადი მატრიცული ქსელის ბლოკ-სქემა და ფუნქციონალური გრაფი სახეათა გამოცნობისათვის. ჩატარებული დიდი კვლევითი სამუშაოს შედეგად აგებული იქნა ხელოვნური თვითორგანიზებადი ქსელის ჰიბრიდული მოდელი, რომელიც იყენებს გამოსახულებების ალბათურ-სტატისტიკურ ანალიზს. მოცემული კომპლექსური მოდელი პროგრამულად იყო განხორციელებული და აპრობირებული არაბული ციფრების, ლათინური და ქართული ანბანების ამოცნობის მაგალითზე. აპრობაციამ გვიჩვენა, რომ ამ პროგრამის უპირატესობა იმაშია, რომ მას შეუძლია არა მარტო ნაბეჭდი, არამედ ხელნაწერი სიმბოლოების ამოცნობაც, ის შეიძლება გამოყენებული იქნას ნებისმიერი ანბანების და კონტურული გამოსახულებების კლასიფიკაციისათვის და აგრეთვე იძლევა სიმბოლოების გამოცნობის მაღალ შედეგებს რეცეპტორების მატრიცის ექსპერიმენტალურად დაბალი გარჩევითუნარიანობისას და ეტალონური გამოსახულებების ნაკრების მცირე ბაზისას. წარმოდგენილია აგრეთვე პროგრამის ფრაგმენტები და სახეების ამოცნობის ალგორითმების ლისტინგი მრავალფენოვანი თვითორგანიზებადი ნეიროქსელის საფუძველზე, რომელიც იყენებს ორგანზომილებიანი მასივების დამუშავებას, მანქანურიდან ციფრულ კოდში გამოსახულებების და გრაფიკული დიაგრამების სტატისტიკურ ანალიზს და აგრეთვე დისკრეტულ სიმრავლეებზე სხვადასხვა შეფასებით ოპერაციებს.

სახეთა ამოცნობის (სა) პრობლემის გადაწყვეტადობა მრავალ ფაქტორზეა დამოკიდებული. ხარისხიანი (სა)-ს პირობაა შეყვანილი ეტალონების საკმარისი ნაკრები ყოველი კლასის წარმომადგენლების მონაცემთა ბაზის (მბ), რომლის გამოყენებით შესაძლებელია ჩატარებული იქნას ანალიტიკური შეჯერებები და გამოიყენებოდეს ნეიროქსელის იდენტიფიკაციის ალგორითმები. სიმბოლოების და მეტად დამახინჯებული ობიექტების შეყვანამ შეიძლება გამოიწვიოს სიძნელეები სახეთა გამოცნობისას, რაც არსებითად შეამცირებს ამოცნობის პროცენტს. (მბ)-ს ყოველი სიმბოლოს წარმომადგენლებს უნდა გააჩნდეთ შემდეგი მახასიათებლები: უნდა იყვნენ კლასიცირებადი, არ იყვნენ ერთმანეთის ძლიერად მსგავსი და არ უნდა შეიცავდნენ კლასის შიგნით ძლიერად დეფორმირებულ ელემენტებს. თუ ერთი და იგივე სიმბოლო განსხვავებული ვიზუალური მოხაზვისაა, (მბ) უნდა იყოფოდეს სინონიმური სიმბოლოების სეპარირებულ კლასებად, რომლებიც უნდა ასოციირდებოდეს ერთ და იმავე სახესთან. მაგალითად, შეიძლება გამოვიყენოთ ნახ. 1-ზე მოყვანილი სიმბოლოების შემდეგი გამოსახულებები:

სახეთა ამოცნობისთვის იყო გამოყენებული წონების აწყობის კომბინირებული ნეიროქსელური სქემა შეცდომის უკუგავრცელების ალგორითმით. ამან მისცა (ხნქ)-ს სამუშაო

ციკლებში თვითაწყობის საშუალება სწავლების ეტაპზე და ნელნელა შეცდომების მოცილებისა.

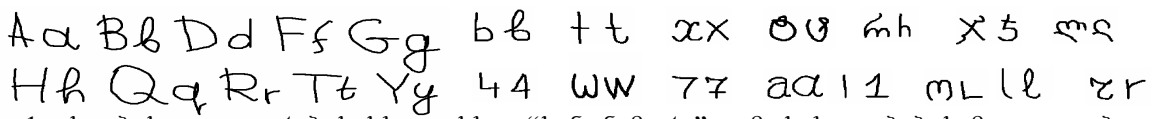

ნახ. 1. ასოების და ციფრების სხვადასხვა "სინონიმური" გამოსახულებების მაგალითები.

თვითშეწყობა ან სწავლება შეიძლება განხორციელდეს როგორც მასწავლებლის დახმარებით, როდესაც მომხმარებელს შეუძლია უპირატესობა მიანიჭოს რომელ სახესთან უფრო ახლოა შემოსული პროგრამის შესასვლელზე სიმბოლო, ასევე მასწავლებლის გარეშე, სხვადასხვა დონის ნეირონული მატრიცის შესაბამისი წონების ავტომატური თვითაწყობის გზით, ადამიანის მონაწილეობის გარეშე. მასწავლებლის გარეშე სწავლების რეალიზაცია არის მეტად ეფექტური და ავტომატიზებული ხერხი და ამავე დროს უფრო რთული განხორციელებისთვის, მაგრამ სწორედ ეს ხერხი იყო ჩადებული (სა)-ს ალგორითმის საფუძველში.

ეტალონური სიმბოლოების გამოსახულებები მიეწოდება რეცეპტორების მატრიცას და ინახება (მბ)-ში. რაც უფრო მაღალია რეცეპტორების მატრიცის გარჩევითუნარიანობა და ეგზემპლარების რაოდენობა, მით უფრო ნაკლები გაჩნდება შეცდომები, რომლებიც დაკავშირებულია სიმბოლოების მეტამორფოზულ მსგავსებასთან და მით უფრო ზუსტად შეიძლება გამოვლინდეს კანონზომიერებები და იდენტიფიცირებული იქნას ნიშნები რეკოგნაციული მოდელის აგებისთვის. ამ ნაშრომში დასმული იყო ამოცნობის მიღწევის ამოცანა, როდესაც ეტალონური ეგზემპლარების რაოდენობა და რეცეპტორების მატრიცის გარჩევითუნარიანობა რედუცირებულია ამოცნობის დეფექტიანობის დანაკარგის გარეშე. ამიტომ იყო არჩეული ოპტიმალური მატრიცა 12x16 გარჩევითუნარიანობით და (მბ)-ს წარმომადგენლების ყველა ციფრის, ლათინური და ქართული ასოების ნაკრებიდან ყოველი სიმბოლოსთვის ორმოც ორმოცი ეგზემპლარის ნაკრები.

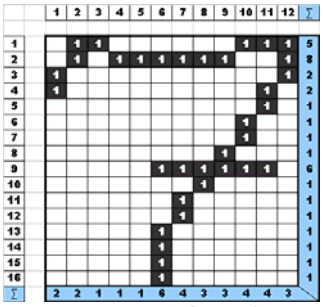

ნახ. 2 რეცეფტორების მატრიცა.

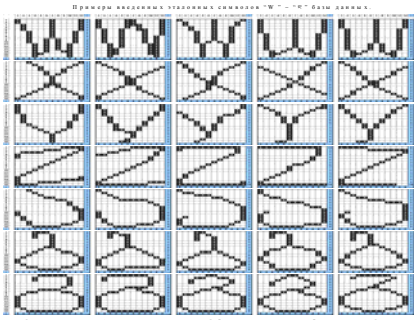

ნახ. 3 შემოყვანილი სიმბოლოების მაგალითები.

მიუხედავად იდენტიფიკაციის პირობების გამკაცრებისა, აგებულმა მოდელმა გვიჩვენა ობიექტების ამოცნობის მაღალი შედეგები (ხნქ)-ს კარგად აგებული სქემის წყალობით. ნახ. 2-ზე მოყვანილია 34 წერტილით რეცეპტორული ველის შევსების მაგალითი, რის შედეგადაც მიიღება ციფრი შვიდის გრაფიკულ-ციფრული გამოსახულება. ზოგიერთი ნებისმიერი (მბ)-ს ასოების და ციფრების გამოსახულებათა ფრაგმენტები მოყვანილია ნახ.3-ზე. გამოსახულების დეკოდირება გრაფიკული ფორმატის ფაილიდან, რომელიც შემოსულია პროგრამის შესასვლელზე და მისი მატრიცულ ფორმაში ტრანსფორმირება შემდგომი ამოცნობისთვის. სიმბოლოს გამოსახულება ინახება გრაფიკულ ფაილში, (BMP) ფაილის აგების ფორმატის გამოყენებით. (BMP) ფორმატის სათაური ინახავს ინფორმაციას სტრუქტურის, ზომის, ფერის სიღრმის, კომპრესიის ტიპის, სიბრტყეების რაოდენობის, სიგანის, სიმაღლის, რეზერვირებული მინდვრების და სხვ. შესახებ. თვით გამოსახულება იწყება კოდიანი ბლოკით 118 ინდექსით (HEX) ფორმატში (ნახ. 4). "FF" კოდი ფაილის შიფრის სხეულის შიგნით განსაზღვრავს თეთრ შეუღებავ წერტილს, "00" კი – შავს. გამოსახულების მქონე ფაილი შეიცავს აგრეთვე სტრიქონებს შორის გასაყოფ ბლოკებს და დაჯავშნული სიმბოლოების ფაზით გადაწეულია, ინახება გადაბრუნებული ტრანსპონირებული ფორმით (ჩაწერილია სტრიქონებით მარცხნიდან მარჯვნივ და ქვემოდან ზემოთ). პროგრამაში წარმატებით იყო რეალიზებული მოდული, რომელიც ახორციელებს გრაფიკული გამოსახულების დეკოდირებას (BMP)-ს ფაილიდან ორგანზომიელებიან ნორმალიზებულ მასივში "0" და "1".

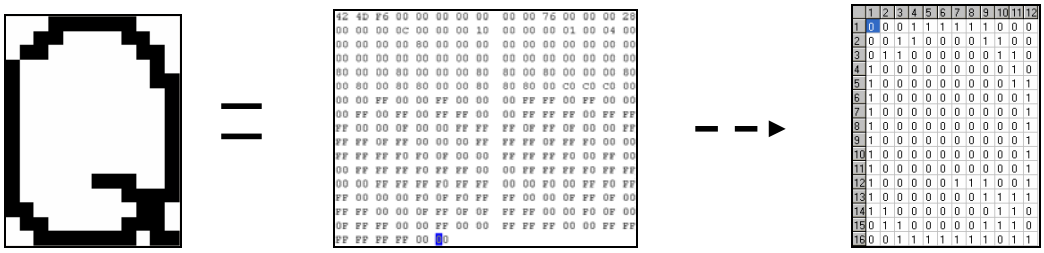

ნახ. 4 გამოსახულების გარდაქმნა გრაფიკულიდან ციფრულ ცხრილურ 2D მასივში.

ყოველ 69 გამოსაკვლევ სიმბოლოსთვის (ციფრი და ასო) იყო აგებული ორი ცხრილი, რომელიც დასახელდა წერტილოვანი წონების და წერტილოვანი ალბათობების ჯამურ მატრიცებად; ისინი შეყვანილი ეტალონების წერტილოვანი წონების და წერტილოვანი ალბათობების შესაბამის ჯამურ მნიშვნელობას შეიცავენ. ფაქტობრად წერტილოვანი წონების ჯამური მატრიცა (ნახ. 5) წარმოადგენს ყველა სიმბოლური პროტოტიპების მატრიცის დასმას ერთ გენერირებად მატრიცაზე, რის შედეგადაც მასზე გამოისახება სიმბოლოს გამოსახულება მნიშვნელოების ცხრლის ველზე გრადიენტური შეღებვის დაპროგრამებული გამოვლენისას, თუ წერტილოვანი წონების მნიშვნელობა გადაამეტებს გარკვეულ ზღვრულ მნიშვნელობებს. ქართული ანბანის ასო “ა”-ს მაგალითზე მოყვანილია წერტილოვანი წონების და წერტილოვანი ალბათობების ჯამური მატრიცები ნახ. 5-ზე.

	1	2	3	4	5	6	7	8	9	10	11	12	∑
1	27	11	2	3	1	0	0	0	0	0	0	0	44
2	13	14	9	7	1	2	2	0	0	0	0	0	48
3	1	15	12	6	10	5	0	2	0	0	0	0	51
4	0	2	13	16	9	8	7	3	2	0	0	0	60
5	0	0	3	7	13	13	10	8	7	3	0	0	64
6	0	0	0	3	6	9	14	13	8	8	4	0	65
7	0	0	0	0	0	3	7	10	14	13	9	4	60
8	0	0	0	0	0	0	0	4	9	13	17	13	56
9	0	0	0	0	0	0	0	0	0	4	9	30	43
10	2	5	2	0	0	0	0	0	0	0	2	38	49
11	10	2	1	0	0	0	0	0	0	0	0	40	53
12	17	5	1	0	0	0	0	0	0	0	2	38	63
13	18	12	0	0	0	0	0	0	0	0	6	34	70
14	18	16	3	0	0	0	0	0	1	5	25	12	80
15	13	11	18	3	1	0	2	11	19	23	14	2	117
16	0	11	20	37	39	40	38	29	20	12	2	0	248
∑	119	104	84	82	80	80	80	80	80	81	90	211	

	1	2	3	4	5	6	7	8	9	10	11	12	∑
1	0.68	0.28	0.05	0.08	0.03	0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.10
2	0.33	0.35	0.23	0.18	0.03	0.05	0.05	0.00	0.00	0.00	0.00	0.00	1.20
3	0.03	0.38	0.30	0.15	0.25	0.13	0.00	0.05	0.00	0.00	0.00	0.00	1.28
4	0.00	0.05	0.33	0.40	0.23	0.20	0.18	0.08	0.05	0.00	0.00	0.00	1.50
5	0.00	0.00	0.08	0.18	0.33	0.33	0.25	0.20	0.18	0.08	0.00	0.00	1.60
6	0.00	0.00	0.00	0.08	0.15	0.23	0.35	0.33	0.20	0.20	0.10	0.00	1.63
7	0.00	0.00	0.00	0.00	0.00	0.08	0.18	0.25	0.35	0.33	0.23	0.10	1.50
8	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.10	0.23	0.33	0.43	0.33	1.40
9	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.10	0.23	0.75	1.08
10	0.05	0.13	0.05	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.05	0.95	1.23
11	0.25	0.05	0.03	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.00	1.33
12	0.43	0.13	0.03	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.05	0.95	1.58
13	0.45	0.30	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.15	0.85	1.75
14	0.45	0.40	0.08	0.00	0.00	0.00	0.00	0.00	0.03	0.13	0.63	0.30	2.00
15	0.33	0.28	0.45	0.08	0.03	0.00	0.05	0.28	0.48	0.58	0.35	0.05	2.93
16	0.00	0.28	0.50	0.93	0.98	1.00	0.95	0.73	0.50	0.30	0.05	0.00	6.20
∑	2.98	2.60	2.10	2.05	2.00	2.00	2.00	2.00	2.00	2.03	2.25	5.28	

ნახ. 5 წერტილოვანი წონების და წერტილოვანი ალბათობების ჯამური მატრიცები.

შემოყვანილია ახალი ტერმინები, რომლებიც განსაზღვრავს ზონდების განლაგებას ვერტიკალურად და ჰორიზონტალურად, დასახელებით შესაბამისად v-ზონდი (ვერტიკალური) და h-ზონდი (ჰორიზონტალური); აგრეთვე გათვლილია წონების ჯამები მატრიცის ვერტიკალურ და ჰორიზონტალურ შემადგენლებზე. გამოსახულებების აპრობაციული ანალიზისთვის და (სა)-თვის იყო გამოყენებული ახალი მოდიფიცირებული მეთოდი, რომელშიც ზონდების სტანდარტული მეთოდისგან განსხვავებით გამოყენებულია v/h-ზონდების ნაჯერი რაოდენობა – 28 ზონდი, მთლიანად დაკავებული რეცეპტორების ველით სიმბოლოების შორის განსხვავებების დამახასიათებელი თვისებების დეტექტირების გაუმჯობესების მიზნით, მაგრამ ექსპერიმენტებით იყო გამოვლენილი, რომ ზონდების გაჯერება იდენტიფიკაციის პროცესის გაუმჯობესებისთვის არაარსებითია, რადგანაც ამ მეთოდში მატრიცის წერტილების ზონდებათან გადაკვეთების რაოდენობა გადაკვეთის პოზიციას განსაზღვრავს არაერთმნიშვნელოვნად და, შედეგად, გამოცნობადი გამოსახულების პატერნი ყოველთვის არ იქნება იდენტიფიცირებული.

შემუშავებულ პროგრამაში იყო განხორციელებული კვლევადი სტატისტიკური მონაცემების MS Excel სიმრავლის ცხრილების ავტომატური დატვირთვის პროცედურა და ყველა გამოსაკვლევი კლასების მახასიათებლების გენერალური (მბ)-ს ჩატვირთვის პროგრამულ დანართში.

სტატისტიკური და ალბათური კანონზომიერებების ანალიზის პროცესში გათვლილი იქნა კლასის ყოველი წარმომადგენლის მახასიათებლები. გამოსახულებების მახასიათებლების გამოვლენისთვის იყო გამოკვლეული ჯამური გაყოფილი წერტილოვანი ალბათობები, რომლებიც პირობით იყო გამოყოფილი ოთხ დიაპაზონად [0.00, 0.25], [0.25, 0.50], [0.50, 0.75], [0.75, 1.00] და ასოციირებული ფერების პალიტრასთან დომინირებადი და რეცესიული ალბათობების ვიზუალური გამოყოფისთვის, რაც იძლევა ყოველი სიმბოლოს წერტილების ალბათური განაწილების ჯამურ ვიზუალურ სურათს რეცეპტორების ველზე.

ალბათობების დიაპაზონები და წერტილების ფერებთან შესაბამისობა:

[0.00, 0.25] თეთრი წერტილები
[0.25, 0.50] ღია რუხი წერტილები

რეცესიული

[0.50, 0.75] მუქი რუხი წერტილები
[0.75, 1.00] შავი წერტილები

დომინირებული

მოცემული ამოცანის სტატისტიკურად გაანალიზებული წერტილების საერთო რაოდენობამ შეადგინა 529920 (69 სიმბოლო x 40 (მბ)-ს ეტალონი x რეცეპტორების მატრიცის 192 წერტილზე). (მბ)-ის ყოველი სახის წერტილოვანი ალბათობების მატრიცების საფუძველზე იყო გათვლილი ზოგადი სტატისტიკური მონაცემები (ცხრილი 1): მატრიცის წონების ჯამები, მატრიცის ალბათობების ჯამები, მატრიცის საშუალო მნიშვნელობა, მატრიცის წონების მედიანა და აგრეთვე ალბათობების სხვადასხვა დიაპაზონების მქონე წერტილების რაოდენობა.

სახეების მახასიათებლების გამოვლენისთვის წერტილოვანი ალბათობების განაწილების დასაბალანსებლად დამატებით იყო განხორციელებული პოტენციალების მეთოდის მოდიფიკაცია ჯამური მატრიცისთვის, პირველი დონის წერტილოვანი წონების ინტერპოლაციურ გასწორებად წოდებული (ნახ. 6). ეს მეთოდი იძლევა საშუალებას შეივსოს სიცარიელები ეტალონურ მოხაზულობებს შორის და გამოვლინდეს დომინირებული და მოსცილდეს წერტილების რეცესიული ჯგუფები მასების ბუნებრივი შერჩევის გზით. ამით შეიძლება ეტალონური (მბ)-ს მინინაკრების საფუძველზე ავტომატურად მივიღოთ ჯამური მატრიცის სურათი, რომელიც შეესაბამება (მბ)-ის მაქსინაკრების რაოდენობას, რაც მკვეთრად ამაღლებს ეფექტიანობას და ამცირებს (მბ)-ში ეტალონური ეგზემპლარების უზარმაზარი მასივების შეყვანის საჭიროებას. სახეების ანალიზისთვის შეიძლება გამოყენებული იქნას აგრეთვე მეორე დონის რეკურენტული ინტერპოლაცია პირველი დონის მატრიცის გასწორების საფუძველზე. მეორე დონის წერტილოვანი წონების ინტერპოლაციური გასწორება (ნახ. 6) იძლევა მატრიცის წონების უფრო დაბალანსებულ განაწილებას, რის შედეგადაც ამოცნობადი ობიექტების იდენტიფიკაცია შეიძლება უფრო მაღალი ალბათობით ან ნაკლები შეცდომებით.

0.99	0.60	0.27	0.18	0.09	0.03	0.02	0.01	0.00	0.00	0.00	0.00	2.19
0.67	0.63	0.44	0.31	0.13	0.11	0.08	0.01	0.01	0.00	0.00	0.00	2.39
0.25	0.58	0.56	0.39	0.42	0.25	0.09	0.09	0.02	0.01	0.00	0.00	2.65
0.09	0.19	0.52	0.63	0.47	0.41	0.33	0.19	0.12	0.04	0.01	0.00	2.98
0.01	0.06	0.20	0.37	0.55	0.56	0.48	0.40	0.32	0.17	0.05	0.02	3.18
0.00	0.01	0.04	0.17	0.30	0.43	0.58	0.57	0.44	0.38	0.22	0.09	3.21
0.00	0.00	0.01	0.03	0.07	0.19	0.34	0.47	0.59	0.58	0.45	0.32	3.04
0.00	0.00	0.00	0.00	0.01	0.03	0.08	0.23	0.41	0.56	0.72	0.67	2.70
0.04	0.03	0.02	0.01	0.00	0.00	0.01	0.04	0.09	0.26	0.59	1.15	2.23
0.14	0.18	0.08	0.01	0.00	0.00	0.00	0.00	0.01	0.05	0.43	1.36	2.24
0.41	0.18	0.07	0.01	0.00	0.00	0.00	0.00	0.00	0.01	0.38	1.40	2.46
0.66	0.32	0.09	0.01	0.00	0.00	0.00	0.00	0.00	0.03	0.42	1.36	2.87
0.79	0.54	0.12	0.01	0.00	0.00	0.00	0.00	0.02	0.12	0.51	1.27	3.38
0.80	0.69	0.26	0.08	0.01	0.01	0.04	0.10	0.21	0.40	0.93	0.71	4.23
0.61	0.58	0.77	0.44	0.40	0.38	0.42	0.62	0.79	0.88	0.60	0.32	6.80
0.29	0.28	0.50	0.93	0.98	1.00	0.95	0.73	0.50	0.30	0.05	0.15	6.64
5.72	4.86	3.94	3.57	3.42	3.39	3.42	3.45	3.53	3.78	5.35	8.79	

1.62	1.20	0.70	0.42	0.24	0.12	0.07	0.03	0.01	0.00	0.00	0.00	4.42
1.27	1.17	0.88	0.62	0.35	0.25	0.15	0.05	0.02	0.00	0.00	0.00	4.79
0.67	0.99	1.02	0.83	0.76	0.50	0.27	0.20	0.08	0.03	0.01	0.00	5.36
0.30	0.47	0.89	1.06	0.92	0.80	0.64	0.42	0.28	0.12	0.04	0.02	5.96
0.08	0.19	0.45	0.73	0.96	1.01	0.92	0.78	0.60	0.36	0.16	0.09	6.33
0.02	0.05	0.15	0.36	0.59	0.81	1.01	1.02	0.87	0.73	0.47	0.29	6.38
0.00	0.01	0.04	0.10	0.21	0.42	0.66	0.87	1.05	1.05	0.89	0.74	6.04
0.01	0.01	0.01	0.02	0.05	0.12	0.24	0.48	0.76	1.02	1.29	1.31	5.32
0.10	0.08	0.06	0.02	0.01	0.02	0.06	0.14	0.29	0.61	1.24	1.90	4.53
0.30	0.30	0.14	0.03	0.00	0.00	0.01	0.02	0.07	0.27	1.08	2.14	4.36
0.70	0.43	0.18	0.04	0.00	0.00	0.00	0.00	0.01	0.18	1.01	2.19	4.74
1.11	0.67	0.25	0.04	0.00	0.00	0.00	0.00	0.02	0.21	1.05	2.15	5.51
1.39	1.01	0.37	0.08	0.01	0.01	0.02	0.05	0.13	0.44	1.17	2.05	6.72
1.44	1.25	0.67	0.33	0.18	0.16	0.23	0.36	0.57	0.91	1.53	1.43	9.06
1.13	1.11	1.24	0.93	0.87	0.85	0.90	1.08	1.26	1.35	1.07	0.80	12.59
0.78	0.28	0.50	0.93	0.98	1.00	0.95	0.73	0.50	0.30	0.05	0.47	7.45
10.94	9.21	7.53	6.56	6.14	6.06	6.12	6.24	6.51	7.59	11.05	15.60	

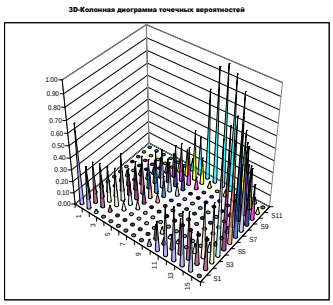

ნახ. 6 ინტერპოლირებული გასწორებული 1-ლი და მე-2 დონის პოტენციალების მეთოდის მეშვეობით ჯამური მატრიცისთვის. ქართული ასო “ა”-ს წერტილოვანი ალბათობების 3D-სვეტური დიაგრამა.

მიღებული მატრიცების საფუძველზე იყო აგებული 3D-სვეტური წერტილოვანი ალბათობების დიაგრამა (ნახ. 7) და “დაქტილოსკოპიურ პატერნებად” წოდებული გრაფიკები, რომლებიც წარმოადგენს v-ზონდის და h-ზონდის ჯამურ მატრიცაზე (ნახ. 7) მოხატულობის წერტილებთან გადაკვეთის დიაგრამებს. ამ დიაგრამებიდან ჩანს სურათების ინფორმაციულ-გრაფიკული სპეციფიკა, რომელსაც გააჩნია გარკვეული სიმბოლოს პატერნის ინფორმაციული უნიკალობა დაკტილოსკოპიურ ნახატის მსგავსად და v/h (ზონდის) მეთოდით უფრო ზუსტად ობიექტების იდენტიფიცირება.

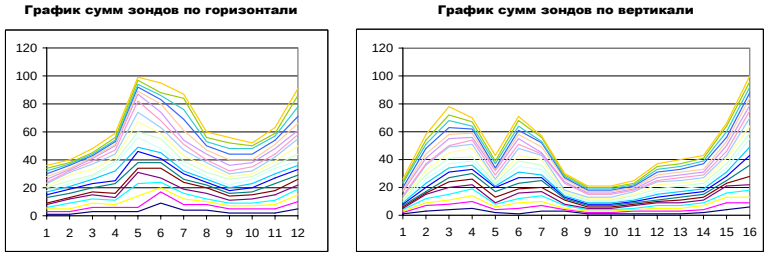

ნახ. 7 ზონდების ჯამის გრაფიკები ვერტიკალით და ჰორიზონტალით

ქართული ანბანის ასო “ზ”-ს მაგალითზე (ნახ. 8) მოყვანილია (მბ)-ს ეტალონური ელემენტების მატრიცები, სტატისტიკური გაანგარიშების ცხრილები, ვერტიკალური და ჰორიზონტალური ზონდების გრაფიკები და წერტილოვანი ალბათობების დიაგრამები.

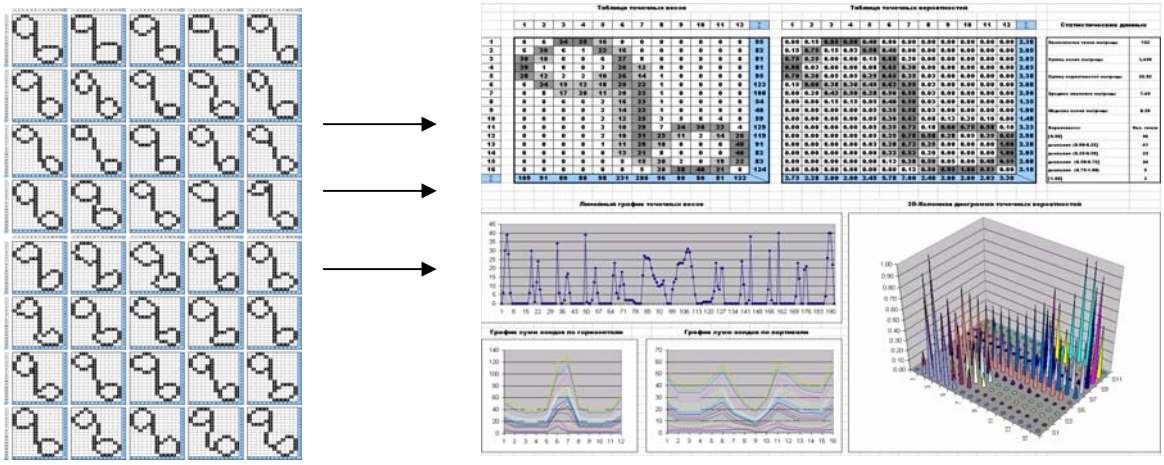

ნახ. 8 ხელით შეყვანილი და (მბ)-ში გადატანილი ასო “ზ”-ს მატრიცის ელემენტები. ალბათობით–სტატისტიკური ანალიზი და ასო “ზ”-ს დაქტილოსკოპიური გარჩევა.

რომ შევადაროთ სხვადასხვა სიმბოლოების ზონდების ვერტიკალური და ჰორიზონტალური გრაფიკები, მაგალითად, ლათინური ასო “M” და ქართული ასო “უ”, შევამჩნევთ მათ გრაფიკულ დივერსიფიკაციას (ნახ. 9). გრაფიკების და ალბათობების შედარების და ერთმანეთზე დადების გზით შეიძლება გაირკვეს შესასვლელზე შემოსული გამოსახულების დაშორება სხვადასხვა სახეების ყოველ ჯამურ მატრიცასთან. გაწყვეტის დისტანცია განსაზღვრავს მიახლოებას ან განშორებას შეყვანილ გამოსახულებას და (მბ)-დან სიმბოლოებს შორის.

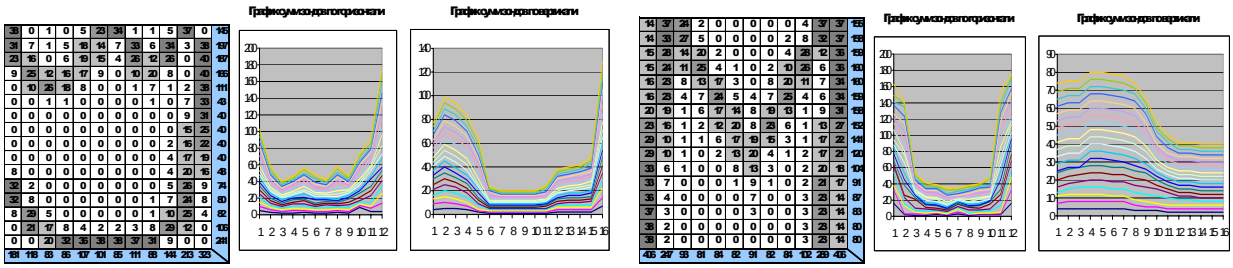

ნახ. 9 გრაფიკების პატერნების “დაქტილოსკოპიური” შედარება.

შეიძლება გამოყენებული იქნას სხვა დიაგრამაც – წერტილოვანი წონების ხაზობრივი გრაფიკი, რომელიც წარმოადგენს წერტილოვანი წონების განაწილების კომბინირებულ გრაფიკს (ნახ. 10) და გააჩნია რეცეპტორების ველზე წერტილების განაწილების უფრო კრებსითი ინფორმაცია ზონდების ჰორიზონტალურ და ვერტიკალურ გრაფიკებთან შედარებით.

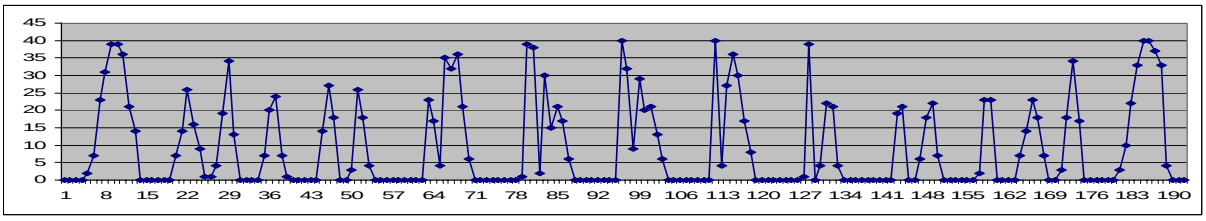

ნახ. 10 წერტილოვანი წონების ხაზობრივი გრაფიკი.

მოყვანილ გრაფიკებზე ჩანს განსხვავებები სხვადასხვა სიმბოლოების მოხაზულობის პატერნში, ნახატს გააჩნია “დაქტილოსკოპიური” განმასხვავებელი ნიშნები ქართული ასო “გ”-ს და ლათინური ასო “V”- ს წერტილოვანი წონების ხაზობრივი გრაფიკების ვიზუალური შედარებისასაც კი (ნახ. 11).

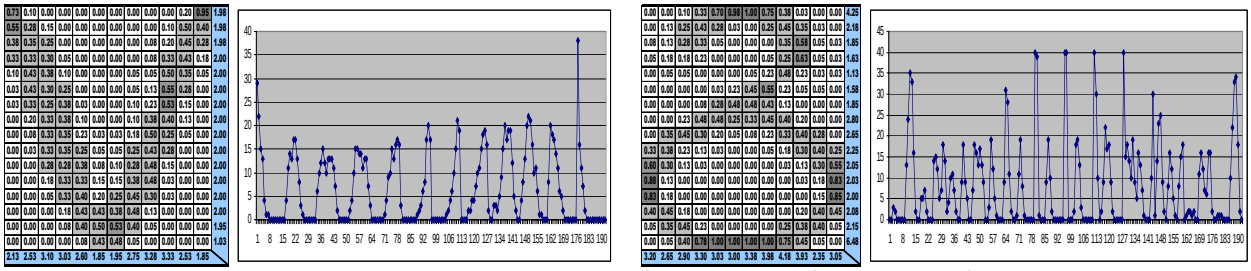

ნახ. 11 წერტილოვანი წონების გრაფიკების შედარება.

გარკვეული სახეების წარმომადგენელ (მბ)-ს შორის დაშორების განსაზღვრისათვის, მაგალითად, ლათინური ასო “V”- ს და ქართული ასო “გ”-ს, შეიძლება გამოვეყენოთ წერტილოვანი წონების სხვაობის შუალედური მატრიცა, რომლის საფუძველზე აიგება კომბინირებული ხაზობრივი შედარებების გრაფიკი (ნახ. 12). რაც უფრო ნაკლებია სხვაობა ან ჯამური მნიშვნელობა, მით უფრო ახლოა ერთმანეთთან გამოსახულებები (მბ)-დან და პირიქით.

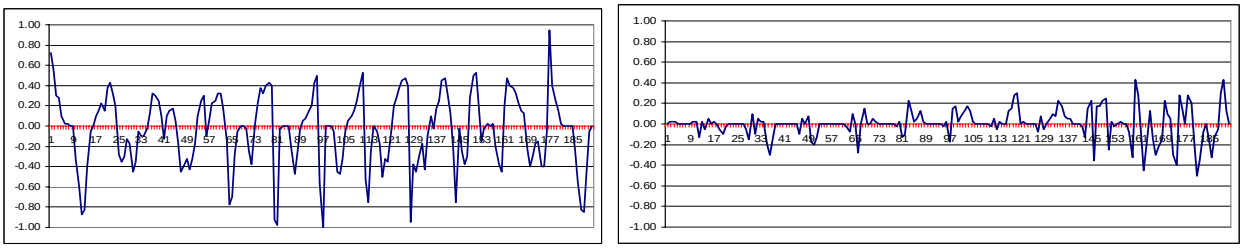

ნახ. 12 “V”-ს და “გ”-სთან არასიმილარული სახეების შედარების გრაფიკი და ციფრი “3“ და ქართული ასო “ვ”-ს სიმილარული სახეების შედარების გრაფიკი.

ეს მექანიზმი შეიძლება გამოიყენებოდეს შესასვლელზე შემოსულ გამოსახულებების და ჯამური მატრიცის შორის დისპერსიის განსაზღვრისათვის ეტალონურ (მბ)-სთან შედარებისთვის. თუ შევადარებთ (მბ)-დან სიმილარულ სახეებს, მაგალითად, ციფრი “3” და ქართული ასო “ვ”, მივიღებთ შემდეგ დიაგრამას. ნახ. 12-ის გრაფიკების შედარებით ჩნდება, რომ რაც უფრო მაღალია გრაფიკების ამპლიტუდები, მით უფრო ნაკლებად სიმილარულია (მბ)-ს სახეები, და პირიქით, რაც უფრო დაბალია გრაფიკის ამპლიტუდები, მით უფრო ვიზუალურად მიახლოებულია სახეები. მოვიყვანოთ იგივე გრაფიკები მოდულურ წარმოდგენაში, სადაც ამ სხვაობების მნიშვნელობის ჯამი მოდულით გაითვლება (ნახ. 13).

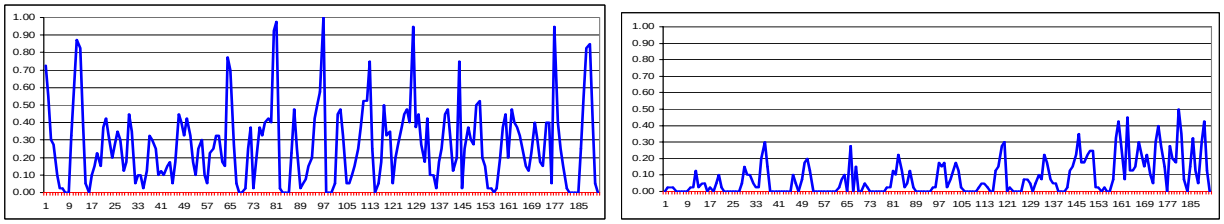

ნახ. 13 “V” “გ”-სთან არასიმილარული სახეების და ციფრი “3“ და ასო “ვ”-ს სიმილარული სახეების შედარების მოდულური გრაფიკები.

მოყვანილი ახალი სქემები და გრაფიკები, თუმცა გვაახლოებს ამოცნობის ამოცანის გადაწყვეტილებასთან, მაგრამ არ წყვეტს მას იმის გამო, რომ არ ითვალისწინებს ზოგ ფაქტორს, რომელიც დაკავშირებულია ჰიბრიდულ მატრიცებზე წერტილების კატეგორიზაციასთან. ამოცნობის გაუმჯობესებისთვის შემუშავებული იყო და შემოყვანილი იყო რეცეპტორული მატრიცის წერტილების ჯამურ ეტალონურ (მბ)-სთან შედარების ახალი მეთოდიკა, რომელიც მდგომარეობს წერტილოვან ანალიზში და წერტილოვანი მასების სხვადასხვა კლასტერების გათვლაში.

შემოყვანილია ახალი ტერმინები, რომლებიც მატრიცების სხვადასხვა კატეგორიებს (ნახ. 1) წარმოადგენს: კონგრუენტული, დივერსიული, პასიური და სიმბიოზური მატრიცები.

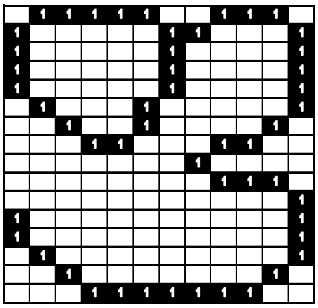

0.03	0.03	0.53	0.93	0.60	0.08	0.03	0.30	0.88	0.78	0.13	0.00
0.03	0.50	0.45	0.10	0.43	0.50	0.18	0.70	0.15	0.23	0.68	0.13
0.38	0.48	0.15	0.00	0.28	0.53	0.38	0.53	0.05	0.05	0.38	0.60
0.65	0.33	0.03	0.00	0.18	0.43	0.58	0.30	0.03	0.00	0.23	0.78
0.85	0.15	0.00	0.00	0.05	0.48	0.63	0.20	0.00	0.00	0.13	0.90
0.95	0.05	0.00	0.00	0.00	0.35	0.65	0.10	0.00	0.00	0.00	1.00
0.98	0.05	0.00	0.00	0.00	0.18	0.43	0.03	0.00	0.00	0.03	0.98
0.95	0.05	0.00	0.00	0.00	0.13	0.25	0.03	0.00	0.00	0.05	0.95
0.93	0.08	0.00	0.00	0.00	0.08	0.18	0.03	0.00	0.00	0.08	0.93
0.85	0.15	0.00	0.00	0.00	0.05	0.10	0.00	0.00	0.00	0.15	0.85
0.78	0.23	0.00	0.00	0.00	0.00	0.08	0.00	0.00	0.00	0.23	0.78
0.58	0.40	0.03	0.00	0.00	0.00	0.00	0.00	0.00	0.03	0.40	0.58
0.40	0.53	0.08	0.00	0.00	0.00	0.00	0.00	0.00	0.08	0.53	0.68
0.30	0.48	0.23	0.00	0.00	0.00	0.00	0.00	0.00	0.23	0.48	0.30
0.10	0.43	0.43	0.05	0.00	0.00	0.00	0.00	0.05	0.43	0.43	0.10
0.00	0.18	0.68	0.20	0.00	0.00	0.00	0.00	0.20	0.70	0.15	0.00

ნახ. 14 რეცეპტორების მატრიცის წერტილების მაგალითი ასო "ფ"-სთვის და ჯამური (მბ) ასო "ო"-სთვის.

<u>კონგრუენტული მატრიცები</u> მიიღება შემოსასვლელზე შემოსული გამოსახულების მატრიცის წერტილების მნიშვნელობების და ალბათობების ჯამური მატრიცების შესაბამის პოზიციაში მდგომი წერტილების მნიშვნელობებზე გამრავლების ოპერაციის შედეგად.

<u>დივერსიული მატრიცები</u> მიიღება შემდეგნაირად: თუ სხვაობა შემავალი გამოსახულების მატრიცის წერტილის მნიშვნელობისა და ჯამური მატრიცის წერტილის შესაბამის მნიშვნელობისა 1-ის ტოლია, მაშინ დივერსიულ მატრიცაში პოზიციით შესაბამისი წერტილი იღებს 1-ის მნიშვნელობას, წინააღმდეგ შემთხვევაში იწერება 0-ის ტოლი მნიშვნელობა.

<u>პასიური მატრიცა</u> მიიღება ალბათობების ჯამური მატრიცების წერტილების მნიშვნელობების და კონგრუენტული მატრიცების წერტილების შესაბამისი პოზიციის მნიშვნელობების გამოკლების ოპერაციის შედეგად.

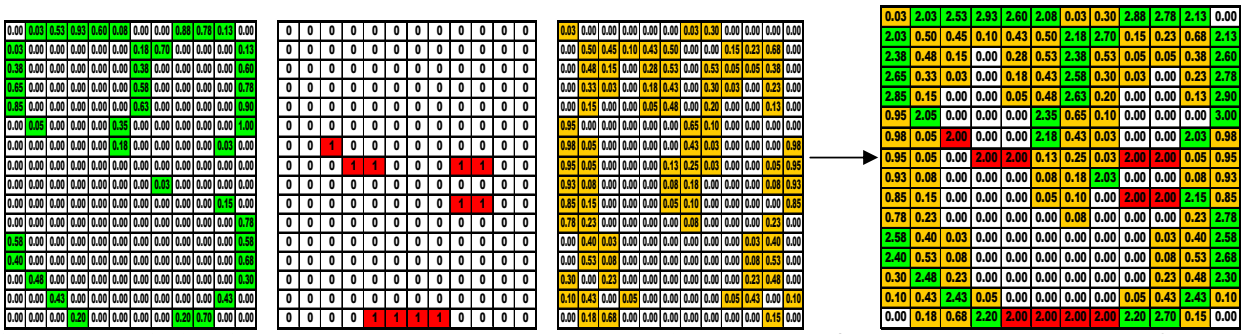

ნახ. 15 კონგრუენტული, დივერსიული და პასიური წერტილების ასო "ფ"-სთვის გამოყოფის მაგალითი (მბ)-ის ეტალონურ ასო "ო"-სთვის შედარებისას, აგრეთვე სიმბიოზური მატრიცების მიღება.

<u>სიმბიოზური მატრიცა</u> მიიღება კონგრუენტული, დივერსიული და პასიური მატრიცებიდან წერტილების (არატოლი 0-ის) მნიშვნელობების ერთ საერთო მატრიცაში გადატანის შედეგად. ამასთან სიმბიოზურ მატრიცაში ეს წერტილები არ დაედება კოორდინატებით ერთმანეთს აგების თანახმად.

ნულოვანი წერტილები – ეს სიმბიოზური მატრიცის ის წერტილებია, რომლების მნიშვნელობა ნულის ტოლია.

სიმბიოზური მატრიცა არის შედეგობრივი მატრიცა, რომელიც შეიცავს მასების სხვადასხვა კატეგორიებთან დაკავშირებულ ინფორმაციას – კონგრუენტულ, დივერსიულ, პასიურ და ნულოვან (ნარჩენ მასებს ნულოვანი მნიშვნელობებით). შესრულებული სამუშაოს ღრმა ანალიზის საფუძველზე სახეთა ამოცნობის კანონზომიერებები იყო გამოვლენილი.

<u>მასების სიმბიოზის ჰიპოტეზა.</u>

სიმბიოზურ მატრიცაში რაც უფრო მეტია კონგრუენტული და ნულოვანი წერტილები და ნაკლებია დივერსიული და პასიური წერტილები, მით უფრო მიახლოებულია რეცეპტორების მატრიცის გამოსახულება სახის საძიებელ ჯამურ მატრიცასთან, ე. ი. რეალურ გამოსახულებასთან.

სხვადასხვა კატეგორიებზე ჯამური მატრიცის წერტილების დაყოფის გრადაციის გამოყენებით და სიმბიოზური მატრიცის მიღებით შეიძლება გარკვეული ნიშნებით გამოვლინდეს ამა თუ იმ სახის სიმბოლოების გარკვეული კლასის წევრობა ქსელის ნეირომატრიცული თვითორგანიზაციის გამოყენებით.

მატრიცების ნეიროქსელური ალგორითმი სახეების ამოცნობისთვის.

ფაქტობრად ამოცანა მდგომარეობს იმაში, რომ (მბ)-ში შეყვანილი 40 კონფიგურაციის საფუძველზე ყოველი სიმბოლოსთვის გამოვლინდეს მათი დამახასიათებელი ნიშნები და ამოცნობილი იქნას გამოცნობაზე წარდგენილი სიმბოლო. მოცანა იყოფა შემდეგ ნაბიჯებად:

1. MS Excel ფაილიდან 2 760 შეყვანილი ეტალონური სიმბოლოების შემცველი (მბ)-ს ჩატვირთვა პროგრამაში;
2. ნებისმიერი სიმბოლოს გამოსახულების შეყვანა შემდგომი გამოცნობისთვის რეცეპტორების (12x16) მატრიცაში და მისი შენახვა BM P ფორმატში (16 Color);
3. ამოცნობისთვის შეყვანილი გამოსახულების შეჯერება ფაილიდან პროგრამაში;
4. გამოსახულების ორობითი წარმოდგენიდან ცხრილურ 0 და 1 მასივში გარდაქმნა, სადაც 0 შეესაბამება შეუღებავი, ხოლო 1 – შეღებილი უჯრედებს.
5. მე-2 ფენის შუალედური კონგრუენტული ნეირონული მატრიცის დათვლა;
6. მე-2 ფენის შუალედური დივერსიული ნეირონული მატრიცის დათვლა;
7. მე-2 ფენის შუალედური პასიური ნეირონული მატრიცის დათვლა;
8. მე-3 ფენის ჯამური სიმბიოზური ნეირონული მატრიცის დათვლა, რომელიც ემყარება პირველი და მეორე ფენების მატრიცების მახასიათებლებს;
9. სიმბიოზური მატრიცების მახასიათებლების გამოვლენა და გამოსავლებზე ჯამური მნიშვნელობების გამოთვლა.
10. სიმბიოზური მატრიცების გამოსავლების უდიდესი მნიშვნელობის გამოვლენა, მისი კოდის განსაზღვრა და შესავალზე შემოსულ გამოსახულებასთან ასოცირება;
11. 1-ლი დონის ჯამური მატრიცის (მასწავლებლით ან მასწავლებლის გარეშე) კორექტირება მაღალი შეცდომის შემთხვევაში;
12. მე-2 ნაბიჯზე გადასვლა, სანამ შეცდომის სიდიდე არ იქნება დამაკმაყოფილებელი.

ხელოვნური ნეირო-მატრიცული ქსელი (ხნმქ) აგებულია შემდეგი სქემით (ნახ. 16): ნეირონული სქემის შესასვლელზე შემოდის სიმბოლოს რასტრული გამოსახულება, შესავალი შეიძლება წარმოვადგინოთ როგორც რეცეპტორების მატრიცა, ხოლო გამოსახულება შეიძლება გამოიხატოს როგორც 0-ს და 1-ის მიმდევრობა, სადაც 0 – შეუღებავი უჯრედებია, ხოლო 1 – შეღებილი. რეცეპტორების მატრიციდან ინფორმაცია მიეწოდება და ტრანსფორმირდება მეორე დონეზე – წარმომადგენლების და (მბ)-ს ყოველი სახისთვის შეფასების კრიტერიუმების ნეირონული მატრიცების კლასი, ამის მერე შუალედური წონები დაითვლება და გამოიყენება მატრიცული სახით ჩაწერილი ელემენტების გადარჩევის კრიტერიუმები – მესამე დონე.

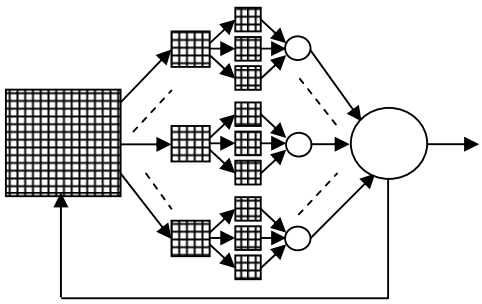

ნახ. 16 მატრიცული ნეირონული თვითორგანიზებადი ქსელის გრაფი.

შემდეგ ეტაპს წარმოადგენს მიღებული შედეგების აწონვა ყოველი მატრიცული სქემის მიზნობრივი ფუნქციის გამოთვლის მეშვეობით შეფასების სხვადასხვა კრიტერიუმების გათვალისწინებით. ყველა წონის გამოთვლის შემდეგ ბოლო ეტაპზე ტარდება მიღებული შედეგების გადათვალიერება და ყველაზე მიახლოებული სახე შეესაბამება ყველაზე მაღალ მნიშვნელობას. შექმნილ სქემაში გამოიყენება ქსელის თვითორგანიზაცია, ე.ი. სახის განსაზღვრის შემდეგ ხდება კრიტერიუმების სხვადასხვა მატრიცების წონის გადაწყობა ციკლში, ამგვარად სქემა არის არა სტატიკური, არამედ დინამიურად აწყობადი და ეფექტურად კრებადი. პრინციპიალურად ახალი თვითორგანიზებადი ნეირონული სქემის აგების საფუძველზე და ალბათურ-სტატისტიკური მეთოდების გამოყენებით მიღებული იყო ამოცნობის მაღალი შედეგები. ნახ. №16 მოცემულია აგებული ხელოვნური ნეირონული ქსელის (ხნქ)-ს სტრუქტურული სქემა.

ქვემოთ მოყვანილია სახეების ამოცნობისთვის უფრო დეტალური ნეირონული ქსელის ბლოკ-სქემა, რომელზეც აღწერილია (მბ)-ის ჩატვირთვის ძირითადი ეტაპები,

გამოცნობისთვის გამოსახულების შეყვანის, ჯამური, კონგრუენტული, დივერსიული, პასიური და სიმბიოზური მატრიცების ჩათვლით ყოველი სახისთვის და მიზნობრივი ფუნქციის გათვლა უმაღლესი მიახლოებული მნიშვნელობის, სახის ამოცნობის განმსაზღვრელი კოდის გამოსავლენად. (ხნქ)-ს შესაბამის ბლოკ-სქემას სახეთა გამოცნობისთვის აქვს შემდეგი სახე:

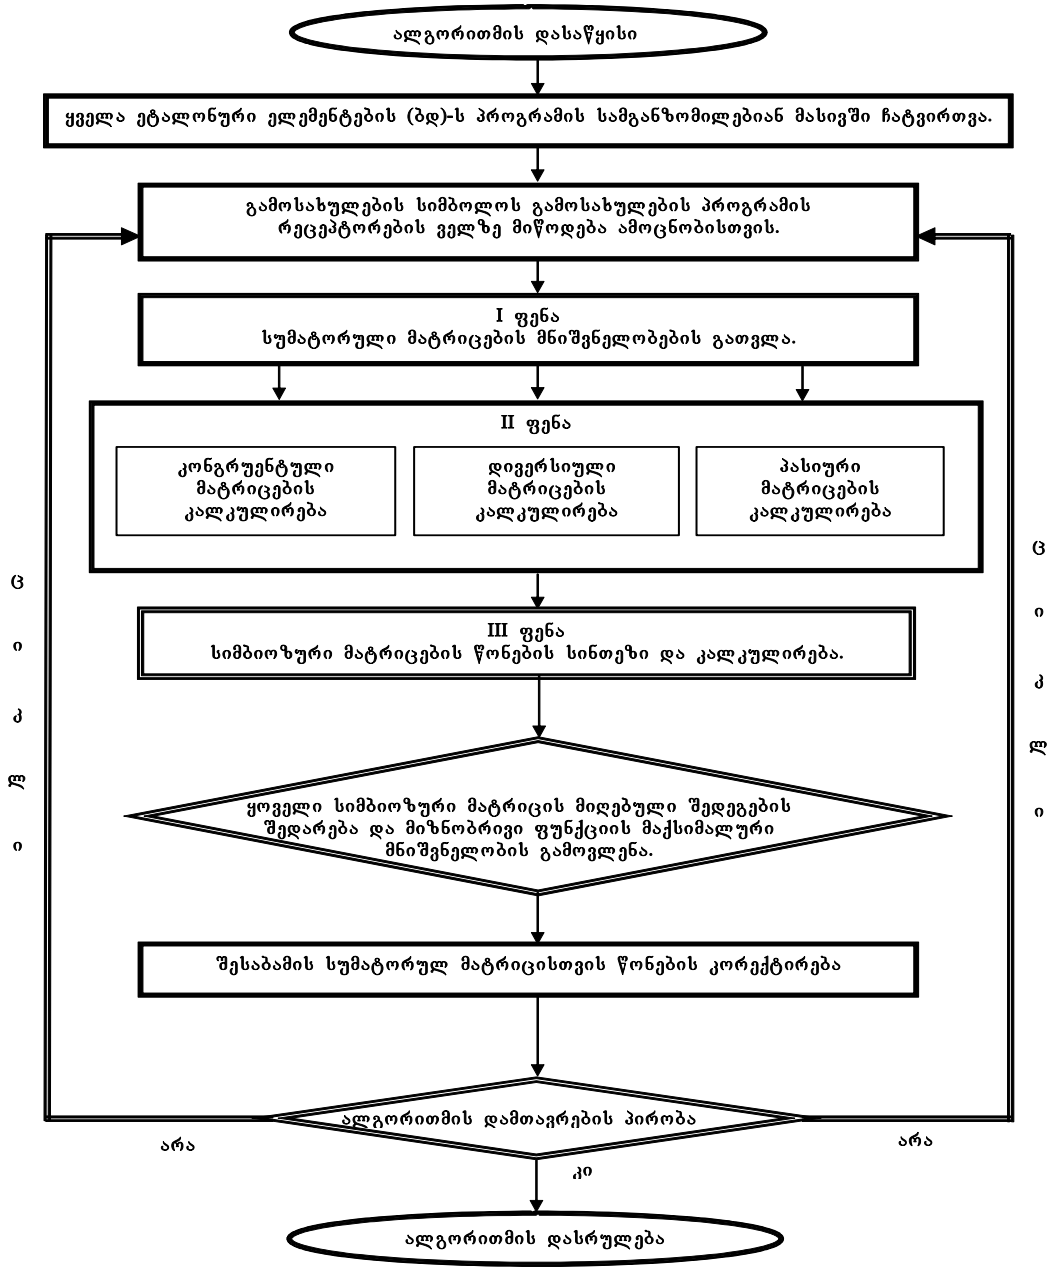

მიღებული შედეგები.

ჩატარებული სამუშაოს შედეგად იყო განხორციელებული პროგრამული მოდელი (ნახ. 17), რომელიც აწარმოებს სახეთა ამოცნობას (არაბული ციფრები, ქართული და ლათინური ანბანების ასოები) ხელოვნური ნეირონული ქსელის (ხნქ)-ს და სახეთა ალბათურ-სტატისტიკურ ანალიზის მეშვეობით. პროგრამა ახორციელებს სიმბოლოს გრაფიკული ინფორმაციის გადაყვანას მატრიცულ ფორმაში, ტვირთავს ეტალონურ (მბ)-ს პროგრამაში და ითვლის შუალედურ კონგრუენტულ, დივერსიულ და პასიურ ცხრილებს ყოველი სიმბოლოსათვის. შემდგომში ტარდება ყოველი სიმბოლოს სიმბიოზური მატრიცების გათვლა, წონების აწონვის ანალიზი და საბოლოო მნიშვნელობების მიღება, რომლებიდანაც უნდა გამოვლინდეს უდიდესი, რომელიც საზღვრავს ამა თუ იმ სიმბოლოს კუთვნილების კოდს.

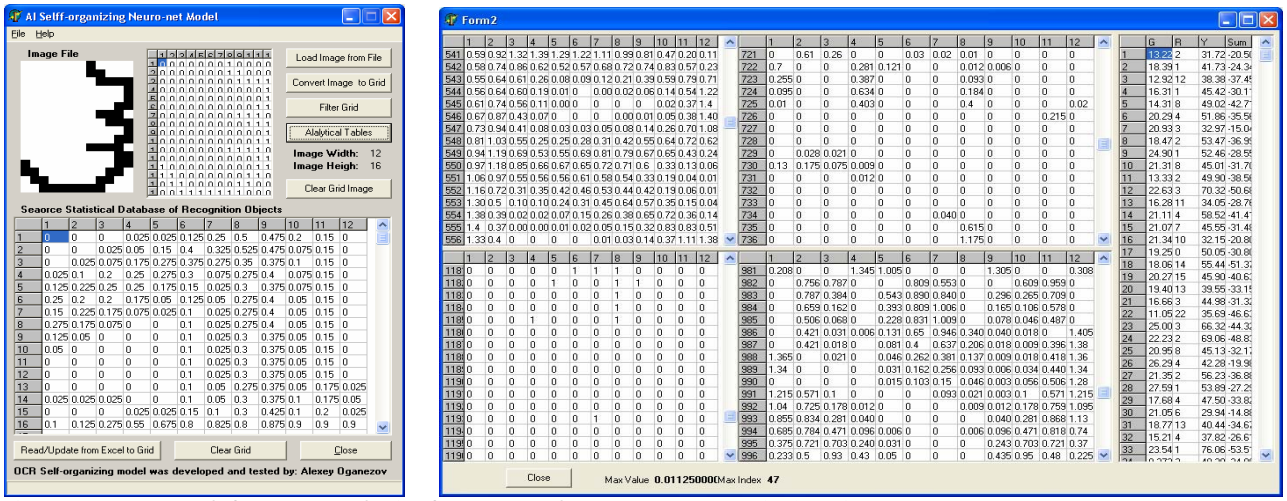

ნახ. 17 პროგრამების ფრაგმენტები და სუმატორული, კონგრუენტული, დივერსიული და პასიური გათვლის მატრიცების ანალიზი.

პროგრამა შეიცავს მეთოდოლოგიურად ახალ მიდგომას რაც მდგომარეობს მეთოდის გამოყენებას ალბათურ-სტატისტიკური (ხნქ)-ს პროგრამის აპრობაციის შედეგად მიღებული იყო სახეთა გამოცნობის მაღალი მაჩვენებლები. პროგრამა მოდელირებულია ხელნაწერისთვის და ადვილად შეიძლება ადაპტირებული იქნას კონკრეტულ შრიფტზე ამოცნობის გაუმჯობესების მიზნით. ამოცნობისთვის კონკრეტულ შრიფტის არჩევისას და მოდელის ამ შრიფტზე ნეიროშეწყობა საწყისი დაკალიბრებული (მბ)-ს მეშვეობით პროგრამა არსებითად ამოცნობის პროცენტს ამაღლებს და აღწევს 97%-ს და უფრო მეტსაც შეწყობის ხარისხზე დამოკიდებულებით, რაც გვაძლევს საშუალებას გამოვიყენოთ ეს პროგრამული მოდულური ბირთვი სხვა პროგრამებში.

პროგრამა ადარებს, აანალიზებს და ცვლის წონითი მატრიცების წონების მახასიათებლებზე მოდელის რაც ზრდის ეფექტურებას და სიზუსტეს. ამის გარდა სიმბოლოების გამოცნობა ხორციელდება საკმაოდ ოპერატულად, მილისეკუნდებში, და თან არ გამოიყენება განპარალელობის შესაძლებლობა პროცესების ბლოკური სტრუქტურული გაყოფის მიუხედავად. მთლიანობაში შექმნილი პროგრამა უნიკალურია და ეფექტურია ნებისმიერი ბრტყელი სიმბოლოების ამოცნობისათვის, რომელიც ეყრდნობა ხელნაწერ ეტალონურ (მბ)-ს ჩაშენებული ალბათურ-სტატისტიკური (ხნქ)-ით, ანალიტიკური გათვლის მექანიზმებით და მულტიმატრიცული ფენების შეწყობით.

დასკვნა

ჩატარებული გამოკვლევების საფუძველზე შემოთავაზებულია სახეთა გამოცნობის ახალი მეთოდი – სამფენოვანი ხელოვნური ნეირო-მატრიცული ქსელის აგების მასწავლებლის გარეშე, რომელიც ეყრდნობა წონითი კოეფიციენტების წერტილოვან შეფასებების ალბათურ-სტატისტიკურ ანალიზს. სადისერტაციო შრომის ძირითადი შედეგები შემდეგია:

1. ნაშრომში შესწავლილია ნეირობიოლოგიის, კიბერნეტიკის და ხელოვნური ინტელექტის ძირითადი პრინციპები, რომლებიც გამოიყენება სახეთა ამოცნობის პრობლემის გადაწყვეტაში.
2. ფორმირებულია ეტალონური სახეების მონაცემთა ბაზა (მბ), რომელიც შედგება 10 არაბული ციფრისაგან, 26 ლათინური ასოგან და 33 ქართული ასოსაგან. მათი ფორმირებისათვის საჭირო გახდა ყოველი სიმბოლოსათვის დაახლოებით რასტრული ეგზემპლარის 40 ნაირსახეობის შეყვანა სისტემაში.
3. გაანალიზებულია და დათვლილია წერტილოვანი მატრიცების ალბათობების სტატისტიკური მაჩვენებლები შეყვანილი რასტრული 529920 წერტილისათვის, წონების ჯამისთვის, ალბათობებისთვის, გასაშუალოებელი მნიშვნელობებისთვის და მატრიცების წონების მედიანებისთვის, ჩატარებულია წერტილების რაოდენობის კონტროლი ყველა ეტალონური სახეებისთვის, რომლებსაც გააჩნია აქტიური წერტილების გამოჩენის ალბათობა დიაპაზონებიდან [0, 00], [0.00–0.25], [0.25–0.50], [0.50–0.75], [0.75–1.00], [1,00], ყოველი სიმბოლური სახის მახასიათებლების გამოსავლინებლად.

4. აგებულია გამოსახულების ზონდების ვერტიკალური და ჰორიზონტალური შემადგენლების დამოკიდებულების გრაფიკები, წერტილოვანი წონების ხაზოვანი გრაფიკები და აგრეთვე წერტილოვანი ალბათობების 3D-სვეტიანი დიაგრამები ყოველი სახესთვის.
5. შემოყვანილია ახალი განსაზღვრებები და ცნებები, რომლებიც გამოიყენება სახეთა გამოცნობისთვის v-ზონდის და h–ზონდის მატრიცების კონგრუენტული, დივერსიული, პასიული და სიმბიოზური ნულოვანი მატრიცების სახეობები.
6. შექმნილია ყოველი სიმბოლოს კონგლომერატული სტატისტიკური მონაცემები, რომლებიც გამოყენებულია (სნქ)-ს პირველი ფენის ჯამური მატრიცების ასაგებად და პირველი და მეორე დონეების ინტერპოლაციური ჯამური მატრიცის წონითი კოეფიციენტების დაბალანსებისა და გასწორებისთვის. აგებულია მეორე ფენის შუალედური ნეირომასივები: კონგრუენტული, დივერსიული და ნეიტრალური, აგრეთვე მესამე ფენის სიმბიოზური მატრიცები.
7. ფორმირებულია ხელოვნური სამფენიანი ნეირო-მატრიცული სქემა მასწავლებლის გარეშე ბრტყელი გრაფიკული სახეების ამოცნობისთვის. სქემის დემონსტრირებისა და ტესტირებისათვის შექმნილია პროგრამული უზრუნველყოფა, რომელიც შედგება ორი ნაწილისგან. პირველი ნაწილი წარმოდგენილია MS Excel-ის ფაილის სახით, ხოლო მეორე რეალიზებულია RAD Delphi საშუალებებით.
8. შემუშავებულია ბლოკ-სქემა და (სნქ)-ს სწავლების ალგორითმი, კომპილირებულია საპროექტო მოდულები და აპრობირებულია პროგრამული უზრუნველყოფა RAD Borland Delphi არეში Object Pascal პროგრამირების ენაზე.
9. მოდელირებული პროგრამა ახდენს გამოცნობისთვის შემოსული სახის ღრმა ანალიზს, გაატარებს მას (სნქ)-ს ფენებში, ადარებს (მბ)-დან ყოველ ჯამურ მატრიცულ ანაბეჭდს, ავლენს კანონზომიერებებს, ახდენს იდენტიფიცირებას, საჭიროების შემთხვევაში გარდაქმნის წონით კოეფიციენტებს და განსაზღვრავს სიმბოლოს კონკრეტულ კლასს.
10. ახალი შემუშავებული მეთოდიკა უნიფიცირებულია და შეიძლება გამოყენებული იქნას ბრტყელი სიმბოლოების, ნიშნების, ნაბეჭდი შრიფტების, ანბანების და აგრეთვე ხელნაწერი გამოსახულებების ამოცნობისთვის.
11. მიღწეულია სახეთა ამოცნობის ეფექტურობა და მაღალი პროხენტი – 97%. შედარებით კომპაქტური და კარგად გამოყოფადი სახეთა კლასებისათვის შესაძლებელია ეგრეთვე დამუშავების პირველივე ციკლის დროს მოვახდინოთ მასწავლი ნაკრების მოცულობის საგრძნობი შემცირება, რაც (ხნქ)-ს კარგად მოდილირებული სტრუქტურის მაჩვენებელია.
12. ექსპერიმენტების შედეგები ადასტურებს მიღებული შედეგების ეფექტურობას და შესაძლებელია მათი გამოყენება ნებისმიერი ბრტყელი ფიგურების გამოცნობის ამოცანებში.

დისერტაციის ძირითადი შედეგები ასხულია სამეცნიერო ნაშრომებში:

1. Oganezov A. “Neuro-matrix object recognition model”, “Bulletin of the Georgian National Academy of Sciences”, Tbilisi, V. 173 №3, 2006.
2. Oganezov A. “Flat figures recognition based on fingerprinting signs in neural nets”, “Bulletin of the Georgian National Academy of Sciences”, Tbilisi, V. 174 №1, 2006.
3. Кочладзе З.Ю., Оганезов А.Л., “Об одном возможном подходе к проблеме распознавания плоских фигур”, “Труды Тбилисского Государственного Университета им. Ив.Джавахишвили”, Тбилиси, 2005, № 364 (24), стр. 149-155.
4. ოგანეზოვი ა. “ინფორმაციული დამუშავების ალბათობითი და ნეირონული სქემების გამოყენება ქართული შრიფტების ამოცნობის პროცესისათვის”, “მეცნიერება და ტექნოლოგიები”, თბილისი, №1-3, 2006, გ. 30-31.
5. Кочладзе З.Ю., Оганезов А.Л. “Использование двухслойной нейронной модели в процессах распознавания образов”, “Энергия”, Тбилиси, 2005 №4(36) I, стр. 78-82.
6. Оганезов А.Л., Кочладзе З.Ю. “Задача распознавания инженерных 2D чертежей и преобразование в электронные 3D стереометрические объекты”, “Энергия”, Тбилиси, 2005 №4(36) I, стр. 72-81.
7. ოგანეზოვი ვ., ოგანეზოვი ა. “არატრადიციულ ენერგეტიკაში გამოთვლითი ტექნიკის გამოყენება”, “ბუნება და ენერგია”, თბილისი, 19-20 ივნისი, 1998, გ. 138-144.
8. Oganezov A. “Creation of Energy Efficiency Fund for Georgia”, “Proceedings of Second International Energy Conference in Armenia”, Part 2, Yerevan, Armenia, Sept. 24-28, 2001, p: 47-51.

Тбилисский Государственный Университет им. И. Джавахишвили

на правах рукописи

ОГАНЕЗОВ АЛЕКСЕЙ ЛЕВАНОВИЧ

ПРИМЕНЕНИЕ НЕЙРОННЫХ СЕТЕЙ В ЗАДАЧАХ РАСПОЗНАВАНИЯ ОБРАЗОВ

05.13.11 – математическое и программное обеспечение для вычислительных машин, систем, комплексов и сетей

А В Т О Р Е Ф Е Р А Т

диссертации на соискание ученой степени
кандидата физико-математических наук

Тбилиси
2006

Диссертационная работа выполнена в Тбилисском Государственном Университете им. И. Джавахишвили.

Научный руководитель: **Кочладзе Зураб,**
кандидат технических наук, доцент

Официальные оппоненты: **Меладзе Гамлет**,
доктор физико-математических наук, профессор

Сихарулидзе Анна,
кандидат физико-математических наук

Защита диссертации состоится 22 Декабря 2006 г. в 14^{00} ч. на заседании диссертационного совета Ph.M.01.08 №8 Тбилисского государственного университета им. И. Джавахишвили. Адрес: ул. Университетская №2, г. Тбилиси, 0043, ТГУ Институт прикладной математики им. И. Векуа.

Ознакомление с диссертацией возможно в библиотеке Тбилисского государственного университета им. И. Джавахишвили. Адрес: ул. Университетская №2, г. Тбилиси, 0043

Автореферат разослан 20 Ноября 2006 г.

Ученый секретарь диссертационного совета,
доктор физико-математических наук,
профессор /Т. Тадумадзе/

Общая характеристика работы.

Актуальность темы. Одной из самых актуальных и развивающихся тенденций кибернетической науки является искусственный интеллект, в котором различают два основных направления:

- символьное (семиотическое, нисходящее), основанное на моделировании высокоуровневых процессов мышления человека и использовании знаний;
- нейрокибернетическое (нейросетевое, восходящее), основанное на моделировании отдельных низкоуровневых структур мозга (нейронов).

Главной задачей искусственного интеллекта является построение интеллектуальных компьютерных систем, которые обладали бы уровнем эффективности решений неформализованных задач, сравнимым с человеческими возможностями или превосходящим их.

Создание нейрокомпьютеров и моделирование адаптивных нейронных сетей рассматривается как наиболее востребованное направление в решении многих проблем искусственного интеллекта. Актуальность исследований в этом направлении подтверждается массой различных применений, например: автоматизация процессов распознавания речи и образов, доказательство математических теорем, искусственный синтез речи по тексту, создание экспертных систем, аппроксимация функционалов, машинный перевод текстов, прогноз финансовых показателей на биржевом рынке, управление бизнес процессами, построении нейронных самообучающихся систем и многое другое.

В настоящее время одним из актуальных вопросов информационных технологий в области искусственного интеллекта является проблема распознавания образов с применением принципиально новых методов, использующих искусственные самоорганизующиеся нейронные сети. Для осуществления преобразования рукописной и печатной информации в электронный вид наиболее актуальной проблемой в Грузии является распознавание шрифтов грузинского алфавита.

Цель работы. Целью данной работы является проектирование искусственной матрично-самоорганизующейся нейронной сети и моделирование программной реализации для распознавания любых символьных образов (в частности цифр, символов латинского и грузинского алфавитов), а также достижение высокого результата классификации при минимально возможном разрешении матрицы рецепторов и количестве представителей образов из каждого набора символьных элементов базы данных.

Методы исследования. В работе использованы теория искусственных самоорганизующихся нейронных сетей для графических массивов базы данных с применением процесса распознавания без учителя, алгоритмы обратного распространения, метод зондов, теория вероятностей и статистический анализ, теория кодирования/декодирования и дискретных систем, концептуального анализа, теория множеств и кластеризации/категоризации объектов, методы алгоритмизации, методы компьютерного моделирования в VBA для Access и на основе MS Excel статистических таблиц, а также объектно-ориентированного программирования (ООП) на языке Object Pascal в среде Rapid Application Development (RAD) оболочки Borland Delphi.

Научная новизна. Имеющиеся в арсенале алгоритмы классификации в основном используют неадаптивные алгоритмы распознавания образов, которые работают для определенных печатных шрифтов. Незначительное отклонение от стандартного изображения приводит к низким результатам распознавания. На основе проведенных исследований предложены новые и эффективные методы распознавания образов с помощью искусственной нейронной сети (ИНС) без учителя не только для печатных, но и рукописных символов, в частности цифр и букв грузинского и латинского алфавитов, позволяющие существенно повысить коэффициент распознавания образов. Научная новизна заключается в формулировании методики и создании нового, адаптивного алгоритма, с использованием ИНС без учителя и вероятностно-статистического анализа графической информации. Были введены понятия v/h-зондов, конгруэнтных, диверсивных, пассивных и нейтральных масс, представляющих собой различные категории весов нейронной сети; а также различные виды матриц: сумматорные, конгруэнтные, диверсивные, пассивные и симбиозные. На основе новой методики сформулирована гипотеза симбиоза масс для детерминирования принадлежности изображения к тому или иному классу визуальных объектов.

Практическая и теоретическая ценность работы. На основе построения принципиально новой нейронной схемы и применения вероятностно-статистических методов получены высокие результаты распознавания не только печатных, но и прописных образов. Обычно для качественного исследования набора символов используют эталонные символы, к примеру, в номинальном количестве 1000 экземпляров и разрешении матрицы 120x160 точек. При учете если мы имеем дело, например, как в нашем случае, с 69 разновидностями символов и 25%-ой активности воспринимающей матрицы точечной закраски, имеем 331200000 (331.2 миллионов активных закрашенных точек). Основной ценностью нового метода является то, что вопреки уменьшению базы набора для исследования графической информации, получается более качественный результат, т.е. при минимальном количестве введенных эталонных образов, а именно в

количестве всего 40 прототипов для каждого символа, вводимых в базу данных и при минимально возможной матрице рецепторов с разрешением 12x16 точек получается высокий результат распознавания. Таким образом, вместо номинальных для внесения 331200000 точек мы имеем дело с 132480 точками, что на 331067520 точек меньше понадобилось для ввода и информационной обработки изображений. Существенное уменьшение базы данных набора в данном случае на 99.96% и повышения эффективности распознавания объектов является большой практической ценностью нового метода.

Реализация результатов исследования. Результаты исследований предложены для имплементации на кафедре Кибернетики Тбилисского Государственного Университета им. И. Джавахишвили.

Апробация работы. Основные положения и результаты диссертационной работы докладывались на семинарах кафедры искусственного интеллекта Тбилисского Государственного Университета им. И. Джавахишвили, на конференциях Московского Государственного Университета Экономики Статистики и Информатики (МЭСИ).

Публикации. Основные результаты диссертации содержатся в приведенном списке публикаций автореферата – 8 научных работах. В работах, написанных в соавторстве, научные результаты были получены с активным участием диссертанта.

Содержание работы.

Во введении обоснована актуальность темы диссертации, в частности решение задачи распознавания образов с применением альтернативной технологии обработки информации – искусственных нейронных сетей (ИНС), сформулированы цель работы, методы исследования, научная новизна и практическая ценность, дается краткое изложение диссертации по главам.

В первой главе диссертации рассматриваются вопросы нейробиологии, в частности дается общее понятие о структуре и строении мозга, биологическом нейроне, составляющих его элементах (аксоны, синапсы, дендриты), типах его клеток, синаптичесокой силе, нейронных сетях и принципах их работы, проводится аналогия между компьютером и человеческим мозгом. Излагается понятие искусственного нейрона, весов, активационных функций (сигмоидальной логистической и гиперболического тангенса), пороговой величины, коэффициентов усилений; также были рассмотрены однослойные и многослойные искусственные нейронные сети; архитектура и свойства сетей с обратным распространением ошибки (Eerror Backpropagation), нейронные сети Хебба прямопоточных (Feedforward) сетей, алгоритм Кохонена обучения без учителя и основанные на этом методе нейронные сети особого типа – так называемые самоорганизующиеся структуры с подстройкой синапсов – Self-organizing Feature Maps (SOM), однослойные сети Хопфилда и двухслойные сети Хэмминга с ассоциативной памятью, а также формальные алгоритмы обучения сетей.

Во второй главе диссертации рассмотрены рецепторная структура восприятия информации, понятие образа, проблема обучения распознаванию образов (ПРО), геометрический и структурный подходы проблемы распознавания образов, гипотеза компактности и понятие адаптации. Приведен метод зондов и преобразование изображений в цифровой код. Рассмотрены алгоритмические построения и процесс обучения искусственных нейронных сетей с учителем и без учителя. Даны алгоритмы распознавания образов, в частности, алгоритм секущих плоскостей, алгоритм, основанный на методе потенциалов. Рассмотрен метод обучения Уидроу-Хоффа и исследования Кохонена на самоорганизующихся структурах. Описаны составные элементы (R/S/A) и интегральное устройство персептрона Розенблатта, анализируется работа персептрона, основывающаяся на принципах структуры мозга и зрительного аппарата и его применение для распознавания образов. Приведена так же схемотехника и функциональность узнающей машины Гамба. Затронут вопрос персептронной представляемости, потенциал многослойных персептронов и проблема функции «исключающего ИЛИ».

В третьей главе диссертации рассмотрены вопросы моделирования искусственных нейронных сетей для распознавания образов, проблемы, возникающие при этом, такие как достаточность набора базы данных образов, качество эталонных составляющих, а также этапы разрешения проблем, в частности операции группировки, секвестирования, ассоциирования. Описывается матрица рецепторов, проводятся подсчеты статистических показателей, сумм весов и вероятностей матрицы, усредненных значений и медиан весов матрицы, а также анализ количества точек, имеющих вероятности появления активных (закрашенных) точек из диапазонов [0.00], (0.00-0.25], (0.25-0.50], (0.50-0.75], (0.75-1.00], [1.00], для выявления характеристик каждого символьного образа. Также построены графики зависимостей вертикальных и горизонтальных составляющих зондов изображения, линейный график точечных весов, 3D-колонные диаграммы точечных вероятностей для каждого образа, описан новый метод точечной интерполяции весов первого и второго уровня на основе метода потенциалов. Были созданы усредненные контуры каждого символа и построена нейронная самообучающаяся сеть обработки изображения для

улучшения показателей сходимости и распознавания. Разработана блок-схема и функциональный граф матричной нейронной самоорганизующейся сети для распознавания образов. В результате проведенной большой исследовательской работы была построена гибридная модель искусственной самоорганизующейся нейронной сети, использующая вероятностно-статистический анализ изображений. Данная комплексная модель программно была реализована и апробирована на примере распознавания арабских цифр, латинского и грузинского алфавитов. В результате апробации было выявлено, что преимуществом данной программы является то, что она может распознавать как печатные, так и непечатные символы, может быть применена для классификации любых алфавитов и контурных изображений, а также дает высокие результаты распознавания символов при экспериментально низком разрешении матрицы рецепторов и малой базе набора эталонных изображений. Представлены также фрагменты программы и листинг алгоритмов распознавания образов, на основе многослойной самоорганизующейся нейросети, использующей обработку двумерных массивов, трансформацию изображений с машинного в цифровой код, матричные калькуляции, вероятно-статистический анализ табличных данных и графических диаграмм, а так же различные оценочные операции над дискретными множествами.

Разрешимость проблемы распознавания образов (РО) зависит от многих факторов. Условием для качественного РО является достаточный набор введенных эталонов – Базы Данных (БД) представителей каждого класса, используя которую можно проводить аналитические сверки и применять алгоритмы нейросетевой идентификации. Точность и эффективность распознавания символов непосредственно зависит от хорошо подобранных и откалиброванных эталонных представителей. Внесение в эталонную БД плохо детерминированных и сильно искаженных объектов может повлечь за собой трудности при классификации образов, что существенно снизит процент распознавания. Представители каждого символа БД должны обладать следующими характеристиками: быть классифицируемыми, не быть сильно схожими между собой и не содержать сильно деформированные элементы внутри класса. Если один и тот же символ имеет различное визуальное начертание, то БД должна подразделяться на сепарированные классы синонимных символов, которые должны ассоциироваться с одним и тем же образом. Примером могут служить следующие изображения символов, приведенных на рис. 1

Для распознавания образов была использована комбинированная нейросетевая схема настройки весов с алгоритмом обратного распространения ошибки. Это позволило ИНС в рабочих циклах самонастроиться на этапе обучения и постепенно устранить погрешности. Самоподстройка или обучение может осуществляться как с учителем, т.е. когда пользователь может делать предпочтение, к какому образу более близок поступивший на вход программы символ, так и без учителя, путем автоматической самонастройки соответствующих весов нейронной матрицы на разных уровнях без участия человека.

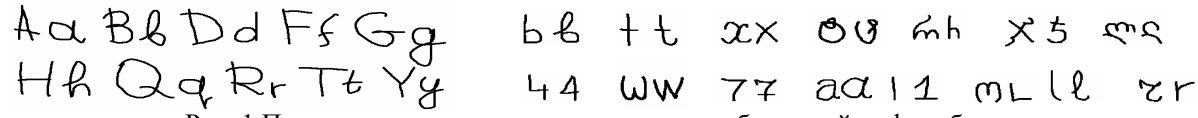

Рис. 1 Примеры различных «синонимных» изображений цифр и букв.

Реализация обучения без учителя является наиболее эффективным и автоматизированным способом, но в тоже время более сложным для имплементации, тем не менее, именно этот способ был заложен в основу алгоритма для РО.

Изображения эталонных символов подают на матрицу рецепторов и хранят в БД. Чем выше разрешение матрицы рецепторов и количество экземпляров, тем меньше возникнет погрешностей связанных с метаморфозным сходством символов и тем точнее можно аналитически выявить закономерности и идентифицировать признаки для построения рекогнационной модели. Настоящей работой ставилась задача достижения распознавания при редуцировании количества эталонных экземпляров и разрешения матрицы рецепторов без потери эффективности распознавания. Поэтому была выбрана оптимальная матрица с разрешением 12x16 и БД представителей из набора всех цифр, букв латинского и грузинского алфавитов по 40 экземпляров для каждого символа.

Несмотря на ужесточение условий для идентификации, построенная модель дала высокие результаты распознавания объектов, благодаря хорошо построенной схеме ИНС. На рис. 2 приведен пример заполнения поля рецептора 34-мя точками, в результате которого получается графически-цифровое изображение цифры семь. Фрагменты некоторых произвольных изображений цифр и букв БД [2] приводятся на рис. 3. Декодирование изображения из графического формата файла, поступившего на вход программы и трансформирование в матричный вид для последующего распознавания. Изображение символа хранится в графическом файле в закодированном виде. Для анализа закодированного изображения необходимо преобразовать его в более доступный для восприятия матричный вид [3], используя формат

построения BMP файл. Заголовок формата BMP хранит служебную информацию о структуре, размере, глубине цвета, типе компрессии, числе плоскостей, ширине, высоте, зарезервированных полях и др.

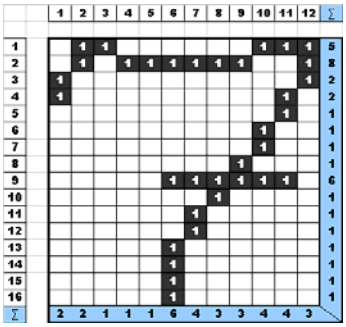

Рис. 2 Матрица рецепторов.

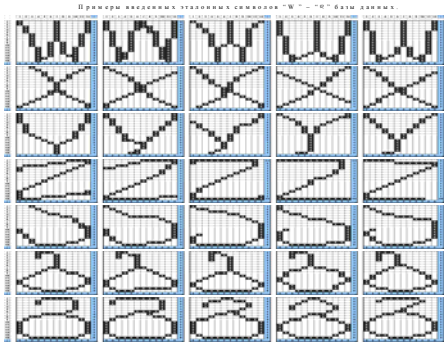

Рис. 3 Примеры введенных символов.

Само изображение начинается с кодового блока с индексом 118 в HEX формате (рис. 4). Код “FF” внутри тела шифра файла определяет белую, не закрашенную точку, а “00” – черную. Файл, несущий изображение, содержит также разделительные блоки между строками, смещен на фазу забронированных символов, хранится в перевернутом и транспонированном виде (записан по строкам слева направо и снизу вверх). В программе был успешно реализован модуль, осуществляющий декодирование графического изображения из файла BMP в двухмерный нормализованный массив “0” и “1”.

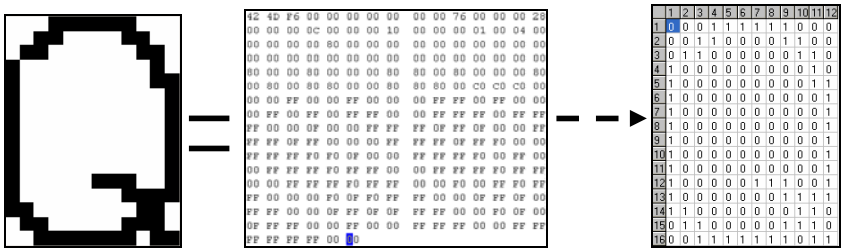

Рис. 4 Преобразование изображения из графического вида в цифровой табличный 2D массив.

Для каждой из 69 исследуемых символов (цифр и букв) были построены две таблицы, названные сумматорными матрицами точечных весов и точечных вероятностей, содержащие соответственно суммарные значения точечных весов и точечных вероятностей введенных эталонов. Фактически сумматорная матрица точечных весов (рис. 5) представляет собой матрицу наложений всех символьных прототипов на одну генерируемую матрицу, в результате чего на ней вырисовывается изображение символа при запрограммированном выявлении градиентного закрашивания на табличном поле значений, если значение точечных весов перевешивает определенные пороговые значения. На примере буквы “ა” грузинского алфавита приведены сумматорные матрицы точечных весов и точечных вероятностей (рис. 5).

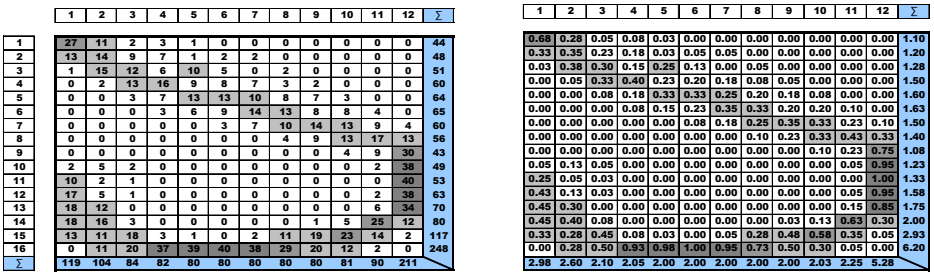

	1	2	3	4	5	6	7	8	9	10	11	12	∑
1	27	11	2	3	1	0	0	0	0	0	0	0	44
2	13	14	9	7	1	2	2	0	0	0	0	0	48
3	1	15	12	6	10	5	0	2	0	0	0	0	51
4	0	2	13	16	9	8	7	3	2	0	0	0	60
5	0	0	3	7	13	13	10	8	7	3	0	0	64
6	0	0	0	3	6	9	14	13	8	8	4	0	65
7	0	0	0	0	0	3	7	10	14	13	9	4	60
8	0	0	0	0	0	0	0	4	9	13	17	13	56
9	0	0	0	0	0	0	0	0	0	4	9	30	43
10	2	5	2	0	0	0	0	0	0	0	2	38	49
11	10	2	1	0	0	0	0	0	0	0	0	40	53
12	17	5	1	0	0	0	0	0	0	0	2	38	63
13	18	12	0	0	0	0	0	0	0	0	6	34	70
14	18	16	3	0	0	0	0	0	1	5	25	12	80
15	13	11	18	3	1	0	2	11	19	23	14	2	117
16	0	11	20	37	39	40	38	29	20	12	2	0	248
∑	119	104	84	82	80	80	80	80	80	81	90	211	

	1	2	3	4	5	6	7	8	9	10	11	12	∑
1	0.68	0.28	0.05	0.08	0.03	0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.10
2	0.33	0.35	0.23	0.18	0.03	0.05	0.05	0.00	0.00	0.00	0.00	0.00	1.20
3	0.03	0.38	0.30	0.15	0.25	0.13	0.00	0.05	0.00	0.00	0.00	0.00	1.28
4	0.00	0.05	0.33	0.40	0.23	0.20	0.18	0.08	0.05	0.00	0.00	0.00	1.50
5	0.00	0.00	0.08	0.18	0.33	0.33	0.25	0.20	0.18	0.08	0.00	0.00	1.60
6	0.00	0.00	0.00	0.08	0.15	0.23	0.35	0.33	0.20	0.20	0.10	0.00	1.63
7	0.00	0.00	0.00	0.00	0.00	0.08	0.18	0.25	0.35	0.33	0.23	0.10	1.50
8	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.10	0.23	0.33	0.43	0.33	1.40
9	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.10	0.23	0.75	1.08
10	0.05	0.13	0.05	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.05	0.95	1.23
11	0.25	0.05	0.03	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.00	1.33
12	0.43	0.13	0.03	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.05	0.95	1.58
13	0.45	0.30	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.15	0.85	1.75
14	0.45	0.40	0.08	0.00	0.00	0.00	0.00	0.00	0.03	0.13	0.63	0.30	2.00
15	0.33	0.28	0.45	0.08	0.03	0.00	0.00	0.05	0.28	0.48	0.58	0.35	0.05	2.93
16	0.00	0.28	0.50	0.93	0.98	1.00	0.95	0.73	0.50	0.30	0.05	0.00	6.20
∑	2.98	2.60	2.10	2.05	2.00	2.00	2.00	2.00	2.00	2.03	2.25	5.28	

Рис. 5 Сумматорные матрицы точечных весов и точечных вероятностей.

Введены новые термины, определяющие расположения зондов по вертикали и горизонтали, названные соответственно v-zond (вертикальные) и h-zond (горизонтальные) и подсчитаны суммы весов по вертикальным и горизонтальным составляющим матриц. Для апробационного анализа изображений и РО был использован новый модифицированный метод, в котором в отличие от стандартного метода зондов, применялось насыщенное количество v/h-зондов – 28 зондов, полностью захватывающих поле рецепторов с целью улучшения детектирования характерных признаков различий между символами. Однако из

экспериментов было выявлено, что насыщение зондов несущественно улучшает процесс идентификации, т.к. в этом методе количество пересечений точек матрицы с зондами не однозначно определяет позицию пересечения, и в результате не всегда будет идентифицировать паттерн опознаваемого изображения.

В разработанной программе была реализована процедура автоматической загрузки исследуемых статистических данных из множества MS Excel таблиц и загрузки генеральной БД характеристик всех исследуемых классов в программное приложение.

В процессе анализа статистических и вероятностных закономерностей были подсчитаны характеристики каждого представителя класса. Для выявления характеристик изображений были исследованы сумматорные точечные вероятности, которые были условно разделены на четыре диапазона (0,0.25], (0.25,0.5], (0.5,0.75], (0.75,1.00] и ассоциированы с цветовой палитрой для визуального выделения доминирующих и рецессивных вероятностей, что дало суммарную визуальную картину вероятностного распределения точек каждого символа на поле рецепторов.

Диапазоны вероятностей и соответствие цветов точек:

(0,0.25] – белые точки
(0.25,0.5] – светло-серые точки

(0.5,0.75] – темно-серые точки
(0.75,1.00] – черные точки

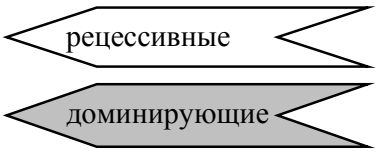

Общее количество статистически проанализированных точек данной задачи составило 529920 (69 символов x 40 эталонов БД x 192 точек матрицы рецепторов). На основе матриц точечных вероятностей для каждого образа из БД были подсчитаны общие статистические данные (табл. 1): суммы весов матрицы, суммы вероятностей матрицы, среднее значение матрицы, медиана весов матрицы, а также количество точек, имеющие различные диапазоны вероятностей.

Для выявления характеристик образов и балансирования распределения точечных вероятностей была дополнительно реализована модификация метода потенциалов для сумматорной матрицы, названная интерполяционным сглаживанием точечных весов первого уровня (рис. 6). Этот метод позволяет заполнять пустоты между эталонными начертаниями и выявлять доминирующие и устранять рецессивные группы точек путем естественного отбора масс. Это позволяет на основе мини набора эталонной БД автоматически получить картину сумматорной матрицы, соответствующую количеству макси набора БД, что резко повышает эффективность и уменьшает надобность ввода огромных массивов эталонных экземпляров в БД. Для анализа образов может быть использована также рекуррентная интерполяция второго уровня на основе использования сглаживания матрицы первого уровня. Интерполяционное сглаживание точечных весов второго уровня (рис. 6) дает более сбалансированное распределение весов матрицы, в результате чего можно идентифицировать опознаваемые объекты с более высокой вероятностью или меньшей погрешностью ошибки.

0.99	0.60	0.27	0.18	0.09	0.03	0.02	0.01	0.00	0.00	0.00	0.00	2.19
0.67	0.63	0.44	0.31	0.13	0.11	0.08	0.01	0.01	0.00	0.00	0.00	2.39
0.25	0.58	0.56	0.39	0.42	0.25	0.09	0.09	0.02	0.01	0.00	0.00	2.65
0.09	0.19	0.52	0.63	0.47	0.41	0.33	0.19	0.12	0.04	0.01	0.00	2.98
0.01	0.06	0.20	0.37	0.55	0.56	0.48	0.40	0.32	0.17	0.05	0.02	3.18
0.00	0.01	0.04	0.17	0.30	0.43	0.58	0.57	0.44	0.38	0.22	0.09	3.21
0.00	0.00	0.01	0.03	0.07	0.19	0.34	0.47	0.59	0.58	0.45	0.32	3.04
0.00	0.00	0.00	0.00	0.01	0.03	0.08	0.23	0.41	0.56	0.72	0.67	2.70
0.04	0.03	0.02	0.01	0.00	0.00	0.01	0.04	0.09	0.26	0.59	1.15	2.23
0.14	0.18	0.08	0.01	0.00	0.00	0.00	0.00	0.01	0.05	0.43	1.36	2.24
0.41	0.18	0.07	0.01	0.00	0.00	0.00	0.00	0.00	0.01	0.38	1.40	2.46
0.66	0.32	0.09	0.01	0.00	0.00	0.00	0.00	0.00	0.03	0.42	1.36	2.87
0.79	0.54	0.12	0.01	0.00	0.00	0.00	0.00	0.02	0.12	0.51	1.27	3.38
0.80	0.69	0.26	0.08	0.01	0.01	0.04	0.10	0.21	0.40	0.93	0.71	4.23
0.61	0.58	0.77	0.44	0.40	0.38	0.42	0.62	0.79	0.88	0.60	0.32	6.80
0.29	0.28	0.50	0.93	0.98	1.00	0.95	0.73	0.50	0.30	0.05	0.15	6.64
5.72	4.86	3.94	3.57	3.42	3.39	3.42	3.45	3.53	3.78	5.35	8.79	

1.62	1.20	0.70	0.42	0.24	0.12	0.07	0.03	0.01	0.00	0.00	0.00	4.42
1.27	1.17	0.88	0.62	0.35	0.25	0.15	0.05	0.02	0.00	0.00	0.00	4.79
0.67	0.99	1.02	0.83	0.76	0.50	0.27	0.20	0.08	0.03	0.01	0.00	5.36
0.30	0.47	0.89	1.06	0.92	0.80	0.64	0.42	0.28	0.12	0.04	0.02	5.96
0.08	0.19	0.45	0.73	0.96	1.01	0.92	0.78	0.60	0.36	0.16	0.09	6.33
0.02	0.05	0.15	0.36	0.59	0.81	1.01	1.02	0.87	0.73	0.47	0.29	6.38
0.00	0.01	0.04	0.10	0.21	0.42	0.66	0.87	1.05	1.05	0.89	0.74	6.04
0.01	0.01	0.01	0.02	0.05	0.12	0.24	0.48	0.76	1.02	1.29	1.31	5.32
0.10	0.08	0.06	0.02	0.01	0.02	0.06	0.14	0.29	0.61	1.24	1.90	4.53
0.30	0.30	0.14	0.03	0.00	0.00	0.01	0.02	0.07	0.27	1.08	2.14	4.36
0.70	0.43	0.18	0.04	0.00	0.00	0.00	0.00	0.01	0.18	1.01	2.19	4.74
1.11	0.67	0.25	0.04	0.00	0.00	0.00	0.00	0.02	0.21	1.05	2.15	5.51
1.39	1.01	0.37	0.08	0.01	0.01	0.02	0.05	0.13	0.44	1.17	2.05	6.72
1.44	1.25	0.67	0.33	0.18	0.16	0.23	0.36	0.57	0.91	1.53	1.43	9.06
1.13	1.11	1.24	0.93	0.87	0.85	0.90	1.08	1.26	1.35	1.07	0.80	12.59
0.78	0.28	0.50	0.93	0.98	1.00	0.95	0.73	0.50	0.30	0.05	0.47	7.45
10.94	9.21	7.53	6.56	6.14	6.06	6.12	6.24	6.51	7.59	11.05	15.60	

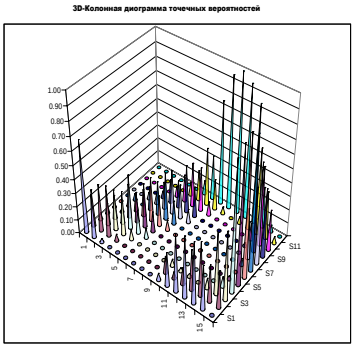

Рис. 6 Интерполяционное сглаживание 1-го и 2-го уровня с помощью метода потенциалов для сумматорной матрицы. 3-D колонная диаграмма точечных вероятностей грузинской буквы ”ა”.

На основе полученных матриц были построены 3-D колонная диаграмма точечных вероятностей (рис. 7) и графики, названные “дактилоскопическими паттернами”, представляющие собой диаграммы пересечения v-zond и h-zond с точками узора на сумматорной матрице (рис. 7). Из диаграмм видна информационно-графическая специфика картин, несущая информационную уникальность паттерна определенного символа, подобно дактилоскопическому рисунку и в отличие от метода v/h-zond более точно сможет идентифицировать объекты [2].

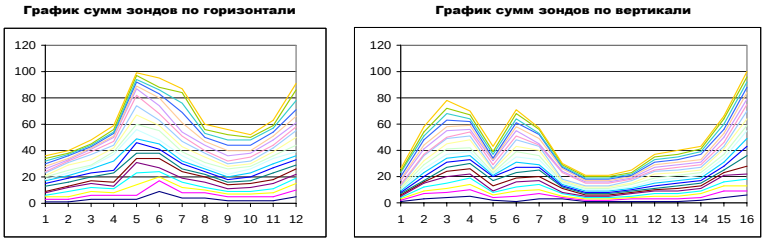

Рис. 7 Графики суммы зондов по вертикали и горизонтали.

На примере буквы “ბ” грузинского алфавита (Рис. 8), приведены матрицы эталонных элементов БД, таблицы статистических подсчетов, графики зондов по горизонтали и вертикали и диаграммы точечных вероятностей.

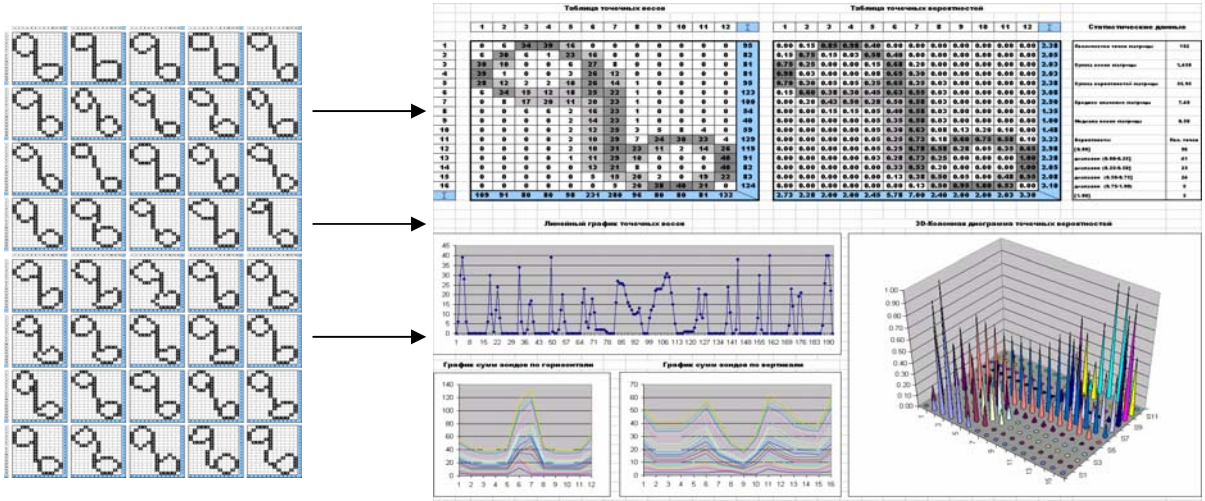

Рис. 8 БД элементов, вероятностно-статистический и дактилоскопический анализ буквы “ბ”.

Если сравнить вертикальные и горизонтальные графики зондов различных символов, например, латинскую букву “M” с грузинской буквой “შ”, то можно заметить их графическую диверсификацию (рис. 9). Путем наложений и сравнения графиков и вероятностей можно определить удаленность поступившего на вход изображения с каждой сумматорной матрицей различных образов. Дистанция разрыва будет определять приближенность или удаленность между введенным изображением и символами из БД.

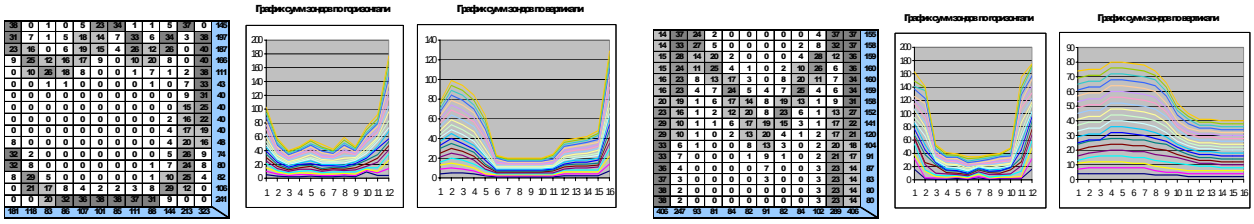

Рис. 9 “Дактилоскопическое” сравнение паттернов графиков.

Можно использовать другую диаграмму - линейный график точечных весов, который представляет собой комбинированный график (рис. 10) распределения точечных весов и несет более собирательную информацию распределения точек на поле рецепторов по сравнению с горизонтальным и вертикальными графиками зондов.

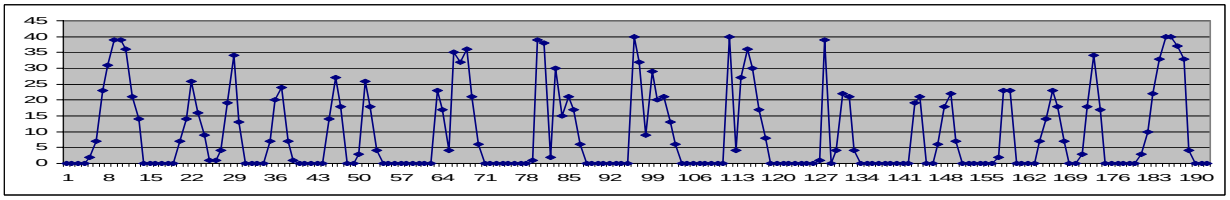

Рис. 10 Линейный график точечных весов.

Из приведенных графиков видны отличия в паттерне начертаний различных символов, узор имеет “дактилоскопические” отличительные признаки даже при визуальном сравнении линейных графиков точечных весов грузинской буквы “ბ” и латинской буквы “V” (рис. 11).

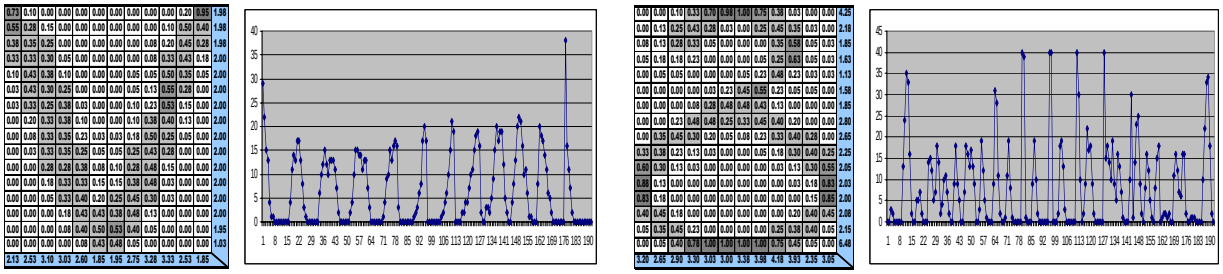

Рис. 11 Сравнение линейных графиков точечных весов.

Для определения удаленности между двумя БД, представляющими определенные образы, например латинской буквой “V” и грузинской буквой “ბ”, можно использовать промежуточную матрицу разницы по точечным весам, на основе которой строится комбинированный линейный график сравнений (рис. 12). Чем меньше разница или суммарное значение, тем ближе друг к другу изображения из БД и наоборот.

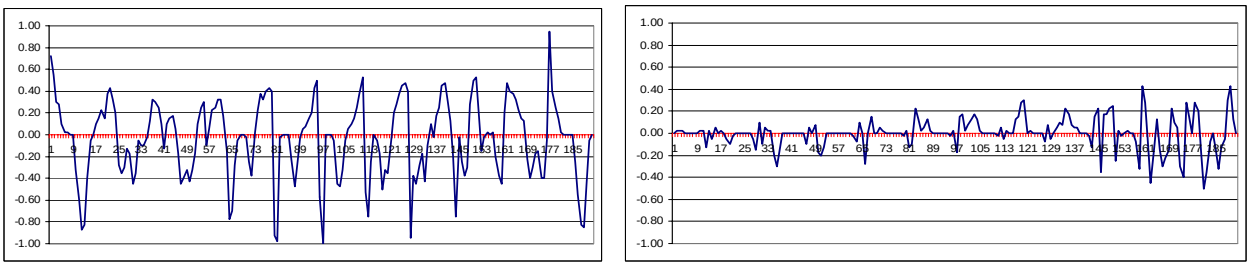

Рис. 12 Графики сравнения несимилярных образов “V” с “ბ”и симилярных образов цифры “3” и грузинской буквы “ვ”.

Этот механизм можно использовать для определения дисперсии между поступившим на вход изображением и сумматорной матрицей для сравнения с эталонной БД. Если сравнить симилярные образы из БД, например цифру “3” и грузинскую букву “ვ”, то получим следующую диаграмму. Из сравнения графиков на рис. 12 видно, что чем выше амплитуды графиков, тем менее симилярны образы из БД и наоборот, чем ниже амплитуда на графике, тем более визуально приближены образы. Приведем эти же графики в модульном представлении, где подсчитывается сумма по модулю значений этих разниц (рис13).

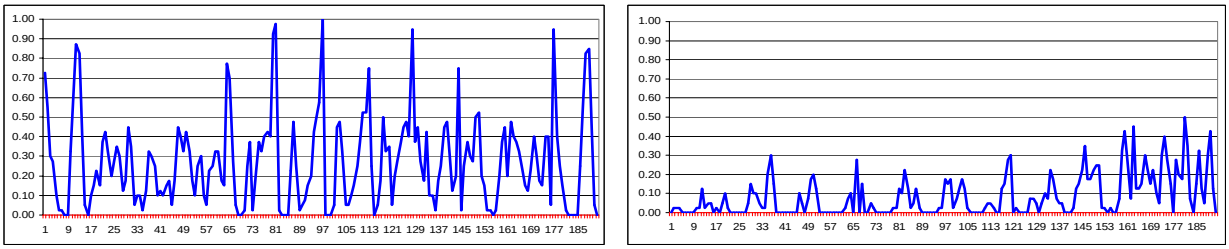

Рис. 13 Модульный график сравнения несимилярных образов “V” с “ბ” и симилярных образов цифры “3” и буквы “ვ”.

Приведенные новые схемы и графики хоть и приближают нас к разрешению задачи распознавания, но не разрешают ее, ввиду того, что не учитывают некоторые факторы, связанные с категоризацией точек на гибридных матрицах. Для улучшения распознавания была разработана и введена новая методика сравнения точек рецепторной матрицы с сумматорной эталонной БД (рис. 14), заключающаяся в точечном анализе и подсчете различных кластеров точечных масс.

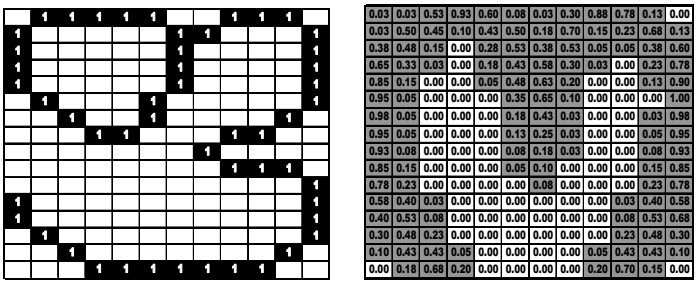

Рис. 14 Пример точек буквы “Ʒ” матрицы рецепторов и сумматорной БД буквы “Ʊ”.

Введены новые термины, представляющие разные категории матриц (рис. 15): конгруэнтные, диверсивные, пассивные и симбиозные матрицы.

Конгруэнтные матрицы получаются в результате операции умножения значений точек матрицы поступившего на вход изображения, с соответствующими по позиции значениями точек из сумматорных матриц вероятностей.

Диверсивные матрицы получаются следующим образом: если разница между значением точки из матрицы входного изображения и соответствующим значением точки из сумматорной матрицы равно 1, то в диверсивной матрице соответствующая по позиции точка принимает значение равное 1, в противном случае – записывается значение равное 0.

Пассивные матрицы получаются в результате операции вычитания значений точек сумматорных матриц вероятностей с соответствующими по позиции значениями точек из конгруэнтных матриц.

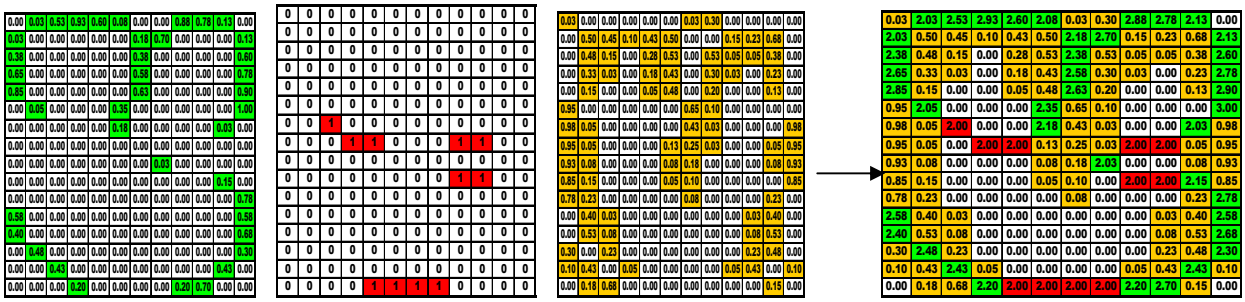

Рис. 15 Пример выделения конгруэнтных, диверсивных и пассивных точек “Ʒ” при сравнивании с эталонной БД буквы “Ʊ” и получение симбиозной матрицы.

Симбиозные матрицы получаются в результате перенесения значений точек (не равных нулю) из конгруэнтных, диверсивных и пассивных матриц в одну общую матрицу. При этом в симбиозной матрице эти точки не будут накладываться по координатам друг на друга в силу построения.

Нулевые точки – это точки симбиозной матрицы, значения которых равны нулю.

Симбиозная матрица является итоговой матрицей, которая содержит в себе информацию, связанную с различными категориями масс – конгруэнтных, диверсивных, пассивных и нулевых (остаточных масс с нулевыми значениями). На основании глубокого анализа проделанной работы были выявлены закономерности для распознавания образов.

Гипотеза симбиоза масс

Чем больше конгруэнтных и нулевых точек в симбиозной матрице и меньше диверсивных и пассивных точек, тем больше приближение изображения матрицы рецепторов к искомой сумматорной матрице образа, т.е. к реальному изображению.

Используя градацию деления точек сумматорной матрицы на различные категории и получая симбиозную матрицу, можно выявлять по определенным признакам принадлежность того или иного образа к определенному классу символов, применяя нейроматричную самоорганизацию сети.

Алгоритм нейросетевой самоорганизации матриц для распознавания образов.

Фактически задача заключается в том, что на основе 40 введенных конфигураций в БД для каждого символа выявить их характерные признаки и распознать изображение представленного на опознавание символа. Задача распадается на следующие шаги:

1. Загрузка БД, содержащую 2760 введенных эталонных символов из MS Excel файла, в программу;

2. Введение изображения произвольного символа для последующего опознавания на матрице рецепторов (12x16) и сохранение в формате .BMP (16 Color);
3. Считывание введенного изображения для распознавания из файла в программу;
4. Преобразование изображения из двоичного представления в табличный массив 0 и 1 программы, где 0 – определяет незакрашенные, а 1 – закрашенные ячейки массива;
5. Подсчет конгруэнтной промежуточной нейронной матрицы 2-го слоя;
6. Подсчет диверсивной промежуточной нейронной матрицы 2-го слоя;
7. Подсчет пассивной промежуточной нейронной матрицы 2-го слоя;
8. Подсчет итоговой симбиозной нейронной матрицы 3-го слоя, основанной на характеристиках матриц первого и второго слоев;
9. Выявление характеристик симбиозных матриц и вычисление итоговых значений на выходах;
10. Выявление наибольшего значения из выходов симбиозных матриц, определение его кода и ассоциирование с поступившим на вход изображением;
11. Корректировка сумматорной матрицы 1-го уровня (с учителем или без учителя) в случае высокой погрешности;
12. Переход к шагу 2, пока величина погрешности не будет удовлетворяющей.

Искусственная нейро-матричная сеть (ИНМС) построена по следующей схеме (рис. 16): на вход нейронной сети подается растровое изображение символа, вход можно представить как матрицу рецепторов, а изображение может быть представлено в виде последовательности 0 и 1, где 0 - незакрашенные ячейки, а 1 - закрашенные ячейки. Информация из матрицы рецепторов подается и трансформируется на второй уровень - класс нейронных матриц представителей и критериев оценок для каждого образа базы данных, после этого подсчитываются промежуточные веса и применяются критерии отбора элементов, которые также прописаны в матричном виде - третий уровень.

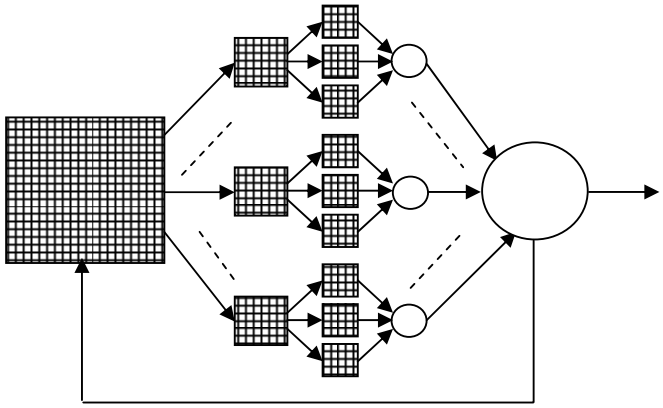

Рис. 16 Граф матричной искусственной нейронной сети с разделенной структурой неронов.

Следующим этапом является взвешивание полученных результатов с помощью вычисления целевой функции каждой матричной схемы, учитывая различные критерии оценок. После вычисления всех весов на последнем этапе просматриваются полученные результаты, и наивысшему значению будет соответствовать наиболее приближенный образ. В созданной схеме используется самоорганизация сети, т.е. после определения образа происходит перенастройка весов различных матриц критериев в цикле, таким образом, схема не является статической, а является динамически подстраиваемой и эффективно сходящейся.

На основе построения принципиально новой самоорганизующейся нейронной схемы и применения вероятностно-статистических методов были получены высокие результаты распознавания. Данный граф показывает структурную схему построенной искусственной нейронной сети (ИНС) для распознавания графических образов.

Ниже приводится более детализированная блок-схема нейронной сети для распознавания образов, на которой описаны основные этапы, включающие загрузку БД, ввод изображения для опознавания, получение сумматорных, конгруэнтных, диверсивных, пассивных и симбиозных матриц для каждого образа и подсчет целевой функции для выявления наивысшего приближенного значения определяющего код распознавания образа.

Блок-схема соответствующей ИНС для распознавания образов имеет следующий вид:

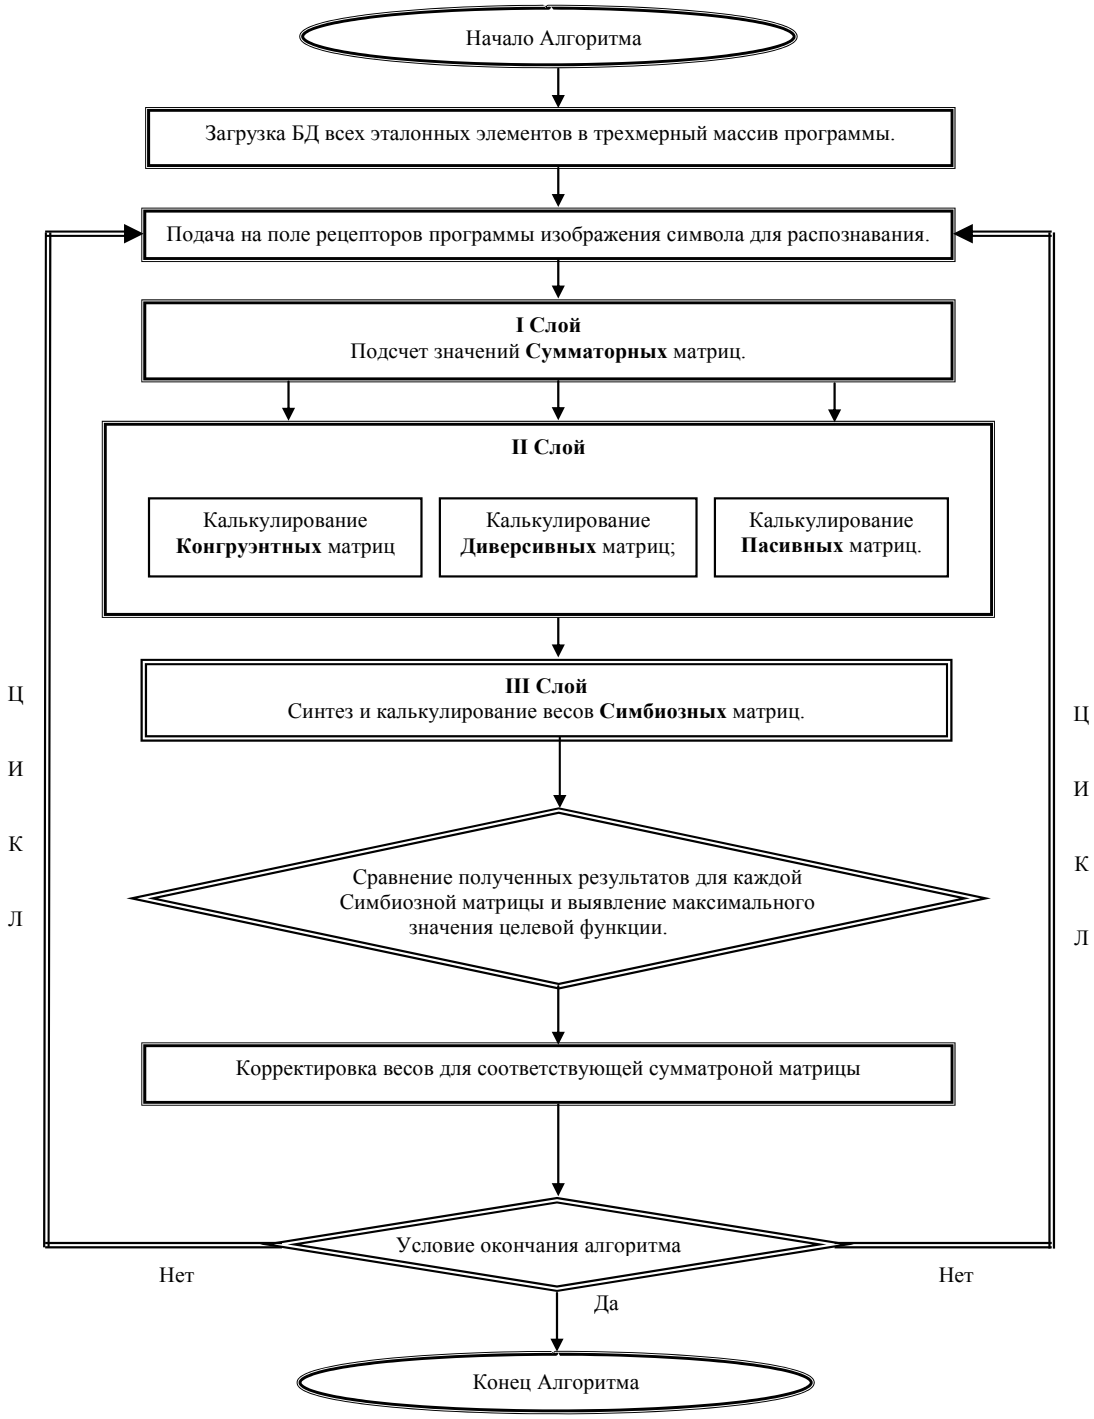

Полученные результаты.

В результате проделанной работы была смоделирована программная модель, реализующая распознавание образов (арабских цифр, букв грузинского и латинского алфавитов) с помощью Искусственной Нейронной Сети (ИНС) и вероятностно-статистического анализа образов. Программа реализует перевод графической информации изображения символа в матричный вид, загружает внешнюю эталонную БД сумматорных таблиц в программу и вычисляет промежуточные: конгруэнтные, диверсивные и пассивные таблицы для каждого символа. Далее производится подсчет симбиозных матриц каждого

символа, анализ взвешивания весов и получение результирующих значений, из которых выявляется наибольшее значение, определяющее код принадлежности к тому или иному символу (рис. 17).

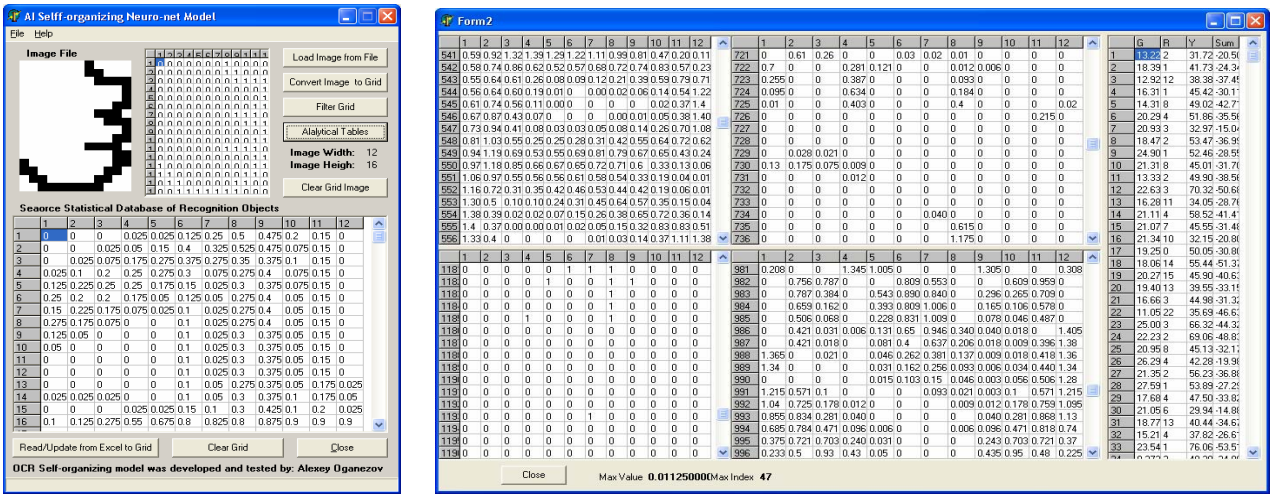

Рис. 17 Фрагменты программы и анализ сумматорной, конгруэнтной, диверсивной и пассивной матриц.

Программа содержит новый подход в методологии с применением вероятностно-статистической ИНС. В результате апробации программы были получены высокие результаты распознавания образов. Программа смоделирована для рукописного почерка и легко адаптируется под конкретный шрифт в целях улучшения распознавания. При выборе конкретного шрифта для распознавания и нейро подстройки модели под этот шрифт с помощью откалиброванной начальной БД программа существенно повышает процент распознавания и достигает высокие результаты распознавания 97% и выше в зависимости от качества подстройки, что позволяет применить это программное модульное ядро для современного использования в других программах.

Программа сравнивает, анализирует и изменяет весовые характеристики весовых матриц, повышая эффективность и точность модели. Кроме этого, распознавание символов осуществляется довольно оперативно за миллисекунды, не используя при этом возможность распараллеливания, несмотря на структурное блочное разделение процессов. В целом созданная программа является уникальной и эффективной для распознавания любых плоских символов, которая основывается на рукописной эталонной БД с внедренной вероятностно-статистической ИНС и механизмами аналитических подсчетов и подстроек мульти-матричных слоев.

Заключение.

На основе проведенных исследований предложен новый метод распознавания образов с помощью построения трехслойной искусственной нейро-матричной сети без учителя, базирующийся на вероятно-статистическом анализе точечных оценок весовых коэффициентов. Основные результаты диссертационной работы следующие:

1. В работе проработаны, выявлены и применены принципы и знания из теории нейробиологии, нейроинформатики, кибернетики, искусственного интеллекта, искусственных нейронных сетей на основе специальной литературы и ресурсов Интернета.
2. Сформирована База Данных (БД) эталонных образов, состоящая из 10 арабских цифр, 26 букв латинского и 33 букв грузинского алфавитов, содержащая 40 разновидностей растровых экземпляров для каждого символа с целью выявления и исследования общих графических характеристик и математических закономерностей структуры построения плоских символов для дальнейшей идентификации образов.
3. Проанализированы и подсчитаны статистические показатели точечных вероятностей для 529920 введенных растровых точек матриц, суммы весов, вероятностей, усредненных значений и медиан весов матриц, проведен контроль количества точек для всех эталонных образов, имеющих вероятности появления активных точек из диапазонов [0.00], (0.00-0.25], (0.25-0.50], (0.50-0.75], (0.75-1.00], [1.00], для выявления характеристик каждого символьного образа.

4. Построены графики зависимостей вертикальных и горизонтальных составляющих зондов изображения, линейные графики точечных весов, а также 3D-колонные диаграммы точечных вероятностей для каждого образа.
5. Введены новые определения и понятия, применяемые для распознавания образов: v-zond, h-zond, конгруэнтные, диверсивные, пассивные и нулевые точки матриц, а также конгруэнтные, диверсивные, пассивные и симбиозные виды матриц.
6. Созданы конгломератные статистические данные каждого символа, которые использованы при построении сумматорных матриц первого слоя ИНС, применена интерполяция первого и второго уровней для сглаживания и балансирования весовых коэффициентов сумматорной матрицы, построены промежуточные нейро-массивы второго слоя: конгруэнтные, диверсивные и нейтральные, а также симбиозные матрицы третьего слоя.
7. Сформирована трехслойная схема искусственной самообучающейся нейро-матричной сети для распознавания плоских графических образов без учителя, которая обрабатывает и модифицирует эталонную базу образов – сумматорную матрицу при сравнении с поданными на вход тестовыми изображениями.
8. Разработаны блок-схема и алгоритм обучения ИНС, скомпилированы проектные модули и апробировано программное обеспечение в среде RAD Borland Delphi на языке программирования Object Pascal.
9. Смоделированная программа производит глубокий анализ поступившего на опознавание образа, пропускает его через слои ИНС, сравнивает с каждым сумматорным матричным слепком из БД, выявляет закономерности, идентифицирует, при необходимости перестраивает весовые коэффициенты и определяет его принадлежность к конкретному классу символов.
10. Разработанная новая методика является унифицированной и может быть применена для распознавания плоских символов, знаков, печатных шрифтов, алфавитов, а также рукописных изображений.
11. Достигнута высокая эффективность и хороший процент распознавания образов – 97% для сравнительно компактных и разделенных множеств на первом же цикле обработки изображения, несмотря на минимизированный объем выборочного наборова БД и редуцированной матрицы рецепторов, что является показателем хорошо смоделированной структуры ИНС.
12. Результаты экспериментальных исследований подтверждают эффективность разработанного метода весовых настроек синаптических массивов для обучения ИНС, имеют практическую ценность и могут быть применены для распознавания любых плоских фигур.

Основные результаты диссертации содержатся в научных трудах:

1. Oganezov A. “Neuro-matrix object recognition model”, “Bulletin of the Georgian National Academy of Sciences”, Tbilisi, V. 173 №3, 2006.
2. Oganezov A. “Flat figures recognition based on fingerprinting signs in neural nets”, “Bulletin of the Georgian National Academy of Sciences”, Tbilisi, V. 174 №1, 2006.
3. Кочладзе З.Ю., Оганезов А.Л., “Об одном возможном подходе к проблеме распознавания плоских фигур”, “Труды Тбилисского Государственного Университета им. Ив.Джавахишвили”, Тбилиси, 2005, № 364 (24), стр. 149-155.
4. ოგანეზოვი ა. “ინფორმაციული დამუშავების ალბათობითი და ნეირონული სქემების გამოყენება ქართული შრიფტების ამოცნობის პროცესისათვის”, “მეცნიერება და ტექნოლოგიები”, თბილისი, №1-3, 2006, გ. 30-31.
5. Кочладзе З.Ю., Оганезов А.Л. “Использование двухслойной нейронной модели в процессах распознавания образов”, “Энергия”, Тбилиси, 2005 №4(36) I, стр. 78-82.
6. Оганезов А.Л., Кочладзе З.Ю. “Задача распознавания инженерных 2D чертежей и преобразование в электронные 3D стереометрические объекты”, “Энергия”, Тбилиси, 2005 №4(36) I, стр. 72-81.
7. ოგანეზოვი ვ., ოგანეზოვი ა. “არატრადიციულ ენერგეტიკაში გამოთვლითი ტექნიკის გამოყენება”, “ბუნება და ენერგია”, თბილისი, 19-20 ივნისი, 1998, გ. 138-144.
8. Oganezov A. “Creation of Energy Efficiency Fund for Georgia”, “Proceedings of Second International Energy Conference in Armenia”, Part 2, Yerevan, Armenia, Sept. 24-28, 2001, p: 47-51.