

საქართველოს ტექნიკური უნივერსიტეტი

ელგუჯა გუბანებიშვილი

სახელა ბარჩევის გეორგიდები

(ლექციების პონსამზე)



თბილისი

2011

1 სახეობა გარჩევის ზოგადი ცნებები და განმარტებები

1.1 სახეობა გარჩევის არსი

სახეობა გარჩევა არის მეცნიერება სახეების ანუ ობიექტების კლასიფიკაციის მეთოდებისა და ალგორითმების შესახებ. იგი მიეკუთვნება ინტელექტურ სისტემებს, რომლებიც ინფორმაციის შემადგენელი ნაწილია. ადამიანი სახეობა გარჩევის ამოცანას ყოველწლიურად აწყდება. მაგალითად, ჩვენ გარჩევთ ადამიანებსა და ობიექტებს, გარჩევთ ციფრებსა და ანბანს, გვესმის მეტყველება და ბევრ სხვა. შეიძლება ითქვას, რომ ცოცხალი ორგანიზმი იძულებულია თავის ცხოვრების მანძილზე მუდმივად გადაწყვეტოს გარჩევის ამოცანები. გარჩევის ამოცანის წარმატებულ გადაწყვეტაზე ბევრადად დამოკიდებული ბიოლოგიური ობიექტების წარმატებული ფუნქციონირება და თვით სიცოცხლისუნარიანობა.

ამრიგად, ადამიანის არსებობის აუცილებელი პირობაა გარემოს ობიექტების აღქმა და მიღებული ინფორმაციის გადამუშავება, რის საფუძველზედაც მიღება გარკვეული გადაწყვეტილება და მისი შესაბამისი ქმედების განხორციელება. გადაწყვეტილების მიღების ეს პროცედურა შეიძლება აღინიშნოს ერთი ტერმინით “გარჩევა”

გარჩევის პროცესის განხორციელების აუცილებელი პირობაა ადამიანის ცნობიერებაში გასარჩევი ობიექტის ინფორმაციული პროტოტების არესებობა. საკმარის პირობად შეგვიძლია მივიჩნიოთ გასარჩევ ობიექტი თუნდაც ერთი განმასხვავებელი თვისების არსებობა, რომლის აღქმაც შეუძლია ადამიანს.

ფსიქოლოგიური და ფიზიოლოგიური გამოკვლევების საფუძველზე გარკვეულწლიული ცნობილი გახდა, რომ ადამიანი გადაწყვეტილების მიღებისას სარგებლობს უმარტივესი ფუნქციებით, ძირითადად ლოგიკური და მხოლოდ განსაკუთრებულ შემთხვევაში იყენებს წრფივ ან კიდევ უფრო რთულ შემთხვევაში მარტივ არაწრფივ ფუნქციებს. უაღრესად მცირე ინფორმაცია არის იმის შესახებ, თუ როგორ ხდება ადამიანის მიერ ობიექტთა დამახასიათებელი ნიშნების ფორმირება, შეფასება, არჩევა და რანჟირება.

უნდა აღინიშნოს, რომ ადამიანის გონებაში ნიშანთა ფორმირების პროცესი, განმასხვავებელი ნიშნების გამოყოფა და დადგენა ძირითადად მიმდინარეობს მისგან დამოუკიდებლად.

პერიფერიული ნერვული სისტემა ძირითადად მონაწილეობს ობიექტთა აღქმაში. კერძოდ, ხედვითი, სმენითი, ყნოსვითი და გემოს ანალიზატორებიდან მიღებული ინფორმაციის ცენტრალურ ნერვულ სისტემამდე გადაცემის პროცესში, რაც საბოლაოდ ამ ინფორმაციის საფუძველზე გარკვეული გადაწყვეტილების მიღებით მთავრდება, რასაც ჩვენ გარჩევა ვუწოდეთ.

მეცნიერებისთვის ჯერ კიდევ უცნობია ის ფაქტი თუ როგორ ახერხებს ადამიანი ასეთი სისტრაფით გაარჩიოს გარემომცველ ობიექტთა მრავალფეროვნებანი. ეს პარადოქსი წარმოადგენს მეცნიერების ერთ-ერთ ყველაზე აქტუალურ პრობლემას, რომლის ახსნა უდიდეს ბიძგს მისცემს არა მარტო გარჩევის, არამედ საერთოდ, მაღალეფებში ინტელექტუალური სისტემების შექმნის პრობლემის გადაწყვეტასაც.

ამრიგად, გარჩევის პროცესი წარმოადგენს ადამიანის ინტელექტუალური მოქმედების ერთ-ერთ ძირითად ასპექტს, რომლის განხორციელებაში მონაწილეობენ როგორც პერიფერიული, ასევე ცენტრალური ნერვული სისტემები.

მიუხედავად ზემოდაღნიშნულისა, ადამიანის შესაძლებლობები ობიექტთა გარჩევის თვალსაზრისით მნიშვნელოვნად შეზღუდულია იმ ამოცანებისათვის,

რომლებიც ხასიათდებიან მრავალი ნიშან-თვისებებით. შეზღუდვები განსაკუთრებით ეხება ისეთ ობიექტებს, რომელთა აღქმა ადამიანის მიერ შეუძლებელია მისი მგრძნობიარე ელემენტების - რეცეპტორების არასრულყოფილებით ან არარსებობის გამო. მაგალითად, ადამიანის ყური ვერ აღიქვამს 20 ჰერცამდე და 20.000 ჰერცზე მაღალ სიხშირის რხევებს, ხოლო თვალი - ოპტიკური სიგნალის მთელი დიაპაზონის დაახლოებით 20%-ს. გარდა ამისა, ადამიანს არ გააჩნია რაღიაცის ან ელექტრომაგნიტური რხევების აღქმის ორგანოები, რაც ბუნებრივია, შეუძლებელს ხდის მის მიერ ამ თვისების მქონე ობიექტთა აღქმას და გარჩევას. აქედან გამომდინარე, აუცილებელია ისეთი ტექნიკური სისტემების შექმნა, რომლებიც უზრუნველყოფენ ადამიანის დამახასიათებელ სწორ და მაღალსაიმედო ამოცნობას და ამასთან ერთად, ექნება კომპიუტერისათვის დამახასიათებელი სიჩქარე.

ზემოდანიშნულიდან გამომდინარე, არჩევენ ხელოვნურ და ბუნებრივ ინტელექტუალურ სისტემებს. ინტელექტუალურ სისტემებს მიეკუთვნება სახეთა გარჩევის კომპიუტერული სისტემები, ხოლო ბუნებრივს - ცენტრალური პერიფერიული ნერვული სისტემები.

სახეთა გარჩევის თეორიაში პირველი ნაშრომები მე-20 საუკუნის მეორე ნახევარში აშშ გამოჩნდა. პირველი პრაქტიკული ამოცანა, რომლის გადაწყვეტას ცდილობდნენ სპეციალისტები გახდათ ე.წ, წამკითხავი ავტომატის შექმნა, რომელსაც ავტომატურად უნდა აღექვა და გაერჩია ნაბეჭდი, ხელნაწერი ტექსტები ან ცალკეული სიმბოლოები. პირველი მეცნიერი, რომელმაც სხვადასხვა ობიექტების გასარჩევად შექმნა გამოივლით სისტემა იყო ფ. როზენბლატი, რომელმაც შეიმუშავა ე.წ. პერსეპტორი - თავის ტვინის ნეირონის ელექტრული ანალოგი.

სახეთა გარჩევის ზოგადი თეორია შექმნა გრენანდერმა, რომლის პირველი ნაშრომები 60-იან წლებში გამოჩნდა. 70-იანი წლების დასაწყისში კ. ფუმ ორგანზომილებიანი ობიექტების გასარჩევად შეიმუშავა სტრუქტურული ანალიზის (სინტაქსური, გეომეტრიული) თეორია. 80-იან წლებში მნიშვნელოვანი შედეგები იქნა მიღებული ცალკეული სამეტყველო სიგნალებისა და სამგანზომილებიანი ობიექტების გარჩევის პრობლემების გადასაწყვეტად. ამან უზრუნველყო რობოტი მანიპულატორებისათვის შექმნათ ე.წ. ტექნიკური ხედვის სისტემა.

შეიძლება მოვიყვანოთ ინტელექტუალური სისტემების ყველაზე მნიშვნელოვანი მიმართულებები, სადაც გამოიყენება სახეთა გარჩევის მეთოდები:

-სიმბოლოების (ბეჭდვითი, ხელნაწერი, საბანკო ჩეკები, ფულადი კუპიურები და სხვ.) გარჩევა;

-გამოსახულებების გარჩევა, რომლებიც მიიღებიან სხვადასხვა სიხშირულ დიაპაზონებში;

-მეტყველების გარჩევა;

-სამედიცინო დიაგნოსტიკა;

-უსაფრთხოების სისტემები;

-კლასიფიკაცია, იდენტიფიკაცია და მონაცემთა ბაზებში ძიება, მათ შორის ინტერნეტ-რესურსებში.

მომავალში გარჩევის სისტემები კიდევ უფრო ფართო გამოყენებას პპოვებს საყოფაცხოვრებო პროცესებში, მედიცინასა და ტექნიკაში, როგორც ხელოვნური ინტელექტუალური სიტემების შემადგენელი ნაწილი და როგორც დამოუკიდებელად ფუნქციონირებადი ინტელექტუალური სისტემები. განსაკუთრებით აღსანიშნავია ცენტრალური ნერვული სისტემის ფუნქციონირების პრინციპზე დაფუძნებელი ე.წ. ხელოვნური ნეირონული ქსელის აგების პრობლემა, რომლის ერთ-ერთი ძირითადი მიზანია ნეიროპრომპიუტერის შექმნა. აქ მთავარი მიზანია კომპიუტერის მოქმედების სისტრაფის შერწყმა ბუნებრივ ნეირონული ქსელის მონაცემების პოტენციალთან. ასეთი პროექტის განხორციელება შექმნიდა განუსაზღვრელ შესაძლებლობას როგორც სახეთა გარჩევის, ასევე ნებისმიერი პროცესის მართვის თვალსაზრისით.

1.2 ძირითადი ცნებები

სანამ გადავიდოდეთ სახეთა გარჩევის მეთოდების განხილვაზე, მოვიყვანოთ ზოგიერთი ცნების განსაზღვრება.

სახე ეწოდება საერთო თვისების მქონე ყველა იმ ობიექტების (რეალიზაციების) სიმრავლეს, რომლებიც სივრცეში გარკვეული აზრით ქმნიან კომპაქტურ არეს. მაგალითად, „ფანჯრების” სახეს მიეკუთვნება ყველა ზომის და ფერის ფანჯარი, მაგრამ „წითელი ფანჯრების” სახეში შედის მხოლოდ წითელი ფერის ფანჯრები. სახეს მიეკუთვნებიან აგრეთვე ნაბეჭდი ან ხელნაწერი სიმბოლოები, სხვადასხვა საგნები, დეტალები და მოწყობილობები, დაავადებები, მოვლენები, სიტუაციები და ა.შ.

კლასი წარმოადგენს ცნება „სახის” სრულ ანალოგს და შესაბამისად ამავე ტერმინის სინონიმს.

ყოველი სახე წარმოდგენილია გარკვეული რაოდენობის ობიექტებისგან. ობიექტი შეიძლება იყოს ორ ან სამგანზომილებიანი. ორგანზომილებიან ობიექტს გამოსახულება ეწოდება. გამოსახულების მაგალითებია: ნაბეჭდი ან ხელნაწერი სიმბოლოები და ტექსტები, ნახატები, ნახაზები და სხვა. თავის მხრივ გამოსახულება შეიძლება იყოს შტრიხული და ლაქისებრი.

შტრიხული ეწოდება ისეთ გამოსახულებას, რომელიც შედგება მხოლოდ წრფეებისა და მრუდებისგან. მაგალითად, ხელნაწერი და ნაბეჭდი სიმბოლოები, სურათები, ბიოსიგნალების ჩანაწერები და ა.შ.

ლაქისებრი ეწოდება ისეთ გამოსახულებას, რომელიც შედგება მთლიანი, ნებისმიერი ფორმის ლაქებისაგან. მაგალითად, ფოტოსურათები, რენტგენული გამოსახულებები, ვიდეოგამოსახულებები, ნახატები და სხვა.

სცენა ეწოდება სივრცის იმ ნაწილს, სადაც მოთავსებულია სამგანზომილებიანი გასარჩევი ობიექტები. სცენა და სცენის ობიექტები შეიძლება იყოს დეტალები, ლანდშაფტი და მასზე განლაგებული შენობა-ნაგებობები, სამხედრო ობიექტები, მაგიდაზე განლაგებული საგნები და ა.შ.

გარჩევა ეწოდება პროცესს, რომლის შედეგად უცნობი ობიექტი მიეკუთვნება ამა თუ იმ სახეს. გარჩევის გარდა ლიტერატურაში გვხვდება მისი სინონიმი ტერმინები: იდენტიფიკაცია, ამოცნობა. გარჩევის პროცესი აუცილებლად შეიცავს კ. წ. „შედარების” პროცედურას. რომლის განხორციელებისთვის საჭიროა მინიმუმ ორი ობიექტი, აქედან ერთი უცნობი ობიექტია, ხოლო მეორე უნდა იყოს ისეთი, რომელიც წარმოადგენს მოცემულ სახეს.

უცნობი ობიექტის შესადარებელ ობიექტს ეტალონი ეწოდება. თვით ამ ტერმინს გააჩნია მრავალი სინონიმი: პროტოტიპი, ნიმუში, საყრდენი ობიექტი, სახის აღწერა. აუცილებელია თითოეულ სახეს ჰქონდეს მინიმუმ ერთი და რთულ შემთხვევებში რამდენიმე ეტალონი.

ობიექტის მიკუთვნება ან არმიკუთვნება ამა თუ იმ სახისადმი ეწოდება გადაწყვეტილების მიღების პროცესი.

სახეთა ნებისმიერ ანსამბლს გააჩნია თვისებათა გარკვეული სიმრავლე, რომელთა საშუალებითაც ხდება ანსამბლში შემავალი სახეთა წარმოდგენა და აღწერა, რასაც სახეთა გარჩევაში ნიშნები (პარამეტრები) ეწოდება. იმისთვის, რომ გარჩევის პროცესისათვის შესაძლებელი იყოს ნიშნების გამოყენება, აუცილებელია მათი ანალიზი. მაგალითად, თუ ნიშნები ზომვადია, მაშინ ისინი უნდა გაიზომოს, ხოლო თუ ნიშნები თვისებრივი სასიათისაა, რომლებიც არ იზომებიან, მაშინ ისინი უნდა დაფიქსირდნენ (აღირიცხონ). ნიშნების მაგალითებია სხვადასხვა ტექნოლოგიური პროცესების პარამეტრები, როგორიცაა: ტემპერატურის, მასის, წნევის და მექანიკური ძალების მნიშვნელობები. მედიცინაში ასეთია დაავადებათა სიმტომო-კომპლექსები,

მაგალითად, არტერიულ წნევის, სხეულის ტემპერატურის, გულის შექმნების ნიშანის და სხვა პარამეტრების მნიშვნელობები.

სახეთა ანსამბლის ნიშანთა სიმრავლე ეწოდება იმ ნიშანთა ერთობლიობას, რომელსაც ვიყენებო მოცემულ სახეთა სიმრავლის აღწერისათვის

ნიშანთა სივრცე ეწოდება რაოდენობრივ ნიშანთა დალაგებულ სიმრავლეს, სადაც განსაზღვრულია რაიმე მეტრიკული ზომა.

რეცეპტორული ველი ეწოდება ტექნიკურად განხორციელებულ ან გრაფიკულად მოცემულ ნიშანთა სივრცის ანალოგს. რეცეპტორული ველის სინონიმია ტერმინი – რასტრი.

პიქსელი ეწოდება რეცეპტორულ ველში ანუ რასტრში შემავალი ერთი ნიშნის ანალოგს.

ნიშანთა სიმრავლის მაგალითებია: ყველა სიმპტომი, რომელიც შეიძლება ახასიათებდეს მოცემულ ავადმყოფს. ამ შემთხვევაში გვაქვს როგორც თვისებრივი ასევე რაოდენობრივი ნიშნები. ტექნოლოგიური პროცესების ამსახველი პარამეტრები, მარგი წიაღისეულის დაზვერვაში გამოყენებული ნიშნები და სხვა.

ნიშნების გაზომვით (ანალიზით) მიღებულ შედეგთა ერთობლიობას რეალიზაცია ეწოდება. იგი წარმოადგენს ვექტორს, რომელსაც ზოგჯერ სახის ვექტორს უწოდებენ. რეალიზაციის სინონიმია: დაკვირვებათა შედეგები, გაზომვათა შედეგები, სახის გამოსახულება. სახეში შემავალ ობიექტთა სიმრავლე წარმოადგენს ამ სახის რეალიზაციათა სიმრავლეს. ხშირად გამოიყენება ტერმინი რეალიზაციათა ამონარჩევი.

უცნიბი რეალიზაციები ეწოდება იმ რეალიზაციებს, რომლებისთვისაც არაა გარკვეული რომელ სახეს მიეკუთვნებიან ისინი. რეალიზაციათა ის სიმრავლე, რომლებისთვისაც ცნობილია რომელ სახეს მიეკუთვნებიან, შეიძლება გამოყენებულ იქნას ე.წ. „სწავლების” პროცესში ანუ ეტალონური აღწერებისა და გადაწყვეტილებათა მიღების პროცესების ფორმირებისთვის. რეალიზაციის ასეთ ანსამბლს (სიმრავლეს) სასწავლო ამონარჩევი ეწოდება.

რეალიზაციათა სასწავლო ამონარჩევის იმ ნაწილს, რომლებიც გადაწყვეტილებათა მიღების პროცესში გამოიყენება უცნობი რეალიზაციის ნაცვლად, საგამოცდო ამონარჩევი ეწოდება. ამ ტერმინის სინონიმად ლიტერატურაში ხშირად გამოიყენება ტერმინი - საკონტროლო ამონარჩევი.

ამრიგად, ყოველი სახე, მაგალითად C, რომელიც აღინიშნება {C} სიმბოლოთი, შეიცავს ობიექტთა ანუ რეალიზაციათა X_i , $i=1,2,\dots,m$ ერთობლიობას, ხოლო თვით რეალიზაციები წარმოდგენილნი არიან x_1, x_2, \dots, x_n ნიშნების ანუ პარამეტრების ერთობლიობით. ე.ი. $X_i = (x_1, x_2, \dots, x_n)$ ¹.

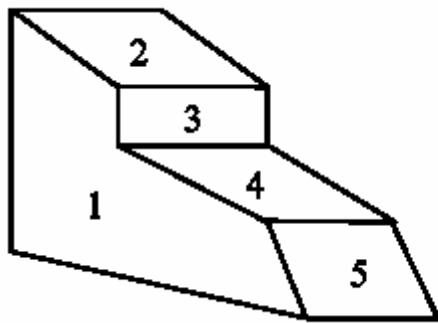
1.3 სახეების და გარჩევის სისტემების კლასიფიკაცია

სახეებს არჩევენ პარამეტრების ტიპის მიხედვით. გამოყოფენ შემდეგ მახასიათებელ – პარამეტრებს (ნიშნებს):

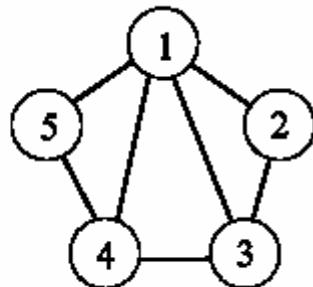
1. ფიზიკური მახასიათებლები. ასეთია მაგალითად მაჩვენებლები, რომლებიც მოხსნილია სხვადასხვა გადამწოდებით. ფიზიკური მახასიათებლები შეიძლება იყოს დეტერმინირებული და ალბათური. სასურველია ფიზიკური მახასიათებლები აღწერილ იყვნენ ვექტორებით, მათი შემდგომში მათემატიკური დამუშავებისთვის.

2. თვისებრივი მახასიათებლები. მაგალითის სახით შეგვიძლია მოვიყვანოთ ცნებები: „შავი”, „თეთრი”, „მაღალი”, „დაბალი” და ა.შ. ასეთი მახასიათებლები შეიძლება აღიწერონ ე.წ. ლინგვისტგური ცვლადებით, არამკაფიო სიმვრავლეთა თეორიის გამოყენებით.

3. სტრუქტურული მახასიათებლები, რომლებიც ძირითადად გამოიყენებიან რთული გამოსახულებების აღწერისათვის. მაგალითად, ნახ. 1 წარმოდგენილი ობიექტისათვის, სტრუქტურული მახასიათებლების აღწერისათვის, შეიძლება გამოვიყენოთ ზოგიერთი ფორმალური ენა, მაგალითად, გრაფების თეორია (ნახ. 2)



ნახ. 1



ნახ. 2

4. ლოგიკური მახასიათებლები. ესენია გამონათქვამები, რომელთა მიმართ შეგვიძლია ვთქვათ ჭეშმარიტია იგი თუ მცდარი.

გარჩევის სისტემების კლასიფიკაციისათვის შეიძლება გამოვიყენოთ რამოდენიმე კრიტერიუმი. ერთ-ერთი ასეთი კრიტერიუმია განსხვავება პარამეტრების ტიპის მიხედვით. პარამეტრები შეიძლება იყოს:

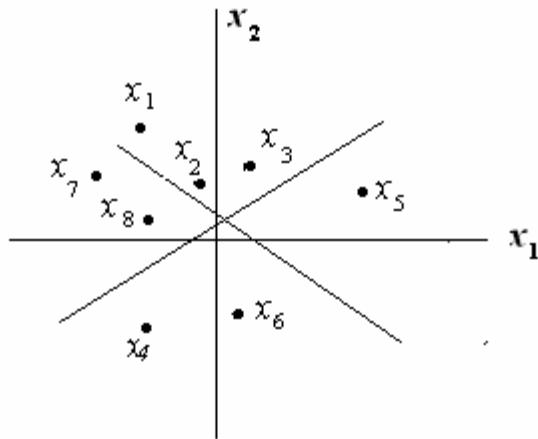
- დეტერმინისტული;
- ალბათური;
- ლოგიკური;
- სტრუქტურული;
- კომბინირებული.

სხვა კრიტერიუმია გასარჩევ ობიექტებზე აპრიორული ინფორმაცია. კერძოდ, გასარჩევი სისტემა შეიძლება იყოს სამი ტიპის:

1. სისტემა მასწავლებლის გარეშე. ამ შემთხვევაში სისტემა თვითონ ირჩევს პარამეტრების იმ მინიმალურ რაოდენობას, რომელიც საკმარისი იქნება გარჩევის ამოცანის გადასაწყვეტად. გარდა ამისა, ის განსაზღვრავს კლასების საზღვრებს. ამ შემთხვევაში გარჩევის სიტემაში სწავლების ბლოკი არ გამოიყენება.

2. სისტემა, რომელიც ეფუძნება სწავლებას მასწავლებლის საშუალებით. ამ შემთხვევაში სისტემის განკარგულებაშია ობიექტების გარკვეული რაოდენობა, რომლებიც წარმოადგენენ სასწავლო ობიექტებს და ცნობილია თუ რომელ კლასს მიეკუთვნებიან ისინი. სისტემა თვითონ არეგულირებს პარამეტრებს და აყალიბებს გარჩევის პროცედურას ისე, რომ გარჩევის პროცედურაში იყოს მინიმალური ცდომილება.

მაგალითისათვის განვიხილოთ ნახაზზე წარმოდგენილი სასწავლო ამონარჩევები, რომლებიც ერთმანეთისგან შეიძლება გამოვყოთ ორი წრფით ისე რომ x_1, x_2 და x_3 ობიექტები მოხვდნენ პირველ კლასში, x_4, x_5 და x_6 ობიექტები მოხვდნენ მე-2 კლასში, ხოლო x_7, x_8 - მე-3 კლასში.

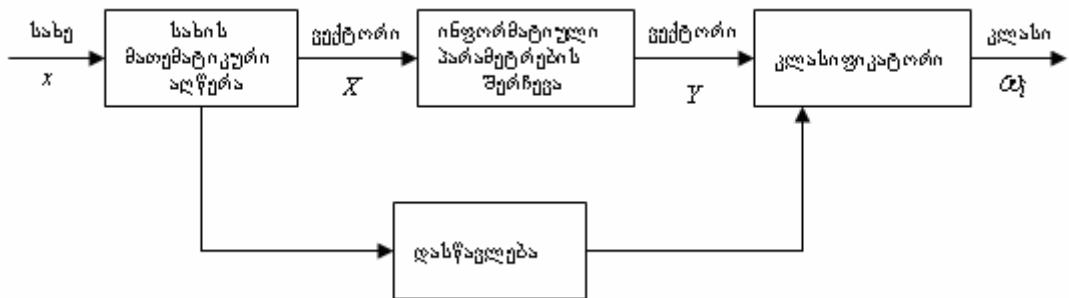


3. თვითსწავლების სისტემები. ამ შემთხვევაში გარჩევის სისტემაში შეტანილია წესების გარკვეული ერთობლიობა, რომლებიც აღწერენ გასარჩევ ამოცანას. ეს წესები, როგორც წესი, ამუშავებენ ექსპერტები ანუ დარგობრივი სფეროს სპეციალისტები. ასეთ სისტემებს უწოდებენ ექსპერტულს ანუ ინტელექტუალურ სისტემებს. გარჩევის სისტემამ არსებული წესების საფუძვლზე უნდა შეარჩიოს პარამეტრები და განსაზღვროს კლასების საზღვრები. ამ შემთხვევაში, როგორც წესი, გამოიყენება მონაცემთა დამუშავების ლოგიკურ-დიაგნოსტიკური მეთოდები. გარჩევის ასეთ ტიპიურ მაგალითს წარმოადგენს სამედიცინო დიაგნოსტიკური სისტემები.

1.4 სახეოთა გარჩევის თეორიის მირითადი ამოცანები

განვიხილოთ სახეოთა გარჩევის ამოცანები ტექნიკური სისტემის მუშაობის მაგალითზე, სადაც ხდება სიმბოლოების (ციფრები, ასოები და სხვ.) გარჩევა. ასეთი სისტემა 60-ან წლებში შეიქმნა აშშ და დიდი ხნის განმავლობაში გამოიყენებოდა საფოსტო კონვერტების გარჩევისთვის.

დავუშვათ სისტემას მიეწოდება რაიმე C სიმბოლო და საჭიროა მისი ამოცნობა. სახეოთა გარჩევის სისტემის ზოგადი სქემა წარმოდგენილია შემდეგ ნახაზზე:



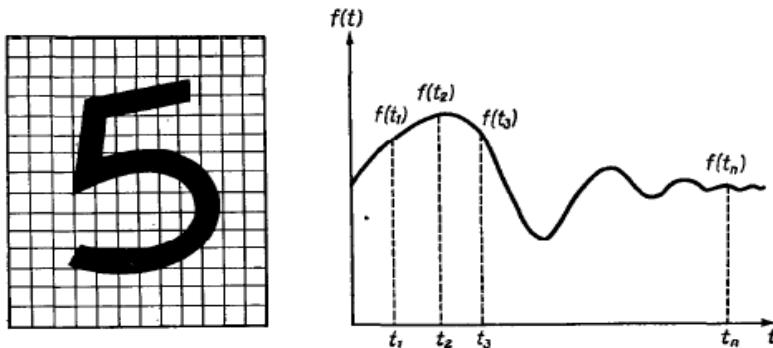
კლასიფიკატორის დანშნულებაა C სახის მიკუთვნება რომელიმე w_i კლასს. გარჩევის ზოგად სქემაში შეიძლება იყოს დასწავლების ბლოკი, რომლის დანიშნულებაა ჩამოყალიბოს იდენტიფიკაციის წესი.

შეიძლება ჩამოყალიბოთ სახეოთა გარჩევის შემდეგი ძირითადი ამოცანები:

1. სახეების მათემატიკური აღწერა. ამ მხრივ ყველაზე მოსახერხებელია სახის ვექტორული წარმოდგენა. ამ შემთხვევაში C სახეს შეესაბამება ვექტორი $X_i = (x_1, x_2, \dots, x_n)^T$, სადაც x_1, x_2, \dots, x_n წარმოადგენენ სახის პარამეტრებს (ნიშნებს). ასეთ

ვექტორულ სივრცეს პარამეტრების სივრცე ეწოდება, რომელიც წარმოადგენს მეტრიკულს და სასრულო ზომას.

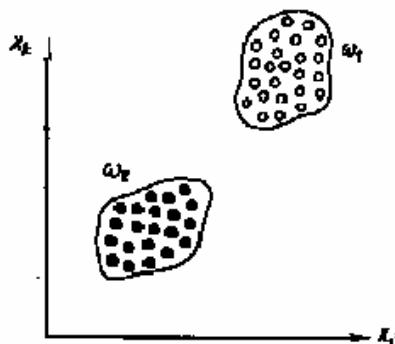
ამრიგად, პირველი ამოცანა მდგომარეობს საწყისი მონაცემების წარმოდგენაში. თითოეული გაზომილი სიდიდე წარმოადგენს სახის რეალიზაციის მახასიათებელ მნიშვნელობას. მაგალითად, თუ საჭიროა სიმბოლოების გარჩევა, მაშინ გადამწოდად შეგვიძლია გამოვიყენოთ გაზომვის ბადე ანუ უჯრედთა დალაგებული ერთობლიობა, რომლებიც ქმნიან რეცეპტორულ ველს როგორც ეს შემდეგ ნახაზზე წარმოდგენილი:



თუ ბადე შედგება n რაოდენობის უჯრედებისგან და ყოველი უჯრედი განიხილება როგორც ერთი ცალკე აღებული ნიშანი, მაშინ გაზომვის შედეგი შეგვიძლია წარმოვიდგნინოთ, როგორც სახის ანსამბლის ვექტორი $X_i = (x_1, x_2, \dots, x_n)^T$, სადაც თითოეული კომპონენტი X_i ღებულობს, მაგალითად ერთის ტოლ სიდიდეს, როცა i -ურ უჯრედში გადის სიმბოლოს გამოსახულება და ნულს, წინააღმდეგ შემთხვევაში. მეორე მაგალითი წარმოდგენილია ზემოდ მოყვანილ ნახაზზე.

ამ შემთხვევაში საქმე გვაქვს უწყვეტ ფუნქციასთან (მაგ. ბიოსიგნალი). თუ ფუნქციის გაზომვა ხდება t_1, t_2, \dots, t_n დროით წერტილებში, მაშინ სახის ვექტორის კომპონენტები იქნებიან $x_1 = f(t_1), x_2 = f(t_2), \dots, x_n = f(t_n)$

2. ინფორმაციული პარამეტრების შერჩევა. გაზომვის პროცესი შეიძლება განვიხილოთ, როგორც კოდირების პროცესი. მაგალითისთვის განვიხილოთ ნახაზზე წარმოდგენილი ორი w_1 და w_2 სახე.



თითოეული სახე სასიათდება ორი x_1 და x_2 კომპონენტით, რომელიც მიიღება გაზომვის შედეგად. რეალიზაციის ვექტორს აქვს შემდეგი სახე: $X=(x_1, x_2)^T$. როგორც ნახაზიდან ჩანს, ეს ორი სახე ქმნის გადაუკვეთავ ერთობლიობას, რაც მეტად ხელსყრელია სახეთა გარჩევის ამოცანის გადასაწყვეტად. სამწუხაროდ, პრაქტიკაში ყოველთვის ასე როდია, მაგალითად, ძალზე ძნელია ისეთი პარამეტრების შერჩევა, რომლებიც მოგვცემდნენ გადაუკვეთავ სიმრავლეებს. აქედან გამომდინარეობს სახეთა გარჩევის მეორე ამოცანა, რომელიც მდგომარეობს საწყისი მონაცემებიდან ინფორმატიული (მახასიათებელი) პარამეტრების (ნიშნების) შერჩევაში და აქედან გამომდინარე, ობიექტების განზომილების შემცირებაში.

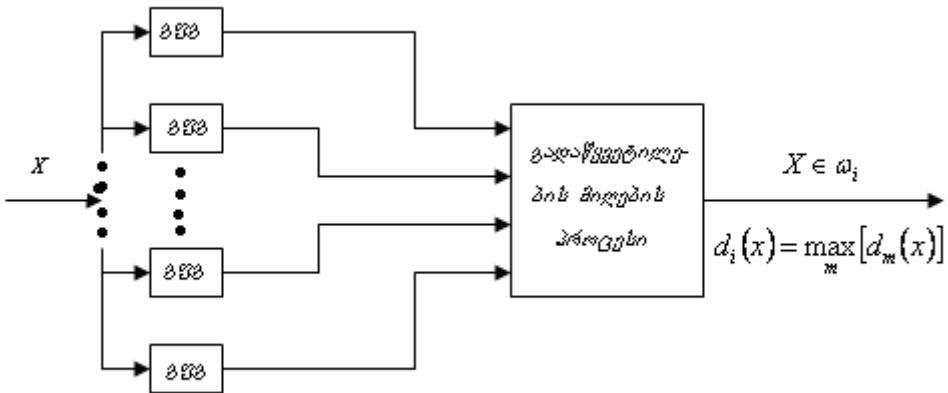
სახეთა გარჩევის თეორიაში პარამეტრების შერჩევა წარმოადგენს ერთ-ერთ უმნიშვნელოვანეს ამოცანას, რომლის მიზანია შეარჩიოს რაც შეიძლება მინიმალური პარამეტრების რაოდენობა, რომლებიც ადეკვატურად აღწერენ სახეებს. ის პარამეტრები, რომლებიც განსხვავდებიან კლასებს შორის, წარმოადგენენ ინფორმატიულებს და მათ სახეთაშორისო (კლასთაშორისო) პარამეტრებს უწოდებენ. ის პარამეტრები, რომლებიც სახეებს შორის არ განსხვავდებიან, სახეთა გარჩევის ამოცანიდან გამომდინარე, მათ არ მოაქვთ რაიმე სასარგებლო ინფორმაცია და ამიტომ შეიძლება მათი უგულვებელყოფა.

თუ გაზომვა გვაძლევს საშუალებას მივიღოთ ყველა კლასისათვის მთლიანი განმასხვავებელი პარამეტრების რაოდენობა, მაშინ სახეთა გარჩევა არ წარმოადგენს პრობლემას. პრაქტიკაში ასეთი სრული განმასხვავებელი პარამეტრთა ერთობლიობის მიღება თითქმის შეუძლებელია. საბედნიეროდ, საწყის პარამეტრთა ერთობლიობიდან შეიძლება შეირჩეს გარკვეული რაოდენობის განმასხვავებელი პარამეტრები, რომლებიც შეიძლება გამოვიყენოთ სახეთა გარჩევის ამოცანის გადასაწყვეტად.

3. ერთგვაროვანი კლასების შექმნა. ეს ამოცანა, რომელსაც კლასტერიზაციის ამოცანა ეწოდება, წარმოადგენს უმნიშვნელოვანეს ეტაპს სახეთა გარჩევის სისტემის შექმნის დროს. სწორედ კლასტერიზაციის მეთოდები გამოიყენებიან საწყის პარამეტრთა ერთობლიობიდან, ერთგვაროვან კომპაქტურ სივრცეში, არაგადამკვეთი სახეების შესაქმნელად, რაც წინაპირობაა იმისა, რომ სახეთა გარჩევის ამოცანა ხდება პრაქტიკულად რეალიზებადი.

4. გადაწყვეტილების მიღების პროცედურის ოპტიმიზაცია. როგორც აღვნიშნეთ, გადაწყვეტილების მიღების პროცედურა ეფუძნება გარჩევის პროცესს, რომელსაც მივყავართ იდენტიფიკაციის ანუ დისკრიმინანტული ანალიზის ამოცანამდე.

დავუშვათ, მოცემულია W_1, W_2, \dots, W_m კლასები. ამ შემთხვევაში სახეთა გარჩევის ამოცანა შეიძლება განვიხილოთ როგორც m რაოდენობის კლასის გამყოფი საზღვრების აგების ამოცანა. ვთქვათ, ასეთი გამყოფი ფუნქციები $d_1(x), d_2(x), \dots, d_m(x)$ მოცემულია. ეს ფუნქციები, რომლებსაც გადამწყვეტ ან განმამხოვებელ ფუნქციებს უწოდებენ, წარმოადგენენ $\{C\}$ სახის სკალარულ და ერთმნიშვნელიან ფუნქციებს. თუ $d_i(x) > d_j(x), \dots$ ყველა $i, j = 1, 2, \dots, m$, $i \neq j$, მაშინ C რეალიზაცია მიეკუთვნება W_i კლასს. სხვა სიტყვებით, თუ i -ურ გადამწყვეტ ფუნქციას $d_i(x)$ გააჩნია ყველაზე დიდი მნიშვნელობა, მაშინ $C \in W_i$. ამ პრინციპზე აგებული ავტომატიზებული იდენტიფიკაციური სისტემის ბლოკ-სქემას აქვს შემდეგი სახე:



სადაც C – უცნობი რეალიზაციაა, გფგ – გადამტკიცების გენერატორი. საზოგადოდ, გადამტკიცები ფუნქცია შეიძლება მივიღოთ სხვადასხვა მეთოდებით, რომლებიც პირობითად შეიძლება დაგურთ თუ ჯგუფად: დეტერმინირებულ და სტრუქტურულ ალგორითმებად.

იმ შემთხვევაში, როცა ცნობილია გასარჩევ ობიექტთა შესახებ აპრიორული ინფორმაცია, მაშინ გადამტკიცები ფუნქციის განსაზღვრა შესაძლებელია ზუსტად. წინააღმდეგ შემთხვევაში, როცა ობიექტთა მიმართ გაგვაჩნია მხოლოდ თვისებრივი ნიშნები, მაშინ გადამტკიცებათა მიღების არე შეიძლება მნიშვნელოვნად განსხვავდებოდეს რეალურისაგან და ამიტომ საჭიროა შეიქმნას ისეთი გარჩევის სისტემა, რომელიც თანდათანობით მიგვიყვანდა გადამტკიცები ფუნქციის განსაზღვრის ოპტიმალურ ან მისაღებ ვარიანტამდე.

1.5 მანძილის და მსბავსების ზომის ცნებები

სახეთა გარჩევის თეორიაში მანძილის და მსგავსების ცნებებს ენიჭებათ ფუნდამენტალური მნიშვნელობა. აქედან გამომდინარე, განვიხილოთ ყველაზე უფრო გამოყენებადი მანძილის და მსგავსების ზომები.

ნებისმიერი ორი x_i და x_j რეალიზაციისათვის $d(x_i, x_j)$ ფუნქციას ეწოდება მანძილის ფუნქცია თუ სრულდება შემდეგი პირობები:

- ა) $d(x_i, x_j)=0$ როცა $x_i=x_j$
- ბ) $d(x_i, x_j)=d(x_j, x_i)$
- გ) $d(x_i, x_j) \leq d(x_i, x_k)+d(x_k, x_j)$

სადაც x_i, x_j და x_k n -განზომილებიანი სიგრცის ნებისმიერი ვექტორებია.

სახის ვექტორებს შეიძლება ჰქონდეთ სხვადასხვა განზომილება, სხვადასხვა რიგის სიდიდე, სხვადასხვა პრიორიტეტები. აქედან გამომდინარე სანამ განვსაზღვრავთ ვექტორებს შორის მანძილებს, სასურველია ვექტორების ნორმირება და სტანდარტიზაცია.

როგორც ვიცით, თითოეული სახის ვექტორი $X_i=(x_{i1}, x_{i2}, \dots, x_{in})^T$ შედგება ცალკეული კოორდინატებისგან (პარამეტრებისგან). სტანდარტიზაციის პროცედურა საშუალებას გვაძლევს ვექტორის ყველა კოორდინატი წარმოვადგინოთ საერთო მასშტაბით. არსებობს პარამეტრების სტანდარტიზაციის რამდენიმე მეთოდი. მაგალითად, იგი შეგვიძლია შევასრულოთ შემდეგი ფორმულით:

$$\bar{X}_{ik} = \frac{x_{ik} - m_i}{s_i}, \quad k=1,2,\dots,n$$

სადაც m_i i -ური კოორდინატის საშუალო მნიშვნელობაა, s_i - საშუალო გვადრატული გადახრა. სტანდარტიზაცია შესაძლებელია შემდეგი გამოსახულებითაც:

$$\bar{X}_{ik} = \frac{x_{ik} - \min_k x_{ik}}{\max_k x_{ik} - \min_k x_{ik}}, \quad k=1,2,\dots,n$$

განვიხილოთ მანძილი n - განზომილებიან ნიშანთა სივრცეში ორ ვექტორს შორის, ვექტორსა და სიმრავლეს შორის და ბოლოს ორ სიმრავლეს შორის

1. მანძილი ორ ვექტორს შორის. n - განზომილებიან ევკლიდეს სივრცეში X_i და X_j ვექტორებს შორის განისაზღვრება ფორმულით:

$$d(x_i, x_j) = \|X_i - X_j\| = \sqrt{(X_i - X_j)^T (X_i - X_j)} = \sqrt{\sum_{k=1}^n (X_{ki} - X_{kj})^2} \quad (1)$$

ევკლიდეს მანძილი ყველაზე უფრო გავრცელებული მეტრიკაა სახეთა გარჩევის თეორიაში. განსაკუთრებით საინტერესო „შეწონილი” ევკლიდეს მანძილი:

$$d(x_i, x_j) = \sqrt{\sum_{k=1}^n w_k (X_{ki} - X_{kj})^2}$$

სადაც სახის თითოეულ რეალიზაციას გააჩნია წონითი w_k კოეფიციენტი ($\text{ჩვეულებრივ } 0 < w < 1$), რომელიც სახეთა გარჩევის ამოცანის გადაწყვეტის თვალსაზრისით პროპორციულია X_i პარამეტრის მნიშვნელობის ხარისხისა. კერძოდ, რაც უფრო ინფორმატიულია პარამეტრი, მით უფრო დიდია მისი წონითი კოეფიციენტი და პირიქით,

2. მანძილი ვექტორსა და სიმრავლეს შორის. მანძილი X ვექტორსა და ვექტორთა $\{A^i\}$ $i=1,2,\dots,m$ სიმრავლეს შორის განისაზღვრება, როგორც საშუალო კვადრატული მანძილი X ვექტორსა და $\{A^i\}$ სიმრავლეს შორის შემდეგი გამოსახულებით:

$$d^2(X, A^i) = \frac{1}{m} \sum_{i=1}^m \sum_{k=1}^n (x_k - a_k^i)^2$$

სადაც n - ვექტორთა განზომილებაა.

3. შიგა სიმრავლის მანძილი. მოცემული $\{A^i\}$ $i=1,2,\dots,m$ ვექტორთა შიგასიმრავლის მანძილი განისაზღვრება როგორც შიგასიმრავლის საშუალო კვადრატული მანძილი შემდეგი ფორმულით:

$$\overline{d^2(A^i A^j)} = \frac{1}{m(m-1)} \sum_{j=1}^m \sum_{i=1}^m \sum_{k=1}^n (a_k^i - a_k^j)^2$$

სადაც $m-1$ სიდიდე იმიტომაა აღებული, რომ როცა $i=j$, მაშინ მანძილი ნულის ტოლია. შიგა სიმრავლის მანძილი შეიძლება განისაზღვროს A^i ვექტორების დისპერსიების საშუალებით შემდეგი ფორმულით:

$$d^2(A^i, A^j) = 2 \sum_{k=1}^m s_k^2$$

4. სიმრავლეებს შორის მანძილი. მანძილი $\{A^i\}$ და $\{B^j\}$ სიმრავლეს შორის განსაზღვრება ისევე, როგორც შიგასიმრავლის მანძილის განსაზღვრისას, კერძოდ (2) ფორმულით და მისი ზოგადი სახით წარმოდგენა არც ისე ადვილია. სიმრავლეებს შორის მანძილის გასაგებად უფრო ხშირად იყენებენ მახანალობისის მანძილის ფორმულას:

$$d(A^c, B^j) = (\bar{A} - \bar{B})^T S^{-1} (\bar{A} - \bar{B})$$

სადაც \bar{A} და \bar{B} სიმრავლეების საშუალო ვექტორებია, S – გაერთიანებული კოვარიაციული მატრიცაა. მახანალობისის მანძილის ფორმულას გაანია მთელი რიგი უპირატესობა, კერძოდ იგი ინვარიანტულია ნებისმიერი წრფივი გარდაქმნის მიმართ.

მართლაც, განვიხილოთ $Z = AX$ წრფივი გარდაქმნა, მაშინ გვექნება

$$\begin{aligned} d^2(X_i - X_j) &= (Z_i - Z_j)^T S^{-1} (Z_i - Z_j) = (AX_i - AX_j)^T S^{-1} (AX_i - AX_j) = (X_i - X_j)^T S^{-1} (X_i - X_j) = \\ &= (X_i - X_j)^T A^T (AS^{-1} A^T) A (X_i - X_j) = (X_i - X_j)^T S^{-1} (X_i - X_j) = d^2(X_i - X_j) \end{aligned}$$

ამ თვისებიდან გამომდინარე, თუ პარამეტრები გაზომილი არიან სხვადასხვა ფიზიკურ ერთეულებში, მაშინ საჭირო არ არის მათი ნორმირება.

სახეთა გარჩევის თეორიაში W_m და W_e კლასებს შორის მანძილის განსაზღვრისთვის ხშირად გამოიყენება შემდეგი მანძილები:

1) მანძილი, განსაზღვრული „უახლოესი მეზობლის“ პრინციპით:

$$d_{\min}(W_m, W_e) = \min d(X_i, X_j), \quad \text{როცა } X_i \in W_m \text{ და } X_j \in W_e$$

2) მანძილი, განსაზღვრული „უკიდურესი მეზობლის“ პრინციპით:

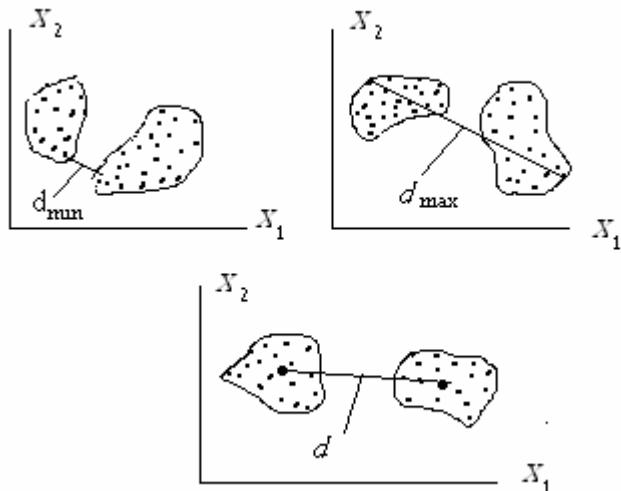
$$d_{\max}(W_m, W_e) = \max d(X_i, X_j), \quad \text{როცა } X_i \in W_m \text{ და } X_j \in W_e$$

3) მანძილი, განსაზღვრული კლასების „სიმძიმის ცენტრებს“ შორის:

$$d(W_m, W_e) = d(\bar{X}(m), \bar{X}(e)),$$

სადაც $\bar{X}(m)$ და $\bar{X}(e)$ – კლასების სიმძიმის ცენტრები ანუ საშუალო არითმეტიკულებია.

ქვემოთ მოყვანილ ნახაზებზე ნაჩვენებია ორ კლასს შორის ზემოთ მოყვანილი მანძილის ფუნქციები



სახეთა გარჩევის თეორიაში მანძილის გარდა ფართოდ გამოიყენება მსგავსების ზომა. არაუარყოფით ნამდვილ ფუნქციას $j(X_i, X_j)$ ეწოდება მსგავსების ზომა, თუ სრულდება შემდეგი პირობები:

$$\text{ა) } j(X_i, X_j) = \max j(X_i, X_j) = 1, \text{ როცა } X_i = X_j$$

$$\text{ბ) } 0 \leq j(X_i, X_j) < 1, \text{ როცა } X_i \neq X_j$$

$$\text{გ) } j(X_i, X_j) = j(X_j, X_i)$$

მსგავსების მატრიცას აქვს შემდეგი სახე:

$$\Phi = \begin{bmatrix} 1 & j_{12} & j_{13} & \dots & j_{1n} \\ j_{21} & 1 & j_{23} & \dots & j_{2n} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ j_{n1} & j_{n2} & j_{n3} & \dots & 1 \end{bmatrix}$$

სადაც j_{ij} – ელემენტებს ეწოდებათ მსგავსების კოეფიციენტები.

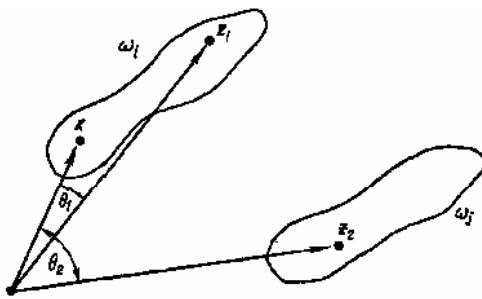
რაც უფრო ნაკლებია მანძილი ორ X_i , და X_j ვექტორებს შორის მით უფრო დიდია მსგავსება ამ ვექტორებს შორის. აქედან გამომდინარე, მსგავსებასა და მანძილს შორის არსებობს შემდეგი დამოკიდებულება:

$$j_{ij} = \frac{1}{1 + d_{ij}}.$$

მსგავსება არ განისაზღვრება მხოლოდ მანძილით, იგი შეიძლება განისაზღვროს, მაგალითად, შემდეგი გამოსახულებით:

$$d(X_i, X_j) = \frac{X_i^T X_j}{\|X_i\| \|X_j\|}$$

რომელიც არითმეტიკული ფუნქციაა და გეომეტრიულად წარმოადგენს ორ ვექტორს შორის კუთხის კოსინუსს, რომელიც მაქსიმუმს აღწევს იმ შემთხვევაში, როცა ვექტორების მიმართულებები ემთხვევიან ერთმანეთს. ამ მსგავსების ზომის გამოიყენება მოსახერხებელია იმ შემთხვევაში, როცა კლასებს გააჩნიათ მთავარი დერძის მიმართ განლაგების ტენდეცია, ისე როგორც ეს ნახვენებია შემდეგ ნახაზზე:



$$d(X_1, Z_1) = \cos Q_1 \frac{X_1^T Z_1}{\|X_1\| \|Z_1\|}, \quad d(X_1, Z_2) = \cos Q_2 \frac{X_1^T Z_2}{\|X_1\| \|Z_2\|}$$

ეს ნახაზი გვიჩვენებს, რომ Z_1 სახეს გააჩნია X სახესთან უფრო მეტი მსგავსება, ვიდრე Z_2 სახეს ($\cos Q_1 > \cos Q_2$). უნდა აღინიშნოს, რომ მსგავსების ამ ზომას გააჩნია

გარკვეული ნაკლოვანებები, რომლებიც დაკავშირებულნი არიან ისეთ შეზღუდვებთან როგორიცაა მაგალითად, კლასების მნიშვნელოვანი დაშორება როგორც ერთმანეთთან, ასევე კოორდინატთა სათავიდან.

ზემოთ მოყვანილი მანძილისა და მსგავსების ზომის გამოყენება შესაძლებელია იმ შემთხვევაში თუ სახის რეალიზაციები ზომვადია. თვისებრივი მონაცემებისათვის სახეთა გარჩევის ამოცანის გადასაწყვეტად უნდა გამოვიყენოთ არაფორმალური პროცედურები, სადაც „მანძილის“ და „კავშრის ფუნქციის“ ფორმალური ცნებების გამოყენება დაუშვებელია.

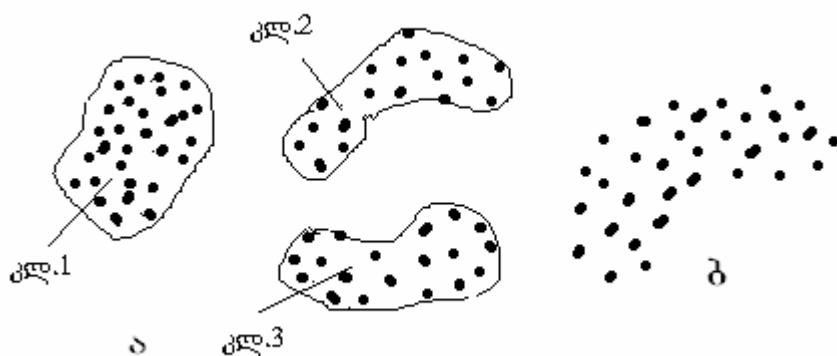
2. კლასტერიზაციის მეთოდები

2.1. კლასტერიზაციის ამოცანის ჩამოყალიბება

ობიექტთა (რეალიზაციათა) ერთობლიობის დაყოფას ერთგვაროვან (პომოგენურ) ჯგუფებად (კლასტერებად) ეწოდება კლასტერიზაციის ამოცანა. კლასტერიზაციის ტერმინთან ერთად ხშირად გამოიყენება მისი სინონიმები: „კლასიფიკაცია“, „დაჯგუფება“ და „ტაქსონომია“.

კლასტერი ეწოდება გარკვეული წესით შედგენილ რეალიზაციათა ერთობლიობას. კლასტერის სინონიმია „ჯგუფი“. ამ განმარტებიდან გამომდინარეობს კლასტერიზაციის განმარტება. კლასტერიზაცია ეწოდება კლასტერის შედგენის (აგების) პროცედურას, რომელიც ეფუძნება კომპაქტურობის პიპოთეზას და რომლის არსი იმაში მდგომარეობს, რომ ერთი და იგივე კლასტერის რეალიზაციები სიგრცეში, გარკვეული აზრით, ქმნიან კომპაქტურ ერთობლიობას.

კლასტერები შეიძლება თვალსაჩინოდ წარმოვადგინოთ სიბრტყეზე მოცემული სიმრავლეებით. ნახ.1 ა-ზე მოცემულია წერტილთა სიმრავლე, რომლებიც ქმნიან სამ კლასტერს, ხოლო ნახ.1 ბ-ზე მოცემულია წერტილთა სიმრავლე, რომლებიც არ ქმნიან კლასტერებს, რაც იმას ნიშნავს, რომ მათი დაყოფა გვაძლევს მხოლოდ ერთ კლასტერს – მთლიანად მოცემულ წერტილთა სიმრავლეს.



ნახ.1

უნდა შევნიშნოთ, რომ კლასტერის ცნება მნიშვნელოვნად ინტუიციურია, რაც აძნელებს ამ ცნების მკაცრი მეცნიერული განსაზღვრის ჩამოყალიბებას. ამიტომ კლასტერების გამოვლენა წარმოადგენს „ხელოვნებას“, თანაც ემპირიულს, რადგან ალგორითმის მუშაობის ეფექტიანობა ბევრადაა დამოკიდებული როგორც ობიექტთა

სიმრავლის მახასიათებლებზე, ასევე მსგავსების ზომაზე და კლასტერების იდენტიფიკაციის მეთოდზე.

დავუშვათ მოცემულია ობიექტთა (რეალიზაციათა) სიმრავლე $\{X\}$ და საჭიროა მისი დაყოფა ქვესიმრავლებად ანუ კლასტერებად. როგორც კლასტერიზაციის განსაზღვრებიდან ჩანს, ამისთვის საჭიროა არსებობდეს რაიმე მახასიათებელი ნიშნები (პარამეტრები), რომლთა მიხედვითაც შესაძლებელი იქნება მოცემული სიმრავლის ელემენტების ერთმანეთისგან გარჩევა და შემდგომ დაყოფა.

განვიხილოთ უმარტივესი შემთხვევა, როდესაც ნიშანი მხოლოდ ერთია. თუ ასეთი ნიშანი თვისებრივია, მაგალითად რაიმე საგნის ფერი, მაშინ დაყოფა გარდაიქმნება კ.წ. დიქოტომიად, როდესაც საგანს შეიძლება ჰქონდეს ეს ფერი ან არ ჰქონდეს. ამ შემთხვევაში კლასტერთა მაქსიმალური რაოდენობა ორის ტოლია.

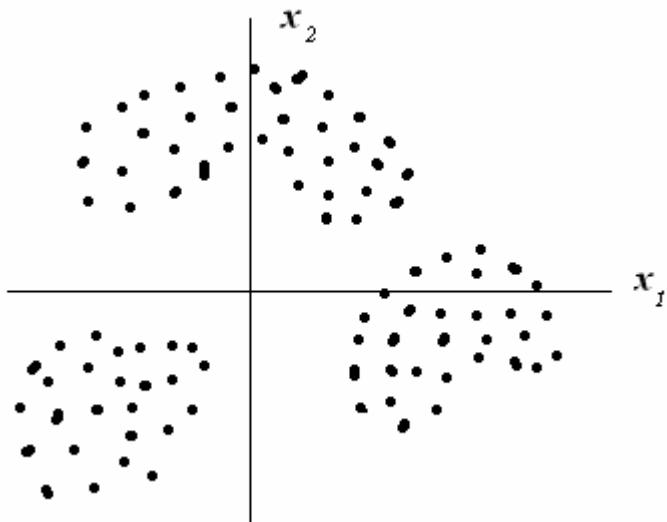
იმ შემთხვევაში, როცა ნიშანი ზომვადია, მაგალითად იდებს მნიშვნელობებს ნამდვილ რიცხვთა სიმრავდან, მაშინ შესაძლოა გვქონდეს კლასტერების ნებისმიერი სასრული რაოდენობა, მაგალითად, ისე როგორც ეს წარმოდგენილია შემდეგ ნახაზზე:

-----*-----*-----*-----*

c_1 c_2 c_3

სადაც გვექნება C_1 , C_2 და C_3 კლასტერი. თუ კლასტერი შეიცავს მხოლოდ ერთი სახის რეალიზაციებს, მაშინ ისინი კომპაქტურნი არიან, ხოლო თუ რომელიმე ჯგუფი შეიცავს ერთზე მეტი სახის რეალიზაციას, მაშინ გვაქვს არაკომპაქტური კლასტერი.

განვიხილოთ შემთხვევა, როდესაც ნიშნები ზომვადია და ერთზე მეტია, მაშინ ორი ნიშნის შემთხვევაში გვექნება სიბრტყეზე მოცემულ წერტილთა სიმრავლეები:



აქ სახეთა ნიშნები მოცემულია x_1 და x_2 სიმბოლოებით, რომელთა კონკრეტული მნიშვნელობები გვაძლევს სურათზე მოცემულ წერტილებს.

თუ ნიშანთა რაოდენობა სამია, მაშინ გვექნება სამგანზომილებიან სივრცეში მოცემული კლასტერები და ა.შ. საზოგადოდ, n -განზომილებიან ნიშანთა სივრცეში ნებისმიერი გეომეტრიული ფიგურა და მათ შორის კლასტერიც, შეიძლება წარმოვიდგინოთ როგორც პიკერსფერო, რომელსაც გააჩნია ცენტრი და რადიუსი. პიკერსფეროს რადიუსის არჩევისას გამოითვლება მინიმალური $\min\{X\}$ და მაქსიმალური $\max\{X\}$ მანძილები კლასტერის რეალიზაციებს შორის. ბუნებრივია, რომ რადიუსი უნდა აკმაყოფილებდეს შემდეგ პირობას:

ეყუბანეიშვილი. სახეთა გარჩევის მეთოდები

$$\min\{X\} < r < \max\{X\}$$

თუ არ სრულდება მარცხენა უტოლობით მოცემული პირობა, მაშინ ყველა რეალიზაცია $\{X\}$ სიმრავლეში იქნება ცალკე კლასტერი, ხოლო თუ მარჯვენა უტოლობა არ სრულდება, მაშინ $\{X\}$ სიმრავლის ყველა რეალიზაცია გაერთიანდება ერთ კლასტერში.

კლასტერის, როგორც რთული ობიექტის აგება შეუძლებელია, თუ არ იქნება მისი შემადგენელ რეალიზაციებს შორის მოცემული რაიმე მიმართება ანუ კრიტერიუმი. მაშასადამე, კრიტერიუმის არჩევა კლასტერიზაციის პროცესის განხორციელებისთვის არის უპირველესი, უმთავრესი და უაღრესად რთული პრობლემა.

კლასტერიზაციისთვის შერჩეული კრიტერიუმი უნდა აკმაყოფილებდეს შემდეგ პირობებს:

1. კრიტერიუმი უნდა აღწერდეს განსხვავებას ერთ კლასტერში გაერთიანებულ ობიექტებსა და სხვა კლასტერში მყოფ ობიექტებს შორის.
 2. უნდა იყოს კონსტრუქტიული ანუ რეალიზებადი, როგორც თეორიულად ასევე პრაქტიკულად.
 3. უნდა იყოს ცალსახად განსაზღვრული და შეძლებლისდაგვარად თვალსაჩინო.
- კლასტერიზაციის შემდგომი ეტაპია არჩეული კრიტერიუმის შესაბამისი ალგორითმის ფორმირება, რომელიც უნდა აკმაყოფილებდეს შემდეგ მოთხოვნებს:
- a) მაქსიმალური კონსტრუქტიულობა კ.ი. პროგრამული მოდელის მაქსიმალურად მარტივად განხორციელების შესაძლებლობა.
 - b) კლასტერიზაციის შედეგები არ უნდა იყოს დამოკიდებული საწყის რეალიზაციის არჩევაზე.
 - c) არ უნდა საჭიროებდეს ევრისტიკულად არჩეულ პარამეტრებს.
 - d) შესაძლებელი უნდა იყოს მიღებული შედეგების მაქსიმალურად თვალსაჩინო ინტერპრეტაცია.

2.2 კლასტერიზაციის პრიტერიუმები

კლასტერიზაციის კრიტერიუმი შეიძლება ეფუძნებოდეს რაიმე ევრისტიკულ მოსაზრებას ან რაიმე მაჩვენებლის თვისების მინიმიზაციას ან მაქსიმიზაციას. ევრისტიკულ მიღებისას გადამწყვეტ როლს თამაშობს ინტუიცია და გამოცდილება. იგი ითვალიწინებს წესების გარკვეულ რაოდენობას, რომლის საშუალებითაც ხდება სახეობა გარჩევის პროცესის რეალიზაცია.

კლასტერიზაცია, სადაც გამოიყენება რეალიზაციების თვისებები, ეფუძნება შერჩეული პარამეტრების თვისებების მინიმიზაციას, რაიმე კრიტერიუმის გამოყენებით. ერთ-ერთი ყველაზე პოპულარული კრიტერიუმია ცდომილებათა კვადრატების ჯამი.

$$I_1 = \sum_{m=1}^k \sum_{X_i \in S_m} d^2(X_i, \bar{X}_m) , \quad (1)$$

სადაც \bar{X}_m - w_m ჯგუფის სიმძიმის ცენტრია (საშუალო ვექტორი), k - ჯგუფების ანუ კლასტერების რაოდენობა. ამ ფუნქციონალს გააჩნია უბრალო ინტერპრეტაცია, კერძოდ w_m კლასტერისათვის \bar{X}_m საშუალო ვექტორი ყველაზე კარგად წარმოადგენს რეალიზაციებს $X_i \in w_m$, რადგან ის ახდენს X_i ვექტორების სიგრძის კვადრატების ჯამის მინიმიზაციას. ამრიგად I_1 ზომავს კვადრატულ ცდომილებას და დამოკიდებულია იმაზე თუ როგორ არიან დაჯგუფებულები რეალიზაციები. ოპტიმალურად ითვლება კლასტერიზაციის ის შემთხვევა, როდესაც ხდება I_1 გამოსახულების მინიმიზაცია. ასეთი ტიპის კლასტერიზაციას ხშირად უწოდებენ დაყოფას მინიმალური დისპერსიით.

მოყვანილი კლასტერიზაციის კრიტერიუმი ძირითადად გამოიყენება $\{X\}$ რეალიზაციათა ერთობლიობის ორ-სამ კლასტერად დაყოფის შემთხვევაში. მისი გამოყენება შეზღუდულია, როცა კლასტერები რეალიზაციების რაოდენობით მნიშვნელოვნად განსხვავდებიან ერთმანეთისგან. ასეთ შემთხვევაში შეიძლება ისე მოხდეს, რომ დაჯგუფება, რომელიც ქმნის დიდი მოცულობის კლასტერს, გააჩნდეს უაირატესობა, ვიდრე დაჯგუფებას, რომლის მოცულობა მცირეა, მაგრამ ინარჩუნებს სახის ერთიანობას.

(1) გამოსახულებაში უბრალო ალგებრული გარდაქმნით შეიძლება გამოვრიცხოთ საშუალების ვექტორი და მივიღოთ ექვივალენტური ფუნქციონალი, რომელსაც მივყავართ თითქმის იგივე შედეგთან.

$$I_2 = \frac{1}{2} \sum_{m=1}^k N_m \bar{d}_m,$$

სადაც \bar{d}_m - W_m ჯგუფის რეალიზაციების შორის საშუალო კვადრატული მანძილია. N_m რეალიზაციათა რაოდენობა. \bar{d}_m სიდიდე შეიძლება შეიცვალოს საშუალო მანძილით ან W_m კლასტერში გაერთიანებულ რეალიზაციებს შორის მაქსიმალური მანძილით.

განსაკუთრებით საინტერესოა კლასტერიზაციის კრიტერიუმად გაფანტვის მატრიცის გამოყენება. დავუშვათ მოცემული $\{X\}$ ერთობლიობს W_m კლასტერის გაფანტვის მატრიცად P_m , რომელიც განისაზღვრება შემდეგნაირად:

$$P_m = \sum_{x_i \in S_m} [X_i - \bar{X}_m][X_i - \bar{X}_m]^T.$$

მაშინ k რაოდენობის კლასტერების შიგაგაფანტვის მატრიცა იქნება:

$$P_k = \sum_{m=1}^k P_m ,$$

ხოლო ჯგუფთაშორისი გაფანტვის მატრიცა P_b შეგვიძლია ასე განვსაზღვროთ:

$$P_b = \sum_{m=1}^k N_m [\bar{X}_m - \bar{X}][\bar{X}_m - \bar{X}]^T$$

სადაც \bar{X} - $\{X\}$ ერთობლიობის საშუალო ვექტორია. გაფანტვის საერთო მატრიცა ტოლია:

$$P_T = \sum_{x_i \in S_m} [X_i - \bar{X}][X_i - \bar{X}]^T.$$

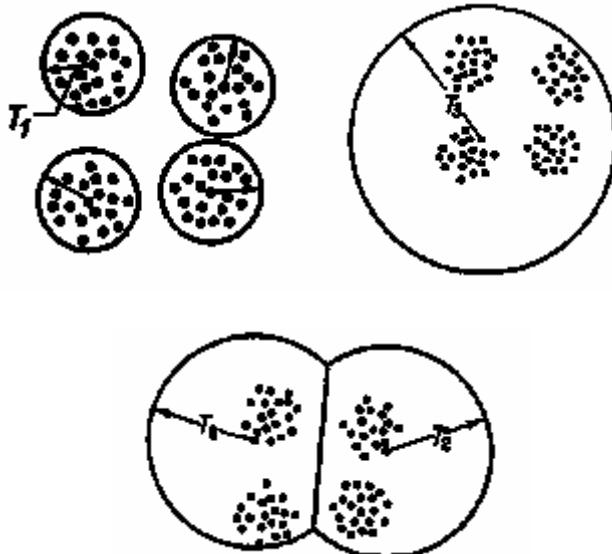
მიღებული გამოსახულების თნებმად, საერთო გაფანტვის მატრიცა შეიძლება წარმოვიდგინოთ როგორც შიგაჯგუფური და ჯგუფთაშორისო გაფანტვის მატრიცების ჯამი ე. ი. $P_T = P_K + P_b$.

გაფანტვის მატრიცები (შიგაჯგუფური და ჯგუფთაშორისი) დამოკიდებულია კლასტერიზაციის მეთოდებზე და მათ შორის არსებობს შემდეგი დამოკიდებულება: ჯგუფთაშორისო გაფანტვა იზრდება, თუ შიგაჯგუფური გაფანტვა მცირდება, ეს მეტად ხელსაყრელია სახეთა გარჩევის ამოცანის გადასაწყვეტად, რადგან შიგაჯგუფური გაფანტვის მატრიცის მინიმიზაციით, მიიღწევა ჯგუფთაშორისი (სახეთაშორისი) გაფანტვის მატრიცის მაქსიმიზაცია.

2.3. კლასტერიზაცია ზღურბლის ბამოყვებით

ვთქვათ, მოცემულია N ობიექტთა ერთობლიობა $\{X\}$. დავუშვათ, რომ პირველი კლასტერის ცენტრი Z_1 ემთხვევა ნებისმიერ X_i , $i=1,2,\dots,N$ რეალიზაციას, მაგალითად, პირველს ე. ი. $Z_1=X_1$. ამის შემდეგ გამოითვლება ევკლიდის მანძილი d_{21} X_2 რეალიზაციასა და Z_1 ცენტრს შორის, თუ მიღებული მანძილის მნიშვნელობა მეტია მოცემული ზღურბლის T მნიშვნელობაზე, მაშინ ჩამოყალიბდება მეორე კლასტერი $Z_2 = X_2$ ცენტრით. წინააღმდეგ შემთხვევაში X_2 რეალიზაცია მიეკუთვნება პირველ კლასტერს. ვთქვათ, შესრულდა $d_{21} > T$ პირობა, ე. ი. Z_2 არის ახალი კლასტერის ცენტრი, მაშინ გამოითვლება მანძილები X_3 რეალიზაციასა Z_1 და Z_2 ცენტრებს შორის ე. ი. d_{31} და d_{32} სიდიდეები. თუ ეს ორი მანძილი აღმოჩნდება T სიდიდეზე მეტი, მაშინ შეიქმნება ახალი მესამე კლასტერი $Z_3 = X_3$ ცენტრით. წინააღმდეგ შემთხვევაში X_3 რეალიზაცია მიეკუთვნება იმ კლასტერს, რომელთანაც მას გააჩნია მინიმალური მანძილი და ა. შ.

კლასტერიზაციის ეს ალგორითმი, პირველ რიგში, დამოკიდებულია პირველი კლასტერის ცენტრის შერჩევის და T ზღურბლის მნიშვნელობაზე. ეს ზეგავლენა ნაჩვენებია შემდეგ ნახაზზე, სადაც მოცემულია ერთი და იგივე ორგანზომილებიანი რეალიზაციებისათვის კლასტერების ცენტრის შერჩევის სამი ვარიანტი.



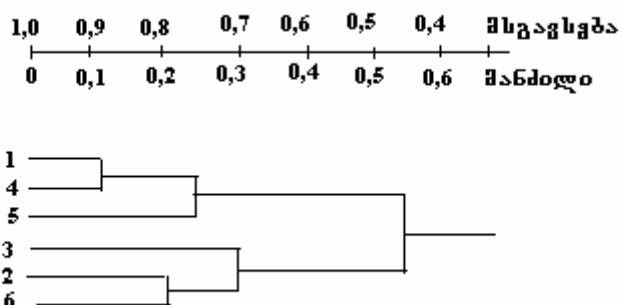
აღნიშნული ალგორითმი იძლევა საშუალებას საკმაოდ მარტივად და სწრაფად შევაფასოთ $\{X\}$ ერთობლიობის სტრუქტურა. მეთოდი იმითაა მიმზიდველი, რომ მას სჭირდება საწყისი რეალიზაციების X_i , $i=1,2,\dots,N$ ერთჯერადი განხილვა. პრაქტიკულად ალგორითმის გამოყენება დაიყვანება ზღურბლის მნიშვნელობის და კლასტერის საწყისი ცენტრის მრავალჯერადი ექსპერიმენტალურად შერჩევაზე, რაც მიუთითებს მეთოდის ნაკლებობას. მიუხედავად ამისა, კლასტერიზაციის ეს მარტივი მეთოდი, სადაც ხდება რეალიზაციების ერთჯერადი დამუშავების შედეგად მიღებული მიახლოვებითი შედეგების მიღება, მეტად ეფექტურია გამოთვლითი პროცედურის თვალსაზრისით.

2.4 კლასტერიზაცია იმრარჩის პრინციპით

განვიხილოთ N განზომილებიანი $\{X\}$ ერთობლიობის დაყოფა k რაოდენობის ერთგვაროვან კლასტერად. დასაწყისში ჩავთვალოთ, რომ გვაქვს N კლასტერი, რომლებიც შეიცავენ მხოლოდ ერთ რეალიზაციას (ობიექტს). შემდეგ, ორი უველაზე დაშორებული ან უკელაზე უახლესი მეზობელი ობიექტი ერთიანდებიან ერთ ჯგუფში და ამრიგად, კლასტერიზაციის რაოდენობა მცირდება ერთით, ე. ი. გვექნება ($N-1$). ეს პროცესი გრძელდება მანამ, სანამ უველა N ობიექტი არ მოხვდება ერთ კლასტერში. ამრიგად, პირველ ბიჯზე გვაქვს k რაოდენობის კლასტერი, ხოლო $N - \text{ურ ბიჯზე} -$ ერთი კლასტერი. განხილულ დაჯგუფების თანმიმდევრობას გააჩნია ის თვისება, რომ რეალიზაციები X_i და X_j ერთიანდებიან, ვთქვათ m -ურ ბიჯზე ერთ კლასტერში და რჩებიან მასში შემდგომ ბიჯებზეც. დაჯგუფების ასეთ თანმიმდევრობას ეწოდება იერარქიული.

ნებისმიერი იერარქიული კლასტერიზაციისთვის არსებობს შესაბამისი ხე, რომელსაც დენდოგრამა ეწოდება. განვიხილოთ ამოცანა, ვთქვათ მოცემულია ექვსი რეალიზაციის მანძილების მატრიცა

$$D = \begin{bmatrix} 0 & 0.55 & 0.55 & 0.10 & 0.25 & 0.55 \\ & 0 & 0.50 & 0.55 & 0.55 & 0.20 \\ & & 0 & 0.55 & 0.55 & 0.30 \\ & & & 0 & 0.25 & 0.55 \\ & & & & 0 & 0.55 \\ & & & & & 0 \end{bmatrix}$$



1 და 4 ობიექტი უკელაზე უფრო მსგავსია, ამიტომ ისინი ერთიანდებიან ერთ ჯგუფში 0,9 მსგავსების ზომით. 2 და 6 ობიექტები ერთიანდებიან 0,8 მსგავსების ზომით მეორე ჯგუფში. ამ ბიჯზე ჩვენ გვაქვს ოთხი კლასტერი (1,4), 5, 3, (2,6). მე-4 და მე-5 ბიჯზე იქმნება ორი ჯგუფი (1,4,5) და (3,2,6), რომლებსაც შევსაბამება 0,75 და 0,7 მსგავსების ზომებს. საბოლოოდ უველა ობიექტი ერთიანდება ერთ კლასტერში 0,45 მსგავსების ზომით.

განხილულ მაგალითში შეიძლება ითქვას, რომ მესამე და მეოთხე ბიჯზე გაერთიანება ბუნებრივია, ხოლო მე-5 და მე-6 ბიჯებზე ხელოვნურია მსგავსების ზომის შემცირების გამო. აქედან გამომდინარე, თუ გვაქვს N რაოდენობის ობიექტი, შესაძლებელია შეიქმნას შესაბამისი რაოდენობის დენდოგრამები.

იერარქიული კლასტერიზაცია თავისი სიმარტივის გამო ფართოდ გამოიყენება დაჯგუფების ამოცანის გადასაწყვეტად. სხვა პროცედურებთან შედარებით ისინი იძლევიან სახეთა გეომეტრიული სტრუქტურის სრულ ანალიზს, რაც გვაძლევს თვალსაჩინო ინტერპრეტაციის საშუალებას. ასეთი პროცედურის გამოყენება შესაძლებელია მოცემულ $\{X\}$ რეალიზაციათა ერთობლიობიდან ერთგვაროვანი კლასტერების გამოსაყოფად. ამ დროს ალგორითმის შეჩერების კრიტერიუმად შეიძლება მივიღოთ წინასწარ მოცემული სახეთა რაოდენობა ან სხვა რაიმე კლასტერიზაციის კრიტერიუმი (მაგ. ცდომილებათა კვადრატების ჯამი, მსგავსების კრიტერიუმი, შიგაჯგუფების და ჯგუფთაშორისი გაფანტვის მატრიცები და სხვა).

იერარქიული კლასტერიზაციისას შეიძლება გამოვიყენოთ „უახლესი მეზობლის“ და „უკიდურესი მეზობლის“ ალგორითმები, რომლებიც წარმოადგენენ იერარქიული პროცედურის ორ უკიდურეს მიდგომას. ისევე როგორც სხვა მიდგომები, რომლებიც ორიენტირებული არიან მაქსიმუმზე და მინიმუმზე, ისინი მეტად მგრძნობიარენი არიან სხვადასხვა გადახრების მიმართ. ამ ნაკლის გამოსწორება შეიძლება თუ გამოვიყენებთ კლასტერების „სიმბიმის ცენტრებს“ შორის მანძილს ფუნქციებს.

2.4.1 უახლოესი მეზობლის მანძილის მეთოდი

ვთქვათ, საჭიროა მოცეული ობიექტებისათვის ჩავატაროთ კლასტერიზაცია. ჩავთვალოთ, რომ თითოეული ობიექტი არის დამოუკიდებელი კლასტერი. მანძილის მატრიცის მიღებისათვის უნდა განისაზღვროს კლასტერებს შორისო მანძილები. ყოველ ბიჯზე მანძილის D მატრიცაში მოიძებნება ორ კლასტერს შორის უმცირესი მანძილი და ეს ორი კლასტერი ერთიანდებიან და ქმნიან ახალ კლასტერს. ამის შემდეგ ხდება D მატრიცის კორექტირება ახალი კლასტერის გათვალისწინებით, კერძოდ, ახალ კლასტერსა და დანარჩენ კლასტერებს შორის განისაზღვრება უმცირესი მანძილები და ამით ხდება D მატრიცის კორექტირება. ეს პროცედურა გრძელდება მანამ, სანამ ყველა კლასტერი აღმოჩნდება ერთ კლასტერში.

ალგორითმის მუშაობა განვიხილოთ კერძო მაგალითზე. ვთქვათ, მოცეულია ოთხი ობიექტის მანძილების მატრიცა

$$D = \begin{bmatrix} 1 & 2 & 3 & 4 \\ 0 & 2,06 & 4,03 & 6,32 \\ & 0 & 2,50 & 4,12 \\ & & 0 & 2,24 \\ & & & 0 \end{bmatrix} \begin{matrix} 1 \\ 2 \\ 3 \\ 4 \end{matrix}$$

ბიჯი 1. პირველ ბიჯზე გვაქვს ოთხი (1), (2), (3), (4) კლასტერი და მათ შორის მანძილების D მატრიცა. D მატრიცაში ვეძებთ უმცირეს მანძილს. ასეთია (1) და (2) კლასტერებს შორის მანძილი, რომელიც ტოლია $d(1,2) = 2,06$. (1) და (2) კლასტერი გაერთიანდებიან ახალ (1,2) კლასტერში. ამის შემდეგ საჭიროა D მატრიცის კორექტირება ახალი (1,2) კლასტერის გათვალისწინებით. მაშინ მივიღებთ:

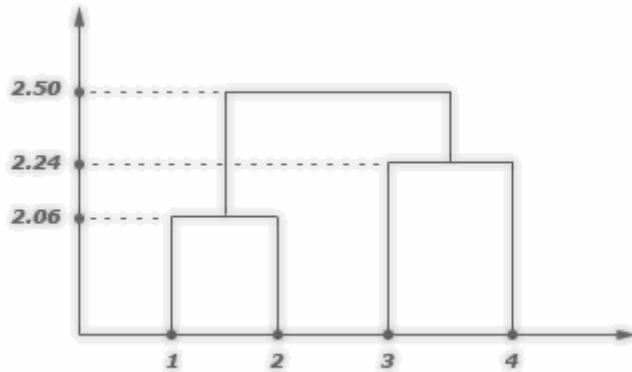
$$D = \begin{bmatrix} 1,2 & 3 & 4 \\ 0 & 2,50 & 4,12 \\ & 0 & 2,24 \\ & & 0 \end{bmatrix} \begin{matrix} 1,2 \\ 3 \\ 4 \end{matrix}$$

მაგალითებისათვის განვიხილოთ მანძილი (1,2) და (3) კლასტერებს შორის. რადგან, $d(1,3) = 4,03$, $d(2,3) = 2,50$, ამიტომ ვირჩევთ ამ ორი მანძილიდან უმცირეს და საბოლაოდ გვექნება $d((1,2),3) = 2,50$.

ბიჯი 2. ახალ D მატრიციდან გამომდინარე უმცირესი მანძილი გააჩნიათ (3) და (4) კლასტერს, რომლებიც ერთიანდებიან ახალ (3,4) კლასტერში 2,24 მანძილით. მოვახდინოთ D მატრიცის კორექტირება, მაშინ მივიღებთ”

$$D = \begin{bmatrix} 1,2 & 3,4 \\ 0 & 2,50 \\ & 0 \end{bmatrix} \begin{matrix} 1,2 \\ 3,4 \end{matrix}$$

ბიჯი 3. მიღებული D მატრიციდან (1,2) და (3,4) კლასტერები 2,50 ტოლი მანძილით გაერთიანდებიან ერთ კლასტერში. ამით ალგორითმი სრულდება, რადგან ოთხივე ობიექტი მოხვდა ერთ კლასტერში. დენდოგრამას აქვს შედეგი სახე:



2.4.2 უკიდურესი მეზობლის მანძილის მეთოდი

ამ შემთხვევაში მანძილების D მატრიცის ელემენტები განისაზღვრებიან როგორც მანძილები კლასტერების უკიდურეს მეზობლებს შორის. ერთიადებიან ის კლასტერები, რომელთა შორის მანძილი უმცირესია.

ამ გზით მიღებულ მანძილების მატრიცაში ყოველ ბიჯზე ვეძებთ იმ კლასტერებს რომელთა შორის მანძილი უმცირესია. ნაპოვნი კლასტერები ერთიანდებიან და ქმნიან ახალ კლასტერს. ეს პროცედურა გრძელდება მანამ, სანამ არ მოხდება ყველა კლასტერის გაერთიანება ერთ კლასტერში.

მაგალითი. ვთქვათ, მოცემულია მანძილების მატრიცა:

$$D = \begin{bmatrix} 1 & 2 & 3 & 4 \\ 0 & 2,06 & 4,03 & 6,32 \\ & 0 & 2,50 & 4,12 \\ & & 0 & 2,24 \\ & & & 0 \end{bmatrix} \begin{matrix} 1 \\ 2 \\ 3 \\ 4 \end{matrix}$$

პირველ ბიჯზე ჩავთვალოთ, რომ ყველა ობიექტი წარმოადგენს დამოუკიდებელ კლასტერს. ამ ბიჯზე ერთიანდებიან (1) და (2) კლასტერი, რადგან მათ შორის მანძილი 2,06 უმცირესია სხვა მანძილებთან შედარებით. ამის შემდეგ ხდება D მატრიცის კორექტირება. უნდა ვახსოვდეს, რომ მანძილი კლასტერებს შორის განისაზღვრება, როგორც მანძილი უკიდურესად დაშორებულ რეალიზაციებს შორის. მაშინ მივიღებთ:

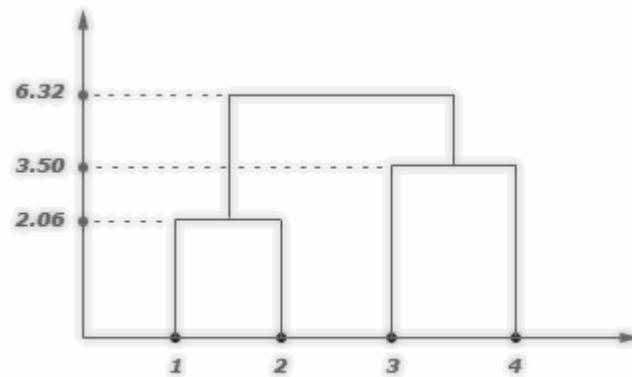
$$D = \begin{bmatrix} 1,2 & 3 & 4 \\ 0 & 4,03 & 6,32 \\ & 0 & 3,50 \\ & & 0 \end{bmatrix} \begin{matrix} 1,2 \\ 3 \\ 4 \end{matrix}$$

მაგალითებისათვის განვიხილოთ მანძილი (1,2) და (3) კლასტერებს შორის. რადგან, $d(1,3) = 4,03$, $d(2,3) = 2,50$, ამიტომ ვირჩევთ ამ ორი მანძილიდან უდიდეს და საბოლოოდ გვექნება $d((1,2),3) = 4,03$.

ბიჯი 2. ამ ბიჯზე ვაქვს სამი კლასტერი (1,2), (3), (4). როგორც D მატრიციდან ჩანს, (3) და (4) კლასტერები ერთიანდებიან, რადან მათ შორის მანძილი 3,50 მინიმალურია. D მატრიცის კორექტირების შემდეგ ვდებულობთ:

$$D = \begin{bmatrix} 1,2 & 3,4 \\ 0 & 6,32 \\ & 0 \end{bmatrix} \begin{matrix} 1,2 \\ 3,4 \end{matrix}$$

ბიჯი 3. ამ ეტაპზე ვაქვს ორი (1,2) და (3,4) კლასტერი, რომლებიც 6,32 მანძილით ერთიანდებიან ერთ კლასტერში. ალგორითმი ასრულებს თავის მუშაობას. დენდოგრამას აქვს შედეგი სახე:



2.4.3 არაშეწონილი წყვილ-წყვილი საშუალოების მეთოდი

იერარქიული კლასტერიზაციის ერთ – ერთ მეთოდს წარმოადგენს არაშეწონილი წყვილ-წყვილი საშუალოების მეთოდი (*Unweited Pair-group Metod Usin Aritmetic Averaes*). განვიხილოთ ეს მეთოდი.

ვთქვათ, საჭიროა მოცემული ობიექტების კლასტერიზაცია. ჩავთვალოთ, რომ თითოეული ობიექტი არის დამოუკიდებელი კლასტერი. ჯერ უნდა განისაზღვროს კლასტერებშორისო მანძილები, რომლებიც ქმნიან მანძილების D მატრიცას. D მატრიცაში ვეძებთ უმცირეს მანძილს. ვთქვათ, ასეთ მანძილს ქმნიან u და v კლასტერი, რომლებიც ერთიანდებიან და ქმნიან ახალ k კლასტერს. ამრიად D მატრიცაში u და v კლასტერების სვეტები და სტრიქონები ამოვარდებიან და მათ მაგივრად დაემატება ახალი k კლასტერისათვის ერთი სტრიქონი და ერთი სვეტი. აქედაან გამომდინარე, მანძილების D მატრიცა მცირდება ერთი სვეტით და ერთი სტრიქონით. ეს პროცედურა გრძელდება მანამ, სანამ ყველა კლასტერი არ გაერთიანდებიან ერთ საერთო კლასტერში.

დაუშვათ, u , v და k კლასტერები შეიცავენ შესაბამისად N_u , N_v და N_k რაოდენობის ობიექტებს. რადან k კლასტერი შეიქმნა u და v კლასტერების გაერთიანებით, ამიტომ $N_k = N_u + N_v$. მანძილი გაერთიანებულ k კლასტერსა და მაგალითად, w კლასტერს შორის განისაზღვრება ფორმულით:

$$d[(u, v), w] = \frac{N_u d(u, w) + N_v d(v, w)}{T_u + T_v} \quad (1)$$

მაგალითი. ვთქვათ, მოცემულია მანძილების მატრიცა:

$$D = \begin{bmatrix} & 1 & 2 & 3 & 4 & 5 \\ 0 & 2,06 & 4,03 & 6,32 & 2,08 \\ & 0 & 3,50 & 4,12 & 5,43 \\ & & 0 & 2,25 & 3,65 \\ & & & 0 & 4,81 \\ & & & & 0 \end{bmatrix} \begin{matrix} 1 \\ 2 \\ 3 \\ 4 \\ 5 \end{matrix}$$

ბიჯი 1. ყოველი ობიექტი ითვლება კლასტერად (1), (2), (3), (4), (5). ამ ბიჯზე ხდება იმ ორი კლასტერის გაერთიანება, რომელთაც გააჩნიათ უმცირესი მანძილი, სხვა მანძილებთან შედარებით. როგორც D მატრიციდან ჩანს $u = (1)$ და $v = (2)$ კლასტერები 2,06 მანძილით ერთიანდებიან ახალ (1,2) კლასტერში. ამის შემდეგ საჭიროა D მატრიცის ელემენტების კორექტორება (1,2) კლასტერის გათვალისწინებით. მაგალითვისათვის მოვიყვანოთ $k = (1,2)$ და $w = (3)$ კლასტერებს შორის მანძილის გამოთვლა. მონაცემებს ვიღებთ საწყის D მატრიციდან. მაშინ გვექნება $k = (1,3)$, $w = (3)$, $u = (1)$, $v = (2)$, $d(1,3) = 4,03$, $d(2,3) = 3,50$. თუ ამ მონაცემებს ჩავსვამთ (1) ფორმულაში მივიღებთ:

$$d[(1,2), (3)] = \frac{1 \cdot 4,03 + 1 \cdot 3,50}{1 + 1} = 3,765.$$

ანალოგიურად განისაზღვრება სხვა მანძილები და მივიღებთ შემდეგ კორექტორებულ მატრიცას:

$$D = \begin{bmatrix} (1,2) & 3 & 4 & 5 \\ 0 & 3,765 & 5,22 & 3,755 \\ & 0 & 2,25 & 3,65 \\ & & 0 & 4,81 \\ & & & 0 \end{bmatrix} \begin{matrix} (1,2) \\ 3 \\ 4 \\ 5 \end{matrix}$$

ბიჯი 2. მიღებული მატრიცის თანახმად (3) და (4) კლასტერები ერთიანდებიან 2,25 მანძილით და ვღებულობთ ახალ (3,4) კლასტერს. ამის შემდეგ კვლავ უნდა მოვახდინოთ D მატრიცის კორექტირება (3,4) კლასტერის გათვალისწინებით.

მაგალითებისათვის განვსაზღვროთ მანძილი $k = (3,4)$ და $w = (1,2)$ კლასტერებს შორის. კლასტერი k შეიქმნა $u = (3)$ და $v = (4)$ კლასტერების გაერთიანებით. $d(u,w)$ და $d(v,w)$ მანძილებს ვიღებთ წინა ბიჯის მატრიციდან, კერძოდ $d[(3),(1,2)] = 3,765$, $d[(4),(1,2)] = 5,22$. მიღებულ მნიშვნელობებს თუ ჩავსვამთ (1) ფორმულაში მივიღებთ:

$$d[(3,4),(1,2)] = \frac{1 \cdot 3,765 + 1 \cdot 5,22}{1+1} = 4,4925.$$

ანალოგიურად განისაზღვრება სხვა მანძილები და მივიღებთ:

$$D = \begin{bmatrix} (1,2) & (3,4) & 5 \\ 0 & 4,4925 & 3,755 \\ & 0 & 4,23 \\ & & 0 \end{bmatrix} \begin{matrix} (1,2) \\ (3,4) \\ 5 \end{matrix}$$

ბიჯი 3. ამ ბიჯზე 3,755 მანძილით ერთიანდებიან (1,2) და (5) კლასტერები და ქმნიან $k = (1,2,5)$ კლასტერს. საჭიროა D მატრიცის კორექტირება.

მაგალითისათვის განვიხილოთ $k = (1,2,5)$ და $w = (3,4)$ კლასტერებს შორის მანძილი. k კლასტერი შეიქმნა $u = (1,2)$ და $v = (5)$ კლასტერების გაერთიანებით. $d(u,w)$ და $d(v,w)$ მანძილებს ვიღებთ წინა ბიჯის მატრიციდან, კერძოდ

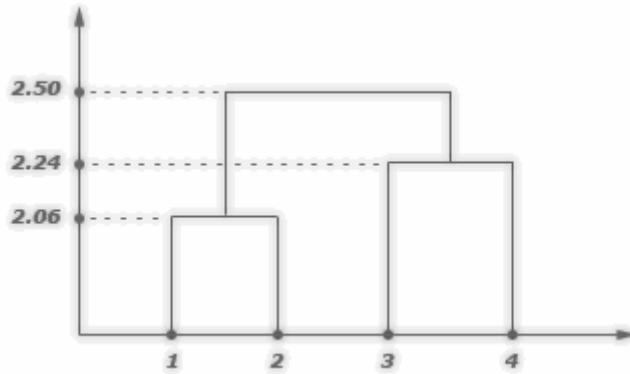
$d(u,w) = d[(1,2),(3,4)] = 4,4925$, $d(v,w) = d[(5),(3,4)] = 4,23$. მიღებულ მნიშვნელობებს თუ ჩავსვამთ (1) ფორმულაში მივიღებთ:

$$d[(1,2,5),(3,4)] = \frac{2 \cdot 4,4925 + 2 \cdot 4,23}{2+2} = 4,405 .$$

ე.ო. მივიღებთ:

$$D = \begin{bmatrix} (1,2,5) & (3,4) \\ 0 & 4,405 \\ & 0 \end{bmatrix} \begin{matrix} (1,2,5) \\ (3,4) \end{matrix}$$

ბიჯი 4. ამ ბოლო ბიჯზე 4,405 მანძილით ერთიანდებიან (1,2,5) და (3,4) კლასტერები. ამით ალგორითმი დასრულებულია. დენდოგრამას აქვს შედეგი სახე:



2.5 K შიგაჯგუფური საშუალოს მეთოდი

განვიხილოთ კლასტერიზაციის ერთ-ერთი პოპულარული მეთოდი, რომელიც ეფუძნება კლასტერში შემავალი ყველა რეალიზაციის თავისივე ცენტრთან მანძილების კვადრატების ჯამის მინიმიზაციას. ეს არის კლასტერების ცენტრების განსაზღვრის ბიჯური ალგორითმი, რომელსაც K შიგაჯგუფური საშუალოს მეთოდი ეწოდება და რომელიც შედგება შემდეგი ბიჯებისგან:

1. შეირჩევა K რაოდენობის რეალიზაციები, რომლებსაც ვდებულობთ კლასტერების საწყის ცენტრებად, ე.ი. $C_1^{(1)} = X_1, C_2^{(1)} = X_2, \dots, C_k^{(1)} = X_k$

2. იტერაციის შედეგ, $m -$ ურ ბიჯზე მოცემული $\{X\}$ ერთობლიობაში შემავალი რეალიზაციები $X_i, i = 1, 2, \dots, N$ K კლასებს შორის გადანაწილდებიან უახლოესი მეზობლის მანძილის გამოყენებით შემდეგი წესით:

$$X_i \in W_j^m \text{ როცა } d(X_i, C_j^{(m)}) < d(X_i, C_j^{(m)})$$

$i=1,2,\dots,k$, ყველა $i=1,2,\dots,N$, გარდა $i = j$. $W_j^{(m)}$ – რეილიზაციათა ერთობლიობაა, რომელიც შედიან $C_j^{(m)}$ ცენტრის მქონე კლასტერში. ტოლობის შემთხვევაში გადაწყვეტილება მიიღება ნებისმიერად.

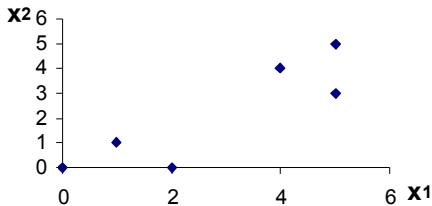
3. მე - 2 ბიჯის შედეგების შედეგად განისაზრება კლასტერების ახალი ცენტრები $C_1^{(m+1)}, C_2^{(m+2)}, \dots, C_k^{(m+1)}$

$$C_i^{(m+1)} = \frac{1}{N_j} \sum_{X_i \in S_j^{(m+1)}} X_i$$

სადაც $N_j - W_j^{(m+1)}$ კლასტერში შემავალი რეალიზაციების რაოდენობაა.

4. მოწმდება ახალი და წინა ბიჯზე მიღებული ცენტრების ტოლობის პირობა $C_i^{(m+1)} = C_i^{(m)}, i=1,2,\dots,K$. თუ ეს პირობა სრულდება, მაშინ კლასტერიზაციის პროცედურა მთავრდება. წინააღმდეგ შემთხვევაში გადავდივართ მე - 2 ბიჯზე.

მაგალითისათვის განვიხილოთ ორგანზომილებიანი რეალიზაციები $X_1 = (1,1)$, $X_2 = (0,0)$, $X_3 = (2,0)$, $X_4 = (4,4)$, $X_5 = (5,5)$, $X_6 = (5,3)$, რომლებიც წარმოდგენილნი არიან შემდეგ ნახაზზე:



1. საწყის ცენტრებად ავიღოთ $C_1^{(1)}=X_1$ და $C_2^{(1)}=X_2$
2. უახლოესი მეზობლის მანძილით $\{X_1, X_2, \dots, X_6\}$ ერთობლიობა გადავანაწილოთ $C_1^{(1)}$ და $C_2^{(1)}$ ცენტრების მიმართ, მაშინ მივიღებთ:

$$W_1^{(1)} = \{X_1, X_3, X_4, X_5, X_6\}, \quad W_2^{(1)} = \{X_2\}$$

3. განვსაზღვროთ მიღებული $W_1^{(1)}$ და $W_2^{(1)}$ კლასტერების ცენტრები:

$$C_1^{(2)} = \frac{1}{5} \left(\begin{matrix} X_{11} + X_{31} + X_{41} + X_{51} + X_{61} \\ X_{12} + X_{32} + X_{42} + X_{52} + X_{62} \end{matrix} \right) = \frac{1}{5} \left(\begin{matrix} 1+2+4+5+5 \\ 1+0+4+5+3 \end{matrix} \right) = \frac{17/5}{13/5}$$

$$C_2^{(2)} = X_2 = \begin{pmatrix} 0 \\ 0 \end{pmatrix}$$

4. შევამოწმოთ ცენტრების ტოლობის პირობა: $C_1^{(1)} \neq C_1^{(2)}$, $C_2^{(2)} = C_2^{(1)}$. რადგან პირველი კლასტერის ცენტრები არ ემთხვევიან ერთმანეთს, ამიტომ ვაგრძელებთ კლასტერიზაციის პროცედურას.

5. მოცემული $\{X_1, X_2, \dots, X_6\}$ ერთობლიობა გადავანაწილოთ ახალი $C_1^{(2)}$ და $C_2^{(2)}$ ცენტრების მიმართ, მივიღებთ:

$$W_1^{(2)} = \{X_4, X_5, X_6\}, \quad W_2^{(2)} = \{X_1, X_2, X_3\}$$

6. განვსაზღვროთ მიღებული $W_1^{(2)}, W_2^{(2)}$ კლასტერების ცენტრები:

$$C_1^{(3)} = \frac{1}{5} \left(\begin{matrix} X_{41} + X_{51} + X_{61} \\ X_{42} + X_{52} + X_{62} \end{matrix} \right) = \frac{1}{5} \left(\begin{matrix} 4+5+5 \\ 4+5+3 \end{matrix} \right) = \frac{14/3}{4}$$

$$C_2^{(3)} = \frac{1}{5} \left(\begin{matrix} X_{11} + X_{21} + X_{31} \\ X_{12} + X_{22} + X_{32} \end{matrix} \right) = \frac{1}{5} \left(\begin{matrix} 1+0+2 \\ 1+0+0 \end{matrix} \right) = \frac{1}{1/3}$$

7. შევამოწმოთ ცენტრების ტოლობის პირობა: $C_1^{(3)} \neq C_1^{(2)}$ და $C_2^{(3)} \neq C_2^{(1)}$ ვაგრძელებთ ალგორითმის შესრულებას.

8. უახლოესი მეზობლის პრინციპით $\{X_1, X_2, \dots, X_6\}$ ერთობლიობა დავაჯგუფოთ $C_1^{(3)}$ და $C_2^{(3)}$ ცენტრების მიმართ, ვდებულობთ:

$$W_1^{(3)} = \{X_4, X_5, X_6\}, \quad W_2^{(3)} = \{X_1, X_2, X_3\}$$

9. კვლავ განვსაზრებოთ კლასტერების ცენტრები $C_1^{(4)}$ და $C_2^{(4)}$, რომლებიც დაემთხვევიან წინა ბიჯზე განსაზღვრულ ცენტრებს: $C_1^{(4)} = C_1^{(3)}$ და $C_2^{(4)} = C_2^{(3)}$. ამით ალგორითმი დასრულდა და საბოლაოდ მივიღეთ ორი კლასტერი:

$$W_1 = \{X_4, X_5, X_6\}, \quad W_2 = \{X_1, X_2, X_3\}$$

K შიგაჯგუფური მეთოდის მუშაობის ხარისხი ბევრად არის დამოკიდებული საწყისი ცენტრების შერჩევაზე, რეალიზაციების თანმიმდევრულ განლაგებაზე და რასაკვირველია თვით რეალიზაციების გეომეტრიულ თავისებურებებზე. კერძოდ, ეს

მეთოდი კარგად მუშაობს, როცა კლასტერები გეომეტრიულად ერთმანეთისაგან დაშორებული არიან ანუ N განზომილებიან სივრცეში არ გადაკვეთავენ ერთმანეთს.

თუ აპრიორულად ცნობილი არ არის კლასტერების რაოდენობა, მაშინ ამ მეთოდის გამოყენება მოითხოვს ექსპერიმენტების ჩატარებას კლასტერების რაოდენობის დასადგენად.

2.6. ალგორითმი ISODATA

K – შიგაჯგუფური საშუალოს მეთოდი დაედო საფუძვლად კლასტერიზაციის ერთ-ერთ უძლიერეს მეთოდს *ISODATA* (*Iterative Self-Organizing Data Analysis Techniques – ანალიზის იტერაციული თვითორგანიზებადი მეთოდი*). K – შიგაჯგუფური საშუალოს მეთოდისაგან განსხვავებით ალგორითმი *ISODATA* შეიცავს მრავალ ევრისტიკულ პროცედურას.

პირველ ბიჯზე ხდება რამდენიმე საწყისი პარამეტრის წინასწარი განსაზღვრა. ესენია:

- ა) კლასტერების საჭირო რაოდენობა q_1 ;
- ბ) კლასტერში გაერთიანებული რეალიზაციათა ზღურბლური რაოდენობა q_2 ;
- გ) კლასტერის საშუალო კვადრატული გადახრის მნიშვნელობა q_3 ;
- დ) ქვეკლასტერების ცენტრების ის მაქსიმალური რაოდენობა, რომელთა გაერთიანება დასაშვების q_4 ;
- ე) კლასტერის კომპაქტურობის დამახასიათებელი პარამეტრი q_5 ;
- ვ) იტერაციულ ალგორითმში დასაშვებ ციკლთა რაოდენობა q_6 .

ISODATA ალგორითმში არსებობს სულ 14 ბიჯი, სადაც ზემოთ ჩამოთვლილი პარამეტრების მიხედვით ხდება კლასტერების დაყოფა ან გაერთიანება ისე, რომ მიღებული კლასტერების რაოდენობა q სიდიდის ტოლი იყოს. ამასთან არ უნდა მოხდეს იმაზე მეტი კლასტერის გაერთიანება, სადაც დასაშვებ q_2 სიდიდეს აღემატებოდეს. იტერაციის რაოდენობა არ უნდა აღემატოს q_6 სიდიდეს. კლასტერიზაციის პროცესის შედეგების შეფასება ხდება q_5 პარამეტრის მიხედვით და ა. შ.

ISODATA ალგორითმი რთულია და არათვალსაჩინო. ამის გარდა, მისი პროგრამული რეალიზირება მოითხოვს უმაღლესი დონის პროგრამირების პროცედურებს. საწყისი პარამეტრების განსაზღვრა მოითხოვს დასაჯგუფებელ მონაცემებზე წინასწარი ექსპერიმენტების ჩატარებას და კლასტერიზაციის პროცესში კი ხდება მათი კორექტორება.

2.7 ალგორითმი FOREL

ალგორითმი *FOREL* (*Formal efement*) – ში ისევე, როგორც K – შიგაჯგუფური საშუალოს ალგორითმში, გამოითვლება კლასტერების სიმბიმის ცენტრები. მაგრამ K – საშუალოს მეთოდთან შედარებით აქ კლასტერად განიხილება არა ცენტრთან არსებული უახლოესი მეზობლის პრინციპით შერჩეული რეალიზაციები, არამედ უკელა ის რეალიზაცია რომლებიც იმყოფებიან R რადიუსის მქონე სფეროში. ალგორითმი შედგება შემდეგი ბიჯებისაგან. წინასწარ შეირჩევა სფეროს რადიუსი R .

1. აიგება R რადიუსის სფერო, რომლის $C^{(1)}$ ცენტრად შეირჩევა ნებისმიერი რეალიზაცია, მაგალითად X_1 . ე.ი $C^{(1)}=X_1$
2. განისაზღვრებიან ის რეალიზაციები $X_i^{(1)}$, $i=1,2,\dots$, რომლებიც აქმაყოფილებენ $|X_i^1 - C_i^1| < R$ პირობას, ანუ ეს რეალიზაციები მოხვდებიან სფეროში.
3. განისაზღვრება შერჩეული (სფეროში მოხვდერილი) $X_i^{(1)}$ რეალიზაციების სიმძიმის ცენტრი $C^{(2)}$
4. აიგება R რადიუსის სფერო $C^{(2)}$ ცენტრით და განისაზღვრებიან ის რეალიზაციები $X_i^{(2)}$, $i = 1,2,\dots$ რომლებიც აქმაყოფილებენ $|X_i^{(2)} - C_i^{(2)}| < R$ უტოლობას.
5. განისაზღვრება $X_i^{(2)}$ რეალიზაციების სიმძიმის ცენტრი $C^{(3)}$ და ა.შ. ცენტრების შექმნის პროცესი სრულდება მაშინ, როცა შესრულდება შემდეგი უტოლობა: $|C^{(k+1)} - C^{(k)}| < \Delta$, სადაც Δ წინასწარ მოცემული სიდიდეა. სფერო $C^{(k+1)}$ ცენტრით წარმოადგენს W_1 კლასტერს.
6. ის რეალიზაციები, რომლებიც მოხვდენ ენ W_1 კლასტერში ამონარჩევიდან გამოირიცხებიან და დარჩენილ რეალიზაციებისათვის ტარდება ზემოთ მოყვანილი პროცედურა, დაწყებული პირველი ბიჯიდან.
7. ალგორითმის დამთავრების შემდეგ ვდებულობთ W_1, W_2, \dots თანმიმდევრობას, რომლებიც წარმოადგენენ R რადიუსის მქონე კლასტერებს.

2.8 კლასტერიზაცია კორელაციური კავშირის საშუალებით

2.8.1 კორელაციის კოეფიციენტი და სიახლოვის ზომა

კლასტერიზაციის ამოცანის გადასაწყვეტად ხშირად გამოიყენება კორელაციური ანალიზი. როგორც ვიცით, პარამეტრები შეიძლება ერთმანეთის მიმართ იყვნენ ან არ იყვნენ კორელაციურ დამოკიდებულებაში, რომლის მაჩვენებელს წარმოადგენს კორელაციის კოეფიციენტი r . ორ X და Y ცვლადს შორის კორელაციური (სტატისტიკური) კავშირი შეიძლება იყოს ძლიერი ან სუსტი. რაც უფრო ძლიერია კავშირი, მით უფრო დიდია კორელაციის კოეფიციენტი და როცა $r_{xy} = \pm 1$, მაშინ კავშირი გადადის ფუნქციონალურში.

სახეობა გარჩევის თეორიაში მსგავსების ზომად, მანძილის ფუნქციის გარდა, ფართოდ გამოიყენება ორ ვექტორს შორის კუთხის კოსინუსი. თუ მოცემულია ორი X და Y ვექტორი კომპონენტებით x_1, x_2, \dots, x_n და y_1, y_2, \dots, y_n , მაშინ ამ ვექტორებს შორის კუთხის კოსინუსი ტოლია:

$$\cos(X, Y) = \cos q = \frac{\sum_{i=1}^n X_i Y_i}{\sqrt{\sum_{i=1}^n X_i^2} \cdot \sqrt{\sum_{i=1}^n Y_i^2}}.$$

თუ გავიხსენებთ პირსონის კორელაციის კოეფიციენტის გამოსათვლელ ფორმულას და თუ ჩავთვლით, რომ მონაცემები ცენტრირებულია, მაშინ მივიღებთ:

$$z_{xy} = \frac{\sum_{i=1}^n \hat{X}_i \hat{Y}_i}{\sqrt{\sum_{i=1}^n X_i^2} \cdot \sqrt{\sum_{i=1}^n Y_i^2}}, \text{ სადაც } \hat{X}_i = X_i - \bar{X}, \quad \hat{Y}_i = Y_i - \bar{Y}$$

ე.ი. $\cos q = r_{xy}$ რაც იმას ნიშნავს, რომ კორელაციის კოეფიციენტი განსაზღვრავს ვექტორებს შორის კავშირის ზომას. როცა ვექტორები ერთმანეთს ემთხვევა, ე.ი პუთხე მათ შორის ნულის ტოლია და $\cos q = 1$ (შესაბამისად $r_{xy}=1$), მაშინ ცვლადებს შორის ფუნქციონალური კავშირი შეიმჩნევა. პუთხის ზრდასთან ერთად ეს კავშირი მცირდება და როცა $q = \frac{\pi}{2}$, მაშინ $\cos q = 0$ (შესაბამისად $r_{xy}=0$) და კავშირი ორ ცვლადს შორის არ არსებობს. კუთხის შემდგომი ზრდა იწვევს კავშირის ზრდასაც და როცა იგი მიაღწევს ჩ სიდიდეს, მაშინ ვექტორებს შორის კავშირი ძლიერია, თუმცა იგი უარყოფითია ($r_{xy}=1$).

ამრიგად, კლასტერიზაციის ამოცანის გადასაწყვეტად გარდა მანძილის და მსგავსების ზომისა შესაძლებელია კორელაციის კოეფიციენტის გამოყენება, როგორც სიახლოვის ზომა ორ რეალიზაციას შორის. უნდა გვახსოვდეს, რომ კორელაციის კოეფიციენტების პირდაპირი გამოყენება მიზანშეუწონელია, რადგან დადებითი და უარყოფითი კორელაციის კოეფიციენტები ადგენერ სხვადასხვა კლასტერებს. ეს რომ თავიდან ავიცილოთ ამისათვის საჭიროა ავილოთ კორელაციის კოეფიციენტის მოდული.

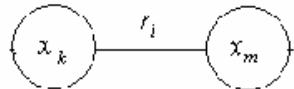
2.8.2 კორელაციური პლეადის მეთოდი

კორელაციული პლეადის მეთოდით მარტივად შეგვიძლია გადავწევიტო კლასტერიზაციის ამოცანა. მეთოდის არსი შემდგები მდგომარეობს. მოცემული R კორელაციური მატრიცის საშუალებით ადგენერ რეალიზაციათა ურთიერთობის გრაფს, რომელიც შემდგომში გარკვეული კრიტერიუმის გამოყენებით ყოფენ ერთგვაროვან ქვეგრაფებდ ანუ „პლეადებად“.

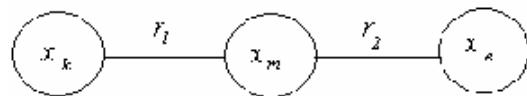
განვიხილოთ $\{X\}$ ერთობლიობის $X_i, i=1,2,\dots,N$ რეალიზაციათა კორელაციური მატრიცა R , რომლის ელემენტებია პირსონის კორელაციის კოეფიციენტები. დავხაზოთ N რაოდენობის რგოლები, რომლებმიც ჩავწეროთ რეალიზაციის ნომერი. შევაერთოთ თოთოეული რგოლი სხვებთან და შეერთების ხაზებზე დავწეროთ შესაბამისი კოლერაციის კოეფიციენტის მნიშვნელობები. ყველა შეერთების შემდეგ მივიღებთ საწყის გრაფს. გარკვეული მოსაზრებიდან გამომდინარე, შემოვილოთ კორელაციის კოეფიციენტის ზღურბლური მნიშვნელობა $r_0^{(1)}$ და ის შეერთების ხაზები გამოვრიცხოთ, რომლის მნიშვნელობები ნაკლებია $r_0^{(1)}$ მნიშვნელობაზე. შემდეგ გავზარდოთ ზღურბლის მნიშვნელობა $r_0^{(2)}$ -მდე და საწყისი გრაფიდან გამოვრიცხოთ ის შეერთების ხაზები, რომელთა კორელაციის კოეფიციენტების მნიშვნელობები ნაკლებია $r_0^{(2)}$. ეს პროცედურა გავაგრძელოთ სასრული მნიშვნელობის ზღურბლამდე. შემდეგ მივიღებთ ქვეგრაფებს, რომლებიც იზოლირებული არიან ერთმანეთის მიმართ ე.ი მოვახდინეთ კლასტერების გამოყოფა. აღწერილი პროცედურა მოუხერხებელია, რადგან საჭირო ხდება დიდი რაოდენობის $N(N-1)$ კავშირების დათვალიერება.

უფრო მარტივი და ეფექტური პროცედურაა შემდეგი. კორელაციურ მატრიცაში იძებნება აბსოლუტურად ყველაზე დიდი მნიშვნელობის კორელაციის კოეფიციენტი

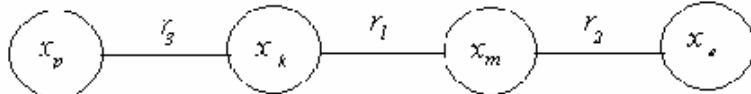
(დიაგონალური მნიშვნელობები არ ითვლებიან) დაუშვათ ესაა $r(X_K X_m) = r_1$, რომელიც მიღებულია X_K და X_m რეალიზაციებისაგან. იხაზება ორი წრე, რომლებშიც იწერება X_K და X_m სიმბოლოები და მათ შემაერთებელ სწორ ხაზზე იწერება r_1 კორელაციის კოეფიციენტის მნიშვნელობა.



შემდეგ ბიჯზე მოიძებნება X_K და X_M -ის დანარჩენ პარამეტრებთან (რეალიზაციებთან) უდიდესი კორელაციის კოეფიციენტები და ამ თრიდან ამოირჩევა უდიდესი, ვთქვათ ესაა $r(X_m, X_e) = r_2$, მაშინ ეს უკანასკნელი დაემატება გრაფს და ვღებულობთ:



მესამე ბიჯზე იძებნება X_k და X_e პარამეტრებთან დარჩენილი პარამეტრების უდიდესი კოლერაციის კოეფიციენტები და აიღება უდიდესი მნიშვნელობა. ვთქვათ ესაა $r(X_k, X_p) = r_3$, მაშინ მივიღებთ:



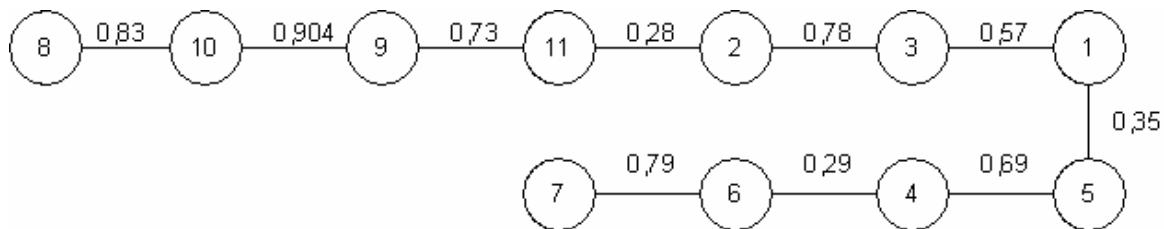
და ა. შ. სანამ ყველა ცვლადები არ მოხვდებიან თანმიმდევრულ გრაფში. თუ შემოვიდებთ ზღურბლის მნიშვნელობას r_0 და იმ შეერთების ხაზებს გამოვრიცხავთ რომლის მნიშვნელობები ნაკლებია ზღურბლის მნიშვნელობაზე, მაშინ მიღებული გრაფი დაიყოფა ქვეგრაფებად ანუ მივიღებთ ერთგაროვან ჯგუფებს.

საზოგადოდ, ზღურბლის მნიშვნელობა ($0 < r_0 < 1$) შეგვიძლია შევარჩიოთ რაიმე კონკრეტული მოსაზრებიდან გამომდინარე ან უმჯობესია იგი დავადგინოთ $H_0: r(X_i, X_j) = 0$ ნულოვანი პიპოტეზის შემოწმების საშუალებით. კერძოდ, უნდა მოვძებნოთ კორელაციის კოეფიციენტის ის მნიშვნელობა, რომლის დროსაც მიიღება ნულოვანი პიპოტეზა და ეს მნიშვნელობა ავიდოთ r_0 ტოლად.

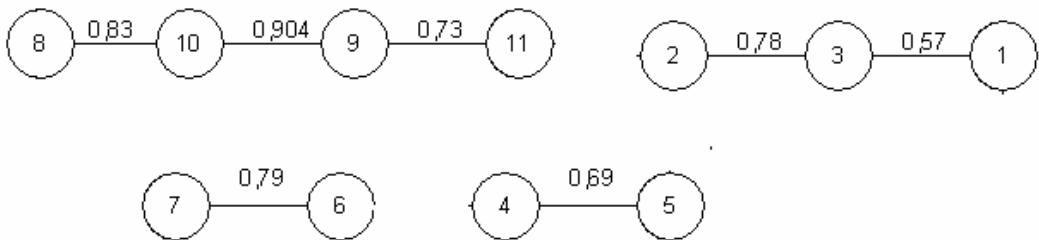
განვიხილოთ მაგალითი. ვთქვათ მოცემულია შემდეგი კორელაციური მატრიცა:

1	0,56	0,57	0,15	0,35	0,25	0,26	0,02	-0,21	-0,09	-0,08
1		0,78	0,06	0,20	0,22	0,01	-0,02	-0,002	0,61	0,28
1			0,29	0,48	0,28	0,07	0,14	0,11	0,23	0,15
1				0,69	0,29	0,03	0,05	0,07	0,06	0,18
1					0,43	0,07	0,15	0,04	0,03	0,22
1						0,79	0,20	0,15	0,11	0,04
1							0,11	0,05	0,02	0,02
1								0,81	0,83	0,70
1									0,904	0,73
1										0,77
										1

კორელაციური მატრიციდან ყველაზე დიდი კორელაციის კოეფიციენტი 0,904 გააჩნია მე-9 და მე-10 პარამეტრებს. ზემოთ მოყვანილი პროცედურის შემდეგ მივიღებთ:



თუ ზღურბლის მნიშვნლობას ავიღებთ $r_0 = 0,4$ ტოლად, მაშინ მივიღებთ ოთხ „პლეადას“:



ე.ი მივიღეთ ოთხი ერთგვაროვანი ჯგუფი.

კორელაციური პლეადის მეთოდის გამოყენება მიზანშეწონილია იმ შემთხვევაში, როცა გასაანალიზირებულ პარამეტრებს შორის არსებობს სარწმუნო კორელაციური კავშირები. იმ შემთხვევაში, როცა კორელაციის კოეფიციენტებს აქვს მცირე აბსოლუტური მნიშვნელობა ე.ი კავშირი არაა სარწმუნო, დაჯგუფების ამოცანის გადაწყვეტა ძნელდება, რადგან r_0 ზღურბლის მნიშვნელობის დადგენა რთულია.

2.9 კლასტერიზაციის პროცესის შეფასების ზოგიერთი საკითხები

კლასტერიზაციის ნებისმიერი მეთოდის სირთულე იმაში მდგომარეობს, რომ ჩვენ არ გვაქვს საშუალება ვიზუალურად წარმოვადგინოთ მიღებული შედეგების გეომეტრიული თავისებურებანი. განხილული მაგალითები შეეხება მხოლოდ ორგანზომილებიან სისტემებს, სადაც გეომეტრიულად ადვილად შეიძლება წარმოვადგინოთ კლასტერიზაციის შედეგი. რეალურ ბიოსამედიცინო კვლევებში ჩვენ საქმე გვაქვს ზოგჯერ ასობით მაჩვენებელთან, რაც საკმაოდ ართულებს შედეგების ინტერპეტაციას. ამ პრობლემის გადასაწყვეტად საჭიროა გამოვიყენოთ დამატებითი ინფორმაცია, რომლიც საშუალებას მოგვცემს შევაფასოთ მიღებული კლასტერების გეომეტრიული სტრუქტურა.

შედეგების ინტერპრეტაციისთვის მიზანშეწონილია გამოვიყენოთ კლასტერების ცენტრებს შორის მანძილი. ასეთი ინფორმაცია უმჯობესია წარმოვადგინოთ ცხრილის სახით. დაუშვათ კლასტერიზაციის შედეგად მიღებულია ხუთი ჯგუფი და ვთქვათ ამ ჯგუფების ცენტრებს შორის მანძილების მატრიცას აქვს შემდეგი სახე:

კლასტერების ცენტრები	z_1	z_2	z_3	z_4	z_5
z_1	0,0	4,8	14,7	2,1	50,6
z_2		0,0	21,1	6,1	48,3
z_3			0,0	15,0	36,7
z_4				0,0	49,3
z_5					0,0

როგორც ცხრილიდან ჩანს, მნიშვნელოვანია ის, რომ კლასტერის ცენტრი Z_5 მნიშვნელოვნად არის დაშორებული დანარჩენი ოთხი კლასტერის ცენტრებიდან. გარდა ამისა, მანძილი Z_1 და Z_2 კლასტერების ცენტრებს შორის, ისევე როგორც Z_1 და Z_4 კლასტერების ცენტრებს შორის, შედარებით ერთნაირია. თუ ცნობილია, რომ Z_5 ცენტრის მქონე კლასტერი შედეგება ერთი ან ორი ობიექტისაგან, მაშინ გარკვეული გამოკვლევების შედეგად შეიძლება მივიღოთ გადაწყვეტილება, რომ მასში მოხვედრილი ობიექტები წარმოადგენენ არტეფაქტებს და შეიძლება მათი გამორიცხვა ანალიზიდან. მეორეს მხრივ, თუ კლასტერში აღმოჩნდება საკმაო რაოდენობის ობიექტები, მაშინ შეგვიძლია ჩავთვალოთ, რომ მიღებული ჯგუფი რეალურია და იგი ნამდვილად აერთიანებს ერთგვაროვან ობიექტებს.

ცხრილში მოყვანილი ინფორმაცია შეიძლება გამოვიყენოთ ჯგუფების გაერთიანებისათვისაც. მაგალითად, თუ კლასტერების ცენტრები საკმაოდ ახლოს არიან ერთმანეთთან, მაშინ მათი გაერთიანება ერთ ჯგუფში შესაძლებელია.

ცენტრებს შორის მანძილების შემდეგ, მეორე მნიშვნელოვან ინფორმაციას წარმოადგენს კლასტერის ცენტრის მიმართ რეალიზაციების გაფანტვის მაჩვენებელი, რომლებიც გვაძლევენ საშუალებას ობიექტების შიგაჯგუფურ განლაგებაზე წარმოდგენას. დაუშვათ გვაქვს ხუთი კლასტერი, რომლებიც წარმოდგენილნი არიან ოთხი ობიექტით და ვთქვათ დისპერსიების ცხრილს აქვს შემდეგი სახე:

კლასტერები	დასპერსაცია			
	σ_1	σ_2	σ_3	σ_4
ω₁	1,2	0,9	0,7	1,0
ω₂	2,0	1,3	1,5	0,9
ω₃	3,7	4,8	7,3	10,4
ω₄	0,3	0,8	0,7	1,1
ω₅	4,2	5,4	18,3	3,3

როგორც ცხრილიდან ჩანს, W_1 კლასტერს გააჩნია დაახლოებით ჰიპერსფეროს ფორმა, რადგან დისპერსიები ოთხივე დერძის მიმართ თითქმის ერთნაირია (1,2; 0,9; 0,7; 1,0). რაც შეეხება W_5 კლასტერს, მისი ფორმა წაგრძელებულია მე-3 დერძის მიმართ, ამიტომ ის უფრო შეესაბამება ჰიპერელიფსიდს. ანალოგიურად შეგვიძლია გავაანალიზოთ სხვა კლასტერებიც.

ამრიგად, ინფორმაციები, რომლებიც ზემოთაა მოყვანილი და აგრეთვე დამატებითი მონაცემები კლასტერებში მოხვედრილი ობიექტების რაოდენობა საშუალებას გაძლევს გავაანალიზოთ თითოეული ჯგუფის სტრუქტურა და მისი გეომეტრიული განლაგება სივრცეში.

რასაკვირველია არსებობენ კლასტერების სხვა რაოდენობრივი მახასიათებლები, რომლებიც მეტ-ნაკლებობით გამოიყენებიან ჯგუფების დასახასიათებლად. მაგალითად სასარგებლოა ვიცოდეთ კლასტერში ცენტრიდან უველაზე ახლო და უველაზე დაშორებულ ობიექტების შესახებ. კლასტერის ცენტრის მიმართ საშუალო კვადრატული მანძილები და სხვა. ცხადია, რომ უველა ეს დამატებითი ინფორმაცია შესაძლებელია გამოყენებულ იქნას ავტომატური კლასტერიზაციის შედეგად მიღებული შედეგების დასახასიათებლად.

III იდენტიფიკაციის მეთოდები

3.1 იდენტიფიკაციის ამოცანის ჩამოყალიბება

როგორვ ვიცით, სახეთა გარჩევის სისტემის ძირითადი დანიშნულებაა ობიექტთა მიკუთვნება როგორიმე მოცემულ კლასს, რომელსაც გარჩევის ანუ იდენტიფიკაციის ამოცანა ეწოდება. გარჩევის პროცესის მაღალსაიმედო განხორციელებისათვის აუცილებელია შემდეგი ორი პრობლემის ეფექტური გადაწყვეტა. ესენია: სახეთა აღწერის ანუ ეტალონის აგება და გადაწყვეტილებათა მიღების წესის ფორმირება. ეს ორი პრობლემა საკმაოდ მჭიდრო კავშირშია ერთმანეთთან. კერძოდ, აგებული კლასის ეტალონების სახე თუ მახასიათლები ძალიან ხშირად განსაზღვრავენ გადაწყვეტილებათა მიღების წესს და პირიქით.

სახის აღწერა ანუ ეტალონი, როგორც გარკვეული ტიპის ობიექტების ამსახველი მოდული, უნდა აკმაყოფილებდეს შემდეგ პირობებს:

- აღეკვატურად აღწეროს მოცემული სახე;
- განსხვავდებოდეს სხვა სახის აღწერისაგან;
- იყოს კონსტრუქციული (გამოყენებადი).

გადაწყვეტილების მიღების პროცესი შედგება შედარებისა და შედარებით მიღებული ალტერნატივებიდან (შედეგებიდან) ერთ-ერთის არჩევის პროცედურისაგან. შედარების პროცედურის განსახორციელებლად აუცილებელია მსგავსების რაიმე ზომის არსებობა.

სახეთა გარჩევის სისტემებში სახეთა აღწერის და გადაწყვეტილებათა მიღების წესების ფორმირებისას ფართოდ გამოიყენება სწავლების პროცედურები. სახეთა აღწერა ცოცხალ ორგანიზმში ფორმირდება ბუნებრივად, ხოლო ტექნიკურ სისტემისათვის აუცილებელია აპრიორულად არსებული სწავლების ალგორითმები და მათი განხორციელების საშუალებები.

არსებობს სწავლების ორგარი ფორმა: სწავლება მასწავლებლით და მასწავლებლის გარეშე. სწავლება მასწავლებლით გულისხმობს ისეთი სუბიექტის არსებობას, რომლისთვისაც ცნობილია სახეები და შეუძლია ნებისმიერი რეალიზაცია უშეცდომოდ მიაკუთვნოს მოცემულ სახეთა ერთობლიობიდან ერთ-ერთს. ასეთი მასწავლებლის ფუნქციებს უმაღლესი ინტელექტის მქონე არსებების სიცოცხლის საწყის პერიოდში ასრულებენ მშობლები, შემდეგ კი პროფესიონალი მასწავლებლები. ტექნიკური სისტებებისათვის იგივე ფუნქციას ასრულებენ მკლევარ-ექსპერიმენტატორები.

ბუნებრივ სისტემისაგან განსხვავებით, ხელოვნური სისტემების სწავლებისათვის აუცილებელია რეალიზაციათა მახასიათებლების - ნიშნების (პარამეტრების) წინასწარ ზუსტად განსაზღვრა და ნიშანთა სიმრავლის (სივრცის) ფორმირება, რადგან ამის გარეშე შეუძლებელია სასწავლო ალგორითმის ფორმირება.

სწავლების გარკვეული ეტაპის გავლის შემდეგ ბუნებრივ სისტემებს გამოუმუშავდებათ თვითსწავლების ანუ მასწავლებლის გარეშე სწავლების პროცესის უნარი, რაც ხელოვნურ სისტემებისათვის უაღრესად პრობლემატურია. კერძოდ, თვით სწავლების (ადაპტაციის) პროცესი შესაძლებელია მხოლოდ უმარტივესი ობიექტებისა და პროცესებისათვის.

სწავლების პროცესები პირობითად შეიძლება დავყოთ ორ ეტაპად. პირველ ეტაპს მიეკუთვნება ინფორმაციის მოპოვება და დამახსოვრება, ხოლო მეორე ეტაპს - ინფორმაციის გადამუშავება. თუ სწავლება ხორციელდება მასწავლებლით, მაშინ ინფორმაციის მოპოვება და წარმოდგენა არის მასწავლებლის მოვალეობა. ინფორმაციის დამახსოვრება და შემდეგ გადამუშავება ტექნიკურ სისტემაში მოცემული უნდა იყოს ალგორითმის სახით.

ტექნიკურ სისტემებში სწავლების პროცესის განხორციელებისათვის ხშირად გამოიყენება იტერაციული პროცედურები შესაბამისი ფუნქციებით. ამ შემთხვევებისათვის არსებობს სხვადასხვა მათემატიკური მეთოდები, მაგალითად კარგად დამუშავებული ოპტიმიზაციის მეთოდები, რომლებიც გამოიყენებიან სწავლების როგორც დეტერმინირებული, ასევე სტოქასტიკური (შემთხვევითი) პროცესების კვლევისათვის. აქ იტერაციის ყოველ ბიჯზე ხდება მიზნობრივი ფუნქციის გამოთვლა და შედეგების შედარება წინა ბიჯზე გამოთვლილი მიზნობრივი ფუნქციის მაჩვენებელთან.

3.2 ეტალონის აბება

როგორც უკვე ავღნიშნეთ, სახეთა გარჩევის ამოცანის გადასაწყვეტად აუცილებელია მოცემული კლასების ეტალონების აგება. არსებობს ეტალონების აგების სტატისტიკური და დეტერმინირებული მეთოდები. განვიხილოთ ზოგიერთი მათგანი.

სტატისტიკური ეტალონის აგება. დაუშვათ მოცემულია $\{X\}$ სიმრავლე, რომელიც შედგება $X_i, i = 1, 2, \dots, N$ რეალიზაციებისაგან. რადგან თითოეული რეალიზაცია ფორმირდება N რაოდენობის ნიშნებისაგან, ამიტომ გვაქვს N განზომილებიანი გექტორი x_1, x_2, \dots, x_n კოორდინანტებით. განვიხილოთ ორი შემთხვევა:

ა) როცა x_1, x_2, \dots, x_n რაოდენობრივი მაჩვენებლებია. დაუშვათ, ცნობილია თითოეული რეალიზაციის, რომლებიც ნორმალურად არიან განაწილებულები, განაწილების სიმკვრივის ფუნქცია

$$f(x_n) = \frac{1}{\sqrt{2\pi} s_i} \exp\left\{-\frac{1}{2}\left(\frac{x_n - m_i}{s_i}\right)^2\right\}, \quad (1)$$

სადაც s_i საშუალო კვადრატული გადახრაა, m_i – მათემატიკური ლოდინი. ამ სიდიდეების გამოთვლა შესაძლებელია სასწავლო რეალიზაციების გამოყენებით:

$$\bar{m}_{in} = \frac{1}{m_i} \sum_m x_{n,m}; \quad s_i^2 = \frac{1}{m_i} \sum_m (x_{n,m} - \bar{m}_{in})^2,$$

სადაც m_{in} არის W_i სახის x_n ნიშნის მათემატიკური ლოდინის შეფასება; m_i – რეალიზაციათა რაოდენობაა W_i სახის სასწავლო ამონარჩევში, $x_{n,m}$ არის W_i სახის m -ური რეალიზაციის n -ური ნიშანი, s_i^2 -დისპერსიის შეფასებაა. შეფასებები მით უფრო ზუსტია, რაც მეტია რეალიზაციათა რაოდენობა თითოეული სახის სასწავლო ამონარჩევში.

თუ სახეთა ნიშნები ურთიერთდამოკიდებულია, მაშინ (1) გამოსახულების გამოყენება მოცემული სახით არ შეიძლება. საჭიროა ერთობლივი განაწილების სიმკვრივის ფუნქციების გამოთვლა, რაც მოითხოვს რეალიზაციების დიდ რაოდენობას. ასეთი რაოდენობის რეალიზაციათა ამონარჩევების ფორმირება ყოველთვის არ არის შესაძლებელი. გარდა ამისა, ეტალონის მიღება დაკავშირებულია გამოთვლების მოცულობისა და დროის გაზრდასთან. ამ მიზეზების გამო, მრავალგანზომილებიანი დამოკიდებულ ნიშანთა სიმრავლეები გარჩევის სისტემებში პრაქტიკულად არ გამოიყენებიან.

ბ) როცა x_1, x_2, \dots, x_n ბინარული $(0,1)$ მნიშვნელობებია. ასეთ რეალიზაციებს ბინარული რეალიზაციები ეწოდებათ და მათი გამოყენება გარჩევის სისტემებში გაცილებით უფრო მოსახერხებელია გამოთვლების სისტრაფისა და მოცულობის თვალსაზრისით, ვიდრე მთელ ან ნამდვილრიცხვებიანი ნიშანთა სიმრავლეებისაგან შემდგარი რეალიზაციებისა.

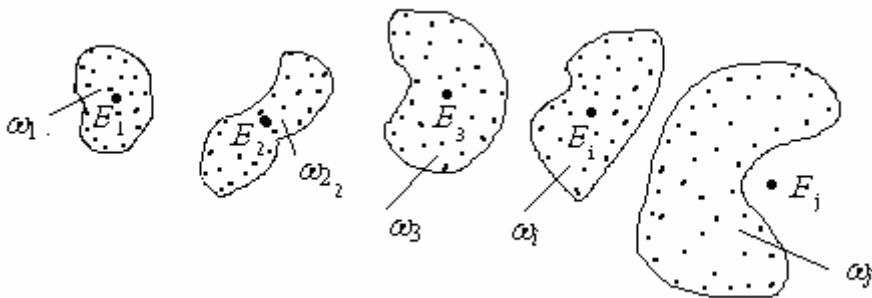
თანაბარგანზომილებიანი ბინარული რეალიზაციებისათვის დასაშვებია ე.წ. სუპერპოზიციის ანუ ზედგების პრინციპი, რაც გულისხმობს თითოეული სახის სასწავლო რეალიზაციისათვის ერთი და იმავე ნიშნის მქონე ობიექტების ზედგებას. ამ გზით მივიღებთ $W(x)$ მატრიცას, რომლის ყოველი ელემენტი აკმაყოფილებს შემდგა პირობას: $0 \leq W(x) \leq 1$. ნიშნის ნულოვანი მნიშვნელობა გვაქვს მაშინ, როდესაც შესაბამის უჯრედში მოცემული სიმბოლოს არც ერთი ელემენტი მოცემული სახის რეალიზაციათა სასწავლო ამონარჩევისათვის არც ერთხელ არ განხორციელდა. ერთის ტოლი მნიშვნელობა გვაქვს მაშინ, როდესაც ერთი სახის გამოსახულების რომელიმე ელემენტი ყოველთვის არის მოთავსებული მოცემულ უჯრედში.

ზედგების პრინციპით მიღებული სტატისტიკური ეტალონი $W(x)$, რომელსაც შეიძლება ჰქონდეს როგორც მატრიცის, ასევე ვექტორის ფორმა, აკმაყოფილებს ეტალონებისადმი წაყენებულ ადეკვატურობის პირობას. ხვადასხვა სახის

სტატისტიკური ეტალონები განსხვავდებიან ერთმანეთისაგან, თუ შესრულდება შემდეგი პირობა: სახეების ნებისმიერი რეალიზაცია განსხვავდებული უნდა იყოს სხვა სახეების რეალიზაციებისაგან. რეალიზაციათა სტაბილურობის უზრუნველყოფა დამოკიდებულია მრავალ ფაქტორზე: რეალიზაციათა განზომილებაზე, ნაბეჭდი შრიფტების ან ხელნაწერი სიმბოლოებისათვის შრიფტებისა და კალიგრაფიის თავისებურებებზე და სხვა.

ყოველი ახალი რეალიზაციის გამოჩენისას შესაძლებელია ზედდების პროცედურის გამოყენებით გადავიანგარიშოთ და შესაბამისად, უფრო დავაზუსტოთ სტატისტიკური ეტალონი.

დეტერმინირებული ეტალონების აგება. დაუშვათ, რომ $\{W_i\}$ სახეთა სიმრავლისათვის მოცემულია $\{X\}$ რეალიზაციათა სასწავლო ამონარჩევი. ამასთან ყოველი W_i სახისათვის გვაქვს რეალიზაციათა სასწავლო ნაკრების სიმრავლე. თოთოვეული რეალიზაცია N განზომილებისაა, ამიტომ ნიშანთა შესაბამის სივრცეში ყოველი რეალიზაცია შეგვიძლია წარმოვადგინოთ ერთი წერტილის სახით. თვალსაჩინეობისათვის დაუშვათ, რომ ნიშანთა რაოდენობა ორის ტოლია, მაშინ რეალიზაციათა არსებული განლაგება შეიძლება წარმოვადგინოთ სიბრტყეზე, მაგალითად, ისე როგორც ეს შემდეგ ნახაზზე წარმოდგენილი:



დეტერმინირებული ეტალონების მრავალი ტიპი არსებობს, რომელთაგან უმარტივესია ე.წ. პროტოტიპი, რომელიც სასწავლო ამონარჩევში მოცემული რეალიზაციების სიმძიმის ცენტრს წარმოადგენს. პროტოტიპის ეტალონური აღწერა ავდნიშნოთ E -ით. ცხადია, რომ მას გააჩნია იგივე განზომილება, რაც სახეთა რეალიზაციებს. E_i პროტოტიპის $\{e_{n_i}\}$ კოორდინანტები ყოველი W_i სახისათვის გამოითვლება შემდეგი გამოსახულებით:

$$e_{n_i} = \frac{1}{m} \sum_m x_{n_i} m , \quad n_i = 1, 2, \dots, N ,$$

სადაც e_{n_i} არის E_i ეტალონის n -ური კოორდინანტის მნიშვნელობა. როგორც ნახაზიდან ჩანს, კლასტერის რთული ფორმის შემთხვევაში (მაგ. W_j სახის კლასტერი), სიმძიმის ცენტრი გამოდის კლასტერის გარეთ და ამის გამო, ვერ შეასრულებს ეტალონის ფუნქციას ანუ იგი რეალურად არ წარმოადგენს მოცემული სახის პროტოტიპს. ასეთი სიტუაციების თავიდან ასაცილებლად მიმართავენ კლასტერების გადაფარვას ჰიპერსფეროებით. ამ დროს ერთ სახეს შეიძლება რამდენიმე პროტოტიპი ჰქონდეს.

თუ ჰიპერსფეროების გამოყენების შემთხვევაში საკმარისია მხოლოდ მისი ცენტრისა და რადიუსის დაფიქსირება, ჰიპერელიპსოიდების შემთხვევაში საჭირო ხდება

გაცილებით მეტი ინფორმაციის ცოდნა, კერძოდ ყოველ კლასტერზე იმდენი ნასევარდერძის სიგრძის განსაზღვრაა საჭირო რა განზომილებისაცაა ნიშანთა სივრცა, რაც კიდევ უფრო ართულებს გადაფარვის პრობლემას.

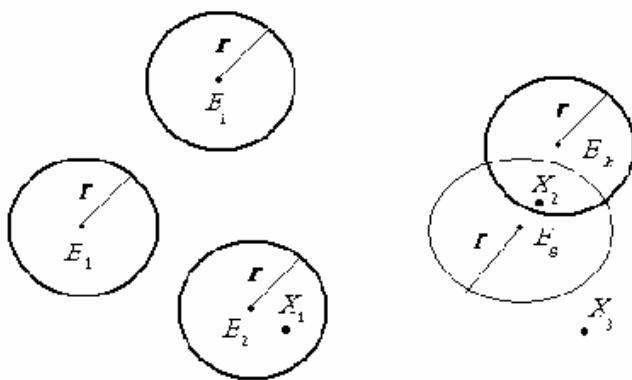
არსებობს ეტალონის აგების სხვა დეტერმინირებული მეთოდები, მაგალითად განაპირო წერტილების, რანგული კავშირების, მინი და მაქსი პორტრეტების და სხვა, რომლებიც მეტ-ნაკლებად გამოყენებადია პრაქტიკაში.

3.3 გადაწყვეტილების მიღების პროცედურის აღწერა

გადაწყვეტილების მიღება ფაქტიურად წარმოადგენს უშუალოდ გარჩევის პროცესს. ამ პროცესის პირველი ეტაპია შედარების პროცედურა, რის შედეგაც ვიდებთ ასარჩევ ალტერნატივათა სიმრავლეს. მეორე ეტაპზე ალტერნატივების სიმრავლიდან ვირჩევთ ერთს, რომლის მიხედვითაც ხდება წინასწარ შემუშავებული წესით (კრიტერიუმის) მიხედვით გადაწყვეტილების მიღება (დასკვნა). შედარების პროცედურის განხორციელებისათვის აუცილებელია სახეთა ეტალონური აღწერის, მსგავსების ზომის ფუნქციის და უცნობი რეალიზაციის არსებობა.

უცნობი რეალიზაცია X და ეტალონური აღწერა $\{E\}$ წარმოადგენებს მსგავსების ზომის ფუნქციის $j(X, \{E\})$ არგუმენტებს. ეტალონთა $\{E\}$ სიმრავლის ყოველი ელემენტისათვის $j(\bullet)$ ფუნქციის გამოთვლის შედეგად ვდებულობთ ერთ ალტერნატივას – სკალარს, რომელიც a სიმბოლოთი ავდნიშნოთ. ყველა ეტალონთან შედარების შედეგად ვდებულობთ ალტერნატივების სიმრავლეს $\{a\}$.

გადაწყვეტილების მიღებისათვის საჭიროა მსგავსების ზომის ზღურბლური მნიშვნელობის შერჩევა ევრისტიკულად ან ექსპერიმენტალურად. მსგავსების ზომის ზღურბლის გამოყენების თვალსაჩინო ინტერპრეტაცია გარჩევის პროცესში შეიძლება წარმოვადგინოთ სტატისტიკური ან სიმბიმის ცენტრებით (საშუალო არითმეტიკულებით) მოცემული ეტალონებისათვის ეპლიდეს მანძილების გამოყენებით, როგორც ეს ნაჩვენებია შემდეგ ნახაზზე:



ამ ნახაზზე ნაჩვენებია მსგავსების ზომის ზღურბლის (r) მნიშვნელობის ტოლი რადიუსით შემოსაზღვრული ჰიპერსფერები, რომელთა ცენტრები არიან ეტალონური აღწერები. თუ უცნობი რეალიზაცია მოხვდა რომელიმე (მაგალითად E_2 ცენტრის მქონე) ჰიპერსფეროს შიგნით, მაშინ სრულდება შემდეგი პირობა:

$$d(X_1, E_2) < r \quad (1)$$

თუ (1) პირობა სრულდება მხოლოდ ერთი ($\text{მაგ. } w_2$) სახისათვის, მაშინ X უცნობი რეალიზაცია ცალსახად მიეკუთვნება w_2 სახეს. თუ (1) გამოსახულებით მოცემული პირობა შესრულდა ერთზე მეტი სახისათვის ($\text{მაგალითად } X_2$ რეალიზაციისათვის E_j და E_k ეტალონების მიმართ), მაშინ გადაწყვეტილებას ვერ ვღებულობთ და უცნობი რეალიზაცია X გაიგზავნება გარჩევის მეორე საფეხურზე (თუ ასეთი არსებობს) მხოლოდ w_j და w_i სახეების მითითებით.

თუ (1) გამოსახულებით მოცემული პირობა სახეთა ანსაბლის არც ერთი წევრისათვის არ სრულდება ($\text{მაგალითად } X_3$ რეალიზაცია), მაშინ ცალსახად მიიღება გადაწყვეტილება იმის შესახებ, რომ უცნობი რეალიზაცია არ მიეკუთვნება მოცემულ სახეთა სიმრავლეს. იგივე დასკვნა შეიძლება გამოვიყენოთ მეორე შემთხვევის დროს ($\text{ნახაზ } X_2$ რეალიზაცია) თუკი არ არსებობს გარჩევის მეორე საფეხური.

გადაწყვეტილებათა მიღების მეთოდების რაოდენობა ძალიან დიდია და უაღრესად მრავალფეროვანი. მათი კლასიფიკაცია შესაძლებელია მრავალი ნიშან-თვისებების მიხედვით. მიზეზ-შედეგობრივი კავშირების მიხედვით შესაძლებელია გამოვიყენოთ გადაწყვეტილებათა მიღების ორი კლასი: ალბათური და დეტერმინირებული.

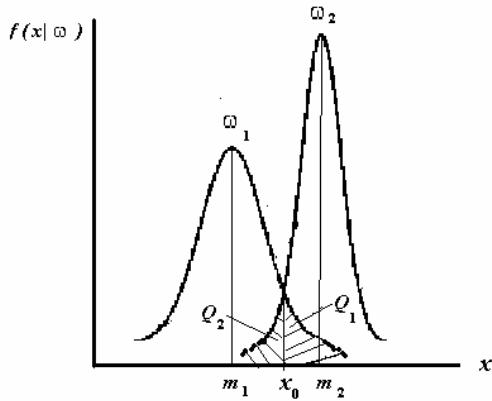
სახეთა გარჩევის თეორიის ფორმირების საწყის ეტაპზე გადაწყვეტილებათა მიღების ალბათური მეთოდები ყველაზე უფრო გავრცელებული იყო ამომცნობ სისტემებში. ალბათური მეთოდების გამოყენება გადაწყვეტილების მიღებისას აუცილებლად გულისხმობს რეალიზაციათა ყოველი სახისადმი განაწილების კანონების აპრიორულ დადგენას. ამასთან, თუ ნიშნები (პარამეტრები) დამოკიდებულია არიან, მაშინ საჭიროა განაწილებათა ერთობლივი კანონების დადგენა, რაც მოითხოვს სასწავლო ამონარჩევის რეალიზაციათა დიდ რაოდენობას, რომელთა მიღება ყოველთვის არ არის შესაძლებელი. ამ მიზეზების გამო, ალბათური მეთოდები ძირითადად გამოვიყენება სახეებისა და ნიშნების შეზღუდული რაოდენობის შემთხვევაში.

დეტერმინირებული გადაწყვეტილებათა მიმღები ფუნქციები კიდევ უფრო მრავალფეროვანია. მათ მიეკუთვნება წრფივი და არაწრფივი გადამწყვეტი ფუნქციები, პოგენციალთა ფუნქციების მეთოდი, პერსეპტონის მეთოდი და სხვა. განვიხილოთ ზოგიერთი მათგანი.

3.4 იდენტიფიკაციის ალბათური მეთოდები

4.4.1 ალბათური მეთოდის არსი

იდენტიფიკაციის ალბათური მეთოდის არსი განვიხილოთ უბრალო მაგალითზე, როდესაც მოცემულია ორი w_1 და w_2 სახე. სიმარტივისათვის მივიღოთ, რომ გვაქვს ერთი ნიშანი x , რომლითაც არის წარმოდგენილი რეალიზაციები. დაუშვათ ეს ორი სახე აღიწერებიან ნორმალური განაწილების პირობითი სიმკვრივის ფუნქციებით: $f(x|w_1)$ და $f(x|w_2)$, რომელთა ურთიერთგანლაგება ნაჩვენებია შემდეგ ნახაზზე:



მოცემულია აგრეთვე X რეალიზაციის კლასებში მოხვედრის აპრიორული ალბათობები $P(w_1)$ და $P(w_2)$. როგორც ნახაზიდან ჩანს, სახეები სიმკვრივეთა განაწილების არეში იკვეთება. ამიტომ პრინციპულად შეუძლებელია შეცდომების თავიდან აცილება. გარჩევა მდგომარეობს იმაში, რომ შეცდომების რაოდენობა რაც შეიძლება ნაკლები იყოს.

ავარჩიოთ x ნიშნის ზღურბლური მნიშვნელობა და აღნიშნოთ იგი x_0 -ით. ამ აღნიშვნიდან გამომდინარე უცნობი რეალიზაციის რომელიმე კლასისადმი (სახესადმი) მიკუთვნების პროცესში გადაწყვეტილების მიღების წესისათვის გვაქნება:

$$X \in w_1 \text{ თუ } X < x_0 ; X \in w_2 \text{ თუ } X > x_0$$

თუ $X \in w_1$ და მას მიაკუთვნებენ w_2 სახეს, მაშინ დაშვებული იქნება პირველი რიგის შეცდომა, რომლის ალბათობა განისაზღვრება შემდეგი გამოსახულებით:

$$Q_1 = \int_{x_0}^{\infty} f(x | w_1) dx$$

თუ $X \in w_2$ და მას მიაკუთვნებენ w_1 კლასს, მაშინ დაშვებული იქნება მეორე რიგის შეცდომა, რომლის ალბათობა ტოლია:

$$Q_2 = \int_{-\infty}^{x_0} f(x | w_2) dx$$

უნდა განისაზღვროს არასწორი გადაწყვეტილების მიღების დანაკარგი (ლირებულება). ზოგადად, საქმე გვაქს შემდეგ დანაკარგებობა: c_{12} —პირველი გვარის ცდომილების ლირებულება, c_{21} —მეორე გვარის ცდომილების ლირებულება, c_{11} და c_{22} —სწორი გადაწყვეტილების ლირებულებები. საშუალო ლირებულება \bar{c} ტოლია არასწორი და სწორი ლირებულებების ჯამისა, მათი ალბათობების და აპრიორული ალბათობების გათვალისწინებით, ე.ო.

$$\bar{c} = P(w_1)c_{11}(1-Q_1) + P(w_1)c_{12}Q_1 + P(w_2)c_{22}(1-Q_2) + P(w_2)c_{21}Q_2$$

თუ ამ გამოსახულებაში ჩავსვამთ Q_1 და Q_2 მნიშვნელობებს, მივიღებთ:

$$\bar{c} = P(w_1) \left[c_{11} \int_{-\infty}^{x_0} f(x | w_1) dx + c_{12} \int_{x_0}^{\infty} f(x | w_1) dx \right] + P(w_2) \left[c_{22} \int_{x_0}^{\infty} f(x | w_2) dx + c_{21} \int_{-\infty}^{x_0} f(x | w_2) dx \right] \quad (1)$$

x_0 სიდიდე ისე უნდა შევარჩიოთ, რომ \bar{c} მნიშვნელობა იყოს მინიმალური. ამისათვის (1) გამოსახულება გავაწარმოვოდ $x=0$, როცა $x=x_0$

$$\frac{d\bar{c}}{dx} = P(W_1)[c_{11}f(x_0 | W_1) - c_{12}f(x_0 | W_2)] + P(W_2)[c_{21}f(x_0 | W_2) - c_{22}f(x_0 | W_1)]$$

თუ ავიდებთ განაწილების სიმკვრივეების ფარდობას, რომელსაც დასაჯერობის კოეფიციენტი 1 ეწოდება, მივიდებთ:

$$I = \frac{f(x_0 | W_2)}{f(x_0 | W_1)} = \frac{P(W_1)(c_{11} - c_{12})}{P(W_2)(c_{21} - c_{22})} .$$

როცა $x = x_0$ დასაჯერობის კოეფიციენტი, რომელსაც I_0 სიმბოლოთი ავდნიშნავთ, დებულობს კონკრეტულ მნიშვნელობას. როცა $c_{11} = c_{22} = 0$, $c_{12} = c_1$, $c_{21} = c_2$, მაშინ გვექნება:

$$I_0 = \frac{f(x_0 | W_2)}{f(x_0 | W_1)} = \frac{P(W_1) c_1}{P(W_2) c_2} .$$

თუ $f(x_0 | W_1)$ და $f(x_0 | W_2)$ ნორმალურადაა განაწილებული m_1, m_2 მათემატიკური ლოდინებით და $S_1, S_2 = S$ საშუალო კვადრატული გადახრით, მაშინ გვექნება:

$$I_0 = \exp \left\{ -\frac{1}{2S^2} [(x_0 - m_1)^2 - (x_0 - m_2)^2] \right\} .$$

თუ ამ გამოსახულებას ამოვხსნით x_0 მიმართ, როცა $c_1 = c_2$ და $P(A_1) = P(A_2)$, მაშინ მივიღებთ:

$$x_0 = \frac{1}{2}(m_1 + m_2) .$$

რომელიც ასდენს იდენტიფაციის ცდომილების მინიმიზაციას.

ამრიგად, უცნობი რეალიზაცია მიეკუთვნება W_1 სახეს თუ დასაჯერობის კოეფიციენტი ნაკლებია მის კრიტიკულ ლი მნიშვნელობაზე და W_2 სახეს, თუ იგი მეტია ლი სიდიდეზე.

3.4.2 დისკრიმინანტული ანალიზის ალბათური მოდელი

ვთქვათ, მოცემულია ორი W_1 და W_2 სახე, რომლებიც აღიწერებიან X_1 და X_2 n -განზომილებიანი რეალიზაციებით და $f(x_1, x_2, \dots, x_n | W_1)$ და $f(x_1, x_2, \dots, x_n | W_2)$ განაწილების პირობითი სიმკვრიბის ფუნქციებით. დაუშვათ, რომ სახეების რეალიზაციები ნორმალურად არიან განაწილებულები და კოვარიაციული მატრიცები ერთმანეთის ტოლია. ე.ო. გვაძეს:

$$f(x_1, x_2, \dots, x_n | W_1) = \frac{1}{(2\pi)^{\frac{n}{2}}} \exp \left\{ -\frac{1}{2} (X - M_1) S^{-1} (X - M_1)' \right\} ,$$

$$f(x_1, x_2, \dots, x_n | W_2) = \frac{1}{(2\pi)^{\frac{n}{2}}} \exp \left\{ -\frac{1}{2} (X - M_2) S^{-1} (X - M_2)' \right\},$$

სადაც M_1 და M_2 საშუალოების გექტორია, S – გაერთიანებული კოვარიაციული მატრიცაა. თუ ავიდებთ განაწილების სიმკვრივეების ფარდობას, რომელსაც დასაჯერობის კოეფიციენტი ეწოდება, მაშინ მივიდებთ:

$$| = \frac{f(x_1, x_2, \dots, x_n | W_2)}{f(x_1, x_2, \dots, x_n | W_1)} = \exp \left\{ \frac{1}{2} (X - M_2) S^{-1} (X - M_2)' - \frac{1}{2} (X - M_1) S^{-1} (X - M_1)' \right\}$$

ამ გამოსახულების გალოგარითმებისა და მათემატიკური გარდაქმნების შედეგად ვდებულობთ:

$$\ln | = \frac{1}{2} X S^{-1} (X - M_2)' - \frac{1}{2} M_2 S^{-1} (X - M_2)' - \frac{1}{2} X S^{-1} (X - M_1)' + \frac{1}{2} M_1 S^{-1} (X - M_1)'$$

თუ ფრჩხილებს გავხსნით, დავაჯგუფებთ და გამოვყოფთ დაგვირვებათა $X = (x_1, x_2, \dots, x_n)'$ გექტორს მივიდებთ:

$$\begin{aligned} \ln | &= \frac{1}{2} X S^{-1} X' - \frac{1}{2} X S^{-1} M_2' - \frac{1}{2} M_2 S^{-1} X' + \frac{1}{2} M_2 S^{-1} M_2' - \frac{1}{2} X S^{-1} X' + \frac{1}{2} X S^{-1} M_1' + \\ &+ \frac{1}{2} M_1 S^{-1} X' - \frac{1}{2} M_1 S^{-1} M_1' = X S^{-1} M_1 - X S^{-1} M_2' + \frac{1}{2} M_2 S^{-1} M_2' - \frac{1}{2} M_1 S^{-1} M_1' = X S^{-1} (M_1 - M_2)' + E \end{aligned}$$

სადაც

$$E = \frac{1}{2} M_2 S^{-1} M_2' - \frac{1}{2} M_1 S^{-1} M_1'$$

წარმოადგენს მუდმივ წევრს, ხოლო გამოსახულებას

$$Z = X S^{-1} (M_1 - M_2)' = c_1 x_1 + c_2 x_2 + \dots + c_n x_n$$

დისკრიმინანტული ფუნქცია ეწოდება, რომლის კოეფიციენტები $c_i, i = 1, 2, \dots, n$ მოიძებნება შემდეგი გამოსახულებით:

$$\begin{pmatrix} c_1 \\ c_2 \\ \vdots \\ c_n \end{pmatrix} = \begin{pmatrix} s_{11}, s_{12}, \dots, s_{1n} \\ s_{21}, s_{22}, \dots, s_{2n} \\ \hline \hline \\ s_{n1}, s_{n2}, \dots, s_{nn} \end{pmatrix}^{-1} \begin{pmatrix} m_1^1 - m_1^2 \\ m_2^1 - m_2^2 \\ \hline \hline \\ m_n^1 - m_n^2 \end{pmatrix} \quad C = S^{-1} (M_1 - M_2)'$$

თუ ზღრუბლის მნიშვნელობა $|_0$ შერჩეულია, მაშინ $X \in W_1$ როცა $| < |_0$ და $X \in W_2$, როცა $| > |_0$. ხშირად ასეთი იდენტიფიკაციის პროცედურას დისკრიმინანტული ანალიზი ეწოდება.

დისკრიმინანტული ფუნქციის კოეფიციენტების მოძებნა არ მოითხოვს რეალიზაციების ნორმალურ განაწილებას. მაგრამ, ალგორითმის ეფექტიანობა ბევრად არის დამოკიდებული განაწილების კანონზე, რადგან c_i კოეფიციენტების განსაზღვრა S

კოვარიაციული მატრიცის და საშუალოების ვექტორების M_1 და M_2 თვისებებზეა დამოკიდებული. თუ განაწილების კანონი მნიშვნელოვნად განსხვავდება ნორმალურისაგან, მაშინ S, M_1, M_2 პარამეტრები ცუდად ახასიათებენ რეალიზაციებს და დისკრიმინანტული ანალიზი გამოდის არასაიმედო.

აქვე უნდა შევნიშნოთ, რომ თუ რეალიზაციები ნორმალურად არიან განაწილებული, მაშინ მათ გააჩნიათ საშუალო სიდიდის მიმართ დაჯგუფების ტენდეცია, ხოლო მათი გაფანტვა საშუალო კვადრატული გადახრის პროპორციულია.

3.4.3 ბაიესის მეთოდი

ეს მეთოდი ეფუძნება ალბათობის თეორიაში ცნობილ ბაიესის ფორმულას. ვთქვათ, მოცემულია შეუთავსებადი პიპოთეზების W_1, W_2, \dots, W_m სრული ჯგუფი. (პიპოთეზების როლს გარჩევის სისტემაში სახეები ასრულებენ). ცნობილია ამ პიპოთეზების აპრიორული (ცდამდე) ალბათობები $P(W_1), P(W_2), \dots, P(W_m)$. დაუშვათ, ცდის შედეგად მოხდა b_j ხდომილება ანუ რაიმე კონკრეტული რეალიზაცია. გვაინტერესებს როგორ შეიცვლება პიპოთეზების აპოსტერიორული (ცდის შემდგომი) პირობითი ალბათობები $P(W_i | b_j)$. ამისათვის გამოვიყენოთ ბაიესის ფორმულა

$$P(W_i | b_j) = \frac{P(W_i)P(b_j | W_i)}{\sum_{i=1}^m P(W_i)P(b_j | W_i)},$$

სადაც $P(W_i | b_j)$. პირობითი ალბათობები მოცემულია.

სახეთა გარჩევის ბაიესის კრიტერიუმი ასე ჩამოყალიბდება: რეალიზაცია მიეკუთვნები იმ სახეს (კლასს), რომელთანაც მას გააჩნია უდიდესი პირობითი ალბათობა. ე.ი.

$$b_j \in W_i \text{ როცა } P(W_j | b_j) = \max_k \{P(W_k | b_j)\}.$$

განვიხილოთ მაგალითი. ვთქვათ, მოცემულია ცხრილი, სადაც წარმოდგენილია 17 სიმპტომი, რომლებიც მეტ-ნაკლებად ახასიათებენ ოთხ დაავადებას. 1-ით აღნიშნულია სიმპტომის არსებობა, 0-ით არაარსებობა. d_1 – მიოკარდიუმის ინფარქტი, d_2 – მესამე ხარისხის შოკი, d_3 – პერიტონიტი, d_4 – სისხლის მიმოქცევის მწვავე უკმარისობა.

1	სიმპტომები	დიაგნოზები			
		d_1	d_2	d_3	d_4
1	ტკივილები გულის არეში	1	0	0	1
2	ტკივილები მუცელის არეში	0	0	1	0
3	ტკმპერატურის მომატება	1	0	1	0
4	ტკმპერატურის დაჭვითება	0	1	0	0
5	გულის რითმის მოშლა	1	0	0	0
6	ლეიკოციტოზი	1	0	1	0
7	არტერიული წნევის მომატება	1	0	0	0
8	არტერიული წნევის დაჭვითება	0	1	1	1

9	კანის გაუფერულობა	0	1	1	1
10	პულსის გახშირება	0	1	1	1
11	სუნთქვის გახშირება	0	1	0	1
12	რევლექსების დათრგუნვა	0	1	0	0
13	მუცლის ზედაპირის დაძაბულობა	0	0	1	0
14	მუცლის შეტერვა	0	0	1	0
15	საერთო სისუსტე, თავბრუსხევება	0	0	0	1
16	გულის გაგანიერება	0	0	0	1
17	გულის ყრუ ტონები	1	0	0	1

დაუშვათ b_1 პაციენტს გააჩნია შემდეგი სიმპტომები: (1,3,5,7,10,11,17). გვაინტერესებს ამ ოთხი დაავადებიდან რომლითად იგი დაავადებული. ამისათვის ჯერ გამოვთვალოთ ოთხივე დაავადების აპრიორული ალბათობები:

$$P(d_1) = \frac{6}{17} = 0,35; \quad P(d_2) = \frac{6}{17} = 0,35; \quad P(d_3) = \frac{8}{17} = 0,47; \quad P(d_4) = \frac{8}{17} = 0,47 ,$$

ხოლო შემდეგ აპრიორული ალბათობები:

$$P(b_1 | d_1) = \frac{5}{17} = 0,29; \quad P(b_1 | d_2) = \frac{2}{17} = 0,12; \quad P(b_1 | d_3) = \frac{2}{17} = 0,12; \quad P(b_1 | d_4) = \frac{4}{17} = 0,24 .$$

თუ მიღებულ სიდიდეებს ჩავსვამთ ბაიესის ფორმულაში მივიღებთ:

$$P(d_1 | b_1) = \frac{0,35 \cdot 0,29}{0,35 \cdot 0,29 + 0,35 \cdot 0,12 + 0,47 \cdot 0,12 + 0,47 \cdot 0,24} = \frac{0,1}{0,31} = 0,32; \quad P(d_2 | b_1) = \frac{0,042}{0,31} = 0,14;$$

$$P(d_3 | b_1) = \frac{0,056}{0,31} = 0,18; \quad P(d_4 | b_1) = \frac{0,11}{0,31} = 0,35 .$$

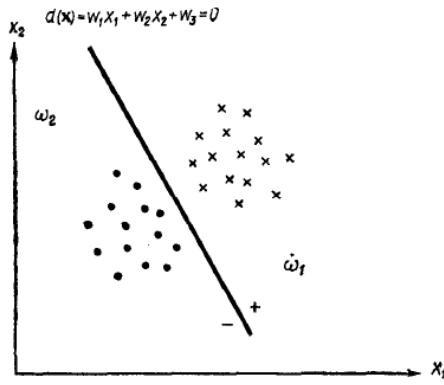
როგორც გამოვლილი აპრიორული პირობითი ალბათობებიდან ჩანს, b_1 პაციენტი, 0,35 სიდიდის ტოლი ალბათობით, დაავადებულია სისხლის მიმოქცევის მწვავე უკმარისობით.

3.5 0დენტივიკაციის დეტერმინირებული მათოდები

3.5.1 გადამწყვეტი ფუნქციები

როგორც ვიცით, იდენტიფიკაციის ამოცანის გადასაწყვეტად საჭიროა შემოვიტანოთ გარკვეული წესები ანუ კრიტერიუმები, რომელთა საშუალებით ხდება გადაწყვეტილების მიღება. ერთ-ერთ ასეთ კრიტერიუმად ითვლება გადამწყვეტი (დისკრიმინანტული) ფუნქციების გამოყენება.

განვიხილოთ მეოთხის არსი ქვემოთ მოყვანილ ნახაზზე წარმოდგენილი შემთხვევის დროს, სადაც ნაჩვენებია ორი w_1 და w_2 სახე ანუ კლასი, რომლებიც შედგებიან ორგანზომილებიანი (x_1, x_2) რეალიზაციებისაგან.



როგორც ნახაზიდან ჩანს, ეს ორი კლასი ერთმანეთისაგან იყოფა სწორი ხაზით. დაუშვათ, რომ მას აქვს შემდეგი სახე:

$$d(X) = w_1x_1 + w_2x_2 + w_3 = 0 \quad (1)$$

რომელსაც გამყოფი განტოლება ეწოდება. აქ w_i კოეფიციენტებია, x_1 და x_2 პარამეტრები. ნახაზიდან ჩანს, რომ (1) განტოლებაში w_1 კლასიდან ნებისმიერი X რეალიზაციის ჩასმით მივიღებთ $d(X)$ ფუნქციის დადებით მნიშვნელობას, ხოლო A_2 კლასიდან რეალიზაციის ჩასმით მივიღებთ უარყოფით მნიშვნელობას. აქედან გამომდინარე, $d(X)$ ფუნქცია შეიძლება გამოყენებული იყოს, როგორც გადამწყვეტი ფუნქცია, რადგან უცნობი რეალიზაცია X მიეკუთვნება w_1 კლასს, როცა $d(X) > 0$, ხოლო ვა კლასს, როცა $d(X) < 0$.

თუ რეალიზაცია იმყოფება საზღვარზე, ე.ი. ადგილი აქვს $d(X) = 0$ ტოლობას, მაშინ საჭმე გვაქვს განუსაზღვრელობასთან და ამოცანა გადაუჭრელი ხდება. სახეთა გარჩევის ასეთი მიღვიმა სამართლიანია ნებისმიერი n -განზომილებიანი გვკლიდეს სივრცისათვის, მაშინ გვექნება:

$$d(X) = w_1x_1 + w_2x_2 + w_3x_3 + \dots + w_nx_n = W'X, \quad (2)$$

სადაც $X = (x_1, x_2, \dots, x_n; 1)'$ წარმოადგენს სახის ვექტორს, ხოლო $W = (w_1, w_2, \dots, w_n, w_{n+1})'$ წონის ვექტორს. თუ მოცემულია ორი კლასი, მაშინ გადამწყვეტ ფუნქციას აქვს შემდეგი თვისება:

$$d(X) = W'X \begin{cases} > 0, & \text{როცა } X \in W_1 \\ < 0, & \text{როცა } X \in W_2 \end{cases}.$$

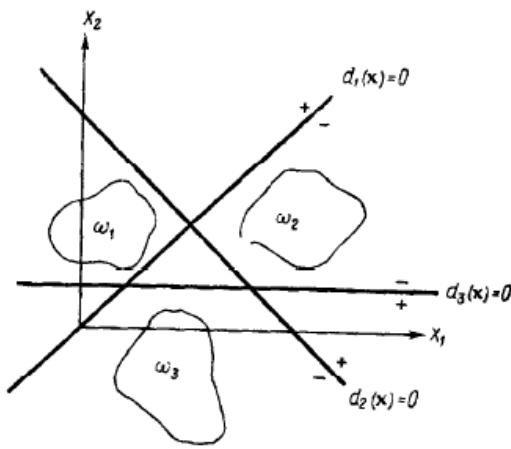
განვიხილოთ შემთხვევა, როცა საჭიროა რამდენიმე w_1, w_2, \dots, w_m კლასების გაყოფა. განვიხილოთ ორი შემთხვევა.

1. თითოეული კლასი გამოყოფილია დანარჩენებისაგან ერთი გამყოფი ზედაპირით. ამ შემთხვევაში არსებულ m რაოდენობის გადამწყვეტ ფუნქციას აქვს შემდეგი თვისება:

$$d_i(X) = W'_i X \begin{cases} > 0, & X \in W_1 \\ < 0, & X \notin W_1 \end{cases}, \quad i = 1, 2, \dots, m$$

აქ

$W_i = (w_{i1}, w_{i2}, \dots, w_{in}, w_{i,n+1})'$ არის i -ური გადამწყვეტი ფუნქციის წონის ვექტორი. ამ შემთხვევის უბრალო მაგალითი მოყვანილია შემდეგ ნახაზზე:

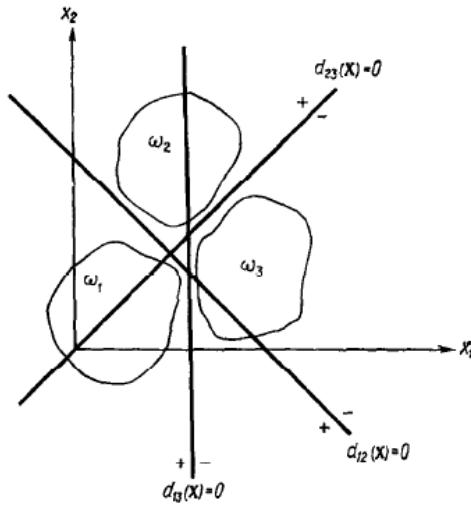


უცნობი რეალიზაცია X მიეკუთვნება ω_1 კლასს იმ შემთხვევაში, როდესაც სრულდება შემდეგი უტოლობები: $d_1(X) > 0$, $d_2(X) < 0$ და $d_3(X) < 0$. ამ შემთხვევაში A_1 კლასის გამყოფი საზღვარი დანარჩენ ω_2 და ω_3 კლასებთან არის $d_1(X) = 0$.

2. თითოეული კლასი გამოყოფილია ნებისმიერი დანარჩენი კლასებიდან ინდივიდუალურად, ე. ი. კლასები წყვილ-წყვილად გაყოფადი არიან. ამ შემთხვევაში გვაქვს $\frac{m(m-1)}{2}$ რაოდენობის გამყოფი ზედაპირი. გადამწყვეტ ფუნქციას აქვს შემდეგი სახე:

$$d_{ij}(X) = W_{ij}^T X$$

და გააჩნია შემდეგი თვისება: თუ უცნობი რეალიზაცია X მიეკუთვნება ω_1 კლასს, მაშინ $d_{ij} > 0$ ყველა $j \neq i$. გარდა ამისა $d_{ij}(X) = -d_{ji}(X)$.



ნახაზზე წარმოდგენილია სამი კლასი. ცხადია, რომ ერთი კლასის გამოყოფა დანარჩენებისაგან ერთი გამყოფი ზედაპირის საშუალებით შეუძლებელია. მაგალითად,

უცნობი რეალიზაცია X მიეკუთვნება w_1 კლასს თუ $d_{12}(X) > 0$ და $d_{13}(X) > 0$. $d_{23}(X)$ გადამწყვეტი ფუნქცია ამ შემთხვევაში არავითარ როლს არ თამაშობს. w_2 კლასის გადაწყვეტილების არესათვის უნდა სრულდებოდეს შემდეგი პირობები: $d_{21}(X) > 0$ და $d_{23}(X) > 0$, ხოლო X მიეკუთვნება w_3 კლასს თუ $d_{23}(X) < 0$ და $d_{13}(X) < 0$.

განზოგადოებულ წრფივ გადამწყვეტ ფუნქციას აქვს შემდეგი სახე:

$$d(X) = w_1 f_1(X) + w_2 f_2(X) + \dots + w_k f_k(X) + w_{k+1} = \sum_{i=1}^{k+1} w_i f_i(X), \quad (3)$$

სადაც $\{f_i(X)\}$, $i = 1, 2, \dots, k$ წარმოადგენენ X რეალიზაციის ნამდვილ ცალსახა ფუნქციებს. $f_{k+1}(X) = 1$.

მიუხედავად იმისა, რომ (3) გამოსახულებით შეიძლება განისაზღვროს რთული გადამწყვეტი ფუნქციები, სათანადო გარდაქმნების საშუალებით ისინი დაიყვანებიან წრფივ გადამწყვეტ ფუნქციებამდე.

ამრიგად, წრფივი გადამწყვეტი ფუნქციების განსაზღვრის ძირითად პრობლემას წარმოადგენს ამ ფუნქციების კოეფიციენტების მოძებნა, რომლებიც შეიძლება განისაზღვროს სხვადასხვა ადაპტური პროცედურებით.

3.5.2 მინიმალური მანძილის კრიტერიუმი

მანძილის ფუნქცია ფართოდ გამოიყენება სახეთა გარჩევის თეორიაში, რადგან იგი წარმოადგენს ევკლიდეს სივრცეში ყველაზე უფრო თვალსაჩინო მსგავსების ზომას. ეს უბრალო იდენტიფიკაციის მეთოდი აღმოჩნდა საკმაოდ ეფექტური იმ შემთხვევებში, როცა კლასები ხასიათდებიან გარკვეულ ფარგლებში შეზღუდული ცვალებადობის ხარისხით.

ზოგიერთ შემთხვევაში სახის რეალიზაციებს გააჩნიათ დაჯგუფების ტენდეცია გარკვეული სახის (მაგალითად, საშუალო ანუ სიმძიმის ცენტრის) მიმართ. ასეთი სიტუაცია წარმოიქმნება იმ შემთხვევაში, როცა რეალიზაციათა ცვალებადობა კლასშიგნით არ არის დიდი და არტეფაქტები აღვილად აღირიცხებიან. ამ შემთხვევაში იდენტიფიკაციის ამოცანის გადაწყვეტა საკმაოდ ეფექტურია მინიმალური მანძილის კრიტერიუმის გამოყენებით.

განვიხილოთ m რაოდენობის w_1, w_2, \dots, w_m სახე, რომლებსაც გააჩნიათ კლასისათვის დამახასიათებელი ეტალონები E_1, E_2, \dots, E_m . როგორც აღვნიშეთ, ეტალონად შეიძლება მივიღოთ სახის რეალიზაციათა საშუალო ვექტორი. კალიდეს მანძილი X ვექტორსა და E_i ეტალონს შორის განისაზღვრება შემდეგნაირად:

$$d(X, E_i) = \|X - E_i\| = \sqrt{(X - E_i)'(X - E_i)}. \quad (1)$$

უცნობი რეალიზაცია X მიეკუთვნება იმ კლასს, მაგალითად w_i , თუ სრულდება შემდეგი პირობები: $d(X, E_i) < d(X, E_j)$ ყველა $j \neq i$. (1) ფორმულა შეგვიძლია წარმოვადგინოთ შემდეგნაირად:

$$d^2(X, E_i)'(X - E_i) = X'X - 2X'E_i + E_i'E_i = X'X - 2\left(X'E_i - \frac{1}{2}E_i'E_i\right).$$

$d^2(X, E_i)$ სიდიდის მინიმალური მნიშვნელობა ექვივალენტურია $\left(X'E_i - \frac{1}{2}E_i'E_i\right)$ სიდიდის მაქსიმალური მნიშვნელობისა, რადგან ნებისმიერი $d^2(X, E_i)$, $i = 1, 2, \dots, m$ გამოთვლისას

XX' წევრი არ არის დამოკიდებული i ინდექსზე. აქედან გამომდინარე, გადამწყვეტი ფუნქცია შეგვიძლია ასე წარმოვადგინოთ:

$$d_i(X) = X'E_i - \frac{1}{2}E_i'E_i, \quad i = 1, 2, \dots, m \quad (2)$$

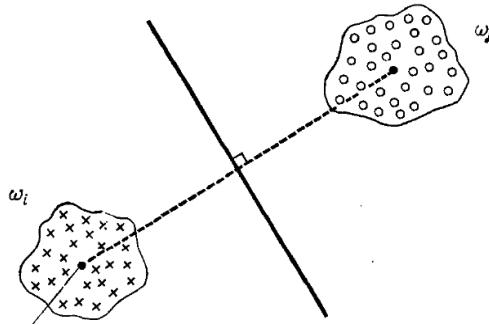
და გადამწყვეტილების მიღების ალგორითმი იქნება შემდეგი:

$$X \in W_i, \text{ თუ } d_i(X) > d_j(X) \text{ ყველა } j \neq i.$$

უნდა ავლი შოთ, რომ $d_i(X)$ არის წრფივი გადამწყვეტი ფუნქცია, ამიტომ (2) გამოსახულების მატრიცული სახე იქნება:

$$d_i(X) = W_i'X, \quad i = 1, 2, \dots, m,$$

სადაც $W_i = (w_{i1}, w_{i2}, \dots, w_{im+1})'$. ქვემოთ მოყვანილ ნახაზზე წარმოდგენილია ორი კლასი თითო ეტალონით და მათი გამყოფი საზღვარი, რომელიც წარმოადგენს პიპერსიბრტეეს, რომლის წერტილები თანაბრად არიან დაშორებულები კლასის ეტალონებისაგან.



დაუშვათ, თითოეული კლასი ხასიათდება არა ერთი, არამედ რამდენიმე ეტალონით $E_i^1, E_i^2, \dots, E_i^{n_i}$, სადაც n_i - i -ური კლასის ეტალონების რაოდენობაა, ე.ი. ნებისმიერი რეალიზაცია, რომელიც ეკუთვნის w_i კლასს ამჟღავნებს დაჯგუფების ტენდეციას რომელიმე $E_i^j, j = 1, 2, \dots, n_i$ ეტალონის მიმართ. ჩავწეროთ D ფუნქცია, რომელიც განსაზღვრავს მანძილს ნებისმიერ X რეალიზაციასა და w_i კლასს შორის

$$D_i = \min \|X - E_i^j\|, \quad j = 1, 2, \dots, n_i$$

ეს იმას ნიშნავს, რომ D_i არის მინიმალური მანძილი იმ მანძილებიდან, რომელიც გამოთვლილია X რეალიზაციასა და w_i კლასის თითოეულ ეტალონთან. უცნობი რეალიზაცია X მიეკუთვნება w_i კლასს, როცა $D_i < D_j$ ყველა $j \neq i$ დროს. ამ შემთხვევაში გადამწყვეტ ფუნქციას აქვს შემდეგი სახე:

$$d_i(X) = \max_k \left\{ (XE_i^k)' - \frac{1}{2}(E_i^k)'E_i^k \right\}, \quad k = 1, 2, \dots, n_i$$

და როგორც წინა შემთხვევაში $X \in W_i$, თუ $d_i(X) > d_j(X)$ ყველა $j \neq i$ დროს.

3.5.3 პოტენციალური ფუნქციების მეთოდი

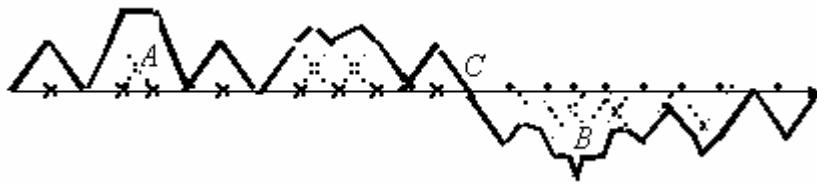
როგორც ფიზიკის კურსიდან ვიცით, წერტილოვანი ელექტრული მუხტი, როელიც მოთავსებულია ერთგვაროვან არეში ქმნის ელექტრულ ვალს. სივრცის ნებისმიერ წერტილში პოტენციალი ტოლი:

$$p = a \frac{q}{r^2} ,$$

სადაც a – მუდმივი კოეფიციენტია, q – მუხტის სიდიდე, r – მანძილი წერტილიდან მუხტამდე. რაც უფრო იზრდება r მანძილი, მით უფრო კლებულობს p პოტენციალი.

ამრიგად, თუ ცნობილია მუხტის სიდიდე და მანძილი მუხტიდან წერტილიდან, მაშინ ადგილი გასაგებია წერტილის პოტენციალი. ე.ი. პოტენციალის სიდიდე შეიძლება გამოყენებულ იყოს წერტილის მუხტიდან დაშორების ზომად. თუ არ შეიცავს რამდენიმე მუხტს, მაშინ არეს ყოველ წერტილში პოტენციალი ტოლია წერტილში ამ მუხტებით გამოწვეული პოტენციალების ჯამისა. თუ მუხტები, რომლებიც ქნიან ველს, კომპაქტურად არიან განლაგებულნი, მაშინ მუხტებით შექმნილი ჯგუფშიგნითა პოტენციალი მაქსიმალურია და დაშორებისას იგი მცირდება.

დავუშვათ, რომ სივრცეში გვაქვს მუხტებისაგან შემდგარი ორი კომპაქტური ჯგუფი. ვთქვათ, ერთ ჯგუფში მუხტები დადებითია, ხოლო მეორეში –უარყოფითი, მაშინ გრაფიკულად გვექნება:



როგორც ნახაზიდან ჩანს, A წერტილში ჭარბობს დადებითი მუხტი, რადგან იგი იმყოფება დადებითი მუხტებისაგან შემდგარ ჯგუფთან, ხოლო B წერტილში გვექნება უარყოფითი პოტენციალი, რადგან იგი იმყოფება უარყოფით მუხტებისაგან შემდგარ ჯგუფთან. C წერტილში პოტენციალი ნულის ტოლია, რადგან დადებითი და უარყოფითი პოტენციალები ამ წერტილში ერთმანეთის ტოლია. ამ შემთხვევაში მიღებული ნიშნის მიხედვით წერტილები (სახეები) შეგვიძლია მივაკუთვნოთ ერთ ან მეორე ჯგუფს (კლასს). ნულის შემთხვევაში (C წერტილი) შეიძლია ჩავთვალოთ, რომ X სახე არც ერთ კლასს არ მიეკუთვნება.

ზემოთ მოყვანილი იდეა გავავრცელოთ სივრცის ნებისმიერ წერტილზე. ამისათვის გამოვიყენოთ ისეთი ფუნქცია, რომელიც წააგავს ზემოთ განხილულ პოტენციალს, ე.ი. ფუნქციას კვების წერტილში უნდა გააჩნდეს მაქსიმალური მნიშვნელობა და წერტილიდან დაშორებისას უნდა კლებულობდეს. ასეთი პოტენციალური ფუნქცია შეიძლება იყოს, მაგალითად შემდეგი:

$$j(r) = \frac{1}{1 + ar^2} ,$$

სადაც a – კოეფიციენტია, რომელზედაც დამოკიდებულია j ფუნქციის კლების სიჩქარე. r წარმოადგენს მანძილს კვების წერტილსა და იმ წერტილს შორის, რომელშიც ითვლება პოტენციალი. r შეიძლება იყოს ნებისიერი მანძილი, მაგალითად, ევკლიდეს ან ჰემინგის.

j სიდიდე ყოველ წერტილში შეიძლება ჩაითვალოს სიახლოვის ზომად წერტილსა და წყაროს წერტილს შორის. დაუშვათ, წყაროდ ჩავთვალეთ წერტილთა

ერთობლიობა, რომლებიც ეკუთვნიან რაიმე A კლასს. მაშინ ამ წერტილთა წყაროების საშუალო პოტენციალი დაახასიათებს თითოეული მათგანის სიახლოეს მოცემულ წერტილსა და მთელ სიმრავლეს შორის. მაგალითად, თუ კომპიუტერის მეხსიერებაში დაფიქსირებულია A და B კალასების წერტილთა სიმრავლეები და ცნობილია ამ სიმრავლეების საშუალო პოტენციალები, მაშინ ახალი წერტილი მიეკუთვნება იმ კლასს, რომლის პოტენციალი ამ წერტილში უდიდესია.

პოტენციალთა მეთოდით სახეთა გარევის უმარტივესი ალგორითმი შემდეგში მდგომარეობს:

1. სწავლება. შესწავლის პროცესში კომპიუტერის მეხსიერებაში ფიქსირებულია ყველა წერტილის (სახის) კოდები და რომელ კლასს მიეკუთვნებიან ისინი.

2. გარჩევა. გასარჩევ უცნობ X წერტილისათვის გამოითვლება თითოეული კლასის პოტენციალი შემდეგნაირად:

$$f(X, A) = \frac{1}{N_A} \sum_{i=1}^{N_A} j_{ai} = \frac{1}{N_A} \sum_{i=1}^{N_A} f(X, a_i)$$

$$f(X, B) = \frac{1}{N_B} \sum_{i=1}^{N_B} j_{bi} = \frac{1}{N_B} \sum_{i=1}^{N_B} f(X, b_i)$$

$$f(X, M) = \frac{1}{N_M} \sum_{i=1}^{N_M} j_{mi} = \frac{1}{N_M} \sum_{i=1}^{N_M} f(X, m_i),$$

სადაც A, B, \dots, M მოცემული კლასებია, N_A, N_B, \dots, N_M —თითოეულ კლასში წერტილების რაოდენობაა.

$$j_{ai} = f(X, a_i) = \frac{1}{1 + ar_{ai}^2}$$

წარმოადგენს პოტენციალს, რომელსაც წარმოშობს გასარჩევ X წერტილში A კლასის i -ური წერტილი.

შემდეგ ხდება $f(X, A), f(X, B), \dots, f(X, M)$ სიდიდეების შედარება და X წერტილი (სახე) მიეკუთვნება იმ კლასს, რომელიც ამ წერტილში ქმნის ყველაზე დიდ პოტენციალს. უმარტივეს შემთხვევაში, როცა საქმე გვაქვს ორ A და B კლასთან, მაშინ გვექნება: $f(X) = f(X, A) - f(X, B)$ და როცა ეს გამოსახულება მიიღებს დადებით მნიშვნელობას, მაშინ სახე მიეკუთვნება ერთ კლასს, ხოლო უარყოფითი სიდიდის დროს მეორე კლასს.

ზემოთ მოყვანილი ალგორითმი შეგვიძლია უფრო გავაუმჯობესოთ, თუ დამატებით ჩავატარებთ შემდეგ ოპერაციებს. როდესაც კომპიუტერს შესწავლის პროცესში ყველა სახეს მივაწვდით, კომპიუტერს ვაიძულებთ იგივე სახეების გარჩევას და თუ იგი შეცდა, მაშინ მეხსიერებაში შედის ბრძანება, რათა შესაბამისი წერტილის წონა გაიზარდოს გარკვეული მნიშვნელობით, მაგალითად, ერთით. ეს იმას ნიშნავს, რომ შემდგომში ამ წერტილში შექმნილი პოტენციალი ორმაგდება. შემდეგ ტარდება ხელმეორედ არჩევის პროცესი და ა.შ. მანამ, სანამ კომპიუტერი უშეცდომოდ არ გაარჩევს ყველა სახეს.

IV. ხელოვნური ნეირონული ქსელები

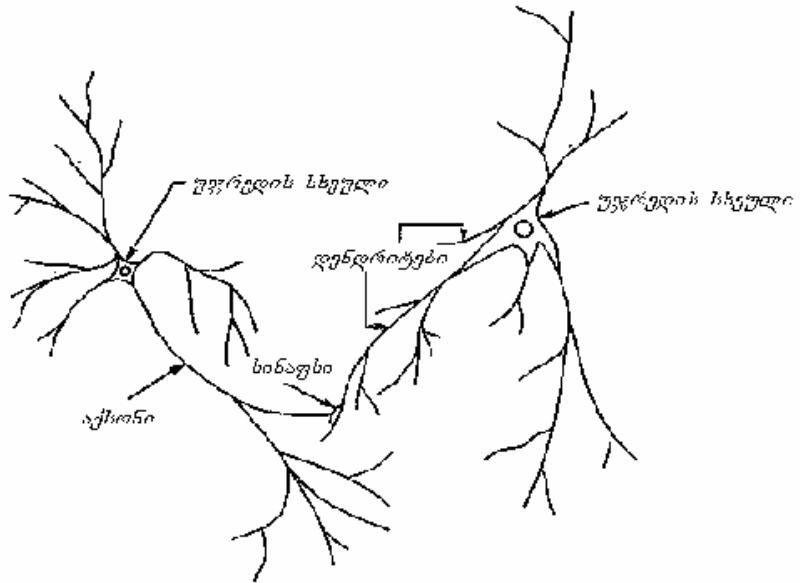
პირველი სამეცნიერო ნაშრომები ხელოვნურ ნეირონულ ქსელებში გამოჩნდა მე-20 საუკუნის ორმოციან წლებში და მათი ავტორები იყვნენ უ. მაკ-კალოკი, ე. პიტსი და უ. გამბა. მათ მიერ შექმნილ ბიოლოგიურ ნეირონის მოდელს ეწოდა პერსეპტრონი. შემდგომში შეიქმნა პერსეპტრონების სხვადასხვა მოდიფიკაციები, რომელთა შორის აღსანიშნავია ფრანკ როზებლანტის მიერ სამოციან წლებში შექმნილი პერსეპტრონი, რომლის საფუძველზეც აიგო ცნობილი გამოთვლითი კომპლექსი ILIAK-4, რომლის ძირითადი მიზანი იყო სახეთა გარჩევის პრობლემების გადაჭრა.

პირველი შედეგები ნეირონული ქსელების მოდელირებისა წარუმატებელი იყო, რის გამოც გამოკვლევები ამ სფეროში გარკვეულ წილად დამუხსრუჟდა. ნეირობიოლოგის განვითარებამ და ნერვულ სისტემებში მიმდინარე პროცესების კვლევაში მრავალი ახალი ინფორმაციის მიღებამ შემდგომში ბიძგი მისცა ხელოვნური ნეირონული ქსელების შექმნის პრობლემას.

ბოლო წლებში საგრძნობლად გაიზარდა ხელოვნური ნეირონული ქსელების გამოყენება სახეთა გარჩევის პროცესებში; დროითი მნკრივების პროგნოზირებაში; წრფივი და არაწრფივი ობიექტების მოდელების შექმნაში; ნეიროკომპიუტერის ანუ ე.წ. პარალელური მოქმედების კომპიუტერის აგებაში და ბევრ სხვა სფეროში.

4.1 ბუნებრივი ნეირონი და მასში მიმდინარე პროცესები

ნეირონი წარმოადგენს ნერვული სისტემის უჯრედს და სხვა უჯრედებისაგან იმით განსხვავდება, რომ მას გააჩნია მთელი რიგი გამოთვლითი ფუნქციები. მიუხედავად ნეირონის მრავალფეროვნებისა ისინი ძირითადად შედგებიან ერთი და იგივე დანიშნულების ელემენტებისაგან: უჯრედის სხეული (სომა), დენდრიტები და აქსონები. სქემატურად ნეირონი წარმოდგენილია შემდეგ ნახაზზე:



ცნობილია, რომ მოზრდილი ადამიანის ტვინის ნეირონები არ აღდგებიან, ისინი კვდებიან. ეს იმას ნიშნავს, რომ ნეირონის ყველა კომპონენტი უწყვეტლივ უნდა იცვლებოდეს, ხოლო მასალა უნდა განახლდეს საჭიროების შემთხვევაში.

უჯრედის სხეული ანუ სომა, რომელიც მოქცეულია მემბრანულ გარსში, არეგულირებს უჯრედში მიმდინარე პროცესებს. იგი მართავს ნეირონის ენერგიის ხარჯვას და არეგულირებს უჯრედში მიმდინარე მრავალ სხვა პროცესებს. უჯრედის სხეულის გარე მემბრანას გააჩნია ნერვული იმპუსების (მოქმედების პოტენციალები) გენერირების უნიკალური უნარი, რომელიც წარმოადგენს ნერვული სისტემის სიცოცხლისათვის საჭირო ფუნქციას და მისი გამოთვლითი უნარის ცენტრს. სომა თავისი ფორმის მიხედვიდან გამომდინარე არჩევენ ათასობით ნეირონის ტიპს, რომელთაც გააჩნიათ ჩვეულებრივ 5-დან 100 მიკრომეტრის სიგრძის დიამეტრი.

სომას დანიშნულებაა შემოსული იმპულსების აკუმულირება (აჯამვა). თუ სომას პოლარიზაციის პროცესი უფრო მზარდია ვიდრე დეპოლიზაციისა, მაშინ აჯამვის გარკვეული ხარისხის მიღწევისას იგი განიმუხტება და აქსონში ჩნდება შესაბამისი სიგნალი. განმუხტვის შემდეგ ნეირონს გარკვეული დროის განმავლობაში აღარ შეუძლია შემოსულ სიგნალზე რეაგირება. დროის ამ მონაკვეთს, რომელიც შეიძლება გაგრძელდეს წამის მეასედებიდნ რამდენიმე წამამდე, ლატენტური პერიოდი ეწოდება. ლატენტური პერიოდის გავლის შემდეგ ნეირონი მოდის საწყის „მუშა“ მდგომარეობაში.

დენდრიტების დანიშნულებაა გარემოდან მიღებული სიგნალების გატარება და გარდაქმნა. გარდაქმნაში იგულისხმება სიგნალის დამუხრუჭება ანუ შემცირება, ან გაზრდა. დენდრიტების საშუალებით გარემოდან ან სხვა ნეირონებიდან გამომავალი სიგნალები მოხვდებიან სომაში. ამრიგად, დენდრიტები წარმოადგენებ განშტოებად სტრუქტურას, რომლებიც გამოდიან სომიდან და მათზე განლაგებულია სინაფსური შენაერთები, რომლებიც დებულობენ სხვა აქსონებიდან სიგნალებს. დენდრიტების მიერ სიგნალების გატარების პროცესი დამოკიდებულია სინაფსურ კავშირებზე და მისი დიამეტრის ცვლილებებზე. ასე მაგალითად, დიამეტრის შემცირება შეიძლება იწვევდეს სიგნალის გაზრდას, ხოლო დიამეტრის გადიდება—შემცირებას ანუ დამუხრუჭებას.

აქსონი წარმოადგენს განუტოტებელ ნერვულ ბოჭკოს, რომლის დანიშნულებაა ნეირონის მიერ გამომუშავებული სიგნალის გატარება. აქსონს გააჩნია განშტოებები, რომელთა საშუალებით იგი უკავშირდება სხვა აქსონებს, დენდრიტებს და მათი საშუალებით სხვა ნეირონებს. აქსონში სიგნალი გვაქვს იმ შემთხვევაში, როდესაც სომა განიმუხტება. იმპულსების ამპლიტუდა განმუხტვის ძალის მიუხედავად მუდმივია, მაგრამ იცვლება მათი სიხშირე. დენდრიტებში მისი დიამეტრის ცვლილებით და

სინაფსების საშუალებით ხდება აკრძალვის, არჩევის და თანაკვეთის ოპერაციები, ანუ ლოგიკური „და“, „ან“ და „არა“ მოქმედებები. აქსონი შეიძლება იყოს მოკლე (0,1 მმ) და გრძელი, რომლის სიგრძე აღემატება 1მ და რომელიც განთავსებულია ადამიანის სხეულის სხვა ნაწილებში.

აქსონის დაბოლოებას გააჩნია უამრავი განშტოება, რომელთა დაბოლოება წარმოადგენებს სინაფსებს, საიდანაც სიგნალი დენდრიტების საშუალებით გადაეცემა სხვა ნეირონებს, ხოლო ზოგიერთ შემთხვევაში სომას.

სინაფს გააჩნია სფეროსებრივი ფორმა, სადაც განთავსებულია ბუშტულები, რომლებიც შეიცავენ ნეიროტრანსმიტერულ მოლეკულების დიდ რაოდენობას. როდესაც იმპულსი გადის აქსონში ზოგიერთი მისი ბუშტულები გამოანთავისუფლებენ თავის შემადგენლობას სინაფსურ ხვრელში, რომლებსაც იჭერენ დენდრიტის სპეციალური რეცეპტორები და ხდება მათი დანერგვა უჯრედის სხეულში. არსებობს 30-ზე მეტი სახის ნეიროტრანსმიტერები, რომელთაგან ზოგი წარმოადგენს ამზენებს და იწვევენ უჯრედის აგზენებას და ზოგიერთი გამოიმუშავებს გამოსავალ იმპულსებს. სხვები წარმოადგენებს დამუხტუჭების ნეიროტრანსმიტერებს, რომლებიც ცდილობენ იმპულსის შემცირებას ან ჩაქრობას.

სომა შემოსულ სიგნალებს აჯამავს და თუ აჯამული სიგნალი ზღურბლურ სიგნალზე მეტია, გამოიმუშავებს იმპულს, რომელიც აქსონის გავლით გადაეცემა სხვა ნეირონებს.

დასკვნის სახით ჩამოვაყალიბოთ შემდეგი:

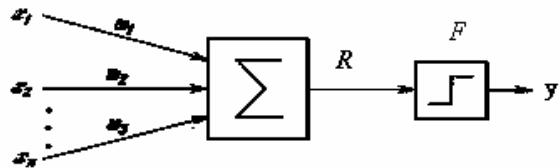
1. ფუნქციონალურად ნეირონი სიგნალებს დებულობს შემავალი არხების ანუ დენდრიტების საშუალებით გარემოდან ან სხვა ნეირონებისაგან სინაფსების საშუალებით. აქედან სიგნალები მოხვდებიან სომაში.

2. სომაში მოხვედრილი სიგნალები აიჯამებიან სხვა ანალოგურ სიგნალებთან ერთად და როდესაც ჯამური სიგნალი გადააჭარბებს გარკვეულ ზღურბლურ მნიშვნელობას მოხდება სომას განმუხტვა და ნეირონის გამოსავალზე ანუ აქსონზე გაჩნდება იმპულსი.

3. ნეირონის მიერ გამომუშავებულ სიგნალს აქსონი გაატარებს და მის ბოლოებზე არსებული სინაფსების საშუალებით გადასცემს სხვა ნეირონებს, რომლებიც თავის მხრივ შეიძლება აღიგზონ ან პირიქით დამუხტუჭები. სინაფს გააჩნია გარკვეული ინტენსიტეტი ანუ წონა, რომელიც შეესაბამება ნეირონის სინაფსურ აქტიობას.

4.2 ხელოვნური ნეირონის მოდელი

პირველი მიახლოებით ხელოვნური ნეირონი, რომელსაც ზოჯერ მათემატიკურ ნეირონსაც უწოდებენ, წარმოადგენს ბუნებრივი ნეირონის თვისებების იმიტაციას. ხელოვნური ნეირონის შესავალზე შედის გარკვეული რაოდენობის სიგნალები, რომელთაგან თითოეული მათგანი წარმოადგენს სხვა ნეირონის გამოსავალს. თითოეული შემოსავალი სიგნალი მრავლდება გარკვეული წონით კოეფიციენტზე, შემდეგ იჯამება და მიღებული ჯამი ახასიათებს ნეირონის აქტივაციის დონეს. ხელოვნური ნეირონის მოდელი ასე შეიძლება წარმოვადგინოთ:



შემავალი სიგნალები x_1, x_2, \dots, x_n შეესაბამებიან ნეირონის სინაფსებში გამავალ სიგნალებს. თითოეული სიგნალი მრავლდება შესაბამის წონით w_1, w_2, \dots, w_m კოეფიციენტებზე და იჯამება აჯამვის \sum ბლოგში. თითოეული წონითი კოეფიციენტი შეესაბამება სინაფსური კავშირის ე.წ. „ძალას“. აჯამვის ბლოკი შეესაბამება სომას და თუ მისგან გამოსულ სიგნალს ავღნიშავთ R სიმბოლოთი, მაშინ გვექნება:

$$R = \sum_i w_i \cdot x_i = W'X.$$

R სიგნალი ახასიათებს ნეირონის რეაქციას და როგორც წესი იგი გარდაიქმნება აქტივაციურ ანუ მახასიათებელ F ფუნქციად და თუ ის რაიმე T ზღრულბზე მეტია, მაშინ ნეირონის გამოსავალზე ვდებულობთ სიგნალს. თუ ნეირონის გამოსავალ სიგნალს ავღნიშავთ Y სიმბოლოთი, მაშინ გვექნება:

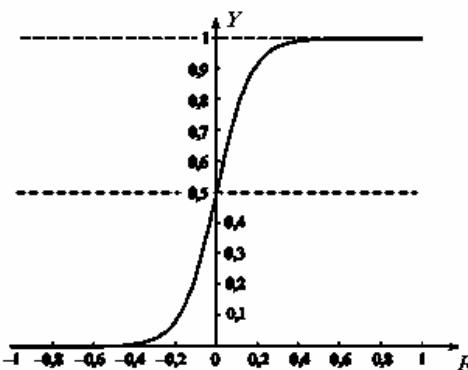
$$Y = f(W'X - T) = f(R - T).$$

აქტივაციური ფუნქცია სხვადასხვა სახისაა და იგი შეიძლება ჩაითვალოს სელოვნური ნეირონის არაწრფივ მაძლიერებელ მახასიათებლად. გაძლიერების კოეფიციენტი განისაზღვრება, როგორც ფარდობა Y სიგნალის ნაზრდისა R სიგნალის ნაზრდზე.

პრაქტიკაში უფრო ხშირად გამოიყენება სიგმაიდალური (სიგმა) ფუნქცია. (ფუნქციას სიგმაიდალური უწოდეს იმის გამო, რომ გრაფიკულად იგი წააგავს „S“ ასოს). სიგმაიდალური აქტივაციის ფუნქცია მათემატიკურად ასე გამოისახება:

$$Y = \frac{1}{1 + \exp\{-R\}}.$$

ხშირად ამ ფუნქციას სტანდარტულს უწოდებენ და როცა $(R - T) \geq 0$, მაშინ $Y = 0$ გრაფიკულად სიგმა ფუნქციას აქვს შემდეგი სახე:



სიგმაიდალური ფუნქციის ერთ-ერთ დირებულებას წარმოადგენს მისი პირველი რიგის წარმოებულის მარტივი სახე:

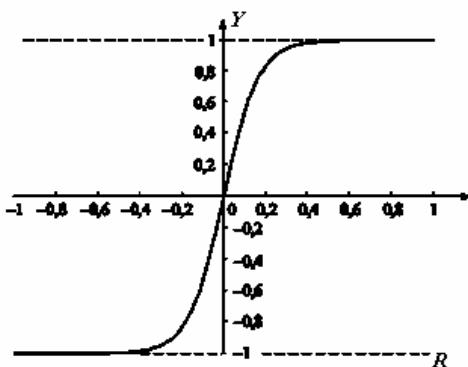
$$y' = F(R)[1 - F(R)]$$

უნდა აღინიშნოს, რომ სიგმაიდალური ფუნქცია დიფერენცირებადია მთელი აბსცისის დერძის მიმართ. ამ თვისების გამო იგი ხშირად გამოიყენება ნეიროქსელების

სწავლების პროცედურებში. გარდა ამისა, მას გააჩნია უნარი გააძლიეროს დაბალი სიგნალები უფრო ძლიერად, ვიდრე დიდი სიგნალები, რაც იწვევს დიდი სიგნალებით გაჯერების თავიდან აცილებას.

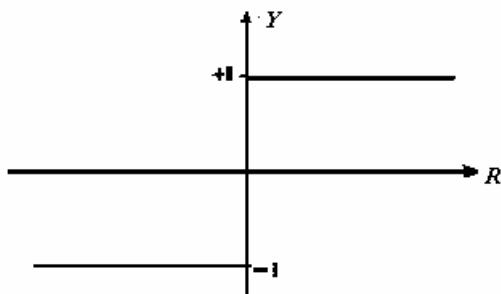
გარდა სიგმაიდალური ფუნქციისა პრაქტიკაში ხშირად გამოიყენება პიპერბოლური ტანგესის ფუნქცია, რომელიც სიგმა ფუნქციის მსგავს ფუნქციას წარმოადგენს იმ განსხვავებით, რომ იგი სიმეტრიულია კოორდინანტთა სათავის მიმართ და $R=0$ წერტილში ნულის ტოლია.

$$Y = \frac{e^x - e^{-x}}{e^x + e^{-x}}$$



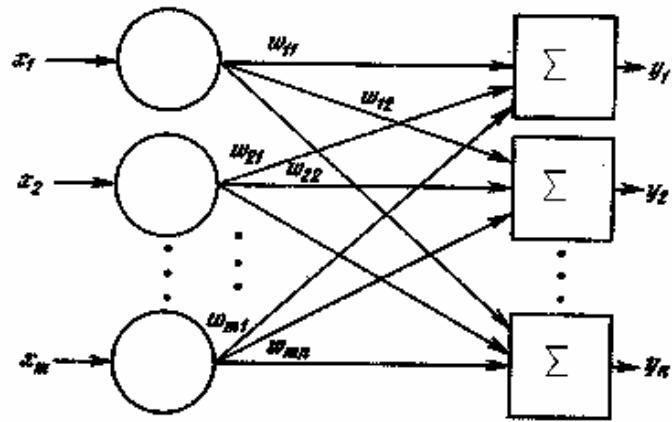
გამოიყენება აგრეთვე კიბისებური ფუნქცია, რომელსაც აქვს შემდეგი სახე:

$$Y = \begin{cases} 1, & \text{როცა } R \geq 0, \\ 0, & \text{როცა } R < 0. \end{cases}$$



არსებობენ სხვა აქტივაციური ფუნქციები (პოპულარული, პარამეტრზე დამოკიდებული, რადალურ-ბაზისური ფუნქციები და სხვა), რომლებიც მეტ-ნაკლებად გამოიყენებიან პრაქტიკულ კვლევებში.

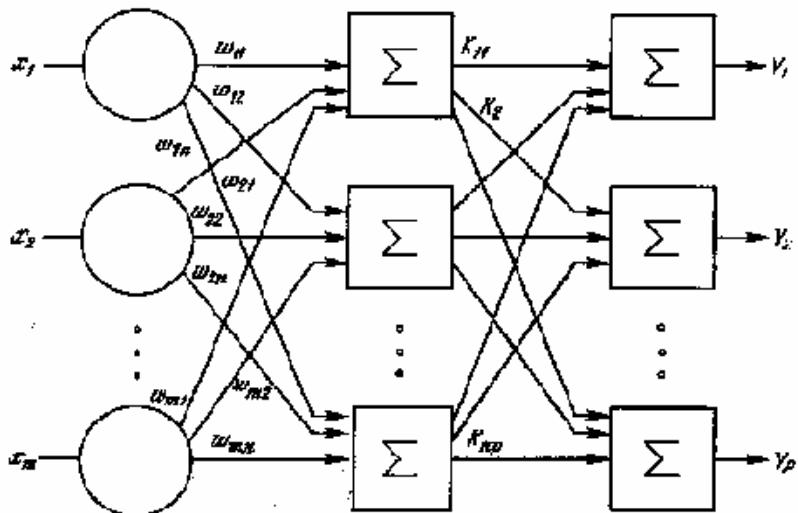
არჩევან ერთშრიან და მრავალშრიან ხელოვნურ ნეირონულ ქსელებს. ერთშრიანი ნეირონული ქსელის ბლოკ-სქემა წარმოდგენილია შემდეგ ნახაზზე:



სქემაზე აღნიშნული რგოლები გამოიყენება მხოლოდ შემავალი სიგნალის განაწილებისათვის. მათ არ გააჩნიათ რაიმე გამოთვლითი ფუნქცია და ამიტომ ისინი შრედ არ შეიძლება ჩაითვალოს.

წონითი კოეფიციენტების W მატრიცას გააჩნია m სტრიქონი და n სვეტი. გამოსავალი ვექტორი Y , რომლის კომპონენტებია ნეირონების გამოსავალი R , მიიღება: $Y = XW$ გამოსახულებით, სადაც Y და X -ვექტორი-სტრიქონებია.

მრავალშრიანი სელოვნური ნეირონული ქსელი შეიძლება ასე წარმოვადგინოთ:



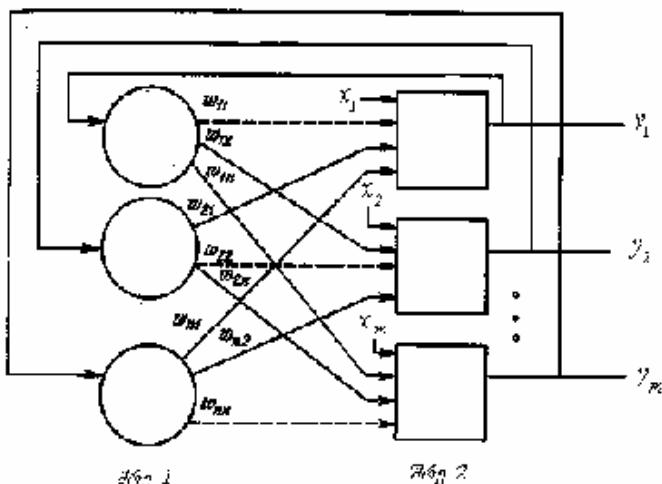
როგორც ვხედავთ, მრავალშრიანი ქსელი შეიძლება შევქმნათ შრეების კასკადებით, სადაც ერთი შრის გამოსასვლელი მეორე შრის შესასვლელია. შრის გამოსასვლელი სიგნალი განისაზღვრება შემავალი ვექტორის პირველი წონით მატრიცაზე გამრავლებით და შემდგომ მიღებული შედეგის გამრავლებით მეორე შრის წონით მატრიცაზე, ე.ი. $(XW_1)W_2$ ანუ $X(W_1W_2)$. მრავალშრიანი ნეირონული ქსელის შუალედურ შრეს, რომელსაც უშუალოდ არ გააჩნია კავშირი ნეიროქსელის გამოსავალთან, ფარული შრე ეწოდება.

ამრიგად, ორშრიანი წრფივი ქსელი ექვივალენტურია ერთშრიანი ქსელისა, რომლის წონის მატრიცა მიიღება ორივე შრის წონითი მატრიცების გადამრავლებით. აქედან გამომდინარე, ნებისმიერი მრავალშრიანი წრფივი ნეირონული ქსელი შეგვიძლია შევცვალოთ მისი ექვივალენტური ერთშრიანი ქსელით.

ერთშრიანი ქსელი საკმაოდ შეზღუდულია თავისი გამოთვლითი შესაძლებლობებით. იმისათვის, რომ ქსელის შესაძლებლობა ერთშრიან ქსელთან შედარებით გაიზარდოს, საჭიროა გამოვიყენოთ არაწრფივი აქტივაციის ფუნქცია.

ზემოთ განხილულ ნეირონულ ქსელებს უკუკავშირი არ გააჩნიათ და ამიტომ მათ პირდაპირი გავრცელების ქსელებს უწოდებენ. ასეთ ქსელებს მეხსიერება არ გააჩნიათ და მათი გამოსავალი მთლიანად განისაზღვრება მიმდინარე შემავალი სიგნალებით და წონებით. პირდაპირი გავრცელების ქსელებს მიეკუთვნებიან: პერსეპტრონები, რადიალურ ბაზისური ფუნქციების ქსელები, ალბათური ქსელები და სხვა.

უკუკავშირიანი ქსელის შემთხვევაში გამოსავალი სიგნალი უბრუნდება შემოსასვლელს და აქედან გამომდინარე, გამოსავალი სიგნალი განისაზღვრება როგორც მიმდინარე შემომავალი სიგნალით, ასევე წინა გამოსავალი სიგნალებით. ამ მიზეზის გამო უკუკავშირებიან ქსელს შეიძლება გააჩნდეს ადამიანის მოკლევადიანი მეხსიერების მსგავსი თვისებები. ერთშრიანი უკუკავშირებიანი ქსელი შეიძლება ასე წარმოვადგინოთ:



უკუკავშირიანი ქსელებს მიეკუთვნებიან: პოპულარული, ჰემინგის, კოპონენტის, ადაპტური რეზონანსული თეორიის ნეიროქსელები და სხვა.

დასკვნის სახით ჩამოვაყალიბოთ შემდეგი ცნებები:

1. ნეირონის მიმდინარე მდგრმარეობა განისაზღვრება ფორმულით:

$$Y_i = \sum_{j=1}^N w_{ij} x_j + T_i , \quad (1)$$

სადაც x_j , $j = 1, 2, \dots, n$ შემავალი სიგნალებია,

w_{ij} – წონითი კოეფიციენტებია,

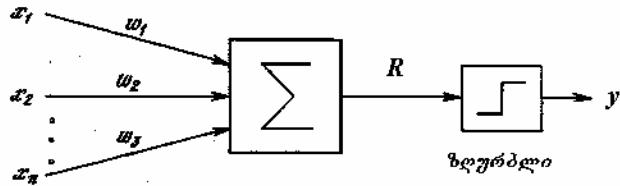
T_i – ზღურბლური მნიშვნელობაა.

2. დადებითი წონის კოეფიციენტები შეესაბამებიან სინაფსების აღზებას, ხოლო უარყოფითები-დამუხრუჭებას. თუ $w_{ij} = 0$, მაშინ კავშირი i -ურ და j -ურ ნეირონებს შორის არ არსებობს.

3. მიღებულ სიგნალს ნეირონი აქტივაციური ფუნქციით გარდაქმნის გამოსავალ $Y_i = F(x_i)$ სიგნალად. ზოგადად, აქტივაციის ფუნქცია წარმოადგენს არაწრფივ ფუნქციას, რომლითაც ხდება აღზების გატარების პროცესის მოდელირება.

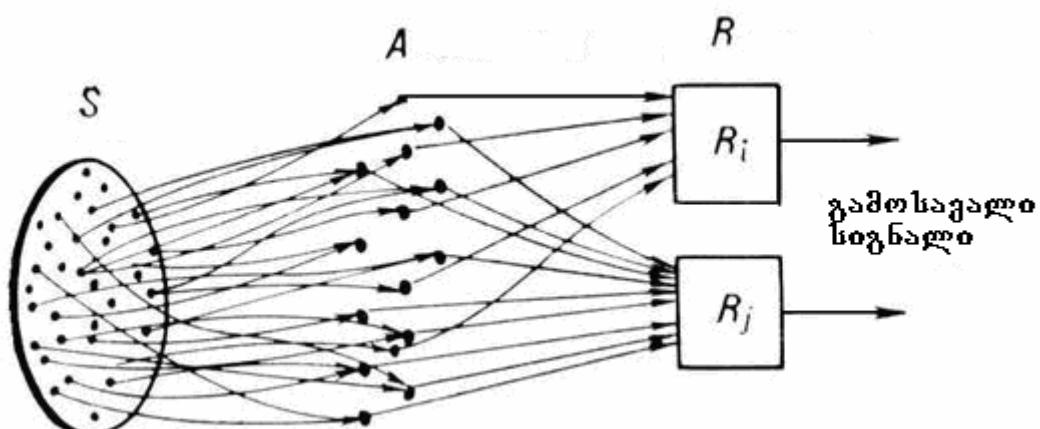
4.3 პერსიატრონი

განვიხილოთ მარტივი ხელოვნური ნეირონის მოდელი



თუ აჯამული სიგნალი $R = \sum_{i=1}^n w_i x_i$ მეტია ზღურბლზე, მაშინ ნეირონის გამოსაგალი სიგნალი $Y = 1$, წინააღმდეგ შემთხვევაში $Y = 0$. ასეთი ნეირონულ მოდელებისაგან შემდგარ სისტემას პერსეპტონი ეწოდება.

განვიხილოთ ფ. როზენბლანტის მიერ დამუშავებული პერსეპტრონი, რომლის ბლოკ-სქემა წარმოდგენილია შემდეგ ნახაზზე:



პერსეპტრონის მიმღებ მოწყობილობად აღებულია ბადურას ფოტოელექტრული მოდელი, კერძოდ რეცეპტორების S არე, რომელიც შედგება რამდენიმე ასეული ფოტოწინაღობებისგან და რომელიც თვალის ბადურის ანალოგიურია და აღიქვამს გარედან შემოსულ სიგნალებს. რეცეპტორების არეს თითოეული ელემენტი შეიძლება იყოს ორ მდგომარეობაში – აგზნებულ და არაგზნებულ ში, იმისდა მიხედვით ეცემა თუ არა შესაბამის ფოტოწინაღობის არეში წარმოდგენილი გასარჩევი ფიგურის კონტური. თითოეული ელემენტის გამოსასვლელზე მიიღება სიგნალი, რომელიც ერთის ტოლია თუ ელემენტი აგზნებულია და ნულის ტოლია, როცა ელემენტი არ არის აგზნებული.

რეცეპტორების გამოსასვლელები მიერთებულია ასოციატური შრის ე.წ. A ელემენტთან შემთხვევითობის პრინციპით და იგი უცვლელია ექსპერიმენტის ბოლომდე. A ელემენტი წარმოადგენს სუმატორს რამდენიმე შესასვლელით და ერთი გამოსასვლელით. A ელემენტი აწარმოებს მის შესასვლელზე მიწოდებული სიგნალების

ალგებრულ აჯამვას და მიღებული მნიშვნელობა თუ აღემატება რაიმე T ზღურბლურ მნიშვნელობას, მაშინ A ელემენტი აგიზნება და გამოსასვლელზე გვაძლევს სიგნალს, რომელიც ერთის ტოლია. წინააღმდეგ შემთხვევაში გამოსასვლელზე გვექნება ნული. ე. ი.

$$x_i = \begin{cases} 1, & \text{როცა } \left(\sum_i r_{ij} x_i - T \right) \geq 0, \\ 0, & \text{როცა } \left(\sum_i r_{ij} x_i - T \right) < 0, \end{cases}$$

სადაც $r_{ij}=1$, როცა i -ური რეცეპტორი მიერთებულია A_j ელემენტთან და $r_{ij}=-1$, როცა i -ური რეცეპტორი მიერთებულია A_j ელემენტთან უარყოფითი ნიშნით. როცა i -ური რეცეპტორი A_j ელემენტთან არ არის მიერთებული, მაშინ $r_{ij}=0$. A ელემენტის გამოსავალი სიგნალები მრავლდებიან შესაბამის w_i წონით კოეფიციენტებზე და შემდეგ აიჯამებიან

$$R = \sum_{j=1}^m w_j x_j$$

აჯამული სიგნალი მიეწოდება ე. წ. რეაგირების ელემენტს ანუ R -ელემენტს. თუ R დადებითია ან ნულის ტოლი, მაშინ R ელემენტი გამოსასვლელზე იძლევა ერთს, ხოლო როცა R უარყოფითია, მაშინ ნულს. ე. ი.

$$Y = \begin{cases} 1, & \text{როცა } R \geq 0, \\ 0, & \text{როცა } R < 0. \end{cases}$$

დავუშვათ, რომ რეცეპტორების არეში დაპროგრამებულია ფიგურები, რომლებიც მიეკუთვნებიან ორ სხვადასხვა კლასს. თუ შესაძლებელია პერსეპტრონი მივიყვანოთ ისეთ მდგომარეობაში, რომ საკმაოდ საიმედოდ გამოსასვლელზე მოგვცემს ერთს, როცა მის შესასვლელზე ერთი კლასის ფიგურადა და ნულს, როცა მეორე კლასის ფიგურაა, მაშინ პერსეპტრონს გააჩნია ორი სახის გარჩევის უნარი.

როცა სახეთა რაოდენობა ორზე მეტია, მაშინ წონითი კოეფიციენტების სიმრავლე $\{w\}$ მოცემული უნდა იყოს ყველა სახისათვის ცალ-ცალკე. ასევე, რეაგირების R ელემენტების რაოდენობა ტოლი უნდა იყოს სახეთა რაოდენობისა. გასარჩევი ობიექტი მიეკუთვნება იმ სახეს, რომლის R ელემენტის გამოსავალი სიგნალი უდიდესია.

4.4 ხელოვნური ნეირონული ქსელის სრავლება

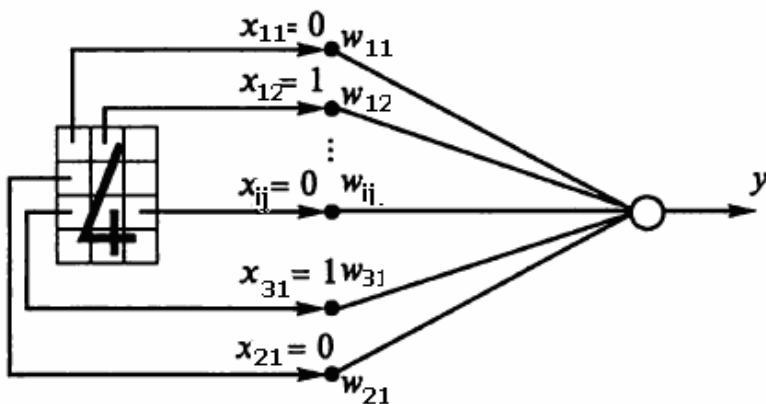
4.4.1 ერთშრიანი ნეირონული ქსელის სწავლება

როგორც ავლიშეთ, ნეირონული ქსელები გამოიყენებიან სახეთა გარჩევის, პროგნოზირების და არაწრფივი დამოკიდებულების (არაწრფივი რეგრესია) ამოცანების გადასაწყვეტად. ამისათვის საჭიროა ნეირონული ქსელების სწავლება. მეტად მნიშვნელოვანია ის ფაქტი, რომ ნეირონული ქსელების სწავლება შესაძლებელია. გასული საუკუნის 60 წლებში როზენბლანტმა დაამტკიცა თეორემა ერთშრიანი პერსეპტრონის სწავლების შესახებ.

სწავლების ზოგადი იდეა შემდეგში მდგომარეობს: დასაწყისში ნეირონული ქსელის შესასვლელს მიეწოდება სასწავლო X ამონარჩევი ცნობილი შედეგებით და

გაკვირდებით ქსელის გამოსავალ სიგნალს $Y = F(X)w_i$. წონით კოეფიციენტების და თითოეული ნეირონის აქტივაციის ზღურბლური მნიშვნელობის რეგულირებით ქსელს გაიძულებთ მის გამოსავალზე მივიღოთ სასურველი შედეგი. ამის შემდეგ, საგამოცდო ამონარჩევით გამოწმებთ ნეირონული ქსელის მუშაობის სიზუსტეს. მაგალითად, კლასიფიკაციის ამოცანაში ჩვენ შეგვიძლია მოვითხოვოთ, რომ ქსელმა 90%-ით სწორად ჩაატაროს სახეების კლასიფიკაცია. პროგნოზირების ამოცანებში ჩვენი მიზანი შეიძლება იყოს პროგნოზირების სიზუსტე, რომელიც არ უნდა აღემატებოდეს წინასწარ მოცემულ მნიშვნელობას. თუ ნეირონული ქსელი პასუხობს წაყენებულ მოთხოვნებს, მაშინ მისი გამოყენება პრაქტიკულ კვლევებში უკვე შესაძლებელია.

განვიხილოთ სწავლების პროცესის ალგორითმი მეტად მარტივ როზენბლატის ერთშრიან პერსეპტონის მაგალითზე. ქვემოთ მოყვანილ ნახაზზე ნაჩვენებია პერსეპტონის უმარტივესი ვარიანტი, რომლის დანიშნულებაა გაარჩიოს რიცხვები ერთმანეთისაგან.



წარმოვიდგინოთ მატრიცა, რომელიც შეიცავს 12 ფოტოელემენტს, რომლებიც განლაგებული არიან 4 პორიზონტალურ მწკრივში. ყოველ მწკრივში მოთავსებულია 3 ფოტოელემენტი. ფოტოელემენტების მატრიცაზე ხდება ბარათის ზედდება, სადაც წარმოდენილია ციფრი (ჩვენი მაგალითისათვის რიცხვი 4). თუ ფოტოელემენტზე მოხვდება ციფრის რომელიმე ფრაგმენტი, მაშინ ეს ფოტოელემენტი გამოიყენება სიგნალს, რომელიც ერთის ტოლია, წინააღმდეგ შემთხვევაში – ნულის. როგორც ნახაზიდან ჩანს, პირველი ფოტოელემენტი იძლევა $x_{11}=0$ სინალს, მეორე ფოტოელემენტი – $x_{12}=1$ სიგნალს და ა.შ.

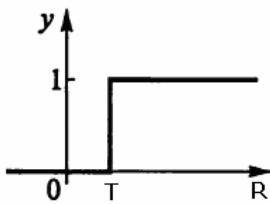
ამის შემდეგ სიგნალები გამრავლდება თავის შესაბამის წონით კოეფიციენტებზე და ხდება მათი აჯამვა.

$$R = \sum_{j=1}^n w_j x_j$$

მიღებული ჯამური R სიგნალი დარღება ზღურბლურ T მნიშვნელობას და თუ შედეგი დამაკმაყოფილებელია, მაშინ გამოსავალი სინალი $Y = 1$, წინააღმდეგ შემთხვევაში $Y = 0$. ე.ი.

$$Y = \begin{cases} 1, & R \geq T, \\ 0, & R < T. \end{cases}$$

როგორც Y ლოგიკურ გამოსახულებიდან ჩანს, ამ შემთხვევაში გამოიყენება შემდეგი სახის კიბისებური აქტივაციის ფუნქცია:



პერსეპტონის მიზანია გამოსავალი სიგნალი იყოს $Y = 1$ ტოლი, როცა ბარათზე აღბეჭდილია ციფრი 4 და $Y = 0$ – სხვა რიცხვების დროს.

ეს მიზანი მიიღწეა პერსეპტონის სწავლებით, რომელიც მდგომარეობს წონითი w_j კოეფიციენტების კორექტირებაში. თუ გამოსავალი სიგნალი $Y = 1$, მაშინ კოეფიციენტების კორექტირება არაა საჭირო, რადგან პერსეპტონის რეაქცია სწორია. მაგრამ, თუ გამოსავალი სიგნალი არასწორია, ე.ი. $Y = 0$, მაშინ საჭიროა იმ წონითი კოეფიციენტების გაზრდა, როლებიც ახდენენ ნეირონის აგზნებას. ჩვენ შეთხვევაში საჭიროა w_{12}, w_{31}, w_{41} და ა.შ. კოეფიციენტების კორექტირება, ანუ ამ შეთხვევაში მათი მნიშვნელობების გაზრდა.

ამრიგად, შეგვიძლია ჩამოგაყალიბოთ წონითი კოეფიციენტების კორექტირების შემდეგი იტერაციული პროცედურა:

ბიჯი 1. წარმოვადგინოთ შემავალი სახე და განვსაზღვროთ პერსეპტონის გამოსავალი Y სიგნალი.

ბიჯი 2. ა) თუ გამოსავალი სწორია, მაშინ გადავიდეთ 1 - ბიჯზე.

ბიჯი 2. ბ) თუ გამოსავალი სიგნალი არასწორია და ნულის ტოლია, მაშინ იზრდება გააქტივებული შემომავალი სინალების კოეფიციენტები, მაგალითად, წონით კოეფიციენტებს დაუმატოთ ყველა შემომავალი სინალი:

$$w_j(t+1) = w_j(t) + x_j$$

ბიჯი 2. გ) თუ გამოსავალი სიგნალი არასწორია და ერთის ტოლია, მაშინ საჭიროა შემომავალი სიგნალის წონითი კოეფიციენტების შემცირება, მაგლითად ასე:

$$w_j(t+1) = w_j(t) - x_j$$

ბიჯი 3. გადავიდეთ 1 - ბიჯზე ან დავამთავროთ შესწავლის პროცესი.

მოყვანილ ალორითმში ბიჯ 2. ბ)-ს უწოდებენ ჰების პირველ წესს, ხოლო ბიჯ 2. გ) – ჰების მეორე წესს. ეს ალორითმი პირველად შემოვთავაზა ჰებმა 1949წ. უნდა შევნიშნოთ, რომ ჰების წესი მოგვაგონებს ცხოველების გაწვრთნის „მათრახი – ტებილეული” – ის მეთოდს ან ბავშვის აღზრდის პროცესს წახალისებისა და დასჯის პრინციპის გამოყენებას.

ზემოდ განხილული სწავლების ალორითმი შეიძლება წარმოვადინოთ ზოგადი ფორმის სახით. თუ d – თი აღვნიშნავთ საჭირო გამოსავალ სინალს, მაშინ ყველ იტერაციაზე შესაძლებელია განისაზღვროს სხვაობა საჭირო d სიგნალსა და რეალურ Y სიგნალს შორის ე.ი. $e = (d - Y)$. როცა $e = 0$, მაშინ ის შეესაბამება ბიჯ 2. ა)-ს იმ შემთხვევაში, როცა გამოსავალი სიდიდე ჭეშმარიტია. როცა $e > 0$ შეესაბამება ბიჯ 2. ბ), ხოლო როცა $e < 0$ შეესაბამება ბიჯ 2. გ) – ს.

პერსეპტონის წავლების ალგორითმი ჰების წესის საშუალებით რჩება, თუ იტერაციულ პროცესს წარვმართავთ შემდეგი ფორმულებით:

$$w_j(t+1) = w_j(t) + \Delta w_j$$

$$\Delta w_j = ex_j$$

სადაც $w_j(t)$ და $w_j(t+1)$ შესაბამისად პერსეპტონის კოეფიციენტების მველი და ახალი მნიშვნელობებია, j - შემავალი სიგნალის რიგითი ნომერია.

შესაძლებელია მივიღოთ ანალოგიური იტერაციული ფორმულა ნეირონის T ზღვრული მნიშვნელობის რეულირებისათვის, თუკი მას განვიხილავთ, როგოც ნეირონის დამატებითი შემომავალი x_0 სინალის წონით კოეფიციენტად. x_0 სინალის მნიშვნელობა -1 ტოლია.

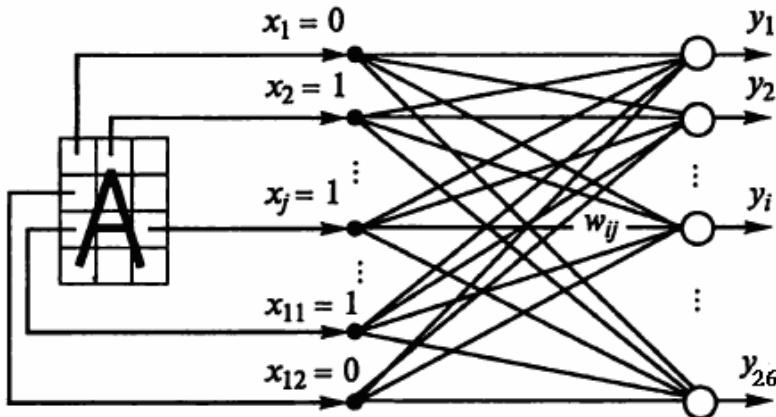
$$T(t+1) = T(t) + \Delta T, \quad \Delta T = -e.$$

იტერაციულ ფორმულებში შესაძლებელია სწავლების | კოეფიციენტის შემოტანა, რომლის საშუალებითაც შესაძლებელია წონით კოეფიციენტების კორექტირება

$$\Delta w_j = l e x_j, \quad \Delta T = -l e.$$

პერსეპტრონის სწავლების ალგორითმს, რომელიც იყენებს ამ ფორმულებს, ეწოდება დელტა-წესი.

ქემოთ მოყანილ ნახაზზე წარმოდგენილია პერსეპტრონის სქემა, რომელიც განკუთვნილია ლათინური ალფავიტის ასოების გასარჩევად. ასეთ პერსეპტრონს გააჩნია 26 ნეირონი, კ.ი. ალფავიტის თითოეულ ასოს შეესაბამება ერთი ნეირონი. ითვლება, რომ პირველი ნეირონის გამოსავალი y_1 უნდა იყოს ერთის ტოლი როცა პერსეპტრონს გასარჩევად მიეწოდება ასო „A“ და ნების ტოლი ყველა დანარჩენი ასოებისათვის. მეორე ნეირონის გამოსავალი y_2 უნდა იყოს ერთის ტოლი როცა ნეირონს „B“ ასო მიეწოდება და ნების ტოლი ყველა დანარჩენი ასოებისათვის და ა.შ.



მოცემული პერსეპტრონის სწავლების ალგორითმი შედგება შემდეგი ბიჯებისაგან:

1. შემთხვევითი რიცხვების გადამწოდით ნეირონების ყველა წონით კოეფიციენტებს w_{ij} და ზღვრულ T_i სიდიდეებს მიენიჭებათ რაიმე მცირე მნიშვნელობები.

2. პერსეპტრონს მიეწოდება ალფავიტის რომელიე ასო და ფოტოელემენტების სისტემის საშუალებით გამოიმუშავებს გამოსავალ ვექტორს $x_j, j = 1, 2, \dots, 12$.

3. თითოეული ნეირონი აწარმოებს შემომავალი სიგნალების აჯამვას:

$$R_i = \sum_{j=1}^{12} w_{ij} x_j$$

და გამოიმუშავებს გამომავალ სინალს $y_i = 1$, როცა $R_i \geq T_i$ და $y_i = 0$, როცა $R_i < T_i$.

4. ყოველი ნეირონისათვის განისაზღვრება ცდომილება:

$$e_i = (d_i - y_i),$$

სადაც d_i - პერსეპტრონის სწორი პასუხის ვექტორია (მაგალითად, „A“ ასოსათვის

$d_1=1, d_2=0, \dots, d_{26}=0$.

5. ხდება ნეირონის წონითი კოეფიციენტების და ზღვრული მნიშვნელობების კორექტირება:

$$\begin{aligned} w_{ij}(t+1) &= w_{ij}(t) + \Delta w_{ij}, \quad \Delta w_{ij} = |e_i x_j|, \\ T_i(t+1) &= R_i(t) + \Delta R_i, \quad \Delta T_i = -|e_i|, \end{aligned}$$

სადაც t – იტერაციის რიცხვი, n მოქმედია.

6. გავიმეოროთ $2 - 5$ ბიჯები საჭირო რაოდენობამდე.

ზემოდ მოყვანილი პერსეპტრონის სქემა, რომელიც განცუთვნილია ალფავიტის ასოების გასარჩევად, შეიძლება გამოვიყენოთ სხვა პრაქტიკული ამოცანების, მაგალითად, სამედიცინო დიაგნოსტიკური ამოცანების გადასაწყვეტად. ყველაფერი დამოკიდებულია იმაზე, თუ რა აზრს მივანიჭებთ შემომავალ x_i და გამომავალ y_i სიგნალებს.

გადასაწყვეტი ამოცანების სფერო მნიშვნელოვნად გაფართოვდება თუკი პერსეპტრონს ვასწავლით არა მარტო ბინარული მნიშვნელობების (0 და 1), არამედ უწყვეტი სიგნალების გამოტანასაც. ასეთი განზოგადოებული პერსეპტრონის შექმნა შესაძლებელია, თუკი აქტივაციის ფუნქციად გამოვიყენებთ არა კიბისებურ, არამედ სიგმაიდალურ ფუნქციას. პრაქტიკულად სიგმაიდალური ფუნქცია უზრუნველყოფს კლასიკური ზღვრული ფუნქციის აპროქსიმაციას.

შემოვიტანოთ რამოდენიმე განსაზღვრება. პერსეპტრონს ეწოდება ადალაინი, როცა მას გააჩნია ერთი გამოსავალი და სიგმაიდალური აქტივაციის ფუნქცია. თუ პერსეპტრონს გააჩნია მრავალი გამოსავალი, მაშინ მას ეწოდება მადალაინი (ინგლისური სიტყვებიდან *ADaptive Linear NEuron* და *Many ADALINE*). ასეთი უწყვეტი აქტივაციური ფუნქციის პერსეპტრონის გამოჩენამ გამოიწვია მისი სწავლების მიმართ ახლებური მიდგომა. უიდროუმ და ხოფმა შემოგთავაზეს საჭირო d_i და რეალური y_i გამოსავალი სიგნალების სხვაობების საშუალო კვადრატული ცდომილების მინიმიზაცია:

$$e = \frac{1}{2} \sum_{i=1}^N (d_i - y_i)^2,$$

სადაც N – პერსეპტრონის გამოსავალი არხების რაოდენობაა.

ასეთი ოპტიმიზაციის ამოცანის გადაწყვეტა შესაძლებელია არაწრფივი დაპროგრამების მეთოდებით, მაგალითად, გრადიენტის მეთოდით, რომელსაც მივყევართ ნეირონის სწავლების შემდეგ იტერაციულ ფორმულებამდე:

$$w_{ij}(t+1) = w_{ij}(t) + \Delta w_{ij},$$

სადაც $\Delta w_{ij} = |d_i x_j|, d_i = (d_i - y_i)y_i(1 - y_i)$.

ამ ალგორითმს ეწოდება დელტა – წესის განზოგადოებული ალგორითმი, რომლის უპირატესობა მდგომარეობს იტერაციის უფრო სწრაფ კრებადობაში და შემავალი და გამომავალი უწყვეტი სიგნალების უფრო ზესტ დამუშავებაში.

4.4.2 ერთშრიანი ნეირონული ქსელის შეზღუდვა

როგორც უკვე ავღნიშეთ, ფ. როზენბლანტმა შესძლო ერთშრიანი პერსეპტრონის საშუალებით ალფავიტის ასოების გარჩევა. ეს იმ დროისათვის იყო მნიშვნელობანი მიღწევა და წინგადადგმული ნაბიჯი ადამიანის აზროვნების შემეცნების სფეროში. მაგრამ, პერსეპტრონის მიერ გადასაწყვეტი ამოცანების სფერო თანდათან

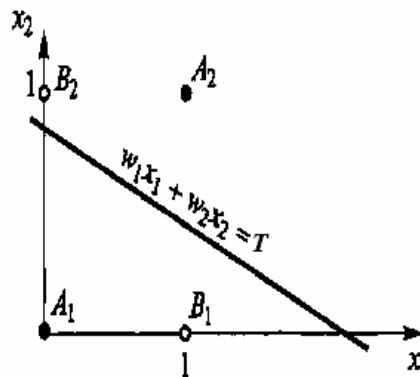
ფართოვდებოდა. სამეცნიერო სფეროს გაშლასთან ერთად წარმოიშვა სიძნელეები, კერძოდ აღმოჩნდა, რომ ზოგიერთი ახალი ამოცანის გადაწყვეტა პერსეპტორნის არ შეუძლია, თუმცა ეს ამოცანები გარეგნულად მნიშვნელოვნად არ განსხვავდებოდნენ იმ ამოცანებისაგან, რომლებსაც პერსეპტორნი წარმატებულად წყვეტდა. საჭირო გახდა წარმოშობილი პარადოქსის ახსნა, სიღრმისეული ანალიზი და ნეირონული ქსელის თეორიული ბაზის შექმნა.

პერსეპტორნის განვითარების შემდეგი ეტაპი იყო მ.მინსკის და ს.პაიპერტის წიგნის „პერსეპტორნები“-ს გამოქვეყნება. ამ წიგნში მათემატიკური სიზუსტით დამტკიცებული იყო ის, რომ ერთშრიან პერსეპტორნის არ ძალუმს მრავალი პრაქტიკული ამოცანების გადაწყვეტა. მათ შორის იყო ლოგიკური ოპერაციის „გამომრიცხავი ან“-ის რეალიზაცია.

„გამომრიცხავი ან“ წარმოადგენს ბულის ორარგუმენტიან ფუნქციას, რომელმაც შეიძლება მიიღოს „ჭეშმარიტი“ ან „მცდარი“ მნიშვნელობა. „ჭეშმარიტ“ მნიშვნელობას ფუნქცია დებულობს მაშინ, როცა ფუნქციის ერთ-ერთი არგუმენტი (და არა ორივე) არის „ჭეშმარიტი“. სხვა შემთხვევებში ფუნქცია დებულობს „მცდარ“ მნიშვნელობას. ფუნქციას აქვს შემდეგი სახე:

$$y = (x_1 \wedge x_2) \vee (x_2 \wedge x_1) \quad (1)$$

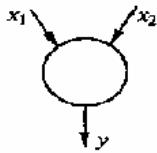
ამოცანა მდგომარეობს ერთშრიანი პერსეპტორით მოვახდინოთ (1) ფუნქციის რეალიზაცია თუ ავღნიშნავთ „ჭეშმარიტ“ სიდიდეს ერთით, ხოლო „მცდარს“ ნულით, მაშინ შემავალი სინალების ყველა შესაძლო კომბინაციები (x_1, x_2) სიბრტყეზე შეიძლება წარმოვადგინოთ ოთხი A_1, A_2, B_1, B_2 წერტილის სახით, როგორც ეს ნაჩვენებია შემდეგ ნახაზზე:



მაგალითად, A_1 წერტილს შეესაბამება შემავალი სიგნალების $x_1 = 0$ და $x_2 = 0$ მნიშვნელობები, ხოლო A_2 წერტილს კი $x_1 = 1$ და $x_2 = 1$. (1) ფორმულის თანახმად, პერსეპტორნის შემავალი და გამომავალი სიგნალების შესაბამისობები მოყვანილია შემდეგ ცხრილში:

წერტილი	x_1	x_2	y
A_1	0	0	0
A_2	1	1	0
B_1	1	0	1
B_2	0	1	1

ერთშრიანი პერსეპტორი, რომელიც გამოსახულია ქვემოთ მოყვანილ ნახაზზე,



აწარმოებს შემდეგ გარდაქმნებს: $R = w_1x_1 + w_2x_2 \quad (2)$. $y = 1$, როცა $R \geq T$ და $y = 0$, როცა $R < T$. თუ (2) განტოლებაში R -ს შევცვლით T -თი, მაშინ მივიღებთ: $w_1x_1 + w_2x_2 = T \quad (3)$.

თუ მიღებულ (3) განტოლებაში x_1 და x_2 ცვლადებია, ხოლო T , w_1 და w_2 მუდმივები, მაშინ (x_1, x_2) სბრტყები (3)

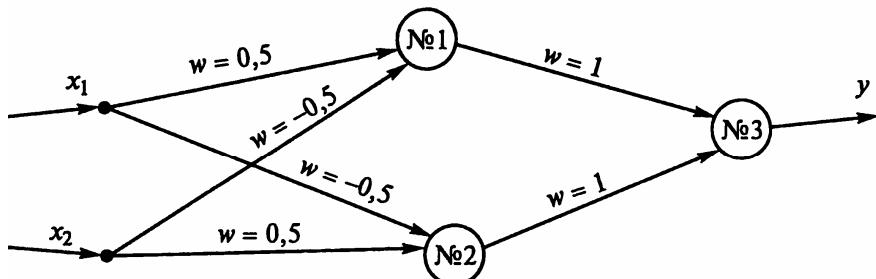
განტოლება გამოისახება სწორი ხაზით, რომლის დახრილობა განისაზღვრება w_1 და w_2 წონითი კოეფიციენტებით და T ზღვრული მნიშვნელობით. იმ წერტილებებისათვის, რომლებიც ამ სწორ საზოეპლოებების გამოსავალი ერთის ტოლია. იმ წერტილებისათვის, რომლებიც განლაგებულნი არიან სწორი ხაზის ქვემოთ პერსეპტორის გამოსავალი სიდიდე ნულის ტოლია. იმ წერტილებისათვის, რომლებიც განლაგებულნი არიან სწორი ხაზის ზემოთ პერსეპტორის გამოსავალი სიდიდე ერთის ტოლია. აქედან გამომდინარე, (3) განტოლებას უწოდებენ ზღვრულ სწორ ხაზს.

ზემოდ მოყვანილი ცხრილის თანახმად, A_1 და A_2 წერტილებში პერსეპტორის გამოსავალი უნდა იყოს ნულის ტოლი, ხოლო B_1 და B_2 წერტილებში – ერთის ტოლი. მაგრამ, ამისათვის ზღვრული სწორი ხაზი ისე უნდა იყოს წარმოდგენილი, რომ A_1 და A_2 წერტილები უნდა იმყოფებოდნენ ამ ხაზის ქვემოთ, ხოლო B_1 და B_2 წერტილები – ზემოთ, რაც ყოვლად შეუძლებელია. ეს იმას ნიშნავს, რომ რა მნიშვნელობებიც არ უნდა მიგანიჭოთ წონით კოეფიციენტებს და ზღურბლს, ერთშრიან ნეირონულ ქსელებს არ შეუძლია „გამომრიცხავი ან“ ფუნქციის წარმოდგენა.

გარდა „გამომრიცხავი ან“ ფუნქციის რეალიზების პრობლემისა, მ.მინსკის წიგნში მოყვანილია სხვა ამოცანებიც, რომელთა გარჩევა ერთშრიან ნეირონულ სელებს არ შეუძლიათ.

4.4.3 მრავალშრიანი პერსეპტორის სწავლება

„პერსეპტორები“ წიგნის გამოსვლამ მეცნიერებს შორის გამოიწვია შოკი. საყოველთაო ოპტიმიზმი შეცვალა პესიმიზმა, რამაც გამოიწვია ნეირონული ქსელის განვითარების გარკვეული შეფერხება. მიუხედავად ამისა, ცალკეული მეცნიერები მაინც განაგრძობდნენ მეცნიერულ კვლევებს. ბევრ მკვლევარს ესმოდა, რომ საჭირო იყო პერსეპტორის სტრუქტურის გართულება. აღმოჩნდა, რომ „გამომრიცხავი ან“ ფუნქციის პრობლემა შეიძლება გადაწყდეს ორშრიანი ნეირონული ქსელის საშუალებით, მაგალითად ისე, როგორც ეს წარმოდგენილია შემდეგ ნახაზზე:



წარმოდგენილი პერსეპტორის მუშაობა სრულდება შემდეგი ალგორითმით:

$$\text{პერსეპტორი } 1 : \quad R_1 = 0,5x_1 + (-0,5)x_2,$$

$$y_1 = 1, \text{ როცა } R_1 \geq T,$$

$$y_1 = 0, \text{ როცა } R_1 < T.$$

პერსეპტონი 2 : $R_2 = (-0,5)x_1 + 0,5x_2,$
 $y_2 = 1, \text{ როცა } R_2 \geq T,$
 $y_2 = 0, \text{ როცა } R_2 < T.$

პერსეპტონი 3 : $R_3 = 1y_1 + 1y_2,$
 $y_3 = 1, \text{ როცა } R_3 \geq T,$
 $y_3 = 0, \text{ როცა } R_3 < T.$

ამ ფორმულების საშუალებით, ადვილად შეიძლება წარმოვადგინოთ პერსეპტონის შემავალი და გამომავალი სიგნალების შესაბამისობები მოცემული $T=0,5$ ზღვრული მნიშვნელობისათვის შემდეგ ცხრილში:

x_1	x_2	R_1	R_2	y_1	y_2	R_3	y_3	y
0	0	0	0	0	0	0	0	0
0	1	-0,5	0,5	0	1	1	1	1
1	0	0,5	-0,5	1	0	1	1	1
1	1	0	0	0	0	0	0	0

მკვლევარებს ესმოდათ, რომ მრავალშრიანი ნეირონული ქსელები აფართოებენ ამოსახსნელ ამოცანათა კლასს, მაგრამ პრობლემა იქნებოდა ასეთი ნეირონული ქსელების სწავლება. მარტივი პონის წესი და მისი მოდიფიცირებული დელტა – წესი ვარგოდა მხოლოდ გამოსავალი შრის ნეირონების წონითი კოეფიციენტების კორექტირებისათვის, მაშინ როცა ნეირონული ქსელის შიგა(ფარული) შრეებისათვის იგი გამოუსადეგარი იყო.

მრავალშრიანი ნეირონული ქსელის სწავლების ეფექტული ალგორითმი შეიქმნა 1986წ., რომელსაც ეწოდება ცდომილების უკუგავრცელების ალგორითმი. მეთოდმა თავისი დასახელება მიიღო იმიტომ, რომ მისი ფუნქციონების დროს ქსელის გამოსავალი ცდომილება, რომელიც განისაზღვრება იტერაციის ყოველ ბიჯზე, გაერცელდება ნეირონულ ქსელში გამოსავალი შრიდან შემოსასვლელამდე (ე.ი. სიგნალის გავრცელების საწინაღმდეგოდ). სწორედ ამ დროს ხდება ფარული შრეების ნეირონების წონითი კოეფიციენტების განსაზღვრა.

V. ობიექტების ფინასორი დამუშავება

5.1 ობიექტების გარდაშვილა და პარამეტრების მოწვევიბება

გარჩევის პროცესის პირველი ეტაპი ძირითადად საწყისი პარამეტრების (ნიშნების) სიმრავლის არჩევის ამოცანაა. მისწრაფება რაც შეიძლება მეტი ინფორმაცია მოვიპოვოთ ობიექტის აღსაწერად, იწვევს ინფორმაციის სიჭარბეს, რაც თავის მხრივ იწვევს გარკვეულ უარყოფით შედეგებს, როგორიცაა გამოთვლების მოცულობისა და დროის გაზრდა.

საწყის ნიშანთა სიმრავლის ფორმირება მნიშვნელოვნად არის დამოკიდებული ანალიზის მეთოდზე. ასე მაგალითად, მედიცინაში რომელიმე დავადების დიაგნოსტიკისათვის შესაძლოა გამოვიყენით ანალიზის სხვადასხვა მეთოდი: რენდგენის სხივები, ულტრაბეგერითი, ოპტიკური, სიმპტომატიკური, ქიმიურ-ბიოლოგიური და ა.შ., რომლებიც განსხვავებულ პარამეტრთა სიმრავლეს გვაძლევენ. გარდა ამისა, გარჩევის სისტემაში, რომლის ძირითადი სტრუქტურული ელემენტია კომპიუტერია, აუცილებელი გახდა გაზომვით მიღებული შედეგების ისეთი გარდაქმნა, რომ შესაძლებელი ყოფილიყო ამ მონაცემების კომპიუტერში შეტანა. ამის გამო. ზოგიერთ შემთხვევაში საჭირო გახდა ანალიზის მეთოდის ან გადამწოდების შეცვლაც.

ამრიგად, გაზომვის პროცესის შემდეგ გვაქვს ინფორმაციის წინასწარი დამუშავების პროცედურები. აქ იგულისხმება არტეფაქტების ფილტრაცია, არადამახასიათებელი ელემენტების მოცილება, მასშტაბირება, ჭარბი ინფორმაციის უგულებელყოფა და საერთოდ, პირველადი ანალიზით მიღებული შედეგების გაუმჯობესება ინფორმატიული პარამეტრების გამოვლენის გზით. ანალიზის საბოლოო პროცედურა შეიძლება იყოს სახეთა რეალიზაციების სასწავლო და საგამოცდო ამონარჩევების ფორმირება. რეალიზაციათა რაოდენობა ამ ამონარჩევებში უნდა აქმაყოფილებდეს წარმომადგენლობითობის (რეპრეზენტატიულობის) პირობას, რაც თავის მხრივ, მნიშვნელობნად არის დამოკიდებული შერჩეულ ნიშანთა სიმრავლის სიმძლავრეზე.

ამრიგად, ნებისმიერი ტიპის სახეთა გარჩევის სისტემის სინთეზის დროს სასურველია გადაიჭრას პარამეტრთა შერჩევის და ობიექტთა განზომილების შემცირების საკითხები.

რეალიზაციის ყველა პარამეტრი არ წარმოადგენს მნიშვნელოვანს სახეთა გარჩევის ამოცანის გადაწყვეტისათვის. კლასების რეალიზაციების შედარებისას, ის პარამეტრები, რომლებიც მნიშვნელოვნად იცვლებიან უნდა გააჩნდეთ დიდი წონითი კოეფიციენტები, ხოლო იმ პარამეტრებს, რომლებიც ნაკლებად იცვლებიან – მცირე წონითი კოეფიციენტები. აქედან გამომდინარე, ეგკლიდეს მანძილი ორ X_i და X_j რეალიზაციას შორის შეიძლება განისაზღვროს შემდეგი ფორმულით:

$$d^2(X_i, X_j) = \sum_{k=1}^n w_{kk}^2 (x_{ki} - x_{kj})^2, \quad (1)$$

სადაც w_{kk} წარმოადგენს წონით კოეფიციენტებს. საჭიროა მოიძებნოს წონითი კოეფიციენტების ისეთი მნიშვნელობები, რომლებიც მოახდენენ (1) გამოსახულების მინიმიზაციას (ან მაქსიმიზაციას) იმის მიხედვით თუ რა ტიპის ამოცანასთან გვაქვს საქმე. ასეთი ამოცანების გადასაწყვეტად საჭიროა მოვახდინოთ წრფივი გარდაქმნა. დაუშვათ გვაქვს ორი $a = (a_1, a_2, \dots, a_n)$ და $b = (b_1, b_2, \dots, b_n)$ ვექტორი, რომელთა მიმართ ჩატარდა გარდაქმნა და მივიღეთ a^* და b^* ვექტორები:

$$a^* = Wa, \quad b^* = Wb,$$

სადაც

$$W = \begin{bmatrix} w_{11} & w_{12} & \dots & w_{1n} \\ w_{21} & w_{22} & \dots & w_{2n} \\ \hline \hline & \dots & \dots & \dots \\ w_{n1} & w_{n2} & \dots & w_{nn} \end{bmatrix}$$

წარმოადგენს გარდაქმნის მატრიცას, რომლის ელემენტებია წონითი კოეფიციენტები. ამოცანა მდგომარეობს W მატრიცის ელემენტების განსაზღვრაში.

იმისათვის, რომ განისაზღვროს W მატრიცის ელემენტები, საჭიროა წონით კოეფიციენტებს დაედოთ დამატებითი შეზღუდვები. განვიხილოთ ორი შემთხვევა.

1. შეზღუდვა $\sum_{k=1}^n w_{kk} = 1$, რომელსაც მივყევართ W გარდაქმნის მატრიცის ელემენტების განსაზღვრის შემდეგ გამოსახულებამდე:

$$w_{kk} = \frac{1}{S_k^2 \sum_{k=1}^n \frac{1}{S_k^2}}, \quad (2)$$

სადაც S_k^2 – დისპერსია. როგორც (2) გამოსახულებიდან ჩანს, იმ პარამეტრებს, რომელთა დისპერსიები დიდად იცვლებიან გააჩნიათ ნაკლები სიდიდის წონითი კოეფიციენტები, ხოლო იმ პარამეტრებს, რომლებიც ნაკლებად იცვლებიან დიდი წონითი კოეფიციენტები.

ეს შემთხვევა ახდენს რეალიზაციის პარამეტრების წონითი კოეფიციენტების ნორმირებას [0,1] ინტერვალში და მათი ჯამი ერთის ტოლია, რაც მეტად პოპულარულს ხდის პრაქტიკაში მის გამოყენებას. უნდა გვახსოვთ ეს შეზღუდვა არ არის საქმარისი, ამიტომ იყენებენ შემდეგ შეზღუდვასაც:

2. შეზღუდვა $\prod_{k=1}^n w_{kk} = 1$, რომელსაც მივყავართ შემდეგ გამოსახულებამდე:

$$w_{kk} = \frac{1}{S_k} \left(\prod_{j=1}^n S_j \right)^{\frac{1}{n}}. \quad (3)$$

როგორც ამ ფორმულიდან ჩანს, რეალიზაციის პარამეტრების წონითი კოეფიციენტები საშუალო კვადრატული გადახრის S უკუკროპორციულია.

ამრიგად, (2) და (3) ფორმულები განსაზღვრავენ W გარდაქმნის მატრიცას ზემოდ მოყვანილი შეზღუდების გათვალისწინებით. თუ სახეთა ვექტორები X სივრციდან გადაგვყავს X^* სივრცეში $X^* = WX$, მაშინ X^* სივრცეში ხდება შიგა სიმრავლის მანძილის მინიმიზაცია. თუ მოვახდენთ მეორე გარდაქმნას $X^{**} = ZX^*$, მაშინ შეგვიძლია მოვახდინოთ პარამეტრების შერჩევა.

როგორც (2) და (3) ფორმულებიდან ჩანს, W გარდაქმნის მატრიცის კოეფიციენტების გამოსათვლელად გამოიყენება დისპერსიების შეფასებები, ე.ი. საჭიროა წინასწარ განისაზღვროს კოვარიაციული მატრიცა, რადგან გარდაქმნას X^* სივრცეში კოვარიაციული მატრიცა გადაყავს დიაგონალურში, რომლის ელემენტებია გადაუადგილებადი დისპერსიის შეფასებები.

საზოგადოდ, კოვარიაციული მატრიცის გამოყენებაზე უნდა ითქვას შემდეგი: ალბათობის თეორიიდან ცნობილია, რომ მრავალგანზომილებიანი ნორმალური განაწილება მთლიანად განისაზღვრება მათემატიკური ლოდინის ვექტორით და კოვარიაციული მატრიცით. თავის მხრივ, კოვარიაციული მატრიცა განისაზღვრება საკუთრივი მნიშვნელობებით და საკუთრივი ვექტორებით. ამასთან, საკუთრივი ვექტორი შეგვიძლია განვიხილოთ, როგორც ვექტორი, რომელიც წარმოგვიდგენს განსახილველი სახის თვისებას. კერძოდ, საკუთრივი ვექტორების ნაწილი შეიცავს გარჩევის ამიცანის გადასაწყვეტად მცირე ინფორმაციას, ვიდრე სხვა საკუთრივი ვექტორები და ამიტომ მათი უგულვებელყოფა შესაძლებელია. სწორედ ეს იდეა უდევს საფუძვლად სახეთა გარჩევის ამოცანისათვის ინფორმატიული პარამეტრების და განზომილების შემცირების საკითხების გადაწყვეტას.

პარამეტრთა შერჩევის ამოცანის გადასაწყვეტად იყენებენ კლასშიგა და კლასთაშორისო მანძილების ცნებას. პარამეტრების შერჩევა, როცა გამოიყენება

კლასშიგა მანძილი, შეიძლება განვიხილოთ როგორც კლასტერიზაციის ამოცანა. როგორც ვიცით, კლასშიგა ანუ შიგასიმრავლის მანძილი არის საშუალო კვადრატული მანძილი ერთი კლასის რეალიზაციებს შორის. აქედან გამომდინარე, ჩვენი მიზანია მოვახდინოთ ისეთი გარდაქმნა, რომელიც მოახდენს კლასშიგა მანძილის მინიმიზაციას, ხოლო კლასთაშორისო მანძილის მაქსიმიზაციას. ამისათვის უნდა გამოვიყენოთ კოვარიაციული მატრიცა და რომელიმე შეზღუდვა, მაგალითად პირველი. აღმოჩნდა, რომ კლასშიგა მანძილი წარმოადგენს გლობალურ მინიმუმს თუ გამოვიყენებთ კოვარიაციული მატრიცის m უმცირეს მახასიათებელ რიცხვებს. ქედან გამომდინარე, თუ ჩვენ გვინდა შიგასიმრავლის მანძილის მინიმიზაცია ამისათვის სახის ვექტორებად უნდა ავიდოთ საკუთრივი ვექტორები, რომლებიც შეესაბამებიან კოვარიაციული მატრიცის უმცირეს საკუთრივ მნიშვნელობებს. ამ შემთხვევაში წონითი კოეფიციენტები განისაზღვრებან შემდეგი გამოსახულებით:

$$w_{kk} = \frac{1}{\sum_{j=1}^m \frac{1}{|j|}} ,$$

ხოლო მინიმალური შიგასიმრავლის მანძილი ტოლია:

$$d^2 = 2 \left(\sum_{j=1}^m \frac{1}{|j|} \right) .$$

ამრიგად, კლასშიგა მანძილის გლობალური მინიმუმი მიიღება, თუ $|j|$ მახასიათებელი რიცხვებიდან აღებულია m რაოდენობის უმცირესი მახასიათებელი რიცხვების შესაბამისი საკუთრივი ვექტორები და მათი საშუალებით ხდება გარდაქმნის Z მატრიცის ფორმირება.

განვიხილოთ პარამეტრთა შერჩევის და სახეთა განზომილების შემცირების ზოგიერთი მეთოდები.

5.2 ენტროპიის მინიმიზაციის მეთოდი

განუსაზღვრელობის სტატისტიკურ ზომას ენტროპია ეწოდება. აქედან გამომდინარე, კლასის რეალიზაციების უწესრიგობის ზომად შეიძლება გამოვიყენოთ ენტროპია, რომელიც ასე განისაზღვრება:

$$H = -M[\ln P] ,$$

სადაც P – კლასის რეალიზაციათა ერთობლიობის სიმკვრივეა, M – მათემატიკური ლოდინის ოპერატორი. ენტროპია შეიძლება გამოვიყენოთ, როგორც პარამეტრთა შერჩევის კრიტერიუმი. კერძოდ, ის პარამეტრები, რომლებიც ამცირებენ განუსაზღვრელობას ითვლებიან უფრო ინფორმატიულად, ვიდრე ის პარამეტრები, რომლებიც იძლევიან საწინაღმდეგო შედეგს. აქედან გამომდინარე, უნდა შევარჩიოთ ისეთი პარამეტრების ერთობლიობა. რომლებიც იწვევენ მოცემული კლასების ენტროპიათა მინიმიზაციას. რადგან ეს წესი ექვივალენტურია დისპერსიის მინიმიზაციისა, ამიტომ უნდა ველოდოთ, რომ ენტროპიის მინიმიზაციას გააჩნია კლასტერიზაციის თვისება.

განვიხილოთ m კლასი w_1, w_2, \dots, w_m , რომელთა პირობითი განაწილების სიმკვრივის ფუნქციები ცნობილია $P(X|w_1), P(X|w_2), \dots, P(X|w_m)$, მაშინ i -ური კლასის ენტროპია განისაზღვრება ფორმულით:

$$H_i = - \int_X P(X | w_i) \ln P(X | w_i) dx ,$$

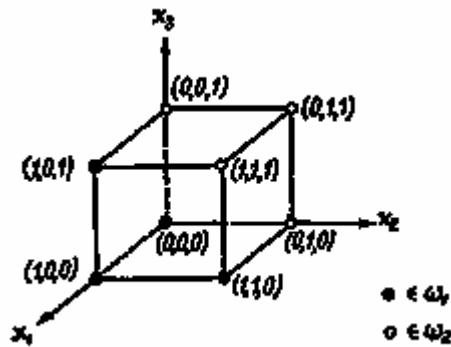
სადაც ინტეგრირება ხდება i -ური კლასის რეალიზაციათა სივრცეში. ცხადია, რომ $P(X | w_i) = 1$, ანუ როცა განუსაზღვრელობა არ არსებობს, ენტროპია გვექნება ნულის ტოლი. ჩავთვალოთ, რომ ყოველი m ერთობლიობა ნორმალურად არის განაწილებული და მათი კოვარიაციული მატრიცები ერთმანეთის ტოლია.

ასეთი დაშვების შემდეგ ამოცანა ჩამოყალიბდება შემდეგნაირად: უნდა განისაზღვროს წრფივი გარდაქმნის Z მატრიცა, რომელსაც მოცემული სახის ვექტორები X გადაყავს უფრო მცირე განზომილების ვექტორებად. ეს გარდაქმნა შეგვიძლია ასე ჩავწეროთ: $Y=ZX$, თანაც გარდაქმნის მატრიცა განისაზღვრება სახეთა ერთობლიობის ენტროპიის მინიმიზაციით. აქ X არის n -განზომილებიანი, ხოლო Y m -განზომილებიანი ($m < n$) ვექტორები. საჭიროა ისეთი m რაოდენობის ვექტორის მოძებნა, რომელიც X ვექტორს გადაიყვანს Y ვექტორში ისე, რომ მოახდინოს ენტროპიის მინიმიზაცია.

დადგინდა, რომ ენტროპიის მინიმიზაცია მიიღწევა იმ შემთხვევაში, თუ გარდაქმნის Z მატრიცა შედგება m რაოდენობის ნორმირებული საკუთრივი ვექტორებისაგან, რომლებიც შეესაბამებიან კოვარიაციული მატრიცის საკუთრივი მახასიათებელ რიცხვების მინიმალურ მნიშვნელობას.

ამრიგად, პარამეტრების გამოყოფის პროცედურა დაიყვანება კოვარიაციული მატრიცის საკუთრივ მნიშვნელობებისა და საკუთრივი ვექტორების განსაზღვრაში.

მიღებული პროცედურა განვიხილოთ მარტივ მაგალითზე. ვთქვათ, საჭიროა მოცემული სახეთა ერთობლიობის განზომილების შემცირება ენტროპიის მინიმიზაციის მეთოდით. დაუშვათ, მოცემულია ორი w_1 და w_2 კლასი და მათში შემავალი ოთხი სამგანზომილებიანი რეალიზაციები ისე, როგორც ეს მოცემულია შემდეგ ნახაზზე:



განვსაზღვროთ მათემატიკური ლოდინის ვექტორის და კოვარიაციული მატრიცის შეფასებები შემდეგი ფორმულებით:

$$m_i = \frac{1}{n_i} \sum_{j=1}^{n_i} X_{ij} , \quad C_i = \frac{1}{n_i} \sum_{j=1}^{n_i} X_{ij} X_{ij}^T - m_i m_i^T ,$$

სადაც $n_i = w_i$ კლასის რეალიზაციათა რაოდენობაა. ამ ფორმულების გამოყენებით მივიღებთ:

$$m_1 = \frac{1}{4} (3, 1, 1)^T , \quad m_2 = \frac{1}{4} (1, 3, 3)^T . \quad C = C_1 = C_2 = \frac{1}{16} \begin{bmatrix} 3 & 1 & 1 \\ 1 & 3 & -1 \\ 1 & -1 & 3 \end{bmatrix} .$$

კოვარიაციის C მატრიცის მახასიათებელი რიცხვებია: $|_1 = \frac{1}{16}$, $|_2 = |_3 = \frac{1}{4}$, ხოლო მათი შესაბამისი საკუთრივი ვექტორებია:

$$e_1 = \frac{1}{\sqrt{3}}(1, -1, -1)', \quad e_2 = \frac{1}{\sqrt{6}}(2, 1, 1)', \quad e_3 = \frac{1}{\sqrt{2}}(0, 1, -1)' .$$

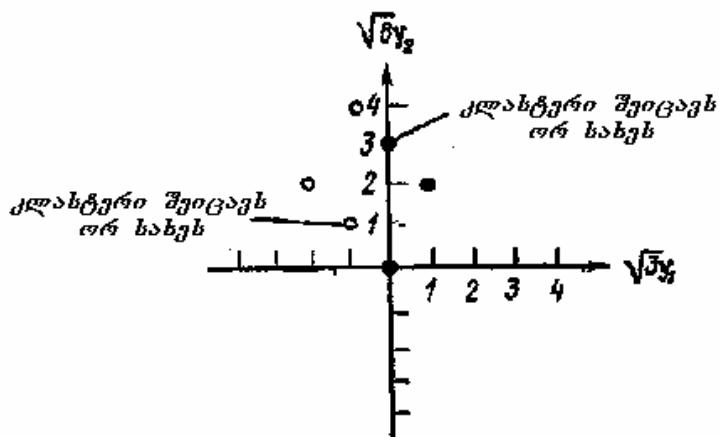
გარდაქმნის Z მარტიცისათვის ავიდოთ e_1 და e_2 საკუთრივი ვექტორები, მაშინ მივიღებთ:

$$Z = \begin{pmatrix} e_1 \\ e_2 \\ e_3 \end{pmatrix} = \begin{bmatrix} \frac{1}{\sqrt{3}} & -\frac{1}{\sqrt{3}} & \frac{1}{\sqrt{3}} \\ \frac{2}{\sqrt{6}} & \frac{1}{\sqrt{6}} & \frac{1}{\sqrt{6}} \end{bmatrix}.$$

თუ გამოვიყენებთ $Y = ZX$ წრფივ გარდაქმნას, მივიღებთ;

w_1	w_2
$y_{11} = (0, 0)'$	$y_{21} = \left(\frac{1}{\sqrt{3}}, \frac{1}{\sqrt{6}}\right)'$
$y_{12} = \left(\frac{1}{\sqrt{3}}, \frac{2}{\sqrt{6}}\right)'$	$y_{22} = \left(-\frac{1}{\sqrt{3}}, \frac{1}{\sqrt{6}}\right)'$
$y_{13} = \left(0, \frac{3}{\sqrt{6}}\right)'$	$y_{23} = \left(-\frac{2}{\sqrt{3}}, \frac{2}{\sqrt{6}}\right)'$
$y_{14} = \left(0, \frac{3}{\sqrt{6}}\right)'$	$y_{24} = \left(-\frac{1}{\sqrt{3}}, \frac{4}{\sqrt{6}}\right)'$

შემცირებული განზომილების სახეები წარმოდგენილია შემდეგ ნახაზზე, სადაც თვალნათლივ ჩანს კლასტერიზაციის ეფექტი.

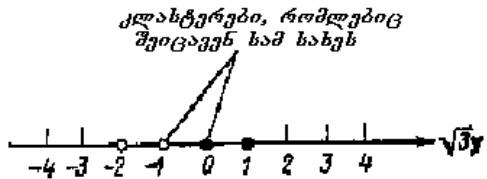


განზომილების შემდეგი შემცირებისათვის ავიდოთ მხოლოდ e_1 ვექტორი, მაშინ მივიღებთ:

$$Z = e'_1 = \frac{1}{\sqrt{3}}(1, -1, -1)'$$

გარდაქმნის გამოყენების შემდეგ მივიღებთ:

W_1	W_2
$y_{11} = 0$	$y_{21} = -\frac{1}{\sqrt{3}}$
$y_{12} = \frac{1}{\sqrt{3}}$	$y_{22} = -\frac{1}{\sqrt{3}}$
$y_{13} = 0$	$y_{23} = -\frac{2}{\sqrt{3}}$
$y_{14} = 0$	$y_{24} = -\frac{1}{\sqrt{3}}$



როგორც ნახაზიდან ჩანს, კლასტერიზაციის ეფექტი შენარჩუნებულია.

5.3 პარამეტრული გამლის მეთოდი

ენტროპიის მინიმიზაციის მეთოდი ეფუძნება ობიექტების ნორმალურ განაწილების კანონს. თუ ეს პირობა დარღვევულია, მაშინ უნდა გამოვიყენოთ სხვა მეთოდები, კერძოდ ორთოგონალური ფუნქციებით გაშლის მეთოდი. ჩვენ განვიხილავთ კარუნენა-ლოგვას გაშლის მეთოდს, რომელიც არ მოითხოვს განაწილების სიმკვრივის ფუნქციის ცოდნას.

ცნობილია, რომ არაპერიოდული შემთხვევი პროცესის რეალიზაციის უშუალოდ წარმოდგენა ფურიეს მწვრივის ურთიერთდამოუკიდებელი კოეფიციენტების საშუალებით არ შეიძლება, მაგრამ ასეთი პროცესის წარმოდგენა შესაძლებელია ორთოგონალური ფუნქციების მწვრივად გაშლის შედეგად, რომლებსაც გააჩნიათ ურთიერთდამოუკიდებელი კოეფიციენტები. ასეთ პროცედურას ხშირად კარუნენა-ლოგვას გაშლის მეთოდს უწოდებენ.

განვიხილოთ m რაოდენობის კლასი W_1, W_2, \dots, W_m , რომლებიც შედგებიან უწყვეტი შემთხვევითი პროცესის რეალიზაციებისაგან $x_i(t)$, $T_1 \leq t \leq T_2$, $i = 1, 2, \dots, m$, მაშინ $x_i(t)$ გაშლა შეიძლება ასე წარმოვადგინოთ:

$$x_i(t) = \sum_{j=1}^{\infty} c_{ij} f_j(t), \quad (1)$$

სადაც c_{ij} შემთხვევითი კოეფიციენტია, რომლებიც აკმაყოფილებენ შემდეგ პირობას: $M[c_{ij}] = 0$, $f_j(t) - \text{ბაზისური ორთოგონალური ფუნქციებია}$.

თუ განვიხილავთ დისკრეტულ შემთხვევას, მაშინ (1) გამოსახულება ასე ჩაიწერება:

$$X_i = \sum_{j=1}^n c_{ij} f_j, \quad (2)$$

სადაც $X_i = (x_1(t_1), x_2(t_2), \dots, x_n(t_n))'$, ხოლო ბაზისური გექტორი $\Phi_j = (f_1(t_1), f_2(t_2), \dots, f_n(t_n))'$. გაშლის კოეფიციენტები განისაზღვრებიან შემდეგნაირად:

თუ კოეფიციენტები ასრულებენ $M[c_{ij}] = 0$ პირობას, მაშინ (2) გამოსახულების მატრიცული სახე იქნება $X_i = \Phi C_i$, სადაც $\Phi = (f_1, f_2, \dots, f_n)'$. გაშლის კოეფიციენტები განისაზღვრებიან შემდეგნაირად: $c_i = \Phi' X_i$. (3)

აღმოჩნდა, რომ ბაზისური გექტორი f_j წარმოადგენს კორელაციური მატრიცის საკუთრივ გექტორს, რომელიც შეესაბამება j -ურ მახასიათებელ რიცხვს. რადგან ბაზისური გექტორები წარმოადგენენ ნამდვილ სიმეტრიულ კორელაციური მატრიცის საკუთრივ გექტორებს, ამიტომ ისინი ორთოგონალურნი არიან. გარდა ამისა, ისინი ორთონორმირებულნიც არიან. ე.ი.

$$f_j/f_k = \begin{cases} 1, & j = k \\ 0, & j \neq k \end{cases}$$

აქედან გამომდინარე, კარუნენა-ლოევას გაშლის მეთოდი პარამეტრთა შერჩევის და განზომილების შემცირების ამოცანის გადასაწყვეტად, შეგვიძლია განვიხილოთ როგორც წრფივი გარდაქმნა. თუ (3) გამოსახულებაში Φ მატრიცის განზომილებაა $m \times n$ და X წარმოადგენს n -განზომილებიან გექტორს, მაშინ ცხადია, რომ c_i კოეფიციენტების განზომილება იქნება $p < n$.

დამტკიცებულია, რომ კარუნენა-ლოევას გაშლა ოპტიმალურია როცა Φ გარდაქმნის მატრიცის სვეტებად აღებულია m რაოდენობის ($p < n$) ნორმირებული საკუთრივი გექტორები, რომლებიც შეესაბამებიან კორელაციური მატრიცის უდიდეს მახასიათებელ რიცხვებს. ამრიგად, თუ დაუშვებთ, რომ $Y = C$, მაშინ ნებისმიერი X გექტორის განზომილების შემცირება განისაზღვრება როგორც $Y = ZX$ წრფივი გარდაქმნა, სადაც $Z = \Phi'$.

ამრიგად, დისკრეტული კარუნენა-ლოევას გაშლის მეთოდი გამოიყენება მოცემული კლასების რეალიზაციათა ერთობლიობის განზომილების შესამცირებლად და შედგება შემდეგი ეტაპებისაგან:

1. განისაზღვრება გაერთიანებული კორელაციური მატრიცა

$$R = \sum_{i=1}^m P(A_i) M[X_i X_i'] ,$$

სადაც $P(A_i) - W_i$ კლასის აპრიორული ალბათობაა.

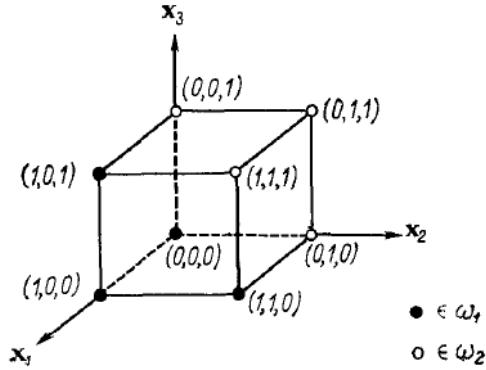
2. გამოითვლება კორელაციური მატრიცის საკუთრივი რიცხვები და საკუთრივი გექტორები.

3. შეირჩევა უდიდესი საკუთრივი რიცხვების შესაბამისი საკუთრივი გექტორები და ფორმირდება გარდაქმნის F მატრიცა.

4. (3) ფორმულით განისაზღვრება კარუნენა-ლოევას გაშლის კოეფიციენტები, რომლებიც გვაძლევენ სახეთა რეალიზაციებს შემცირებული განზომილებით.

კარუნენა-ლოევას გაშლის მეთოდს გააჩნია შემდეგი ოპტიმალური თვისებები: სასრულო რაოდენობის ბაზისური ფუნქციებით მიიღწევა საშუალო კვადრატული ცდომილების მინიმიზაცია და იგი ახდენს ენტროპიის მინიმიზაციასაც.

განვიხილოთ მაგალითი. ქვემოთ მოყვანილ ნახაზზე წარმოდენილია ორი ფს და ფს კლასის რეალიზაციები. კარუნენა-ლოგევას გაშლის მეთოდით მოვახდინოთ განზომილების შემმცირება.

 W_1

$X_{11} = (0,0,0)'$

$X_{12} = (1,0,0)'$

$X_{13} = (1,0,1)'$

$X_{14} = (1,1,0)'$

 W_2

$X_{21} = (0,0,1)'$

$X_{22} = (0,1,0)'$

$X_{23} = (0,1,1)'$

$X_{24} = (1,1,1)'$

დაუშვათ, რომ კლასების აპრიორული ალბათობები ერთმანეთის ტოლია, მაშინ $P(W_1) = P(W_2) = \frac{1}{2}$. კორელაციური მატრიცა განისაზღვრება შემდენაირად:

$$R = \sum_{i=1}^2 P(W_i) M[X_i X'_i] = \frac{1}{2} M[X_1 X'_1] + \frac{1}{2} M[X_2 X'_2].$$

თუ მათემატიკურ ლოდინს შევცვლით საშუალო არითმეტიკულის შეფასებით

$$m = M[X] \approx \frac{1}{2} \sum_{j=1}^n X_j,$$

მაშინ გვექნება:

$$R = \frac{1}{8} \sum_{j=1}^4 X_{1j} X'_{1j} + \frac{1}{8} \sum_{j=1}^4 X_{2j} X'_{2j} = \frac{1}{8} \begin{pmatrix} 3 & 1 & 1 \\ 1 & 1 & 0 \\ 1 & 0 & 1 \end{pmatrix} + \frac{1}{8} \begin{pmatrix} 1 & 1 & 1 \\ 1 & 3 & 2 \\ 1 & 2 & 3 \end{pmatrix} = \frac{1}{4} \begin{pmatrix} 2 & 1 & 1 \\ 1 & 2 & 1 \\ 1 & 1 & 2 \end{pmatrix},$$

რომლის მახასიათებელი რიცხვებია: $|_1 = 1$, $|_2 = |_3 = \frac{1}{4}$, ხოლო მათი შესაბამისი

საკუთრივი ვექტორებია:

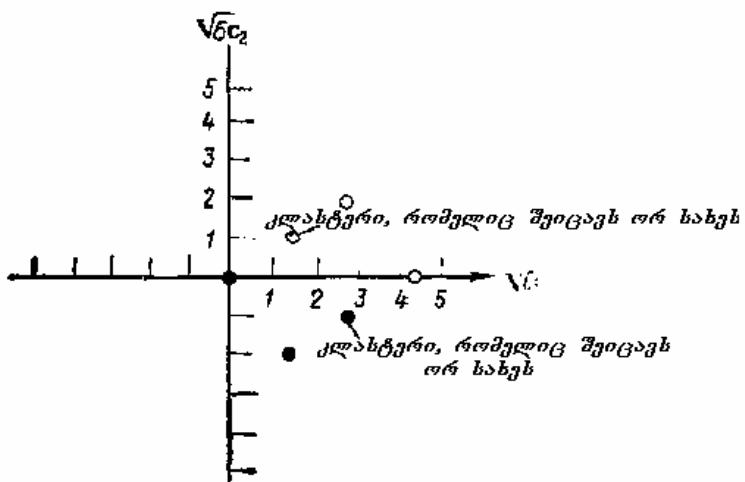
$$e_1 = \frac{1}{\sqrt{3}}(1, 1, 1)', \quad e_2 = \frac{1}{\sqrt{6}}(-2, 1, 1)', \quad e_3 = \frac{1}{\sqrt{2}}(0, 1, -1)'.$$

თუ შევარჩევთ e_1 და e_2 საკუთრივ ვექტორებს, მაშინ გარდაქმნის მატრიცას ექნება შემდეგი სახე:

$$\Phi = \begin{bmatrix} \frac{1}{\sqrt{3}} & -\frac{2}{\sqrt{6}} \\ \frac{1}{\sqrt{3}} & \frac{1}{\sqrt{6}} \\ \frac{1}{\sqrt{3}} & \frac{1}{\sqrt{6}} \end{bmatrix}.$$

თუ გამოვიყენებო $C = \Phi' X$ გარდაქმნას, მაშინ მივიღებო:

w_1	w_2
$c_{11} = (0, 0)'$	$c_{21} = \frac{1}{\sqrt{6}}(\sqrt{2}, 1)'$
$c_{12} = \frac{1}{\sqrt{6}}(\sqrt{2}, -2)'$	$c_{22} = \frac{1}{\sqrt{6}}(\sqrt{2}, 1)'$
$c_{13} = \frac{1}{\sqrt{6}}(2\sqrt{2}, -1)'$	$c_{23} = \frac{1}{\sqrt{6}}(2\sqrt{2}, 2)'$
$c_{14} = \frac{1}{\sqrt{6}}(2\sqrt{2}, -1)'$	$c_{24} = \frac{1}{\sqrt{6}}(3\sqrt{2}, 0)'$



როგორც ნახაზიდან ჩანს, კლასტერიზაციის ეფექტი შეიმჩნევა. მოვახდინოთ განზომილების შემდგომი შემცირება. ამისათვის ავიღოთ მხოლოდ e_1 ვექტორი. მაშინ გარდაქმნის მატრიცას ექნება შემდეგი სახე: $\Phi = \frac{1}{\sqrt{3}}(1, 1, 1)',$ ხოლო გარდაქმნის შემდეგ მივიღებო:

W_1	W_2	ძღვანტკრები, რომელიც შეიცავს სხვადასხვა გლობულურ საბუქს
$c_{11} = 0$	$c_{21} = \sqrt{3}$	
$c_{12} = \sqrt{3}$	$c_{22} = \sqrt{3}$	
$c_{13} = 2\sqrt{3}$	$c_{23} = 2\sqrt{3}$	
$c_{14} = 2\sqrt{3}$	$c_{24} = 3\sqrt{3}$	

როგორც ნახაზიდან ჩანს, კლასტერიზაციის უფექტი არ შეიმჩნევა, რადგან 1 და 2 წერტილებში ორივე კლასის რეალიზაციები ერთმანეთს ემთხვევა, ამიტომ ეს ბოლო გარდაქმნა არასასურველია.

გამოყენებული ლიტერატურა

1. Ту Дж. Гонсалес Р. Принципы распознавания образов. М. «Мир», 1978.
2. Лепский А.Е., Математические методы распознавания образов. Таганрог, ТТИ ЮФУ, 2009 (эл.версия).
3. ვერულავა თ. ხუროძე რ. ამომცნობი სისტემების თეორიის საფუძვლები. თბილისი, სტუ, 2001.
4. Барский А. Б. Нейронные сети: распознавание, управление, принятие решений. — М.: Финансы и статистика, 2004. (эл.версия).
5. Ясницкий Л.Н. Введение в искусственный интеллект. Учеб.пособие, М.,Академия, 2008 (эл.версия).