

**ამოცნობის საიმედოობის პროგნოზირება კლასტერიზაციის
შედეგების მიხედვით**

ოთარ ვერულავა, თეა თოდუა, ლაშა ვერულავა
საქართველოს ტექნიკური უნივერსიტეტი

რეზიუმე

განიხილება ამოცნობის პროცესის პროგნოზირების პროცედურა კლასტერიზაციის შედეგებზე დაყრდნობით. კერძოდ, შემოტანილია სახეების (კლასტერების) გავლენის ზონის ცნება, რის საშუალებითაც ხდება ამოცნობის პროცესში შესაძლო შეცდომების პროგნოზირება. მოცემულია გავლენის ზონების თანაკვეთისა და არათანაკვეთის შემთხვევები. როგორც ამ უკანასკნელის კერძო შემთხვევა, განხილულია არაკომპაქტური კლასტერებიც.

საკანონო სიტყვები: სახეთა ამოცნობა. კლასტერიზაცია. გავლენის ზონები. პროგნოზირება.

1. შესავალი

ამოცნობის საიმედოობის პროგნოზირებისათვის გამოიყენება კლასტერიზაციის პროცესი რანგული კავშირებით [1,2,3], რომლის შედეგები საშუალებას გვაძლევს დავადგინოთ კლასტერების შემდეგი მახასიათებლები:

1. კლასტერების რაოდენობა;
2. თითოეულ კლასტერში შემავალი რეალიზაციების წუსხა და მათი რაოდენობა;
3. კლასტერის აგების მახასიათებელი – აგების რანგის მნიშვნელობა;
4. კლასტერების განმხოლოების მაჩვენებელი – რანგების გამოტოვებების რაოდენობა.

კლასტერიზაციის ოთხივე მახასიათებელი წარმოადგენს სკალარებს, რომელთა მნიშვნელობა მით უფრო სანდოა, რაც უფრო მეტია რეალიზაციათა რაოდენობა თითოეული სახის სასწავლო ნაკრებში. რეალიზაციათა სიმრავლის წარმომადგენლობითობის პირობა საკმაოდ მკაცრი მოთხოვნაა და მისი დაკმაყოფილება პრაქტიკული ამოცანებისათვის წშირად ვერ ხერხდება, ამიტომ იყენებენ ემპირიულ კრიტერიუმს, რაც შემდეგში გამოიხატება: რაც მეტია რეცეპტორული ველის განზომილება, მით მეტი უნდა იყოს რეალიზაციების რაოდენობა თითოეული სახის სასწავლო ნაკრებებში.

წარმოვადგინოთ რამდენიმე ცნება კლასტერიზაციის შედეგების შესაფასებლად.

განსაზღვრა 1. კლასტერი კომპაქტურია, თუ მასში გაერთიანებულია მხოლოდ ერთი სახის რეალიზაციები, წინააღმდეგ შემთხვევაში კლასტერი არაკომპაქტურია.

განსაზღვრა 2. სახე კომპაქტურია, თუ იგი წარმოდგენილია მხოლოდ კომპაქტური კლასტერებით, წინააღმდეგ შემთხვევაში სახე არაკომპაქტურია.

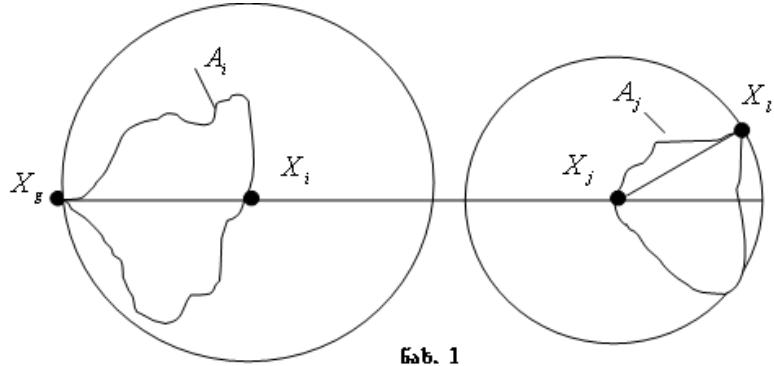
2. ამოცნობის საიმედოობის პროგნოზირება კომპაქტური სახეებისათვის

დავუშვათ, სახეთა რეალიზაციების X სიმრავლე კლასტერიზაციულია და მიღებულია კლასტერიზაციის ზემოთ მოცემული მახასიათებლის მნიშვნელობები. სიმარტივისათვის დავუშვათ, რომ სახეთა სიმრავლიდან აღებულია ორი A_i და A_j ელემენტი, რომლებისთვისაც უნდა განისაზღვროს სწორად ამოცნობის ან შეცდომის დაშვების ალბათობები.

დავუშვათ, რომ A_i და A_j სახეები კომპაქტურია და მათი შესაბამისი კლასტერების განლაგება ნიშანთა სივრცეში ანალოგიურია სურ. 1-ზე ნაჩვენები შემთხვევისა.

განვსაზღვროთ სხვადასხვა კლასტერებში შემავალ რეალიზაციებს შორის მინიმალური მანძილი, რაც წარმოადგენს სიმრავლეებს შორის ჰაუსდორფის მეტრიკას.

დავუშვათ, ჰაუსდორფის მეტრიკა ხორციელდება $X_i \in A_i$ და $X_j \in A_j$ რეალიზაციებზე (სურ. 1). განვსაზღვროთ მაქსიმალური მანძილი X_i და X_j რეალიზაციებიდან თავისავე კლასტერში შემავალ რეალიზაციებამდე, რომლებიც 1-ელ ნახაზზეა წარმოდგენილი შესაბამისად X_g და X_l წერტილებით – რეალიზაციებით.



ნახ. 1

შემოვხაზოთ X_i და X_j წერტილებიდან (რეალიზაციებიდან) ჰიპერსფეროები (წრეწირები) X_iX_g და X_jX_l რადიუსებით.

განსაზღვრა 3. A_i სახის გავლენის ზონა A_j სახის მიმართ ეწოდება ნიშანთა სივრცის იმ ნაწილს, რომელიც შემოსაზღვრულია X_iX_g რადიუსით შემოწერილი ჰიპერსფეროთ.

განსაზღვრა 4. A_j სახის გავლენის ზონა A_i სახის მიმართ ეწოდება ნიშანთა სივრცის იმ ნაწილს, რომელიც შემოსაზღვრულია X_jX_l რადიუსით შემოწერილი ჰიპერსფეროთ.

მივიღოთ მხედველობაში, რომ ზემოთ მოყვანილი განსაზღვრუებები შესაძლებელია გამოვიყენოთ სახეთა A სიმრავლის ელემენტების ნებისმიერი წყვილისათვის.

განვიხილოთ გავლენის ზონების განლაგების რამდენიმე შემთხვევა:

1. გავლენის ზონები არ იკვეთება.

A_i და A_j სახეებისათვის ეს ნიშნავს, რომ X_iX_g და X_jX_l რადიუსიანი ჰიპერსფეროები არ იკვეთებიან (სურ.1), რაც აღიწერება შემდეგი გამოსახულებით:

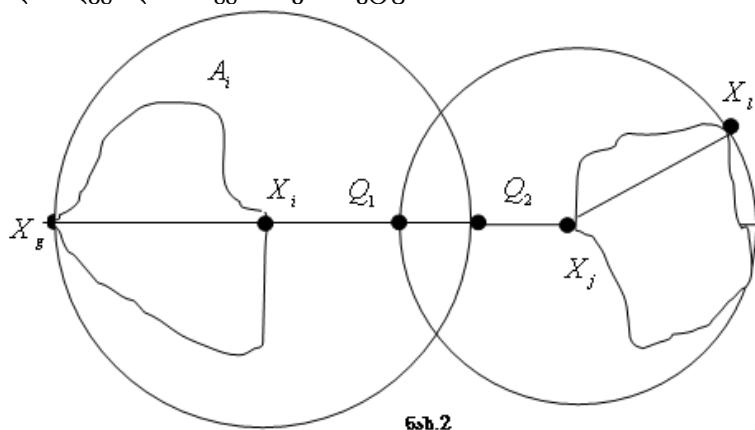
$$X_iX_g + X_jX_l < X_iX_g \quad (1)$$

რანგული კავშირებით კლასტერირების შედეგების მიხედვით კი გვექნება შემდეგი უტოლობა:

$$Rank(X_i; X_g) + Rank(X_j; X_l) < Rank(X_i; X_j)$$

2. გავლენის ზონები იკვეთება (ნახ.2).

ცხადია, რომ გავლენის ზონების გადაკვეთა არ ნიშნავს კლასტერების თანაკვეთას, რადგან ასეთ შემთხვევაში დაირღვეოდა სახეების კომპაქტურობის პირობა.



ნახ. 2

მე-2 ნახაზზე გამოსახული შემთხვევა შესაძლოა წარმოავალგინოთ შემდეგი უტოლობით:

$$X_iX_g + X_jX_l > X_iX_l \quad (2)$$

რანგული კავშირების მიხედვით გვექნება:

$$Rank(X_i; X_g) + Rank(X_j; X_l) > Rank(X_i; X_g)$$

ამოცნობის საიმედოობის პროგნოზირება ემყარება შემდეგ აქსიომებს:

აქსიომა 1. ნებისმიერი სახის რეალიზაციები სხვა სახის მიმართ შესაძლოა გამოჩნდეს მხოლოდ თავის გავლენის ზონაში ამ სახის მიმართ.

აქსიომა 2. ამოცნობის პროგნოზირებული საიმედოობა განისაზღვრება მოცემული სახის გავლენის ზონაში არსებული რეალიზაციების რაოდენობის ფარდობით კლასტერში მოთავსებულ რეალიზაციების მთელ რაოდენობასთან.

აღვნიშნოთ A_i სახის რეალიზაციების რაოდენობა M_i -ით, ხოლო M_{ij} -ით იმ რეალიზაციების რაოდენობა, რომელიც განლაგდა A_j სახის გავლენის ზონაში. ამოცნობის შეცდომის (ავლნიშნოთ P_{ij}^- -ით) შესაფასებლად აქსიომა 2-ის მიხედვით, გვექნება:

$$P_{ij}^- = \frac{M_{ij}}{M_i} \quad (3)$$

სადაც P_{ij}^- - შეცდომის ალბათობაა, $i, j = \overline{1, I}, i \neq j$.

სწორად ამოცნობის ალბათობებისათვის, ავლნიშნოთ P_{ij}^+ , გვექნება:

$$P_{ij}^+ = 1 - P_{ij}^-$$

აქსიომა 1-დან გამომდინარე, თუ გავლენის ზონები არ იკვეთება, მაშინ ამ ზონებში სხვა სახის რეალიზაციების გამოჩენის ალბათობა ტოლია ნულის, შესაბამისად, გვექნება $M_{ij} = 0$ და გამოსახულება 3-ის მიხედვით მივიღებთ, რომ $P_{ij}^- = 0 \Rightarrow P_{ij}^+ = 1$

ამოცნობის საიმედოობის შესაფასებლად გამოვიყენოთ გავლენის ზონების თანაკვეთის მაქსიმალური სიგანის ფარდობა კლასტერებს შორის ჰაუსდორფის მეტრიკით განსაზღვრულ მანძილთან. თანაკვეთის ზონის მაქსიმალური სიდიდე მე-2 ნახაზზე აღნიშნულია $Q_1 Q_2$ მანძილით. მის მანძილის გამოსათვლელად გამოვიყენოთ შემდეგი გამოსახულება:

$$Q_1 Q_2 = X_i X_j - (X_i Q_1 + Q_2 X_j) \quad (4)$$

$X_1 Q_1 = X_i X_j - X_j Q_1$; $Q_2 X_j = X_i X_j - X_i Q_2$. ჩავსვათ გამოსახულება (4)-ში $X_1 Q_1$ და $Q_2 X_j$ მიღებული მნიშვნელობები; მივიღოთ მხედველობაში, რომ $X_1 Q_1 = X_i X_g$ და $X_j Q_2 = X_j X_l$; მარტივი გარდაქმნებით მივიღებთ:

$$Q_1 Q_2 = -X_i X_j + X_j X_l + X_i X_g \quad (5)$$

იმის გამო, რომ $Q_1 Q_2$ სიდიდე მანძილია და ამის გამო დადებითი სიდიდეა, ასევე საიმედოობის მნიშვნელობები მხოლოდ არაუკარყოფითი სკალარებია, ამიტომ მივიღოთ, რომ

$$Q_1 Q_2 = |-X_i X_j + X_j X_l + X_i X_g| \quad (6)$$

ამოცნობის საიმედოობის შესაფასებლად გვექნება:

$$P_{ij}^- = \frac{|-X_i X_j + X_j X_l + X_i X_g|}{X_i X_j} \quad (7)$$

იგივე შეიძლება ვიანგარიშოთ რანგული კავშირებით მიღებული გამოსახულებების მიხედვით, რისთვისაც გამოვიყენოთ (2) უტოლობა, რომელიც გადავწეროთ შემდეგნაირად:

$$Rank(X_i X_j) - (Rank(X_i; X_g) + Rank(X_j; X_l)) < 0 \quad (8)$$

როგორც (8) გამოსახულებიდან ჩანს, მიღებული სხვაობა უარყოფითი სიდიდეა, ამიტომ

(7) გამოსახულების მსგავსად ვისარგებლოთ სხვაობის აბსოლუტური მნიშვნელობით. შესაბამისად, რანგული კავშირებით ამოცნობის საიმედოობის შესაფასებლად გვექნება:

$$P_{ij}^{-} = \frac{|Rank(X_i; X_j) - (Rank(X_i; X_j) + Rank(X_j; X_i))|}{Rank(X_i; X_j)} \quad (9)$$

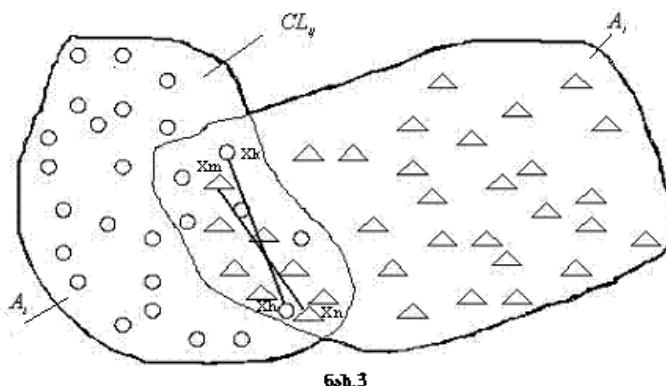
სადაც $i, j = \overline{1; I}, i \neq j$.

(7) გამოსახულებით ვისარგებლოთ მაშინ, როდესაც კლასტერირება არაა შესრულებული რანგული კავშირებით, ხოლო გამოსახულება (9)-ით – რანგული კავშირებით კლასტერირებისას.

3. ამოცნობის საიმედოობის პროგნოზირება არაკომპაქტური სახეებისათვის

არაკომპაქტური სახეები, განსაზღვრა 2-დან გამომდინარე, გვაქვს მაშინ, როდესაც ერთ კლასტერში გაერთიანებულია ერთზე მეტი სახის რეალიზაციები. დაუშვათ, რომ A_i და A_j სახეები არაკომპაქტურია, რომელთა შესაბამისი არაკომპაქტური კლასტერი აღვნიშნოთ CL_{ij} -თი. (ნახ.3). აյ თრმაგი კონტურული ხაზით გამოსახულია CL_{ij} კლასტერი, ხოლო ერთმაგი კონტურული ხაზით და პატარა წრეწირებით A_i სახის, ხოლო სამკუთხედებით მონიშნული არით A_j სახის რეალიზაციები. ამ შემთხვევაში აუცილებელია თანაკვეთის არის განსაზღვრა, ანუ თანაკვეთაში მოთავსებული რეალიზაციების (წერტილების) ნუსხის შედგენა. ამ ამოცანის გადაწყვეტა შესაძლებელია რანგული კავშირებით კლასტერირების მეთოდში შემუშავებული მეზობლების [1,3], არინციას გამოყენებით, რომელიც ემყარება კლასტერის აგების რანგის ცნებას.

მოცემულ შემთხვევაში, კლასტერის აგების რანგი, აღვნიშნოთ r_{ij} -ით, საშუალებას მოგვცემს კლასტერში გაერთიანებული ყველა წერტილისთვის განვსაზღვროთ ის რეალიზაციები, რომელიც მოცემულ წერტილთან იმყოფება r_{ij} -ის ტოლ ან ნაკლებ ჩაკეტილ რანგულ კავშირში.



ასეთი მეთოდით შევადგენთ ქვეკლასტერებს თითოეული რეალიზაციისათვის და მათგან შევარჩევთ მხოლოდ ისეთებს, რომლებშიც გაერთიანებულია ორივე A_i და A_j სახის რეალიზაციები. ასეთი ქვეკლასტერების გაერთიანება მოგვცემს თანაკვეთის არეს მასში შემავალი რეალიზაციების ნუსხით.

თანაკვეთაში შემავალი A_i სახის რეალიზაციებისათვის განვსაზღვროთ მაქსიმალური მანძილი, რომელიც მე-3 ნახაზზე მოცემული მაგალითისათვის ხორციელდება X_h და X_k წერტილებზე. იგივე ოპერაცია ჩავატაროთ A_j სახის რეალიზაციებისათვის თანაკვეთის არიდან; შესაბამისად, მივიღებთ X_m და X_n წერტილებს. ამ წერტილებიდან შემოვხაზოთ ჰიპერსფეროები რადიუსებით $X_k X_h$ და $X_m X_n$. $X_k X_h$ რადიუსით შემოსაზღვრული ჰიპერსფეროებისათვის განვსაზღვროთ A_i სახის იმ რეალიზაციების რაოდენობა, რომლებიც მოთავსდა ამ

ჰიპერსფერობებში (ნახ.3). აქ მხედველობაში უნდა მივიღოთ ის გარემოება, რომ რეალიზაციები დათვლილი უნდა იყოს მხოლოდ ერთჯერ, იმ შემთხვევებში, როდესაც ის მოთავსდა ორივე ჰიპერსფერობი. აღვნიშნოთ დათვლილი რეალიზაციების რაოდენობა M_{ji} , ხოლო $X_k X_h$ რადიუსით შემოსაზღვრული ჰიპერსფერობებში გაერთიანებული X_j სახის რეალიზაციების რაოდენობა - M_{ij} -ით. შეცდომით ამოცნობის ალბათობისთვის გვექნება:

$$P_{ij}^- = \frac{M_{ij}}{M_i}; \quad P_{ji}^- = \frac{M_{ji}}{M_j} \quad (10)$$

სადაც, $i, j = \overline{i, I}, i \neq j$.

ამოცნობის საიმედოობის შეფასებისათვის გვექნება:

$$P_{ij}^+ = 1 - P_{ij}^-; \quad P_{ji}^+ = 1 - P_{ji}^-$$

4. დასკვნა

ამოცნობის საიმედოობის შესაფასებლად გამოყენებულია ე.წ. სახეობა გავლენის ზონები, რომლებიც შეიძლება განვსაზღვროთ კლასტერირების შედეგებით. კლასტერირების ალგორითმები უნდა აქმაყოფილებდეს დეტერმინირებულობის პირობებს. ნაშრომში გამოყენებულია რანგული კავშირებით კლასტერირების მეთოდი, მაგრამ განხილულია ამოცნობის საიმედოობის პროგნოზირებისთვის სხვა ალგორითმების გამოყენების შესაძლებლობაც.

ლიტერატურა:

1. Verulava O. Clustering Analysis by "Rank of Links" Method. Transactions of GTU, #3(414), Tbilisi, 1997.
2. Verulava O., Khurodze R. Clustering Analysis and Decision-making by "Rank of Links". Mathematical Problems in Engineering, 2002, vol. 8(4-5), Machine Intelligence Center #347, Tbilisi.
3. ვერულავა ო., ხუროძე რ. რანგული კავშირების თეორია – ამოცნობის პროცესების მოდელირება. სტუ, თბილისი.

FORECASTING OF RELIABILITY OF RECOGNITION ON THE BASIS OF RESULTS OF CLUSTERING

Verulava Otar, Todua Tea, Verulava Lasha
Georgian Technical University

Summary

There are considered problem of prediction of recognition process on the basis of the results of clustering. Introduced notion of influence zones for patterns (clusters). By means of influence zones might be prediction of possible recognition errors. In this article are considered cases: 1. Influence zones are disjointed; 2. influence zones are intersected (as special case of this is discussed non-compact clusters).

ПРОГНОЗИРОВАНИЕ НАДЕЖНОСТИ РАСПОЗНАВАНИЯ НА ОСНОВЕ ИТОГОВ КЛАСТЕРИЗАЦИИ

Верулава О., Тодуа Т., Верулава Л.
Грузинский Технический Университет

Резюме

Рассмотрена проблема прогнозирования процессов распознавания на основе итогов кластеризации. В частности, введено понятие зоны «влияния образов», с помощью которого определяются возможные ошибки распознавания. Рассматриваются случай, когда зоны влияния не пересекаются, пересекаются и как частный случай последнего, рассматриваются некомпактные кластеры.