



შავი ზღვის საერთაშორისო უნივერსიტეტი
ბიზნესის მართვის ფაკულტეტი
ბიზნესის ადმინისტრირების პროგრამა

**სწავლების პროცესის ხარისხის კონტროლის მეთოდის დამუშავება
რობასტული სტატისტიკური მეთოდების გამოყენებით (ჩრდილოეთ
ერაყის უნივერსიტეტის მაგალითზე).**

აჰმეთ დემირი
ბიზნესის ადმინისტრირების სადოქტორო დისერტაციის ვრცელი რეზიუმე

თბილისი, 2015

სამეცნიერო ხელმძღვანელი:

ირაკლი როდონაია

(სახელი, გვარი)

შავი ზღვის საერთაშორისო უნივერსიტეტის პროფესორი, დოქტორი

(აკადემიური წოდება)

ექსპერტები (სახელი, გვარი & აკადემიური წოდება):

1. ალექსანდრე მილნიკოვი პროფ. დოქტორი

2. სალავათ საიფილლუნ ასოც. პროფესორი

ოპონენტები (ექსპერტები (სახელი, გვარი & აკადემიური წოდება):

1. ალექსანდრე ედიბერიძე პროფ. დოქტორი

2. მედეა თევდორაძე პროფ. დოქტორი

შესავალი

ხშირ შემთხვევაში სწავლების პროცესის ხარისხის მოთხოვნები მოცემულია შემდეგი ფორმებით: მაგალითად, „სუსტ“ (ჩაჭრილ) სტუდენტებად შესაძლოა ჩაითვალოს ის სტუდენტები, რომელთა შეფასებაც ნაკლებია 60-ზე და მათი პროცენტული მაჩვენებელი უნდა იყოს 30%; „საშუალო“ (მისაღები დონის) სტუდენტებად მიჩნეულნი არიან ისინი, ვისი შეფასებაც არის 61-დან 95-მდე, ხოლო მათი პროცენტულობა უნდა იყოს 65%; მეორე კატეგორიის, ე.წ. „საშუალო“ დონის სტუდენტებად ითვლებიან ისინი, რომელთა პროცენტულობაც სტუდენტთა სრული რაოდენობის მაქსიმუმ 50%-ს წარმოადგენს (ჩაჭრილი სტუდენტების ჩათვლით) და „საშუალო“ სტუდენტის 20%-ია; ვთქვათ, ამ „საშუალო დონის“ სტუდენტების შეფასებაა 80 (ან სხვა), ამგვარად, შეფასება 80 შეიძლება ჩაითვალოს ნიშნების განაწილების მედიანად. “ბრწყინვალე” სტუდენტებად მიჩნეულია ის ნაწილი, რომელთა შეფასება 95%-ზე მაღალია და მათი პროცენტული მაჩვენებელი 5%; ყველა ცნობილ ნაშრომში ასეთი გადანაწილება წარმოდგენილია. მაგრამ ყველა ცნობილ ნაშრომებში ესეთი სახის განაწილებისას გამოიყენება ან ჩვეულებრივი ან სხვა კარგად ცნობილი განაწილება (ბეტა განაწილება, გამა განაწილება, ვეიბულის განაწილება და სხვა (beta distribution, gamma distribution, Weibull distribution)). მაგრამ ნორმალური განაწილების გამოყენებისას შედეგების ექვივალენტობა და სიზუსტე მნიშვნელოვნად არის დამოკიდებული გადახრის ხარისხზე და ხშირად მიუღებელია. იმ შემთხვევაში, თუ გამოვიყენებთ სხვა განაწილებას (ბეტა, გამა და სხვა) შესატყვისი განაწილების შეფასების პრობლემა იზრდება. ხშირ შემთხვევაში ანალიტიკური გამოხატვა ვერ იქნება მიღებული ახლო ფორმით; უმეტეს შემთხვევაში ანალიტიკური გამოსახულების მიღება მიახლოებითი ფორმით შეუძლებელია. გარდა ამისა, როდესაც იცვლება მოთხოვნები ხარისხის ცვლილებებისადმი, PDF და CDF + - ფუნქციების შესაბამისი ფორმები იცვლება (shapes). შედეგად, საჭიროა განაწილების პარამეტრების შეფასების ხშირად გართულებული პროცედურების

გამოყენება. შედეგად, აუცილებელია გამოვიყენოთ ხშირად რთული პროცედურები პარამეტრების განაწილების გამოსათვლელად.

ანალოგიური ამოცანა ჩვეულებისამებრ გვხვდება პროდუქტის ხარისხის კონტროლის სფეროშიც. მსგავსი დავალება ხშირად გვხვდება პროდუქციის ხარისხის კონტროლისას. პროდუქტის ხარისხისადმი მოთხოვნის შესაძლო ფორმაა შემდეგი:

გადახრის პროცენტი ხარისხის ზოგიერთი პარამეტრის საჭირო დონიდან რაიმე ხარისხის პარამეტრის მოთხოვნადი დონე უნდა იყოს არა უმეტეს $\pm 5\%$ პროდუქტის გამოშვების 95% -ში; ასეთ შემთხვევაში პროდუქტის ხარისხი შეფასებულია როგორც „საუკეთესო“. იმისათვის, რომ პროდუქტი შეფასდეს როგორც „მისაღები“, მისი ხარისხი უნდა ითალისწინებდეს შემდეგს: გადახრის ხარისხის ზოგიერთი პარამეტრის საჭირო დონიდან არის $\pm 6\%$ - 20% პროდუქტის გამოშვების 3% -ში. პროდუქტი ფასდება „მიუღებლად“ (ან დეფექტურად), იმ შემთხვევაში თუ არის 20% =ზე მეტი გადახრა (შესაბამისად, დეფექტური, ანუ წუნდებული პროდუქციის პროცენტულობა არ უნდა იყოს 2% -ზე მეტი). წინასწარ არ არის ცნობილი თუ რომელი ტიპის განაწილება უნდა იყოს გამოყენებული ამ შემთხვევაში. ზემოთ ნაჩვენები განაწილებები (რომლებიც ასახავენ ხარისხის მოთხოვნებს) ეწოდებათ შემდგომ „სტილის“ (“pattern”) განაწილება (ფუნქციები (functions)). სასურველია დღევანდელი გამოცდების შეფასებათაგან განაწილება ან პროდუქტის ხარისხის დონის გადახრა იყოს მაქსიმალურ შესაბამისობაში ნიმუშთან.

სანიმუშე განაწილება წარმოადგენს ხარისხის მოთხოვნას მთელი სასწავლო პროცესისადმი (რომელშიც გათვალისწინებული უნდა იყოს ყველა რელევანტური ტესტი). ანუ სხვადასხვა სახის შეფასებები (რომელიც მიღებული აქვს სტუდენტთა ჯგუფს ერთი ან რამოდენიმე კურსის განმავლობაში) უნდა მიუახლოვდნენ სანიმუშე განაწილება რათა ჯგუფი ჩაითვალოს წარმატებულად და აკმაყოფილებდეს სწავლების ხარისხისათვის საჭირო მოთხოვნებს. რატემაუნდა, შესაძლებელია მოხდეს ყველა მიმდინარე ტესტის შეფასებების შედარება სანიმუშე განაწილებასთან

და შეჯამდეს შედეგები. მაგრამ აღნიშნული მიდგომა ასოცირდება დამატებითი და განმეორებითი კალკულაციების დიდი რაოდენობით.

ყოველივე ზემოაღნიშნულის გათვალისწინებით, წინამდებარე ნაშრომში შემოთავაზებულია რელევანტური შეფასებების განაწილება ერთიანი არაპარამეტრული შეფასების ახალი ძირითადი მეთოდის გამოყენება და მისი შედეგების შედგომი ათვისება სწავლების ხარისხის შეფასების პროცესში.

საყურადღებოა, რომ აღნიშნული მეთოდი არ მოითხოვს შეფასების განაწილება პარამეტრების მეტად რთული პროცედურების შესრულებას (როგორცაა ვთქვათ, სტანდარტული გადახრა, მესამე ან მეოთხე დონის). მეთოდი შესაძლოა გამოყენებულ იქნას სხვადასხვა მრავალრიცხოვანი ტესტების შეფასებების შესაბამისობისა და მათი შედარებისათვის სანიმუშე განაწილებასთან, იგივე ერთიანი ხერხებისა და ალგორითმების გამოყენებით. აღნიშნული მიდგომა უზრუნველყოფს ხარისხის საერთო კრიტერიუმის შექმნას მიდგომა წარმოადგენს ზოგადი ხარისხის კრიტერიუმის ფორმირების საშუალებას ყველა ტესტური შედეგებისათვის და გვამღევეს მეთოდს შევადაროთ იგი ხარისხის მოთხოვნის სტილს.

კვლევის მიზანი

ზოგადად, ჩატარებული კვლევის მიზანია განათლებასა და პროდუქციაში ხარისხის დონის განსაზღვრის ხერხების განვითარება მაშინ, როდესაც, ხარისხის დონის განმსაზღვრელი სტანდარტები მოცემულია დახურული ფორმებით, მაგალითად, განაწილების ფუნქციების ფორმით. ამ კონტექსტში, კვლევის ძირითადი მიზნები შემდეგნაირია:

- მოცემული დარგის სრულფასოვანი შესწავლა მსგავსი ნაშრომების გაცნობის გზით;
- განათლებას, მრეწველობასა და ბიზნესში ხარისხის მენეჯმენტის სპეციფიური მიზნებისა და იდეების გაგება და განმარტება;

- იმ გზებისა და მეთოდების განვითარება, რომელიც ეხმარება დაინტერესებულ მხარეებს დარგში არსებული შესაძლო პრობლემების, დაბრკოლებებისა და ხელის შეშლელი ფაქტორების სწრაფად და საფუძვლიანად გამომჟღავნებასა და აღმოფხვრაში;
- სერიოზული სამეცნიერო პროცედურის შემოთავაზება, რომელიც დასახავს ღრმა და სასარგებლო გზებს წარმოქმნილი პრობლემების ძიებაში;
- წარმოქმნილი პრობლემების გადაჭრის ღრმა სამეცნიერო და ეფექტური მეთოდების შემოთავაზება;
- ზემოთ აღნიშნული პრობლემების გადაჭრის მიზნით პრაქტიკულად მისაწვდომი და მნიშვნელოვანი პროცედურების განვითარება შესაძლო უმაღლესი დონის ავტომატიზაციის გზით;
- განვითარების ყველა გზა უნდა იყოს გამოყენებადი და მორგებული, რეალიზაციის ფართო სპექტრისათვის: განათლება, მრეწველობა, ეკონომიკა და სხვა.

მეთოდოლოგია

ნაშრომში დასახული მიზნების მისაღწევად, გამოიყენება შემდეგი სახის ხერხები და კვლევის მეთოდები:

- მოწინავე არაპარამეტრული მეთოდები რომლებიც მოერგება რთულ, არასტანდარტულ ან უცნობ ფუნქციურ დამოკიდებულებებს: განზოგადებული ლამბდას განაწილება, პოლინომები, კოლმოგოროვ-სმირნოვის სტატისტიკა (Generalized Lambda Distribution , Piecewise () Cubic Hermite Interpolant Polinomials (უბან-უბან კუბიკური ერმიტული ინტერლოლაციური პოლინომები), Kolmogorov-Smirnov statistics);
- საინფორმაციო თეორიის უახლესი მეთოდები: კულბაკ-ლეიბლერის განშლადობის (გადახრის) მატრიცა (Kullback-Leibler divergence metrics);
- დიზაინისა და ექსპერიმენტული მეთოდები (თანმიმდევრული ადაპტირებადი შერჩევა (sequential adaptive sampling));
- გლობალური ოპტიმიზაციის მეთოდები: (გენეტიკური ალგორითმი (Genetic Algorithm));
- ნეირონულ ქსელებზე დაფუძნებული მეტა-მოდელირების მეთოდი (ზოგადი რეგრესიის ნეირონული ქსელი (Generalized Regression Neural Network));
- პროგრამირება მათემატიკურ ლაბორატორიაში (MATLAB).

ძირითადი სამეცნიერო სიახლე

- სხვადასხვა სამრეწველო, საგანმანათლებლო და ბიზნეს ორგანიზაციებში პროდუქციისა თუ სასწავლო პროცესის ხარისხის მოთხოვნები განსხვავდება. წინამდებარე ნაშრომში წარმოდგენილია ამ მოთხოვნების დაკმაყოფილებისა და პროდუქციის თუ სასწავლო პროცესის იმ რეალურ (აქტუალურ) ხარისხთან მიახლოების შეფასების სრულიად ახალი მიდგომა, რომელიც დაფუძნებულია

პროდუქციის გამოშვების ხარისხის ინდიკატორებისა და საგამოცდო ტესტების ქულობრივ შედეგებზე. შემოთავაზებული ტექნიკური საშუალებებით ხდება მკაცრად განსაზღვრული მიახლოებითი პროცედურების გამოყენება, რაც მომხმარებელს ხარისხის მოთხოვნების ცვლილებების შემთხვევაში აქტუალური ხარისხის დონესთან მიახლოების ავტომატური შეფასების საშუალებას აძლევს.

- აქტუალურ და სანიმუშე განაწილებებს შორის მნიშვნელოვანი ცვლილებების არსებობის შემთხვევაში, ნაშრომში შემოთავაზებულია სრულიად ახალი მიდგომა („განზოგადებული რეგრესიის ნეირონული ქსელები“ ნეირონული ქსელის ტიპის გამოყენებით) იმ ფაქტორთა რელევანტური ღირებულებების განსაზღვრისადმი, რომლებსაც მოყვებათ ნიმუში ერთის (ნიმუში 1) აქტუალური განაწილება.

ნაშრომში წარმოდგენილია ორი ახალი და ორიგინალური პროცედურა:

- პროცედურა, რომელიც ითვალისწინებს სასწავლო პროცესის საერთო ხარისხის დონის ინტეგრირებული ფაქტორების (პარამეტრების) რელევანტური ღირებულებების აღმოჩენას. აღნიშნული პროცედურა დაფუძნებულია გენეტიკური ალგორითმზე (GA) და ეფექტური და ქმედითუნარიანია საგანმანათლებლო დაწესებულებაში სასწავლო პროცესის რელევანტური პარამეტრების საერთო (ინტეგრირებული) ხარისხის დონისა და კრიტიკული ღირებულებების სწრაფი განსაზღვრისა და გაანალიზების კუთხით; პროცედურის შედეგად გამოვლენილი ხარისხის არადამაკმაყოფილებელი დონის შემთხვევაში, შემოთავაზებულია საერთო ხარისხის გაუმჯობესების რელევანტური ქმედებები.
- GA-ზე დაფუძნებული პროცედურა არ ანსხვავებს ერთმანეთისაგან ისეთ სასწავლო კურსებს, რომლებსაც შესაძლოა ახასიათებს პარამეტრების სხვადასხვა ოპტიმალური მნიშვნელობა და ასევე არ ითვალისწინებს

სხვადასხვა სასწავლო კურსების სპეციფიურ ნიშნებს (თავისებურებებს). მაგალითად, რომ შევადაროთ მათემატიკისა და ისტორიის საშინაო დავალებებზე სტუდენტის მიერ სახლში დახარჯული საათების საშუალო რაოდენობა, სრულიად განსხვავებულ შედეგს მივიღებთ. შესაბამისად, აღნიშნული პრობლემის დაძლევის მიზნით ნაშრომში შემოთავაზებულია მეორე პროცედურა, რომელსაც შეუძლია განსაზღვროს სასწავლო პროცესის ხარისხის არადამაკმაყოფილებელი დონე ცალკეულ სასწავლო კურსებთან მიმართებაში და წარმოადგინოს რელევანტური გზები მოცემული სასწავლო კურსის ხარისხის გაუმჯობესების მიზნით.

ორივე პროცედურა საშუალებას აძლევს ოხმარებელს იმუშაოს ინტენსიურ ინტერაქტიულ (როდესაც ხარისხის მენეჯმენტის საქმიანობის მოთხოვნები არ არის მკაფიოდ ჩამოყალიბებული) ან სრულიად ავტომატურ რეჟიმში.

უნდა აღინიშნოს, რომ შემოთავაზებული ხერხები და პროცედურები გამოყენებადია სხვადასხვა დარგებში: სასწავლო პროცესების ხარისხის მენეჯმენტი განათლებაში, პროდუქტის ხარისხის დონე მრეწველობაში, ბიზნეს პროცესები ეკონომიკაში და სხვა.

პრაქტიკული მნიშვნელობა

კვლევის მთავარი მიზანია რელევანტური სტრუქტურის აგება, რომელიც დამკვიდრდება და განხორციელდება ისეთი დარგების ხარისხის მენეჯმენტში, როგორცაა განათლება, მრეწველობა, ბიზნესი. ჩატარებული კვლევის წვლილი და მნიშვნელობა ხარისხის მენეჯმენტში მომავალში ჩატარებული კვლევების მთავარი ღერძი და სათავე იქნება. შესაძლოა წარმოდგენილი ნაშრომი ზემოაღნიშნულ დარგებში შემდგომი სარწმუნო და პრაქტიკულად გამოსადეგი მეთოდების განვითარების ერთერთი მნიშვნელოვანი საბაზისო ნაშრომი გახდეს.

ნაშრომის სტრუქტურა და მოცულობა

ნაშრომის მოცულობაა ??? გვერდი და შედგება 3 თავისაგან, გამოყენებული ლიტერატურის სიის, ციფრებისა და ცხრილებისაგან.

პრობლემის ჩამოყალიბება

მოცემული შემთხვევითი მაგალითისათვის $x_1, x_2, x_3, \dots, x_n$, პრობლემას წარმოადგენს ამ მონაცემთათვის სტატისტიკური გადაწილების მორგებას რომელიც მორგებულია მიღებული მაგალითის დაახლოვებით განაწილებასთან.

თუკი თეორიული მოსაზრებებიდან ცნობილია რომ კონკრეტული ტიპის განაწილება (მაგალითად, გამა განაწილება (gamma distribution) უცნობი პარამეტრებით), მაშინ მომენტალური დაჯგუფებით ან სხვა რაიმე საშუალებით შესაძლებელია ისეთი განაწილების განსაზღვრა, რომელიც მიესადაგება მონაცემებს.

როგორც წესი, ეს ასე არაა და იმ შემთხვევაში თუ არ არსებობს ინფორმაცია განაწილების შესახებ, შესაძლებელია განაწილების მოქნილ ოჯახს მივმართოთ და ავირჩიოთ ერთი სპეციფიური წევრი.

მოქნილ ოჯახში ვგულისხმობთ ისეთს, რომლის წევრებსაც შეუძლიათ სხვადასხვა ფორმების შექმნა, მიღება: გადახრა რომელიმე მიმართულებით, განაწილების ნაწილი, რომელიც წაკვეთილია ან გაშვერილია უსასრულობისაკენ რომელიმე ან ორივე მხარეს, ზარისებრი ფორმის დანაწილება და ასევე ამოტრიალებული ზარისებრი განაწილება.

განაწილების ოჯახისათვის მორგებადი მეორე სასურველი ხარისხი არის ის რომ ოჯახი წარმოადგენდეს განაწილებათა ფართო ნიშანთვისებებს როგორცაა მომენტური და პროცენტული დანაყოფის კომბინაციები. მესამე სასურველი ნიშანთვისება გახლავთ ის რომ ოჯახს გააჩნდეს მოხერხებული ფორმა ერთერთ ფუნქციებში, PDF, CDF და პროცენტული. იმისათვის რომ დააკმაყოფილოს ზომების მიხედვით ფუნქციათა ფართო განაწილება გამოიყენება ლამბდას განაწილება. (**Generalized Lambda Distribution (GLD)**). ემპირიული განაწილებისაგან განსხვავებით, ძირითადი მასალის მოწოდების ნაცვლად მეთოდი განსაზღვრავს ოთხ პარამეტრების მნიშვნელობას თითოეული შემთხვევისათვის.

ფუნქციური ფორმა საშუალებას გვაძლევს დავაჯგუფოთ შემთხვევები რომლებიც ერთდაგვარია და ავიცდინოთ უამრავი ციფრებისა და გრაფიკული გამოსახულებების ერთმანეთში არევა.

ზოგადი ლამბდა განაწილების ოჯახი პარამეტრებით $\lambda_1, \lambda_2, \lambda_3, \lambda_4$, GLD ($\lambda_1, \lambda_2, \lambda_3, \lambda_4$), ყველაზე პარტივად არის განსაზღვრული შემდეგ ფორმულაში:

$$Q(y) = Q(y; \lambda_1, \lambda_2, \lambda_3, \lambda_4) = \lambda_1 + \frac{y^{\lambda_3} - (1-y)^{\lambda_4}}{\lambda_2} \quad (1)$$

სადაც $0 \leq y \leq 1$. პარამეტრები λ_1 და λ_2 არის, შესაბამისად, ლოკაციისა და მასშტაბის პარამეტრები, იმ დროს, როდესაც λ_3 და λ_4 განსაზღვრავს გადახრას და GLD ($\lambda_1, \lambda_2, \lambda_3, \lambda_4$) კოეფიციენტის ექსცესა. გავიხსენოთ, რომ X სტოქასტიკური ცვლადი სიდიდეების პროცენტული ფუნქცია (PF) არის ფუნქცია $Q(y)$, რომელიც ყოველ y -ზე 0-სა და 1-ს შორის გვაძლევს x -ის ხარისხს, როგორცაა $F(x) = y: Q(y) = (x - \text{ს ხარისხი, როგორცაა } F(x) = y), 0 \leq y \leq 1$

აქ $F(x)$ არის კრებითი, X ცვლადი სიდიდის კუმულაციური განაწილების ფუნქცია (CDF):

$$F(x) = P(X \leq x), -\infty < x < +\infty.$$

შეზღუდვები $\lambda_1, \lambda_2, \lambda_3, \lambda_4$, რომელსაც მოაქვს ვალიდური GLD($\lambda_1, \lambda_2, \lambda_3, \lambda_4$) განაწილება და λ_3 და λ_4 ზემოქმედება GLD ($\lambda_1, \lambda_2, \lambda_3, \lambda_4$) PDF (შესაძლო ხვედრითი წონის ფუნქცია (Probability Density Function) ფორმაზე განხილული იქნება მოგვიანებით.

შესაბამისად, გაცილებით მარტივია შესაძლო ხვედრითი წონის ფუნქციის პოვნა GLD ([6]. For the GLD ($\lambda_1, \lambda_2, \lambda_3, \lambda_4$) პროცენტული ფუნქციიდან

$$f(x) = \frac{\lambda_2}{\lambda_3 y^{\lambda_3-1} + \lambda_4 (1-y)^{\lambda_4-1}}$$

შესაძლო ხვედრითი წონის ფუნქციაა:

(2)

at $x = Q(y)$.

როგორც დავინახეთ, ხშირად ხარისხის მოთხოვნები მოცემულია საჭირო პროცენტულობის ფორმაში (ჩაჭრილი, ჩვეულებრივი, საშუალო და საუკეთესო სტუდენტების პროცენტულობა, ზოგიერთი პროდუქტის ხარისხის პარამეტრების თავიანთი ნომინალური ხარისხიდან, ღირებულებებიდან გადახრის პროცენტულობა და ა.შ.). პროცენტულობაზე დაფუძნებული მიდგომა მიესადაგება GLD ($\lambda_1, \lambda_2, \lambda_3, \lambda_4$) მონაცემთა კრებულის, მოდემის განაწილებას ოთხი პროცენტულობაზე დაფუძნებული სანიმუშე სტატისტიკის მითითებითა და მათი შესაბამის GLD ($\lambda_1, \lambda_2, \lambda_3, \lambda_4$) სტატისტიკასთან გატოლებით. შედეგად შექმნილი განტოლებები შემდეგ ამოხსნილია $\lambda_1, \lambda_2, \lambda_3, \lambda_4$ -თვის, იმ აზრით, რომ მიღებული GLD იქნება სწორი, ვალიდური განაწილება.

ზემოთაღნიშნული მეთოდი, ითხოვს λ_3 and λ_4 პარამეტრების სხვადასხვა ხარისხების კომპლექსური ცხრილების გამოყენებას. შესაბამისობის, მორგების პროცესის ავტომატიზაციის მიზნით ნაშრომში გამოყენებულია ალგორითმი P-KS ([7]). სტრატეგია მდგომარეობს ($\lambda_1, \lambda_2, \lambda_3, \lambda_4$) პარამეტრების ჯგუფის აღმოჩენაში, რაც იძლევა კოლმოგოროვ-სმირნოვის EKS შემფასებლის ყველაზე დაბალ ხარისხს:

$$E_{ks} = \max |\hat{F}_n - F(x)| \quad (3)$$

სადაც \hat{F}_n არის ემპირიული კუმულაციური განაწილების ფუნქცია (ECDF).

როგორც ზემოთ აღინიშნა, სანიმუშე განაწილება მოცემულია პროცენტის სახით.


სექციის მაგალითისათვის ჩვენ გვაქვს შემდეგი მონაცემები (გამოხატული მათემატიკური ლაბორატორიის წესით):

$$x = [0, 60, 80, 95, 100];$$


$$y = [0, 0.30, 0.50, 0.95, 1];$$

სანიმუშე განაწილების შესაქმნელად (რომლითაც აქტუალური, რეალური ტესტების ქულები იქნება შედარებული) ჩვენ გვჭირდება მრუდის შესაბამისობა მოცემულ მონაცემებთან. შესაბამისობის მრუდი გამოყენებული იქნება შუალედურ შეფასებებში (რომელიც განსხვავდება ქულების ორიგინალური ვარიანტისაგან) - ინტერპოლაციის

ქულებში მონაცემთა ხარისხის გამოყვანის მიზნით. ინტერპოლაციურ წერტილებში წარმოქმნილ მონაცემთა სიგლუვისა და მაქსიმალური სიზუსტის უზრუნველყოფის მიზნით გამოყენებულია კუბის ფორმის სპლინი. სანიმუშე განაწილებისათვის ECDF გრაფიკი შემდეგნაირი:



ფიგ. 1. ECDF სანიმუშე განაწილებისათვის




ფიგ.2 PDF ფუნქცია სანიმუშე განაწილებისათვის

შესაბამისი PDF ფუნქცია მიიღება ანალოგიურად და მოცემულია ფიგ. 2-ში.

როგორც ჩანს, PDF - ის ფორმა არასტანდარტულია და რთულია იმის ამოცნობა, თუ რომელი თეორიული განაწილება წარმატებით მიესადაგება მას.

ახლა ჩვენ შეგვიძლია შევაფასოთ (რელევანტური მათემატიკური ლაბორატორიის წესების გამოყენებით) სანიმუშე განაწილების ხარისხი ინტერპოლაციის წერტილებში, რაც ნიშნავს, რომ ჩვენ შეგვიძლია შევაფასოთ სხვადასხვა პროცენტულობის ხარისხი (მაგალითად, მე-10, მე-20, 30-ე, მე-40, 50-ე, მე-60, 70-ე, მე-80, 90-ე), რათა სანიმუშე განაწილება შედარებულ იქნას რეალური ტესტების შეფასების პროცენტულობასთან; როგორც აღვნიშნეთ ზემოთ, განაწილებასთან შესაბამისობის GLD პროცენტულობაზე დაფუძნებული მიდგომა ინტენსიურად იყენებს ოპერაციებს PF პროცენტულ ფუნქციებს (საწინააღმდეგო კუმულაციური განაწილების ICDF ფუნქციები). ჩვენ შეგვიძლია გამოვითვალოთ საწინააღმდეგო CDF არაპარამეტრული შეფასება. ფაქტობრივად, საწინააღმდეგო CDF შეფასება არის

სწორედ CDF შეფასება გაცვლილი ღერძით. აქ ჩვენ კვლავ ვიყენებთ **Piecewise Cubic Hermite Interpolant Polinomial (PCHIP)**, რათა შევაფასოთ ICDF (ფიგ.3) ხარისხი.



ფიგ.3 . PCHIP ICDF ხარისხის შესაფასებლად

როდესაც გვაქვს PF ხარისხი, ჩვენ შეგვიძლია გამოვთვალოთ ამჯერად $\hat{p}_1, \hat{p}_2, \hat{p}_3, \hat{p}_4$ ხარისხი. როდესაც გამოვთვლით ამ ხარისხებს, ვიწყებთ P-KS პროცედურას. შერჩეულია ამოხსნა საუკეთესო KS კრიტერიით წყვილების (λ_3, λ_4) ყველა შესაძლო კომბინაციისათვის და მათთან ასოცირებული წყვილებისათვის (λ_1, λ_2) . როგორც ეს ყოველივე განმარტებულ იქნა ზემოთ, $\lambda_1, \lambda_2, \lambda_3, \lambda_4$ ცოდნითა და ფორმულა (1) და (2) გამოყენებით, ჩვენ შეგვიძლია ავაგოთ PDF მრუდი: ვიღებთ y ხარისხის მმართველ ბადეს (როგორცაა .01, .02, .03, . . . , .99, რაც გვაძლევს 1%, 2%, 3%, . . . , 99% ქულას), ვპოულობთ x ყველა იმ ქულაში (ფორმულა 1) და ვპოულობთ $f(x)$ x ფორმაში (ფორმულა 2). შემდეგ ჩვენ ვადგენთ წყვილებს $(x, f(x))$ და ვაკავშირებთ მათ გლუვი მრუდით.

ახლა, სასურველობის ფუნქციის მოდიფიკაციის გამოყენებით, ჩვენ უნდა შევქმნათ ცალკეული ინტეგრირებული PDF მრუდი (რომელიც წარმოადგენს ყველა აქტუალური ტესტის PDF მრუდეებს). ჩვენი მიზნისათვის საკმარისია ცალკეული ინტეგრირებული PDF მრუდის შექმნა არითმეტიკული მნიშვნელობის გამოყენებით. დავუშვათ, რომ არის R აქტუალური ტესტების PDF მრუდეები (რომელიც მოცემულია ინტერპოლაციურ წერტილებში i , მაგალითად, i ნიშნავს მე-10, მე-20, 30-

ე, მე-40, 50-ე, მე-60, 70-ე, მე-80, 90-ე პროცენტები, იხილეთ განმარტება ზემოთ), აღნიშნული $F_r(x_i)$, ($r = 1 \dots R$). ისინი კომბინირებულია, რათა მიღებულ იქნას საერთო PDF მრუდი D :

$$D(i) = \frac{\sum_1^R (F_r(x_i))}{R}, \quad (4)$$

ინტეგრირებული PDF მრუდი უნდა შედარდეს სანიმუშე PDF მრუდთან, რომელიც მიღებულია ზემოთ. განაწილების ფუნქციების (და, ამავე დროს სწავლების პროცესის ხარისხის განსაზღვრის) სიახლოვის (ან თავისებური ნიშნის) განსაზღვრის მიზნით ჩვენ გამოვიყენებთ კულბაქ-ლეიბლერის გადახრას (Kullback–Leibler Divergence). ვთქვათ D და P არის ორი PDFs, რომელიც განსაზღვრულია, როგორც $D(x)$, სადა x არის ემპირიული ვექტორების ზომა, განზომილება. კულბაქ-ლეიბლერის გადახრა (KL divergence) D და P შორის არის განსაზღვრული როგორც:

$$KL(D \parallel P) = \int_{\mathbb{R}^n} D(x) \log \frac{D(x)}{P(x)} dx \quad (5)$$

მოცემულ განტოლებაში $D(x)$ არის ინტეგრირებული PDF, მიღებული ფორმულა (4) ში, და $P(x)$ არის სანიმუშე PDF.

კარგი ზემო და ქვემო ზღვარების მიღების პრობლემა შეფარდებითი ენთროპიისათვის (entropy) იწვევს მნიშვნელოვან ინტერესს საინფორმაციო თეორიაში. ჩვენ ვიყენებთ ზემო ზღვარის შემდეგ შეფასებას

$$KL(D \parallel P) \leq \min \left[\sum_1^n \frac{D(x_i)^2}{P(x_i)} - 1, \sum_1^n \sqrt{\frac{D(x_i)}{P(x_i)}} |D(x_i) - P(x_i)| \right] \quad (6)$$

თუ KL მეტრული, დაანგარიშებული (5) ფორმულაში, მეტია ვიდრე ხარისხი, მიღებული (6) ფორმულაში, ჩვენ ვვარაუდობთ, რომ განათლების ხარისხი ან სამრეწველო პროცესები არ არიან ახლოს მოთხოვნად სტანდარტებთან. ამ

შემთხვევაში მიღებულ უნდა იქნას რელევანტური ზომები ხარისხის გაუმჯობესების მიმართულებით.

თუ ვივარაუდებთ, რომ ინტეგრირებული ნიმუშისა და აქტუალური, რეალური განაწილების შედარებამ მოგვცა უარყოფითი შედეგი: (6) ფორმულის ხარისხი მეტია ვიდრე (5). ეს კი ნიშნავს, რომ სასწავლო პროცესის ხარისხი არის სუსტი და ჩვენი ვალია გამოააშკარავოთ ის სასწავლო კურსები და ჯგუფები, რომლებმაც გამოიწვია აღნიშნული არასასურველი შედეგი.

მაშასადამე, ჩვენ უნდა შევიმუშაოთ ისეთი მეთოდი, რომლის მეშვეობითაც შესაძლებელი იქნება იმ კურსების (ან კურსის) დადგენა, რომელთა ხარისხი (პერფორმანსი) არ შეესაბამება მოდელის განაწილების მოთხოვნებს. ამასთანავე, ჩვენ შევეცდებით გამოვიკვლიოთ სწავლების ხარისხის გაუმჯობესების გზები აღნიშნულ კურსებში.

უპირველეს ყოვლისა, ჩვენ უნდა გავითვალისწინოთ უშუალოდ გამოცდები. სიმარტივისთვის, ვიღებთ 5 ჯგუფს, თითოეული მათგანი შედგება 20 სტუდენტისგან (სულ: 100 სტუდენტი). ამრიგად, ვიღებთ 100 ქულას მიღებულს გამოცდებში ორი განსხვავებული კურსისთვის. მეტიც, თითოეული გამოცდისთვის ვითვალისწინებთ რამოდენიმე ფაქტორს რამაც შეიძლება გავლენა იქონიოს ხარისხზე (ე.ი. მიღებულ ქულებზე). რათმაუნდა, ასეთი ფაქტორები დადგენადია და შესაძლებელია მათი დადგენა სტუდენტთა გამოკითხვის საფუძველზე (შესაბამისი კითხვარების შევსება). აქვე, სიმარტივისთვის ჩვენ ვითვალისწინებთ შემდეგი სახის ფაქტორებს (ზოგადად, ფაქტორების რაოდენობა არ არის გადამწყვეტი შემუშავებული მეთოდისთვის და შესაძლებელია ნებისმიერი რაოდენობის ფაქტორის ჩართვა):

1. სტუდენტთა ჯამური შუალედური შეფასება (“ჯშშ”), ანუ, სტუდენტის მიერ სემესტრის განმავლობაში ლაბორატორიული და პრაქტიკული სამუშაოებისთვის, ქვიზებისთვის, შუალედური გამოცდისთვის მიღებული

შეფასება; აღნიშნული პარამეტრის შესაძლებელი ღირებულებაა შემდეგი დიაპაზონი: 20÷60; პარამეტრის ღირებულებები შეივსება სტუდენტის მიერ კითხვარში.

2. საათების საშუალო რაოდენობა (კვირაში) (ვექტორი: “საშინაო დავალების საათები“), რასაც სტუდენტი ხარჯავს საშინაო დავალებებზე სემესტრის განმავლობაში; სავარაუდო ღირებულებები განისაზღვრება 0.1÷5 საათით; პარამეტრის ღირებულება შეივსება მასწავლებლის მიერ კითხვარში.
3. ქულათა საშუალო რაოდენობა (ვექტორი “საშუალო პრერეკვიზიტები“): რაც სტუდენტმა დააგროვა აღებული საგნის პრერეკვიზიტებისვის (ვექტორი “საშუალო პრერეკვიზიტები“); სავარაუდო ღირებულება იქნება 51÷100; პარამეტრის ღირებულება შეივსება სტუდენტის მიერ კითხვარში.
4. გამოცდის სირთულის ხარისხი (ვექტორი: “გამოცდის სირთულე“):

- 1 = არ საჭიროებს სწავლას/მომზადებას
- 2 = საჭიროებს ზედაპირულ გადახედვას
- 3 = საჭიროებს საკმაო მომზადებას
- 4 = საჭიროებს რეალურ სწავლას/მომზადებას
- 5 = საჭიროებს მნიშვნელოვან სწავლას/მომზადებას

პარამეტრის ღირებულებები ივსება კითხვარში მასწავლებლის მიერ. განვიხილოთ პირველი ფაქტორი (პარამეტრი). მოცემულია სტუდენტის მიერ ლაბორატორიული და პრაქტიკული სამუშაოებისთვის, ქვიზებისა და შუალედური გამოცდებისთვის მიღებული ქულების შემდეგნაირი განაწილება:

20	21	23	23	25	25	26	26	26	27	28	29	30	30	31	30	30	31	31	32
32	32	32	33	33	33	30	34	34	35	34	35	36	36	37	37	36	37	37	37
37	38	38	38	37	38	38	38	38	38	39	39	39	40	40	41	41	42	42	41
42	42	43	43	44	44	45	45	45	45	46	45	46	46	47	47	47	48	49	49
49	49	50	51	51	51	52	52	54	53	54	54	55	55	55	56	56	57	59	58

მეორე ფაქტორი - საათების საშუალო რაოდენობა (კვირაში) რასაც სტუდენტი ხარჯავს სახლში საშინაო დავალებების შესრულებისათვის სემესტრის განმავლობაში:

0.49	0.51	0.65	0.65	0.78	0.78	0.86	0.86	0.88	0.9	0.96	1.1	1.1
1.1	1.2	1.2	1.3	1.3	1.3	1.4	1.4	1.4	1.4	1.4	1.5	1.5
1.5	1.7	1.7	1.7	1.8	1.8	1.8	2	2	2.1	2.2	2.2	2.2
2.4	2.4	2.5	2.5	2.5	2.5	2.5	2.5	2.6	2.7	2.7	2.7	2.7
2.8	2.8	2.8	2.8	2.8	2.9	2.9	3.1	3.1	3.1	3.2	3.2	3.2
3.3	3.3	3.3	3.3	3.3	3.3	3.4	3.4	3.4	3.4	3.5	3.5	3.5
3.6	3.7	3.7	3.7	3.7	3.7	3.7	3.8	3.8	3.8	3.8	4.1	4.2
4.8	4.8	4.9										

მესამე ფაქტორი - 3. ქულათა საშუალო რაოდენობა, რაც სტუდენტმა დააგროვა

აღებული საგნის პრერეკვიზიტებისვის:

51	51	51	52	52	52	53	54	53	56	57	57	57	57	58	58	59	59	59	58
59	59	60	60	61	61	62	63	62	63	63	67	64	65	64	65	66	65	68	67
67	68	68	68	69	68	69	69	70	69	70	70	71	72	72	72	72	74	74	75
75	75	75	74	76	76	76	77	76	77	77	78	76	79	79	80	80	81	80	81
82	83	82	83	85	84	84	85	85	87	86	87	87	88	88	89	90	95	95	97

მეოთხე ფაქტორი - გამოცდის სირთულის ხარისხი; სირთულის ხარისხი ყველა სტუდენტისთვის არის 3 (საშუალო დონე).

მოცემულ ფაქტორებზე (პარამეტრებზე) დაყრდნობით მოხდა დამოუკიდებელი სამუშაოების ცხრილის ფორმულირება (4x100 მწკრივი “დამოუკიდებელი სამუშაოების ცხრილი“):

1 სვეტი 12-დან:

20	21	23	23	25	25	26	26	26	27	28	29
0.49	0.51	0.65	0.65	0.78	0.78	0.86	0.86	0.88	0.9	0.96	1.1
51	51	51	52	52	52	53	54	53	56	57	57
3	3	3	3	3	3	3	3	3	3	3	3

13 სვეტი 25-დან:

30	30	31	30	30	31	31	32	32	32	32	33
1.1	1.1	1.2	1.2	1.3	1.3	1.3	1.4	1.4	1.4	1.4	1.4
57	57	58	58	59	59	59	58	59	59	60	60
3	3	3	3	3	3	3	3	3	3	3	3

97 სვეტი 100-დან: 97

56	57	59	58
4.5	4.8	4.8	4.9
90	95	95	97
3	3	3	3

ეხლა კი ჩვენ ჩამოვყალიბებთ მართული სამუშაოების ცხრილს (ვექტორი: “მართული სამუშაოების ცხრილი“), ანუ, ქულები, რაც სტუდენტმა მიიღო გამოცდებიდან ერთერთზე:

12	12	17	18	21	22	23	24	24	24	26	27	28	28	28	30	30	31	31	33
33	34	35	36	37	39	40	40	41	41	43	45	46	46	46	46	46	48	50	50
51	53	54	55	55	55	55	56	56	57	57	57	58	62	63	64	64	65	66	66
66	67	67	67	70	71	72	73	73	74	75	77	77	77	78	78	79	80	80	80
81	81	82	82	82	83	83	84	86	87	88	88	89	89	90	90	92	97	99	99

როგორც ჩანს, ქულათა განაწილება შემდეგნაირია: სტუდენტთა დაახლოებით 50 %-ს აქვს 60 ან ნაკლები ქულა, დაახლოებით 30 %-ს აქვს ქულა 61-სა და 80-ს შორის, დაახლოებით 18 %-ს სტუდენტებისა აქვს ქულები 81-სა და 95-ს შორის და 2 &-ს კი ქულები 96-სა და 100 შორის. რათქმაუნდა, ქულათა აღნიშნული განაწილება არ შეესაბამება განაწილების (მოთხოვნილ) მოდელს.

ჩვენ უნდა გადავჭრათ შემდეგი საკითხი: დავადგინოთ ქულათა აღნიშნულ ფაქტორებზე (პარამეტრებზე) დამოკიდებულება (რაც ქმნის დამოუკიდებელი სამუშაოების ცხრილს) და შევეცადოთ იმ ფაქტორთა მინიმალური ღირებულების დადგენა, რომლებიც უზრუნველყოფენ პირველი მოდელისთვის რეალურ განაწილებას. ეს გამოიხატება იმაში, რომ იმ სტუდენტთა პროცენტული მაჩვენებელი, რომლებმაც მიიღეს 60-ზე ნაკლები ან 60 ქულა, უნდა შეადგენდეს 40 %-ს, მათი პროცენტული მაჩვენებელი, რომლებმაც მიიღეს 60-სა და 80-ს შორის ქულები, უნდა შეადგენდეს 20 %-ს, 81-სა და 95 ქულის ამღებთა პროცენტული რაოდენობა უნდა იყოს 30 % და ისინი, ვინც იღებენ 96-დან 100 ქულამდე უნდა შეადგენდნენ 10 %-ს. ქულათა რეალური პროცენტული მაჩვენებელი (იხ. ზემოთ) რამდენადმე განსხვავებულია.

აღნიშნული ამოცანის შესრულება უკავშირდება გარკვეულ სირთულეებს. სტუდენტთა მიერ მიღებული კონკრეტული ქულების ამ პარამეტრებზე დამოკიდებულების პროცენტული მაჩვენებლის თავისებურება სრულიად უცნობია. მეტიც, ჩვენს შემთხვევაში დამოკიდებულებები სავარაუდოდ არა-წრფივია.

შესაბამისად, შეუძლებელია რეგრესიული დამოკიდებულების ტიპის წინასწარ განსაზღვრა, რაც აუცილებელია რეგრესიულობის ანალიზის ჩასატარებლად.


ზემოთ მოყვანილ მსჯელობაზე დაყრდნობით ყველაზე ადექვატური მიდგომა იქნება ნეურალური ნეთვორქების მეთოდის გამოყენება. აღნიშნული მიდგომის გამოყენებით შესაძლებელი იქნება თეორიულად გამართლებული და ობიექტური კვლევის მეშვეობით ზემოთ აღნიშნული დამოკიდებულების ფარული თავისებურების გამოვლენა. ნეირონული ქსელები - მოდელირების ძლიერი საშუალება, რაც საშუალებას იძლევა მოხდეს მეტად კომპლექსური დამოკიდებულებების კვლავწარმოება. ნეირონული ქსელები არიან არასწორხაზოვანი ბუნების. ამასთანავე, ნეირონული ქსელები შეუძლიათ გამუკლავდნენ “განზომილებითობის პრობლემას“, რომელიც არ იძლევა იმის საშუალებას, რომ მოვახდინოთ არასწორხაზოვან დამოკიდებულებათა სიმულირება ცვლადთა დიდი რაოდენობის არსებობის შემთხვევაში. აღნიშნული ურთიერთქმედების განსაზღვრის შემდეგ კი შეიძლება განისაზღვროს პარამეტრის აუცილებელი ღირებულება. მოცემული მიდგომის მიზანიც სწორედ ეს არის.

ჩვენი ამოცანისთვის ნეურალური ნეთვორქის მოდელის შექმნის მიზნით ჩვენ გამოვიყენებთ განზოგადებული რეგრესიის ნეირონულ ქსელებს (*the Generalized Regression Neural Network (GRNN)*). ცნობილია, რომ აღნიშნული მეთოდი მეტად ეფექტურია კომპლექსური დამოკიდებულებების მორგებისა და მიახლოებისთვის. ნეურალური ნეთვორქის განზოგადებული რეგრესია წარმოადგენს რადიალური ბაზისური ნეთვორქების განსაკუთრებული სახეობაა (Radial Basis Networks)[4]. აქ, რადიალური ბაზისური ფუნქცია (*radial basis function*) (ასევე, ცნობილი როგორც *kernel function*) გამოიყენება დამოკიდებული ცვლადების ღირებულების წინასწარ განსაზღვრის მიზნით გარკვეულ საფეხურზე სხვა დაკავშირებული ელემენტებში დამოკიდებულ ცვლადთა ღირებულებების გათვალისწინებით. რადიალური ბაზისური ფუნქცია გამოიყენება დისტანციისთვის, რათა გამოვლილ იქნას

თითოეული ელემენტის სიმძიმე (გავლენა). ფუნქციას ეწოდება რადიალური საბაზისო იმიტომ, რომ რადიუსის დისტანცია წარმოადგენს ფუნქციის შინაარსს.

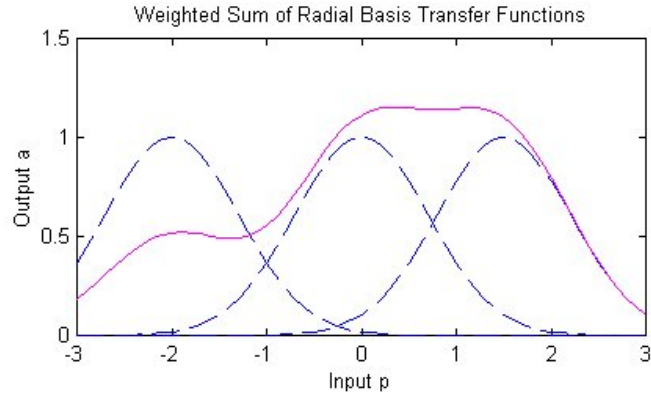
სიმძიმე = /რადიალური ბაზისური ფუნქცია /RBF (დისტანცია)

რაც უფრო შორსაა სხვა წერტილი მოცემული წერტილისგან (რომლისთვისაც ტარდება პროგნოზირება), მით უფრო ნაკლები გავლენა გააჩნია მას.

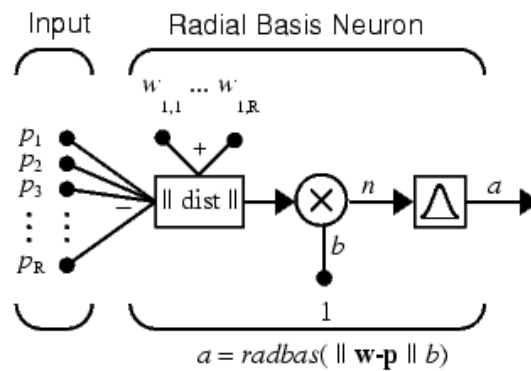


შესაძლებელია განსხვავებული ტიპის რადიალური საბაზისო ფუნქციების გამოყენება მაგრამ, მათ შორის ყველაზე გავრცელებულია Gaussian-ის ფუნქცია (Gaussian function). მოცემული წერტილისთვის საუკეთესო პროგნოზირებული ღირებულება (რომლისთვისაც ტარდება პროგნოზირება) შეიძლება მიღებულ იქნას სხვა წერტილების ღირებულებების შეჯამებით რაც გაიზომება რადიალური საბაზისო ფუნქციის მეშვეობით.


რადიალური საბაზისო ფუნქციის უმაღლესი წერტილი ყოველთვის განლაგებულია იმ წერტილზე, რომელსაც იგი ზომავს. ფუნქციის სიგმას მნიშვნელობა (σ) განსაზღვრავს რადიალური საბაზისო ფუნქციის განვრცობადობას, ანუ, რამდენად სწრაფად მცირდება ფუნქცია იმისდა პარალელურად, რომ გაიზარდა დისტანცია წერტილიდან.



კიდევ უფრო დიდი სიგმა მნიშვნელობებისა და განვრცობადობის შემთხვევაში, დამორებულ წერტილებს გააჩნიათ მეტი გავლენა. იმ შემთხვევაში, თუ სიგმას მნიშვნელობები მეტად დიდია, მაშინ მოდელი ვერ შეძლებს ახლოს მოერგოს ფუნქციას. თუკი სიგმას მნიშვნელობები მეტად მცირეა, მოდელი ზედმეტად მოერგება მონაცემებს რადგანაც, თითოეულ საწვრთნელ წერტილს ექნება ზედმეტი გავლენა. MATLAB-ის მეთოდი იყენებს შეერთებული დახრილობის ალგორითმს ოპტიმალური სიგმა მნიშვნელობების გამოთვლისთვის. მოცემულია რადიალური საბაზისო ნეთვორქი R შენატანებით:



მოცემულია განზოგადებული რეგრესიის ნეირონული ქსელების (the Generalized Regression Neural Network) დიაგრამა:



ყველა განზოგადებული რეგრესიის ნეირონულ ქსელებს გააჩნია ოთხი ეტაპი:


- **შენატანების ეტაპი** - თითოეულ პროგნოზირებად ცვლადს შეესაბამება თითო ნეირონი შრეზე. კატეგორიული ცვლადების შემთხვევაში $N-1$ ნეირონები გამოიყენება სადაც, N წარმოადგენს კატეგორიების ნომერს. შენატანების ნეირონები (ან პროცესირება შენატანის ეტაპამდე) ახდენს მნიშვნელობათა სტანდარტიზირებას მედიანის გამოყვანითა და ინტერკვარტილური დიაპაზონის დაყოფით. შენატანის ნეირონები ამარაგებენ მნიშვნელობებს თითოეული ნეირონისთვის ფარულ შრეებში.
- **ფარული შრე** - აღნიშნულ შრეს გააჩნია ერთი ნეირონი თითოეული შემთხვევისთვის სავარჯიშო მონაცემთა ცხრილში. ნეირონი ინახავს პროგნოზირებადი ცვლადების მნიშვნელობებს თითოეული შემთხვევისთვის სამიზნე მნიშვნელობის პარალელურად. შენატანთა მნიშვნელობის X ვექტორის წარდგენისას შენატანთა შრეში ფარული ნეირონი ითვლის ევკლიდესურ დისტანციას სატესტო შემთხვევისა ნეირონის ცენტრალური წერტილიდან და შემდეგ მიუსადაგებს რადიალურ ბაზისურ ფუნქციას (radial basis function) სიგმას მნიშვნელობების გამოყენებით. მიღებული შედეგი (მნიშვნელობა) გადაეცემა ნეირონებს ნიმუშის შრეში.

- **სანიმუშე შრე / საერთო შრე** - სანიმუშე შრეში არსებობს მხოლოდ ორი ნეირონი. ერთი ნეირონი წარმოადგენს შეჯამების დენომინატორ ერთეულს ხოლო მეორე არის მისი ნუმერატორი. შეჯამების დენომინატორ ერთეული უმატებს მნიშვნელობას რაც მოდის თითოეული ფარული ნეირონიდან. ნუმერატორი ერთეული კი უმატებს მნიშვნელობას რაც გამრავლებულია თითოეული ფარული ნეირონის რეალური სამიზნე მნიშვნელობაზე.
- **გადაწყვეტილების შრე** - აღნიშნული შრე ჰყოფს შეჯამების ნუმერატორ ერთეულში დაგროვებულ მნიშვნელობას შეჯამების დენომინატორი ერთეულის მნიშვნელობაზე და იყენებს მიღებულ შედეგს როგორც პროგნოზირებად სამიზნე მნიშვნელობას.

სტანდარტული პირდაპირი ნეთვორქებისგან განსხვავებით განზოგადებული რეგრესიის ნეირონული ქსელების (the Generalized Regression Neural Network) გამოანგარიშებას ყოველთვის შეუძლია შეეთავსოს გლობალურ გადაწყვეტას და არ იყოს შეზღუდული ლოკალური მინიმუმით.

ჩვენ MATLAB-ის სამართავ სისტემას სახელად “nntool” ვაძლევთ შემდეგ სახელს: “Neural Networks”. შემდეგ ჩვენ გადმოგვაქვს (დილაკ ‘Import’-ის მეშვეობით) ორი მონაცემთა კრებული: ‘independent_training_set’ (დამოუკიდებელი სამუშაოს ცხრილი) და ‘dependent_training_set’ (მართული სამუშაოს ცხრილი). შემდეგ ჩვენ შევქმნით განზოგადებული რეგრესიის ნეირონული ქსელების ტიპის ნეირონულ ქსელს რაც არის “განზოგადებული რეგრესიის ნეურალური ნეთვორქის“ (GGRNI) იდენტური. აქ ჩვენ ვანიჭებთ და ვავრცელებთ უცვლელ მნიშვნელობას 0.7. გამოყენებულია ცხრილი რომელიც 1-ზე ნაკლებია, შენატანების მნიშვნელობებს შორის დისტანცია, იმისთვის, რომ მივიღოთ ფუნქცია რომელიც ერგება ინდივიდუალურ მონაცემებს საკმაოდ მჭიდროდ. მცირე ცხრილი მონაცემებს უფრო კარგად მოერგებოდა მაგრამ იგი ნაკლებად მოქნილი იქნება.

ქსელი შემდეგნაირად გამოიყურება:



როგორც ზემოთ აღინიშნა, განზოგადებული რეგრესიის ნეირონული ქსელების (the Generalized Regression Neural Network (GRNN) უპირატესობა მდგომარეობს იმაში, რომ ტრენინგის პროცესი ტარდება ნეთვორქის შექმნის პარალელურად. შესაბამისად, შესაძლებელია გამოვიყენოთ ნეთვორქი ახალი მონაცემებისთვის.

განზოგადებული რეგრესიის ნეირონული ქსელები (GRNN) გამოიყენება სწავლების პროცესის ზოგადი ხარისხის დონის ინტეგრირებული პარამეტრების რელევანტური მნიშვნელობების დადგენის პროცედურაში, რაც განხილულია მოცემულ თეზისში. აღნიშნულ პროცედურაში ვიყენებთ პარამეტრების მნიშვნელობათა ძიების მეთოდს რაც ამკვიდრებს გენეტიკურ ალგორითმსა (**genetic algorithm (GA)**) და სასურველობის ფუნქციებს (**desirability function**). უფრო კონკრეტულად, პროცედურა ითვლის ინტეგრირებული PDF-ს მრუდს. ინტეგრირებული PDF-ს მრუდი უნდა იყოს შედარებული სანიმუშე PDF-ს მრუდთან რომელიც მიღებულ იქნა ზემოთ. განაწილების სიახლოვის დასადგენად (და შესაბამისად, სწავლების პროცესის ხარისხის განსასაზღვრად) ჩვენ ვიყენებთ კულბახ-ლეიბლერის გადახრას (Kullback–Leibler Divergence). დავუშვათ, D და P უდრის ორ PDF-ს სადაც, n არის ვექტორთა განზომილება $\mathbf{x} = (x_1, x_2, \dots, x_n)$.

ნაშრომში ჩვენ ვიყენებთ “კარგი“ ზედა ზღვარის შემდეგ შეფასებას ($UBEst(\mathbf{x})$), $KL(\mathbf{x})$ -სთვის:

$$UBEst(\mathbf{x}) = \min \left[\sum_1^n \frac{D(x_i)^2}{P(x_i)} - 1, \sum_1^n \sqrt{\frac{D(x_i)}{P(x_i)}} |D(x_i) - P(x_i)| \right]$$

ამგვარად, ზემოთ მოყვანილი მსჯელობის შესაბამისად, მოცემული \mathbf{x} ვექტორისთვის ვექტორით შესაბამისობის ფუნქციას (the **fitness function**) $FF(\mathbf{x})$:

$$FF(\mathbf{x}) = KL(\mathbf{x}) - UBEst(\mathbf{x})$$

გავიხსენოთ, რომ \mathbf{x} ვექტორი გამოთვლილია განზოგადებული რეგრესიის ნეირონული ქსელების (the Generalized Regression Neural Network (GRNN) დანერგვის მეშვეობით, რაომელიც ნავარაუდებია, როგორც მეტამოდელი მოცემულ ნაშრომში. შევიძუშაოთ შემდეგი ჩაწერის სისტემა:

\mathbf{x} - გადაწყვეტის ვექტორი GA ოპტიმიზაციის პროცესისთვის

$f(\mathbf{x})$ - უშუალო შესაბამისობის ფუნქციის შედეგი (როდესაც გამოიყენება ინტეგრირებული PDF-ს შედეგის მნიშვნელობები)

$p(\mathbf{w}, \mathbf{x})$ - ინტეგრირებული შესაბამისობის ფუნქციის შედეგი რომელიც წინასწარ განსაზღვრულია განზოგადებული რეგრესიის ნეირონული ქსელების მეშვეობით \mathbf{w} მაჩვენებლების გამოყენებით როდესაც პასუხი \mathbf{x} გამოიყენება როგორც შენატანი (inputs)

\mathbf{x}^* - GA ოპტიმიზაციის პრობლემისთვის ცნობილი საკითხის საუკეთესო გადაწყვეტა
GA ოპტიმიზაციის პრობლემის პარალელურად არსებობს ტრენინგის პროცესიც, რომელიც შედგება \mathbf{w} მაჩვენებლების ფორმულირების მიგნებისგან რაც ახდენს ცდომილების გაერთიანებულ საზომს - საშუალო კვადრატული ცდომილება (MSE).

ვივარაუდოთ, რომ \mathbf{x} -ის ოპტიმალური მნიშვნელობების ძიებისას პროცედურა რომელიც გამოიყენება ოპტიმიზაციის პრობლემასთან მიმართებაში ახდენს ყველა პასუხის გენერირებას \mathbf{x} . მიაქციეთ ყურადღება იმ ფაქტს, რომ \mathbf{x}^* ეკუთვნის ALL წყობას. დავუშვათ, TRAIN არის შემთხვევითი ნიმუში პასუხებისა ALL წყობაში შემდეგნაირად: $|TRAIN| \leq |ALL|$. შესაბამისად, ტრენინგის პრობლემას, როგორც:

$$\text{Min } g(\mathbf{w}) = \frac{1}{|TRAIN|} \sum_{\mathbf{x} \in TRAIN} (f(\mathbf{x}) - p(\mathbf{w}, \mathbf{x}))^2$$

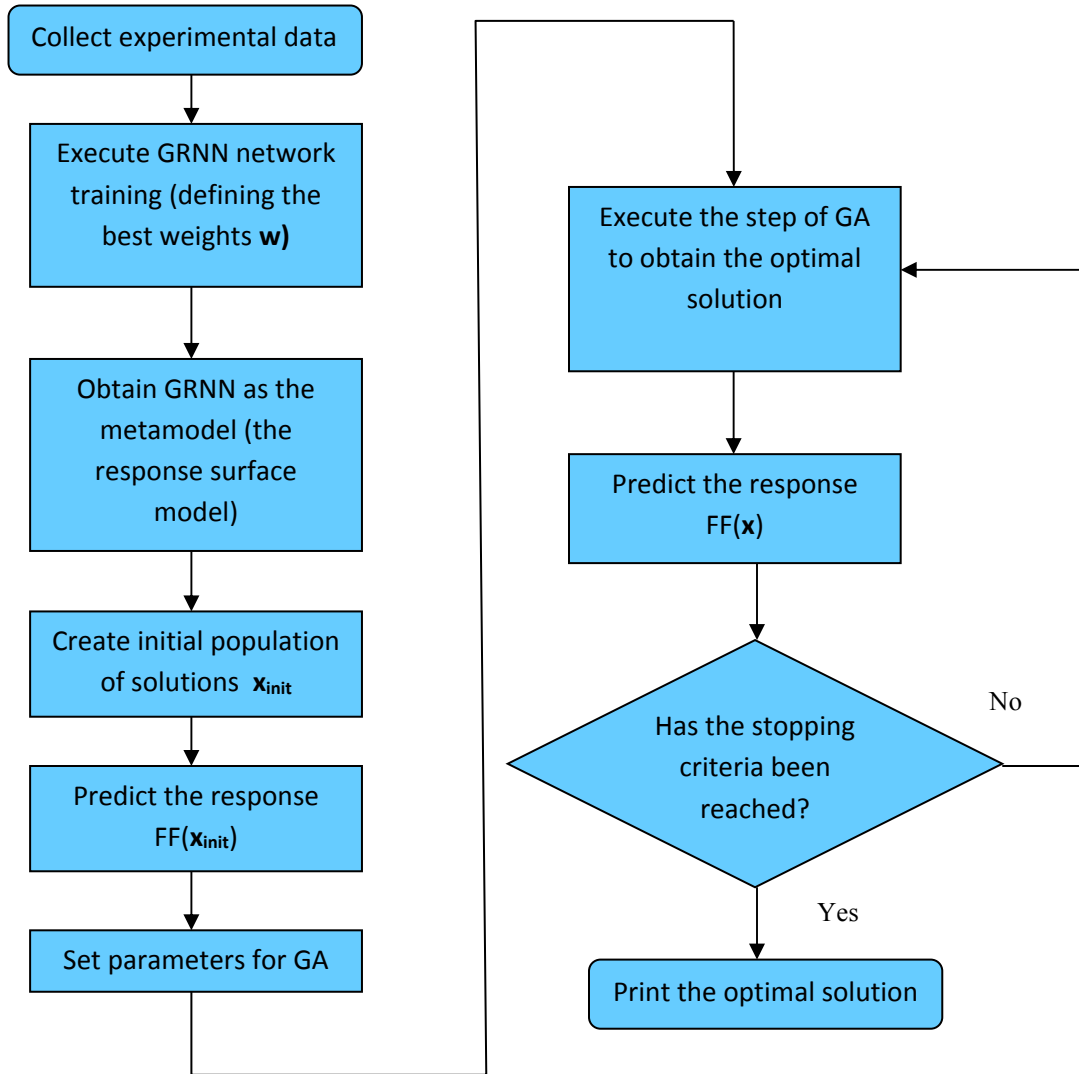
სადაც, \mathbf{w} არის ტრენინგის პრობლემის ოპტიმიზაციის ცვლადების წყობა. რადგანაც ტრენინგის პრობლემა ვერ გადაწყდება მანამ, სანამ არ გვექნება $|TRAIN|$ საკითხის

გადაჭრა ALL წყობაში, GA ძიების პროცედურა უნდა ოპერირებდეს განზოგადებული რეგრესიის ნეირონული ქსელების (the Generalized Regression Neural Network (GRNN) დახმარების გარეშე როდესაც იგი გამოითვლის საცდელ გადაწყვეტას x რეალური შესაბამისობის ფუნქციის გამოყენებით (როდესაც გამოიყენება რეალური ინტეგრირებული PDF-ს შედეგების მნიშვნელობები). GA ოპტიმიზაციის ძიების განვითარების პარალელურად ALL გადაწყვეტილებებიც შესაბამისად იზრდება იმგვარად, რომ მოხდეს შესაფერისი ტრენინგის წყობის კონსტრუირება. ტრენინგის პრობლემის მოგვარება ხდება პერიოდულად ახალი TRAIN წყობების მეშვეობით იმ მიზნით, რომ ამაღლდეს პროგნოზირების სიზუსტის ხარისხი რაც გენერირებულია დაკავშირებული ნეირონული ქსელების (GRNN) მიერ. ცხრილი 4 აჩვენებს აღნიშნული მიდგომის ფუნქციონირების სქემას.

ოპტიმიზირების საფეხური მოიცავს GA-ს შესაბამისობის ფუნქციის ოპტიმიზაციის მიზნით და შესაბამისი კომბინაციების მნიშვნელობებს დამოუკიდებელი პარამეტრებისა საკითხის შესაბამისი გადაწყვეტის სივრციდან. აქ კი, შესაძლებელი გადაწყვეტა წარმოადგენს ქრომოსომას (**chromosome**). ქრომოსომა წარმოადგენს რიგის სახეობას, რომელიც ორგანიზებულია პრობლემის პარამეტრების მნიშვნელობების თანმიმდევრულობის მეშვეობით. ინდივიდუალური ნაწილები ქრომოსომაზე რომლებშიც ინახება პარამეტრების მნიშვნელობები განისაზღვრება როგორ გენები (**genes**). გენები ქრომოსომებში ფორმირდება პარამეტრების მნიშვნელობების მეშვეობით. ქრომოსომები ვითარდება თანმიმდევრული განმეორებების მეშვეობით რომლებსაც ეწოდება გენერაციები (**generations**). თითოეული გენერაციისას ქრომოსომები ფასდება შესაბამისობის ფუნქციის (fitness function) მეშვეობით.

ოპერაციული საფეხურები მოცემულია შემდეგი სახით:

ნაბიჯი 1. წყობის პოპულაციის ზომა, გადაკვეთის კოეფიციენტი P_c და მუტაციის კოეფიციენტი P_m . 1 ზომის რიგის შემთხვევითი პოპულაციის ინიციალიზება. მაქსიმუმი დაშვებული გენერაციის რაოდენობის არჩევა t_{max} . Set $t=0$



ნახაზი 4. GA ოპტიმიზაციის საძიებო პროცედურის სქემა

ნაბიჯი 2. შესაბამისობის ფუნქციის გამოთვლა ტრენირებული განზოგადებული რეგრესიის ნეირონულ ქსელებში (GRNN) პარამეტრების მნიშვნელობათა ჩართვით

ნაბიჯი 3. If $t < t_{max}$, შემდეგ წაშლა

ნაბიჯი 4. პოპულაციაზე რეპროდუქციის პერფორმირება

ნაბიჯი 5. მწკრივების წყვილზე გადაკვეთის პერფორმირება ალბათობის P_c -ის მეშვეობით

ნაბიჯი 6. მწკრივებზე მუტაციის პერფორმირება ალბათობის P_M -ის მეშვეობით.

ნაბიჯი 7. მწკრივების მნიშვნელობათა გამოთვლა. $t=t+1$ აწყობა და მე-2 საფეხურზე გადასვლა

ნაბიჯი 8. პარამეტრების მნიშვნელობების ოპტიმალური კომბინაციების მიღება და სათანადო შესაბამისობის ფუნქცია FF.

ზემოთ მოყვანილი პროცედურაში გამოიყენება Matlab-ის გენეტიკური ალგორითმის ფუნქცია **ga** შემდეგი სინტაქსით

$$[x, fval] = ga(@fitnessfun, nvars, options)$$

სადაც:

- *@fitnessfun* არის შესაბამისობის ფუნქციის ტიტული სადაც, *fitnessfun.m* არის M- ფაილი რომელიც ითვლის შესაბამისობის ფუნქციას
- *nvars* არის დამოუკიდებელი ცვლადების რაოდენობა შესაბამისობის ფუნქციისთვის
- ოფციები წარმოადგენს სტრუქტურას, რომლებიც შეიცავენ ოფციებს გენეტიკური ალგორითმისთვის. იმ შემთხვევაში , თუკი ვერ გაივლით აღნიშნულ არგუმენტს, **ga** იყენებს დეფოლტირებულ ოფციებს.

შედეგები მოცემულია:

- **x** — ვექტორი სადაც საბოლოო მნიშვნელობა მიიღება
- **fval** - შესაბამისობის ფუნქციის საბოლოო მნიშვნელობა

ჩვენი პრობლემისთვის შესაბამისობის ფუნქცია არის FF (ფუნქციის ტიტული $@FF$, $FF(\mathbf{x}) = KL(\mathbf{x}) - UBEst(\mathbf{x})$), **nvars**-ის მნიშვნელობა არის 4 – პარამეტრების რაოდენობა (მთლიანი შუალედური შეფასება (ინტეგრირებული ყველა საგნისთვის) სტუდენტისთვის, საათების ჯამური (ინტეგრირებული) რაოდენობა რასაც ხარჯავს თითოეული სტუდენტი საშინაო დავალებებზე, ქულათა საშუალო რაოდენობა, რასაც თითოეული სტუდენტი იღებს ინტეგრირებული საგნების პრერეკვიზიტებისთვის, ინტეგრირებული გამოცდების სირთულის დონე).

პროცედურა ტარდება და შესაბამისობის ფუნქციის საბოლოო მნიშვნელობა როდესაც ტერმინირებული ალგორითმი არის $fval = 0.02184$ – რას საკმაოდ ახლოა თეორიულად გამოთვლილ მნიშვნელობასთან: 0.01851.

საბოლოო ვექტორი x ამ შემთხვევაში არის [16; 1.26; 54; 3]. გავიხსენოთ, რომ x ვექტორის კომპონენტები არიან:

x (1) - სტუდენტის ჯამური შუალედური (ინტეგრირებული ყველა საგნისთვის) შეფასება (=16);

x (2) - საშუალო (ინტეგრირებული) რაოდენობა საათებისა რასაც თითოეული სტუდენტი ხარჯავს საშინაო დავალებებზე (=1.26)

x (3) - ქულათა საშუალო რაოდენობა რასაც იღებს თითოეული სტუდენტი ინტეგრირებული საგნის ყველა პრერეკვიზიტებისთვის (=54)

x (4) - ინტეგრირებული გამოცდის სირთულის დონე (=3)

როგორც GA-ს ოპტიმიზაციის პროცედურის დეტალებიდან ჩანს, მოცემული მიდგომა ეფექტურია საგანმანათლებლო დაწესებულებაში სწავლის პროცესის ზოგადი ხარისხისა და კრიტიკული მნიშვნელობების რელევანტური პარამეტრების დადგენისა და სწრაფი ანალიზისთვის. მხოლოდ ინტეგრირებული ინდიკატორების მნიშვნელობები გათვალისწინებულია GA პროცედურაში. არა დამაკმაყოფილებელი მნიშვნელობების შემთხვევაში რაც მიიღება პროცედურის მეშვეობით, აუცილებელია ხარისხის გაზრდის მიზნით რელევანტური ზომების მიღება. თუმცა, აღნიშნულ მეთოდს გააჩნია უარყოფითი მხარეებიც. საქმე იმაშია, რომ განსხვავებულ საგნებს შეიძლება გააჩნიდეს პარამეტრების განსხვავებული ოპტიმალური მნიშვნელობები. მაგალითად, საათების სასუალო რაოდენობა რასაც თითოეული სტუდენტი ხარჯავს საშინაო დავალებებზე შეიძლება განსხვავდებოდეს, მაგალითად, მათემატიკასა და ისტორიისთვის. შემოთავაზებული GA-ს პროცედურა არ ასხვავებს აღნიშნულ ფაქტორებს და არ შეუძლია გაითვალისწინოს განსხვავებულ საგანთა სხვადასხვა სპეციფიკური თავისებურებები. ამგვარად, GA-ს პროცედურა ვერ შემოგვთავაზებს ისეთ ოპერაციებს, რომლებსაც შეუძლია სწავლების პროცესის ხარისხის

გაუმჯობესება კონკრეტული საგნისთვის. რათქმაუნდა, პროცედურას გააჩნია ისეთი ვარიანტი, რომელიც ოპერირებს არა ინტეგრირებული PDF-ს მეშვეობით (PDF ცალკეული საგნისათვის), მაგრამ მას აკლია გარკვეული უპირატესობა რომლსაც გააჩნია პროცედურის ინტეგრირებული ვარიანტი. ამ პრობლემასთან გამკლავებისთვის მოცემული ნაშრომის ფარგლებში შემუშავდა სხვა პროცედურა, რომელსაც შეუძლია სწავლების პროცესის არადამაკმაყოფილებელი ხარისხის დონის გამოვლენა ცალკეულ საგანთან მიმართებაში და შემოგვთავაზოს რელევანტური ზომები ამავე საგნის ხარისხის გასაუმჯობესებლად.

ალტერნატიულ თანმიმდევრობით ადაპტაციურ პროცედურაში გამოვლინდება სწავლების პროცესის ხარისხის დონე ცალკეული საგნისთვის. შემოთავაზებული პროცედურა არსებითად იყენებს თანმიმდევრობითი ადაპტაციური სტრატეგიის პრინციპებს საექსპერიმენტო ობიექტების თანმიმდევრობითი მაგალითებით. ამოცანის გადასაჭრელად (ფაქტორთა მინიმალური მნიშვნელობის დადგენა, რაც უზრუნველყოფს ტესტირების შეფასების (ცალკეული საგნისთვის) უშუალო განაწილებას) ჩვენ შეგვიძლია შევცვალოთ ერთერთი ფაქტორის მნიშვნელობა (ან ყველა ფაქტორის). ცვლილება შეიძლება იყოს ფაქტორის გაზრდა ან შემცირება (იმასთან კავშირში, უშუალო ქულების პროცენტული მაჩვენებელი ცოტაა თუ მეტია ნიმუშ პირველზე). ჩაჭრილი სტუდენტების პროცენტულ მაჩვენებელს რაც შეეხება (ისინი, ვინც აიღეს 60 ქულაზე ნაკლები), ცვლილებები შემდეგნაირად გამოიყურება: თუკი უშუალო პროცენტული მაჩვენებელი მეტია ვიდრე ნიმუში პირველი, ალგორითმმა უნდა გაზარდოს პირველი სამი ფაქტორის მნიშვნელობები (სტუდენტის ჯამური შუალედური შეფასება, საათების საშუალო რაოდენობა რასაც თითოეული სტუდენტი ხარჯავს სასიანო დავალებებზე, საშუალო ქულების რაოდენობა რასაც თითოეული სტუდენტი იღებს საგნის ყველა პრერეკვიზიტებისთვის) და, შესაძლებელია, გამოცდის სირთულის დონის დაკლება (იმ შემთხვევაში, თუკი პირველი სამი ფაქტორის ცვლილებებმა არ მოიტანა დადებითი შედეგი).

ფაქტორების (პრიორიტეტების) წყობა რომლებიც უნდა შეიცვალოს განსაზღვრულია ადმინისტრაციის მიერ. ერთერთი ვარიანტი პრიორიტეტებისა შეიძლება იყოს:

1. სტუდენტის ჯამური შუალედური შეფასება
2. საათების საშუალო რაოდენობა რასაც თითოეული სტუდენტი ხარჯავს საშინაო დავალებებზე
3. თითოეული სტუდენტის ქულების საშუალო რაოდენობა რასაც ისინი იღებენ კონკრეტული საგნის ყველა პრერეკვიზიტისათვის
4. გამოცდის სირთულის დონე

სხვა ოფციაა ის, როდესაც ყველა მოცემულ ფაქტორს ენიჭება ერთნაირი პრიორიტეტი.

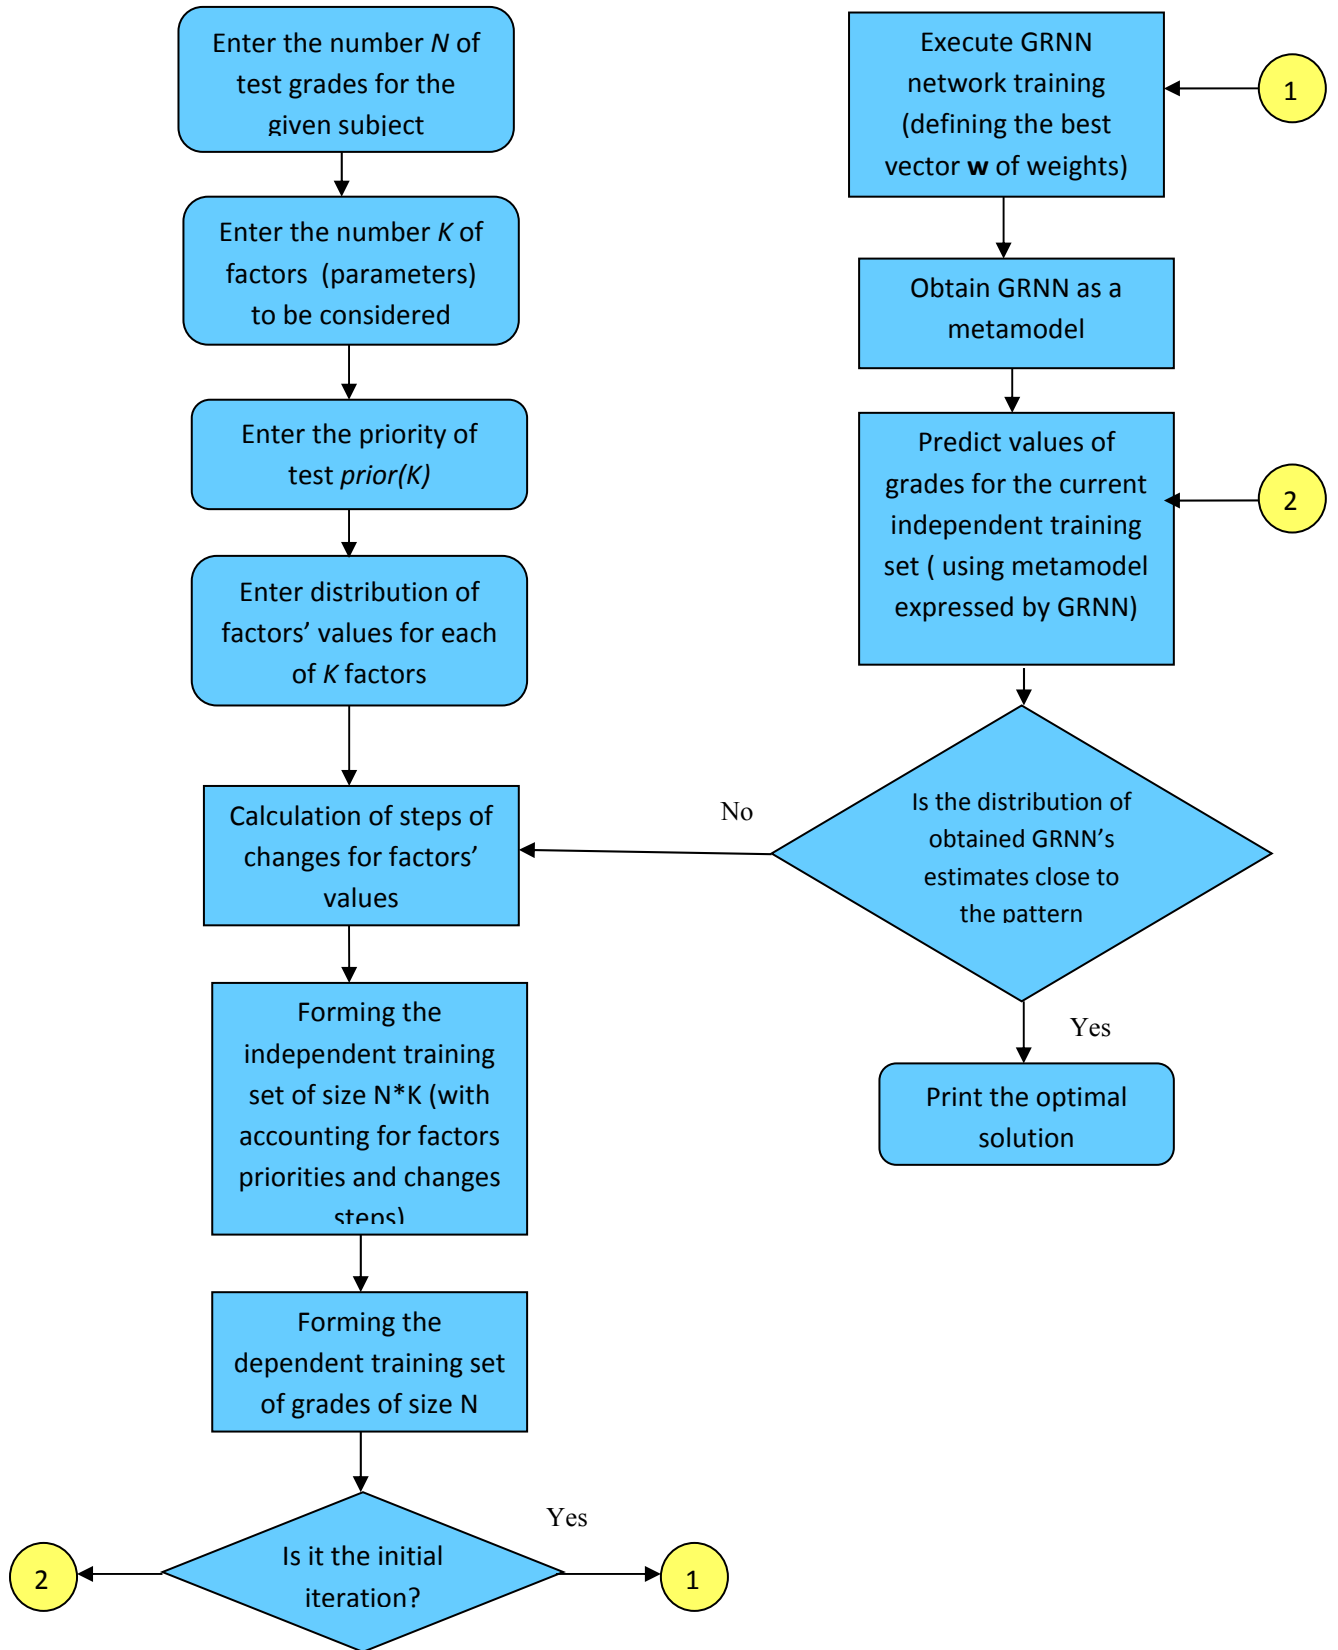
სხვა პროცენტული მაჩვენებლებისთვის (იმ სტუდენტების პროცენტული მაჩვენებელი, რომლებმაც მიიღეს 61-დან 80 ქულამდე, 81-დან 95-მდე, 96-დან 100-ის ჩათვლით) შემდეგნაირი წესი მოქმედებს: თუკი უშუალო პროცენტული მაჩვენებელი ნაკლებია ნიმუშ პირველზე, ალგორითმი სავარაუდოდ ზრდის პირველი სამი ფაქტორის მნიშვნელობას რათა შემცირდეს გამოცდის სირთულის დონე (იმ შემთხვევაში, თუკი ცვლილებებმა პირველ სამ ფაქტორში არ მოიტანა დადებითი შედეგი). თუკი უშუალო პროცენტული მაჩვენებელი მეტია ნიმუშ ერთზე, შესაძლებელია აუცილებელი იყოს სირთულის დონის ამაღლება (რადგანაც პირველი სამი ფაქტორის მნიშვნელობათა შემცირება არ არის რეკომენდირებული პედაგოგიური შეხედულებებიდან გამომდინარე). აქ აუცილებელია შემდეგი მომენტის გათვალისწინება: ფაქტორების მნიშვნელობების შეცვლა გათვლილია იმაზე, რომ დადგენილ იქნას ის მნიშვნელობები, რაც მომავალში იქნება გამოსადეგი რაც იმას ნიშნავს, რომ ფაქტორების განახლებული მნიშვნელობები შეიძლება გათვალისწინებულ და რეკომენდირებულ იქნას სამომავლო გამოცდების მომზადების მხრივ. მაგალითად, თუკი ჩაჭრილი სტუდენტებისთვის პრერეკვიზიტების საშუალო ქულა, რაც გამოთვლილ იქნა შემოთავაზებული

პროცედურის მეშვეობით არის, ვთქვათ 68, ასეთ შემთხვევაში ადმინისტრაციამ შეიძლება შეიმუშაოს რეგულაცია იმის თაობაზე, რომ სტუდენტები, რომლებსაც აქვთ 68 ქულაზე ნაკლები პრერეკვიზიტებისთვის, არ დაიშვებიან გამოცდაზე, წინააღმდეგ შემთხვევაში ნიმუშის მოთხოვნების დარღვევების შესაძლებლობა იმატებს და შესაბამისად, სწავლების პროცესი ვერ უმჯობესდება. ამასთანავე, სავარაუდოა, რომ სტუდენტთა სწავლის შესაძლებლობა (რაც გამოიხატება გამოცდებში აღებული ქულებით) არ შეიცვლება მომავალში. შეთავაზებული მიდგომის ძირითადი მიზანია უნივერსიტეტის ადმინისტრაციის მიერ სწავლების პროცესის ხარისხის მოთხოვნების დაკმაყოფილება.

ცხრილი 5 აჩვენებს შეთავაზებულ თანმიმდევრულ ადაპტაციურ პროცედურას.

ზემოთ ხსენებულის შესაბამისად ჩვენ შეგვიძლია გავაგრძელოთ ახალი ტრენინგის წყობის ფორმულირება მაგალითად, ჯამური შუალედური შეფასების ფაქტორისთვის. ცვლილება გამოიხატება: (მაქსიმალური მნიშვნელობა - მინიმალური მნიშვნელობა) / 10, ან $(59-20)/10=3.9$. დამრგვალებული მნიშვნელობა იქნება 4. განახლებული ფაქტორის მნიშვნელობებია:

24	25	27	27	29	29	30	30	30	31	32	33	34	34	35	34	34	35	35	36
36	36	36	37	37	37	34	38	38	39	38	39	40	40	41	41	40	41	41	41
41	42	42	42	41	42	42	42	42	42	43	43	43	44	44	45	45	46	46	45
46	46	47	47	48	48	49	49	49	49	50	49	50	50	51	51	51	52	53	53
53	53	54	55	55	55	56	56	58	57	58	58	59	59	59	60	60	60	60	60



ნახაზი 5. თანმიმდევრული ადაპტაციური პროცედურა

ჩვენ ისევ მივმართავთ განზოგადებული რეგრესიის ნეირონულ ქსელებს (GRNN) და წარმოვადგენთ განახლებულ ტრენინგის წყობას. შედეგები (ქულების განახლებული მნიშვნელობები) შემდეგნაირად გამოიყურება:

18	21	22	23	24	24	26	28	26	28	32	33	33	33	35	34	36	36	36	36
36	36	40	41	42	42	41	46	46	46	46	54	46	47	46	47	54	48	56	54
54	57	57	57	57	57	60	60	64	60	64	64	64	67	67	67	67	75	75	72
75	75	77	77	77	77	77	78	77	78	80	80	77	80	80	80	80	82	82	82
82	83	84	86	86	86	86	87	89	89	89	90	90	90	90	90	90	92	99	99

როგორც ჩანს, ჩაჭრილთა პროცენტული რაოდენობა შემცირდა და მოცემულ ეტაპზე შეადგენს 46 %-ს.

შემდგომი ქმედება დამოკიდებულია ფაქტორებს შორის პრიორიტეტების განაწილებაზე. თუკი ყველა ფაქტორს გააჩნია იდენტური პრიორიტეტები, მაშინ მომდევნო ქმედება იქნება შემდეგი ფაქტორების მნიშვნელობების შეცვლა (აქ ეს გამოიხატება საათების სასუალო რაოდენობით, რასაც თითოეული სტუდენტი ხარჯავს საშინაო დავალებაზე). თუკი ახლანდელ ფაქტორს გააჩნია უფრო მეტი პრიორიტეტი, მაშინ მისი მნიშვნელობები იზრდება ერთი საფეხურით (უდრის 4-ს), განახლებული დამოუკიდებელი ტრენინგის წყობა ჩართულია ქსელში, განახლებული ქულები თავიდან ანალიზირდება და ასე შემდეგ. თუკი ფაქტორის სავარაუდო მნიშვნელობების რიგის ბოლო დადგინდება და სასურველი შედეგი ვერ მიიღწევა (რაც გამოიხატება იმაში, რომ ვერ მიიღწევა ჩაჭრილი სტუდენტების პროცენტული მაჩვენებელ 40 %-ის შემცირება), ჩვენ ვაგრძელებთ შემდეგი ფაქტორის მნიშვნელობების განახლებას.

ვივარაუდოთ, რომ ყველა ფაქტორს გააჩნია იდენტური პრიორიტეტი. ამ შემთხვევაში ჩვენ ვაგრძელებთ მომდევნო ფაქტორით.

ამგვარად, ჩვენ უნდა შევცვალოთ (გავზარდოთ) მეორე ფაქტორის მნიშვნელობა - საათების საშუალო რაოდენობა, რასაც თითოეული სტუდენტი ხარჯავს საშინაო დავალებებზე. ცვლილება გამოიხატება: (მაქსიმალური მნიშვნელობა - მინიმალური მნიშვნელობა) / 10=0.4441. ფაქტორის განახლებული მნიშვნელობა არის:

0.93	0.96	1.1	1.1	1.2	1.2	1.3	1.3	1.3	1.3	1.4	1.5	1.5	1.6
1.6	1.6	1.7	1.7	1.8	1.8	1.8	1.9	1.9	1.9	1.9	1.9	2	2
2.1	2.1	2.1	2.2	2.2	2.3	2.4	2.4	2.5	2.6	2.6	2.6	2.6	2.8
2.9	2.9	2.9	2.9	2.9	3	3	3	3.1	3.2	3.2	3.2	3.2	3.2
3.2	3.2	3.2	3.4	3.4	3.5	3.5	3.5	3.7	3.7	3.7	3.8	3.8	3.8
3.8	3.8	3.8	3.8	3.9	3.9	3.9	3.9	3.9	3.9	3.9	4	4.1	4.1
4.1	4.1	4.1	4.1	4.2	4.2	4.2	4.2	4.3	4.5	4.6	4.9	5.2	5.3
5.3													

განმეორებით ვრთავთ ქსელში განახლებულ დამოუკიდებელი ტრენინგის წყობას, ვახდენთ მის სიმულირებას და შედეგია:

18	21	23	23	24	24	26	28	26	28	32	33	33	33	35	34	36	36	36	36
36	36	40	41	42	42	41	46	46	46	46	54	46	47	46	48	54	48	56	54
54	57	57	57	57	57	61	61	64	61	64	64	64	67	67	67	67	75	75	73
76	76	77	77	77	77	77	78	77	78	80	80	77	80	80	80	80	82	82	82
83	83	84	86	86	86	86	87	89	89	89	90	90	90	90	90	90	92	99	99

როგორც ჩანს, ვერ იქნა მიღებული ჩაჭრილი სტუდენტების პროცენტული მაჩვენებლის შემცირება: აღნიშნული მნიშვნელობა რჩება 46 %. ამგვარად, ჩვენ ვაგრძელებთ მომდევნო ფაქტორით - საშუალო ქულა, რაც თითოეულმა სტუდენტმა აიღო აქტიური საგნის ყველა პრერეკვიზიტისათვის. ჩვენ ვცვლით ამ ფაქტორის მნიშვნელობას შესაბამისი წყობით, განმეორებით ვრთავთ განახლებულ წყობას ქსელში, ვახდენთ ქსელის სიმულირებას, ვიღებთ ქულებს. ახლა ჩვენ მივიღეთ ჩაჭრილ სტუდენტთა შემცირებული პროცენტული მაჩვენებელი: 42 %.

რადგანაც ვერ იქნა მიღებული სასურველი მნიშვნელობა: 40 %, ჩვენ ვუბრუნდებით პირველ ფაქტორს, ვახდენთ მის განახლებას, ვრთავთ ქსელში, ვახდენთ მის სიმულირებას და ვიღებთ ახალ შედეგს: ჩაჭრილ სტუდენტთა პროცენტული

მაჩვენებელია 39 %. ამრიგად, ვიღებთ სასურველ შედეგს და იგი შეესაბამება ფაქტორთა მინიმალურ მნიშვნელობებს:

ჯამური შუალედური შეფასების მინიმალური მნიშვნელობა = 28

მინიმალური საშუალო რაოდენობა საათებისა, რასაც თითოეული სტუდენტი ხარჯავს საშინაო დავალებებზე = 0.93.

მინიმალური საშუალო ქულა რასაც თითოეული სტუდენტი იღებს ყველა პრერეკვიზიტისათვის = 60

გამოცდის სირთულის დონე = 3

ამ ფაქტორების მნიშვნელობათა კომბინაცია გვაძლევს სწავლების პროცესის სასურველ ხარისხს ჩაჭრილ სტუდენტთა პროცენტული მაჩვენებლის მხრივ. ფაქტორის მნიშვნელობა შეიძლება გათვალისწინებულ იქნას როდესაც მოზადდება სამომავლო გამოცდები.

სხვა პროცენტულ მაჩვენებლებს რაც შეეხება, შესაფერისი მნიშვნელობების ძიება გათვალისწინებულია (იმ განსხვავებებით, რაც ზემოთაა მოცემული).

თუმცა, როგორც ჩანს, ეს პროცესი საკმაოდ თავისებურია (“nntool” ფუნქციის პანელის მანუალურად გამოყენება). შესაბამისად, სრულიად ავტომატიზირებული მოდული შემუშავდა მოცემულ ნაშრომში. გამოყენებულ იქნა პროგრამა MATLAB-ის კონსტრუირებები. მოდულის რიგი ძირითადი პრინციპები მოცემულია ქვემოთ:

დამოუკიდებელი ტრენინგის წყობა=

[20	21	23	23	25	25	26	26	26	27	28	29	30	30	31	30	30	31	31	
32	32	32	32	33	33	33	30	34	34	35	34	35	36	36	37	37	36	37	37
37	37	38	38	38	37	38	38	38	38	38	39	39	39	40	40	41	41	42	42
41	42	42	43	43	44	44	45	45	45	45	46	45	46	46	47	47	47	48	49
49	49	49	50	51	51	51	52	52	54	53	54	54	55	55	55	56	56	57	59
58;																			
0.49	0.51	0.65	0.65	0.78	0.78	0.86	0.86	0.88	0.9	0.96	1.1	1.1							
1.1	1.2	1.2	1.3	1.3	1.3	1.4	1.4	1.4	1.4	1.5	1.5	1.5							
1.5	1.7	1.7	1.7	1.8	1.8	1.8	2	2	2.1	2.2	2.2	2.2	2.2	2.2					
2.4	2.4	2.5	2.5	2.5	2.5	2.5	2.5	2.5	2.6	2.7	2.7	2.7	2.7	2.7					
2.8	2.8	2.8	2.8	2.8	2.9	2.9	3.1	3.1	3.1	3.2	3.2	3.2	3.2	3.2					
3.3	3.3	3.3	3.3	3.3	3.3	3.4	3.4	3.4	3.4	3.5	3.5	3.5	3.5	3.5					

```

3.6 3.7 3.7 3.7 3.7 3.7 3.7 3.8 3.8 3.8 3.8 4.1 4.2 4.5
4.8 4.8 4.9;
51 51 51 52 52 52 53 54 53 56 57 57 57 57 58 58 59 59 59 58
59 59 60 60 61 61 62 63 62 63 63 67 64 65 64 65 66 65 68 67
67 68 68 68 69 68 69 69 70 69 70 70 71 72 72 72 72 74 74 75
75 75 75 74 76 76 76 77 76 77 77 78 76 79 79 80 80 81 80 81
82 83 82 83 85 84 84 85 85 87 86 87 87 88 88 89 90 95 95
97;
3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3
3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3
3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3
3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3
3 3 3 3 3 3 3 3];

```

მართული ტრენინგის წყობა=

```

[12 12 17 18 21 22 23 24 24 24 26 27 28 28 28 30 30 31 31
33 33 34 35 36 37 39 40 40 41 41 43 45 46 46 46 46 46 48
50 50 51 53 54 55 55 55 55 56 56 57 57 57 58 62 63 64 64 65
66 66 66 67 67 67 70 71 72 73 73 74 75 77 77 77 78 78 79
80 80 80 81 81 82 82 82 83 83 84 86 87 88 88 89 89 90 90
92 97 99 99];

```

ცხრილი = 0.7;

grnn1= newgrnn (დამოუკიდებელი ტრენინგის წყობა, მართული ტრენინგის წყობა, ცხრილი);

grnn1_outputs=sim (grnn1, დამოუკიდებელი ტრენინგის წყობა);

% პირველი ფაქტორის მზარდი მნიშვნელობა - ჯამური შუალედური შეფასება - 4

დამოუკიდებელი ტრენინგის წყობა (1,:)= დამოუკიდებელი ტრენინგის წყობა (1,:) +4;

grnn1_outputs=sim (grnn1, დამოუკიდებელი ტრენინგის წყობა);

.....

და ასე შემდეგ.

თანმიმდევრული ადაპტაციური პროცედურის ძირითადი უპირატესობა არის ის, რომ პარამეტრების მნიშვნელობების რეგულირება ხდება გაცილებით მეტი სიზუსტით. თანაც, პროცესირების დრო გაცილებით მოკლეა, ვიდრე GA ოპტიმიზაციის პროცედურის შემთხვევაში.

დასკვნა

წარმოების, ბიზნესისა და სწავლების პროცესების შეფასების პრობლემა განხილულია მოცემულ ნაშრომში. დემონსტრირებულია არა-პარამეტრული მიახლოებითი მნიშვნელობების გამოყენების საჭიროება. შემოთავაზებულია წარმოებისა და სწავლების პროცესების რეალისტური ხარისხის კავშირის სანიმუშე მოთხოვნებთან შეფასება. აღნიშნული მიდგომა შეიძლება გამოყენებულ იქნას წარმოებაში, ბიზნესში და სწავლების სფეროებში. გათვალისწინებულია შესაფერისი მნიშვნელობებისა და რელევანტური პარამეტრების პოვნის პრობლემა. განხილულია აგრეთვე მეტამოდელირების, ექსპერიმენტების დაგეგმვის, ოპტიმიზაციის სტრატეგიების ძირითადი პრინციპები. მოცემულია ნეირონული ქსელების პრინციპების დეტალური აღწერა.

ავტორის მიერ დისერტაციასთან დაკავშირებული გამოცემები:

1. ა.დემირი, ი. როდონაია, ი. მილნიკოვი. (2014). ბიზნესისა და განათლების წარმოების ხარისხის დონის ერთიანი მიდგომა, საერთაშორისო კონფერენცია მათემატიკა და კომპიუტერები მეცნიერებასა და ინდუსტრიაში 2014. გვ.60-63.
2. ა.დემირი. (2014). ელექტროენერჯის შემუშავება, ჩრდილოეთ ერაყის წარმოება- მოხმარება ურთიერთობის სამომავლო მოლოდინები, ეკონომიკისა და მეცნიერული მართვის აკადემიური კვლევის საერთაშორისო ჟურნალი. ნომ. 5, ს ე ქ ტ. 2014, გ ვ . 101-106.
3. ა.დემირი, ი. როდონაია. (2014). განზოგადებული ხერხები წარმოების ხარისხის დონის შეფასების, ბიზნესი და საგანმანათლებლო პროცესები. ბიზნესის ჟურნალი 3(1), გვ. 33-36.