

საქართველოს ტექნიკური უნივერსიტეტი

ი.შუგანევიშვილი, მ.მასხია

ნეირომსელური ტექნოლოგიები
STATISTICA სისტემის გაზახე

პრაქტიკული

თბილისი 2016

შესავალი

ნეირონული ქსელები ფართოდ გამოიყენება ყველგან, სადაც საჭიროა პროგნოზირების, კლასიფიკაციის, კლასტერიზაციის, ოპტიმიზაციის, წარმოების პროცესების მართვის და სხვა პრაქტიკული ამოცანების გადაწყვეტა. ნეიროქსელური ტექნოლოგიები შეიძლება გამოიყენებული იყოს დამოუკიდებლად ან მონაცემთა ანალიზის ტრადიციულ მეთოდებთან ერთად, სადაც ის წარმოადგენს მნიშვნელოვან დანამატს.

კლასიფიკაციული სტატისტიკული მეთოდების უმეტესობა ძირითადად დაკავშირებულია მათემატიკური მოდელების აგებაში, რომლებიც დაფუძნებულნი არიან ამა თუ იმ დაშვებებზე და თეორიულ მოსაზრებებზე. (მაგალითად, საძებნი დამოკიდებულება წრფივია, ცვლადებს გააჩნიათ ნორმალური განაწილება და ბევრი სხვა).

ნეიროქსელური მიღები თავისუფალია მოდელური შეზღუდვებისაგან. ის ერთნაირად გამოიყენება როგორც წრფივი, ასევე რთული არაწრფივი დამოკიდებულებების დროს. განსაკუთრებით საინტერესოა ნეიროქსელური ტექნოლოგიების გამოყენება, როცა უცნობია პარამეტრებს შორის დამოკიდებულება. გარდა ამისა, ნეიროქსელებს გააჩნიათ მეტად უნიკალური თვისება, რომელიც წარმოადგენს თვითსწავლებას. სწავლების პროცედურა შედგება სინაფსური წონების რეგულირებაში, რათა მიღწეული იყოს ცდომილების ფუნქციის მინიმიზაცია.

ნეიროქსელური პროგრამული პროდუქტი **STATISTICA Neural Networks (SNN)** წარმოადგენს ნეირონული ქსელების მოდელების შექმნის და ანალიზის მძლავრ და სწრაფ საშუალებას. ნეიროქსელის აგებისათვის საჭიროა შეირჩეს ცვლადები (რიცხვითი ან ნომინალური), რომლებიც მოქმედებენ შედეგზე. პროგრამაში გათვალისწინებულია შემავალი და გამომავალი ცვლადები. ცვლადები არის ორი სახის: დამოკიდებული (გამომავალი ცვლადები) და დამოუკიდებელი (შემავალი ცვლადები), რომლებიც გამოიყენებიან ქსელის შესასწავლად.

არსებობს აგრეთვე, კატეგორიალური ცვლადები, რომლებიც შეიცავენ მთელ რიცხვებს ან ტექსტურ მნიშვნელობებს და მიეკუთვნებიან დამაჯგუფებელ ცვლადების კატეგორიას. კატეგორიალური ცვლადის ტიპიურ მაგალითს წარმოადგენს სქესი ორი მნიშვნელობით (მამრობითი და დედრობითი).

პროგრამაში შეიძლება გამოვიყენოთ ამოცანის ამოხსნის ორი ინსტრუმენტი: გადაწყვეტის ოსტატი (**Intelligent Problem Solver**) და ქსელის კონსტრუქტორი (**Custom Network Designet**). ამოცანის ამოსახსნელად გადაწყვეტის ოსტატს სჭირდება დიდი დრო (რომელსაც ის ამას კარგად იყენებს), განსაკუთრებით განზომილების შემცირების დროს. ქსელის კონსტრუქტორის მთავარი თვისება ის არის, რომ მისი საშუალებით შესაძლებელია ნეირონული ქსელის აგება წინასწარ მოცემული პარამეტრებით: ქსელის ტიპი (ტოპოლოგია, არქიტექტურა), ფარული შრეების რაოდენობა და სხვა.

ნეიროქსელის აგებაში მონაწილე ამონარჩევი (ობიექტები, სახეები, მოვლენები) ორი სახისაა: სასწავლო და ტესტური (საკონტროლო). სასწავლო ამონარჩევის დაკვირვებები გამოიყენებიან ქსელის სწავლებისათვის. ტესტირების ამონარჩევის დაკვირვებები არ გამოიყენებიან ქსელის სწავლების პროცესში, ისინი გამოიყენებიან სწავლების შემდგომ ქსელის საბოლაო შეფასებისათვის.

სწავლების პროცესის ავტომატური დამთავრება ხდება მაშინ, როცა ქსელი ყველა მაგალითს დაამუშავებს მოცემული სწავლების ცდომილების გათვალისწინებით. ამის შემდეგ შესაძლებელია მოცემული ნეირონული ქსელის გამოყენება ნებისმიერი სახის ახალი შემავალი მონაცემების დამუშავებისათვის.

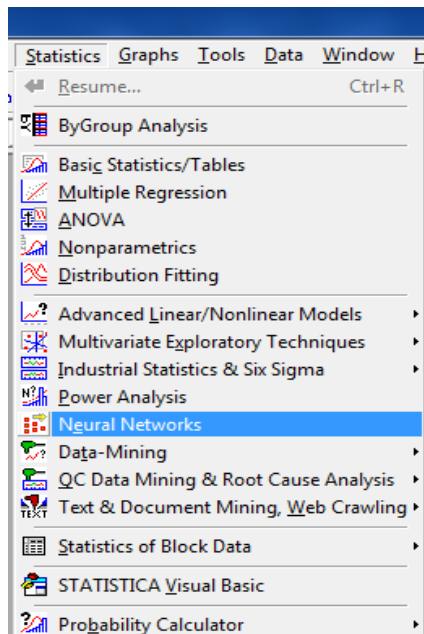
პრაქტიკული სამუშაო 1

თანამედროვე ნეირომსელური პროგრამული პროდუქტის ***STATISTICA Neural Networks (SNN)*** გაცნობა რეზისიული ანალიზის მაგალითზე.

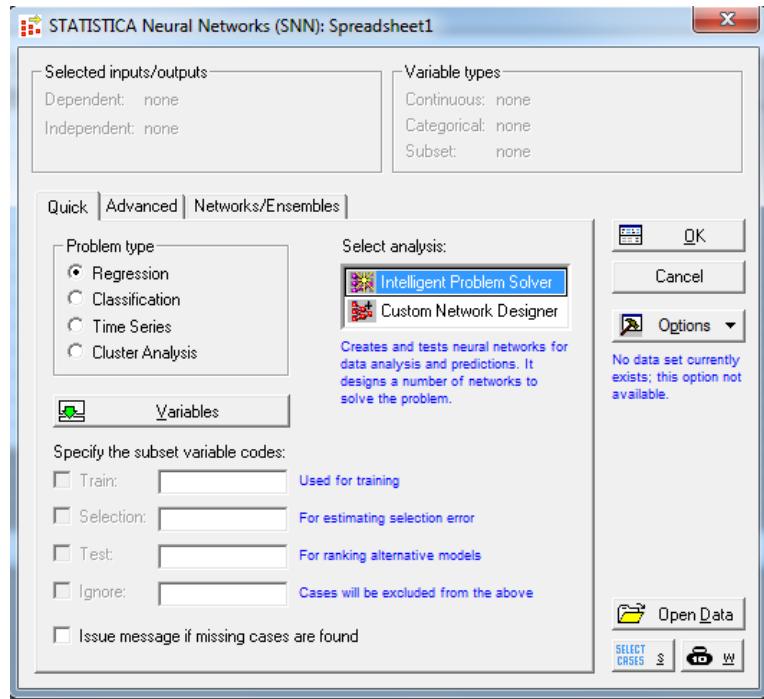
პროგრამასთან მუშაობის პროცედურა ზოგადად შედგება შემდეგი ბიჯებისაგან

ბიჯი 1. *Neural Networks*სა სტარტო პროგრამის გაცნობა.

STATISTICA Neural Networksპროგრამის გამოსახახებლად ჩავტვირთოდ ***STATISTICA 7*** სისტემა და **Statistics** მენიუში მოვნიშნოთ ბრძანება ***Neural Networks***.



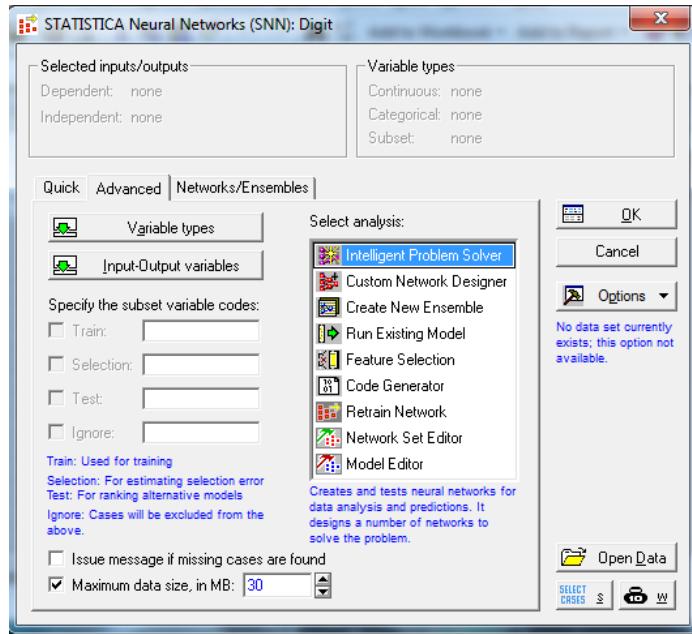
ეკრანზე გამოდის ***STATISTICA Neural Networks(SNN)*** პროგრამის სასტარტო ფანჯარა, რომელსაც აქვს შემდეგი სახე:



ფანჯრის **Problem type** ჩარჩოში შეგვიძლია შევარჩიოთ ანალიზის სხვადასხვა ტიპი: **Regression** (რეგრესია), **Classification** (კლასიფიკაცია), **Time Series** (დროითი მწერივები) და **Cluster Analysis** (კლასტერული ანალიზი). შევარჩიოთ რომელიმე მათგანი, მაგალითად რეგრესია.

Select analysis ველში შევარჩიოთ ანალიზის ინსტრუმენტი **Intelligent Problem Solver** (გადაწყვეტის ოსტატი) ან **Custom Network Designet** (ქსელის კონსტრუქტორი). დამწყები მომხმარებლისათვის რეკომენდირებულია შეირჩეს გადაწყვეტის ოსტატი, ხოლო გამოცდილი მომხმარებლისათვის – ქსელის კონსტრუქტორი. შევარჩიოთ გადაწყვეტის ოსტატი.

Advanced (დამატებითი) ჩანართის ჩართვის შემდეგ



შესაძლებელია დამატებითი ინსტრუმენტების გამოყენება, მაგალითად, განზომილების შემცირება, კოდის გენერატორი და სხვა.

ბიჯი 2 მონაცემების ფაილის ჩატვირთვა.

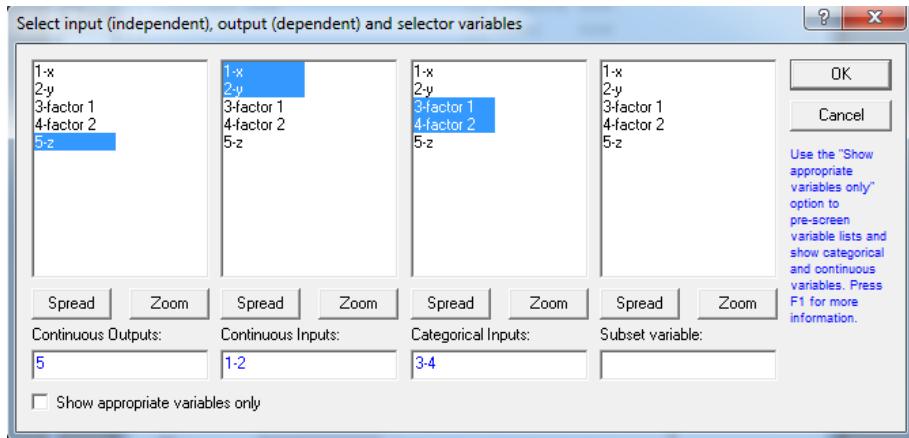
თუ მონაცემთა ფაილი გახსნილი არ არის, მაშინ **STATISTICA 7** სისტემის ფანჯარაში გავხსნათ მენიუ **File + Open Examples**. ეკრანზე გამოსულ **Open STATISTICA Data File** ფანჯარაში გავხსნათ **Datasets** საქაღალდე და შესაბამისი ფაილის დასახელებაზე დავაწკაპუნოთ (*Click*).

Data: Spreadsheet1* (5v by 14c)

| | 1 x | 2 y | 3 factor 1 | 4 factor 2 | 5 z |
|----|----------|----------|---------------|---------------|----------|
| 1 | 33,75958 | 40,2234 | m | i | 1357,921 |
| 2 | 67,40318 | 53,43791 | m | i | 3601,639 |
| 3 | 84,7438 | 4,086428 | m | d | -0,49068 |
| 4 | 95,52904 | 53,16935 | s | i | 148,8916 |
| 5 | 84,3379 | 14,12091 | s | i | 98,31806 |
| 6 | 33,91217 | 2,569658 | m | i | 87,4407 |
| 7 | 2,444533 | 14,12091 | s | d | 0,061378 |
| 8 | 90,99399 | 70,47945 | m | d | 0,076019 |
| 9 | 83,3491 | 10,57772 | s | i | 93,15478 |
| 10 | 71,79174 | 55,54979 | s | d | -0,08583 |
| 11 | 93,82306 | 72,1305 | m | d | -0,39306 |
| 12 | 97,56157 | 86,84347 | m | i | 8472,709 |
| 13 | 58,64742 | 21,05167 | m | d | 0,073404 |
| 14 | 49,04935 | 76,18641 | m | d | 0,234397 |

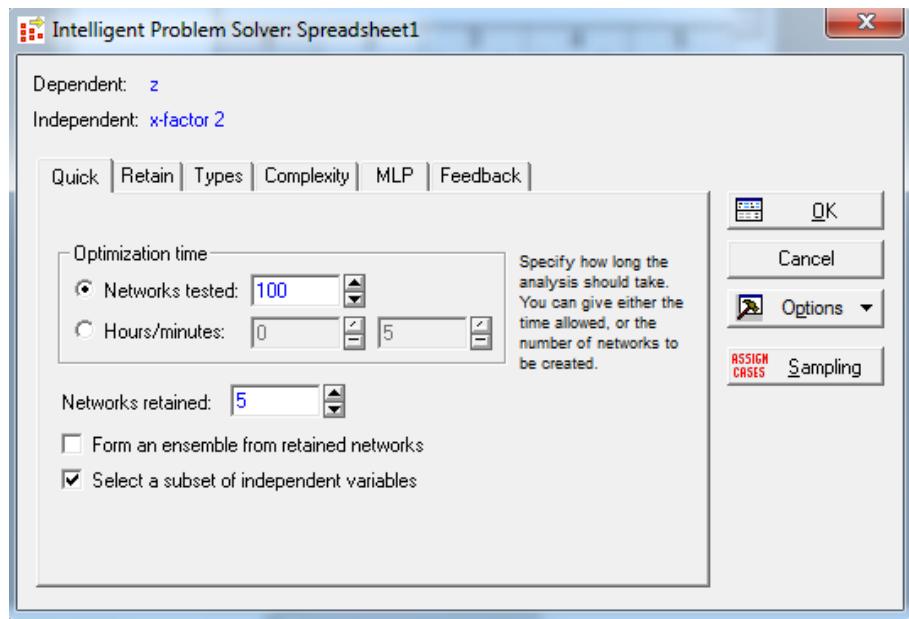
ბიჯი 3. ცვლადების მონიშვნა.

ამისათვის პროგრამის სასტარტო ფანჯარაში **Click Variables** ღილაკზე და ეკრანზე გამოსულ **Select input(independent), outp(dependent) and Selector vaeiables** მოვნიშნოთ შემავალი (დამოუკიდებული), გამომავალი (დამოკიდებული) და დამაჯგუფებელი ცვლადები. **Continuous outputs** (უწყვეტი გამომავალი) ველში ჩვენ შემთხვევაში, უნდა მოვნიშნოთ z ცვლადი. **Continuous inputs** (უწყვეტი შემავალი) ველში – x და y ცვლადები. **Categorical inputs** (შემავალი გატეგორიალური) ველში, ჩვენი ამოცანიდან გამომდინარე, **Factor 1** და **Factor 2**. **Subset variable** (ქვესიმრავლებად დაყოფა) არ წარმოადგენს აუცილებელს. იგი განკუთვნილია იმ ცვლადების მოსანიშნად, რომლებიც შეიცავენ კოდებს მონაცემების დასაყოფად სასწავლო და ტესტურ სიმრავლეებად. ანალიზის გასაგრძელებლად **Click OK** ღილაკზე.



ბიჯი 4. ანალიზის ხანგრძლივობის და ქსელის რაოდენობის დაყენება.

ვტრუნდებით სასტარტო ფანჯარაში და კვლავ *OK*. ეპრანზე გამოდის *Intelligent Problem Solver* ფანჯარა,

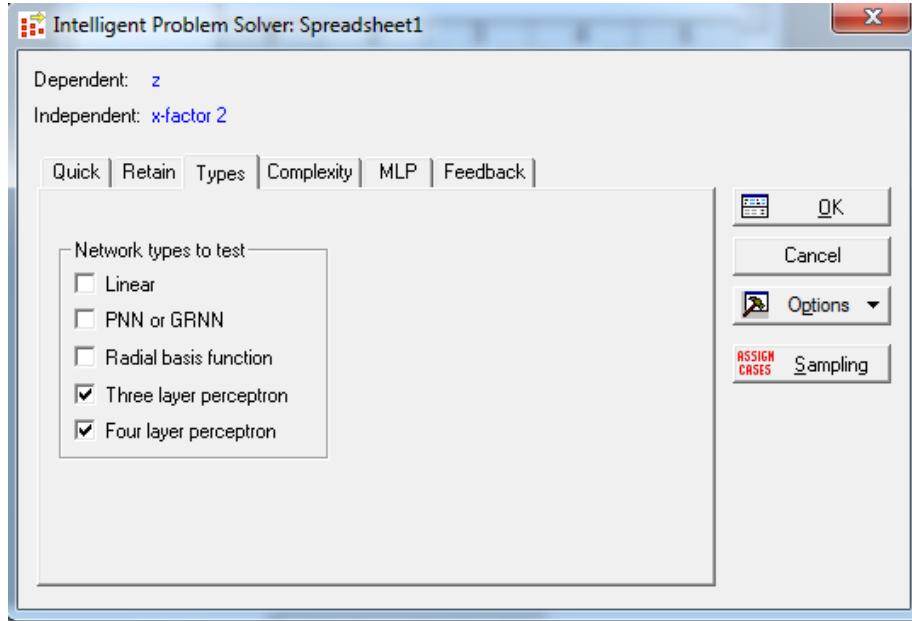


სადაც ჩავრთოდ *Quick* ჩანართი. *Networks tested* და *Networks retained* ველებში ანალიზის ტიპიდან და ამოცანიდან გამომდინარე ჩავწეროთ შესაბამისი მნიშვნელობები (100 და 5).

ბიჯი 5. ქსელის ტიპის შერჩევა.

ჩავრთოდ *Types* ჩანართი და *Network types to test* ველში მოვნიშნოთ ქსელის ან ქსელების ტიპები: *linear*(წრფივი), *PNN or GRNN* (ალბათური ნეიროქსელი ან

განზოგადოებული რეგრესიული ნეიროქსელი), **Radial basis function** (რადიალურ-ბაზისური ფუნქცია), **Three layer perceptron** (სამშრიანი რეგრესია), **Four layer perceptron** (ოთხშრიანი რეგრესია). შემდეგ *OK*.



კლასიფიკაციის ამოცანებში ძირითადად გამოიყენებიან მრავალშრიანი პერსეპტრონები, რადიალურ-ბაზისური ფუნქცია, ალბათური ნეიროქსელი(**PNN**) და წრფივი ქსელი. ამასთან შემავალი მონაცემები უნდა იყოს რიცხვითი და არა ნომინალური.

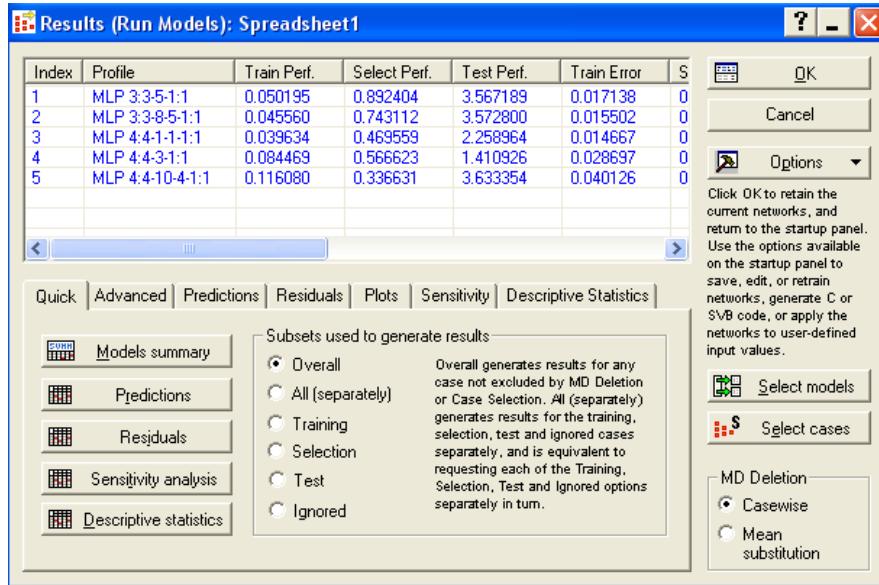
რეგრესიის ამოცანებში ძირითადად გამოიყენებიან მრავალშრიანი პერსეპტრონები, რადიალურ-ბაზისური ფუნქცია, განზოგადოებული რეგრესიული ნეიროქსელი (**GRNN**) და წრფივი ქსელი.

დროითი მწკრივების ანალიზის ძირითადი მიზანია მომავალი მნიშვნელობების პროგნოზირება. როგორც წესი, პროგნოზირებადი ცვლადი რიცხვითი მნიშვნელობისაა, ამიტომ დროითი მწკრივის პროგნოზირება წარმოადგენს რეგრესიის კერძო შემთხვევას. მაგრამ **STATISTICA 7** სისტემაში ეს შეზღუდვა არ არის გათვალისწინებული და ამიტომ შესაძლებელია ნომინალური (ანუ საკლასიფიკაციური) დროითი მწკრივის პროგნოზირებაც. აქედან გამომდინარე, დროითი მწკრივის პროგნოზირების ამოცანაში გამოიყენება ყველა ტიპის ნეიროქსელი (ამოცანიდან გამომდინარე ქსელის ტიპი უნდა მიესადაგებოდეს რეგრესიას ან კლასიფიკაციას).

კლასტერიზაციის ამოცანებში ძირითადად გამოიყენებიან კოპონენტის ქსელი და მრავალშრიანი ნეირონული ქსელები. ქსელის ტიპის მონიშვნის შემდეგ *OK*.

ბიჯი 6. ქსელის სწავლების პროცედურა.

ქსელის ტიპის შერჩევის შემდეგ ეკრანზე ჯერ გამოდის სწავლების პროცედურის ფანჯარა და შემდეგ შედეგების **Results (Run Models)** ფანჯარა,



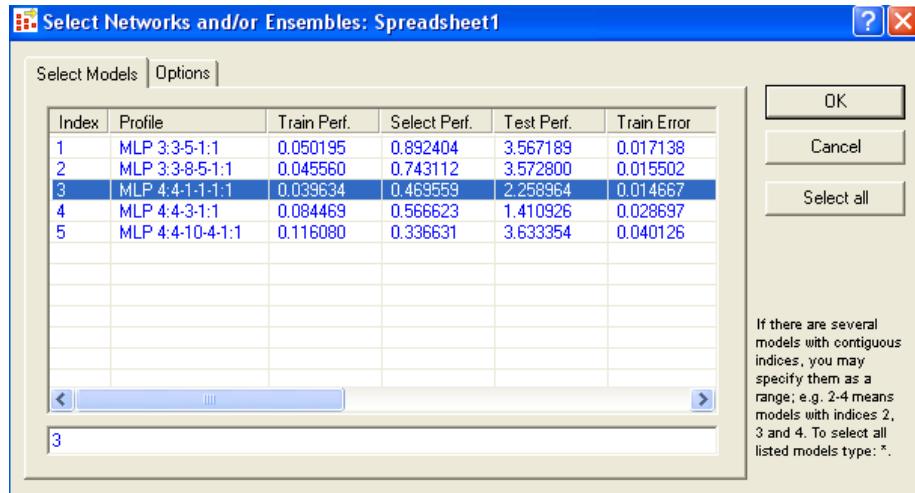
სადაც პროგრამას გამოაქვს საუკეთესო ქსელები, რომელთა მნიშვნელოვან მაჩვენებლებს წარმოადგენენ: **Profile**(ქსელის ტიპი), **TrainPerformance**(სწავლების ეფექტიანობა), **Select. Perf.** (შერჩევის ეფექტიანობა), **TestPerf.** (ტესტირების ეფექტიანობა), **Train Error**(სწავლების ცდომულება), **SelectError** (შერჩევის ცდომილება), **ModelError** (ტესტირების ცდომილება).

Profile სვეტში წარმოდგენილია: ქსელის ტიპი, რომელიც აღწერილია ნეიროქსელის ტოპოლოგიით ანუ ქსელის კლასით, რომელსაც ის მიეკუთვნება (მაგალითად, **MLP**-პერსეპტრონი, შემავალი და გამომავალი ცვლადების რაოდენობა, ფარული შრეების რაოდენობა და თითოეული შრის ელემენტების რაოდენობა).

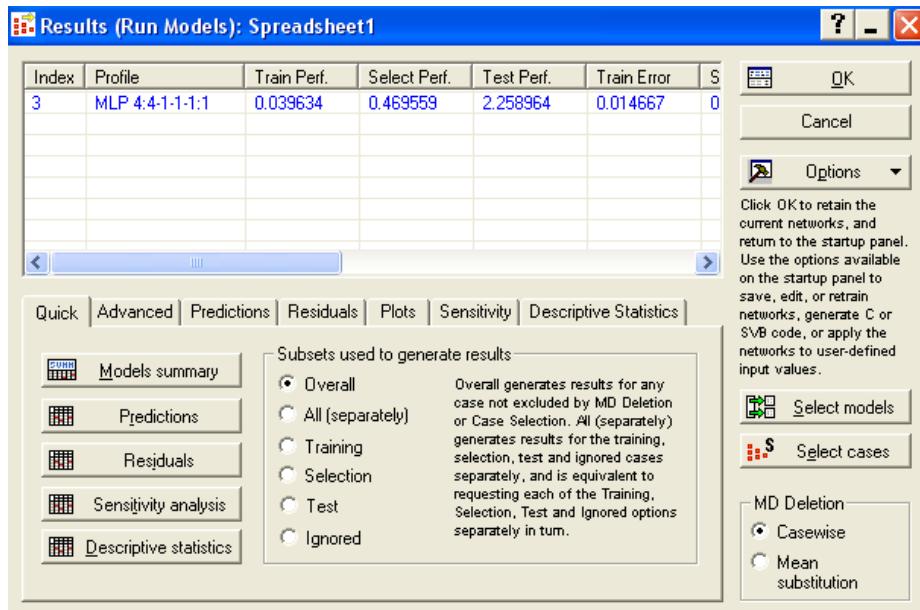
მიღებულ შეგეგებიდან ჩანს, რომ ქსელის ფარული შრის ელემენტების რაოდენობის გაზრდით, იზრდება შედეგის სიზუსტე. უნდა ავღნიშნოთ, რომ ყველა მოდელს აქვთ შესაძლებლობა ყოველ ახალ დაკვირვებაზე განაზოგადოს შედეგი.

ბიჯი 7. ნეირონული ქსელის შერჩევა.

Click **Select models** (მოდელის მონიშვნა) დილაპზე და ეკრანზე გამოსულ ცხრილში მოვნიშნოთ მე-3 ქსელი, რადგან მას გააჩნია ყველაზე კარგი შედეგი.



შემდეგ Click OK.



შედეგების **Results(Run Models)** ფანჯარის **Quick** ჩანართში Click **Descriptive statistics**(აღწერითი სტატისტიკა)-ის დილაპზე. ეპრანზე გამოდის რეგრესიის შეცდომების ცხრილი,

| | Regression (3) (Spreadsheet1) |
|-------------|-------------------------------|
| | z.3 |
| Data Mean | 989,968 |
| Data S.D. | 2282,389 |
| Error Mean | -4,146 |
| Error S.D. | 201,133 |
| Abs E. Mean | 155,630 |
| S.D. Ratio | 0,088 |
| Correlation | 0,996 |

სადაც წარმოდგენილია **Data Mean** (მონაცემების საშუალო სიდიდე), **Data S.D.** (მონაცემების საშუალო კვადრატული გადახრა), **Error Mean** (პროგნოზის საშუალო კვადრატული გადახრა), **Error S.D.** (პროგნოზის კვადრატული გადახრა), **Abs. E. Mean** (პროგნოზის საშუალო აბსოლუტური კვადრატული გადახრა), **S.D.Ratio** (პროგნოზის საშუალო კვადრატული გადახრის კვადრატული ფარდობა მონაცემების საშუალო კვადრატულ გადახრასთან), **Correlation** (კორელაციის მნიშვნელობა რეალურ და პროგნოზირებად მნიშვნელობებს შორის).

S.D.Ratio წარმოადგენს ერთ-ერთ ყველაზე უფრო მნიშვნელოვან და გამოყენებად მაჩვენებელს. მისი მნიშვნელობა [0;1] დიაპაზონში იცვლება და დამოკიდებულია ყოველი მნიშვნელობის ცდომილებაზე (ნიშანზე არ არის დამოკიდებული). ამასთან ის საკმარის მგძნობიარეა ამოგარდნების მიმართ.

ემპირიული გამოკვლებების შედეგად ჩამოყალიბდა გარკვეული წესი, რომლის თანახმად თუ **S.D.Ratio** $< 0,2$ სიდიდეზე, მაშინ ითვლება, რომ ნეიროქსელი შერჩეულია კარგად. თუ **S.D.Ratio** მნიშვნელობა მოთავსებულია $[0,2:0,4]$ დიაპაზონში, მაშინ ითვლება, რომ ქსელი შერჩეულია დამაკმაყოფილებლად, ხოლო როცა **S.D.Ratio** $> 0,4$ სიდიდეზე, მაშინ ქსელი ცუდად არის შერჩეული.

მიღებულ შედეგებიდან ჩანს, რომ მე-3 ქსელის სტანდარტული გადახრა (**S.D.Ratio**) 0,088 ტოლია. ე.ი. ქსელი კარგად არის შერჩეული.

ნეიროქსელის შერჩევის ერთ-ერთ მნიშვნელოვან მეთოდს წარმოადგენს **კროს-შემოწმების** მეთოდი, სადაც გამოიყენება ტესტური ამონარჩევი. ტესტური ამონარჩევით მიღებული შედეგის სიზუსტე დარდება სასწავლო ამონარჩევით მიღებული შედეგის სიზუსტეს. თუ ტესტური ამონარჩევი იძლევა დაახლოებით იგივე შედეგს, რასაც სასწავლო ამონარჩევი, მაშინ ითვლება, რომ მოდელმა გაიარა კროს-შემოწმება.

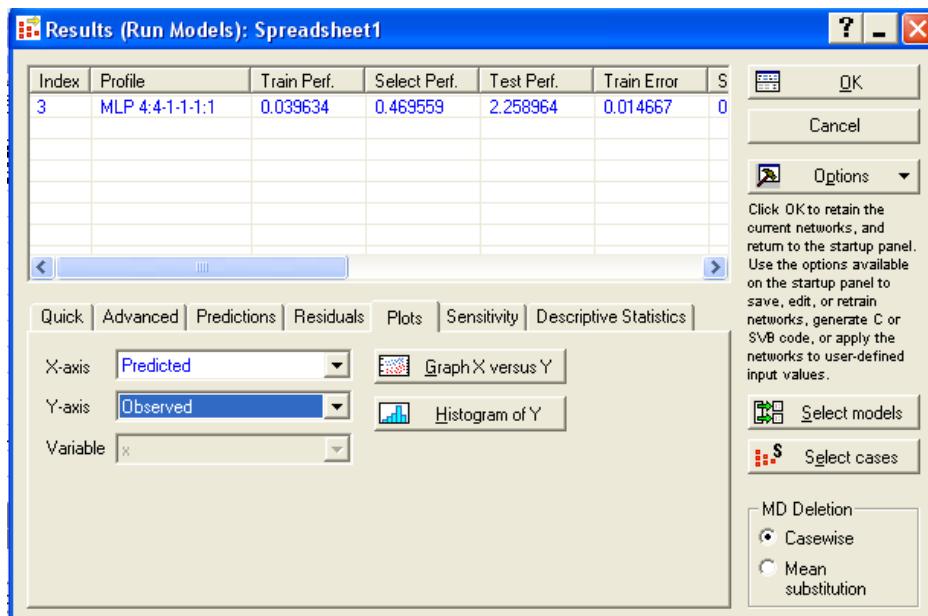
თუ შედეგების **Results(Run Models)** ფანჯრის **Subsets used to generate results** (შერჩევის შედეგების გამოყვანა)-ის ველში **Overall** (სრული) ოპციის მაგივრად ჩავრთავთ **All (separately)** (ყველა ცალკე) ოპციას, მაშინ ეს მოგვცემს საშუალებას მივიღოთ ცხრილი, სადაც შერჩევის შედეგები ყველა მოდელისათვის ცალკე არის წარმოდგენილი.

| | Regression (1-5) (Spreadsheet1) | | | | |
|-------------|---------------------------------|----------|----------|----------|----------|
| | z.1 | z.2 | z.3 | z.4 | z.5 |
| Data Mean | 989,968 | 989,968 | 989,968 | 989,968 | 989,968 |
| Data S.D. | 2282,389 | 2282,389 | 2282,389 | 2282,389 | 2282,389 |
| Error Mean | -21,598 | 26,533 | -4,146 | -78,328 | -32,846 |
| Error S.D. | 285,010 | 256,302 | 201,133 | 280,211 | 295,892 |
| Abs E. Mean | 201,060 | 166,186 | 155,630 | 254,778 | 242,745 |
| S.D. Ratio | 0,125 | 0,112 | 0,088 | 0,123 | 0,130 |
| Correlation | 0,992 | 0,994 | 0,996 | 0,992 | 0,992 |

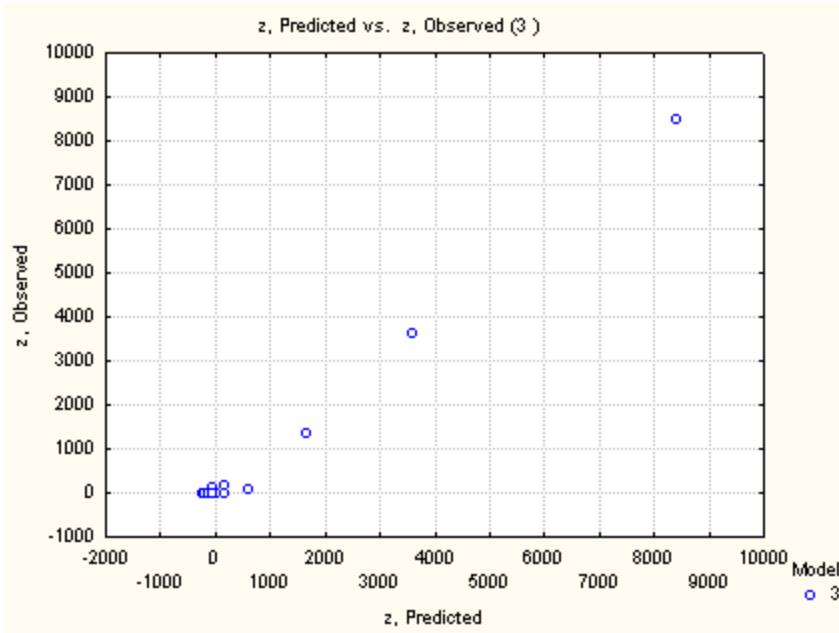
როგორც ცხრილიდან ჩანს **S.D.Ratio** სიდიდე უკელა ამ მოდელისათვის თითქმის ერთნაირია და ნაკლებია 0,2 სიდიდეზე.

საწყისი მონაცემების დაყოფა სასწავლო და ტესტურ სიმრავლეებად ხორციელდება მონაცემების დაყოფით გარკვეული პროპორციით. მაგალითად, სასწავლო ამონარჩევი – 2/3, ხოლო ტესტური – 1/3. განუმების პრინციპით დაკვირვებები იყოფა სამ ქვესიმრავლედ 2 : 1 : 1 შეფარდებით. ასე მაგალითად, თუ გვაძვს 50 სასწავლო დაკვირვება, მაშინ 25 იქნება საკონტროლო და შემდეგი 25 – სატესტო.

დაკვირვების გრაფიკის ასაგებად ჩავრთოდ ჩანართ **Plots** (გრაფიკი). და **X-axis** (ღერძზე)-ის ველში შევარჩიოთ **Predicted**(პროგნოზირება), ხოლო **Y-axis**(ღერძზე) – **Observed**(დაკვირვება).

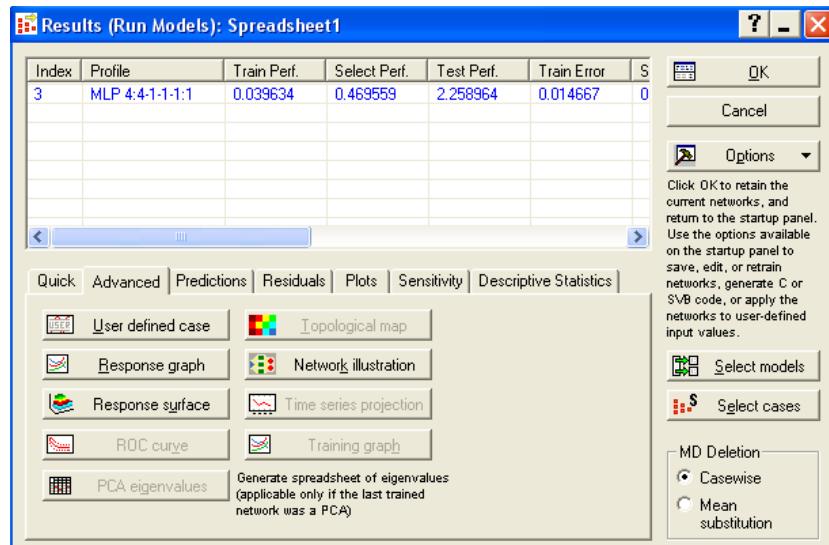


აგვთ X და Y ცვლადების დამოკიდებულების გრაფიკი. ამისათვის *Click GraphX versus Y* დილაგზე. ეკრანზე გამოდის დამოკიდებულების გრაფიკი

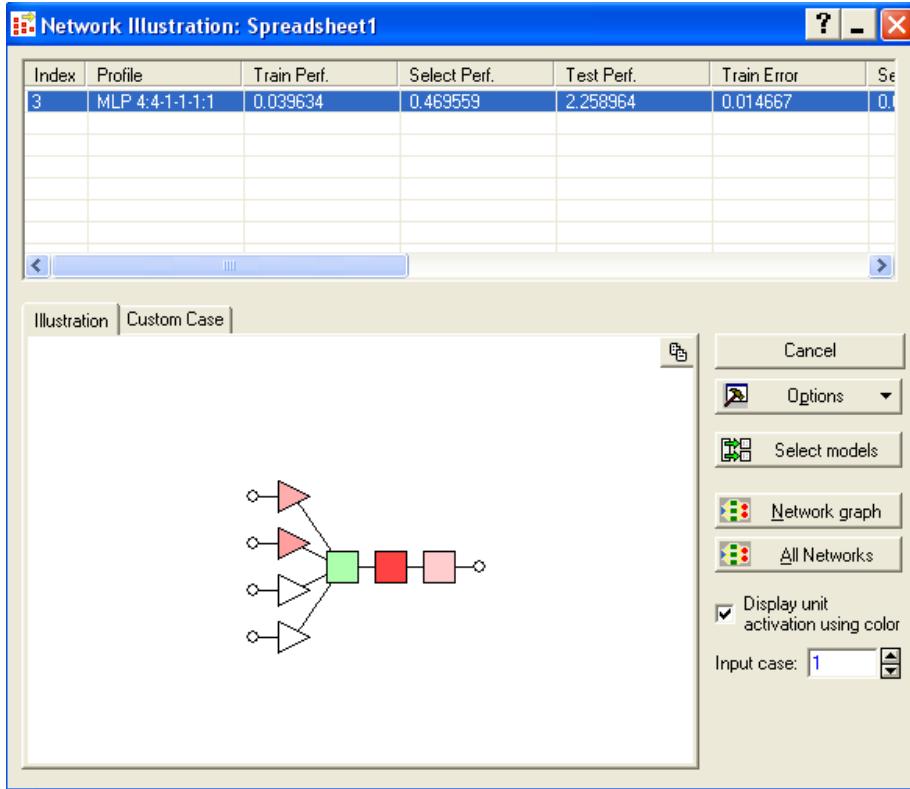


საიდანაც ჩანს, რომ გრაფიკი ფაქტიურად იდეალურად დევს სწორ ხაზზე. ამ შედეგის მიღება მოსალოდნელი იყო, რადგან როგორც შედეგების **Results(Run Models)** ფანჯარაში ჩანს მე-5 მოდელის სწავლების შეცდომა შეადგენს მხოლოდ 0,15%.

ნეირონული ქსელის არქიტექტურის ასაგებად შედეგების **Results(Run Models)** ფანჯარაში ჩავრთოდ **Advanced** ჩანართი



და **Click Network Archition**(ქსელის არქიტექტურა)-ის დილაგზე ეკრანზე გამოდის ნეიროქსელის გრაფი.



ქსელს აქვს პირდაპირი გავრცელების სტრუქტურა ოთხი შემავალი ცვლადით, ერთი ფარული შრით, რომელიც შეიცავს ერთ ელემენტს და ერთ ერთელემენტიან გამომავალ შრეს. მოდელის აგების სიზუსტე, ტესტირების ეფექტიანობის **TestPerf.** მაჩვენებლიდან გამომდინარე, 2,25% ტოლოა, რაც არასაკმარისი შედეგია.

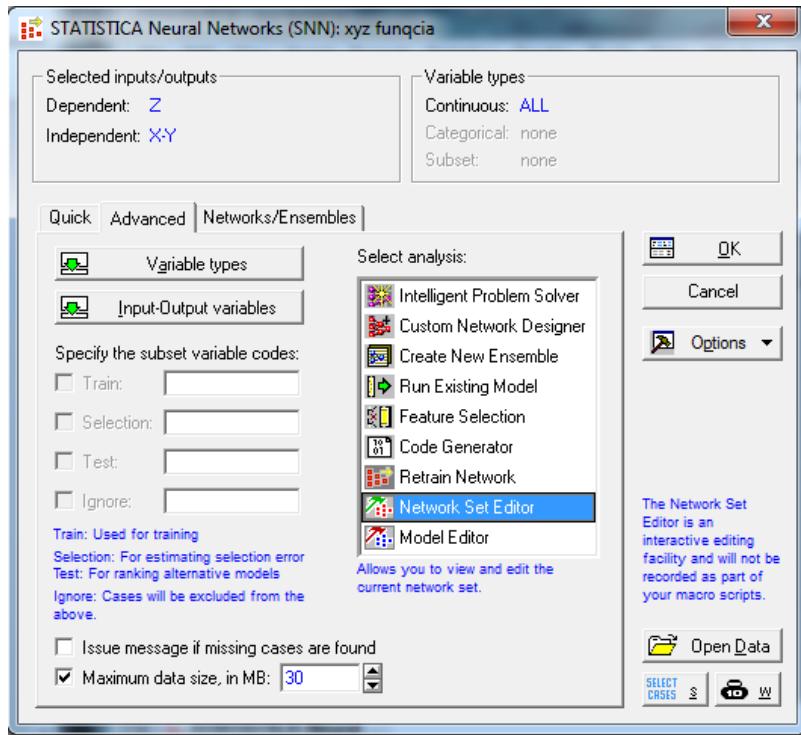
იმისათვის, რომ საბოლაოდ დავრწმუნდეთ ნეიროქსელის შერჩევის სისწორეში **Results(Run Models)** ფანჯარაში ჩავრთოდ **Predictions** ჩანართი და **Click Predictions** ღილაკზე. ეკრანზე გამოდის შედეგების ცხრილი,

| | Prediction (3) (Spreadsheet1) | |
|----|--------------------------------|----------|
| | z | z.3 |
| 1 | 1357,921 | 1652,803 |
| 2 | 3601,639 | 3613,136 |
| 3 | -0,491 | -150,879 |
| 4 | 148,892 | 163,665 |
| 5 | 98,318 | -54,211 |
| 6 | 87,441 | 602,561 |
| 7 | 0,061 | -215,899 |
| 8 | 0,076 | 182,492 |
| 9 | 93,155 | -65,686 |
| 10 | -0,086 | -201,365 |
| 11 | -0,393 | 41,302 |
| 12 | 8472,709 | 8404,828 |
| 13 | 0,073 | -111,661 |
| 14 | 0,234 | -59,584 |

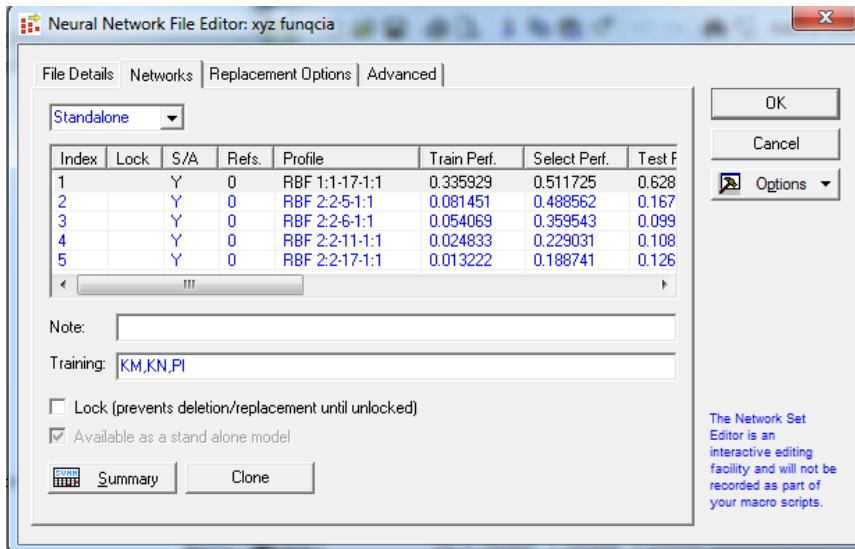
სადაც მარცხენა სვეტში მოცემულია z -ის ჭეშმარიტი მნიშვნელობები, ხოლო მარჯვენა სვეტში – ნეიროქსელის მიერ პროგნოზირებული მნიშვნელობები. როგორც ცხრილიდან ჩანს, მიღებული შედეგები არადამაკმაყოფილებელია. განსაკუთრებით ცუდი შედეგია, როცა z დებულობს ნულთან მიახლოებულ მნიშვნელობებს. ამ შემთხვევაში ცდომილება საკმაოდ დიდია. ასევე დიდია ცდომილება, როცა $z < 0,2$ სიდიდეზე. როცა $z > 100$, მაშინ შედეგი ასე თუ ისე დამაკმაყოფილებელია.

ბიჯი 8. ქსელის რედაქტირება.

STATISTICA Neural Networks სასტარტო ფანჯარაში ჩავრთოდ **Advanced** (დამატებითი) ჩანართი

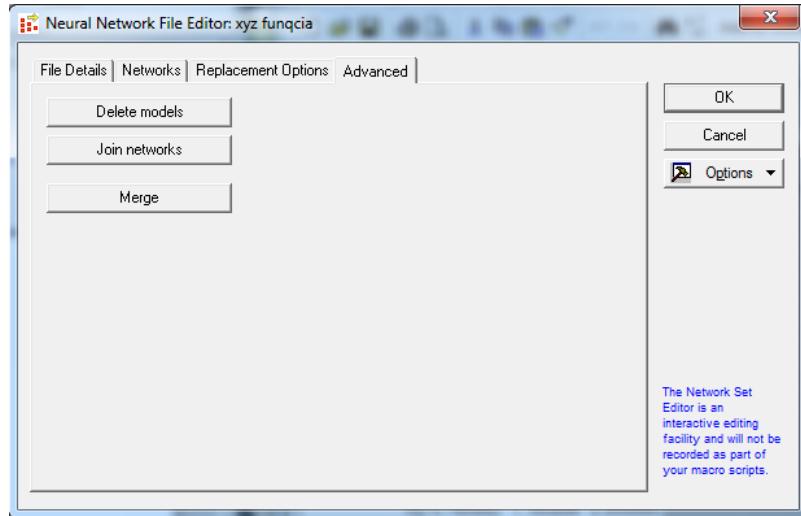


და **Select analysis** ველში მოვნიშვნოთ **Network Set Editor**. შემდეგ *Click OK*. ეკრანზე გამოდის **Neural Networks File Editor** ფანჯარა.

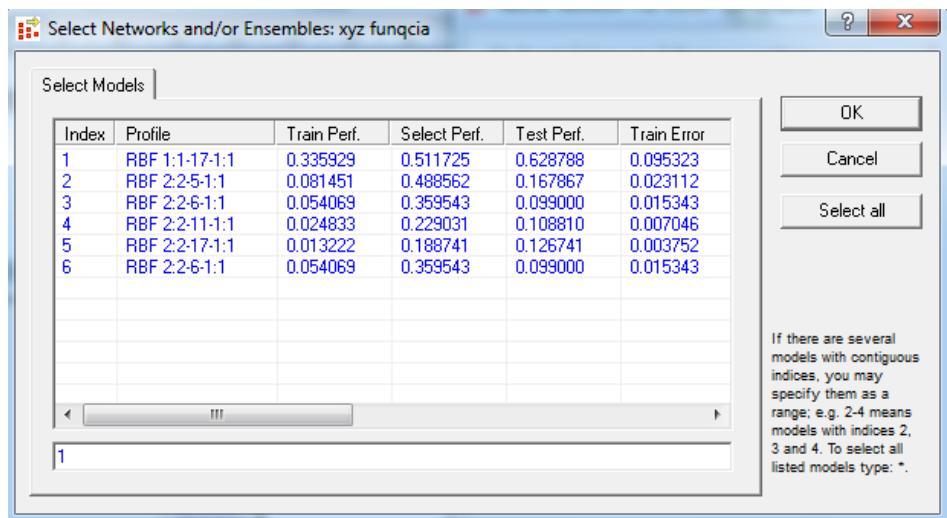


ჩავრთოდ **Networks** ჩანართი. ამ დიალოგიურ ფანჯარაში შეიძლება დაგათვალიეროთ, ამოვირჩიოთ და დაგალაგოთ სხვადასხვა ნეირონული ქსელები და ანსამბლები.

ქსელის შესწავლის შემდეგ შეგვიძლია წავშალოთ ზოგიერთი მათგანი. ქსელის წასაშლელად **Neural Networks File Editor** ფანჯარაში ჩავრთოდ **Advanced** ჩანართი და



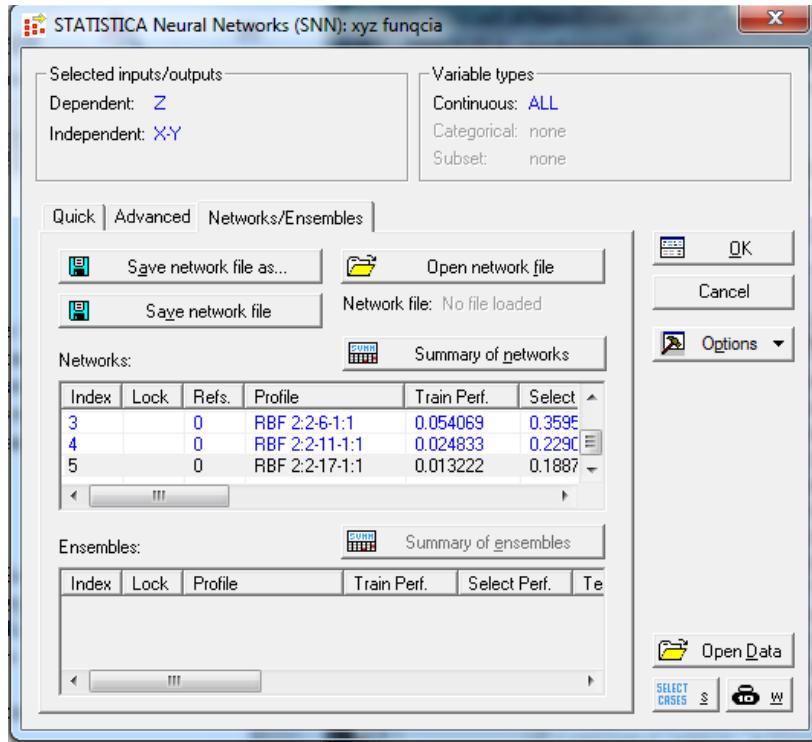
ეკრანზე გამოსულ ფანჯარაში **Click Delete models** დილაპებე. ეკრანზე გამოდის **Select Networks and/or Ensembles** ფანჯარა.



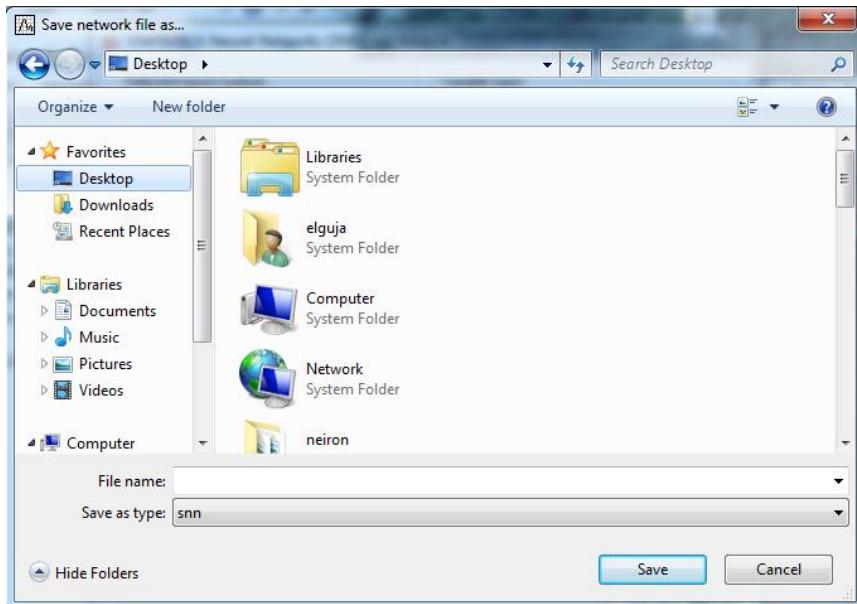
მოვნიშნოთ წასაშლელი ქსელი ან ქსელები და შემდეგ **Click OK**.

ბიჯი 9. ნეიროქსელის შენახვა.

. ნეირონული ქსელების შესანახად ვძრუნდებით სასტარტო ფანჯარაში. ჩავრთოდ **Networks/Ensembles** (ქსელები / ანსამბლები) ჩანართი



Click Save network file as.. დილაპტე. ეკრანზე გამოდის ამავე დასახელების Save network file as.. ფანჯარა



სადაც **File name** ველში ჩავწეროთ შესანახი ფაილის სახელი (ფაილს აქვთ გაფართოება ..snn). შევარჩიოთ ფაილის შენახვის ადგილი (მაგალითად, Desktop, Local Disk (C) და სხვა). შემდეგ *Click Save* დილაპტე.

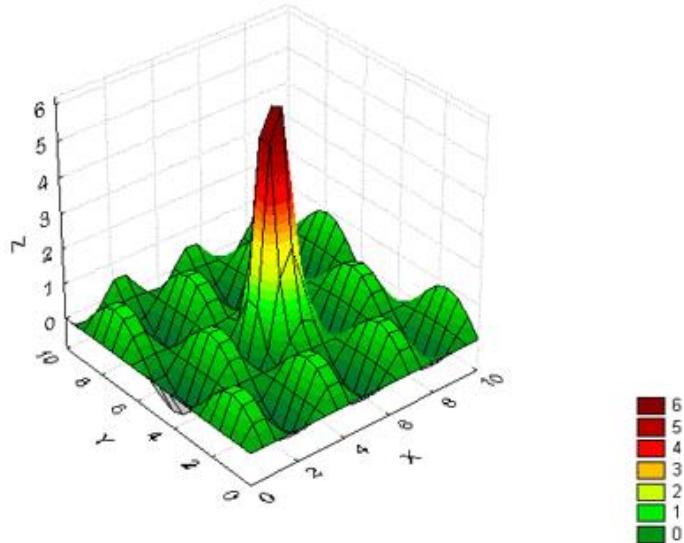
დაახლოებით ასეთი პროცედურით ხდება **STATISTICA 7** სისტემაში ნეირონული ქსელებით სხვადასხვა ტიპის ამოცანების გადაწყვეტა.

პრაქტიკული სამუშაო 2

ზუნძცის აპროშეიმაცია

მოცემულია ორი ცვლადის უცნობი ფუნქცია, რომელებიც წარმოდგენილნი არიან 1000 მნიშვნელობებით ინტერვალში $[0,10] \times [0,10]$. იგულისხმება, რომ წერტილები, სადაც მოცემულია ფუნქციის მნიშვნელობები, მოცემულ კვადრატში განაწილებულია შემთხვევით.

უნდა ავაგოთ მათემატიკური მოდელი, რომელიც აღწერს დამოკიდებულებას ფუნქციის მნიშვნელობასა და დამოუკიდებელი ცვლადების მნიშვნელობებს შორის. ფუნქციის გრაფიკული გამოსახულება მოცემულია შემდეგ ნახაზზე:

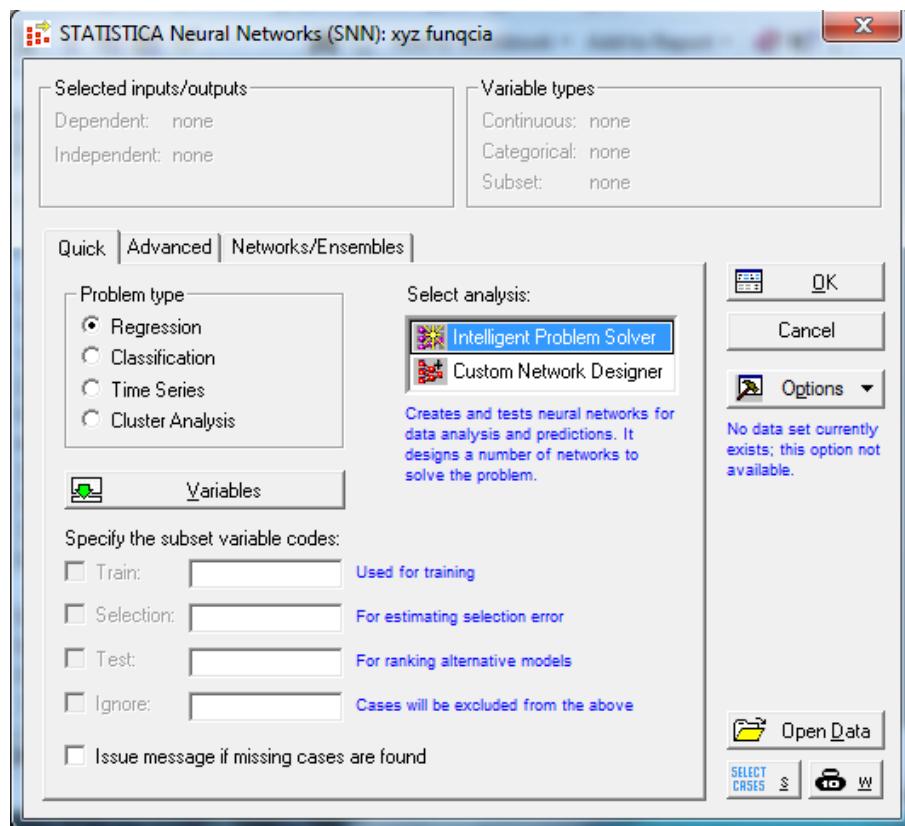


გავხსნათ *xyzfuncia*. მონაცემთა ფაილი, რომელიც შედგება სამი ცვლადისაგან: X, Y, Z . X და Y -დამოუკიდებელი ცვლადებია, ხოლო ცვლადი Z -დამოკიდებული.

| | 1 X | 2 Y | 3 Z |
|----|----------|-----------|----------|
| 1 | 1,566684 | 2,071826 | 2,36023 |
| 2 | 1,221973 | 0,930952 | 0,250917 |
| 3 | 1,031099 | 2,775307 | 4,035066 |
| 4 | 1,848694 | 3,446776 | 4,969204 |
| 5 | 2,427282 | 1,908399 | 1,603156 |
| 6 | 0,744185 | 1,327998 | 1,283903 |
| 7 | 4,036675 | 3,460967 | 3,903596 |
| 8 | 3,902029 | 2,973617 | 2,996219 |
| 9 | 3,549554 | 2,938368 | 3,101959 |
| 10 | 3,763685 | 4,323054 | 5,764265 |
| 11 | 0,282497 | 0,47174 | -0,19777 |
| 12 | 4,19236 | 3,197317 | 3,298455 |
| 13 | 0,891796 | 2,7666762 | 4,087627 |
| 14 | 0,624997 | 1,536103 | 1,759708 |
| 15 | 0,785442 | 1,145894 | 0,899066 |
| 16 | 3,794871 | 4,010025 | 5,122615 |
| 17 | 0,372507 | 2,497742 | 3,80923 |
| 18 | 1,85062 | 2,814768 | 3,704226 |
| 19 | 2,363822 | 3,158815 | 4,13572 |
| 20 | 4,556097 | 3,430906 | 3,583764 |
| 21 | 0,80317 | 1,235618 | 1,069651 |
| 22 | 8,816658 | 6,858928 | 6,308527 |
| 23 | 1,870483 | 2,274316 | 2,61339 |
| 24 | 1,740074 | 2,479156 | 3,088275 |
| 25 | 4,156881 | 3,09389 | 3,10934 |
| 26 | 0,123189 | 0,316279 | -0,42904 |
| 27 | 8,858022 | 7,122111 | 8,815211 |
| 28 | 8,113952 | 4,49707 | 3,937164 |
| 29 | 3,111362 | 1,004074 | -0,54753 |
| 30 | 9,767911 | 1,32040 | 2,74200 |

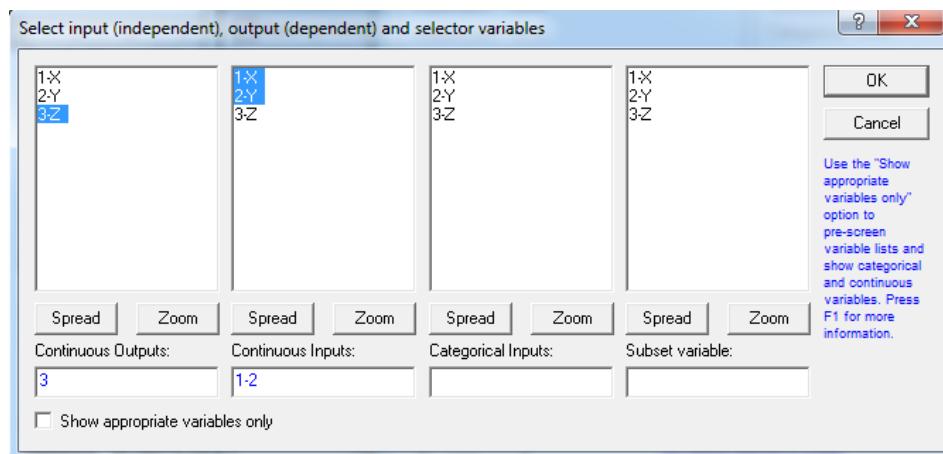
ამოცანის ამოხსნის კლასიკური მიღებომა მდგომარეობს იმაში, რომ პირველ ბიჯზე ვაგებთ მრავლობითი რეგრესიის მოდელს. აშკარაა, რომ დამოკიდებულება არაწრფივია და ამიტომ ყველა წრფივი მოდელები მოგვცემენ "ცუდ" შედეგს. ამ მაგალითისთვის ავაგოთ ნეიროქსელური მოდელი.

სასტარტო პანელის **STATISTICA Neural Networks** გამოსაძახებლად, მენიუდან **Statistics** შევარჩიოთ ბრძანება **Neural Networks**. ეკრანზე გამოდის **STATISTICA Neural Networks(SNN)** ფანჯარა,

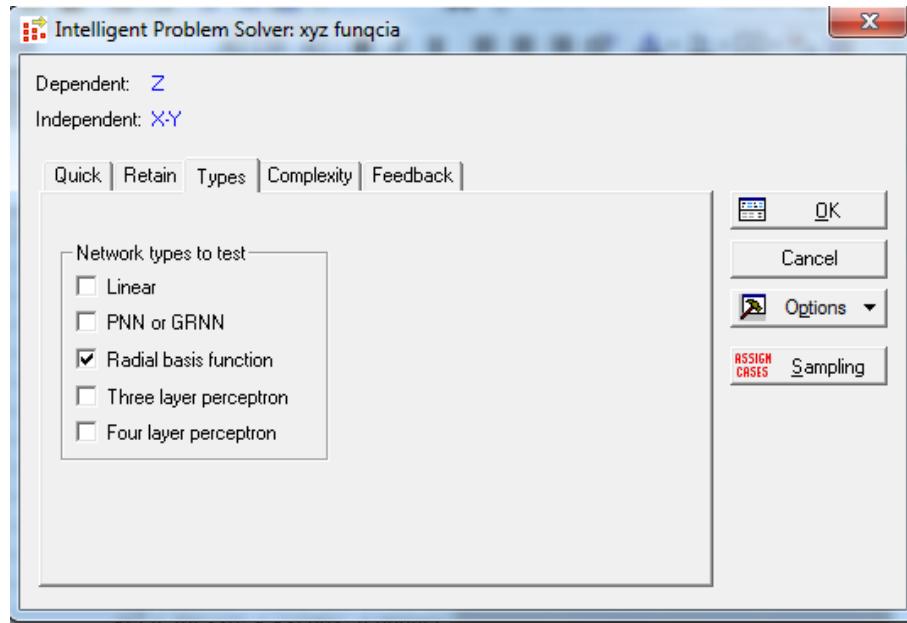


სადაც ჩავრთოდ **Quick** ჩანართი და **Problem type** ველში შევარჩიოთ ამოცანის ტიპი **Regression**, ხოლო **Select analysis** ველში ამოხსნის მეთოდი – **Intelligent Problem Solver** (გადაწყვეტის ოსტატი).

ცვლადების მოსანიშნად **Click Variables** ღილაკზე და ეკრანზე გამოსულ ფანჯარაში მოვნიშნოთ **Continuous Outputs**: (უწყები გამომავალი) ველში z ცვლადი, ხოლო **Continuous Inputs** (უწყები შემავალი) ველში – x, y ცვლადები. შემდეგ **OK**.

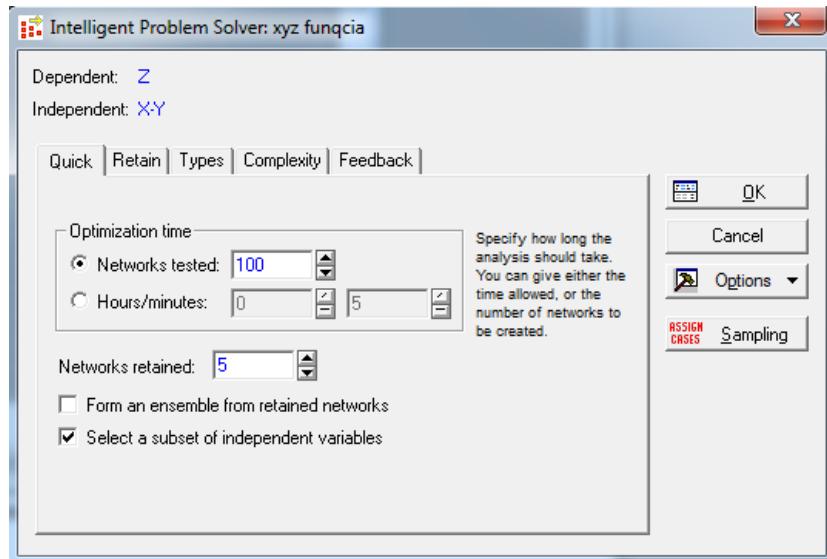


ვბრუნდებით **STATISTICA Neural Networks (SNN)** ფანჯარაში და კვლავ *OK*. ეკრანზე გამოდის **Intelligent Problem Solver**(გადაწყვეტის ოსტატი)-ისფანჯარა. ქსელის ტიპის შესარჩევად ჩავრთოდ **Types**(ტიპი) ჩანართი.

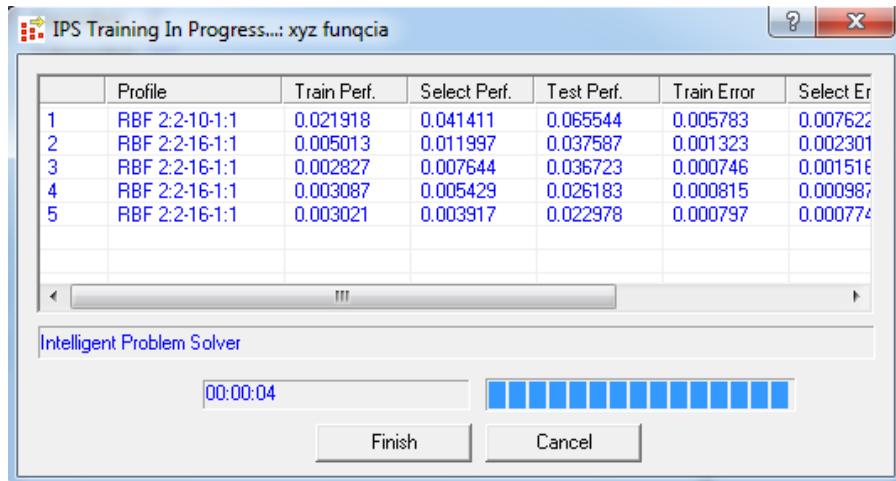


როგორც ჩანს ეს ამოცანა ტოპოლოგიურად ახლოს არის ისეთ ნეიროქსელურ არქიტექტურასთან, რომელიც ეფუძნება რადიალურ-ბაზისურ ფუნქციებს, ამიტომ **Network types to test** ველში ჩავრთოდ **Radial basis function** (რადიალური ბაზისური ფუნქცია)-ის ოპცია.

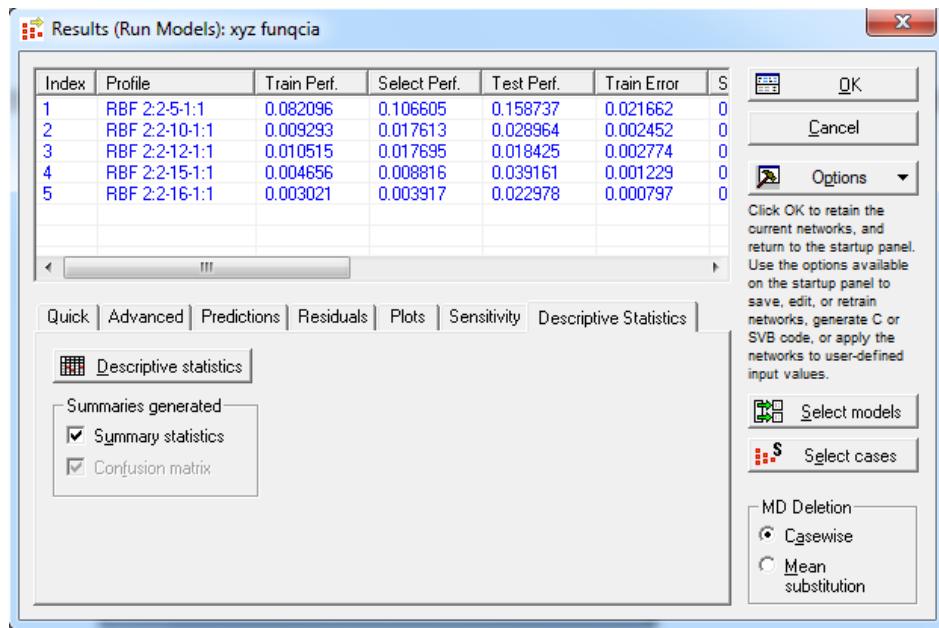
ჩავრთოდ **Quick**(სწრაფი) ჩანართი,



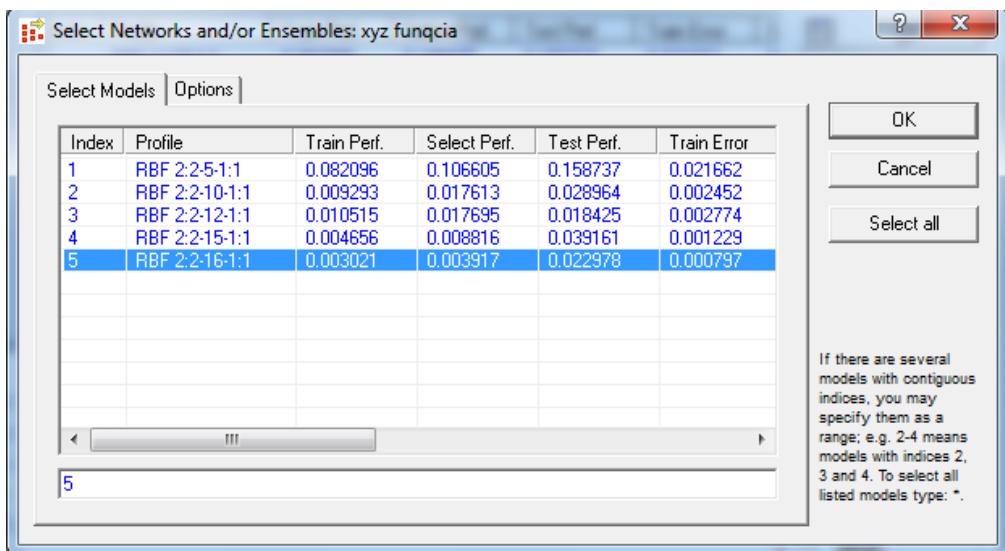
სადაც **Optimization time** (ანალიზის ხანგრძლივობა) ჯგუფის **Networks tested** (ქსელების ტესტირება) ველში ჩავწეროთ 100, ხოლო ქსელის შესანახად **Networks retained** (ქსელის შენარჩუნება) ველში ჩავწეროთ ციფრი 5, რათა პროგრამამ შეინახოს 5 საუკეთესო ქსელის ვარიანტი. შემგაბარებელი შემთხვევაში Click OK დილაკზე. ეკრანზე გამოჩენდება ნეიროქსელის სწავლების დიალოგიური **Training In Progress**(მიმდინარეობს შესწავლა) ფანჯარა.



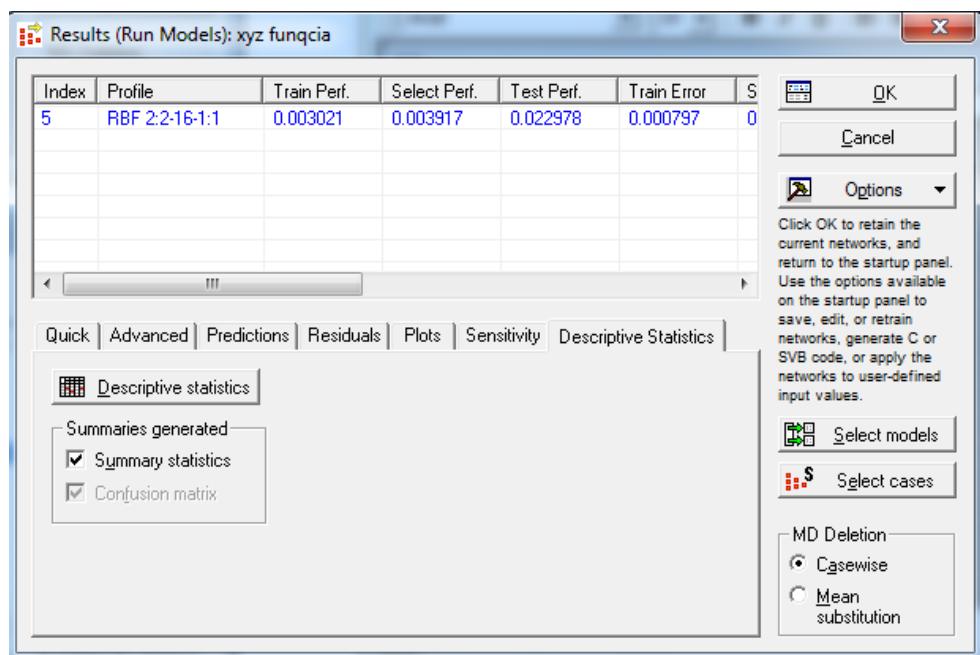
ძებნის დასრულების შემდეგ ეკრანზე გამოჩენდება შედეგების **Results(Run Models)** (შედეგები) ფანჯარა.



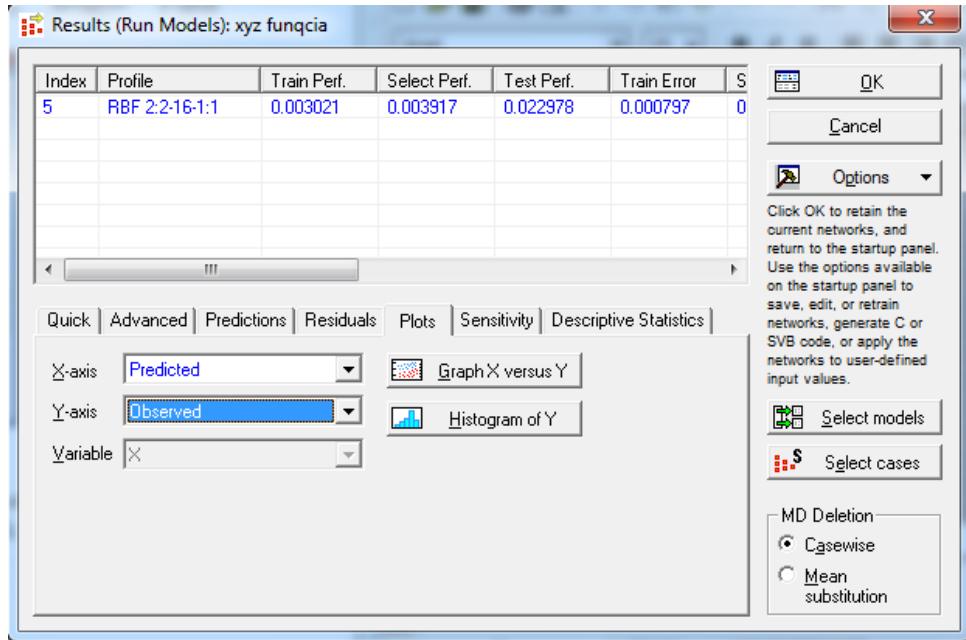
Click Select models (მოდელის მონიშვნა) დილაკზე და ეკრანზე გამოსულ შედეგების ცხრილში მოვნიშნოთ მე-5 მოდელი, რადგან მას გააჩნია ყველაზე კარგი შედეგი.



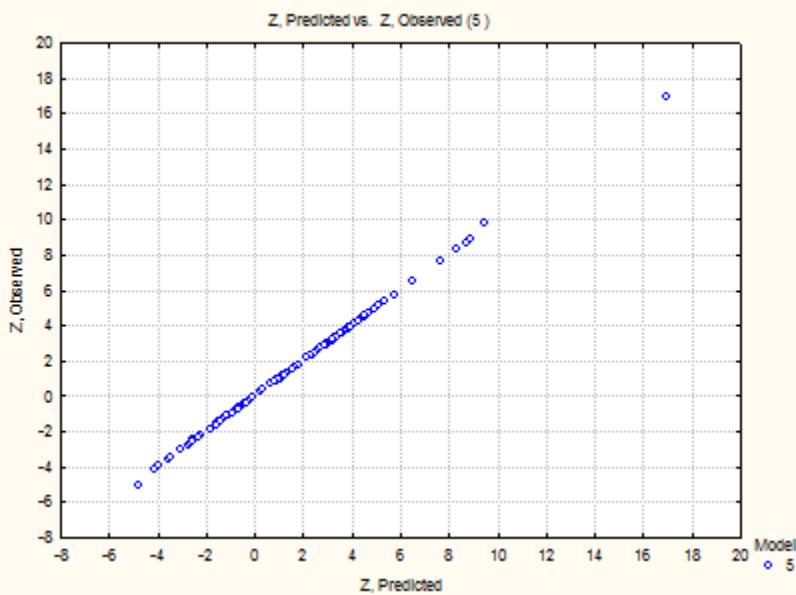
შემდეგ *OK*.



დაკვირვებების გრაფიკის ასაგებად ჩავრთოდ ჩანართ **Plots** (გრაფიკი) და **X-axis** (დერმზე)-ის ველში შევარჩიოთ **Predicted** (დაკვირვება), ხოლო **Y-axis** (დერმზე) – **Observed** (პროგნოზირება).



ავგოთ X და Y ცვლადების დამოკიდებულების გრაფიკი. ამისათვის
Click GraphX versus Y დილაპზე. ეკრანზე გამოდის დამოკიდებულების გრაფიკი,



საიდანაც ჩანს, რომ გრაფიკი ფაქტიურად იდეალურად დევს სწორ ხაზზე. ამ შედეგის მიღება მოსალოდნელი იყო, რადგან როგორც შედეგების **Results(Run Models)** ფანჯარაში ჩანს მე-5 მოდელის სწავლების ცდომილება შეადგენს მხოლოდ 0,08%.

შედეგების **Results(Run Models)** ფანჯარის **Quick** ჩანართში *Click Descriptive statistics* (აღწერითი სტატისტიკა)-ის დილაპზე. ეკრანზე გამოდის რეგრესიის შეცდომების ცხრილი,

| | Regression (5) (xyz funqcia) |
|-------------|-------------------------------|
| | Z.5 |
| Data Mean | 1,654097 |
| Data S.D. | 3,417326 |
| Error Mean | -0,001730 |
| Error S.D. | 0,040803 |
| Abs E. Mean | 0,014707 |
| S.D. Ratio | 0,011940 |
| Correlation | 0,999932 |

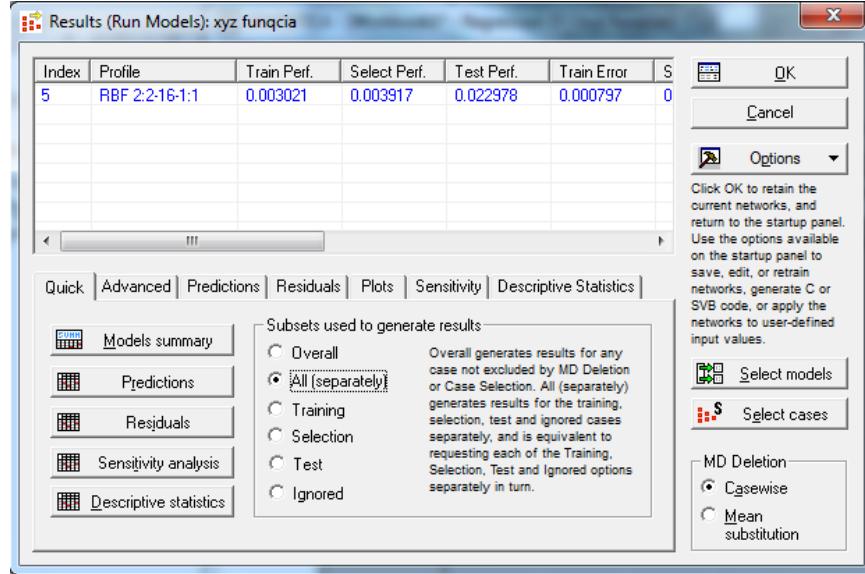
მიღებულ შედეგებიდან ჩანს,რომ მე-5 ქსელის სტანდარტული გადახრების ფარდობის სიდიდე **S.D.Ratio** 0,0119 ტოლია, რაც საკმაოდ კარგი მაჩვენებელია.

თუ შედეგების **Results(Run Models)** ფანჯარის **Subsets used to generale results** (შერჩევის შედეგების გამოყვანა)-ის ველში **Overall** (სრული) ოპციის მაგივრად ჩავრთავთ **All (separately)** (ყველა ცალკე) ოპციას, მაშინ ეს მოგვცემს საშულებას მივიღოთ ცხრილი, სადაც შერჩევის შედეგები ყველა ამონარჩევისათვის ცალკე გამოდის.

| | Regression (5) (xyz funqcia) | | | |
|-------------|-------------------------------|-----------|-----------|-------|
| | T.Z.5 | S.Z.5 | X.Z.5 | I.Z.5 |
| Data Mean | 1,858886 | 1,595856 | 1,287589 | 0,00 |
| Data S.D. | 3,722170 | 2,546201 | 3,483434 | 0,00 |
| Error Mean | 0,000000 | -0,004443 | -0,002606 | 0,00 |
| Error S.D. | 0,011245 | 0,009974 | 0,080042 | 0,00 |
| Abs E. Mean | 0,008911 | 0,007468 | 0,033965 | 0,00 |
| S.D. Ratio | 0,003021 | 0,003917 | 0,022978 | 0,00 |
| Correlation | 0,999995 | 0,999993 | 0,999783 | 0,00 |

როგორც ცხრილიდან ჩანს **S.D.Ratio** სიდიდე ყველა ამონარჩევისათვის თითქმის ერთნაირია.

იმისათვის, რომ საბოლაოდ დავრწმუნდეთ ნეიროქსელის შერჩევის სისწორეში **Results(Run Models)** ფანჯარაში ჩავრთოდ **Predictions** ჩანართო.

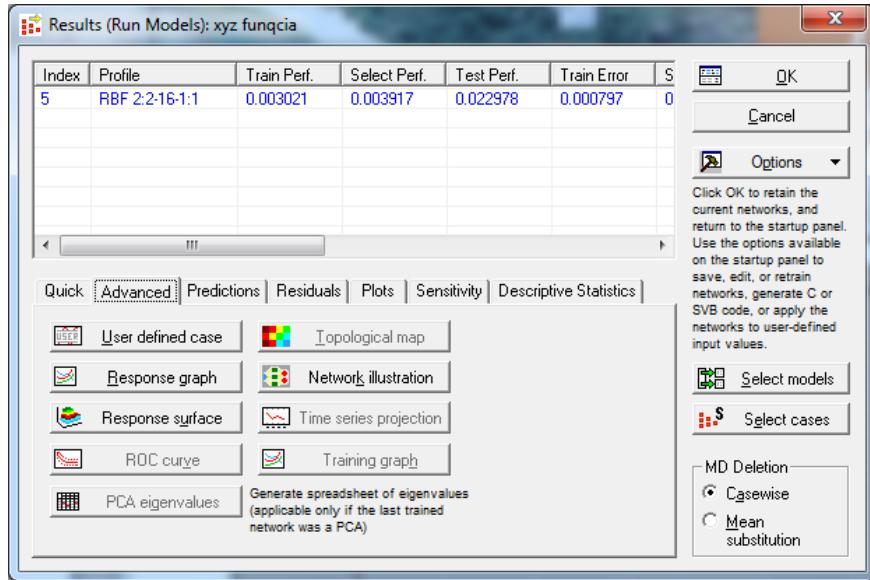


და **Click Predictions** (პროგნოზირება)-ის ღილაპიტე. ეკრანზე გამოდის შედეგების ცხრილი,

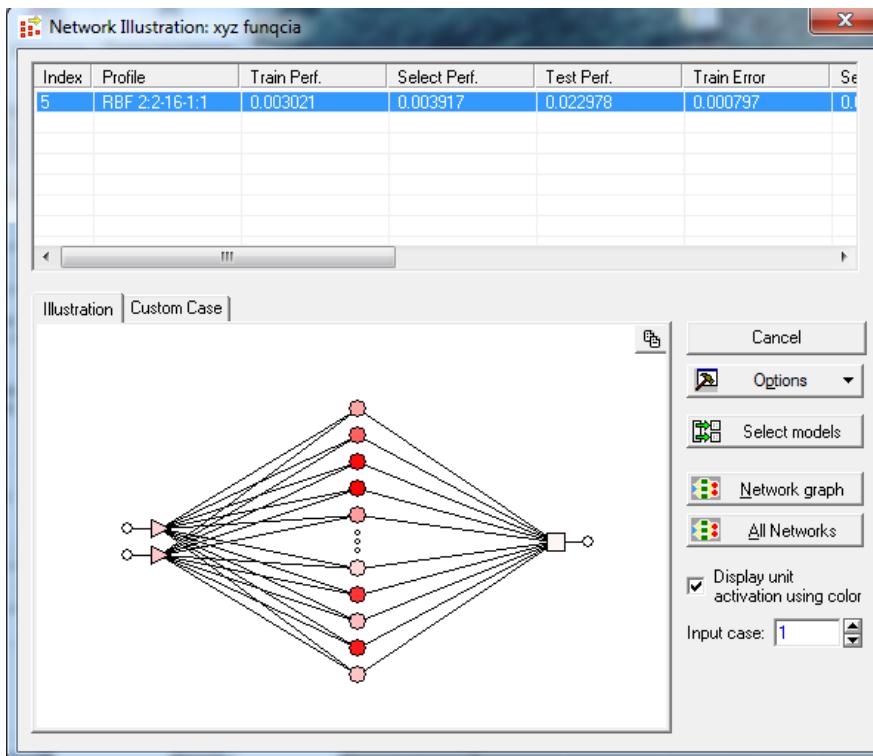
| | Prediction (5) (Test) (xyz funqcia) | |
|----|-------------------------------------|----------|
| | Z | Z.5 |
| 1 | 2,36023 | 2,35839 |
| 7 | 3,90360 | 3,89803 |
| 12 | 3,29845 | 3,30537 |
| 24 | 3,08827 | 3,08128 |
| 25 | 3,10934 | 3,11988 |
| 29 | -0,54753 | -0,54004 |
| 37 | -2,49322 | -2,52592 |
| 38 | -2,19896 | -2,22933 |
| 40 | 1,01722 | 1,02118 |
| 44 | -0,36025 | -0,34414 |
| 53 | 8,67305 | 8,74829 |
| 63 | 9,79347 | 9,45707 |
| 64 | -0,06371 | -0,06382 |
| 71 | 1,17087 | 1,19267 |
| 72 | -3,46453 | -3,47633 |
| 74 | 2,96469 | 2,95817 |
| 75 | -3,44946 | -3,47298 |
| 76 | 5,32762 | 5,35440 |
| 77 | -1,51580 | -1,53374 |
| 78 | -0,26789 | -0,25244 |

სადაც მარცხენა სვეტში მოცემულია z-ის ჭეშმარიტი მნიშვნელობები, ხოლო მარჯვენა სვეტში – ნეიროქსელის მიერ ტესტური ამონარჩევით მიღებული პროგნოზირებული მნიშვნელობები. როგორც ცხრილიდან ჩანს, მიღებული შედეგები დამაკმაყოფილებელია.

ნეირონული ქსელის არქიტექტურის ასაგებად შედეგების **Results(Run Models)** ფანჯარაში ჩავრთოდ **Advanced** ჩანართი



და **Click Network Archition** (ქსელის არქიტექტურა)-ის დილაპზე. ეკრანზე გამოდის ნეიროქსელის გრაფი.



ქსელს აქვს პირდაპირი გავრცელების სტრუქტურა ორი შემავალი ცვლადით, ფარული შრე 16 ელემენტით და ერთი ელემენტი გამომავალ შრეში. მოდელის აგების სიზუსტე, ტესტირების ეფექტიანობის **TestPerf.** მაჩვენებლიდან გამომდინარე, 0,08% ტოლოა.

შეიძლება გამოვიტანოთ დასკვნა, რომ ქსელმა წარმატებით მოახდინა შესასწავლი ნაკრების სტრუქტურის გარჩევა და მისი გამოყენება შეიძლება დამოკიდებული ცვლადის მნიშვნელობების პროგნოზირებისთვის. შევინახოთ მოდელი. ისე როგორც მოცემულია პრაქტიკული სამუშაო 1 –ში

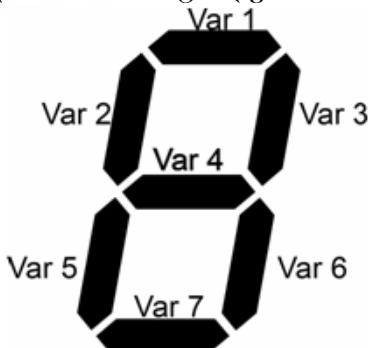
პრაქტიკული სამუშაო 3

სახეთა ბარჩევის ამოცანა

ნეირონულ ქსელების საშუალებით შესაძლებელია სახეთა გარჩევის ამოცანის გადაწყვეტა. მაგალითისათვის განვიხილოთ იმიტირებული მონაცემები, წარმოადგენილნი ციფრების სახით, რომლებიც გამონათებულნი არიან გაუმართავი კალკულატორის ეკრანზე. დამოკიდებულ **Digit** ცვლადის დაკვირვების კლასები შეესაბამებიან ციფრებს 0, 1, 2, 3, .. 9, რომლებიც შეუვანილია კალკულატორის კლავიშიდან.

ამოცანაში გვაქვს 7 კატეგორიალური პრედიქტორები **Var1 - Var7** ხაზების სახით, რომლებიც ქმნიან ციფრების კონფიგურაციას. კატეგორიალური პრედიქტორის ღონე (0 – არ არის; 1 - არის) გვიჩვენებს, გაანათა თუ არა ეკრანზე შესაბამისმა ხაზმამ იმ შვიდი ხაზიდან (3 ჰორიზონტალურიდა 4 ვერტიკალური), რომლითაც წარმოდგენილია გასარჩევი ციფრი.

პრედიქტორის ცვლადების აღწერა : **Var1**-ზედა ჰორიზონტალური, **Var2**–ზედა მარცხენა ვერტიკალური, **Var3** -ზედა მარჯვენა ვერტიკალური, **Var4** –შეუ ჰორიზონტალური, **Var5** –ქვედა მარცხენა ვერტიკალური, **Var6** –ქვედა მარჯვენა ვერტიკალური და **Var7** –ქვედა ჰორიზონტალური.



კალკულატორი გაუმართავია, ასე რომ, როდესაც დავაჭერთ ციფრულ კლავიატურის ნებისმიერ ღილაპს, ეკრანზე ყოველთვის არ გამოანათებს შესაბამისი ხაზების კომბინაცია.

Statistica სისტემის **Datasets** ბიბლიოთეკიდან გავხსნათ **Digit** მონაცემთა ფაილი, რომლის ფრაგმენტი წარმოდგენილია შემდეგ ნახაზზე:

| Data: Digit (8v by 500c) | | | | | | | | |
|--------------------------|--------------------------------------|-----------|-----------|-----------|-----------|-----------|-----------|--|
| 1 DIGIT | Example data for pattern recognition | | | | | | | |
| | 2 VAR1 | 3 VAR2 | 4 VAR3 | 5 VAR4 | 6 VAR5 | 7 VAR6 | 8 VAR7 | |
| 1 seven | ONE | ZERO | ONE | ZERO | ZERO | ONE | ZERO | |
| 2 one | ZERO | ZERO | ONE | ZERO | ZERO | ONE | ZERO | |
| 3 four | ZERO | ONE | ONE | ONE | ZERO | ONE | ZERO | |
| 4 two | ONE | ONE | ONE | ONE | ONE | ZERO | ZERO | |
| 5 eight | ZERO | ONE | ONE | ONE | ONE | ONE | ONE | |
| 6 one | ZERO | ZERO | ONE | ZERO | ZERO | ONE | ZERO | |
| 7 five | ONE | ONE | ZERO | ONE | ZERO | ONE | ONE | |
| 8 six | ONE | ZERO | ZERO | ONE | ONE | ONE | ONE | |
| 9 two | ONE | ZERO | ONE | ONE | ONE | ZERO | ONE | |
| 10 eight | ONE | ONE | ONE | ONE | ZERO | ONE | ONE | |
| 11 one | ZERO | ZERO | ONE | ZERO | ONE | ONE | ZERO | |
| 12 eight | ONE | ONE | ONE | ONE | ONE | ONE | ONE | |
| 13 one | ONE | ZERO | ONE | ZERO | ONE | ONE | ZERO | |
| 14 seven | ONE | ZERO | ONE | ZERO | ZERO | ONE | ZERO | |
| 15 seven | ZERO | ZERO | ONE | ZERO | ONE | ONE | ZERO | |
| 16 six | ONE | ONE | ZERO | ONE | ONE | ONE | ONE | |
| 17 zero | ONE | ZERO | ONE | ZERO | ONE | ONE | ZERO | |
| 18 one | ZERO | ZERO | ONE | ZERO | ZERO | ONE | ONE | |
| 19 four | ZERO | ONE | ONE | ONE | ZERO | ONE | ZERO | |
| 20 six | ONE | ONE | ZERO | ONE | ONE | ONE | ONE | |

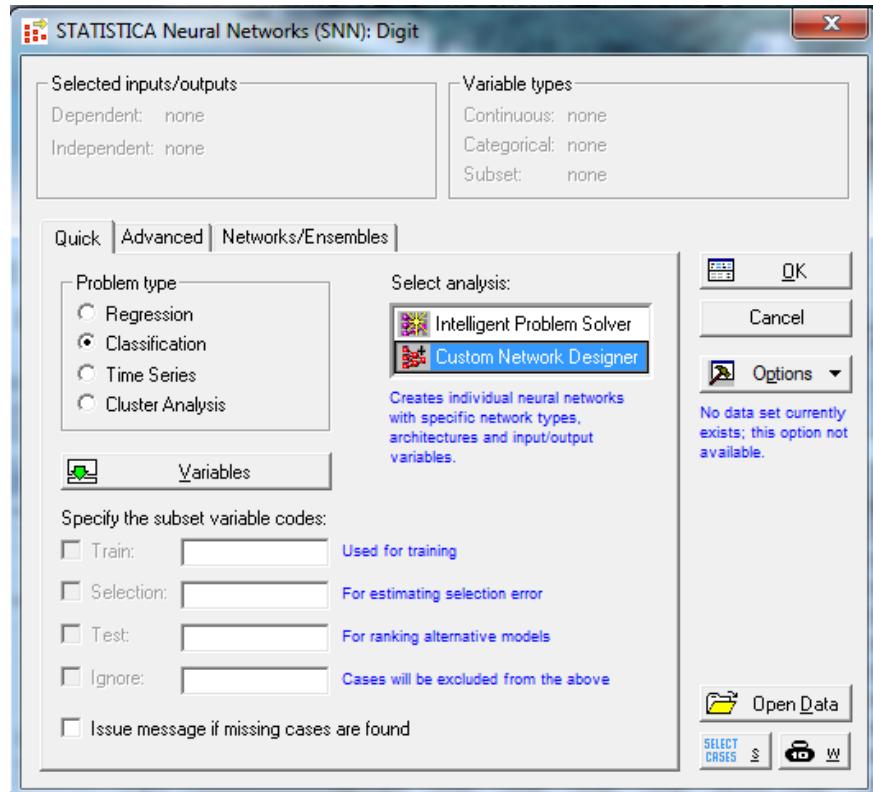
ფაილი წარმოდგენს მონაცემების მთელ კომპლექტს, რომელიც შედგება 500 დაკვირვებულისაგან. გარჩევის შედეგები ჩაწერილია **Digit** ცვლადის სვეტში. **Var1 - Var7** ცვლადების სვეტებში წარმოდგენილია დამოუკიდებელი კატეგორიალური პრედიქტორების დონეები (ნული ან ერთი).

მოცემულ მაგალითში საჭიროა ავაგოთ რეალური კალკულატორისაგან მიღებული ციფრების გარჩევის მოდელი. მიზანშეწონილია ნეირონული ქსელის მიმართ ჩამოვაყალიბოთ შემდეგი მოთხოვნები: 1) ქსელმა უნდა შეძლოს მონაცემთა ექსტრაპოლირება ანუ ჩამოვაყალიბოს სწორი პროგნოზი პრედიქტორების კომბინაციებზე, რომლებიც ძალიან განსხვავდებიან სასწავლო სიმრავლისაგან. 2) პრაქტიკული გამოყენებისათვის პროგნოზირების მცირე დორო.

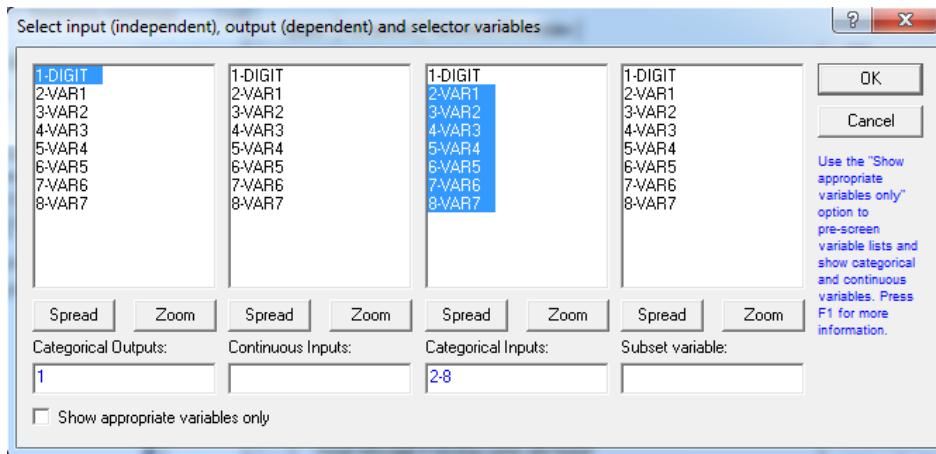
მითითებულ პირობებს შეესაბამება მრავალშრიანი პერსეპტრონის არქიტექტურა. ელემენტების რაოდენობა ფარულ შრეში შევარჩიოთ 5(კლასიფიკაცია წარმოებს 10 კლასსში). საზოგადოდ, მოდელის აგებისას პირველი მიახლოებით ფარული შრის ელემენტებს ირჩევენ შემაგალი და

გამომავალი ელემენტების ჯამის ნახევრის სიდიდის ტოლად, მაგრამ ჩვენ შემთხვევაში ელემენტების რაოდენობის შერჩევა განპიროვნებულია კლასების რაოდენობითაც.

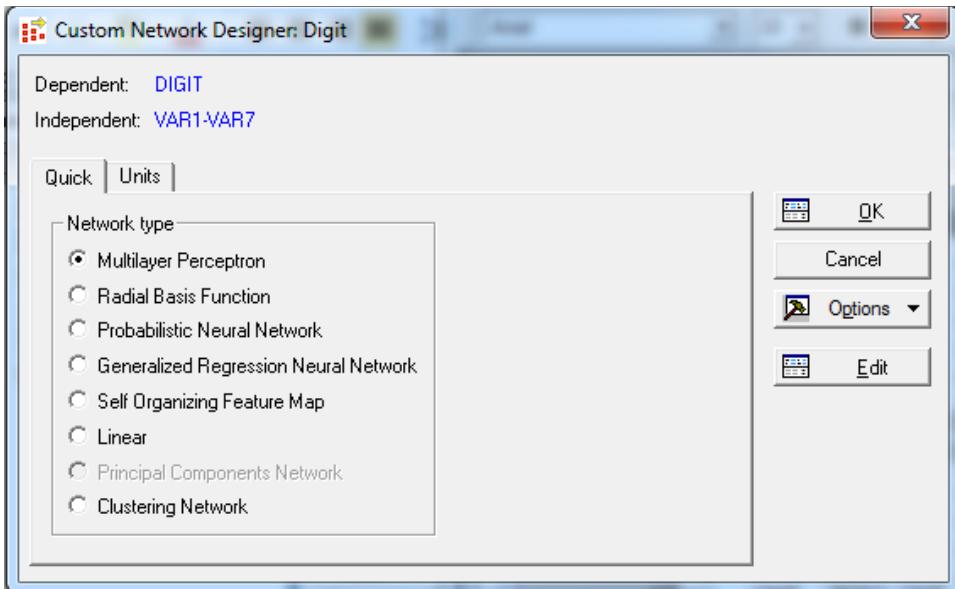
სასტარტო პანელის **STATISTICA Neural Networks** გამოსაძახებლად, მენიუდან **Statistics** შევარჩიოთ ბრძანება **Neural Networks**. ეპრანზე გამოდის **STATISTICA Neural Networks(SNN)** ფანჯარა.



ჩავრთოდ **Quick** ჩანართი და **Problem type** ველში შევარჩიოთ ამოცანის ტიპი **Classification**, ხოლო **Select analysis** ველში ამოხსნის მეთოდი – **Custom Network Designer** (ქსელის კონსტრუქტორი). ცვლადების მოსანიშნად **Click Variables** ღიაპზე და ეკრანზე გამოსულ **Select input(independent), outp(dependent) and Selector variables** (მოვნიშნოთ შემავალი (დამოკიდებული), გამომავალი (დამოკიდებული) და დამაჯგუფებელი ცვლადები) ფანჯრის **Continuous outputs** (უწყვეტი გამომავალი) ველში მოვნიშნოთ **DIGIT** ცვლადი, ხოლო **Categorical inputs** (შემავალი გატეგორიალური) ველში – **VAR 1- VAR7** ცვლადები.

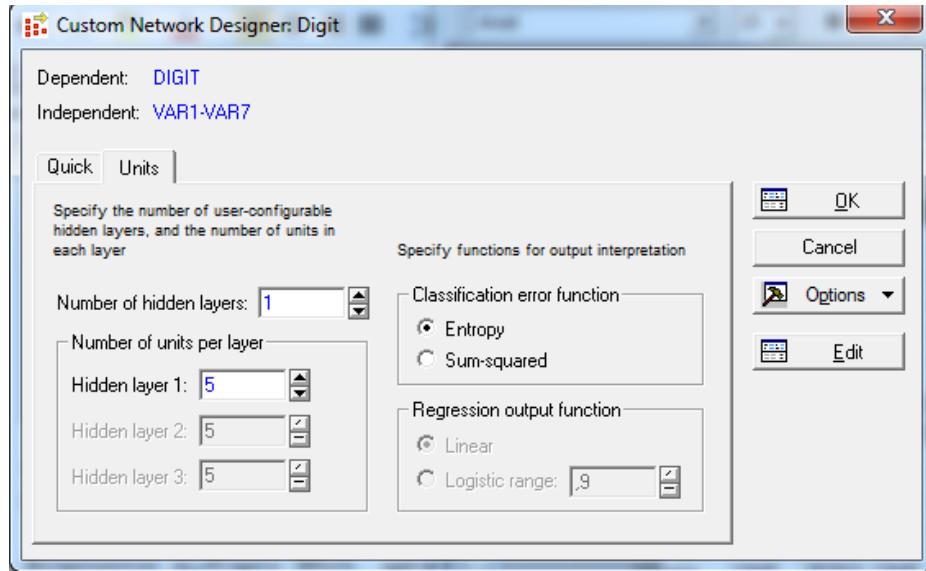


შემდეგ Click OK. ვპრუნდებით **STATISTICA Neural Networks (SNN)** ფანჯარაში და კვლავ OK. ეკრანზე გამოდის **Custom Network Designer** ფანჯარა

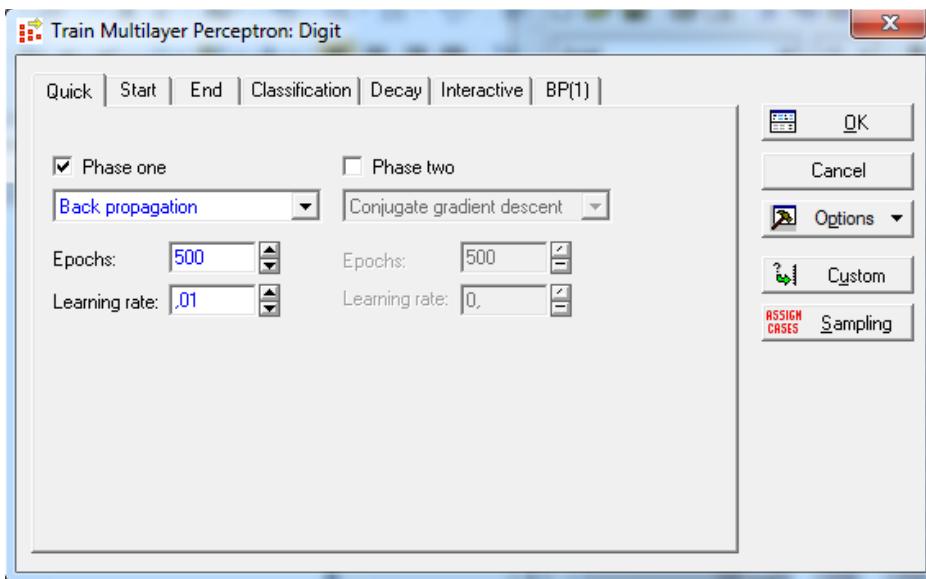


სადაც **Quick** (სწრაფი) ჩანართში შევარჩიოთ ქსელის ტიპი **Multilayer Perceptron** (მრავლობითი პერსეპტორი).

ამავე ფანჯარაში ჩავრთოდ **Units** (ქსელის ელემენტები) ჩანართი და **Hidden layer 1** ველში მიუთითოთ ფარული შრის ელემენტების რაოდენობა 5.



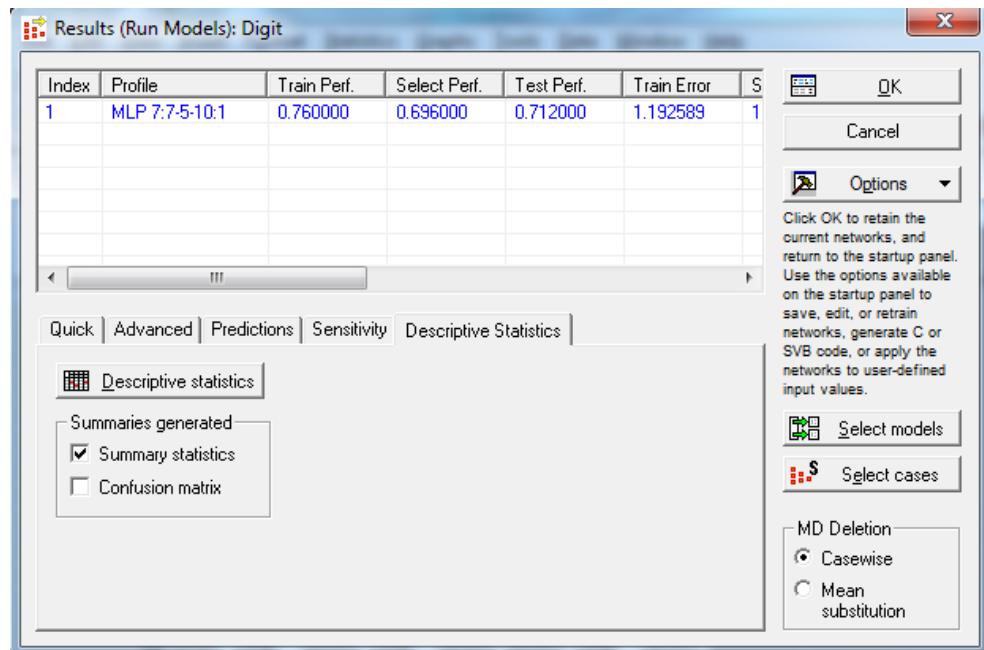
ამდენად, ქსელების არქიტექტურა დადგენილია. Click **OK**. ეკრანზე გამოდის **Train Multilayer Perceptron** (მრავალშრიანი პერსისტრონის სწავლება)-ის ფაჯარა,



სადაც ჩავრთოდ **Phase one** (პირველი ფაზა) ოპცია და შევარჩიოთ სწავლების **Back propagation** (უკუგავრცელების) ცდომილების უკუგავრცელების ალგორითმი. ეს ალგორითმი შეიძლება გამოყენებულ იყოს **Statistica Neural Networks** პაკეტის ქსელების უმრავლესობისათვის, მაგრამ ის განსაკუთრებით მოსახერხებელია მრავალშრიანი პერსისტრონების სწავლებისათვის. სხვა სწავლების ალგორითმებთან შედარებით მას სჭირდება ნაკლები მეხსიერება და ჩვეულებრივ საკმაოდ სწრაფად აღწევს დასაშვებ მინიმალური ცდომილების დონემდე. **Epochs** (ეპოქები)-ის ველში ჩავწეროთ 500. ეპოქის ქვეშ იგულისხმება სწავლის პროცესში ინტერაციის მაქსიმალური რაოდენობა. ჩვეულებრივად ეპოქების

რაოდენობა იცვლება 100 -დან 1000-მდე. **Learning rate** (სწავლების სიჩქარე) ვალიში გაჩუმების პრინციპით დაყენებული მნიშვნელობა დავტოვოთ ხელუხლებლად, რადგან ეს სიდიდე უმტკის ამოცანებისათვის უზრუნველყოფს სწავლების პროცესის მდგრადობას.

უნდა აღინიშნოს, რომ სწავლების პროცედურა უნდა გავიმეოროთ მანამ, სანამ არ მივიღებთ სწავლების მინიმალურ ცდომილებას. სწავლების პარამეტრების დაყენების შემდეგ *Click OK*. ჩაირთვება სწავლების პროცედურა და ეკრანზე გამოდის **Results (Run Models)** შედეგების ფანჯარა,

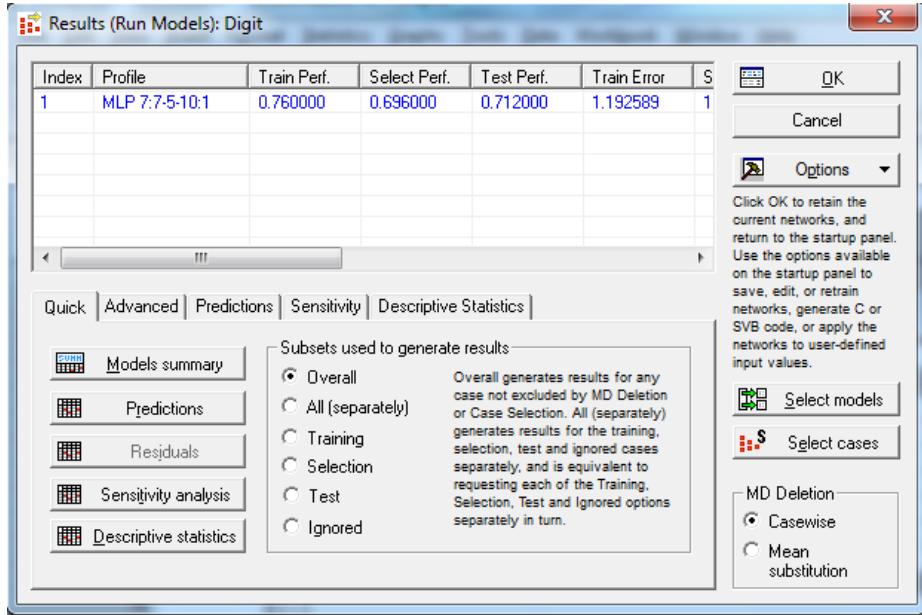


სადაც ჩავრთოდ *Quick* ჩანართი და *Click Descriptive statistics* (აღწერითი სტატისტიკა)-ის ღილაკზე. ეკრანზე გამოდის შეცდომების ცხრილი: **Classification** (კლასიფიკაცია).

| | Classification (1) (Digit) | | | | | | | | | | |
|------------|----------------------------|-------------|--------------|-------------|---------------|--------------|-------------|--------------|--------------|---------------|--|
| | DIGIT.seven.1 | DIGIT.one.1 | DIGIT.four.1 | DIGIT.two.1 | DIGIT.eight.1 | DIGIT.five.1 | DIGIT.six.1 | DIGIT.zero.1 | DIGIT.nine.1 | DIGIT.three.1 | |
| Total | 48,00000 | 43,00000 | 52,00000 | 43,00000 | 58,00000 | 54,00000 | 50,00000 | 42,00000 | 55,00000 | 55,00000 | |
| Correct | 32,00000 | 35,00000 | 43,00000 | 32,00000 | 39,00000 | 40,00000 | 43,00000 | 33,00000 | 33,00000 | 36,00000 | |
| Wrong | 16,00000 | 8,00000 | 9,00000 | 11,00000 | 19,00000 | 14,00000 | 7,00000 | 9,00000 | 22,00000 | 19,00000 | |
| Unknown | 0,00000 | 0,00000 | 0,00000 | 0,00000 | 0,00000 | 0,00000 | 0,00000 | 0,00000 | 0,00000 | 0,00000 | |
| Correct(%) | 66,66667 | 81,39535 | 82,69231 | 74,41860 | 67,24138 | 74,07407 | 86,00000 | 78,57143 | 60,00000 | 65,45455 | |
| Wrong(%) | 33,33333 | 18,60465 | 17,30769 | 25,58140 | 32,75862 | 25,92593 | 14,00000 | 21,42857 | 40,00000 | 34,54545 | |
| Unknown(%) | 0,00000 | 0,00000 | 0,00000 | 0,00000 | 0,00000 | 0,00000 | 0,00000 | 0,00000 | 0,00000 | 0,00000 | |

სადაც ათივე კლასისათვის წარმოდგენილია დაწვრილებით ინფორმაცია სწორი და არასწორი კლასიფიცირებული დაკვირვების რაოდენობაზე, კერძოდ **Total** (სულ), **Correct** (სწორი), **Wrong** (მცდარი), **Unknown** (უცნობია) შედეგები და მათი პროცენტული მნიშვნელობები: **Correct (%)**, **Wrong (%)**, **Unknown (%)**.

როგორც ცხრილიდან ჩანს, ყველაზე დიდი შეცდომა დაშვებული იყო „9“ კლასის გარჩევისას (**Wrong (%) = 40%**).



პრედიქტორების მიმართ მგრძობიარობის ანალიზის ჩასატარებლად *Click Sensitivity Analysis* (მგრძნობიარობის ანალიზი)-ის დილაკზე. ეკრანზე გამოდის ამავე დასახელების ცხრილი,

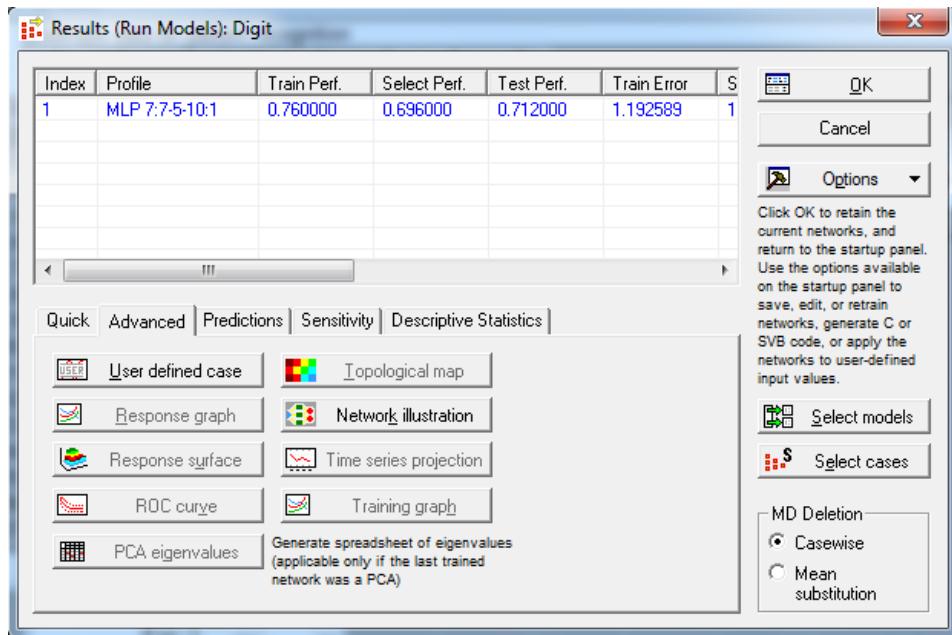
| | Sensitivity Analysis - 1 (Digit) | | | | | | |
|----------------|----------------------------------|----------|----------|----------|----------|----------|----------|
| | VAR1 | VAR2 | VAR3 | VAR4 | VAR5 | VAR6 | VAR7 |
| Ratio.1 | 1,181192 | 1,157405 | 1,318093 | 1,226775 | 1,186577 | 1,075947 | 1,125123 |
| Rank.1 | 4,000000 | 5,000000 | 1,000000 | 2,000000 | 3,000000 | 7,000000 | 6,000000 |

სადაც შვიდივე პრედიქტორისთვის წარმოდგენილია **Ratio** (ფარდობა) და **Rank** (რანგი) მნიშვნელობები. **Rank.1** შეესაბამება უდიდეს მგრძნობიარობას მოცემული პრედიქტორისათვის. როგორც ცხრილიდან ჩანს, **VAR3** (ზედა მარჯვენა ვერტიკალური) და **VAR4** (შეუარრიზონული) ცვლადებს შეაქვთ დიდი წვლილი ციფრების გარჩევაში.

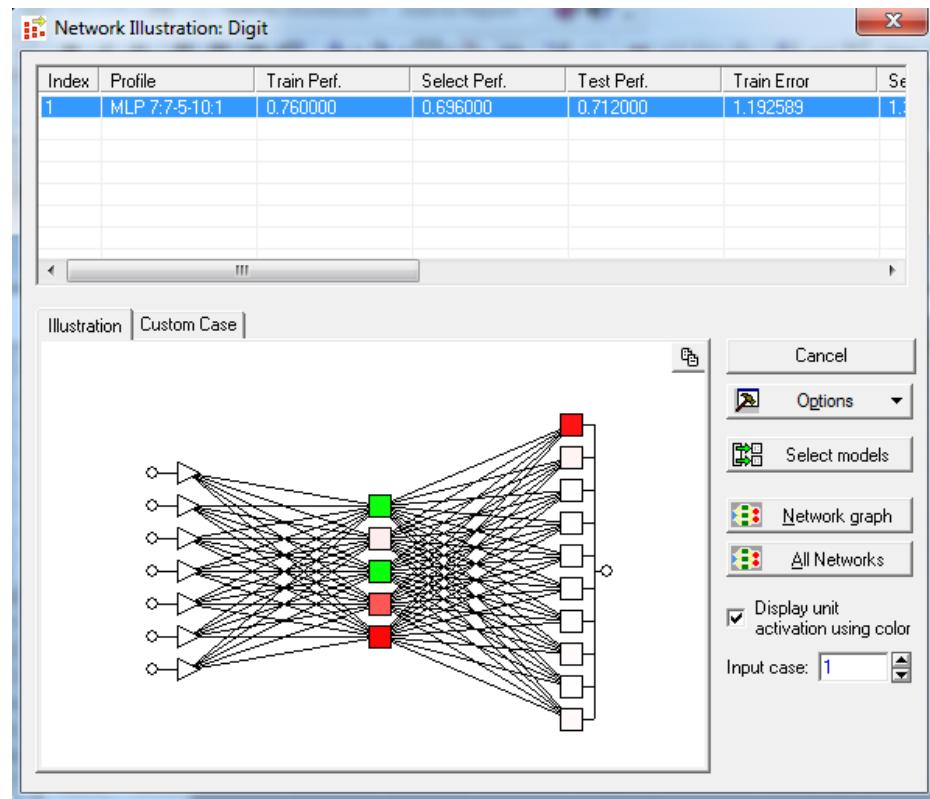
მოდელის შედეგი სასწავლო, საკონტროლო, და ტესტური სიმრავლეებისათვის შეიძლება მივიღოთ **Predictions** (პროგნოზირება) დილაკზე დაჭრით. პროგნოზირების ცხრილი პირველი 15 დაკვირვებისთვის ნაჩვენებია შემდეგ ნახაზზე:

| | Prediction (1) (Digit) | |
|----|-------------------------|---------|
| | DIGIT | DIGIT.1 |
| 1 | seven | seven |
| 2 | one | one |
| 3 | four | four |
| 4 | two | eight |
| 5 | eight | eight |
| 6 | one | one |
| 7 | five | five |
| 8 | six | six |
| 9 | two | two |
| 10 | eight | nine |
| 11 | one | one |
| 12 | eight | eight |
| 13 | one | seven |
| 14 | seven | seven |
| 15 | seven | one |

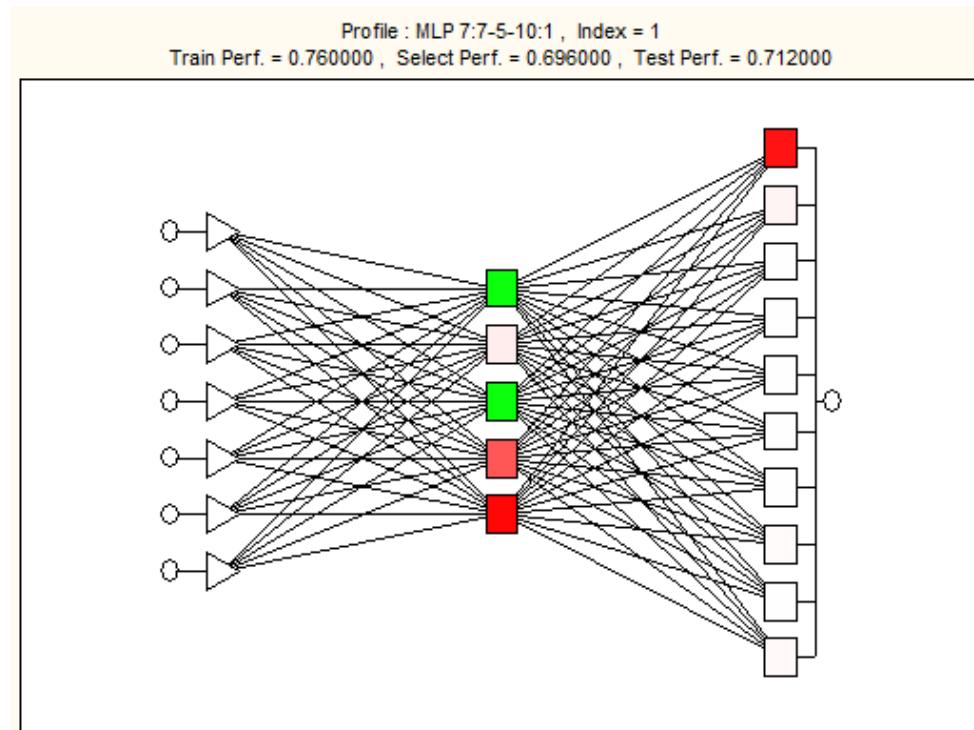
აგებული ქსელის არქიტექტურა მოსახერხებელია წარმოვაჩინოთ გრაფიკული სახით. გრაფიკის ასაგებად **Results (Run Models)** შედეგების ფანჯარაში ჩავრთოდ **Advanced** ჩანართი



და **Click Network illustration** (ქსელის ილუსტრაცია)-ის ღილაკზე. ეკრანზე გამოდის ამავე დასახელების ფანჯარა.



თუ გვინდა ნეირონული ქსელის ცალკე გრაფის სახით წარმოდგენა, მაშინ *Click Network graph* ღილაპიტი



ქსელის აქტივაციის დონე აღნიშნულია ფერებით: წითელი – დადებითი აქტივიზაციისათვის, მწვანე – უარყოფითი აქტივიზაციისათვის.

პრაქტიკული სამუშაო 4

პროგნოზირების ამოცანის გადაწყვეტა

მაგალითისათვის განვიხილოთ სრული სამი წლის ნავთობის ფასის მონაცემები. ამასთანავე ნავთობის ფასის ცვლა დაფიქსირებულია უოველ სავაჭრო დღეს. უნდა გააგანალიზოთ დროითი მწერივი (*Time Series*) და გამოვყოთ ნავთობზე ფასის მერყეობის დამახასიათებელი პერიოდები. დროითი მწერივის მოდელის დახმარებით საჭიროა ავაგოთ ნავთობის გაყიდვის პროგნოზი წინსვლით რამდენიმე თვით ადრე და შევაფასოთ პროგნოზიზის სიზუსტე:

Statistica სისტემის *Datasets* ბიბლიოთეკიდან გავხსნათ *OIL* ნავთობის ფასის მონაცემთა ფაილი, რომლის ფრაგმენტი წარმოდგენილია შემდეგ ნახაზზე:

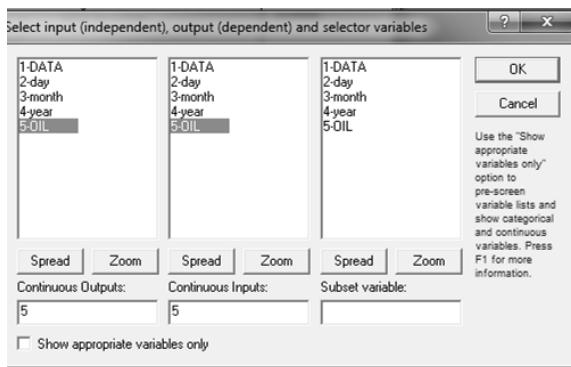
| | OIL Price | | | | |
|----|-----------|----------|------------|-----------|----------|
| | 1 DATA | 2 day | 3 month | 4 year | 5 Oil |
| 1 | 27/12/95 | 27 | 12 | 95 | 18.73 |
| 2 | 28/12/95 | 28 | 12 | 95 | 18.78 |
| 3 | 29/12/95 | 29 | 12 | 95 | 18.65 |
| 4 | 02/01/96 | 2 | 1 | 96 | 18.95 |
| 5 | 03/01/96 | 3 | 1 | 96 | 19.15 |
| 6 | 04/01/96 | 4 | 1 | 96 | 19.13 |
| 7 | 05/01/96 | 5 | 1 | 96 | 19.50 |
| 8 | 08/01/96 | 8 | 1 | 96 | 19.68 |
| 9 | 09/01/96 | 9 | 1 | 96 | 19.05 |
| 10 | 10/01/96 | 10 | 1 | 96 | 18.48 |
| 11 | 11/01/96 | 11 | 1 | 96 | 17.85 |
| 12 | 12/01/96 | 12 | 1 | 96 | 17.58 |
| 13 | 15/01/96 | 15 | 1 | 96 | 17.50 |
| 14 | 16/01/96 | 16 | 1 | 96 | 17.73 |
| 15 | 17/01/96 | 17 | 1 | 96 | 17.43 |
| 16 | 18/01/96 | 18 | 1 | 96 | 17.88 |
| 17 | 19/01/96 | 19 | 1 | 96 | 17.53 |
| 18 | 22/01/96 | 22 | 1 | 96 | 17.53 |
| 19 | 23/01/96 | 23 | 1 | 96 | 17.38 |
| 20 | 24/01/96 | 24 | 1 | 96 | 17.33 |
| 21 | 25/01/96 | 25 | 1 | 96 | 17.00 |
| 22 | 26/01/96 | 26 | 1 | 96 | 16.70 |
| 23 | 29/01/96 | 29 | 1 | 96 | 16.23 |
| 24 | 30/01/96 | 30 | 1 | 96 | 16.53 |
| 25 | 31/01/96 | 31 | 1 | 96 | 16.63 |
| 26 | 01/02/96 | 1 | 2 | 96 | 16.78 |
| 27 | 02/02/96 | 2 | 2 | 96 | 17.05 |

სადაც **DATA**(თარიღი) ცვლაში ჩაწერილია თარიღები, ხოლო ცვლადები 2–4 წარმოადგენენ თარიღის ჩანაწერს სამი ცვლადის საშუალებით **day, month, year**, (დღე/ თვე /წელი).

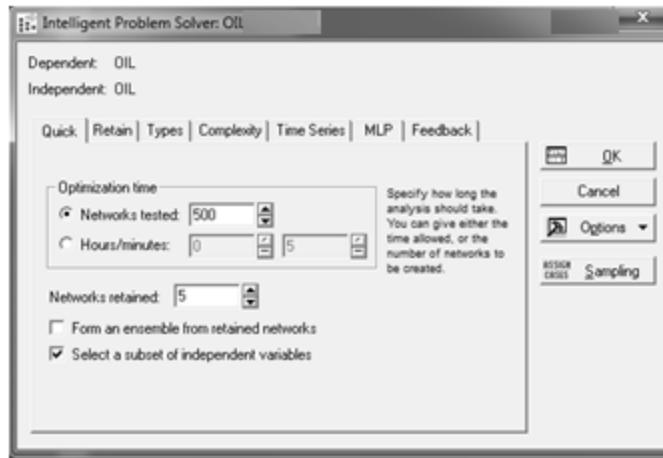
სასტარტო პანელის **STATISTICA Neural Networks** გამოსაძახებლად, მენიუდან **Statistics** შევარჩიოთ ბრძანება **Neural Networks**. ეკრანზე გამოდის **STATISTICA Neural Networks(SNN)** ფანჯარა.



ჩავრთოდ **Quick** ჩანართი და **Problem type** ველში შევარჩიოთ ამოცანის ტიპი **Time Series** (დროითი მწკრივები), ხოლო **Select analysis** ველში ამოხსნის მეთოდი – **Intelligent Problem Solver** (გადაწყვეტის ოსტატი). ცვლადების მოსანიშნად **Click Variables** ღიკაპზე და ეკრანზე გამოსულ **Select input(independent), output(dependent) and Selector variables** (მოვნიშნოთ შემავალი (დამოკიდებული), გამომავალი (დამოკიდებული) და დამაჯილდებელი ცვლადები) მოვნიშნოთ **OIL**.

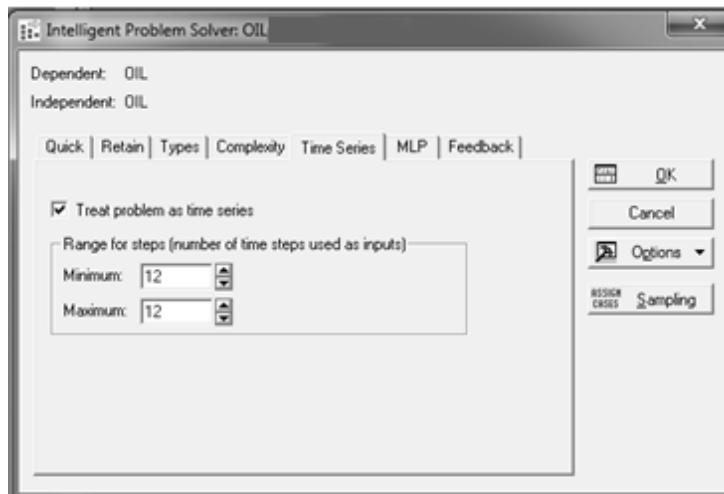


შემდეგ **Click OK**. ვბრუნდებით **STATISTICA Neural Networks (SNN)** ფანჯარაში და კვლავ **OK**. ეკრანზე გამოდის **Intelligent Problem Solver** ფანჯარა.

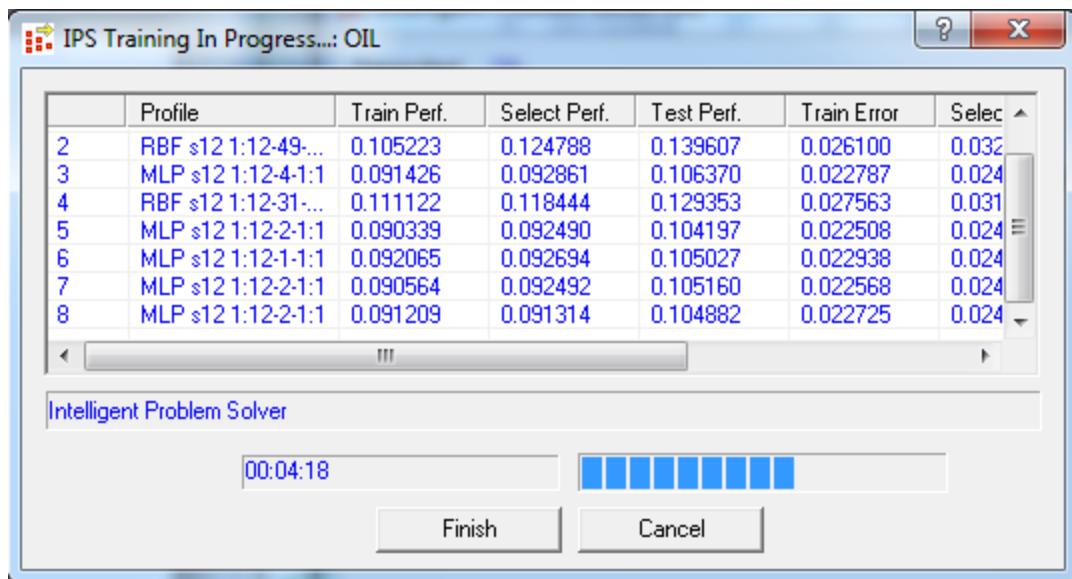


ჩავრთოდ **Quick** (სწრაფი) ჩანართი. ჯგუფში **Optimization time** (ანალიზის ხანგრძლივობა) ველში **Networks tested** (ქსელების ტესტირება) ჩავწეროთ 500. მოცემული პარამეტრი განსაზღვრავს ჩატარებული ანალიზის ხანგრძლივობას (ტესტირებისთვის განკუთვნილი მოდელების რიცხვი). ქსელის შესანახად **Networks retained** (ქსელის შენარჩუნება) ველში ჩავწეროთ ციფრი 5, რათა **Intelligent Problem Solver** (გადაწყვეტის ოსტატი) შეინახოს 5 საუკეთესო ქსელის ვარიანტი. **Types** ჩანართით შევარჩიონ ქსელის ტიპი.

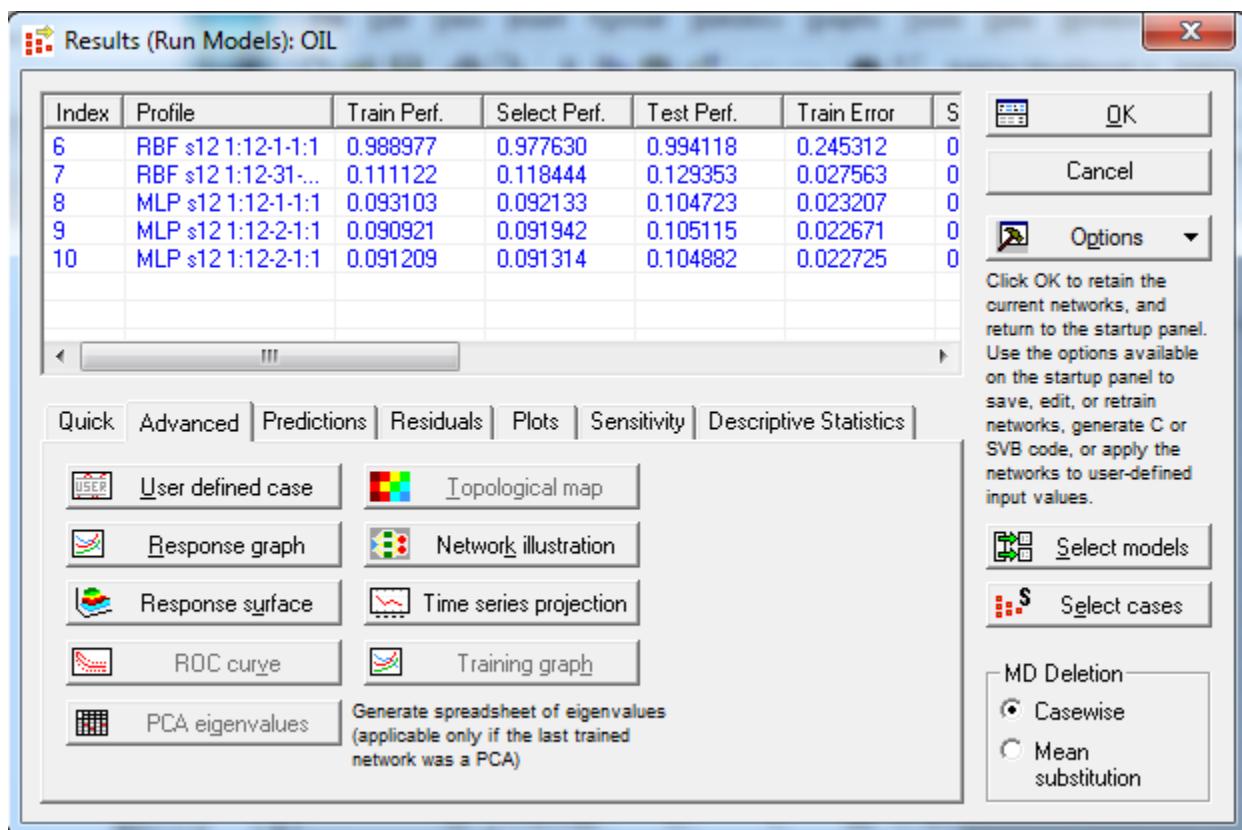
ჩავრთოდ **Time Series** ჩანართი და მოვნიშნოთ ოპცია **Treat problem as time series** (მონაცემთა ინტერპრეტაცია როგორც დროის მწკრივი).



პროგნოზირების ფანჯრად ავიდოთ 12, ამიტომ **Range for steps (number of steps used as inputs)** ჩარჩოს მინიმუმ და მაქსიმუმ ველებში ჩავწეროთ 12, რომელიც შეესაბამება იმას, რომ ერთი წლის მონაცემებით მოხდება მომდევნო ერთი თვის მნიშვნელობის პროგნოზირება. Click OK. დაიწყება მოდელის შესწავლა.



მოდელის სწავლების შემდეგ ეპრანზე გამოჩნდება **Results** (შედეგები) ფანჯარა

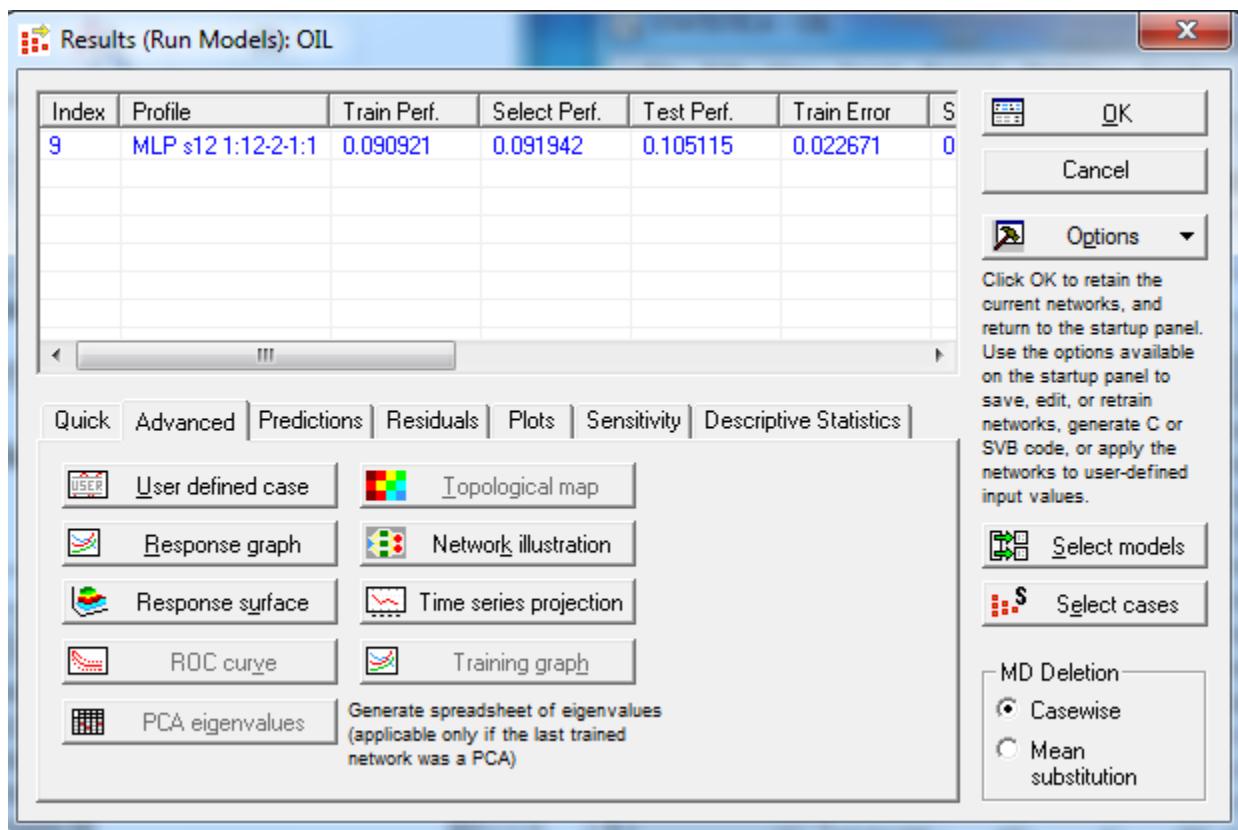


ცხრილის ზედა ნაწილში იმყოფება შენახული ქსელების არქიტექტურა და აგებული მოდელის სხვადასხვა ხარისხის მაჩვენებელი.

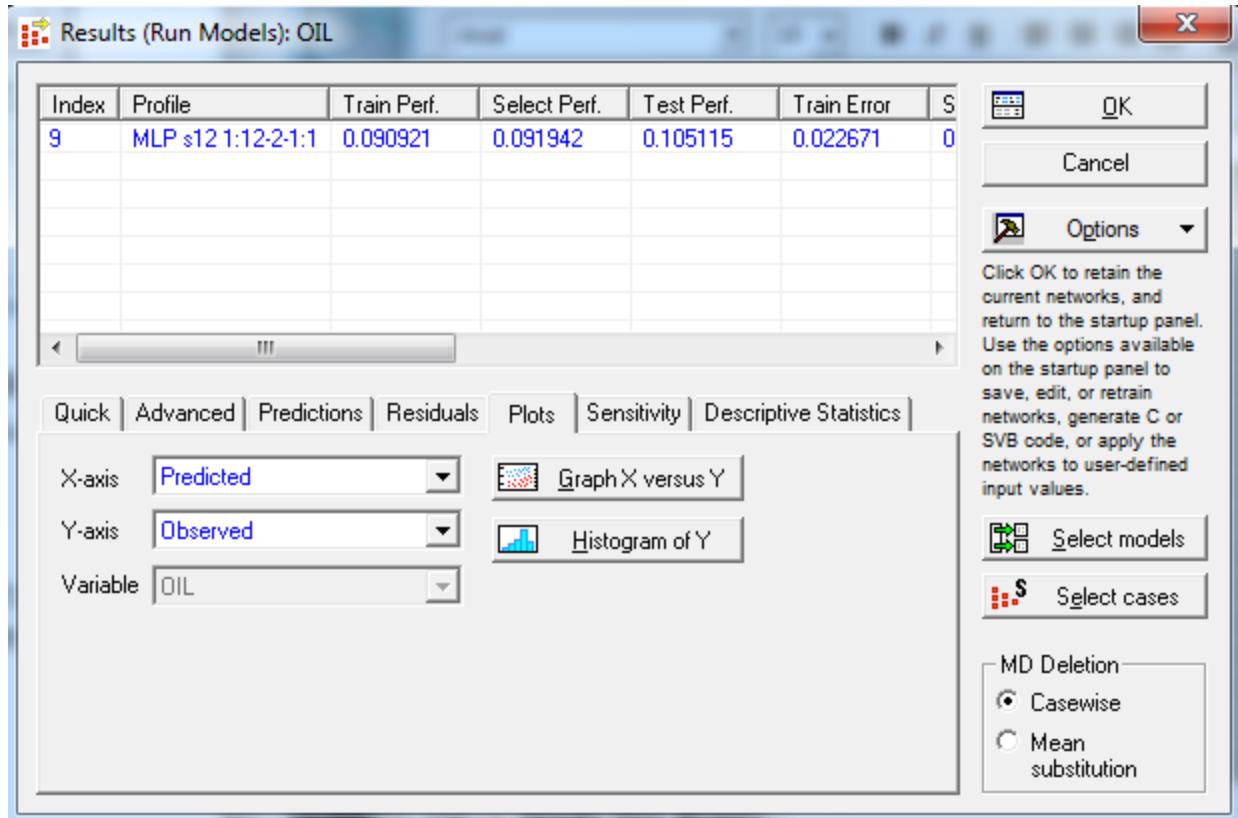
გავხსნათ **Descriptive Statistics** ჩანართი და **Click Descriptive Statistics** დილაგზე.
ეპრანზე გამოდის შედეგების ცხრილი

| | Regression (6-10) (OIL) | | | | |
|-------------|--------------------------|----------|----------|----------|----------|
| | OIL.6 | OIL.7 | OIL.8 | OIL.9 | OIL.10 |
| Data Mean | 17,27094 | 17,27094 | 17,27094 | 17,27094 | 17,27094 |
| Data S.D. | 4,06047 | 4,06047 | 4,06047 | 4,06047 | 4,06047 |
| Error Mean | -0,04965 | -0,02728 | -0,01291 | -0,01033 | -0,02783 |
| Error S.D. | 4,00649 | 0,47723 | 0,38842 | 0,38443 | 0,38438 |
| Abs E. Mean | 3,35501 | 0,37364 | 0,29300 | 0,28813 | 0,28824 |
| S.D. Ratio | 0,98670 | 0,11753 | 0,09566 | 0,09468 | 0,09466 |
| Correlation | 0,16328 | 0,99307 | 0,99542 | 0,99551 | 0,99551 |

სადაც **SD Ratio** მაჩვენებლით და სწავლების ცდომილებით შევარჩიოთ მე-9
მოდელი

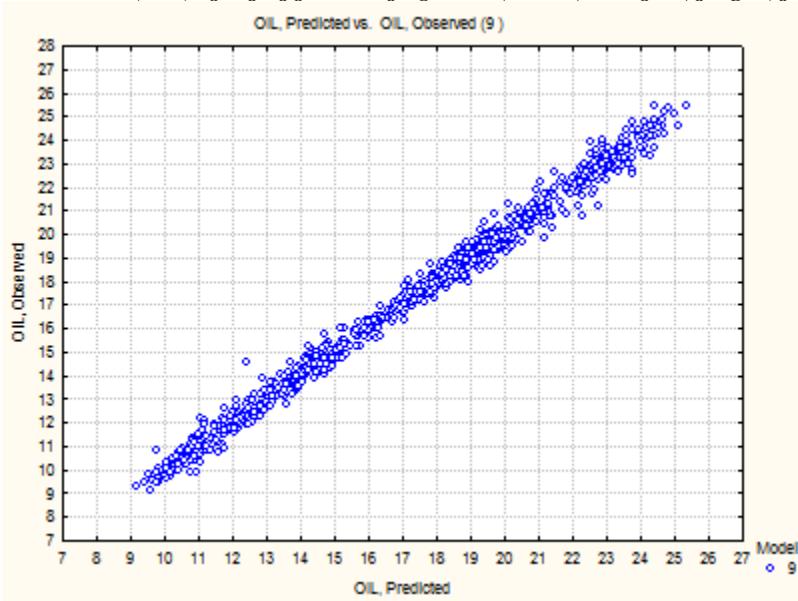


დაკვირვების გრაფიკის ასაგებად ჩავრთოდ ჩანართ **Plots** (გრაფიკი) და **X-axis** (ღერძზე)-ის ველში შევარჩიოთ **Predicted** (პროგნოზება), ხოლო **Y-axis** (ღერძზე) – **Observed** (დაკვირვება).



ავგოთ X და Y ცვლადების დამოკიდებულების გრაფიკი. ამისათვის

Click GraphX versus Y დილაკზე. ეკრანზე გამოდის დამოკიდებულების გრაფიკი.,



საიდანაც ჩანს, რომ გრაფიკი ფაქტიურად იდეალურად დევს სწორ ხაზზე. ამ შედეგის მიღება მოსალოდნელი იყო, რადგან როგორც შედეგების **Results(Run Models)** ფანჯარაში ჩანს მე-9 მოდელის სწავლების ცდომილება შეადგენს მხოლოდ 2,27%, ხოლო ტესტირების ცდომილება – 2,5%.

შედეგების **Results(Run Models)** ფანჯარის **Quick** ჩანართში **Click Descriptive statistics** (აღწერითისტატისტიკა)-ის ლილაკზე ეპრანზე გამოდის რეგრესიის შეცდომების ცხრილი,

| | Regression (9) (OIL) |
|-------------|-----------------------|
| | OIL.9 |
| Data Mean | 17,27094 |
| Data S.D. | 4,06047 |
| Error Mean | -0,01033 |
| Error S.D. | 0,38443 |
| Abs E. Mean | 0,28813 |
| S.D. Ratio | 0,09468 |
| Correlation | 0,99551 |

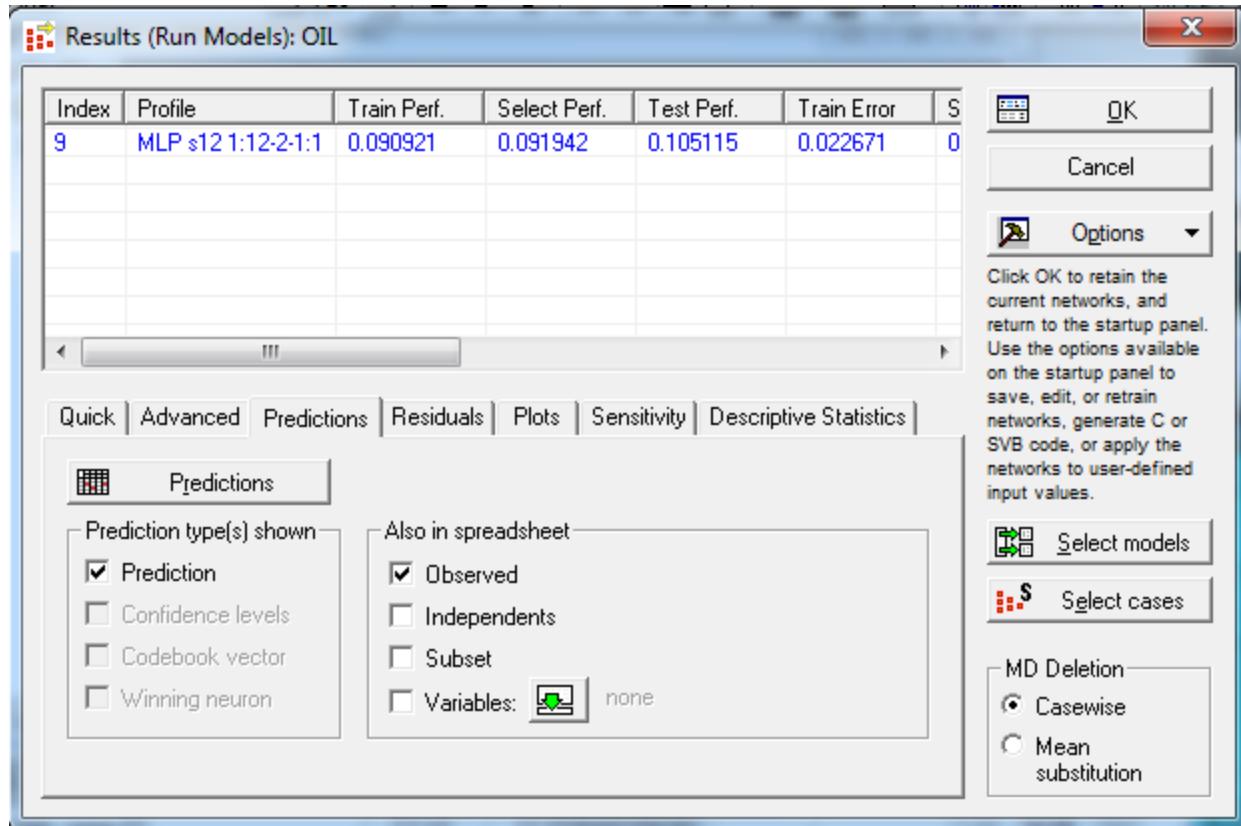
მიღებულ შედეგებიდან ჩანს,რომ მე-9 ქსელის სტანდარტული გადახრების ფარდობის სიდიდე **S.D.Ratio** 0,09 ტოლია, რაც საკმაოდ კარგი მაჩვენებელია.

თუ შედეგების **Results(Run Models)** ფანჯარის **Subsets used to generate results** (შერჩევის შედეგების გამოყვანა)-ის ველში **Overall** (სრული) ოპციის მაგივრად ჩავრთავთ **All (separately)** (ყველა ცალკე) ოპციას, მაშინ ეს მოგვცემს საშულებას მივიღოთ ცხრილი, სადაც შერჩევის შედეგები ყველა ამონარჩევისათვის (სასწავლო, საკონტროლო, ტესტური და იგნორირებული) ცალკე გამოდის.

| | Regression (9) (OIL) | | | |
|-------------|-----------------------|----------|----------|---------|
| | T.OIL.9 | S.OIL.9 | X.OIL.9 | I.OIL.9 |
| Data Mean | 17,23265 | 16,97906 | 17,64076 | 0,00 |
| Data S.D. | 4,02374 | 4,26405 | 3,89514 | 0,00 |
| Error Mean | 0,01482 | -0,03275 | -0,03910 | 0,00 |
| Error S.D. | 0,36584 | 0,39205 | 0,40944 | 0,00 |
| Abs E. Mean | 0,27919 | 0,29031 | 0,30415 | 0,00 |
| S.D. Ratio | 0,09092 | 0,09194 | 0,10511 | 0,00 |
| Correlation | 0,99586 | 0,99578 | 0,99451 | 0,00 |

როგორც ცხრილიდან ჩანს **S.D.Ratio** სიდიდე ყველა ამონარჩევისათვის თითქმის ერთნაირია.

იმისათვის, რომ საბოლაოდ დავრწმუნდეთ ნეიროქსელის შერჩევის სისწორეში **Results(Run Models)** ფანჯარაში ჩავრთოდ **Predictions** ჩანართი



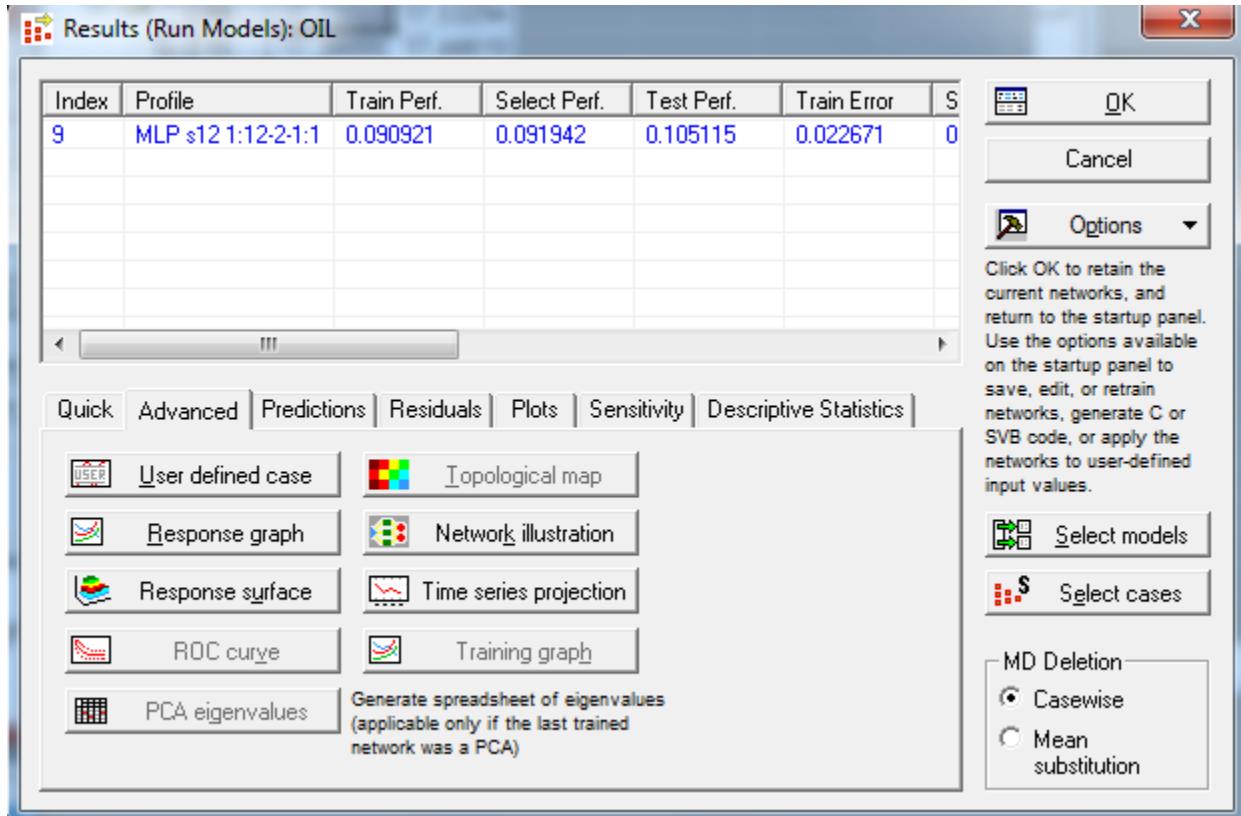
და **Click Predictions** (პროგნოზირება)-ის ღილაპიტე. ეკრანზე გამოდის შედეგების ცხრილი,

| | Prediction (9) (Test) (OIL) | |
|----|------------------------------|----------|
| | OIL | OIL.9 |
| 14 | 17,73000 | 17,53294 |
| 19 | 17,38000 | 17,44610 |
| 25 | 16,63000 | 16,52752 |
| 32 | 17,23000 | 17,01658 |
| 36 | 18,18000 | 18,29873 |
| 41 | 19,28000 | 19,06372 |
| 43 | 18,85000 | 18,96416 |
| 46 | 18,80000 | 18,66067 |
| 50 | 19,18000 | 18,74652 |
| 52 | 18,85000 | 19,08645 |
| 61 | 20,35000 | 20,40001 |
| 64 | 21,68000 | 21,33770 |
| 65 | 21,33000 | 21,66931 |
| 66 | 20,25000 | 21,42842 |
| 68 | 20,80000 | 20,31212 |
| 69 | 21,18000 | 20,78403 |
| 75 | 22,73000 | 23,78474 |

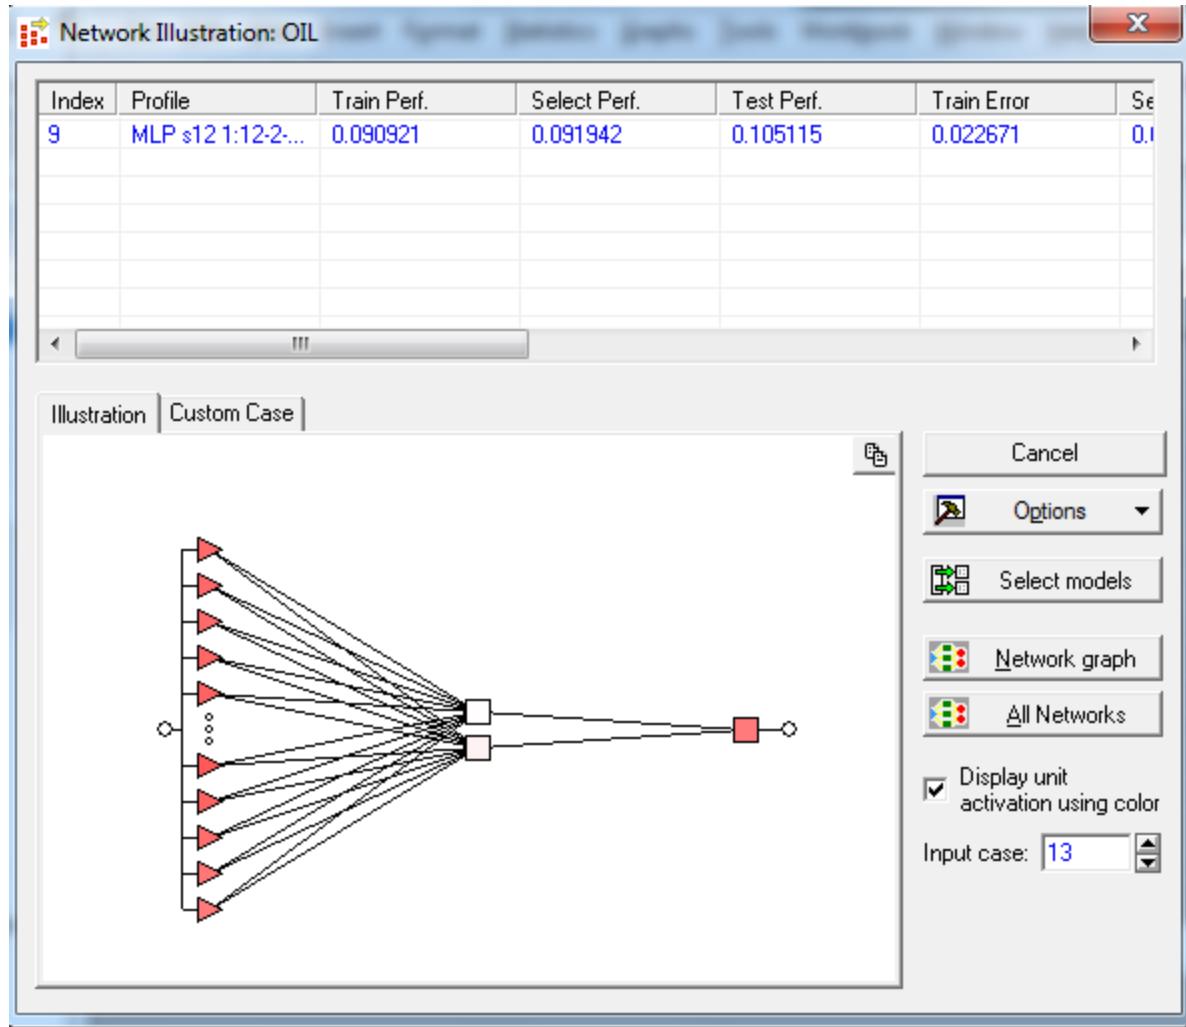
სადაც მარცხენა სვეტში მოცემულია **OIL**-ის ჭეშმარიტი მნიშვნელობები, ხოლო მარჯვენა სვეტში – ნეიროქსელის მიერ ტესტური ამონარჩევით მიღებული

პროგნოზირებული მნიშვნელობები. როგორც ცხრილიდან ჩანს, მიღებული შედეგები დამაკმაყოფილებელია. ნეიროქსელის შერჩევა შესაძლებელია აგრეთვე, კროს-შემოწმების მეთოდით (იხ. პრაქტიკულისამუშაო 1).

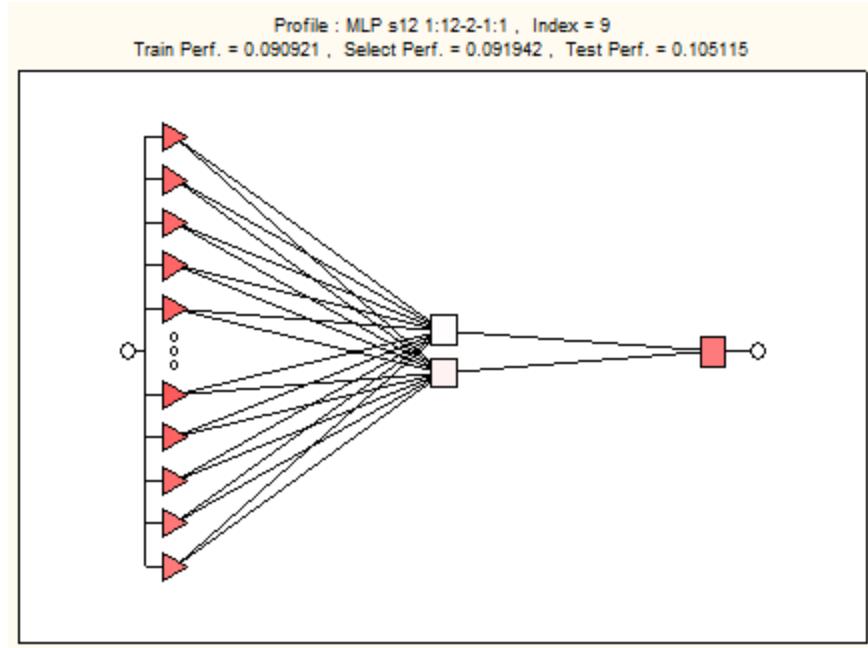
ნეირონული ქსელის არქიტექტურის ასაგებად შედეგების **Results(Run Models)** ფანჯარაში ჩავრთოდ **Advanced** ჩანართი



და **Click Network illustration** (ქსელის სქემა)-ის დილაკზე. ეპრანზე გამოდის ამავე დასახელების ფანჯარა.



თუ გვინდა ნეირონული ქსელის ცალკე გრაფის სახით წარმოდგენა, მაშინ *Click Network graph* ღილაპიჟე



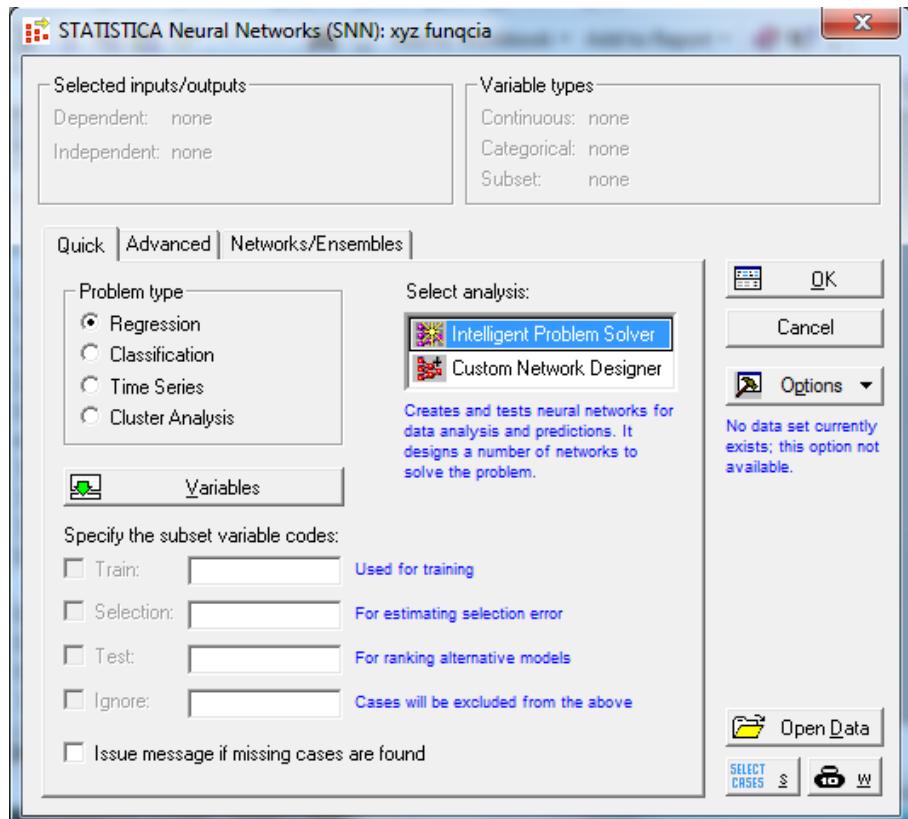
პრაქტიკული სამუშაო 5

ცვლადების შერჩევა და განზომილების შემცირება

პროგრამის მუშაობა განვიხილოთ ***pd 2*** მოდელური ფაილისათვის, რომელსაც გააჩნია დამოკიდებული Y ცვლადი და რამოდენიმე ათეული დამოუკიდებელი ცვლადები (პრედიქტორები). უნდა აღინიშნოს, რომ ფაილი შეიცავს პრედიქტორების დიდ რაოდენობას, კერძოდ 45, ამიტომ მიზანშეწონილია შევარჩიოთ ინფორმატიული ცვლადები და ამით მოვახდინოთ განზომილების შემცირება. საწყისი მონაცემების ფაილის ფრაგმენტი წარმოდგენილია შემდეგ ნახაზზე:

| | Data: pd 2 (46v by 100c) | | | | | | | | | | | | | | |
|----|--------------------------|---------|---------|---------|---------|----------|----------|---------|---------|-----------|-----------|-----------|-----------|-----------|-----------|
| | 1 F1 | 2 F2 | 3 F3 | 4 F4 | 5 F5 | 6 F6 | 7 F7 | 8 F8 | 9 F9 | 10 F10 | 11 F11 | 12 F12 | 13 F13 | 14 F14 | 15 F15 |
| 1 | 1024 | 2435 | 711.5 | 16,055 | 16,94 | 13,23555 | 0,6209 | 98,6549 | 10,2 | 14 | 108,6499 | 85,9 | 78,6 | 8,09 | 6,74 |
| 2 | 1011 | 2459,6 | 774,6 | 8,625 | 8,855 | 12,61 | 1,69576 | 100,394 | 90 | 50 | 111,9129 | 99,3 | 62,5 | 8,34 | 14,14 |
| 3 | 1117 | 2599 | 804,4 | 21,865 | 22,915 | 16,1 | 1,29677 | 98,8863 | 12 | 12,2 | 96,23004 | 119,8 | 58,8 | 4,77 | 36,36 |
| 4 | 945 | 2367 | 533 | 28,05 | 29,93 | 15,15548 | 2,74386 | 99,1474 | 86 | 10,21 | 95,68411 | 115,5 | 36,2 | 4,78 | 33,8 |
| 5 | 959 | 2376 | 350 | 25,34 | 25,785 | 19,65147 | 2,30093 | 102,662 | 11,7 | 94,94796 | 111,5913 | 118,3 | 78,8 | 3,07 | 10,22 |
| 6 | 1008 | 2436 | 855,5 | 10,355 | 10,51 | 18,56315 | 2,07885 | 104,996 | 8 | 98,45073 | 94,20351 | 115,4 | 82,1 | 122 | 15,68 |
| 7 | 1025,2 | 2449 | 550 | 30,21 | 32,375 | 18,02188 | 3,0341 | 97,9636 | 19,8 | 95,60386 | 109,416 | 184,9 | 64,7 | 96 | 170 |
| 8 | 1023 | 2439,6 | 350 | 5,705 | 5,745 | 21,36781 | 3,16542 | 100,687 | 22,94 | 91,62065 | 108,9486 | 161,7 | 73,8 | 1,02 | 4,42 |
| 9 | 1006 | 2424 | 844,4 | 18,15 | 18,455 | 21,69199 | 3,99269 | 99,7761 | 10,3 | 93,51479 | 107,1998 | 127,6 | 51 | 3,24 | 11,4 |
| 10 | 1013,2 | 2427 | 750 | 66,07 | 72,395 | 23,71771 | 3,165 | 97,6319 | 49 | 94,31208 | 113,5048 | 166,8 | 82,2 | 4,76 | 3,7 |
| 11 | 996 | 2396 | 533 | 40,42 | 43,485 | 21,69096 | 13,23555 | 103,168 | 13,2 | 96,86733 | 94,77887 | 158,6 | 49,5 | 540 | 11,98 |
| 12 | 1047 | 2456 | 650,4 | 4,955 | 5,11 | 22,60129 | 12,61308 | 98,0758 | 12,89 | 94,79189 | 100,0957 | 138,6 | 67 | 629 | 31,84 |
| 13 | 1109 | 2528 | 850 | 27,63 | 29,42 | 25,41543 | 16,0987 | 96,3053 | 13,2 | 15,5 | 110,7379 | 88,9 | 859 | 42,8 | 2,66 |
| 14 | 1016 | 2441 | 657 | 30,035 | 33,22 | 26,91658 | 15,15548 | 96,7556 | 12,7 | 93,41488 | 96,55905 | 78,4 | 612 | 76,2 | 6,2 |
| 15 | 1061 | 2495 | 450 | 3,72 | 4,11 | 25,56655 | 19,65147 | 100,778 | 13,9 | 96,22288 | 107,925 | 42 | 451 | 69,5 | 10,7 |
| 16 | 940 | 2364 | 362,3 | 0,895 | 0,92 | 25,00308 | 18,65315 | 56,3381 | 10,9 | 36,3 | 112,379 | 142 | 70,8 | 364 | 118 |
| 17 | 1149 | 2565 | 459,9 | 50,935 | 52,57 | 24,91046 | 18,02188 | 52,2928 | 10,2 | 49,7 | 103,6192 | 94,9 | 53 | 209 | 3,32 |
| 18 | 1026 | 2326 | 450 | 24,16 | 16,47 | 26,47922 | 7,03438 | 51,8912 | 7,7 | 62,5 | 112,7804 | 110,4 | 55,2 | 11,4 | 8,84 |
| 19 | 935 | 2539 | 362,3 | 34,41 | 18,66 | 29,61682 | 9,380429 | 51,3659 | 15,4 | 6,7 | 90,07166 | 92,8 | 54,9 | 378 | 2,92 |
| 20 | 1062,8 | 2426 | 459,9 | 26,82 | 14,09 | 29,9272 | 10,48961 | 65 | 16,9 | 7,1 | 93,00613 | 167,2 | 698 | 61,1 | 6,34 |
| 21 | 947 | 2356 | 606 | 26,42 | 12,27 | 28,60062 | 4,1136 | 23,2 | 96 | 4,78 | 112,3285 | 153,9 | 1061 | 56,3 | 77,1407 |
| 22 | 1682 | 2594 | 675 | 29,29 | 15,55 | 28,43999 | 10,46996 | 45,3 | 70 | 2,75 | 98,08788 | 184,3 | 1008 | 96,7 | 78,18 |
| 23 | 903 | 2412 | 811,5 | 11,255 | 13 | 28,99903 | 3,04167 | 63 | 16,3 | 85 | 107,4324 | 114,3 | 816 | 68 | 8,4186 |

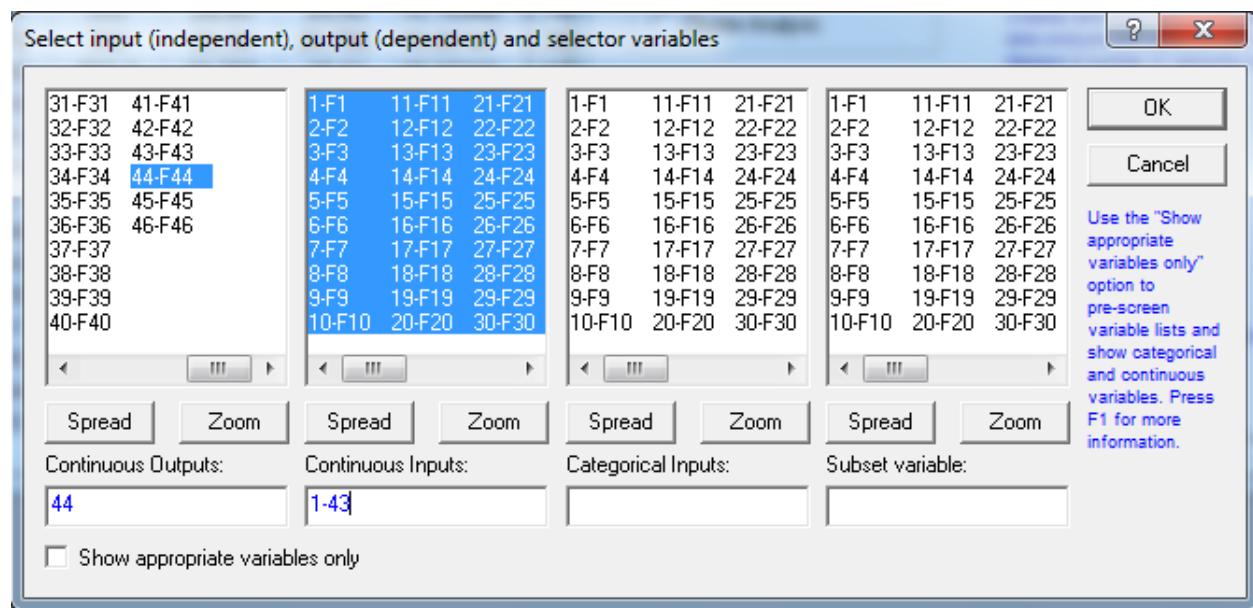
სასტატისტიკო პარსელის **STATISTICA Neural Networks** გამოსაძახებლად, მენიუდან **Statistics** შევარჩიოთ ბრძანება **Neural Networks**. ეკრანზე გამოდის **STATISTICA Neural Networks(SNN)** ფანჯარა,



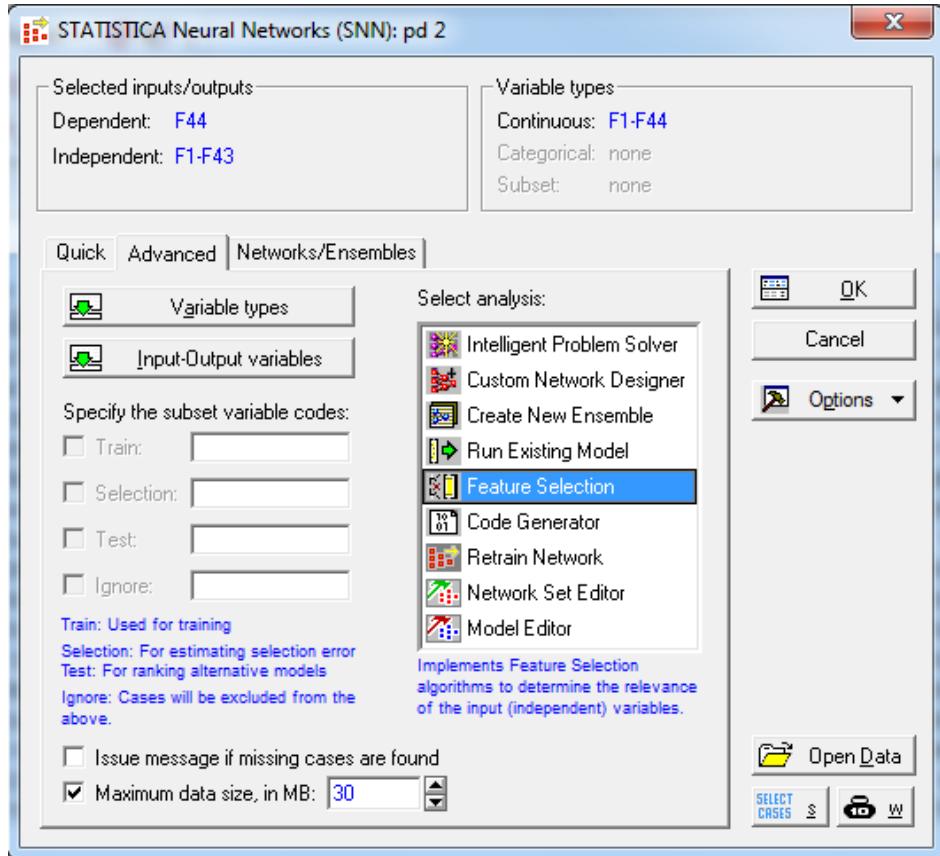
სადაც ჩავრთოდ **Quick** ჩანართი და **Problem type** ველში ჟევარჩიოთ ამოცანის ტიპი **Regression**, ხოლო **Select analysis** ველში ამოხსნის მეთოდი – **Intelligent Problem Solver** (გადაწყვეტის ოსტატი).

ცვლადების მოსანიშნად **Click Variables** ღილაკზე და გურანზე გამოსულ ფანჯარაში ავირჩიოთ ცვლადები. მოცემულ მაგალითში არის გამომავალი (დამოკიდებული) ცვლადი და 46 შემავალი ცვლადი.

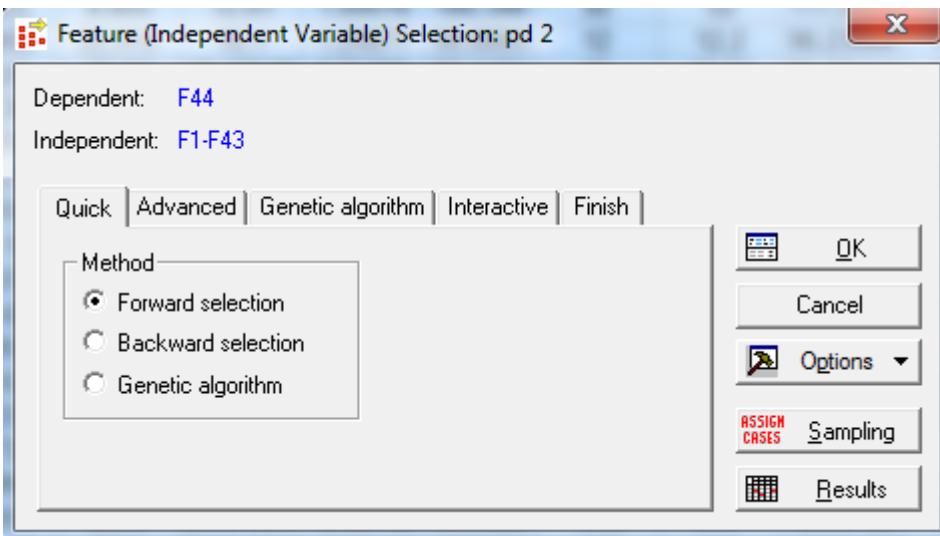
მოგნიშნოთ **Continuous Outputs** (უწყვეტი გამომავალი) ველში - უ ცვლადი, რომლის ნომერია 44, ხოლო **Continuous Inputs** (უწყვეტი შემავალი) ველში – დამოუკიდებელი ცვლადები 1-43. რადგან არ გაგვაჩნია კატეგორიული ცვლადი, ამიტომ (**Categorical Inputs**) ველში ცვლადი არ მოინიშნება. შემდეგ **OK**.



STATISTICA Neural Networks(SNN) ფანჯარაში ჩავრთოდ **Advance** (დამატებითი) ჩანართიდა ამოვირჩიოთ ინსტრუმენტი **Feature Selection** (განზომილების შემცირება).



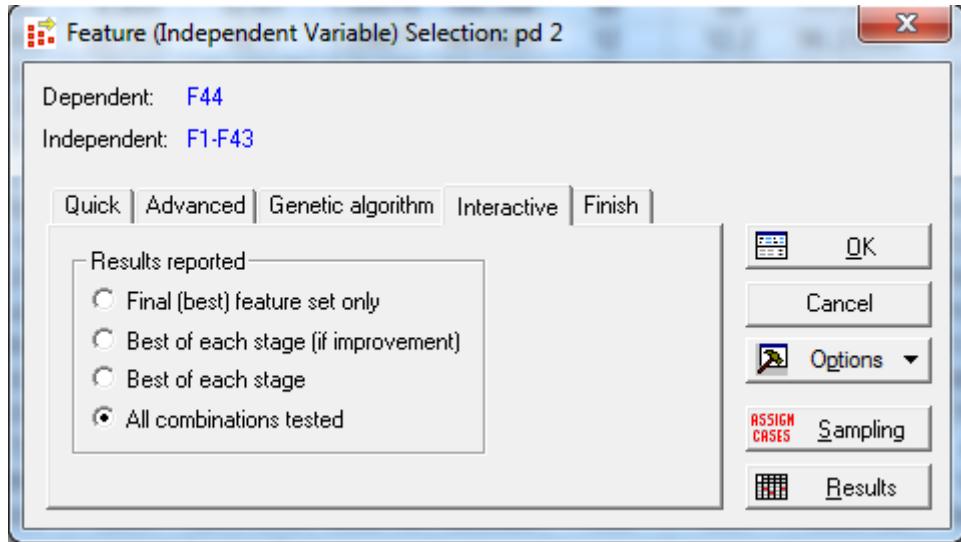
შემდეგ *Click OK* დილაპზე. ეპრანზე გამოჩნდება განზომილების შემცირების დიალოგის ფანჯარა **Feature (Independent Variable) Selection**,



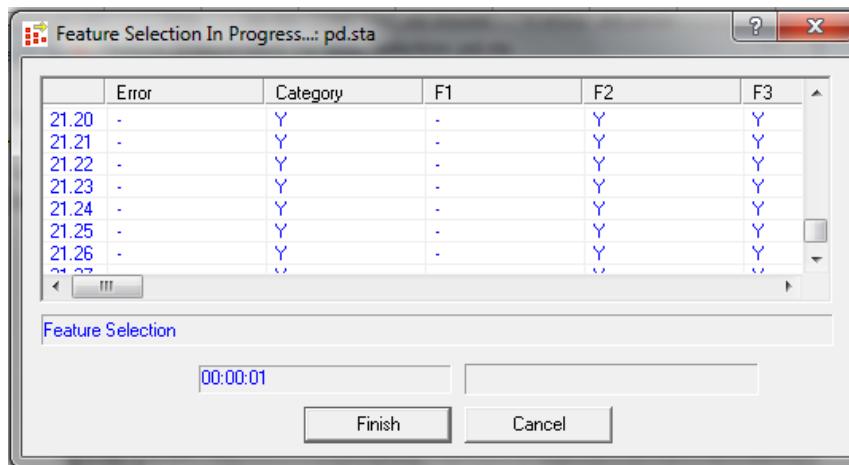
სადაც **Quick** ჩანართში ხელმისაწვდომია შემდეგი მეთოდები: **Forward selection** (თანმიმდევრული ჩართვით). **Backward selection** (თანმიმდევრული გამორიცხვით). **Genetic algorithm** (გენეტიკური ალგორითმი).

1. თანმიმდებრული ჩართვის მეთოდი.

Feature (Independent Variable) Selection ფანჯარაში ჩავრთოდ **Forward selection** (თანმიმდევრული ჩართვით) ოპცია. გავხსნათ **Interactive** (ინტერაქტიური) ჩანართი და ამოვირჩიოთ **All combinations tested** (ტესტირების ყველა კომბინაცია).



შემდეგ *Click OK* დილაპზე. ეპრანზე გამოჩნდება ნეიროქსელის სწავლების დიალოგიური **Feature Selection In Progress** (მიმდინარეობს შესწავლა) ფანჯარა.



ალგორითმის მუშაობის შედეგი წარმოდგენილია **Forwards Selection** ცხრილში.

| | Forwards Selection (pd 2) | | | | | | | | | | | | | | | | | | | | | |
|------|---------------------------|----|----|----|----|----|----|----|----|----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|
| | Error | F1 | F2 | F3 | F4 | F5 | F6 | F7 | F8 | F9 | F10 | F11 | F12 | F13 | F14 | F15 | F16 | F17 | F18 | F19 | F20 | F21 |
| 1.1 | 0,041686 | Y | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - |
| 1.2 | 0,041665 | - | Y | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - |
| 1.3 | 0,041718 | - | - | Y | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - |
| 1.4 | 0,042087 | - | - | - | Y | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - |
| 1.5 | 0,041817 | - | - | - | - | Y | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - |
| 1.6 | 0,041690 | - | - | - | - | - | Y | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - |
| 1.7 | 0,041736 | - | - | - | - | - | - | Y | - | - | - | - | - | - | - | - | - | - | - | - | - | - |
| 1.8 | 0,041597 | - | - | - | - | - | - | - | Y | - | - | - | - | - | - | - | - | - | - | - | - | - |
| 1.9 | 0,041953 | - | - | - | - | - | - | - | - | Y | - | - | - | - | - | - | - | - | - | - | - | - |
| 1.10 | 0,041654 | - | - | - | - | - | - | - | - | - | Y | - | - | - | - | - | - | - | - | - | - | - |
| 1.11 | 0,041683 | - | - | - | - | - | - | - | - | - | - | Y | - | - | - | - | - | - | - | - | - | - |
| 1.12 | 0,041624 | - | - | - | - | - | - | - | - | - | - | - | Y | - | - | - | - | - | - | - | - | - |
| 1.13 | 0,041662 | - | - | - | - | - | - | - | - | - | - | - | - | Y | - | - | - | - | - | - | - | - |
| 1.14 | 0,041662 | - | - | - | - | - | - | - | - | - | - | - | - | - | Y | - | - | - | - | - | - | - |
| 1.15 | 0,041686 | - | - | - | - | - | - | - | - | - | - | - | - | - | - | Y | - | - | - | - | - | - |
| 1.16 | 0,041667 | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | Y | - | - | - | - | - |
| 1.17 | 0,041589 | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | Y | - | - | - | - |
| 1.18 | 0,041599 | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | Y | - | - | - |
| 1.19 | 0,041666 | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | Y | - | - |
| 1.20 | 0,041673 | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | Y | - |
| 1.21 | 0,041673 | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | Y |

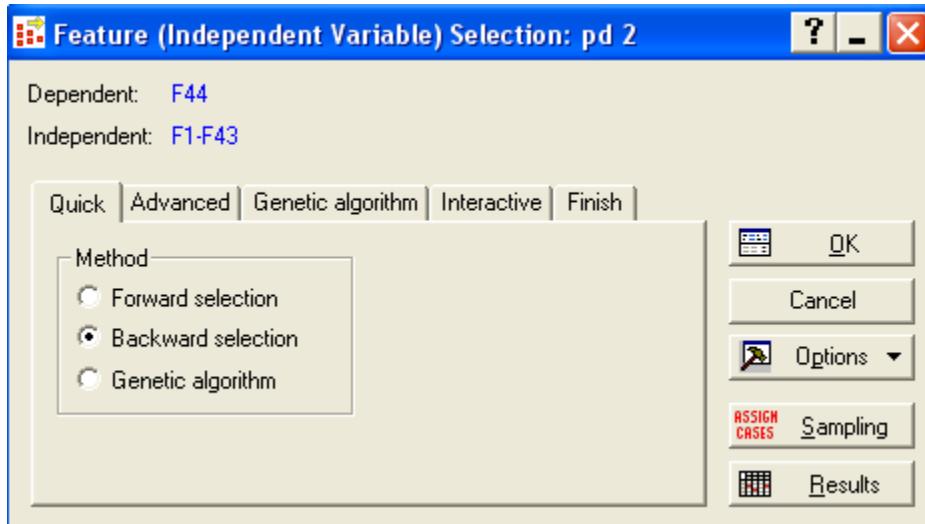
თავდაპირველად ცვლადები ცალ-ცალკე ირთვებიან მოდელში. იძებნება ის პირველი ცვლადი, რომელიც იძლევა ყველაზე მცირე შეცდომას. შემდეგ მოდელი იწყებს მეორე ცვლადის ქვენის პროცედურას, რომელიც ამცირებს შეცდომის მნიშვნელობას და ა.შ. მანამდე სანამ ახალი ცვლადების მოდელში ჩართვა იწვევს ცდომილების შემცირებას. საბოლოო შედეგი ჩაწერილია ცხრილის ბოლო სტრიქონში (*Final*).

| Forwards Selection (pd 2) | | | | | | | | | | | | | | | | | | | | | | | |
|---------------------------|----------|----|----|----|----|----|----|----|----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|
| Error | F1 | F2 | F3 | F4 | F5 | F6 | F7 | F8 | F9 | F10 | F11 | F12 | F13 | F14 | F15 | F16 | F17 | F18 | F19 | F20 | F21 | F22 | F23 |
| 8.38 | 0,041009 | - | - | - | - | - | - | Y | - | - | - | - | - | - | - | - | Y | Y | - | - | - | Y | Y |
| 8.40 | 0,041010 | - | - | - | - | - | - | - | Y | - | - | - | - | - | - | - | Y | Y | - | - | - | Y | Y |
| 8.41 | 0,041005 | - | - | - | - | - | - | - | Y | - | - | - | - | - | - | - | Y | Y | - | - | - | Y | Y |
| 8.42 | 0,041000 | - | - | - | - | - | - | - | Y | - | - | - | - | - | - | - | Y | Y | - | - | - | Y | Y |
| 8.43 | 0,041011 | - | - | - | - | - | - | - | Y | - | - | - | - | - | - | - | Y | Y | - | - | - | Y | Y |
| Final | 0,040919 | - | - | - | - | - | - | - | Y | - | - | - | - | - | - | - | Y | Y | - | - | - | Y | Y |

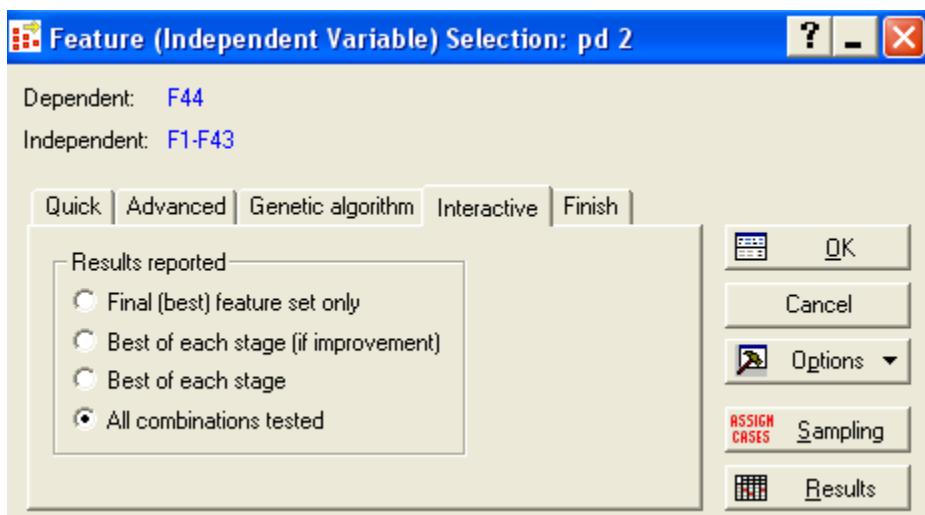
როგორც მიღებული შედეგიდან ჩანს მოდელის მიერ შერჩეული მნიშვნელოვანი ცვლადები შემდეგია: F8, F17, F18, F27, F31, F36 და F39. ამრიგად, 45 პრედიქტორისაგან შეირჩა მხოლოდ 7.

2. თანმიმდევრული გამორიცხვის მეთოდი.

Feature (Independent Variable) Selection ფანჯარაში ჩავრთოდ და **Backward selection** (თანმიმდევრული გამორიცხვით) ოპცია.



გავხსნათ **Interactive** (ინტერაქტიური) ჩანართი და ამოვირჩიოთ **All combinations tested** (ტესტირების ყველა კომბინაცია).



შემდეგ *Click OK* დილაპტე.

დასაწყისში მოდელში ჩართულია ყველა პრედიქტორი და შემდეგ ყოველ ბიჯზე ხდება უმნიშვნელო პრედიქტორის გამორიცხვა. შედეგები წარმოდგენილია შემდეგ ცხრილში.

| | Backwards Selection (pd 2) | | | | | | | | | | | | | | | | | | | | | | |
|-------|----------------------------|----|----|----|----|----|----|----|----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|
| Error | F1 | F2 | F3 | F4 | F5 | F6 | F7 | F8 | F9 | F10 | F11 | F12 | F13 | F14 | F15 | F16 | F17 | F18 | F19 | F20 | F21 | F22 | F23 |
| 3.2 | 0,066359 | Y | - | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y |
| 3.3 | 0,066341 | Y | Y | - | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y |
| 3.4 | 0,066199 | Y | Y | Y | - | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y |
| 3.5 | 0,066549 | Y | Y | Y | Y | - | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y |
| 3.6 | 0,065542 | Y | Y | Y | Y | Y | - | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y |
| 3.7 | 0,066279 | Y | Y | Y | Y | Y | Y | - | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y |
| 3.8 | 0,066369 | Y | Y | Y | Y | Y | Y | Y | - | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y |
| 3.9 | 0,066349 | Y | Y | Y | Y | Y | Y | Y | Y | - | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y |
| 3.10 | 0,066124 | Y | Y | Y | Y | Y | Y | Y | Y | Y | - | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y |
| 3.11 | 0,066342 | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | - | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y |
| 3.12 | 0,066373 | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | - | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y |
| 3.13 | 0,066374 | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | - | Y | Y | Y | Y | Y | Y | Y | Y | Y |
| 3.14 | 0,066359 | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | - | Y | Y | Y | Y | Y | Y | Y | Y |
| 3.15 | 0,066331 | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | - | Y | Y | Y | Y | Y | Y | Y |
| 3.16 | 0,066320 | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | - | Y | Y | Y | Y | Y | Y |
| 3.17 | 0,066366 | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | - | Y | Y | Y | Y | Y |
| 3.18 | 0,066346 | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | Y | - | Y | Y | Y | Y |

საბოლაო შედეგი ჩაწერილია ცხრილის ბოლო სტრიქონში (*Final*).

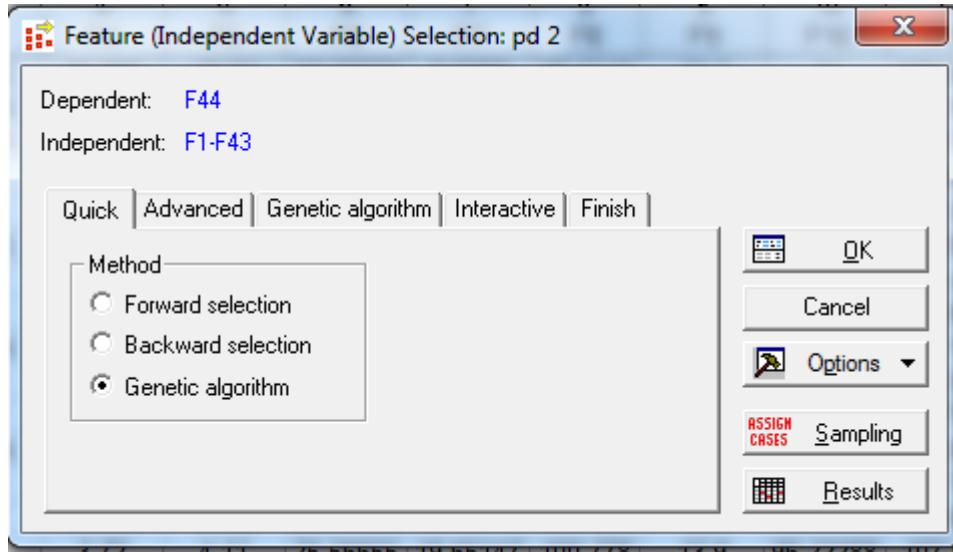
| | Backwards Selection (pd 2) | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |
|-------|----------------------------|----|----|----|----|----|----|----|----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|
| Error | F1 | F2 | F3 | F4 | F5 | F6 | F7 | F8 | F9 | F10 | F11 | F12 | F13 | F14 | F15 | F16 | F17 | F18 | F19 | F20 | F21 | F22 | F23 | F24 | F25 | F26 | F27 | F28 | F29 | F30 | F31 | F32 | F33 | F34 | F35 | F36 | F37 | F38 | F39 | F40 |
| 38.33 | 0,062341 | - | - | - | Y | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | Y | - | - | Y | Y | - | - | - | Y | - | | | | |
| 38.34 | 0,062403 | - | - | - | Y | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | Y | - | - | Y | Y | - | - | Y | - | | | | | |
| 38.35 | 0,062518 | - | - | - | Y | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | Y | - | - | Y | Y | - | - | - | Y | - | | | | |
| 38.39 | 0,062540 | - | - | - | Y | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | Y | - | - | Y | Y | Y | - | - | - | - | | | | |
| Final | 0,062324 | - | - | - | Y | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | - | Y | - | - | Y | Y | Y | - | - | - | Y | - | | | |

როგორც მიღებული შედეგიდან ჩანს მოდელის მიერ შერჩეული მნიშვნელოვანი ცვლადები შემდეგია: F5, F27, F31- F35 და F39.

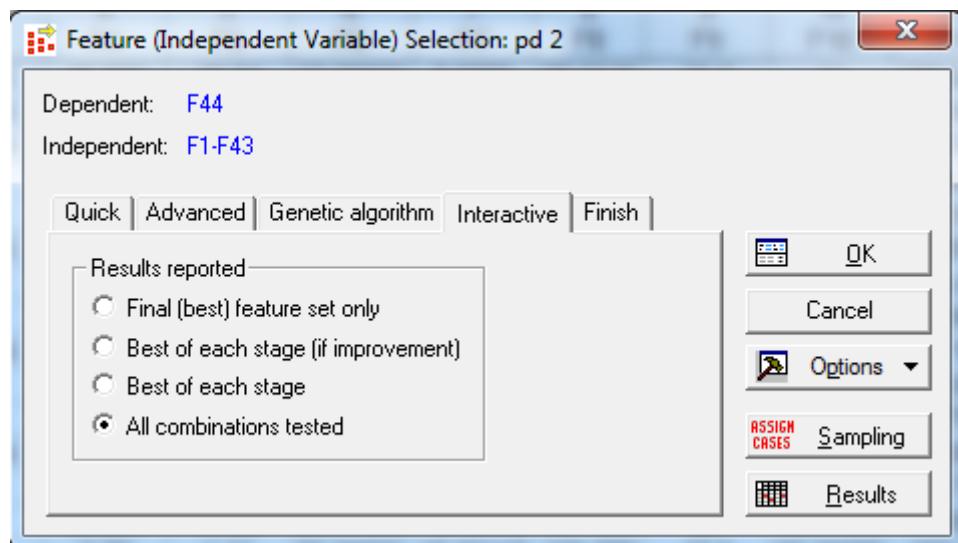
3. გენეტიკური ალგორითმი.

გენეტიკური ალგორითმი წარმოადგენს პარამეტრების შერჩევის მეტად ეფექტურ ინსტრუმენტს. მართალია ეს ალგორითმი მოითხოვს გამოთვლების დიდ დროს, მაგრამ **STATISTICA Neural Networks** პაკეტში რეალიზირებული **PNN/GRNN** ტიპის ნეიროქსელები საშუალებას იძლევიან გენეტიკური ალგორითმის მუშაობის სისტრატეგის გაზრდას.

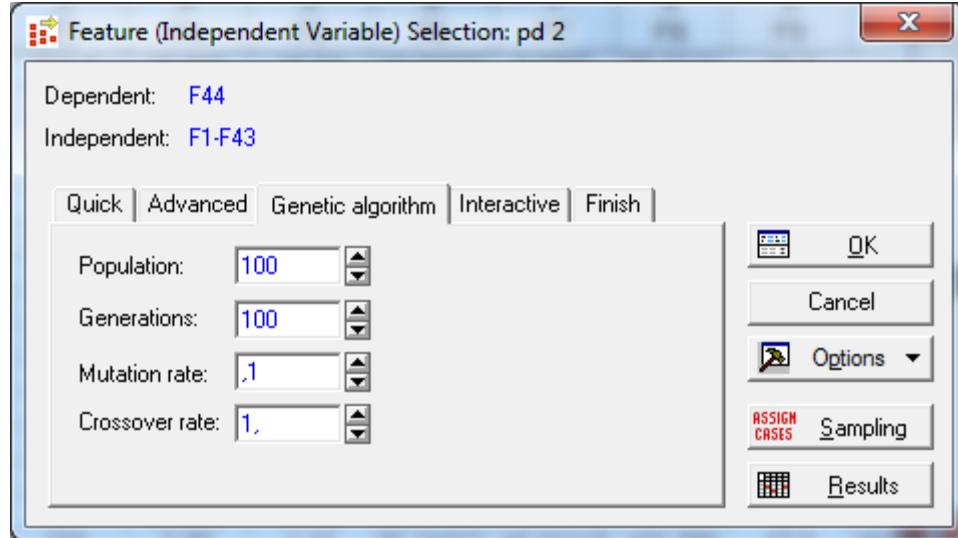
Feature (Independent Variable) Selection ფანჯარაში ჩავრთოდ გენეტიკური (გენეტიკური ალგორითმი)-ის ოპცია.



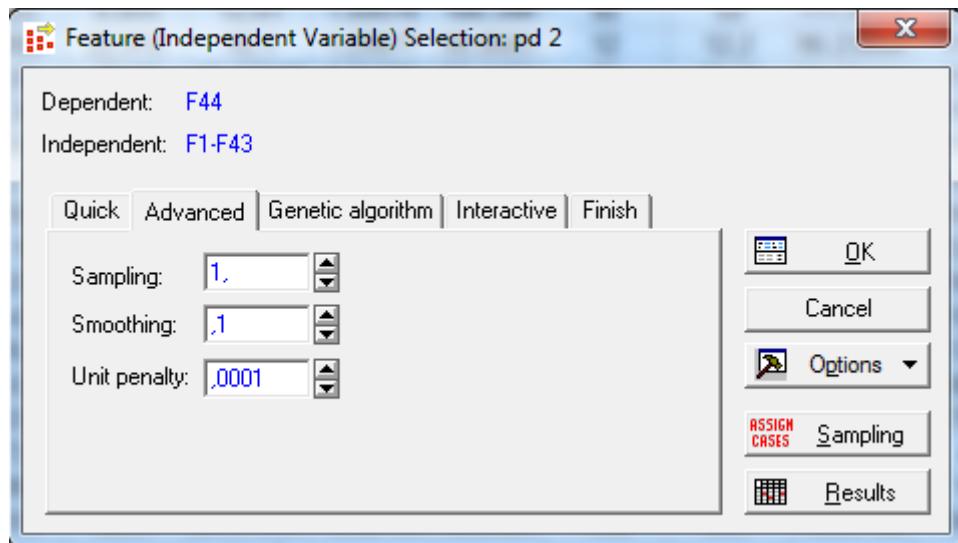
გავხსნათ **Interactive** (ინტერაქტიური) ჩანართი და ამოვირჩიოთ **All combinations tested** (ტესტირების ყველა კომბინაცია).



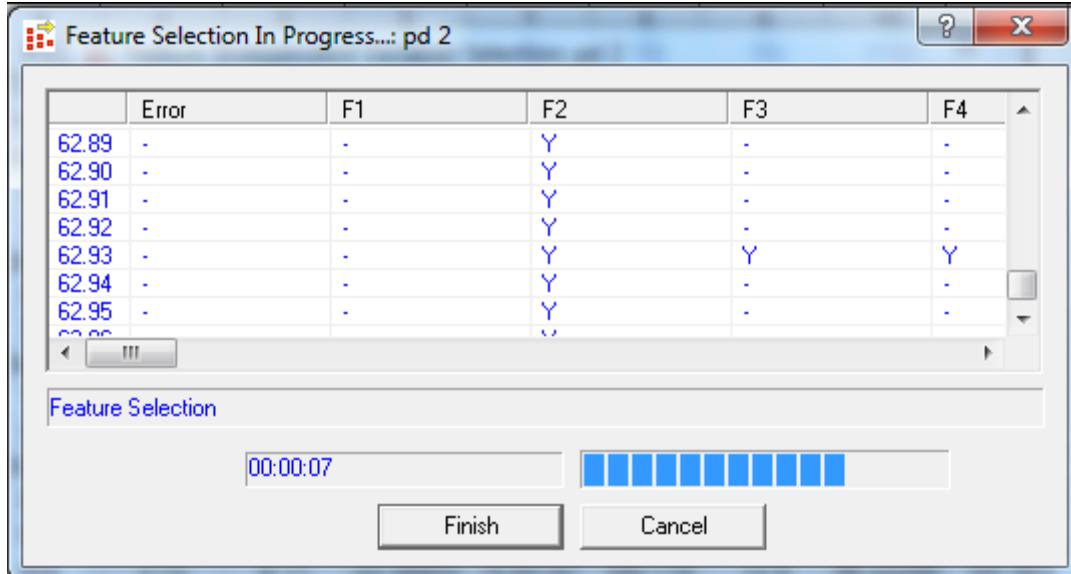
Genetic algorithm ჩანართში გაჩუმების პრინციპით წარმოდგენილია **Population** (პოპულაცია), **Generations** (მემკვიდრეობა), **Mutation rate** (მუტაციის სისწრაფე), **Crossover rate** (შეჯვარების სისწრაფე) მაჩვენებლები. დაგტოვოთ ეს მაჩვენებლები.



თუ გავხსნით **Advanced** ჩანართს ვნახავთ, რომ **Unit penalty** (ჯარიმების ბლოკი)-ის ველში გაჩუმების პრინციპით ჩაწერილია 0,0001 სიდიდე. ზოგადად, რეკომენდირებულია ჯარიმის სიდიდე შევარჩიოთ 0,0001 – 0,0005 დიაპაზონში.



დავტოვოთ ეს მაჩვენებლები და შემგეგ Click OK დილაპზე. ეკრანზე გამოჩნდება ნეიროქსელის სწავლების დიალოგიური **Feature Selection In Progress** (მიმდინარეობს შესწავლა) ფანჯარა.



სწავლების დასრულების შემდეგ ეკრანზე გამოდის შედეგების ცხრილი

| | Genetic Algorithm Selection (pd 2) | | | | | | | | | | | | | | | | | | | | | | |
|------|------------------------------------|----|----|----|----|----|----|----|----|----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|
| | Error | F1 | F2 | F3 | F4 | F5 | F6 | F7 | F8 | F9 | F10 | F11 | F12 | F13 | F14 | F15 | F16 | F17 | F18 | F19 | F20 | F21 | F22 |
| 1.1 | 0.038219 | Y | Y | - | - | - | Y | - | - | Y | - | - | - | Y | Y | Y | Y | - | - | - | Y | Y | Y |
| 1.2 | 0.038122 | - | - | Y | Y | - | Y | Y | Y | Y | - | - | - | Y | Y | - | - | Y | - | Y | Y | - | Y |
| 1.3 | 0.038173 | Y | Y | Y | Y | Y | - | Y | Y | - | Y | - | Y | Y | Y | - | Y | - | Y | Y | Y | Y | - |
| 1.4 | 0.038055 | - | - | Y | Y | Y | - | - | Y | Y | - | Y | - | - | - | Y | - | Y | Y | - | - | Y | - |
| 1.5 | 0.038023 | - | - | Y | - | - | Y | Y | Y | Y | - | - | - | Y | Y | - | - | Y | - | Y | Y | Y | - |
| 1.6 | 0.038713 | Y | Y | Y | Y | Y | - | Y | Y | Y | - | - | Y | Y | Y | - | Y | Y | Y | Y | Y | Y | Y |
| 1.7 | 0.038036 | Y | Y | - | Y | - | - | - | - | Y | Y | Y | Y | Y | - | Y | Y | Y | Y | Y | - | - | - |
| 1.8 | 0.037668 | Y | Y | - | Y | - | - | Y | - | - | Y | - | - | - | Y | - | - | Y | - | Y | Y | Y | - |
| 1.9 | 0.038326 | - | - | Y | Y | - | Y | Y | Y | Y | - | - | - | Y | Y | Y | - | Y | Y | - | - | Y | Y |
| 1.10 | 0.038472 | - | - | Y | Y | - | Y | Y | Y | Y | - | - | - | Y | Y | - | - | Y | - | Y | - | - | - |
| 1.11 | 0.037502 | - | Y | - | - | - | - | - | Y | - | - | Y | - | - | Y | - | Y | Y | - | - | Y | Y | - |
| 1.12 | 0.037960 | - | - | - | Y | - | - | - | - | - | - | Y | - | Y | - | Y | - | - | Y | - | Y | - | - |
| 1.13 | 0.037326 | Y | - | - | - | - | - | Y | - | - | - | Y | - | - | Y | - | - | - | - | Y | Y | - | - |
| 1.14 | 0.038099 | - | - | Y | Y | Y | Y | Y | Y | - | - | - | Y | - | Y | - | - | - | Y | - | Y | - | - |
| 1.15 | 0.037596 | Y | - | Y | - | Y | Y | Y | - | Y | Y | - | - | Y | Y | - | - | - | Y | - | - | - | - |
| 1.16 | 0.038646 | - | Y | Y | Y | Y | Y | Y | - | Y | - | Y | Y | Y | - | - | Y | - | - | Y | - | Y | - |

საბოლოო შედეგი ჩაწერილია ცხრილის ბოლო სტრიქონში (*Final*).

როგორც მიღებული შედეგიდან ჩანს მოდელის მიერ შერჩეული მნიშვნელოვანი ცვლადები შემდეგია: F3, F6, F10, F26, F27, F31, F35 და F39.

ლიტერატურა

1. Нейронные сети. *STATISTICA Neural Networks.* Методология и технология современного анализа данных. Под редакцией В.П.Боровикова. М.,Горячая линия – Телеком, 2008.
2. Жильцов В.В.б Чувикова В.В. Практикум по нейросетевым технологиям. Учебно – методическое пособие. Омск, СибАДИ, 2010.
3. Ясницкий Л.Н. Введение в искусственный интеллект: учебное пособие для студ. высш. учеб. заведений. – М.: Издательский центр «Академия», 2005
4. Баимаков А.И., Баимаков И.А. Интеллектуальные информационные технологии: учебное пособие.– М.: Изд-во МГТУ им.Баумана, 2005.
5. ე. უცბანეიშვილი ხელოვნური ნეირონული ქსელები მედიცინაში. ლექციების კურსი. სტუ, 2013, http://gtu.ge/books/ms/xel_medicina.pdf.