

ივანე ჯავახიშვილის სახელობის თბილისის
სახელმწიფო უნივერსიტეტი

ნინო დურდიაძე



ხელოვნური ნეირონული ქსელების მოდელირება ინსულტის
დიაგნოსტიკისთვის უკუგანვრცობადი ალგორითმის
გამოყენებით

ინფორმაციული ტექნოლოგიები

ნაშრომი შესრულებულია ინფორმაციული ტექნოლოგიების მაგისტრის
აკადემიური ხარისხის მოსაპოვებლად

ხელმძღვანელი: ასოცირებული პროფესორი ლელა მირცხულავა

დოქტორი ჯილიან პირსი

თბილისი

2015

ანოტაცია

ამ ნამუშევრის მიზანია ხელოვნური ნეირონული ქსელის წარმოდგენა და მისი გამოყენება ინსულტის დიაგნოსტიკური მიდგომებისათვის მონაცემების საშუალებით, რომელიც შეიძლება წარმოდგენილი იქნას ხელოვნურ ნეირონულ ქსელში შემავლების სახით. ჩვენს მოდელში ვიყენებთ კლინიკურ სიმპტომებს, სხვადასხვა სახის ბიოქიმიურ მონაცემებს. თითოეული ტიპის მონაცემი შეიცავს ინფორმაციას, რომელიც უნდა შეფასდეს და იქნეს გამოყენებული ინსულტის დიაგნოსტიკის დროს. დიაგნოსტიკური პროცესის გასამარტივებლად და იმისათვის, რომ შემცირდეს შეცდომები შეგვიძლია გამოვიყენოთ ხელოვნური ინტელექტის მეთოდები. ადაპტური სწავლების ალგორითმი შეიძლება გამოვიყენოთ სხვადასხვა ტიპის სამედიცინო მონაცემებთან.

ტექნოლოგიურმა და კომპიუტერულმა ევოლუციამ ხელი შეუწყო ახალ შესაძლებლობებს ცხოვრების ხარისხის გასაუმჯობესებლად, კერძოდ მწვავე დაავადებების ადრეულ გამოვლენას. ბევრი ტექნოლოგიური სისტემა შეიქმნა ჯანდაცვის გაუმჯობესების მიზნით. ხელოვნური ინტელექტუალური სისტემა მართლაც ღირს შესასწავლად და ინტეგრირება სამედიცინო სისტემაში დიაგნოზის მისაღებად და რეცეპტის მისაღებად.

ნეირონული ქსელები სამადიცილო საკითხებში მრავალი კუთხით გამოიყენება.

ნეირონული ქსელები ძალიან სასარგებლოა სამედიცინო დიაგნოსტიკისა, დაავადებათა დადგენისა და დახმარების აღმოჩენისათვის.

სამედიცინო მეცნიერებათა მთავარი ამოცანაა დაავადებათა თავიდან აცილება და მათი დიაგნოსტიკა. ჩვენ ფოკუსირებას მოვახდენთ მეორე საკითხზე. 2001 წელს ბრაუზმა აღნიშნა რომ თითქმის ყველა ფიზიკოს მედიკოსი დაპირისპირებაში არიან დიაგნოსტიკის შესწავლის საკითხზე.

მათ პრობლემის გადაწყვეტის ერთერთ გზად აირჩიეს არსებულ დასკვნებზე დაყრდნობით და გარკვეულ დაავადების მკურნალობა მეტნაკლებად განსაზღვრული ცოდნითა და გამოკვლევებით.

ქვემოთ მოყვანილია დიაგნოსტიკის რამდენიმე სირთულე რომელიც უნდა იქნას გათვალისწინებული, დადასტურებული დიაგნოზის საფუძვლები, საკმარისი კარგი გამოცდილების მქონე შემთხვევები, და ექიმის ასაკი, შუა ხნის ასაკი რათა მისი გამოცდილება შეესაბამებოდეს აკადემიურ ჩამოყალიბებასა.

1) ზემოთ ჩამოთვლილები განსაკუთრებით გამართლებულია იშვიათი და ახალი დაავადებების დროს, რომელის შესახებაც გამოცდილების მხრივ ერთ დონეზე არიან გამოცდილი და დამწყები მედიკოსები.

2) რეალურად ადამიანი არ გავს კომპიუტერს, მათ შეუძლიათ ობიექტებზე და კვირვება და ამოცნობა, მაგრამ როდესაც არსებობს შეცდომის ალბათობა უნდა ჩატარდეს დამატებითი გამოვლევა

3) დიაგნოზის სიზუსტე და ხარისხი მთლიანადაა დამოკიდებული ექიმის ტალანტსა და მის გამოცდილებაზე

4) ემოციური პრობლემები და დაღლილობა აუარესებს ექიმის შესაძლებლობებს

5) ექიმთა გადამზადება და სწავლება ხანგრძლივი დაძვირადღირებული პროცესია, განვითარებულ ქვეყნებშიც კი ხშირად იგრძნობა კვალიფიციური ექიმების ნაკლებობა

6) სამედიცინო მცნერება არის ერთერთი ყველაზე სწრაფად მზარდი და ცვალებადი მეცნიერება, ახალი მიღწევები ხშირად უგულველყოფენ ძველს, ახალი დაავადებები და წამლები ყოველდღე მიიღება, ექიმი კი უნდა ეცადოს რომ მივეს ამ განვითარებას მუდმივად.

ისმის კითხვა როგორ უნდა დაეხმაროს კომპიუტერული ტექნოლოგიები სამედიცინო დიაგნოსტიკას, ათწლეულების წინად დაინერგა კომპიუტერთა გამოყენება სამედიცინო სექტორში. და დაიწყო ლოკალური და ასევე გლობალურ ქსელში ციფრული არქივებისა და სტატისტიკების შენახვა, მაგრამ ჯერჯერობით არ ითვლებოდა რეალურად სრულად ავტომატიზებულ კომპიუტერულ დიაგნოსტიკაზე გადასვლა.

თუმცა, ბოლოდროინდელი ტექნოლოგიური მიღწევების შედეგად ჩანს რომ ფართოდ ხდება შესაძლებელი კომპიუტერთა გამოყენება სამედიცინო სფეროში, რომლებიც იქნებიან აღჭურვილნი გარკვეული დონის ხელოვნური ინტელექტით, რომელთა განახლება და განვითარება დროში სწრაფი და იაფი იქნება.

ხელოვნური ნეირონული ქსელი გვევლინება ძლიერ და კარგ ინსტრუმენტად ექიმთა დასახმარებლად, ანალიზისა მოდელირების და კომპლექსური კლინიკური ინფორმაციის მომზადებისათვის ფართო სამედიცინო სპექტრში.

კომპიუტერული ტექნოლოგიები მეცნიერები იყვნენ შთაგონებული აადამიანის ტვინის მოდელის მიხედვით, 1943 წელს ნევროლოგმა უორენ მაკკალოხმა და მოაზროვნე უოლტერ პიტმა გამოიგონეს პირველი კონცეფტუალური მოდელი ხელოვნური ნეირონული ქსელის,

მათ აღწერეს ნეირონის კონცეფტუალური მოდელი, სადაც ერთი კლექტა არის მთლიანი ქსელის ნაწილი, სადაც ისინი იღებენ შესასვლელ სიგნალს, ამუშავებენ და აგენერირებენ გამოსავალს.

დღესდღეობით ყველაზე მეტად გავრცელებული ამოცანა ნეირონული ქსელებში არის “easy-for-a-human, difficult-for-a-machine” ხშირად მოიხსენიებენ როგორც მოდელის ამოცნობის ამოცანას.

Abstract

The aim of this work is to present a model of ANN and to use it in diagnostic approaches for stroke by using the data that can serve as inputs for ANNs. In our model we use clinical

symptoms, various types of biochemical data. Each type of data provides information that must be evaluated and used during the process of stroke diagnosis. . The adaptive learning algorithm can be used with diverse types of medical data.

Computer technology and the evolution of new features contributed to the quality of life, particularly in the early detection of acute diseases. Many of the technological system was developed in order to improve health care. Artificial intelligent system is really worth exploring and integrating the medical diagnosis and prescription for the system.

Neural networks have found many uses in medicine. Neural networks are particularly useful in recognition, aiding in medical diagnosis. Specific examples of neural networks within the health industry follow.

The major task of medical science is to prevent and diagnose the diseases. Here our focus is the second task, which is not a direct and simple task at all. In 2001, Brause highlighted that almost all the physicians are confronted during their formation by the task of learning to diagnose. Here, they have to solve the problem of deducing certain diseases or formulating a treatment based on more or less specified observations and knowledge. Below some certain difficulties of medical diagnosis that have to be taken into account are listed: the basis for a valid diagnosis, a sufficient number of experienced cases, is reached only in the middle of a physician's career and is therefore not yet present at the end of the academic formation.

- 1) This is especially true for rare or new diseases where also experienced physicians are in the same situation as newcomers.
- 2) Principally, humans do not resemble statistic computers but pattern recognition systems. Humans can recognize patterns or objects very easily but fail when probabilities have to be assigned to observations.
- 3) The quality of diagnosis is totally depends on the physician talent as well as his/her experiences.
- 4) Emotional problems and fatigue degrade the doctor's performance.
- 5) The training procedure of doctors, in particular specialists, is a lengthily and expensive one. So even in developed countries we may feel the lack of MDs.
- 6) Medical science is one of the most rapidly growing and changing fields of science. New results disqualify the older treats, new cures and new drugs are introduced day by day. Even unknown diseases turn up every now and then. So a physician should always try hard to keep his/ herself up to date .

Question would be how computers can help in medical diagnosis. A computer system never gets tired or bored, can be updated easily in a matter of seconds, and is rather cheap and can be easily distributed.

სარჩევი

ანოტაცია.....	2
ABSTRACT	4
შესავალი.....	8
ინსულტის რისკ-ფაქტორები	10
ნეირონული ქსელის აღწერა და დახასიათება	12
მათემატიკური ფონი.....	16
დამალული ფენები.....	17
ხელოვნური ნეირონული ქსელის მიმოხილვა სამედიცინო დიაგნოსტიკაში	17

ნეირონული ქსელის მოდელის შესაძლებლობა ინსულტის დიაგნოსტიკისთვის	22
ნეირონული ქსელის დიზაინი იშემიური ინფაქტისათვის	22
BACKPROPAGATION ალგორითმი	25
სენსორები.....	27
შემაჯავლი:სენსორები	28
აქსელერომეტრი.....	29
კომპასი.....	29
ძირითადი მეთოდები	30
წინასწარი დამუშავება : ხმაურის მოცილება და სეგმენტაცია	31
ნეირონული ქსელის დროის რიგების პროგნოზი და მოდელირება.....	32
პრობლემის განსაზღვრა.....	32
GUI -ის გამოყენება.....	33
დასკვნა.....	49
გამოყენებული ლიტერატურა	49

შესავალი

ტვინი არის ორგანოების მართვის ცენტრი. ის აკონტროლებს ფიქრებს, მეხსიერებას, მეტყველებასა და მოძრაობას. ის არეგულირებს ორგანოების ფუნქციებს. როცა ტვინი ჯანსაღია ის კარგად და ავტომატურად მუშაობს. თუმცა, როდესაც მოხდება დარღვევა, შედეგები შეიძლება განადგურდეს. ერთ-ერთი ყველაზე გავრცელებული ტვინის ჯანმრთელობის მოშლა არის ინსულტი, რომელსაც ასევე ეძახიან ტვინის შეტევას. ინსულტი არის ძირითადი მიზეზი სიკვდილიანობის, როგორც განვითარებულ ასევე ნაკლებად განვითარებულ ქვეყნებში. ამიტომ ჯანდაცვის ხარჯებიდან ინსულტს ხმარდება დიდი ნაწილი ევროპასა და ამერიკაში.

ინსულტს ახასიათებს ტვინის გარკვეულ ნაწილებში სისხლის მიმოქცევის დაკარგვა, რის შედეგადაც ხდება დაკარგვა შესაბამისი ნერვული ფუნქციის. არსებობს ორი სახის ინსულტი:

1. იშემიური
2. სისხლდენითი

იშემიური ინსულტი ხდება, როდესაც არის არასაკმარისი სისხლის მიწოდება ტვინში. სისხლი შეიცავს ტვინისათვის აუცილებელ საკვებ ნივთიერებებსა და ჟანგბადს.

ხოლო *სისხლდენითი* ინსულტი ხდება, როდესაც სისხლძარღვი დაზიანებულია თავის ტვინში. როგორც ფიქრობენ სისხლდენითი ინსულტი უფრო ემუქრება სიცოცხლეს ვიდრე იშემიური.

გულის შეტევა და იშემიური ინსულტი ძალიან გავს ერთმანეთს. თითქმის 80 პროცენტი ინსულტისა არის იშემიური ინსულტი.

ტექნოლოგიების გამოყენებით განსაკუთრებით ხელოვნური ნეირონული ქსელის გამოყენებით შესაძლებელია ინსულტით სიკვდილიანობის საგრძნობლად შემცირება, ასევე დანახარჯების, დროის და სამედიცინო შეცდომების.

ყოველ წელს 15 მილიონი ადამიანს ემართება ინსულტი. თითქმის 5 მილიონი იღუპება და 6 მილიონი რჩება ინვალიდი. ინსულტი მეორე მიზეზია ინვალიდობის დემენციის შემდეგ. (ჰკუასუსტობა) ინვალიდობა შეიძლება ნიშნავდეს დაბრმავებას ან დამუნჯებას, პარალიზს ან დაბნეულობას. გლობალური მამტაბით ინსულტი წარმოადგენს მეორე წამყვან მიზეზს სიკვდილიანობის 60 წელს ზევით ასაკის ადამიანებში, ხოლო მეხუთე ადგილზეა სიკვდილიანობით 15 დან 59 წლამდე ასაკის ადამიანებში. ინსულტი ნაკლებად გავრცელებულია 40 წლამდე ასაკში, მაგრამ ამდროსაც შესაძლებელია მოხდეს. ინსულტი მესამე წამყვანი მიზეზია სიკვდილის ამერიკაში. 2000 წელს ინსულტმა შეადგინა 7% სიკვდილიანობის - 15 409 კანადელი. ამავე წელს ამერიკაში ინსულტით დაიღუპა 140 000 ადამიანი. ახალგაზრდებში ყველაზე გავრცელებული ინსულტის გამომწვევი მიზეზებია მაღალი არტერიული წნევა ან ნამგლისებური უჯრედის დაავადება. ჩინეთში 1,3 მილიონ ადამიანს ემართება ინსულტი ყოველ წელს და 75% ინვალიდდება. ჯანდაცვის მსოფლიო ორგანიზაციის მონაცემებით 15 მილიონი ადამიანს ემართება ინსულტი მსოფლიოში ყოველ წელიწადს. აქედან 5 მილიონი იღუპება და 5 მილიონი ინვალიდდება. ევროპაში საშუალოდ დაახლოებით 650,000 სიკვდილიანობაა ინსულტით ყოველ წელს.

ინსულტი შეიძლება დაემართოს ყველას ნებისმიერ დროს. ეს ხდება მაშინ, რომცა სისხლის ნაკადი წყდება ტვინში. როდესაც ეს ხდება ტვინის უჯრედები განიცდიან ჟანგბადის უკმარისობას და კვდებიან.

ამერიკის შეერთებულ შტატებში ინსულტი არის ყოველი მესამე მიზეზი სიკვდილის. 700 000 შემთხვევა წელიწადში , 1 ადამიანი იღუპება ინსულტით ყოველ სამ წუთში. ინსულტის შემთხვევაში 76% არის გადარჩენილი , აქედან 50% აქვს ჰემიპარეზი, 26% ხდება დამოკიდებული თავის ყოველდღიურ ცხოვრებაზე, 26% იძულებული ხდება იყოს მოხუცებულთა სახლში. ამდენად, ინსულტი არის სასიკვდილო დაავადება , მაგრამ ის თიშავს უფრო მეტ უჯრედს ვიდრე კლავს. ამ ფაქტმა გამოიწვია , რომ ემუშავათ იმაზე რომ შეემუშავებინათ მეთოდი ნერვული სისტემის აღსადგენად.

ბიძგმა, რომ გადაეტანათ ინსულტის მკურნალობის თერაპიები ცხოველთა მეთოდიდან საავადმყოფოებში გამოიწვია ბევრი კლინიკური გამოკვლევები 1990 _იან წლებში.მათ შორის ბევრმა კვლევებმა განიცადა მარცხი. რამოდენიმე თანამედროვე მიმოხილვები არის აგრეთვე ორიენტირებული cell death მექანიზმზე და ნერვული სისტემის აღდგენაზე ინსულტის შემდეგ.

თითოეული წყარო ინსულტის დაკავშირებულია სხვადასხვა ინფაქტის მექანიზმსა და ზომაზე, დაწყებული ლაკუნალური ინფაქტით მცირე სისხლძარღვების დაზიანებით და ა.შ. თუმცა, მაშტაბური კლინიკური კვლევები და სამყაროს რუტინული ანგიოგრაფიული და ტვინის გრაფიკის შესწავლა დოკუმენტით დადასტურდა .

ინსულტის რისკ-ფაქტორები

იშემიური ინსულტის რისკის ფაქტორი ვლინდება ადამიანის ფიზიკურ მდგომარეობაში. არტერიული წნევის მომატება, გაზრდილი ქოლესტერინის დონე, საძილე სტენოზი და წინაგულების ფიბრილაცია წარმოადგენს ზუსტ ფაქტორებს იშემიური ინსულტის რისკის.

სიგარეტის მოწევა, შაქრიანი დიაბეტი, გულის იშემიური დაავადება და გულის სარქვლოვანი დაავადება, ალბათ ასევე იშემიური ინსულტის რისკის ფაქტორებია, რადგან ჯგუფურმა გამოკვლევებმა დაადასტურეს, რომ ეს თვისებები მნიშვნელოვლად ზრდის ინსულტის რისკს.

იშემიურმა ინსულტმა შეიძლება გამოიწვიოს დამბლა, მეტყველების დაქვეითება, მხედველობისა და სხვა პრობლემები. ინსულტის სიმპტომები, როგორც წესი წარმოიქმნება მოულოდნელად. დაწყების მოულოდნელობა მას განასხვავებს სხვა დაავადებებისაგან, მაგალითად როგორცაა შაკიკი ან ტვინის სიმსიმნე.

პროცედურები ტარდება, რათა შემდგომში დაგვარად შემცირდეს დამანგრეველი შედეგის მიღება ინსულტის შემდეგ. სიმპტომები და რისკ ფაქტორები ტვინის დაავადებების დიდად დამოკიდებულია კონკრეტულ პრობლემასთან. ზოგიერთ შემთხვევაში დაზიანება არის მუდმივი. სხვა შემთხვევებში, მკურნალობის მეთოდი, როგორცაა ოპერაცია ან ფიზიკური თერაპია შეიძლება გამოასწოროს პრობლემის წყარო ან გააუმჯობესოს სიმპტომები. ინსულტის ამერიკულმა ასოციაციამ გამოაშკარავა რამოდენიმე ფაქტორი, რომლებიც ზრდიან იშემიური ინსულტის რისკს. ზოგიერთი ინსულტის გამომწვევი რისკი არის არაკონტროლირებადი როგორცაა ასაკი, მემკვიდრეობა, რასობრივი და გენდერული. უმეტესობას ვისაც აქვს გადატანილი ინსულტი არიან 55 წელს ზევით რაც უფრო წლოვანი ხდება ადამიანი მით უფრო იმატებს რისკი ინსულტის. კაცები 25 პროცენტით უფრო მეტად არიან ინსულტის რისკის ქვეშ, და უფრო ადრეულ ასაკში ქალთან შედარებით. მიუხედავად ამისა, რადგან ქალები უფრო დიდხანი ცხოვრობენ უფრო მეტი შემთხვევაა ქალებში ინსულტის. მაგრამ სხვა კონტროლირებადი რისკ ფაქტორები არის:

- **მაღალი სისხლის წნევა**—მაღალი სისხლის წნევა წარმოადგენს იშემიური ინსულტის ყველაზე მნიშვნელოვან რისკ ფაქტორს. ფაქტობრივად ინსულტის რისკი იცვლება პირდაპირ არტერიული წნევის შესაბამისად.
- **მოწევა**—ბოლო წლებში გამოკვლევებმა აჩვენა, რომ მოწევა წარმოადგენს ძირითად ფაქტორს ინსულტის განვითარების რისკის. ნიკოტინი მრავალი გზით აზიანებს გულ—სისხლძარღვთა სისტემას.

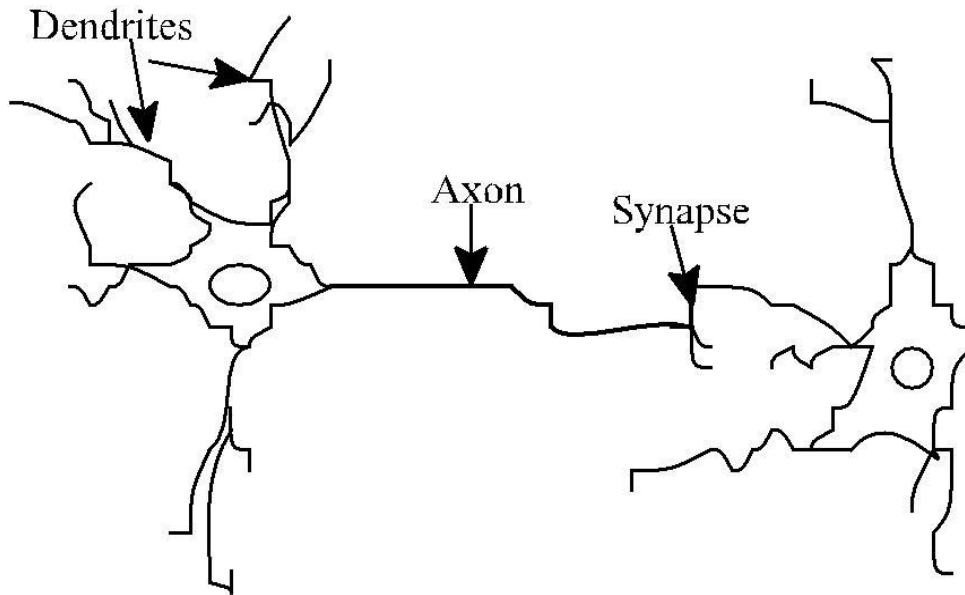
- **დიაბეტი**–ეს არის დამოუკიდებელი რისკ ფაქტორი ინსულტის და დიდად უკავშირდება მაღალ სისხლის წნევას.ხალხი ვისაც აწუხებს დიაბეტი ასევე ხშირად აქვთ მაღალი ქოლესტერინი და არიან ჭარბწონიანები , რაც უფო ზრდის რისკს.
- **საძილე არტერიების დაავადება**–საძილე არტერიები კისერში აწვდიან სისხლს ტვინს. საძილე არტერია დაზიანებული ათეროსკლერით ,შეიძლება დაიბლოკოს შესქელებული სისხლით, რომელმაც შეიძლება მიგვიყვანოს ინსულტამდე.
- **გარდამავალი იშემიური შეტევები**–გარდამავალი იშემიური შეტევები არის პატარა ინსულტები, რომელიც წარმოქმნიან ინსულტს მსგავს სიმპტომებს , მაგრამ არა ხანგრძლივი დაზიანებით.ისინი არიან ძლიერი წინასწარ მანიშნებლები ინსულტის.ადამიანს, რომელსაც ქონდა ერთი ან მეტი გარდამავალი ისემიური შეტევა თითქმის 10 ჯერ მეტი შანსია ქონდეს ინსულტი ვიდრე მისი ასაკის და გენდერის მქონე ადამიანს , რომელსაც არ ქონია ეს შეტევები.

ეს რისკ ფაქტორები შეიძლება იქნას შემცირებულნი ან ნამკურნალევი ცხოვრების წესის შეცვლით ან გარემოს ან ექიმების დახმარებით.

ნეირონული ქსელის აღწერა და დახასიათება


ხელოვნური ნეირონი არის კომპიუტერული მოდელი,რომელიც ინსპირირებულია ბუნებრივი ნეირონებით. ბუნებრივი ნეირონები იღებენ სიგნალებს სინაპსებიდან, (ნერვული უჯრედების შეერთების ადგილები) რომელიც მდებარეობს დენდრიტაზე (ლენტისებური კრისტალები) ან ნეირონების მემბრანაზე.როდესაც ძლიერი სიგნალი მიიღება ნეირონი აქტიურდება და გადასცემს სიგნალს ნერვული უჯრედების კონსტრუქციას, რომელიც ორგანიზმისათვის ელექტრიკულ იმპულსებს აწარმოებს.

(axon) ეს სიგნალი შეიძლება გაიგზავნოს ასევე სხვა სინაპსებში და გააქტიურდეს სხვა ნეირონებიც.



სურათი 1: ბუნებრივი ნეირონები

სირთულე ბუნებრივი ნეირონების არის დიდად დამაფიქრებელია ხელოვნური ნეირონების მოდელირებისას. ისინი ძირითადად შედგებიან შემომსვლელებისაგან (როგორც სინაპსები), რომელიც მრავლდება წონით, და შემდეგ გამოითვლება მათემატიკური ფუნქციით, რომელიც საზღვრავს ნეირონის გააქტიურებას. სხვა ფუნქცია გამოითვლის ხელოვნური ნეირონის გამომავალს. ხელოვნური ნეირონული ქსელი აერთიანებს ხელოვნურ ნეირონებს, რომ დაამუშაოს ინფორმაცია.



სურათი 2: ხელოვნური ნეირონი

რაც უფრო მეტია ხელოვნური ნეირონის წონა, მით ძლიერია შემაველი.წონა ასევე შეიძლება იყოს უარყოფითი, ამიტომ ჩვენ შეგვიძლია ვთქვათ, რომ სიგნალი არის შეფერხებული უარყოფითი წონით.წონაზე დამოკიდებულებით ნეირონების გამოთვლა იქნება სხვადასხვა.ხელოვნური ნეირონების წონის რეგულირებით ჩვენ შეგვიძლია მივიღოთ ჩვენთვის საჭირო გამოსავალი კონკრეტული შესავლებიდან. მაგრამ როცა ჩვენ გვაქვს საქმე ხელოვნურ ნეირონულ ქსელთან იქ არის ასობით ან ათასობით ნეირონები და საკმაოდ ძნელი იქნება ხელით პოვნა ყველა სასურველი წონის.მაგრამ ჩვენ შეგვიძლია ვიპოვოთ ალგორითმი, რომლითაც შეგვიძლია დავარეგულიროთ წონები ხელოვნურ ნეირონულ ქსელში იმისათვის, რომ მივიღოთ სასურველი გამომავალი ქსელში.

ხელოვნური ნეირონული ქსელის ტიპების რაოდენობა და მათი გამოყენება საკმაოდ დიდია.პირველი ნეირონული მოდელის შემდეგ იქნა შემუშავებული ასობით სხვადასხვა მოდელები, რომლებიც განხილული იყო, როგორც ხელოვნური ნეირონული ქსელი.განსხვავებები მათ შორის შეიძლება იყოს ფუნქციები, მიღებული შედეგები, ტოპოლოგია, სწავლის ალგორითმები და ა.შ

ხელოვნური ნეირონული ქსელს ასევე შეიძლება განვიხილოთ, როგორც მათემატიკური წარმოდგენა ადამიანის ნეირონული არქიტექტურისა. ხელოვნური ნეირონული ქსელი ფართოდ გამოიყენება კვლევებში, რადგან მათ შეუძლიათ ფართოდ მოდელირება არაწრფივი სისტემების, რომელშიც ურთიერთკავშირი ცვლადებს შორის უცნობია ან ძალიან კომპლექსურია. ნეირონული ქსელი ჩამოყალიბებულია რიგი „ნეირონებისაგან“ (ან „კვანძებისაგან“), რომლებიც ორგანიზებულია ფენებად. თითოეული ნეირონი ფენაში დაკავშირებულია ყოველ ნეირონთან შემდეგის ფენის წონითი დაკავშირების გზით. წონის ღირებულება w_{ij} მიუთითებს კავშირის სიმძლიერეზე i^{th} ნეირონის პირველ ფენაში და j^{th} ნეირონის მეორე ფენაში.

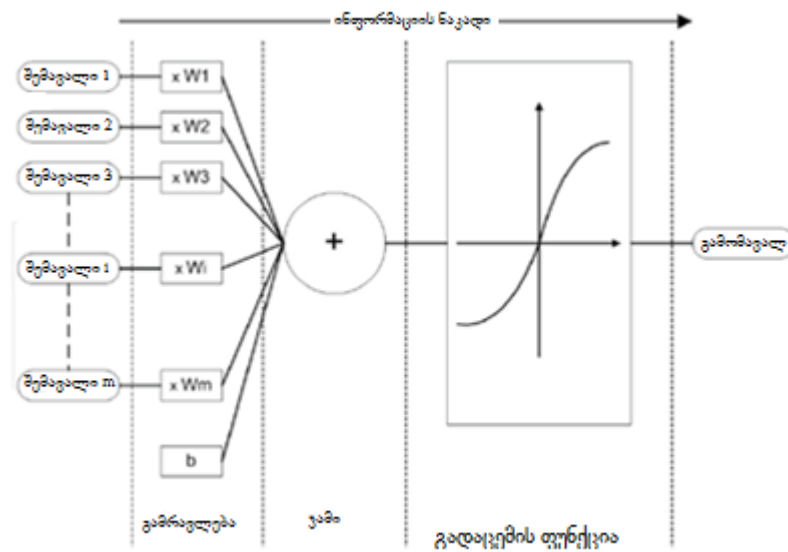
ნეირონული ქსელის სტრუქტურა ჩამოყალიბებულია „შემავალი“ ფენით, ერთი ან მეტი „დამალული“ ფენებითა და „გამომავალი“ ფენით. ნეირონების რაოდენობა ფენებში და ფენების რაოდენობა ძალზედ დამოკიდებულია შესასწავლი სისტემის სირთულეზე. აქედან გამომდინარე, ოპტიმალური ქსელის არქიტექტურა უნდა განისაზღვროს. ნახატი 1-ზე მოცემულია ზოგადი სქემა ტიპური სამ ფენიანი ხელოვნური ნეირონული ქსელის.



Fig.1. Overview of the main applications

მათემატიკური ფონი

ხელოვნური ნეირონული ქსელი არის მათემატიკური მოდელი, რომელიც ცდილობს მიახლოებას სტრუქტურა და ფუნქციონალურობები ბიოლოგიურ ნეირონულ ქსელებს. ძირითადი ფუძე ხელოვნური ნეირონული ქსელისა არის ხელოვნური ნეირონი, რომელიც არის მარტივი მათემატიკური მოდელი (ფუნქცია). ასეთ მოდელს გააჩნია მარტივი წესების კომპლექტი: გამრავლება, შეჯამება და გააქტიურება. ხელოვნური ნეირონის შესასვლელში შემავლები იწონებიან, რაც ნიშნავს, რომ ყოველი შემავალი მნიშვნელობა მრავლდება ინდივიდუალურ წონაზე. ხელოვნური ნეირონის შუა სექციაში არის შეჯამების ფუნქცია, რომელიც აჯამებს ყველა შემავლის წონას და წანაცვლება. ხელოვნური ნეირონის გამოსასვლელში ჯამი აწონილი შემავლებისა და წანაცვლება გადის აქტივაციის ფუნქციას, რომელსაც ასევე ეძახიან გადაცემის ფუნქციას. (სურათი 2)



სურათი 2: ხელოვნური ნეირონის მუშაობის პრინციპი

ნეირონები შესასვლელ ფენაში იღებენ მონაცემებს და აგზავნიან მათ პირველ დამალულ ფენის ნეირონებთან წონითი კავშირების მეშვეობით. აქ, მონაცემები არის მათემატიკურად დამუშავებული და შედეგი გადაეცემა შემდეგი ფენის ნეირონებს.

დამალული ფენები

ფარული ერთეულები არის კვანძები, რომლებიც განლაგებულია შემავალ და გამომავალ კვანძებს შორის. ფარული ერთეულები საშუალებას აძლევს ქსელს არაწრფივი ფუნქციების შესწავლის. ფარული ერთეულები საშუალებას აძლევს ქსელს წარმოიდგინოს კომბინაცია შემავალი მახასიათებლების იმის გათვალისწინებით, რომ შეიძლება იყოს მოცემული ბევრი ფარული ერთეულები ნეირონული ქსელი დაიმასხოვრებს შემავალი ნიმუშებს. თუ მოცემულია ძალიან ცოტა ფარული ერთეულები, ნეირონულმა ქსელმა შეიძლება ვერ შეძლოს წარმოდგენა ყველა საჭირო განზომილებების.

საბოლოოდ, ბოლო ფენის ნეირონები უზრუნველყოფენ ქსელის გამომავალს. j -th ნეირონი ფარულ ფენაში ამუშავებს შემომავალ მონაცემებს (x_i) საშუალებით:

1. შეწონილი წონის გამოთვლა

$$net_j = \sum_{i=1}^m x_i \times w_{ij} + \theta_j \quad (j=1,2,\dots,n) \quad (1)$$

სადაც y_{ij} და y_j^* არის აქტიური

2) გარდაქმნის net_j -ს მათემატიკური “გადატანის ფუნქციის” მეშვეობით

3) შედეგების გადაცემა ნეირონებისათვის შემდეგ ფენაში. უმეტესად

გამოიყენება გადაცემის ფუნქცია: $f(x) = 1/(1 + e^{-x})$

ხელოვნური ნეირონული ქსელის მიმოხილვა სამედიცინო

დიაგნოსტიკაში

კონცეფცია პირველად იქნა ასახული 1988 წელს პიონერულ ნამუშევარში და მას შემდეგ ბევრი ნაშრომი იქნა გამოქვეყნებული. მაგალითად ხელოვნური ნეირონული ქსელი იქნა გამოყენებული კოლორექტარული კიბოს, გაფანტული სკლეროზის დაზიანების, მსხვილი ნაწლავის კიბოს, პანკრეასის დაავადების, გინეკოლოგიური დაავადებებისა და ადრეული დიაბეტის დიაგნოზირებისათვის. გარდა ამისა,

ხელოვნური ნეირონული ქსელი ასევე გამოიყენება ანალიზისათვის. adaptive დაავადების დიაგნოზის სისტემა შემუშავებულია ხელოვნური ნეირონული ქსელის ვექტორის კვანტირების შესწავლის საფუძველზე. ეს ალგორითმი წარმოადგენს პირველ შემოთავაზებულ adaptive ალგორითმს და შეიძლება გამოყენებულ იქნას სხვადასხვა განსხვავებულ დაავადებებთან. კიბო, დიაბეტი და გულსისხლძარღვთა დაავადებები ყველაზე სერიოზული და მრავალფეროვანია დაავადებებს შორის. ინსტრუმენტალური და კლინიკური ანალიზებიდან მიღებული მონაცემების რაოდენობა ამ დაავადებების დროს ძალიან დიდია და ამიტომ ძალიან მნიშვნელოვანია დიაგნოზის დადგენის გაადვილების ინსტრუმენტების შემუშავება.

Patient code	MEDICAL DATA	DIAGNOSIS
1	data _{1,1} ... data _{1,j} ... data _{1,m}	POSITIVE
2	data _{2,1} ... data _{2,j} ... data _{2,m}	POSITIVE
3	data _{3,1} ... data _{3,j} ... data _{3,m}	POSITIVE
...
k	data _{k,1} ... data _{k,j} ... data _{k,m}	NEGATIVE
k+1	data _{k+1,1} ... data _{k+1,j} ... data _{k+1,m}	NEGATIVE
...
n	data _{n,1} ... data _{n,j} ... data _{n,m}	NEGATIVE

სურ:3 სასწავლო ბაზის სტრუქტურა

ნიმუში

პირდაპირწრფივი ნეირონული ქსელი ფართოდ გამოიყენება პროგნოზირების, კლასიფიკაციისა და პრობლემის გადაჭრისათვის. ტიპური პირდაპირწრფივი უკუგავრცობადი (backpropagation) ნეირონული ქსელი არის წარმოდგენილი დაავადებების დიაგნოზირებისათვის და აქვს მხოლოდ ერთი პირობა:

იფორმაციის შეტანა უნდა ხდებოდეს შესასვლელიდან გასასვლელამდე მხოლოდ ერთი მიმართულებით back-loops გარეშე. იქ არ არის შეზღუდვა ფენების რაოდენობაზე, გადაცემის ფუნქციის ტიპი გამოყენებული ინდივიდუალურ

ხელოვნური ნეირონების ან რიცხვი შეერთებების(კავშირისა) ინდივიდუალურ ხელოვნურ ნეირონებს შორის.

ნიმუშში, რომელიც წარმოდგენილია აქ არის ნეირონული ქსელის მოდელი 16 შემავლით , რომლებიც არის კომბინაცია სიმპტომებისა და რისკ ფაქტორების წარმოდგენილი პაციენტების მიერ. სიმპტომისა და რისკ ფაქტორის არსებობა გამოიხატება 1 -ით და არ არსებობა 0-ით. ამ ნიმუშში გამოყენებულია ორი ფარული ფენა. გამომავალი ფენა შედგება ერთი კვანძისაგან , რომელიც გვიჩვენებს ინსულტის წარმოქმნის ალბათობას.

პაციენტის სიმპტომები	
1.	მოულოდნელი დაბუჟება ან სისუსტე სახის, ხელის ან ფეხის, ხშირად სხეულის ერთი მხარე
2.	მოულოდნელი დაბნეულობა, მეტყველებასთან პრობლემა და გაგების პრობლემა(აღქმის)
3.	მოულოდნელი პრობლემები ხედვასთან დაკავშირებით ერთი თვალიდან ან ორივედან
4.	მოულოდნელი პრობლემები სიარულთან, თავბრუსხვევა , ორიონტაციისა და კოორდინაციის დაკარგვა
5.	მოულოდნელი თავის ტკივილები მიზეზის გარეშე
6.	მაღალი სისხლის წნევა
7.	დიაბეტი
8.	გარდამავალი იშემიური ინსულტები
9.	სამილე არტერიის სტენოზი(დავიწროვება)
10.	მოწევა
11.	სახის სისუსტე
12.	ხელის სისუსტე
13.	მეტყველების პრობლემები
14.	hemiparesis or hemisensory დარღვევა

15.	ატაქსია(ნერვული დაზიანება)
16.	დიპლოპია / მხედველობის დაკარგვა

ნეირონული ქსელის შემავალი ფენა დამოკიდებულია შემავალი მონაცემების მახასიათებლებზე. ინსულტის პროგნოზირებისათვის ჩვენ გამოვიყენეთ 16 შემავალი , რომელიც არის კომბინაცია სიმპტომებისა და რისკ ფაქტორების.

ფარული ფენა ავტომატურად იღებს შემავლის მახასიათებლებს და ამცირებს მის ზომას შემდგომისათვის. ორი ფარული ფენაა გამოყენებული. ამ მოდელში ჩვენ ავარჩიეთ ერთი ფარული ფენა 20 ნეირონით და ლოგისტიკური სიგმოიდური ფუნქციები. ჩვენ შეგვიძლია ვივარაუდოდ, ინსულტის მოსალოდნელობა ან უქონლობა ნეირონული ქსელის გამომავალზე დაყრდნობით. ამიტომ, თუ გამომავალი არის 1 მაშინ მოსალოდნელია ინსულტი ხოლო, თუ გამომავალი არის 0 არ არის მოსალოდნელი ინსულტი. ქსელის error ფუნქცია $E(t)$ სადაც t არის დრო განისაზღვრება შემდეგნაირად:

$$E = \frac{1}{2} \sum_{i=1}^m \sum_{j=1}^n (y_{ij} - y_{ij}^*)^2$$

სადაც y_{ij} და y_{ij}^* არის ნამდვილი და network's j -th output corresponding to the i -th input vector, respectively.

მიმდინარე წონის ცვლილება მოცემულ ფენაში წარმოდგენილია შემდეგი ფორმულის საშუალებით:

$$\Delta w_{ij} = -\eta (dE/dw_{ij})$$


სადაც η არის დადებითი კონსტანტა , რომელსაც ეძახიან შესწავლის სიჩქარე(learning rate). იმისათვის , რომ შესწავლა გახდეს უფრო სწრაფი და თავიდან ავიცილოთ local minima :

$$\Delta w_{ij}^k = -\eta(dE/dw_{ij}) + \mu\Delta w_{ij}^{k-1}$$

სადაც μ არის „იმპულს“ ტერმინი და Δw_{ij}^{k-1} არის w_{ij} წონის ცვლილება $(k-1)$ -th სწავლის ციკლიდან.

მაგალითი

შევქმნათ ქსელი ოთხი ხელოვნური ნეირონისაგან. ორი მათგანი იქნება შემავალი ქსელში და ორი მათგანი იქნება გამავალი ქსელიდან.



არის წინები მინიჭებული თითოეულ ისარზე, რომელიც წარმოადგენს საინფორმაციო ნაკადს. ეს წონები მრავლდება შედეგებზე, რომლებიც გადის თითოეულ ისარში, რომ მისცეს მეტი ან ნაკლები ძალა სიგნალს, რომელსაც ისინი გადასცემენ. ვინაიდან

შემავალ ნეირონებს აქვთ მხოლოდ ერთი შემავალი მათი გამომავალი იქნება შემავალი რომელსაც ისინი მიიღებენ გამრავლებული წონაზე.

ნეირონები გამომავალ ენაზე მიიღებენ გამომავალს ორივე შემავალი ნეირონის, გამრავლებული მათ შესაბამის წონაზე და და დაჯამებული. ისინი იღებენ გამომავალ სიგნალს, რომელიც არის გამრავლებული სხვა წონაზე.

ახლა დავაყენოთ ყველა წონა 1 ის ტოლი. ეს ნიშნავს ,რომ ინფორმაცია იქნება უცვლელი.

ნეირონული ქსელის მოდელის შესაძლებლობა ინსულტის დიაგნოსტიკისთვის

ნეირონული ქსელი

ნეირონული ქსელები შთაგონებულია ბიოლოგიურ ორგანიზმში ნევრული სისტემის გამოჩენით. ნეირონული ქსელი განკუთვნილია დამოკიდებულების დასაჭერად დამოკიდებული და დამოუკიდებელი ცვლადი სიდიდეების მონაცემთა ბაზის მოცემულ მოდელში. განსხვავებით პარამეტრული მოდელებისა გამოიყენება სტატისტიკურ მეთოდებში.

ნეირონული ქსელის დიზაინი იშემიური ინფაქტისათვის

ბოლო წლებში ნეირონული ქსელის ტექნოლოგია ფართოდ იქნა გამოყენებული სამედიცინო პრობლემების პროგნოზისათვის, რომლებშიც ჩვეულებრივ გამოიყენებოდა უკუგანვრცობადი ალგორითმი. მოდელი რომელსაც შევქნით აქ არის უკუგანვრცობადი ნეირონული ქსელის მოდელი 10 შესასვლელით , რომლებიც არიან კომბინაცია სიმპტომებისა და რისკ ფაქტორების ინშემიური ინსულტის პროგნოზირებული პაციენტის მიერ. რისკ ფაქტორისა და სიმპტომის არსებობა არის 1 ხოლო არარსებობა არის 0. ამ მოდელში ერთი პარული ფენა იქნა

გამოყენებული.გამომავალი ფენა შედგება ერთი კვანძისაგან, რომელიც გვიჩვენებს იშემიური ინსულტის ალბათობას.

A. შემავალი ფენა

ნეირონული ქსელის შემავალი ფენა განისაზღვრება შემავალი მონაცემების მახასიათებლებით.იშემიური ინსულტის პროგნოზისათვის ჩვენ გამოვიყენებთ 10 სემავალს , რომელიც დაკომპლექტებულია სიმპტომებითა და რისკებით.შმდეგი რისკები და სიმპტომებია შემავალი ნეირონული ქსელის:

S1 მოულოდნელი გაშეშება ან მოდუნება სახის, ხელის ან ფეხის, ერთი მხარე სხდელის.

S2 მოულოდნელი დაბნეულობა, პრობლემები მეტყველებასთან დაკავშირებით ან გაგებასთან დაკავშირებით.

S3 მოულოდნელი პრობლემები ხედვასთან ერთი თვალიდან ან ორივე თვალიდან

S4 მოულოდნელი პრობლემები სიარულთან, თავბრუსხვევა ბალანსის დაკარგვა ან კოორდინაციის.

S5 მოულოდნელი ძლიერი თავისტკივილი გაურკვეველი მიზეზებით.

R6 მაღალი სისხლის წნევა

R7 დიაბეტი

R8 გარდამავალი იშემიური შეტევები

R9 საძილე ატერიის შევიწროვება

R10 მოწევა

B: დაფარული ფენა

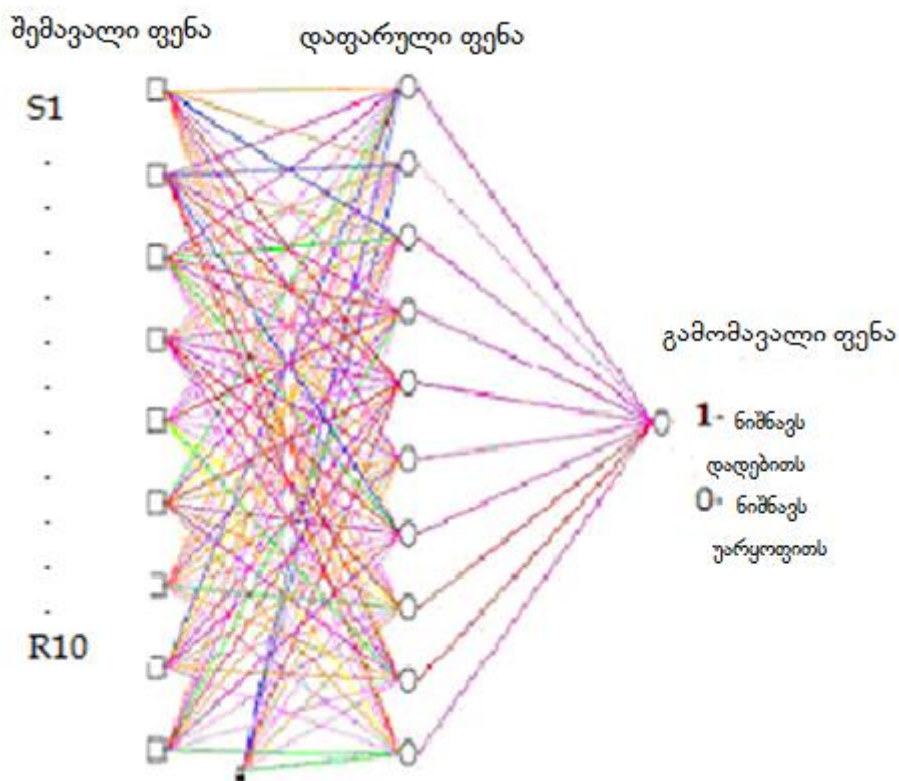
ფარული ფენა ავტომატურად იღებს შემავლის მახასიათებლებს და და ამცირებს მათ ზომას.არ არსებობს კონკრეტული წესი, რომელიც გვკარნახობს ფარული ფენების ციფრს.როგორც წესი, გამოიყენება ერთი ფარული ფენა. ამ მოდელში ჩვენ გვაქვს ერთი ფარული ფენა 20 ნეირონით.

C: გამომავალი ფენა

გამომავალი ფენა ქსელის შემუშავებულია გამომავალი განაცხადების მოთხოვნების შესაბამისად. ნეირონული ქსელის გამომავალისაგან მოელოდებიან პროგნოზირებას დადასტურდეს ან უარყოს იშემიური ინსულტი. ასე, რომ თუ გამომავალია 1 დაავადება არის ხოლო თუ გამომავალია 0 დაავადება არა არის. ივარაუდება, რომ ფაქტობრივი გამომავალი ნეირონის, გამომავალფენაში არის $y_j(t)$ t დროზე და მოსალოდნელი გამომავალი $d_j(t)$ t დროზე, ასე რომ ასელური შეცდომა იქნება $E(t)$ t დროზე განსაზღვრელი შემდეგი სახით:

$$E(t) = \frac{1}{2} \sum_{j=1}^q (y_j(t) - d_j(t))^2$$

Q არის ნეირონების რიცხვი გამომავალ ფენაზე. ϵ არის წინასწარ დასახული ცდომილება. მოდელი შეწყვეტს ტესტირებას, როცა $E(t)$ იქნება ნაკლები ვიდრე ϵ .



სურათი 1: დამალული ფენა

დამოკიდებულებით მონაცემების სისწორით , რიცხვი სასწავლო ნიმუშების, და შეცდომა სწავლების დასასრულისათვის ,ტესტის შედეგები გაიზრდება 98% დან 99,99%_ მდე.

backpropagation ალგორითმი

Backpropagation ალგორითმი გამოიყენება ფენებიან პირდაპირ გადაცემად ხელოვნურ ნეირონულ ქსელებში. ეს ნიშნავს, რომ ხელოვნური ნეირონები ორგანიზებულნი არიან ფენებად და აგზავნიან სიგნალებს „წინ“ , ხოლო შემდეგ შეცდომები უკან იგზავნება.ქსელი იღებს შემავალ სიგნალს ნეირონებიდან, რომლებიც განთავსებულნი არიან შემავალ ფენაზე,ხოლო ქსელის გამომავალი მოცემულია ნეირონების მიერ ,რომლებიც განთავსებულია გამომავალ ფენაზე. იქ შეიძლება იყოს ერთი ან რამოდენიმე შუალედური დაფარული ფენები. Backpropagation ალგორითმის აზრი არის ის, რომ მან შეამციროს შეცდომები სანამ ხელოვნური ნეირონული ქსელი დაიწყებს მონაცემების გადამუშავებას (შესწავლას). დამუშავება იწყება შემთხვევითი წონებით და მიზანია ,რომ მოაწესრიგოს ისინი ისე ,რომ შეცდომები იყოს მინიმალური.

ხელოვნური ნეირონების აქტივაციის ფუნქციას ხელოვნურ ნეირონულ ქსელში ასრულებს Backpropagation ალგორითმი წონითი ჯამი(შემავლების ჯამი x_i გამრავლებული მათ შესაბამის წონებზე გამრავლებული w_{ji})

$$A_j(\bar{x}, \bar{w}) = \sum_{i=0}^n x_i w_{ji}$$

ჩვენ ვხედავთ , რომ აქტივაცია დამოკიდებულია მხოლოდ შემავლებზე და წონებზე. თუ გამომავალი ფუნქცია ტოლი იქნება (გამომავალი = აქტივაცია) მაშინ ნეირონს შეგვიძლია ვუწოდოთ წრფივი.მაგრამ მათ აქვთ დიდი შეზღუდვები.ყველაზე გავცელებული გამომავალი ფუნქცია არის სიგმოიდური ფუნქცია:

$$O_j(\bar{x}, \bar{w}) = \frac{1}{1 + e^{-A_j(\bar{x}, \bar{w})}}$$

სიგმოიდური ფუნქცია ძალიან ახლოს არის ერთთან დიდი დადებითი ციფრისათვის, და ძალიან ახლოსაა ნულისკენ დიდი უარყოფითი ციფრისათვის. ეს ხელს უწყობს მაღალი და დაბალი ნეირონის გამომავლის ადვილად გადასვლაზე. ჩვენ ვხედავთ, რომ გამომავალი დამოკიდებულია მხოლოდ აქტივაციაზე, რაც თავის მხრივ დამოკიდებულია შემავლის მნიშვნელობაზე და მათ შესაბამის წონაზე.

ახლა შესწავლის მიზანი არის, რომ მიიღოს სასურველი გამომავალი, როდესაც კონკრეტული შემავლები არის მოცემული. მას შემდეგ, რაც შეცდომა არის განსხვავება ნამდვილ და სასურველ გამომავალს შორის, შეცდომა დამოკიდებულია წონებზე, და ჩვენ უნდა დავალაგოთ წონები იმისათვის, რომ შევამციროთ შეცდომები. ჩვენ შეგვიძლია განვსაზღვროთ შეცდომის ფუნქცია თითოეული ნეირონის გამომავლისათვის:

$$E_j(\bar{x}, \bar{w}, d) = (O_j(\bar{x}, \bar{w}) - d_j)^2$$

ჩვენ ვიღებთ კვადრატს სხვაობის გამომავალსა და შდევს შორის, იმიტომ, რომ ეს ყოველთვის იქნება დადებითი და იმიტომ, რომ იქნება უფრო მეტი თუ სხვაობა დიდია და უფრო მცირე თუ სხვაობა არის პატარა. ქსელის შეცდომა იქნება ჯამი შეცდომებისა ყველა ნეირონის გამომავალ ფენაში:

$$E(\bar{x}, \bar{w}, \bar{d}) = \sum_j (O_j(\bar{x}, \bar{w}) - d_j)^2$$

ახლა უკუგანვრცობადი ალგორითმი ითვლის რამდენად დამოკიდებულია შეცდომა გამომავალზე, შესავალზე და წონებზე. მას შემდეგ, რაც ჩვენ გავიგებთ ჩვენ შეგვიძლია მოვარგოთ წონები *gradient descent* მეთოდის გამოყენებით:

$$\Delta w_{j_i} = -\eta \frac{\partial E}{\partial w_{j_i}}$$

ეს ფორმულა შეიძლება იქნას ახსნილი შემდეგნაირად: რეგულირება თითოეული წონის იქნება უარყოფითი მუდმივა ეთა (η)

სენსორები

განვიხილოთ სმარტფონების სენსორები და აპლიკაციების რამდენიმე ვარიაცია . მოქმედების ამოცნობა ძალიან მნიშვნელოვანია ბევრი აპლიკაციისათვის. გულმოდგინედ დავამუშავოთ ეს შემდეგი მაგალითებით. მაგალითად, ვივარაუდოთ, რომ ტელეფონი აღმოაჩენს , რომ მომხმარებელი აპირებს ოთახიდან გასვლას და მისი ამინდის აპლიკაცია აჩვენებს რ, რომ მოგვიანებით იწვიმებსშემხსენებელი ფანჯარა გაიხსნება შმდეგი შეტყობინებით“იქონიეთ ქოლგა . დიდი ალბათობით იწვიმებს.“

კიდევ ერთი მნიშვნელოვანი აპლიკაცია მოქმედების ამოცნობის მეთოდი არის ორივე შიდა და გარე ლოცალიზაცია ნავიგაციის მშენებლობისათვის.

ეს შეიძლება დაგვეხმაროს საშიში საქმიანობის თავიდან არიდებაში, როგორცაა ახალგაზრდული აუტიზმის სპექტრის აშლილობის გამოვლენა სკალში და ა.შ. იმისათვის, რომ დაეხმაროს მომხმარებელს შეიქმნას ჯანსაღი ფიტნეს ჩვევა, სმარტ ტელეფონს შეუძლია გაუგზავნოს შეხსენების ფანჯარა თუ ის აღმოაჩენს , რომ მომხმარებელი იჯდა ძალიან დიდი ხანი. რამოდენიმე პოპულარული ფიტნეს მრჩეველი , როგორცაა „Fitbit One“ აგებულია upon wearable სენსორებზე და მოქმედების ამომცნობი ტექნიკით.ისინი ითვლიან მომხმარებლის გადადგმულ ნაბიჯებს, კბეებზე ასვლას, კალორიის დაწვას, ძილის საათებს,განვლილ მანძილს, ძილის ხარისხიანობას და ა.შ.

ფონი

მოქმედების ამომცნობი აპლიკაცია იღებს დაუმუშავებელ სენსორს როგორც შემავალი და პროგნოზირებას უკეთებს მომხმარებლის მონიტორის მოქმედებას.სანამ ჩავუღრმავდებით ალგორითმის დეტალებს შემდეგ განყოფილებაში , განვიხილოთ ეს ძირითადი ცნებები.

შემავალი:სენსორები

სენსორები არის წყარო პირველადი მონაცემების შეგროვებისათვის მოქმედების ამომცნობისათვის.ჩვენ ვყოფთ სენსორებს სამ კატეგორიად: ვიდეო სენსორები,გარემოზე დაფუძნებული სენსორები და wearable სენსორები.ვიდეო სენსორები ზირითადად დაყენებულია ფიქსირებულ ადგილებში, როგორცაა შესასვლელი და გასასვლელი საზოგადოებრივ ადგილებში ან საცხოვრებელ ოთახში და საწოლ ოთახში.კამერები ასევე დამონტაჟებულია რობოტებში უფრო აქტიური ვიზუალური მონაცემების შესაგროვებლად.

გარემოზე დაფუძნებული სენსორები გამოიყენება აღმოჩენისათვის მომხმარებლის ურთიერთდამოკიდებულება გარემოსთან. ისინია რადიოზე დაფუძნებულია სენსორები როგორც wifi , Bluetooth, და infrared . ეს სენსორები, როგორც წესი განლაგებულია ოფისებში ან სახლებში. ისინი პასიურად აკონტროლებენ მომხმარებლის ადგილმდებარეობას გარკვეულ ადგილებში ან მომხმარებლის ურტიერტქმედებას ობიექტთან რომელიც ასევე აღჭურვილია სენსორებით. მათი შეზღუდვებია ის, რომ ისინი შეიძლება იქნან გამოყენებულნი მხოლოდ გარკვეულ ფიქსირებულ ადგილებში და ღირებულება სრული განლაგების ასეთი სენსორების ძალიან ძვირია.

მოსახერხებელი სენსორი არის მობილური სენსორი, რომელიც განკუთვნილია ყოველდღიურ სატარებლად.მათ შეუძლიათ მონაცემების მოწოდება მომხმარებლის ფიზიოლოგიური მდებარეობის შესახებ, როგორცაა ადგილმდებარეობის შეცვლა , მოძრაობის მიმართულება ,სიჩქარე და ა.შ. ასეთი სენსორები შეიცავენ აქსელერომეტრს, მიკროფონს.GPS, ბარომეტრს და ა.შ. მობილური სენსორის უმეტესობა აღჭურვილია სმარტ ტელეფონებში. ცხრილი 1 აჯამებს სენსორების

ერტობლიობას, რომელიც გათვალისწინებულია ძირითადი სმარტ ტელეფონებისათვის.


აქსელერომეტრი

აქსელერომეტრ სენსორები გრძნობენ აჩქარების შემთხვევას სმარტ ტელეფონებისათვის. შესწავლა შეიცავს სამ ღერძს, რომლის მიმართულებაც წინასწარ არის დადგენილი, როგორც სურათ 2_ში. დაუმუშავებელი მონაცემების ნაკადი აქსელერომეტრიდან არის აჩქარება თითოეულ ღერძზე ერთეულ გ-ძალაზე. დაუმუშავებელი მონაცემები წარმოდგენილია ვექტორების სახით: $Acc_i = \langle x_i ; y_i ; z_i \rangle, (i = 1; 2; 3; \dots)$. უმეტესი არსებული აქსელერომეტრიდან უზრუნველყოფენ მომხმარებლის ინტერფეისს შერჩევის სიხშირის კომფიგურაციისათვის, ისე რომ მომხმარებელს შეეძლოს აირჩიოს საუკეთესო შერჩევის განაკვეთი ექსპერიმენტის მეშვეობით.

აქსელერომეტრი ფართოდ იხმარება სმარტ ტელეფონების სენსორებში დაფუძნებული მოქმედების ამოცნობაზე.

კომპასი

კომპასი არის ტრადიციული საშუალება მიმართულების დასადგენად მხედველობაში მიღებით დედამიწის ჩრდილო-სამხრეთ პოლუსის მაგნეტიზმის გამოყენებით. სმარტ ტელეფონების კომპასის სენსორიც მუშაობს ანალოგიური ფუნქციით. სურათი 3 გვიჩვენებს კომპასს სმარტ ტელეფონის ეკრანზე.



სურათი3: ტელეფონის კომპასი

დაუმუშავებელი მონაცემების კომპასიდან ამოკითხვა ნამდვილი რიცხვი 0° და 360° შორის. ის იწყება 0° დან როგორც აბსოლიტური ჩრდილოეთი .

მაგალითად მიმართულია აბსოლიტური აღმოსავლეთით არის 90° და აბსოლიტური დასავლეთი 270° .

ძირითადი მეთოდები

დაუმუშავებელი მონაცემთა შეგროვება

დაუმუშავებელი მონაცემების შეგროვების გზა აუცილებლად იქონიების გავლენას სიზუსტეზე დამუშავების(ამოცნობის) დროს.

სენსორების რაოდენობა და მათი ნაირფეროვნება ასევე გავლენას ახდენს ამოცნობის შედეგზე , ასევე ადგილი სადაც მოქმედება ხდება. ცხრილ 3_ში ჩვენ შევაჯამებთ ცდის პარამეტრებს სენსორების თვალსაზრისით და საგნების უმეტესად ლიტერატურული აქტივობის ამომცნობი მობილური სენსორის გამოყენებით.

არსებობს სხვადასხვა პარამეტრები მგრძობელობის ეფექტის შესამცირებლად ადგილმდებარეობასა და სიროვნებაზე. მაგალითად, [17] ნამუშევარში „ზოგიერთი სენსორი გამოიყენება გრავიტაციის ეფექტის გასაქრობად ასელერომეტრის შედეგიდან და გარდაქმნას აქსელერომეტრი ისე, რომ შედეგი მიიღოს სხეულის კოორდინატთა სისტემიდან დედამიწის საკოორდინატო სისტემით. ამით მომზადებული მოდელი ხდება სენსორები_ორიენაციით-დამოუკიდებელი. [15] ნაშრომში, ავტორები ცდილობდნენ შეეგროვებინათ მონაცემები სხვადასხვა მომხმარებლისაგან და დაეყნებინათ სენსორები სუბიექტების სხეულის სხვადასხვა ნაწილებზე. მათ დაასკვნეს, რომ უფრო დიდი შემსწავლელ კომპლექტს მიღებული სხვადასხვა პარამეტრებიდან, ადგილმდებარეობა და პირადი მგრძობელობა შეიძლება შემცირებინა.

სხვა ძირითადი მხარე დაუმუშავებელი მონაცემების შეგროვებაში წარმოადგენს შერჩევის რაოდენობა. თითქმის ნებისმიერი სენსორი უზრუნველყოფს API-ს იმისათვის, რომ მომხმარებელს შეეძლოს შერჩევის რაოდენობის კონფიგურირება. ასევე მონაცემების შეგროვება უმაღლესი რაოდენობით უზრუნველყოფს მეტი ინფორმაციას მომხმარებელზე, ამან ასევე შეიძლება წარმოგვიდგინოს მეტი ხმა . აქედან გამომდინარე, უმაღლესი შერჩევის რაოდენობა ყოველთვის არ გვაძლევს უმაღლეს სიზუსტეს.

წინასწარი დამუშავება : ხმაურის მოცილება და სეგმენტაცია

დაუმუშავებელი მონაცემების შეგროვების შემდეგ სხვადასხვა სენსორებიდან, შემდეგი ნაბიჯი არის მათი წინასწარ დამუშავება სანამ შემდეგი ნაწილის განხორციელებაზე გადავალთ. ერთ-ერთი მიზანი მონაცემების წინასწარ დამუშავების არის, რომ შევამციროთ ხმაური მომხმარებლისაგან და თვითონ სენსორის. ლიტერატურა [23,30] გამოიყენება საშუალო დამარბილებელი მეთოდი. ისინი გააადგილებენ თითოეულ დაუმუშავებელ მონაცემებს მათი საშუალოს საშუალებით ორი გვერდიგვერდ მდგომი მონაცემით ხმის შემცირებამდე , რომელის შეიძლება იყოს გამოწვეული ტელეფონის შემთხვევით ძირს დავარდნით.

კიდევ ერთი მნიშვნელოვანი ნაბიჯი არის მონაცემების სეგმენტაცია. სეგმენტაცია შეიძლება დაიყოს ორ კატეგორიად:

1. სეგმენტაცია გადაფარვით
2. სეგმენტაცია გადაფარვის გარეშე

ნეირონული ქსელის დროის რიგების პროგნოზი და მოდელირება.

დავუშვათ, მაგალითად , რომ თქვენ გაქვთ მონაცემები pH ნეიტრალიზაციის პროცესიდან. გსურთ რომ შეიმუშაოთ ქსელი, რომელსაც შეეძლება pH_ ის პროგნოზირება მისი წინა მაჩვენებლების მეშვეობით და წინა მნიშვნელობა მჟავის დანაკარგისა და რეზერვუარში მოთავსებულის.თქვენ გაქვთ მთლიანად 2001 დროითი ნაბიჯი.

თქვენ შეგიძლიათ ეს გადაჭრათ ორი გზით:

1. მომხმარებლის გრაფიკული ინტერფეისი გამოყენებით, 'ntstool', როგორც აღწერილია „[Using the Neural Network Time Series Tool](#) „_ში.
2. command-line ფუნქციების გამოყენებით, როგორც აღწერილია „[Using Command-Line Functions](#)“ _ში.

ეს როგორც წესი საუკეთესო გზაა დავიწყოთ GUI_ით , ხოლო შემდეგ გამოვიყენოთ GUI command-line სკრიფტის ავტომატური შექმნისათვის. ნებისმიერი მეთოდის გამოყენებამდე პირველი ნაბიჯი მდგომარეობს პრობლემის დასმაში. ყოველ GUI_ის აქვს წვდომა მონაცემების კომპლექტის ნიმუშთან, რომელიც შეგიძლიათ გამოიყენოთ toolbox -თან.თუ თქვენ გაქვთ სპეციფიკური პრობლემა, რომელიც გინდათ გადაჭრათ, თქვენ შეგიძლიათ ჩაწეროთ თქვენი მონაცემები სამუშაო ადგილას.შემდეგი განყოფილება აღწერს მონაცემთა ფორმატს.

პრობლემის განსაზღვრა

იმისათვის , რომ განვსაზღვროთ დროითი რიგების პრობლემა toolbox -ისათვის, მოვამზადოთ კომპლექტი TS ვექტორებისა, როგორც სვეტები მასივში. შემდეგ მოვამზადოთ მეორე კომპლექსი TS ვექტორებისა მეორე მასივში.თუმცა, არის შემთხვევები, როდესაც თქვენ მხოლოდ გჭირდებათ მონაცემების კომპლექსი. მაგალითად, თავენ შეგიძლიათ განსაზღვროთ შემდეგი დროითი რიგების პრობლემა, რომელშიც თქვენ გინდათ გამოიყენოთ წინა მონაცემები, რომ პროგნოზირება შეძლოთ შემდეგი მონაცემის:

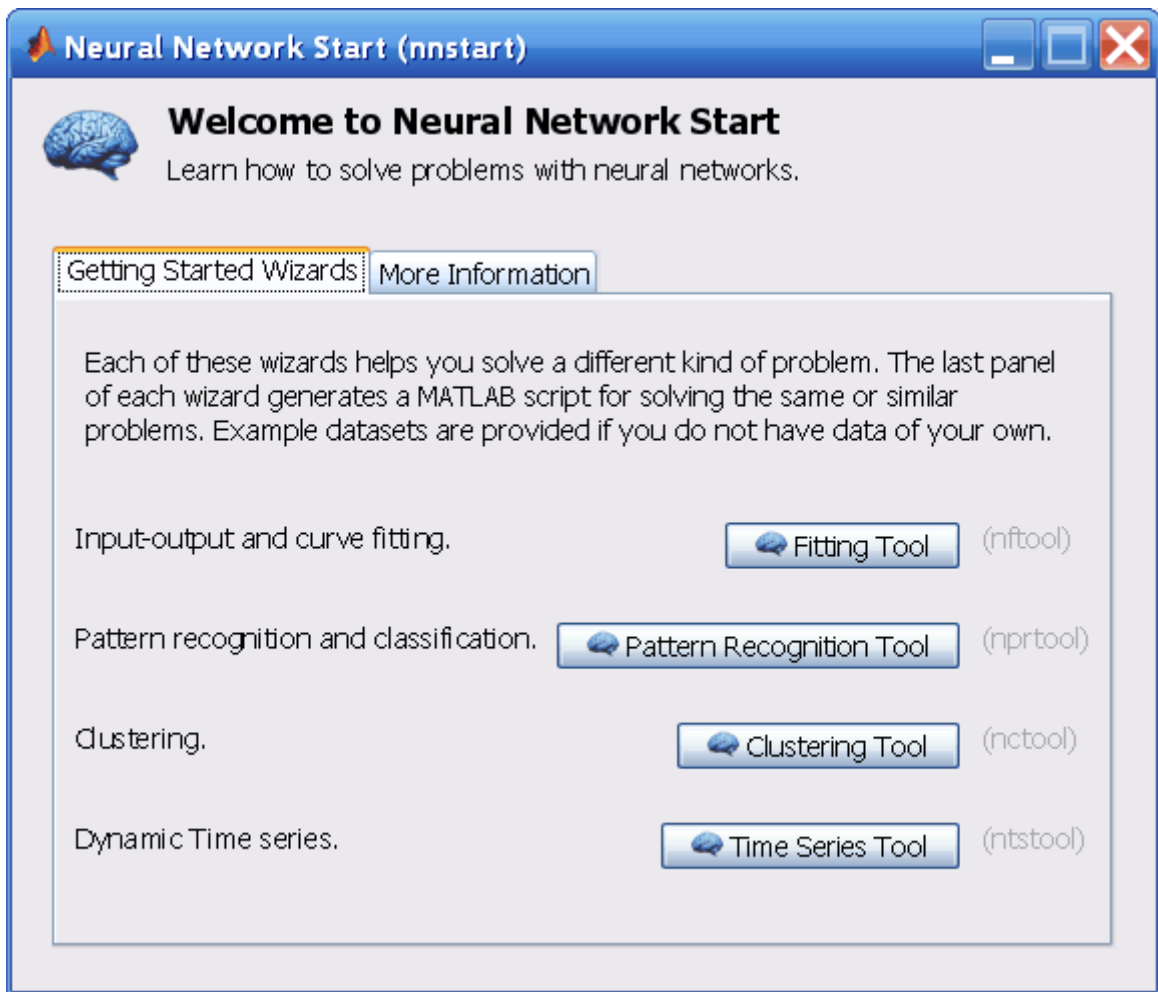
```
targets = {1 2 3 4 5};
```


შემდეგი განყოფილება გვიჩვენებს, თუ როგორ უნდა მოვამზადოთ ქსელი იმისათვის, რომ მოვარგოთ დროითი რიგის მონაცემთა კომპლექსს, GUI -ის გამოყენებით.

GUI -ის გამოყენება

1. საჭიროების შემთხვევაში, გახსენით ნეირონული ქსელის დაწყება (Neural Network Start) GUI ბრძანების გამოყენებით.

nnstart



- დააჭირეთ „ Time Series Tool“ ბრძანებას იმისათვის, რომ გახსნათ Neural Network Time Series Tool . (ასევე შეგიძლიათ გამოიყენოთ ბრძანება ntstool.)

Neural Network Time Series Tool (ntstool)

Welcome to the Neural Network Time Series Tool.
Solve a nonlinear time series problem with a dynamic neural network

Introduction

Prediction is a kind of dynamic filtering, in which past values of one or more time series are used to predict future values. Dynamic neural networks, which include tapped delay lines are used for nonlinear filtering and prediction.

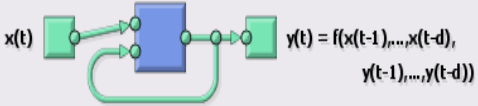
There are many applications for prediction. For example, a financial analyst might want to predict the future value of a stock, bond or other financial instrument. An engineer might want to predict the impending failure of a jet engine.

Predictive models are also used for system identification (or dynamic modelling), in which you build dynamic models of physical systems. These dynamic models are important for analysis, simulation, monitoring and control of a variety of systems, including manufacturing systems, chemical processes, robotics and aerospace systems.

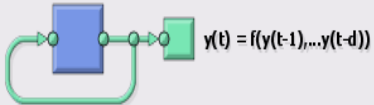
This tool allows you to solve three kinds of nonlinear time series problems shown in the right panel. Choose one and click [Next].

Select a Problem

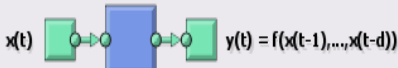
Nonlinear Autoregressive with External (Exogenous) Input (NARX)
Predict series $y(t)$ given d past values of $y(t)$ and another series $x(t)$.



Nonlinear Autoregressive (NAR)
Predict series $y(t)$ given d past values of $y(t)$.



Nonlinear Input-Output
Predict series $y(t)$ given d past values of series $x(t)$.
Important Note: NARX solutions are more accurate than this solution. Only use this solution if past values of $y(t)$ will not be available when deployed.



Choose a problem, then click [Next].

Neural Network Start Welcome Back Next Cancel

შეამჩნევდით, რომ გახსნილი პალაია გამოვიყენოთ სამი სხვადასხვა დროითი რიგის პრობლემის გადასაჭრელად.

- პირველი ტიპის დროითი რიგის პრობლემა, თქვენ გინდათ განსაზღვროთ მომავალი შედეგი $y(t)$ დროითი რიგის წარსული მონაცემებით ამავე დროითი რიგის და წარსული მონაცემები მეორე დროითი რიგის $x(t)$. ამ პროცესის ფორმას ეწოდება არაწრფივი ავტორეგრესიული გარეგანი შემავლებით.

$$y(t) = f(y(t-1), \dots, y(t-d), x(t-1), \dots, (t-d))$$

ეს მოდელი შეიძლება გამოყენებულ იქნას პროცესირებისათვის აქციების ან ობლიგაციების მომავალი ფულადი ღირებულების. ასევე შეიძლება გამოყენებულ იქნას სისტემის იდენტიფიკაციისათვის, რომელშიც მოდელები

იქმნება, რომ წარმოვადგინოთ დინამიური სისტემები, როგორცაა ქიმიური პროცესები, წარმოების სისტემა, რობოტები, კოსმიური მანქანები და ა.შ.

- მეორე ტიპის დროის რიგით პრობლემაში, აქ მხოლოდ ერთი სერიაა ჩართული. მომავალი შედეგები დროითი რიგების $y(t)$ პროგნოზირდება მხოლოდ ამ რიგის წარშული შედეგებით. ამ პროგნოზის ფორმას ეწოდება არაწრფივი ავტორეგრესიული, და შეიძლება ჩაიწეროს შემდეგნაირად:

$$y(t) = f(y(t-1), \dots, y(t-d))$$

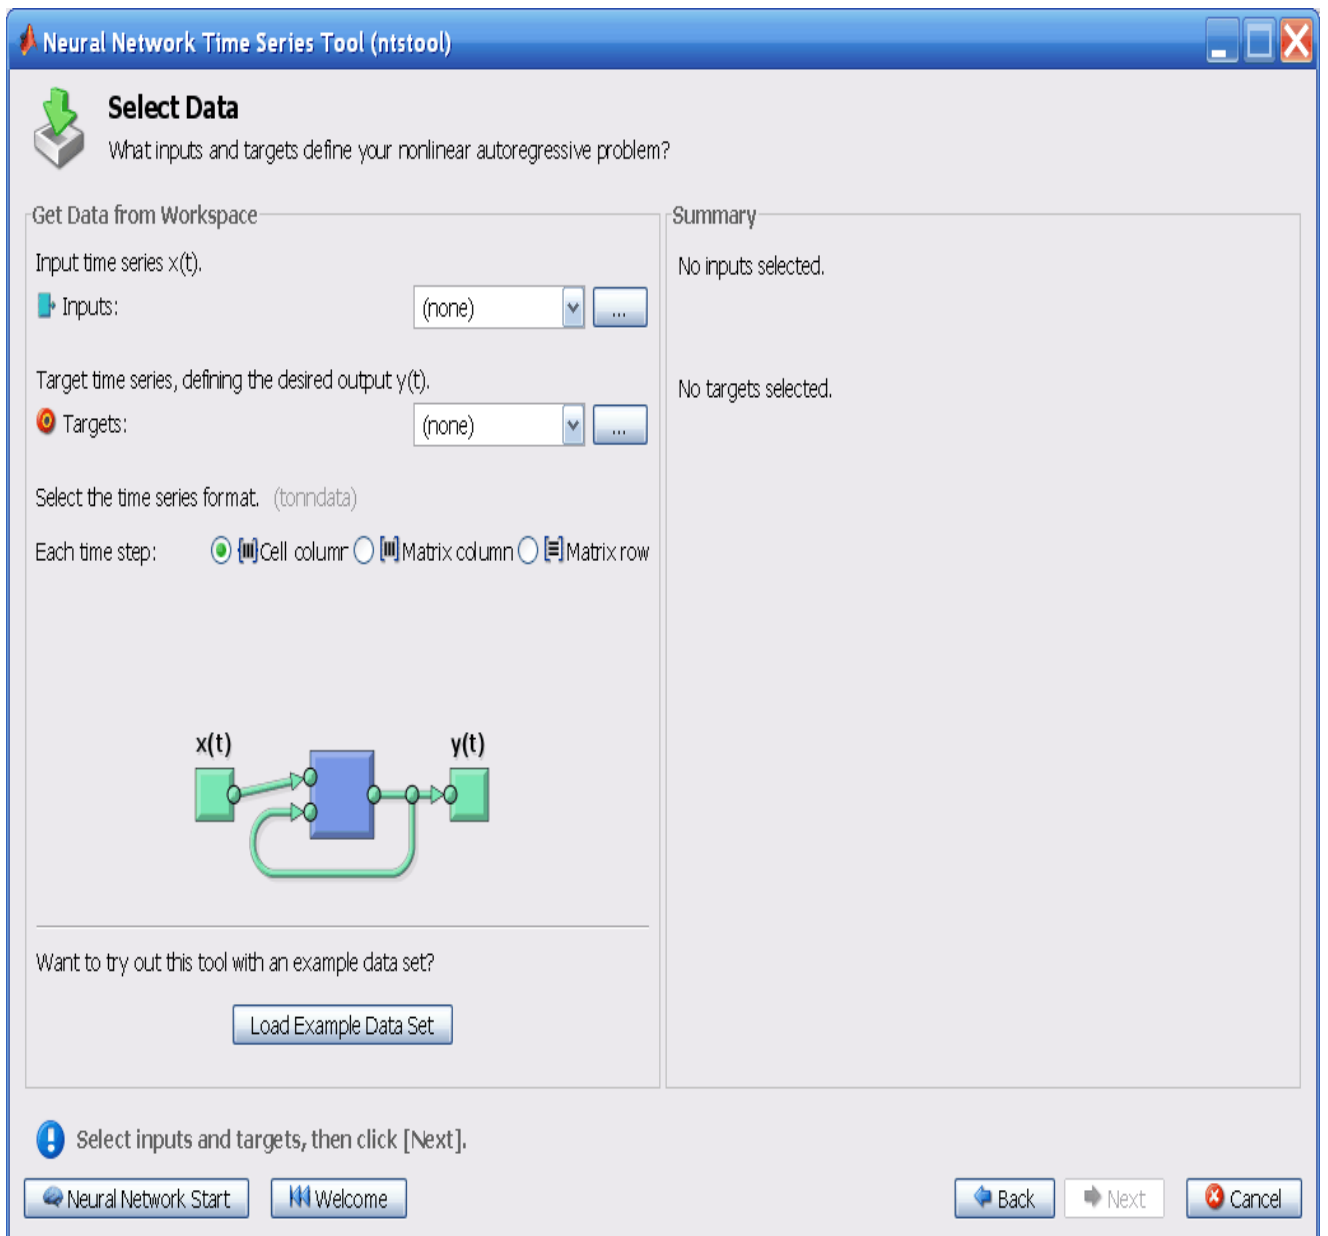
ეს მოდელი ასევე შეიძლება გამოყენებულ იქნას ფინანსული ინსტრუმენტების წინასწარ განსაზღვრისათვის, მაგრამ თანამონაწილე რიგის გამოყენების გარეშე.

- მესამე დროიტი რიგის პრობლემა არის იგივე რაც პიველი ტიპის, ორი რიგი მონაწილეობს, შემავალი რიგი $x(t)$ და გამომავალი რიგი $y(t)$. აქ ჩვენ გვინდა განვსაზღვროთ (პროგნოზირება გავაკეთოთ) $y(t)$ -ის წინა მონაცემებიდან $x(t)$ -სი, მაგრამ $y(t)$ -ს წინა მონაცემების ცოდნის გარეშე.

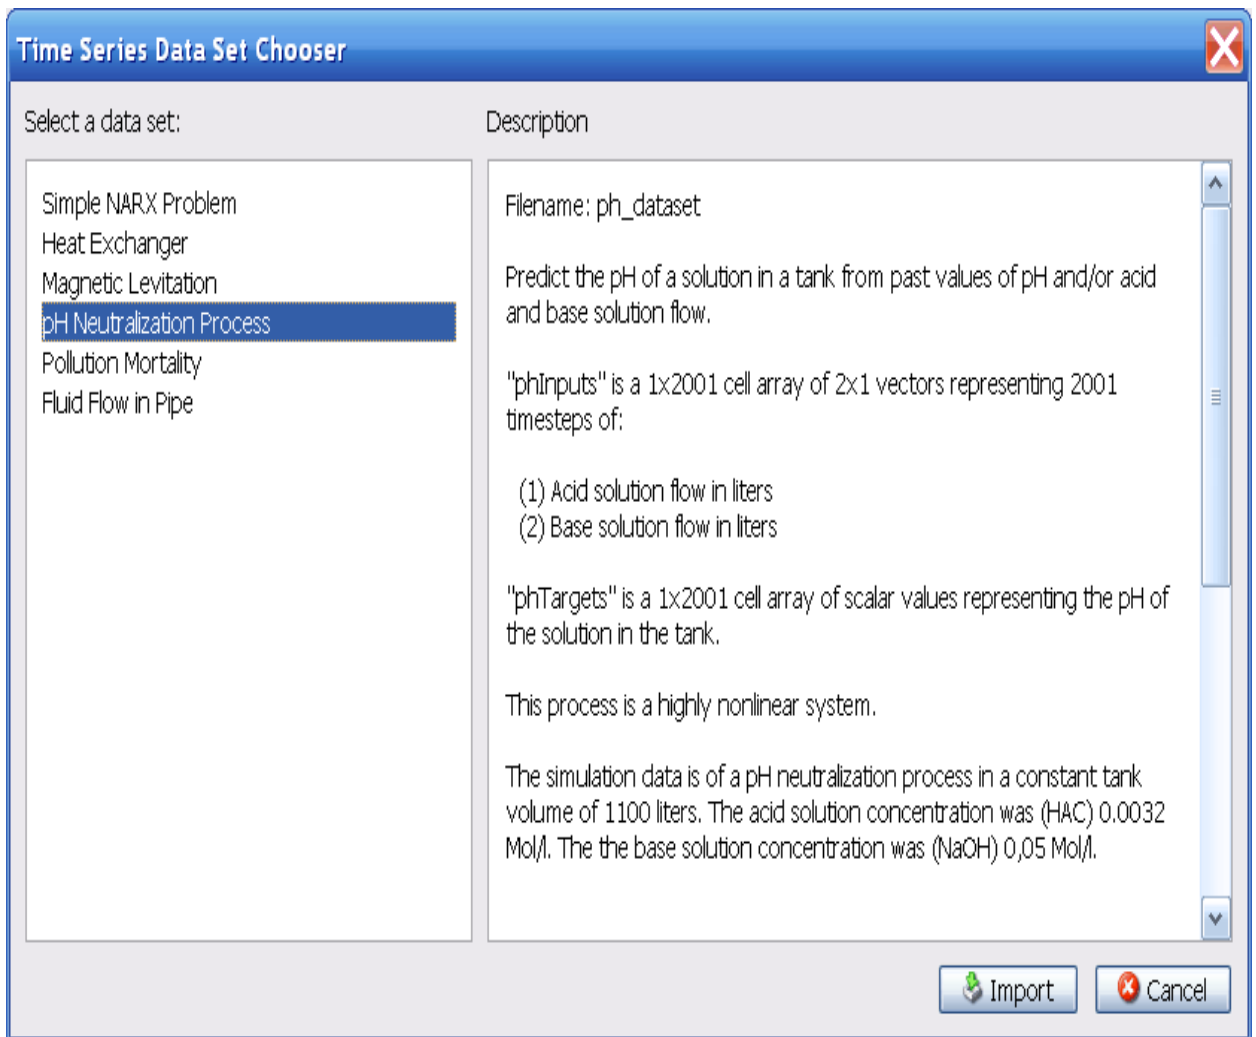
$$y(t) = f(x(t-1), \dots, x(t-d))$$

ამ სამი მოდელის შემთხვევაში საუკეთესო შედეგს მოგვცემს პირველი (NARX) მოდელი, რადგან დიდად დაგვეხმარება $y(t)$ რიგის წინა მონაცემების ცონა და გამოყენება ზუსტი პროგნოზის გაკეთებაში.

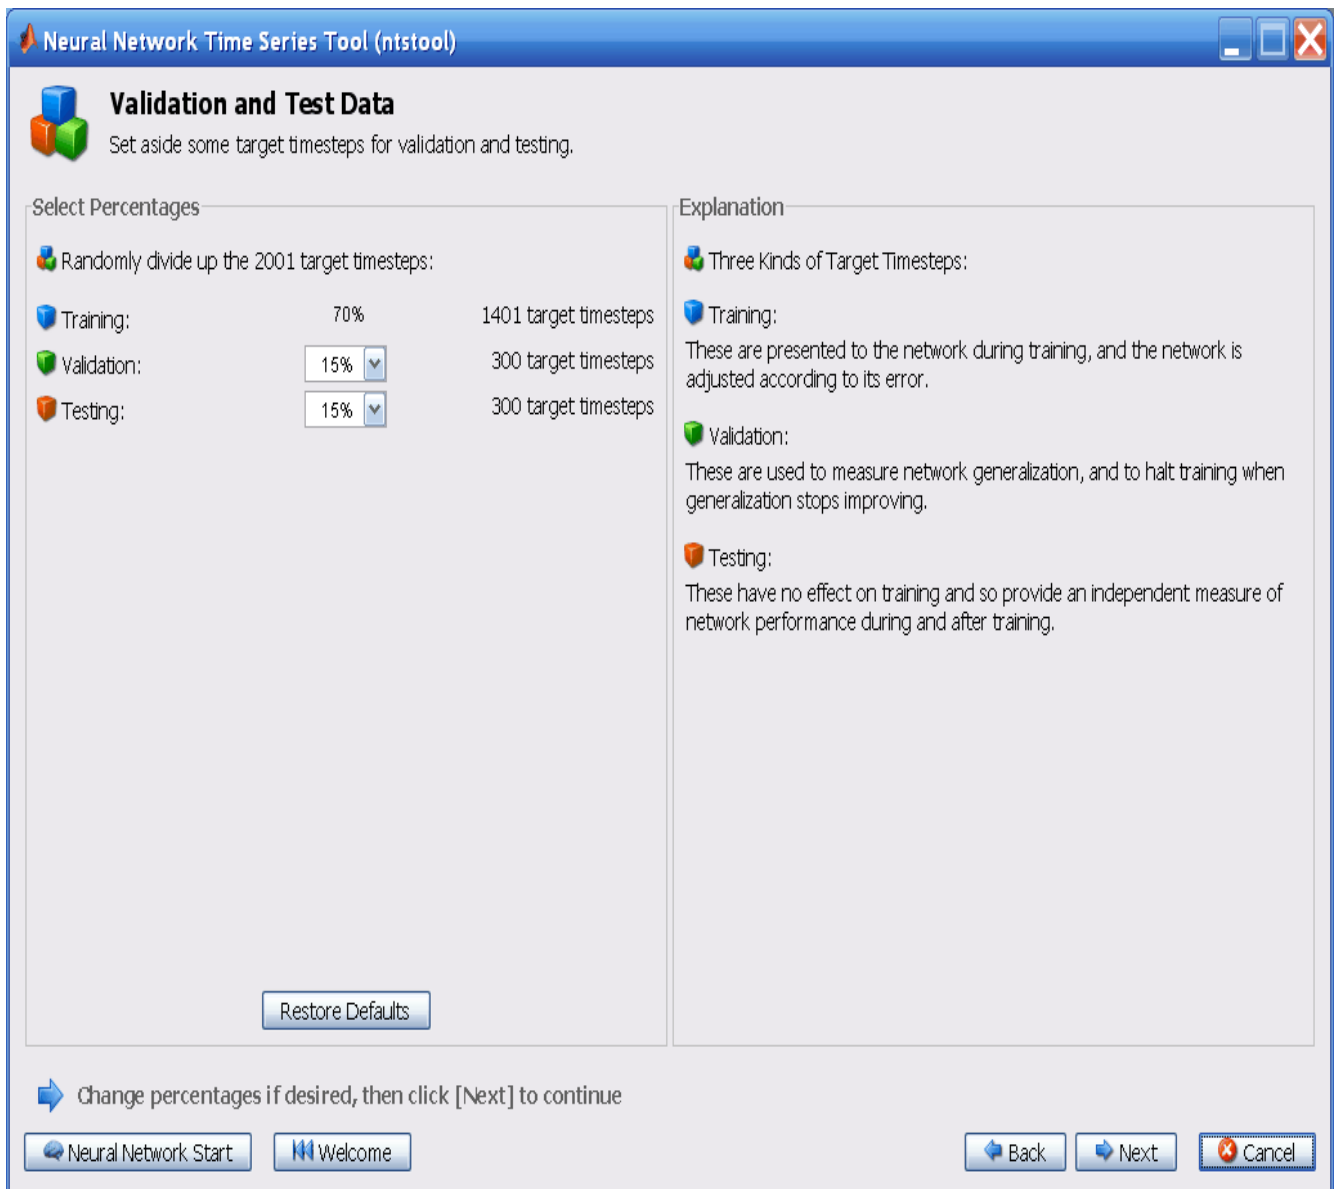
3. ამ მაგალითის გამოყენებით მონიშნეთ NARX მოდელი და დააცვირეთ next -ს.



4. დააჭირეთ “Load Example Data Set” Select Data ფანჯარაში.



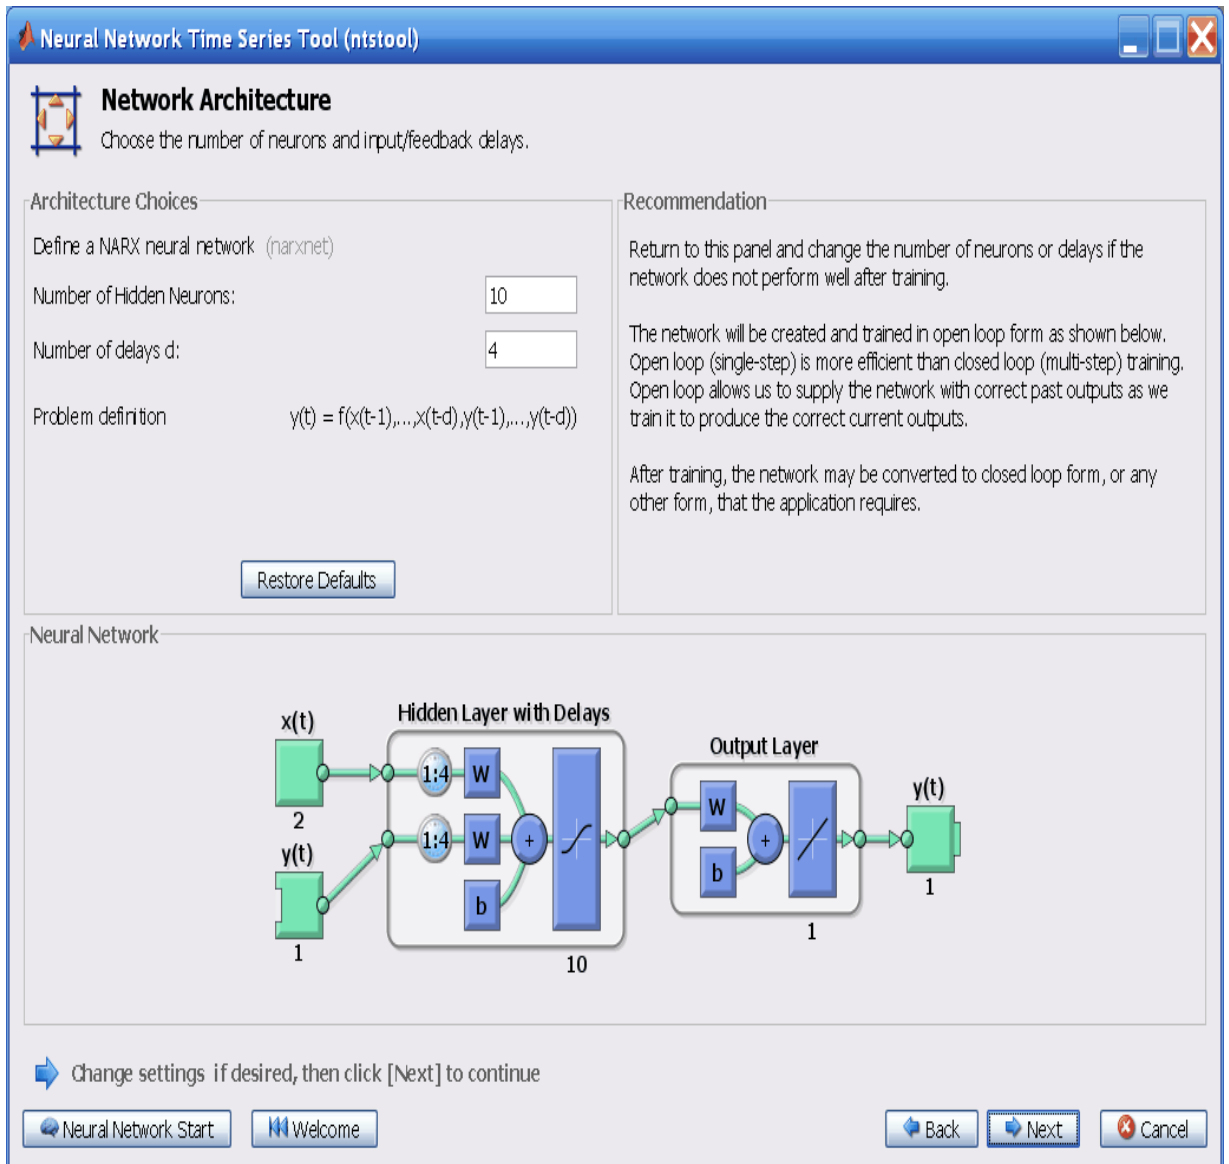
5. აირჩიეთ **pH Neutralization Process** და დააჭირეთ **Import**. ეს დაგაბრუნებთ Select Data ფანჯარაში.
6. დააჭირეთ next რომ გადახვიდეთ Validation and Test Data ფანჯარაში.



ამ პარამეტრების გამოყენებით შემავალი და გამომავალი ვექტორები შემთხვევითი (randomly) იქნებიან დაყოფილი სამ ჯგუფად:

- 70% იქნება გამოყენებული შესწავლისათვის (training)
- 15% გამოიყენება შესამოწმებლად, რომ ქსელი არის განზოგადებული და შეჩერდეს სანამ დაიწყება შესწავლა
- დარჩენილი 15% იქნება გამოყენებული, როგორც სრულიად დამოუკიდებელი ტესტი ქსელის განზოგადების.

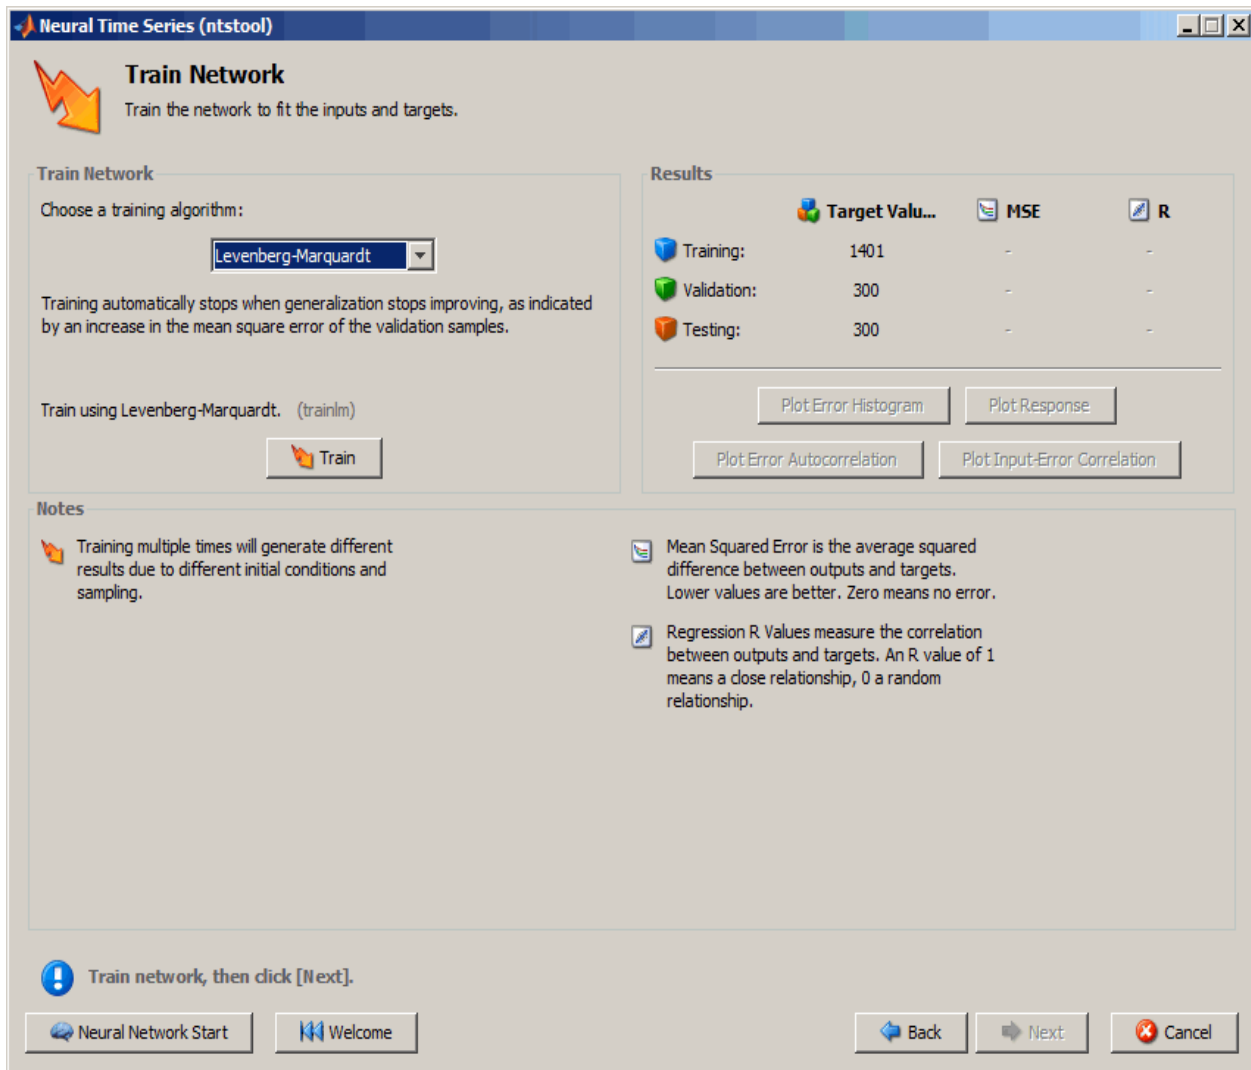
7. დააჭირეთ next



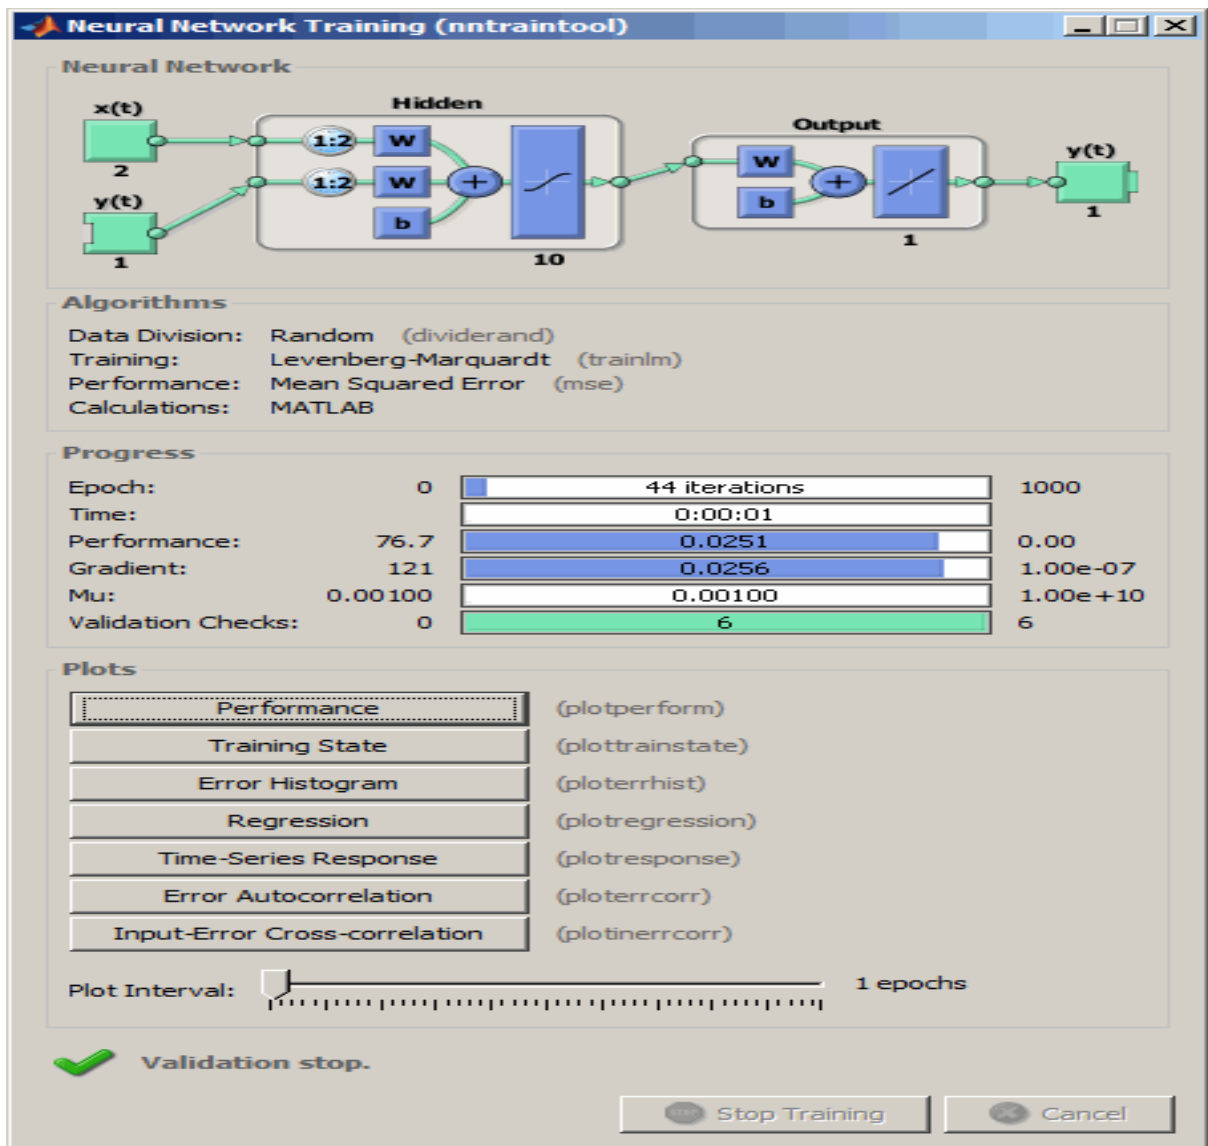
სტანდარტული NARX ქსელი არის ორფენიანი feedforward ქსელი, სიგმოიდური ფუნქციით ფარულ ფენაში და წრფივი გადაცემის ფუნქციით გამოშვალ ფენაში. ეს ქსელი ასევე იყენებს tapped delay lines წინა მონაცემების შესანახად $x(t)$ და $y(t)$ -დან. გაითვალისწინეთ, რომ NARX ქსელით გამოშვალი $y(t)$ ისევ ბრუნდება ქსელის შემავალში, სადა $x(t)$ არის ფუნქცია $x(t-1)$, $x(t-2)$, ..., $x(t-d)$ -ის.

ნაგულისხმები რიცხვი ფარული ფენისა არის 10. ნაგულისხმები შეყოვნებული რიცხვი არის 2. შეცვალეთ ეს მნიშვნელობა 4. თქვენ შეგიძლიათ შეცვალოთ ეს რიცხვები თუ ქსელის შესწავლის წარმოდგენა არის სუსტი.

8. დააჭირეთ next



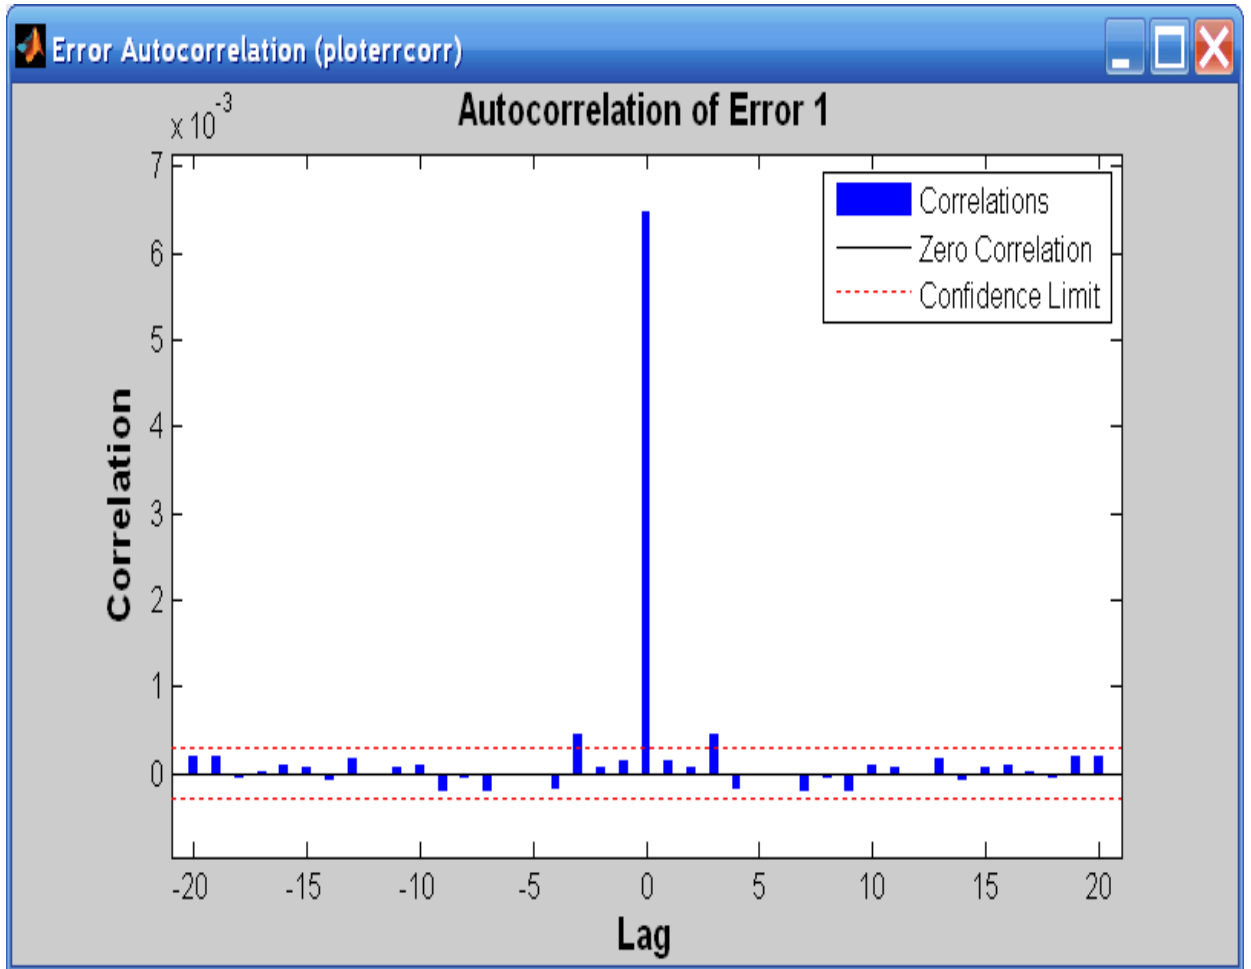
9. აირჩიეთ შემსწავლელი ალგორითმი შემდეგ დააჭირეთ train . Levenberg-Marquardt (trainlm) რეკომენდირებულია უმეტესი პრობლემისათვის, მაგრამ ზოგიერთი პატარა პრობლემისათვის შეგვიძლია გამოვიყენოთ Bayesian Regularization (trainbr), მან შეიძლება წაიღოს ბევრი დრო მაგრამ მივიღოთ საუკეთესო შედეგი. დიდი პრობლემების დროს , Scaled Conjugate Gradient (trainscg) რეკომენდირებული ვინაიდან ის იყენებს გრადიენტის გამოთვლებს , რომელიც უფრო ეფექტურია. ეს მაგალითი გამოიყენებს ნაგულისხმები Levenberg-Marquardt.



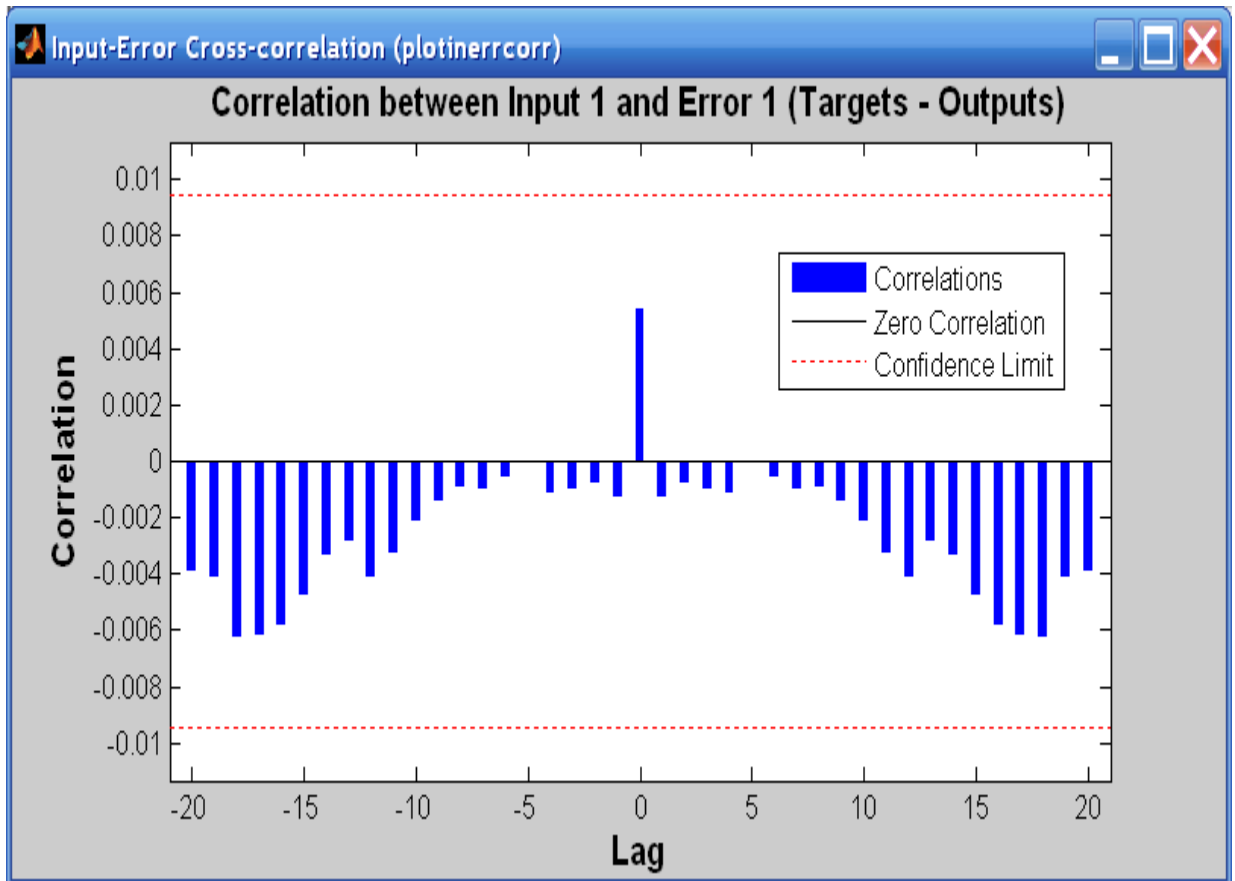
10. **Plots**-ის დაბლა დააჭირეთ **Error Autocorrelation**. ეს გამოიყენება ქსელის მუშაობის შესამოწმებლად.

შემდეგი გრაფიკი გამოსახავს შეცდომის ავტოკორელაციის ფუნქციას. ეს აღწერს თუ როგორ არის შეცდომის პროგნოზი დაკავშირებული დროსთან. პროგნოზის სრული მოდელისათვის უნდა იყოს მხოლოდ ერთი არანულოვანი მნიშვნელობა ავტოკორელაციური ფუნქციის და ეს უნდა მოხდეს ნულოვანი შეყოვნებით. ეს ნიშნავს, რომ პროგნოზი შეცდომების სრულიად შეუთავსებელია ერთმანეთთან. თუ იქ იყო მნიშვნელოვანი შეთავსება შეცდომების პროგნოზში, შემდეგ შესაძლებელი უნდა იყოს პროგნოზის გაუმჯობესების- შესაძლოა delays რიცხვის გაზრდით tapped delay ხაზებში.

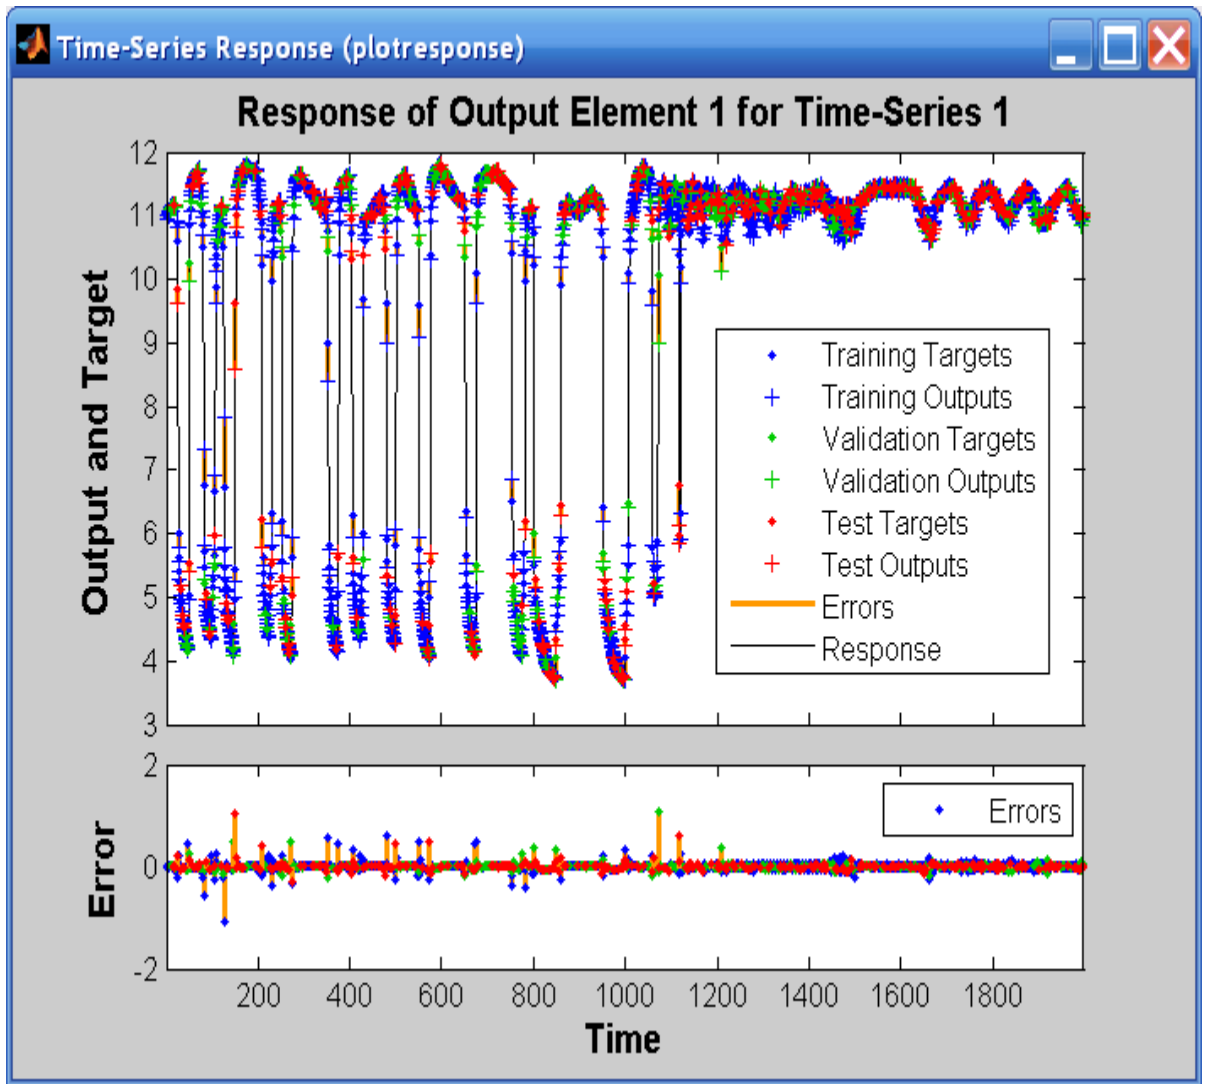
შემდეგ ვაჭერთ **Retrain** ntraintool- ში. ეს შეცვლის დაწყებით წონებს და ქსელის biases და შეიძლება შექმნას გაუმჯობესებული ქსელი გადამზადების შემდეგ.



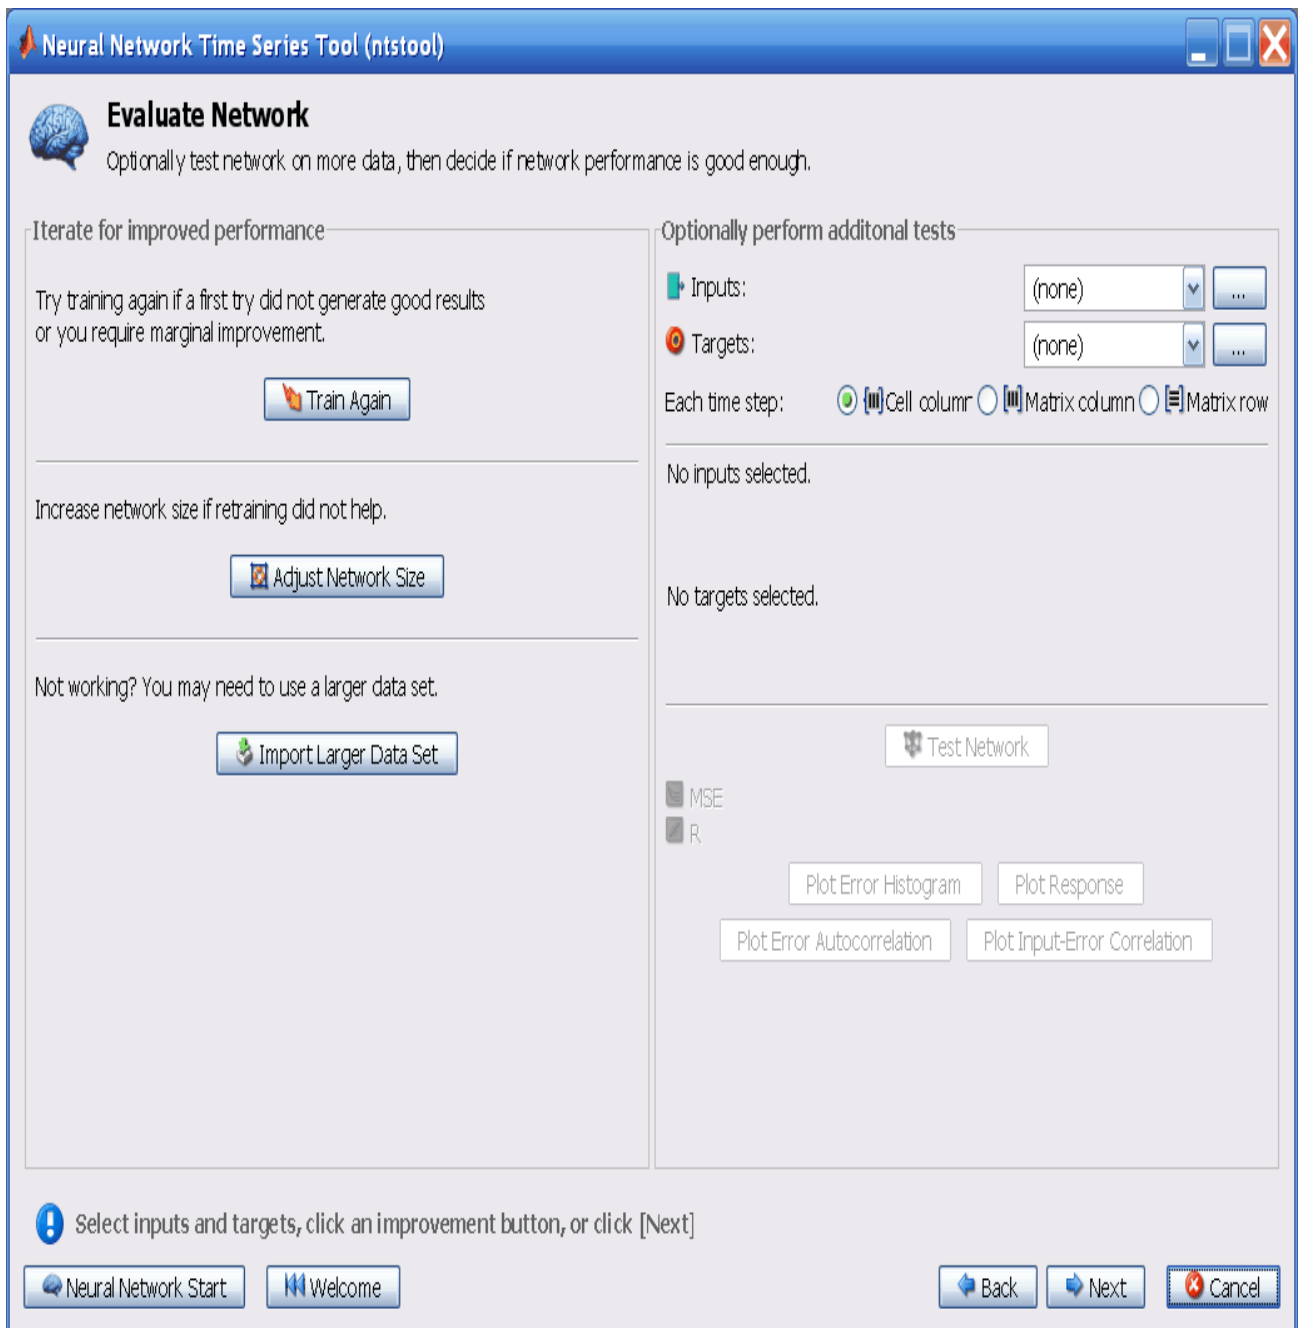
11. ნახეთ შემავალი-შეცდომები გადამკვეთი-კორელაციური ფუნქცია დამატებითი შემოწმებისათვის ქსელის შესრულებისა.



12. Plots -ის დაბლა დააჭირეთ **Time Series Response** ბრძანებას. ეს აჩვენებს შემავლების, გამომავალსა და შეცდომებს დროზე დამოკიდებულად. ის ასევე მიუთითებს დროის რა ნაწილი იყო გამოყოფილი შესწავლისათვის, ტესტირებისათვის და შემოწმებისათვის.



13. დააკორეთ next ბრამანებას Neural Network Time Series Tool -ში რომ შევასდეს ქსელი.



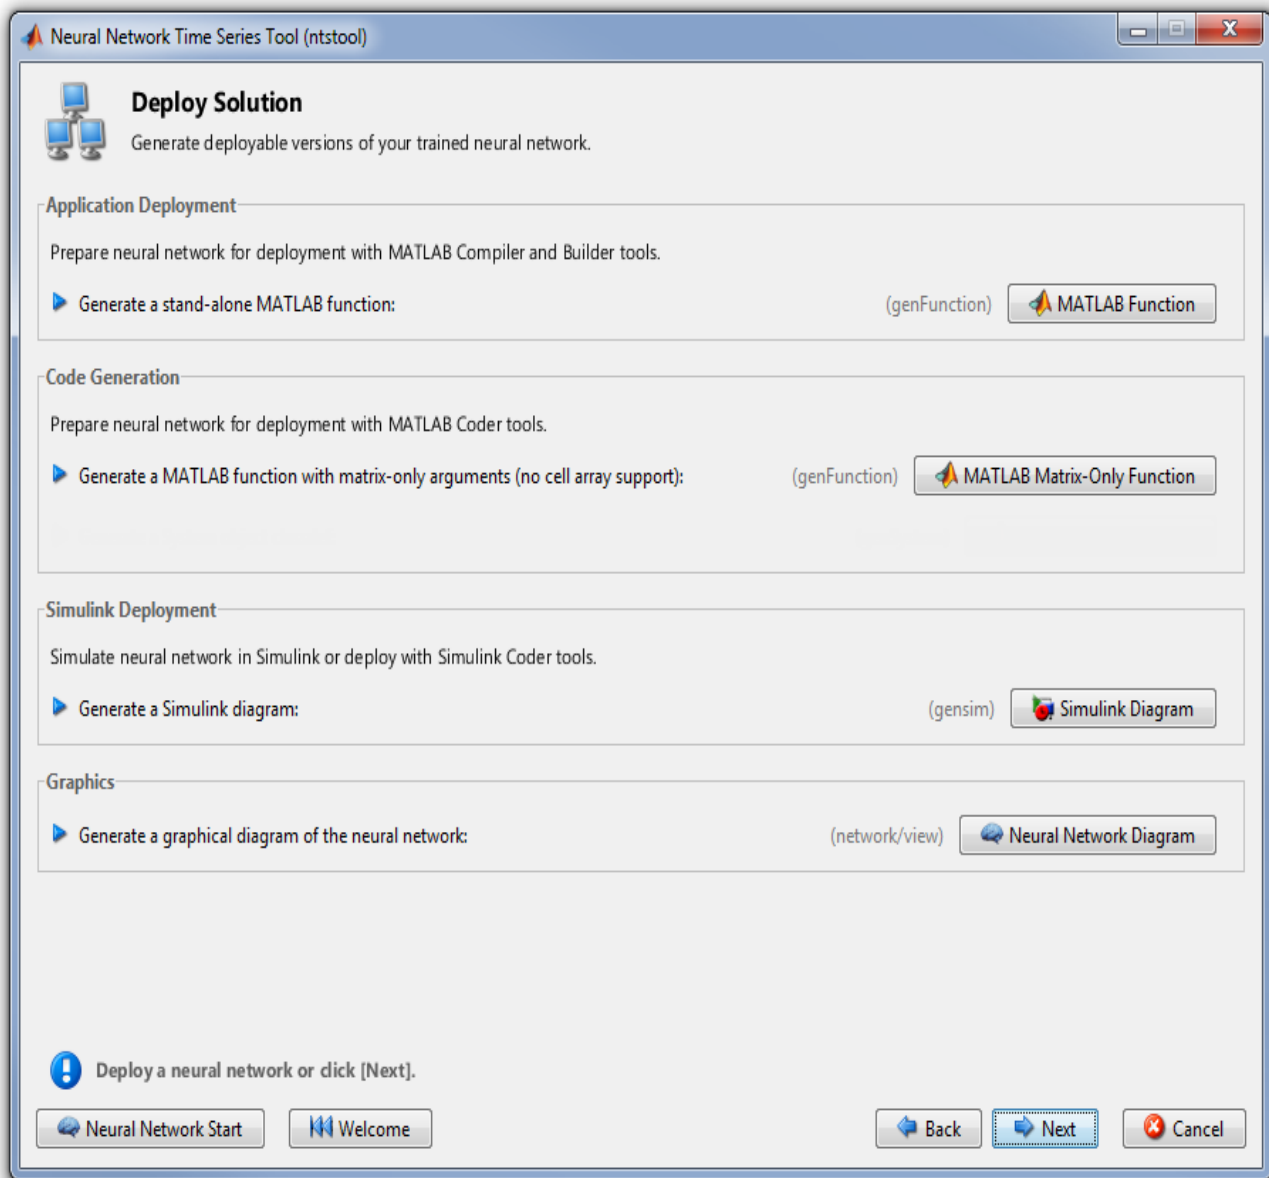
ამ ეტაპზე შეგიძლიათ დატესტოთ ქსელი ახალი მონაცემებით.

თუ თქვენ უკმაყოფილო ხართ ქსელის მუშაობით შეცვანით ან ახალ მონაცემებით, შეგიძლიათ მოიქცეთ შემდეგნაირად:

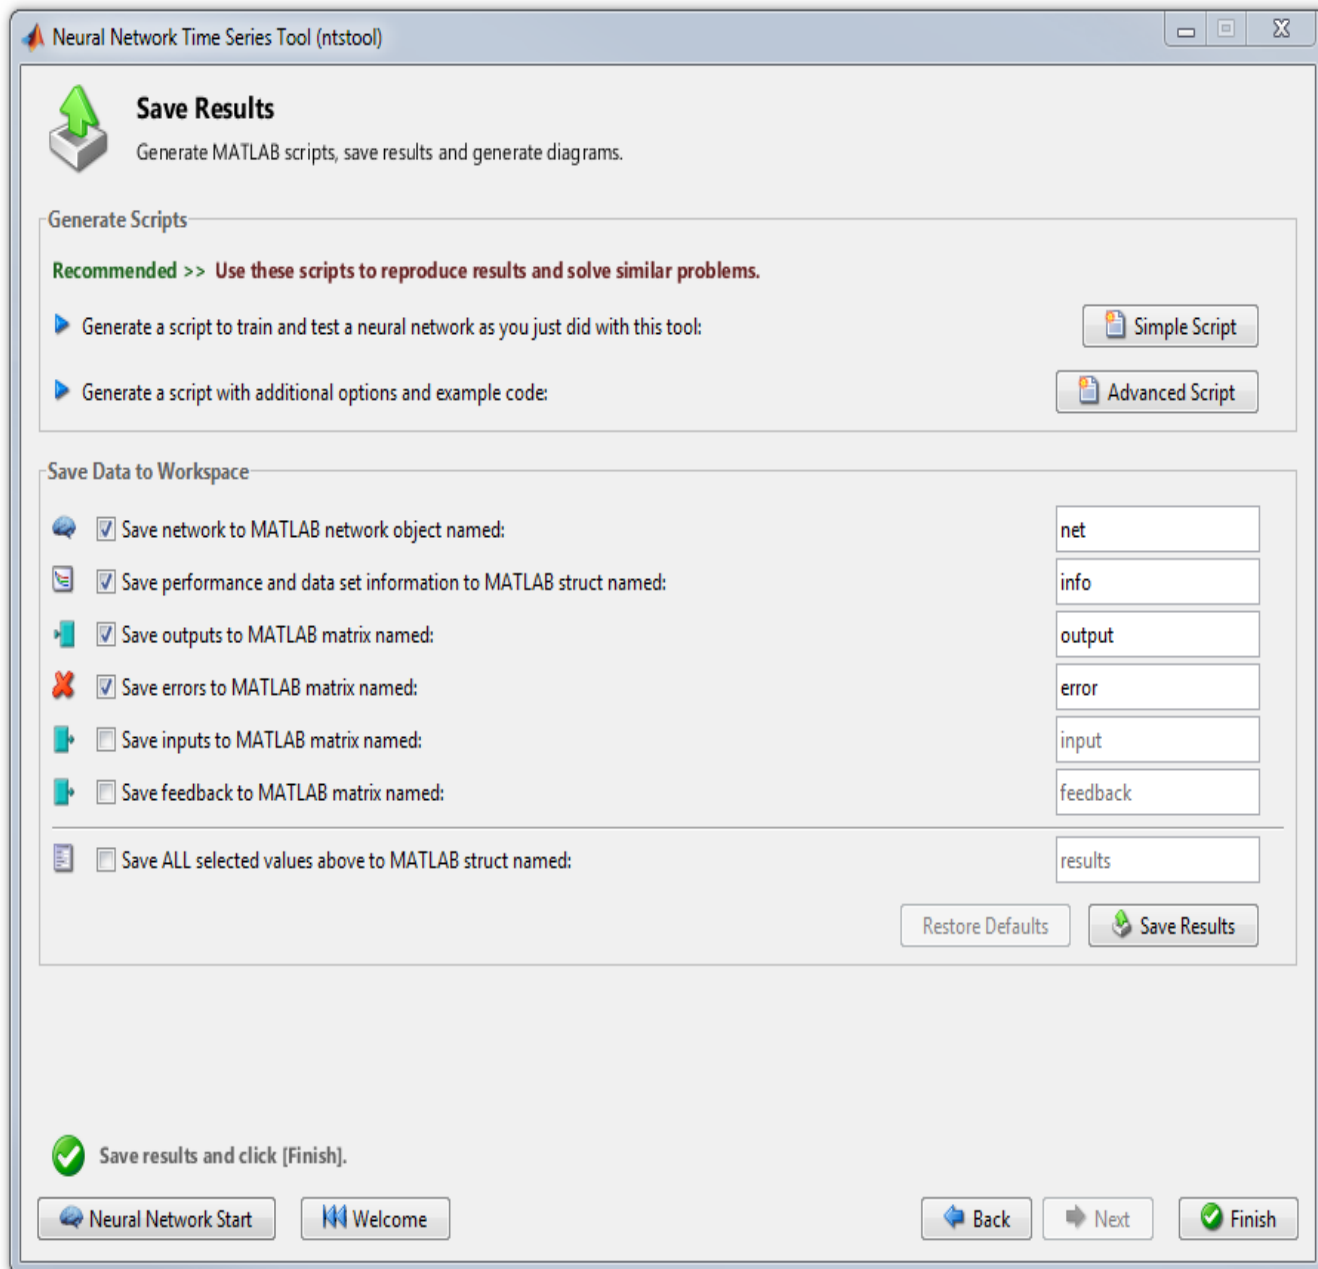
- მოამზადოთ (train) თავიდან
- ნეირონებისა და/ან **delays** რაოდენობის გაზრდა

14. თუ კმაყოფილი ხართ ქსელის მუშაობით, დააჭირეთ next

15. გამოიყენეთ ეს პანელი MATLAB ფუნქციის შესაქმნელად ან Simulink® სქემა თქვენი ნეირონული ქსელის მოდელირებისათვის.



16. გამოიყენებ ღილაკები ეკრანზე რომ გამოაჩინოთ სკრიპტები ან შეინახოთ თქვენი შედეგი.



- შეგიძლიათ დააჭიროთ **Simple Script** ან **Advanced Script** ბრძანებას, რომ შეიქმნას MATLAB -ის კოდი, რომელიც შეიძლება გამოყენებულ იქნას, რომ იმიტირება გაუკეთოთ ყველა გასულ ნაბიჯს command-line _იდან.
- თქვენ ასევე შეგიძლიათ გქონდეთ ქსელი , შენახული როგორც ქსელი სამუშაო ადგილას.

17. MATLAB -ის კოდის შექმნის შემდეგ და შედეგების შენახვის შემდეგ დააჭირეთ **Finish**.

დასკვნა

ამ ნაშრომში ჩვენ შევიმუშავეთ ხელოვნური ნეირონული ქსელის სამედიცინო დიაგნოზი. თუ როგორ შეიძლება გამოვიყენოთ ხელოვნური ნეირონული ქსელი და backpropagation ალგორითმი სამედიცინო დიაგნოსტიკისათვის, კონკრეტულად კინსულტის დიაგნოსტიკისათვის. ხელოვნურმა ნეირონულმა ქსელმა აჩვენა მნიშვნელოვანი შედეგები მონაცემებთან მუშაობაში, რომლებიც წარმოდგენილია სიმპტომებად. შედეგებმა აჩვენა, რომ ნეირონული ქსელის მიერ შეთავაზებული დიაგნოზი შეიძლება იყოს სასარგებლო დაავადებული ადამიანისათვის.

გამოყენებული ლიტერატურა

1. Lela Mirtskhulava „Artificial Neural Network Model in Stroke Diagnosis“
2. Gillian Pearce, Lela Mirtskhulava, „Artificial Neural Network and Mobile Applications in Medical diagnosis „
3. Xing Su, Hanghang Tong, and Ping Ji “Activity Recognition with Smartphone Sensors”
4. <https://mathtasks.wordpress.com>
5. Graeme J. Hankey “**Potential New Risk Factors for Ischemic Stroke: What Is Their Potential?**”
6. S. Thomas Carmichael “Rodent Models of Focal Stroke: Size, Mechanism, and Purpose”

7. Carlos Gershenson “**Artificial Neural Networks for Beginners**”
8. Anita Thakur¹, Surekha Bhanot², S.N.Mishra³^{1,2}Birla Institute of Technology and Science, Pilani, Rajasthan ³Shinas college of Technology, Sultanate of Oman “Early Diagnosis of Ischemia Stroke using Neural Network”