

საქართველოს ტექნიკური უნივერსიტეტი

არჩილ ფრანგიშვილი, ოლეგ ნამიჩიეშვილი

არჩილ ელიზბარაშვილი

ნეირონული ქსელები

(ლექციათა კურსი)



დამტკიცებულია საქართველოს ტექნიკური უნივერსიტეტის სასწავლო-მეთოდური
საბჭოს მიერ

თბილისი «ტექნიკური უნივერსიტეტი» 2007

წიგნში მოცემულია ხელოვნური ნეირონული ქსელების თეორიის საფუძვლები. მის მთავარ ამოცანას წარმოადგენს პრაქტიკული შესავალი ინფორმაციის დამუშავების თანამედროვე მეთოდებში და სისტემებში, რომლებიც სამეცნიერო ლიტერატურაში გაერთიანებულია ტერმინით Computational Neuroscience, აგრეთვე ახალი თაობების გამომოვლელი და საინფორმაციო სისტემების აგების პერსპექტიულ მიდგომათა გაშუქება.

თემის თავისებურება მის სადისციპლინათშორისო ხასიათში ვლინდება. ნეირომეცნიერების ჩამოყალიბებაში თავისი წვლილი მრავალ მეცნიერებას აქვს შეტანილი. ესენია ბიოლოგია და უმაღლესი ნერვული მოქმედების ფიზიოლოგია, აღქმის ფსიქოლოგია, დისკრეტული მათემატიკა, სტატისტიკური ფიზიკა და სინერგეტიკა, აგრეთვე კიბერნეტიკა, და, რა თქმა უნდა, კომპიუტერული მოდელირება.

განკუთვნილია სტუდენტებისათვის, რომლებიც კომპიუტერულ მეცნიერებათა ჩარჩოებში ხელოვნური ნეირონული ქსელების თეორიასა და პრაქტიკულ გამოყენებებს ეუფლებიან ზოგად ასპექტში.

რედაქტორი

პროფ. დავით გორდეზიანი

რეცენზენტები :

პროფ. კონსტანტინე კამკამიძე

პროფ. ჰამლეტ მელაძე

© გამომცემლობა «ტექნიკური უნივერსიტეტი», 2007

6 1404000000

608(06)–02

ISBN 99928-932-8-1

ლექცია 1. შესავალი.

გამოთვლითი (ინფორმატიკული) ნეირომეცნიერების (Computational Neuroscience) საგნის შესავალი. ნეირომეცნიერების სათავეები : ბიოლოგიისა და ფიზიოლოგიის, ფსიქოლოგიის, დისკრეტული მათემატიკის, კიბერნეტიკის, სტატისტიკური ფიზიკისა და სინერგეტიკის მიღწევები. კომპიუტერული მოდელირების როლი. ნეირომეცნიერების ფილოსოფიური საფუძვლები. ისტორიული მიმოხილვა. კურსის სტრუქტურა. სასწავლო და გაცნობითი ხასიათის ლიტერატურა.

«თვალი ჩაუკარით კომპიუტერს და იგი მიგიხვდებათ». გასული საუკუნის 90-ანი წლების დასაწყისში ასეთი სათაურით უძველეს და პატივისცემ გაზეთ «New York Times»-ში გაჩნდა სტატია, რომელიც მოუთხრობდა მკითხველს თანამედროვე მიღწევებისა და მიმართულებების შესახებ ინტელექტუალური კომპიუტერული სისტემების სფეროში. ამ მიმართულების განვითარების მაგისტრალურ გზათა შორის გამოცემის ექსპერტებმა გამოყვეს :

- ინფორმაციის დამუშავების პარალელიზმის მაღალი ხარისხის მქონე კომპიუტერები, რომლებსაც შეუძლია ამა თუ იმ ამოცანის დაყოფა ნაწილებად და მათი ერთდროულად დამუშავება, რაც საბოლოო ჯამში მნიშვნელოვნად ამცირებს გამოთვლათა საერთო დროს ;
- კომპიუტერები, რომლებშიც ინფორმაციის გადასაცემად ოპტიკა გამოიყენება, ელექტრონული სიგნალების ნაცვლად. ოპტიკური სიგნალების გამოყენება უკვე დაწყებულია მონაცემთა გადასაცემად კომპიუტერებს შორის ;
- კომპიუტერები ნეირონული ქსელებით, რომლებიც ჩვენი თანამედროვე შეხედულებების თანახმად მოქმედ ტვინთან ანალოგიით მომუშავე მანქანებს წარმოადგენს.

სწორედ ეს უკანასკნელი, მესამე, მიმართულება, რომელიც არსებითად პირველ ორს ეყრდნობა, ლექციათა წინამდებარე კურსის ძირითად თემას წარმოადგენს. ამასთან ერთად, ყურადღება გამახვილებულია ხელოვნური ნეირონული ქსელების მიმართულების მხოლოდ ერთ სფეროზე, სახელდობრ, ნეიროინფორმატიკაზე - მეცნიერებაზე, რომელიც შეისწავლის ინფორმაციის კომპიუტერებით დამუშავებას ნეირონის მსგავსი ხერხებით.

სხვადასხვა დიაგნოსტიკური ინფორმაციის ნაირნაირობას (მრავალფეროვნებას), დიდ მოცულობასა და წინააღმდეგობრიობას წინა პლანზე გამოაქვს ასეთი ინფორმაციის დამუშავების შემძლე ფიზიკური სისტემების ძებნის პრობლემა. ამ კომპლექსური ამოცანის ამოხსნა მჭიდროდაა დაკავშირებული ახალ საინფორმაციო ტექნოლოგიებთან, რომელთა შორის მნიშვნელოვანი ადგილი უკავია სახეთა გამოცნობისა და კატეგორიზაციის მეთოდებს. ნეირონული ქსელები – მძლავრი და სადღეისოდ, ალბათ, საუკეთესო მეთოდია სახეთა გამოცნობის ამოცანათა გადასაწყვეტად სიტუაციებში, როცა ექსპერიმენტულ მონაცემებს ინფორმაციის მნიშვნელოვანი ფრაგმენტები აკლია, ხოლო არსებული ინფორმაცია უკიდურესად დამახინჯებულია. პარალელურობის მაღალი ხარისხი, რომელიც ნეიროსისტემათა აგებისას ადვილად განსახორციელებელია, ოპერატორისათვის მიუღწეველი მოცულობის ინფორმაციის დამუშავებას უზრუნველყოფს დროის ისეთ შუალედებში, რომლებიც გავრძობა დასაშვებ ხანგრძლივობაზე ნაკლებია ან მათი შესაღარიბია.

ოთხმოციანი წლების მიჯნაზე მნიშვნელოვან შედეგებს მიაღწიეს სრულიად ახალგაზრდა სინერგეტიკაში - არაწონასწორულ სისტემათა თვითორგანიზაციის შემსწავლელ მეცნიერებაში. სისტემატიზება ჩაუტარდა ფაქტებს და ჩატარდა მრავალრიცხოვანი ახალი ექსპერიმენტი ნეიროფიზიოლოგიაში, სახელდობრ, დაწვრილებით გაირკვა ცალკეულ ნეორონთა აგებულება და მოქმედების მექანიზმი ; ჩამოყალიბდა მუშაობის პრინციპი და შეიქმნა პირველი ელექტრონული გამომთვლელი მანქანა პარალელური არქიტექტურით. ეტყობა, ამ გარემოებამ ნეირონული ქსელების ინტენსიურ კვლევასაც შეუწყო ხელი ასოციაციური მექანიზმების მოდელთა როლში.

ფართო ინტერესი ნეირონული ქსელების მიმართ ჰოპფილდის (Hopfield J.J., 1982) ნაშრომის გამოქვეყნების შემდეგ გაჩნდა, რომელმაც უჩვენა, რომ იზინგის (Ernst Ising, 1900–1998, გერმანელი და ამერიკელი ფიზი-

კოსი და მათემატიკოსი) ნეირონებთან¹ დაკავშირებული ამოცანა შეიძლება დავეყვანოთ რიგი ისეთი მოდელის განზოგადებაზე, რომელიც იმ მომენტი-სათვის იყო შესწავლილი მოუწესრიგებელ სისტემათა ფიზიკაში. ჰოპფელდის ქსელის მუშაობა (რომელიც დაწვრილებით ფიზიკურ ლიტერატურაში განიხილება) მდგომარეობს ორობითი კოდების მატრიცის საწყისი «სპინური პორტრეტის» რელაქსაციაში ერთ-ერთ სტაციონარულ მდგომარეობამდე. ნებისმიერი ასეთი მდგომარეობა სწავლების წესით (ჰების წესით) განისაზღვრება. ამრიგად, მოცემული ქსელი გამოცნობის ამოცანებისათვის შეიძლება გამოვიყენოთ.

1986 წელს გამოვიდა რუმელჰარტის, ჰინტონისა და ვილიამსის (Rumelhart D.E., Hinton G.E., Williams R.J., 1986) ნაშრომი, რომელიც შეიცავდა პასუხს ხანგრძლივი დროის განმავლობაში ნეირონიფორმატიკის განვითარების შემაფერხებელ შეკითხვაზე: როგორ მიმდინარეობს იერარქიული ფენოვანი ნეირონული ქსელების სწავლება, რომლებისთვისაც ჯერ კიდევ გასული საუკუნის ორმოციან-ორმოცდაათიან წლებში «კლასიკოსების» მიერ დამტკიცებული იყო უნივერსალობა ამოცანათა ფართო კლასისათვის? მომდევნო წლებში ჰინტონის მიერ წამოყენებულმა შეცდომათა შექცეული გავრცელების ალგორითმა უამრავი ცვლილება განიცადა.

არსებული ალგორითმები ხასიათდება დამუშავების დეტალიზაციის სხვადასხვა ხარისხით, მათი პარალელური რეალიზების შესაძლებლობით, აგრეთვე აპარატული შესრულების არსებობით. ამ ალგორითმების ასეთი ნაირ-ნაირობა და მრავალფეროვნება უზრუნველყოფს სხვადასხვა მეთოდების შედარებითი მახასიათებლების მიხედვით გამოკვლევის განსაკუთრებულ აქტუალობას.

ამჟამად ნეირომეტნიერება სიჭაბუკის მდგომარეობიდან მოწიფულობაში გადადის. ნეირონული ქსელების თეორიაში და გამოყენებებში განვითარება მრავალი სხვადასხვა მიმართულებით მიდის: ხორციელდება ახალი არა-წრფივი ელემენტების ძებნა, რომლებსაც რთული კოლექტიური ქცევის რეალიზება შეეძლება ნეირონთა ანსამბლში, პროექტდება ნეირონული ქსელები ახალი არქიტექტურით, მიმდინარეობს გამოყენების სფეროების ძებნა გამოსახულებათა დამუშავების, სახეთა და მეტყველების გარჩევის სისტე-

¹ არსებობს განსაკვივრებელი ანალოგია ჰოპფელდის ქსელებსა და იზინგის მაგნიტურ სპინურ სისტემათა მოდელს შორის.

მეზში, რობოტულ ტექნიკაში და სხვ. მნიშვნელოვანი ადგილი მოცემულ გამოკვლევებში ტრადიციულად მათემატიკურ მოდელირებას უკავია.

ნეირონული ქსელებისა და მათ საფუძველზე აგებული გამომთვლელი სისტემების თეორიაში სისტემატური კურსის დაწერის აუცილებლობა, უმთავრესად, განისაზღვრება სამამულო სასწავლო მონოგრაფიების არარსებობით ამ თემაზე. გარდა ამისა, ამ თემას ჯერ არ დაუკავებია თავისი ადგილი ქართული უნივერსიტეტების ტრადიციულ კურსებს შორის. და, მიუხედავად იმისა, რომ ამერიკის პერსპექტიულ გამოკვლევათა სამმართველოს (DARPA) სამრეწველო ექსპერტები ვარაუდობენ ახალი ნეიროქსელური ტექნოლოგიების მასობრივი გავრცელების დაწყებას ახალ ათასწლეულში, მსოფლიოს საინფორმაციო ინდუსტრიაში ნეირონული ქსელების თეორიული გაგებისა და პრაქტიკული გამოყენების უკვე დღევანდელი დონე სულ უფრო აშკარად მოითხოვს პროფესიულ ცოდნას ამ სფეროში.

მოცემული კურსის მთავარ ამოცანას წარმოადგენს პრაქტიკული შესავალი ინფორმაციის დამუშავების თანამედროვე მეთოდებში და სისტემებში, რომლებიც სამეცნიერო ლიტერატურაში გაერთიანებულია ტერმინით Computational Neuroscience (გამოთვლითი, ინფორმატიკული ნეირომეცნიერება), აგრეთვე ახალი თაობების გამომთვლელი და საინფორმაციო სისტემების აგების პერსპექტიულ მიდგომათა გაშუქება. განსახილველი თემის თავისებურება მის სადისციპლინათშორისო ხასიათში ვლინდება. ნეირომეცნიერების ჩამოყალიბებაში თავისი წვლილი მრავალ მეცნიერებას აქვს შეტანილი. ესენია ბიოლოგია და უმაღლესი ნერვული მოქმედების ფიზიოლოგია, აღქმის ფსიქოლოგია, დისკრეტული მათემატიკა, სტატისტიკური ფიზიკა და სინერგეტიკა, და, რა თქმა უნდა, კიბერნეტიკა, და, რა თქმა უნდა, კომპიუტერული მოდელირება.

ლექციები შეიცავს ძირითად ინფორმაციას ბუნებრივი (ბიოლოგიური) ნეირონული ქსელებისა და მათი მათემატიკური მოდელის – ხელოვნური ნეირონული ქსელების – ორგანიზაციის პრინციპების შესახებ. ეს ინფორმაცია აუცილებელია ნეიროქსელური ალგორითმების სინთეზისათვის პრაქტიკულ ამოცანათა გადასაწყვეტად. ამ მიზნით ნაშრომში შეტანილია ორი შესავალი თემა მათემატიკური (ლექცია 2) და ბიოლოგიური (ლექცია 3) ცნობებით. კურსის ფორმალური მათემატიკური შიგთავსი დაყვანილია მინიმუმამდე. იგი წარფივი ალგებრისა და დიფერენციალური განტოლებების საბაზო ცოდნას ეყრდნობა. ამიტომ ლექციათა კურსს რეკომენდაცია შეი-

ძლება გაეწიოს გამოსაყენებლად საინჟინრო სპეციალობების სტუდენტებისათვის, აგრეთვე გამოყენებითი მიმართულებების მათემატიკოსებისათვის და პროგრამისტებისათვის.

კურსის ძირითადი შინაარსი

- შესავალი, ცნობები ბიოლოგიიდან, უმაღლესი ნერვული მოქმედების ფიზიოლოგიიდან, ფსიქოლოგიიდან, კიბერნეტიკიდან, სტატისტიკური ფიზიკიდან და დისკრეტული მათემატიკიდან ;
- ბიოლოგიური ნეირონი და მისი მათემატიკური მოდელი ;
- პერსპექტივები, წრფივი განცალკევებადობა და როზენბლატის თეორემა სწავლების შესახებ ;
- ნეირონული ქსელის სწავლება როგორც კომბინატორული ობტიმიზაციის ამოცანა ;
- ჰების წესი, ჰოპფილდის მოდელი და მისი განზოგადება ;
- იერარქიული ნეირონული ქსელები ;
- შეცდომათა შექცეული გავრცელების ალგორითმი ;
- ლიპმან-ჰემინგის, ჰეტ-ნილსენის, კოსკოს მოდელები ;
- ნეირონულ ქსელებში ინფორმაციის წარმოდგენის წესები (ხერხები, მეთოდები) ;
- თანამედროვე ნეიროქსელური არქიტექტურები, ფუკუშიმას კოგნიტრონი და ნეოკოგნიტრონი ;
- ადაპტური რეზონანსის თეორია ;
- გენეტიკური ძებნის ალგორითმები ნეირონული ქსელების ტოპოლოგიის ასაგებად და სწავლებისათვის ;
- ადაპტური კლასტერული ანალიზი და კოჰონენის თვითორგანიზაციის რუკა (ბარათი) ;
- სასრული ავტომატები და ნეირონული ქსელები ;
- დასკვნა – ნეირომეცნიერების დღევანდლობა, მეექვსე თაობის ნეიროკომპიუტერები, ნეიროპროცესორები, მათემატიკური უზრუნველყოფა, მეცნიერული და კომერციული გამოყენებანი.

ლიტერატურა

ა. ძირითადი

1. Warren Sturgis McCulloch and Walter Pitts. *A logical calculus of the ideas immanent in nervous activity*. **Bulletin of Mathematical Biophysics**, 5:115-133, 1943.
2. Franck Rosenblatt. *The Perceptron : probabilistic model for information storage and organization in the brain*. **Psychological Review**, 65:386-408, 1958.
3. Marvin Lee Minsky and Seymour Papert. *Perceptrons : an introduction to computational geometry*. **MIT Press**, Cambridge, Expanded Edition, 1988.
4. John Joseph Hopfield. *Neural networks and physical systems with emergent collective computational abilities*. **Proceedings of the National Academy of Sciences**, 79:2554-2558, 1982.
5. Y. Le Cun. *Une procédure d'apprentissage pour réseau à seuil asymétrique*. **COGNITIVA 85**, Paris, 4-7 Juin, 1985.
6. D. E. Rumelhart and J. L. Mc Clelland. *Parallel Distributed Processing: Exploration in the MicroStructure of Cognition*. **MIT Press**, Cambridge, 1986.
7. J. A. Anderson and E. Rosenfeld. *Neuro Computing Foundations of Research*. **MIT Press**, Cambridge, 1988.
8. Tom Mitchell. *Machine Learning*. **McGraw-Hill Science**, 1997.

ბ. დამატებითი

1. Léon Personnaz, Isabelle Rivals. *Réseaux de neurones formels pour la modélisation, la commande et la classification*, CNRS Éditions, 2003.
2. Richard P. Lippman. *An Introduction to Computing with Neural Nets*, **IEEE ASSP Magazine**, April 1987, p. 4-22.
3. Gérard Dreyfus, Jean-Marc Martinez, Manuel Samuelides, Mirta Gordon, Fouad Badran, Sylvie Thiria, Laurent Héroult. «Réseaux de neurones, méthodologie et applications», Eyrolles, 2ème édition, 2004.
4. Simon Haykin. «Neural Networks : A Comprehensive Foundation», Second Edition, Prentice Hall, 1998.
5. Christopher M. Bishop. «Neural Networks for Pattern Recognition», Oxford University Press, 1995.
6. Ben Kröse, Patrick van der Smagt. «An Introduction to Neural Networks», Eighth Edition, University of Amsterdam, 1996. (იხ. web-ზე).

ლექცია 2. ცნობები უმაღლესი მათემატიკიდან.

ვექტორული სივრცე. ბაზისი. ორთოგონალური პროექციები. ჰიპერსფეროები და ჰიპერზელაბირები. მატრიცები. წრფივი გარდასახვები.


ნეირონული ქსელების აღწერისათვის მათემატიკურ ენად ტრადიციულად ვექტორული და მატრიცული ალგებრის აპარატი გამოიყენება. ვზღუდავთ რა – თხრობის მაქსიმალური სიმარტივის მისაღწევად – ზოგადმათემატიკური ცნობების ნაკრებს მხოლოდ ამ აპარატით, გვინდა აღვნიშნოთ, რომ თანამედროვე ნეირომეცნიერებაში მათემატიკის სხვა განყოფილებებიც ფართოდ გამოიყენება. მათ შორისაა დიფერენციალური განტოლებები, რომლებიც იხმარება ნეირონული ქსელების გასაანალიზებლად უწყვეტ დროში, აგრეთვე ნეირონის დაწვრილებითი მოდელების ასაგებად ; ფურიე ანალიზი სისტემის ქცევის აღწერისათვის კოდირებისას სინშირულ არეში ; ოპტიმიზაციის თეორია სწავლების ალგორითმების შექმნის საფუძვლად ; მათემატიკური ლოგიკა და ბულის ალგებრა ბინარული (ორობითი) ქსელების შესასწავლად და სხვა. ამ ლექციაში გადმოცემული მასალა საცნობო ხასიათს ატარებს და სისრულეზე პრეტენზიას არ აცხადებს. ამომწურავი ცნობები თეორიიდან განტმახერის წიგნში შეიძლება მოინახოს, აგრეთვე წრფივი ალგებრისა და ანალიზური გეომეტრიის სტანდარტულ კურსებში.

ვექტორული სივრცეები.


ძირითად სტრუქტურულ ელემენტს ნეირონული ქსელით ინფორმაციის დამუშავების აღწერაში წარმოადგენს ვექტორი – ვექტორის კომპონენტებად წოდებული რიცხვების მოწესრიგებული ნაკრები. შემდგომ ვექტორები ლათინური (a, b, c, x) ასოებით იქნება აღნიშნული, ხოლო სკალარები (რიცხვები) – ბერძნული $(\alpha, \beta, \gamma, \theta)$ ასოებით. მატრიცათა აღნიშვნისათვის კი

გამოყენებული იქნება მთავრული ლათინური ასოები. განსახილველი ამოცანის თავისებურებათა შესაბამისად ვექტორის კომპონენტები შეიძლება იყოს ნამდვილი რიცხვები, მთელი რიცხვები (მაგალითად, გამოსახულების სიკაშკაშის გრადაციათა აღსანიშნავად), აგრეთვე ბულის რიცხვები «ნოლი, ერთი» ან «მინუს ერთი, ერთი». $x = (x_1, x_2, \dots, x_n)$ ვექტორის კომპონენტები შეიძლება განვიხილოთ მის კოორდინატებად n -განზომილებიან სივრცეში. ნამდვილი კომპონენტების შემთხვევაში ეს სივრცე \mathbf{R}^n სიმბოლოთი აღინიშნება და n ნამდვილი რიცხვით შედგენილი ყველა შესაძლო ერთობლიობის ნაკრებს შეიცავს. ამბობენ, რომ x ვექტორი \mathbf{R}^n სივრცეს მიეკუთვნება (ან x ვექტორი \mathbf{R}^n სივრციდანაა). მომავალში, თუ ჩვენ დაგვჭირდება ვექტორთა ნაკრები, მათ დანომვრას ზედა ინდექსებით განვახორციელებთ, რათა არ მოხდეს მათი გაიგივება კომპონენტთა ნუმერაციასთან : $\{x^1, x^2, \dots, x^k\}$.

განხილვისას ჩვენ არ განვასხვავებთ ცნებებს *ვექტორი* (კომპონენტთა მოწესრიგებული ერთობლიობა) და *სახე* (სახის *თვისებათა* ან *ნიშნთა* ერთობლიობა). ნიშნთა ერთობლიობის არჩევისა და ინფორმაციული (საინფორმაციო) ვექტორის ფორმირების ხერხები (წესები) კონკრეტული გამოყენებებით განისაზღვრება.



ა)



ბ)

ნახ. 2.1. ვექტორების მაგალითები : ა) ბულის ვექტორი 25 კომპონენტით, რომლებიც გადანომრილია სტრიქონების გასწვრივ, ბ) ნამდვილი ვექტორი \mathbf{R}^4 სივრციდან

ნამდვილი კომპონენტების შემცველი ვექტორების სიმრავლე **წრფივ ვექტორულ V სივრცედ** წოდებული უფრო ზოგადი ცნების კერძო შემთხვევაა,

თუ მისი ელემენტებისათვის განსაზღვრულია «+» ვექტორული შეკრებისა და «·» სკალარზე გამრავლების ოპერაციები, რომლებიც ქვემოთ ჩამოთვლილ თანაფარდობებს აკმაყოფილებს (აქ x, y, z - ვექტორებია V -დან, ხოლო α, β - სკალარები R -დან) :

1. $x + y = y + x$, შედეგი მიეკუთვნება V -ს
2. $\alpha \cdot (x + y) = \alpha \cdot x + \alpha \cdot y$, შედეგი მიეკუთვნება V -ს
3. $(\alpha + \beta) \cdot x = \alpha \cdot x + \beta \cdot x$, შედეგი მიეკუთვნება V -ს
4. $(x + y) + z = x + (y + z)$, შედეგი მიეკუთვნება V -ს
5. $(\alpha \cdot \beta) \cdot x = \alpha \cdot (\beta \cdot x)$, შედეგი მიეკუთვნება V -ს
6. $\exists \circ \in V$ -დან: $\forall x \in V$ -დან $\Rightarrow \circ + x = x$ (არსებობს ნულოვანი ელემენტი)
7. 0 და 1 სკალარებისათვის, $\forall x \in V$ -დან გვაქვს: $0 \cdot x = \circ, 1 \cdot x = x$

პირველ თვისებას კომუტაციურობის თვისებას უწოდებენ, მეორე და მესამე თვისებას – დისტრიბუციულობის თვისებას, ხოლო მეოთხე თვისებას - შემოტანილი ოპერაციების ასოციაციურობის თვისებას. წრფივი ვექტორული სივრცის მაგალითს R^n სივრცე წარმოადგენს შეკრებისა და გამრავლების ოპერაციებით კომპონენტებისათვის.

ორი ვექტორული სივრცის ელემენტისათვის შეიძლება განისაზღვროს მათი **სკალარული (შინაგანი) ნამრავლი** : $(x, y) = x_1 y_1 + x_2 y_2 + \dots + x_n y_n$. სკალარულ ნამრავლს გააჩნია სიმეტრიულობის, ადიტიურობისა და წრფივობის თვისებები თითოეული თანამამრავლის მიმართ :

1. $(x, y) = (y, x)$
2. $(\alpha \cdot x, y) = \alpha \cdot (x, y)$
3. $(x + y, z) = (x, z) + (y, z)$
4. $(x, x) \geq 0$, ამასთან ერთად $(x, x) = 0 \Leftrightarrow x = \circ$

თუ ორი ვექტორის სკალარული ნამრავლი ნულის ტოლია, ეს ხსენებული ვექტორების ურთიერთორთოგონალობას ნიშნავს, ჩვეულებრივი გეომეტრიული წარმოდგენების შესაბამისად.

ორი განსხვავებული სახე (ან ვექტორი) შეიძლება ამა თუ იმ ზომის მსგავსებას ამჟღავნებდეს. მსგავსების ხარისხის მათემატიკური აღწერისათვის ვექტორულ სივრცეს შეიძლება სკალარული *მეტრიკა* გააჩნდეს - $d(x, y)$ მანძილი ნებისმიერ ორ x და y ვექტორს შორის. სივრცეს, მოცემული მეტრიკით, *მეტრიკულს* უწოდებენ. მეტრიკისათვის უნდა სრულდებოდეს არაუარყოფითობისა და სიმეტრიულობის პირობები, აგრეთვე სამკუთხედის უტოლობა :

1. $d(x, y) \geq 0$, ამასთან ერთად $d(y, x) = 0 \Leftrightarrow x = y$
2. $d(x, y) = d(y, x)$
3. $\forall y, d(x, z) \leq d(x, y) + d(y, z)$

შემდგომი განხილვისას, ძირითადად, ორი მეტრიკა იქნება გამოყენებული - *ეკვლიდეს მანძილი* და *ჰემინგის მეტრიკა*. ეკვლიდეს მეტრიკა კოორდინატთა მართკუთხა სისტემისათვის შემდეგი ფორმულით განისაზღვრება :

$$d_E(x, y) = \sqrt{(x_1 - y_1)^2 + (x_2 - y_2)^2 + \dots + (x_n - y_n)^2}.$$

ჰემინგის d_H მანძილი კი, ჩვეულებრივ, ბულის ვექტორებისათვის გამოიყენება (მათი კომპონენტების წარმოდგენა 0-ით და 1-ით ხდება) და უდრის ორივე ვექტორში ერთმანეთისაგან განსხვავებულ კომპონენტთა რიცხვს.

ვექტორებისათვის $\|x\|$ *ნორმის* - x ვექტორის სიგრძის - ცნება შემოაქვთ. სივრცეს, რომელშიც ვექტორების ნორმა განსაზღვრული, *ნორმირებული* ეწოდება. ნორმას შემდეგი თვისებები უნდა გააჩნდეს :

1. $\|x\| \geq 0$, ამასთან ერთად $\|x\| = 0 \Leftrightarrow x = 0$
2. $\|\alpha \cdot x\| = |\alpha| \cdot \|x\|$

$$3. \quad \|x + y\| \leq \|x\| + \|y\|$$

სივრცეს ევკლიდეს მეტრიკითა და ნორმით ევკლიდეს სივრცეს უწოდებენ. ნამდვილი ნიშნების შემცველი სახეებისათვის მომავალში ჩვენ საქმე გვექნება სწორედ ევკლიდეს სივრცესთან. n განზომილების ბულის ვექტორების შემთხვევაში განსახილველი სივრცე ჰემინგის მეტრიკის მქონე n -განზომილებიანი ჰიპერკუბის წვეროთა სიმრავლეს წარმოადგენს. მანძილი ორ წვეროს შორის განისაზღვრება მათი შემაერთებული უმოკლესი გზის სიგრძით, რომელიც წიბოთა გასწვრივია გადაზომილი.

ნეიროქსელური გამოყენებებისათვის მნიშვნელოვან შემთხვევას წარმოადგენს გარკვეული ტიპის ვექტორთა სიმრავლე : ყოველი ასეთი ვექტორის კომპონენტები $[0, 1]$ მონაკვეთის ნამდვილი რიცხვებია. ხსენებული ვექტორების სიმრავლე არ არის წრფივი ვექტორული სივრცე, რადგან მათ ჯამს შეიძლება გააჩნდეს კომპონენტები მოცემული მონაკვეთის ფარგლებს გარეთ. მაგრამ მსგავსი ვექტორების წყვილისათვის შენარჩუნებულია სკალარული ნამრავლისა და ევკლიდეს მანძილის ცნებები.

მეორე საინტერესო მაგალითს, რომელიც მნიშვნელოვანია პრაქტიკული თვალსაზრისით, ერთნაირი (მაგალითად, ერთეულოვანი) სივრცის ვექტორთა სიმრავლე წარმოადგენს. ხატოვნად რომ ვთქვათ, ამ ვექტორების «დაბოლოებები» მიეკუთვნება ერთეულოვანი რადიუსის *ჰიპერსფეროს* n -განზომილებიან სივრცეში. ჰიპერსფეროც ასევე არ არის წრფივი სივრცე (კერძოდ, წარმოდგენილი არ არის ნულოვანი ელემენტი).

ვექტორთა სიმრავლის განმსაზღვრელი ნიშნების მოცემული ერთობლიობისათვის შეიძლება ამ ნიშნების სხვადასხვა ხარისხით მქონე ვექტორების ისეთი *მინიმალური* ნაკრების ფორმირება, რომ მის საფუძველზე, ნაკრების ვექტორთა წრფივი კომბინირებით, შესაძლებელი იქნება ყველა დანარჩენი ვექტორის ფორმირებაც. ასეთ ნაკრებს სივრცის *ბაზისი* ეწოდება. განვიხილოთ ეს მნიშვნელოვანი ცნება უფრო დავწვრილებით.

x^1, x^2, \dots, x^m ვექტორები წრფივად დამოუკიდებელია, როცა მათი ნებისმიერი $\alpha_1 \cdot x^1 + \alpha_2 \cdot x^2 + \dots + \alpha_m \cdot x^m$ წრფივი კომბინაცია ნულად არ იქცევა, თუ, რა თქმა უნდა, ყველა $\alpha_1, \alpha_2, \dots, \alpha_m$ კონსტანტა ერთდროულად არ

უდრის ნულს. ბაზისი შეიძლება შეიცავდეს n წრფივად დამოუკიდებელი ვექტორის ნებისმიერ კომბინაციას, სადაც n – სივრცის განზომილებაა.

ავიჩინოთ წრფივად დამოუკიდებელი x^1, x^2, \dots, x^m ვექტორების გარკვეული სისტემა, სადაც $m < n$. ამ ვექტორების ყველა შესაძლო წრფივი კომბინაცია m განზომილების წრფივ სივრცეს აფორმირებს, რომელიც საწყისი n – განზომილებიანი სივრცის L ქვესივრცე ანუ წრფივი გარსი იქნება. ცხადია, რომ L ქვესივრცეში m ვექტორის შემცველი არჩეული საბაზო სისტემა ბაზისის როლს ითამაშებს. წრფივი გარსის მნიშვნელოვან კერძო შემთხვევას წარმოადგენს ქვესიმრავლე, რომლის განზომილება ერთით ნაკლებია საწყისი სივრცის განზომილებაზე ($m = n - 1$). მას **ჰიპერსიბრტყე** ეწოდება. სამგანზომილებიანი სივრცის შემთხვევაში იგი ჩვეულებრივი სიბრტყეა. ჰიპერსიბრტყე ორ ნაწილად ყოფს სივრცეს. ჰიპერსიბრტყეთა ერთობლიობა კი სივრცეს რამდენიმე სიმრავლედ ანაწილებს, რომელთაგანაც თითოეული შეიცავს ვექტორებს ნიშნების ახლო (მსგავსი) ნაკრებით, რითაც ვექტორთა კლასიფიკაცია ხორციელდება.

ორი ქვესივრცისათვის შეიძლება შემოვიტანოთ მათი ურთიერთ-ორთოგონალურობის ცნება. ორი L_1 და L_2 ქვესივრცე ურთიერთორთოგონალურია, თუ ერთი ქვესივრცის ნებისმიერი ელემენტი მეორე ქვესივრცის თითოეული ელემენტის ორთოგონალურია.

ნებისმიერად არჩეული წრფივად დამოუკიდებელი ვექტორები აუცილებლად ურთიერთორთოგონალური როდია. მაგრამ ზოგიერთ გამოყენებაში მოხერხებულა სწორედ ორთოგონალურ სისტემებთან მუშაობა. ამისათვის აუცილებელი ხდება საწყისი ვექტორების გაორთოგონალება. გრამ-შმიდტის გაორთოგონალალების კლასიკური პროცესი შემდეგში მდგომარეობს : წრფივად დამოუკიდებელი არანულოვანი x^1, x^2, \dots, x^m ვექტორების სისტემის გამოყენებით რეკურენტულად აგებენ h^1, h^2, \dots, h^m ორთოგონალური ვექტორების სისტემას. პირველ h^1 ვექტორად ირჩევენ საწყის x^1 ვექტორს. ნებისმიერი მომდევნო (i – ური) h^i ვექტორი ყველა წინა ვექტორის ორთოგონალური უნდა გახდეს, რისთვისაც x^i – ს უნდა გამოაკლდეს მისივე პროექციები ყველა ადრინდელ ვექტორზე :

$$h^i = x^i - \sum_{j=1}^{i-1} \frac{(x^i, h^j)}{\|h^j\|^2} \cdot h^j .$$

თუ ამ დროს რომელიმე h^i ვექტორი მიღებულთა შორის ნულის ტოლ მნიშვნელობას იძენს, მისი გადაგდება ხდება. შეიძლება ვუჩვენოთ, რომ, აგების შესაბამისად, ვექტორების ასეთი სისტემა ორთოგონალური იქნება, ესე იგი თითოეულ ვექტორში მხოლოდ მისთვის უნიკალური ნიშნები აღმოჩნდება წარმოდგენილი.

შემდეგ წარმოდგენილი იქნება ვექტორებზე წრფივი გარდაქმნების თეორიული ასპექტები.

მატრიცები და ვექტორების წრფივი გარდაქმნები.

მსგავსად იმისა, თუ როგორ იყო განხილული ვექტორი – ერთი ინდექსით (კომპონენტის ან ნიშნის ნომრით) განსაზღვრული ობიექტი, შესაძლებელია ორინდექსიანი ობიექტის, **მატრიცის**, შემოტანაც. ეს ორი ინდექსი მატრიცის სტრიქონებსა და სვეტებში განლაგებულ A_{ij} კომპონენტებს განსაზღვრავს. ამასთან პირველი i ინდექსი სტრიქონის ნომერს იძლევა, ხოლო მეორე j ინდექსი – სვეტის ნომერს. საინტერესოა აღინიშნოს, რომ ნახაზზე 2.1.a) გამოსახულება შეიძლება განიხილობედოს ან როგორც ვექტორი 25 კომპონენტით, ან როგორც მატრიცა ხუთი სტრიქონითა და ხუთი სვეტით.

ერთნაირი $(n \times m)$ განზომილების ორი A და B მატრიცის ჯამი წარმოადგენს იმავე განზომილების C მატრიცას საწყისი მატრიცების შესაბამისი კომპონენტების ჯამის ტოლი კომპონენტებით : $C_{ij} = A_{ij} + B_{ij}$. მატრიცა შეიძლება გამრავლდეს სკალარზე, ამის შედეგად იმავე განზომილების მატრიცა მიიღება, რომლის თითოეული კომპონენტა ამ სკალარზე გამრავლებული. ორი $A(n \times l)$ და $B(l \times m)$ მატრიცის ნამრავლი ასევე $C(n \times m)$ მატრიცას წარმოადგენს, რომლის კომპონენტები შემდეგი თანაფარდობით მოიცემა :

$$C_{ij} = \sum_{k=1}^l A_{ik} \cdot B_{kj} \quad .$$

აღსანიშნავია, რომ გადასამრავლებელი მატრიცების განზომილებები შეთანხმებული უნდა იყოს – პირველი მატრიცის სვეტების რიცხვი (l) მეორე მატრიცის სტრიქონთა (l) რიცხვს უნდა უდრიდეს.

მნიშვნელოვან კერძო შემთხვევაში, როცა მეორე მატრიცა ვექტორს წარმოადგენს (ესე იგი მატრიცას, რომლის ერთ-ერთი განზომილება ერთის ტოლია; ვექტორ-სვეტის შემთხვევაში $m=1$), მოცემული წესი განსაზღვრავს მატრიცის გამრავლების ხერხს ვექტორზე :

$$c_i = \sum_{k=1}^l A_{ik} \cdot b_k \quad .$$

გამრავლების შედეგად ასევე c ვექტორი მიიღება, ამასთან კვადრატული $A(l, l)$ მატრიცისათვის მისი განზომილება თანამამრავლი b ვექტორის განზომილებას უდრის. კვადრატული A მატრიცის თავისუფლად არჩევისას ნებისმიერი $y = T(x)$ წრფივი გარდაქმნა შეიძლება აიგოს, რომლითაც ერთი (x) ვექტორი იმავე განზომილების მეორე (y) ვექტორად გარდაისახება : $y = Ax$. უფრო ზუსტად : იმისათვის, რომ ერთი ვექტორის მეორე ვექტორად გარდასახვა, აღნიშნული T სიმბოლოთი, წრფივი იყოს, აუცილებელი და საკმარისია $T(\alpha \cdot x^1 + \beta \cdot x^2) = \alpha \cdot T(x^1) + \beta \cdot T(x^2)$ ტოლობის შესრულება, სადაც x^1 და x^2 – ორი ვექტორია, ხოლო α და β – რიცხვებს წარმოადგენს. შეიძლება ვუჩვენოთ, რომ ვექტორების ნებისმიერ წრფივ გარდასახვას საწყისი ვექტორის გამრავლება შეესაბამება გარკვეულ მატრიცაზე.

თუ A მატრიცის x ვექტორზე გამრავლების ზემოთ მოყვანილ ფორმულაში ამ ვექტორის კომპონენტები უცნობია, ხოლო A მატრიცა და b ვექტორ-შედეგი გარკვეულია, მაშინ $Ax = b$ გამოსახულების შესახებ საუბრობენ როგორც წრფივ ალგებრულ განტოლებათა სისტემაზე x ვექტორის კომპონენტების მიმართ. სისტემას ერთადერთი ამონახსნი გააჩნია, თუ კვადრატული A მატრიცის სტრიქონებით განსაზღვრული ვექტორები წრფივად დამოუკიდებელია.

მატრიცათა განსაკუთრებით ხშირად გამოყენებულ კერძო შემთხვევებს **დიაგონალური მატრიცები** წარმოადგენს, სადაც ყველა ელემენტი მთავარი დიაგონალის გარეთ ნულის ტოლია. დიაგონალურ მატრიცას, რომლის მთავარი დიაგონალის ყველა ელემენტი ერთს უდრის, ***I* ერთეულოვან მატრიცას** უწოდებენ. ერთეულოვანი მატრიცით განსაზღვრული წრფივი გარდასახვა იგივეურია : ნებისმიერი x ვექტორისათვის $Ix = x$.

მატრიცებისათვის, გამრავლებისა და შეკრების ოპერაციათა გარდა, განსაზღვრულია აგრეთვე **ტრანსპონირების ოპერაცია**. ტრანსპონირებული A^T მატრიცა მიიღება საწყისი A მატრიციდან სტრიქონთა შეცვლისას სვეტებით : $(A_{ij})^T = A_{ji}$. მატრიცებს, რომლებიც ტრანსპონირებისას არ იცვლება, **სიმეტრიულ მატრიცებს** უწოდებენ. სიმეტრიული S მატრიცის S_{ij} კომპონენტებისათვის ადგილი აქვს $S_{ij} = S_{ji}$ თანაფარდობას. ყოველი დიაგონალური მატრიცა, ცხადია, ერთდროულად სიმეტრიულიცაა.

ერთნაირი განზომილების კვადრატული მატრიცების სივრცე შეკრებისა და სკალარზე ელემენტობრივ (ელემენტობით) გამრავლების შემოტანილი ოპერაციებით წრფივ სივრცეს წარმოადგენს. მისთვის ასევე შეიძლება მეტრიკისა და ნორმის შემოტანა. ნულოვან ელემენტად მიიჩნევენ მატრიცას, რომლის ყველა ელემენტი ნულის ტოლია.

დასასრულს აღვნიშნოთ ზოგიერთი იგივეობა ოპერაციებისათვის მატრიცებზე. ნებისმიერი A , B და C მატრიცებისათვის, აგრეთვე I ერთეულოვანი მარტივისათვის ადგილი აქვს შემდეგ თანაფარდობებს :

1. $IA = AI = A$
2. $(AB)C = A(BC)$
3. $A(B + C) = AB + AC$
4. $(A^T)^T = A$
5. $(A + B)^T = A^T + B^T$
6. $(AB)^T = B^T A^T$

ამ თანაფარდობათა დამტკიცება სასარგებლო სავარჯიშოდ გამოდგება.

ლექცია 3. ბიოლოგიური ნეირონი და მისი კიბერნეტიკული მოდელი.

ნეირობიოლოგია. ბილოგიური ნეირონი, მისი აღნაგობა და ფუნქციები. ნეირონების ქსელებად გაერთიანება. ნეირონული ქსელების ბიოლოგიური ცვალებადობა და სწავლება. ნეირონის კიბერნეტუკული მოდელი – მაკალოკისა და პიტსის ფორმალური ნეირონი. ნეირონის სწავლება სიკაშკაშის საზღვრის გამოვლენის ამოცანაში.

ეს ლექცია გამომთვლელი (ინფორმატიკული) ნეირონული ქსელების შემსწავლელი მეცნიერების ბიოლოგიურ საფუძვლებს ეძღვნება. წინა ლექციის მსგავსად, მასალა აქაც საცნობო ხასიათს ატარებს და განკუთვნილია მკითხველისათვის, რომელსაც სპეციალური ცოდნა ბიოლოგიაში არ გააჩნია. უფრო ღრმა პროფესიული ცნობების მოპოება შეიძლება ნ. გრინის, უ. სტაუტისა და დ. ტეილორის რუსულად ნათარგმნ წიგნში, აგრეთვე გ. შეპერდის მონოგრაფიაში. გაცნობითი ხასიათის საკითხავ ლიტერატურრიდან კი ფ. ბლუმის, ა. ლეიზერსონისა და ლ. ჰოფსტედტერის წიგნს უნდა გაეწიოს რეკომენდაცია.

მთელი ამ კურსის ფარგლებში ჩვენი მთავარი მიზანი იქნება იმ მეთოდებისა და კიბერნეტიკული სისტემების კვლევა, რომლებიც ტვინის ფუნქციათა იმიტირებას ახორციელებს საინფორმაციო ამოცანათა გადაწყვეტისას. ხელოვნური გამომთვლელი სისტემების აგების მსგავსი გზა ბუნებრივად უნდა ჩაითვალოს – უმაღლესი ბიოლოგიური ორგანიზმები, და განსაკუთრებით ადამიანი, ადვილად ძლევს და ართმევს თავს ასეთ – მათემატიკური განხილვისათვის უკიდურესად რთულ – პრობლემებს. მათ რიცხვს მიეკუთვნება, მაგალითად, მხედველობითი, სმენითი, სენსორული და სხვა ტიპის სახეების გამოცნობა, მეხსიერება ან სხეულის მოძრაობის მდგრადი მართვა. ბიოლოგიური საფუძველი ამ ფუნქციათა შესწავლისას ძალზე მნიშვნელოვანია, ბუნებრივი მრავალფეროვნება განსაკუთრებულად მდიდარ

საწყის მასალას იძლევა ხელოვნური მოდელების მიმართული შექმნისათვის.

ლექციის დასკვნით ნაწილში წარმოდგენილი იქნება ნეირონის კლასიკური კიბერნეტიკული მოდელი – მაკკალოკისა და პიტსის ეგრეთ წოდებული ფორმალური ნეირონი. ფორმალური ნეირონის ზოგიერთი თვისება კი ფერთა გადასვლის საზღვრის დეტექტირების ამოცანაზე შეისწავლება («შავი-თეთრი» გადასვლა მარტივ გამოსახულებაში).

ნეირობიოლოგიის მეთოდი.

ნეირობიოლოგიის საგანს ნერვული სისტემის და მისი მთავარი ორგანოს – ტვინის – შესწავლა მიეკუთვნება. პრინციპულ საკითხს ამ მეცნიერებისათვის ნერვული სისტემის აღნაგობასა და მის ფუნქციას შორის თანაფარდობის გამორკვევა წარმოადგენს. ამასთან განხილვა რამდენიმე დონეზე ხდება : მოლეკულის, უჯრედის, ცალკეული ორგანოს, მთლიანად ორგანიზმისა და შემდეგ სოციალური ჯგუფის. ამრიგად, კლასიკური ნეირობიოლოგიური მიდგომა მდგომარეობს თანამიმდევრულ წინსვლაში ელემენტარული ფორმებიდან მათი გართულების მიმართულებით.

ჩვენი პრაქტიკული მიზნებისათვის ამოსავალ წერტილად უჯრედული დონე იქნება. თანამედროვე შეხედულებების თანახმად, სწორედ ამ დონეზე ცალკეულ უჯრედში მიმდინარე ელემენტარული მოლეკულური ქიმიურ-ბიოლოგიური პროცესების ერთობლიობა აყალიბებს მას ინფორმაციის უმარტივესი გადაამუშავების შემდეგ ელემენტარულ პროცესორად.


ბიოლოგიური ნეირონი.

ტვინის უჯრედული სტრუქტურის ელემენტს ნერვული უჯრედი – ნეირონი – წარმოადგენს. ნეირონს თავის აღნაგობაში მრავალი საერთო ნიშანი გააჩნია ბიოქსოვილის სხვა უჯრედებთან : ნეირონის ტანი (სხეული) გარშემორტყმულია პლაზმური მემბრანით, რომლის შიგნით ციტოპლაზმა, ბირთვი და უჯრედის სხვა შემადგენელი კომპონენტია წარმოდგენილი. მაგრამ ნერვული უჯრედი არსებითად განსხვავდება სხვებისაგან თავისი ფუნქციური დანიშნულებით. ნეირონი ინფორმაციის მიღებას, ელემენტარულ გარდაქმნას და სხვა ნეირონებისათვის შემდგომ გადაცემას ასრუ-

ლებს. ინფორმაცია ნერვული აქტივობის იმპულსთა სახით გადაიცემა. ეს იმპულსები ელექტროქიმიური ბუნებისაა.

ნეირონები მეტისმეტად სხვადასხვაგვარისაა ფორმით, რომელიც დამოკიდებულია მათ ადგილმდებარეობაზე ნერვულ სისტემაში და ფუნქციონირების თავისებურებებზე. ნახაზზე 3.1. ნაჩვენებია «ტიპური» ნეირონის აგებულება. უჯრედის სხეული შეიცავს ორი ტიპის მრავალ დატოტვლილ გამონაზარდს. პირველი ტიპის გამონაზარდებს *დენდრიტებს* უწოდებენ ტოტებგაშლილი ხის ვარჯთან (კრონასთან) მსგავსების გამო. ისინი შემაკალი არხების როლს თამაშობს სხვა ნეირონების ნერვული იმპულსებისათვის. ეს იმპულსები შედის 3 – 100 მკმ ზომის უჯრედის *სომაში* ანუ *ტანში* და იწვევს მის სპეციფიკურ აგზნებას, რომელიც შემდეგ მეორე ტიპის გამომყვან წამონაზარდში – *აქსონში* – ვრცელდება. აქსონთა სიგრძე, ჩვეულებრივ, მნიშვნელოვნად აღემატება დენდრიტების ზომებს და ცალკეულ შემთხვევებში ათეულ სანტიმეტრებს და მეტრებსაც კი აღწევს. კალმარის (თაფვეხიანთა კლასის ზღვის მოლუსკის) გიგანტური აქსონის სისქე დაახლოებით მილიმეტრს შეადგენს და სწორედ მასზე ჩატარებული დაკვირვებები გამოიყენეს ნეირონებს შორის ნერვული იმპულსების გადაცემის მექანიზმის გამოსარკვევად.

ნეირონის ტანი, რომელიც გამტარი იონური ხსნართაა ავსებული, გარემორტყმულია მცირე გამტარობის 75 ანგსტრემაძღე (ერთი ანგსტრემი სანტიმეტრის მეასმილიონედს შეადგენს ; შვედი ფიზიკოსის Angström-ის გვარის მიხედვით) სისქის მემბრანით. მემბრანის შიგა ზედაპირსა და გარემოს შორის ელექტრულ პოტენციალთა სხვაობა იქმნება. ეს ხორციელდება იონური ტუმბოების მოლეკულური მექანიზმის საშუალებით : ტუმბოები დადებით K^+ და Na^+ იონების სხვადასხვა კონცენტრაციას უზრუნველყოფს უჯრედის შიგნით და მის გარეთ. ნეირონის მემბრანის გამჭვირვალობა სელექტიური ხასიათისაა ამ იონებისათვის. სიმშვიდის მდგომარეობაში მყოფი უჯრედის აქსონის შიგნით იონების აქტიური ტრანსპორტი ცდილობს შეინარჩუნოს კალიუმის იონების კონცენტრაცია უფრო მაღალ დონეზე, ვიდრე ნატრიუმის იონების, მაშინ როცა აქსონის გარშემო არსებულ სითხეში Na^+ იონების კონცენტრაცია უფრო მაღალ დონეზე რჩება. მეტი ძვრადობის მქონე კალიუმის იონების პასიური დიფუზია იწვევს მათ ინტენსიურ გამოსვლას უჯრედიდან, რაც განაპირობებს გარემოს მიმართ მის საერთო უარყოფით *სიმშვიდის პოტენციალს*, რომელიც დაახლოებით –65 მილივოლტს შეადგენს.



ნახ. 3.1. ბიოლოგიური ნეირონის აგებულების ზოგადი სქემა.

სხვა ნეირონების მასტიმულირებელი სიგნალების ზემოქმედებით აქსონის მემბრანა დინამიკურად იცვლის თავის გამტარობას. ეს მაშინ ხდება, როცა ჯამური შინაგანი პოტენციალი -50 მვ მასშტაბის ზრუბლურ მნიშვნელობას გადააჭარბებს. მემბრანა მოკლე დროით, რომელიც დაახლოებით 2 მილიწამს შეადგენს, იცვლის თავის პოლარობას (დეპოლარიზდება) და *ქმედების პოტენციალს* აღწევს, რაც $+40$ მილივოლტს უდრის დაახლოებით. მიკროდონეზე ეს აიხსნება მემბრანის გამჭვირვალობის ხანმოკლე მომატებით (გაზრდით) Na^+ იონებისათვის და მათი აქტიური შესვლით აქსონში. შემდგომში იმისდა მიხედვით, თუ როგორია კალიუმის იონების გამოსვლა, დადებითი მუხტი მემბრანის შიდა მხრიდან იცვლება უარყოფითით და დაახლოებით 200 მიკროწამის ხანგრძლივობის ეგრეთ წოდებული *რეფრაქტერიობის პერიოდი* დგება. ამ დროის განმავლობაში ნეირონი მთლიანად პასიური რჩება და პრაქტიკულად უცვლელად ინარჩუნებს პოტენციალს აქსონის შიგნით დაახლოებით -70 მილივოლტის დონეზე.

უჯრედული მემბრანის დეპოლარიზაციის იმპულსი, რომელსაც *სპაიკი* (ინგლ. spike) ეწოდება, აქსონის გასწვრივ პრაქტიკულად მილევის გარეშე ვრცელდება და ლოკალური იონური გრადიენტების წყალობით არსებობს. სპაიკის გადაადგილების სიჩქარე შედარებით დაბალია და წაშში ასიდან ათასამდე სანტიმეტრს შეადგენს.

ნეირონის აგზნება სპაიკის სახით გადაეცემა სხვა ნერონებს, რომლებიც ამრიგად გაერთიანებულია ნერვული იმპულსების გამტარ ქსელში. მემბრანის უბნებს აქსონზე, სადაც განთავსებულია მოცემული ნეირონის აქსონის კონტაქტის არე სხვა ნეირონების დენდრიტებთან, *სინაფსებს* (ბერძნ. synapsis – შეერთება, კავშირი) უწოდებენ. რთული აგებულების მქონე სინაფსის არეში ხდება ნეირონებს შორის ინფორმაციის გაცვლა აგზნების შესახებ. სინაფსური გადაცემის მექანიზმები საკმარისად რთული და მრავალფენიანია. მათი ბუნება შეიძლება იყოს ქიმიური და ელექტრული. ქიმიურ სინაფსში იმპულსების გადაცემაში მონაწილეობს განსაკუთრებული ქიმიური ნივთიერებები – *ნეირომედიატორები*, რომლებიც მემბრანის ლოკალური უბნის გამჭვირვალობის ცვლილებებს იწვევს. გამომუშავებული მედიატორის ტიპის მიხედვით სინაფს შეიძლება ახსიათებდეს ამგზნები, აღმძვრელი (აგზნების ეფექტურად გამტარი) ან მამუხრუჭებელი მოქმედება. ჩვეულებრივ, ერთი ნეირონის ყველა გამონაზარდზე ერთისა და იმავე მედიატორის გამომუშავება ხდება და ამიტომ ნეირონი მთლიანობაშია ფუნქციურად მამუხრუჭებელი ან ამგზნები (აღმძვრელი). ეს მნიშვნელოვანი შენიშვნა სხვადასხვა ტიპის ნეირონების არსებობის შესახებ მომდევნო თავებში არსებითად იქნება გამოყენებული ხელოვნური სისტემების დაპროექტებისას.

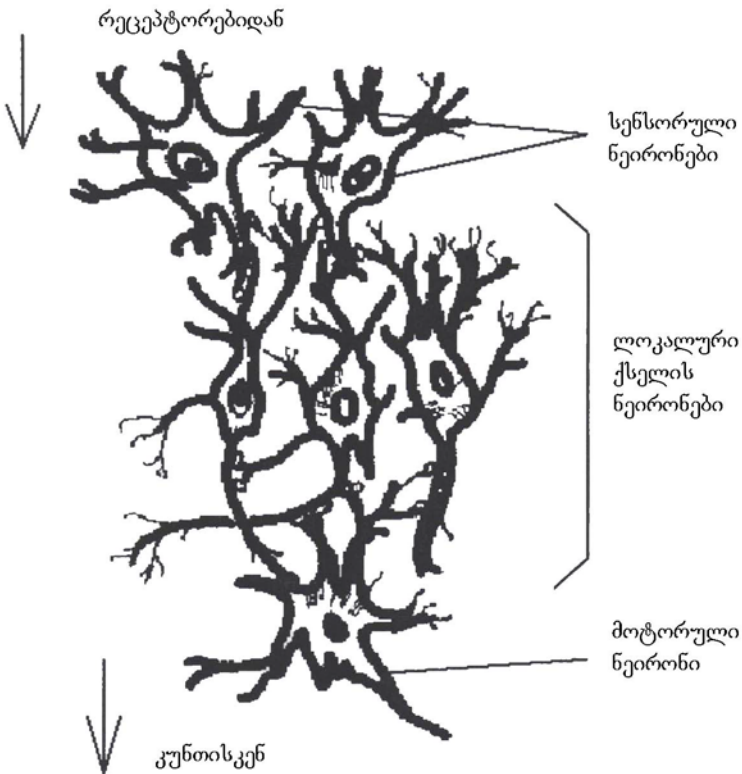
ნეირონული ქსელები.

გამონაზარდებში აგზნებათა გადაცემის საშუალებით ერთმანეთთან ურთიერთმოქმედი ნეირონები ქმნის *ნეირონულ ქსელებს*. გადასვლა ცალკეული ნეირონის განხილვიდან ნეირონული ქსელების შესწავლაზე ბუნებრივი ნაბიჯია ნეირობიოლოგიურ იერარქიაში.

ადამიანის ცენტრალურ ნერვულ სისტემაში ნეირონთა საერთო რიცხვი ($10^{10} - 10^{11}$)-ს აღწევს და ამასთან ერთად თითოეული ნერვული უჯრედი დაკავშირებულია საშუალოდ $10^3 - 10^4$ სხვა ნეირონთან. დადგენილია, რომ

თავის ტვინში ნეირონების ერთობლიობა 1მმ^3 მასშტაბის მოცულობაში ქმნის გარკვეული ფუნქციური დატვირთვის მატარებელ, შედარებით დამოუკიდებელ, ლოკალურ ქსელს.

ერთმანეთისაგან სტრუქტურითა და დანიშნულებით განსხვავებული ნეირონული ქსელების რამდენიმე (ჩვეულებრივ, სამ) ძირითად ტიპს გამოყოფენ. პირველ ტიპს *იერარქიული* ქსელები შეადგენს, რომლებსაც ხშირად ვხვდებით სენსორულ და მამოძრავებელ გზებში. ასეთ ქსელებში ინფორმაცია თანამიმდევრული გადასვლის პროცესში გადაიცემა იერარქიის ერთ დონიდან მეორეზე.



ნახ. 3.2. მარტივი რეფლექტორული ნეირონული ქსელის სტრუქტურა.

ნეირონები ორი დამახასიათებელი ტიპის შეერთებას ქმნის – *კონვერგენტულს*, როცა ერთი დონის ნეირონთა დიდი რიცხვი შემდეგი დონის ნეირონთა ნაკლებ რაოდენობასთან შედის კონტაქტში, და *დივერგენტულს*, როცა კონტაქტები მომდევნო იერარქიული ფენების ნეირონთა სულ უფრო ზრდად რაოდენობასთან მყარდება. კონვერგენტულ და დივერგენტულ შეერთებათა შეთავსება (შეხამება, შეწყობა) საინფორმაციო გზების მრავალჯერად დუბლირებას უზრუნველყოფს, რაც ნეირონული ქსელის საიმედოობის გადამწყვეტ ფაქტორს წარმოადგენს. უჯრედთა ნაწილის დაღუპვის შემთხვევაში ქსელის მოქმედებას შემორჩენილი ნეირონები უზრუნველყოფს. ნეირონული ქსელების მეორე ტიპს *ლოკალური ქსელები* მიეკუთვნება. მათი ფორმირება გავლენის შეზღუდული სფეროს მქონე ნეირონებით ხდება. ლოკალური ქსელების ნეირონები ინფორმაციის დამუშავებას იერარქიის ერთი დონის ფარგლებში აწარმოებს. ამასთან ერთად ფუნქციურად ლოკალური ქსელი შედარებით იზოლირებულ მამუხრუჭებულ ან ამგზნებ (ამძრავ) სრუქტურას წარმოადგენს. მნიშვნელოვან როლს თამაშობს აგრეთვე ეგრეთ წოდებული დივერგენტული *ქსელები ერთი შესასვლელით*. ასეთი ქსელის ფუძეში მყოფ საკომანდო (მბრძანებელ) ნეირონს შეუძლია გავლენა მოახდინოს ერთდროულად მრავალ ნეირონზე და ამიტომ ქსელები ერთი შესასვლელით გვევლინება შემთანხმებელ ელემენტად ყველა ტიპის ნეიროქსელური სისტემის რთულ შეუღლებაში.

განვიხილოთ სქემატურად ნეირონული ქსელი, რომელიც ქმნის მარტივ რეფლექტორულ წრედს აგზნების გადაცემით გამაღიზიანებლიდან მამოძრავებელ კუნთამდე (ნახ. 3.2.).

გარეგანი გამაღიზიანებლის სიგნალი მგრძნობიარე რეცეპტორულ უჯრედებთან დაკავშირებული *სენსორული* ნეირონებით აღიქმება. სენსორული ნეირონები აყალიბებს იერარქიის პირველ (ქვედა) დონეს. მათ მიერ გამო-მუშავებული სიგნალები ლოკალური ქსელის ნეირონებს გადაეცემა, რომლებიც დივერგენტულ და კონვერგენტულ შეერთებებთან შეხამებულ უამრავ პირდაპირ და შექცევულ კავშირს (ე.წ. *უკუკავშირს*) შეიცავს. ლოკალურ ქსელებში გარდასახული სიგნალის ხასიათი *მოტორული* ნეირონების აგზნების მდგომარეობას განსაზღვრავს. ეს ნეირონები, რომლებიც განსახილველ ქსელში იერარქიის ზედა დონეს შეადგენს, ხატოვნად რომ ვთქვათ, «გადაწყვეტილებას იღებს», რაც გამოიხატება ზემოქმედებით კუნთოვანი ქსოვილის უჯრედებზე ნერვულ-კუნთური შეერთებების საშუალებით.

ბიოლოგიური ცვალებადობა და ნეირონული ქსელების სწავლება.

ნეირონული ქსელების ძირითადი ტიპების სტრუქტურა წინასწარ განსაზღვრულია გენეტიკურად. ამასთან ერთად გამოკვლევები შედარებით ნეიროანატომიის სფეროში მოწმობს იმაზე, რომ აგებულების ძირითადი გემის მიხედვით ტვინი ძალიან არაარსებითად შეიცვალა ევოლუციის პროცესში. მაგრამ დეტერმინისტული ნეირონული სტრუქტურები ავლენს ცვალებადობის თვისებებს, რაც განაპირობებს მათ ადაპტაციას ფუნქციონირების კონკრეტული პირობებისადმი.

გენეტიკურ წინასწარგანსაზღვრულობას ადგილი აქვს აგრევე ცალკეული ნეირონების თვისებათა მიმართაც, როგორცაა, მაგალითად, გამოყენებული ნეირომედიატორის ტიპი, უჯრედის ფორმა და ზომა. ცვალებადობა უჯრედულ დონეზე სინაფსური კონტაქტების *პლასტიკურობაში* ვლინდება. ნეირონის მეტაბოლური აქტიურობის ხასიათი და სინაფსური მემბრანის გამჭვირვალობა შეიძლება იცვლებოდეს ნეირონის ხანგრძლივი გააქტიურების (აქტივიზაციის) ან დამუხრუჭების პასუხად. სინაფსური კონტაქტი «იწვრთნება» ფუნქციონირების პირობათა შესაბამისად.

ცვალებადობა ქსელის დონეზე დაკავშირებულია ნეირონების თვისებურებასთან. ნერვული ქსოვილი პრაქტიკულად მოკლებულია უჯრედთა დაყოფის გზით რეგენერაციის უნარს, რაც ესოდენ დამახასიათებელია ქსოვილთა სხვა ტიპისათვის. მაგრამ ნეირონები ახალი წამონაზარდებისა და ახალი სინაფსური კონტაქტების ფორმირების უნარს ავლენს. რიგი ექსპერიმენტებისა ნერვული გზების წინასწარგანზრახული დაზიანებით მოწმობს, რომ ნეირონული წამონაზარდების განვითარებას თან სდევს კონკურენცია სინაფსური უბნების ფლობისათვის. მთლიანობაში ეს თვისება უზრუნველყოფს ნეირონული ქსელების ფუნქციონირების მდგრადობას მათი ცალკეული კომპონენტების – ნეირონების – შედარებითი არასაიმედოობის პირობებში.

ნეირონული ქსელებისა და ცალკეული ნეირონების თვისებათა სპეციფიკური ცვალებადობა საფუძვლად უდევს მათ უნარს ისწავლოს, გაიწვრთნას, გაიწაფოს – განიცადოს ადაპტაცია ფუნქციონირების პირობებისადმი პრაქტიკულად მორფოლოგიური სტრუქტურის უცვლელობის პირობებში. მაგრამ მაინც უნდა შევნიშნოთ, რომ ნეირონების მცირე ჯგუფების ცვალებადობისა და სწავლების განხილვა პასუხის გაცემის საშუალებას არ იძლევა

შეკითხვებზე წვრთნის შესახებ ფსიქიკური მოქმედების უმაღლეს ფორმებთან (ინტელექტთან, აბსტრაქტულ აზროვნებასთან და მეტყველებასთან) დაკავშირებულ დონეზე.

ახლა კი ნეირონების მოდელებისა და ხელოვნური ნეირონული ქსელების განხილვამდე, რეზიუმეს სახით, ჩამოვაყალიბოთ ზოგადი ფაქტოლოგიური დებულებები ბიოლოგიური ნეირონული ქსელების შესახებ. აქ ჩვენ ვეყრდნობით ფ. ბლუმის, ა. ლეიზერსონისა და ლ. ჰოფსტედტერის წიგნს.


ნერვული სისტემის ძირითად მოქმედ ელემენტებს ნეირონებად წოდებული ცალკეული უჯრედები წარმოადგენს. მათ მრავალი საერთო ნიშანი გააჩნია სხვა ტიპის უჯრედებთან, მაგრამ ამასთან ერთად ნეირონები ძალიან განსხვავდება ამ უჯრედებისაგან თავისი კონფიგურაციითა და ფუნქციური დანიშნულებით. ნერვული იმპულსების გადაცემისას და დამუშავებისას ნეირონების აქტივობა რეგულირდება მემბრანის თვისებებით, რომლებიც სინაფსური მედატორების ზემოქმედებით შეიძლება შეიცვალოს. ნეირონის ბიოლოგიური ფუნქციები ასევე შეიძლება შეიცვალოს და ადაპტაცია განიცადოს ფუნქციონირების პირობათა შესაბამისად. ნეირონები ერთიანდება ნეირონულ ქსელებად. მათი ძირითადი ტიპები, აგრეთვე ტვინის გამტარი გზების სქემები გენეტიკურად წინასწარ დაპროგრამებულია. განვითარების პროცესში შესაძლებელია ნეირონული ქსელების ლოკალური სახეცვლა ახალი კავშირების დამყარებით ნეირონებს შორის. უნდა აღინიშნოს აგრეთვე, რომ ნერვული სისტემა, ნეირონების გარდა, სხვა ტიპის უჯრედებსაც შეიცავს.

ფორმალური ნეირონი.

ისტორიულ ასპექტში პირველ ნაშრომად, რომელმაც თეორიული საძირკველი ჩაუყარა ნეირონებისა და ნეირონული ქსელების ხელოვნური მოდელების შექმნას, უორენ ს. მაკკალოკისა და ვალტერ პიტსის მიერ 1943 წელს გამოქვეყნებული სტატიაა მინიწერილი («ნერვულ აქტივობასთან შეხებაში მყოფი იდეების ლოგიკური აღრიცხვა»). მაკკალოკისა და პიტსის თეორიის მთავარი პრინციპი მდგომარეობს იმაში, რომ უმაღლეს ნერვულ მოქმედებასთან შეხებაში მყოფი ნებისმიერი მოვლენა შეიძლება გაანალიზებული და გაგებული იყოს როგორც გარკვეული აქტივობა მხოლოდ ორი მდგომარეობის («ყველაფერი ან არაფერი») მქონე ლოგიკური ელემენტებისაგან შედგენილ ქსელში. ამასთან ერთად ნებისმიერი ლოგიკური გამოსა-

ზულებსათვის, რომელიც ხსენებული ავტორების მიერ ჩამოყალიბებულ პირობებს აკმაყოფილებს, შეიძლება ლოგიკური ელემენტების ქსელის პონა ამ გამოსახულებასთან შეთანხმებული ქცევით. სადისკუსიო საკითხები, რომლებიც ეხება ფსიქიკის, ცნობიერებისა და მისთანანის მოდელირების შესაძლებლობას, ამ სალექციო კურსის ჩარჩოებს მიღმა რჩება.

შემავალი სინაფსური აჯამვის არაწრფივი გამომავალი სიგნალები წონები ბლოკი გარდაქმნის ბლოკი სიგნალი



ნახ. 3.3. მაკალოკისა და პიტსის ფორმალური ნეირონის ფუნქციური სქემა.

შემდგომში «ფორმალური ნეირონის» სახელწოდებით აღიარებული ასეთი ლოგიკური ელემენტის მოდელისათვის გავრცელდა ნახ. 3.3.-ზე ნაჩვენები სქემა. თანამედროვე თვალსაზრისით ფორმალური ნეირონი რამდენიმე შესასვლელისა და ერთი გამოსასვლელის მქონე მარტივი პროცესორის მათემატიკურ მოდელს წარმოადგენს. «დენდრიტების» მეშვეობით მიწოდებული შემავალი სიგნალების ვექტორი გარდაიქმნება ნეირონის მიერ «აქსონით» გამოტანილ გამომავალ სიგნალად სამი ფუნქციური ბლოკის გამოყენებით : ლოკალური მეხსიერების, შეკრებისა და არაწრფივი გარდაქმნის.

ლოკალური მეხსიერების ვექტორი შეიცავს ინფორმაციას წონით თანამამრავლებზე, რომლებითაც შემავალი სიგნალები ინტერპრეტირებული იქნება ნეირონის მიერ. ეს ცვლადი წონები პლასტიკური სინაფსური კონტაქტების გრძნობიერების ანალოგს წარმოადგენს. წონათა არჩევით ნეირონის ესა თუ ის ინტეგრალური ფუნქცია მიიღება.

შეკრების ბლოკში საერთო შემავალი სიგნალის დაგროვება ხდება, რომელიც შესასვლელთა აწონილ ჯამს უდრის და იგი, ჩვეულებრივ, *net* სიმბოლოთი აღინიშნება :

$$net = \sum_{i=1}^n W_i x_i .$$

მაკაკლოკისა და პიტსის მოდელში წარმოდგენილი არ არის შემავალი სიგნალების დაყოვნებები, ამიტომ *net* -ის მნიშვნელობა განსაზღვრავს ნეირონის მიერ აღქმულ სრულ გარემო აგზნებას. ნეირონის გამოძახილი ამის შემდეგ აღიწერება პრინციპით «ყველაფერი ან არაფერი», ესე იგი ცვლადი არაწრფივ ზღურბლურ გარდასახვას განიცდის, რომლის დროსაც *Y* გამოსასვლელი (ნეირონის აქტივაციის მდგომარეობა) ერთის ტოლ მნიშვნელობას იძენს, თუ $net > \Theta$, და $Y = 0$ წინააღმდეგ შემთხვევაში, როცა $net \leq \Theta$. Θ ზღურბლის მნიშვნელობა, რომელსაც ხშირად ნულის ტოლად მიიჩნევენ, ასევე ლოკალურ მეხსიერებაში ინახება.

ფორმალური ნეირონები ქსელებად შეიძლება გაერთიანდეს ნეირონების ერთი ჯგუფის გამოსასვლელთა შერთვისას (შეკვრისას) ნეირონების მეორე ჯგუფის შესასვლელებთან, და ასეთ კიბერნეტიკურ სისტემას სათანადოდ შერჩეული წონებით შეუძლია ნებისმიერი ლოგიკური ფუნქციის წარმოდგენა. მიღებული ნეირონული ქსელების თეორიული აღწერისათვის ლოგიკური პრედიკატების აღრიცხვის მათემატიკური ენა უნდა გამოყენებიათ.

უნდა აღინიშნოს, რომ დღესაც კი, მაკაკლოკისა და პიტსის ნაშრომის გამოქვეყნებიდან ექვსი ათეული წლის გავლისას, ნებისმიერი ფუნქციის განმხორციელებელი ლოგიკური ნეირონული ქსელების სინთეზის ამომწურავი თეორია, როგორც ჩანს, არ არსებობს. ყველაზე წარმატებული აღმოჩნდა გამოკვლევები მრავალფენიანი (მრავალშრიანი) სისტემებისა და სიმეტრიული კავშირების მქონე ქსელების სფეროში. მოდულების უმრავლესობა თავის საფუძველში ეყრდნობა ფორმალური ნეირონის სხვადასხვა სახეცვალებას (მოდულიზაციას). ფორმალური ნეირონის მნიშვნელოვან განვითარებას ანალოგურ (უწყვეტ) სიგნალებზე და არაწრფივ $Y = f(net)$ გარდამავალ ფუნქციათა სხვადასხვა ტიპზე გადასვლა წარმოადგენს. აღვწერთ გარდამავალ ფუნქციათა ის ტიპები, რომლებსაც განსაკუთრებით ხშირად ხმარობენ.

- (მაკაკლოკოსა და პიტსის მიერ განხილული) ზღურბლური ფუნქცია :

$$Y = f(net) = \begin{cases} 1, & net > \Theta \\ 0, & net \leq \Theta \end{cases}$$

- წრფივი ფუნქცია, აგრეთვე მისი ვარიანტი – წრფივი ფუნქცია უარყოფითი სიგნალების ჩაწმობით :

$$Y = f(net) = \begin{cases} net, & net > \Theta \\ 0, & net \leq \Theta \end{cases}$$

- სიგმოიდური ფუნქცია :


$$Y = f(net) = \frac{1}{1 + \exp(-(net - \Theta))}$$

როგორც ჯერ კიდევ ს. გროსბერგი მიუთითებდა, სიგმოიდურ ფუნქციას გააჩნია შერჩევითი გრძნობიერება სხვადასხვა ინტენსივობის სიგნალების მიმართ, რაც შეესაბამება ბიოლოგიურ მონაცემებს. უდიდესი გრძნობიერება შეიმჩნევა ზღურბლის არეში, სადაც *net* სიგნალის მცირე ცვლილებები გამოსასვლელის მნიშვნელოვან ცვლილებებს იწვევს. პირიქით, სიგნალის ვარიაციების მიმართ ზღურბლური დონის ძალიან ზევით ან ქვევით სიგმოიდური ფუნქცია მგრძნობიარე არ არის, ვინაიდან მისი წარმოებული დიდი და მცირე არგუმენტის შემთხვევაში ნულისაკენ მიისწრაფვის.

ამჟამად განიხილება აგრეთვე ფორმალური ნეირონების მათემატიკური მოდელები, რომლებიც ითვალისწინებს არაწრფივ კორელაციებს შესასვლელებს შორის. მაკაკლოკოსა და პიტსის ნეირონებისათვის შექმნილია ელექტროტექნიკური ანალოგები პირდაპირი აპარატული მოდელირების განსახორციელებლად.

ნეირონის გაწვრთნა (გაწაფვა) შავი და თეთრი ფერების საზღვრის დეტექტირებისათვის.

ფორმალური ნეირონის უნარი სწავლებისადმი ვლინდება წონების W ვექტორის მნიშვნელობათა ცვლილების შესაძლებლობაში, რომელიც ბიოლოგიური ნეირონების სინაფსთა პლასტიკურობას შეესაბამება. განვიხილოთ ფორმალური ნეირონის სწავლება საზღვრის დეტექტირების უმარტივესი ამოცანის მაგალითზე. დავუშვათ, რომ გვაქვს სახე, რომელიც შედგენილია შავი და თეთრი უჯრედების ერთგანზომილებიანი მიმდევრობით. შავი უჯრედები ერთეულოვან სიგნალს შეესაბამება, ხოლო თეთრი – ნულოვანს. ფორმალური ნეირონის შესასვლელებზე სიგნალი მყარდება მოცემული სახის მომიჯნავე უჯრედთა წყვილების ტოლ მნიშვნელობებზე. ნეირონი ყოველთვის სწავლობს აგზნებასა და ერთეულოვანი გამოძავალი სიგნალის გამოცემას, თუ მისი პირველი შესასვლელი (ნახ. 3.4.-ზე – მარცხენა) შეერთებულია თეთრ უჯრედთან, ხოლო მეორე (მარჯვენა) – შავთან. ამრიგად, ნეირონი სახის ნათელი ტონიდან მუქ ტონზე გადასვლის საზღვრის დეტექტორად უნდა გამოიყენებოდეს.



ნახ. 3.4. ორშესასვლელიანი ფორმალური ნეირონი, რომელიც ამუშავებს შავი და თეთრი უჯრედების ერთგანზომილებიანი მიმდევრობით წარმოდგენილ სახეს.

ნეირონის მიერ შესასრულებული ფუნქცია შემდეგი ცხრილით განისაზღვრება :

| შესასვლელი 1 | შესასვლელი 2 | საჭირო გამოსასვლელი |
|--------------|--------------|---------------------|
| 1 | 1 | 0 |
| 1 | 0 | 0 |
| 0 | 1 | 1 |
| 0 | 0 | 0 |

მოცემული ამოცანისათვის ნეირონის წონებისა და ზღურბლის მნიშვნელობები ყოველგვარი სწავლების სპეციალური პროცედურის გარეშეც განისაზღვრება. ადვილად შეიძლება დავრწმუნდეთ, რომ საჭირო მოთხოვნებს $\Theta = 0, W_1 = -1, W_2 = +1$ ნაკრები აკმაყოფილებს. მუქიდან ნათელისაკენ გადასვლის საზღვრის დეტექტირების ამოცანის შემთხვევაში კი წონებს ადვილი უნდა შეეცვალოს.

ზოგად შემთხვევაში წონების გადასაწყობად ნეირონის სწავლებისას შექმნილია სხვადასხვა ალგორითმები, რომლებიც განხილული იქნება ფორმალური ნეირონებისაგან შედგენილი კონკრეტული ტიპის ნეირონული ქსელების მიხედვით.


ლექცია 4. როზენბლატის პერსეპტრონი.

უმარტივესი ნეირონული ქსელი – როზენბლატის პერსეპტრონი. წრფივი განცალკევებადობა და თეორემა პერსეპტრონის სწავლების შესახებ.

ამ და მომდევნო ლექციებში ჩვენ შევუდგებით ლიტერატურაში აღწერილი ხელოვნური ნეირონული ქსელების ძირითადი მოდელებისა და შესაბამისი ამოცანების უშუალო განხილვას. დავიწყებთ პერსეპტრონით – კიბერნეტიკულ განხორციელებამდე (რეალიზაციამდე) მიყვანილი პირველი ნეიროქსელური პარადიგმით (ნიმუშით, მაგალითით).

როზენბლატის პერსეპტრონი.

ერთ-ერთ პირველ ხელოვნურ წრედს, რომელსაც პერცეფციის (აქმის ; ლათ. perceptio) და აღქმულ სტიმულზე რეაქციის ფორმირების უნარი გააჩნდა, როზენბლატის პერსეპტრონი (perceptron) წარმოადგენს (F. Rosenblatt, 1957). პერსეპტრონი მისი ავტორის მიერ განიხილებოდა არა როგორც კონკრეტული ტექნიკური მოწყობილობა, არამედ როგორც ტვინის მუშაობის მოდელი. უნდა აღინიშნოს, რომ გამოკვლევათა რამდენიმე ათწლეულის შემდეგ თანამედროვე გამოკვლევები ხელოვნური ნეირონული ქსელების დარგში იშვიათად ისახავს ასეთ მიზანს.



ნახ. 4.1. როზენბლატის ელემენტარული პერსექტრონი.

უმარტივესი კლასიკური პერსექტრონი შეიცავს ნეირონის მსგავს საბი ტიპის ელემენტებს (იხ. ნახ. 4.1.). მათი დანიშნულება საერთო ჯამში შეესაბამება წინა ლექციაში განხილული რეფლექტორული ნეირონული ქსელის ნეირონებს. S-ელემენტები ქმნის სენსორული უჯრედების ბაღურას (ბადისებრ გარსს) სიგნალების მისაღებად გარე სამყაროდან. ამის შემდეგ სიგნალები ასოციაციური ანუ A-ელემენტების ფენას მიეწოდება (გამოსახულების გასამარტივებლად კავშირები (ბმები) S-უჯრედებიდან A-უჯრედებამდე ნაწილობრივადაა ნაჩვენები). მხოლოდ ასოციაციური ელემენტები, რომლებიც ფორმალურ ნეირონებს წარმოადგენს, ინფორმაციის არაწრფივ დამუშავებას აწარმოებს, და ასეთ ელემენტებს კავშირების (ბმების) ცვალებადი წონები გააჩნია. დაფიქსირებული წონების მქონე R-ელემენტები კი ქმნის პერსექტრონის რეაქციის სიგნალს შემავალ სტიმულზე.

როზენბლატი ასეთ ნეირონულ ქსელს სამფენიანს უწოდებდა, მაგრამ თანამედროვე ტერმინოლოგიით, რომელიც ლექციათა ამ კურსშია დაცული, წარმოდგენილ ქსელს ერთფენიანად განიხილავენ, რადგან მას ნეიროპროცესორული ელემენტების მხოლოდ ერთი ფენა გააჩნია. ერთფენიანი პერსექტრონი S-დან A-მდე დამყარებული სინაფსური კავშირების (ბმების) W მატრიცით ხასიათდება. ამ მატრიცის W_{ij} ელემენტი შეესაბამება კავშირს (ბმას), რომელიც i-ურ S-ელემენტიდან j-ურ A-ელემენტამდე მიდის.

კორნელის საავიაციო ლაბორატორიაში MARK-1 პერსპეტრონის ელექტროტექნიკური მოდელი დააპროექტეს, რომელიც 8 გამომავალ R -ელემენტს და 512 A -ელემენტს შეიცავდა. მათი შეერთება სხვადასხვა კომბინაციით იყო შესაძლებელი. ამ პერსპეტრონზე ანბანის ასოებისა და გეომეტრიული სახეების გამოსაცნობად ექსპერიმენტების მთელი სერია ჩატარდა.

როზენბლატის ნაშრომებში გაკეთდა დასკვნა იმის შესახებ, რომ განხილული არქიტექტურის ნეირონულ ქსელს *ნებისმიერი* ლოგიკური ფუნქციის ასახვა (აღწარმოება) შეეძლება, მაგრამ, როგორც ეს მოგვიანებით მ. მინსკისა და ს. პეიპერტის მიერ იყო ნაჩვენები (M.Minsky, S.Papert, 1969), ხსენებული დასკვნა ზუსტი არ აღმოჩნდა. გამოვლინდა ერთფენიანი პერსპეტრონების აურიდებელი (მოუცილებელი, მოუშორებელი) შეზღუდვები და ამის შემდეგ ძირითადად პერსპეტრონის მრავალფენიანი ვარიანტის განხილვა დაიწყო, რომელშიც პროცესორული ელემენტების რამდენიმე ფენა არსებობს.

დღევანდელი პოზიციებიდან ერთფენიანი პერსპეტრონი უფრო ისტორიულ ინტერესს წარმოადგენს, მაგრამ მის მაგალითზე შესაძლებელია ძირითადი ცნებებისა და ნეირონული ქსელების სწავლების მარტივი ალგორითმების შესწავლა.

თეორემა პერსპეტრონის სწავლების შესახებ.

ქსელის სწავლება თითოეული ნეირონის წონითი კოეფიციენტების გადაწყობაში (დაყენებაში) მდგომარეობს. დავუშვათ, რომ გვაქვს ვექტორთა (x^α, y^α) , $\alpha = 1, \dots, p$ წყვილების სიმრავლე, რომელსაც *მასწავლებელი* (გამწაფველი, გამწვრთნელი) *ა(მო)ნაკრები* ეწოდება. ნეირონულ ქსელს მოცემულ მასწავლებელ (გამწაფველ, გამწვრთნელ) *ა(მო)ნაკრებზე* ნასწავლი (გაწვრთნილი, გაწაფული) ვუწოდოთ, თუ ქსელის შესასვლელებზე თითოეული x^α ვექტორის მიწოდებისას გამოსასვლელებზე ყოველთვის შესაბამისი y^α ვექტორი მიიღება.

ფ. როზენბლატის მიერ წამოყენებული სწავლების მეთოდი მდგომარეობს წონათა მატრიცის იტერაციულ გადაწყობაში, რომელიც თანამიმდევრობით

ამცირებს ცდომილებას გამოშვალ ვექტორებში. ალგორითმი რამდენიმე ბიჯს შეიცავს :

| | |
|---------|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| ბიჯი 0. | ყველა ნეირონის წონათა $W(t=0)$ საწყისი მნიშვნელობები შემთხვევით სიდიდეებად მიიჩნევა. |
| ბიჯი 1. | ქსელს x^α შემავალი სახე მიეწოდება, შედეგად გამოშვალვი $\tilde{y}^\alpha \neq y^\alpha$ სახის ფორმირება ხდება. |
| ბიჯი 2. | გამოითვლება ქსელის მიერ გამოსასვლელზე დაშვებული ცდომილების $\delta^\alpha = (y^\alpha - \tilde{y}^\alpha)$ ვექტორი. შემდგომი იდეა იმაში მდგომარეობს, რომ წონითი კოეფიციენტების ვექტორის ცვლილება მცირე ცდომილებათა არეში გამოსასვლელზე გაჩენილი ცდომილების პროპორციული უნდა იყოს, ან ნულის ტოლი, თუ ეს ცდომილება ნულს უდრის. |
| ბიჯი 3. | წონათა ვექტორების მოდიფიცირება $W(t + \Delta t) = W(t) + \eta \cdot x^\alpha \cdot (\delta^\alpha)^T$ ფორმულით ხორციელდება. აქ $0 < \eta < 1$ – სწავლების ტემპს, ხოლო T – ტრანსპონირების ნიშანს წარმოადგენს, დაბოლოს, t და $t + \Delta t$ – ბიჯთა წინა და მომდევნო მომენტებია. |
| ბიჯი 4. | 1 – 3 ბიჯები მეორდება ყველა მასწავლებელი ვექტორისათვის. მთელი ა(მო)ნაკრების წარდგენის ერთ ციკლს ეპოქს ეწოდება. სწავლება რამდენიმე ეპოქის გავლის შემდეგ სრულდება, სახელდობრ : ან ა) როცა იტერაციების დაახლოება მოხდება, ესე იგი წონების ვექტორის ცვლილება შეწყდება, ან ბ) როცა სრული, ყველა ვექტორით დაჯამებული, აბსოლუტური ცდომილება გარკვეულ მცირე მნიშვნელობაზე ნაკლები გახდება. |

მესამე ბიჯზე გამოყენებული ფორმულა შემდეგ გარემოებებს ითვალისწინებს : ა) მოდიფიცირებას წონათა მატრიცის მხოლოდ ის კომპონენტები განიცდის, რომლებიც შესასვლელების არანულოვან მნიშვნელობებს შეესაბამება ; ბ) წონის ნაზრდის ნიშანი ცდომილების ნიშანს შეესაბამება, ესე იგი დადებითი შეცდომა ($\delta > 0$ და, ამრიგად, გამოსასვლელის მნიშვნელობა ნაკლებია საჭიროზე) კავშირის (ბმის) გაძლიერებას იწვევს ; გ) ყოველი ნეირონის სწავლება დანარჩენი ნეირონების სწავლებისაგან დამოუკიდებლად ხორციელდება, რაც – ბიოლოგიური თვალსაზრისით ძალიან მნიშვნელოვან – სწავლების *ლოკალურობის* პრინციპს შეესაბამება.

სწავლების ამ მეთოდს ფ. როზენბლატმა უწოდა «კორექციის მეთოდი შეცდომის სიგნალის უკუგადაცემით». მოგვიანებით უფრო ფართოდ « δ -წესის» სახელწოდება გავრცელდა. წარმოდგენილი ალგორითმი *მასწავლებლით სწავლების* ალგორითმთა მნიშვნელოვან კლასს მიეკუთვნება, ვინაიდან ცნობილია როგორც შემავალი ვექტორები, ასევე გამომავალი ვექტორების საჭირო მნიშვნელობები (სხვანაირად რომ ვთქვათ, წარმოდგენილია მასწავლებელი, რომელსაც მოსწავლის პასუხის სისწორე შეუძლია შეაფასოს).

როზენბლატის მიერ დამტკიცებული თეორემა δ -წესით განხორციელებული სწავლების კრებადობის შესახებ გვეუბნება, რომ პერსეპტრონს ნებისმიერი მასწავლებელი a (მო)ნაკრების შესწავლა (ათვისება) შეუძლია, თუ განსახორციელებელი ფუნქცია პერსეპტრონის მიერ რეალიზებად ფუნქციათა კლასს მიეკუთვნება, ანუ, სხვანაირად, თუ პერსეპტრონს ამ a (მო)ნაკრების *წარმოდგენის უნარი გააჩნია*.

წრფივი განცალკევებადობა და პერსეპტრონული წარმოდგენადობა.

თითოეული პერსეპტრონის ნეირონი ფორმალურ ზღურბლურ ელემენტს წარმოადგენს, რომელიც ერთეულოვან მნიშვნელობებს იღებს, თუ ჯამური აწონილი შესასვლელი გარკვეულ ზღურბლურ მნიშვნელობაზე მეტია :

$$y_j = \begin{cases} 1, & \sum_i W_{ij} x_i > \Theta_j \\ 0, & \sum_i W_{ij} x_i \leq \Theta_j \end{cases}$$


ამრიგად, წონებისა და ზღურბლის მოცემული სიდიდეების პირობებში ნეირონს გამომაგალი აქტივობის განსაზღვრული მნიშვნელობა გააჩნია შესასვლელების ყოველი შესაძლო ვექტორისათვის. შესასვლელ ვექტორთა სიმრავლე, რომელზეც ნეირონი აქტიურია ($y = 1$), განცალკევებულია ასეთ ვექტორთა სიმრავლისაგან, რომელზეც ნეირონი პასიურია ($y = 0$), შემდეგი განტოლებით აღწერილი *ჰიპერსიბრტყით* :

$$\sum_i W_{ij} x_i - \Theta_j = 0 .$$

მაშასადამე, ნეირონს შესასვლელთა ვექტორების მხოლოდ ორი ისეთი სიმრავლის *განცალკევება* შეუძლია, რომლისთვისაც ერთი სიმრავლის მეორე სიმრავლისაგან წამკვეთი ჰიპერსიბრტყე არსებობს. ასეთ სიმრავლეებს *წრფივად განცალკევებადი* ეწოდება. ეს ცნება მაგალითზე დავასურათოთ.

დავუშვათ, რომ გვაქვს ნეირონი, რომლისთვისაც შემავალი ვექტორი სიბრტყის განმსაზღვრელ მხოლოდ ორ (x_1, x_2) ბულის კომპონენტს შეიცავს. მოცემულ სიბრტყეზე ვექტორთა შესაძლო მნიშვნელობები ერთეულოვანი კვადრატის წვეროებს შეესაბამება. ყოველ წვეროში განსაზღვრულია ნეირონის აქტივობის *საჭირო (მოთხოვნილი)* მნიშვნელობა : 0 (ნახ. 4.2.-ზე – თეთრი წრე) ან 1 (შავი წრე იმავე ნახაზზე). უნდა დადგინდეს : არსებობს თუ არა ნეირონის წონებისა და ზღურბლთა ისეთი ნაკრები, რომელზეც ამ ნეირონს სხვადასხვა ფერის წრეთა განცალკევება შეეძლება?

ნახაზზე 4.2. წარმოდგენილია ერთ-ერთი ისეთი სიტუაცია, როცა ამის გაკეთება *შეუძლებელია* თეთრი და შავი წრეების სიმრავლეთა წრფივი განცალკევებადობის გამო.



ნახ. 4.2. თეთრი წრეები არ შეიძლება განვაცალკევოთ შავებისაგან ერთი წრფით.

ამ ნახაზისათვის ნეირონის საჭირო (მოთხოვნილი) აქტივობა განისაზღვრება ცხრილით, რომელშიც ადვილი ამოსაცნობია XOR-ფუნქციის («გამორიცხველი ან»-ის) ჭეშმარიტობის შემდეგი ტაბულა :

| X_1 | X_2 | Y |
|-------|-------|-----|
| 0 | 0 | 0 |
| 1 | 0 | 1 |
| 0 | 1 | 1 |
| 1 | 1 | 0 |

ფუნქციის სხვადასხვა მნიშვნელობების შესაბამის არგუმენტთა სიმრავლეების წრფივი განუცალკევებლობა იმას ნიშნავს, რომ ლოგიკურ მოწყობილობებში ესოდენ ფართოდ გამოყენებული XOR-ფუნქცია არ შეიძლება წარმოდგენილი იყოს ფორმალური ნეირონით. მისი სწორედ ასეთი მოკრძალებული შესაძლებლობები იქნა გამოყენებული ფ. როზენბლატის პერსეპტრონული მიმართულების კრიტიკისათვის მ. მინსკისა და ს. პეპერტის მხრიდან.

არგუმენტთა რიცხვის გაზრდისას მდგომარეობა კიდევ უფრო კატასტროფული ხდება : ფარდობითი რაოდენობა ფუნქციებისა, რომლებსაც წრფივი განცალკევებადობის თვისება გააჩნია, მკვეთრად მცირდება. მასასადამე, მკვეთრად იზღუდება ფუნქციათა ის კლასი, რომელიც პერსექტრონით შეიძლება იყოს რეალიზებული (ეგრეთ წოდებული პერსექტრონული წარმოდგენადობის თვისების მქონე ფუნქციების კლასი). შესაბამისი მონაცემები მოყვანილია შემდეგ ცხრილში :

| ცვლადების რიცხვი N | შესაძლო ლოგიკური ფუნქციების სრული რაოდენობა 2^{2^N} | მათ შორის წრფივად განცალკევებადი ფუნქციები |
|----------------------|-------------------------------------------------------|--------------------------------------------|
| 1 | 4 | 4 |
| 2 | 16 | 14 |
| 3 | 256 | 104 |
| 4 | 65536 | 1882 |
| 5 | > 1000000000 | 94572 |

როგორც ვხედავთ, ერთფენიანი პერსექტრონი უკიდურესად შეზღუდულია თავის შესაძლებლობებში ზუსტად წარმოადგინოს წინასწარ მოცემული ლოგიკური ფუნქცია. უნდა აღინიშნოს, რომ მოგვიანებით, გასული საუკუნის სამოცდაათიანი წლების დასაწყისში, ეს შეზღუდვა გადალახული იქნა ნეირონების რამდენიმე ფენის შემოტანით, მაგრამ კრიტიკულმა განწყობამ და დამოკიდებულებამ კლასიკური პერსექტრონის მიმართ ძალიან შეასუსტა ინტერესი ხელოვნური ნეირონული ქსელების სფეროში და დაამუხრუჭა სამეცნიერო კვლევები ამ დარგში.

დასასრულს შევჩერდეთ იმ პრობლემებზე, რომლებიც ღია დარჩა ფ. როზენბლატის პუბლიკაციის შემდეგ. ამ ამოცანების ნაწილი მოგვიანებით გადაწყდა (და ნაწილობრივად განხილულია მომდევნო ლექციებში), ზოგიერთი კი სრულ თეორიულ განხილვას დღესაც მოითხოვს.

1. სიმრავლეთა წრფივი განცალკევებადობის პირობის პრაქტიკული შემოწმება. როზენბლატის თეორემა წარმატებული სწავლების გარანტიას მხოლოდ პერსექტრონულად წარმოდგენად ფუნქციებისათვის იძლევა, მაგრამ არაფერს ამბობს იმის შესახებ, თუ როგორ გამოვავლინოთ პრაქტიკულად ეს თვისება *სწავლებაში*.
2. რამდენი ბიჯი იქნება საჭირო იტერაციული სწავლების დროს? სხვა სიტყვებით : გაჭიანურებული, გაჯანჯლებული სწავლება შეიძლება იყოს როგორც ფუნქციის წარმოდგენადობის შედეგი (და ამ შემთხვევაში იგი არასდროს დასრულდება), ასევე უბრალოდ ალგორითმის თავისებურება.
3. როგორ გავლენას ახდენს სწავლებაზე სახეთა წარდგენის მიმდევრობა სწავლების ეპოქის განმავლობაში?
4. საერთოდ თუ აქვს σ -წესს უპირატესობები წონათა მარტივ გადასინჯვასთან (გადარჩევასთან) შედარებით, ანუ თუ წარმოდგენს იგი სწრაფი სწავლების კონსტრუქციულ ალგორითმს?
5. როგორი იქნება სწავლების ხარისხი, როცა მასწავლებელი ა(მ)ონაკრები ვექტორთა შესაძლო წყვილების *მხოლოდ ნაწილს* შეიცავს? როგორი იქნება პერსექტრონის პასუხები ახალ ვექტორებზე?

უკანასკნელი საკითხი უკავშირდება ინფორმატიკული (გამოთვლითი) ნეირომეტრიკების ღრმა შრეებს. ისინი შეეხება ხელოვნურ სისტემათა უნარს *განზოგადოს* შეზღუდული ინდივიდუალური გამოცდილება სიტუაციების უფრო ფართო კლასზე, როცა გამოძახილი წინასწარ ცნობილი არ არის ნეიროქსელისათვის. სიტუაცია, სადაც სისტემას უხდება ახალ სახეებთან მუშაობა, ტიპურია, რადგან *ყველა შესაძლო* მაგალითის რაოდენობა ექსპონენტურად სწრაფად იზრდება ცვლადთა რიცხვის მომატებასთან ერთად, ამიტომ პრაქტიკაში ქსელის ინდივიდუალური გამოცდილება ყოველთვის პრინციპულად არ არის სრული.

განზოგადების შესაძლებლობები ნეიროქსელებში დაწვრილებით იქნება განხილული შემდეგ ლექციაში.

ლექცია 5. ნეირონულ ქსელებში სწავლების პროცესთა თვისებები.

ნეირონული ქსელების სწავლება მაგალითებზე. განზოგადებათა (კატეგორიების) ფორმირება სწავლებისას. ნეირონული ქსელის ნიშანთვისებითი და კონფიგურაციული (ფაზური) სივრცე. სწავლება როგორც მრავალფაქტორიანი ოპტიმიზაციის ამოცანა.

მაგალითებზე ნეირონული ქსელის სწავლების ამოცანა.

თავისი ორგანიზაციისა და ფუნქციური დანიშნულების მიხედვით ხელოვნური ნეირონული ქსელი რამდენიმე შესასვლელითა და გამოსასვლელით შემავალი სტიმულების – გარე სამყაროს შესახებ სენსორული ინფორმაციის – გამომავალ მმართველ სიგნალებად გარკვეულ გარდასახვას ასრულებს. გარდაქმნილი სტიმულების რიცხვი ქსელის შესასვლელთა n რაოდენობას უდრის, ხოლო გამომავალი სიგნალების რიცხვი გამოსასვლელთა m რაოდენობას შეესაბამება. n განზომილების ყველა შესაძლო შემავალი ვექტორის ერთობლიობა \mathbf{X} ვექტორულ სივრცეს ქმნის, რომელსაც ამჟამად ჩვენ ნიშანთვისებით სივრცეს ვუწოდებთ. შესაბამისი სივრცეების განზომილების იგულისხმება შეკრებისა და სკალარზე გამრავლების ჩვეულებრივი ვექტორული ოპერაციების გამოყენება (დაწვრილებით იხ. ლექცია 2). ანალოგიურად, გამომავალი ვექტორები ასევე ქმნის ნიშანთვისებით სივრცეს, რომელიც \mathbf{Y} სიმბოლოთი აღინიშნება. ახლა ნეირონული ქსელი შეიძლება განიხილებოდეს როგორც გარკვეული მრავალგანზომილებიანი ფუნქცია $F: \mathbf{X} \rightarrow \mathbf{Y}$, რომლის არგუმენტი შესასვლელთა ნიშანთვისებით სივრცეს მიეკუთვნება, ხოლო მნიშვნელობა – გამომავალ ნიშანთვისებით სივრცეს.

ქსელის ნეირონთა სინაფსური წონითი კოეფიციენტების ნებისმიერი მნიშვნელობების პირობებში ქსელით რეალიზებული ფუნქცია ასევე ნებისმიერია. საჭირო ფუნქციის მისაღებად კი წონათა სპეციფიკური (განსაკუთრე-

ბული) არჩევა აუცილებელი. ყველა ნეირონის ყველა წონითი კოეფიციენტის მოწესრიგებული ერთობლიობა W ვექტორის სახით შეიძლება წარმოვადგინოთ. ასეთი ვექტორების სიმრავლე კი ქმნის ვექტორულ სივრცეს, რომელსაც *მდგომარეობათა სივრცე* ანუ *კონფიგურაციული (ფაზური) სივრცე* ეწოდება და W სიმბოლოთი აღინიშნება. ტერმინი «ფაზური სივრცე» მოვიდა მრავალ ნაწილაკთა სტატისტიკური ფიზიკიდან, სადაც ამ სიტყვებით სისტემის შემადგენელი ყველა ნაწილაკის კოორდინატებისა და იმპულსების ერთობლიობა აღინიშნება.

ვექტორის მოცემა კონფიგურაციულ სივრცეში მთლიანად განსაზღვრავს ყველა სინაფსურ წონას და, ამრიგად, ქსელის მდგომარეობასაც. მდგომარეობას, რომლის დროსაც ქსელი დაკისრებულ ფუნქციას ასრულებს, ქსელის W^* *ნასწავლ მდგომარეობას* უწოდებენ. შევნიშნოთ, რომ მოცემული ფუნქციისათვის ნასწავლი მდგომარეობა შეიძლება არ არსებობდეს ან ერთადერთი არ იყოს. ახლა სწავლების ამოცანა ფორმალურად კონფიგურაციულ სივრცეში რაღაც ნებისმიერი W^0 მდგომარეობიდან ნასწავლ მდგომარეობაში გადასვლის პროცესის აგების ეკვივალენტურია (ტოლფასია).

საჭირო ფუნქცია ცალსახად აღიწერება ნიშანთვისებითი X სივრცის თითოეული ვექტორისათვის Y სივრციდან რაღაც ვექტორის შესაბამისობის მოცემით. ერთნეირონიანი ქსელის შემთხვევაში საზღვრის დეტექტირების ამოცანიდან, რომელიც მესამე ლექციის ბოლოშია განხილული, საჭირო ფუნქციის სრული აღწერა ვექტორთა მხოლოდ ოთხი წევრის მოცემით მიიღწევა. მაგრამ ზოგად შემთხვევაში, როგორც, მაგალითად, ვიდეოგამოსახულებასთან მუშაობისას, ნიშანთვისებით სივრცეებს შეიძლება მაღალი განზომილება გააჩნდეს, ამიტომ ბულის ვექტორების შემთხვევაშიც კი ფუნქციის ცალსახა განსაზღვრა ერთობ უზარმაზარი ხდება (იმ პირობით, ცხადია, რომ ფუნქცია ცხადად არ არის მოცემული, მაგალითად, ფორმულით ; მაგრამ ცხადი სახით მოცემული ფუნქციებისათვის, ჩვეულებრივ, ნეიროქსელური მოდელებით მათი წარმოდგენის მოთხოვნილება არც წარმოიქმნება). მრავალ პრაქტიკულ შემთხვევაში საჭირო ფუნქციების მნიშვნელობები არგუმენტის მოცემული მნიშვნელობებისათვის ექსპერიმენტიდან ან დაკვირვებებიდან მიიღება და, მაშასადამე, ცნობილია ვექტორების მხოლოდ *შეზღუდული ერთობლიობისათვის*. გარდა ამისა, ფუნქციის ცნობილი მნიშვნელობები შეიძლება ცდომილებებს შეიცავდეს, ხოლო ცალკეული მონაცემები შეიძლება ნაწილობრივ ეწინააღმდეგებოდეს კიდევ ერთმანეთს. ამ

მიზეზების გამო ნეირონული ქსელის წინაშე, ჩვეულებრივ, არსებული მაგალითების საფუძველზე ფუნქციის მიაზღობითი წარმოდგენის ამოცანა დგას. ვექტორებს შორის შესაბამისობების მაგალითებს, რომლებიც მკვლევარის განკარგულებაშია, ან ყველა მაგალითიდან სპეციალურად შერჩეულ განსაკუთრებულად წარმომადგენლობით მონაცემებს მასწავლებელ ა(მო)ნაკრებს უწოდებენ. მასწავლებელი ა(მო)ნაკრები, ჩვეულებრივ, ვექტორთა წყვილის მოცემით განისაზღვრება, თანაც ყოველ წყვილში ერთი ვექტორი სტიმულს შეესაბამება, ხოლო მეორე – მოთხოვნილ (საჭირო) რეაქციას. ნეირონული ქსელის სწავლება მდგომარეობს მასწავლებელი ა(მო)ნაკრების სტიმულთა ყველა ვექტორზე მოთხოვნილი (საჭირო) რეაქციების მიღებაში ნეირონების წონითი კოეფიციენტების არჩევის გზით.

კიბერნეტიკის ზოგადი პრობლემა, რომელიც მოცემული ფუნქციური ქცევის ხელოვნური სისტემის აგებას გულისხმობს, ნეირონული ქსელების კონტექსტში საჭირო ხელოვნური ქსელის *სინთეზის* ამოცანად განიხილება. იგი შემდეგ ქვეამოცანებს შეიძლება შეიცავდეს : 1) გადასაწყვეტი ამოცანისათვის არსებითი ნიშნების არჩევა და ნიშანთვისებითი სივრცეების ფორმირება ; 2) გადასაწყვეტი ამოცანის ადეკვატური ნეირონული ქსელის არქიტექტურის არჩევა ან დაპროექტება ; 3) მასწავლებელი ა(მო)ნაკრების მიღება ნიშანთვისებითი სივრცეების ყველაზე წარმომადგენლობითი, ექსპერტთა აზრით, ვექტორებიდან ; 4) ნეირონული ქსელის სწავლება მასწავლებელ ა(მო)ნაკრებზე.

უნდა აღინიშნოს, რომ პირველი სამი ქვეამოცანა ნეირონულ ქსელებთან მუშაობის გარკვეულ ექსპერტულ გამოცდილებას მოითხოვს, და აქ არ არსებობს ამომწურავი ფორმალური რეკომენდაციები. ეს საკითხები მთელი ამ კურსის მანძილზე განიხილება სხვადასხვა ნეიროქსელურ არქიტექტურებთან დაკავშირებით, მათი სწავლების თავისებურებათა და გამოყენებათა ილუსტრაციებით.

კლასიფიკაცია და კატეგორიზაცია.

იმ შემთხვევაში, როცა გამომავალი ნიშანთვისებითი სივრცე წარმოადგენს დისკრეტულ ჩამონათვალს მონაცემთა ორი ან მეტი ჯგუფით, ნეირონული ქსელის ამოცანა მიაკუთვნოს შემაჯავლი ვექტორები ერთ-ერთ ამ ჯგუფს. ასეთ შემთხვევაში ამბობენ, რომ ნეიროქსელური სისტემა მონაცემთა *კლასიფიკაცია*ს და *კატეგორიზაცია*ს ასრულებს.

ეს ორი ინტელექტუალური ამოცანა, ეტყობა, ერთმანეთისაგან უნდა განვასხვავოთ. ტერმინი *კლასი* გარკვეული ნიშნებისა და წესების მიხედვით გამოყოფილი და დაჯგუფებული საგნებისა და ცნებების (სახეების) ერთობლიობად შეიძლება განისაზღვროს. *კლასიფიკაცია* გარკვეული *სახის* მოთავსებას გულისხმობს კლასში ამ ფორმალური წესებით ნიშნების ერთობლიობის საფუძველზე. *კატეგორია* კი (თუ ამ ცნების სპეციფიკურ ფილოსოფიურ ხასიათს მოვწყდებით) სახეთა მხოლოდ გარკვეულ ზოგად თვისებებს და სახეთა შორის კავშირებს (ბმებს) ადგენს. *კატეგორიზაციის* (ესე იგი მოცემული სახის რომელიმე კატეგორიასთან კავშირის გარკვევის) ამოცანა გაცილებით უფრო ნაკლებადაა განსაზღვრული, ვიდრე კლასისადმი მიმართების პრობლემა. სხვადასხვა კატეგორიების საზღვრები არამკაფიოა, ბუნდოვანი, და, ჩვეულებრივ, თავად კატეგორია ფორმალური განმარტების საფუძველზე კი არ აღიქმება, არამედ მხოლოდ სხვა კატეგორიებთან შედარების შედეგად. კლასების საზღვრები კი, პირიქით, საკმარისად ზუსტადაა განსაზღვრული – სახე მოცემულ კლასს მიეკუთვნება, თუ მას ამ კლასისათვის დამახასიათებელი ნიშნების აუცილებელი რაოდენობა გააჩნია.

მაშასადამე, კლასიფიკატორმა (მაკლასიფიცირებელმა სისტემამ) უნდა დაადგინოს : ეკუთვნის თუ არა სახე ერთ-ერთ ფორმალურად განსაზღვრულ კლასს. ასეთი ამოცანის მაგალითებია მცენარეთა კლასიფიკაცია ბოტანიკაში, ქიმიურ ნივთიერებათა კლასიფიკაცია მათი თვისებებისა და შესაძლო რეაქციათა ტიპების მიხედვით, და მასთანანი. ფორმალური ნიშნები «თუ..., მაშინ...» ტიპის წესების საშუალებით შეიძლება განისაზღვროს, ხოლო სისტემები, რომლებიც ასეთ წესებს იყენებს, *საექსპერტო სისტემების* სახელწოდებითაა ცნობილი. ნეირონულ ქსელებზე აგებული კლასიფიკატორების გამოყენების ტრადიციულ არეს მალალი ენერგიების ექსპერიმენტული ფიზიკა წარმოადგენს, სადაც ერთ-ერთ აქტუალურ ამოცანად ექსპერიმენტში დარეგისტრირებული – ელემენტარულ ნაწილაკებთან დაკავშირებული – მოვლენების სიმრავლიდან მხოლოდ მოცემული ექსპერიმენტისათვის საინტერესო ხდომილობათა გამოყოფა მიაჩნიათ.

კატეგორიზაციის პრობლემა ერთი საფეხურით უფრო მაღლა დგას სირთულის მიხედვით კლასიფიკაციასთან შედარებით. მისი თავისებურება ისაა, რომ, სახის მიკუთვნების გარდა რომელიმე ჯგუფისათვის, აუცილებელია თავად ამ ჯგუფების დადგენა, ესე იგი კატეგორიების ფორმირება.

მასწავლებლით სწავლების შემთხვევაში (მაგალითად, პერსპექტონში) კატეგორიათა ფორმირება «სინჯებისა და შეცდომების მეთოდით» ხორციელდება ცნობილი – ექსპერტის მიერ მიცემული – პასუხების მქონე მაგალითების საფუძველზე. კატეგორიათა ფორმირება ძალიან გვაგონებს სწავლების პროცესს ცოცხალ ორგანიზმებში და ამიტომ ექსპერტს, ჩვეულებრივ, «სუპერვიზორს» ანუ მასწავლებელს უწოდებენ. მასწავლებელი სწავლებას კავშირების პარამეტრთა და, უფრო იშვიათად, თავად ქსელის ტოპოლოგიის ცვლილების საშუალებით მართავს.

კატეგორიზატორის ამოცანას წარმოადგენს განზოგადებული ნიშნების ფორმირება მაგალითების ერთობლიობაში. მაგალითების რაოდენობის გაზრდისას არაარსებითი, შემთხვევითი ნიშნების შერბილება ან სულაც წაშლა ხდება, ხოლო ხშირად გამოვლენილი ნიშნები ძლიერდება, თანაც ამ დროს კატეგორიათა საზღვრების თანდათანობით დაზუსტებასაც აქვს ადგილი. კარგად ნასწავლ ნეიროქსელურ სისტემას შეუძლია ნიშნების ამოღება ახალი – სისტემისათვის ადრე უცნობი – მაგალითებიდან და მათ საფუძველზე მისაღები გადაწყვეტილებების მიღება.

მნიშვნელოვანია ხაზი გაესვას განსხვავებას ორი ტიპის «ცოდნის» თავისებურებებს შორის : ერთი მხრივ, არსებობს არაცხადი «ცოდნა», რომელიც ხელოვნურმა ნეირონულმა ქსელმა დაიმახსოვრა, და, მეორე მხრივ, ცხადი, ფორმალური «ცოდნა», ჩადებული საექსპერტო სისტემებში. ზოგიერთი მსგავსება და განსხვავება მათ შორის წარმოდგენილია შემდეგ ცხრილში.

| | საექსპერტო სისტემები | ნეიროქსელური სისტემები |
|--------------|---------------------------------------------------------------------------------------------------------------------------------------|-----------------------------------------------------------------------------------------------------------------------------------------------|
| ცოდნის წყარო | ექსპერტის ფორმალიზებული გამოცდილება, გამოხატული ლოგიკური მტკიცებების – წესების და ფაქტების – სახით, რომლებსაც უცილობლად იღებს სისტემა | ექსპერტ-მასწავლებლის, რომელიც არჩევს მაგალითებს სწავლებისათვის, და ნეირონული სისტემის, რომელიც ამ მაგალითებზე სწავლობს, ერთობლივი გამოცდილება |

| | | |
|-------------------------|---------------------------------------------------------------------|-------------------------------------------------------------------------------------------------------------------------------------|
| ცოდნის ხასიათი | «მარცხენა ნახევარსფეროს» ფორმალურ-ლოგიკური ცოდნა წესების სახით | «მარჯვენა ნახევარსფეროს» ასოციაციური ცოდნა ქსელის ნეირონებს შორის კავშირების სახით |
| ცოდნის განვითარება | წესებისა და ფაქტების ერთობლიობის (ცოდნის ბაზის) გაფართოების სახით | სწავლების გაგრძელების ფორმით მაგალითების დამატებით მიმდევრობაზე, კატეგორიათა საზღვრების დაზუსტებით და ახალი კატეგორიების ფორმირებით |
| ექსპერტის როლი | წესების საფუძველზე საექსპერტო სისტემის ცოდნის სრულ მოცულობას იძლევა | აწარმოებს დამახასიათებელი მაგალითების შერჩევას და ამასთან არ ასაბუთებს სპეციალურად თავის არჩევანს |
| ხელოვნური სისტემის როლი | ფაქტებისა და წესების მიმდევრობის ძებნა აზრის დასამტკიცებლად | ინდივიდუალური გამოცდილების ფორმირება მაგალითებისა და კატეგორიზაციის საფუძველზე მიღებული კატეგორიების ფორმით |

განსხვავება საექსპერტო და ნეიროქსელურ სისტემათა ხასიათში განაპირობებს განსხვავებას მათი გამოყენების სფეროებშიც. საექსპერტო სისტემები გამოიყენება ვიწრო საგნობრივ სფეროებში კარგად სტრუქტურირებული ცოდნით, მაგალითად, კონკრეტული ტიპის დანადგარების დაზიანებათა კლასიფიკაციისას, ფარმაკოლოგიაში, სინჯების ქიმიური შედგენილობის ანალიზისას და ა.შ. ნეირონული ქსელები კი, ჩამოთვლილი სფეროების გარდა, გამოიყენება ამოცანებში ნაკლებად სტრუქტურირებული ინფორმა-

ციით, მაგალითად, სახეთა, ხელნაწერი ტექსტის გამოცნობისას, მეტყველების ანალიზისას და სხვ.

ნეირონული ქსელის სწავლება მასწავლებლით – მრავალფაქტორიანი ოპტიმიზაციის ამოცანა.

ცნება ოპტიმიზაციის ამოცანის შესახებ.

ოპტიმიზაციის თეორიის გამოყენება ნეირონული ქსელების სწავლებისასათვის ძალიან მიმზიდველია, რადგან ოპტიმიზაციის მრავალი კარგი და მოსინჯული მეთოდი არსებობს, რომელიც სტანდარტულ კომპიუტერულ პროგრამამდე მიყვანილი. სწავლების პროცესის შეპირისპირება (შედარება) რაღაც ოპტიმუმის ძებნის პროცესთან არც ბიოლოგიურ საფუძვლებს არის მოკლებული, თუ გარემო პირობებთან ორგანიზმის ადაპტაციის ელემენტები საკვების ოპტიმალური რაოდენობის, ენერგიის ოპტიმალური ხარჯვის და ა.შ. ასპექტში განიხილება. ოპტიმიზაციის მეთოდების დაწვრილებითი განხილვა ცდება ლექციათა ამ კურსის ჩარჩოებს, ამიტომ აქ ჩვენ შემოვიფარგლებით მხოლოდ ძირითადი ცნებებით. საკითხის უფრო ღრმად შესწავლა ბ. ბანდის წიგნით შეიძლება.

ერთი ნამდვილი ცვლადის $f(x)$ ფუნქცია აღწევს ლოკალურ მინიმუმს რაღაც x_0 წერტილზე, თუ არსებობს ამ წერტილის ისეთი δ -არე, რომ ყველა x -სათვის ამ არიდან, ესე იგი $|x - x_0| < \delta$ პირობის შესრულებისას, ადგილი აქვს $f(x) > f(x_0)$ უტოლობას.

ფუნქციის სიგლუვის თვისებათა შესახებ დამატებითი ვარაუდის გარეშე, მხოლოდ მოცემული განმარტების გამოყენებით, შეუძლებელია მინიმუმის წერტილის უზღუდრად (სარწმუნოდ) დადგენა, ვინაიდან ნებისმიერი არე წერტილების კონტინუუმს შეიცავს. მინიმუმის *მახლოებითი* ძებნისათვის რიცხვითი მეთოდების გამოყენებისას მკვლევარი რამდენიმე პრობლემას შეიძლება წააწყდეს. ჯერ ერთი ფუნქციის მინიმუმი შეიძლება ერთადერთი არ იყოს, მეორეც და პრაქტიკაში ხშირად *გლობალური* და არა ლოკალური მინიმუმის დადგენა ესაჭიროებათ, მაგრამ, ჩვეულებრივ, ყოველთვის რჩება ეჭვი : ხომ არ გააჩნია ფუნქციას კიდევ ერთი, ნაპოვნზე უფრო ღრმა, მინიმუმი?

მრავალგანზომილებიან სივრცეში ფუნქციის ლოკალური მინიმუმის მათემატიკურ განმარტებას იგივე სახე აქვს, თუ x და x_0 წერტილებს ვექტორებით შევცვლით, ხოლო მოდულის ნაცვლად ნორმას გამოვიყენებთ. მრავალი ცვლადის (მრავალი *ფაქტორის*) ფუნქციისათვის მინიმუმის ძებნა არსებითად უფრო ძნელ ამოცანას წარმოადგენს, ვიდრე ერთი ცვლადის ფუნქციისათვის. ეს დაკავშირებულია უპირველეს ყოვლისა იმასთან, რომ ფუნქციის მნიშვნელობის შემცირების *ლოკალური* მიმართულება შეიძლება არ შეესაბამებოდეს მინიმუმის წერტილისაკენ მოძრაობის მიმართულებას. გარდა ამისა, განზომილების ზრდასთან ერთად სწრაფად იზრდება ფუნქციის გამოსათვლელად საჭირო დანახარჯები.

ოპტიმიზაციის ამოცანის ამოხსნა მეტწილად ხელოვნებას წარმოადგენს ; ნებისმიერ სიტუაციაში უეჭველად მომუშავე და ეფექტური ზოგადი მეთოდები არ არსებობს. იმ მეთოდებს შორის, რომლებსაც ხშირად მიმართავენ, შეიძლება გამოვყოთ ნელდერის სიმპლექს-მეთოდი, ზოგიერთი გრადიენტული მეთოდი, აგრეთვე შემთხვევითი ძებნის მეთოდები. მე-9 და მე-15 ლექციებში ოპტიმიზაციის ამოცანის გადასაწყვეტად მოწვის იმიტაციისა და გენეტიკური ძებნის მეთოდები განიხილება, რომლებიც შემთხვევითი ძებნის მეთოდთა რიცხვში შედის.

მაშინ, როცა ნებისმიერი დამოუკიდებელი ცვლადი დისკრეტულია და გარკვეული ფიქსირებული ნაკრებიდან ერთი მნიშვნელობის მიღება შეუძლია, მრავალგანზომილებიანი ოპტიმიზაციის ამოცანა რამდენადმე მარტივდება. ამ დროს ძებნის წერტილთა სიმრავლე *სასრული* ხდება და, მაშასადამე, ამოცანა შეიძლება, თუნდაც თეორიულად, გადაწყდეს სრული გადარჩევის გზით. ოპტიმიზაციის ამოცანებს ძებნის სასრული სიმრავლით *კომბინატორული ოპტიმიზაციის* ამოცანებს უწოდებენ.

კომბინატორული ამოცანებისათვის ასევე არსებობს მიახლოებითი ამონახსნის ძებნის მრავალი მეთოდი, რომელიც წერტილების გადარჩევის გარკვეულ სტრატეგიას ახორციელებს გამოთვლათა მოცულობის არსებით შემცირების უზრუნველყოფით. აღსანიშნავია, რომ მოწვის იმიტაცია და გენეტიკური ალგორითმი კომბინატორული ოპტიმიზაციის ამოცანებშიც შეიძლება გამოვიყენოთ.

ოპტიმიზაციის ამოცანის დასმა ნეირონული ქსელის სწავლებისას.

დავუშვათ, რომ გვაქვს ნეირონული ქსელი, რომელიც ახორციელებს შესასვლელთა ნიშანთვისებითი \mathbf{X} სივრციდან X ვექტორების გარდასახვას გამოშვალა \mathbf{Y} სივრცის Y ვექტორებად, რაც $F: \mathbf{X} \rightarrow \mathbf{Y}$ სახით ჩავწეროთ. ქსელი W მდგომარეობაში იმყოფება მდგომარეობათა \mathbf{W} სივრციდან. ამის შემდეგ დავუშვათ, რომ გვაქვს (X^α, Y^α) , $\alpha = 1, \dots, p$ მასწავლებელი ა(მო)ნაკრები. განვიხილოთ სრული E შეცდომა, რომელსაც ქსელი W მდგომარეობაში უშვებს :

$$E = E(W) = \sum_{\alpha} \|F(X^\alpha; W) - Y^\alpha\|^2 = \sum_{\alpha} \sum_i [F_i(X^\alpha; W) - Y_i^\alpha]^2.$$

შეგჩერდეთ სრული შეცდომის ორ თვისებაზე. ჯერ ერთი, $E = E(W)$ შეცდომა წარმოადგენს W მდგომარეობის ფუნქციას, რომელიც მდგომარეობათა სივრცეზე განსაზღვრული და, განმარტების თანახმად, არაუარყოფით მნიშვნელობებს იძენს. მეორეც, რაღაც W^* ნასწავლ მდგომარეობაში, როცა ქსელი შეცდომებს არ უშვებს მასწავლებელ ა(მო)ნაკრებზე, მოცემული ფუნქცია ნულის ტოლ მნიშვნელობას იღებს. ამრიგად, ნასწავლი მდგომარეობები შემოტანილი $E(W)$ ფუნქციის მინიმუმის წერტილებს წარმოადგენს.

მამასადამე, ნეირონული ქსელის სწავლების ამოცანა შეცდომის ფუნქციის მინიმუმის ძებნის ამოცანას წარმოადგენს მდგომარეობათა სივრცეში და, ამრიგად, მისი ამოხსნისათვის ოპტიმიზაციის თეორიის სტანდარტული მეთოდების გამოყენება შეიძლება. ეს ამოცანა მრავალფაქტორიანი ამოცანების კლასს ეკუთვნის : ასე, მაგალითად, N შესასვლელიანი და M გამოშვასვლელიანი ერთფენიანი პერსეპტრონისათვის საქმე ეხება მინიმუმის ძებნას $N \times M$ განზომილების სივრცეში.

პრაქტიკაში შეიძლება გამოიყენებოდეს ნეირონული ქსელები მდგომარეობებში შეცდომის გარკვეული მცირე მნიშვნელობით, როცა ეს მდგომარეობები არ წარმოადგენს ზუსტად შეცდომის ფუნქციის მინიმუმებს. სხვანაირად რომ ვთქვათ, ამონახსნად მიიჩნევა გარკვეული მდგომარეობა W^* ნასწავლი მდგომარეობის არიდან. ამ დროს შეცდომის დასაშვები დონე

კონკრეტული გამოყენებითი ამოცანის თავისებურებებით, აგრეთვე მომხმარებლისათვის სწავლებაზე გასაწევი დანახარჯების მისაღები მოცულობით განისაზღვრება.

ამოცანა

ორი შესასვლელისა და ერთი გამოსასვლელის მქონე ერთფენიანი პერსპექტრონის სინაფსურ წონით კოეფიციენტებს -1 და $+1$ მნიშვნელობების მიღება შეუძლია. ზღურბლის მნიშვნელობა კი ნულს შეადგენს. განიხილეთ ასეთი ლოგიკური «და» ფუნქციის პერსპექტრონის სწავლების ამოცანა მრავალფაქტორიანი ოპტიმიზაციის პრობლემად.

ლექცია ნ. მრავალფენიანი პერსპექტივიზაცია.

ერთფენიანი ნეირონული ქსელების შეზღუდულობა. ნეირონული ქსელის იერარქიული ორგანიზაციის აუცილებლობა. მრავალფენიანი პერსპექტივიზაცია. შეცდომათა უკუგავრცელების ალგორითმი.

ნეიროქსელურ არქიტექტურათა იერარქიული ორგანიზაციის აუცილებლობა.

წინა ლექციებში ჩვენ წავაწყდით ერთფენიანი ქსელების შესაძლებლობებზე დადებულ უკიდურესად მკაცრ შეზღუდვებს და, კერძოდ, კლასთა წრფივი განცალკევებადობის მოთხოვნას. ბიოლოგიური ქსელების აგებულების თავისებურებანი უბიძგებს მკვლევარს უფრო რთული, სახელდობრ, იერარქიული არქიტექტურების გამოყენებისაკენ. იდეა შედარებით მარტივია – იერარქიის დაბალ დონეებზე კლასები ისე გარდაიქმნება, რომ მივიღოთ წრფივად განცალკევებული სიმრავლეები, რომლებიც, თავის მხრივ, წარმატებით იქნება გამოცნობილი ნეირონების მიერ იერარქიის მომდევნო (მაღალ) დონეებზე.


მაგრამ ძირითად პრობლემას, რომელიც ტრადიციულად ზღუდავს შესაძლო ქსელურ ტოპოლოგიებს უმარტივესი სტრუქტურებით, სწავლების პრობლემა წარმოადგენს. სწავლების ეტაპზე ქსელს მასწავლებელ ა(მო)ნაკრებად წოდებული გარკვეული შემავალი ნიმუშები წარედგინება და მიღებული გამომავალი რეაქციების გამოკვლევა ხდება. სწავლების მიზანი მდგომარეობს მოცემულ მასწავლებელ ა(მო)ნაკრებზე დაკვირვებული რეაქციებისათვის საჭირო (ადეკვატური) სახის მიცემაში სინაფსური ბმების მდგომარეობათა ცვლილებით. ქსელს ნასწავლად მიიჩნევენ, თუ ყველა რეაქცია სტიმულთა მოცემულ ნაკრებზე ადეკვატურია. მასწავლებლით სწავლების მოცემული კლასიკური სქემა ითხოვს შეცდომათა ცხად ცოდნას *თითოეული* ნეირონის ფუნქციონირებისას, რაც, უდავოდ, ძნელია იერარქიული სისტემებისათვის, სადაც უშუალოდ მხოლოდ შესასვლელები და გამოსა-

სვლელები კონტროლირდება. გარდა ამისა, აუცილებელი სიჭარბე იერარქიულ ქსელებში იწვევს იმას, რომ სწავლების მდგომარეობა *მრავალი* ხერხით შეიძლება იყოს რეალიზებული, რაც გაურკვევლობის ელფერს ანიჭებს თავად «ნეირონის მიერ დაშვებული შეცდომის» ცნებას.

ესოდენ სერიოზული სიძნელების არსებობა მნიშვნელოვნად აფერხებდა პროგრესს ნეირონული ქსელების სფეროში გასული საუკუნის ოთხმოციანი წლების შუამდე, როცა იერარქიული ქსელების სწავლების ეფექტური ალგორითმები იქნა მიღებული.

მრავალფენიანი პერსპეტრონი.

განვიხილოთ იერარქიული ქსელური სტრუქტურა, რომელშიც ერთმანეთთან დაკავშირებული ნეირონები (ქსელის კვანძები) რამდენიმე ფენადაა გაერთიანებული (ნახ. ნ.1). ასეთი არქიტექტურების აგების შესაძლებლობაზე ჯერ კიდევ ფ. როზენბლატმა მიუთითა, მაგრამ მან ვერ შეძლო სწავლების პრობლემის გადაწყვეტა. ქსელის ნეირონთშორისი სინაფსური კავშირები ისეა მოწყობილი, რომ ყოველი ნეირონი იერარქიის მოცემულ დონეზე იღებს და ამუშავებს სიგნალებს უფრო დაბალი დონის თითოეული ნეირონისაგან. ამრიგად, მოცემულ ქსელში ნეიროიმპულსების გავრცელების გამოყოფილი მიმართულება არსებობს – შემავალი ფენიდან ერთი (ან რამდენიმე) ფარული ფენის გავლით ნეირონების გამომავალ ფენისაკენ. ასეთი ტოპოლოგიის ნეიროქსელს ჩვენ *განზოგადებულ მრავალფენიან პერსპეტრონს* ან, თუ ეს გაუგებრობას არ გამოიწვევს, უბრალოდ *პერსპეტრონს* ვუწოდებთ.



ნახ. 6.1. მრავალფენიანი პერსეპტრონის სტრუქტურა (პერსეპტრონს ხუთი შესასვლელი, ფარულ ფენაში სამი ნეირონი და გამოძვალ ფენაში ერთი ნეირონი გააჩნია).

პერსეპტრონი წარმოადგენს ქსელს, რომელიც მაკაკლოკისა და პიტსის ფორმალური ნეირონების რამდენიმე თანამიმდევრულად შეერთებული ფენისაგან შედგება. იერარქიის ყველაზე დაბალ დონეზე სენსორული ელემენტებისაგან შედგენილი *შემაჯალი* ფენა იმყოფება, რომლის ამოცანა მხოლოდ შემაჯალი ინფორმაციის მიღებითა და ქსელში გავრცელებით ამოწურება. შემდეგ მიდის ერთი ან, უფრო იშვიათად, რამდენიმე *ფარული* (მალული) ფენა. ყოველ ნეირონს ფარულ ფენაზე ერთი გამოსასვლელი და რამდენიმე შესასვლელი გააჩნია, რომლებიც წინა ფენის გამოსასვლელს ან უშუალოდ X_1, X_2, \dots, X_n შემაჯალ სენსორებს უერთდება. ნეირონი წონითი კოეფიციენტების უნიკალური w ვექტორით ხასიათდება. ფენის ყველა ნეირონის წონა აყალიბებს მატრიცას, რომელსაც ჩვენ V ან W სიმბოლოს მივაწერთ. ნეირონს მისი შესასვლელების აწონილი ჯამის

გამოანგარიშება და ამ ჯგამის გამომავალ სიგნალად არაწრფივი გარდასახვა ევალება :

$$y = 1 / \left(1 + \exp \left(- \left(\sum_i W_i x_i - \Theta \right) \right) \right) . \quad (6.1)$$

უკანასკნელი, გამომავალი, ფენის ნეირონთა გამოსასვლელეები კლასიფიკაციის $Y = Y(X)$ შედეგს აღწერს. პერსექტრონის მუშაობის თავისებურებანი შემდეგი ხასიათისაა. ყოველი ნეირონი იერარქიის წინა ღონის ნეირონებიდან მასთან მოსული სიგნალეების შეჯამებას ახდენს სინაფსთა მდგომარეობის შესაბამისი წონებით და საპასუხო სიგნალს იძლევა (აგზნებულ მდგომარეობაში გადადის), თუ მიღებული ჯამი ზღურბლურ მნიშვნელობას აღემატება. პერსექტრონს გადაჰყავს იერარქიის ყველაზე დაბალი ღონის ნეირონთა აგზნების ზარისხის მაჩვენებელი შემავალი სახე უმაღლესი ღონის ნეირონებით განსაზღვრულ გამომავალ სახეში. ამ უკანასკნელთა რაოდენობა, ჩვეულებრივ, შედარებით მცირეა. ნეირონის აგზნების მდგომარეობა მაღალ ღონეზე შემავალი სახის ამა თუ იმ კატეგორიის მაჩვენებელია.

ტრადიციულად ანალოგური ლოგიკა განიხილება, როცა სინაფსური კავშირების დასაშვები მდგომარეობები ნებისმიერი ნამდვილი რიცხვებით განისაზღვრება, ხოლო ნეირონთა აქტივობის ზარისხები – ნამდვილი რიცხვებით 0-დან 1-მდე. ზოგჯერ იკვლევენ აგრეთვე მოდელეებს დისკრეტული არითმეტიკით, რომელშიც სინაფსი ბულის ორი ცვლადით ხასიათდება : აქტივობით (0 ან 1) და პოლარობით (-1 ან +1), რაც სამნიშნა ლოგიკას შესაბამება. ნეირონების მდგომარეობათა აღწერა კი ამ დროს ბულის ერთი ცვლადის საშუალებით შეიძლება ხდებოდეს. მოცემული დისკრეტული მიდგომა ნეირონული ქსელის მდგომარეობათა კონფიგურაციულ სივრცეს სასრულ ხასიათს ანიჭებს, იმაზე რომ აღარა ვთქვათ რა უპირატესობებია აპარატული რეალიზაციის თვალსაზრისით.

აქ, ძირითადად, აღწერილი იქნება მრავალფენიანი ქსელის კლასიკური ვარიანტი ანალოგური სინაფსებით და ნეირონთა გადაცემის სიგმიოდური ფუნქციით, რომელიც (6.1) ფორმულით განისაზღვრება.

შეცდომათა უკუგავრცელების მეთოდით სწავლება.

მრავალფენიანი ქსელის სწავლებისათვის 1986 წელს რუმელჰარტის, ჰინტონისა და ვილიამსის (Rummelhart D.E., Hinton G.E., Williams R.J., 1986) მიერ წამოყენებული იყო შეცდომათა უკუგავრცელების (error back propagation) ალგორითმი. დიდძალი პუბლიკაცია მრავალფენიან ქსელებში სწავლების ამ ალგორითმის გამოყენების შესახებ პრაქტიკულად ადასტურებს მის პრინციპულ შესაძლებლობას.

იმთავითვე ჩნდება მართებული, საფუძვლიანი შეკითხვა : რატომ არ შეიძლება მრავალფენიანი პერსეპტრონის სწავლებისათვის როზენბლატის უკვე ცნობილი δ -წესის (იხ. ლექცია 4) გამოყენება? პასუხი იმაში მდგომარეობს, რომ როზენბლატის მეთოდის გამოსაყენებლად აუცილებელია ნეირონთა არა მხოლოდ მიმდინარე y გამოსასვლელების, არამედ მოთხოვნილი სწორი Y მნიშვნელობების ცოდნა. მრავალფენიანი ქსელის შემთხვევაში ხსენებული სწორი მნიშვნელობები მხოლოდ გამოძვალა ფენის ნეირონებისათვისაა ცნობილი. გამოსასვლელთა მოთხოვნილი (საჭირო) მნიშვნელობები ფარული ფენების ნეირონებისათვის კი უცნობია, რაც, ბუნებრივია, ზღუდავს δ -წესის გამოყენებას.

უკუგავრცელების ძირითადი იდეა ფარული ფენების ნეირონებისათვის შეცდომის შეფასების მიღებაში მდგომარეობს. შევნიშნოთ, რომ გამოძვალა ფენის ნეირონების მიერ დაშვებული ცნობილი შეცდომები ფარული ფენების ნეირონთა ჯერ კიდევ უცნობი შეცდომების შედეგად ჩნდება. რაც უფრო მეტია ფარული ფენის ნეირონსა და გამოძვალა ნეირონს შორის სინაფსური კავშირის მნიშვნელობა, მით უფრო დიდ გავლენას ახდენს წინა ფენის შეცდომა მომდევნო ფენის შეცდომაზე. მაშასადამე, ფარული ფენების ელემენტთა შეცდომის შეფასება შეიძლება მივიღოთ მომდევნო ფენების შეცდომათა აწონილი ჯამის სახით. სწავლებისას ინფორმაცია იერარქიის დაბალი ფენებიდან მაღალი ფენებისაკენ ვრცელდება, ხოლო ქსელით დაშვებული შეცდომების – შექცეული მიმართულებით, რაც მეთოდის დასახელებაშიც პოულობს ასახვას.

გადავიდეთ ამ ალგორითმის დაწვრილებით განხილვაზე. ნოტაციის (პირობით ნიშანთა სისტემის) გასამარტივებლად შემოვიფარგლოთ სიტუაციით, როცა ქსელს მხოლოდ ერთი ფარული ფენა გააჩნია. შესასვლელებიდან ფარული ფენისაკენ მიმართული წონითი კოეფიციენტების მატრიცა W

ასოთი წარმოვადგინოთ, ხოლო ფარული და გამოძავალი ფენის შემაერთებელი წონების მატრიცა V სიმბოლოთი აღვნიშნოთ. ინდექსებისათვის შემდეგი შეთანხმებები შემოვიღოთ : შესასვლელი მხლოდ i ინდექსით გადავნიშნოთ, ფარული ფენის ელემენტები – j ინდექსით, ხოლო გამოსასვლელი, შესაბამისად, k ინდექსით.

დავუშვათ, რომ ქსელი (X^α, Y^α) , $\alpha = 1, \dots, p$ ა(მო)ნაკრებზე სწავლობს. ნეირონთა რეაქციები ნუსხური y ასოებით აღვნიშნოთ, ხოლო ნეირონთა ჯამური აწონილი შესასვლელი – ნუსხური x ასოებით (სათანადო ინდექსთა გამოყენების პირობებში).

ალგორითმის საერთო სტრუქტურა მეოთხე ლექციაში განხილული აღწერის მსგავსია წონათა დაზუსტების ფორმულათა გართულებით.

ცხრილი 6.1. შეცდომის უკუგავრცელების ალგორითმი.

| | |
|---------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| ბიჯი 0. | ყველა ფენის ყველა ნეირონის წონათა $V(t=0)$ და $W(t=0)$ საწყისი მნიშვნელობები მიჩნეულია შემთხვევით სიდიდეებად. |
| ბიჯი 1. | <p>ქსელს X^α შემავალი სახე მიეწოდება, შედეგად გამოძავალი $y \neq Y^\alpha$ სახე მიიღება. ამ დროს ნეირონები თანამიმდევრობით ფენიდან ფენისაკენ შემდეგი ფორმულებით ფუნქციონირებს :</p> <p>ფარულ ფენაში</p> $x_j = \sum_i W_{ij} X_i^\alpha; \quad y_j = f(x_j) ;$ <p>გამომავალ ფენაში</p> |

| | |
|---------|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| | $x_k = \sum_j V_{jk} y_j; \quad y_k = f(x_k) .$ <p>აქ $f(x)$ – (6.1) ფორმულით განსაზღვრული სიგმოიდური ფუნქციაა.</p> |
| ბიჯი 2. | <p>ქსელის კვადრატული შეცდომის ფუნქციონალს მოცემული შემავალი სახისათვის შემდეგი ფორმა აქვს :</p> $E = 1/2 \sum_k (y_k - Y_k^\alpha)^2 .$ <p>მოცემული ფუნქციონალის მინიმიზება უნდა მოხდეს. ოპტიმიზაციის კლასიკური გრადიენტული მეთოდი არგუმენტის იტერაციულ დაზუსტებაში მდგომარეობს შემდეგი ფორმულის შესაბამისად :</p> $V_{jk}(t+1) = V_{jk}(t) - h \cdot \frac{\partial E}{\partial V_{jk}} .$ <p>შეცდომის ფუნქცია ცხადი ფორმით არ შეიცავს V_{jk} წონაზე დამოკიდებულებას, ამიტომ ვისარგებლოთ რთული ფუნქციის არაცხადი დიფერენცირების ფორმულებით :</p> $\frac{\partial E}{\partial y_k} = \delta_k = (y_k - Y_k^\alpha);$ $\frac{\partial E}{\partial x_k} = \frac{\partial E}{\partial y_k} \cdot \frac{\partial y_k}{\partial x_k} = \delta_k \cdot y_k (1 - y_k);$ |

$$\frac{\partial E}{\partial V_{jk}} = \frac{\partial E}{\partial y_k} \cdot \frac{\partial y_k}{\partial x_k} \cdot \frac{\partial x_k}{\partial V_{jk}} =$$

$$= \delta_k \cdot y_k (1 - y_k) \cdot y_j \cdot$$

აქ გათვალისწინებულია $f(x)$ სიგმოიდური ფუნქციის სასარგებლო თვისება : მისი წარმოებული მხოლოდ თავად ფუნქციის მნიშვნელობით განისაზღვრება, რადგან $f'(x) = f(1-f)$. ამრიგად, V გამოძავალი ფენის წონათა გადასაწყობად საჭირო ყველა სიდიდე მიღებულია.

ბიჯი 3.

ამ ბიჯზე ფარული ფენის წონათა გადაწყობა სრულდება. გრადიენტული მეთოდი კვლავ იძლევა :

$$W_{ij}(t+1) = W_{ij}(t) - h \cdot \frac{\partial E}{\partial W_{ij}}.$$

წარმოებულთა გამოანგარიშება იმავე ფორმულებით ხორციელდება, δ_j შეცდომისათვის რამდენადმე გართულებული ფორმულის გარდა :

$$\frac{\partial E}{\partial x_k} = \frac{\partial E}{\partial y_k} \cdot \frac{\partial y_k}{\partial x_k} = \delta_k \cdot y_k (1 - y_k);$$

$$\frac{\partial E}{\partial y_j} = \delta_j = \sum_k \frac{\partial E}{\partial x_k} \cdot \frac{\partial x_k}{\partial y_j} =$$

$$= \sum_k \delta_k \cdot y_k (1 - y_k) \cdot V_{jk};$$

| | |
|---------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| | $\frac{\partial E}{\partial W_{ij}} = \frac{\partial E}{\partial y_j} \cdot \frac{\partial y_j}{\partial x_j} \cdot \frac{\partial x_j}{\partial W_{ij}} =$ $= \delta_j \cdot y_j (1 - y_j) \cdot X_i^\alpha =$ $= \left(\sum_k \delta_k \cdot y_k (1 - y_k) \cdot V_{jk} \right) \cdot \left(y_j (1 - y_j) \cdot X_i^\alpha \right).$ <p>აქ სწორედ შეცდომათა უკუგავრცელების პრინციპი იქნა გამოყენებული : კერძო წარმოებულები აღებულია მხოლოდ მომდევნო ფენის ცვლადებით. მიღებული ფორმულების საშუალებით ფარული ფენის ნეირონთა წონების მოდიფიცირება ხდება. თუ ნეირონულ ქსელში რამდენიმე ფარული ფენაა, მაშინ უკუგავრცელების პროცედურა თანამიმდევრობით გამოიყენება ყოველი მათგანისათვის, დაწყებული იმ ფენიდან, რომელიც გამოძავალი ფენის წინაა, და დამთავრებული იმ ფენით, რომელიც შემავალი ფენის მერეა. ამასთან ყველა ფორმულა ინარჩუნებს თავის სახეს, მაგრამ გამოძავალი ფენის ელემენტების შეცვლა შესაბამისი ფარული ფენის ელემენტებით ხდება.</p> |
| ბიჯი 4. | <p>1 – 3 ბიჯები ყველა მასწავლებელი ვექტორისათვის მეორდება. სწავლება სრული შეცდომის მცირე მნიშვნელობის ან იტერაციათა დასაშვები რიცხვის მიღწევისას მთავრდება, როგორც ეს როზენბლატის მეთოდშია.</p> |

როგორც მეორე-მესამე ბიჯების აღწერიდან ჩანს, სწავლება დაიყვანება შეცდომის ფუნქციონალის ოპტიმიზაციის ამოცანის ამოხსნამდე გრადიენტული მეთოდით. შეცდომის უკუგავრცელების მთელი «გემო და ლაზათი» იმაში მდგომარეობს, რომ მისი შეფასებისათვის ფარული ფენების ნეირონებისათვის შეიძლება მივიღოთ მომდევნო ფენის შეცდომათა აწონილი ჯამი.

h პარამეტრს სწავლების ტემპის აზრი გააჩნია და იგი საკმარისად მცირე უნდა იყოს მეთოდის კრებადობისათვის. კრებადობის შესახებ აუცილებელია რამდენიმე დამატებითი შენიშვნის გაკეთება. ჯერ ერთი, პრაქტიკა გვიჩვენებს, რომ უკუგავრცელების მეთოდის კრებადობის სისწრაფე ძალიან ნელია. კრებადობის დაბალი ტემპი ყველა გრადიენტული მეთოდის «გენეტი-

კურ სენს» წარმოადგენს, რადგან გრადიენტის ლოკალური მიმართულება სულაც არ ემთხვევა მიმართულებას მინიმუმისაკენ. მეორეც და, წონათა გადაწყობა დამოუკიდებლად ხორციელდება მასწავლებელი ა(მო)ნაკრების სახეთა თითოეული წყვილისათვის. ამასთან ფუნქციონირების გაუმჯობესება რომელიმე მოცემულ წყვილზე შეიძლება, საერთოდ რომ ვთქვათ, იწვევდეს მუშაობის გაუარესებას წინა სახეებზე. ამ თვალსაზრისით კრებადობის *სარწმუნო* გარანტიები არ არსებობს (მეთოდის გამოყენების ძალზე ფართო პრაქტიკის გარდა).

გამოკვლევებით ნაჩვენებია, რომ მასწავლებელი ა(მო)ნაკრების საშუალებით მოცემული ნებისმიერი ფუნქციური ასახვის წარმოსადგენად ნეირონთა სულ *ორი ფენა* საკმარისი. მაგრამ პრაქტიკაში, რთული ფუნქციებისათვის, ერთზე მეტი ფარული ფენის გამოყენებას ნეირონთა სრული რაოდენობის ეკონომიის მოცემა შეუძლია.

დასასრულს გავაკეთოთ შენიშვნა ნეირონთა ზღურბლების შესახებ. ადვილი შესაძენია, რომ ნეირონის Θ ზღურბლი (-1) -ის ტოლ ფიქტიურ x_0 შესასვლელთან მიერთებული დამატებითი W_0 წონის ეკვივალენტად შეიძლება იყოს მიჩნეული. მართლაც, თუ დავუშვებთ, რომ $W_0 = \Theta$, $x_0 = -1$ და შევჯამებას ნულიდან დავიწყებთ, მაშინ შეიძლება განვიხილოთ ნულოვანი ზღურბლის მქონე ახალი ნეირონი ერთი დამატებითი შესასვლელით :

$$\begin{aligned}
 y &= f\left(\sum_{i=1}^n W_i x_i - \Theta\right) = f\left(\sum_{i=1}^n W_i x_i + \Theta \cdot (-1)\right) = \\
 &= f\left(\sum_{i=1}^n W_i x_i + W_0 \cdot x_0\right) = f\left(\sum_{i=0}^n W_i x_i\right)
 \end{aligned}$$

ნეირონთა ზღურბლების შესატყვისი დამატებითი შესასვლელი ნახ.6.1.-ზე ნაჩვენებია მუქი კვადრატებით. ამ შენიშვნის გათვალისწინებით, შესასვლელთა სიმრავლეზე შეჯამების ყველა ფორმულა, რომელიც უკუგავრცელების ალგორითმშია მოცემული, ნულის ტოლი ინდექსით იწყება.

ლექცია 7. სხვა იერარქიული არქიტექტურები.

სამეთაურო ნეირონები და გროსბერგის ნეირონები-დეტექტორები. პრინციპი: «გამარჯვებულს თან მიაქვს ყველაფერი» (WTA – Winner Take All). ლიბ-მან-ჰემინგის მოდელი. კოჰონენის თვითორგანიზაციის რუკა. შემხვედრი გავრცელების ქსელები.

ამ ლექციაში განხილული იქნება ერთგვაროვანი (ერთისა და იმავე ტიპის ნეირონებით შედგენილი) და არაერთგვაროვანი ნეირონული ქსელების კომპონენტები. იერარქიულ არქიტექტურათა ზოგიერთი უპირატესობა – განზოგადების უფრო განვითარებული უნარი, მკაცრი შეზღუდვების არარსებობა წარმოდგენად ასახვათა ტიპებზე ნეირონული ფუნქციის სიმარტივის შენარჩუნებით და ვეპერთელა პარალელურობის თვისება ინფორმაციის დამუშავებისას – უკვე შესწავლილი იყო ჩვენს მიერ წინა ლექციაში, მრავალფენიანი პერსპეტონისა და შეცდომათა უკუგავრცელების მეთოდით მისი სწავლების განხილვისას. ახლა კი ჩვენ გავეცნობით სხვა მიდგომებს ნეიროქსელების აგებისა და სწავლების მეთოდებისადმი, სახელდობრ, სწავლებისადმი უმასწავლებლოდ თვითორგანიზაციის საფუძველზე.

გროსბერგის ვარსკვლავები.

ბიოლოგიური კიბერნეტიკის გარიჟრაჟზე სტეფან გროსბერგის გამოკვლევებში ასახული იდეები მრავალ მომდევნო ნეიროქსელურ ძიებას დაედო საფუძვლად. ამიტომ ჩვენ ვიწყებთ იერარქიული სტრუქტურების განხილვას გროსბერგის შემავალი და გამომავალი ვარსკვლავების კონფიგურაციით (S. Grossberg, 1969).

ნეირონს შემავალი ვარსკვლავის ფორმით გააჩნია N რაოდენობის X_1, X_2, \dots, X_N შესასვლელი, რომლებსაც W_1, W_2, \dots, W_N წონები და შესა-

სვლელთა აწონილ ჯამად წარმოდგენილი ერთი Y გამოსასვლელი შეესაბამება. შემაჯავლი ვარსკვლავი სწავლობს სიგნალის გამოტანას გამოსასვლელზე ყოველთვის, როცა კი შესასვლელზე გარკვეული ვექტორი შედის. ამრიგად, შემაჯავლი ვარსკვლავი თავისი შესასვლელების ერთობლივი მდგომარეობის დეტექტორს წარმოადგენს. სწავლების პროცესი შემდეგი იტერაციული ფორმულით აისახება :

$$W_i(t+1) = W_i(t) + \alpha(X_i - W_i(t)) .$$

სწავლების α ტემპს 0.1 მასშტაბის საწყისი მნიშვნელობა აქვს და სწავლების პროცესში იგი თანდათანობით მცირდება. აწყობის პროცესში ნეირონი გასაშუალებულ მასწავლებელ ვექტორებს უუფლება.

გროსბერგის გამომაჯავლი ვარსკვლავი საწინააღმდეგო ფუნქციას ასრულებს – *სამეთაურო* ნეირონის ფუნქციას, როცა სიგნალის შემოსვლისას შესასვლელზე მას განსაზღვრული ვექტორი გამოაქვს გამოსასვლელზე. ამ ტიპის ნეირონს ერთი შესასვლელი და W_1, W_2, \dots, W_M წონების M გამოსასვლელი გააჩნია, რომლებიც სწავლობს ფორმულით :

$$W_i(t+1) = W_i(t) + \beta(Y_i - W_i(t)) .$$

მიზანშეწონილია $\beta \approx 1$ მნიშვნელობით დაწყება და სწავლების პროცესში მისი თანდათანობითი შემცირება ნულამდე. იტერაციული პროცესის კრებადობის შედეგი მასწავლებელი ვექტორების ერთობლიობიდან მიღებული კრებითი სახე იქნება.

გროსბერგის ვარსკვლავთა ფორმის ნეირონების თავისებურებას მეხსიერების ლოკალურობა წარმოადგენს. შემაჯავლი ვარსკვლავის ფორმის თითოეულ ნეირონს მხოლოდ «თავისი» – მისი შესაბამისი – სახე ახსოვს და უგულებელყოფს ყველა დანარჩენს. ნებისმიერი გამომაჯავლი ვარსკვლავისათვის ასევე დამახასიათებელია მხოლოდ კონკრეტული სამეთაურო ფუნქცია. მეხსიერების სახე მიბმულია გარკვეულ ნეირონთან და სრულებითაც არ ჩნდება ნეირონთა სიმრავლის ურთიერთქმედების შედეგად ქსელში.

«გამარჯვებულს თან მიაქვს ყველაფერი» (WTA - Winner Take All) პრინციპი ლიპმან-ჰემინგის მოდელში.

განვიხილოთ ამოცანა ξ სახის რაღაც X_k კლასში მოხვედრის შესახებ, როცა ეს კლასი განსაზღვრულია მოცემული x_k საბიბლიოთეკო სახეებით. მასწავლებელი ა(მო)ნაკრების თითოეული მოცემული სახე უშუალოდ განსაზღვრავს თავის საკუთარ კლასს და, ამრიგად, ამოცანა «უახლოესი» სახის ძებნაზე დაიყვანება. ორი ორობითი $(0-1)$ სახის შემთხვევაში მანძილი მათ შორის ჰემინგის ხერხით შეიძლება განისაზღვროს როგორც დაუმთხვეველ კომპონენტთა რიცხვი. ახლა, ყველა წყვილი $\rho_k = \rho(X^k, \xi)$ მანძილის გამოთვლის შემდეგ, დასადგენი კლასი განისაზღვრება უმცირესი მანძილით მათ შორის.

ამ ამოცანის ნეიროქსელური ამონახსნის მიღება ლიპმან-ჰემინგის (Lippman R., 1987) არქიტექტურის საფუძველზე შეიძლება. ქსელს ერთნაირი ნეირონების ერთი ფენა გააჩნია, და ამ ნეირონთა რაოდენობა კლასთა რიცხვის ტოლია. ამრიგად, ნებისმიერი ნეირონი «პასუხს აგებს» თავისი კლასისათვის. თითოეული ნეირონი დაკავშირებულია ყველა შესასვლელთან, რომლის რიცხვი განსაზღვრავს საბიბლიოთეკო სახეთა განზომილებას უდრის. კავშირების წონებს ნორმირებული საბიბლიოთეკო სახეების ტოლ სიდიდებად მიიჩნევენ :

$$W_n^m = x_n^m / \left(\sum_i x_i^m \right).$$


აქ W_n^m – კავშირის (ბმის) წონაა n -ურ შესასვლელიდან m -ურ ნეირონამდე (იხ. ნახ. 7.1.). ნეირონულ ქსელში ξ ვექტორის შესახებ ინფორმაციის შემოსვლის პროცესი უიტერაციაა. ამასთან თავდაპირველად შემავალი ვექტორის ნორმირება ხდება

$$s_n = \xi_n / \left(\sum_i \xi_i \right)$$

ფორმულის საფუძველზე, და ნეირონები აქტივობის საწყის ღონეებს იძენს :

$$y^m(0) = f\left(\left(1/2\right)\sum_n s_n W_n^m - \Theta\right).$$

აქ $f(x)$ - ნეირონის გადაცემის ფუნქციაა (სხვანაირად - აქტივაციის ფუნქცია). მას ისე ირჩევენ, რომ იგი ნულს უდრის, თუ $x < 0$, და $f(x) = x$, როცა $x > 0$. Θ ზღურბლთა მნიშვნელობებს კი, ჩვეულებრივ, ნულის ტოლად მიიჩნევენ.



ნახ. 7.1. ლიპმან-ჰემინგის ნეირონული ქსელი.

შემომავალი ვექტორის შემოსვლისას საწყის აგზნებას იძენს ყველა ნეირონი, რომლის მეხსიერების ვექტორთა სკალარული ნამრავლი შემავალ ვექტორზე ზღურბლს აღემატება. შემდგომში მათ შორის უნდა შეირჩეს ერთი, რომლისთვისაც იგი მაქსიმალურია. ამის მიღწევა ხდება «ლატერალური დამუხრუჭების» (ლათ. lateralis – გვერდითი) პრინციპზე აგებული დამატებითი უკუკავშირების შემოტანით ნეირონებს შორის. თითოეული ნეირონი მამუხრუჭებელ (უარყოფით) ზემოქმედებას იღებს ყველა დანარჩენ-

ნი ნეირონისაგან მათი აგზნების დონის პროპორციულად, და ამგზნებ (დადებით) ზემოვმდებებს განიცდის საკუთარი თავის მხრიდან. ნეირონულ ფენაში ლატერალურ კავშირთა წონების ნორმირება ისე ხდება, რომ ჯამური სიგნალი ამგზნები იცოს მხოლოდ მაქსიმალური საწყისი აქტივობის მქონე ნეირონისათვის. დანარჩენი ნეირონი დამუხრუჭებას განიცდის :

$$y^m(t+1) = f\left(y^m(t) - \frac{1}{(M+1)} \sum_{n \neq m} y^n(t)\right).$$

იტერაციათა გარკვეული t რიცხვის შესრულებისას ყველა ნეირონისათვის, ერთის გარდა, $f(x)$ ფუნქციის არგუმენტის მნიშვნელობა უარყოფითი ხდება, რაც მათ y^m აქტივობას ნულად აქცევს. ერთადერთი, აქტიურად დარჩენილი ნეირონი, გამარჯვებულად უნდა ჩაითვალოს. სწორედ იგი მიუთითებს იმ კლასს, რომელსაც ეკუთვნის შემოტანილი სახე. ასეთმა მექანიზმმა მიიღო სახელწოდება : «გამარჯვებულს თან მიაქვს ყველაფერი» (Winner Take All – WTA). WTA–ს მექანიზმი სხვა ნეიროქსელურ არქიტექტურებშიც გამოიყენება. მის საფუძველში ჩადებულ ლატერალური დამუხრუჭების პრინციპს ღრმა ბიოლოგიური საფუძველები გააჩნია და ძალიან ფართოდაა გავრცელებული ცოცხალი ორგანიზმების ნეირონულ ქსელებში.


ლიპმან-ჰემინგის ნეიროქსელური პარადიგმა (ბერძნ. პარადიგმა – მაგალითი, ნიმუში) წარმოადგენს მოდელს მეხსიერების პირდაპირი სტრუქტურით. საბიბლიოთეკო სახეებში მოთავსებული ინფორმაციის განზოგადება სულაც არ ხდება, იგი უშუალოდაა დამახსოვრებული სინაფსურ კავშირებში (ბმებში). მეხსიერება აქ არ არის განაწილებული, ვინაიდან ერთი ნეირონის დაზიანების შემთხვევაში მთლიანად იკარგება ინფორმაცია მეხსიერების მისი შესაბამისი მთელი სახის შესახებ.

კოჰონენის თვითორგანიზაციის ბარათი (რუკა).

ჰემინგის ქსელის საწინააღმდეგოდ კოჰონენის (T.Kohonen, 1982) მოდელი მიწოდებული ინფორმაციის განზოგადებას ასრულებს. კოჰონენის ნეირონული ქსელის მუშაობის შედეგად მიიღება სახე, რომელიც მასწავლებელი ა(მო)ნაკრებიდან ამოღებული ვექტორების განაწილების რუკას წარმოადგენს. ამრიგად, კოჰონენის მოდელის თანახმად, შემავალ სახეთა სივრცეში

კლასტერების (ინგლ. cluster – საერთო ნიშნით გაერთიანებულ ობიექტთა ერთობლიობა) პოვნის ამოცანის ამოხსნა სრულდება.

მოცემული ქსელის სწავლება უმასწავლებლოდ ხდება თვითორგანიზაციის საფუძველზე. სწავლების მიმდინარეობის მიხედვით ნეირონთა წონები კლასტერების ცენტრებისაკენ მიისწრაფვის. კლასტერი ამ შემთხვევაში მასწავლებელი ა(მო)ნაკრების ვექტორთა ჯგუფადაა გაგებული. საინფორმაციო ამოცანათა ამოხსნის ეტაპზე ქსელს შეჰყავს წაყენებული სახე ერთ-ერთ შედგენილ (ჩამოყალიბებულ) კლასტერში და ამით მიუთითებს კატეგორიას, რომელსაც ეს სახე ეკუთვნის.



ნახ. 7.2. კოჰონენის რუკის მაგალითი. ყოველი კვადრატის ზომა შესაბამისი ნეირონის აგზნების ხარისხს შეესაბამება.

განვიხილოთ კოჰონენის ნეირონული ქსელის არქიტექტურა და სწავლების წესები უფრო დაწვრილებით. კოჰონენის ქსელი, ლიპმან-ჰემიჰვის ქსელის მსგავსად, ნეირონების ერთი ფენისაგან შედგება. ყოველი ნეირონის შესასვლელთა რიცხვი შემაჯავლი სახის განზომილებას უდრის. ნეირონების რაოდენობა კი განისაზღვრება წვრილმანების გამოდევნების იმ ხარისხით, რომლითაც სურთ საბიბლიოთეკო სახეთა ნაკრების კლასტერიზაციის განხორციელება. ნეირონთა საკმარისი რაოდენობისა და სწავლების კარგი პარამეტრების პირობებში კოჰონენის ნეირონულ ქსელს შეუძლია არა მხოლოდ სახეთა ძირითადი ჯგუფების გამოყოფა, არამედ მიღებული კლასტერების «ნაზი სტრუქტურის» დადგენაც. ამასთან მსგავს შემაჯავლ სახეებს ნეირონული აქტივობის ასეთივე მსგავსი რუკები შეესაბამება.

სწავლება იწყება კავშირების (ბმების) W_n^m მატრიცისათვის შემთხვევითი მნიშვნელობების მიცემით. შემდგომში თვითორგანიზაციის პროცესი წარმართება, რომელიც მდგომარეობს წონათა სახეცვალებაში შესასვლელზე მასწავლებელი ა(მო)ნაკრების ვექტორთა მიწოდებისას. ყოველი ნეირონისათვის შესაძლებელია შესასვლელის ვექტორამდე მისი მანძილის განსაზღვრა :

$$d_m = \sum_{i=1}^N (x_i(t) - W_i^m(t))^2 .$$

ამის შემდეგ ირჩევენ $m = m^*$ ნეირონს, რომლისთვისაც ეს მანძილი მინიმალურია. სწავლების მიმდინარე t ბიჯზე მოდიფიცირებული იქნება მხოლოდ იმ ნეირონების წონები, რომლებიც m^* ნეირონის არიდანაა :

$$W_n^m(t+1) = W_n^m(t) + \eta(x_n(t) - W_n^m(t)) .$$

თავდაპირველად ნებისმიერი ნეირონის არეში ქსელის ყველა ნეირონი იმყოფება, მაგრამ შემდეგ ეს არე ვიწროვდება. სწავლების ეტაპის დასრულებისას მხოლოდ უახლოესი ნეირონის წონათა დაზუსტება მიდის. სწავლების $\eta(t) < 1$ ტემპი დროის განმავლობაში ასევე მცირდება. მასწავლებელი ა(მო)ნაკრების სახეთა წარდგენა თანამიმდგრულად ხდება და ყოველთვის წონათა შესწორება კეთდება. კოჰონენის ნეირონული ქსელის სწავლება შემაჯავლი ვექტორების დამახინჯებულ ვერსიებზეც შეიძლება : სწავლების

პროცესში დამახინჯებათა შერბილება და წაშლაც კი ხორციელდება, თუ ისინი სისტემატურ (გამუდმებულ) ხასიათს არ ატარებს.

რუკის წარმოდგენის თვალსაჩინოებისათვის კოჰონენის ნეირონების ორგანოზომილებიან მატრიცებად მოგვარება შეიძლება, ამასთან გამარჯვებული ნეირონის არედ მატრიცის (სტრიქონებისა და სვეტების მიხედვით) მეზობელი ელემენტები მიიჩნევა. საბოლოო შედეგის შესაბამისი რუკა მოხერხებულია ორგანოზომილებიან გამოსახულებად წარმოვადგინოთ, რომელზეც ნეირონთა აგზნების სხვადასხვა ხარისხები განსხვავებული ფართობის კვადრატებით მოიცემა. კოჰონენის 100 ნეირონის მიხედვით აგებული რუკის მაგალითი ნაჩვენებია ნახ. 7.2.-ზე.

ყოველი ნეირონი ატარებს ინფორმაციას კლასტერის – შემავალ სახეთა სივრცეში არსებული შენადელის – შესახებ და აყალიბებს მოცემული ჯგუფისათვის კრებით სახეს. ამრიგად, კოჰონენის ნეირონულ ქსელს განზოგადების უნარი გააჩნია. კონკრეტულ კლასტერს რამდენიმე ნეირონიც შეიძლება შეესაბამებოდეს ვექტორთა წონების ახლო მნიშვნელობებით. ამიტომ ერთი ნეირონის დაზიანება იმდენად მნიშვნელოვანი და კრიტიკული არ არის კოჰონენის ნეირონული ქსელის მუშაობისათვის, როგორც ამას ჰემინგის ქსელის შემთხვევაში ჰქონდა ადგილი.


შემხვედრი გავრცელების ნეირონული ქსელი.

შემხვედრი გავრცელების (counter propagation) არქიტექტურა წარმატებით აერთიანებს კოჰონენის ქსელის უპირატესობას, რომელსაც ინფორმაციის განზოგადების შესაძლებლობა განაპირობებს, და გროსბერგის გამომავალი ვარსკვლავის სწავლების სიმარტივეს. შემხვედრი გავრცელების ქსელის შემქმნელი რ. ჰეხტ-ნილსენი (R.Hecht-Nielsen, 1987) რეკომენდაციას იძლევა გამოვიყენოთ ეს არქიტექტურა სისტემათა სწრაფი მოდელირებისათვის კვლევათა საწყის ეტაპებზე, ხოლო შემდგომში, თუ ამის საჭიროება გაჩნდა, გადავიდეთ სწავლების გაცილებით უფრო ძვირ, მაგრამ ზუსტ მეთოდზე შეცდომათა უკუგავრცელებით.

შემხვედრი გავრცელების ნეირონული ქსელი ვექტორთა წყვილების (X^{α}, Y^{α}) ა(მო)ნაკრებზე $X \rightarrow Y$ ასახვის წარმოდგენას სწავლობს. ამ ქსელის შესანიშნავ თავისებურებას მიეკუთვნება უნარი შეისწავლოს აგრე-

თვე XY ერთობლიობის საკუთარ თავშივე ასახვა. ამასთან, განზოგადების წაყლობით, (XY) წყვილის აღდგენის საშუალება ჩნდება ერთი-ერთი ცნობილი $(X$ ან $Y)$ კომპონენტის საფუძველზე. გამოცნობის ეტაპზე მხოლოდ X ვექტორის წარდგენისას (ნულოვანი საწყისი Y -ით) პირდაპირი ასახვა – Y -ის აღდგენა – ხდება და, პირიქით, თუ ცნობილია Y , მაშინ შესაძლებელია მისი შესაბამისი X -ის აღდგენა. პირდაპირი და შებრუნებული, ასევე ცალკეული არარსებული კომპონენტის აღდგენის ჰიბრიდული ამოცანის ამოხსნის შესაძლებლობა ანიჭებს მოცემულ ნეიროქსელურ არქიტექტურას უნიკალური ინსტრუმენტის სტატუსს.

შემხვედრი გავრცელების ქსელი ნეირონთა ორი – კოპონენისა და გროსბერგის – ფენისაგან შედგება (იხ. ნახ. 7.3.). ფუნქციონირების (გამოცნობის) რეჟიმში კოპონენის ფენის ნეირონები მუშაობს პრინციპით «გამარჯვებულს თან მიაქვს ყველაფერი» და განსაზღვრავს კლასტერს, რომელსაც შემავალი სახე მიეკუთვნება. ამის შემდეგ გროსბერგის ფენის გამოშვალი ვარსკვლავი კოპონენის ფენაში გამარჯვებული ნეირონის სიგნალით ქმნის ქსელის გამოსასვლელებზე შესაბამის სახეს.



ნახ. 7.3. შემხვედრი გავრცელების ქსელის არქიტექტურა (გამოსასვლელების გასამარტივებლად ყველა კავშირი არ არის ნაჩვენები).

კოპონენის ფენის წონათა სწავლება მასწავლებლის გარეშე ზორციელდება თვითორგანიზაციის საფუძველზე (იხ. წინა პუნქტი). თავდაპირველად შემავალი (ანალოგური) ვექტორის ნორმირება ხდება მიმართულების შენარჩუნებით. სწავლების ერთი იტერაციის განხორციელების შემდეგ გამარჯვებული ნეირონი განისაზღვრება, რომლის აგზნების მდგომარეობა ერთის ტოლად ყენდება, და შემდეგ მისი შესაბამისი გროსბერგის ვარსკვლავის წონათა მოდიფიცირებაც შეიძლება. კოპონენისა და გროსბერგის ნეირონთა სწავლების ტემპები შეთანხმებული უნდა იყოს. კოპონენის ფენაში გამარჯვებულის არიდან ყველა ნეირონის წონათა სწავლება მიმდინარეობს, ვიდრე ეს არე თანდათანობით ერთ ნეირონამდე არ შევიწროვდება.

შემხვედრი გავრცელების ნასწავლ ქსელს ინტერპოლაციის რეჟიმშიც შეუძლია ფუნქციონირება, როცა კოპონენის ფენაში ტოვებენ არა ერთ, არამედ რამდენიმე გამარჯვებულს. მაშინ მათი აქტივობის დონეთა პროპორციული ნორმირება ხდება, რათა ჯამში ისინი ერთს შეადგენდეს, ხოლო გამომავალი ვექტორი გროსბერგის აქტიური ვარსკვლავების გამომავალ ვექტორთა ჯამით განისაზღვრება. ამრიგად, ნეირონული ქსელი წრფივ ინტერპოლაციას აწარმოებს რამდენიმე კლასტერის შესაბამის გამომავალ ვექტორთა მნიშვნელობებს შორის. მაგრამ ინტერპოლაციის რეჟიმი შემხვედრი გავრცელების ქსელში იმდენად შესწავლილი არ არის, რომ მის ფართო გამოყენებას რეკომენდაცია გაეწიოს.

ლექცია 8. ჰოპფილდის მოდელი.

უკუკავშირიანი ქსელების კონფიგურაცია და მდგრადობა. ჰოპფილდის მოდელი. ჰების სწავლების წესი. ასოციაციური მეხსიერება. სახეთა გამოცნობა.

ჰოპფილდის მოდელს (J.J.Hopfield, 1982) განსაკუთრებული ადგილი უჭირავს ნეიროქსელურ მოდელთა რიგში. აქ პირველად გახდა შესაძლებელი კავშირის დამყარება არაწრფივ დინამიკურ სისტემებსა და ნეირონულ ქსელებს შორის. ქსელის მეხსიერების სახეები დინამიკური სისტემის მდგრად ზღვრულ – მიზიდვის – წერტილებს (ატრაქტორებს) შეესაბამება (ლათ. attractio - მიზიდულობა). განსაკუთრებით მნიშვნელოვანი აღმოჩნდა არაწრფივი დინამიკური სისტემების (და საერთოდ სტატისტიკური ფიზიკის) მათემატიკური აპარატის გადატანის შესაძლებლობა ნეირონულ ქსელებზე. ამასთან ერთად ჰოპფილდის ქსელის მეხსიერების მოცულობის თეორიული შეფასებისა და ქსელის პარამეტრთა იმ არის განსაზღვრის შესაძლებლობა გაჩნდა, სადაც საუკეთესო ფუნქციონირება მიიღწევა.

ამ ლექციაში ჩვენ განვიხილავთ უკუკავშირიანი ქსელების საერთო თვისებებს, დავადგენთ სწავლების წესს ჰოპფილდის ქსელისათვის (ჰების წესს) და გადავალთ ხსენებული ნეირონული ქსელის მეხსიერების ასოციაციური თვისებების მიმოხილვაზე სახეთა გამოცნობის ამოცანათა ამოხსნის ასპექტში.


უკუკავშირიანი ქსელები.

ჩვენს მიერ ადრე განხილული პერსპეტრონი მიეკუთვნება ქსელების კლასს ინფორმაციის გავრცელების მიმართული ნაკადით და არ შეიცავს უკუკავშირებს. ფუნქციონირების ეტაპზე ყოველი ნეირონი თავის ფუნქციას –

სხვა ნეირონებისათვის აგზნების გადაცემას – ზუსტად ერთჯერ ასრულებს. ნეირონთა მდგომარეობების დინამიკა უიტერაციაა.

რამდენადმე უფრო რთულია დინამიკა კოჰონენის ქსელში. ნეირონების კონკურენტული შეჯიბრება მიიღწევა იტერაციებით, რომლებშიც ინფორმაცია ნეირონებს შორის მრავალჯერ გადაიცემა.

ზოგად შემთხვევაში შეიძლება განვიხილოთ ნებისმიერი უკუკავშირების შემცველი ნეირონული ქსელი (იხ. ნახ. 8.1.) ; უკუკავშირებით გადაცემული აგზნება უბრუნდება მოცემულ ნეირონს და იგი ხელმეორედ ასრულებს თავის ფუნქციას. ბიოლოგიურ ლოკალურ ნეიროქსელებზე დაკვირვებები მრავალგვარი უკუკავშირის არსებობას ადასტურებს. ნეიროდინამიკა ასეთ სისტემებში იტერაციული ხდება. ეს თვისება არსებითად აფართოებს ნეიროსელურ არქიტექტურათა ტიპების სიმრავლეს, მაგრამ ერთდროულად ახალ პრობლემათა გაჩენას იწვევს.



ნახ. 8.1. პირდაპირი გავრცელების (A) და უკუკავშირებიანი ქსელების (B) ფრაგმენტები.

ნეირონთა მდგომარეობების უიტერაციო დინამიკა, როგორც ჩანს, ყოველთვის მდგრადია. უკუკავშირები შეიძლება იწვევდეს არამდგრადობათა გაჩე-

ნას, მსგავსად იმ სიტუაციებისა, რომლებიც რადიოტექნიკურ სისტემებში წარმოიქმნება დადებითი უკუკავშირის პირობებში. ნეირონულ ქსელში არამდგრადობა ნეირონების მდგომარეობათა მოხეტიალე, ცთომილ შენაცვლებადადობაში ვლინდება, რასაც სტაციონარულ მდგომარეობათა გაჩენა არ მოჰყვება. ზოგად შემთხვევაში პასუხი შეკითხვაზე ნებისმიერი უკუკავშირიანი სისტემის დინამიკის მდგრადობის შესახებ უკიდურესად რთულია და დღემდე ღია რჩება.

ქვემოთ ჩვენ შევჩერდებით ნეიროქსელური არქიტექტურის მნიშვნელოვან კერძო შემთხვევაზე, რომლისთვისაც მდგრადობის თვისებები დაწვრილებითაა შესწავლილი.

ნეიროდინამიკა ჰოპფილდის მოდელში.

განვიხილოთ N ფორმალური ნეირონით შედგენილი ქსელი, რომელშიც თითოეული ნეირონის აგზნების $S_i, i = 1, N$ ხარისხს მხოლოდ ორი $\{-1, +1\}$ მნიშვნელობის მიღება შეუძლია. ნებისმიერ ნეირონს კავშირი გააჩნია ყველა დანარჩენ S_j ნეირონთან, რომლებიც თავის მხრივ დაკავშირებულია მასთან. i -ურ ნეირონიდან j -ურ ნეირონამდე კავშირის ძალა W_{ij} სიმბოლოთი აღვნიშნოთ.

ჰოპფილდის მოდელში კავშირთა *სიმეტრიულობის* $W_{ij} = W_{ji}$ პირობა და მხოლოდ ნულოვანი $W_{ii} = 0$ დიაგონალური ელემენტების არსებობა იგულისხმება. სამწუხაროდ, ამ პირობას არავითარი კავშირი არ აქვს ბიოლოგიური ქსელებთან, სადაც, პირიქით, თუ ერთი ნეირონი აგზნებას გადასცემს მეორეს, მაშინ ეს უკანასკნელი, უმრავლეს შემთხვევაში, პირველთან უშუალოდ დაკავშირებული არ არის. მაგრამ სწორედ კავშირების სიმეტრიულობა, როგორც ეს მომდევნო მასალიდან გახდება ცხადი, არსებით გავლენას ახდენს დინამიკის მდგრადობაზე.

თითოეული ნეირონის S_j მდგომარეობის ცვლილება ჰოპფილდის მოდელში მაკკალოკისა და პიტსის ფორმალური ნეირონებისათვის მიღებული ცნობილი წესის შესაბამისად ხდება. მის შესასვლელებზე t მომენტში შემოსული S_j სიგნალები კავშირების (ბმების) მატრიცის W_{ij} ელემენტებით

აიწონება და აიჯამება, რითაც შემავალი სიგნალის ძალის სრული დონე განისაზღვრება :

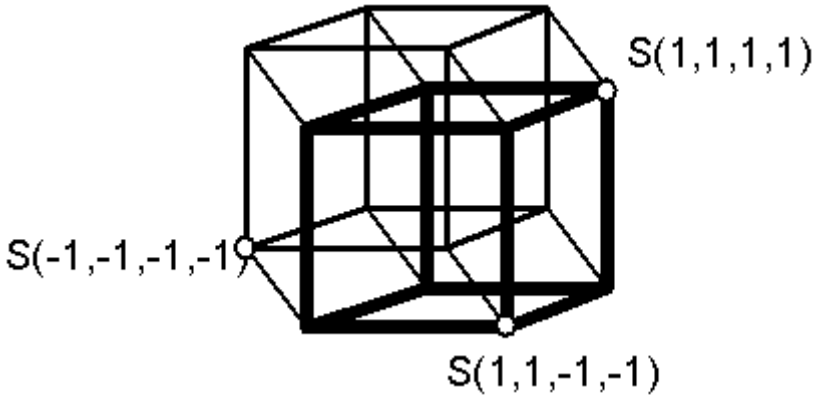
$$h_j = \sum_{i \neq j} W_{ij} S_i .$$

შემდეგ $t+1$ მომენტში ნეირონი იცვლის თავისი აგზნების მდგომარეობას h სიგნალის დონისა და თითოეული ნეირონის ინდივიდუალური T ზღურბლის მიხედვით :

$$\begin{cases} S_j(t+1) = -1, & h_j(t) < T_j \\ S_j(t+1) = +1, & h_j(t) > T_j \\ S_j(t+1) = S_j(t), & h_j(t) = T_j \end{cases} .$$

ყველა ნეირონის აგზნების მდგომარეობათა ცვლილება ერთდროულადაც შეიძლება ხდებოდეს და ასეთ შემთხვევაში *პარალელური* დინამიკის შესახებ ლაპარაკობენ. ასევე განიხილება *მიმდევრობითი* ნეიროდინამიკაც, როცა დროის მოცემულ მომენტში მხოლოდ ერთი ნეირონის მდგომარეობის ცვლილება ხდება. მრავალი გამოკვლევის შედეგად დადგინდა, რომ ნეირონული ქსელის მეხსიერების თვისებები პრაქტუკულად არ არის დამოკიდებული დინამიკის ტიპზე. ნეიროქსელის მოდელირებისას ჩვეულებრივ კომპიუტერზე უფრო მოხერხებულია ნეირონთა მდგომარეობის მიმდევრობით შეცვლა. ჰოპფილდის ნეიროქსელების აპარატურ რეალიზაციებში კი პარალელური დინამიკა გამოიყენება.

ყველა ნეირონის აგზნების S_i მნიშვნელობათა ერთობლიობა დროის გარკვეულ მომენტში ქმნის ქსელის *მდგომარეობის S ვექტორს*. ნეიროდინამიკა იწვევს მდგომარეობის ვექტორის $S(t)$ კანონით ცვლილებას. ნეიროქსელის მდგომარეობათა სივრცეში მდგომარეობის ვექტორი ტრაექტორიას აღწერს. ეს სივრცე ქსელისათვის, რომელშიც თითოეული ნეირონი აგზნების ორი დონით ხასიათდება, ცხადია, ნეირონთა N რიცხვის ტოლი განზომილების ჰიპერკუბის წვეროთა სიმრავლეს წარმოადგენს. ჰიპერკუბის წვეროთა კოორდინატების მნიშვნელობათა შესაძლო ნაკრებები (იხ. ნახ. 8.2.) სწორედ მდგომარეობის ვექტორის შესაძლო მნიშვნელობებს განსაზღვრავს.



ნახ. 8.2. ოთხგანზომილებიანი ჰიპერკუბის პროექცია სიბრტყეზე. ნახაზზე ნაჩვენებია სამი წერტილი ოთხნეირონიანი ქსელის შესაძლო მდგომარეობათა მაგალითს წარმოადგენს.

ასევე მდგომარეობათა ცვლილების დინამიკის მდგრადობის პრობლემა განვიხილოთ. ვინაიდან დროის თითოეულ ბიჯზე გარკვეული i -ური ნეირონი იცვლის თავის მდგომარეობას $(h_i - T_i)$ სიდიდის ნიშნის შესაბამისად, ქვემოთ მოყვანილი თანაფარდობა ყოველთვის არადადებითია :

$$\Delta E_i = -(S_i(t+1) - S_i(t)) \cdot (h_i - T_i) \leq 0 .$$

მაშასადამე, შესაბამის E სიდიდეს, რომელიც ცალკეულ E_i მნიშვნელობათა ჯამს წარმოადგენს, ნეიროდინამიკის პროცესში მხოლოდ შემცირება ან თავისი მნიშვნელობის შენარჩუნება შეუძლია :

$$E = -(1/2) \cdot \sum_i \sum_{j \neq i} W_{ij} S_i S_j + \sum_i S_i T_i .$$

ასეთი გზით შემოტანილი E სიდიდე მდგომარეობის $E = E(S)$ ფუნქციას წარმოადგენს და მას ჰოპფილდის ნეირონული ქსელის *ენერგეტიკული ფუნქცია* ან უბრალოდ *ენერჯია* ეწოდება. ვინაიდან ქსელის დინამიკაში E -ს არაზრდადობის თვისება გააჩნია, იგი ამ ქსელისათვის ერთდროულად ლიაპუნოვის (А.М. Ляпунов, 1892) ფუნქციას წარმოადგენს. ასეთი დინა-

მიკური სისტემის ქცევა მდგრადია მდგომარეობის ნებისმიერი საწყისი $S(t=0)$ ვექტორისათვის და კავშირების (ბმების) ნებისმიერი სიმეტრიული W მატრიცისათვის ნულოვანი დიაგონალური ელემენტებით. ამასთან ერთად დინამიკა ლიაპუნოვის ფუნქციის ერთ-ერთ მინიმუმზე დამთავრდება, თანაც ყველა ნეირონის აქტივობა შემავალ h სიგნალებს დაემთხვევა ნიშნით.

$E(S)$ ენერჯის ზედაპირს მდგომარეობათა სივრცეში ერთობ რთული ფორმა აქვს ლოკალური მინიმუმების დიდი რაოდენობით, რაც, ხატოვნად, დალიანდაგებულ საბანს გვაგონებს. მინიმუმის შესაბამისი სტაციონარული მდგომარეობები შეიძლება ინტერპრეტირებული იქნეს როგორც ნეირონული ქსელის მესხიერების *სახეები*. ევოლუცია ასეთი სახისაკენ შეესაბამება მესხიერებიდან ამოღების პროცესს. კავშირების (ბმების) ნებისმიერი W მატრიცის პირობებში სახეებიც ნებისმიერია. ქსელის მესხიერებაში რაიმე გააზრებული ინფორმაციის ჩასაწერად საჭიროა W წონათა განსაზღვრული მნიშვნელობა, რომლის მიღება სწავლების პროცესში შეიძლება ხორციელდებოდეს.

ჰების სწავლების წესი.

ჰობფილდის ქსელისათვის სწავლების წესი დონალდ ჰების (D. Hebb, 1949) გამოკვლევებს ეყრდნობა, რომელმაც ივარაუდა, რომ ორი ნეირონის შემართებული სინაფსური კავშირი გაძლიერდება, თუ სწავლების პროცესში ორივე ნეირონი შეთანხმებულად განიცდის აგზნებას ან დამუხრუჭებას. მარტივმა ალგორითმა, რომელშიც სწავლების ასეთი მექანიზმია რეალიზებული, *ჰების წესის* სახელწოდება მიიღო. დაწვრილებით განვიხილოთ იგი.

დავუშვათ, რომ მოცემულია სახეთა მასწავლებელი ξ_α , $\alpha = \overline{1, p}$ ა(მო)ნაკრები. მოგვეთხოვება W კავშირების (ბმების) მატრიცის მიღების პროცესის აგება. ამ მატრიცის შესაბამის ნეირონულ ქსელს სტაციონარულ მდგომარეობებად მასწავლებელი ა(მო)ნაკრების სახეები უნდა გააჩნდეს (ნეირონების ზღურბლთა T მნიშვნელობები, ჩვეულებრივ, ნულის ტოლად მიიჩნევა).

ერთი მასწავლებელი სახის შემთხვევაში საჭირო მატრიცას ჰების წესი იძლევა :

$$W_{ij} = \xi_i \cdot \xi_j .$$

ეუჩვენოთ, რომ $S = \xi$ მდგომარეობა სტაციონარულია ასეთი მატრიცის მქონე ჰოპფელდის ქსელისათვის. მართლაც, i და j ნეირონთა ნებისმიერი წყვილისათვის მათი ურთიერთქმედების ენერგია ξ მდგომარეობაში თავის მინიმალურად შესაძლებელ $E_{ij} = -(1/2)\xi_i\xi_j\xi_i\xi_j = -(1/2)$ მნიშვნელობას აღწევს.

ამასთან ერთად სრული E ენერგია $E = -(1/2) \cdot N^2$ სიდიდის ტოლია, რაც გლობალურ მინიმუმს შეესაბამება.

სხვა სახეთა დასამახსოვრებლად იტერაციული პროცესის გამოყენება შეიძლება :

$$W_{ij}^{(\alpha)} = W_{ij}^{(\alpha-1)} + \xi_i^{(\alpha)} \cdot \xi_j^{(\alpha)}, \quad W^{(0)} = 0, \quad \alpha = \overline{1, p} .$$

კავშირების (ბმების) სრული მატრიცის მიღებას იგი ჰების ფორმით უზრუნველყოფს :

$$W_{ij} = \sum_{\alpha=1}^p \xi_i^{(\alpha)} \cdot \xi_j^{(\alpha)} .$$

სახეთა ერთობლიობის მდგრადობა არაა ისე ცხადი, როგორც ერთი სახის შემთხვევაში. ზოგიერთი გამოკვლევა ადასტუებს, რომ ჰების წესით ნასწავლ ნეირონულ ქსელს, საშუალოდ, ქსელის დიდი N ზომების პირობებში, მაქსიმუმ $p \approx 0.14 \cdot N$ სხვადასხვა სახის შენახვა შეუძლია. მდგრადობა ნაჩვენები შეიძლება იქნას ორთოგონალურ სახეთა ერთობლიობისათვის, როცა

$$(1/N) \cdot \sum_{j=1}^N \xi_j^{(\alpha)} \cdot \xi_j^{(\beta)} = \delta_{\alpha\beta} = \begin{cases} 1, & \alpha = \beta \\ 0, & \alpha \neq \beta \end{cases} .$$

ამ შემთხვევაში ყოველი ξ^α მდგომარეობისათვის i -ური ნეირონის ჯამური h_i შესასვლელის ნამრავლი მისი აქტოვობის $S_i = \xi_i^\alpha$ სიდიდეზე დადებითი აღმოჩნდება. ამრიგად, თავად ξ^α მდგომარეობა მიმზიდველ მდგომარეობას (მდგრად ატრაქტორს) წარმოადგენს :

$$h_i \cdot \xi_i^\alpha = \sum_j \left[\left(\sum_\beta \xi_i^\beta \xi_j^\beta \right) \xi_j^\alpha \right] \cdot \xi_i^\alpha = N > 0 .$$

მაშასადამე, ჰების წესი უზრუნველყოფს ჰობფილდის ქსელის მდგრადობას ორთოგონალურ სახეთა შედარებით უმნიშვნელო რაოდენობის მოცემულ ნაკრებზე. შემდეგ პუნქტში ჩვენ შევჩერდებით მიღებული ნეირონული ქსელის მეხსიერების თავისებურებებზე.

მეხსიერების ასოციაციურობა და გამოცნობის ამოცანა.

ჰობფილდის ნეირონული ქსელის მდგომარეობათა მიმდევრობითი შენაცვლებადობის დინამიკური პროცესი გარკვეულ სტაციონარულ მდგომარეობაში სრულდება, რომელიც $E(S)$ ენერგეტიკული ფუნქციის ლოკალურ მინიმუმს წარმოადგენს. ენერჯის არაზრდადობა დინამიკის პროცესში იწვევს S -ის ისეთი ლოკალური მინიმუმის არჩევას, რომლის მიზიდულობის «აუზში» (არეალში), საწყისი S_0 მდგომარეობაც (ქსელისათვის თავდაპირველად მიწოდებული სახეც) ხვდება. ამ შემთხვევაში აგრეთვე ამობენ, რომ S_0 მდგომარეობა S -ის მინიმუმის «ფიალაში (თასში, ჯამში)» იმყოფება.


მიმდევრობითი დინამიკის დროს სტაციონარულ მდგომარეობად არჩეული იქნება ისეთი S სახე, რომელიც ცალკეული ნეირონების მდგომარეობათა ცვლილების მინიმალურ რიცხვს მოითხოვს. ვინაიდან ორი ბინარული ვექტორისათვის კომპონენტების ცვლილებათა მინიმალური რიცხვი, რომლებითაც ერთი ვექტორი მეორეში გადაიყვანება, ჰემინგის $\rho_H(S, S_0)$ მანძილს წარმოადგენს, აქედან შეიძლება დაავასკვნათ, რომ ქსელის დინამიკა ენერჯის უახლოეს – ჰემინგის მიხედვით – ლოკალურ მინიმუმზე მთავრდება.

დაუშვათ, რომ S ვექტორი მეხსიერების გარკვეულ იდეალურ სახეს შეესაბამება. მაშინ S_0 მდგომარეობიდან S მდგომარეობაში ევოლუცია (გადასვლა) შეიძლება შევადაროთ S იდეალური სახის თანდათანობით აღდგენის პროცედურას მისი დამახინჯებული (ხმაურის შემცველი ან არასრული) S_0 ასლის საშუალებით. ინფორმაციის წაკითხვის პროცესის ასეთი თვისებების მქონე მეხსიერება *ასოციაციურია* : ძებნისას გარკვეული მთლიანობის დამახინჯებული ნაწილების აღდგენა არსებული დაუმახინჯებელი ფრაგმენტებით ხდება მათ შორის არსებული ასოციაციური კავშირების საფუძველზე.

ჰოპფილდის ქსელის მეხსიერების ასოციაციური ხასიათი ხარისხობრივად განასხვავებს მას ჩვეულებრივი, სამისამართო, კომპიუტერული მეხსიერებისაგან. უკანასკნელში საჭირო ინფორმაციის ამოღება მისი საწყისი წერტილის (მეხსიერების უჯრედის) *მისამართით* ხორციელდება. მისამართის (ან თუნდაც მისამართის ერთი ბიტის) დაკარგვისას მთელი საინფორმაციო ფრაგმენტი მიუწვდომელია. ასოციაციური მეხსიერების გამოყენებისას კი ინფორმაციაში შეღწევა უშუალოდ მისი *შინაარსით* ხდება, ესე იგი ნაწილობრივ ცნობილი დამახინჯებული ფრაგმენტებით. ინფორმაციის ნაწილის დაკარგვა ან მისი დამახინჯება ინფორმაციული ხმაურით არ იწვევს შეღწევის კატასტროფულ შეზღუდვას, თუ დარჩენილი ინფორმაცია საკმარისია იდეალური სახის ამოსაღებად.


იდეალური სახის ძებნას არსებული არასრული ან საინფორმაციო ხმაურით დამახინჯებული ვერსიის საფუძველზე *სახის გამოცნობის* ამოცანა ეწოდება. ჩვენს ლექციაში ჰოპფილდის ნეირონული ქსელით ამ ამოცანის ამოხსნის თავისებურებანი ნაჩვენებია იქნება მაგალითებზე, რომლებიც მიღებულია ქსელის მოდელის გამოყენებით პერსონალურ კომპიუტერზე.

განხილულ მოდელში ქსელი 10×10 განზომილების მატრიცით მოწესრიგებულ 100 ნეირონს შეიცავდა. ქსელის სწავლება ჰების წესით ხდებოდა სამ იდეალურ სახეზე - M , A და G ლათინური ასოების შრიფტულ მოხაზულობებზე, დაწერილობებზე (იხ. ნახ. 8.3.). სწავლების დასრულებისას ნეიროქსელს ნეირონთა საწყის მდგომარეობებზე სახეთა სხვადასხვა დამახინჯებული ვერსიები მიეწოდებოდა, რომლებიც შემდგომში მიმდევრობითი დინამიკით სტაციონარულ მდგომარეობებში გადადიოდა.



ნახ. 8.3. მასწავლებელი ა(მო)ნაკრების იდეალური სახეები. მუქი კვადრატები შეესაბამება ნეირონებს (+1) მდგომარეობაში, ნათელი კვადრატები კი - (-1) მდგომარეობაში.


გამოსახულებათა ყოველი წყვილისათვის ნახაზებზე 8.4., 8.5., 8.7. მარცხენა სახე წარმოადგენს საწყის მდგომარეობას, ხოლო მარჯვენა - ქსელის მუშაობის შედეგს, მიღწეულ სტაციონარულ მდგომარეობას.



ა)

ბ)


ნახ. 8.4. (ა) - ერთ-ერთი იდეალური სახე სტაციონარულ წერტილს წარმოადგენს. (ბ) - სხვა შრიფტით მოცემული სახე წარმატებით გამოიცნობა.





ა)

ბ)

ნახ. 8.5. (ა, ბ) – საინფორმაციო ხმაურის შემცველი სახეები წარმატებით გამოიცნობა.



ნახ. 8.6. სახე მისი მცირე ფრაგმენტის საფუძველზე გამოიცნობა.



ა)

ბ)

ნახ. 8.7. (ა) – ყალბ სახისაკენ რელაქსაციის მაგალითი. (ბ) – მარცხენა (ა) სურათისათვის ინფორმაციის დამატება სწორ გამოცნობას უზრუნველყოფს.

სახე ნახაზზე 8.4.(ა) არჩეული იყო ქცევის ადეკვატურობის ტესტირებისათვის იდეალურ ამოცანაზე, როცა წარდგენილი გამოსახულება ზუსტად შეესაბამება ინფორმაციას მესსიერებაში. ამ შემთხვევაში ერთი ბიჯით მიღწეულ იქნა სტაციონარული მდგომარეობა. სახე ნახაზზე 8.4.(ბ) დამახასიათებელია ტექსტის გამოცნობის ამოცანებისათვის შრიფტისაგან დამოუკიდებლად. საწყისი და საბოლოო გამოსახულებები, ეჭვს გარეშეა, მსგავსია, მაგრამ აბა ერთი ცადეთ და აუხსენით ეს მანქანას!

დავალეები ნახაზზე 8.5. დამახასიათებელია რეალურ გამოყენებათათვის. ნეიროქსელურ სისტემას პრაქტიკულად მთლიანად დამახინჯებული საინფორმაციო ხმაურით სახეების გამოცნობის უნარი გააჩნია. ამოცანები, რომლებიც შეესაბამება ნახაზებს 8.6. და 8.7.(ბ), ავლენს ჰოპფილდის ქსელის შესანიშნავ თვისებას ასოციაციით გამოიცნოს სახე მისი მცირე ფრაგმენტის საფუძველზე. ქსელის მუშაობის უმნიშვნელოვანეს თავისებურებას ყალბი სახეების გენერაცია წარმოადგენს. ყალბი სახისადმი რელაქსაციის მაგალითი ნაჩვენებია ნახაზზე 8.7.(ა). ყალბი სახე ენერჯის მდგრად ლოკალურ ექსტრემუმს წარმოადგენს, მაგრამ არც ერთ იდეალურ სახეს არ შეესაბამება. გარკვეული აზრით იგი გვევლინება კრებით სახედ, რომელმაც თვისებები მემკვიდრეობით მიიღო იდეალური თანამომძეებისაგან. სიტუაცია ყალბი სახით შემდეგი მარტივი აზრის ტოლოფასია : «სადღაც მე უკვე მინახავს ეს» (გაიხსენეთ ფსიქოლოგიაში ფრანგული ფრაზა «djà-vu» – უკვე ნანახის ილუზია, პარამნეზია, მესსიერების მცდარობა, ცრუ მოგონება!).

მოცემულ უმარტივეს ამოცანაში ყალბი სახე «არასწორ», «მცდარ» ამონახსნს წარმოადგენს და ამიტომ საზიანოა. მაგრამ, უნდა ვიფიქროთ, რომ ქსელის მსგავსი განზოგადების უნარი წარმატებითაც შეიძლება, ალბათ, გამოვიყენოთ. დამახასიათებელია, რომ სასარგებლო ინფორმაციის მოცულობის გაზრდისას (შეადარეთ ნახ. 8.7.(ა) და ნახ. 8.7.(ბ)) საწყისი მდგომარეობა მოთხოვნილი სტაციონარული მდგომარეობის მიზიდულობის არეში ხვდება და სახის გამოცნობაც ხდება.

დასკვნითი შენიშვნები ჰოპფილდის მოდელის შესახებ.

საინტერესო თვისებების მიუხედავად, ნეირონული ქსელი ჰოპფილდის მოდელში სრულყოფილებას მოკლებულია. მას მეხსიერების შედარებით მოკრძალებული მოცულობა გააჩნია, რომელიც ქსელის ნეირონთა N რიცხვის პროპორციულია, მაშინ როცა სამისამართო მეხსიერების სისტემას 2^N სხვადასხვა სახის შენახვა შეუძლია N ბიტის გამოყენებით. გარდა ამისა, ჰოპფილდის ნეირონულ ქსელს არ შეუძლია გამოცნობის ამოცანათა გადაწყვეტა, თუ გამოსახულება წანაცვლებულია ან მობრუნებულია მისი საწყისი დამახსოვრებული მდგომარეობის მიმართ. ესა და სხვა ნაკლებოვანება განსაზღვრავს დღეს საერთო დამოკიდებულებას ჰოპფილდის მოდელისადმი : იგი უფრო თეორიული აზრთწყობაა, რომელიც მოხერხებულია კვლევებისათვის, ვიდრე საყოველღეო გამოყენებისათვის განკუთვნილი პრაქტიკული საშუალება.

მომდევნო ლექციებში ჩვენ განვიხილავთ ჰოპფილდის მოდელის განვითარებას, ჰების წესის ზოგიერთ სახეცვალებას, რომლითაც მეხსიერების მოცულობა იზრდება, აგრეთვე ჰოპფილდის მოდელის ალბათურ განზოგადებათა გამოყენებას კომბინატორული ოპტიმიზაციის ამოცანებში.

ლექცია 9. ჰოფილდის მოდელის განზოგადებები და გამოყენებები.

ჰოფილდის მოდელის ალბათური განზოგადებები და ბოლცმანის სტატისტიკური მანქანა. კოსკოს ორმხრივიმიმართული ასოციაციური მეხსიერება. ინფორმაციის წარმოდგენა კომბინატორული ოპტიმიზაციის ამოცანის გადაწყვეტ ჰოფილდის ქსელში. ნეიროგამოთვლები და ნეირომათემატიკა. გამოთვლითი პროცესების ორგანიზაცია ნეიროკომპიუტერებში.

ჰების წესის სახეცვალებები.

სინაფსური მეხსიერების ტევადობის შემოსაზღვრულობამ, აგრეთვე ჰოფილდის მოდელში ჰების წესით ნასწავლი კლასიკური ნეირონული ქსელის ყალბი მეხსიერების პრობლემამ ხელი შეუწყო მრავალი კვლევის გაჩენას, რომლის მიზანი ამ შეზღუდვათა მოხსნა იყო. ამასთან განსაკუთრებული ყურადღება ექცეოდა სწავლების წესთა სახეცვალებას.

ჰების მატრიცა სახეთა გაორთოგონალებით.

წინა ლექციაში დადგინდა, რომ მასწავლებელი ა(მო)ნაკრების სახეთა ორთოგონალობა ძალიან ხელსაყრელ გარემოებას წარმოადგენს, ვინაიდან ამ შემთხვევაში შესაძლებელია მათი მდგრადი შენახვის უზრუნველყოფა მეხსიერებაში. ზუსტი ორთოგონალობის დროს მეხსიერების მაქსიმალური ტევადობა მიიღწევა, რომელიც N -ს უდრის – ორთოგონალურ სახეთა მაქსიმალურ შესაძლო რიცხვს N კომპონენტთა სიმრავლეში.

ორთოგონალურ სახეთა სწორედ ამ თვისებაზეა დამყარებული ჰების წესის გაუმჯობესების ერთ-ერთი ყველაზე გავრცელებული ხერხი : დამახსოვრების წინ ნეირონულ ქსელში საწყის სახეთა გაორთოგონალება ხდება.

გაორთოგონალების პროცედურა კი მენსიერების მატრიცას ახალ ფორმას აძლევს :

$$W_{ij} = \sum_{\alpha, \mu} \xi_i^{(\alpha)} \xi_j^{(\mu)} B_{\alpha\mu}^{-1} .$$

აქ B^{-1} – B -ს შებრუნებული მატრიცაა :

$$B_{\alpha\mu} = \sum_i \xi_i^{(\alpha)} \xi_i^{(\mu)} .$$

მენსიერების მატრიცის ასეთი ფორმა $p < N$ სახის შემცველი ნებისმიერი ნაკრების აღდგენას უზრუნველყოფს. მაგრამ ამ მეთოდის არსებით ნაკლებლოვანებას მისი არალოკალურობა წარმოადგენს : ორ ნეირონს შორის კავშირის სწავლება ყველა დანარჩენი ნეირონის მდგომარეობათა ცოდნას მოითხოვს. გარდა ამისა, სწავლების დაწყებამდე წინასწარ უნდა იყოს ცნობილი ყველა მასწავლებელი სახე. ახალი სახის დამატება ქსელის კვლავ სწავლებას მოითხოვს. ამიტომ ასეთ მიდგომას საერთო არაფერი აქვს ჰოპფილდ-ჰების ქსელის საწყის ბიოლოგიურ საფუძვლებთან, თუმცა-ღა პრაქტიკულად იგი მისი ფუნქციონირების შესამჩნევ გაუმჯობესებას იწვევს.

უარის თქმა სინაფსთა სიმეტრიაზე.

მეორე მიდგომას ჰების წესის გასაუმჯობესებლად სინაფსურ შეერთებათა სიმეტრიაზე უარის თქმა წარმოადგენს. მენსიერების მატრიცა შემდეგი ფორმით შეიძლება აირჩეს :

$$W_{ij} = \left(\sum_{\alpha} \xi_i^{(\alpha)} \xi_j^{(\alpha)} \right) \cdot (1 - P_{ij}) .$$

მატრიცის P_{ij} ელემენტები $\{0, 1\}$ სიმრავლიდან მართავს კავშირის (ბმის) არსებობას ან არარსებობას i -ურ ნეირონიდან j -ურ ნეირონამდე.

მეხსიერების ტევადობის გადიდებას ასეთ მოდელში, ძირითადად, P მატრიცასთან დაკავშირებული თავისუფლების ახალი ხარისხების გაჩენით შეიძლება მივაღწიოთ. მაგრამ ზოგად შემთხვევაში ძნელია ასეთი მატრიცის არჩევის ალგორითმის დასაბუთება. აღსანიშნავია ის ფაქტიც, რომ დინამიკური სისტემისათვის არასიმეტრიული მატრიცით მდგრადობა სრულებითაც არ წარმოადგენს სავალდებულო თვისებას.

გადავიწყების (გადაჩვევის) ალგორითმები.

ზედმეტი, უსარგებლო ინფორმაციის გადავიწყების შესაძლებლობა ბიოლოგიური მეხსიერების ერთ-ერთ შესანიშნავ თვისებას წარმოადგენს. ამ თვისების გამოყენების იდეა ჰოპფილდის ხელოვნურ ნეიროქსელში «საიცრად» მარტივია : მასწავლებელი ა(მო)ნაკრების სახეთა დამახსოვრებისას მათთან ერთად ყალბი სახეების დამახსოვრებაც ხდება. და სწორედ ამ ყალბი სახეების «დავიწყებაა» საჭირო.

შესაბამისი ალგორითმებისათვის გადავიწყების (გადაჩვევის) ალგორითმების სახელწოდებაა მიღებული. მათი არსი ასეთია.

წვრთნის პირველ ფაზაში ქსელის სწავლება ჰების სტანდარტული წესით ხორციელდება. მეხსიერება ივსება ჭეშმარიტი სახეებით და მრავალი ყალბი ინფორმაციით. შემდეგ ფაზაში (გადავიწყების ფაზაში) ქსელს გარკვეული (შემთხვევითი) $\lambda^{(0)}$ სახე მიეწოდება. ევოლუციის შედეგად ქსელი $\lambda^{(0)}$ მდგომარეობიდან რაღაც $\lambda^{(f)}$ მდგომარეობაში გადადის, რომელიც მასწავლებელი ა(მო)ნაკრების დიდი მოცულობის პირობებში, უფრო ხშირად, ყალბი აღმოჩნდება. ახლა კავშირების მატრიცა შეიძლება გასწორდეს ამ ყალბი მდგომარეობის შესაბამისი ენერჯის მინიმუმის სიღრმის შესამცირებლად :

$$W_{ij}(t+1) = W_{ij}(t) - \varepsilon \cdot \lambda_i^{(f)} \lambda_j^{(f)} .$$

გადავიწყების ε ხარისხად გარკვეული მცირე რიცხვის არჩევა ხდება, რაც სასარგებლო მეხსიერების უმნიშვნელო გაუარესების გარანტიას იძლევა, თუ $\lambda^{(f)}$ მდგომარეობა ყალბი არ აღმოჩნდა. «გადავიწყების რამდენიმე სეანსის» შემდეგ ქსელის თვისებები უმჯობესდება (J.J.Hopfield et al., 1983)

მოცემულ პროცედურას ფირმალური თეორიული დასაბუთება არ გააჩნია, მაგრამ პრაქტიკულად იგი უზრუნველყოფს ნეირონული ქსელის უფრო რეგულარულ ენერგეტიკულ ზედაპირსა და სასარგებლო სახეთა მიზიდულობის აუზების მოცულობის გადიდებას.

ორმხრივმიმართული ასოციაციური მეხსიერება.

ასოციაციური მეხსიერების ნეიროქსელური არქიტექტურები შემდგომ განვითარებას ბარტ კოსკოს ნაშრომებში (B. Kosko, 1987) პოულობს. მან წამოაყენა *ჰეტეროასოციაციური* მეხსიერების მოდელი, რომელშიც სახეთა წყვილებს შორის არსებული ასოციაციების დამახსოვრება ხდება. დამახსოვრება ისე ხორციელდება, რომ ქსელისათვის ერთ-ერთი სახის წარდგენისას წყვილის მეორე წევრის აღდგენა ხდება.

სახეთა დამახსოვრება მათ შორის არსებული ასოციაციების საშუალებით დამახასიათებელია ადამიანის მეხსიერებისათვის. საჭირო ინფორმაციის გახსენება (აღდგენა) ასოციაციათა ჯაჭვის (მიმდევრობის) აგებით შეიძლება ხდებოდეს. ასე, მაგალითად, ქუჩაში ქარხნის საკვამურიდან კვამლის დანახვისას შესაძლებელია, რომ ჩართულ გაზქურაზე შინ დარჩენილი ჩაიდან გაიხსენოთ.

ორმხრივმიმართული ქსელი კოსკოს მოდელში ნეირონთა ორი – A და B – ფენისაგან შედგება. კავშირები ფენებს შორის ისეა მოწყობილი, რომ ერთი ფენის ყოველი ნეირონი მეორე ფენის თითოეულ ნეირონთანა დაკავშირებული. ფენების შიგნით კავშირები ნეირონებს შორის არ არსებობს, ნეირონების რაოდენობა ყოველ ფენაზე სხვადასხვა შეიძლება იყოს. დასამახსოვრებლად $(\xi^a, \xi^b)^{(\alpha)}$, $\alpha = \overline{1, p}$ სახეთა წყვილებია განკუთვნილი.

სწავლება ჰების წესით ხორციელდება :

$$W_{ij} = \sum_{\alpha=1}^p \left((\xi_i^a)^{(\alpha)} (\xi_j^b)^{(\alpha)} \right).$$

სისტემის დინამიკა პარალელურია და შემდეგი ფორმულებით აისახება :

$$\begin{cases} b_i = f\left(\sum_{j=1}^{N_a} W_{ji} a_j\right) \\ a_j = f\left(\sum_{i=1}^{N_b} W_{ji} b_i\right) \end{cases}.$$

აქ $\{a_j\}, j = \overline{1, N_a}$ - A ფენის ნეირონთა აქტივობის მდგომარეობებია, ხოლო $\{b_i\}, i = \overline{1, N_b}$ - B ფენის. ნეირონულ f ფუნქციად ზღურბლური ფუნქცია ან სიგმოიდი შეიძლება გამოიყენებოდეს. ერთნაირი ფენებისა და მასწავლებელ წყვილებში ერთნაირი სახეების კერძო შემთხვევაში კოსკოს ქსელი ჰოპფილდის მოდელის ეკვივალენტურია მთლიანად.

იტერაციული დინამიკის პროცესში A ფენის ნეირონთა მდგომარეობები იწვევს B ფენის ნეირონთა მდგომარეობების ცვლილებას, ისინი კი, თავის მხრივ, A ნეირონთა მდგომარეობების მოდიფიკაციას ახდენს, და ასე შემდეგ. იტერაციები, ისევე როგორც ჰოპფილდის ქსელში, კრებადია, რადგან კავშირების (ბმების) მატრიცა სიმეტრიულია. ქსელისათვის მხოლოდ A ფენის სახის წარდგენისას აღდგენილი იქნება აგრეთვე B ფენის შესაბამისი სახეც და, პირიქით.

კოსკოს ქსელს აგრეთვე *ავტოასოციაციურობის (თვითასოციაციურობის)* თვისებაც გააჩნია: თუ A და B ფენებზე ერთდროულად ცნობილია სახეთა გარკვეული ფრაგმენტები, მაშინ დინამიკის პროცესში წყვილის ორივე სახე იქნება ერთდროულად აღდგენილი.

დეტერმინირებული და ალბათური ნეიროდინამიკა.

წინა ლექციაში განხილული იყო ჰოპფილდის კლასიკური მოდელი ორობითი ნეირონებით. ნეირონების მდგომარეობათა დროში ცვლილება დეტერმინირებული წესით აღიწერებოდა, რომლითაც ცალსახად განისაზღვრებოდა ქსელის ყველა ნეირონის ავზების ხარისხი დროის მოცემული მომენტისათვის.

ეკოლუცია ჰოპფილდის ქსელის მდგომარეობათა სივრცეში მთავრდება სტაციონარულ წერტილზე – ენერჯის ლოკალურ მინიმუმზე. ამ მდგომარეობაში ნებისმიერი ნეირონის აქტივობის ყოველგვარი ცვლილება აკრძა-

ლულია, რადგან ეს ქსელის ენერჯის ზრდას იწვევს. თუ გავაგრძელებთ ანალოგიის გატარებას კლასიკურ ნეიროდინამიკასა და ფიზიკის სტატისტიკურ (დინამიკურ) სისტემებს შორის, მაშინ შესაძლებელი გახდება ნეირონთა სტატისტიკური ანსამბლის ტემპერატურის ცნების შემოღებაც. ჰოვინგის ქსელის ქცევა სტატისტიკური სისტემის ნულოვან ტემპერატურას (სრულ გაყინვას) შეესაბამება.

მკაცრად ნულოვანი ტემპერატურის ($T = 0$) პირობებში ბოლცმანის სტატისტიკური $\sim \exp(-\Delta E/T)$ ფაქტორი შეუძლებელს ხდის ენერჯის გაზრდას. არანულოვან ტემპერატურებზე გადასვლა ($T > 0$) მნიშვნელოვნად ამდიდრებს დინამიკას : სისტემას უკვე არანულოვანი ალბათობით შეუძლია გადასვლები E ენერჯის გაზრდით და ახალ სტატისტიკურ მდგომარეობათა მონახულებაც.

დავუბრუნდეთ ნეირონულ ქსელებს. რომელიმე ნეირონისათვის გადასვლის შესაძლებლობა მეტი ენერჯის მქონე მდგომარეობაში ნიშნავს უარის თქმას მდგომარეობათა ცვლილების დეტერმინირებული კანონის შესაბამისად მოქმედებაზე. არანულოვანი ტემპერატურების პირობებში ნეირონის მდგომარეობა ალბათურად განისაზღვრება :

$$\begin{cases} S_i(t+1) = \text{sign}(h_i(t) - \Theta), & P_i \text{ ალბათობით} \\ S_i(t+1) = -\text{sign}(h_i(t) - \Theta), & 1 - P_i \text{ ალბათობით} \end{cases}$$

გადასვლის ალბათობა მდგომარეობაში ენერჯის ზრდით მით ნაკლებია, რაც მეტია სხვაობა საბოლოო და საწყის მდგომარეობათა E_2 და E_1 ენერჯიებს შორის. სტატისტიკურ სისტემებში ეს ალბათობა ბოლცმანის ფორმულით განისაზღვრება :

$$P = \frac{1}{1 + \exp\left(-\frac{(E_2 - E_1)}{T}\right)}$$

ძნელი შესამჩნევი არ არის, რომ დაბალ ტემპერატურათა ზღვარში ($T \rightarrow 0$) ხსენებული P ალბათობა ერთისაკენ მიისწრაფვის, და დინამიკა ჩვეულებრივ დეტერმინირებულ ნეიროდინამიკაში გადადის.

მაღალ ტემპერატურებზე ($T \gg \Delta E$) კი $P = 1/2$, ესე იგი ნეირონის მდგომარეობის ცვლილება არასგზით არ უკავშირდება ამ ნეირონის არც წინა მდგომარეობას, არც $h(t)$ «ნეირონული ველის» მნიშვნელობას. ქსელის მდგომარეობა მთლიანად ქაოსურად, არეულ-დარეულად იცვლება და სიტუაცია არაფრით გვაგონებს მეხსიერებიან სისტემას.

არანულოვანი ტემპერატურების პირობებში ნეირონული სისტემის ქცევა უკვე არ ემორჩილება ლიაპუნოვის დინამიკას, რადგან ქსელის ენერგია დროთა განმავლობაში მონოტონურად არ მცირდება. ამასთან ერთად, საერთოდ რომ ვთქვათ, ქსელის სრული სტაბილიზაციაც არ ხდება – მდგომარეობა განაგრძობს ცვლილებას, რომლის დროსაც $\Delta E \propto T$.

თუ ახლა ქსელის ტემპერატურა იწყებს თანდათანობით შემცირებას, ენერგიის დიდი ცვლილება სულ უფრო ნაკლებად შესაძლებელი ხდება და სისტემა იყინება მინიმუმის არეში. ძალიან მნიშვნელოვანია აღინიშნოს, რომ გაყინვა დიდი ალბათობით განხორციელდება ყველაზე ღრმა და ფართო მინიმუმის თასში (ფიალაში, ჯამში), სხვანაირად რომ ვთქვათ, ქსელი უპირატესად ენერგიის გლობალურ მინიმუმს აღწევს.

მდგომარეობის მდორე (ნელი) გაგრილების (გაცივების) და ლოკალიზაციის პროცესი დაბალი ენერგიების არეში ლითონთა მოწვის პროცესის ანალოგიურია (მსგავსია), რომელიც მრეწველობაში ფოლადის წრთობისას გამოიყენება, ამიტომ ამ პროცესმა *მოწვის იმიტაციის* სახელწოდება მიიღო.

ნეიროქსელის დინამიკაში ნულისაგან განსხვავებული ტემპერატურის შემოტანა აუმჯობესებს მეხსიერების თვისებებს, რადგან სისტემა კარგავს ყალბ სახეთა შესაბამისი მცირე ლოკალური მინიმუმების «აღქმის» უნარს. მაგრამ ამის საფასურია უზუსტობანი სახეთა აღდგენისას სისტემის სრული სტაბილიზაციის უქონლობის გამო მინიმუმის წერტილზე.

ჰოპფილდის ქსელის გამოყენებები კომბინატორული ოპტიმიზაციის ამოცანებში.

ჰოპფილდის ნეირონული ქსელის მექანიზმების ასოციაციურობა არ წარმოადგენს მის ერთადერთ ღირსებას, რომელიც პრაქტიკაში გამოყენებას პოულობს. ამ არქიტექტურის სხვა მნიშვნელოვან თვისებათა რიცხვს ეკუთვნის მისი ლიაპუნოვის ფუნქციის შემცირება ნეიროდინამიკის პროცესში. მაშასადამე, ჰოპფილდის მოდელი შეიძლება განიხილებოდეს როგორც ქსელის ენერჯის სახით მოცემული მიზნობრივი ფუნქციის *ოპტიმიზაციის ალგორითმი*.

ნებისმიერი მიზნობრივი ფუნქცია, რომლის მინიმიზაცია შესაძლებელია ნეირონული ქსელით, საკმარისად მრავალრიცხოვან კლასს წარმოადგენს: მასში ხვდება ყველა ბინარული და კვადრატული ფორმა სიმეტრიული მატრიცით. მეორე მხრივ, მათემატიკურ პრობლემათა ძალიან ფართო წრე შეიძლება ჩამოყალიბდეს ოპტიმიზაციის ამოცანათა ენაზე. მათ რიცხვს მიეკუთვნება ისეთი ტრადიციული ამოცანები, როგორცაა ვარიაციული სახით წარმოდგენილი დიფერენციალური განტოლებები; წრფივი ალგებრის ამოცანები და არაწრფივ ალგებრულ განტოლებათა სისტემები, სადაც ამონახსნი გარკვეული სიდიდის მინიმიზაციის ფორმით იძებნება, და სხვა.

ასეთი ამოცანების გადასაჭრელად ნეირონული ქსელების გამოყენების შესაძლებლობათა შესწავლამ დღეს ახალი მეცნიერული დისციპლინის – *ნეირომათემატიკის* – ჩამოაყალიბებას შეუწყო ხელი.

ნეირონული ქსელების გამოყენება ტრადიციული მათემატიკური ამოცანების ამოსახსნელად ძალიან მიმზიდველად გამოიყურება, რადგან ნეიროპროცესორი წარმოადგენს სისტემას პარალელურობის უკიდურესად მაღალი დონით ინფორმაციის დამუშავებისას. ლექციათა ამ კურსში ნეირო-ოპტიმიზატორების გამოყენებას ჩვენ რამდენადმე განსხვავებული ამოცანებისათვის განვიხილავთ, სახელდობრ, კომბინატორული ოპტიმიზაციის ამოცანებისათვის.

რესურსთა ოპტიმალური განთავსებისა და დაგეგმვის, მარშრუტების არჩევის, ავტომატიზებული დაპროექტებისა და სხვა მრავალ ამოცანას, დასმის გარეგნული მოჩვენებითი სიმარტივის პირობებში, გააჩნია ამონახსნი, რომლის მიღება ვარიანტების მხოლოდ სრული გადარჩევის შედეგად შეიძლე-

ბა. ხშირად ვარიანტების რაოდენობა სწრაფად იზრდება ამოცანაში სტრუქტურულ ელემენტთა N რიცხვის ზრდასთან ერთად (მაგალითად, როგორც N -ის ფაქტორიალი : $N!$), და ზუსტი ამონახსნის ძებნა N -ის პრაქტიკულად სასარგებლო მნიშვნელობებისათვის ამკარად მიუღებელი ხდება ღირებულების გამო. ასეთ ამოცანებს არაპოლინომურად რთულ ანუ NP -სრულ ამოცანებს უწოდებენ. თუ ხერხდება ასეთი ამოცანის ჩამოყალიბება ლიაპუნოვის ფუნქციის ოპტიმიზაციის ტერმინებში, მაშინ ნეირონული ქსელი მიახლოებით ამონახსნის ძებნის ძალიან მძლავრ ინსტრუმენტს იძლევა.

განვიხილოთ NP -სრული პრობლემის კლასიკური მაგალითი – ვერეთ წოდებული კომივოიჯორის (მოხეტიალე ვაჭრის) ამოცანა. სიბრტყეზე N ქალაქია განლაგებული. თითოეული მათგანი გეოგრაფიული კოორდინატების $(x_i, y_i), i = 1, N$ წყვილითაა განსაზღვრული. ერთმა ვინმემ, ნებისმიერი პუნქტიდან დაწყებით, უნდა მონახულოს ეს ქალაქები და ამასთან თითოეული მხოლოდ ერთხელ. პრობლემა მდგომარეობს მოგზაურობის მარშრუტის არჩევაში გზის მინიმალურად შესაძლო საერთო სიგრძით.

შესაძლო მარშრუტების საერთო რაოდენობა $\frac{N!}{2N}$ სიდიდეს უდრის, და მათ შორის უმცირესის პოვნა გადარჩევის მეთოდით ძალიან შრომატევადი პროცესია. მისაღები მიახლოებით ამონახსნი შეიძლება ვიპოვოთ ნეირონული ქსელის საშუალებით, რისთვისაც, როგორც ეს უკვე აღინიშნა, ამოცანა ხელახლა უნდა ჩამოყალიბდეს ლიაპუნოვის ფუნქციის ოპტიმიზაციის ენაზე (J.J. Hopfield, D.W. Tank, 1985).

ქალაქების სახელები მთავრული $(A, B, C, D \dots)$ ასოებით აღვნიშნოთ. ნებისმიერი მარშრუტის წარმოდგენა შესაძლებელია ცხრილის სახით, რომელშიც ერთიანი მოცემული ქალაქის შესაბამის სტრიქონში განსაზღვრავს მის ნომერს მარშრუტში.

ცხრილი 9.1. მარშრუტი $B-A-C-D\dots$

| | ქალაქის ნომერი მარშრუტში | | | | |
|--------|--------------------------|-----|-----|-----|-----|
| ქალაქი | 1 | 2 | 3 | 4 | ... |
| A | 0 | 1 | 0 | 0 | ... |
| B | 1 | 0 | 0 | 0 | ... |
| C | 0 | 0 | 1 | 0 | ... |
| D | 0 | 0 | 0 | 1 | ... |
| ... | ... | ... | ... | ... | ... |

ცხრილის უჯრედს X სტრიქონისა და i სვეტის გადაკვეთაზე შეეუპირისპიროთ S_{xi} ნეირონი $\{0, 1\}$ -დან. მოცემული ნეირონის აქზნებული მდგომარეობა მიუთითებს იმაზე, რომ X ქალაქის მონახულება მარშრუტში უნდა მოხდეს i -ურ ეტაპზე. შევადგინოთ ოპტიმალური მარშრუტის ძებნის ამოცანის $E(S)$ მიზნობრივი ფუნქცია. მასში 4 შესაკრები შევა :

$$E(S) = E_1 + E_2 + E_3 + E_4 .$$

პირველი სამი შესაკრები ასახავს იმ ფაქტს, რომ მარშრუტი დასაშვებია და სათანადო შეზღუდვებს აკმაყოფილებს. სახელდობრ, ნებისმიერი ქალაქის მონახულება ერთჯერ უფრო მეტად არ შეიძლება (მატრიცის თითოეულ სტრიქონში ერთ ერთიანზე მეტი წარმოდგენილი არ არის), თითოეული ნიშრით ერთ ქალაქზე მეტის მონახულება არ უნდა ხდებოდეს (ყოველ სვეტში ერთ ერთიანზე მეტი არ არის) და, გარდა ამისა, მონახულებათა საერთო რაოდენობა ქალაქების N რიცხვს უდრის (მატრიცაში სულ ზუსტად N ერთიანია განთავსებული). აქედან გამომდინარე :

$$\begin{cases} E_1 = \frac{\alpha}{2} \sum_X \sum_i \sum_{j \neq i} S_{X_i} S_{X_j} \\ E_2 = \frac{\beta}{2} \sum_i \sum_X \sum_{Y \neq X} S_{X_i} S_{Y_i} \\ E_3 = \frac{\gamma}{2} \left(\sum_X \sum_i S_{X_i} - N \right)^2 \end{cases} .$$

როგორც ვხედავთ, სამივე შესაკრები დასაშვებ მარშრუტებზე ნულის ტოლი ხდება, და იქნს ნულზე მეტ მნიშვნელობებს დაუშვებელ მარშრუტებზე. უკანასკნელი, მეოთხე შესაკრები მარშრუტის მინიმიზირებას ახდენს :

$$E_4 = \frac{\eta}{2} \sum_X \sum_{Y \neq X} \sum_i d_{XY} S_{X_i} (S_{Y_{i+1}} + S_{Y_{i-1}}) .$$

აქ d_{XY} სიმბოლოთი აღნიშნულია მანძილი X და Y ქალაქებს შორის. შევნიშნავთ, რომ გზის $X - Y$ მონაკვეთის შეტანა (ჩართვა) ჯამში მხოლოდ მაშინ ხდება, როცა Y ქალაქი X ქალაქის მიმართ ან წინა პუნქტია, ან მომდევნო. α , β , γ და η თანამამრავლებს შესაკრებთა ფარდობითი წონების აზრი აქვს მინიჭებული.

ჰობფილდის ქსელისათვის ლიაპუნოვის ფუნქციის საერთო სახე მოიცემა შემდეგი გამოსახულებით (იხ. წინა ლექცია) :

$$E = -\frac{1}{2} \sum_X \sum_Y \sum_i \sum_j W_{X_i Y_j} S_{X_i} S_{Y_j} + \sum_{X_i} \Theta_{X_i} S_{X_i} .$$

ოთხი შესაკრების შემცველი მიღებული მიზნობრივი ფუნქცია ლიაპუნოვის ფუნქციის ფორმით აღმოჩნდება წარმოდგენილი, თუ ქსელის წონათა და ზღურბლთა მნიშვნელობებს შემდეგი სახით ავირჩევთ :

$$\begin{aligned}
W_{xiYj} = & -\alpha \cdot \delta_{XY} \cdot (1 - \delta_{ij}) - \\
& -\beta \cdot \delta_{ij} \cdot (1 - \delta_{XY}) - \\
& -\gamma - \\
& -\eta \cdot d_{XY} \cdot (\delta_{j+1} + \delta_{j-1}), \\
\Theta_{xi} = & -\gamma N.
\end{aligned}$$

ასლა შეიძლება ჰების ალგორითმით სწავლება შეიცვალოს მითითებული წონებისა და ზღურბლების პირდაპირი მიცემით ნეიროქსელისათვის, და მიღებული სისტემის დინამიკა გამოიწვევს კომივიოაჟორის მარშრუტის სიგრძის შემცირებას. ამ ამოცანაში მიზანშეწონილია ალბათური დინამიკის გამოყენება მოწვის იმიტაციით, რადგან ენერჯის გლობალური მინიმუმი მეტ ინტერესს წარმოადგენს.

ჰოპფილდისა და ტენკის მიერ აღწერილი მოდელი შემოწმდა გამოთვლით ექსპერიმენტში. ნეირონული ქსელი ახერხებდა ოპტიმალურთან მიახლოებული ამონახსნების პოვნას მისაღებ დროში რამდენიმე ათეული ქალაქის შემცველი ამოცანისათვის. შემდგომ პერიოდში მრავალი პუბლიკაცია განაგრძობდა ნეიროქსელური ოპტიმიზატორების სხვადასხვაგვარ გამოყენებათა შესახებ. დასასრულს განვიხილოთ ერთ-ერთი ასეთი გამოყენება – ამოცანა სიმბოლური კოდის გაშიფვრის შესახებ.

დავუშვათ, რომ მოცემულია გარკვეული (საკმარისად გრძელი) ტექსტური შეტყობინება, დაწერილი რომელიმე ენაზე A, B, C, \dots, Z ალფაბეტისა და «ინტერვალის» სიმბოლოს გამოყენებით. ამ უკანასკნელს სიტყვათა განცალკევება ევალება. მოცემული შეტყობინება ისეა კოდირებული, რომ თითოეულ სიმბოლოს, «ინტერვალის» ჩათვლით, გარკვეული სიმბოლო უპირისპირდება i, j, k, \dots მიმდევრობიდან. საჭიროა შეტყობინების გაშიფვრა.

მოცემული ამოცანა აგრეთვე NP -სრული ამოცანების კლასს მიეკუთვნება: შიფრის გასაღებთა საერთო რაოდენობა ფაქტორიალურადაა დამოკიდებული ალფაბეტის სიმბოლოთა რიცხვზე. მიახლოებითი ნეიროქსელური ამოხსნა შეიძლება ეყრდნობოდეს იმ ფაქტს, რომ ყოველ ენაში ცალკეულ სიმბოლოთა და სიმბოლოთა კონკრეტული წყვილების გაჩენის სიხშირებს სავსებით განსაზღვრული მნიშვნელობები გააჩნია (მაგალითად, ქარ-

თულ ენაში «ა» ასოს გაჩენის სიხშირე შესამჩნევად აღემატება «ჯ» ასოს გაჩენის სიხშირეს, «ნი» მარცვალი საკმაოდ ხშირად ჩნდება, ხოლო, მაგალითად, «ჭწ» შეერთება საერთოდ შეუძლებელია, ალბათ).

სიმბოლოებისა და მათი წყვილების გაჩენის P_i და P_{ij} სიხშირეები კოდირებულ შეტყობინებაში უშუალოდ შეიძლება გამოითვალოს. მერე, გვექნება რა ჩვენს განკარგულებაში ენის სიმბოლოებისა და მათი წყვილების გაჩენის სიხშირეთა P_A და P_{AB} მნიშვნელობები, საჭირო გახდება ამ სიდიდეთა გაიგივება კოდისათვის გამოთვლილ მნიშვნელობებთან. საუკეთესო თანამთხვევა საჭირო გასაღებს მოგვცემს.

ამ ამოცანის მიზნოვრივი ფუნქცია ხუთ შესაკრებს შეიცავს. პირველი სამი შესაკრები მთლიანად ემთხვევა პირველ სამ წევრს კომივოიაჟორის ამოცანის გამოსახულებაში ენერგისათვის. ისინი განსაზღვრავს გასაღების მისაღებობას (ენის ყოველ სიმბოლოს კოდის ერთი სომბოლო შეესაბამება). დანარჩენი შესაკრები ცალკეული სიმბოლოებისა და მათი წყვილების სიხშირეთა კოდში და ენაში დამთხვევის მოთხოვნას ასახავს.

სრულ გამოსახულებას მიზნობრივი ფუნქციისათვის შემდეგი სახე აქვს :

$$E(S) = E_1 + E_2 + E_3 +$$

$$+ \frac{\chi}{2} \sum_{AB,ij} (P_{AB} - P_{ij})^2 S_{Ai} S_{Bj} + .$$

$$+ \frac{\varepsilon}{2} \sum_{Ai} (P_A - P_i)^2 S_{Ai}$$

მიზნობრივი ფუნქცია – ისევე, როგორც ამოცანაში კომივოიაჟორისათვის – ლიაპუნოვის ფუნქციაზე დაიყვანება, რის შემდეგ ნეირონული ქსელი საჭირო გაშიფვრას ასრულებს.

ამოცანები

1. უშუალო გამოთვლით დარწმუნდით, რომ მასწავლებელი ა(მო)ნაკრების ყველა სახე ქსელის მდგრად მდგომარეობებს წარმოადგენს ჰების მატრიცის ორთოგონალურობის პირობებში.

2. კომივოიაჟორის ამოცანისათვის მიიღეთ $E(S)$ მიზნობრივი ფუნქციის წარმოდგენა ლიაპუნოვის ფუნქციის ფორმით.

3. გამოიყვანეთ ჰოპფელდის ქსელის ენერგეტიკული ფუნქცია პროგრამული კოდისა და მონაცემების ნარევეთა მრავალპროცესორიან – «ჰიპერკუბის» ტიპის – არქიტექტურაში ოპტიმალური განთავსების ამოცანისათვის.

ამოხსნა (Терехов С.А., Олейников П.В., 1994). ამ არქიტექტურის მრავალპროცესორიან კომპიუტერში პროცესორები განლაგებულია მრავალგანზომილებიანი კუბის წვერობებში. თითოეული პროცესორი დაკავშირებულია თავის უახლოეს კვანძებთან. ყოველ პროცესორს გამოეყოფა (დაენიშნება) პროგრამის კოდის გარკვეული ფრაგმენტი და ლოკალური მონაცემები. გამოთვლათა პროცესში პროცესორებს შორის ინფორმაციის გაცვლა ხდება, ამასთან პროგრამათა შესრულების სიჩქარე შენელებას განიცდის. შეტყობინების გადაგზავნაზე დახარჯული დრო მით მეტია, რაც უფრო დაშორებულია ერთმანეთისაგან ინფორმაციის გაცვლაში მონაწილე პროცესორები. საჭიროა კოდისა და მონაცემთა ნარევის ისეთნაირად განლაგება რეალურ პროცესორებში, რომ მაქსიმალურად შემცირდეს ინფორმაციის გაცვლასთან დაკავშირებული დანაკარგები.

კომივოიაჟორის ამოცანასთან ანალოგიით პროცესორები მთავრული ასობით აღვნიშნოთ, ხოლო ნარევეთა ნომრები – ლათინური ინდექსებით. თუ d_{XY} – ჰიპერკუბის წიბოების გასწვრის გადაზომილი (ჰემინგის) მანძილია პროცესორებს შორის, ხოლო D_{ij} - i -ურ და j -ურ ნარევეთა შორის გადასაცემი ინფორმაციის მოცულობას წარმოადგენს, მაშინ საძიებელი ამონახსნი $\sum d_{XY} D_{ij}$ ჯამის მინიმიზაციას უნდა ახდენდეს. ამიტომ მიზნობრივი ფუნქცია შემდეგი სახით ჩაიწერება :

$$E(S) = E_1 + E_2 + E_3 + (\eta/2) \sum_i \sum_j \sum_X \sum_Y (S_{X_i} S_{Y_j} d_{XY} D_{ij}) .$$

შემდეგ ამ გამოსახულებას ლიაპუნოვის ფუნქციის ფორმა ეძლევა. რიცხვითი ექსპერიმენტები 3, 4 და 5 განზომილების ჰიპერკუბებზე გვიჩვენებს, რომ ნეიროქსელური მიდგომის გამოყენება საინფორმაციო გაცვლების რიცხვთა 1,5-ჯერ შემცირების მიღების (და, შესაბამისად, კომპიუტერის მწარმოებლურობის გაზრდის) საშუალებას იძლევა ზოგიერთი ამოცანისათვის.

ლექცია 10. ფუკუშიმას ნეოკოგნიტრონი.

ფუკუშიმას კოგნიტრონი და ნეოკოგნიტრონი. სწავლების წესები. სახეთა ინვარიანტული გამოცნობა ნეოკოგნიტრონის მიერ.

ამ ლექციაში ჩვენ გადავდივართ ზოგიერთი – შედარებით ახალი – თანამედროვე არქიტექტურის განხილვაზე. მათ შორის, უპირველეს ყოვლისა, უნდა აღინიშნოს ნეოკოგნიტრონი და მისი სახეცვალებები. მომდევნო ლექციაში კი განხილული იქნება ადაპტური რეზონანსის თეორიაზე აგებული ქსელების ვარიანტები.

კოგნიტრონი : თვითორგანიზებადი მრავალფენიანი (მრავალშრიანი) ნეიროქსელი.

კოგნიტრონის შექმნა (K. Fukushima, 1975) ნეიროფიზიოლოგებისა და ფსიქოლოგების, აგრეთვე ნეიროკიბერნეტიკის სფეროს ადამიანის აღქმის სისტემის შესწავლით დაკავებული სპეციალისტების ძალათა სინთეზის ნაყოფი იყო. მოცემული ნეირონული ქსელი ერთდროულად წარმოადგენს როგორც მიკროდონზე მიმდინარე აღქმის პროცესების მოდელს, ასევე სახეთა გამოცნობის ტექნიკური ამოცანებისათვის გამოსაყენებელ გამომთვლელ სისტემას.

კოგნიტრონი შედგება ორი – მამუხრუჭებელი და ამგზნები – ტიპის ნეირონთა იერარქიულად დაკავშირებული ფენებისაგან. ყოველი ნეირონის აგზნების მდგომარეობა მისი მამუხრუჭებელი და ამგზნები შესასვლელების ჯამით განისაზღვრება. სინაფსური კავშირები (ბმები) მიდის ერთი ფენის (პირველი ფენის) ნეირონებიდან შემდეგისაკენ (მეორე ფენისაკენ). მოცემული სინაფსური კავშირის მიმართ პირველი ფენის შესაბამისი ნეირონი პრესინაფსურია, ხოლო მეორე ფენის ნეირონი – პოსტსინაფსური. პოსტ-

სინაფსური ნეირონები დაკავშირებულია პირველი ფენის არა ყველა ნეირონთან, არამედ მხოლოდ მათთან, რომლებიც პოსტსინაფსურ ნეირონთა კავშირების (ბმების) ლოკალურ არეს ეკუთვნის. მეზობელი პოსტსინაფსური ნეირონების კავშირთა (ბმათა) არეები გადაფარულია, ამიტომ მოცემული პრესინაფსური ნეირონის აქტივობა გავლენას მოახდენს იერარქიის მომდევნო ფენების პოსტსინაფსური ნეირონების სულ უფრო ფართო არეებზე.


ამგზნები პოსტსინაფსური ნეირონის (ნახ. 10.1.-ზე : i ნეირონის) შესასვლელი ამ ნეირონის ამგზნებ (a_1 , a_2 და a_3) შესასვლელთა E ჯამის მამუხრუჭებელ შესასვლელთა (საუბარია b_1 შესასვლელზე და შესასვლელზე X ნეირონიდან) I ჯამთან ფარდობით განისაზღვრება :

$$E = \sum_j a_j u_j, \quad I = \sum_j b_j v_j,$$

სადაც u – ამგზნები შესასვლელია a წონით, v – მამუხრუჭებელი შესასვლელია b წონით. ყველა წონას დადებითი მნიშვნელობა გააჩნია. E და I სიდიდეთა საფუძველზე გამოითვლება ჯამური ზემოქმედება i -ურ ნეირონზე :

$$net_i = \left((1 + E) / (1 + I) \right) - 1.$$

მისი გამომავალი u_i აქტივობა შემდეგ net_i დონეზე ყენდება, თუ $net_i > 0$. წინააღმდეგ შემთხვევაში გამოსასვლელი ნულოვან მნიშვნელობაზე დგება. ჯამური ზემოქმედების ფორმულის ანალიზი გვიჩვენებს, რომ მცირე I დამუხრუჭების პირობებში ეს ზემოქმედება ამგზნებ და მამუხრუჭებელ სიგნალთა სხვაობის ტოლია. ხოლო იმ შემთხვევაში, როცა ორივე ხსენებული სიგნალი მძლავრია, ზემოქმედება ფარდობით შემოისაზღვრება. რეაქციის ასეთი თავისებურებები ზემოქმედებათა ფართი დიაპაზონში მოქმედ ბიოლოგიურ ნეირონთა რეაქციებს შეესაბამება.



ნახ. 10.1. მე-2 ფენის პოსტსინაფსური i ნეირონი დაკავშირებულია პირველი (1) ფენის სამ (1, 2 და 3) ნეირონთან კავშირების (ბმების) არეში და (მუქი ფერით ნაჩვენებ) ორ მამუხრუჭებელ ნეირონთან. მამუხრუჭებელი X ნეირონი ახორციელებს ლატერალურ დამუხრუჭებას i ნეირონის კონკურენციის არეში.

პრესინაფსურ მამუხრუჭებელ ნეირონებს კავშირთა (ბმათა) იგივე არე გააჩნია, რაც განსახიხლველად აღებულ ამგზნებ პოსტსინაფსურ i ნეირონს. ამასთან ასეთი მამუხრუჭებელი ნეირონების $c1$, $c2$ და $c3$ წონები მოცემულია და სწავლების პროცესში არ იცვლება. მათი ჯამი ერთის ტოლია და, ამრიგად, მამუხრუჭე პრესინაფსური ნეირონის გამოსასვლელი უდრის ამგზნები პრესინაფსური ნეირონების საშუალო აქტივობას კავშირთა (ბმათა) არეში :

$$v_i = \sum_j c_j u_j .$$

ამგზნებ ნეირონთა წონების სწავლება «გამარჯვებულს თან მიაქვს ყველაფერი» (WTA - Winner Take All) პრინციპით ხდება კონკურენციის არეში – მოცემული ამგზნები ნეირონის რომელიმეა არეში. ამ ბიჯზე სახეცვალელებას მხოლოდ მაქსიმალურად აგზნებული ნეირონის a_i წონები განიცდის :

$$\delta a_i = qc_j u_j ,$$

სადაც c_j – პირველს ფენაში j ნეირონის კაშირის (ბმის) მამუხრუჭებელი წონაა, u_j – ამ ნეირონის აგზნების მდგომარეობას წარმოადგენს, ხოლო q – სწავლების კოეფიციენტად მიჩნეული სიდიდეა. მეორე ფენის i მამუხრუჭებელი ნეირონის წონათა სახის შეცვლა ამგზნებ შესასვლელთა ჯამის მამუხრუჭებელ შესასვლელთა ჯამთან ფარდობის პროპორციულად ხდება :

$$\delta b_i = (q/2) \sum_j a_j u_j / \sum_j c_j u_j .$$

იმ შემთხვევაში, როცა კონკურენციის არეში (მე-2 ფენაზე) გამარჯვებული არ არის, როგორც ამას ადგილი აქვს, მაგალითად, სწავლების დასაწყისში, წონათა აწყობა სხვა ფორმულებით ხორციელდება :

$$\delta a_i = q' c_j u_j ; \quad \delta b_i = q' \sum_k c_k u_k ; \quad 0 < q' < q .$$


სწავლების მოცემული პროცედურა აქტიური ნეირონების ამგზნები კავშირების (ბმების) შემდგომ ზრდასა და პასიურ ნეირონთა დამუხრუჭებას იწვევს. ამასთან ერთად მე-2 ფენაში თითოეული ნეირონის წონათა აწყობა გარკვეული სახის მიმართ ხდება, რომლის მიწოდებას სწავლებისას განსაკუთრებით ხშირად აქვს ადგილი. ამ სახის ახალი წარდგენა გამოიწვევს შესაბამისი ნეირონის აგზნების მაღალ დონეს, ხოლო სხვა სახეთა გაჩენისას მისი აქტივობა მცირე დარჩება და ჩანს მობილი აღმოჩნდება ლატერალური დამუხრუჭების პროცესში.

კონკურენციის არეში ლატერალური დამუხრუჭების განმხორციელებელი X ნეირონის წონები არამოდიფიცირებადი და მათი ჯამი ერთის ტოლია. ამასთან ერთად, მეორე ფენაში სრულდება იტერაციები, რომლებიც კონკურენტული იტერაციების მსგავსია ლიპმან-ჰეინგის ქსელში. უკანასკნელი მე-7 ლექციაში იყო განხილული ჩვენს მიერ.

შეგნიშნავთ, რომ მეორე ფენის მახლობელ ნეირონთა კონკურენციის გადაფარული არეები სხვა ნეირონების შედარებით მცირე რაოდენობას შეიცავს, ამიტომ კონკრეტულ გამარჯვებულ ნეირონს მთელი მეორე ფენის დამუხრუჭება არ შეუძლია. მაშასადამე, კონკურენტულ ბრძოლაში მეორე ფენის რამდენიმე ნეირონს შეუძლია გამარჯვება, და შესაბამისად ინფორმაციის უფრო სრული და საიმედო გადამუშავების უზრუნველყოფა.

საერთოდ კოგნიტრონი წარმოადგენს ერთმანეთთან მიმდევრობით დაკავშირებულ ფენათა იერარქიას, როგორც ეს ზევით იყო განხილული წყვილსათვის «ფენა 1 – ფენა 2». ამასთან ერთად ფენის ნეირონები ქმნის არა ერთგანზომილებიან ჯაჭვს (მიმდევრობას), როგორც ნახ. 10.1.-ზე, არამედ ფარავს სიბრტყეს, ადამიანის მხედველობის ქერქის შრეული (შრეებრივი) აგებულების მსგავსად. თითოეული ფენა ინფორმაციის განზოგადების თავის დონეს ახორციელებს. შემავალი ფენები მგრძნობიარეა ცალკეული ელემენტარული სტრუქტურების – მაგალითად, გარკვეული ორიენტაციის ან ფერის წირების – მიმართ. მომდევნო ფენები კი უფრო რთულ განზოგადებულ სახეებზე რეაგირებს. იერარქიის უმაღლეს დონეზე აქტიური ნეირონები ქსელის მუშაობის შედეგს – გარკვეული სახის გამოცნობას – განსაზღვრავს. ყოველი – უმეტეს ნაწილში ახალი – სახისათვის გამომავალი ფენის აქტივობის სურათი უნიკალური იქნება. ამასთან ერთად იგი შენარჩუნდება ამ სახის დამახინჯებული ან ხმაურით შეცვლილი ვერსიის წარდგენისას. ამრიგად, ინფორმაციის დამუშავება კოგნიტრონის მიერ ასოციაციებისა და განზოგადებების ფორმირებით ხდება.

კოგნიტრონის ავტორი ფუკუშიმა ამ ქსელს სიმბოლოების (არაბული ციფრების) ოპტიკური გამოცნობისათვის იყენებდა. ექსპერიმენტებში იგი მიმართავდა ქსელს ნეირონთა ოთხი ფენით. ნეირონები მოწესრიგებული იყო 12×12 მატრიცებად. თითოეული ნეირონის კავშირების არე 5×5 ზომის კვადრატს წარმოადგენდა, ხოლო კონკურენციის მიდამოს 5 ნეირონის ტოლი სიმაღლისა და სიგანის რომის ფორმა გააჩნდა. სწავლების პარამეტრები $q = 16$, $q' = 2$ ტოლობებით განისაზღვრებოდა. შედეგად განხორციელდა სისტემის წარმატებული სწავლება ციფრების ზუთ სახეზე. ისინი ასოთა იმ სურათებს წააგავდა, რომლებსაც ჩვენ ჰოპფილდის ქსელისათვის ვიხილავდით). ამასთან სწავლების 20 ციკლამდე ჩატარება აღმოჩნდა საჭირო ყოველი სურათისათვის.



ნახ. 10.2. ერთმანეთის მიმართ წანაცვლებული «ერთნაირი» სახეები ითხოვს მათი «იდენტურობის» დასადგენად გამოცნობის ინვარიანტულ სასიათს ნებისმიერი ძვრების მიმართ.

წარმატებული გამოყენებებისა და მრავალი ღირსების მიუხედავად, – როგორცაა, მაგალითად, ნეიროსტრუქტურისა და სწავლების მექანიზმების ბიოლოგიურ მოდელებთან შესაბამისობა, ინფორმაციის დამუშავების პარალელურობა და იერარქიულობა, მეხსიერების განაწილებულობა და ასოციაციურობა – კოგნიტრონს თავისი ნაკლულოვანებებიც გააჩნია. მათ შორის მთავარია, ალბათ, ამ ქსელის უუნარობა გამოიცნოს სახე, რომელიც თავისი საწყისი მდგომარეობის მიმართ წანაცვლებული ან მობრუნებული არის. ასე, მაგალითად, ორი სურათი ნახ. 10.2.-ზე ადამიანის თვალსაზრისით, უდავოდ, ერთისა და იმავე ციფრის – ხუთის – სახეს წარმოადგენს, მაგრამ კოგნიტრონს არ ძალუძს შეამჩნიოს ეს მსგავსება.

თუ გამოცნობა დამოკიდებული არ არის სახეთა მდგომარეობაზე, ორიენტაციაზე, ხოლო ზოგჯერ ზომაზე და სხვა დეფორმაციაზე, მაშინ მას *ინვარიანტული* გამოცნობა ეწოდება შესაბამისი გარდაქმნის მიმართ. მეცნიერთა ჯგუფმა კ. ფუკუშიმას ხელმძღვანელობით, განავითარა რა კოგნიტრონი, ახალი ნეიროქსელური პარადიგმაც შექმნა – ნეოკოგნიტრონი, რომელსაც ინვარიანტული გამოცნობა შეუძლია.

ნეოკოგნიტრონი და სახეთა ინვარიანტული გამოცნობა.

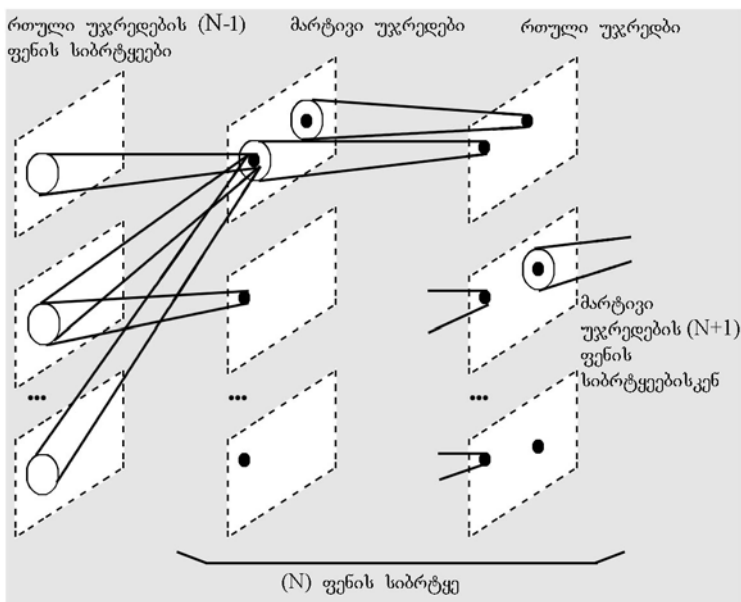
ფუკუშიმას ახალი ნაშრომი 1980 წელს გამოქვეყნდა. ნეოკოგნიტრონმა, მიუხედავად იმისა, რომ მას მრავალი საერთო თვისება აკავშირებდა თავის წინაპართან – კოგნიტრონთან, ერთდროულად მნიშვნელოვანი ცვლილება და გართულება განიცადა ახალი ნეირობიოლოგიური მონაცემების გაჩენის შესაბამისად (Hubel D.H., Wiesel T.N., 1977, და სხვ.).

ნეოკოგნიტრონი ნეირონულ ფენათა იერარქიისაგან შედგება. თითოეულ ფენაში კი სიბრტყეთა მასივია წარმოდგენილი. მასივის ყოველი ელემენტი ნეირონების სიბრტყეთა წყვილისაგან შედგება. პირველ სიბრტყეზე განლაგებულია ეგრეთ წოდებული *მარტივი* ნეიროუჯრედები, რომლებიც სიგნალებს წინა ფენისაგან იღებს და გარკვეულ სახეებს გამოყოფს. ამ სახეებს შემდეგ მეორე სიბრტყის *რთული* ნეირონები ამუშავებს. ამ ნეირონთა ამოცანა მდგომარეობს იმაში, რომ გამოყოფილი სახეები აღმოჩნდეს ნაკლებად დამოკიდებული მათ მდგომარეობაზე.

სიბრტყეთა თითოეული წყვილის ნეირონები სწავლობს რეაგირებას განსაზღვრულ სახეზე, რომელიც წარმოდგენილია გარკვეული ორიენტაციით. სხვა სახისათვის ან სახის მობრუნების სხვა კუთხისათვის საჭიროა სიბრტყეთა ახალი წყვილი. ამრიგად, ინფორმაციის დიდი მოცულობის პირობებში, ნეოკოგნიტრონი წარმოადგენს სტრუქტურას სიბრტყეებისა და ნეირონთა ფენების მნიშვნელოვანი რაოდენობით.

მარტივი ნეირონები მგრძნობიარეა შემაჯალი სახის მცირე არის მიმართ, რომელსაც *რეცეფციური* (ლათ. *receptio* - მიღება) ან, რაც იგივეა, *კავშირების (ბმათა) არე* ეწოდება. მარტივი ნეირონი მოდის აგზნებულ მდგომარეობაში, თუ მის რეცეფციურ არეში გარკვეული სახე ჩნდება. მარტივ უჯრედთა რეცეფციური არეები მთელ გამოსახულებას ეფინება და ალაგ-ალაგ გადაფარულია. რთული ნეირონები იღებს სიგნალებს მარტივ უჯრედებისაგან, ამასთან რთული ნეირონის ასაგზნებად საკმარისია ნებისმიერი მარტივი ნეირონის ერთი სიგნალი. ამით რთული უჯრედი რეაგირებს განსაზღვრულ სახეზე მისი დეტექტირების მაწარმოებელი მარტივი ნეირონისაგან და, მაშასადამე, ამ სახის მდებარეობისაგან დამოუკიდებლად.

ინფორმაციის გავრცელებისას ფენიდან ფენისაკენ ნეირონული აქტივობის სურათი სულ უფრო ნაკლებად მგრძნობიარე ხდება სახის ორიენტაციისა და მდებარეობის, ხოლო გარკვეულ საზღვრებში, მისი ზომის მიმართ. გამომავალი ფენის ნეირონები საბოლოო ინვარიანტულ გამოცნობას აწარმოებს.



ნახ. 10.3. ნეოკოგნიტრონის ზოგადი სქემა. კავშირების (ბმის) არეები ნაჩვენებია დიდი თეთრი, ხოლო კონკურენციის არეები – მცირე შუქი წრეებით.

ნეოკოგნიტრონის გაწვრთნა კოგნიტრონის უკვე განხილული სწავლების მსგავსად ხდება. ამასთან მხოლოდ მარტივი უჯრედების სინაფსური წონეები იცვლება. მამუხრუჭებელი ნეირონები კავშირების (ბმების) არეში – ნეირონთა საშუალო აქტივობის ნაცვლად – იყენებს კვადრატულ ფესვს შესასვლელთა კვადრატების აწონილ ჯამიდან :

$$v_i = \sqrt{\sum_j (b_j u_j)^2} .$$

ასეთი ფორმულა მამუხრუჭებელი უჯრედის აქტივობისათვის ნაკლებად მგრძობობარეა სახის ზომის მიმართ. წონათა სწავლებისათვის მარტივი ნეირონის არჩევის შემდეგ, იგი ფენის წარმომადგენლად განიხილება, და

ყველა დანარჩენი ნეირონის წონები ასეთივე წესებით იწვრთნება. ამრიგად, თითოეული მარტივი უჯრედი სწავლობს ერთნაირად და გამოცნობისას ერთნაირი რეაქციით პასუხობს ერთნაირ სახეებზე.

დასამუშავებელი ინფორმაციის მოცულობის შესაძვრებლად ნეირონთა რეცეფტორული ველები ფენიდან ფენაზე გადასვლისას ფართოვდება, ხოლო ნეირონთა რაოდენობა მცირდება. გამომავალ ფენაში თითოეულ სიბრტყეზე მხოლოდ ერთი ნეირონი რჩება, რომლის რეცეფტორული ველი ფარავს წინა ფენის სახის მთელ ველს.

საზოგადოდ ნეოკორტიკონი შემდგენიარად ფუნქციონირებს. შემავალი გამოსახულების ასლები პირველი ფენის მარტივი უჯრედების თითოეულ სიბრტყეს მიეწოდება. შემდეგ ყველა სიბრტყე პარალელურად ფუნქციონირებს და ინფორმაციას მომდევნო ფენას გადასცემს. გამომავალი ფენის მიღწევისას, სადაც თითოეული სიბრტყე ერთ ნეირონს შეიცავს, აქტივობის რაღაც საბოლოო განაწილება მყარდება. გამოცნობის შედეგზე მიუთითებს ის ნეირონი, რომლის აქტივობა მაქსიმალური აღმოჩნდა. ამასთან არსებითად სხვადასხვაგვარ შემავალ გამოსახულებებს გამოცნობის სხვადასხვა შედეგები შეესაბამება.

ნეოკორტიკონმა წარმატებით წარმოაჩინა თავი სიმბოლოების გამოცნობისას. აღსანიშნავია, რომ ამ ქსელის სტრუქტურა არაჩვეულებრივად რთულია და გამოთვლათა მოცულობა ძალიან დიდია, ამიტომ ნეოკორტიკონის კომპიუტერული მოდელები მეტისმეტად ძვირი იქნება სამრეწველო გამოყენებისათვის. შესაძლო ალტერნატივას, რასაკვირველია, აპარატულ ან ოპტიკურ რეალიზაციებზე გადასვლა წარმოადგენს, მაგრამ მათი განხილვა ცდება ლექციათა ამ კურსის ჩარჩოებს.

ლექცია 11. ადაპტური რეზონანსის თეორია.

სტაბილურობის-პლასტიკურობის პრობლემა სახეთა გამოცნობისას. სტეფან გროსბერგისა და გეილ კარპენტერის ადაპტური რეზონანსის პრინციპი. ნეიროქსელური არქიტექტურები ადაპტური რეზონანსის თეორიის საფუძველზე (ართ ნეიროქსელური არქიტექტურები).

აღქმის სტაბილურობის-პლასტიკურობის დილემა.

სტაბილურობის-პლასტიკურობის პრობლემა ერთ-ერთ ყველაზე რთულ და ძნელად გადასაწყვეტ ამოცანას წარმოადგენს აღქმის მამოდელირებელი ხელოვნური სისტემების აგებისას. გარე სამყაროს აღქმის ხასიათი ცოცხალი ორგანიზმებით (და, უპირველეს ყოვლისა, ადამიანის მიერ) მუდამ დაკავშირებულია შემდეგი დილემის გადაწყვეტასთან : რომელიღაც სახე «ახალ» ინფორმაციას წარმოადგენს, და, მასასადამე, რეაქცია მასზე უნდა იყოს საძებნო-შემეცნებითი, ამ სახის შენახვით მეხსიერებაში, ან ეს სახე «ძველი», უკვე ნაცნობი სურათის, ვარიანტია, და ამ შემთხვევაში ორგანიზმის რეაქცია უნდა შეესაბამოდეს უფრო ადრე დაგროვებულ გამოცდილებას. უკანასკნელ შემთხვევაში ამ სახის სპეციალური დამახსოვრება საჭირო არ არის. ამრიგად, აღქმა ერთდროულად *პლასტიკურია*, ადაპტირებულია ახალ ინფორმაციასთან, და ამასთან ერთად *სტაბილურია*, ესე იგი არ ანადგურებს მეხსიერებას ძველ სახეთა შესახებ.

წინა ლექციებში განხილულ ნეირონულ ქსელებს ამ ამოცანის გადაწყვეტის უნარი არ გააჩნია. ასე, მაგალითად, მრავალფენიანი პერსპექტრონი, რომელიც უკუგავრცელების მეთოდით სწავლობს, მასწავლებელი ინფორმაციის მთელ პაკეტს იმახსოვრებს, ამასთან ერთად, სწავლების პროცესში, მასწავლებელი ა(მო)ნაკრების სახეთა წარდგენა გამოსაცნობად მრავალჯერ ხდება. ყოველი მცდელობა – შეასწავლო პერსპექტრონს ახალი სახე – გამოიწვევს სინაფსური კავშირების მოდიფიკაციას წინა სახეთა შესახებ არ-

სებული მეხსიერების სტრუქტურის არაკონტროლირებადი განადგურებით, ზოგად შემთხვევაში. მაშასადამე, პერსექტრონს არ შეუძლია ახალი ინფორმაციის დამახსოვრება, საჭირო ხდება ქსელის მთლიანად ხელახლა სწავლება.

ანალოგიურ სიტუაციას აქვს ადგილი კოპონენის და ლიპმან-ჰემინგის ქსელებში, რომლებიც თვითორგანიზაციის საფუძველზე სწავლობს. მოცემული ქსელები ყოველთვის დადებით შედეგებს იძლევა კლასიფიკაციის დროს. ეს კი იმას ნიშნავს, რომ ასეთ ნეირონულ ქსელებს არ შეუძლია ახალი სახეების განცალკევება ძველ სახეთა დამახინჯებული ან ხმაურით დაზიანებული ვერსიებისაგან.


ბოსტონის უნივერსიტეტის ადაპტურ სისტემათა ცენტრში სტეფან გროსბერგის ხელმძღვანელობით შესრულებული კვლევები სტაბილურობის-პლასტიკურობის პრობლემის სფეროში დაგვირგვინდა ადაპტური რეზონანსის თეორიის (**ართ**) აგებითა და მის საფუძველზე ახალი ტიპის ნეიროქსელურ არქიტექტურათა შექმნით. ჩვენ გადავივიარეთ ადაპტური რეზონანსის თეორიის ზოგადი დებულებების განხილვაზე, რომლებიც ს. გროსბერგის მიერ 1976 წელს იყო წამოყენებული და მოგვიანებით დაწვრილებით განხილული 1987 წლის ფუძემდებლურ ნაშრომში (S.Grossberg, G.Carpenter, 1987).

ადაპტური რეზონანსის პრინციპი.

ნეირონულ ქსელს ადაპტური რეზონანსით მიმზიდველი თავისებურება გააჩნია – იგი ინარჩუნებს პლასტიკურობას ახალი სახეების დამახსოვრებისას, და, ამავე დროს, ახერხებს ძველი მეხსიერების მოდიფიკაციის თავიდან აცილებას. ნეიროქსელს სიახლის შინაგანი დეტექტორი აქვს – გამოსაცნობად მიწოდებული სახისა და მეხსიერების შიგთავსის ერთმანეთთან შედარების ტესტი. თუ ძებნა მეხსიერებაში წარმატებით დასრულდა, მაშინ გამოსაცნობად მიწოდებული სახის კლასიფიცირება ხდება და იმ ნეირონს, რომელმაც ეს კლასიფიკაცია განახორციელა, ერთდროულად სინაფსური წონების დამაზუსტებელი მოდიფიკაცია უტარდება. ასეთ დროს ამბობენ, რომ ქსელში *ადაპტური რეზონანსი* დამყარდა გამოცნობის მოთხოვნის საპასუხოდ. თუ გარკვეული მოცემული ზღურბლური დონის საზღვრებში რეზონანსი არ ჩნდება, მაშინ წარმატებულად სიახლის ტესტი ითვლება,

და ობიექტი ქსელის მიერ ახალ სახედ აღიქმება. ამასთან არ ზღვება წონების მოდიფიკაცია იმ ნეირონებში, რომლებსაც რეზონანსი არ განუცდია.

ადაპტური რეზონანსის თეორიაში მნიშვნელოვან ცნებას ინფორმაციის გერეთ წოდებული კრიტიკული თვისებების შაბლონი (critical feature pattern) წარმოადგენს. ეს ტერმინი უჩვენებს, რომ გარკვეულ სახეში მოცემულ თვისებათა შორის ყველა არ არის აღქმის სისტემისათვის არსებითი. გამოცნობის შედეგი განისაზღვრება სპეციფიკური, განსაკუთრებული კრიტიკული თვისებებების არსებობით სახეში. განვიხილოთ ეს მაგალითზე.



ნახ. 11.1. სახის კრიტიკულ თვისებათა ცნების ასახსნელად მოყვანილი მაგალითი.

ნახ. 11.1.-ზე სურათების ორივე წყვილს ერთნაირი თვისება გააჩნია : თითოეულ წყვილში შავი წერტილი მარჯვენა ქვედა კუთხეში ჩანაცვლებულია თეთრით, ხოლო თეთრი წერტილი მარცხენა ქვედა კუთხეში – შავით. ასეთი ცვლილება სურათების ქვედა (b) წყვილისათვის, ცხადია, მხოლოდ ხმაურს წარმოადგენს და (b) წყვილის ორივე სახე ერთისა და იმავე გამოსახულების დამახინჯებულ ვერსიებად აღიქმება. ამრიგად შეცვლილი წერტილები ამ სახისათვის კრიტიკული არ არის.

სულ სხვა სიტუაციას აქვს ადგილი სურათების ზედა (ა) წყვილისათვის. აქ წერტილთა ასეთივე ცვლილება მეტად არსებითი ხდება სახისათვის, ასე რომ მარჯვენა და მარცხენა სურათები სხვადასხვა სახეს წარმოადგენს. მაშასადამე, სახის ერთი და იგივე თავისებურება შეიძლება არაარსებითი იყოს ერთ შემთხვევაში, და კრიტიკული მეორეში. ნეირონული ქსელის ამოცანად სწორი რეაქციის ფორმირება რჩება ორივე შემთხვევაში :

(ა) წყვილისათვის – «პლასტიკური» გადაწყვეტილება ახალი სახის გაჩენის შესახებ და (ბ) წყვილისათვის – «სტაბილური» გადაწყვეტილება სურათთა თანამთხვევის თაობაზე. ამასთან ინფორმაციის კრიტიკული ნაწილის გამოყოფა ავტომატურად უნდა ხდებოდეს ქსელის მუშაობისა და სწავლების პროცესში, მისი ინდივიდუალური გამოცდილების საფუძველზე.

აღსანიშნავია, რომ ზოგად შემთხვევაში თავისებურებათა მხოლოდ ჩამოთვლა (იგი წინასწარ ადამიანმაც რომ შეასრულოს ქსელის შემდგომი მუშაობის გარკვეული პირობების ვარაუდისას) საკმარისი შეიძლება არ აღმოჩნდეს ხელოვნური ნეირონული სისტემის წარმატებით ფუნქციონირებისათვის, თუ სპეციფიკური კავშირები რამდენიმე ცალკეულ თვისებას შორის კრიტიკულ ხასიათს ატარებს.

თეორიის მეორე მნიშვნელოვან შედეგს წარმოადგენს მეხსიერებაში სახეთა ძებნის ალგორითმის თვითადაპტაციის აუცილებლობა. ნეირონული ქსელი გამუდმებით ცვალებად პირობებში მუშაობს, ასე რომ ძებნის წინასწარ განსაზღვრული სქემა, რომელიც ინფორმაციის გარკვეულ სტრუქტურას შეესაბამება, შემდგომში არაეფექტური შეიძლება აღმოჩნდეს ამ სტრუქტურის შეცვლისას. ადაპტური რეზონანსის თეორიაში ამის მიღწევა სპეციალიზებული მაორიენტირებელი სისტემის შემოტანით ხდება, რომელიც თვითშეთანხმებულად წყვეტს რეზონანსის შემდგომ ძებნას მეხსიერებაში და იღებს გადაწყვეტილებას ინფორმაციის სიახლის თაობაზე. მაორიენტირებელი სისტემა აგრეთვე სწავლობს მუშაობის პროცესში.

რეზონანსის არსებობის შემთხვევაში ადაპტური რეზონანსის თეორია გულისხმობს მეხსიერების იმ სახის პირდაპირ წვდომას, რომელიც გამოეხმინა რეზონანსს. ასეთ ვითარებაში კრიტიკული თვისებების შაბლონი წარმოადგენს გასაღებ პროტოტიპს პირდაპირი შეღწევისათვის.

ადაპტური რეზონანსის ეს და მრავალი სხვა თავისებურება ასახულია ნეიროქსელურ არქიტექტურებში, რომლებმაც **ართ** სახელწოდება მიიღო.

ართ -1 ნეირონული ქსელი.


ართ ქსელების რამდენიმე ნაირსახეობა არსებობს, ისტორიულად პირველი იყო ქსელი, რომელმაც შემდეგ **ართ -1** სახელწოდება მიიღო (S.Grossberg, G.Carpenter, 1987). ეს ქსელი ორიენტირებულია ორობითი ინფორმაციის შემცველ სახეთა დამუშავებაზე. მომდევნო ნაბიჯი – **ართ -2** არქიტექტურა, რომელიც იმავე 1987 წელს გამოქვეყნდა (S.Grossberg, G.Carpenter, 1987), – ორიენტირებულია როგორც ორობით, ასევე ანალოგურ სახეებთან მუშაობაზე. სამი წლის შემდეგ დაბეჭდილ შეტყობინებაში **ართ -3** სისტემის შესახებ (G.Carpenter, 1990) საუბარია გროსბერგისა და კარპენტერის ადაპტური რეზონანსული თეორიის გავრცობის შესახებ მრავალფენიან ნეიროარქიტექტურებზე. ამ ლექციაში ჩვენ შეგწერდებით კლასიკურ **ართ -1** ქსელზე.

ართ -1 ნეიროსიტემა წარმოადგენს შემაჯავლი ორობითი სახეების კლასიფიკატორს ქსელის მიერ აგებული რამდენიმე კატეგორიის მიხედვით. გადაწყვეტილება მიიღება გამომცნობი ფენის ერთ-ერთი ნეირონის აგზნების ფორმით, სახისა და მოცემული კატეგორიის კრიტიკულ თვისებათა შაბლონის მსგავსების ხარისხის შესაბამისად. თუ მსგავსების ეს ხარისხი მცირეა, ესე იგი სახე არც ერთ არსებულ კატეგორიას არ შეესაბამება, მაშინ მისთვის ახალი კლასის აგება ხდება, რომელიც შემდგომში შეიცვლება და დაზუსტდება სხვა სახეებით, რაც კრიტიკული ნიშნების საკუთარი შაბლონის ჩამოყალიბებას უზრუნველყოფს. ამ კატეგორიის აღწერისათვის გამოიყოფა ახალი, აქამდე გამომცნობ ფენაში უმოქმედო, ნეირონი.

ადაპტური რეზონანსის ქსელისა და მისი მუშაობის თეორიის სრული აღწერა, რომელიც გროსბერგისა და კარპენტერის ორიგინალურ პუბლიკაციაშია წარმოდგენილი, ერთობ ვეებერთელაა, ამიტომ ამ მასალის გადმოცემისას ჩვენ ფ. უოსერმენის უფრო გვიანდელ წიგნს გამოვიყენებთ, ხოლო მას **ართ -2**-ის თავისებურებათა და ახალი **ართ -3** არქიტექტურის ზოგად აღწერას დავუმატებთ.

ართ -1 ქსელი ხუთი ფუნქციური ბლოკისაგან შედგება (ნახ. 11.2.) : ნეირონთა ორი – შედარებისა და გამომცნობის – ფენისაგან, და სამი სამართი

სპეციალიზებული – ჩამოყრის, მართვის (1) და მართვის (2) – ნეირონისაგან.



ნახ. 11.2. ართ-1 ნეირონული ქსელის ზოგადი სქემა.

მართვის (1) ნეირონის საწყის მნიშვნელობას ერთის ტოლად მიიჩნევენ : $G1=1$. შემავალი ორობითი X ვექტორი მიეწოდება შედარების ფენას, რომელიც თავდაპირველად მას უცვლელად ატარებს, ამასთან შედარების ფენის გამომავალი C ვექტორი X ვექტორს უდრის : $C = X$. ამას უზრუნველყოფენ ეგრეთ წოდებული $2/3$ -ის წესის გამოყენებით შედარების ფენის ნეირონებისათვის. ამ ფენის თითოეულ ნეირონს სამი ორობითი შესასვლელი აქვს – სიგნალი X ვექტორის შესაბამისი კომპონენტისაგან, სიგნალი მართვის (1) ნეირონისაგან და უკუკავშირის R სიგნალი გამოცნობის ფენისაგან (ეს სიგნალი საწყის მომენტში ნულის ტოლია). ნეირონის აქტივაციისათვის შედარების ფენაში საჭიროა, რომ სამი სიგნალიდან ორი სიგნალი მაინც უდრიდეს ერთს, რასაც საწყის მომენტში მართვის (1) შესასვლელითა და X ვექტორის აქტიური კომპონენტებით აღწევენ.

შედარების ფენით გამოუმავებული C სიგნალი გამოცნობის ფენის ნეირონთა შესასვლელებს მიეწოდება. გამოცნობის ფენის ყოველ ნეირონს b_j წონების (ნამდვილი რიცხვების) ვექტორი გააჩნია, ამასთან ამ ფენის მხოლოდ ერთი ნეირონი აიგზნება, რომლის წონათა ვექტორი ყველაზე უფრო

ახლოს იმყოფება C -თან. ამის მიღწევა შესაძლებელია, მაგალითად, «გამარჯვებულს თან მიაქვს ყველაფერი» ტიპის ლატერალური დამუხრუჭების მექანიზმის ხარჯზე (იხ. ლექცია 7). გამარჯვებული ნეირონის გამოსასვლელი დგება ერთის ტოლ მნიშვნელობაზე, დანარჩენი ნეირონი მთლიანად დამუხრუჭებულია. უკუკავშირის სიგნალი გამარჯვებული ნეირონისაგან კვლავ შედარების ფენაში შედის სინაფსური T წონების საშუალებით. T ვექტორი, არსებითად, გამარჯვებული ნეირონით განსაზღვრული კატეგორიის კრიტიკული ნიშნების მატარებელია.

მართვის (1) ნეირონის გამოსასვლელი ერთის ტოლი მხოლოდ მაშინაა, როცა შემავალ X სახეს არანულოვანი კომპონენტები აქვს და ნეირონი შესასვლელზე სახის გაჩენის ფაქტის დეტექტირებას ასრულებს. მაგრამ, როცა გამოცნობის ფენის ნეირონების არანულოვანი R გამოხმინება წარმოიქმნება, მართვის (1) მნიშვნელობა ნულდება : $G1 = 0$.

მართვის (2) ნეირონის სიგნალი ასევე ერთზე ყენდება არანულოვანი X ვექტორის შემთხვევაში. ამ ნეირონის ამოცანას გამოცნობის ფენაზე აქტივობის ჩახშობა წარმოადგენს, თუ ქსელში არავითარი ინფორმაცია არ შესულა.

ამრიგად, გამოცნობის ფენის R გამოხმინების გენერაციისას გამოსასვლელი $G1 = 0$, და ახლა შედარების ფენის ნეირონების აქტივირება X სახისა და R გამოხმინების სიგნალებით ხდება. ორი შესამდის წესი იწვევს შედარების ფენის მხოლოდ იმ ნეირონის აქტივაციას, რომლისთვისაც X -იც და R -იც ერთს უდრის. ამრიგად, შედარების C ფენის გამოსასვლელი ახლა უკვე არ ემთხვევა ზუსტად X -ს, არამედ შეიცავს X -ის მხოლოდ იმ კომპონენტებს, რომლებიც გამარჯვებული კატეგორიის კრიტიკულთვისებებს (ნიშნებს) შეესაბამება. ადაპტური რეზონანსის თეორიაში ამ მექანიზმა X სახის ადაპტური ფილტრაციის სახელწოდება მიიღო.

ახლა სისტემის ამოცანას წარმოადგენს პასუხის გაცემა შეკითხვაზე : საკმარისია ამ კრიტიკული ნიშნების ნაკრები იმისათვის, რომ X სახე საბოლოოდ მიეკუთვნოს გამარჯვებული ნეირონის კატეგორიას? ამ ფუნქციას ახორციელებს ჩამოყრის ნეირონი, რომელიც ზომავს მსგავსებას X და C ვექტორებს შორის. ჩამოყრის ნეირონის გამოსასვლელი განისაზღვრება C ვექტორში ერთეულოვან კომპონენტთა რიცხვის საწყისი X სახის ერთეულოვან კომპონენტთა რიცხვთან ფარდობით. თუ ეს ფარდობა მსგავ-

სების გარკვეულ დონეზე ნაკლებია, ნეირონი ჩამოყრის სიგნალს იძლევა. ეს კი იმას ნიშნავს, რომ X სახის რეზონანსის დონე სავარაუდო კატეგორიის ნიშნებთან (თვისებებთან) საკმარისი არ არის დადებითი დასკვნისათვის კლასიფიკაციის დასრულების შესახებ. ჩამოყრის სიგნალის გაჩენის პირობად შემდეგი თანაფარდობა მიიღება :

$$\|C\|/\|X\| < \rho \text{ ,}$$

სადაც $\rho < 1$ – მსგავსების პარამეტრია.

ჩამოყრის სიგნალი გამარჯვებული უიღბლო ნეირონის სრულ დამუხრუჭებას ახორციელებს. ეს ნეირონი ქსელის მომდევნო მუშაობაში მონაწილეობას არ იღებს.

ართ ქსელში მიმდინარე მოვლენები კლასიფიკაციის პროცესისათვის შემდეგ ლექციაშია აღწერილი თანამიმდევრობით.

ლექცია 12. ართ ქსელი და მისი შემდგომი განვითარება.

კლასიფიკაციის პროცესში მიმდინარე მოვლენები : ქსელის საწყისი მდგომარეობა, შედარების ფაზა, ძეგნის ფაზა ; ართ ქსელის სწავლება, ქსელის სწავლებისა და ფუნქციონირების დამახასიათებელი თეორემები ; ართ-ის შემდგომი განვითარება : ართ-2 და ართ-3 არქიტექტურები, ართ-1-ის გადაუწყვეტი (ამოუხსნელი) პრობლემები და ნაკლულოვანებები, ართ-2 და ართ-3 ქსელები.

კლასიფიკაციის პროცესში მიმდინარე მოვლენები.

ქსელის საწყისი მდგომარეობა.

X შემაჯავლი ვექტორის კომპონენტთა ნულოვანი მნიშვნელობები აყენებს მართვის (2) ნეირონის სიგნალს ნულზე, ისევე როგორც გამოცნობის ფენის ნეირონთა გამოსასვლელებს. X -ის არანულოვანი მნიშვნელობების გაჩენისას მართვის ორივე ($G1$ და $G2$) სიგნალი ერთს უტოლდება. ამასთან, ორი მესამედის წესის შესაბამისად, შედარების C ფენის ნეირონთა გამოსასვლელები X ვექტორის კომპონენტთა ტოლია ზუსტად.

C ვექტორი გამოცნობის ფენის ნეირონთა შესასვლელებს მიეწოდება. ხსენებული ნეირონები კონკურენტულ ბრძოლაში ადგენს გამარჯვებულ ნეირონს, რომელიც კლასიფიკაციის სავარაუდო შედეგს აღწერს. საბოლოო ანგარიშით გამოცნობის ფენის გამოშავალი R ვექტორი ზუსტად ერთ ერთეულოვან კომპონენტს შეიცავს, ხოლო დანარჩენი მნიშვნელობები ნულს უდრის. გამარჯვებული ნეირონის არანულოვანი გამოსასვლელი აყენებს ნულზე მართვის (1) სიგნალს : $G1 = 0$. გამარჯვებული ნეირონი უკუკავშირის საშუალებით გზავნის სიგნალს შედარების ფენაში, და იწყება შედარების ფაზა.

შედარების ფაზა.

შედარების ფენაში გამოცნობის ფენის გამოსმიანებათა სიგნალების მარაოს X ვექტორის კომპონენტებთან შედარება ხდება. შედარების ფენის C გამოსასვლელი ახლა შეიცავს ერთეულოვან კომპონენტებს მხოლოდ იმ პოზიციებში, რომლებშიც ერთიანები გააჩნია X შემაჯალ ვექტორსაც და უკუკავშირის R ვექტორსაც. თუ C და X ვექტორთა შედარების შედეგად მნიშვნელოვანი განსხვავებები არ გამოვლინდა, მაშინ ჩამოყრის ნეირონი არააქტიურ მდგომარეობაში რჩება. C ვექტორი კვლავ გამოიწვევს გამოცნობის ფენაში იმავე გამარჯვებული ნეირონის აგზნებას, რითაც კლასიფიკაციის პროცესი წარმატებით დასრულდება. წინააღმდეგ შემთხვევაში გამოთქმავდება ჩამოყრის სიგნალი, რომელიც დაამუხრუჭებს გამარჯვებულ ნეირონს გამოცნობის ფენაში, და ძებნის ფაზა დაიწყება.

ძებნის ფაზა.

ჩამოყრის დაამუხრუჭებული სიგნალის მოქმედების შედეგად გამოცნობის ფენის ყველა ნეირონი ნულოვან გამოსასვლელს იძენს, და, ამრიგად, მართვის (1) ნეირონი აქტივობის ერთეულოვან მნიშვნელობას მიიღებს. შედარების ფენის C გამომავალი სიგნალი კვლავ ზუსტად X -ის ტოლი ხდება, როგორც ეს ქსელის მუშაობის დასაწყისში იყო. მაგრამ ახლა გამოცნობის ფენის კონკურენტულ ბრძოლაში წინათ გამარჯვებული ნეირონი არ მონაწილეობს, და ნაპოვნი იქნება ახალი კატეგორია – კანდიდატი. ამის შემდეგ შედარების ფაზა კვლავ მეორდება.

ძებნის იტერაციული პროცესი ორი შესაძლო გზით სრულდება.

1. მოიძებნება დამახსოვრებული კატეგორია, რომლის მსგავსება X შემაჯალ ვექტორთან საკმარისი იქნება წარმატებული კლასიფიკაციისათვის. ამის შემდეგ ტარდება სწავლების ციკლი, რომელშიც მოდიფიკაციას კლასიფიკაციის მომწყობი აგზნებული ნეირონის B და T ვექტორთა b_i და t_i წონები განიცდის.
2. ძებნის პროცესში ყველა დამახსოვრებული კატეგორია შემოწმებული აღმოჩნდება, მაგრამ არც ერთ მათგანს საჭირო მსგავსება არ მოუცია. ამ შემთხვევაში X შემაჯალი სახე ცხადდება ახალ სახედ ნეიროქსელისათვის და მას (სახეს) ახალი ნეირონი გამოეყო-

ფა გამოცნობის ფენაში. ამ ნეირონის B და T წონითი ვექტორები X ვექტორის ტოლ მნიშვნელობებზე ღებება.

მნიშვნელოვანია გვესმოდეს, საერთოდ რატომ ხდება საჭირო ძებნის ფაზა და კლასიფიკაციის საბოლოო შედეგი პირველივე ცდაზე არ მოიპოვება. ყურადღებიანმა შეითხველმა, ალბათ, უკვე მიაგნო პასუხს ამ შეკითხვაზე. **ართ** ქსელის სწავლება და ფუნქციონირება ერთდროულად ხორციელდება. გამარჯვებული ნეირონი განსაზღვრავს *შემავალ ვექტორთა სიფრცვეში* მოცემული შემავალი სახის მიმართ *უახლოეს* მესსიერების ვექტორს, და საწყისი ვექტორის ყველა ნიშანი კრიტიკული რომ იყოს, ეს სწორი კლასიფიკაცია იქნებოდა. მაგრამ კრიტიკულ ნიშანთა სიმრავლის სტაბილიზაცია შედარებით ხანგრძლივი სწავლების შემდეგ ხდება. სწავლების მოცემულ ფაზაზე შემავალი ვექტორის მხოლოდ ზოგიერთი კომპონენტი ეკუთვნის კრიტიკულ თვისებათა აქტუალურ სიმრავლეს, ამიტომ შეიძლება მოიძებნოს მეორე ნეირონ-კლასიფიკატორი, რომელიც *კრიტიკულ ნიშანთა სიმრავლეზე* საწყისი სახის მიმართ უფრო ახლოს აღმოჩნდება. სწორედ იგი განისაზღვრება ძებნის შედეგად.

უნდა აღინიშნოს, რომ სწავლების პროცესის შედარებითი სტაბილიზაციის შემდეგ კლასიფიკაცია ძებნის ფაზის გარეშე სრულდება. ამ დროს ამბობენ, რომ ყალიბდება პირდაპირი შეღწევა მესსიერებაში. ადაპტური რეზონანსის თეორიაში მტკიცდება პირდაპირი წვდომის გაჩენა სწავლების პროცესში.

ართ ქსელის სწავლება.

ფუნქციონირების დაწყებისას ნეირონთა B და T წონები, აგრეთვე მსგავსების პარამეტრი საწყის მნიშვნელობებს იღებს. ადაპტური რეზონანსული თეორიის თანახმად, ეს მნიშვნელობები უნდა აკმაყოფილებდეს შემდეგ პირობას :

$$\begin{aligned} b_i &< L/(L-1+m) \\ t_i &= 1 \end{aligned}$$

სადაც m – შემავალი X ვექტორის კომპონენტთა რიცხვია, ხოლო $L > 1$ (მაგალითად, $L = 2$). წონათა ასეთი არჩევა უზრუნველყოფს სწავ-

ლების მდგრადობას. მსგავსების ρ პარამეტრის არჩევა გადასაწყვეტი ამოცანის მოთხოვნათა საფუძველზე ხდება. ამ პარამეტრის მაღალ მნიშვნელობათა პირობებში კატეგორიების დიდი რაოდენობა ჩამოყალიბდება და თითოეულ მათგანში მხოლოდ ძალიან მსგავსი ვექტორები აღმოჩნდება წარმოდგენილი. ρ -ს დაბალი დონის პირობებში კი ქსელი კატეგორიათა უმნიშვნელო რაოდენობას შექმნის განზოგადების მაღალი ხარისხით.

სწავლების პროცესი უმასწავლებლოდ ხორციელდება თვითორგანიზაციის საფუძველზე. სწავლება გამარჯვებული ნეირონის წონებს უტარდება როგორც წარმატებული, ასევე წარუმატებელი კლასიფიკაციის შემთხვევაში. ამასთან B ვექტორის წონები C ვექტორის კომპონენტთა ნორმალიზებული სიდიდისაგან მიისწრაფვის.

$$b_i = (Lc_i) / \left(l - 1 + \sum_k c_k \right) .$$


ამასთან კომპონენტთა ნორმალიზაციის როლი უკიდურესად მნიშვნელოვანია. მრავალი ერთიანის შემცველი ვექტორები b წონათა მცირე მნიშვნელობებს განაპირობებს და, პირიქით. ამრიგად,

$$(b \cdot c) = \sum b_i c_i$$

ნამრავლი მასშტაბირებული აღმოჩნდება. ხოლო მასშტაბირების გამო ვექტორების სწორი გარჩევა (განსხვავება) შესაძლებელი ხდება იმ შემთხვევაშიც კი, როცა ერთი მეორის ქვესიმრავლეა. დაუშვათ, რომ $X1$ ნეირონი (100000) სახეს შეესაბამება, ხოლო $X2$ ნეირონი – (111100) სახეს. ცხადია, რომ ეს სახეები განსხვავებულია. ნორმალიზაციის გარეშე სწავლებისას (ესე იგი, როცა $b_i \rightarrow c_i$) პირველი სახის შესვლისას ქსელში, იგი მოგვცემს ერთნაირ სკალარულ ნამრავლებს, რომლებიც 1-ის ტოლი აღმოჩნდება ორივე ($X1$ და $X2$) ნეირონის წონათა შემთხვევაში. $X2$ ნეირონს, წონათა მნიშვნელობებში ხმაურით გამოწვეული მცირე გადახრების არსებობისას, შეუძლია კონკურენციის მოგება. ასეთ ვითარებაში მისი T ვექტორის წონები (100000) მნიშვნელობებზე დადგება და (111100) სახე ქსელს «დაავიწყდება».

ნორმალიზაციის გამოყენებისას კი საწყისი სკალარული ნამრავლები ერთის ტოლი იქნება $X1$ ნეირონისათვის და $2/5$ მნიშვნელობას შეიძენს $X2$ ნეირონისათვის (როცა $L=2$). ასეთ პირობებში $X1$ ნეირონი დამსახურებულად და ადვილად მოიგებს კონკურენტულ შეჯიბრებას.

T ვექტორის კომპონენტები, როგორც უკვე ითქვა, C ვექტორის შესაბამის მნიშვნელობებს უტოლდება სწავლებისას. ხაზი უნდა გაესვას იმ გარემოებას, რომ ეს პროცესი შეუქცევადია. თუ რომელიმე t_j კომპონენტი ნულის ტოლი აღმოჩნდა, მაშინ შემდგომი სწავლების პროცესში შედარების ფაზებზე შესაბამისი c_j კომპონენტი არასოდეს მიიღებს შევლას $t_j = 0$ სიდიდისაგან $2/3$ -ის წესით, და, ამრიგად, t_j -ის ერთეულოვანი მნიშვნელობის აღდგენა შეუძლებელი ხდება. სწავლებას, მაშასადამე, თან ახლავს T ვექტორის კომპონენტთა სულ უფრო მეტი რაოდენობის განულება, ხოლო დარჩენილი არანულოვანი კომპონენტები განსაზღვრავს მოცემული კატეგორიის კრიტიკულ თვისებათა (ნიშანთა) სიმრავლეს. ეს თავისებურება ილუსტრირებულია ნახ. 12.1.-ზე.



12.1. მასწავლებელი C სახეები და კრიტიკულ თვისებათა აგებული T ვექტორი – კატეგორიის საერთო ელემენტთა მინიმალური ნაკრები.

პირველწყაროში სწავლება დიფერენციალურ განტოლებათა ტერმინებში განიხილება. ამ განტოლებებიდან ჩვენს მიერ მითითებული მნიშვნელობები ზღვრულ გადასვლათა შედეგად მიიღება.

ახლა მოკლედ შევჩერდეთ ადაპტური რეზონანსული თეორიის ძირითად თეორემებზე, რომლებიც ქსელის სწავლებასა და ფუნქციონირებას ახასიათებს.

ართ თეორემები.

1. სწავლების სტაბილური მდგომარეობის მიღწევისას ერთ-ერთი მასწავლებელი ვექტორის წარდგენა სწორი კლასიფიკაციით მთავრდება ძებნის ფაზის გარეშე, პირდაპირი შეღწევის საფუძველზე.
2. ძებნის პროცესი მდგრადია.
3. სწავლების პროცესი მდგრადია. გამარჯვებული ნეირონის წონათა სწავლება არ გამოიწვევს შემდგომში სხვა ნეირონზე გადართვას.
4. სწავლების პროცესი სასრულია. ნასწავლი მდგომარეობა სახეთა მოცემული ნაკრებისათვის იტერაციათა სასრული რაოდენობით იქნება მიღწეული, ამასთან ერთად ამ სახეთა შემდგომი წარდგენა არ გამოიწვევს წონათა მნიშვნელობების ციკლურ ცვლილებებს.

ართ -ის შემდგომი განვითარება : ართ-2 და ართ-3 არქიტექტურები.

ართ-1-ის გადაუწყვეტელი პრობლემები და ნაკულულოვანებები.

ართ ნეირონულ ქსელებს, მათი შესანიშნავი თვისებების მიუხედავად, რიგი ნაკულულოვანება ახასიათებს. ერთ-ერთ მათგანს ქსელში სინაფსური კავშირების დიდი რაოდენობა წარმოადგენს, დამახსოვრებული ინფორმაციის ერთეულზე გადაანგარიშებისას. ხსენებული კავშირების წონათა (მაგალითად, T ვექტორის მდგენელთა) შორის მრავალი სიდიდე ნულის ტოლი აღმოჩნდება სწავლების შემდეგ. ამ თავისებურების გათვალისწინება აუცილებელია აპარატულ რეალიზაციებში.

ართ-1 ქსელი მხოლოდ ბიტურ ვექტორებთან სამუშაოდ გამოდგება. ეს მოუხერხებლობა დაძლეულია **ართ-2** და **ართ-3** ქსელებში. მაგრამ ამ არქიტექტურებში, ისევე როგორც **ართ-1** არქიტექტურაში, შენარჩუნებულია **ართ** არქიტექტურის მთავარი ნაკულულოვანება — მეხსიერების ლო-

კალიზებული ხასიათი. **ართ** ნეიროქსელის მეხსიერება არ არის განაწილებული, გარკვეულ მოცემულ კატეგორიას გამოცნობის ფენის სავსებით კონკრეტული ნეირონი შეესაბამება. მისი დაზიანების შემხვევაში ქრება მეხსიერება მთელი კატეგორიის შესახებ. ეს თავისებურება ვაი, რომ არ იძლევა საშუალებას მივიჩნიოთ ადაპტური რეზონანსული თეორიის ქსელები ბიოლოგიური ქსელების პირდაპირ მოდელებად! ბიოლოგიური ქსელების მეხსიერება განაწილებულია.

ართ-2 და ართ-3 ქსელები.

ართ-2 ნეირონული ქსელის ძირითად განმასხვავებელ ნიშანს ანალოგურ ვექტორებთან და სიგნალებთან მუშაობის შესაძლებლობა წარმოადგენს. **ართ-1** არქიტექტურასთან შედარებით ქსელის **ართ-2** არქიტექტურაში განხორციელებულია ზოგიერთი ცვლილება, რომელიც ცალკეულ ქვესისტემას ასინქრონულად ფუნქციონირების საშუალებას აძლევს, რასაც პრინციპული მნიშვნელობა აქვს აპარატული რეალიზაციებისათვის.

ანალოგური სიგნალები ბიტური სიგნალებისაგან მნიშვნელოვნად განსხვავდება იმით, რომ ანალოგურ ვექტორებს რაგინდ დიდი ურთიერთისახლოვის, ურთიერთმსგავსების პრინციპული შესაძლებლობა გააჩნია (მაშინ როცა ბიტური ვექტორების სივრცე დისკრეტულია). ამის გამო შედარების ფენის ნეირონთა ფუნქციონირების მიმართ დამატებითი მოთხოვნები ჩნდება – რეზონანსის არის გამოსაყოფად საჭიროა უფრო ფაქიზი და მგრძობიარე მექანიზმი. ზოგად გადაწყვეტილებად ასეთ ვითარებაში მრავალფენიანი არქიტექტურის გამოყენება მიაჩნიათ, როცა ფენიდან ფენაზე გადასვლა სულ უფრო ზუსტ აწყობას უზრუნველყოფს. სწორედ ეს იდეა ხორციელდება **ართ-2** არქიტექტურაში. გამოცნობის ფენის ფუნქციონირება კი პრინციპულად არ იცვლება.

ართ-2 ქსელებს მოძრავ გამოსახულებათა გამოსაცნობად იყენებდნენ. წარმატებითი ექსპერიმენტები შესრულებულია მასაჩუსეტსის (Massachusetts) ტექნოლოგიურ ინსტიტუტში. ვინაიდან **ართ** ნეიროსისტემები არ შეიცავს ინვარიანტული გამოცნობის მექანიზმს (ნეოკოგნიტრონისაგან განსხვავებით, იხ. ლექცია 10), მათთან შეხამებით სახეთა ინვარიანტული წარმოდგენის სპეციალიზებულ (ხშირად, არანეიროქსელურ) სისტემებსაც იყენებენ, მაგალითად, ფურიეს ორგანზომილებიან გარდასახვას, ან უფრო რთულ ალგორითმებს. **ართ-2** არქიტექტურის თავისებურებათა და გამო-

ყენებათა უფრო დაწვრილებითი განხილვა პროფესიულ შესწავლას მოითხოვს და ჩვენს მიზნებში არ შედის.

ართ არქიტექტურის განვითარებაში შემდეგ ნაბიჯად **ართ-3** ქსელი გახდა. **ართ-1** და **ართ-2** ქსელების ნეირონთა სწავლების თავისებურებანი ამ ქსელების უფრო მსხვილი იერარქიული ნეიროსისტემების ელემენტებად გამოყენების საშუალებას არ იძლევა. მაგალითად, შეუძლებელია ამ ქსელების საშუალებით მრავალფენიანი ქსელების შედგენა. ამის გამო **ართ** არქიტექტურის პირობებში გაძნელებულია იერარქიულად ორგანიზებული ინფორმაციის წარმოდგენა, რაც დამახასიათებელია ადამიანისა და ცხოველთა აღქმის სისტემებისათვის.

ეს პრობლემები გადაწყვეტილია **ართ-3** ქსელში, რომელიც მრავალფენიანი არქიტექტურის როლში გამოდის. ფენიდან ფენაზე გადასვლისას შემავალ სახეთა კონტრასტირება და მათი სულ უფრო ზოგადი კატეგორიების ფორმით დამახსოვრება ხდება. ამასთან ყოველი ფენის ძირითად ამოცანას შემავალი ინფორმაციის შეკუმშვა (კომპრესია) წარმოადგენს.

სახე შედის ადაპტირებად რეზონანსში, რომელიც ფენათა გარკვეულ წყვილს შორის ჩნდება, შემდგომ ეს რეზონანსი ვრცელდება იერარქიის მომდევნო ფენებზე. **ართ-1** და **ართ-2** არქიტექტურებში რეზონანსის არასაკმარისი დონე იწვევდა ჩამოყრის სიგნალის გენერაციას, რაც გამოცნობის ფენის სრული დამუხრიჭებით მთავრდებოდა. მრავალფენიანი **ართ-3** ქსელის შემთხვევაში ეს დაუშვებელია, რადგან წყდება ინფორმაციის ნაკადი. ამიტომ **ართ-3** არქიტექტურაში შემოტანილია უკუკავშირების სინაფსთა აქტივობის დროზე დამოკიდებულების სპეციალური მექანიზმი, რომელიც ბიოლოგიური ნეირონის რეფრაქტერული² დამუხრუჭების ტოლფასია აგზნების გადაცემის შემდეგ. ამის გამო სიგნალის სრული ჩამოყრის ნაცვლად უკუკავშირის სინაფსური სიგნალების დამუხრუჭება ხდება, და შედარების ფენა აგზნების საწყის მდგომარეობას იძენს ახალი რეზონანსის ძებნის ფაზის განსახივრციელებლად.

² რეფრაქტერობა (ფრანგ. réfractaire – ძნელად აღქმელი, ძნელად შემთვისებელი, შეუვალი) – ნერვის ან კუნთის აგზნების არარსებობა ან დაქვეითება წინა (წარსული, გასული) აგზნების შემდეგ, აგზნებაშეუვალობა; დამუხრუჭების საფუძველია.

საინტერესო წინადადებად გვეჩვენება აგრეთვე მრავალფენიან იერარქიაში ისეთი ფენების გამოყენება, რომლებიც **ართ** ფენებს არ წარმოადგენს და რაღაც სხვა არქიტექტურას ეკუთვნის. ასეთ შემთხვევაში ჰიბრიდული სისტემა მიიღება, რაც ახალი სასარგებლო თვისებების გაჩენით შეიძლება დაგვირგვინდეს.

ადაპტური რეზონანსული თეორიის განვითარება გრძელდება. თეორიის ავტორთა თქმით, იგი წარმოადგენს რაღაც არსებითად უფრო კონკრეტულს, ვიდრე ფილოსოფიური აზრთწყობაა, მაგრამ გაცილებით უფრო ნაკლებად კონკრეტულს, ვიდრე დასრულებული პროგრამაა კომპიუტერისათვის. მაგრამ უკვე თანამედროვე სახითაც კი, მრავალწლიან ისტორიაზე დაყრდნობით, **ართ** ქსელები უჩვენებს თავიანთ წარმატებულ გამოყენებებს სხვადასხვა დარგში. **ართ** არქიტექტურამ მნიშვნელოვანი ნაბიჯი გადადგა აგრეთვე პლასტიკურ-სტაბილური აღქმის მოდელირების ზოგად პრობლემაშიც.

ლექცია 13. თანამედროვე არქიტექტურათა თვისებები.

ნეირონული ქსელების თანამედროვე არქიტექტურები. ფუნდამენტურ კვლევათა აქტუალური მიმართულებები. ნეირონული ქსელების პროგრამული და აპარატული რეალიზაციები. ნეიროპროცესორები. სამეცნიერო და სამრეწველო გამოყენებანი.

თანამედროვე არქიტექტურათა თვისებები.

ომისმერმინდელ წლებში შესრულებულმა კლასიკურმა გამოკვლევებმა და შემდგომმა მძაფრმა პროგრესმა ოთხმოციანი წლების ნეიროინფორმატიკაში ზოგიერთ პერსპექტიულ არქიტექტურათა საერთო ნიშნები (თვისებები) და კვლევათა მიმართულებები განსაზღვრა. და თუმცადა ნებისმიერი შეფასება ამ სფეროში ერთობ სუბიექტურია, მაინც შესაძლებელია გარკვეული თვალთახედვის ჩამოყალიბება გამოკვეთილ ტენდენციათა შესახებ. შევჩერდეთ ზოგიერთ მათგანზე.

1. თეორიული გამოკვლევების მჭიდრო შერწყმა ნეირონული ქსელების აპარატული რეალიზაციისათვის საჭირო ახალი ფიზიკური გარემოსა და პრინციპების ძებნასთან. აქ პირველ რიგში უნდა აღინიშნოს ოპტიკური სისტემები, როგორც წრფივი, ასევე არაწრფივი : ფურიე-ოპტიკა, ჰოლოგრამები, არაწრფივი ფოტორეფრაქციული კრისტალები, ოპტიკური ტალღმზიდი ბოჭკოები, ელექტრონულ-ოპტიკური მამრავლები და სხვა. პერსპექტიულია აგრეთვე ქიმიური და ბიოლოგიური გარემოები ბუნებრივი ავტოტალღური თვისებებით. ყველა ასეთ გარემოში ინფორმაციის დამუშავებისას რეალიზებულია მასიური პარალელურობის მნიშვნელოვანი თვისება. გარდა ამისა, ისინი, როგორც წესი, «თვითრეგულირების» მექანიზმებსაც შეიცავს, რომლებიც უმასწავლებლოდ სწავლების ორგანიზების საშუალებას იძლევა.

2. არქიტექტურათა იერარქიულობა და ნეირონთა ფუნქციების განაწილება. თანამედროვე არქიტექტურებში რამდენიმე სხვადასხვა ტიპის ფუნქციები ან ცალკეული ნეირონები გამოიყენება : სამეთაურო გადამრთველი ნეირონები, ზღურბლური ნეირონები, «გამარჯვებულს თან მიაქვს ყველაფერი» პრინციპით მომუშავე ნეირონული ფუნქციები ლატერალური დამუხრუჭებით. ნეირონთა ფუნქციების აპრიორული განაწილება მნიშვნელოვნად ამარტივებს სწავლებას, რადგან ქსელი სტრუქტურულად იმთავითვე შეესაბამება ამოცანას.
3. უმასწავლებლოდ – თვითორგანიზაციის ხარჯზე – სწავლების მეთოდთა უპირატესი გამოყენება. ამ მეთოდებს ღრმა ბიოლოგიური საფუძვლები გააჩნია, ისინი სწავლების ლოკალურ ხასიათს უზრუნველყოფს. ეს კი ქსელის გლობალური ბმულობის გამოყენებლად მუშაობის საშუალებას იძლევა. მასწავლებლის დახმარებით ნეირონთა მხოლოდ გარე, გამოძავალი ფუნქციები სწავლობს და ამასთან მასწავლებლის როლი ხშირად ქსელის მუშაობის ხარისხის ზოგად საექსპერტო შეფასებამდე დაიყვანება.
4. გამოკვლევებისა და არქიტექტურების უშუალო ორიენტაცია გამოყენებებზე. ზოგადი ხასიათის მოდელები, როგორცაა ჰოპფილდის ქსელი ან მრავალფენიანი პერსეპტრონი, ძირითადად, მეცნიერულ ინტერესს წარმოადგენს, რადგან ამ მოდელებზე შესაძლებელია შედარებით სრული თეორიული გამოკვლევების ჩატარება.

ეს სია, რასაკვირველია, სრულიადაც არ არის ამომწურავი. მასში არ შესულა, მაგალითად, თანამედროვე გამოკვლევები ჰიბრიდულ ნეირონულ საექსპერტო სისტემათა სფეროდან, რომლებიც იყენებს როგორც ფორმალურ ლოგიკას, ასევე ასოციაციურ გამოცნობასაც. მკითხველს თავადაც შეუძლია ხსენებული ტიპის ნეირონული ქსელების გაანალიზება საერთო თვისებათა და ტენდენციათა გამოსავლენად.

ნეირომეცნიერების დღევანდლობა.

ზოგიერთი ცნობა ნეირომეცნიერების ისტორიიდან მკითხველმა უკვე მიიღო შესავალში. ფუნდამენტური გამოკვლევები ნეირონული ქსელებისა და ინფორმაციის დამუშავების ინტელექტუალურ მეთოდთა თეორიაში ახალ ფაზას აღწევს 1986 წლიდან შემდგარი რიგი სპეციალიზებული კონფერენციის შემდეგ, რომელიც უშუალოდ ნეირომეცნიერებას მიეძღვნა. 1988 წლის შემოდგომაზე დაარსდა ნეირონული ქსელების საერთაშორისო საზოგადოე-

ბა (INNS – International Neural Networks Society), რომელიც მსოფლიო «ნეიროაქტივობის» კოორდინაციას ახორციელებს.

ნეირომეცნიერების განვითარების ტენდენციათა ერთიანად მიწვდომა შესაძლებელია, მაგალითად, ნეირონული ქსელებისადმი მიძღვნილი 1994 წლის მსოფლიო კონგრესის პროგრამის ძირითადი თემატური საკითხების გადახედვით. ეს კონგრესი სწორედ ნეირონული ქსელების საერთაშორისო საზოგადოების მიერ იყო ორგანიზებული.

1. *ბიოლოგიური მხედველობა.* ამ მიმართულებას სათავეში უდგას ს. გროსბერგი.

2. *მანქანური მხედველობა.* მიმართულება მოიცავს ტექნიკურ სისტემებში მხედველობის ფუნქციათა მოდელირების ასპექტებს. განსაკუთრებული განხილვის ცენტრშია შერჩევითი ყურადღების პრინციპები სამხური სცენის ობიექტების მიმართ.

3. *ბგერა და ენა.* ბგერის სინთეზისა და გამოცნობის სხვადასხვა ასპექტი.

4. *ბიოლოგიური ნეირონული ქსელები.* განყოფილების თემატიკა მოიცავს ცალკეული ნეირონების, მოძრაობისა და სმენის მართვის ნეირონული ქსელების თვისებებს, ბიოლოგიურ ქსელებში სწავლების ასპექტებს, ასევე ბიოლოგიური ნეირონებიდან ხელოვნურ (სილიციუმის, კაჟბადის) ნეირონებზე გადასვლის გზებს.

5. *ნეირომართვა და რობოტოტექნიკა.* ტერმინი «რობოტი» (ჩეხურად : მონური შრომა) პირველად გამოიყენა ცნობილმა ჩეხმა მწერალმა კარლ ჩაპეკმა 1920 წელს პიესაში «R.U.R.».

6. *მასწავლებლით სწავლება.*

7. *უმასწავლებლოდ სწავლება.*

8. *სახეთა გამოცნობა.*

9. *სისტემათა პროგნოზი და იდენტიფიკაცია*. განიხილება როულ სისტემათა კიბერნეტიკული მოდელირების მეთოდები ნეირონულ ქსელთა ბაზაზე.
10. *ნეირომეცნიერება ცნობიერების შესახებ*. უმაღლესი ნერვული სისტემის მოქმედების ორგანიზაციისა და მოდელირების ასპექტები.
11. *ცნობიერების შესახებ მეცნიერების კავშირი ხელოვნურ ინტელექტთან*.
12. *არამკაფიო ნეირონული სისტემები*. არამკაფიო ლოგიკის ნეირომოდელის აგება.
13. *სივნალების დამუშავება*. ნეირონული ქსელებისა და სახეთა გამოცნობის თეორიის გამოყენებათა ერთ-ერთი უძველესი სფერო – ხმაურიდან სივნალის გამოყოფა და მისი თვისებების ანალიზი.
14. *ნეიროდინამიკა და ქაოსი*. იგულისხმება ნეირონული ქსელების თვისებათა შესწავლა ამ ქსელების არაწრფივ დინამიკურ სისტემადად განხილვისას.
15. *აპარატული რეალიზაციები*. პერსპექტიულ გამოყენებათა საკვანძო საკითხი – ახალი ფიზიკური პრინციპები და გარემოები ინფორმაციის დასამუშავებლად.
16. *ასოციაციური მეხსიერება*.
17. *გამოყენებები*. ეს განყოფილება განსაკუთრებით მრავალფეროვანია.
18. *ნეიროგამოთვლები და ვირტუალური რეალობა*. აქ განიხილება ნეირონული ქსელების და ასეთ ქსელებზე მაღალპარალელურ გამოთვლათა გამოყენების შესაძლებლობა ხელოვნური რეალობის შესაქმნელად. ვირტუალური რეალობის როული აპარატულ-პროგრამული სისტემა ადამიანის მიერ აღქმადი გარე სამყაროს ძირითადი სივნალების მოდელირებას ახდენს და რეაგირებს მის მოქმედებაზე. ხსენებული აპარატულ-პროგრამული სისტემა მოტყუებით ცვლის რეალურ სამყაროს და ამ სამყაროდ საკუთარ თავს წარმოაჩენს.

19. *ქსელები და სისტემური ნეირომეცნიერება*. ძირითადი ყურადღება ექცევა სიგნალების დროში ქცევას ბიოლოგიურ და ხელოვნურ ნეირონულ კონტურებში.

20. *მათემატიკური საფუძვლები*.

ზოგიერთი მიმართულება – როგორცაა, მაგალითად, სწავლება მასწავლებლის დახმარებით და მის გარეშე, ნეიროდინამიკა და ასოციაციური მექანიზმები, სახეთა გამოცნობა, მათემატიკური ამოცანების ამოხსნა ნეირონულ ქსელებზე – ძირითადი კლასიკური შედეგების სახით იყო წარმოდგენილი ლექციათა ამ კურსში. ნეიროინფორმატიკის მრავალი უახლესი სხვა გამოყენებაც, შესაძლოა, ცნობილია მკითხველისათვის. მაგალითად, განსაკუთრებული ინტერესი გაჩნდა ნეიროინფორმატიკის გამოყენებათა მიმართ ეკონომიკასა და ფინანსებში, რაც ცდება ჩვენი სალექციო კურსის ჩარჩოებს.

პროგრამული და აპარატული უზრუნველყოფა. ნეიროკომპიუტერი.

ამჟამად ნეიროქსელური პროდუქტების ვრცელი ბაზარია ჩამოყალიბებული. პროდუქტების დიდი უმრავლესობა მამოღელირებელი პროგრამული უზრუნველყოფის სახითაა წარმოდგენილი. წამყვანი ფირმები ქმნის აგრეთვე სპეციალიზებულ ნეიროჩიპებს ან ნეიროფირფიტებს ჩვეულებრივი (როგორც წესი, IBM PC AT პლატფორმის) კომპიუტერის მისაღვამის სახით. ამასთან პროგრამებს შეუძლია მუშაობა როგორც ნეირო-მისაღვამების გარეშე, ასევე მათი გამოყენებითაც. უკანასკნელ შემთხვევაში ჰიბრიდული კომპიუტერის სწრაფქმედება ასჯერ და ათასჯერ იზრდება.

შეიძლება ჩამოვთვალოთ ზოგიერთი ცნობილი და პოპულარული ნეიროსისტემა და მისი მწარმოებელი.

პროგრამების პაკეტი «NeuralWorks Professional II Plus». ეს NeuralWare ფირმის მიერ დამუშავებული NeuralWorks პროდუქტის ერთ-ერთი უკანასკნელი ვერსიაა. პაკეტი შეიცავს ნეირონული ქსელების მრავალი არქიტექტურის პროგრამულ მოდელს (მათ შორის ლექციათა ამ კურსში განხილულსაც). ფირმის გამოცხადებული აქვს SUN ტიპის სამუშაო სადგური-სათვის პაკეტის ვერსიისა და nCUBE პარალელური პროცესორების გამოშვებაც.

პროგრამების პაკეტი «ExploreNet 3000». პროფესორ რობერტ ჰეხტ-ნილსენის (R.Hecht-Nielsen) მიერ დაარსებული HNC ფირმის ნაწარმოები პროდუქტია. პაკეტი ფართო შესაძლებლობებს იძლევა მონაცემთა მოდელირებისა და მართვის უზრუნველსაყოფად. ამჟამინდელი როლში გამოიყენება HNC ფირმის ტექნიკური მოწყობილობები – ANZA და ANZA+ ნეიროპროცესორები, რომლებიც ერთ-ერთ პირველ აპარატულ გადაწყვეტილებათა რიცხვს მიეკუთვნება. ფირმა სთავაზობს მომხმარებელს აგრეთვე გამოყენებითი პროგრამების დამუშავების საშუალებას – C ენაზე დაფუძნებულ დაპროგრამების სპეციალიზებულ AXON ენას.

გარსი «NeuroShell 2.0». ამ პროგრამის ღირსებას მონაცემთა მართვის პოპულარულ MicroSoft Excel პაკეტთან თავსებადობა წარმოადგენს, რის გამოც პროდუქტი გამოსადეგი ხდება მასობრივი გამოყენებისათვის.

რუსეთში ცნობილია აგრეთვე ტაგანროვის მრავალპროცესორიანი გამომთვლელი სისტემების სამეცნიერო კვლევითი ინსტიტუტის ნაწარმი – ციფრული ნეიროკომპიუტერებისათვის განკუთვნილი ზედიდე ინტეგრალური სქემა, რომელიც 20 მეგაპერცზე მუშაობს და 100 000 ლოგიკურ ვენტის (პორტს) შეიცავს. ფუნქციონირებს აგრეთვე ნეიროკომპიუტერების მოსკოვის ცენტრი, სადაც მზადდება აპარატული სისტემები ტრანსპიუტერების საფუძველზე. პროგრამულ სისტემათა შორის უნდა აღინიშნოს კრასნოიარსკის უნივერსიტეტის ნეიროკიბერნეტიკის კათედრის პროდუქცია, როსტოვის უნივერსიტეტის ნეიროკიბერნეტიკის სამეცნიერო კვლევითი ინსტიტუტისა და ნიჟნი ნოვგოროდის გამოყენებითი ფიზიკის სახეთა გამოცნობის სისტემები.

1993 წელს გერმანულმა ფირმამ Siemens-მა გამოაცხადა იმ დროისათვის ყველაზე სწრაფქმედი ნეიროკომპიუტერის (SYNAPSE-I) გამოშვების შესახებ. ეს ნეიროკომპიუტერი წარმოადგენს სისტემას, რომელიც შეიცავს მმართველ (host) მანქანას და სპეციალიზებულ ნეიროპროცესორს ლოკალური მეხსიერებით სინაფსური წონებისათვის. ყოველ ნეიროქსელურ პარადიგმაში ადვილად გამოიყოფა ნეირონული ქსელებისათვის დამახასიათებელი ოპერაციების შედარებით მცირე ნაკრები, რომელიც შეიძლება იყოს ძალიან ეფექტურად შესრულებული პარალელურ რეჟიმში სპეციალიზებულ პროცესორზე. ასეთ ოპერაციათა რიცხვს მიეკუთვნება, მაგალითად, მატრიცებისა და ვექტორების გამრავლება და შეკრება, მატრიცათა ტრანსპონირება, ზღურბლურ გარდასახვათა გამოანგარიშება, ცხრილის ფუნქციონირება.

პარალელური გამოთვლა და სხვა. განვითარებული ლოგიკის მქონე ალგორითმის დარჩენილი ფრაგმენტები, რომლებიც გამოთვლათა საერთო დროიდან, ჩვეულებრივ, მხოლოდ რამდენიმე პროცენტს მოითხოვს, წარმატებით შეიძლება იყოს შესრულებული ტრადიციულ კომპიუტერზე.

SYNAPSE-1 ნეიროკომპიუტერში ასეთი host-მანქანის როლში Sun Sparc Station II სამუშაო სადგური გვევლინება. SYNAPSE-1 კომპიუტერში დაგეგმილი აჩქარება ნეიროპერაციებზე თითქმის რვა ათასს (!) შეადგენს თავად host-სადგურის მიმართ. მომხმარებლისათვის გათვალისწინებულია მოხერხებული და პრობლემურად ნეიროქსელზე ორიენტირებული დაპროგრამების nAPL ენა, დაპროგრამების გარემო C++ ენაზე და UNIX-თავსებადი ოპერაციული სისტემა.

ზემოჩამოთვლილი ნეიროსისტემები შედარებით ძვირია და ისინი, ძირითადად, განკუთვნილია პროფესიული გამოყენებისათვის. სასწავლო-კვლევითი მიზნებისათვის ლექციათა ამ კურსში მოყვანილია ერთფენიანი პერსექტორის სწავლებისა და გამოცნობის ალგორითმების მარეალიზებული მარტივი პროგრამა. მკითხველს, რომელმაც დაპროგრამების ენა პასკალი იცის, შეუძლია შეტანისა და გამოტანის მოდულების დამატებისას ამ პროგრამის გამოყენება როგორც ექსპერიმენტების ჩასატარებლად ნეირონულ ქსელზე, ასევე ნეიროპროგრამული უზრუნველყოფის შექმნის ტექნოლოგიის ასათვისებლად საწყის დონეზე.

ლექცია 14. ნეიროქსელების კომპიუტერული მოდელირება.

ნეიროქსელების იმიტაციური მოდელირებისათვის განკუთვნილი პროგრამული უზრუნველყოფის შექმნის პრინციპები. პროგრამის ბლოკთა სტრუქტურა და ფუნქციები. პერსპექტივის სწავლების ალგორითმის პროგრამული განხორციელების მაგალითი.

ნეირონული ქსელების გამოყენებათა მნიშვნელოვანი წილი მათი პროგრამული მოდელების გამოყენებაზე მოდის, რომლებსაც, ჩვეულებრივ, *ნეირო-იმიტატორებს* უწოდებენ. პროგრამის შექმნა, როგორც წესი, უფრო იაფი ჯდება, ხოლო მიღებული პროდუქტი უფრო დამაჯერებელი, მობილური და მოხერხებული სახისაა, ვიდრე სპეციალიზებული აპარატურა. ნებისმიერ შემთხვევაში, ნეიროქსელის აპარატურულ რეალიზაციას ყოველთვის წინ უნდა უძღვოდეს მისი ყოველმხრივი შესწავლა თეორიის საფუძველზე კომპიუტერული მოდელის გამოყენებით.

ლექციათა კურსის ამ ნაწილში აღწერილია შედარებით მცირე, ჩვეულებრივ, ინდივიდუალური მოხმარების ნეიროპროგრამათა შექმნის ყველაზე ზოგადი პრინციპები. თხრობის მაქსიმალურად გაადვილების მიზნით შერჩეულია ნეირონული ქსელის მარტივი არქიტექტურა – ერთფენიანი პერსპექტივი. ამ ქსელის თეორიული საფუძვლები მეთხე ლექციაში იყო განხილული.

დასასრულს ლექციაში მოყვანილია აღწერილ პროგრამათა ლისტინგები, რომლებიც ტურბო პასკალზე IBM PC პერსონალური კომპიუტერისათვის დაპროგრამებას გაცნობილ მკითხველს შეუძლია სასწავლო მიზნებით გამოიყენოს ან გადააკეთოს საკუთარი სურვილის შესაბამისად.

ნეიროიმიტატორთა შექმნის პრინციპები.

ნეიროიმიტატორი წარმოადგენს კომპიუტერულ პროგრამას (ან პროგრამათა პაკეტს), რომელიც შემდეგ ფუნქციებს ასრულებს :

- ნეირონული ქსელის არქიტექტურის აღწერა და ფორმირება ;
- მონაცემთა შეგროვება მასწავლებელი ა(მო)ნაკრებისათვის ;
- არჩეული ნეიროქსელის სწავლება მასწავლებელ ა(მო)ნაკრებზე ან უკვე ნასწავლი ქსელის ჩატვირთვა დისკოდან ;
- ნასწავლი ნეიროქსელის ტესტირება ;
- სწავლებისა და ტესტირების პროცესის ვიზუალიზაცია ;
- ამოცანათა ამოხსნა ნასწავლი ქსელით ;
- სწავლების შედეგებისა და მიღებულ ამონახსნთა ჩაწერა დისკოზე.

ამ ფუნქციათა სარეალიზაციოდ სამრეწველო ნეიროიმიტატორები (როგორცაა, მაგალითად, Neural Ware ფირმის Neural Works Professional II+ ან კრასნოიარსკის სამეცნიერო ცენტრში შექმნილი MultiNeuron პროგრამული პაკეტები) აღჭურავს მკვლევარს შესაძლებლობათა ფართო სპექტრით.

ინდივიდუალურ პროგრამებში, როცა მომხმარებელს, უწინარეს ყოვლისა, ნეიროქსელის მუშაობის შედეგი აინტერესებს, ამ ფუნქციათა ნაწილი შეიძლება მაქსიმალურად გამარტივდეს.

ამოცანათა ამოხსნა ნეიროქსელების გამოყენებით ხშირად შემდეგი ეტაპებისაგან შედგება (ამასთან, არც ყველა ეტაპია სავალდებულო და არც მათი შესრულება აქ მითითებული თანამიმდევრობით).

ამოცანის დასმა ნეირონული ქსელის ტერმინებში.

ამოცანის დასმას ნეირონული ქსელისათვის გარკვეული თავისებურება გააჩნია და ამაში მკითხველს უკვე შეეძლო დარწმუნება მთელი კურსის მანძილზე. უწინარეს ყოვლისა, აუცილებელია გადაწყდეს, ეკუთვნის თუ არა ამოსახსნელი ამოცანა ნეიროქსელურ დასმათა ერთ-ერთ სტანდარტულ ტიპს, როგორცაა : კლასიფიკაციის (კატეგორიზაციის), ფუნქციური მოდელის აგების (სისტემის იდენტიფიკაციის), ოპტიმიზაციისა და ნეირომა-

თემატიკის, მართვის, დაბოლოს, სახეთა გამოცნობისა და სიგნალების დამუშავების.

ნეიროკომპიუტერისათვის ამოცანის არასტანდარტული დასმა, ჩვეულებრივ, მოითხოვს სპეციალურ კვლევათა ჩატარებას და სხვა ამოცანათა ამოხსნის დიდ გამოცდილებას. ამ ეტაპზე აუცილებლად უნდა გაეცეს პასუხი შეკითხვას : საჭიროა საერთოდ მოცემული ამოცანის ამოსახსნელად ნეირონული ქსელი? სავსებით შესაძლებელია (და ხშირად ასეც ხდება), რომ ამონახსნი ალგორითმული გზითაც მიიღებოდეს. ასეთ შემთხვევაში ნეირომიმბატორის გამოყენება, ჩვეულებრივ, არაეფექტურია

შემდეგ უნდა განისაზღვროს ამოცანაში გამოყენებული ნიშნების (თვისებების) სივცეები, რომლებშიც შეტანილია ამ ამოცანისათვის მნიშვნელოვანი როლის მქონე პარამეტრები. თუ თქვენ განსახილველ საგნობრივ სფეროში ექსპერტი არ ხართ, მაშინ ამ ეტაპზე მიზანშეწონილია კონსულტაციათა მიღება. კოლეგებთან ურთიერთობა საზიანო არასოდეს იქნება, იმ შემთხვევაშიც კი, თუ თქვენ წამყვან სპეციალისტად გთვლიან ამ საკითხში.

თვისებათა სივცეების აგებისას გათვალისწინებული უნდა იქნას შესაბამისი მონაცემების არსებობა და ხელმისაწვდომობა, წინააღმდეგ შემთხვევაში თქვენ არ გექნებათ ინფორმაცია ნეიროქსელის სწავლების განსახორციელებლად.

დაბოლოს, ფრიად სასარგებლოა ნეიროქსელის მუშაობის მოსალოდნელი შედეგისა და მისი შემდგომი გამოყენების წარმოდგენა. მრავალ შემთხვევაში ეს ამარტივებს ამოცანის დასმას და შედეგად უფრო ეფექტურ ამონახსნს იძლევა. თუ მიღებული შედეგები თქვენი მოლოდინის შესაბამისი არ აღმოჩნდა, მაშინ ეს კიდევ ერთი მიზეზი გახდება იმისა, რომ გაცილებით უფრო საფუძვლიანად მიუდგეთ ამოცანას.

ამოცანის ადეკვატური ნეიროარქიტექტურის არჩევა და ანალიზი.

გამოსაყენებელი ნეიროქსელის ტიპი უმეტესწილად ნაკარნახებია დასმული ამოცანით. ასე, მაგალითად, კლასიფიკაციის ამოცანისათვის მოხერხებული შეიძლება აღმოჩნდეს მრავალფენიანი პერსეპტრონი და ლიპმან-ჰემინგის ქსელი. პერსეპტრონი გამოდგება ასევე სისტემათა იდენტიფიკაციისა და პროგნოზის ამოცანებისათვის. კატეგორიზაციის ამოცანათა გადასაწყვეტად

საჭირო გახდება კოჰონენის რუკა, შემხვედრი მიმართულების არქიტექტურა ან ქსელი ადაპტური რეზონანსით. ნეირომათემატიკის ამოცანები, ჩვეულებრივ, ჰოპფილდის მოდელის სხვადასხვა მოდიფიკაციათა გამოყენებით ამოიხსნება.

უკეთესია ისეთი არქიტექტურის გამოყენება, რომლის თვისებები ცნობილია თქვენთვის, რადგან ეს გაამარტივებს შედეგების ინტერპრეტაციას. გავლენა არჩევანზე შეიძლება მოახდინოს აგრეთვე სათანადო პროგრამათა თქვენთვის ხელმისაწვდომობამ ან მიუწვდომლობამ.

მონაცემთა შერჩევა და მასწავლებელი ა(მო)ნაკრების ფორმირება.

იდეალურია მდგომარეობა, როცა შესაძლებელია რაგინდ ბევრი სხვადასხვა მონაცემის მიღება დასმული ამოცანისათვის. ასეთ შემთხვევაში მთავარი საზრუნავი ისაა, რომ მონაცემებში არ გაჩნდეს სისტემატური შეცდომები და გადახრები (თუ, რასაკვირველია, თავად ეს საკითხი არ წარმოადგენს გამოკვლევათა საგანს). მასწავლებელ ა(მო)ნაკრებში მიზანშეწონილია, უწინარეს ყოვლისა, იმ მონაცემთა შეტანა, რომლებიც ნეიროსისტემის შემდგომი გამოყენების პირობებთან მიახლოებულ ვითარებას აღწერს.

სახეთა გამოცნობის ზოგიერთი ამოცანის გადასაწყვეტად მონაცემთა წარმოდგენა საჭიროა ინვარიანტული ფორმით, თუ ეს შესაძლებელია, რა თქმა უნდა.

პრაქტიკული მიზნებისათვის მასწავლებელი ა(მო)ნაკრების გარკვეულ ნაწილს არ უნდა მიმართავდნენ სწავლებისას, რათა შემდგომ შესაძლებელი გახდეს მისი გამოყენება ნეიროქსელის ტესტირებისათვის. უნდა გვესმოდეს, რომ მასწავლებელ მონაცემთა ძალზე დიდი ა(მო)ნაკრები ერთობ შეანელებს სწავლების პროცესს და შედეგის არსებითი გაუმჯობესებაც არ მოხდება.

თუ თქვენს განკარგულებაში მონაცემთა ფრიად შეზღუდული მოცულობაა, მაშინ გასაანალიზებელი ხდება მისი საკმარისობა ამოცანის გადასაწყვეტად. ჩვეულებრივ, ეს ძალიან რთული საკითხია. ერთ-ერთ გზად ამოცანის თვისებათა (ნიშანთა) სივრცის განზომილების შემცირება შეიძლება აღმოჩნდეს. ნებისმიერ შემთხვევაში, მასწავლებელ მონაცემთა რაოდენობა ნეიროქსელის გასაწვრთნელ პარამეტრთა რიცხვს უნდა აღემატებოდეს.

საკუთარი პროგრამის შექმნა თუ არსებული ნეიროიმიტატორის გამოყენება?

ბაზარზე არსებული ნეიროიმიტატორები შექმნილია პროფესიონალების მიერ სპეციალურად თქვენი მოხერხებულობისათვის. პრაქტიკული მიზნებისათვის უმჯობესია მათი გამოყენება. ეს უზრუნველყოფს სტანდარტების შესრულებას და თქვენს მიერ მიღებული შედეგების დამაჯერებლობას.

გამონაკლისს შეადგენს არასტანდარტული ამოცანები და ნეიროქსელების სპეციალიზებული არქიტექტურები, ამ შემთხვევაში საჭიროა ახალი პროგრამის შექმნა. თქვენი პროექტისათვის ტექნიკური გარემოს არჩევისას სასარგებლოა ნეიროპროგრამის დასაწერად და მონაცემთა ბაზების დასამუშავებლად არსებული ინსტრუმენტული საშუალებების გათვალისწინება. დაპროგრამების ენად ყველაზე უფრო ხშირად C (ან C++) გამოიყენება. მცირე პროექტებისათვის პასკალის ან ბეისიკის არჩევაც შეიძლება.

და კიდევ : არ ხარჯოთ დრო კვადრატული ფეხვის გამოსაანგარიშებელი სტანდარტული ფუნქციის ხელახლა დაპროგრამებაზე, გეთაყვა !

შედეგების ანალიზი.

ეს ამოცანის ამოხსნის ერთ-ერთი ყველაზე მნიშვნელოვანი ფაზაა. ანალიზის სისრულისათვის საჭიროა შედეგების თვალსაჩინოებაზე, სიცხადეზე ზრუნვა, რისთვისაც მათი გრაფიკული სახით წარმოდგენა შეიძლება. თუ შედეგების გამოყენება კომპიუტერზე ჩატარებულ მომდევნო გამოთვლებში მოხდება, მაშინ მიზანშეწონილია ამ შედეგების იმთავითვე წარმოდგენა სხვა პროგრამებისათვის გასაგებ ფორმატში. პროგრამებს შორის მონაცემთა მცირე ცხრილების გაცვლის უზრუნველსაყოფად ტექსტურ წარმოდგენას შეიძლება მივმართოთ. დიდი მოცულობებისათვის უკეთესია სტანდარტული ფორმატების გამოყენება. მათ რიცხვს მიეკუთვნება, მაგალითად, Ashton-Tate ფირმის მიერ შექმნილი dBASE სისტემის dbf-ფაილების ფორმატი. მომხმარებელს ეს ავტომატურად დართავს ნებას გამოიყენოს ხსენებული (და მრავალი სხვა) სისტემის მონაცემთა დამუშავების (წარმოდგენის, შენახვისა და რელაქტირების) საშუალებები.

თუ მიღებული შედეგი არსებითად განსხვავდება მოსალოდნელისაგან, მაშინ, ალბათ, ამოცანის დასმას უნდა დავუბრუნდეთ.

თუმცადა შესაძლებელია, რომ თქვენ ახალი აღმოჩენის პირას ხართ...

PERC პროგრამის აღწერა.

ამ პუნქტში აღწერილი იქნება უმარტივესი PERC პროგრამა, რომელიც ერთფენიანი პერსპექტივის სწავლებას ახორციელებს. მაგალითის სახით არჩეულია შემდეგი ამოცანა. ნეირონულ ქსელს წარედგინება ვექტორი, რომელიც 10 ბინარული კომპონენტისაგან შედგება, სხვანაირად, ნებისმიერი მდგენელი მხოლოდ ნულს ან ერთს შეიძლება უდრიდეს. ქსელმა უნდა ისწავლოს განსაზღვრა იმისა, თუ რა უფრო მეტია ვექტორში – ნულის თუ ერთის ტოლი მდგენელი.

ასეთი ამოცანის გადასაწყვეტად აუცილებელია სულ ცოტა ერთი ნეირონი მაინც ათი შესასვლელით და ერთი გამოსასვლელით (თუმცა პროგრამა რამდენიმე ნეირონის გამოყენების საშუალებასაც იძლევა). განსახიზრციელებელი დამოკიდებულება წრფივად განცალკევებად ფუნქციათა კლასს მიეკუთვნება, ამიტომ ამონახსნის მისაღებად ერთი ნეირონიც საკმარისია.

მასწავლებელ ა(მო)ნაკრებად 200 ვექტორი გამოიყენება. მათი კომპონენტების გათამაშება პასკალის ფსევდოშემთხვევით რიცხვთა გენერატორის გამოყენებით ხდება. სწორი პასუხი ნულებისა და ერთიანების რიცხვის უშუალო შედარებით განისაზღვრება.

სწავლება მეოთხე ლექციაში დაწვრილებით განხილული ფ. როზენბლატის დელტა-წესით ხორციელდება. სწავლების დასრულებისას პროგრამა შესრულებულ იტერაციათა რიცხვსა და სწავლების მიღწეული შეცდომის მნიშვნელობას იძლევა. ამ პუნქტის დასკვნით ნაწილში მოთავსებულია PERC პროგრამის სრული ლოსტინგი და მისი მუშაობის შედეგები. საყურადღებოა, რომ გამოთვლების ჩატარებისას თქვენს კომპიუტერზე, მიღებული შედეგები შეიძლება ოდნავ განსხვავდებოდეს მოცემული მნიშვნელობებისაგან შემთხვევით სიდიდეთა სხვადასხვა მიმდევრობების გამო.

სწავლების ხარისხის ტესტირებისათვის შექმნილია ცალკე TEST პროგრამა (რომლის ტექსტი და მუშაობის შედეგები მოთავსებულია ამავე ლექციაში). გამოყენებულ მონაცემთა სტრუქტურები და პროგრამის მუშაობა PERC მოდულის მსგავსია. ტესტირებისათვის აგრეთვე შემთხვევითი ვექტორები გამოიყენება.

ტესტის შედეგები ერთობ დამაკმაყოფილებელია, ნეირონულმა ქსელმა წარმატებით დასძლია თავისი ამოცანა პასუხის მეორე-მესამე ნიშანში შეცდომამდე სიზუსტით. ამ შეცდომათა ინტერპრეტაცია სიძნელეს ან გაუგებრობას არ იწვევს.

PERC პროგრამის ტექსტი.

```
PROGRAM PERC ;
```

```
(* PERC - სასწავლო პროგრამა *)  
(* ერთფენიანი პერსეპტრონი *)  
(* თარიღი : 2007 წლის 3 თებერვალი *)  
(* ავტორები : არჩილ ფრანგიშვილი, ოლეგ ნამიჩიშვილი *)  
(* და არჩილ ელიზბარაშვილი *)
```

```
CONST
```

```
CMaxInp = 20 ;  
(* შესასვლელთა მაქსიმალური რიცხვი *)  
CMaxOut = 10 ;  
(* გამოსასვლელთა მაქსიმალური რიცხვი *)  
CMaxImages = 200 ;  
(* სახეთა მაქსიმალური რიცხვი *)  
CEta = 0.75 ;  
(* სწავლების ტემპი *)  
CError = 5.0e-3 ;  
(* მოთხოვნილი შეცდომის საზღვარი *)  
CCounter = 1000 ;  
(* იტერაციათა მაქსიმალური რიცხვი *)  
CInitWeight = 5.0 ;  
(* შემთხვევითი სინაფსური წონების *)  
(* მაქსიმალური საწყისი მნიშვნელობა *)  
CBiasNeuron = 1.0 ;  
(* ნეირონ-ზღურბლის აქტივობა *)
```

```
TYPE
```

```
TMatrix = ARRAY[0..CMaxInp,1..CMaxOut] OF REAL ;  
(* ნულოვანი სვეტი შეიცავს ზღურბლების მნიშვნელობებს *)  
TInpVector = ARRAY[1..CMaxInp] OF REAL ;
```

```

TOutVector = ARRAY[1..CMaxOut] OF REAL;

(* ქსელის სტრუქტურა *)
TPerceptron = RECORD
    NInp : INTEGER;
    (* შესასვლელთა რიცხვი *)
    NOut : INTEGER;
    (* გამოსასვლელთა რიცხვი *)
    Inp : TInpVector;
    (* შესასვლელთა მიმდინარე ვექტორი *)
    Out : TOutVector;
    (* გამოსასვლელთა მიმდინარე ვექტორი *)
    W : Tmatrix;
    (* კავშირების, ანუ ბმების მატრიცა *)
END;

(* ჩანაწერი მონაცმთა ბაზაში - მასწავლებელ ანაკრებში *)
TBaseRecord = RECORD
    X : TInpVector;
    Y : TOutVector;
END;

(* მონაცემთა ბაზის სტრუქტურა *)
TBase = RECORD
    NImages : INTEGER;
    (* მასწავლებელ სახეთა რიცხვი *)
    Images: ARRAY[1..CMaxImages] OF TBaseRecord;
END;

VAR
    VNet : TPerceptron;
    VBase : TBase;
    VOK : BOOLEAN;
    VError, VTemp, VDelta : REAL;
    VCounter, Vi, Vj, Vk : INTEGER;
    VFile : FILE OF TPerceptron;

PROCEDURE InitAll;

(* 10/1 ტიპის ნეირონული ქსელის ინიციალიზაცია *)

```

```

(* კავშირთა მატრიცის საწყისი შემთხვევითი მნიშვნელობების შეტანა *)
VAR
  Li, Lj, Lk : INTEGER;
BEGIN
  WITH VNet, VBase DO
  BEGIN
    NInp := 10;
    NOut := 1;
    FOR Li := 0 TO NInp DO
      FOR Lj := 1 TO NOut DO
        W[Li,Lj] := CInitWeight*(RANDOM-0.5);
      END;
    VOK := TRUE;
  END;
END;

PROCEDURE GetDataBase;

(* 200 შემთხვევითი სახის შემცველი მასწავლებელი ანაკრების გენერაცია *)
(* ერთიანების დათვლა უშუალოდ ხდება *)

VAR
  Li, Lj, Lk : INTEGER;
BEGIN
  VOK := TRUE;
  WITH VBase, VNet DO
  BEGIN
    NImages := 200;
    FOR Li:= 1 TO NImages DO
      BEGIN
        Lk := 0;
        FOR Lj:=1 TO NInp DO
          BEGIN
            (* შემთხვევით 0 ან 1 *)
            Images[Li].X[Lj] := RANDOM( 2 );
            (* ერთიანების გამოანგარიშება *)
            IF ( Images[Li].X[Lj] > 0 )
              THEN Lk := Lk + 1;
          END;
        END;
      END;
    END;
  END;
END;

```

```

(* გამოსასვლელზე ერთიანია, თუ მოცემულ უმაკრალ ვექტორში *)
(* ერთიანების რიცხვი ნულების რაოდენობას აღემატება *)
      IF ( Lk > (NInp-Lk) )
          THEN Images[Li].Y[1] := 1
          ELSE Images[Li].Y[1] := 0
      END;
  END;
END;

PROCEDURE SaveNet;

(* ნეირონული ქსელის პარამეტრების ჩაწერა SAMPLE.DAT ფაილში *)
(* მოწმდება გამოტანის ოპერაციები *)
(* ტურბო პასკალის კომპილატორის +1 და -1 გასალებებით *)

BEGIN
  ASSIGN( VFile, 'SAMPLE.DAT' );
  {$I-}
  REWRITE( VFile );
  {$I+}
  VOK := (IOResult = 0);

  IF VOK THEN
    BEGIN
      {$I-}
      WRITE( VFile, VNet );
      CLOSE ( VFile );
      {$I+}
      VOK := (IOResult = 0);
    END;
  END;
END;

FUNCTION Sigmoid( Z: REAL ): REAL;

(* ნეირონის სიგმოიდური გარდამავალი ფუნქცია *)

BEGIN
  Sigmoid := 1.0/(1.0+EXP(-Z));

```

```

END;

(* ძირითადი პროგრამა *)
BEGIN
  WRITELN(' << PERCEPTRON >> (ნეირომიტატორი) ');
  WRITELN('----- ');
  VOK := TRUE;

  (* ინიციალიზაცია შეცდომის კონტროლით *)
  RANDOMIZE;
  InitAll;
  IF (NOT VOK) THEN
  BEGIN
    WRITELN('ინიციალიზაციის შეცდომა');
    HALT;
  END;

  (* მონაცემთა ბაზის გენერაცია *)
  VOK := TRUE;
  GetDataBase;
  IF (NOT VOK) THEN
  BEGIN
    WRITELN('შეცდომა მონაცემთა ბაზის გენერაციისას');
    HALT;
  END;

  (* სწავლების ციკლი *)
  VOK := TRUE;
  VCounter := 0;
  WITH VNet, VBase DO
  REPEAT
    VError := 0.0;
    (* ციკლი მასწავლებელი ანაკრების მიხედვით *)
    FOR Vi := 1 TO NImages DO
    BEGIN
      (* მორიგი სახის მიწოდება ქსელის შესასვლელებზე *)
      FOR Vj := 1 TO NInp DO
      BEGIN
        Inp[Vj] := Images[Vi].X[Vj];
      END;
    END;
  END;

```

```

(* ციკლი ნეირონების მიხედვით *)
(* აპარატული რეალიზაციის დროს პარალელურად შესრულება! *)
FOR Vk := 1 TO NOut DO
  BEGIN
    (* მორიგი ნეირონის მდგომარეობა *)
    VTemp := CBiasNeuron*W[0,Vk];
    FOR Vj := 1 TO NInp DO
      BEGIN
        VTemp := VTemp +
          Inp[Vj]*W[Vj,Vk];
      END;
    Out[Vk] := Sigmoid( VTemp );

    (* შეცდომის დაგროვება *)
    VDelta:=Images[Vi].Y[Vk]-Out[Vk];
    VError:=VError+0.5*SQR(VDelta);

    (* სწავლება როზენბლატის დელტა-წესით *)
    W[0,Vk] := W[0,Vk] +
      CEta*CBiasNeuron*VDelta;
    FOR Vj := 1 TO NInp DO
      BEGIN
        W[Vj,Vk] := W[Vj,Vk] +
          CEta*Inp[Vj]*VDelta;
      END;
    END;
  END;
  VCounter := VCounter + 1;
  UNTIL ( (VCounter >= CCounter) OR
    (VError <= CError) );
  (* ციკლი დამთავრდა იტერაციათა მაქსიმალური რიცხვის *)
  (* ან მინიმალურად საკმარისი შეცდომის მიღწევისას *)

  WRITELN( 'შესრულდა ', VCounter, ' იტერაცია');
  WRITELN( 'სწავლების შეცდომამ შეადგინა ', VError );

  (* სწავლების შედეგების შენახვა დისკოზე *)
  SaveNet;
  IF (NOT VOK) THEN

```

```

BEGIN
    WRITELN( 'შეცდომა დისკოზე ჩაწერისას' );
    HALT;
END;

WRITE( 'ნეირონული ქსელი ნასწავლია და მისი პარამეტრები' );
WRITELN( 'ჩაწერილია SAMPLE.DAT ფაილში' );
END.

```

PERC პროგრამის მუშაობის შედეგი

<< P E R C E P T R O N >> (ნეირომიტატორი)

შესრულდა 243 იტერაცია
სწავლების შეცდომამ შეადგინა 4.9997994218E-03
ნეირონული ქსელი ნასწავლია და მისი პარამეტრები
ჩაწერილია SAMPLE.DAT ფაილში

TEST პროგრამის ტექსტი

```
PROGRAM TEST;
```

(* TEST - პროგრამა PERC ნეირომიტატორის ტესტირებისათვის *)

```
CONST
```

```

CMaxInp      = 20;
CMaxOut      = 10;
CMaxImages   = 15;
CBiasNeuron  = 1.0;

```

```
TYPE
```

```

TMatrix      = ARRAY[0..CMaxInp,1..CMaxOut] OF REAL;
TInpVector   = ARRAY[1..CMaxInp] OF REAL;
TOutVector   = ARRAY[1..CMaxOut] OF REAL;
TPerceptron = RECORD
    NInp      : INTEGER;
    NOut      : INTEGER;
    Inp       : TInpVector;
    Out       : TOutVector;
    W         : TMatrix;

```

```

END;

VAR
    VNet          : TPerceptron;
    VTemp         : REAL;
    VCorrect      : REAL;
    Vi, Vj, Vk    : INTEGER;
    VOK           : BOOLEAN;
    VFile         : FILE OF TPerceptron;

PROCEDURE LoadNet;

(* ნეირონული ქსელის პარამეტრთა წაკითხვა SAMPLE.DAT ფაილიდან *)
(* მოწმდება შეტანის ოპერაციები *)
(* ტურბო პასკალის კომპილატორის +1 და -1 გასაღებებით *)

BEGIN
    ASSIGN( VFile, 'SAMPLE.DAT' );
    {$I-}
    RESET( VFile );
    {$I+}
    VOK := (IOResult = 0);

    IF VOK THEN
        BEGIN
            {$I-}
            READ( VFile, VNet );
            CLOSE ( VFile );
            {$I+}
            VOK := (IOResult = 0);
        END;
    END;

FUNCTION Sigmoid( Z: REAL ): REAL;
BEGIN
    Sigmoid := 1.0/(1.0+EXP(-Z));
END;

BEGIN
    VOK := TRUE;
    RANDOMIZE;

```



```

( * ნასწავლი ნეიროქსელის პარამეტრთა წაკითხვა * )
LoadNet;
IF (NOT VOK) THEN
BEGIN
    WRITELN(' შეცდომა ფაილის წაკითხვისას ');
    HALT;
END;
VOK := TRUE;
WITH VNet DO
BEGIN
    WRITELN('<<PERCEPTRON>> (ტესტური პროგრამა) ');
    WRITELN('-----');
    WRITELN(' შეკითხვა      პასუხი      სწორი პასუხი ');
    WRITELN('-----');
    FOR Vi := 1 TO CMaxImages DO
    BEGIN
        ( * შემთხვევითი სახის მიწოდება შესასვლელზე * )
        Vk := 0;
        FOR Vj:=1 TO NInp DO
        BEGIN
            ( * შემთხვევით 0 ან 1 * )
            Inp[Vj] := RANDOM( 2 );
            ( * ერთიანების გამონაგარიშება * )
            IF ( Inp[Vj] > 0 )
            THEN Vk := Vk + 1;
        END;
        ( * სწორი პასუხი ცნობილია ! * )
        IF ( Vk > (NInp-Vk) )
        THEN VCorrect := 1.0
        ELSE VCorrect := 0.0;
        ( * პასუხს ნეიროქსელი იძლევა * )
        FOR Vk := 1 TO NOut DO
        BEGIN
            VTemp := CBiasNeuron*W[0,Vk];
            FOR Vj := 1 TO NInp DO
            BEGIN
                VTemp := VTemp +
                    Inp[Vj]*W[Vj,Vk];
            END;
            Out[Vk] := Sigmoid( VTemp );
        END;
    END;
END;

```

```

        END;
        (* შედეგების გამოტანა *)
        FOR Vj := 1 TO NInp DO
            WRITE( Inp[Vj]:2:0 );
            WRITELN(' ,Out[1]:4:2, ', VCorrect:2:0);
        END;
    END;
    END;
    WRITELN('-----');
END.

```

TEST პროგრამის მუშაობის შედეგი

<<PERCEPTRON>> (ტესტური პროგრამა)

| შეკითხვა | პასუხი | სწორი პასუხი |
|---------------------|--------|--------------|
| 0 0 0 0 1 1 1 1 0 0 | 0.00 | 0 |
| 0 0 1 0 0 0 0 1 0 1 | 0.00 | 0 |
| 1 1 0 0 0 0 0 1 0 0 | 0.00 | 0 |
| 1 1 1 1 0 1 0 1 1 1 | 1.00 | 1 |
| 0 1 1 1 0 1 1 0 0 0 | 0.01 | 0 |
| 1 0 1 0 1 0 1 1 1 0 | 0.99 | 1 |
| 1 0 1 1 1 0 0 1 1 0 | 0.98 | 1 |
| 1 0 1 1 1 1 0 0 1 1 | 1.00 | 1 |
| 1 1 0 1 1 1 1 0 1 0 | 1.00 | 1 |
| 1 1 0 1 1 1 0 0 0 1 | 1.00 | 1 |
| 0 0 0 0 1 1 0 1 0 1 | 0.00 | 0 |
| 1 0 0 1 0 0 0 0 0 1 | 0.00 | 0 |
| 1 0 0 1 0 0 0 1 1 0 | 0.00 | 0 |
| 0 1 0 1 1 1 0 1 0 0 | 0.02 | 0 |
| 1 1 1 1 1 1 0 1 1 0 | 1.00 | 1 |

ამოცანები.

1. PERC პროგრამის საშუალებით შეიძლება შევისწავლოთ ამონახსნის დამოკიდებულება მასწავლებელი ა(მო)ნაკრების მონაცემთა მოცულობაზე. ამის მიღწევა Nimages ცვლადის მნიშვნელობის შეცვლით ხდება GetDataBase ქვეპროგრამაში. შეეცადეთ ახსნათ ტესტის შედეგების გაურესება, როცა სწავლებისას სახეთა რაოდენობა თანდათანობით მცირდება.
2. მოახდინეთ PERC და TEST პროგრამათა მოდიფიკაცია ნეირონის გარდამავალი ფუნქციის ტიპის შეცვლით. შედეგები შეადარეთ.
3. ჩაატარეთ სწავლების სიჩქარის დამოკიდებულების გამოკვლევა ტემპზე (CEta) და წონათა საწყის მნიშვნელობებზე (CinitWeight). ახსენით თქვენს მიერ მიღებული შედეგები.

ლექცია 15. დამატებითი ცნობები.

წარმოდგენა ევოლუციური ალგორითმების შესახებ. კომბინატორული ოპტიმიზაცია გენეტიკური ძებნის მეთოდით. ნეირონული ქსელები არამკაფიო ლოგიკით. სასრული ავტომატები და ნეირონული ქსელები.

ინფორმაციის ანალიზის კომპიუტერული მეთოდები გამუდმებით განიცდის სრულყოფას. ამასთან, მათემატიკური მოდელირების ფართოდ გავრცელებულ და მტკიცედ დამკვიდრებულ მეთოდებთან ერთად, სულ უფრო ვითარდება და გამოიყენება სხვა, არატრადიციული მიდგომები. ხელოვნურ ნეირონულ ქსელებთან დაკავშირებული ერთ-ერთი მათგანი, ლექციათა ამ კურსის ძირითად საგანს წარმოადგენს.

სურათის სისრულისათვის ავტორებს საჭიროდ მიიჩნიათ სხვა მეთოდების მოკლე მიმოხილვაც. უპირველეს ყოვლისა, ყურადღების ცენტრშია მოხვედრილი გენეტიკური ალგორითმები, სისტემები არამკაფიო ლოგიკით და უჯრედული ავტომატები. იმისათვის რომ არ დაირღვეს მასალის გადმოცემის მთლიანობა, ამ მეთოდების განხილვა ნეიროქსელურ ალგორითმებთან შეფარდებაში ხდება.

გენეტიკური ძებნა.

წარმატება ნეირონული ქსელების განვითარებაში, უწინარეს ყოვლისა, დაკავშირებულია მრავალ არქიტექტურაში ჩადებულ ღრმა ბიოლოგიურ საფუძვლებთან. ბიოლოგიური ევოლუციის ზოგიერთი თავისებურება, კოდირებისა და მემკვიდრეობითობის მექანიზმის დონეზე დნმ-ში, საფუძვლად დაედო სამოცდაათიანი წლების დასაწყისში წამოყენებულ (J.H. Holland, 1975) ე.წ. *გენეტიკურ ალგორითმებს*, რომლებიც განსაკუთრებით ინტენსიურად ვითარდება უკანასკნელ წლებში.

ნებისმიერი *ობიექტი* ანუ სისტემა (ბიოლოგიაში - ორგანიზმი) შეიძლება აღიწეროს ნიშნების ანუ თვისებების ერთობლიობით, რომლებიც კოდირებულია სიმბოლოების ანუ ბიტების ჯაჭვით (მიმდევრობით) და *ობიექტის გენოტიპს* შეადგენს. რამდენიმე *ობიექტი* პოპულაციას ქმნის, რომელიც ხასიათდება თითოეული *ობიექტის* ჯაჭვთა ნაკრებით. ამ *ობიექტთა* სიმრავლე პოპულაციის *გენოფონდს* განსაზღვრავს.

სხვადასხვა *ობიექტს*, საერთოდ რომ ვთქვათ, ნიშნების სხვადასხვა ნაკრები შეიძლება გააჩნდეს. პოპულაციაში ნიშნების დიდ მრავალფეროვნებაზე, ნაირნაირობაზე საუბრობენ როგორც მდიდარ გენოფონდზე. პოპულაციის ევოლუციისას მასში ახალი *ობიექტები* ჩნდება, რომლებიც მემკვიდრეობით იძენს ამა თუ იმ ნიშანს თავისი წინაპრებისაგან. ამ დროს პოპულაციის ზომა ნაკლებად იცვლება, რაც უზრუნველყოფილია *ობიექტების* კონკურენტული *შერჩევით*. შერჩევის პროცესში ისეთი ნიშნების ან მათი ერთობლიობების (კოდონებისა³ და გენების) მიმართული ძეგნა ხორციელდება, რომლებიც მნიშვნელოვანია გარკვეული მოცემული *მიზნობრივი ფუნქციის* – მაგალითად, არსებობის პირობების მიმართ *ობიექტის* ადაპტაციის დონის – მხრივ. ამიტომ ევოლუციური ალგორითმები აგრეთვე *გენეტიკური ძებნის* მეთოდებადაც მოიხსენიება ლიტერატურაში.

ინფორმაციის დამუშავება გენეტიკური ალგორითმით სასარგებლო ნიშანთა შერჩევის ორ ძირითად მექანიზმს იყენებს, რომლებიც გადმოღებულია თანამედროვე წარმოდგენებიდან ბუნებრივი შერჩევის შესახებ: *მუტაციებს* ცალკეულ ჯაჭვში და *შეჯვარდინებას* (ინგლ. *crossingover* – კროსინგოვერი) ორ ჯაჭვს შორის. განვიხილოთ ეს მექანიზმები უფრო დავწერილებით.

| | |
|----------------------------------------------------------------------------------|--------------------------------------|
| <p>001110101100001001</p> <p><i>000110100001101001</i></p> | <p>ა) საწყისი გენეტიკური ჯაჭვები</p> |
|----------------------------------------------------------------------------------|--------------------------------------|

³ კოდონი (მაკოდირებელი ტრინუკლეოტიდი) – გენეტიკური კოდის ერთეული, ნუკლეოტიდურ ნარჩენთა სამეული (ტრიბლეტი) დნმ-ში ან რნმ-ში.

| | |
|---------------------------------------------------------------------------------------------|-----------------------------------------------------------------|
| <p>0011101</p> <p>.....01100001001</p> <p>.....00001101001</p> <p>0001101</p> | <p>ბ) უბნის შემთხვევითი გაჩენა შემდგომი შეჯვარედინებისათვის</p> |
| <p>0011101</p> <p>.....00001101001</p> <p>.....01100001001</p> <p>0001101</p> | <p>გ) კოდის ფრაგმენტების გაცვლა</p> |
| <p>001110100001101001</p> <p>000110101100001001</p> | <p>დ) ჯაჭვები შეჯვარედინების შემდეგ</p> |

ნახ. 15.1. ორი გენეტიკური ჯაჭვის შეჯვარედინების პროცესი.

ნახ. 15.1-ზე წარმოდგენილია ორი ჯაჭვის შეჯვარედინებისას ინფორმაციის გაცვლის თანამიმდევრული ეტაპები. მიღებული ახალი ჯაჭვები (ან მათგან ერთ-ერთი) შემდგომ პერიოდში შეიძლება შევიდეს პოპულაციაში, თუ მათ მიერ მოცემული ნიშნების ნაკრები მიზნობრივი ფუნქციის უკეთეს მნიშვნელობას უზრუნველყოფს. წინააღმდეგ შემთხვევაში ამ ნიშანთა განთესვა მოხდება და პოპულაციაში მათი წინაპრები დარჩება. მუტაცია გენეტიკურ ჯაჭვში წერტილოვან ხასიათს ატარებს : ჯაჭვის რომელიღაც შემთხვევით წერტილზე ერთ-ერთი კოდი შეიცვლება მეორეთი (ნოლი – ერთით, ხოლო ერთი – ნოლით).

ინფორმაციის დამუშავების ხელოვნურ სისტემათა თვალთახედვით გენეტიკური ძებნა ოპტიმიზაციის ამოცანის ამონახსნის პოვნის სპეციფიკურ მეთოდს წარმოადგენს. ამასთან ასეთი იტერაციული ძებნა ადაპტირებადია

მიზნობრივი ფუნქციის თავისებურებების მიმართ : შეჯვარდინების პროცესში დაბადებული ჯაჭვები ნიშანთა სივრცის სულ უფრო ფართო არეთა ტესტირებას აწარმოებს და უპირატესად ოპტიმუმის უბანში თავსდება. შედარებით იშვიათი მუტაციები ხელს უშლის გენოფონდის გადაგვარებას, რაც ოპტიმუმის იშვიათი, მაგრამ უწყვეტი ძეგლის ტოლფასია ნიშანთა სივრცის ყველა დანარჩენ არეში.

გენეტიკური ალგორითმი შეიძლება გამოვიყენოთ ნეირონული ქსელის სწავლებისათვის. ამ დროს ჯაჭვის მიერ ქსელის მდგომარეობის – ყველა წონითი კოეფიციენტის ერთობლიობის – კოდირება ხდება. კოდი შემდეგნაირად შეიძლება იყოს მოწყობილი. ჯაჭვის პირველი რვა ელემენტი წონათა მატრიცის პირველი ელემენტის რვაბიტიან წარმოდგენას შეესაბამება, შემდეგი რვა – მეორეს, და ასე შემდეგ. მიზნობრივ ფუნქციად სწავლების სრული შეცდომა გვევლინება. ნეირონული ქსელების პოპულაცია ნასწავლ მდგომარეობისაკენ ევოლუციონირებს, ამასთან შერჩევის პროცესში სიკვდილს გადარჩება მცირე შეცდომების მაკოდირებელი ნეირონულ ქსელთა ჯაჭვები.

გენეტიკური ალგორითმი წარმოადგენს ისეთი ამოცანის მაგალითს, რომლისთვისაც შესაძლებელია პარალელურობის მაღალი ხარისხის მიღწევა თანამედროვე ვექტორულ კომპიუტერებზე მოდელირებისას. შესასრულებელ ამოცანათა სიმარტივის გამო საუცხოო პერსპექტივა გადაიშალა აგრეთვე სპეციალიზებული გენეტიკური პროცესორების შესაქმნელად.

არამკაფიო ლოგიკის სისტემები.

არამკაფიო ლოგიკა (Fuzzy Logic) ჩვეულებრივი ბულის ლოგიკის განზოგადებას წარმოადგენს, რომელშიც ორობით რიცხვებს ხმარობენ. ეს რიცხვები შეესაბამება ლოგიკურ ცნებებს «*ჭეშმარიტი*» და «*მცდარი*». არამკაფიო ლოგიკაში ამ ცნებათა განზოგადება ხდება ყველა შუალედურ მდგომარეობაზე «*ჭეშმარიტსა*» და «*მცდარს*» შორის. ამის შესაბამისად, არამკაფიო ლოგიკა იყენებს რიცხვებს $[0, 1]$ ინტერვალიდან, რომლებიც გამონათქვამის ჭეშმარიტობის ხარისხს ასახავს. პირველად არამკაფიო სიმრავლეთა თეორია ჩამოაყალიბა კალიფორნიის უნივერსიტეტის პროფესორმა ზადემ.

არამკაფიო ლოგიკა ნაწილობრივ სარწმუნო და წინააღმდეგობრივ ინფორმაციასთან ურთიერთობაში მყოფ გამოყენებით მეცნიერებათა მრავალ პრაქტიკულ მოთხოვნილებას ეყრდნობა. ასეთ მეცნიერებათა რიცხვს მიეკუთვნება მაკროეკონომიკა, არასრული ინფორმაციის საფუძველზე მართვისა და გადაწყვეტილებათა მიღების თეორია, სისტემური ეკოლოგია, რომელიც დაკავებულია სამრეწველო წარმოებათა ტექნოგენური ზემოქმედებით გამოწვეული რისკის შეფასებით, აგრეთვე ავარიათა შედეგების ანალიზით და სხვა.

რიცხვთა ორობითი წარმოდგენიდან ინტერვალურზე გადასვლა მოითხოვს ლოგიკური ოპერაციების განზოგადებას შესაბამის ოპერაციებზე არამკაფიო რიცხვების სიმრავლისათვის. ამასთან, განზოგადებული ოპერაციები უნდა გადადიოდეს კლასიკურში, თუ ოპერანდებს 0 და 1 მნიშვნელობები მიენიჭება.

განვიხილოთ ასეთი განზოგადების მაგალითი. დავუშვათ, რომ მოცემულია ორი, a და b , არამკაფიო რიცხვი. ორი არამკაფიო რიცხვის ჯამი ეწოდება არამკაფიო რიცხვს, რომელიც მაქსიმალურ ოპერანდს ემთხვევა: $c = a + b = \max(a, b)$. ორი არამკაფიო რიცხვის ნამრავლი ეწოდება არამკაფიო რიცხვს, რომელიც მინიმალურ ოპერანდს უდრის: $c = a * b = \min(a, b)$. შემოტანილი განმარტებების შესაბამისად, არამკაფიო რიცხვთა სიმრავლე ჩაკეტილია მოცემული ოპერაციების მიმართ.

არამკაფიო ლოგიკის ერთ-ერთ მნიშვნელოვან გამოყენებათა რიცხვს არამკაფიო საექსპერტო სისტემები წარმოადგენს, რომლებშიც დასკვნის ლოგიკური წესები არამკაფიო ოპერაციებს იყენებს. არამკაფიო საექსპერტო სისტემებთან და არამკაფიო ლოგიკის სხვა გამოყენებებთან გასაცნობად იაპონელ ავტორთა – ტ. ტერანოს, კ. ასაის და მ. სუგენოს – წიგნს შეიძლება გაეწიოს რეკომენდაცია.

კურსის ამ ლექციაში ჩვენ განვიხილავთ ნეიროქსელური მოდელების ფორმულირებას არამკაფიო ლოგიკის ენაზე. ჰობფილდის მოდელში (იხ. ლექცია 8) ქსელის სწავლებისას ჰების წესით ყველა გამოთვლა დაფუძნებულია შეკრებისა და გამრავლების ოპერაციებზე. თუ ნეირონთა წონებისა და აქტივობის მნიშვნელობების აღწერას არამკაფიო რიცხვებით განვახორციელებთ, მაშინ ჰების წესი შეიძლება ჩამოყალიბდეს არამკაფიო ოპერაციების

ენაზე. კავშირების (ბმების) მატრიცაში $\xi^{(k)}$ სახის წვლილი შემდეგნაირად ჩაიწერება :

$$W_{ij}^{(k)} = \min(\xi_i^{(k)}, \xi_j^{(k)}) .$$

კავშირების (ბმების) სრული მატრიცა ცალკეულ წვლილთა არამკაფიო შეკრებით მიიღება :

$$W_{ij} = \max_k (W_{ij}^{(k)}) = \max_k \left(\min(\xi_i^{(k)}, \xi_j^{(k)}) \right) .$$

ნეირონთა აქტივობის გამოთვლა სკალარული ნამრავლის გამოყენებით ხორციელდება :

$$S_i(t+1) = \max_j \left(\min(S_j(t), W_{ij}) \right) .$$

არამკაფიო არითმეტიკაში წარმოდგენილი ჰოპფილდის ნეირონული ქსელი ძალზე მოხერხებელია მოდელირებისათვის ჩვეულებრივი ჩრდილიანი ოპტიკის გამოყენებით. ოპერანდების წარმოდგენა შესაძლებელია რიცხვთა სიდიდების პროპორციული ფართობების მქონე მართკუთხა ხვრელებით.

რიცხვთა გასამრავლებლად ხვრელების ერთმანეთზე ზედდება უნდა მოხდეს, ამ დროს სინათლის გატარება შეზღუდული აღმოჩნდება *მინიმალური* ხვრელით, რომელიც საჭირო ნამრავლს იძლევა. შეკრებისას ერთ სიბრტყეზე სინათლის ორი პარალელური სხივის ფოკუსირება უნდა განხორციელდეს. ყოველ მათგანს დამოუკიდებლად ატარებენ ერთ-ერთ ხვრელში. მიღებული სინათლის ლაქა *მაქსიმალური* ხვრელის შესაბამისი აღმოჩნდება. ჰოპფილდის ქსელის შესაბამისი ოპტიკური სქემა Optics Letters ჟურნალში იყო თავის დროზე წამოყენებული და გამოქვეყნებული.

საჭიროა აღინიშნოს, რომ ჰოპფილდის ნეირონული ქსელის ოპტიკური რეალიზაცია ჰების არამკაფიო წესით ბუნებრივად გამოირჩევა გამოთვლათა დიდი სიჩქარით და პარალელიზმის მაღალი დონით.

უჯრედული ავტომატები და ნეირონული ქსელები.

უჯრედული ავტომატი ეწოდება ქსელს, რომლის ყოველი ელემენტი იცვლის თავის მდგომარეობას დროის დისკრეტულ მომენტებში თავად ელემენტისა და მისი უახლოესი მეზობლების მდგომარეობის მიხედვით დროის წინა მომენტში.

სხვადასხვა უჯრედულ ავტომატს შეუძლია ერთობ სხვადასხვაგვარი ქცევის ჩვენება. ინფორმაციის დასამუშავებლად ამ ქცევის ადაპტირება შეიძლება ორად ორი ფაქტორის არჩევით, სახელდობრ : ა) ელემენტის მდგომარეობის ცვლილების კანონის და ბ) «უახლოესი მეზობლის» ცნების კონკრეტული განმარტების. დაკვირვებული მკითხველი ადვილად შეამჩნევს, რომ სავესებით შესაძლებელია, მაგალითად, ჰოპფილდის ნეირონული ქსელის განხილვა უჯრედულ ავტომატად, რომლის ელემენტები ფორმალურ ნეირონებს წარმოადგენს. ნეირო-ავტომატის მდგომარეობის ცვლილების კანონად ნეირონთა შესასვლელების აწონილი ჯამის ზღურბლური გარდასახვა გამოიყენება, ხოლო თითოეული ელემენტის უახლოეს მეზობლებად ავტომატის ყველა დანარჩენი ელემენტი განიხილება.

უჯრედულ ავტომატთა სამყაროში არსებობს კლასიფიკაცია (S. Wolfram, 1983), რომლის თანახმად ყველა ავტომატი ოთხ კლასად იყოფა ცვალებად მდგომარეობათა დინამიკის მიხედვით. *პირველი კლასის* ავტომატები სასრული დროის გასვლის შემდეგ ერთგვაროვან მდგომარეობას აღწევს, რომელშიც ყველა ელემენტის მნიშვნელობა ერთნაირია და დროშიც უცვლელი რჩება. ავტომატთა *მეორე კლასის* მიეკუთვნება სისტემები, რომლებსაც ელემენტების მდგომარეობათა სტაციონარულ ან დროში პერიოდულ ლოკალიზებულ სტრუქტურებამდე მივყავართ. მესამე კლასს «მოხეტიალე» ავტომატები შეადგენს, რომლებიც დროის განმავლობაში ნებისმიერი (არაპერიოდული) წესით ახერხებს ელემენტთა ყველა შესაძლო მდგომარეობის ნახვას და არც ერთ მათგანში არ ყოვნდება. დაბოლოს, მეოთხე კლასს შეადგენს «უცნაური» ავტომატები. მათი დინამიკის ხასიათი დამოკიდებულია ელემენტების საწყისი მდგომარეობის თავისებურებებზე. ზოგიერთ საწყის მდგომარეობას ავტომატის ერთგვაროვან გადაგვარებამდე მივყავართ, სხვებს — მდგომარეობათა ციკლური თანამიმდევრობის გაჩენამდე, მესამეს — ელემენტთა აქტივობის უწყვეტად ცვლად სურათებამდე, როცა ამ ცვლილებაში შეინიშნება სისტემატურობა, ან იგი ხილულად არ ვლინდება.

მეოთხე ტიპის ავტომატებს ჯ. კონვეის სახელგანთქმული თამაში «სიცოცხლე» მიეკუთვნება. «სიცოცხლის» კოლონიის ყოველი ელემენტი (ორგანიზმი) შეიძლება ომყოფობოდეს სიმშვიდის ან აქტივობის მდგომარეობაში. უახლოეს ელემენტებად მოცემულის მიმართ ოთხი მისი მეზობელი ცხადდება კვადრატულ მესერზე. მშვიდ ელემენტში შეიძლება აღორძინდეს აქტივობა, თუ მის გვერდით ზუსტად სამი აქტიური მეზობელი იმყოფება. აქტიური ელემენტი ინარჩუნებს «სიცოცხლისუნარიანობას» ორი აქტიური მეზობლის შემთხვევაში. თუ მეზობლების რიცხვი ორს აღემატება, ელემენტი იღუპება სივიწროვის გამო, ხოლო, თუ მათი რიცხვი ორზე ნაკლებია, მას მოწყენილობა, დარდი კლავს. თუმცაღა «სიცოცხლის» საწყისი მდგომარეობის რთული ევოლუციის დაკვირვებამ გონების კვლევითი მოქმედებისათვის გარკვეული საკვების მიცემა შეუძლია, საერთო ჯამში ეს ავტომატი მათემატიკურ გასართობად რჩება

მაგრამ არსებობს უჯრედული ავტომატების გაცილებით უფრო სერიოზული გამოყენებები. მათ შორის, უპირველეს ყოვლისა, უნდა გამოვყოთ ავტომატები, რომლებიც დისკრეტულ სხვაობით სქემებს ახორციელებს მათემატიკური ფიზიკის ნაირ-ნაირი ამოცანისათვის. ამ მიზნებისათვის მეორე გვარის ავტომატები გამოიყენება.

ავტომატის ელემენტთა პოპულაციის აქტივობა შეიძლება აღწერდეს აგრეთვე ისეთ რთულ მოვლენებს, როგორცაა კრისტალების ზრდა ჩანასახის მდგომარეობიდან, დიფუზია და მიგრაცია სითხის არაერთგვაროვან სფერებებიან (ფორებიან, ფოროვან) გარემოში, ტურბულენტობის გაჩენისა და განვითარების თავისებურებანი სითხეებისა და აირების ნაკადებში, იმპულსის გავრცელება ნერვულ სისტემაში, სიმსივნის ზრდა ბიოლოგიურ ქსოვილში, ხანძრების გავრცელება ტყეში და მრავალი სხვა. უჯრედული ავტომატების მრავალფეროვან გამოყენებათა აღწერა დაძაბულ ცალკე ყურადღებას იმსახურებს

მაგრამ ეს უკვე ლექციათა სხვა კურსის საგანია.

პროგრამა «სიცოცხლე»

ახლა ჯ. კონვეის ცნობილი თამაშის - «სიცოცხლე» - დაპროგრამებაზე შევჩერდეთ დაწვრილებით. კაცმა რომ თქვას, ეს თამაში კი არა, არამედ, როგორც ვთქვით, ვირტუალურ ორგანიზმთა გაერთიანების ევოლუციის

უბრალო მოდელია. ამ თამაშის თაობათა მრავალი რიცხვის ერთობლიობაზე დაკვირვებამ რაღაც საიმოვნებაც კი შეიძლება მიანიჭოს ადამიანს (საკუთარი მნიშვნელოვნობის გარკვეული შეგრძნების გაჩენით, რადგან ვირტუალური საზოგადოების ბედი მის ხელშია!).

სათამაშო მოედანი, ესე იგი ამ თამაშის სასიცოცხლო სივრცე, ორგანზომილებიან ზედაპირს წარმოადგენს (ჩვენთან ეს ტორის ზედაპირია, რომელსაც საზღვრები არ გააჩნია: საზღვრების არსებობა ყოველთვის დაკავშირებულია პრობლემებთან), რომელიც კვადრატულ უჯრედებადაა დაყოფილი. ყოველ უჯრედს რვა მეზობელი გააჩნია. უჯრედში შეიძლება ერთი ორგანიზმი იყოს ჩასახლებული («ცოცხალი» უჯრედი), მაგრამ შესაძლებელია, რომ უჯრედი ცარიელიც იყოს («მკვდარი» უჯრედი). პოპულაციის მოცემა პირველ თაობაში შემთხვევით ხდება. ეს ნიშნავს, რომ ყოველი კონკრეტული უჯრედის დასახლება გარკვეული ალბათობით ხორციელდება.

დასახლებული უჯრედების განაწილება მომდევნო თაობაში განისაზღვრება წესით, რომელიც ერთდროულად გამოიყენება ყველა უჯრედის მიმართ:

1. ცოცხალი უჯრედი, რომელსაც ერთ ცოცხალ მეზობელზე მეტი არ გააჩნია, მარტობის გამო კვდება;
2. ცოცხალი უჯრედი, რომელსაც ოთხი ან მეტი ცოცხალი მეზობელი გააჩნია, ასეთ ჭარბად დასახლებულ გარემოში იღუპება;
3. მკვდარი უჯრედი სამი ცოცხალი მეზობლის გარემოცვაში სიცოცხლეს იბრუნებს;
4. ყველა დანარჩენ შემთხვევაში უჯრედის მდგომარეობა უცვლელი რჩება.

LIFE პროგრამაში (იხილე ქვემოთ) ვირტუალურ ორგანიზმთა გაერთიანების ევოლუციის ასახვისას *ანიმაციის* (ესე იგი დინამიკური, ცვალებადი გამოსახულების გამოტანის) ხერხი გამოიყენება. ეფექტი აქ ემყარება კადრების – გრაფიკული გამოსახულებების - თანამიმდევრულ შეცვლას. სწრაფი გადასვლისათვის პოპულაციის ამსახველი ერთი «კადრიდან» მეორეზე ჩვენ ორ გრაფიკულ გვერდს გამოვიყენებთ. გრაფიკული გვერდი წარმოადგენს ვიდეომეხსიერების არეს, რომელიც გამოსახულებას ინახავს. თუ ამასთან ერთად ვიდეოადაპტერის ფუნქციონირების რეჟიმი მხოლოდ ერთ გვერდთან მუშაობას უზრუნველყოფს, მაშინ ამ გვერდის შიგთავსი დისპლეის ეკრანზე აისახება. მუშაობის ზოგიერთ რეჟიმში შესაძლებელია

რამდენიმე გვერდთან ურთიერთობა. ერთ-ერთი მათგანის («ვიზუალური» გვერდის) შიგთავსი ეკრანზე აისახება, ხოლო მეორეზე («აქტიურზე»), რომელიც უხილავია მომხმარებლისათვის, ამ დროს ახალი გამოსახულების აგება შეიძლება ხორციელდებოდეს. აქტიურ გვერდზე მომზადებული გამოსახულების გამოტანა კი შემდეგ ეკრანზე შეიძლება. ასეთი მეთოდი დასაშვებია, მაგალითად, VGA რეჟიმში 640x350 გარჩევადობით მუშაობისას, ვინაიდან ამ რეჟიმში ორი გრაფიკული გვერდია წარმოდგენილი.

კონსტანტათა აღწერების კარში მოცემულია პროგრამის პარამეტრები, რომელთა შეცვლა იშვიათად მოგვიხდება, ამის საჭიროებაც რომ გაჩნდეს, და ამიტომ მოუსწერებელია მათი ხელახლა შეტანა პროგრამის ყოველი გაშვების დროს:

1. hor - უჯრედების რაოდენობა ჰორიზონტალის გასწვრივ;
2. ver - უჯრედების რაოდენობა ვერტიკალის გასწვრივ;
3. cell_width, cell_height - უჯრედის სიგანე და სიმაღლე;
4. prob_factor - საწყისი პოპულაციის ფორმირებისას უჯრედთა დასახლებულობის ალბათობის განმსაზღვრელი პარამეტრი.

ზომები მითითებულია პიქსელობით.

LIFE პროგრამის ტექსტი

```
PROGRAM LIFE;
```

```
(* LIFE - ჯ. კონვეის ცნობილი თამაში *)  
(* «სიცოცხლე» *)  
(* თარიღი : 2007 წლის 3 თებერვალი *)  
(* ავტორები : არჩილ ფრანგიშვილი, ოლეგ ნამიჩიშვილი *)  
(* და არჩილ ელიზბარაშვილი *)
```

```
uses crt, dos, Graph;
```

```
const
```

```
  hor = 100;  
  ver = 70;  
  cell_width = 8;  
  cell_height = 6;  
  prob_factor = 0.5;
```

```

var
  old_gen, new_gen : array[0..ver, 0..hor] of 0..1;
  probab : real;
  ch : char;
  x_center : array[0..hor] of word;
  y_center : array[0..ver] of word;
  gen_count, radius, page : word;
  ss : string[10];
procedure init_cells;
var
  j, k : word;
begin
  gen_count := 0;
  for j := 0 to ver do
    for k := 0 to hor do
      begin
        old_gen[j, k] := 0;
        if random <= probab then
          new_gen[j, k] := 1
        else
          new_gen[j, k] := 0;
        end;
      end;
end;
procedure next_generation;
var
  j, k, m, prev_j, next_j, prev_k, next_k : word;
begin
  old_gen := new_gen;
  for j := 0 to ver do
    begin
      if j = 0 then
        prev_j := ver
      else
        prev_j := j - 1;
      if j = ver then
        next_j := 0
      else
        next_j := j + 1;
      for k := 0 to hor do
        begin
          if k = 0 then

```

```

    prev_k := ver
else
    prev_k := k - 1;
if k = hor then
    next_k := 0
else
    next_k := k + 1;
m := old_gen[prev_j, prev_k]
    + old_gen[prev_j, k
    ]
    + old_gen[prev_j, next_k]
    + old_gen[j, prev_k]
    + old_gen[j, next_k]
    + old_gen[next_j, prev_k]
    + old_gen[next_j, k
    ]
    + old_gen[next_j, next_k];
if (old_gen[j, k] = 1) and ((m <= 1) or
                            (m>= 4)) then
    new_gen[j, k] := 0
else
    if (old_gen[j, k] = 0) and (m = 3) then
        new_gen[j, k] := 1
    else
        new_gen[j, k] := old_gen[j, k];
end;
end;
end;
procedure init_screen;
var
    GraphDriver, GraphMode : integer;
    j, k : word;
begin
    GraphDriver := VGA; GraphMode := VGAMed;
    page := 0;
    InitGraph(GraphDriver, GraphMode, '');
    if GraphResult <> grOK then
        halt;
    for k := 0 to hor do
        x_center[k] := k*cell_width + cell_width div 2;
    for j := 0 to ver do
        y_center[j] := j*cell_height+cell_height div 2;
    radius := 4;

```

```

end;
procedure display;
var
  j, k : word;
procedure rule_plane;
var
  j, k : word;
begin
  setfillstyle(SolidFill, Blue);
  bar(0, 0, getmaxx, 10);
  SetColor(white);
  outtext('Generation: ');
  OutTextXY(250, 0, 'Q: Quit');
  OutTextXY(450, 0, 'Any other key: renew');
  str(gen_count, ss); outtext(ss);
  SetBkColor(DarkGray);
end;{rule_plane}
begin
  if gen_count <> 0 then
    next_generation;
  inc(gen_count);
  page := 1 - page;
  setactivepage(page);
  cleardevice;
  setcolor(yellow);
  for j := 0 to ver do
    for k := 0 to hor do
      if new_gen[j, k] = 1 then
        circle(x_center[k], y_center[j], radius);
  rule_plane;
  setvisualpage(page);
end;{display}
begin
  init_screen;
  repeat
    randomize;
    prob := 0.1 + prob_factor * random;
    outtextxy(0, 0, 'Conway''s Game of Life');
    writeln;
    outtextxy(0, 15, 'Live cells inserted at
random');

```



```

str(prob:3:3, ss);
outtextxy(0, 30, 'with probability'+ ss);
outtextxy(0, 60, 'Press any key to start: ');
ch := readkey;
cleardevice;
init_cells;
repeat
  display;
  if keypressed then
    begin
      ch := readkey;
      break;
    end;
until false;
cleardevice;
setcolor(white);
if upcase(ch) = 'Q' then
  break;
until false;
CloseGraph;
end.

```

`init_cells` პროცედურა საწყისი პოპულაციის ფორმირებას ახორციელებს და `new_gen` მასივის ელემენტებს ანიჭებს ნულოვან და ერთეულოვან მნიშვნელობებს ჩასახლების ალბათობის არჩეული მნიშვნელობის გათვალისწინებით.

`next_generation` პროცედურა `new_gen` მასივში მომდევნო პოპულაციას აგებს თამაშის წესების შესაბამისად.

`init_screen` პროცედურაში გრაფიკული რეჟიმის ინიციალიზება და უჯრედების ცენტრთა გრაფიკული კოორდინატების `x_center` და `y_center` მასივების შევსება ხდება.

`display` პროცედურა ძირითად მოქმედებებს ასრულებს თამაშის სასიცოცხლო სივრცის (სამუშაო მინდერის) გამოსახულების ასაგებად უხილავ აქტიურ გვერდზე და მის გამოსატანად ეკრანზე. ამას `SetActivePage` და `SetVisualPage` პროცედურები უზრუნველყოფს. მათი გამოძახება გვერდების განმსაზღვრელი 0 ან 1 პარამეტრებით ხორციელდება. პირველი პროცედურა გამოძახებისას აქტიურ გვერდს აყენებს, ხოლო მეორე – ვიზუალურს.

ამოცანები.

1. ჩამოაყალიბეთ $f(x) = (x - 0.5)^2$ ფუნქციის მინიმუმის პოვნის ამოცანა $[0, 1]$ მონაკვეთზე გენეტიკური ალგორითმისათვის.

2. უჯრედული ავტომატების რომელ ტიპს მიეკუთვნება ჰოპფილდის კლასიკური ნეირონული ქსელი? როგორი ტიპისაა ავტომატი, რომელსაც ჰოპფილდის ქსელის ალბათური განზოგადება იძლევა ძალიან მაღალ ტემპერატურებზე? რატომ?

დასკვნა.

ლექციათა ეს კურსი დასრულებულია, მაგრამ ნეირომცენიერებაში, რა თქმა უნდა, წერტილის დასმა ნაადრევია. ავტორებს იმედი აქვთ, რომ ეს წიგნი არამხოლოდ შეასრულებს თავის ძირითად ამოცანას როგორც ნეირონული ქსელების თეორიის სისტემატური შესავალი, არამედ დაგვეხმარება მივუახლოვდეთ პასუხს მნიშვნელოვან შეკითხვას: არის ხელოვნური ნეირონული ქსელი დიდი ხნის ნანატრი, ნალოდინევი მაგისტრალური მიმართულება, რომელშიც გაგრძელდება ხელოვნური ინტელექტის მეთოდთა განვითარება, თუ იგი მოდური «ახალი სიოს დაბერვაა», როგორც ეს უკვე არაერთხელ მომხდარა საექსპერტო სისტემებისა და სამეცნიერო კვლევათა ზოგიერთი სხვა აპარატის (მაგალითად, ფინიშანის დიაგრამების) შემთხვევაში? საზოგადოება მათგან რეკოლუციურ გარღვევებს მოელოდა, მაგრამ, თანდათანობით თავს იჩენდა ამ მეთოდებისათვის დამახასიათებელი შეზღუდვები და ისინი იკავებდა შესაბამის (თუმცაღა ღირსეულ) ადგილს მეცნიერების ზოგად სტრუქტურაში.

დღეს ნეირონული ქსელები არ წარმოადგენს უკვე თეორეტიკოსთა მცირე ჯგუფის ხვედრს. ნეიროქსელურ გამოყენებებს სხვადასხვა სპეციალობის ინჟინრები და მკვლევარები უერთდებიან. განსაკუთრებით სასიხარულოა პროგრესი მთლიანად ექსპერიმენტულ მონაცემებზე დაფუძნებული საკვლევო მოვლენების მოხერხებული ნეიროქსელური მოდელების აგებაში. აქ განსაკუთრებით სრულად ვლინდება ხელოვნური ნეირონული სისტემების შესანიშნავი თვისებები: ინფორმაციის დამუშავების მასიური პარალელურობა, მეხსიერების ასოციაციურობა და სწავლების შესაძლებლობა ცდის გამოყენებით. ამით ახალი პერსპექტივების გადაშლა ხდება დიდძალი ექსპერიმენტული ინფორმაციის სისტემატიზაციისათვის ცოდნის ისეთ სფეროებში, სადაც, ტრადიციულად, ძნელად მკვიდრდება მათემატიკური ფორმალიზმი, მაგალითად, მედიცინაში, ფსიქოლოგიაში და ისტორიაში.

სარჩევი :

| | | |
|------------------|--------------------------------------------------------------|------------|
| ლექცია 1 | შესავალი | 3 |
| ლექცია 2 | ცნობები უმაღლესი მათემატიკიდან..... | 9 |
| ლექცია 3 | ბიოლოგიური ნეირონი და მისი კიბერნეტიკული მოდელი | 18 |
| ლექცია 4 | როზენბლატის პერსექტრონი | 32 |
| ლექცია 5 | ნეირონულ ქსელებში სწავლების პროცესთა თვისებები | 41 |
| ლექცია 6 | მრავალფენიანი პერსექტრონი | 51 |
| ლექცია 7 | სხვა იერარქიული არქიტექტურები | 61 |
| ლექცია 8 | ჰოპფილდის მოდელი | 71 |
| ლექცია 9 | ჰოპფილდის მოდელის განზოგადებები და გამოყენებები | 84 |
| ლექცია 10 | ფუკუშიმას ნეოკოგნიტრონი | 98 |
| ლექცია 11 | ადაპტური რეზონანსის თეორია | 107 |
| ლექცია 12 | ართ ქსელი და მისი შემდგომი განვითარება | 115 |
| ლექცია 13 | თანამედროვე არქიტექტურათა თვისებები | 124 |
| ლექცია 14 | ნეიროქსელების კომპიუტერული მოდელირება | 131 |
| ლექცია 15 | დამატებითი ცნობები | 148 |

იბეჭდება ავტორთა მიერ წარმოდგენილი ფორმით

გადაეცა წარმოებას 01.02.2007. ხელმოწერილია დასაბეჭდად 01.03.2007.
ქალაქის ზომა $60 \times 84 \frac{1}{16}$. პირობითი ნაბეჭდი თაბახი 10,0.
სააღრიცხვო-საგამომცემლო თაბახი 9. ტირაჟი 100 ეგზ. შეკვეთა №140.

გამომცემლობა «ტექნიკური უნივერსიტეტი», თბილისი,

მერაბ კოსტავას ქ., 77

სტუ-ს სტამბა, თბილისი, მერაბ კოსტავას ქ., 75