

ხელოვნური ნეირონული ქსელების განვითარების შესახებ

ცირა ბერაძე

ქუთაისის აკაკი წერეთლის სახელმწიფო უნივერსიტეტი

აბსტრაქტი. აღნიშნულია რომ ხელოვნური ინტელექტის რესურსი განუსაზღვრელია მსოფლიო-ში, ის თანდათან ინტეგრირდება არა მარტო მეტეოროლოგიური პროცესების მართვაში არამედ მეცნიერების სხვადასხვა სფეროებში. განხილულია ხელოვნური ინტელექტის დისციპლინის, პერსპექტიული მიმართულებების, ნეირონული ქსელების კონსტრუირების ალგორითმები, მათი ანალიზის საფუძველზე შემოთავაზებულია ქსელის აგების ახალი კონცეფცია და მისი განხორციელების ალგორითმები. აღნიშნულია რომ ინტენსიურად მიმდინარეობს ხელოვნური ნეირონული სისტემების განვითარება, რაც უმოკლესი დროის პერიოდში უამრავი პრობლემის გადაჭრის საშუალებას იძლევა.

საკვანძო სიტყვები - ხელოვნური ინტელექტი, ნეირონული ქსელები, კონსტრუირების ალგორითმები, აქტივაციის ფუნქციები.

თანამედროვე მსოფლიოში ხელოვნური ინტელექტი, მისი მრავალ განზომილებიანი პოტენციალის გამო, სულ უფრო დიდ ღირებულებას იძენს. მართლაც, თანამედროვე მეცნიერება ქმნის და ავითარებს ისეთ მექანიზმებს, რომლებიც ადამიანის შრომას გაცილებით ეფექტიანს ხდის, თანაც, გაცილებით მოკლე დროში. დღეისათვის აქტუალური ხდება ნეირონული ქსელების გამოყენება ისეთ სისტემებში, რომლებშიც შეიცავენ მრავალ დამოუკიდებელ ცვლადს, რომლებიც დეტერმინისტულად არიან დამოკიდებულნი მიზნობრივ ფუნქციაზე. მრავალ პრაქტიკულ სიტუაციაში ფუნქციონალური კავშირი დამოუკიდებელ ცვლადებსა და მიზნობრივ ფუნქციას შორის უცნობია.

თანამედროვე ტექნოლოგიური ცივილიზაცია, გონივრული განვითარების შემთხვევაში განსხვავებულ სურათს იძლევა. ნეირონული ქსელების არე აღორძინების ხანაშია, ინტენსიურად მიმდინარეობს ხელოვნური ინტელექტის სისტემების განვითარება, რომლებსაც შეუძლიათ გადაწყვიტონ ისეთი ამოცანები როგორებიცაა: ეკონომიკური მდგრადობის, მეტეოროლოგიური პროცესების, ადამიანის ჯანმრთელობის მდგომარეობის დიაგნოსტიკა, პროგნოზირება და სხვა.

ხელოვნური ნეირონული ქსელი (ANN) არის ინფორმაციის დამუშავების ახალი სტრუქტურა, იგი შედგენილია დიდი რაოდენობის უმაღლესად ურთირთდაკავშირებული გაპროცესების ელემენტებისაგან (ნეირონები), რომლებიც მუშაობენ ერთდროულად რომ გადაწყვიტონ სპეციფიკური პრობლემები. ნეირონული ქსელის სიმულაციები არის ახალი ქმნილება. გავარჯიშებული ნეირონული ქსელი შეიძლება იყოს ჩაფიქრებული, როგორც „ექსპერტი“ კონკრეტული კატეგორიის ინფორმაციისათვის, რომელიც მას მიეცა ანალიზისათვის. ეს „ექსპერტი“, შემდეგ შეიძლება მოვიმარაგოთ დასაპროექტებლად ახალი სიტუაციებისათვის, რომლებიც ჩვენ გვინტერესებს და კითხვისათვის „რა იქნება თუ“.

სხვა უპირატესობებია: 1. ადაპტიური სწავლება: ANN-ის შესაძლებლობა ვასწავლოთ როგორ გადავაწყვეტინოთ ამოცანები, დაფუძნებულია მონაცემებზე, რომლებიც მიცემული ჰქონდა ვარჯიშის დროს ან საწყისი გამოცდილების ბაზაზე. 2. თვით ორგანიზებულება: ANN-ს აქვს უნარი შექმნას საკუთარი ორგანიზებულება ან წარმოდგენა იმ ინფორმაცი-

ისა, რომელიც მან მიიღო სწავლების დროს. 3. ოპერაცია რეალურ დროში: გამოთვლები შეიძლება შესრულდეს პარალელურად და სპეციალური ტექნიკური მოწყობილობები შეიძლება იყოს დაპროექტებული და წარმოებული, რომლებიც იღებენ უპირატესობას ამ შესაძლებლობით. 4. შეცდომისადმი ტოლერანტობა ჭარბი ინფორმაციის კოდირებით: ქსელის ნაწილობრივ დანგრევა იწვევს წარმადობის შესატყვის შემცირებას. მაგრამ ქსელის ზოგიერთი შესაძლებლობები შეიძლება იყოს შენარჩუნებული მაშინაც კი, როცა ქსელის უმეტესი ნაწილი დაზიანებულია. ნეირონული ქსელები იყენებენ განსხვავებულ მიდგომას პრობლემის გადაწყვეტისადმი, ვიდრე თანამედროვე კომპიუტერები.

თანამედროვე კომპიუტერები იყენებენ ალგორითმულ მიდგომას პრობლემის გადაწყვეტად ე.ი. კომპიუტერი ასრულებს ინსტრუქციების მიმდევრობას პრობლემის გადაწყვეტად. თუ ინსტრუქციების მიმდევრობა არაა ცნობილი, კომპიუტერს არ შეუძლია გადაწყვიტოს პრობლემა. ეს ზღუდავს კომპიუტერის შესაძლებლობებს ისეთი პრობლემებით, რომლებიც ჩვენთვის ცნობილია თუ როგორ უნდა გადავწყვიტოთ. კომპიუტერები იქნებოდნენ ბევრად უფრო სასარგებლო, რომ მათ შეეძლოთ გააკეთონ ისეთი რამეები, რომელთა გაკეთება ჩვენთვის არაა ცნობილი. ნეირონული ქსელები აპროცესებენ ინფორმაციას იმის მსგავსად, როგორც ადამიანის ტვინი აკეთებს.

ქსელი შედგენილია უმაღლესად ურთიერთ დაკავშირებული დიდი რაოდენობა ელემენტებისაგან (ნეირონებისაგან), რომლებიც მუშაობენ პარალელურად, რომ გადაწყვიტონ სპეციფიკური პრობლემა. ნეირონული ქსელები სწავლობენ მაგალითზე. ისინი არ შეიძლება იყონ დაპროგრამებული, რომ შეასრულონ სპეციფიკური ამოცანა. თანამედროვე კომპიუტერები იყენებენ შემეცნებით მიდგომას პრობლემის გადასაწყვეტად. გზა, რომლითაც პრობლემა უნდა იყოს გადაწყვეტილი, უნდა იყოს რეალიზებული დაპროგრამების ენის არაორაზროვან ინსტრუქციებში და გადაყვანილი მანქანურ კოდში, რომელსაც შემდეგ კომპიუტერი შეასრულებს. ასეთი მანქანები არიან ტოტალურად წინასწარ გამოცნობადი. თუ რაიმე კეთდება არასწორად, იგი გამოწვეულია პროგრამული უზრუნველყოფის ან ტექნიკური მოწყობილობის შეცდომებით.

ნეირონული ქსელები და თანამედროვე ალგორითმული კომპიუტერები არ არიან ურთიერთ შეჯიბრებაში, არამედ ავსებენ ერთიმეორეს. არსებობენ ამოცანები, რომელთათვისაც უფრო სასურველია ალგორითმული მიდგომა და არსებობენ ამოცანები, რომელთათვისაც სასურველია ნეირონული ქსელები. უფრო მეტიც, არსებობენ დიდი რაოდენობა ამოცანებისა, რომლებიც მოითხოვენ სისტემებს, სადაც გამოყენებულია კომბინირებულ მიდგომა (ჩვეულებრივ, თანამედროვე კომპიუტერი გამოიყენება ნეირონული ქსელის სამართავად), რომ მაქსიმალური ეფექტურობით გადაწყდეს პრობლემა.

ხელოვნური ნეირონული ქსელები გამოყენება კლასიფიკაციის და პროგნოზირების ამოცანებში, ასევე გენეტიკურ ალგორითმებთან ერთობლიობაში. ქსელი შედგება N ხელოვნური ნეირონისაგან. ნეირონები ღებულობენ ორ მნიშვნელობას ან $+1$, ან -1 , რომელიც მსგავსია გამომავალი ნეირონის. ამის გამო ჰოპფილდის ქსელს სპინებსაც უწოდებენ. W_{ij} – წონის ფუნქციები ამ მატრიცაში სწავლების დროს ჩაიწერება N განზომილებიანი ბინარული ვექტორები $\rho_m = (S_{m1}, S_{m2}, S_{mn})$. დიაგონალური ელემენტები $W_{ii} = 0$ ნულის ტოლია,

რაც გამორიცხავს ნეირონის თავის თავზე ზემოქმედების ეფექტს, რომელიც აუცილებელია ჰოპფილდის ქსელისთვის და არაა საკმარისი ქსელის მდგრადობისთვის. ქსელის სწავლება სხვა ქსელების სწავლებისაგან განსხვავდება იმით რომ მიმდევრობითი მიახლოება მიზნისაკენ შეცდომების მინიმიზაციის გზით კი არ ხდება, არამედ ყველა წონითი კოეფიციენტი ნულოვან მატრიცაში გამოითვლება ერთი და იმავე ფორმულით ერთ ციკლში, რის შემდეგ ქსელი მზადაა სამუშაოდ. 27 კოეფიციენტების გამოთვლა ხდება შემდეგი პრინციპით: ყველა დამახსოვრებელი ხატისათვის (სურათისთვის). Xi მატრიცა უნდა აკმაყოფილებდეს განტოლებას. ასეთი მდგომარეობა იქნება მდგრადი და ამ მდგომარეობაში დარჩება ქსელი. N - ვექტორის განზომილება m -დამახსოვრებული გამოსავალი ვექტორების რაოდენობა d - დამახსოვრებული გამოსავალი ვექტორის ნომერი თუ გავითვალისწინებთ, რომ როდესაც არის i-ური დამახსოვრებული ვექტორის სტრიქონი. ამ წონითი კოეფიციენტების გამოთვლას ეწოდება ქსელის სწავლება. F-აქტივაციის ფუნქცია. ჰოპფილდის ქსელის მუშაობის რეჟიმი არის ასინქრონული. 28 უკუკავშირი X1 Y1 X2 Y2 Xi Yi Xn Yn შესავალი გამოსავალი ჰოპფილდის ქსელის სტრუქტურული სქემა. კოლმოგოროვის თეორემა ნებისმიერი n ცვლადიანი უწყვეტი ფუნქცია შეიძლება წარმოდგენილი იქნას მარტივი ფუნქციების და შეკრებით) კოლმოგოროვის თეორემა არის ის მათემატიკური საფუძველი ხელოვნური ნეირონული ქსელების ფუნქციონირებისათვის, რომელიც საშუალებას იძლევა სხვადასხვა მაგ . n რაოდენობის ერთ ცვლადიანი მარტივი ფუნქციები მივაწოდოთ ხელოვნურ ნეირონულ ქსელს შესავალზე და ქსელის გამოსავალზე მივიღოთ n ცვლადიანი ფუნქცია. ხელოვნური ნეირონული ქსელი არის ხელოვნური ნეირონებისა და ამ ნეირონების დამაკავშირებელი წახნაგებისაგან შემდგარი ქსელი. ზოგიერთი წახნაგი მოცემული ნეირონისთვის განიხილება შემომავლად, ხოლო ზოგიერთი გამავლად.


ნეირონული ქსელის არქიტექტურა არის ნეირონების განთავსების, მათი დაკავშირების და აქტივაციის ფუნქციის ერთობლიობა. აქტივაციის ფუნქციის შერჩევა ხდება კონკრეტული გამოყენების დარგის მიხედვით. მისი ძირითადი დანიშნულებაა შემომავალი სიგნალის ლიმიტირება, რადგან, როგორც წესი გამოსავალზე საჭიროა სიგნალი კონკრეტულ ფარგლებში. აქტივაციის ფუნქციად ყველაზე ხშირად გამოიყენება სიგმიოიდი

$$f(\text{net})=11+\exp\{-(\text{net}+\theta)\} \text{ ან ჰიპერბოლური ტანგენსი.}$$

$$f(\text{net})=\exp\{-(\text{net}+\theta)\}-\exp\{-(\text{net}+\theta)\}+\exp\{-(\text{net}+\theta)\}$$

უკუპროპაგაციული მოდელი არის ხელოვნურ ნეირონულ ქსელებში ერთ-ერთი ყველაზე გამოყენებადი. მას გააჩნია შემომავალი და გამავალი შრეები, აგრეთვე ერთი ან მეტი შიდა შრე. მეზობელ შრეებს შორის ყველა ნეირონი ერთმანეთშია დაკავშირებული. სიგნალის მოძრაობა ხდება შემოსავლიდან გამოსავალზე შიდა შრეების სათითოდ გავლით. ნეირონების დამაკავშირებელი წახნაგების წონების შერჩევის გზით შესაძლებელია ასეთ ნეირონულ ქსელს "ვასწავლოთ" შემოსავლის შესაბამის გასავალში გარდაქმნა, მაგალითად, ხელნაწერი ასოების ამოსაცნობად. პერცეპტრონი არის უმარტივესი ნეირონული ქსელის არქიტექტურა, რომელიც გამოიყენება წრფივად გაყოფადი არეების ამოსაცნობად. პერცეპტრონს გააჩნია მხოლოდ ორი სრულად დაკავშირებული შრე – შემომავალი და გამავალი შრეები. თუმცა პერცეპტრონის გამოსავალი შესაძლებელია გამოთვლილი იყოს ანალიტი-

კური გზით და მას შეუძლია მხოლოდ შეზღუდული სახეობის სტრუქტურების ამოცნობა (წრფივად გაყოფადი არე), ის მაინც წარმოადგენს ერთ-ერთ ყველაზე სასარგებლო მოდელს თეორიული კვლევისთვის. შეიძლება ბოლცმანის განაწილება შეიცვალოს კომის განაწილებით. კომის განაწილებას (ნახ. 1) გააჩნია უფრო გრძელი „კუდები“ და ამით ზრდის დიდი ბიჯების ალბათობას. მართლაც, კომის განაწილებას გააჩნია უსასრულო (განუსაზღვრელი) დისპერსია. ასეთი მარტივი ცვლილებების საშუალებით კრებადობის სიჩქარე ხდება არა ლოგარითმული სიდიდის უკუპროპორციული, როგორც ეს იყო ბოლცმანის განაწილებისას, არამედ - წრფივის. ეს კი მკვეთრად ამცირებს სწავლების დროს.



ნახ. 1. კომის განაწილება და ბოლცმანის განაწილება

ყოველივე ზემოთ თქმული გვაძლევს დასკვნის საფუძველს, რომ მსგავსი ამოცანები შეიძლება გადაწყდეს შემდეგი ალგორითმით:

1. სისტემას ვაკვირდებით და ვაგროვებთ მონაცემებს შემსწავლელი სიმრავლისთვის. შემსწავლელი სიმრავლის თითოეული ელემენტი შედგება დაკვირვებისას მიღებული გაზომვებისაგან და შეიცავს ყველა შემავალ (შემავალი ვექტორი) და გამომავალ (გამომავალი ვექტორი) სიდიდეს.
2. ქსელს ვასწავლით ამ შემსწავლელ სიმრავლეზე. სწავლება შედგება შემავალი ვექტორის წარდგენისაგან, გამომავალი ვექტორის გამოთვლისაგან, გამოთვლილი გამომავალი ვექტორის შედარებისაგან დაკვირვების პროცესში მიღებულ გამომავალ ვექტორთან და წონების კორექციისაგან, რომელიც მინიმიზაციას უკეთებს ამ სხვაობას. თითოეული შემავალი ვექტორი წარედგინება რიგრიგობით და ქსელი თანდათან სწავლობს. შემავალი ვექტორების მრავალჯერადი წარდგენის შემდეგ ქსელი მიაღწევს ამოხსნას, რომელიც მინიმიზირებას უკეთებს სისტემის სასურველ და გაზომილ გამომავალ ვექტორებს შორის სხვაობას. ფაქტიურად ქსელი აგებს უცნობი სისტემის შიგა მოდელს. თუ შემსწავლელი სიმრავლე საკმაოდ დიდია, ქსელი აგებს სისტემის ზუსტ მოდელს. თუ ქსელს წარუდგენთ რაიმე შემავალ ვექტორს, რომელიც განსხვავდება სწავლებისას წარდგენილი ნებისმიერი შემავალი ვექტორისაგან, მაშინ სრულად ნასწავლი ქსელი მოგვცემს ისეთ გამომავალ ვექტორს, რომელსაც მოგვცემდა რეალური სისტემა.
3. მიზნობრივი ფუნქცია მაქსიმიზირდება. გამოსავლების მიზნობრივი ფუნქცია ისე უნდა

იყოს კონსტრუირებული, რომ გამოხატავდეს შედეგით “კმაყოფილების“ ხარისხს. ახლა, ნასწავლი ქსელისთვის შესავლები ხდება ცვლადი. მათი შეწყობა უნდა მოხდეს იმ სწავლების ალგორითმის საშუალებით, რომელიც გამოიყენებოდა მე-2 ბიჯზე წონების მისაღებად, მაგრამ ახლა გამოყენებული იქნება მიზნობრივი ფუნქციის მაქსიმიზაციისთვის.

ბევრ შემთხვევაში შეიძლება არსებობდეს ამოცანის პირობებით გათვალისწინებული შეზღუდვები. მაგალითად, ფიზიკურად შეუძლებელი იყოს ცვლადების მონაცემების აღება რაიმე დიაპაზონის გარეთ. ეს შეზღუდვები (რომლებიც შეიძლება წარმოადგენდეს რთულ გამოსახულებებს) შეიძლება ადვილად გავითვალისწინოთ მე-3 ბიჯზე, თუ არ მივიღებთ შემავალი ცვლადის ისეთ ცვლილებას, რომელიც არღვევს მიღებულ შეზღუდვებს.

ნაშრომის მიზანს წარმოადგენს არსებული მდგომარეობის ანალიზი და მის საფუძველზე ახალი მიმართულების გამოკვეთა, ნეირონული ქსელის კონსტრუირების ახალი კონცეფცია, ჩატარებული კვლევების საფუძველზე მიღებულია მისი განხორციელების პირობითი ალგორითმები, რომლის საფუძველზეც შესაძლებელია ოპტიმალური ქსელის კონსტრუირება კონკრეტული ამოცანათა კლასისათვის³

ლიტერატურა:

1. კ. ოდიშარია, ს. ხომტარია, ჟ. ებანოიძე სისტემების და პროცესების მოდელირება თბილისი 2011.
2. Ф. Уоссермен. Нейрокомпьютерная техника М: Мир 1992 г.
3. Geman S., Geman D. 1984. Stochastic relaxation, Gibbs distribution and Bayesian restoration of images. IEEE Transactions on Pattern Analysis and Machine Intelligence 6:721-41.
4. Hinton G. E., Sejnowski T. J. 1986. Learning and relearning in Boltzmann machines. In Parallel distributed processing, vol. 1, Cambridge, MA: MIT Press.
5. Parker D. B. 1987. Optimal algorithms for adaptive networks. Second order Hebbian learning. In Proceedings of the IEEE First International Conference on Neural Networks, eds. M. Caudill and C. Buller, vol. 2, San Diego, CA: SOS Printing.

On the development of artificial neural networks Summary

It is noted that the potential of artificial intelligence is unlimited in the world, and it is being gradually integrated into the management of meteorological processes and various fields of science.

The paper considers neural network design algorithms as one of the promising areas of the Artificial Intelligence discipline, and based on their analysis, a new concept of network design and its implementation algorithms are proposed.

It is noted that intensive work is underway to develop artificial neural systems, which allow for solving many problems as quickly as possible.