

ნეირონული ქსელები

პაატა გოგიშვილი

თბილისი
2017

სარჩევი

თავი 1. შესავალი.....	4
§ 1. KNN კლასიფიკატორი	Error! Bookmark not defined.
§ 2. თანამედროვე ნეირონული ქსელების მიმოხილვა	Error! Bookmark not defined.
§ 3. პროგრამული ბიბლიოთეკების მიმოხილვა	Error! Bookmark not defined.
თავი 2. ნეირონი და ნეირონული ქსელი	6
§ 1. ბუნებრივი ნეირონი და ნეირონული ქსელი	6
§ 2. ხელოვნური ნეირონი	8
§ 3. ხელოვნური ნეირონული ქსელი.....	9
თავი 3. სრულად ბმული ნეირონული ქსელი	11
§ 1. შეცდომის ენერჯია (უმცირეს კვადრატთა მეთოდი)	11
§ 2. სრულად ბმული ქსელის სწავლება (დელტა წესი)	12
გამომავალი შრის სწავლება	13
ფარული შრის სწავლება	14
თავი 4. კონვოლუციური ნეირონული ქსელი (Convolutional Neural Network).....	16
§ 1. კონვოლუციური ქსელის ტოპოლოგია.....	16
§ 2. Convolutional შრე (Convolutional Layer).....	17
§ 3. Pooling შრე (Pooling Layer)	18
§ 4. Dropout.....	19
§ 5. რეგულარიზაცია	19
§ 6. Convolutional ქსელის სწავლება	19
თავი 5. რეკურენტული ნეირონული ქსელები (Reccurent Neural Networks)	20
თავი 6. ნეირონული ქსელის სწრაფი სწავლება (Transfer learning).....	21
თავი 7. მათემატიკური აპარატი.....	22
§ 1. ნორმალური განაწილება	22
§ 2. softMax ფუნქცია	22
§ 3. cross entropy error	24
§ 4. Batch Normalization	24
თავი 8. კომენტარები	25
თავი 9. ხელოვნური ნეირონული ქსელების ფილოსოფიური ასპექტები.....	26
§ 1. ინტელექტის ცნება.....	26
ტიურინგის ტესტი.....	26
CAPTCHA.....	26
§ 2. სამყაროს აღქმა.....	26

§ 3. ხელოვნური ინტელექტის განვითარების პერსპექტივები.....	27
ლიტერატურა	29

თავი 1. შესავალი

„შეიცან თავი შენი და შეიცნობ ყოველს“
ლაო ძი

ხელოვნური ინტელექტის სისტემები განსაკუთრებით სწრაფად განვითარდა ბოლო დროს. შეიქმნა რამდენიმე ძალიან პოპულარული ციფრული ასისტენტი: Google Assistant, Siri, Cortana, Alexa. მათ შეუძლიათ ახალი ამბების წაკითხვა, ფოსტის შემოწმება, საოჯახო აპარატურის (ტელევიზორის, კონდენციონერის, ჟალუზების...) მართვა..



ასისტენტების შესაძლებლობები სულ უფრო იზრდება და მალე საოცრად მრავალმხრივი დამხმარეები, და შეიძლება მეგობრებიც, გვეყოლება.

უკვე არსებობს მარტოხელა მოხუცთა დამხმარეები, რომელთაც შეუძლიათ წამლის დალევის შეხსენება, წნევის გაზომვაში დახმარება და, საჭიროების შემთხვევაში, სასწრაფოს გამოძახებაც.



ელექტრონული მიმტანები მოგემსახურებათ კაფეებში, კონსულტაციას გაგიწევთ ბანკებში იპოთეკური სესხისა და ჯანმრთელობის დაზღვევის შესახებ.

გამოჩნდნენ თვითმავალი ავტომობილებიც. ისინი გაცილებით უსაფრთხოდ მოძრაობენ ვიდრე ამას ადამიანები ვახერხებთ. მომავალში, უნდა ვივარაუდოთ, რომ ადამიანის საჭესთან დაჯდომა საერთოდ აღარ იქნება საჭირო.

ხელოვნური ინტელექტის ასეთი ნახტომისებური განვითარება არის „ნეირონული ქსელების“ მძლავრი მოდელების შექმნის დამსახურება.

ხელოვნურ ნეირონულ ქსელებზე დაფუძნებული ტექნოლოგიებით გახდა შესაძლებელი ბიონიკური თვალის და კიდურების პროთეზების დამზადება. ხელოვნურად დამზადებული ბიონიკური თვალით ადამიანი ხედავს, ხოლო თანამედროვე პროთეზები იმდენად სრულყოფილია, რომ მათ ადამიანი თითქმის საკუთარი სხეულის ნაწილად აღიქვამს, გრძნობს შეხებას, ტემპერატურას, ტკივილსაც კი.





კიდევ მრავალი სფეროს ჩამოთვლა შეიძლება, სადაც პროგრესის მამოძრავებელი გახდა ხელოვნური ნეირონული ქსელი.

ეს წიგნი ხელოვნურ ნეირონულ ქსელებს ეძღვნება. განხილულია სხვადასხვა ტიპის ქსელი, გარჩეულია მათი სწავლების მეთოდები და გამოყენების არეები. წიგნი მაქსიმალურად სრულად წარმოგვიდგენს ხელოვნური ინტელექტის ლამაზ სამყაროს და მასში ნეირონული ქსელების გამორჩეულ როლს ცხადად დაგვანახებს.

თავი 2. ნეირონი და ნეირონული ქსელი

კომპიუტერის გამოგონებამ ადამიანის ცხოვრება რადიკალურად შეცვალა. რიცხვებზე ოპერაციების გარდა, კომპიუტერმა სწრაფად შეითავსა თითქმის ყველა სფეროსთვის საჭირო ფუნქცია. კომპიუტერის სწრაფქმედების გაზრდად ადამიანს იმდენად მძლავრი ხელსაწყო მოუვლინა მოულოდნელად, რომ მისი რესურსის სრულად გამოყენებისთვის ახლებური ალგორითმების მოფიქრება დღემდე გრძელდება.

მრავალი გამოწვევა არსებობდა კომპიუტერების შემოღების დღიდან საინფორმაციო ტექნოლოგიებში. ერთ-ერთ მიუღწეველ მიზანს გამოსახულების ამოცნობა წარმოადგენდა. ვერ ხერხდებოდა ელემენტარული ობიექტების ამოცნობაც კი. ამ ამოცანას თუ ძველებური მიდგომით განვიხილავთ, უნდა მოვახდინოთ ამოსაცნობი ობიექტის ზუსტი აღწერა და ამ გზით შევეცადოთ მის მოძიებას. ზუსტი აღწერის შედგენა არ არის მარტივი. ვთქვათ, გვინდა მანქანის აღწერის შედგენა. მანქანა ბევრნაირი არსებობს და ყოველი ახალი სურათი შეიძლება



რადიკალურად განსხვავდებოდეს წინასგან.

მიუხედავად ასეთი რთული ამოცანისა, ადამიანი ადვილად ახერხებს ამოცნობას პრაქტიკულად ნებისმიერ სურათზე, მათ შორის სქემატურ ნახატებზეც კი, რომლის მსგავსი მანქანაც ბუნებაში საერთოდ არ მოიძებნება.



ყოველივე ზემოთ თქმულიდან გამომდინარე, ცხადია, რომ ახლებური მიდგომების შემუშავება იყო აუცილებელი.

ახალი ალგორითმების შესამუშავებლად ადამიანებმა ისევ დედა ბუნებას მიმართეს. გადაწყვიტეს, გამოეკვლიათ ტვინის მუშაობა და მისი მსგავსი მეთოდებით ეწარმოებინათ ამოცნობა. ადამიანის ტვინი, ერთ-ერთ ურთულეს მექანიზმს წარმოადგენს, სწორედ მისი საშუალებით მივაღწიეთ განვითარების ასეთ მაღალ დონეს და, ცხადია, ინფორმაციის დამუშავების ამოცანებში, მისი ფუნქციონირების გამოყენება დიდი გარღვევის საწინდარი უნდა გამხდარიყო.

ასეც მოხდა, ადამიანის ტვინის სტრუქტურის მსგავსი მოწყობილობების გამოჩენამ ტექნიკური პროგრესი ახალ საფეხურზე აიყვანა.

ცნობილია, რომ ადამიანის ტვინი შედგება სპეციფიკური ტიპის უჯრედებისგან - ნეირონებისგან. ნეირონები ერთმანეთთან არის დაკავშირებული. გარკვეულწილად გამოკვლეულია უჯრედებს შორის კავშირის მექანიზმიც. საოცარია, მაგრამ თითქმის იდენტური უჯრედების ნაკრები ახერხებს ანალიტიკურ აზროვნებას და აფორმირებს მეხსიერებასაც. ინფორმაცია ნეირონებს გადაეცემა გარე რეცეპტორებიდან (გრძნობის ორგანოებიდან: სმენა, მხედველობა, ყნოსვა, გემო, ვესტიბულარული აპარატი, ...) და სხვა ნეირონებიდან. ნეირონების მიერ დამუშავებული სიგნალების მიხედვით ხდება ადამიანის აქტივობა [neuroscience].




სურათი 1 - ადამიანის ტვინი

ძალიან საინტერესო იქნება თუ დავამზადებთ ტვინის ელექტრონულ მოდელს და მისი საშუალებით ვცდით აზროვნებისთვის დამახასიათებელი თვისებების მოდელირებას.

სწორედ ასეთი მოდელების შესწავლის კვალობაზე ჩამოყალიბდა მეცნიერების მიმართულელება - ნეირონული ქსელები. მიღებულია პრაქტიკული შედეგებიც - ნეირონული ქსელების ბაზაზე აგებული მოწყობილობები უკვე ფართოდ ინერგება ყოფა-ცხოვრებაში. აღსანიშნავია, რომ ადამიანის აზროვნებასთან მიახლოება, ამ სისტემების მიერ, ჯერ ადრეულ სტადიაზეა [human brain project][brain initiative].

§ 1. ბუნებრივი ნეირონი და ნეირონული ქსელი

როგორც ზემოთ აღვნიშნეთ, ბუნებრივი ნეირონი არის ტვინის უჯრედი. ნეირონს სხვა ნეირონებთან აქვს კავშირი. ტვინის ფუნქციონირებისას ერთი ნეირონიდან მეორეს გარკვეული სიგნალები გადაეცემა.



სურათი 2. ბუნებრივი ნეირონული ქსელი

ნეირონს აქვს მრავალი არხი, საიდანაც სხვა ნეირონების სიგნალებს იღებს და აქვს ერთი არხი, საიდანაც საკუთარ სიგნალს გადასცემს სხვებს.


ნეირონები წარმოადგენს არა მხოლოდ აზროვნების საშუალებას - ადამიანის მეხსიერებასაც.

ადამიანის ტვინი 100 მილიარდამდე ნეირონისგან შედგება. ნეირონებს შორის დაახლოებით 60 ტრილიონი კავშირია.


დენდრიტების საშუალებით ნეირონში შედის სიგნალები, ხოლო აქსონის საშუალებით ნეირონიდან გამომავალი სიგნალი სხვა ნეირონებს მიეწოდება. სიგნალების გაცვლა-გამოცვლა ელექტროქიმიური ფორმით ხდება. დამუხტული იონები

დამაკავშირებელ არხებში გადაადგილდებიან და ნეირონის ბირთვში ხვდებიან. თუ ბირთვში სხვადასხვა დენდრიტიდან მოხვედრილი იონების ჯამური მუხტი გარკვეულ ზღვარს გადააჭარბებს, დამუხტული იონები ზვავისებურად გამოიტყორცნება ნეირონის აქსონიდან და სხვა ნეირონებს გადაეცემა. ნეირონის ფუნქციონირების ეს სქემა გამოყენებული საინფორმაციო ტექნოლოგიებში ხელოვნური ნეირონული ქსელების დამზადებისას.

საოცარია, რომ ასეთი ერთნაირი და მარტივი კომპონენტებისგან შედგება ჩვენი ტვინი. მაღალინტელექტუალური ქმედებების შესაძლებლობას, სწორედ, ეს ერთი შეხედვით მარტივი, მოწყობილობა იძლევა.



სურათი 3. ბუნებრივი ნეირონი



სურათი 4. ადამიანის ნერვული სისტემა

ტვინში გარე სენსორებიდან შედის სიგნალები, ეს სიგნალები თავის ტვინის ნეირონებს მიეწოდება. ნეირონებში გარედან შემოსული სიგნალები გადამუშავდება. საბოლოოდ, ნეირონების მიერ ფორმირებული სიგნალი ნერვული დაბოლოებებით გადაეცემა სხეულის სხვადასხვა ორგანოს კონკრეტული მოქმედებების განსახორციელებლად.

ადამიანის სხეული არის დაქსელილი ნერვული არხებით. ზოგიერთი არხით თავის ტვინის ნეირონები იღებენ გარედან შემოსულ ინფორმაციას, ხოლო ზოგი სხეულის მოქმედების განსახორციელებლად არის განკუთვნილი.

ამ თვალსაზრისით თუ განვიხილავთ, ადამიანი არის ძალიან აკურატულად აწყობილი მექანიზმი. ნეიროქირურგებს შეუძლიათ ნერვული დაბოლოებების მიერთება ელექტრულ აპარატურასთან, რაც ხელოვნური პროთეზების დამზადების საშუალებას იძლევა. ასეთი პროთეზი ბუნებრივი კიდურის მსგავსად იმართება ადამიანის ტვინის მიერ და, შესაბამისი სენსორების არსებობის შემთხვევაში, ტვინს კიდურიდან შეგრძნებებიც ეგზავნება.

თავის ტვინის მიერ ინფორმაციის გადამუშავების და სიგნალების ფორმირების პროცესში ძალიან ბევრი ნეირონი მონაწილეობს. ასევე მრავალი ნეირონი ჩართული ინფორმაციის შენახვის პროცესშიც. რამდენიმე ნეირონის მწყობრიდან გამოსვლა აზროვნების პროცესს არ უშლის ხელს, არც მეხსიერების დაკარგვას იწვევს.*

* თანამედროვე გამოკვლევებით დადგენილია, რომ ალკოჰოლის მიღება ასუსტებს ნეირონულ კავშირებს, სწორედ ამის გამო ხდება ადამიანის რეაქციის შენელება. ალკოჰოლის მცირე დოზის მიღების შემდეგ შესუსტებული ნეირონული კავშირები სრულად აღდგება. მცირე რაოდენობით ღვინო ნეირონებს არ აზიანებს და ჯანმრთელობისთვის სასარგებლოც არის. დიდი ოდენობით ალკოჰოლი არა მხოლოდ ნეირონებს აზიანებს, არამედ ადამიანისთვისაც შეიძლება დასრულდეს სასიკვდილო შედეგით.

ზემოთ აღწერილი სქემა ბუნებრივად გვიბიძგებს საინტერესო შეკითხვებზე პასუხის მიებისკენ. ზოგიერთი მოსაზრება ძალიან შორსმომავალიც შეიძლება იყოს, ამიტომ, გთავაზობთ, რომ დიდი სიფრთხილით მოვეკიდოთ ადამიანის ტვინის მოწყობასთან დაკავშირებულ ყველა საკითხს.*

ამ წიგნში ბუნებრივი ნეირონული ქსელის კომპიუტერულ მოდელებს ავაგებთ, განვიხილავთ მათი სწავლების სახეებს და პრაქტიკული დანიშნულებით გამოვიყენებთ.


§ 2. ხელოვნური ნეირონი

ხელოვნური ნეირონი არის ბუნებრივი ნეირონის მსგავსი მოწყობილობა. ასეთ მოწყობილობებს ერთმანეთთან აერთებენ და იღებენ ხელოვნურ ნეირონულ ქსელს. სხვადასხვა ტიპის ნეირონულ ქსელებს სხვადასხვა პრაქტიკული ამოცანის გადასაწყვეტად იყენებენ.

როგორც წინა პარაგრაფში აღვწერეთ, ბუნებრივ ნეირონს დენდრიტების საშუალებით მიეწოდება დამუხტული იონები. დამუხტული იონები ნეირონის ბირთვში იყრის თავს, თუმცა აქსონის საშუალებით მომენტალურად არ ხდება მათი გამოსვლა ნეირონიდან. აქსონში იონების გამოტყორცნა მოხდება ერთბაშად, მხოლოდ იმ შემთხვევაში, თუ ნეირონში არსებული ჯამური მუხტი გარკვეულ ზღვარს გადააჭარბებს.

შევქმნათ ბუნებრივი ნეირონის მათემატიკური მოდელი, ანუ ხელოვნური ნეირონი, რომელსაც ექნება ბუნებრივის მსგავსი მექანიზმი.

ხელოვნური ნეირონი (შემდგომში მას უბრალოდ ნეირონს ვუწოდებთ) არის მოწყობილობა, რომელსაც აქვს რამდენიმე შესასვლელი და ერთი გამოსასვლელი. შესასვლელზე მოდებული სიგნალები ნეირონის მიერ გადამუშავდება და გამოსასვლელზე აღიმკრება გამომავალი სიგნალი.



სურათი 5. ხელოვნური ნეირონი

ხელოვნურ ნეირონში შემავალი x_1, x_2, \dots, x_n რიცხვების მიხედვით ხდება გამომავალი y მნიშვნელობის გამოთვლა, ანუ ეს დამოკიდებულება n ცვლადის ფუნქციას წარმოადგენს.

$$y = f(x_1, x_2, \dots, x_n)$$

როგორც წესი, ეს ფუნქცია შემდეგი სახისაა (იმიტომ, რომ ძალიან ჰგავს ბუნებრივი ნეირონის მოქმედების პრინციპს):

$$y = \varphi \left(\sum_{i=1}^n x_i w_i - \theta \right)$$

w_i -ს ნეირონის წონებს, ხოლო θ -ს ზღურბლს ეძახიან. $w_i, \theta \in \mathbb{R}$


φ ფუნქციას აქტივაციის ფუნქცია ეწოდება. აქტივაციის ყველაზე გავრცელებული ფუნქციებია:

sgn - რიცხვის ნიშანი

σ - ლოგისტიკური ფუნქცია $\sigma(t) = \frac{1}{1+e^{-t}}$

th - ჰიპერბოლური ტანგენსი

ReLU - $f(t) = \max(0, t)$




განვიხილოთ ნეირონის გამოყენების მაგალითი: მოცემულია 5×8 მატრიცა, სადაც თითოეულ უჯრაში შეიძლება ეწეროს 1 ან

* თუ ადამიანის ტვინი ზემოთ აღწერილი სქემით ფუნქციონირებს და მეხსიერება ნეირონებში ინახება, მაშინ ახალი ნეირონების ტვინში ხელოვნურად ჩანერგვით უნდა შეგვეძლოს ადამიანის მეხსიერების გადანერგვა, ანუ ხელოვნური მოგონებების შექმნა.

ადამიანის ტვინზე ექსპერიმენტების ჩატარება ეთიკურ და სხვა ზნეობრივ საკითხთან არის დაკავშირებული, ამიტომ ანალოგიური ექსპერიმენტები ვირთავებზე ტარდება ხოლმე. MIT-ის ლაბორატორიაში ჩატარეს ზემოთ აღწერილი ექსპერიმენტი და წარმატებით შეძლეს ხელოვნური მოგონებების ჩანერგვა ვირთავისთვის [false memories].

0. 1 ნიშნავდეს უჯრის შავად შეღებვას 0 - თეთრად. ასეთნაირად მატრიცაში შეიძლება ჩავხატოთ გამოსახულებები. მატრიცის თითო უჯრა მიეკუთვნება 40 შესასვლელიანი ნეირონის თითო შესასვლელს. ნეირონის აქტივაციის ფუნქციაა sgn .



ჩვენს მიზანს წარმოადგენს ნეირონის ისეთი w_i წონების და θ ზღურბლის მოძებნა რომ, რომ მატრიცაში ჩახატული კენტი ციფრის დროს ნეირონის გამოსასვლელზე გამოვიდეს 1, ხოლო ლუწის დროს - 0.

ეს ამოცანა მეტნაკლები წარმატებით არის დაძლევადი. ამ ამოცანის ნაწილობრივმა დაძლევამ ასეთი მარტივი მეთოდებით, დიდი იმედები გააჩინა ნეირონების გამოყენების თვალსაზრისით 1957 წელს [perceptron].

x_1	x_2	y
0	0	0
0	1	1
1	0	1
1	1	0

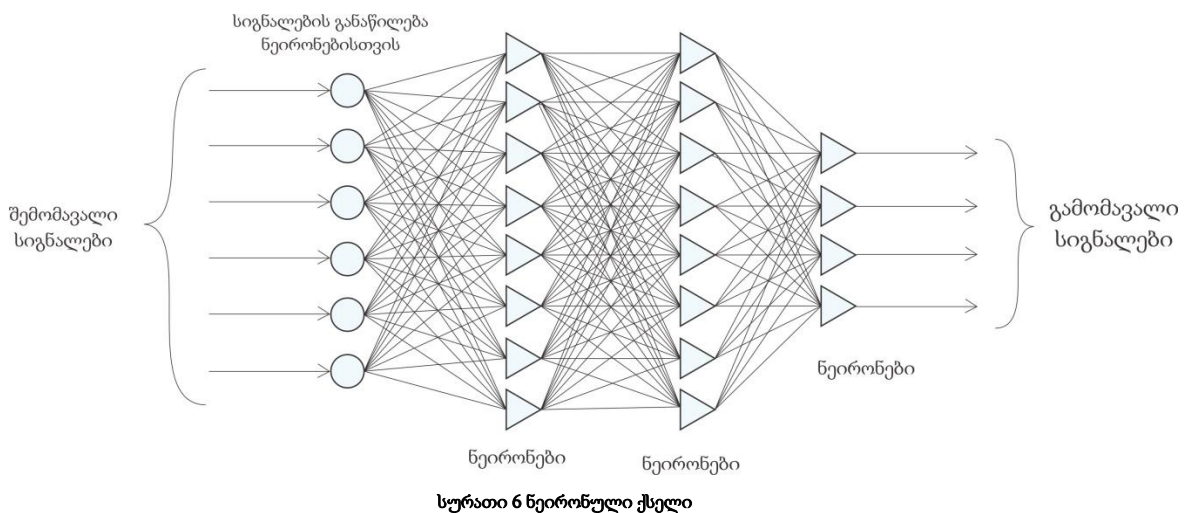
1969 წელს ცნობილმა მეცნიერმა [minsky] დაამტკიცა, რომ ზემოთ მოყვანილი ნეირონის შესაძლებლობები საკმაოდ შეზღუდულია. კერძოდ, დამტკიცდა, რომ ნეირონს არ ძალუძს XOR ორობითი ფუნქციის განხორციელება. ეს ფაქტი დამთრგუნველი აღმოჩნდა მეცნიერებისთვის და დიდი ხნით გადაიდო ნეირონული ქსელების განვითარება. შეფერხების მიუხედავად, ცალკეული მეცნიერები აგრძელებდნენ მუშაობას და, საბოლოო ჯამში, მაინც მოახერხეს დადებითი შედეგების მიღება.

§ 3. ხელოვნური ნეირონული ქსელი

ხელოვნური ნეირონული ქსელი არის ბიოლოგიური ქსელის მოდელი, რომელიც წარმოადგენს ერთმანეთზე მიერთებული ნეირონების ერთობლიობას და გამოიყენება მის შესასვლელებსა და გამოსასვლელებს შორის რთული ურთიერთდამოკიდებულების დასამყარებლად.

არსებობს მრავალი ტიპის ნეირონული ქსელი.

- სრულად ბმული ქსელები (Fully Connected Neural Networks)
- ღრმა ნეირონული ქსელები (Deep Neural Networks)
- Convolutional ნეირონული ქსელები (Convolutional Neural Networks)
- რეკურენტული ნეირონული ქსელები (Recurrent Neural Networks)
- ავტოენკოდერები (autoencoder)
- თვითორგანიზებადი რუკები (self-organizing map)



გამომავალ სიგნალებს, ხანდახან, ამოცნობილ სიგნალებს ან ქსელის გადაწყვეტილებას უწოდებენ. ნეირონული ქსელის მიზანი სწორი გადაწყვეტილებების მიღებაა. სწორი გადაწყვეტილებების მისაღებად საჭიროა ქსელის ტოპოლოგია და თითოეული ნეირონის პარამეტრები ოპტიმალურად შევარჩიოთ. ქსელის ტოპოლოგიის და ნეირონების პარამეტრების ოპტიმალურად შერჩევის პროცესს ნეირონული ქსელის სწავლებას უწოდებენ.

დღეს არსებულ ყველაზე რთულ ქსელებს შეუძლიათ წარმატებით გაუმკლავდნენ ისეთ ამოცანებს როგორცაა

- ფუნქციის აპროქსიმაცია
- რეგრესიული ანალიზი
- რიცხვით მიმდევრობაში კანონზომიერების აღმოჩენა
- მონაცემთა კლასიფიკაცია
- მონაცემთა ფილტრაცია, კლასტერიზაცია,
- მონაცემთა კომპრესია


შესაბამისად, საკმაოდ ფართოა ნეირონული ქსელების პრაქტიკაში გამოყენების არეალიც:

- სამედიცინო დიაგნოსტიკა
- სამხედრო აღჭურვილობა
- სახეტა ამოცნობა
- დიდი მოცულობის ინფორმაციის კატეგორიზაცია
- კრედიტების გაცემის მიზანშეწონილობის შეფასება
- ბირჟების პროგნოზირება
- ტექსტების დამუშავება
- რობოტოტექნიკა

თავი 3. სრულად ბმული ნეირონული ქსელი

განვიხილოთ ერთ-ერთი ყველაზე გავრცელებული და ეფექტური ნეირონული ქსელი - სრულად ბმული ქსელი. ამ ქსელში ნეირონები რამდენიმე შრეზეა განლაგებული.

- პირველი შრე ნეირონების შესასვლელში შემავალი სიგნალების განაწილებისთვის გამოიყენება. ამ შრეში ნეირონები არ გვაქვს. ყველა შესასვლელი სიგნალი მიეწოდება მეორე შრეზე განლაგებულ ყველა ნეირონს.
- მეორე და ყოველ შემდგომ შრეს, ბოლოს გარდა, ფარულ შრეს უწოდებენ. ფარულ შრეებში არის განლაგებული ნეირონები. ფარული შრის ყველა ნეირონის გამოსასვლელი მიეწოდება შემდეგი შრის ყველა ნეირონს.
- ბოლო შრეზე განლაგებული ნეირონების გამომავალი სიგნალები წარმოადგენს ნეირონული ქსელის გამოსასვლელს.



სურათი 7. სრულად ბმული ნეირონული ქსელი

სრულად ბმული ნეირონული ქსელის დანიშნულებაა შემავალი სიგნალების მიხედვით, წინასწარ მოცემული გამომავალი სიგნალების გენერაცია. ფაქტობრივად, მოცემული გვაქვს (x_1, x_2, \dots, x_p) შემავალი და (d_1, d_2, \dots, d_q) სასურველი გამომავალი სიგნალების წყვილების N ელემენტარული სიმრავლე. თითოეულ წყვილს სასწავლო ნიმუშს უწოდებენ, ხოლო მათ სიმრავლეს სასწავლო ნიმუშების სიმრავლეს.

ქსელი იდეალურად იქნება შედგენილი, თუ მასზე ყოველი სასწავლო ნიმუშის (x_1, x_2, \dots, x_p) შესასვლელი სიგნალების მოდებისას, გამოსასვლელზე მიღებული (y_1, y_2, \dots, y_q) გამომავალი სიგნალები ამავე ნიმუშის (d_1, d_2, \dots, d_q) სასურველ გამომავალ სიგნალებს დაემთხვევა.

ნეირონული ქსელი იდეალური შეიძლება არ იყოს, თუმცა, მისი შედეგები ახლოს იყოს სასურველთან. ასეთ დროს, აქტუალობას იძენს ქსელის ეფექტურობის შეფასების კრიტერიუმის არსებობა. ამ კრიტერიუმს ქსელის შეცდომის ენერჯია ეწოდება.

§ 1. შეცდომის ენერჯია (შეხიროს კვადრატთა მეთოდი)

შეცდომის ენერჯია ნეირონული ქსელის ეფექტურობის მახასიათებელია.

ვთქვათ, მოცემულია სასწავლო ნიმუშების N ელემენტარული სიმრავლე. ავიღოთ n -ური სასწავლო ნიმუში და მისი (x_1, x_2, \dots, x_p) ვექტორი მოვდოთ ნეირონულ ქსელს. გამოვთვალოთ ნეირონული ქსელის გამომავალი ვექტორი (y_1, y_2, \dots, y_q) და ვნახოთ რამდენად ახლოა სასწავლო ნიმუშის (d_1, d_2, \dots, d_q) ვექტორთან. ადვილი გამოსათვლელია გამომავალი შრის ნეირონების შეცდომები, $e_j(n)$ -ით აღვნიშნოთ n -ური სასწავლო ნიმუშის ამოცნობისას j -ური ნეირონის გამოსასვლელზე არსებული ცდომილება. ცხადია $e_j(n) = d_j(n) - y_j(n)$. მთელი ნიმუშის ამოცნობისას დაშვებული შეცდომა ასეთნაირად შეიძლება შევაფასოთ:

$$\mathcal{E}(n) = \frac{1}{2} \sum_{j \in V} e_j^2(n). \quad (1)$$

ამ ფორმულაში არის გამომავალი შრის ნეირონების ცდომილებების კვადრატები შეკრებილი და წინ მიწერილი აქვს კოეფიციენტი $\frac{1}{2}$. კოეფიციენტი ფორმულის არსს უცვლელს ტოვებს და შემდგომ გამოთვლებში შეგვიწყობს ხელს. გამომავალი შრის ნეირონების ცდომილებები კვადრატში აყვანილია იმიტომ, რომ მათი პირდაპირი შეკრება დადებითი და უარყოფითი ცდომილებების გაბათილებას გამოიწვევდა, რაც საერთო ცდომილების არსს დაკარგავდა. კვადრატების მაგივრად მოდულების აღებაც არ იქნებოდა ურიგო იდეა, თუმცა გამოთვლებისთვის (მაგალითად გაწარმოებისთვის) მოდული ნაკლებად კომფორტული ოპერაციაა.

$\mathcal{E}(n)$ წარმოადგენს ნეირონული ქსელის ცდომილებას n -ური სასწავლო ნიმუშისთვის.

ნეირონული ქსელის ცდომილება უნდა გამოვთვალოთ ყველა სასწავლო ნიმუშისთვის და ასეთნაირად შევაფასოთ ქსელის საშუალო ეფექტურობა:

$$\mathcal{E} = \frac{1}{N} \sum_{n=1}^N \mathcal{E}(n). \quad (2)$$

\mathcal{E} წარმოადგენს ნეირონული ქსელის შეცდომის ენერგიას. შეცდომის ენერგია არსებითად არის დამოკიდებული სასწავლო ნიმუშებს სიმრავლეზე. სწორედ სასწავლო ნიმუშების ამოცნობის ეფექტურობას აფასებს შეცდომის ენერგია. შეცდომის ენერგიის საშუალებით ნეირონული ქსელის ეფექტურობის შეფასების მეთოდს უმცირეს კვადრატთა მეთოდსაც უწოდებენ.

§ 2. სრულად ბმული ქსელის სწავლება (დელტა წესი)

ამ პარაგრაფში მოყვანილი მეთოდი ზოგადია და გამოდგება მრავალი ტიპის ნეირონული ქსელისთვის.

სასწავლო ნიმუშების სწორად ამოცნობისთვის, საჭიროა ნეირონების პარამეტრების შერჩევა. ამ კონკრეტულ შემთხვევაში ქსელის ტოპოლოგიას არ შევხებით, შრეების რაოდენობას და თითოეულ მათგანში ნეირონების რიცხვს თავიდანვე დავადგენთ და აღარ შევცვლით. თითოეული ნეირონის გადაწყვეტილება შემდეგნაირად მიიღება $y = \varphi(\sum_{i=1}^m x_i w_i - \theta)$. ეს ფორმულა ახალი აღნიშვნებით უფრო კომპაქტურად ჩაიწერება:

$$y = \varphi \left(\sum_{i=1}^{m+1} x_i w_i \right)$$

აქ შემოღებული გვაქვს $x_{m+1} \equiv -1$ და $w_{m+1} \equiv \theta$ ფორმალური აღნიშვნები.

ქსელის ეფექტურობა, ანუ \mathcal{E} შეცდომის ენერგია, დამოკიდებულია ყველა ნეირონის w წონაზე. ფაქტობრივად, \mathcal{E} წარმოადგენს ფუნქციას, რომელსაც პარამეტრებად w წონები აქვს. $\mathcal{E} = \mathcal{E}(w_{11}, w_{12}, \dots, w_{21}, w_{22}, \dots, w_{31}, w_{32}, \dots)$.

\mathcal{E} ფუნქციის მნიშვნელობის გამოთვლა კონკრეტულ w წერტილში (w წერტილი მრავალგანზომილებიანია და კოორდინატებად ყველა ნეირონის წონები აქვს) საკმაოდ მარტივი პროცესია, საამისოდ უნდა ვიცოდეთ:

1. ნეირონული ქსელის შრეების რაოდენობა და ნეირონების რიცხვი თითოეულ შრეზე (ანუ ქსელის ტოპოლოგია).
2. სასწავლო ნიმუშების სიმრავლე.

ჩვენი მიზანი არის ისეთი w წონების მოძებნა, რომლების დროსაც \mathcal{E} ფუნქცია მინიმალურ მნიშვნელობას მიიღებს. ამ პროცესს ფუნქციის მინიმიზაცია ეწოდება.

არსებობს მრავალი ცვლადის ფუნქციის მინიმიზაციის სტანდარტული ალგორითმები. \mathcal{E} ფუნქციის მნიშვნელობის გამოთვლისთვის საჭირო ყველა ფორმულა არის სათანადოდ შერჩეული, ადვილია მათი გაწარმოება, ამიტომ, მინიმიზაციისთვის ავირჩიოთ უკუ-გრადიენტის მეთოდი.

სწავლების პროცესის განმავლობაში, ჩვენ მოვახდენთ წონების მოდიფიცირებას ნაბიჯ-ნაბიჯ, ისე, რომ მოდიფიცირებული ქსელის შეცდომის ენერგია სულ უფრო და უფრო მცირდებოდეს.

ავიღოთ ერთ-ერთი სასწავლო ნიმუში (სწორად არის დასაწერი Batch მეთოდი. უნდა ვახსენო ეპოქაც) და გამოვთვალოთ ნეირონული ქსელის შეცდომის ენერჯია ამ ნიმუშის ამოცნობისას. შევეცადოთ ისე შევეცვალოთ ნეირონების წონები, რომ ეს ენერჯია შემცირდეს.

შემოვიღოთ რამდენიმე აღნიშვნა, რომელიც შემდგომ გამოთვლებს გაგვიმარტივებს:

- i, j და k ინდექსებით ნეირონები გადავნიშნოთ. იმ ნეირონს, რომელზეც უშუალოდ გვექნება საუბარი, j ინდექსი მივაკუთვნოთ. i ინდექსი ეკუთვნოდეს j ნეირონის წინა შრეში მოთავსებულ ნეირონს, ხოლო k ინდექსი j ნეირონის შემდგომ შრეში მოთავსებულ ნეირონს. ანუ, ჯერ არის განთავსებული შრე, რომლის ნეირონებს i ინდექსი აქვთ, შემდეგ მოდის შრე j ინდექსით და მის შემდეგ შრე k ინდექსით.
- გვაქვს სასწავლო ნიმუშების N ელემენტიანი სიმრავლე, რომლითაც ვაწარმოებთ ქსელის სწავლებას. n -ით აღვნიშნოთ n -ური სასწავლო ნიმუში.
- $d_j(n)$ -ით აღვნიშნოთ n -ური სასწავლო ნიმუშის სწავლებისას j -ური ნეირონის გამოსასვლელზე სასურველი მნიშვნელობა.
- $y_j(n)$ -ით აღვნიშნოთ n -ური სასწავლო ნიმუშის სწავლებისას j -ური ნეირონის გამოსასვლელზე არსებული მნიშვნელობა.
- $w_{ji}(n)$ -ით აღვნიშნოთ n -ური სასწავლო ნიმუშის სწავლებისას i -ური და j -ური ნეირონების შემაერთებელი არხის წონა. ამ ეტაპზე ამ წონის კორექციის სიდიდე $\Delta w_{ji}(n)$ -ით აღვნიშნოთ.
- $v_j(n)$ -ით აღვნიშნოთ $\sum_{i=1}^{m+1} x_i w_i$ სიდიდე, რომელიც მე-10 ფორმულაში აქტივაციის ფუნქციის არგუმენტს წარმოადგენს. უნდა აღინიშნოს, რომ ჯამში გამოვიყენეთ i ინდექსი, თუმცა მას საერთო არაფერი აქვს ნეირონის i ინდექსთან. შემდგომ ფორმულებში ამ ორი განსხვავებული სიტუაციის ფორმულების აღრევა არ მოხდება, ამიტომაც აღარ შემოვიღეთ ახალი სიმბოლო ამ სტანდარტული აღნიშვნისთვის.
- $\mathcal{E}(n)$ -ით აღვნიშნოთ n -ური სასწავლო ნიმუშის ამოცნობისას არსებული ცდომილების ენერჯია. \mathcal{E} -თი აღვნიშნოთ ყველა სასწავლო ნიმუშის გასაშუალოებული ცდომილება, ანუ ქსელის შეცდომის ენერჯია.
- $e_j(n)$ -ით აღვნიშნოთ n -ური სასწავლო ნიმუშის ამოცნობისას j -ური ნეირონის გამოსასვლელზე არსებული ცდომილება. ეს ცდომილება გამომავალი შრის ნეირონებისთვის შემდეგნაირად გამოითვლება $e_j(n) = d_j(n) - y_j(n)$.

როგორც ზემოთ აღვნიშნეთ, სწავლების პროცესი ნაბიჯ-ნაბიჯ მიმდინარეობს. თითოეულ ნაბიჯზე გამოითვლება $w_{ji}(n)$ წონის კორექცია და მისი საშუალებით მიიღება ახალი წონა.

$$w_{ji}^{\text{ახალი}}(n) = w_{ji}^{\text{ძველი}}(n) + \Delta w_{ji}^{\text{ძველი}}(n)$$

წონის კორექცია შემდეგნაირად უნდა გამოვთვალოთ:


$$\Delta w_{ji}(n) = -\mu \frac{\partial \mathcal{E}(n)}{\partial w_{ji}(n)},$$

სადაც μ დადებითი მცირე სიდიდეა $0 < \mu < 1$. μ -ს სწავლების სიჩქარე ეწოდება.

ფაქტობრივად, ჩვენ ავიღეთ შეცდომის ენერჯიის გრადიენტის საპირისპირო მიმართულება და ამ მიმართულებით მოვახდინეთ წონის კორექცია. ეს სწორედ შეცდომის ენერჯიის მინიმიზაციისკენ მიმართული ნაბიჯია.

გამომავალი შრის სწავლება

პირველ რიგში, ეს პროცესი განვიხილოთ გამომავალი შრის ნეირონებისთვის, რადგან მათი ცდომილება ადვილად გამოითვლება.



სურათი 8. გამომავალი შრის ნეირონის სწავლება

ჩვენ მიერ შემოღებული აღნიშვნების თანახმად გვექნება

$$\Delta w_{ji}(n) = -\mu \frac{\partial \mathcal{E}(n)}{\partial w_{ji}(n)} = -\mu \frac{\partial \mathcal{E}(n)}{\partial v_j(n)} \frac{\partial v_j(n)}{\partial w_{ji}(n)}$$

შემოვიღოთ აღნიშვნა

$$\delta_j(n) = -\frac{\partial \mathcal{E}(n)}{\partial v_j(n)} = -\frac{\partial \mathcal{E}(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} = e_j(n) \varphi'_j(v_j(n)). \quad (3)$$

წონის კორექციისთვის საბოლოოდ მივიღებთ


$$\Delta w_{ji}(n) = \mu \delta_j(n) y_i(n). \quad (4)$$

δ -ს ლოკალურ გრადიენტს უწოდებენ, ხოლო (4) ფორმულას დელტა წესს ეძახიან.

აქ კიდევ ერთხელ აღვნიშნოთ, რომ მე-3 ფორმულის გამოყვანისას, ჩვენ არსებითად გავითვალისწინეთ ის გარემოება, რომ j -ური ნეირონი გამომავალ შრეში იყო.

ფარული შრის სწავლება

ნეირონი ფარულ შრეში რომ ყოფილიყო მე-3 ფორმულას სხვანაირი სახე ექნებოდა. განვიხილოთ შემთხვევა, როცა j -ური ნეირონი ფარულ შრეშია და ამ შრეს უშუალოდ მოსდევს გამომავალი ნეირონების შრე.



სურათი 9. ფარული შრის ნეირონის სწავლება

ამ შემთხვევისთვის გვექნება

$$\begin{aligned} \delta_j(n) &= -\frac{\partial \mathcal{E}(n)}{\partial v_j(n)} = -\frac{\partial \mathcal{E}(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} = -\frac{\partial \mathcal{E}(n)}{\partial y_j(n)} \varphi'_j(v_j(n)) = \\ &= -\frac{\partial \left(\frac{1}{2} \sum_{k \in V} e_k^2(n) \right)}{\partial y_j(n)} \varphi'_j(v_j(n)) = -\sum_{k \in V} e_k(n) \frac{\partial e_k(n)}{\partial y_j(n)} \cdot \varphi'_j(v_j(n)) = \end{aligned}$$

$$= \sum_{k \in V} e_k(n) \frac{\partial e_k(n)}{\partial v_k(n)} \frac{\partial v_k(n)}{\partial y_j(n)} \cdot \varphi'_j(v_j(n)) \quad (5)$$

გავითვალისწინოთ, რომ k -ური ნეირონი არის გამომავალი შრის ნეირონი

$$\frac{\partial e_k(n)}{\partial v_k(n)} = \frac{\partial (d_k(n) - y_k(n))}{\partial v_k(n)} = \frac{\partial (d_k(n) - \varphi_k(v_k(n)))}{\partial v_k(n)} = -\varphi'_k(v_k(n))$$

და მიღებული გამოსახულება ჩავსვათ მე-5 ფორმულაში.

ასევე გავითვალისწინოთ, რომ

$$\frac{\partial v_k(n)}{\partial y_j(n)} = \frac{\partial (\sum_{l=1}^{m+1} w_{kl}(n) y_l(n))}{\partial y_j(n)} = w_{kj}(n)$$

და ეს მნიშვნელობა ჩავსვათ მე-5 ფორმულაში. საბოლოოდ, ფარული შრის ნეირონისთვის გვექნება შემდეგი გამოსახულება

$$\delta_j(n) = \varphi'_j(v_j(n)) \sum_{k \in V} \delta_k(n) w_{kj}(n). \quad (6)$$

მოკლედ შევაჯამოთ მიღებული შედეგი:

უკუგავრცელების ქსელის სწავლება სასწავლო ნიმუშების სწავლებით მიმდინარეობს. თითოეული ნიმუშის მოდების შემდეგ ხდება ქსელის მიერ ამ ნიმუშის ამოცნობა. ამოცნობილი სიდიდეები დარდება სასურველ სიდიდეებთან და ხდება ქსელის შეცდომის ენერჯის გამოთვლა.

ამის შემდეგ, ხდება შეცდომის ენერჯის შემცირებისკენ მიმართული კორექციები ნეირონის წონებზე. ეს კორექცია შემდეგნაირად გამოისახება

$$\Delta w_{ji}(n) = \mu \delta_j(n) y_i(n). \quad (1)$$

δ სიდიდე (მას ლოკალურ გრადიენტსაც უწოდებენ) სხვადასხვანაირად გამოითვლება გამომავალი შრის და ფარული შრის ნეირონებისთვის, კერძოდ, გამომავალი შრის ნეირონებისთვის

$$\delta_j(n) = e_j(n) \varphi'_j(v_j(n)), \quad (2)$$

ხოლო ფარული შრის ნეირონებისთვის (დამტკიცების გარეშე აღვნიშნოთ, რომ ფორმულას შიდა ფარული შრეებისთვისაც იგივე სახე აქვს)

$$\delta_j(n) = \varphi'_j(v_j(n)) \sum_{k \in V} \delta_k(n) w_{kj}(n). \quad (3)$$

ნეირონული ქსელის სწავლების ამ მეთოდს დელტა წესი ჰქვია, მას ასევე უკუ გრადიენტის მეთოდსაც უწოდებენ.

სწავლების მეთოდის გაუმჯობესების მიზნით, წონის კორექციისას წინა კორექციასაც ითვალისწინებენ და მე-17 ფორმულა შემდეგ სახეს იღებს

$$\Delta w_{ji}(n) = \alpha \Delta w_{ji}(n-1) + \mu \delta_j(n) y_i(n). \quad (4)$$

α -ს სწავლების მომენტი ეწოდება. იგი მცირე სიდიდეა, $0 < \alpha < 1$.

ნეირონული ქსელის სწავლების წარმატება მრავალი ფაქტორით არის განპირობებული.

ცხადია, სწავლების μ სიჩქარის და სწავლების α მომენტის სწორ შერჩევაზე დიდწილად არის დამოკიდებული სწავლების ეფექტურობა. ასევე გადამწყვეტი როლი ენიჭება სასწავლო წყვილების დიაპაზონის სწორ შერჩევას. დიდი მნიშვნელობა აქვს ნეირონული ქსელის კონფიგურაციის, შრეების ოდენობის და შრეებში ნეირონების ოდენობის ოპტიმალურად განსაზღვრასაც.

თავი 4. კონვოლუციური ნეირონული ქსელი (Convolutional Neural Network)

პრაქტიკული ამოცანების წარმატებით გადაწყვეტა შესაძლებელი გახდა ღრმა ნეირონული ქსელების საშუალებით. ღრმა ნეირონული ქსელები გამოირჩევა ფარული შრეების სიმრავლით და სწავლების ოპტიმიზირებული ალგორითმებით.

ღრმა ქსელების საშუალებით განსაკუთრებით ეფექტურად ხდება გრაფიკული გამოსახულებების ამოცნობა. გრაფიკული გამოსახულებების ამოცნობისთვის იყენებენ Convolutional ქსელებს.


§ 1. კონვოლუციური ქსელის ტოპოლოგია

აქამდე შესწავლილი სრულად ბმული ქსელი ნებისმიერ ამოცანაში გამოდგება, თუმცა, სწორედ ეს ზოგადობა ამძიმებს ქსელს და არაეფექტურს ხდის კონკრეტული ამოცანების დამოუკიდებლად გადაწყვეტისთვის.

გრაფიკული გამოსახულების ამოცნობის მიზნით შემუშავებულია სპეციფიკური ქსელი, რომელსაც Convolutional ქსელს უწოდებენ [convolutional networks].

Convolutional ქსელი მრავალი შრისგან შედგება. შრეებს სხვადასხვა დანიშნულება და მოქმედების პრინციპი აქვს.

Convolutional ქსელი შემდეგი სტრუქტურისაა:



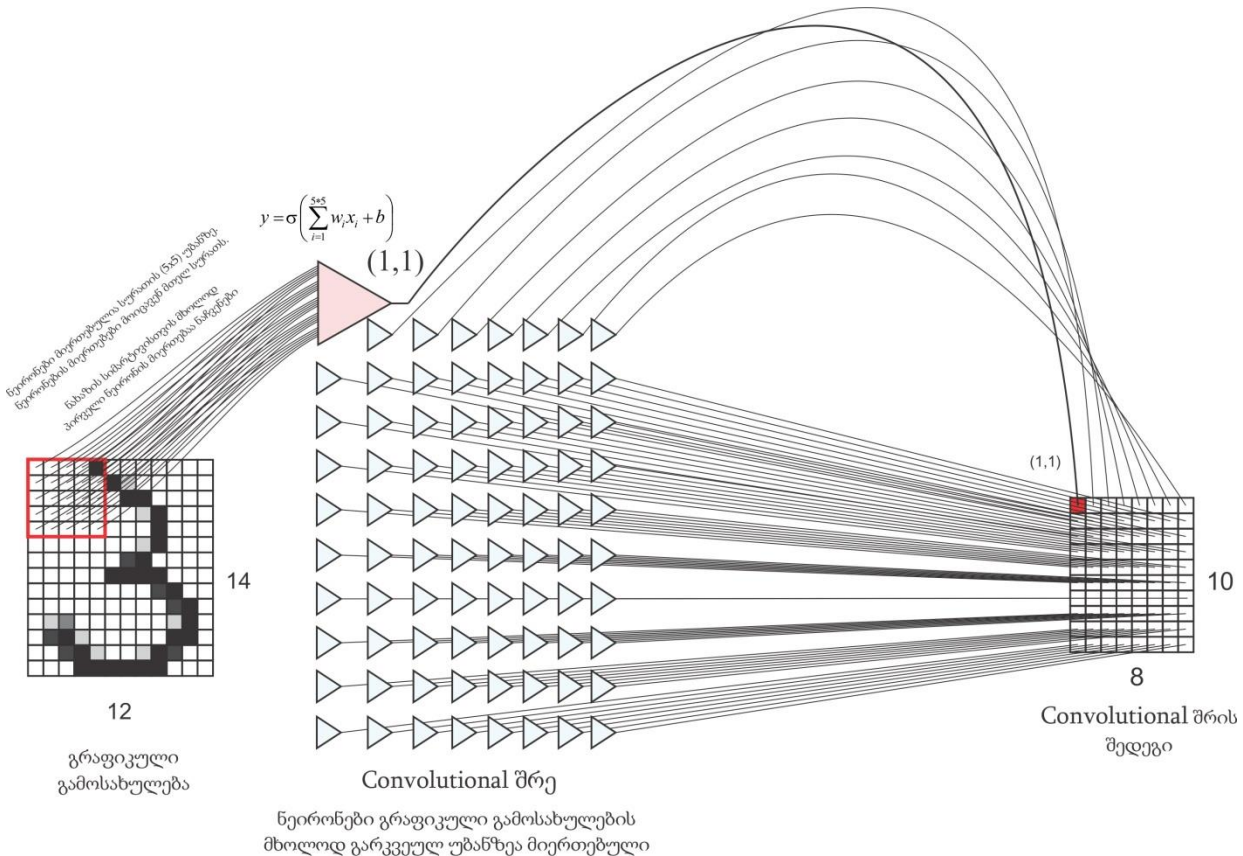
სურათი 10 – Convolutional ქსელი

გრაფიკული გამოსახულება, პირველ ეტაპზე, Convolutional შრეების ნაკრებით მუშავდება. თითოეული Convolutional შრის გამოსასვლელიები მიერთებულია ნეირონების Pooling შრეზე. თითოეული Pooling შრე, თავის მხრივ, გადის რამდენიმე Convolutional შრის დამუშავებას (Convolutional და Pooling შრეების ეს მიმდევრობა რამდენჯერმე შეიძლება მეორდებოდეს) და, საბოლოოდ ჯამში, ქსელის ბოლოს, არის სრულად ბმული ნეირონული ქსელი, რომელიც უშუალოდ აფორმირებს ქსელის გადაწყვეტილებას.

§ 2. Convolutional შრე (Convolutional Layer)


Convolutional შრე შედგება იგივე ტიპის ნეირონებისგან, რაც სრულად ბმული ქსელის შესწავლისას განვიხილეთ. განსხვავება მდგომარეობს მხოლოდ იმაში, რომ საწყისი გრაფიკული გამოსახულების ყველა წერტილი არ არის დაკავშირებული Convolutional შრის თითოეულ ნეირონთან. ნეირონები, გრაფიკული გამოსახულების მხოლოდ მცირე უბანთან (როგორც წესი მართკუთხა ფორმის მატრიცასთან) არის შეერთებული.

ნეირონების მართკუთხა უბნები მიმდევრობით არის განლაგებული საწყის გრაფიკულ გამოსახულებაზე და მთლიანად მოიცავს მას. ასეთნაირად განლაგებული ნეირონების გამოსახულებებიდან მიღებული სიგნალები გეომეტრიულად თვალსაჩინო გამოსახულებებს იძლევა, ამიტომ მათ ისევ მატრიცის სახით გამოსახავენ და არა ისე, როგორც სრულად ბმულ ნეირონულ ქსელშია მოყვანილი.



სურათი 11 – Convolutional შრის მოქმედების პრინციპი

სურათზე მოყვანილ მაგალითში დასამუშავებელი გრაფიკული გამოსახულება 12x14 ზომის მატრიცაში ჩახატული. გამოსახულების წერტილი (ანუ მატრიცის ერთი ელემენტი) არის რიცხვი, რომელიც შავ-თეთრი ფერის კოდს აღნიშნავს. Convolutional შრის თითოეულ ნეირონს 25 შესასვლელი აქვს. ეს შესასვლელები გრაფიკული გამოსახულების მართკუთხა უბანზეა მიერთებული. პირველი ნეირონი მიერთებულია გრაფიკული გამოსახულების უკიდურეს ზემოთა და მარცხენა 5x5 არეზე. მეორე ნეირონი მიერთებულია 5x5 არეზე, რომელიც ერთი უჯრით მარჯვნივ მდებარეობს პირველი ნეირონის არესთან შედარებით. სურათზე მეორე და შემდგომი ნეირონების შეერთებების არეები აღარ არის ნაჩვენები ნახაზის გამარტივების მიზნით. გრაფიკული გამოსახულების მატრიცა მთლიანად არის დაფარული Convolutional შრის ნეირონებთან შეერთებებით.



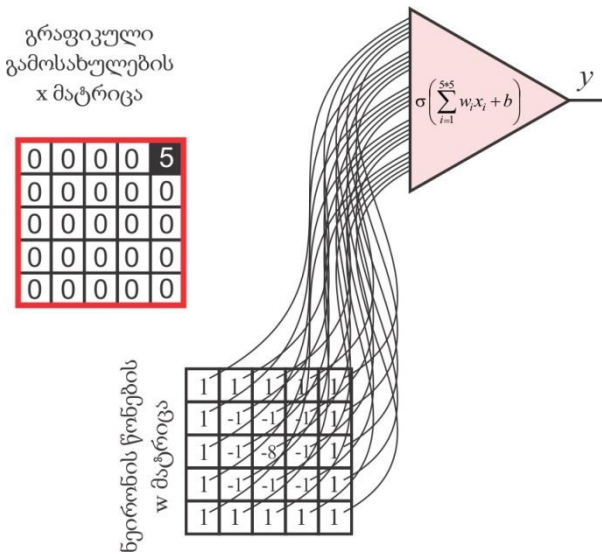
12

საზოგადოდ, მეზობელი ნეირონების მატრიცებს შორის ერთ უჯრაზე მეტი შეიძლება იყოს წამკრა. ამ პარამეტრს stride-ს უწოდებენ. საწყისი გამოსახულების კიდეები შეიძლება 0-ებით შევავსოთ (ანუ დავამატოთ ნულოვანი სვეტები და სტრიქონები), თუ გვსურს, რომ გამოსახულების ყველა უბანზე ხვდებოდეს Convolutional შრის ნეირონების შეერთების მატრიცების ცენტრები.

Convolutional შრის თითოეული ნეირონი შემდეგი ფორმულის საშუალებით ანგარიშობს გამოსასვლელ სიგნალს:

$$y = \sigma \left(\sum_{i=1}^{5 \times 5} x_i w_i + b \right)$$

ფაქტობრივად ხდება გრაფიკული გამოსახულებისა და ნეირონის წონების მატრიცების შესაბამისი წევრების ნამრავლების შეკრება, b -ს დამატება და აქტივაციის ფუნქციის მოდება.



Convolutional შრის ნეირონების გამოსასვლელ სიგნალებს მატრიცის ფორმით ალაგებენ იგივე განლაგებით, რა განლაგებითაც არის შეერთებული გრაფიკულ გამოსახულებასთან ნეირონის არეები. შედეგად, ზემოთ მოყვანილი მაგალითისთვის მიიღება 8x10 ზომის მატრიცა, რომელსაც შემდეგი სახე აქვს.

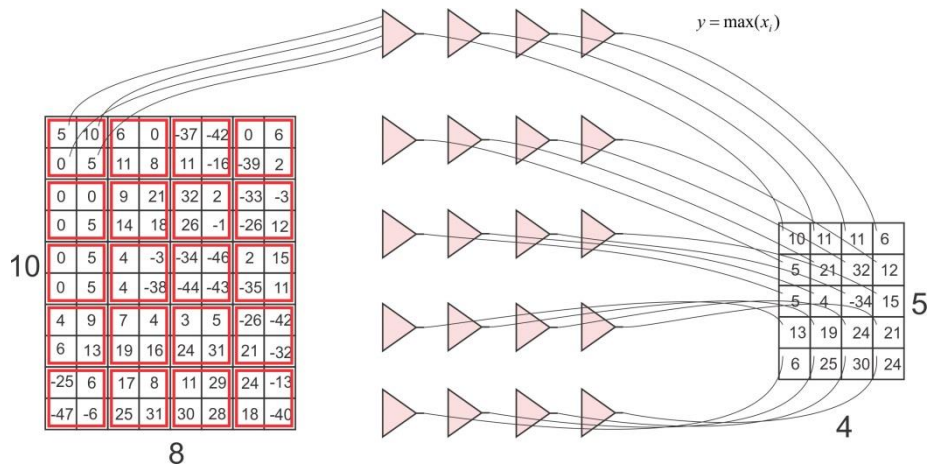
5	10	6	0	-37	-42	0	6
0	5	11	8	11	-16	-39	2
0	0	9	21	32	2	-33	-3
0	5	14	18	26	-1	-26	12
0	5	4	-3	-34	-46	2	15
0	5	4	-38	-44	-43	-35	11
4	9	7	4	3	5	-26	-42
6	13	19	16	24	31	21	-32
-25	6	17	8	11	29	24	-13
-47	-6	25	31	30	28	18	-40

როგორც ზემოთ აღვნიშნეთ, Convolutional ქსელში, პირველ ეტაპზე, ნეირონების რამდენიმე Convolutional შრე გვაქვს, შესაბამისად რამდენიმე 8x10 ზომის მატრიცა გვექნებოდა მიღებული.

Convolutional შრის ნეირონებს, გარდა განლაგებისა, კიდევ აქვთ ერთი ყურადსაღები თავისებურება. ერთი Convolutional შრის ნეირონებს ერთნაირი წონები აქვთ. ეს გარემოება რადიკალურად ამცირებს Convolutional ქსელის პარამეტრების რაოდენობას. Convolutional შრეების ნაკრების გამოსასვლელი სიგნალები Pooling შრეებზე ერთდება.

§ 3. Pooling შრე (Pooling Layer)

Pooling შრე უშუალოდ არის შეერთებული Convolutional შრის გამოსასვლელ სიგნალებთან. ყველა Convolutional შრეს შეერთებული აქვს ცალკე Pooling შრე. Pooling შრის დანიშნულებაა Convolutional შრიდან გამოსული სიგნალების ოდენობის შემცირება. Pooling შრის ნეირონების მიერთება არის Convolutional შრის ნეირონების ანალოგიური, თუმცა, განსხვავება ისაა, რომ Pooling შრის მეზობლად მდგომი ნეირონების მიერთების არეები არ თანაიკვეთება.



სურათი 12 - Pooling შრის მოქმედების პრინციპი

იმის გამო, რომ მეზობელი ნეირონების მიერთების არეები გვერდიგვერდ არის განლაგებული, ანუ არ თანაიკვეთება, მიღებული მატრიცა გაცილებით მცირე გამოდის ვიდრე საწყისი. ჩვენ მიერ მოყვანილ მაგალითში ნეირონის Pooling შრის ნეირონებს 4 შესასვლელი აქვს და $y = \max x_i$ ფორმულის საშუალებით აფორმირებენ გამოსასვლელ სიგნალს. როგორც ვხედავთ, ჩვენს მაგალითში, Pooling შრის მოქმედების შემდეგ 4x5 მატრიცა მივიღეთ. საზოგადოდ, Pooling შრის ნეირონებს შეიძლება მეტი შესასვლელი ჰქონდეს, და, შედეგად, საწყისი მატრიცის მეტჯერად შემცირებას მივიღებთ.

Pooling შრის მოქმედების არსი იმაში მდგომარეობს, რომ შეამციროს დასამუშავებელი ინფორმაციის ოდენობა, თუმცა არ დაკარგოს მნიშვნელოვანი მონაცემები.

§ 4. Dropout

Pooling შრე უშუალოდ არის შეერთებული Convolutional შრის გამოსასვლელ სიგნალებთან. ყველა Convolutional

§ 5. რეგულარიზაცია

ამ პარაგრაფში უნდა დავწერო რეგულარიზაციის L_1 და L_2 პარამეტრების შესახებ.

§ 6. Convolutional ქსელის სწავლება

Pooling შრე უშუალოდ არის შეერთებული Convolutional შრის გამოსასვლელ

თავი 5. რეკურენტული ნეირონული ქსელები (Recurrent Neural Networks)

ნეირონული ქსელების გამოყენების ერთ-ერთი ყველაზე საინტერესო სფეროა ბუნებრივი ენების დამუშავება. ბოლო დროს განსაკუთრებით დიდი წარმატებებით ხდება ლაპრაკის და ტექსტის ამოცნობა, ასევე არის პროგრესი ტექსტის გენერაციაშიც (ხელოვნური ინტელექტის სისტემები ჟურნალისტიკაშიც სცდიან ბედს).

ხელოვნური ნეირონული ქსელები, რომლებიც ბუნებრივი ენის დამუშავებისთვის არის განკუთვნილი, NLP (Natural Language Processing) ქსელებად იხსენიება.

ბუნებრივი ენების დამუშავებას სპეციფიკური ტიპის ქსელი - რეკურენტული ნეირონული ქსელი სჭირდება.

აქ უნდა დაიწეროს თიზისის ბოტის შესახებ.

თავი 6. ნეირონული ქსელის სწავლითი სწავლება (Transfer learning)

ნეირონული ქსელების სწავლების კლასიკური მიდგომაა სასწავლო ნიმუშების დიდი სიმრავლის არსებობა და ამ ნიმუშების მრავალჯერადი სწავლა. ასეთი მეთოდი მოითხოვს სასწავლო დიდი ოდენობის მონაცემებს და დიდი დროს.

აღსანიშნავია, რომ ადამიანი ეფექტურად იყენებს მის მიერ უკვე ნასწავლ ობიექტებს და სტრუქტურებს ახალი ცოდნის ფორმირებისთვის. მაგალითად, ერთხელ ნახავ უცნობი სიმბოლოს ადვილად ვიპოვი ფურცელზე მიუხედავად იმისა, რომ ფურცელი გარკვეული კუთხით შეიძლება იყოს დახრილი. სიმბოლოს ყველა კუთხიდან ნახვა და დამახსოვრება არ არის საჭირო ადამიანისთვის ამ ოპერაციის შესასრულებლად.

კარგი იქნებოდა, რომ ხელოვნურ ნეირონულ ქსელებსაც ჰქონოდათ ასეთი შესაძლებლობები.

დაიწეროს ბოლო შრის გადაპროგრამებით როგორ შეიძლება სწავლების დროის შეცირება.

თავი 7. მათემატიკური აპარატი


ნეირონული ქსელების შესწავლისას დაგვჭირდება ზოგიერთი მათემატიკური ტერმინის, ფუნქციის, მეთოდის ცოდნა. ეს თავი განკუთვნილია ნეირონული ქსელებისთვის აუცილებელი მათემატიკური საფუძვლების თავმოსაყრელად.

§ 1. ნორმალური განაწილება

ნორმალური განაწილება (იგივე გაუსის განაწილება) [normal distribution] წარმოადგენს უწყვეტი ტიპის განაწილებას. ის აღწერს ისეთი შემთხვევითი სიდიდის განაწილებას, რომელიც კონცენტრირებულია ერთი მნიშვნელობის ირგვლივ. გრაფიკულად ნორმალურ განაწილების სიმკვრივეს ზარის ფორმა აქვს. ანალიზურად იგი შემდეგნაირად ჩაიწერება:

$$p(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$$

სადაც μ პარამეტრი წარმოადგენს განაწილების მათემატიკურ ლოდინს, ანუ x -ის იმ მნიშვნელობას, რომლის გარშემოც კონცენტრირდება განაწილება (რომლის მოხდენის ალბათობაც ყველაზე დიდია), ხოლო σ^2 ახასიათებს განაწილების დისპერსიას (იგივე ვარიაციას), ანუ გაფანტულობას. რაც უფრო დიდია ამ უკანასკნელის მნიშვნელობა, მით უფრო "ბრტყელია" განაწილების სიმკვრივის გრაფიკი და პირიქით. ფუნქცია სიმეტრიულია μ წრფის მიმართ და სრულდება პირობა $p(x) \rightarrow 0$ როდესაც $x \rightarrow \pm\infty$, ანუ რაც უფრო გადახრილია მნიშვნელობა მათემატიკური ლოდინიდან, მით უფრო ნაკლებია მისი მოხდენის ალბათობა.



კერძო შემთხვევაში, თუ $\mu = 0$ და $\sigma^2 = 1$ მაშინ გვაქვს სტანდარტული ნორმალური განაწილება.

ნორმალური განაწილება ერთი-ერთი ყველაზე ხშირად გამოყენებადი და ფართოდ გავრცელებული განაწილებაა, რაც განპირობებულია მისი დიდი როლით ცენტრალურ ზღვართ თეორემაში. ცენტრალური ზღვართი თეორემის მიხედვით, დამოუკიდებელი და ერთნაირად განაწილებული გარკვეული ტიპის შემთხვევითი სიდიდეების საშუალო არითმეტიკული მისწრაფის სტანდარტული ნორმალური განაწილებისკენ, როდესაც ამ შემთხვევითი სიდიდეების რაოდენობა უსასრულოდ იზრდება. პრაქტიკულად ეს ნიშნავს, რომ იმ მოვლენათა განაწილება, რომლებზეც ბევრი დაახლოებით ერთნაირი ფაქტორი მოქმედებს, შეიძლება ჩაითვალოს სტანდარტულ ნორმალურ განაწილებად. მაგალითად, რაიმე ობიექტის სიგრძის გაზომვის ცდომილებები განაწილებულია სტანდარტული ნორმალური განაწილებით.

ნორმალური განაწილება პარამეტრებით μ და σ^2 აღინიშნება როგორც $N(\mu, \sigma^2)$. კერძოდ, სტანდარტული ნორმალური განაწილება აღინიშნება, როგორც $N(0,1)$.

§ 2. softMax ფუნქცია

მათემატიკაში, კერძოდ კი ალბათობის თეორიასა და მომიჯნავე მიმართულებებში, softMax ფუნქცია (ანუ ნორმირებული ექსპონენცია) განიხილება ლოგისტიკური ფუნქციის განზოგადებად. softMax ფუნქცია ნებისმიერ K განზომილებიან y ვექტორს გარდაქმნის ისეთ $\sigma(y)$ ვექტორად, რომლის კოორდინატები $(0, 1)$ ინტერვალში მდებარეობს და ჯამში ერთის ტოლია.

$$\sigma(y)_j = \frac{e^{y_j}}{\sum_{k=1}^K e^{y_k}}, j \in \{1, \dots, K\}$$

softMax ფუნქციას ხშირად იყენებენ ნეირონულ ქსელებში. ვთქვათ გვაქვს ნეირონული ქსელი, რომლის მიზანია შესასვლელი x ვექტორების კლასიფიკაცია. დავუშვათ ქსელის გამოსასვლელზე K ცალი ნეირონი

გვაქვს j -ური ნეირონის გამოსასვლელი გვიჩვენებს რამდენად ეკუთვნის x ვექტორი j -ურ კლასს. ვთქვათ j -ური ნეირონის გამოსასვლელი შემდეგნაირად გამოითვლება

$$y_j = \sum x^i w_{ji} + b_j$$

ცხადია, რაც მეტია j -ური ნეირონის გამოსასვლელი, მით მეტია იმის ალბათობა, რომ x ვექტორი j -ურ კლასს ეკუთვნის, თუმცა y_j რიცხვები j -ური კლასის კუთვნილების ალბათობებს არ უდრის, ისინი უბრალოდ ერთმანეთთან შესადარებლად არის გამოსადეგი.

იმისთვის, რომ y_j რიცხვები, ალბათობებად მოვიაზროთ, ცხადია, აუცილებელია, ისინი ისე გარდაექმნათ, რომ მათ შორის მეტ-ნაკლებობის მიმართება არ დავარღვიოთ და თან მათი ჯამი ერთის ტოლი გამოვიდეს. სწორედ ამ გარდაქმნის განსახორციელებლად გამოიყენება softMax ფუნქცია.

მოვიყვანოთ მაგალითი:

ვთქვათ, ჩვენს მიზანს წარმოადგენს ფერის ამოცნობა 3 რიცხვის მიხედვით.

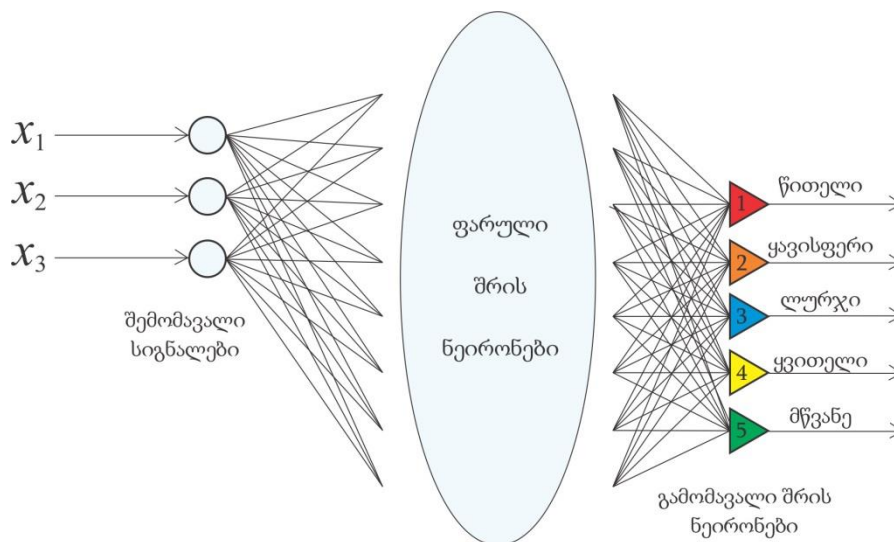
x_1	x_2	x_3	ფერი
8	1	2	წითელი
1	7	2	მწვანე
7	2	1	წითელი
6	0	0	წითელი
2	1	7	ლურჯი
8	4	0	ყავისფერი
8	8	0	ყვითელი
8	7	0	ყვითელი

ვთქვათ, სულ 5 ფერი გვაქვს.

როგორც წესი, როცა ნეირონულ ქსელს მონაცემები კატეგორიებად დაყოფას ავალებენ, ქსელის გამომავალ შრეში ათავსებენ იმდენ ნეირონს, რამდენი კატეგორიაც არსებობს. თითო კატეგორიას თითო გამომავალ ნეირონს უთანადებენ. კატეგორიის სათანადო გამომავალი ნეირონი 1-ის ტოლ სიგნალს მოგვცემს მხოლოდ იმ შემთხვევაში, თუ შემავალი მონაცემები ამ ნეირონის შესაბამის კატეგორიას განეკუთვნება. თუ ნეირონის შესაბამის კატეგორიაში არ ზის შემომავალი მონაცემები, მაშინ, ასეთი ნეირონი 0-ს

იმღევა გამოსასვლელზე.

ავაგოთ 5 გამოსასვლელიანი ნეირონული ქსელი. თითო გამოსასვლელი შევუსაბამოთ თითო, კონკრეტულ, ფერს.



თუ გამოსასვლელი შრის ნეირონების სიგნალებს მიმდევრობით დავწერთ, შეიძლება წარმოვიდგინოთ, რომ თითოეული ფერისთვის ნეირონული ქსელი გარკვეულ კოდს აგენერირებს.

ფერი	კოდი
წითელი	1 0 0 0 0
ყავისფერი	0 1 0 0 0
ლურჯი	0 0 1 0 0
ყვითელი	0 0 0 1 0

მწვანე	00001
--------	-------

ამ შემთხვევაში, ცხადია, ძალიან მოსახერხებელი იქნებოდა, რომ ნეირონების გამოსასვლელებზე არსებული სიგნალები, ამ ნეირონის შესაბამისი ფერის არსებობის ალბათობას გვატყობინებდეს.

ქსელის ნეირონების აქტივაციის ფუნქცია ლოგისტიკური ფუნქცია რომ იყოს, მაშინ გამოსასვლელზე შეიძლება მივიღოთ ასეთი კომბინაცია 0.9, 0.9, 0.7, 0.2, 0.5 რაც, ალბათობები ვერ იქნება, რადგან ჯამში ერთს აჭარბებს. აქედან გამომდინარე, ლოგისტიკური ფუნქცია მიუღებელია, თუ გამომავალი სიგნალები ალბათობებად გვინდა მოვიაზროთ. სწორედ ასეთ შემთხვევებში, იყენებენ აქტივაციის ფუნქციად softMax-ს.

§ 3. cross entropy error

ნეირონული ქსელის ეფექტურობის შესაფასებლად, ზოგჯერ, შეცდომის ენერჯის (უმცირეს კვადრატთა მეთოდის) ნაცვლად იყენებენ cross entropy error ფუნქციას [cross entropy error]. შეცდომის ენერჯია, როგორც ადრე განვიხილეთ (იხილეთ § 2.1. შეცდომის ენერჯია (უმცირეს კვადრატთა მეთოდი)), წარმოადგენს ყველა ნიმუშის შეცდომის ენერჯის არითმეტიკულ საშუალოს:

$$\mathcal{E} = \frac{1}{N} \sum_{n=1}^N \mathcal{E}(n)$$

დავუშვათ, რომ ნეირონის აქტივაციის ფუნქცია არის სიგმოიდური (ლოგისტიკური) ფუნქცია. თითოეული ნიმუშისთვის ცდომილების დასადგენად შემდეგი ფორმულა შევარჩიოთ

$$\mathcal{E}(n) = - \sum_{j \in V} (d_j \log v_j + (1 - d_j) \log(1 - v_j)).$$

ამ ფორმულაში გამოყენებული აღნიშვნები აღებულია პარაგრაფიდან „§2.1. შეცდომის ენერჯია (უმცირეს კვადრატთა მეთოდი)“. ამ ფორმულას cross entropy error ფუნქცია ეწოდება. შეგახსენებთ, რომ ადრე მის მაგივრად ვიხილავდით შემდეგ გამოსახულებას:

$$\mathcal{E}(n) = \frac{1}{2} \sum_{j \in V} e_j^2(n)$$

აღმოჩნდა, რომ cross entropy error ფორმულით შეფასებული ეფექტურობა, სწავლების პროცესში უმცირეს კვადრატთა მეთოდზე უკეთეს შედეგებს იძლევა, კერძოდ, ის უფრო სწრაფ სწავლებას უზრუნველყოფს.

თუ სიგმოიდურის ნაცვლად softMax ფუნქცია გამოიყენება ნეირონულ ქსელში, მაშინ cross entropy error ფუნქციას შემდეგი სახე აქვს

$$\mathcal{E}(n) = - \sum_{j \in V} d_j \log v_i.$$

§ 4. Batch Normalization

?????,

თავი 8. კომენტარები

მრავალი არხისთვის (ფერადისთვის) უნდა დაიწეროს უკეთესად! არ დამავიწყდეს ვიზუალიზაციის საიტზე ნანახი ბმების განხილვა!

თავი 9. ხელოვნური ნეირონული ქსელების ფილოსოფიური ასპექტები

ხელოვნური ნეირონული ქსელები ადამიანის ტვინის მოდელს წარმოადგენს. აქედან გამომდინარე, უამრავი საინტერესო შეკითხვა იზადება მათი მოქმედების პრინციპის გაანალიზებისას.

§ 1. ინტელექტის ცნება

როდესაც ხელოვნურ ნეირონულ ქსელზე ვსაუბრობთ, შეიძლება დავფიქრდეთ იმაზე, რომ წარმოადგენს თუ არა იგი ინტელექტის მქონე მექანიზმს. საამისოდ კი უნდა განვსაზღვროთ „ინტელექტი“-ს ცნება.

ტიურინგის ტესტი

იმისთვის, რომ გამოვარკვიოთ ფლობს თუ არა ინტელექტს რამე ობიექტი, ალან ტიურინგმა შემოგვთავაზა შემდეგი ტესტის (ტიურინგის ტესტი) ჩატარება: ადამიანი ესაუბრება ობიექტს და საუბრის მიხედვით ცდილობს დაადგინოს თანამოსაუბრე ადამიანია თუ არა. თუ თანამოსაუბრე ადამიანად აღიქმება, ესე იგი გვაქვს მისი ინტელექტუალურ სისტემად ცნობის საფუძველი.



რეგულარულად ტარდება ტიურინგის კონკურსი, სადაც უამრავი მოლაპარაკე სისტემა (Chat Bot) იღებს მონაწილეობას, თუმცა დღემდე ვერ მოხერხდა ადამიანის შეცდომაში შეყვანა. აღსანიშნავია, რომ ადამიანებს სულ უფრო მეტი ძალისხმევის გამოჩენა უხდებათ მოლაპარაკე სისტემის და ადამიანის განსასხვავებლად.

CAPTCHA

თანამედროვე ვებ სივრცეში ხშირად წარმოიქმნება სიტუაციები, როცა საჭიროა გავარკვიოთ ადამიანი ზის კომპიუტერთან თუ პროგრამული უზრუნველყოფა ცდილობს საიტზე შეღწევას. მომაბეზრებელი ბოტებისგან თავის დასაღწევად არის მოფიქრებული სისტემა CAPTCHA მისი სხვადასხვა რეალიზაციებით. CAPTCHA არის შემდეგი ფრაზის შემოკლება **Completely Automated Public Turing test to tell Computers and Humans Apart** (ადამიანთა და კომპიუტერთა გასაცალკევებელი სრულად ავტომატიზებული ტიურინგის ტესტი).


ეკრანზე გამოდის დამახინჯებულად დაწერილი სიტყვა და მომხმარებელს ამ სიტყვის ველში აკრეფა ევალეზა იმის დასტურად, რომ იგი ადამიანია.



ეს სისტემა გარკვეული დროის მანძილზე კარგად მუშაობდა, თუმცა ბოტები დაჭკვიანდნენ ნელ-ნელა და ისწავლეს დამახინჯებული ასოების ამოცნობა. დადგა დრო, როცა ბოტები ადამიანზე უკეთ კითხულობდნენ ასეთ ტექსტს. ფაქტობრივად, ხელოვნურმა ინტელექტმა შეძლო ტიურინგის ტესტის ამ ფორმით ჩაბარება! მას მერე აღნიშნულ სისტემას განუწყვეტლივ ხვეწენ და იგონებენ ახალ თავსატეხებს ბოტებისთვის, თუმცა, ახალი თავსატეხები ადამიანისთვისაც მწელად გამოსაცნობი ხდება.

§ 2. სამყაროს აღქმა

როგორ ხდება ადამიანის მიერ სამყაროს აღქმა? მოვიყვანოთ მაგალითი. კომპიუტერის ეკრანის ან მობილური ტელეფონის თეთრ ფონს გამადიდებელი შუშა მიუახლოვებთ. თქვენ დაინახავთ მარჯვნივ გამოსახულ სურათს. საოცარია, მაგრამ ეს რეალობაა - ეკრანზე წითელი, მწვანე და ლურჯი შუქი ანთია, ჩვენ კი თეთრ ფერს ვხედავთ.



ადამიანი აღიქვამს საკუთარ თავს. საკუთარი თავის აღქმა რას ნიშნავს, საკმაოდ რთული განსამარტია. ჩვენ ვგრძნობთ, რომ ვარსებობთ, ვაზროვნებთ, ვმოდრაობთ.. ჩვენ ვართ ჩვენი გონება, გული, ხელები, თვალები, ყველაფერი რაც ჩვენი ფეხის თითიდან თმის ღერამდეა და შეიძლება მეტიც, როგორც თეთრი ფერის შემთხვევაში.

თუ ოდნავ შევიჭრით თმის ბოლოს, ამითი ჩვენი თავის აღქმა არ შეიცვლება, ჩვენ აბსოლუტურად იგივე ვრჩებით. ასევე არ შევიცვლებით, თუ ფრჩხილებს დავიჭრით ან, თუნდაც, კბილს ამოვიღებთ. ზოგიერთ ადამიანს ოპერაციაც აქვს გაკეთებული და აკლია ორგანო(ები), თუმცა საკუთარი თავის აღქმა ამითი არ იცვლება, რაც ვიყავით ზემოთ აღნიშნულ მოვლენებამდე, იგივენი ვართ მას მერეც (თითქოს, ალბათ). ექიმებს ადამიანის თითქმის ყველა ორგანოს გადანერგვა უცდიათ ტვინის გარდა და ამით, საკუთარი თავის აღქმა მაინც უცვლელია. შეიძლება ვივარაუდოთ, რომ სწორედ ტვინით ხდება საკუთარი თავის აღქმა და იდენტიფიცირება.

მოდით, კიდევ უფრო განვავრცოთ მსჯელობა - ადამიანის უჯრედები განუწყვეტლად ახლდება, ანუ, ძველი უჯრედები კვდებიან და ახლები იზადებიან. ეს ხდება მუდმივად. სიცოცხლის მანძილზე ადამიანის პრაქტიკულად ყველა უჯრედის ჩანაცვლება ხდება, თან არაერთხელ. ამ გარემოების გათვალისწინებით, ტვინის ნაწილიც შეიძლება გამოიცვალოს. უცვლელი შეიძლება რჩებოდეს ის ინფორმაცია, რაც ჩვენს ტვინშია მოთავსებული, შეიძლება სწორედ ეს განაპირობებდეს ჩვენს აღქმას.

კიდევ მეტად ჩავუღრმავდეთ საკითხს - ადამიანის ტვინში მოთავსებული ინფორმაციაც განიცდის ცვლილებას. გამოდის, რომ გარკვეული დროის მერე, ჩვენ სრულად განახლებული ვართ, თუმცა, მაინც გვგონია, რომ ისევ ის ვართ, რაც ადრე ვიყავით. ვართ კი იგივენი? ღიად ვტოვებთ ამ კითხვას.

ასეა, თუ ისე, ვგრძნობთ, რომ აღვიქვამთ საკუთარ თავს და, ბუნებრივია, დავინტერესდეთ, აღიქვამს თუ არა საკუთარ თავს ხელოვნური ნეირონული ქსელით აგებული სისტემა? სხვა, ჩვენგან განსხვავებული ცოცხალი თუ ხელოვნური ობიექტი რას გრძნობს და განიცდის, მხოლოდ წარმოდგენით შეიძლება ვივარაუდოთ, ვერასდროს იქნება ჩვენი წარმოდგენები ბოლომდე დამაჯერებელი.

აღიქვამს თუ არა საკუთარ თავს ქვა? ალბათ არა.

აღიქვამს თუ არა საკუთარ თავს მცენარე? ალბათ არა, თუმცა ზოგიერთი შეიძლება სხვაგვარად მიიჩნევდეს.

აღიქვამს თუ არა საკუთარ თავს ფრინველი და ცხოველი? ალბათ კი, თუმცა ზოგიერთი შეიძლება შეგვეკამათოს.

აღიქვამს თუ არა საკუთარ თავს ხელოვნური ინტელექტის სისტემა, რომელიც ბანკის კლიენტებს ეხმარება ანაბრის გაფორმებაში, უგეგმავს იპოთეკური სესხის სქემას, ახარისხებს საბანკო დოკუმენტაციას, კონსულტაციას უწევს ზოგიერთ იურიდიულ საკითხზე და კიდევ მრავალ ინტელექტუალურ (აბა სხვა რა არის ინტელექტუალური?) საქმიანობას ეწევა?

ბოლო კითხვასაც უპასუხოთ დავტოვებთ.

§ 3. ხელოვნური ინტელექტის განვითარების პერსპექტივები

ხელოვნური ნეირონული ქსელები სულ უფრო სწრაფად ვითარდება თანამედროვე ეპოქაში. განვიხილოთ, თუ როგორი შეიძლება იყოს მათი მომავალი და როგორ შეცლის ახალი რეალიები ჩვენს ცხოვრებას.

ქვის ხანაში ადამიანს თავის გამოსაკვებად ნადირობა და მოსავლის მოყვანა სჭირდებოდა. გაცვლა-გამოცვლა იყო საჭირო პროდუქტების მოპოვების დამატებითი საშუალება.

მოგვიანებით გაჩნდა მატერიალური დოვლათის შესაბამისი ექვივალენტი, რომელიც აადვილებდა გაცვლა-გამოცვლის პროცედურას. საქართველოში ასეთი ექვივალენტი, ერთ დროს, იყო ქილა ერბო.

შემდგომ ადამიანმა გაცვლის უფრო მოსახერხებელი ექვივალენტი - ფული შემოიღო.

დღეს უმრავლესობა სწორედ ფულს ღებულობს გაწეული სამუშაოს სანაცვლოდ და შემდეგ ყიდულობს მისი საშუალებით სასურველ პროდუქტს.

ფულს ვიღებთ სამსახურში გარკვეული მუშაობის საზღაურად.

სამუშაო ადგილების სიმცირე სულ უფრო მტკივნეული საკითხია თანამედროვე ეპოქაში.

ხელოვნური ინტელექტი მომავალში ძალიან ბევრ (თითქმის ყველა) საქმის შესრულებას შეძლებს, რაც ახლა ადამიანების მიერ სრულდება.

რამდენიმე კომპანიამ უკვე ჩანაცვლა თანამშრომლების ნაწილი ნეირონული ქსელების საშუალებით შექმნილი ხელოვნური ინტელექტის სისტემებით. კონსულტანტები, რომლებიც სტანდარტულ

სიტუაციებს აცნობენ მომხმარებლებს და მარტივ ოპერაციებს ახორციელებენ, განსაკუთრებით ადვილად ჩანაცვლებადასეთი სისტემებით. ასეთი თანამდებობებია:

1. იპოთეკური და სამომხმარებლო სესხის კონსულტანტები.
2. საანაბრე ოპერაციების ოპერატორები.
3. სადაზღვეო აგენტები.
4. კომუნალური და სხვა ტიპის გადახდების განმახორციელებელი ოპერატორები.
5. მოლარეები.

მომავალში ამ პროფესიების რიცხვი გაიზრდება და უფრო ძნელად შესასრულებელ საქმიანობებსაც გადაწვდება.

ერთი შეხედვით, ყოველთვის ხდებოდა მსგავსი რამ. მაგალითად, როცა ადამიანმა ექსკავატორის გამოყენება დაიწყო მანძის მოპოვების საქმეში, ნიჩბიანი მუშებისთვის პრაქტიკულად აღარ დარჩა ადგილი. როცა ადამიანმა ცხოველების მოშენება დაიწყო საკვების წარმოების მიზნით, მონადირეების ფუნქცია დაიკარგა ამ თვალსაზრისით. მიუხედავად იმისა, რომ წარსულშიც ხდებოდა ადამიანების შრომის ჩანაცვლება მანქანებით და თანამედროვე ტექნოლოგიებით, ხელოვნური ინტელექტის სისტემების გამოყენებას აქვს გამორჩეული ნიშანთვისება - იგი ერთბაშად ჩანაცვლებს ბევრ პროფესიას, მათ შორის ინტელექტუალურ სამუშაო ადგილებსაც.

სად ვიმუშაოთ ჩვენ? *

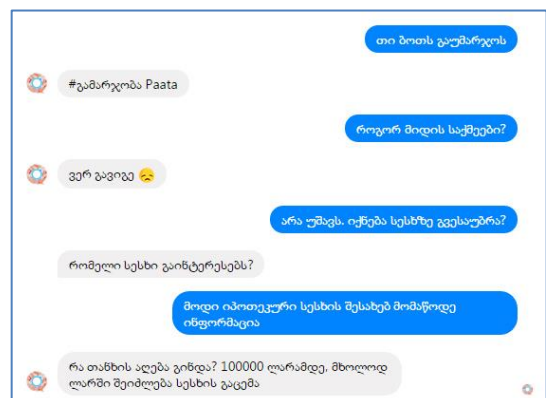
ადამიანის საქმეს მთლიანად ხელოვნური ინტელექტის სისტემები გააკეთებს. ასეთი საქმიანობებია: მშენებლობა, საკვების წარმოება, მედიცინა, ტანსაცმლის და საოჯახო პროდუქციის წარმოება.. ადამიანს მხოლოდ საქმიანობის დაგეგმვა მოუწევს, თვით საქმეს კი მთლიანად რობოტები გააკეთებენ. ადამიანები ამ სამყაროს მოვევლინებით იდეების წარმომქმნელ ინდივიდებად. ჩვენი „მუშაობა“ მხოლოდ ძალიან მაღალინტელექტუალური ქმედებებით იქნება შემოსაზღვრული. შემორჩება მხატვრობა, სპორტი, მუსიკა, სულიერება...

ასე გაგრძელდება თუ ხელოვნურ ინტელექტს არ გაუჩნდება საკუთარი მოთხოვნილებები. თუ ასე მოხდა, მოგვიწევს ანგარიშის გაწევა ამ მოთხოვნილებებისთვის. ასეთ შემთხვევაში მოვლენები შემდეგნაირად განვითარდება:

* 2017 წელს გამოჩნდა პირველი ქართული ციფრული მოლაპარაკე ბოტი - „თი ბოტი“.

თი ბოტი შეიქმნა კლიენტებისთვის თიბისი ბანკის მომსახურებების შესახებ კონსულტაციის გაწევის მიზნით. ახალგაზრდა თი ბოტი ჯერ არ არის დახვეწილი, მას ადამიანის მიერ დასმული ზოგიერთი ფრაზის შინაარსი არ ესმის, რასაც მორიდებულად აღიარებს კიდეც. თუმცა თი ბოტმა უკვე ჩანაცვლა არაერთი კონსულტანტი. თი ბოტის ალბათ მალე შეეძლება დაზღვევის და ანაბრების შესახებ კონსულტირებაც და დაიხვეწება კიდეც.

თანამშრომლების ჩანაცვლება ხელოვნური ინტელექტის სისტემებით საქართველოშიც დაწყებულია და კიდეც უფრო გაღრმავდება მომავალში.



ლიტერატურა

[neuroscience], fourth edition. Dale Purves, George J. Augustine, David Fitzpatrick, William C. Hall, Anthony-Samuel LaMantia, James O. McNamara, Leonard E. White. Sinauer Associates, Inc. Publishers, USA, 2008
(<http://amigo.ge/sangu/neuroscience.zip>)

[human brain project], <https://www.humanbrainproject.eu>

[brain initiative], <http://www.braininitiative.nih.gov>

[perceptron], <https://en.wikipedia.org/wiki/Perceptron>

[minsky], https://en.wikipedia.org/wiki/Marvin_Minsky

[convolutional networks], <http://cs231n.github.io/convolutional-networks/>

[normal distribution] https://ka.wikipedia.org/wiki/ნორმალური_განაწილება

[cross entropy error] <https://www.ics.uci.edu/~pjsadows/notes.pdf>

[neural networks online book] <http://neuralnetworksanddeeplearning.com/index.html>

[false memories] Creating a False Memory in the Hippocampus, Steve Ramirez, Xu Liu, Pei-Ann Lin, Junghyup Suh, Michele Pignatelli, Roger L. Redondo, Tomás J. Ryan, Susumu Tonegawam, Science 26 Jul 2013, Vol. 341, Issue 6144, pp. 387-391