მფეთქავი ნეირონული ქსელები

ცირა ბერაძე
აკაკი წერეთლის სახელმწიფო უნივერსიტეტი

აბსტრაქტი-*სტატიაში განხილულია მფეთქავი ნეირონული ქსელების მათემატიკური მოდელები, ინფორმაციის კოდირების მეთოდები, მრავალშრიანი სტრუქტურების სწავლების ძირითადი ალგორითმები და მათი რეალიზაცია თანამედროვე ნეირომორფულ აპარატულ პლატფორმებზე. კვლევის მიხედვით, ახალი ჩიპები უკვე ახერხებენ პირდაპირ სწავლას რეალურ დროში, რაც მნიშვნელოვანია ავტონომიური სისტემებისთვის. აღნიშნულია რომ სწორი არქიტექტურით შესაძლებელია უფრო დაცული სისტემების შექმნა, მათი ენერგოეფექტურობა და ბიოლოგიურ სისტემებთან სიახლოვე. მთავარი უპირატესობებია: სიჩქარე, რესურსების დაზოგვა და ექსტრემალური პროგნოზირება.*

საკვანძო სიტყვები : *მფეთქავი ნეირონული ქსელები , ნეირომორფული გამოთვლები, ბიოლოგიური ნეირონი.*

შინაარსი. მფეთქავი ნეირონული ქსელები (Spiking Neural Networks, SNN) წარმოადგენს ხელოვნური ნეირონული ქსელების მესამე თაობას. ეს ახალი ტიპის ქსელები ინფორმაციას ამუშავებენ „იმპულსებით“, როგორც ადამიანის ტვინი, რომელთა უპირატესობებია: ბევრად ნაკლები ენერგიის მოხმარება, სწრაფი რეაგირება, ნეირომორფულ აპარატურასთან თავსებადობა და რეალურ დროში მუშაობის შესაძლებლობა. კარგად გამოიყენება რობოტიკაში და ჭკვიან მოწყობილობებში.

ახალი ტექნოლოგიებით შესაძლებელია დიდი ნეირონული ქსელების „შეკუმშვა“, ისე რომ ხარისხი არ დიაკარგოს. ეს ნიშნავს, რომ ძლიერმა AI შეიძლება მალე ჩვეულებრივ ტელეფონებზეც იმუშაოს. ახლა ნეირონულ ქსელებს ფიზიკის კანონებსაც ასწავლიან, რომ უკეთ ამოხსნან სამეცნიერო პრობლემები: ინჟინერია, ამინდის მოდელირება, მედიცინა, მასალების კვლევა და ა.შ.

ტრადიციული ნეირონული ქსელებისგან განსხვავებით, SNN-ში ინფორმაცია გადაეცემა არა უწყვეტი რიცხვითი მნიშვნელობებით, არამედ დროით განსაზღვრული იმპულსებით („სპაიკებით“), რაც უფრო რეალისტურად ასახავს ბიოლოგიური ნეირონების მუშაობას.

SNN-ის ძირითადი ელემენტია მფეთქავი ნეირონი, რომელიც აგროვებს შემავალ სიგნალებს და მხოლოდ მაშინ აგზავნის გამომავალ იმპულსს, როდესაც მისი მემბრანული პოტენციალი აღწევს წინასწარ განსაზღვრულ ზღურბლს. ჩვეულებრივი ნეირონებისგან განსხვავებით, რომლებიც თითოეულ სტიმულზე თითო იმპულსით რეაგირებენ, მფეთქავი ნეირონები წარმოქმნიან მაღალი სიხშირის იმპულსების ჯგუფებს (აფეთქებებს), რასაც მოჰყვება შედარებით ხანგრძლივი დასვენების პერიოდი. ისინი გამოიყენება: რობოტიკაში – სწრაფი რეაგირებისას გარემოზე, თვითმართვად მანქანებში – მოძრაობის აღქმისა და გადაწყვეტილებების მიღებისას, ნეირომეცნიერებაში, Edge AI მოწყობილობებში – დაბალი ენერგომოხმარების გამო, მედიცინაში – EEG სიგნალების ანალიზისა და დიაგნოსტიკისას.

ყველაზე გავრცელებული ნეირონული მოდელებია:

- Leaky Integrate-and-Fire (LIF) – მარტივი და ფართოდ გამოყენებადი მოდელი;
- Izhikevich Model – უფრო ბიოლოგიურად რეალისტური;
- Hodgkin-Huxley Model – მაღალი სიზუსტის, მაგრამ მძიმე გამოთვლით.

SNN-ები გვაძლევს შესაძლებლობას შევისწავლოთ დროითი დინამიკა ისეთ ამოცანებში, სადაც დროის ფაქტორი კრიტიკულია, მისი სწავლება კი ერთ-ერთი ყველაზე რთული გამოწვევა. თანამედროვე კვლევების მიხედვით სუროგატული გრადიენტის მეთოდები ერთ ერთი ყველაზე ეფექტურია, რადგან ისინი საშუალებას იძლევა გამოყენებულ იქნას გრადიენტზე დაფუძნებული ოპტიმიზაცია.

პიკური დროის მიხედვით დამოკიდებული პლასტიკურობა Spike-Timing Dependent Plasticity (STDP) არის ბიოლოგიურად შთაგონებული სწავლების წესი, რომლის მიხედვითაც ნეირონებს შორის კავშირების სიმტკიცე იცვლება მათი აქტივაციის დროის მიხედვით.

ბოლო წლებში პოპულარული გახდა ტრადიციული ხელოვნური ნეირონული ქსელების SNN-ად გარდაქმნა, რაც საშუალებას იძლევა შევინარჩუნოთ მაღალი სიზუსტე და ერთდროულად შევამციროთ ენერგომოხმარებაც. კვლევებმა აჩვენა, რომ ფოტონური აპარატურა მნიშვნელოვნად აჩქარებს SNN-ის გამოთვლებს და ამცირებს ენერგიის მოხმარებას. ახალი ჩიპები უკვე ახერხებენ პირდაპირ სწავლას რეალურ დროში, რაც მნიშვნელოვანია ავტონომიური სისტემებისთვის.

SNN-ის გამძლეობა მოწინააღმდეგობრივი თავდასხმების მიმართ აქტიური კვლევის თემაა, ბოლო ნაშრომები მიუთითებს, რომ სწორი არქიტექტურით შესაძლებელია უფრო დაცული სისტემების შექმნა. ჩვეულებრივი ღრმა სწავლების ქსელები მუშაობენ მუდმივი აქტივაციებით. SNN-ში კი ნეირონი მხოლოდ მაშინ „ისვრის“, როცა მისი მემბრანული პოტენციალი ზღურბლს მიაღწევს.

ახალი კვლევები აჩვენებს, რომ Izhikevich-ის მოდელი ხშირად უკეთ მუშაობს, განსაკუთრებით რთულ ამოცანებში. როგორ სწავლობენ SNN-ები? ეს ყველაზე რთული ნაწილია, რადგან „სპაიკი“ არადიფერენცირებადია (backpropagation პირდაპირ არ მუშაობს).

იდეა: სპაიკის ფუნქციას „გაათანაბრებენ“ გლუვი მიახლოებით, რომ გრადიენტი გამოვთვალოთ. უპირატესობაა მაღალი სიზუსტე, თუ ორი ნეირონი სწორ დროში „ისვრის“, მათი კავშირი ძლიერდება. ეს კარგია: ჯერ ჩვეულებრივ ANN-ს წვრთნიან, მერე SNN-ად გარდაქმნიან. ეს ხშირად საუკეთესო პრაქტიკაა, რადგან: სიზუსტე თითქმის იგივე რჩება, ენერგომოხმარება კი მცირდება.

ძალიან დიდი სიახლეა ფოტონური ჩიპები, სადაც გამოთვლები სინათლით ხდება და არა ელექტრონებით. ახალმა კვლევამ აჩვენა: 1176× ნაკლები დაყოვნება, 239× ენერგიის დაზოგვა, ეს შეიძლება დიდი ნაბიჯი იყოს რეალურ დროში AI-სთვის. ახალი ოპტიკური ჩიპები უკვე ახერხებენ სწავლებას პირდაპირ სინათლით, ელექტრონულ გარდაქმნის გარეშე. მნიშვნელოვანია: ავტონომიური რობოტები, თვითმართვადი მანქანები, edge AI მოწყობილობები Spiking Transformers. ახლა SNN-ს აერთიანებენ Transformer არქიტექტურასთან.

დღეისათვის ღრმა სწავლების მოდელები, როგორიცაა ტრანსფორმერები და კონვოლუციური ქსელები, მიღწევების პიკზეა. მრავალშრიანი მფეთქავი ნეირონული ქსელე-

ბი (SNN) შეიქმნა სწორედ ამ ბიოლოგიური ეფექტურობის ხელოვნურ სისტემებში გადმოტანის მიზნით. ისინი ინფორმაციას ააქტიურებენ მხოლოდ მაშინ, როდესაც ნეირონი აღწევს გარკვეულ ზღვარს და უშვებს მოკლე იმპულსს – სპაიკს.

ბიოლოგიურ ნეირონში ინფორმაცია გადაიცემა აქსონების, სინაფსებისა და დენდრიტების მეშვეობით ელექტრული პოტენციალის ცვლილებით. მრავალშრიან SNN-ებში ბიოლოგიური ნეირონის ქცევის სიმულაციისთვის რამდენიმე მათემატიკურ მოდელს იყენებენ. მათ შორის ყველაზე პოპულარულია:

მოდელი- ინტეგრირება და გატყორცნა გაჟონვით, რომელიც წარმოადგენს ბალანსს ბიოლოგიურ სიზუსტესა და გამოთვლით სიმარტივეს შორის. ნეირონის მემბრანის პოტენციალი $V(t)$ დროში აღიწერება შემდეგი დიფერენციალური განტოლებით: $$\tau_m \frac{dV(t)}{dt} = -(V(t) - V_{rest}) + R \cdot I(t)$$, სადაც τ_m არის მემბრანის დროის მუდმივა, V_{rest} – მოსვენების პოტენციალი, R – მემბრანის წინაღობა, ხოლო $I(t)$ – შესავალი დენი. როდესაც $V(t)$ მიაღწევს ზღურბლურ მნიშვნელობას V_{th}, ნეირონი წარმოქმნის სპაიკს, ხოლო $V(t)$ მომენტალურად ვარდება მოსვენების პოტენციალამდე. რეალური სამყაროს მონაცემები მფეთქავმა ქსელმა რომ დაამუშაოს, საჭიროა მათი გარდაქმნა სპაიკების თანმიმდევრობად. კოდირების ძირითადი მეთოდებია: სიხშირული კოდირება - სიგნალის ინტენსივობა პროპორციულია დროის გარკვეულ მონაკვეთში გენერირებული სპაიკების რაოდენობისა; დროითი - ინფორმაცია კოდირდება ზუსტი დროით, თუ როდის მოხდა პირველი სპაიკის გატყორცნა; ეს მეთოდი უფრო ენერგოეფექტურია; პირდაპირი კოდირება - როდესაც პირველი ფარული შრე თავად ასრულებს კოდირების როლს უწყვეტი მნიშვნელობების მიღებით.

მრავალშრიანი (ღრმა) SNN-ების სწავლების ალგორითმები გაცილებით რთულია, ვიდრე ტრადიციული ხელოვნური ნეირონული ქსელების ANN(Artificial Neural Network), რადგან სპაიკის აქტივაციის ფუნქცია საფეხურებრივია და მისი წარმოებული ყველგან ნულია (გარდა ზღურბლის წერტილისა, სადაც ის უსასრულობაა). ეს შეუძლებელს ხდის კლასიკური Backpropagation-ის პირდაპირ გამოყენებას. დღეისათვის არსებობს სწავლების ორი ძირითადი მიდგომა: ANN-დან SNN- მდე კონვერტაცია, მეთოდი რომელიც გულისხმობს ჩვეულებრივი ღრმა ქსელის ჯერ სწავლებას სტანდარტული მეთოდებით (ReLU ფუნქციით), ხოლო შემდეგ მისი წონების გადატანას SNN არქიტექტურაში. მეთოდი იძლევა მაღალ სიზუსტეს, თუმცა მოითხოვს დიდ დროით სარკმელს სიხშირული კოდირების გამო.

თანამედროვე და ყველაზე პერსპექტიული მიდგომა არის პირდაპირი სწავლება სუროგატული გრადიენტებით. უკუგავრცელების დროს, სპაიკის არადიფერენცირებადი ფუნქცია ჩანაცვლდება გლუვი, დიფერენცირებადი ალტერნატივით (მაგ. სიგმოიდური ან გაუსის ფუნქციით). ეს საშუალებას იძლევა ქსელი პირდაპირ დროში ისწავლოს. სინაფსური პლასტიკურობა დამოკიდებული სპაიკის დროზე რაც არის უზედამხედველო სწავლების მექანიზმი.

თუ პრესინაფსური ნეირონი ასწრებს პოსტსინაფსურ ნეირონს აგზნებას ($t_{pre} < t_{post}$), მათ შორის კავშირი ძლიერდება, წინააღმდეგ შემთხვევაში – სუსტდება (LTD). ტრადიციულ პროცესორებზე SNN-ების სიმულაცია არაეფექტურია, რადგან ისინი მუშაო-

ბენ სინქრონულ ტაქტებზე. SNN-ების სრული პოტენციალის გამოსავლინებლად იქმნება სპეციალური ასინქრონული ნეირომორფული პარატურა:

ჩიპის დასახელება	მწარმოებელი	ძირითადი მახასიათებელი
Loihi 2	Intel	მხარს უჭერს პროგრამირებად ნეირონულ მოდელებს და ონლაინ სწავლებას
TrueNorth	IBM	1 მილიონი ციფრული ნეირონი, ულტრა--დაბალი ენერგომოხმარება
Tianjic	Tsinghua University	ჰიბრიდული ჩიპი, რომელიც აერთიანებს როგორც ANN, ისე SNN გამოთვლებს

SNN-ების ძირითადი გამოყენების სფერო მომავალში იქნება ე. წ. **Edge AI** (მოწყობილობები "ადგილზე" გამოთვლებით) – რობოტექნიკა, ავტონომიური დრონები, სენსორები და სამედიცინო იმპლანტები, სადაც ენერგიის ყოველი მიკროვატი კრიტიკულად მნიშვნელოვანია.

მფეთქავი ნეირონის მუშაობის სქემა:

1. მფეთქავი ნეირონის მუშაობის ოთხფაზიანი ციკლი

მფეთქავი ნეირონის მუშაობა შეიძლება დაიყოს უწყვეტ ციკლურ პროცესად:

[ფაზა 1: მოსვენება] -> [ფაზა 2: დეპოლარიზაცია] -> [ფაზა 3: აქტიური აფეთქება] -> [ფაზა 4: ჰიპერპოლარიზაცია]

ნეირონის მემბრანული პოტენციალი იმყოფება სტაბილურ, უარყოფით ნიშნულზე (დაახლოებით -60mV-დან -70mV-მდე). ამ დროს უჯრედი "დებს" გარეგან სტიმულს ან შინაგან აქტივაციას.

2. ნელი დეპოლარიზაცია-უჯრედში იწყება ნელი მოქმედების კალციუმის (*Ca*2+) ან ნატრიუმის (*Na*+) არხების გახსნა. მემბრანული პოტენციალი ნელ-ნელა იწევს ზემოთ (ხდება უფრო პოზიტიური). როდესაც პოტენციალი მიაღწევს გარკვეულ ზღურბლს, იწყება "აფეთქება".

3. აქტიური აფეთქების ფაზა ზღურბლის მიღწევისთანავე იხსნება, ნეირონი იწყებს მაღალი სიხშირის მოქმედების პოტენციალების (Spikes) სერიის გენერირებას. სიხშირე: ამ ფაზაში იმპულსებს შორის ინტერვალი ძალიან მცირეა (>100 ჰერცი).

4. ჰიპერპოლარიზაცია და დამუხრუჭება. აფეთქების დროს უჯრედში დიდი რაოდენობით კალციუმი (*Ca*2+) შედის. ეს პროცესი ააქტიურებს კალციუმ-დამოკიდებულ კალიუმის (*K*+) არხებს. კალიუმის იონები მასიურად ტოვებენ უჯრედს, რასაც მოჰყვება მემბრანის მკვეთრი ჰიპერპოლარიზაცია (პოტენციალის ვარდნა მოსვენების ნიშნულზე დაბლა). ნეირონი "იღლება", ითიშება და გადადის პაუზის რეჟიმში, სანამ ციკლი თავიდან არ დაიწყება.

ვიზუალური თვალსაჩინოებისთვის შეგვიძლიათ გამოვიყენოთ შემდეგი ცხრილი, რომელიც აჩვენებს, თუ რომელი იონური დენები მართავენ პროცესს:

ფაზა	წამყვანი იონური დენი	ეფექტი ნეირონზე
ინიცირება	ნელი კალციუმის დენი (*IT* ან *IL*)	ნელა ზრდის მემბრანის პოტენციალს ზღურბლამდე.
აფეთქება (Burst)	სწრაფი ნატრიუმის (*INa*) და კალიუმის (*IK*) დენები	წარმოქმნის მაღალი სიხშირის "სპაიკების" სერიას.
დასრულება/-პაუზა	კალციუმ-დამოკიდებული კალიუმის დენი (*IK,Ca*)	თრგუნავს ნეირონს, იწვევს პაუზას და ამზადებს ახალი ციკლისთვის.

მფეთქავი ნეირონების მუშაობის სქემის აღწერისას მნიშვნელოვანია ხაზი გაესვას მათ ფუნქციურ უპირატესობას: ინფორმაციული საიმედოობა - ერთი პროპორციული იმპულსი შეიძლება დაიკარგოს ნეირონულ ხმაურში. "აფეთქება" კი გარანტირებული სიგნალია სინაფსისთვის, რომ ინფორმაციამ დანიშნულების ადგილამდე მიაღწიოს, ბიოლოგიური რიტმები: ეს ნეირონები მუშაობენ როგორც ბუნებრივი "ოსცილატორები". ისინი მართავენ ისეთ რითმულ პროცესებს, როგორიცაა სუნთქვა, გულისცემა, სიარული და ძილღვიძილის ციკლი.

ლიტერატურა:

. 1. გ.უგულავა (2019). ხელოვნური ნეირონული ქსელების გამოყენება ტერიტორიული ეკონომიკური მაჩვენებლების პროგნოზირებისთვის. *გლობალიზაცია და ბიზნესი*, №8,

2. Neftci, E. O., Mostafa, H., & Zenke, F. (2019). Surrogate gradient learning algorithms for neuromorphic hardware. IEEE Signal Processing Magazine, 36(6),

3. Tavanaei, A., Ghodrati, M., Kheradpisheh, S. R., Masquelier, T., & Maida, A. (2019). *Deep learning in spiking neural networks.* Neural Networks, 111.

4. Nature (2026). Photonic acceleration of spiking neural networks.

Spiking Neural Networks

Ts. Beradze

Summary

This article discusses the mathematical models of spiking neural networks, information encoding methods, core learning algorithms for multilayer structures, and their implementation on modern neuromorphic hardware platforms. According to the research, new chips are already capable of direct, real-time learning, which is crucial for autonomous systems. It is noted that with the right architecture, it is possible to create more secure systems that offer high energy efficiency and a closer resemblance to biological systems. The main advantages include speed, resource conservation, and extreme forecasting.

Keywords: Spiking neural networks, neuromorphic computing, biological neuron