

NEUROMORFNO RAČUNARSTVO – IMPULSNE NEURONSKE MREŽE

NEUROMORPHIC COMPUTING – SPIKE NEURAL NETWORKS

Anđela Popović, *Fakultet tehničkih nauka, Novi Sad*

Oblast – RAČUNARSTVO I AUTOMATIKA

Kratak sadržaj – *Neuromorfno računarstvo je oblast u razvoju koja nalazi sve veću primenu. U ovom radu biće ukratko prikazani principi funkcionisanja neuromorfnog računarstva, kao i rezultati implementacije jedne Spiking (impulsne) neuronske mreže u kojoj su sinapse obučene da svoje težine prilagode odgovarajućim ulazima.*

Ključne reči: *Neuromorfno računarstvo, Impulsne neuronske mreže, LIF model, STDP pravilo*

Abstract – *Neuromorphic computing is an evolving field with increasing practical applications. This paper will briefly present the principles of neuromorphic computing, as well as the results of implementation a Spiking Neural Network, where the synapses are trained to adjust their weights according to the corresponding inputs.*

Keywords: *Neuromorphic computing, Spiking Neural Networks, LIF model, STDP rule*

1. UVOD

Neuromorfno računarstvo predstavlja interdisciplinarno polje koje je inspirisano principima funkcionisanja mozga [1]. U nedostatku prevoda na srpski jezik termin engl. *Spiking Neural Networks (SNN)* prevešćemo kao Impulsne neuronske mreže, čime se ističe priroda signala odnosno spike-a.

2. NEUROMORFNO RAČUNARSTVO

Neuromorfno računarstvo zasniva se na podražavanju biološkog nervnog sistema (engl. *neuro-* odnosi se na nervni sistem, i engl. *morphic-* odnosi se na oblik ili strukturu). Kod tradicionalnih veštačkih neuronskih mreža (engl. *Artificial Neural Networks - ANN*) svaki neuron vrši nekakvo računanje, rezultat propagira u naredni sloj, ponovo svaki neuron iz tog sloja vrši računanje, propagira dalje, i tako dok se ne dođe do rešenja. Ne moraju svi neuroni u mozgu da se pobude i obrade novu informaciju (stimulus), ovo bi trajalo predugo. Dovoljno je da samo određeni neuroni pošalju impulse, pa u zavisnosti od toga koji neuroni i kada, mozak donosi zaključak odnosno rešenje.

2.1. Neuroni, sinapse i akcioni potencijal

Neuron je osnovna procesna jedinica neuronske mreže. Neuroni informacije primaju, obrađuju i prenose putem električnih signala, u biologiji poznatih kao akcioni

potencijali. Ovi signali se prenose putem veza između neurona koje se zovu sinapse [1]. Ključni koncept u Impulsnim neuronskim mrežama (SNN) je plastičnost sinapsi, odnosno sposobnost sinaptičkih veza da se menjaju tokom vremena na osnovu iskustva.

Akcioni potencijal je kratkotrajna promena membranskog potencijala koja se dešava kada se dostigne određeni prag. Generisanje akcionog potencijala je rezultat depolarizacije membrane neurona do tačke praga. Do stvaranja akcionog potencijala („okidanje neurona“) dolazi kada potencijal dosegne prag „od dole“. Okidanje neurona je drugim rečima ispaljivanje impulsa odnosno spike-a odakle i naziv.


Nakon okidanja dolazi period refrakcije. Tokom ovog perioda je teže ili nemoguće generisati novi impuls.

2.2. Modeli neurona

Najpoznatiji modeli neurona su Hodgkin–Huxley model (HH) [2], Leaky Integrate-and-Fire model (LIF) [1] i Ižikevič model (IZK) [3].

Hodgkin–Huxley model je jedan od prvih detaljnih matematičkih modela koji opisuju elektrofiziološko ponašanje neurona. Razvijen je 1952. godine od strane Alana Hodžkinsa i Endrua Hakslija, za šta su dobili Nobelovu nagradu. Matematičke jednačine koje opisuju dinamiku membranskog potencijala u HH modelu su kompleksne i uključuju nelinearne diferencijalne jednačine koje opisuju brzinu promene membranskog potencijala u zavisnosti od vremena i membranskog potencijala. Zbog toga, nemoguće je napraviti veliku SNN sa ovakvim modelom neurona.

Leaky Integrate-and-Fire model je jednostavan ali efikasan model koji se modeluje pomoću kondenzatora i otpornika, predstavljen na slici 1 i narednim jednačinama.



Slika 1. LIF model

$$i(t) = i_R(t) + i_C(t) \quad (1)$$

NAPOMENA:

Ovaj rad proistekao je iz master rada čiji mentor je bio dr Vladimir Bugarski, docent.

$$u(t) = R \cdot i_R(t) + V_{REST}$$

$$\Rightarrow i_R(t) = \frac{u(t) - V_{REST}}{R} \quad (2)$$

$$i_C(t) = C \frac{du(t)}{dt} \quad (3)$$

$$C \frac{du(t)}{dt} + \frac{u(t) - V_{REST}}{R} = i(t) \quad (4)$$

$$\frac{du(t)}{dt} + \frac{u(t)}{RC} = \frac{1}{C} i(t) + \frac{V_{REST}}{RC} \quad (5)$$

Vidimo da je diferencijalna jednačina (5) u obliku:

$$\frac{du(t)}{dt} + p(t)u(t) = q(t)$$

gde je $p(t) = 1/RC$ i $q(t) = \frac{1}{C} i(t) + \frac{V_{REST}}{RC}$. Možemo rešiti ovu jednačinu koristeći faktor $\mu(t)$, tako da je:

$$\mu(t)p(t) = \frac{d\mu(t)}{dt} \Rightarrow \frac{d\mu(t)}{\mu} = p(t)dt \quad (6)$$

Integrirajući obe strane jednačine (5) dobija se:

$$\int \frac{d\mu(t)}{\mu} = \int p(t)dt \Rightarrow \ln \mu(t) = \int p(t)dt \quad (7)$$

Prema tome

$$\mu(t) = e^{\int p(t)dt} = e^{\int 1/RC dt} = e^{t/RC} \quad (8)$$

Dalje, množenjem obe strane diferencijalne jednačine (5) sa $\mu(t)$:

$$\mu(t) \frac{du(t)}{dt} + \mu(t)p(t)u(t) = \mu(t)q(t) \quad (9)$$

Uvrštavanjem jednačine (6) dobija se:

$$\mu(t) \frac{du(t)}{dt} + \frac{d\mu(t)}{dt} u(t) = \mu(t)q(t) \quad (10)$$

Primenom Lajbnicovog pravila, $(u \cdot v)' = uv' + u'v$ sledi

$$\frac{d}{dt} [\mu(t)u(t)] = \mu(t)q(t) \Rightarrow \frac{d}{dt} (e^{t/RC} u(t)) = e^{t/RC} \left[\frac{1}{C} i(t) + \frac{V_{REST}}{RC} \right] \quad (11)$$

Da bi se rešila ova jednačina po $u(t)$, potrebno je integrirati obe strane jednačine:

$$e^{t/RC} u(t) = \int e^{t/RC} \left[\frac{1}{C} i(t) + \frac{V_{REST}}{RC} \right] dt$$

$$= \frac{1}{C} \int e^{t/RC} i(t) dt + \frac{V_{REST}}{RC} \int e^{t/RC} dt$$

$$= \frac{1}{C} \int e^{t/RC} i(t) dt + V_{REST} \cdot e^{t/RC} \quad (12)$$

U jednostavnom LIF neuronskom modelu, pretpostavljamo $i(t) = \delta(t)$. Delta funkcija je jednaka nuli svuda osim za $t = 0$. Jedna od posledica toga je da ako se pomnoži bilo kojom funkcijom, nije bitno koje su vrednosti te funkcije sem za $t = 0$. To znači da:

$$\int_{-\infty}^{+\infty} f(t)\delta(t)dt = \int_{-\infty}^{+\infty} f(0)\delta(t)dt$$

$$= f(0) \int_{-\infty}^{+\infty} \delta(t)dt$$

$$= f(0) \quad (13)$$

Sada se može rešiti integral za jednačinu (13):

$$e^{t/RC} u(t) = \frac{1}{C} \int e^{t/RC} i(t) dt + V_{REST} \cdot e^{t/RC}$$

$$= \frac{1}{C} \int e^{0/RC} \delta(t) dt + V_{REST} \cdot e^{t/RC}$$

$$= \frac{1}{C} e^{0/RC} + V_{REST} \cdot e^{t/RC}$$

$$= \frac{1}{C} + V_{REST} \cdot e^{t/RC} \quad (14)$$

Stoga

$$u(t) = \frac{1}{C} e^{-t/RC} + V_{REST} \quad (15)$$

U projektu koji je opisan u ovom radu implementiran je LIF model, zbog svoje zadovoljavajuće biološke podobnosti i računarske efikasnosti.

Ižikevič model neurona postavio je Eugen Ižikevič 2003. godine u kom je neuron opisao dvodimenzionalnim setom diferencijalnih jednačina (16):

$$\frac{dv(t)}{dt} = 0.04v^2(t) + 5v(t) - u(t) + i(t) + 140$$

$$\frac{du(t)}{dt} = a(bv(t) - u(t)) \quad (16)$$

Resetovanje potencijala membrane se modeluje:

$$\text{Ako } v \geq 30mV, \text{ onda } = \begin{cases} v \leftarrow c \\ u \leftarrow u + d \end{cases} \quad (17)$$

Ovde, v i u su bezdimenzione promenljive, a , b , c , d su bezdimenzioni parametri, t je vreme. Promenljiva v predstavlja membranski potencijal neurona, promenljiva u predstavlja promenljivu oporavka membrane (u čije detaljnije objašnjavanje se nećemo upuštati u ovom radu).

3. IMPULSNE NEURONSKE MREŽE


Ključne karakteristike su [1]:

- Bitna karakteristika SNN je modelovanje vremenskih karakteristika informacija putem sekvenci akcionih potencijala. Umesto obrade statičkih ulaznih podataka, SNN obrađuju temporalne sekvence informacija koje se prenose putem impulsa.
- Učenje u SNN često se zasniva na biološki inspirisanim principima učenja, kao što su Spike-Timing-Dependent Plasticity (skraćeno STDP), ili različitim varijantama ovog pravila. Ova pravila omogućavaju mreži da prilagodi svoje sinapse odnosno težine na osnovu tačnog vremenskog odnosa između akcionih potencijala neurona, odnosno njihove uzročnosti.
- Razlike u odnosu na ANN: ANN koriste kontinuirane vrednosti (obično realne brojeve) za predstavljanje aktivnosti neurona i propagaciju signala kroz mrežu. SNN koriste diskretne impulse kako bi predstavile aktivnost neurona. Ovi impulsi se generišu u određenim vremenskim trenucima i prenose se kroz mrežu.

3.1. STDP pravilo

STDP pravilo učenja je biološki inspirisano pravilo učenja koje opisuje kako jačina sinapsi između neurona slabi ili jača u skladu sa vremenskim odnosom između impulsa tih neurona. Donald Heb ga je 1949. godine

definisao sledećom rečenicom: „*Neurons that fire together, wire together*“ (neuroni koji okidaju zajedno, međusobno se povezuju) [4]. Na slici 2 prikazana je šema dva neurona i sinapse između njih.



Slika 2. Presinaptički i postsinaptički neuron, sinapsa

Ako neuron i koji je povezan sa neuronom j izaziva okidanje neurona j onda njihovu vezu (sinapsu) w treba ojačati. Drugim rečima, ako presinaptički neuron generiše impuls pre postsinaptičkog neurona, sinapsu treba ojačati. Ako presinaptički neuron generiše impuls posle postsinaptičkog neurona, sinapsu treba oslabiti. Jačina sinapse se menja zavisno od tačnog vremenskog intervala između presinaptičkog i postsinaptičkog impulsa, $\Delta t = t_{post} - t_{pre}$. Ta promena Δw modeluje se eksponencijalnom funkcijom (jednačine 18 i 19), gde su $A_+ > 0$ i $A_- < 0$ ponderišući faktori.

$$\Delta w_+ = A_+(w) * e^{\frac{-|\Delta t|}{\tau}}; \Delta t > 0 \quad (18)$$

$$\Delta w_- = A_-(w) * e^{\frac{-|\Delta t|}{\tau}}; \Delta t < 0 \quad (19)$$

Konačno ažuriranje jačine sinapsi računa se na sledeći način:

$$w_{ij} = \begin{cases} w_{ij} + \eta \Delta w_{ij} (w_{max} - w_{ij}), & \Delta t > 0 \\ w_{ij} + \eta \Delta w_{ij} (w_{ij} - w_{min}), & \Delta t < 0 \end{cases} \quad (20)$$

Gde je η koeficijent učenja koji se bira iz opsega $w_{min} < w_{ij} < w_{max}$ [4].

4. IMPLEMENTACIJA

Projekat koji je opisan u ovom radu implementira SNN sa LIF modelom, STDP pravilom, i „pobednik uzima sve“ (engl. *winner take all*) strategijom. Ova strategija znači da kada jedan neuron „pobedi“ za određeni ulaz, odnosno ima najprilagođenije težine sinapsi, ostali neuroni će biti prigušeni (smanjiće im se potencijal membrane).

Algoritam radi tako što za svaki neuron izračunava potencijal pomoću LIF modela. Zatim proverava da li je došlo do impulsa, ako jeste, primenjuje se pravilo „pobednik uzima sve“. Dalje se nad svim neuronima primenjuje STDP pravilo. Ova tri pravila izvršavaju se za sve vremenske odabirke. Nakon prolaska kroz sve vremenske odabirke prelazi se na sledeći ulaz (sliku) i nakon što se prođe kroz sve slike, sledi naredna epoha u kojoj se sve ponavlja. Jedini uslov konvergencije algoritma je ispunjenje zadatog broja epoha.

Ovo praktično znači da jedan neuron može da ispali impuls više puta (ili nijednom) tokom trajanja vremenskog intervala. Ako je neuron na kraju pobednik, to znači da se matrica sinapsi vezana za taj neuron najbolje „naučila“ na ulaz za koji je neuron pobedio. Pobednički neuron određuje se za svaki ulaz nakon celog vremenskog intervala. Intuitivno ovo je kao da smo uzeli jednu sliku, pustili sve neurone da je „vide“ npr. 200ms, a onda im pokazivali redom slike po 200ms, i tako npr. 20 puta (epoha). Na kraju svih epoha, za svaku sliku imamo finalni pobednički neuron, čije sinapse su naučene upravo

na tu sliku. U projektu opisanom u ovom radu sinapse su učene da mapiraju odgovarajuće piksele, tako da se na kraju učenja mogu rekonstruisati ulazi.


4.1. Predobrada ulaznih slika

Pre nego što počne učenje, potrebno je predobraditi (engl. *preprocessing*) ulazne podatke, u ovom slučaju slike. Prvo se intenziteti svakog piksela slike normalizuju na određeni opseg. Zatim sledi enkodiranje, odnosno potrebno je doći do povorke ulaznih impulsa.

Na osnovu membranskog potencijala svakog piksela, interpolacijom između minimalne i maksimalne frekvencije, dobija se frekvencija impulsa za taj piksel. Niži potencijali imaju niže frekvencije okidanja impulsa i obrnuto. Na osnovu frekvencije izračunava se interval između impulsa, po obrascu $1/\text{frekvencija}$. Sada se formira niz diskretnih događaja (vrednosti jedan) gde su impulsi razmaknuti za širinu izračunatog intervala. Ovo je ustvari niz Dirakovih impulsa.

Primer radi, za sliku dimenzija 2x2 gde je gornja polovina bela a donja polovina crna (desni deo slike 4), povorka impulsa (za svaki piksel) data je na slici 3. Crna boja ima vrednost 0, stoga nema nijednog impulsa, bela boja izazvaće najveću gustinu impulsa, a ostale nijanse sive bile bi između.

Svrha ove predobrade je da se od ulaznih podataka dobiju nizovi ulaznih impulsa, u odnosu na koje će se računati vreme Δt za STDP pravilo.



Slika 3. Povorka impulsa po pikselu

5. REZULTATI

Mreža je testirana na tri različita skupa podataka. Broj neurona treba da bude veći od broja izlaznih klasa, jer će neki neuroni naučiti šum. Mreža je učena u 20 epoha.

5.1. Početni skup


Prvi skup je jednostavan, *proof of concept* skup, koji se sastoji od samo dve ulazne slike (slika 4).



Slika 4. Prvi ulazni skup


Za ovako mali skup praktično je prikazati potencijale neurona. Na slici 5 prikazani su potencijali 6 neurona gde je na y osi potencijal, a na x osi prikazano je vreme. Crvenom horizontalnom linijom označen je prag. Vidi se da za razliku od ostalih, potencijal neurona 3 nikada ne pređe prag a neuroni 2 i 5 najviše puta prelaze prag, vremenski naizmenično. Po tome možemo zaključiti da su upravo ti neuroni pobednici, svaki za odgovarajuću sliku (naravno algoritam na kraju ispiše pobednike pa nema

potrebe za analiziranjem grafika). Ovo znači da su se oni „naučili“ za odgovarajuće slike, i samo kada je ta slika „prikazana“ neuronu, on ispaljuje impulse i prelazi prag.




Slika 5. Potencijali neurona

Prikaz ispaljivanja impulsa po neuronu dat je na slici 6. Ovde vidimo da samo pobednički neuroni 2 i 5 ispaljuju impulse. Neuroni 0, 1, 3 i 4, iako nekada pređu prag, ne ispaljuju impulse jer bivaju „ugušeni“ od strane pobedničkih neurona („pobednik uzima sve“).



Slika 6. Ispaljeni impulsi po neuronima

Ako pogledamo vizuelizovan prikaz svih sinapsi po svim neuronima (slika 7) vidimo da sinapse neurona 2 i 5 odgovaraju ulaznim slikama




Slika 7. Finalne vrednosti sinapsi (x osa po neuronima (y osa)

5.2. Rezultati na MNIST skupu


Drugi ulazni skup koji se sastoji od 6 različitih slika dimenzija 2x2 mreža takođe uspešno rekonstruiše.

Treći ulazni skup je MNIST skup od 6 slika (slika 8), cifara 0-5. Radi konciznosti neće ponovo biti dati grafici potencijala, ispaljenih impulsa i sinapsi po neuronima.



Slika 8. Ulazni skup

Rezultati rekonstrukcije sinapsi (slika 9) gde je ispod svake slike označen redni broj neurona su:



Slika 9. Rekonstrukcija MNIST skupa

Kao što vidimo sinapse pobedničkih neurona su uspešno naučene, dok su ostale naučile šum.

Mreža je uspešno testirana na tri različita ulazna skupa, uz identične parametre, što potvrđuje njenu sposobnost učenja i robustnost. Važno je prilagoditi broj neurona kojih mora biti barem 20% više od ulaznih klasa.

6. ZAKLJUČAK

Ovo istraživanje pokazuje da je SNN mreža koja implementira LIF model, STDP pravilo, odgovarajuće predobrade (i ostale detalje implementacije) sposobna da uspešno prilagodi sinapse („nauči“) ulaznim slikama, što je jasno prikazano rekonstrukcijom ulaza na osnovu sinaptičkih težina.

7. LITERATURA

- [1] W. Gerstner, W.M. Kistler, “Spiking neuron models: Single neurons, populations, plasticity”, New York, US: Cambridge University Press, 2002. isbn: 978-0-521-81384-6. doi: 10.1017/CBO9780511815706.
- [2] A.L. Hodgkin, A.F. Huxley, “A quantitative description of membrane current and its application to conduction and excitation in nerve,” J. Physiol., Vol. 117, no. 4, pp. 500–544, Aug. 1952. [Online]. <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC1392413/>
- [3] E. Izhikevich, “Simple model of spiking neurons”, *IEEE Trans. Neural Netw.*, vol. 14, no. 6, pp. 1569–1572, Nov. 2003. doi: 10.1109/TNN.2003.820440.
- [4] N. Caporale, Y. Dan, “Spike timing-dependent plasticity: a Hebbian learning rule,” eng, *Annual Review of Neuroscience*, Vol. 31, pp. 25–46, 2008. doi: 10.1146/annurev.neuro.31.060407.125639.

Kratka biografija:



Andela Popović rođena je u Šapcu 2000. god. Diplomski rad na Fakultetu tehničkih nauka iz oblasti Elektrotehnike i računarstva - Računarstvo i automatika odbranila je 2023.god. kontakt: andjela9popovic@gmail.com