

VILNIAUS UNIVERSITETAS

Dalius Krunglevičius

**STDP MOKYMO TAIKYMAS ERDVINĖMS BEI ERDVINĖMS-LAIKINĖMS
STRUKTŪROMS ATPAŽINTI**

Daktaro disertacijos santrauka

Fiziniai mokslai, informatika (09P)

Vilnius, 2016

Disertacija rengta 2011–2015 metais Vilniaus universiteto Matematikos ir informatikos fakultete.

Mokslinis vadovas

prof. habil. dr. Šarūnas Raudys (Vilniaus universitetas, fiziniai mokslai, informatika – 09P).

Disertacija ginama Vilniaus universiteto Informatikos mokslo krypties taryboje:

Pirmininkas

prof. dr. Romas Baronas (Vilniaus universitetas, fiziniai mokslai, informatika – 09P),

Nariai:

prof. dr. Bruce Graham (Stirlingo universitetas, fiziniai mokslai, informatika – 09P),

prof. habil. dr. Kazys Kazlauskas (Vilniaus universitetas, fiziniai mokslai, informatika – 09P),

prof. habil. dr. Henrikas Vaitkevičius (Vilniaus universitetas, biomedicinos mokslai, biofizika – 02B).

prof. dr. Olegas Vasilecas (Vilniaus Gedimino technikos universitetas, fiziniai mokslai, informatika – 09P).

Disertacija bus ginama viešame Vilniaus universiteto Informatikos mokslo krypties tarybos posėdyje 2016 m. rugsėjo mėn. 26 d. 10 val. Vilniaus universiteto Matematikos ir informatikos fakulteto 211 auditorijoje.

Adresas: Didlaukio g. 47, LT-08303, Vilnius, Lietuva.

Disertacijos santrauka išsiuntinėta 2016 m. rugpjūčio mėn. 26 d.

Disertaciją galima peržiūrėti Vilniaus universiteto bibliotekoje ir VU interneto svetainėje adresu: www.vu.lt/lt/naujienos/ivykiu-kalendorius.

VILNIUS UNIVERSITY

Dalius Krunglevičius

STDP LEARNING OF SPATIAL AND SPATIOTEMPORAL PATTERNS

Summary of Doctoral Dissertation

Physical Sciences, Informatics (09P)

Vilnius, 2016

The dissertation work was carried out at the Faculty of Mathematics and Informatics of Vilnius University from 2011 to 2015.

Scientific Supervisor

Prof. Dr. habil. Šarūnas Raudys (Vilnius University, Physical Sciences, Informatics – 09P).

The dissertation will be defended at the Council of the Scientific Field of Informatics of Vilnius University:

Chairman

Prof. Dr. Romas Baronas (Vilnius University, Physical Sciences, Informatics – 09P),

Members:

Prof. Dr. Bruce Graham (University of Stirling, Physical Sciences, Informatics – 09P),

Prof. Dr. habil. Kazys Kazlauskas (Vilnius University, Physical Sciences, Informatics – 09P),

Prof. Dr. habil. Henrikas Vaitkevičius (Vilnius University, Biomedical Sciences, Biophysics – 02B),

Prof. Dr. Olegas Vasilecas (Vilnius Gediminas Technical University, Physical Sciences, Informatics – 09P).

The dissertation will be defended at the public meeting of the Council of the Scientific Field of Informatics Sciences of Vilnius University in the auditorium number 211 at the Faculty of Mathematics and Informatics of Vilnius University at 10 a.m. on the 26th of September 2016. Address: Didlaukio g. 47, LT-08303, Vilnius, Lithuania.

The summary of the doctoral dissertation was distributed on the 26th of August, 2016.

The dissertation is available at the library of Vilnius University and online at www.vu.lt/lt/naujienos/ivykiu-kalendorius.

Turinys

Trumpiniai	7
Įvadas	8
Tyrimo laukas ir motyvacija.....	8
Tyrimo objektas ir problematika	10
Aktualumas	11
Praktinė tyrimo reikšmė.....	12
Tyrimo tikslas	12
Tyrimo uždaviniai.....	12
Metodai	12
Mokslinis naujumas	13
Ginamieji teiginiai	13
Aprobavimas.....	14
Disertacijos struktūra	14
1. Disertacijos rezultatai	16
1.1. Neuronų tinklas, skirtas ilgai trunkančioms erdvinėms impulsų struktūrų sekoms atpažinti.....	16
1.1.1. Neuronų tinklo modelis.....	19
1.1.2. Metodai	23
1.1.3. Bandymuose naudotų impulsų struktūrų pavyzdžiai	25
1.1.4. Rezultatai	25
1.1.5. Diskusija	26
1.2. STDP mokymas kintančio triukšmo sąlygomis	28
1.2.1. Invertuotos STDP taisyklės ypatybės reaguojant į Puasono triukšmą.....	28
1.2.2. Metodai	30
1.2.3. Rezultatai	31

1.2.4.	Diskusija	34
1.3.	Konkurencinis STDP mokymas, kuomet erdvinės impulsų struktūros persidengia 36	
1.3.1.	Neuronų tinklo modelis.....	37
1.3.2.	Rezultatai	39
1.3.3.	Diskusija	42
1.4.	Modifikuota STDP tripleto sąveikos taisyklė žymiai padidina mokymo stabilumą, kuomet neuronas mokosi atpažinti erdvines impulsų struktūras	44
1.4.1.	Metodai	44
1.4.2.	Rezultatai	48
1.4.3.	Diskusija	51
	Išvados	54
	Literatūros sąrašas	56

Trumpiniai

STDP – nuo impulso laiko priklausanti sinapsių plastika (*spike-timing-dependent plasticity*).

LTD – ilgalaikė depresija (*long term depression*).

LTP – ilgalaikė potenciacija (*long term potentiation*).

PSP – postsinapsinis potencialas.

EPSP – žadinamasis (*excitatory*) postsinapsinis potencialas.

IPSP – slopinamasis (*inhibitory*) postsinapsinis potencialas.

SRM – impulso atsako modelis (*spike-response-model*).

WTA – „nugalėtojas pasiima viską“ (*winner-take-all*).

ϑ – neurono slenkstinė vertė.

w – sinapsės svoris (stiprumas).

ϕ – sinapsės svorio koeficientas.

u – membranos potencialas.

ϵ – SRM branduolio funkcija, nusakanti membranos potencialo pokytį, kurį sukelia vienintelis presinapsinis impulsas.

η – SRM branduolio funkcija, nusakanti poveikio potencialą ir pėdsakinę hiperpoliarizaciją.

μ – vidurkis.

Įvadas

Tyrimo laukas ir motyvacija

Pats svarbiausias tikslas mašinų mokymo moksliniame lauke yra pasiekti žmogaus lygio pažinimo galimybes ir pagaliau – dirbtinį intelektą, sukurti mąstančią mašiną, kuri gebėtų samprotauti kaip žmogus ir daugiau. Žinoma, šie ambicingi tikslai šiuo metu yra daugiau mokslinės fantastikos nei mokslo sritis, tačiau iš šių tikslų kyla mokslinių tyrimų kryptys bei motyvacija. Šių tyrimų šalutiniai produktai yra šiuo metu praktikoje jau seniai taikomos apsimokančios mašinos, skirtos euristinei optimizacijai, signalų atpažinimui, prognozei, duomenų klasterizavimui. Mašinų mokymas yra taikomas daugelyje žmogaus veiklos sričių: nuo finansų rinkų prognozių iki medicininės diagnostikos, nuo skaitmeninių pramogų iki pramoninės inžinerijos.

Egzistuoja daugelis būdų, kaip kurti mokytis sugebančias sistemas, dauguma šių būdų yra pagrįsti žinomų gamtos procesų mėgdžiojimu, kaip pavyzdžiui, darvinistinė evoliucija, gyvūnų spiečių elgesys ir taip toliau. Žinoma, siekiant atkartoti žmogaus kognityvinius procesus, bandoma atkartoti centrinės nervų sistemos elgesį. Čia prie problemos galima prieiti dvejopai. Viena iš krypčių – „iš viršaus į apačią“, tai yra, remiantis žiniomis apie tai, „ką smegenys daro“. Šiuo atveju paprastai remiamasi žmonių ar gyvūnų psichologija. Ko gero, pats žymiausias tokio tipo tyrimo rezultatas yra pastiprinimu pagrįstas mašinos mokymasis, pagrįstas behavioristinės psichologijos paradigma (Sutton & Barto, 1998). Kitas kelias – „iš apačios į viršų“, kada mašinos mokymosi principai yra grindžiami žiniomis, „kaip smegenys veikia“, smegenų fiziologija. Geriausi tokio tipo tyrimų pavyzdžiai yra dirbtiniai neuronų tinklai, kuriuose bandoma pamėgdžioti biologinio neurono elgesį. Mašinų mokyme yra naudojami daugelių skirtingų šeimų dirbtiniai neuronų tinklai, verta paminėti daugiasluoksnį perceptroną (MLP), saviorganizuojančius neuronų tinklus (SOM). Wolfgangas Maassas skirsto dirbtinius neuronų tinklus į tris kartas: pirmoji karta buvo paremta McCullocho-Pittso neuronais; antroji karta pasižymėjo tolydžiąja aktyvavimo funkcija, pavyzdžiui, sigmoidine funkcija; ir trečioji karta – impulsiniai neuronų tinklai (Maass, 1997).

Kuomet kalbama apie dirbtinius neuronų tinklus, labai svarbu atskirti du susijusius, bet labai skirtingus mokslo laukus. Pirmasis yra komputacinis neuromokslas, kuris yra grindžiamas teoriniu neuromokslu. Neuromokslas nagrinėja smegenų, jų struktūrų bei biologinių neuronų funkcijas. Antrasis mokslinis laukas – tai mašinų mokymas, kuris priskiriamas informatikos atšakai. Neuronų mokslo tikslas yra paaiškinti smegenų veiklą, o mašinų mokymas yra daugiau taikomas mokslas, siekiantis kurti praktiškai pritaikomas mašinas. Kadangi šie du moksliniai laukai pasižymi labai skirtingais tikslais, tarp jų yra nemaža nesutapimų. Pavyzdžiui, perceptronų tinklas buvo išrastas remiantis tuometinėmis žiniomis ir prielaidomis apie biologinių neuronų elgseną, tačiau šiuo metu jau galima gana užtikrintai teigti, jog biologiniai neuronai elgiasi gerokai kitaip. Pavyzdžiui, daugiasluoksnis perceptronų tinklas dažniausiai yra mokomas pasitelkiant „mokymą su mokytoju“ (*supervised learning*), atgalinio sklidimo (*back-propagation*) algoritmą, tačiau tokia analogija biologinėse neuronų sistemose neegzistuoja, kaip ir „mokymas su mokytoju“. Nepaisant to, perceptronų tinklai buvo vystomi ir tiriami dešimtmečiais, todėl buvo labai naudingi taikant juos praktiniams klasifikavimo ir prognozavimo uždaviniams. Kita vertus, neuromokslas sukūrė keletą reikšmingų neuronų mokymo teorijų, kurios sulaukė labai mažai susidomėjimo mašinų mokyme, kadangi buvo sudėtinga šias teorijas pritaikyti praktikoje. Ryškiausi tokių teorijų pavyzdžiai yra Bienenstocko, Coopero ir Munro sinapsių plastikos teorija (BCM) (Bienenstock et al., 1982) bei adaptinio rezonanso teorija (ART) (Grossberg, 2013).

Ši disertacija priklauso moksliniam konekcionizmo laukui (Elman, 1998). Šiame darbe yra jungiamas neuromokslas ir mašinų mokymas, siekiant sukurti naujus struktūrų atpažinimo metodus, buvo pasitelktos žinios apie biologinių neuronų sinapsių plastika bei komputaciniame neuromoksle naudojami neurono modeliai. Pats terminas konekcionizmas (*angl. – connectionism*) buvo pradėtas naudoti dar Donaldo Hebbo penktajame dvidešimtojo amžiaus dešimtmetyje. Disertacijos tyrimo objektas yra impulsinių neuronų tinklų ir nuo impulso laiko priklausančios sinapsių plastikos (*spike-timing-dependent plasticity, STDP*) taikymas erdvinėms, bei erdvinėms-laikinėms struktūroms atpažinti. STDP mokymas priklauso Hebbo mokymo šeimai ir yra aptiktas biologiniuose neuronuose. Nors neuromoksle naudojami neuronų modeliai dažnai geba stulbinamai tiksliai atkartoti biologinių neuronų elgesį, tačiau šių dirbtinių neuronų

negalima paprasčiausiai imti ir pritaikyti realaus pasaulio uždaviniams: čia susiduriama su visa aibe iškylančių problemų. Pavyzdžiui, net toks iš pirmo žvilgsnio, regis, gan paprastas uždavinys kaip realaus pasaulio duomenų kodavimas impulsų sekomis toli gražu nėra paprastas. Kitos problemos yra susijusios su mokymo stabilumu bei modelio parametru optimalumu. Egzistuoja visa įvairovė fenomenologinių STDP modelių, kiekvienas šių modelių pasižymi skirtingomis ypatybėmis. Šiuo metu dar nėra aišku, kurie iš šių modelių yra artimiausi biologinių neuronų funkcijoms, ir kurie iš šių modelių yra tinkamiausi atpažinimo ir klasifikavimo uždaviniams atlikti. Kalbant paprastais žodžiais, šio tyrimo tikslas buvo pritaikyti impulsinių neuronų tinklą su STDP mokymu atpažinimo uždaviniams. Darbo metu buvo suformuluota ir išspręsta keletas svarbių su STDP mokymu susijusių problemų.

Tyrimo objektas ir problematika

Šio darbo esminis tikslas buvo atrasti būdų, kaip pritaikyti dirbtinius impulsinius neuronų tinklus su STDP mokymu impulsų struktūrų atpažinimui. Problemos buvo identifikuojamos ir sprendžiamos paties tyrimo metu.

Kuomet šis tyrimas buvo pradėtas, literatūroje tebuvo keletas darbų šia tema. Buvo žinoma, kad naudojant vieną iš STDP mokymo taisyklių, neuronas elgiasi kaip sutapimų detektorius, ir tai, jog mokant neuronus pagal šią taisyklę, galima aptikti erdvinių-laikinių (*spatiotemporal*) impulsų struktūrų, įterptų į Puasono triukšmą pradžią (Masquelier et al., 2009; Song et al., 2000; Guyonneau et al., 2005; Gerstner & Kistler, 2002). Keli autoriai panaudojo STDP mokymą raidžių atpažinimui (Gupta & Long, 2007; Nessler et al., 2009). Taip pat buvo įdomių darbų, susijusių su evoliucionuojančiais impulsiniais tinklais (Kasabov et al., 2012; 2013).

Šis tyrimas buvo pradėtas atkartojant Masqueliero ir jo kolegų atliktus eksperimentus (Masquelier et al. 2008; 2009). Masquelieras koncentravosi į erdvines-laikines struktūras. Tačiau STDP mokymas paprastame konkurenciniame neuronų tinkle neleidžia sukurti atminties su laiko dimensija, toks neuronų tinklas sugeba prisiminti tik erdvines struktūras. Ši problema išspręsta sukūrus daugiasluoksnį neuronų tinklą, sugeba išmokti ir erdvines-laikines struktūras (Krungelevicius, 2011). Vėliau koncentruotasi ties problemomis, identifikuotomis eksperimentuojant su šiuo tinklu: neuronų modelio parametrai gali būti

optimalūs tik esant tam tikram stimuliacijos lygiui, t. y. jei stimuliacijos lygis kinta, neuronas turi būti perreguliuotas. Stimuliacijos lygis priklauso tiek nuo erdvinės struktūros dydžio, tiek nuo foninio triukšmo lygio. Dar daugiau, erdvinės struktūros (kurios gali būti ir erdvinės-laikinės struktūros komponentais) gali persidengti, o tokiu atveju paprastas STDP mokymas neleidžia jų atskirti. Ši problema išspręsta sukūrus neuronų tinklą, kuriame sinapsių svoriai tapo priklausomi nuo geometrinio atstumo (Krunglevicius, 2015). Taip pat tirtos kintančio foninio triukšmo keliamos problemos – čia pavyko pritaikyti adaptyvųjį dinaminį slopinimą, pagrįstą invertuotu STDP mokymo langu, taip neuronų parametrai gali būti optimalūs platesniame stimuliacijos lygio režyje (Krunglevicius, 2014).

Vėliau bandyta sukurti metodą, kuris leistų nuspėti STDP mokymo proceso elgseną tiksliau, nei egzistuojantys Puasono skirstiniu pagrįsti metodai (Izhikevich & Desai, 2003). Neuronų impulso atsako modelis (*spike-response-model*, SRM), kuris buvo naudojamas šiame darbe, negali generuoti impulsų pagal Puasono skirstinį, taigi pats Puasono skirstiniu pagrįstas metodas nėra tikslus. Esant kitokiam, nei Puasono skirstiniui, STDP mokymas potencialiai gali elgtis visiškai kitaip, nei prognozuoja Izhikevichiaus ir Desai lygtys. Šioje vietoje bandyta modeliuoti postsinapsinės membranos potencialą pasitelkiant dvimačius Azalini skirsnius, tačiau patikimo rezultato pasiekti nepavyko.

Papildomai, panaudojant euristinės optimizacijos metodą, eksperimentiškai palyginta keletas skirtingų fenomenologinių STDP modelių, ir atskleista, jog esant tam tikroms sąlygoms, mokymas naudojant STDP tripleto sąveikos modelį gali būti nepalyginamai sėkmingesnis, nei naudojant kitus STDP sąveikos modelius (Krunglevicius, 2016).

Aktualumas

Jei kada nors žmogaus lygio suvokimas bus pasiektas mašinių mokyme, neįmanoma nuspėti, koks būtų poveikis žmonijai; tegalima teigti, jog poveikis būtų didžiulis. Žinoma, šis darbas tėra labai menka dalelė į bendrą indėlį, tačiau priklauso šiai mokslinių tyrimų kryptim.

Šiuolaikinių kompiuterių našumas nėra pakankamas, kad dirbtinius impulsinių neuronų tinklus būtų galima pritaikyti praktikoje, tačiau gana drąsiai galima teigti, jog tai tėra

laikina kliūtis. Tam, kad ateityje STDP mokymą būtų galima pritaikyti praktiniams uždaviniams, būtina visų pirma iširti tokių dirbtinių neuronų tinklų potencialias galimybes bei ribas.

Praktinė tyrimo reikšmė

Nors šiuo metu STDP mokymo taikymas praktikoje dar nėra pasiektas, šiame darbe buvo išspręsta keletas svarbių problemų, susijusių su STDP mokymu. Kitaip tariant, šis darbas yra žingsnis link praktinės mašinos sukūrimo. Deja, šiuo metu dar negalima pasakyti, ar tokia mašina gali būti efektyvi.

Tyrimo tikslas

Pagrindinis tyrimo tikslas buvo patobulinti žinomus dirbtinius konkurencinius impulsinius neuronų tinklus su STDP mokymu (Guyonneau et al., 2004; Masquelier et al., 2009) sukuriant ir pritaikant naujas neuronų grandis, kad šiuos neuronų tinklus būtų galima taikyti impulsų struktūrų sekų mokymui, taip pat, kad jie gebėtų atskirti tarpusavyje panašias erdvines struktūras, bei rasti būdų, kaip valdyti mokymo procesą, kad tokie neuronų tinklai galėtų funkcionuoti, esant skirtingiems stimuliacijos lygiams.

Tyrimo uždaviniai

Siekiant pasiekti pagrindinius tyrimo tikslus, buvo atlikti šie uždaviniai:

- Suprojektuotas, sukurtas ir išbandytas naujas dirbtinis neuronų tinklas, gebantis išmokti ilgai trunkančias erdvinių-laikinių impulsų struktūrų sekas.
- Suprojektuotas, sukurtas ir išbandytas naujas dirbtinis neuronų tinklas, gebantis išmokti persidengiančias erdvines impulsų struktūras.
- Suprojektuotas, sukurtas ir išbandytas naujas dirbtinis neuronų tinklas, sugebantis adaptuotis prie kintančio foninio triukšmo lygio.
- Eksperimentiškai palyginti skirtingi fenomenologiniai STDP modeliai ir nustatyta, jog esant tam tikroms sąlygoms, mokymas naudojant tripleto sąveikos modelį yra žymiai patikimesnis, nei naudojant kitų tipų sąveikų modelius.

Metodai

Tyrimo metu buvo naudojamas neuronų impulso-atsako modelis (Gerstner & Kistler, 2002) bei keletas skirtingų STDP modelių, įskaitant „artimiausio kaimyno“ sąveiką, „visų

su visais“ sąveiką (Morrison et al., 2008) bei tripleto sąveiką (Pfister & Gerstner, 2006). Neuronų tinklai buvo sukurti ir išbandyti Matlab bei C/C++ aplinkose.

Mokslinis naujumas

Buvo sukurtas dirbtinis neuronų tinklas, gebantis išmokti ilgai trunkančias erdvines impulsų struktūrų sekas, kitaip tariant, erdvines-laikines struktūras. Tai nėra pirmas STDP mokymu pagrįstas atminties modelis (Szatmáry & Izhikevich, 2010), tačiau šiame darbe pasiūlyta neuronų tinklo struktūra yra nauja tai yra daugiasluoksnis WTA grandžių tinklas, gebantis agreguoti įvykių sekas.

Buvo sukurtas dirbtinis neuronų tinklas, gebantis išmokti persidengiančias bei skirtingo dydžio erdvines impulsų struktūras. Ši neuronų tinklo architektūra yra visiškai nauja, ji pagrįsta prielaida, jog nuo Euklido atstumo priklausantis dendritų laidumas gali žymiai veikti neuronų aktyvumą bei mokymą.

Siekiant reguliuoti apmokomo neurono stimuliacijos lygį kintančio triukšmo sąlygomis, buvo panaudotas vertikalus neurono slopinimas, pasitelkiant invertuotą STDP langą. Tai yra naujas metodas.

Pavyko atrasti, jog tam tikromis sąlygomis STDP tripleto sąveika lemia žymiai stabilesnį mokymą nei kiti sąveikų tipai, pagrįsti impulsų poromis.

Ginamieji teiginiai

1. Nėra jokių teorinių kliūčių siekiant pritaikyti STDP mokymą erdvinėms-laikinėms impulsų struktūroms atpažinti. Tai sutvirtina hipotezę, jog erdvinės-laikinės struktūros perneša informaciją biologinėse nervų sistemose.
2. Pritaikius vertikalų slopinimą bei nuo euklidinio atstumo priklausantį sinapsės svorio koeficientą, įmanoma sukurti dirbtinį neuronų tinklą, gebantį atpažinti persidengiančias bei skirtingo dydžio erdvines impulsų struktūras. Taikant šį metodą taip pat iš dalies išsprendžiama parametrų optimalumo priklausomybės nuo stimuliacijos lygio problema.
3. Esant kintančiam foninio triukšmo lygiui, galima pritaikyti STDP mokymu pagrįstą adaptyvųjį slopinimą. Taip neuronas gali būti efektyviai mokomas, net jei stimuliacijos lygis kinta per laiką.

4. STDP tripleto sąveika gali nulemti kur kas stabilesnį ir spartesnį mokymo procesą nei įprastinės „visų su visais“ ir „artimiausio kaimyno“ sąveikos.

Aprobavimas

Disertacijos rezultatai buvo pristatyti trijose tarptautinėse konferencijose:

- NCTA 2011 – International Conference on Neural Computation Theory and Applications, Paris, France;
- BISIP 2014 – The 3rd IEEE workshop on Bio-Inspired Signal and Image Processing, Vilnius, Lithuania;
- NCTA 2014 – International Conference on Neural Computation Theory and Applications, Rome, Italy.

Pagrindiniai disertacijos rezultatai buvo publikuoti recenzuojamuose leidiniuose:

1. Krunglevicius, D. (2011). Neural Processing of Long Lasting Sequences of Temporal Codes-Model of Artificial Neural Network Based on a Spike Timing-Dependent Learning Rule. IJCCI (NCTA), 196–204. SciTePress, (2011).
2. Krunglevicius, D. (2014). STDP Learning Under Variable Noise Levels. IJCCI (NCTA), 165–171. SciTePress, (2014).
3. Krunglevicius, D. (2015). Competitive STDP Learning of Overlapping Spatial Patterns. Neural Comput, 27(8): 1673–85.
4. Krunglevicius, D. (2016). Modified STDP Triplet Rule Significantly Increases Neuron Training Stability in the Learning of Spatial Patterns. Advances in Artificial Neural Systems, 2016, 1.

Disertacijos struktūra

Disertacija susideda iš įvado, trijų pagrindinių skyrių, išvadų ir literatūros sąrašo. Pirmi du skyriai nėra įtraukti į disertacijos santrauką. Pirmame skyriuje supažindinama su fundamentaliais neurono biologijos pagrindais, kurie yra svarbūs siekiant gerai suprasti disertacijos tekstą. Šiame skyriuje trumpai pristatoma neurono impulso fiziologija, žinomi sinapsių plastikos tipai ir neuroninio kodavimo koncepcijos. Antras skyrius yra skirtas komputaciniam neuromokslui, jame trumpai apžvelgiami plačiai vartojami komputaciniai neuronų modeliai bei fenomenologiniai STDP modeliai. Trečiasis skyrius aprašo tyrimo

eigą bei rezultatus, šiame skyriuje yra penki poskyriai, keturi iš jų yra skirti kiekvienam ginamajam teiginiui.

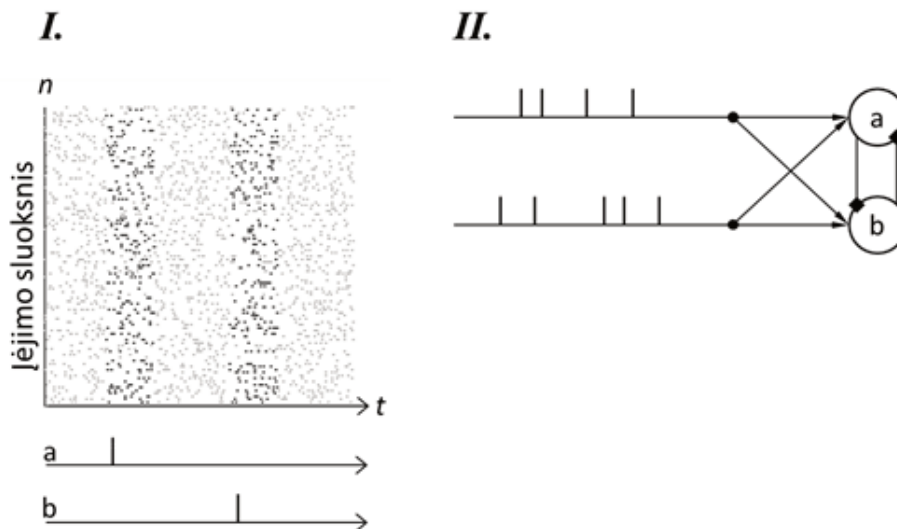
Tyrimo pradžia aprašoma skyriuje „Neuronų tinklas, skirtas ilgai trunkančioms erdvinėms impulsų struktūrų sekoms atpažinti“, šio darbo eigoje buvo identifikuotos kelios problemos, susijusios su konkurenciniu mokymu WTA grandyse: nebuvo aišku, kaip adaptuoti neuroną, kuomet stimuliacijos lygiai yra skirtingi, kaip atskirti erdvinės struktūras vienas nuo kitų, jei jos žymiai persidengia. Šios problemos sprendžiamos skyriuose „STDP mokymas kintančio triukšmo sąlygomis“ ir „Konkurencinis STDP mokymas, kuomet erdvinės impulsų struktūros persidengia“. Disertacijoje yra papildomas skyrius, skirtas kai kurioms SRM modelio statistinėms ypatybėms aptarti, tačiau šioje santraukoje šis skyrius perleistas kaip neesminis. Paskutinis tyrimų dalies skyrius yra „Modifikuota STDP tripleto sąveikos taisyklė žymiai padidina mokymo stabilumą, kuomet neuronas mokosi atpažinti erdvinės impulsų struktūras“, kuriame eksperimentiškai lyginami keli skirtingi STDP modeliai. Čia buvo siekiama parinkti geriausią kandidatą tarp žinomų STDP modelių, siekiant pagerinti anksčiau pasiūlytų neuronų tinklų mokymo našumą.

1. Disertacijos rezultatai

1.1. Neuronų tinklas, skirtas ilgai trunkančioms erdvinėms impulsų struktūrų sekoms atpažinti

Disertacijos tyrime buvo koncentruojamasi į erdvines ir erdvines-laikines impulsų struktūras. Pats paprasčiausias erdvinės-laikinės impulsų struktūros pavyzdys gali būti atvaizduotas dvimačiame dvejetainiame „taip/ne“ masyve, kur kiekvienas stulpelis priklauso skirtingam laiko intervalui, o eilutėse yra nurodomi impulsai, gaunami per individualią sinapsę, kur trumpame laiko lange „taip“ sinapsės impulso tikimybė yra žymiai didesnė nei „ne“ sinapsės, ir kur „taip“ impulsai glaudžiai koreliuojasi lauke, o „ne“ sinapsės generuoja tarpusavyje nesikoreliuojančius impulsus, pavyzdžiui, Puasono triukšmą. Paprasčiausias erdvinės-laikinės struktūros pavyzdys yra erdvinė struktūra, tai yra, visi „taip“ impulsai nutinka vienu metu. Kuomet erdvinėms struktūroms pritaikomas STDP mokymas, tam tikrame modelio parametrų ruože sinapsių, kurios priklauso struktūrai, svoriai auga, o likusiųjų – mažėja. Kitaip tariant, individualus neuronas elgiasi kaip sutapimų detektorius (Abbott & Nelson, 2000). Pačiu paprasčiausiu įmanomu atveju tokio tipo mokymas gali būti supaprastintas į mokymą su mokytoju, kaip paprasta priskyrimo operacija: jei sinapsė priklauso struktūrai, jos svoriui priskiriamas 1, jei ne, svoriui priskiriamas 0.

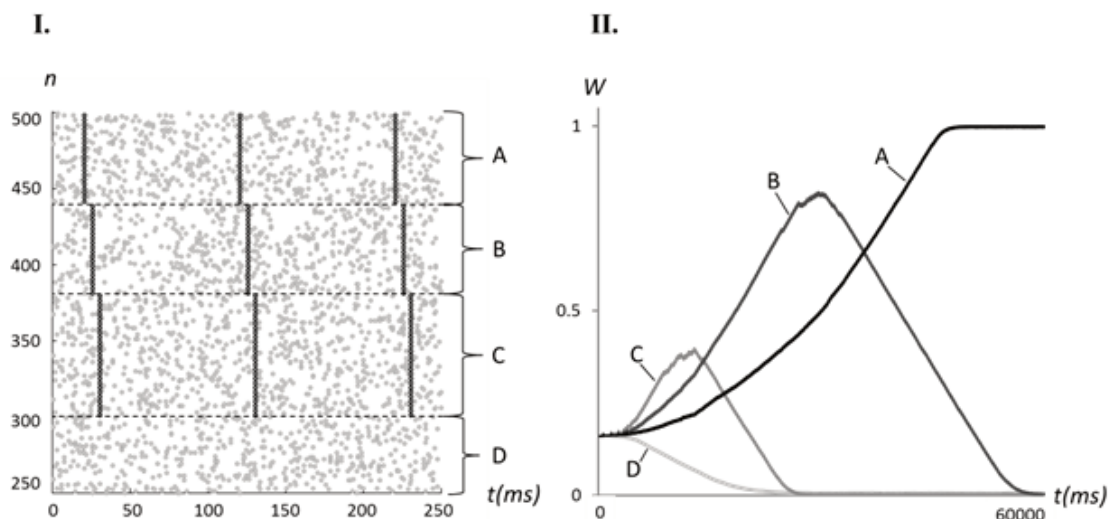
Tyrimas buvo pradėtas atkartojant Masqueliero ir jo kolegų eksperimentus (Masquelier et al., 2008, 2009). Pirmajame darbe (Masquelier et al., 2008) Masquelieras pritaikė vieną SRM neuroną erdvinėms-laikinėms struktūroms, įterptomoms į Puasono triukšmą, atpažinti. Mokymas buvo sėkmingas, net jei struktūros buvo pateikiamos neuronui ne periodiškai. Buvo pademonstruota, jog neuronas sugeba aptikti struktūros pradžią laiko ašyje. Vėliau Masqueliero grupė išplėtė eksperimentą pridėję daugiau tarpusavyje konkuruojančių neuronų (Masquelier et al., 2009) ir parodė, jog keletas neuronų gali išmokti keletą skirtingų struktūrų. Vėlgi, neuronai gebėjo aptikti struktūros pradžią laiko ašyje (Pav. 1.1.).



Pav. 1.1. Masqueliero ir jo kolegų atliktas eksperimentas. Schematiškai perpiešta pagal Masquelier et al., 2009. **I.** Struktūros pavyzdžiai. Juodi taškai žymi nekintančią struktūrą, pilki taškai žymi Puasono triukšmą. Pasikartojančios struktūros buvo įterpamos ne periodiškai. Apačioje pavaizduoti dviejų apmokytų neuronų atsako impulsai, abu neuronai reaguoja į skirtingas struktūras. **II.** Masqueliero tinklo schema. Rodyklės žymi skatinančiąsias sinapses, rombai žymi slopinamąsias sinapses.

Pažvelgus į erdviųjų-laikinių struktūrų mokymosi procesą atidžiau, tampa akivaizdu, jog neuronas sugeba įsiminti tik vieną tokios struktūros komponentą, iš esmės – pirmąjį laiko ašyje. Siekiant detaliau paaiškinti šį neurono gebėjimą, buvo atliktas paprastas eksperimentas: buvo parinkta struktūra, susidedanti iš trijų erdviųjų komponentų, A, B ir C, visuomet išdėstytų laike ta pačia tvarka (Pav. 1.2. I.). Kiekvieną komponentą generavo atitinkama sinapsių grupė. Didžioji dauguma įėjimo sinapsių pastoviai struktūrai nepriklausė, jos yra pažymėtos raide D. Komponentas C buvo parinktas didesnis nei A ir B, siekiant paveikti neurono pasirinkimą mokymo pradžioje (juo didesnis komponentas, juo labiau neapmokytas neuronas yra linkęs į jį reaguoti). Pradiniai sinapsių svoriai buvo parinkti atsitiktinai, pagal tolygųjį skirstinį. Mokymo pradžioje neuronas nebuvo selektyvus nė vieno komponento atžvilgiu. Mokymo pradžioje sinapsių, priklausančių grupei C, svoriai augo sparčiausiai, o sinapsių, priklausančių grupei D, svoriai mažėjo (Pav. 1.2. II.). Kuomet neuronas tapo selektyvus struktūrai C, STDP mokymas ėmė auginti ir sinapsių A ir B svorius, kadangi jos buvo susijusios su laiko ašyje anksčiau esančiomis struktūromis: kuo komponentas yra arčiau postsinapsinio impulso, tuo didesnė yra ilgalaikės potenciacijos vertė, tai yra, tuo sparčiau auga su komponentu susiję svoriai. Kuomet svoriai, susiję su komponentu B, išauga pakankamai, kad neurono atsakas

pasislinktų laike link komponento B tiek, kad būtų ankstesnis už komponentą C, C grupės sinapsės ima patirti ilgalaikę depresiją, tai yra, jų svoriai ima mažėti. Vėliau lygiai tas pats nutinka ir su komponentu A ir galėtų toliau kartotis, jei komponentų būtų daugiau. Pabaigoje tik sinapsės, susijusios su pačiu pirmuoju komponentu laiko ašyje, turi pakankamai didelius svorius, kad galėtų lemti postsinapsinį neurono impulsą, o visa kita neurono sinapsėse buvusi atmintis prarandama.



Pav. 1.2. Struktūros pradžios aptikimas. Vienas neuronas buvo mokomas struktūros, kurią generavo 500 jėjimo neuronų. **I.** Struktūros pavyzdys. Vertikalioje ašyje yra individualūs jėjimo neuronai. Pilki taškai žymi Puasono triukšmą, juodi taškai žymi įterptą struktūrą. Pažymėtos keturios jėjimo neuronų grupės: A, B ir C grupės generavo skirtingas struktūros dalis, o D – tik Puasono triukšmą. **II.** Sinapsių svorių dinamika. Vertikalioje ašyje – vidutiniai sinapsių svoriai.

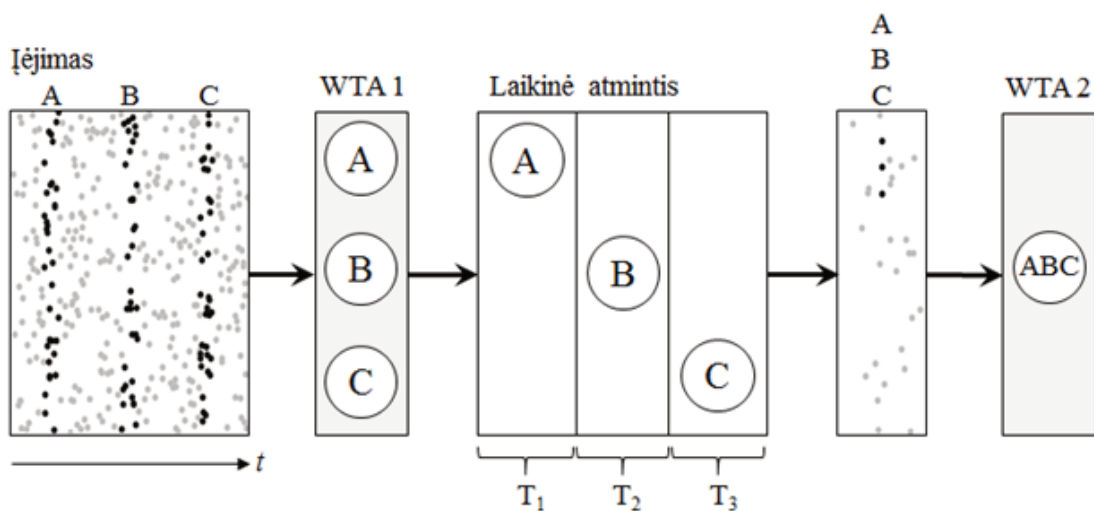
Pažvelgus į eksperimento rezultatus, atvaizduotus Pav. 1.2., tampa akivaizdu, kad visi komponentai, išskyrus patį pirmąjį, gali būti pakeisti, sukeisti vietomis arba pašalinti be jokios įtakos apmokyto neurono elgsenai. Tas pats principas galioja ir Masqueliero eksperimentuose. Taigi, tokio tipo mokymas neleidžia užkoduoti informacijos erdvinėse-laikinėse struktūrose. Šioje stadijoje buvo suformuluota problema: ar galima sukurti STDP mokymu pagrįstą dirbtinių neuronų tinklą, kuris išsaugotų atmintį apie erdvinius komponentus, išsidėsčiusius laike? Jei erdvinis komponentas apibrėžtas raide, ar galima sukurti tinklą, kuris mokytųsi iš raidžių sudarytų žodžių?

Tyrimo metu sėkmingai pavyko sukurti tokį dirbtinių neuronų tinklą, kuris ne tik geba išmokti erdvines-laikines struktūras, bet ir atkartoti erdvinį komponentų (raidžių) sekas.

Šis darbas buvo pristatytas tarptautinėje konferencijoje NCTA 2011 bei publikuotas konferencijos leidinyje ir SCITEPRESS skaitmeninėje bibliotekoje (Krunglevicius, 2011).

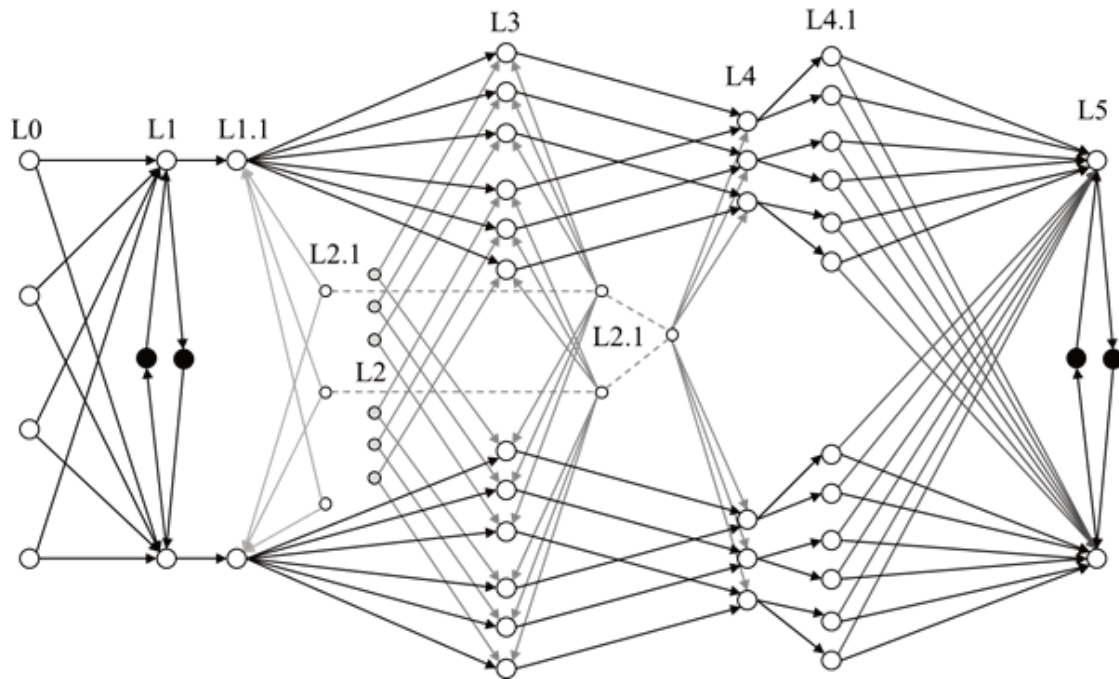
1.1.1. Neuronų tinklo modelis

Pav. 1.3. yra koncepcinė dirbtinio neuronų tinklo diagrama. Šiame tinkle yra du WTA sluoksniai. Pirmasis sluoksnis, WTA1, išmoksta erdvinės-laikines struktūras. WTA1 atsako impulsus įsimena laikinės atminties sluoksnis, kur individualus WTA1 impulsas priskiriamas atitinkamam laiko langui. Vėliau atmintis yra nuskaitoma, dėl ko sugeneruojama nauja erdvinė impulsų struktūra, kurioje kiekvienas impulsas atitinką prieš tai registruotą WTA1 impulsą tam tikrame laiko lange. Ši antrinė erdvinė impulsų struktūra perduodama antrajam, WTA2 sluoksniui. Šioje diagramoje nuoseklūs įvykiai, A, B ir C, buvo konvertuoti į paralelų kodą, tai yra, erdvinę impulsų struktūrą.



Pav. 1.3. Koncepcinė neuronų tinklo diagrama. Čia juodi taškai rodo struktūras, kurias išmoksta WTA sluoksniai, pilki taškai žymi foninį triukšmą. Triukšmas yra būtinas, jog sinapsių, nepriklausančių struktūrai, svoriai sumažėtų.

Dirbtinis neuronų tinklas, kurio schema pavaizduota Pav. 1.4., yra sudarytas iš šešių pagrindinių sluoksnių: L1 ir L5 yra konkurenciniai WTA sluoksniai. Nugalėtojai rašoma daugiskaita, kadangi šiame tinkle keletui neuronų yra įmanoma išmokti tą pačią struktūrą. Sluoksniai L1 ir L5 turi įėjimus iš sluoksnių L0 ir L4. Sluoksnis L3 yra laikinės (temporalinės) atminties sluoksnis; jį moduliuoja sluoksnis L2. Šiame tinkle nėra atkartojamos jokios žinomos biologinių nervų sistemų struktūros, sluoksnių pavadinimai buvo pasirinkti laisvai.



Pav. 1.4. Neuronų tinklo diagrama. Juoda spalva žymi slopinamuosius neuronus. Eksperimento metu slopinamieji neuronai buvo pakeisti tiesioginėmis slopinamosiomis sinapsėmis. Pilkos linijos, jungiančios neuronus L2 ir L2.1, žymi laikinės moduliacijos sistemą. Punktyrinės linijos žymi, jog tai yra tas pats neuronas, kuris, siekiant didesnio aiškumo, diagramoje atvaizduotas du kartus. Sluoksnis L4.1 yra šakotuvus, perduodantis impulsų sekas iš sluoksnio L4 į sluoksnį L5. Sluoksnis L4.1 buvo įtrauktas dėl patogumo programuojant.

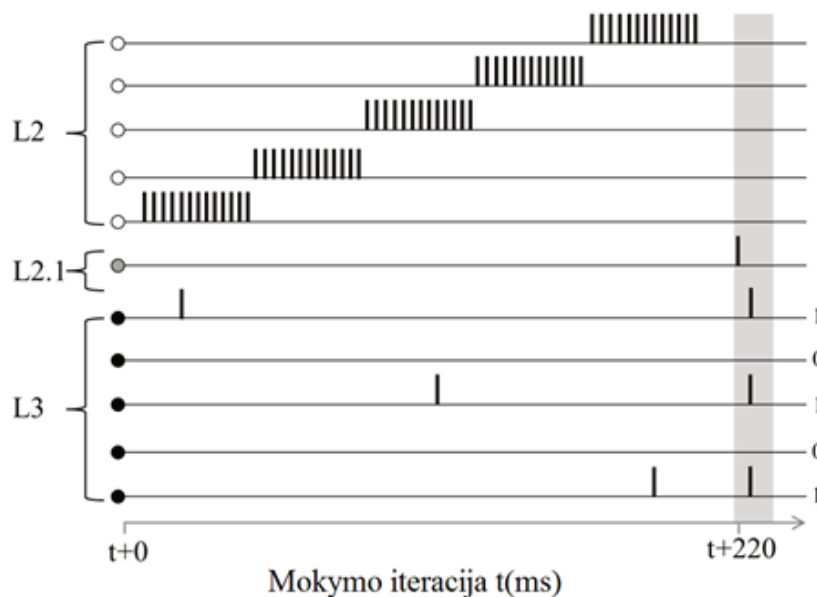
Neuronai, priklausantys sluoksniui L0, periodiškai generuoja erdvinę impulsų struktūrą, taip pat generuoja spontaniškus impulsus su tikimybe PL0 kiekviename simuliacijos žingsnyje, taigi, generuoja Puasono triukšmą. Triukšmas yra reikalingas svoriams mažinti mokymo procese.

Neuronai, priklausantys sluoksniui L1, priima impulsus iš L0, taip pat jie yra sujungti slopinamosiomis sinapsėmis, kurių svoriai nekinta, tokiu būdu L1 yra WTA subtinklas.

L1 neuronai perduoda impulsus L1.1 tarpiniams neuronams per stiprias nekintančių svorių sinapses. Šių sinapsių svoriai yra pakankamai dideli, kad vienas impulsas iš L1 neurono sukeltų postsinapsinį impulsą L1.1 neurone. Sluoksnis L1.1 yra reikalingas, kad vėlesnis atminties nuskaitymas nedarytų įtakos L0 su L1 sluoksnius jungiančių sinapsių svoriams.

Sluoksnis L2, įskaitant L2.1 neuronus, yra laikinės moduliacijos sluoksnis (Pav. 1.5.). Žadinamieji impulsai, kuriuos skleidžia L2 ir L2.1 sluoksnių neuronai, imituoja bangos sklidimą sužadinaujamoje terpėje uždaru ciklu, tik vienas neuronas būna aktyvus vienu metu.

L2 sluoksnio neuronai generuoja impulsų seką, o L2.1 – pavienį impulsą. Sinapsių, išeinančių iš L2 ir L2.1 sluoksnių neuronų, svoriai nekinta.



Pav. 1.5. Laikinės moduliacijos pavyzdys. Pavyzdyje penki L3 sluoksnio neuronai priima impulsus iš vienintelio L1.1 neuro. L2 sluoksnis stimuliuoja individualų L3 neuroną, stimuliacija trunka maždaug 40 ms. Jei per tą laiką L3 neuronas gauna papildomą impulsą iš L1.1, sugeneruojamas paties L3 neuro impulsas, atitinkamai STDP žymiai padidina sinapsės svorį. Po 220 ms L2.1 neuronas iššauna vienintelį impulsą, kuris silpnai stimuliuoja L3 neuronų grupę ir visus L4 neuronus. Tuo metu L3 sluoksnio neuronai jau prisimena ankstesnius impulsus ir sugeneruoja erdvinę struktūrą L4 neuronams. Šiame pavyzdyje L1.1 sluoksnio neuronai iššovė tris impulsus, iš kurių L3 sluoksnio neuronai sugeneravo erdvinę struktūrą 10101.

Kiekviena sinapsė, jungianti L1.1 sluoksnio neuroną su L3 sluoksnio neuronais, yra dvejetainės atminties celė. Sinapsė įsimena L1.1 sluoksnio neuro impulsą, atitinkantį tam tikrą laiko langą, priklausomą nuo L2 sluoksnio neuro aktyvumo laiko. L3 sluoksnio neuronai yra grupėse, grupes apibrėžia sinapsės iš L1.1 sluoksnio neuronų. Kiekvienas L3 sluoksnio neuronas gauna stiprų dirgiklį iš skirtingų L2 sluoksnio neuronų. Tačiau šis dirgiklis nėra pakankamas postsinapsiniam impulsui sugeneruoti. Pradžioje sinapsės, jungiančios L1.1 sluoksnį su L3, yra silpnos: jų svoriai negali tiek augti, kad sukeltų postsinapsinį L3 sluoksnio neuronų impulsą, impulsas sugeneruojamas tik esant papildomai stimuliacijai iš L2 arba L2.1 sluoksnio. Taigi, L3 sluoksnio neuronas generuoja impulsą tik tuo atveju, jei jis yra stimuliuojamas L2 ir L1.1 sluoksnių neuronų impulsų vienu metu. Tokiu atveju STDP žymiai padidina sinapsės svorį.

Eksperimentų metu sinapsių, jungiančių L1.1 sluoksnį su L3, svoriai buvo dirbtinai mažinami su kiekviena laiko iteracija, taip atminties celė buvo atstatoma į pradinę būseną. Biologiniuose neuronuose ilgalaikis sinapsės svorio padidėjimas arba ilgalaikė potenciacija trunka nuo kelių valandų iki mėnesių ir ilgiau (Abraham, 2003), taigi, svorių mažėjimas einant laikui šiame modelyje neprieštarauja biologinių sinapsių ypatybėms.

L2.1 sluoksnio neuronai aktyvuoja atminties nuskaitymą. Kiekvienas L2.1 sluoksnio neuronas turi stiprias sinapses, jungiančias su visais L1.1 neuronais, silpnas sinapses – su visais L4, bei silpnas sinapses – su L3 sluoksnio neuronais. L3 sluoksnio neuronų grupė atitinka laiko langą. Impulsas iš L2.1 sluoksnio visada sugeneruoja impulsą L1.1 sluoksnio neuronuose. L2.1 sluoksnio neuronas aktyvumo metu generuoja vienintelį impulsą: jis stimuliuoja L3 sluoksnio neuroną daug silpniau nei L2, taigi, atminties nuskaitymo metu L3 sluoksnio neurono impulsas galimas tik esant dideliame L1.1 sluoksnį su L3 jungiančios sinapsės svoriui.

Neuronų sluoksnis L4 yra įėjimo sluoksnis WTA sluoksniui L5. Sinapsės, jungiančios L3 sluoksnį su L4, yra vidutinio fiksuoto svorio, taigi impulsas iš L3 gali sugeneruoti impulsą L4 sluoksnio neurone tik tuo atveju, jei L4 sluoksnio neuronas yra papildomai sužadintas impulsu iš L2.1.

Neuronų sluoksnis L4.1 yra įterptas dėl patogumo programuojant bei palengvina parametrų reguliavimą. Tyrimo metu pastebėta, jog didesnis įėjimo neuronų kiekis leidžia turėti platesnius parametrų rėžius, prie kurių mokymas vyksta sėkmingai. Kadangi eksperimento metu buvo naudojama palyginti mažai neuronų, šis sluoksnis padvigubino L5 sluoksnio neuronų įėjimų kiekį. Esant didesniai tinklui, tai būtų visiškai nereikalinga. L4.1 neuronų sluoksnis, analogiškai L0, generuoja ir spontaniškus impulsus, tai yra, Puasono triukšmą.

Neuronų sluoksnis L5 yra analogiškas L1, tačiau STDP mokymo parametrai buvo nustatyti skirtingi.

Bandymų metu L1 sluoksnio neuronai buvo mokomi visą laiką, o L5 sluoksnio pradėti mokyti tik praėjus 100 000 mokymo iteracijų. Paprasčiausiai pirmoje bandymų pusėje L4 sluoksnio neuronams buvo uždrausta generuoti impulsus.

1.1.2. Metodai

Šiame skyriuje aprašomi neurono bei sinapsių plastikos modeliai. Neurono modeliu buvo pasirinktas impulso-atsako modelio (SRM) diskrečioji modifikacija (Gerstner & Kistler, 2002). SRM modelis buvo panašus į naudotą Masqueliero darbuose (Masquelier et al., 2008; 2009), tačiau buvo panaudotos papildomos modifikacijos, siekiant paspartinti skaičiavimus. SRM modelis buvo pasirinktas dėl paprastumo ir pakankamai aukšto tikslumo atkuriant biologinio neurono membranos potencialo procesą (Jolivet et al., 2006). SRM η -kernelio funkcijai, kuri apibrėžia poveikio potencialą bei pėdsakinę hiperpolarizaciją, buvo pasirinkta:

$$\eta(t) = W_{ap} \left(K_{dpl} e^{\frac{-\Delta t_h}{T_m}} - K_{hpl} \left(e^{\frac{-\Delta t_h}{T_m}} - e^{\frac{-\Delta t_h}{T_{ap}}} \right) \right) \quad (1.1),$$

kur $\Delta t_h = t - t_{spike}$, čia t_{spike} yra paskutinio postsinapsinio impulso laikas; pastoviosios $K_{dpl} = 3$, $K_{hpl} = 5$ ir $W_{ap} = 40$ apibrėžia funkcijos amplitudę; $T_m = 10$ ms yra membranos laiko pastovioji, kuri apibrėžia hiperpolarizacijos nuolydį, ir $T_{ap} = 0,5$ ms yra laiko pastovioji, kuri apibrėžia impulso nuolydį.

Eksperimentai buvo atlikti vienos milisekundės tikslumu, todėl viena simuliacijos iteracija apibrėžiama kaip milisekundė.

Postsinapsinio potencialo, kurį generuoja viena sinapsė j , vertė $\epsilon(t)$ yra išreikšta:

$$\epsilon_j(t) = \phi_j w_j \left(e^{\frac{-\Delta t}{T_m}} \left(1 + x_{m_j}(t) \right) - e^{\frac{-\Delta t}{T_s}} \left(1 + x_{s_j}(t) \right) \right) \quad (1.2),$$

kur $\Delta t = t - t_{pre}$; čia t_{pre} yra paskutinio presinapsinio impulso laikas; w_j yra sinapsės svoris; žadinamųjų sinapsių $\phi = 1$, slopinamųjų $\phi = -1$. $T_m = 10$ ms ir $T_s = 2,5$ ms laiko pastoviosios. Kintamieji x_m ir x_s palengvina eksponenčių integravimą ir yra apskaičiuojami:

$$x_{m_j}(t) = \begin{cases} \frac{w_j(t-1)}{w_j(t)} e^{\frac{-\Delta t}{T_m}} \left(1 + x_{m_j}(t-1) \right) & \text{if } t = t_{pre} \\ x_{m_j}(t-1) & \text{if } t \neq t_{pre} \end{cases} \quad (1.3),$$

$$x_{s_j}(t) = \begin{cases} \frac{w_j(t-1)}{w_j(t)} e^{\frac{-\Delta\tau}{T_s}} (1 + x_{s_j}(t-1)) & \text{if } t = t_{pre} \\ x_{s_j}(t-1) & \text{if } t \neq t_{pre} \end{cases} \quad (1.4),$$

čia $\Delta\tau$ yra laiko skirtumas tarp paskutinio ir priešpaskutinio presinapsinių impulsų laikų. Pradinės x_m ir x_s vertės yra nulinės. Lygtys (1.3) ir (1.4) buvo išvestos tokiu būdu: individualių postsinapsinių vienos sinapsės potencialų suma laiko momentu t gali būti išreikšta baigtine eilute:

$$\epsilon_j(t) = w_0 e^{\frac{-(t-t_0)}{T_m}} - w_0 e^{\frac{-(t-t_0)}{T_s}} + \dots + w_n e^{\frac{-(t-t_n)}{T_m}} - w_n e^{\frac{-(t-t_n)}{T_s}} \quad (1.5),$$

kur w_n yra svorių aibė kiekvienam impulsui ir t_n – impulsų laikų aibė. Išraiška teisinga, jei visi $t_n < t$. Imant teigiamus ir neigiamus eilutės narius atskirai, pirmi du eilutės nariai gali būti išreikšti taip:

$$(1 + x_0)w_0 e^{\frac{-(t-t_0)}{T_m}} + w_1 e^{\frac{-(t-t_1)}{T_m}} = (1 + x_1)w_1 e^{\frac{-(t-t_1)}{T_m}} \quad (1.6),$$

kur simuliacijos pradžioje $x_0 = 0$. Algebrinis lygties (1.6) sprendimas yra lygtys (1.3) ir (1.4). Šių kintamųjų naudojimas leidžia sutaupyti operacijų kiekį ir sutrumpinti simuliacijos laiką, kadangi diskrečiajame laike eksponentės gali būti suskaičiuotos iš anksto, o kintamieji x skaičiuojami tik impulso įvykio metu.

Neurono membranos potencialas bet kuriuo metu:

$$u(t) = \begin{cases} \eta(t) & \text{if } t = t_{spike} \\ \eta(t) + \sum \epsilon(t) & \text{otherwise} \end{cases} \quad (1.7).$$

Neurono impulsas sugeneruojamas, kuomet neurono membranos potencialas pasiekia slenkstinę vertę ϑ .

STDP funkcija, naudota šiame tyrime, yra pateikta lygtyje (1.8). Sinapsės svorio pokytis, kada $\Delta t = t_{post} - t_{pre}$ yra:

$$\Delta w_j = \begin{cases} A_{LTP} \cdot e^{\frac{\Delta t}{\tau_{LTP}}} & \text{if } \Delta t < 0 \\ -A_{LTD} \cdot e^{\frac{-\Delta t}{\tau_{LTD}}} & \text{if } \Delta t > 0 \\ 0 & \text{if } \Delta t = 0 \end{cases} \quad (1.8).$$

Sinapsių svoriai buvo apriboti tarp w_{min} ir w_{max} , skirtingų sinapsių tipai šiame tinkle turėjo skirtingus svorius. Siekiant išvengti neapibrėžtumo lygtyse (1.3) ir (1.4), w_{min} niekada nebuvo nulis, o mažiausia galima reikšmė – $1 \cdot 10^{-6}$.

Dalis neurono ir STDP parametrų buvo iš dalies optimizuoti pasitelkiant genetinį algoritmą, likusių parametrų reikšmės buvo sureguliuotos ranka. Bandymų metu STDP taisyklei buvo taikomas „artimiausio kaimyno“ sąveikos tipas.

1.1.3. Bandymuose naudotų impulsų struktūrų pavyzdžiai

L0 sluoksnyje generuojamos struktūros yra 4×250 matricos, kur galimos reikšmės – 0 arba 1, vienetas žymi impulsą. Tai yra buvo panaudota 250 įėjimo neuronų, o struktūros trukmė – 4 ms. Impulsai struktūrose buvo paskirstyti atsitiktinai, pasitelkus tolygųjį skirstinį su tikimybe $p = 0,04$. Patogumo dėlei L0 generuojamos struktūros pažymėtos mažosiomis raidėmis a, b, c, d ir e. Raidės buvo generuojamos 40 ms intervalais. Tarpuose tarp raidžių L0 sluoksnyje generuojamas Puasono triukšmas su ta pačia tikimybe $p = 0,04$. Pirmąsias 100 000 mokymo iteracijų raidės buvo parenkamos atsitiktine tvarka.


Po 100 000 iteracijų raidės buvo sukombinuotos į pastovius žodžius pažymėtus didžiosiomis raidėmis A, B, C, D ir E. Kiekvienas žodis buvo sudarytas iš penkių nesikartojančių raidžių, tai yra atsitiktinių a, b, c, d ir e permutacijų. Žodžiai buvo generuojami atsitiktine tvarka, žodžio pradžia buvo suderinta taip, jog žodis prasidėtų tuoj po L2.1 atminties nuskaitymo momento. Atminties nuskaitymo metu sluoksnyje L0 buvo generuojama atsitiktinė raidė. Intervalai tarp raidžių liko tokie patys – 40 ms.

Sluoksnyje L4.1, analogiškai sluoksniui L0, buvo generuojamas ir Puasono triukšmas. Tačiau L4.1 sluoksnyje triukšmo lygis buvo pasirinktas žemesnis – $p_{L41} = 0,01$.

1.1.4. Rezultatai

Neuronų tinklas buvo išbandytas daugeliu simuliacijų, papildomai atskirai buvo matuojamas klaidų kiekis WTA grandyse. Kiekviena simuliacija truko 700 000 iteracijų,

pirmosios 100 000 iteracijų buvo skirtos tik L1 sluoksnio mokymui. Tipinis L5 sluoksnio atsakas pavaizduotas Pav. 1.6.



Pav. 1.6. L5 sluoksnio impulsai mokymo pradžioje ir pabaigoje. Dvidešimties skirtingų neuronų impulsai išdėstyti vertikaliai. Raidės virš struktūrų žymi žodžius, kurie buvo pateikiami L5 sluoksniui atitinkamu laiko momentu. **(a)** Tinklo atsakas mokymo pradžioje. Nors L5 sluoksnis patyrė tik keletą žodžių, pastovi atsako struktūra ima formuotis jau mokymo pradžioje. **(b)** Tinklo atsakas mokymo pabaigoje.

1.1.5. Diskusija

Šiame skyriuje pristatytas dirbtinis neuronų tinklas geba išmokti ilgai trunkančias erdvinių-laikinių struktūrų kombinacijas. Taip parodoma, jog vien tik STDP mokymo pakanka tam, kad dirbtinis neuronų tinklas sugebėtų įsiminti laiko ašyje besikartojančias impulsų struktūras. Dar daugiau, pasiūlytas dirbtinis neuronų tinklas sugeba atkartoti pateiktas impulsų struktūrų sekas. Atkartojimas gaunamas nuosekliai aktyvuojant L2.1 sluoksnio neuronus.

Gebėjimas atkartoti laiko ašyje stebėtus įvykius reiškia, jog tokio tipo atmintis gali būti kopijuojama, persiunčiama, palyginama ir taip toliau. Taip pat turėtų būti gana paprasta praplėsti šį dirbtinį neuronų tinklo modelį, kad tinklas gebėtų atpažinti ne tik raides, bet ir žodžių kombinacijas, nors toks mokymas pareikalautų kitokio mastelio moduliacijos laiko ašyje.

Biologinis pagrįstumas

Pasiūlyto dirbtinio neuronų tinklo struktūra bei simuliacijos parametrų vertės buvo pasirinkti laisvai, neatsižvelgiant į jokių empirinius duomenis, todėl šis modelis negali būti laikomas biologiškai patikimu. Tačiau esminiai mokymo principai yra pagrįsti žinomu biologiniu procesu, taip pat informacijos kodavimas laikinėmis struktūromis yra iš dalies pagrįstas eksperimentų rezultatais.

Kadangi konkretus neuronų tinklo modelis buvo kuriamas siekiant paprastumo, labai tikėtina jog yra daugybė kitų būdų dirbtiniam neuronų tinklui, pasižyminčiam panašiomis ypatybėmis arba geresniu mokymo našumu, sukurti. Pavyzdžiui, tinklui moduluoti laiko ašyje būtų labiau biologiškai pagrįsta vietoje skatinamųjų neuronų naudoti slopinamuosius neuronus: yra eksperimentinių įrodymų, jog smegenų gama bangos yra generuojamos būtent slopinamųjų neuronų (Cardin et al., 2009).

1.2. STDP mokymas kintančio triukšmo sąlygomis

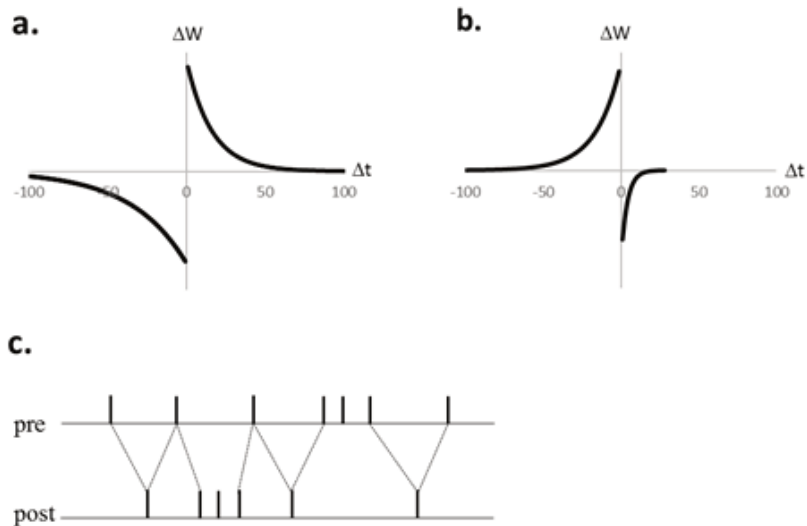
STDP mokymas gali būti pritaikytas laikinoms-erdvinėms impulsų struktūroms didelio foninio triukšmo sąlygomis aptikti. Tačiau neurono parametrai gali būti optimalūs tik tam tikrame triukšmo lygio režyje. Tai tampa akivaizdu iš ankstesnio skyriaus „Neuronų tinklas, skirtas ilgai trunkančioms erdvinėms impulsų struktūrų sekoms atpažinti“ rezultatų: teko nustatyti skirtingus abiejų WTA sluoksnių STDP parametrus, kitu atveju mokymas nepavykdavo. Tai reiškia, jog triukšmo lygis turi būti žinomas prieš pasirenkant dirbtinio neuronų tinklo parametrus. Tai gali būti rimta problema, jei triukšmo lygis yra kintantis. Tyrimo metu pavyko aptikti, jog invertuota STDP taisyklė su „artimiausio kaimyno“ tipo sąveika sugeba prisitaikyti prie foninio triukšmo lygio ir koreguoti atsako dažnį pagal triukšmo lygį su tam tikra netiesine priklausomybe. Šiame skyriuje yra siūlomas metodas, leidžiantis išnaudoti šią invertuotos STDP taisyklės ypatybę apmokomo neurono dirginimo moduliacijai. Šis metodas leidžia adaptuotis prie foninio triukšmo lygio, dėl ko neuronas gali aptikti tą pačią impulsų struktūrą esant plačiam foninio triukšmo lygio režiu.

Šis darbas buvo pristatytas tarptautinėje konferencijoje NCTA 2014 ir buvo publikuotas konferencijos medžiagoje bei SCITEPRESS skaitmeninėje bibliotekoje (Krunglevicius 2014).

1.2.1. Invertuotos STDP taisyklės ypatybės reaguojant į Puasono triukšmą


Buvo tiriama, kaip neuronas reaguoja į Puasono triukšmą. Įėjimo sluoksnyje buvo 4 096 neuronai, kurie generavo impulsus su tikimybe 0,02 kiekviename diskrečiosios simuliacijos žingsnyje, taip impulsai buvo paskirstyti pagal Puasono skirstinį. Buvo lyginamos taisyklės A ir B (Pav. 1.7). Palyginimo rezultatai atvaizduoti Pav. 1.8.

Kuomet neurono įėjimai skleidžia vien tik Puasono triukšmą, STDP taisyklė A, kaip ir tikėtasi, nulemia vieną iš dviejų galimų rezultatų: arba sinapsės nusilpsta tiek, kad neuronas nebegali būti sužadinas, arba visų sinapsių svoriai išauga tiek, kad neuronas yra sužadinas dėl bet kurio įėjimo impulso.



Pav. 1.7. STDP mokymo taisyklės, tirtos šiame skyriuje. Δw yra sinapsės svorio pokytis; Δt yra laiko skirtumas tarp postsinapsinio ir presinapsinio impulsų. **a)** Taisyklė A: STDP taisyklė, vėliau panaudota žadinamasis-į-žadinamąjį tipo sinapsėms. **b)** Taisyklė B: STDP taisyklė, vėliau panaudota žadinamasis-į-slopinamąjį tipo sinapsėms. **c)** Sinapsės svorio pokytis buvo apribotas „artimiausio kaimyno“ su tiesioginėmis poromis sąveika (Burkitt et al. 2004: Modelis IV).

Taisyklės B atveju, neurono elgsena yra kur kas įdomesnė: neuronas linksta link tam tikro stabilaus atsako impulsų dažnumo. Stabilus dažnumas priklauso ne tik nuo neurono slenksčio vertės ir triukšmo lygio, tačiau ir nuo mokymo žingsnio bei pradinių svorių.



Pav. 1.8: STDP taisyklę A ir B palyginimas, esant skirtingoms neurono slenksčio vertėms. Čia Puasono triukšmo lygis buvo pastovus. Vertikalioje ašyje pavaizduotas neurono atsako impulsų dažnumas; horizontalioje ašyje pavaizduotas simuliacijos laikas. **a)** STDP taisyklė A: brūkšniuota linija žymi slenksčio vertę $\vartheta = 100$, taškuota linija – $\vartheta = 340$, ištisinė linija – $\vartheta = 900$. **b)** STDP taisyklė B: brūkšniuota linija žymi slenksčio vertę $\vartheta = 100$, taškuota linija – $\vartheta = 160$, ištisinė linija – $\vartheta = 170$.

Rezultatai, pavaizduoti Pav. 1.8, su tam tikromis išlygomis atitinka prognozes, gaunamas pagal Izhikevichiaus lygtį (Izhikevich & Desai, 2003). Izhikevichiaus lygtis numato, jog

taisyklė A pasižymi nestabilia pusiausvyra, o taisyklė B stabilia. Tačiau Izhikevichiaus lygtis yra patikima tik tuo atveju, jei postsinapsinis neuronas generuoja impulsus pagal Puasono skirstinį, o ši sąlyga SRM neurono modelyje neišpildoma (SRM atveju, Izhikevichiaus lygties prognozė tampa labai apytikslė), todėl buvo atlikti eksperimentiniai matavimai.

1.2.2. Metodai

Šiame skyriuje buvo naudojamas SRM neurono modelis, kurio versija šiek tiek skyrėsi nuo neurono modelio, naudoto ankstesniame skyriuje „Neuronų tinklas, skirtas ilgai trunkančioms erdvinėms impulsų struktūrų sekoms atpažinti“. Galima pastebėti, jog ankstesniajame skyriuje naudotos η -branduolio funkcijos įtaką yra sudėtinga analizuoti, todėl η -branduolys buvo supaprastintas:

$$\eta(t) = -W_r e^{\frac{-\Delta t_h}{T_r}} \quad (1.9),$$

kur $\Delta t_h = t - t_{spike}$, o W_r bei T_r yra parametrai, nustatantys reliatyvios refrakterijos (nedirglumo) amplitudę bei nuolydį.

Neurono membranos potencialas bet kuriuo metu:

$$u(t) = \begin{cases} 5\vartheta & \text{if } t = t_{spike} \\ \eta(t) + \sum \epsilon(t) & \text{otherwise} \end{cases} \quad (1.10),$$

kur ϵ -branduolio funkcija yra tokia pati, kaip ir ankstesniame skyriuje, žr. lygtį (1.2), o ϑ yra slenksčio vertė. Atkreiptinas dėmesys, jog impulso metu membranos potencialas yra prilyginamas konstantai. Kadangi impulso metu neuronas yra absoliučiai nedirglus, membranos potencialo vertė nebeturi jokios įtakos neurono mokymui, čia atvaizduojant membranos potencialo procesą vien dėl patogumo potencialui priskiriama konstanta.

Simuliacijos metu konstantos buvo nustatytos taip: $T_m = 10$; $T_r = 10$; $T_s = 0,5$ ir $W_r = 2\vartheta$. Slopinamųjų neuronų slenksčio vertė visada buvo pastovi: $\vartheta_{inh} = 1,835$.

Sinapsių plastikos modelis buvo identiškas panaudotam ankstesniajame skyriuje ir yra išreikštas lygtimi (1.8). Konstantos, panaudotos STDP taisyklei A pritaikyti, buvo:

$A_{LTP} = 0,75$; $A_{LTD} = 0,63$; $T_{LTP} = 16$; $T_{LTD} = 35$; $w_{min} = 0,5$ ir $w_{max} = 30$. Pradiniai svoriai buvo paimti iš tolygiojo skirstinio, paskirstyti tarp 4,5 ir 5,5.


Konstantos, naudotos taisyklei B pritaikyti (atkreiptinas dėmesys, jog LTD ir LTP yra sukeistos vietomis):

$A_{LTD} = 6,048$; $A_{LTP} = 7,2$; $T_{LTD} = 4$; $T_{LTP} = 16$; $w_{min} = 10^{-6}$ ir $w_{max} = 1$. Pradiniai svoriai buvo iš tolygiojo skirstinio, paskirstyti tarp 0,9 ir 1.

Statiškų slopinamųjų sinapsių svoriai buvo $w = 7,3$ STDP taisyklės B atveju ir $w = 2,0$ – kitais atvejais.

1.2.3. Rezultatai

Buvo pamatuotas mokymo našumas, kuomet mokymo pavyzdys buvo erdvinė impulsų struktūra, kurią generavo 122 pažymėti įėjimo neuronai, šaunantys vienu metu. Įėjimo sluoksnyje buvo naudojami 4 096 neuronai. Erdvinė impulsų struktūra buvo generuojama 40 ms intervalais. Taip pat visi įėjimo sluoksniu neuronai generavo Puasono triukšmą, išskyrus 122 pažymėtus neuronus struktūros generavimo momentais (Pav. 1.11a). Eksperimentai buvo vykdomi diskrečiojoje simuliacijoje, 1 ms tikslumu.



Pav. 1.9. Tyrime lyginti neuronų tinklų modeliai. **a)** Paprastas tinklas buvo sudarytas iš vienintelio besimokančio neuroono ir įėjimo sluoksniu. Šiame tinkle buvo taikoma tikta STDP taisyklė A. **b)** Tinklas su vertikaliu slopinimu. Šis tinklas buvo praplėstas pridėdant papildomus slopinamuosius neuronus. Slopinamųjų sinapsių, pažymėtų punktyrinėmis linijomis, svoriai nekito. Sinapsės, jungiančios įėjimo sluoksniu su slopinamaisiais neuronais, kito pagal STDP taisyklė B, o sinapsės, jungiančios įėjimo sluoksniu su besimokančiu neuroonu, kito pagal STDP taisyklė A.

Mokymo sėkmė buvo vertinama matuojant skirtumą tarp vidutinių asocijuotų ir neasocijuotų su erdvinę struktūrą generuojančiais įėjimo sluoksniu neuronais sinapsių svorių: $\Delta\mu_w = \mu_{w_{in}} - \mu_{w_{out}}$. Vidutinės reikšmės buvo normalizuotos intervalu $[0, 1]$, įvertinant minimalų ir maksimalų galimus sinapsių svorius. Mokymo sėkmės kriterijus

buvo $\Delta\mu_w > 0,85$ simuliacijos pabaigoje. Neuronai, kurie mokymo pabaigoje buvo nedirglūs, buvo vertinami kaip nesėkmingi, nepaisant $\Delta\mu_w$ vertės. Mokymo našumas įvertintas matuojant $\Delta\mu_w$ kitimo greitį.

Šiame tyrime buvo palygintas paprastas neuronų tinklas su tinklu, kuriame buvo panaudotas vertikalus slopinimas (Pav. 1.9).

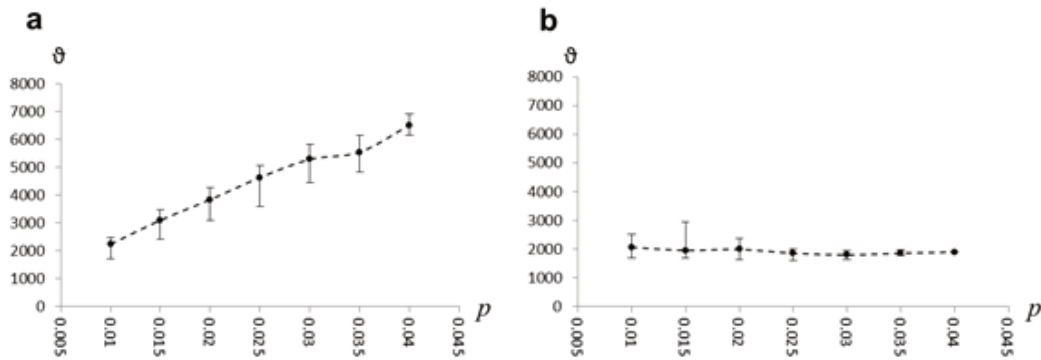
Dirbtinis neuronų tinklas su vertikaliu slopinimu buvo sudarytas iš įėjimo sluoksnio neuronų, penkiasdešimties slopinamųjų neuronų bei vienintelio besimokančio neuro. Besimokantysis neuronas buvo žadinamas iš visų įėjimo sluoksnio neuronų, o slopinamieji neuronai buvo sujungti tik su atsitiktine dalimi įėjimo sluoksnio neuronų (~10 proc.). Besimokančiojo neuro sinapsių svoriai buvo modifikuojami pagal STDP taisyklę A, o slopinamųjų neuronų įėjimo sinapsės keitė savo svorius pagal STDP taisyklę B. Besimokantysis neuronas buvo slopinamas slopinamųjų neuronų per sinapses su nekintančiais svoriais (Pav. 1.9b).

Slopinamųjų neuronų kiekis buvo didesnis nei vienas siekiant sumažinti slopinamųjų postsinapsinių potencialų (IPSP) dispersiją. Padidėjusi postsinapsinio potencialo dispersija sumažina koreliacijas tarp pavyzdžio struktūros presinapsinių impulsų bei besimokančiojo neuro postsinapsinių impulsų, taigi negatyviai veikia mokymo procesą. Slopinamieji neuronai buvo žadinami tik dalies įėjimo sluoksnio neuronų siekiant sumažinti sinchroninių impulsų tikimybę.

Mokymas esant skirtingiems pastovaus triukšmo lygiams

Buvo atlikta serija eksperimentų, esant skirtingiems Puasono triukšmo lygiams. Į triukšmą buvo įterpta erdvinė impulsų struktūra. Puasono triukšmas buvo generuojamas įėjimo sluoksnyje nustačius nekintamą impulso tikimybę kiekviename diskrečiosios simuliacijos žingsnyje. Mokymo sėkmė buvo matuojama esant skirtingoms neuro slenksčio θ vertėms.

Paprasto tinklo atveju (Pav. 1.10a), kaip ir tikėtasi, esant tam tikram triukšmo lygiui, sėkmingas mokymas įmanomas tik tam tikros vertės neuro slenksčių ruože.




Pav. 1.10. Neuronų mokymo sėkmės priklausomybė nuo slenkstinės vertės ir foninio triukšmo santykio. Vertikalioje ašyje yra pažymėta neuronų slenkstinė vertė ϑ , horizontalioje ašyje – triukšmo lygis. Juodi markeriai žymi taškus, kur mokymas buvo sparčiausias, paklaidų brūkšniai žymi slenkstinių verčių ribas, kur mokymas buvo sėkmingas. **a)** Paprastojo tinklo rezultatai. **b)** Tinklo su vertikaliu slopinimu ir pritaikyta STDP taisykle B rezultatai.

Kuomet neuronas mokėsi tinkle su vertikaliu slopinimu, optimali neuronų slenkščio vertė buvo kur kas mažiau priklausoma nuo triukšmo lygio ir išliko maždaug pastovi. Tas pats neuronas su nekintančia slenkstine verte galėjo mokytis plačiame triukšmo lygių ruože (šiam eksperimente, triukšmo lygis kito nuo 0,01 iki 0,04). Tačiau galimų slenkščių verčių rėžis, kylant triukšmo lygiui, mažėjo. Tai gali būti susiję su padidėjusia membranos potencialo dispersija, dėl ko galėjo sumažėti koreliacijos tarp presinapsinių ir postsinapsinių impulsų.

Mokymas kintančio triukšmo sąlygomis

Kitame eksperimente vietoje fiksuoto triukšmo lygio impulsų tikimybė įėjimo sluoksnyje buvo nustatyta pagal sinuso funkciją: $p = 0,01 + 0,015 * ((\sin(t/\lambda) + 1))$ (Pav. 1.11a). Mokymo sparta buvo įvertinta naudojant šias λ reikšmes: 50, 100 ir 150.

Buvo lyginama paprastojo tinklo (Pav. 1.9a) greitaveika su tinklo, kuriame buvo pritaikytas vertikalus slopinimas (Pav. 1.9b), greitaveika. Taip pat palygintas vertikalus slopinimas su pagal STDP taisyklę B kintančiomis sinapsėmis ir su statiškomis sinapsėmis, kuomet sinapsių svoriai iš įėjimo sluoksnio į slopinamuosius neuronus nekito. Palyginimo rezultatai yra pavaizduoti Pav. 1.11b.



Pav. 1.11. Mokymas kintančio triukšmo sąlygomis. **a)** Įėjimo sluoksniu generuojamų impulsų pavyzdys. Juodi taškai vaizduoja erdvinės impulsų struktūros dalį, pilki taškai vaizduoja triukšmą. **b)** $\Delta\mu_w$ reikšmės per pirmuosius 5 000 mokymo žingsnius. Pavaizduoti rezultatai yra parinkti iš eksperimento, kur $\lambda = 150$. Ištinė linija žymi reikšmes tinkle su pritaikyta STDP taisykle B, punktyrinė linija žymi tinklą su stochastinėmis slopinamųjų neuronų sinapsėmis; taškuota linija žymi paprastąjį tinklą.

Visais λ atvejais neuronų tinklo su pritaikyta STDP taisykle B mokymas vyko sparčiausiai. Tinklas su statinėmis slopinamųjų neuronų sinapsėmis mokėsi tik šiek tiek lėčiau, tai buvo netikėtas rezultatas. Paprastasis tinklas mokėsi lėčiausiai, kadangi mokomas neuronas gebėjo generuoti atsako impulsus tik esant triukšmo lygio ekstremumams.

1.2.4. Diskusija

Pasiūlytam metodui pritaikyti naudojama invertuota STDP taisyklė slopinimui, taip moduluojamas mokomo neuroso aktyvumas. Eksperimentiškai pademonstruota, jog toks metodas leidžia praplėsti priimtino triukšmo lygio rėžį, tačiau yra triukšmo lygio viršutinė riba, virš kurios mokymas nebebus sėkmingas. Reguluojant neuroso slenkstinę vertę, toks tinklas gali mokytis ir esant didesniam triukšmo lygiui, nei buvo pasirinkta tyrimo eksperimentų metu.

Šiuose eksperimentuose mokymo pavyzdžiu buvo pasirinkta paprasta, nekintanti erdvinė impulsų struktūra. Tai, žinoma, STDP mokymui nėra būtina sąlyga, mokymo pavyzdys gali būti ir erdvinė-laikinė struktūra arba paralelūs impulsų pliūptelėjimai (Masquelier et

al., 2008; Gilson et al., 2011), taip pat struktūros dydis gali būti kintamas. Šie faktoriai, žinoma, turi įtakos mokomo neurono stimuliacijos lygiui, taigi vertikalaus slopinimo metodo įtaka, naudojant kitokio pavidalo mokymo pavyzdžius, gali būti labai skirtinga.

1.3. Konkurencinis STDP mokymas, kuomet erdvinės impulsų struktūros persidengia

Šis darbas buvo publikuotas žurnale „Neural Computation“, MIT Press (Krunglevicius, 2015).

Šiame tyrime buvo siekiama patobulinti WTA grandis, aprašytas skyriuje „Neuronų tinklas, skirtas ilgai trunkančioms erdvinėms impulsų struktūrų sekoms atpažinti“.

Buvo parodyta, jog STDP mokymas yra tinkamas erdvinėms ir erdvinėms-laikinėms struktūroms atpažinti. Kuomet daugelis neuronų konkuruoja viename tinkle, toks dirbtinis neuronų tinklas geba išmokti daugelį skirtingų struktūrų. Tačiau, jei šios struktūros žymiai persidengia erdvėje, tai yra, struktūros yra vieną kitą apimančios, konkurencija nekliudo jau vieną struktūrą išmokusiam neuronui reaguoti į naują struktūrą, dėl to STDP mokymo sinapsių svoriai pakinta, o atmintis apie pirminę struktūrą prarandama.

Šiame skyriuje yra pristatomas nesudėtingas neuronų tinklas, kuriame ši problema daugeliu atvejų išsprendžiama. Šis neuronų tinklas išnaudoja vertikalų slopinimą bei nuo Euklido atstumo priklausančius sinapsių svorių koeficientus. Taip pat šis tinklas sėkmingai geba mokytis skirtingo dydžio struktūras. Demonstracijos tikslais šis tinklas buvo apmokytas atpažinti dešimtį pirmųjų Brailio abėcėlės simbolių.

Pasiūlytas tinklas sprendžia dvi problemas. Pirmoji iš jų yra struktūrų persidengimas. Tarkim, neuronas išmoksta atpažinti dvimatę F raidės pavidalo struktūrą. Vėliau neuronui pateikiama raidės E pavidalo struktūra, apimanti raidę F. Paprastame konkurenciniame tinkle nėra jokie mechanizmo, draudžiančio neuronui reaguoti į raidę E.

Antroji problema yra glaudžiai susijusi su pirmąja. Tam, kad mokymas būtų sėkmingas, neurono slenkstinė vertė bei pradiniai svoriai turi būti sureguliuoti pagal tikėtiną stimuliacijos dydį. Įsivaizduokite dvi nepersidengiančias dvimates struktūras: viena užima 2 proc. viso recepcinio lauko, o kita – 50 proc.. Jei yra du neuronai, išmokę atpažinti kiekvieną iš šių struktūrų, tuomet neurono, kuris reaguotų į 2 proc. dydžio struktūrą, sinapsių svoriai turėtų būti 25 kartus didesni nei neurono, kuris reaguotų į 50 proc. dydžio struktūrą. Arba, atitinkamai, antrojo neurono slenkstis turi būti 25 kartus mažesnis. Kitu atveju, antrasis neuronas reaguotų į atsitiktinį triukšmą, neurono atsako dažnumas būtų

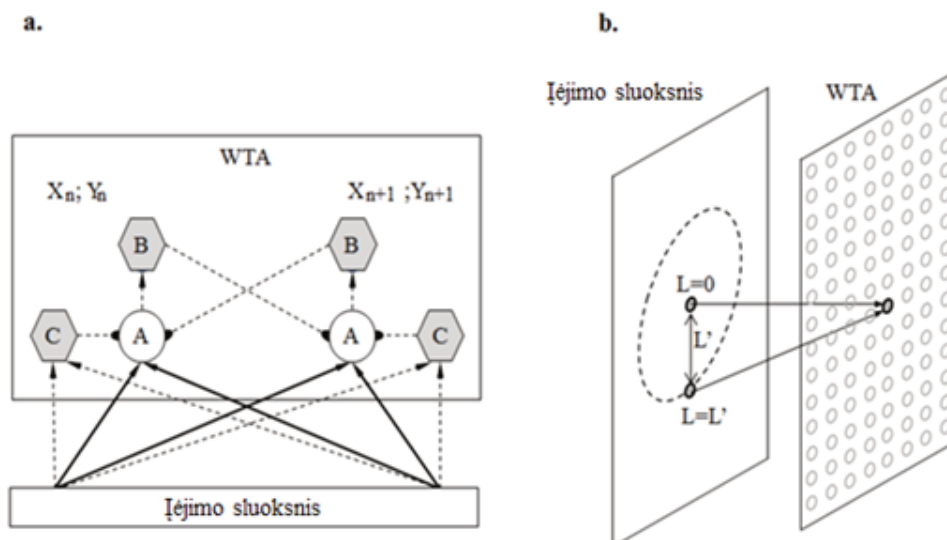
labai aukštas, kas galėtų nulemti nestabilų mokymo procesą, ypač „artimiausio kaimyno“ sąveikos modelyje (Izhikevich & Desai, 2003). Net jei daroma prielaida, jog mokymas didelės struktūros atveju nutraukiamas anksti, kol sinapsių svoriai nespėja išaugti, nėra būdo abiem neuronams tinkamiems pradiniais svoriams nustatyti.

Siekiant išspręsti šias problemas, tikriausiai įmanoma sukurti labai heterogenišką neuronų tinklą, tačiau toks tinklas būtų labai sudėtingas ir vargu, ar vertingas naudoti praktiškai. Taip pat galima svarstyti papildomus mechanizmus, tokius, kaip išorinė moduliacija arba homeostatinė sinapsių plastika, siekiant palaikyti besimokančio neurono atsako dažnumą pageidautinose ribose.

Tyrimo metu buvo pasirinktas paprastesnis būdas – sukurtas dvisluoksnis neuronų tinklas, kur kiekvienas besimokantis neuronas gali būti aktyvus tik esant jam tinkamam stimuliacijos lygiui. Esminis tikslas buvo suteikti individualiems neuronams tokias sąlygas, kuriomis neuronas, kuriam „patogu“ išmokti F raidės pavidalo struktūrą, būtų mažiau aktyvus, jei jam yra demonstruojama E raidės pavidalo struktūra. Kitaip tariant, neuronas, selektyvus F pavidalo struktūrai, nereaguotų į E dėl vertikalaus slopinimo, o neuronas, selektyvus E pavidalo struktūrai, nereaguotų į F dėl nepakankamai stiprių sinapsių. Tai buvo pasiekta priskyrus kiekvienam neuronui erdvinės koordinatės, įtraukus slopinamuosius antagonistinius neuronus ir suteikus sinapsėms svorių koeficientus, proporcingus Euklido atstumui iki individualaus įėjimo sluoksnio neurono.

1.3.1. Neuronų tinklo modelis

Pasiūlytas dirbtinio neuronų tinklo modelis pavaizduotas Pav. 1.12a. Neuronų tinklas yra sudarytas iš dviejų sluoksnių: išėjimo sluoksnio ir WTA sluoksnio. Abiejų sluoksnių neuronai yra išdėstyti stačiakampėje koordinačių sistemoje. Įėjimo sluoksnio neuronai neturi tarpusavio ryšių. WTA sluoksnyje kiekviename koordinačių taške yra trys neuronai: neuronas A, kuris turi plastiškas sinapses, jungiančias su įėjimo sluoksniu, neuronas B, kuris yra slopinamasis interneuronas, ir slopinamasis neuronas C, kuris yra neurono A antagonistas. Kiekvienas neuronas B yra žadinamas vienintelio A neurono ir slopina kitus, kaimyninius A neuronus. C neuronai yra žadinami impulsų iš įėjimo sluoksnio, kiekvienas C neuronas slopina savo porininką – neuroną A.



Pav. 1.12. Neuronų tinklo modelis. **a:** Konkurencinio tinklo neuronų grandis. Ištinės linijos žymi sinapsės su STDP mokymu, punktyrinės linijos žymi sinapsės su nekintamais svoriais, rodyklės žymi žadinamąsias sinapsės, o pusapvalės jungtys žymi slopinamąsias sinapsės. **b:** Sinapsinių svorių koeficientų priskyrimo schema.

Sinapsės, siunčiančios impulsus iš įėjimo sluoksnio į neuronus A ir B, turi priskirtą nuo atstumo priklausantį svorio koeficientą. Čia atstumas yra Euklido atstumas tarp individualaus neurono WTA sluoksnyje ir individualaus neurono įėjimo sluoksnyje, tariant, jog atstumas tarp abiejų sluoksnių yra lygus nuliui (Pav. 1.12b). Vienas neuronas užima vieną erdvės vienetą. Svorių koeficientai priskiriami pagal Gauso funkciją $\phi_j = \exp(-L^2/2\sigma^2)$. A ir C neuronų σ^2 reikšmės yra skirtingos; tinklas sureguliuotas taip, jog neuronas C yra šiek tiek mažiau jautrus, nei neuronas A. Slopinamosios sinapsės iš C į A turi stiprius, nekintančius svorius, todėl net menkas neurono C aktyvumas neleidžia neuronui A sugeneruoti atsako impulso. Taip neuronas C veikia kaip aktyvumo sklendė – „viskas arba nieko“, pridėtinė normalizacija šiame modelyje nebuvo naudojama. Tinklas eliminuoja potencialiai pernelyg aktyvius A neuronus nuo tolimesnės konkurencijos.

Sinapsės, siunčiančios impulsus iš neuronų B į A, taip pat turi nuo atstumo priklausančius svorių koeficientus, todėl WTA grandyje iš tiesų konkuruoja tik artimi kaimynai.

Šis tinklas kiekvienam A ir C neuronui priskiria individualų receptinį lauką. Paprasto WTA tinklo atveju neuronai laimi konkurenciją dėl atsitiktinio pranašumo, priklausančio nuo pradinių sinapsių svorių. Šio tinklo atveju pranašumas įgyjamas dėl pavyzdžio struktūros pavidalo ir neurono geometrinės pozicijos. Jei pavyzdžio struktūra yra santykinai didelė, laimintys neuronai išsidėsto struktūros pakraščiuose, jei struktūra yra

santykinai maža, laimintys neuronai išsidėsto apytiksliai struktūros geometriniam centre. Taip pat šis tinklas atrenka tokius laiminčius neuronus, kurių atsako dažnumas yra pageidautinose ribose.

Šiame tyrime panaudoti neurono ir sinapsių plastikos modeliai yra identiški aprašytiems ankstiniame skyriuje „STDP mokymas kintančio triukšmo sąlygomis“. Simuliacijos metu konstantos buvo pasirinktos laisvai: neurono slenksčio vertė $\vartheta = 100$, $T_m = 10$ ms; $T_r = 10$ ms; $T_s = 0,5$ ms; $W_r = 200$; $A_{LTP} = 0,3$; $A_{LTD} = 0,252$; $T_{LTP} = 12$ ms ir $T_{LTD} = 48$ ms. Vienintelis skirtumas yra tas, jog sinapsių svorių koeficientas ϕ , naudojamas ϵ -branduolio funkcijoje (1.2), nebuvo apribotas kaip +1 arba -1, tačiau priklausė nuo Euklido atstumo tarp presinapsinio ir postsinapsinio neuronų.

1.3.2. Rezultatai

Tinklo mokymas naudojant stochastinę pavyzdžio struktūrą

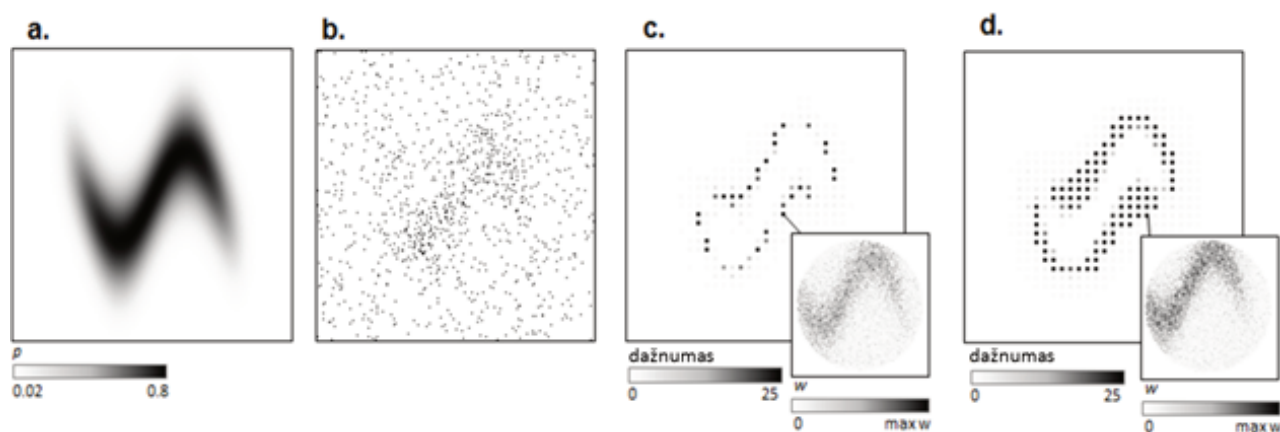
Siekiant pademonstruoti kai kurias pasiūlyto dirbtinio neuronų tinklo ypatybes, tinklas buvo apmokytas pateikiant vienintelę stochastinę pavyzdžio struktūrą, kur įėjimo sluoksnio generuojamų impulsų dažnumai buvo nustatyti pagal tikimybių lentelę (Pav. 1.13).

Simuliacija buvo atlikta 1 ms tikslumu. Struktūra buvo tinklui demonstruojama periodiškai, 10 ms ir 30 ms intervalais. Įėjimo neuronai generavo impulsus nepriklausomai, pagal priskirtą impulso tikimybę. Struktūros rodymo metu įėjimo neuronui buvo priskirta impulso tikimybė iš tikimybių lentelės (Pav. 1.13a), kur galimos reikšmės buvo nuo 0,02 iki 0,08. Periodais tarp pavyzdžio demonstravimų visi įėjimo neuronai generavo impulsus su tikimybe 0,02. Įėjimo sluoksnio dydis buvo 196 x 196, o WTA sluoksnio dydis buvo 29 x 29. Mokymas vyko 5 000 iteracijų.

Šio eksperimento metu pasirinkti parametrai: $\sigma_A^2 = 256$; $\sigma_C^2 = 25$; $\sigma_{BA}^2 = 25$; $w_{BA} = 400$; $w_{AB} = 200$; $w_{CA} = 10\,000$; $w_{IC} = 0,15$; pradinis sinapsės svoris $w_{ini} = 0,26$, maksimalus – $w_{max} = 1,28$.

Laimintys neuronai apsupo struktūrą (Pav. 1.13c ir Pav. 1.13d.). Neuronai, kurie buvo arti labiausiai stimuliuojamos zonos, buvo nuslopinti dėl neuronų C aktyvumo, o pernelyg nutolę neuronai buvo neaktyvūs dėl nepakankamo stimuliavimo. Dėl to, aktyvūs neuronai

išsidėstė aplink struktūros pakraščius. Kuomet horizontalus slopinimas per neuronus B buvo įjungtas (Pav. 1.13c), tik labiausiai sužadinti neuronai išliko konkurencingi, tai yra neuronai, artimiausi struktūros pakraščiu. Pav. 1.13d pavaizduotas neuronų aktyvumas, kuomet horizontalus slopinimas buvo išjungtas, tai yra, A neuronai nekonkuravo tarpusavyje. Lyginant abu atvejus, matosi, jog horizontalus slopinimas sumažina aktyvių neuronų kiekį, tačiau ir sulėtina mokymo spartą: Pav. 1.13d pavaizduoti sinapsių, susijusių su struktūra, svoriai sugebėjo užaugti didesni nei Pav. 1.13c, nors abiem atvejais mokymas vyko tiek pat laiko.




Pav. 1.13. Tinklo mokymas naudojant stochastinę pavyzdžio struktūrą. **a:** Tikimybių lentelė, pagal kurią buvo generuojama pavyzdžio struktūra. **b:** Pavyzdžio struktūra, sugeneruota viename simuliacijos žingsnyje. **c** ir **d:** A neuronų aktyvumas ir laisvai pasirinkto neurono sinapsių svoriai mokymo pabaigoje (išnašoje). **c:** horizontalus slopinimas per neuronus B įjungtas. **d:** horizontalus slopinimas išjungtas.

Tinklo mokymas naudojant Brailio rašto simbolius

Dirbtinis neuronų tinklas (Pav. 1.12) mokėsi dešimties pirmųjų Brailio rašto simbolių: a, b, c, d, e, f, g, h, i ir j. Kiekvienas Brailio taškas buvo atvaizduotas kaip grupė, sudaryta iš 61 kaimyninės sinapsės, Brailio simbolis buvo demonstruojamas recepciniame lauke, sudarytame iš 64 x 64 jėjimo neuronų. Kiekvienas iš visų keturių galimų Brailio taškų visada buvo toje pačioje pozicijoje. WTA sluoksnis buvo sudarytas iš 15 x 15 celių. Atstumas tarp neuronų WTA sluoksnyje buvo 3 erdvės vienetai, o jėjimo sluoksnyje atstumas tarp neuronų buvo vienas erdvės vienetas.

Brailio simbolis buvo demonstruojamas tinklui 30 ms intervalais. Simuliacija buvo vykdoma 1 ms tikslumu. Simbolio demonstracijos metu jėjimo neuronai, kurie buvo priskirti Brailio simboliui, generavo 10 ms trukmės impulsų papliūpas vėlinant po 1 ms


tarp atskirų impulsų papliūpoje. Kiti neuronai ir visi neuronai intervaluose tarp simbolių rodymo laikų generavo Puasono triukšmą, nustatyta impulso tikimybė buvo 0,02. Tas pats simbolis būdavo demonstruojamas 1 000 iteracijų, tuomet atsitiktine tvarka pakeičiamas vienu iš kitų 9 galimų simbolių. Kiekvienas simbolis buvo naudojamas tik vieną kartą per vieną mokymo epochą, visas tinklo mokymas užtruko 60 epochų, taigi, 600 000 mokymo iteracijų.



Pav. 1.14. Tinklo mokymas naudojant Brailio rašto simbolius. **a:** Stulpeliai vaizduoja A tipo neuronų aktyvumą demonstruojant kiekvieną atskirą Brailio simbolį. Simboliai pavaizduoti kiekvieno stulpelio viršuje. Kiekviena eilutė stulpelyje vaizduoja neurono aktyvumą per visas 60 mokymo epochų. Mokymo metu Brailio simboliai buvo keičiami atsitiktine tvarka, tačiau šioje diagramoje pateikti filtruoti rezultatai kiekvieno simbolio demonstracijos atveju atskirai. **b:** A tipo neuronų, selektyvių individualiam Brailio simboliui, pasiskirstymas WTA sluoksnyje. Taškelių tamsumas yra proporcingas sinapsių svoriams (juoda – maksimalus, balta – minimalus). Punktyriniai apskritimai žymi Brailio taškų pozicijas.

Simuliacijos parametrai buvo nustatyti tokie: $\sigma_A^2 = 256$; $\sigma_C^2 = 400$; $\sigma_{BA}^2 = 4\,096$; $w_{BA} = 140$; $w_{AB} = 200$; $\omega_{CA} = 1\,000$; $w_{IC} = 0,12$; pradinis sinapsės svoris $w_{ini} = 0,234$, maksimalus – $w_{max} = 0,594$. Atkreiptinas dėmesys, jog σ_{BA}^2 buvo parinktas didelis skaičius, siekiant įjungti sąveikos „visi su visais“ horizontalų slopinimą. Tai buvo atlikta siekiant sumažinti aktyvių neuronų kiekį. Taip pat σ_C^2 vertė buvo žymiai didesnė nei ankstesniame eksperimente. Ankstesniame eksperimente σ_C^2 buvo sureguliuotas taip, kad aktyvuotų neuronus, esančius arti struktūros pakraščio, šiuo atveju σ_C^2 buvo sureguliuotas taip, jog vieno Brailio taško atveju aktyvus neuronas būtų arti struktūros centro, o keturių taškų atveju aktyvūs neuronai išsidėstytų WTA sluoksniu pakraščiuose.

Pav. 1.14a yra pavaizduotas A tipo neuronų aktyvumas, atvaizduoti tik 42 patys aktyviausi neuronai. Likusių neuronų aktyvumas buvo nežymus, vidutiniškai mažiau nei 0,25 impulso per vieno simbolio demonstraciją. Kiekvienas stulpelis atitinka atskirą Brailio simbolį ir neuronų aktyvumą per 60 mokymo epochų.



Pav. 1.15. Vieno neurono sinapsių svoriai, padauginti iš nuo atstumo priklausančio koeficiento mokymo pabaigoje. Šis neuronas buvo iš dalies selektyvus keturių taškų ir trijų taškų simboliams. Koeficientas žymiai sumažino vieno iš taškų įtaką.

Iš mokymo rezultatų matyti, jog daugelis A tipo neuronų buvo selektyvūs vieninteliame simboliui. Keletas neuronų buvo selektyvūs daugiau nei vienam simboliui, dažniausiai tai buvo trijų ir keturių taškų simboliai. Neuronai, selektyvūs tam pačiam simboliui, aktyviai konkuravo tarpusavyje, tokiu atveju mokymo sparta mažėjo. Tai ypač akivaizdu dviejų taškų ‚i‘ simbolio atveju (Pav. 1.14a, priešpaskutinis stulpelis).

Palyginimui, paprastas WTA tinklas, kuriame nebuvo B ir C tipo neuronų, nesugebėjo atskirti šių dešimties Brailio simbolių. Dažniausiai vienas ar keli neuronai dominavo WTA grandyje, šie neuronai buvo selektyvūs visiems simboliams, turintiems daugiau nei vieną Brailio tašką.

1.3.3. Diskusija

Pasiūlytas dirbtinis neuronų tinklas sėkmingai išmoko dešimt pirmųjų Brailio rašto simbolių. Nors kai kurie neuronai buvo selektyvūs daugiau nei vienam simboliui, toks simbolis vis vien galėjo būti vienareikšmiškai identifikuotas remiantis aktyvių neuronų kombinacijomis. Bandymai išmokyti paprastą WTA tinklą atpažinti tuos pačius Brailio simbolius buvo nesėkmingi, toks tinklas nesugebėjo atskirti daugelio simbolių. Rezultatai

parodo, jog šis tinklo modelis yra efektyvesnis, kuomet mokymo tikslas yra atpažinti erdvėje koncentruotas impulsų struktūras.

Viena silpniausių pasiūlyto tinklo dalių yra horizontalus slopinimas B tipo neuronais. Toks slopinimas neigiamai veikia mokymo spartą, ypač jo pradžioje. Taip pat toks horizontalaus slopinimo būdas nėra pakankamai patikimas siekiant nuslopinti kaimyninius neuronus, kadangi slopinimas per interneuroną B pasižymi vėlinimu, kuris 1 ms tikslumo simuliacijos atveju buvo mažiausiai 2 ms. Siekiant išspręsti šią problemą, galima būtų mažinti diskrečiosios simuliacijos žingsnį arba sukurti išorinės moduliacijos grandį.

1.4. Modifikuota STDP tripleto sąveikos taisyklė žymiai padidina mokymo stabilumą, kuomet neuronas mokosi atpažinti erdvines impulsų struktūras

Šis darbas buvo publikuotas žurnale „Advances in Artificial Neural Systems“ (Krunglevicius, 2016).


Šio tyrimo tikslas buvo eksperimentiškai parinkti tinkamiausią fenomenologinį STDP modelį, kuomet jo pritaikymas būtų dirbtiniai neuronų tinkluose, aprašyti disertacijos skyriuose „Neuronų tinklas, skirtas ilgai trunkančioms erdvinėms impulsų struktūrų sekoms atpažinti“, „STDP mokymas kintančio triukšmo sąlygomis“ ir „Konkurencinis STDP mokymas, kuomet erdvinės impulsų struktūros persidengia“.

Be STDP įvairovės, žinomos iš biologinių tyrimų, dar yra ir nemenkas kiekis skirtingų fenomenologinių STDP modelių. Šiame skyriuje yra lyginami trys skirtingi STDP neuronų impulsų sąveikos modeliai, kuomet mokymo užduotis yra erdvinė impulsų struktūra, periodiškai įterpta į Puasono triukšmą. Palyginimui buvo pasirinktos „visų su visais“, „artimiausio kaimyno“, bei „artimiausio kaimyno“ tripleto (trijų impulsų) sąveikos. Neuronų ir STDP mokymo parametrai buvo optimizuojami naudojant genetinį algoritmą. Užduoties sudėtingumas buvo palaipsniui didinamas (mažinamas impulsų struktūros dydis), optimizacija buvo atliekama kiekviename žingsnyje. Parametrams buvo leista evoliucionuoti laisvai, nesilaikant biologinio realizmo. Daugeliu atvejų tripleto sąveika veikė žymiai geriau nei kiti du lyginami sąveikų tipai. Tripleto atveju, genetinis algoritmas pakeitė trečiojo impulso koeficiento ženklą. „Visų su visais“ sąveikos rezultatai buvo vidutiniai, o „artimiausio kaimyno“ sąveikos – prasčiausi.

1.4.1. Metodai

Neuronai mokėsi atpažinti skirtingų dydžių erdvines impulsų struktūras. Neuronų ir STDP mokymo taisyklių parametrai buvo optimizuojami kiekvieno skirtingo dydžio struktūros atveju. Simuliacijos buvo vykdomos diskrečiajame laike, naudojant 1 ms tikslumo žingsnį. Erdvinė struktūra buvo sukuriama, kuomet grupė pasirinktų įėjimo sluoksnio neuronų sugeneruodavo impulsus vienu metu, kas 40 ms (žr. **Pav. 1.16**). Taip pat visi neuronai spontaniškai generavo atsitiktinius impulsus kiekviename simuliacijos žingsnyje, atsitiktinio impulso tikimybė buvo fiksuota, taip neuronai generavo Puasono triukšmą.

Struktūros įterpimo momentais visi kiti neuronai, nepriskirti struktūrai, impulsų negeneravo. Buvo palyginti trys skirtingi STDP impulsų sąveikų tipai: „visi su visais“, „artimiausio kaimyno“ su tiesioginėmis poromis (Burkitt et al., 2004) bei „artimiausio kaimyno“ su tripletu sąveika (Pfister & Gerstner, 2006).



Pav. 1.16. Erdvinės impulsų struktūros pavyzdys. Pilka spalva Puasono triukšmą, įterptą struktūrą žymi juodi impulsai. Struktūros įterpimo metu įėjimo sluoksnio neuronai, kurie nebuvo priskirti struktūrai, impulsų negeneravo.

Šis eksperimentas buvo panašus į atliktą Masqueliero (Masquelier et al., 2008). Esminis skirtumas, jog šiuo atveju panaudota erdvinė, o ne erdvinė-laikinė struktūra, taip pat struktūra buvo įterpiama periodiškai, o Masqueliero eksperimente – ne.

Mokymo našumas buvo matuojamas trijose skirtingose Puasono triukšmo konfigūracijose. Pirmame eksperimente visų įėjimo neuronų tikimybė sugeneruoti atsitiktinį impulsą buvo $p = 0,04$. Šioje konfigūracijoje neuronų, kurie dalyvavo įterpiant struktūrą, impulsų dažnumas buvo didesnis nei tų, kurie nedalyvavo, atitinkamai 64 Hz ir 39 Hz. Vėliau eksperimentas buvo pakartotas, kuomet visų neuronų impulsų dažnumas buvo 64 Hz, tai yra įėjimo neuronų, nedalyvaujančių įterpiant struktūrą, tikimybė sugeneruoti atsitiktinį impulsą buvo padidinta iki $p = 0,065641026$. Taip pat buvo atlikti riboti 39 Hz / 39 Hz ir 25 Hz / 39 Hz konfigūracijų, kur atsitiktinio impulso tikimybė įėjimo neuronuose, kurie dalyvavo struktūroje, buvo sumažinta atitinkamai iki $p = 0,014358974$ ir 0, eksperimentai.

Euristinis optimizavimas

Pagrindinis tyrimo tikslas buvo eksperimentiškai nustatyti mažiausią įmanomą erdvinės struktūros dydį, tinkamą STDP mokymui. Kadangi pridėtinė STDP taisyklė linkusi nustatyti sinapsių svorius pagal bimodalinį skirstinį, buvo siekta maksimizuoti skirtumą tarp susijusių ir nesusijusių su struktūra sinapsių svorių. Be to, neuronas turėtų būti

aktyvus mokymo pabaigoje, idealiu atveju, selektyvus pavyzdžio struktūrai. Čia vietoje neurono atsako po struktūros laiko vėlinimo minimizavimo, paprastumo vardan, padaryta prielaida, jog neurono atsako dažnumas turi būti apytiksliai lygus įterpiamos impulsų struktūros dažniui. Todėl į tikslo funkciją buvo įterptas Gauso komponentas:

$$f = \begin{cases} \sum_t e^{-(\lambda-\xi)^2/\delta} \Delta\mu_w & \text{if } \Delta\mu_w > 0 \\ \sum_t \Delta\mu_w & \text{if } \Delta\mu_w \leq 0, \end{cases} \quad (1.11),$$

kur $\Delta\mu_w$ yra nustatytas skirtumas tarp sinapsių, susijusių su struktūra, svorių vidurkio ir kitų sinapsių svorių vidurkio; λ yra stebėtas mokomo neurono atsako dažnumas (kartai per sekundę); $\xi = 25$ yra dažnumo tikslas ir $\delta = 20$ nustato nuokrypos nuo dažnumo tikslo toleranciją. Mokymo pradžioje buvo nustatyti vienodi visų sinapsių svoriai, lygūs ω_0 , taigi mokymo pradžioje $\Delta\mu_w$ buvo lygus nuliui. Tikslo funkcijos vertė buvo visų stebėjimų kiekvieną simuliacijos iteraciją suma, taip maksimizuojant tikslo funkciją, kartu buvo didinamas neurono mokymo greitis.

Siekiant maksimizuoti tikslo funkciją (1.11), 7 dimensijų erdvėje buvo vykdoma „artimiausio kaimyno“ ir „visų su visais“ ir 11 dimensijų erdvėje – tripleto sąveikos euristinė paieška. Buvo optimizuojami šie parametrai: ϑ , w_0 , w_{min} , α , A_{pre} , T_{pre} , ir T_{post} . Tripleto sąveikos atveju, buvo optimizuojami dar keturi papildomi parametrai: A_{pre3} , A_{post3} , T_{pre3} ir T_{post3} (žr. lygtis toliau). Euristinei paieškai buvo naudojamas labai paprastas genetinis algoritmas, kuriame buvo panaudota 100 agentų, kiekvienos epochos pabaigoje 60 blogiausių agentų buvo pakeičiami 20-ties geriausių agentų atžalomis. Atžalos buvo generuojamus iš tėvinio agento, optimizuojamiems parametrams pritaikant mutacijas, parinktas pagal normalųjį skirstinį. Skirstinio vidurkis buvo tėvinio agento reikšmė, o standartinis laiko dimensijų (T_{pre} , T_{pre3} , T_{post} ir T_{post3}) nuokrypis buvo 1, visų kitų dimensijų – 0,01. Su kiekvienu agentu buvo atlikta 10 nepriklausomų bandymų kiekvienoje epochoje, tikslo funkcijos reikšmės buvo sudedamos iš kiekvieno 10 šių bandymų rezultatų. Euristinė paieška buvo vykdoma 1 500 epochų. Kiekviename agente buvo 300 įėjimo neuronų.

Pirmojoje 64 Hz / 39 Hz konfigūracijoje pradinis nustatytas impulsų struktūros dydis buvo $n = 24$, tai yra du kartus didesnis nei tikėtinas impulsų kiekis, kurį generavo lygiagretūs Puasono procesai. Vėliau struktūros dydis buvo mažinamas į 12, 8, 4, 2 ir 1.

64 Hz konfigūracijoje struktūrų dydžiai buvo 19, 15, 12, 8 ir 4. Struktūros dydis $n = 19$ yra artimas tikėtinam Puasono triukšmo impulsų kiekiui, kuris buvo 19,2. Šiame eksperimente pradinės sąlygos buvo paimtos iš 64 Hz / 39 Hz ir $n = 24$ konfigūracijos optimizavimo rezultatų, išskyrus pradinės sąlygas tripleto sąveikai (žr. 1.4.2 Rezultatai).


39 Hz / 39 Hz ir 25 Hz / 39 Hz konfigūracijoms pradiniai parametrai buvo paimti iš 64 Hz / 39 Hz ir $n = 8$ konfigūracijos optimizavimo rezultatų, vėlgi, išskyrus pradinės sąlygas tripleto taisyklei (žr. 1.4.2 Rezultatai). Šiame eksperimente impulsų struktūros dydis $n = 8$ keičiamas nebuvo.

Optimizavus parametrus, neurono mokymo sėkmė buvo vertinama 1 000 kartų apmokius neuroną atpažinti to paties dydžio struktūrą. Mokymo sėkmės kriterijai buvo: $\Delta\mu_w \geq 0,3$ ir $12 < \lambda < 50$ mokymo pabaigoje (1.11).

Genetinė optimizacija buvo pakartota keletą kartų, rezultatai buvo panašūs.

Neuronų ir sinapsių plastikos modeliai

Šiame tyrime buvo naudojamas SRM neuronų modelis buvo identiškas aprašytam ankstesniame skyriuje 1.2 „STDP mokymas kintančio triukšmo sąlygomis“.



Pav. 1.17. STDP impulsų sąveikos tipai. **a:** „Artimiausio kaimyno“ sąveika su tiesioginėmis poromis. **b:** Tripleto sąveika. **c:** Sąveika „visi su visais“.

Visų eksperimentų metu buvo nustatyti tokie neuronų modelio parametrai: $T_r = 10$, $T_m = 10$ ir $T_s = 0,5$. W_r priklausė nuo neurono slenkstinės vertės ir jo vertė buvo lygi 29.

Eksperimente buvo taikoma tik viena STDP žadinamasis-į-žadinamąjį taisyklė. Impulsų sąveikos modeliai, naudoti šiame tyrime, yra pavaizduoti **Pav. 1.17**. Tripleto sąveikos taisyklė (Pav. 1.17b) buvo kombinuojama su „artimiausio kaimyno“ taisykle (Pav. 1.17a). STDP sinapsių svorių pokyčiai aprašyti lygtimis (1.12), (1.13) ir (1.14).

„Artimiausio kaimyno“ sąveika:

$$\Delta w_j = \begin{cases} \alpha e^{\frac{-\Delta t}{T_{post}}} & \text{if } \Delta t > 0 \\ -\alpha A_{pre} e^{\frac{-\Delta t}{T_{pre}}} & \text{if } \Delta t < 0 \\ 0 & \text{if } \Delta t = 0 \end{cases} \quad (1.12),$$

„artimiausio kaimyno“ su tripletu sąveika:

$$\Delta w_j = \begin{cases} \alpha \left(1 + A_{post3} e^{\frac{-\Delta t_{post3}}{T_{post3}}} \right) e^{\frac{-\Delta t}{T_{post}}} & \text{if } \Delta t > 0 \\ -\alpha \left(A_{pre} + A_{pre3} e^{\frac{-\Delta t_{pre3}}{T_{pre3}}} \right) e^{\frac{-\Delta t}{T_{pre}}} & \text{if } \Delta t < 0 \\ 0 & \text{if } \Delta t = 0 \end{cases} \quad (1.13),$$

sąveika „visi su visais“:

$$\Delta w_j = \begin{cases} \alpha e^{\frac{-\Delta t}{T_{post}}} (1 + y_{post}) & \text{if } \Delta t > 0 \\ -\alpha A_{pre} e^{\frac{-\Delta t}{T_{pre}}} (1 + y_{pre}) & \text{if } \Delta t < 0 \\ 0 & \text{if } \Delta t = 0 \end{cases} \quad (1.14),$$

kur Δw_j yra individualios sinapsės svorio pokytis; α – mokymo žingsnis; Δt yra laiko skirtumas tarp postsinapsinio ir presinapsinio impulsų; A_{pre} , A_{pre3} , A_{post3} , T_{pre} , T_{pre3} , T_{post} ir T_{post3} yra parametrai, apibrėžiantys STDP funkcijų amplitudes bei nuolydžius. Kintamieji y_{post} ir y_{pre} buvo skaičiuojami taip pat, kaip ir kintamieji x lygtyse (1.3) ir (1.4), vienintelis skirtumas tas, jog čia nebuvo naudojami svoriai.

1.4.2. Rezultatai

Rezultatai iš eksperimentų naudojant 64 Hz / 39 Hz ir 64 Hz konfigūracijas yra pavaizduoti Pav. 1.18. Taikant tripleto sąveikos taisyklę rezultatai buvo žymiai geresni nei kitas dvi

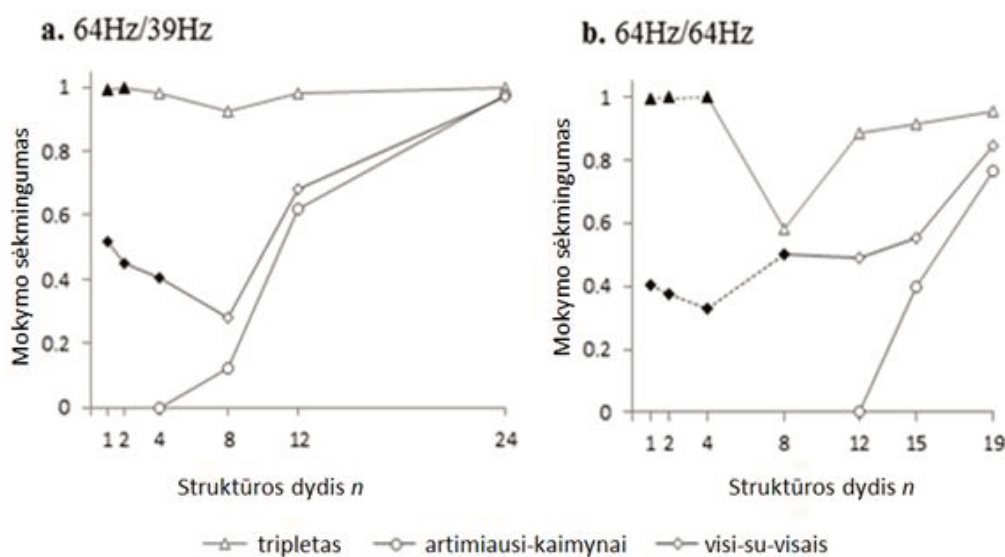
taisyklės abiejose konfigūracijose, nors 64 Hz konfigūracijoje tripleto mokymas žymiai pablogėjo, kuomet nustatytas struktūros dydis buvo $n = 8$. Mokymas su paprasta „artimiausio kaimyno“ sąveikos taisykle pasirodė blogiausiai, neuronas nebesugebėjo išmokti struktūros pavyzdžio, kuomet $n = 4$ 64 Hz / 39 Hz konfigūracijoje, ir $n = 12 - 64$ Hz konfigūracijoje.

Reikia paminėti, kad naudojant 64 Hz konfigūraciją, iš pradžių genetinis algoritmas nesugebėjo surasti taško, kur tripleto sąveika veiktų geriau nei „visi su visais“, o pasiekus $n = 15$, tripleto sąveika veikė prasčiau nei „artimiausio kaimyno“. Tai negalėjo būti globalaus optimalumo taškas, kadangi „artimiausio kaimyno“ sąveika yra specialusis tripleto atvejis. Tai reiškia, jog optimizacija užstrigo lokalaus optimalumo taške. Norint patikrinti šią prielaidą, optimizuoti „artimiausio kaimyno“ parametrai, esant $n = 15$, buvo panaudoti kaip išeities taškas tripleto sąveikai, papildomai A_{pre3} ir A_{post3} buvo nustatyti lygūs nuliui, $T_{pre3} = 2T_{pre}$ ir $T_{post3} = 2T_{post}$. Rezultatai buvo kur kas geresni: tripleto sąveika veikė geriau nei kitos dvi. Siekiant pašalinti galimą nesąžiningą lenktyniavimą, „visų su visais“ ir „artimiausio kaimyno“ sąveikos buvo optimizuojamos papildomus 3 000 epochų, tačiau pagerinti rezultatų nepavyko. Nors čia negalima padaryti tvirtų išvadų, tačiau galima daryti tvirtą prielaidą, jog tripleto sąveika gali veikti geriau.

Kuomet struktūra buvo pakankamai didelė, rezultatai iš abiejų 64 Hz / 39 Hz ir 64 Hz konfigūracijų buvo gana panašūs: neuronas buvo selektyvus struktūrai, atsako impulsas buvo generuojamas su 2 ms vėlinimu. Toks vėlinimas buvo nulemtas parinktos PSP branduolio funkcijos (1.2). 64 Hz / 39 Hz konfigūracijoje neuronas su tripleto sąveika išliko selektyvus iki $n = 4$, o „visų su visais“ atveju – iki $n = 8$; 64 Hz konfigūracijoje tripleto sąveika išliko selektyvi iki $n = 8$, o „visi su visais“ – iki $n = 12$.

Kuomet struktūra tapo per maža, kad visų su struktūra susietų sinapsių svoriai galėtų sąlygoti atsako impulsą, neuronas tapo nebeselektyvus, tačiau įdomu yra tai, jog svoriai, susieti su struktūra, vis vien sugebėjo išaugti labiau už likusiuosius, o neurono atsako dažnumas išliko maždaug stabilus. Čia reikia pabrėžti, jog mažos struktūros atvejais (ypač, kuomet $n = 1$ ir erdvinė struktūra apskritai neegzistavo), tripleto ir visi-su-visais elgsena buvo labai skirtinga. Papildomi bandymai parodė, jog tripleto taisyklės 64 Hz / 39 Hz atveju, neuronas reagavo į padidėjusį įėjimo neuronų impulsų dažnumą, o 64 Hz / 64 Hz

atveju, tripletas, regis, prisitaikė aptikti periodinius impulsus, taip pat mokymo sėkmei įtakos turėjo impulsų plyšiai, generuojami neuronų, nesusietų su struktūra (Pav. 1.16). „Visų su visais“ sąveika 64 Hz / 39 Hz atveju gerai veikė tik tuomet, jei egzistavo ir periodiniai impulsai, ir periodiniai plyšiai, o 64 Hz / 64 Hz atveju pašalinus plyšius „visų su visais“ sąveikos atveju mokymo našumas smarkiai pagerėjo. Čia reikia pabrėžti, jog 64 Hz / 39 Hz konfigūracijoje genetinis algoritmas invertavo „visų su visais“ sąveikos STDP taisyklę, kuomet $n < 8$, tai yra, kuomet neuronas nebebuvo selektyvus. Visos šios STDP ypatybės reikalauja papildomų tyrimų.




Pav. 1.18. Mokymo sėkmės priklausomybė nuo impulsų struktūros dydžio. Juodais markeriais pažymėti mokymo rezultatai, kuomet sinapsių svorių vidurkių skirtumas $\Delta\mu_w$ tenkino sėkmės kriterijų, tačiau neuronas nebuvo selektyvus struktūrai. **a:** Rezultatai naudojant 64 Hz / 39 Hz konfigūraciją. **b:** Rezultatai naudojant 64 Hz konfigūraciją. Punktyrinės linijos žymi, jog euristinė optimizacija tuose taškuose nebebuvo vykdoma, o mokymo sėkmė pamatuota naudojant anksčiau gautus parametrus.

Papildomai buvo atlikti riboti eksperimentai naudojant 39 Hz / 39 Hz ir 25 Hz / 39 Hz konfigūracijas, kur triukšmo lygis iš įėjimo neuronų, priklausančių struktūrai, buvo sumažintas ir apskritai pašalintas (Pav. 1.19). Šio eksperimento atveju „visų su visais“ ir „artimiausio kaimyno“ sąveikų modelių mokymo sėkmės rodikliai žymiai pagerėjo, tačiau tripleto mokymo našumas buvo blogesnis nei sąveikos „visi su visais“, esant 39 Hz konfigūracijai.

Šio eksperimento parametrų optimizacijos išėties taškai buvo paimti iš 64 Hz / 39 Hz konfigūracijos ir $n = 8$ optimizacijos rezultatų; optimizacijos metu struktūros dydis nebuvo

keičiamas ir išliko $n = 8$. Vėliau, analogiškai 64 Hz konfigūracijos eksperimentui, tripleto išeities tašku buvo paimti parametrai iš to paties eksperimento „artimiausio kaimyno“ sąveikos 39 Hz konfigūracijos rezultatų. Tai leido kiek pagerinti tripleto sąveikos mokymo našumą, tačiau nepakankamai, kad aplenktų sąveikos „visi su visais“ rezultatus 39 Hz taške.



Pav. 1.19. Mokymo sėkmės priklausomybė nuo įėjimo impulsų triukšmo lygio. Buvo naudojamas $n = 8$ struktūros dydis, įėjimo neuronų, priklausančių struktūrai, impulsų dažnumas buvo sumažintas nuo 64 Hz iki 39 Hz ir 25 Hz. Kitų įėjimo neuronų impulsų dažnumas buvo 39 Hz. Mokymo sėkmės reikšmės 64 Hz taškuose yra tokios pačios, kaip ir Pav. 1.18a.

Būtina pabrėžti, jog genetinis algoritmas tripleto sąveikai visų eksperimentų atveju pakeitė A_{pre3} koeficiento ženklą iš teigiamo į neigiamą, o 64 Hz konfigūracijos atveju, koeficientas A_{post3} taip pat tapo neigiamas.

1.4.3. Diskusija

Pagrindinis šio tyrimo tikslas yra pademonstruoti, jog pakeitus papildomų tripleto taisyklės koeficientų ženklą (\pm), potencialiai galima tikėtis geresnių neurono mokymo rezultatų, nei naudojant įprastinius dvigubos sąveikos modelius. Pažvelgus atidžiau į tripleto sąveikos taisyklę (Pav. 1.17b), tampa akivaizdu, jog teigiamas A_{pre3} padidina LTD, jei ankstesnis presinapsinis impulsas glaudžiai koreliavo su postsinapsiniu impulsu, taigi turi neigiamos įtakos egzistuojančiai koreliacijai. Ši ypatybė, nors netiesiogiai ir pagrįsta biologiniais tyrimais (Froemke & Dan, 2002, Pfister & Gerstner, 2006), tačiau vienareikšmiškai turi neigiamos įtakos erdvinių struktūrų mokymui. Jei A_{pre3} koeficientas yra neigiamas, jo įtaka mokymui yra atvirkštinė, LTD yra sumažinama arba pakeičiama LTP. Dar daugiau, tokia konfigūracija yra naudinga norint parinkti didesnio presinapsinių impulsų dažnumo sinapses, kadangi juo didesnis presinapsinis impulsų dažnumas, juo

didesnė tikimybė susiformuoti naudingam impulsų tripletui. Taigi, visiškai nenuostabu, jog genetinis algoritmas pakeitė A_{pre3} koeficiento ženklą. Tačiau darbe nesurasta gero paaiškinimo, kodėl genetinis algoritmas pakeitė A_{post3} koeficiento ženklą 64 Hz konfigūracijoje, ir kodėl būtent tik šioje konfigūracijoje. Neigiamas A_{post3} koeficientas nulemia LTD, kuomet du postsinapsiniai impulsai yra artimi laiko atžvilgiu, ir paskutinis postsinapsinis impulsas glaudžiai koreliuojasi su paskutiniu presinapsiniu impulsu. Šiuo metu galima tik spekuliuoti, jog toks LTD yra sukliamas, kuomet postsinapsinio neurono impulso dažnumas yra pernelyg aukštas, taip tokia konfigūracija padeda išlaikyti neurono impulsų dažnumą pageidautinose ribose.

Kitas įdomus pastebėjimas, jog tripleto ir „visų su visais“ sąveikos gali nulemti svorių pusiausvyrą, kuomet neuronų įėjimai yra Puasono triukšmas. Tokia įprastos visi-su-visais sąveikos elgsena jau yra prognozuojama Izikevichiaus ir Desai lygties (Izikevich & Desai, 2003), tačiau ne tuo atveju, jei STDP taisyklė yra invertuota, kaip 64 Hz / 39 Hz konfigūracijos rezultatų atveju, kuomet struktūra yra maža. Be to, tiek tripleto, tiek „visų su visais“ sąveikos sugeba aptikti arba padidėjusį impulsų dažnumą arba tam tikras deformacijas Puasono procese, net jei šios anomalijos nutinka tik vienoje sinapsėje, kurios įtaka postsinapsiniam potencialui nėra reikšminga.

Tų atvejų, kuomet neuronas nebuvo selektyvus struktūrai (Pav. 1.18, juodi markeriai), negalima vertinti kaip sėkmingo neurono mokymo erdvinėms struktūroms atpažinti. Tačiau šie parametrų taškai atskleidžia STDP mokymo įvairovę, kurią būtina toliau tirti ir paaiškinti, nes priešingu atveju, pati STDP mokymo rezultatų interpretacija gali būti nevienareikšmiška.

Svarbu paminėti, jog šiame tyrime buvo palyginta tik maža dalis iš STDP modelių įvairovės. Pavyzdžiui, impulsų sąveikos gali būti modeliuojamos naudojant simetrinę arba postsinapsiškai-centristinę interpretacijas (Morrison et al., 2008), nebuvo tirta valdomų minkštų ribų įtaka (Gütig et al., 2003), taip pat buvo praleista sąveikos „visi su visais“ tripleto versija (Pfister & Gerstner, 2006).

Šiame darbe gauti optimizuoti skirtingo dydžio struktūrų parametrai buvo skirtingi. Tai leidžia manyti, jog neurono parametrus reikia reguliuoti priklausomai nuo uždavinio sąlygų. Iš praktinės pusės tai neatrodo prasminga: jei apie įėjimo struktūrą žinoma tiek

daug, tuomet galima taikyti kur kas efektyvesnius, nei STDP mokymas, tradicinius analizės įrankius. Tačiau rezultatai rodo, jog tripleto taisyklė gali būti labai efektyvi, taikant ją neuronų tinkluose, aprašytuose ankstesniuose šios disertacijos skyriuose.

Šio darbo rezultatai turi būti vertinami atsargiai, kadangi euristinės optimizacijos metodas neužtikrina, jog bus pasiekti globalūs optimalumo taškai. Nors šio tyrimo rezultatai rodo, jog daugeliu atvejų tripleto sąveika gali nulemti labai sėkmingą mokymą, tačiau jie neįrodo, jog neįmanoma pagerinti „visų su visais“ ar „artimiausio kaimyno“ sąveikų rezultatų.

Išvados

Nepaisant milžiniško progreso neuronų moksle, dar nėra gerai žinoma, kaip funkcionuoja biologiniai neuronai, kaip iš tiesų veikia mokymosi ir atminties procesai. Didžiausia problema čia yra ne duomenų stygius, bet biologinių neuronų sistemų sudėtingumas ir didžiulė jų įvairovė. Be žinių apie pačią neuronų fiziologiją spragų šiuo metu yra tiesiog per daug duomenų ir hipotezių, kad būtų galima sukurti suprantamą, vieningą ir susistemintą neuronų teoriją, jau nekalbant apie bendrą smegenų teoriją. Kitais žodžiais tariant, ši dėlionė yra pernelyg didelė ir pernelyg daug detalių dar trūksta. Tačiau vilties teikia šiuo metu vystomi dideli projektai, tokie kaip Blue Brain Project, Human Brain Project (Markram, 2012) ir BRAIN Initiative (Markoff, 2013), kurių tikslas ir yra susisteminti turimas žinias apie biologinių neuronų sistemas.

Rengiant šią disertaciją atlikti tyrimai buvo apriboti vien tik STDP mokymu, kuris, vėlgi, nėra iki galo suprastas, eksperimentiniai duomenys rodo daugelį netiesiškumų, taip pat egzistuoja nemenkas kiekis skirtingų STDP fenomenologinių modelių (Caporale & Dan, 2008; Morrison et. al, 2008). Taigi, šis tyrimas buvo paremtas tik hipoteze apie biologinių neuronų mokymosi būdą, pritaikant šį Hebb'o mokymo būdą erdvinėms bei erdvinėms-laikinėms impulsų struktūroms. Tyrimo metu buvo identifikuotos kelios problemos, susijusios su tokiu mokymu, šios problemos buvo sprendžiamos vėlesnėje tyrimo eigoje.

I. Naudojant vien tik STDP mokymą, įmanoma sukurti dirbtinių neuronų tinklą, skirtą laike išdėstytų erdvinių impulsų struktūrų atpažinimui.

Tyrimo metu buvo suprojektuotas, įgyvendintas ir išbandytas naujas STDP mokymu pagrįstas dirbtinis neuronų tinklas, kuris sugebėjo išmokti ir atpažinti ilgai trunkančias neuronų impulsų struktūrų sekas. Šis tinklas su tam tikromis išlygomis sugeba atkartoti įsimintas struktūras.

II. Įmanoma sukurti dirbtinį neuronų tinklą, kuris sugebėtų išmokti ir atskirti persidengiančias erdvines neuronų impulsų struktūras.

Tyrimo eigoje buvo suprojektuotas, įgyvendintas ir išbandytas naujas STDP mokymu pagrįstas dirbtinis neuronų tinklas, kuriame buvo panaudoti nuo Euklido atstumo priklausantys sinapsių svorių koeficientai. Šis tinklas sugebėjo išmokti ir atskirti

erdvines neuronų impulsų struktūras, kurių aibės pasižymėjo ženkliais aibių sankirtomis. Dar daugiau, šiame tinkle išspręsta neurono slenkstinės vertės optimalumo problema, kuomet vieno mokymo pavyzdžiams naudojamos skirtingos struktūros su skirtingu geometrinio plotu.

III. Invertuotą STDP taisyklę galima pritaikyti kompensuojant kintančio foninio triukšmo lygį, kuomet STDP mokymas yra taikomas kintančio Puasono triukšmo sąlygomis.

Tyrimo metu buvo suprojektuotas, įgyvendintas ir išbandytas STDP mokymu pagrįstas dirbtinis neuronų tinklas, kuriame buvo pritaikytas adaptyvusis vertikalus slopinimas, taip pat, STDP taisyklė su invertuotu mokymo langu. Eksperimentų rezultatai rodo, jog toks būdas pagerina mokymo našumą tam tikromis sąlygomis, tačiau kylant foninio triukšmo lygiui toks tinklas reikalauja vis tikslesnio mokymo parametrų reguliavimo.

IV. STDP tripleto sąveika su invertuotais papildomais liekamojo pėdsako kintamaisiais gali sąlygoti žymiai geresnį mokymo našumą nei įprastinės „visų su visais“ ir „artimiausio kaimyno“ STDP sąveikos.

Buvo palyginti trys skirtingi fenomenologiniai STDP impulsų sąveikų modeliai. Naudojant genetinį algoritmą neurono mokymo parametrai buvo optimizuojami besimokant skirtingo dydžio erdvines neuronų impulsų struktūras. Daugeliu atvejų, naudojant STDP tripleto sąveiką, pavyko pasiekti kur kas geresnių rezultatų nei tikėtasi, palyginti su kitais impulsų sąveikos modeliais.

Literatūros saraksts

Abbott LF, Nelson SB. 2000. Synaptic plasticity: taming the beast. *Nat. Neurosci.* 3:1178-1183

Abraham WC. 2003. How long will long-term potentiation last? *Philos Trans R Soc Lond B Biol Sci* 358: 735–744.

Bienenstock, E. L., Cooper, L. N., & Munro, P.W. (1982). Theory for the development of neuron selectivity: Orientation specificity and binocular interaction in visual cortex. *J. Neurosci.*, 2, 32–48.

Bi GQ, Poo MM. 1998. Synaptic modifications in cultured hippocampal neurons: dependence on spike timing, synaptic strength, and postsynaptic cell type. *J. Neurosci.* 18:10464–72

Bi GQ, Poo MM. 2001. Synaptic modification by correlated activity: Hebb's postulate revisited. *Annu. Rev. Neurosci.* 24:139–66

Burkitt AN, Meffin H, Grayden DB (2004) Spike-timing-dependent plasticity: the relationship to rate-based learning for models with weight dynamics determined by a stable fixed point. *Neural Comput* 16:885–940

Caporale, N., & Dan, Y. (2008). Spike timing-dependent plasticity: a Hebbian learning rule. *Annu. Rev. Neurosci.*, 31, 25 – 46.

Cardin, J. A. et al. (2009) Driving fast-spiking cells induces gamma rhythm and controls sensory responses. *Nature* 459, 663–667.

Elman, J. L. (1998). Rethinking innateness: A connectionist perspective on development (Vol. 10). MIT press.

Froemke RC, Dan Y. 2002. Spike-timing-dependent synaptic modification induced by natural spike trains. *Nature* 416:433–38

Gerstner, W., & Kistler, WM. (2002). Spiking neuron models. Cambridge: Cambridge UP

Gilson, M., Masquelier, T., & Hugues, E. (2011). STDP allows fast rate-modulated coding with Poisson-like spike trains. *PLoS Comput Biol*, 7(10), e1002231.

Grossberg, S. (2013). Adaptive resonance theory. *Scholarpedia*, 8(5), 1569.

Gütig R, Aharonov R, Rotter S, Sompolinsky H (2003) Learning input correlations through nonlinear temporally asymmetric Hebbian plasticity. *J Neurosci* 23(9):3697–3714

Gupta A, Long LN (2007) Character recognition using spiking neural networks. *IJCNN*, pages 53–58.

Guyonneau R, VanRullen R, Thorpe SJ (2004) Temporal codes and sparse representations: a key to understanding rapid processing in the visual system. *Journal of Physiology-Paris*, 98(4), 487-497.

Guyonneau R, VanRullen R, Thorpe SJ (2005) Neurons tune to the earliest spikes through STDP. *Neural Comput* 17: 859–879.

Izhikevich E, Desai N (2003) Relating STDP to BCM. *Neural Comput.*, 15, 1511–1523.

Jolivet R., Rauch A., Luscher H.R., and Gerstner, W. (2006), Predicting spike timing of neocortical pyramidal neurons by simple threshold models. *Journal of Computational Neuroscience* 21:35-49

Kasabov, N. (2012). Evolving spiking neural networks and neurogenetic systems for spatio-and spectro-temporal data modelling and pattern recognition. In *Advances in Computational Intelligence* (pp. 234-260). Springer Berlin Heidelberg.

Kasabov N, Dhoble K, Nuntalid N, Indiveri G (2013) Dynamic evolving spiking neural networks for on-line spatio- and spectro-temporal pattern recognition. *Neural Netw.* 41: 188-201.

Krunglevicius, D. (2011). Neural Processing of Long Lasting Sequences of Temporal Codes-Model of Artificial Neural Network based on a Spike Timing-dependant Learning Rule. *IJCCI (NCTA)*, 196-204. SciTePress, (2011).

Krunglevicius, D. (2014). STDP Learning Under Variable Noise Levels. IJCCI (NCTA), 165-171. SciTePress, (2014).

Krunglevicius, D. (2015). Competitive STDP Learning of Overlapping Spatial Patterns. *Neural Comput*, 27(8):1673-85.

Krunglevicius, D. (2016). Modified STDP Triplet Rule Significantly Increases Neuron Training Stability in the Learning of Spatial Patterns. *Advances in Artificial Neural Systems*, 2016, 1.

Maass, W. (1997). Networks of spiking neurons: the third generation of neural network models. *Neural networks*, 10(9), 1659-1671.

Markoff J. 2013. Obama seeking to boost study of human brain. *New York Times* 17.

Markram H. 2012. The human brain project. *Scientific American* 306.6: 50-55.

Masquelier, T., Guyonneau, R., Thorpe, S. J. (2008). Spike timing dependent plasticity finds the start of repeating patterns in continuous spike trains. *PLoS ONE*, 3(1), e1377.

Masquelier T., Guyonneau R., Thorpe S.J. (2009) Competitive STDP-based spike pattern learning. *Neural Comput* 21:1259–1276.

Morrison, A., Diesmann, M., & Gerstner, W. (2008). Phenomenological models of synaptic plasticity based on spike timing. *Biological cybernetics*, 98(6), 459-478.

Nessler B, Pfeiffer M, Maass M (2009). STDP enables spiking neurons to detect hidden causes of their inputs. *Proceedings of NIPS Advances in Neural Information Processing Systems* (Vancouver: MIT Press).

Pfister, JP., & Gerstner, W. (2006). Triplets of spikes in a model of spike timing-dependent

Song, S., Miller, K.D., and Abbott, L.F. (2000). Competitive Hebbian learning through spike-timing-dependent synaptic plasticity. *Nat Neurosci* 3, 919-926.

Sutton, R. S., & Barto, A. G. (1998). *Reinforcement learning: An introduction* (Vol. 1, No. 1). Cambridge: MIT press.

Szatmáry, B., & Izhikevich, E. M. (2010). Spike-timing theory of working memory. *PLoS Comput Biol*, 6(8), e1000879.

Summary

The large goal in the scientific field of machine learning is to achieve human-level cognition and eventually artificial intelligence, a thinking machine capable of human-level reasoning and beyond. This aspiration remains for now largely in the realm of science fiction, but it is the direction of and motivation for continuing scientific research. Spin-offs from these efforts include a large variety of machines which are applicable to the practical tasks of heuristic optimization, pattern recognition, prediction, data clustering, dimensionality reduction and other jobs. Machine learning is applied in multiple fields of human endeavor, from predicting financial trends to medical diagnosis, from entertainment to industrial engineering.

There are multiple approaches for building systems which are capable of learning, and most of them are based on mimicking nature, such as Darwinian evolution, the behavior of swarms, etc. In the emulation of human-level cognition, there are of course attempts to mimic the behavior of the central nervous system. There are two distinct approaches, one being the top-down approach, where principles of machine learning are based, for example, on assumptions about “what the brain *does*,” and researchers rely upon human or animal psychology. The most prominent example of such an approach is reinforcement learning, based on the behaviorist paradigm within the field of psychology (Sutton & Barto, 1998). Another approach is the bottom-up one where principles of learning are based on “how the brain *works*,” the physiology of the brain. Mimicking the behavior of neurons and artificial neural networks are the best example of this approach. Multiple families of artificial neural networks were developed which have been applied widely in practical machine learning, including the Perceptron, the Self-Organizing-Map and others. Wolfgang Maass distinguishes three generations of artificial neural networks (ANNs): the first generation of ANNs was based on McCulloch-Pitts neurons; the second generation has a continuous activation function, such as a sigmoid function; and the third generation is spiking neural networks (Maass, 1997).

On the subject of artificial neural networks, there are two related but very distinct fields of scientific inquiry, one being computational neuroscience, which is a branch of theoretical neuroscience which studies the function of the brain and the processes of

structures in the brain and biological neurons; and the other being machine learning, which is a branch of computer science. The aim of neuroscience is to explain the brain, while the aim of machine learning is to build a practical machine. Because these are very different goals, the two fields are not always in agreement. As an example, the Perceptron was constructed based on contemporary knowledge and assumptions about the behavior of biological neurons, but we know now with a high degree of certainty that biological neurons behave quite differently. For instance, the multilayer Perceptron network is commonly trained by back-propagation learning. No such process exists in biological neurons; there is no supervised learning at all. Despite that, Perceptron neural networks have been developed and researched for decades because they are a very useful tool for classification and prediction. On the other hand, a number of even prominent theories of neural learning developed in the field of computational neuroscience are almost completely ignored by machine learning because they never find a practical application. The most prominent examples are the Bienenstock-Cooper-Munro (BCM) theory of synaptic plasticity (Bienenstock et al.,1982) and Adaptive Resonance Theory (ART) (Grossberg, 2013).

My dissertation belongs rightly in the field of connectionism (Elman, 1998). I combine the fields of neuroscience, knowledge of the plasticity of biological neurons and models emanating from computational neuroscience for attacking the problem of pattern recognition. The term connectionism was coined by Donald Hebb in the 1940s, and it is therefore an old and established field of scientific inquiry. The subject of my research is spiking neural networks and spike-timing-dependent plasticity (STDP) from the perspective of the learning of spatial and spatiotemporal patterns. STDP is a form of Hebbian learning discovered in biological neurons. Although models of neurons developed in the field of computational neuroscience can reproduce some aspects of biological neurons with astonishing accuracy, one cannot just take an existing model and apply it to real-world data: there are multiple problems associated with this, for example, the seemingly simple problem of how to encode data turns out to be far from trivial. Other problems are connected with the stability of the network and optima of parameters. There is a phenomenological variety of STDP implementations and each has its own distinct behavior. At the present time it remains unclear which is the most accurate, and which one

is the best choice for a given task. Put simply, the goal of my research was to master spiking neural networks with STDP learning for the task of pattern recognition. In the process I identified a number of problems, and solved several of them.

Objectives of Research and Problems

The primary objective of my research was to apply STDP learning to spatiotemporal and spatial pattern recognition. I identified and solved problems as my research progressed.

When I began my research, there were very little works done in the field. It was known that a specific STDP rule can act as a coincidence detector, that it can detect the beginning of a spatiotemporal pattern injected into Poisson noise (Masquelier et al., 2009; Song et al., 2000; Guyonneau et al., 2005; Gerstner & Kistler, 2002). Several authors have used STDP learning for character recognition (Gupta & Long , 2007; Nessler et al., 2009). Interesting work has been done focusing on evolving networks as well (Kasabov et al., 2012; 2013).

I began my research by repeating the experiments of Masquelier and colleagues (Masquelier et al. 2008; 2009). Masquelier and colleagues concentrated their research on spatiotemporal patterns. STDP training is incapable of creating any spatiotemporal memory, however, and is only capable of spatial pattern memory. I solved this problem by designing a multilayer neural circuit capable of learning actual spatiotemporal patterns (Krungelevicius, 2011). I concentrated my research on the problems which I identified in implementing my circuit: the parameters of the neuron model can be optimized only for a certain range of stimulation. The amount of stimulation results from the intensity or spatial size of the pattern itself and from different levels of background noise. Moreover, spatial patterns (which can be components of spatiotemporal patterns) can be inclusive of one another, and STDP learning is unable to discriminate one from another. I solved the latter problem by designing a network circuit with distance-dependent synaptic strength factors (Krungelevicius, 2015a). I also studied the problem of variable background noise and solved it with limited success by introducing dynamic adaptive inhibition based on an inverted STDP training window (Krungelevicius 2014).

I attempted to come up with a method for predicting STDP behavior more accurate than those based on Poisson distribution (Izhikevich & Desai, 2003). The problem is that the

spike-response-model (SRM) which I use in my work cannot produce Poisson distributed postsynaptic spike trains. Since the SRM reproduces the behavior of the biological neuron quite accurately, it is safe to assume that this is the case in biological neurons as well. Non-Poisson distribution of postsynaptic spikes potentially may have completely different outcomes from Poisson distributed ones when dealing with STDP training. I attempted to use bivariate Azalini distributions for modeling the postsynaptic membrane potential process, but had limited success.

In addition, by applying heuristic optimization for benchmarking the performance of STDP training, I discovered that the STDP triplet interaction function under certain conditions can perform far better than other STDP implementations (Krunglevicius, 2015b). This discovery implies that the triplet interaction rule needs more research than has been done to date.

Relevance

If human-level cognition in machine learning is even achievable, it is impossible to predict its effect across the spectrum of human endeavors; one can only surmise the impact would be immense. My work is only a tiny fraction of a fraction of the whole problem, but does belong to the field generally.

For now, existing computer power is insufficient to use spiking neural networks in practice, but it seems safe to assume this is a temporary obstacle. Understanding the limitations and benefits of spiking neural networks with respect to STDP learning is necessary before attempting to use STDP learning for practical applications in the future.

Practical Value of the Research

Although it is still premature to use STDP for practical applications, I did solve a few important problems associated with STDP learning. In other words, this work is a step forward on the way to building a practical machine. At this time, however, it is not possible to determine how efficient such a machine would be.

Aim of the Research

The main aim of the research was to improve existing competitive neural networks with STDP learning (Guyonneau et al., 2004; Masquelier et al., 2009) by implementing novel

neural circuits which could learn sequences of spatial patterns and differentiate similar spatial patterns and to find a way to control the process of training so that neural network could function at different levels of stimulation.

Tasks of the Research

To achieve the main objectives of the research, I completed the following tasks:

- Designed, implemented and tested a novel artificial neural network for learning long-lasting sequences of spatio-temporal patterns.
- Designed, implemented and tested a novel artificial neural network for learning mutually inclusive spatial patterns.
- Designed, implemented and tested a novel artificial neural network for learning spatial patterns in a variable noise environment.
- Experimentally compared different phenomenological models of STDP and determined that under certain conditions the modified triplet interaction model can be more much robust than competitors.

Methods

In my research for modeling spiking neurons I used the spike-response-model (Gerstner & Kistler, 2002) and a few different phenomenological models of STDP, including nearest-neighbor interaction, all-to-all interaction (Morrison et al., 2008) and triplet interaction (Pfister & Gerstner, 2006). I implemented and simulated neural circuits in Matlab and C/C++ environments.

Scientific Novelty

I have designed a neural circuit which is capable of learning long sequences of spatial codes, in other words, spatiotemporal coding. It is not the first model of neural learning and memory based on STDP learning (Szatmáry & Izhikevich, 2010), but I introduced a novel architecture of a multilayer WTA network which is capable of aggregating sequences of events.

I designed a neural circuit for learning overlapping spatial patterns of different size. This is a completely new approach in spiking neural networks based on the assumption that

length-dependent conductivity in dendrites plays a crucial role in controlling neural activity and learning.

I used an inverted STDP window for dynamic inhibition when learning took place in conditions of variable background noise. This is a novel method.

I discovered that under certain conditions triplet STDP interaction can perform better by far than a two-spike-based interaction.

Thesis statements

5. There are no theoretical obstacles to using STDP training for spatiotemporal patterns. This supports the hypothesis of spatiotemporal coding in living neural systems.
6. When applying distance-dependent factors to synaptic strengths in a circuit which combines vertical excitation and inhibition, it is possible to build a neural network which is capable of discriminating overlapping spatial patterns and patterns of different spatial size. This approach overcomes the problem of parameters for the model only being capable of optimization over a specific range of stimulation.
7. It is possible to build an STDP-based neural network with adaptive inhibition, and thus it is possible to train it even if the amount of input stimulation varies over time.
8. The STDP triplet interaction rule can lead to a more rapid and more stable training than usual all-to-all and nearest-neighbor interactions.

Approbation

The results of this thesis have been presented at a number of international conferences:

- NCTA 2011 – International Conference on Neural Computation Theory and Applications, Paris, France;
- BISIP 2014 - The 3rd IEEE Workshop on Bio-Inspired Signal and Image Processing, Vilnius, Lithuania;
- NCTA 2014 – International Conference on Neural Computation Theory and Applications, Rome, Italy.

The main results of this thesis were published in the following peer-reviewed journals:

5. Krunglevicius, D. (2011). Neural Processing of Long Lasting Sequences of Temporal Codes - Model of Artificial Neural Network Based on a Spike Timing-dependant Learning Rule. IJCCI (NCTA), 196-204. SciTePress, (2011).
6. Krunglevicius, D. (2014). STDP Learning under Variable Noise Levels. IJCCI (NCTA), 165-171. SciTePress, (2014).
7. Krunglevicius, D. (2015). Competitive STDP Learning of Overlapping Spatial Patterns. Neural Comput, 27(8):1673-85.
8. Krunglevicius, D. (2016). Modified STDP Triplet Rule Significantly Increases Neuron Training Stability in the Learning of Spatial Patterns. Advances in Artificial Neural Systems, 2016, 1.

Dalius Krunglevičius

STDP MOKYMO TAIKYMAS ERDVINĖMS BEI ERDVINĖMS-LAIKINĖMS
STRUKTŪROMS ATPAŽINTI

Daktaro disertacija

Fiziniai mokslai (P000),

Informatika (09 P)

Redaktorė Eglė Bukienė

Dalius Krunglevičius

STDP LEARNING OF SPATIAL AND SPATIOTEMPORAL PATTERNS

Doctoral Dissertation

Physical Sciences (P000),

Informatics (09 P)

Editor Geoffrey Noah Vasil