

# Neuronimallit jännitepiikkejä käyttävissä neuroverkoissa

LuK-tutkielma  
Turun yliopisto  
Fysiikka  
2024  
Lotta Miettinen  
Tarkastaja:  
Prof. Petriina Paturi

Turun yliopiston laatujärjestelmän mukaisesti tämän julkaisun alkuperäisyys on tarkastettu Turnitin OriginalityCheck-järjestelmällä

TURUN YLIOPISTO

Fysiikan laitos

**MIETTINEN, LOTTA** Neuronimallit jännitepiikkejä käyttävissä neuroverkoissa

LuK-tutkielma, 19 s.

Fysiikka

Maaliskuu 2024

---

Tutkielmassa tutustutaan jännitepiikkejä käyttäviin neuroverkkoihin ja keskitytään erityisesti näissä neuroverkoissa käytettäviin neuronimalleihin, joista esitellään kaksi tällä hetkellä merkittävää mallia ja niiden ominaisuuksia. Ensimmäinen mallista on Hodgkin-Huxley-malli, joka on historiallisesti merkittävä ja realistinen malli. Toinen malli on toteutukseltaan yksinkertaisempi ja energiatehokas Leaky-integrate-and-fire-malli. Tutkielmassa esitellään myös memristorien käyttöä Hodgkin-Huxley-mallissa ja neuroverkkojen synapseina.

Asiasanat: neuronimalli, Hodgkin-Huxley-malli, Leaky-integrate-and-fire-malli, SNN, memristori

# Sisällys

<b>Johdanto</b>	<b>1</b>
<b>1 Jännitepiikkejä käyttävä neuroverkko</b>	<b>1</b>
<b>2 Neuronin biologiset ominaisuudet</b>	<b>3</b>
<b>3 Memristorit</b>	<b>4</b>
<b>4 Hodgkin-Huxley-malli</b>	<b>5</b>
4.1 Hodgkin-Huxley-mallin matemaattinen esitys . . . . .	6
4.2 Virtapiiri . . . . .	8
4.3 Memristiivinen Hodgkin-Huxley-malli . . . . .	9
<b>5 Leaky-integrate-and-fire-malli</b>	<b>11</b>
5.1 Virtapiiri . . . . .	11
5.2 LIF-neuronien toiminta . . . . .	12
5.3 LIF-mallin hyvät ja huonot puolet . . . . .	14
<b>6 Ristikkorakenne</b>	<b>15</b>
<b>7 Yhteenveto</b>	<b>17</b>

## Johdanto

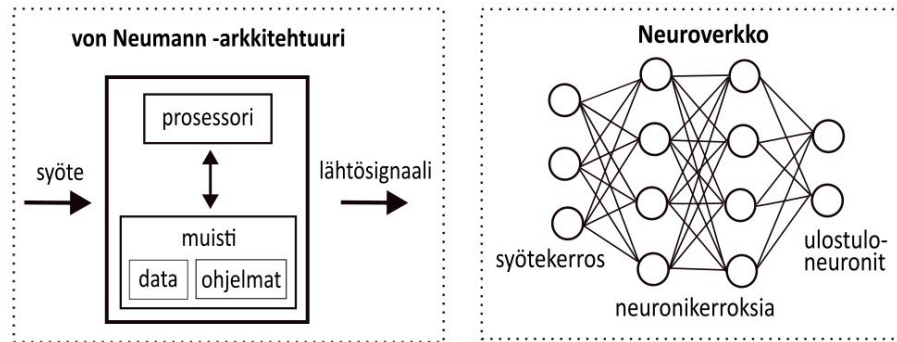
Tietokoneiden laskentateho on kasvanut nopeasti viimeisten vuosikymmenien aikana. Kasvua on voitu ylläpitää pienentämällä transistorien kokoa, jolloin niiden määrää on voitu kaksinkertaistaa kahden vuoden välein Mooren lain mukaisesti. Mooren lain mukainen kasvu on kuitenkin pysähtymässä. Käsiteltävät datamäärät sen sijaan jatkavat kasvua ja niiden käsittelyyn tarvitaan lisää laskentatehoa. Tämä on ongelma von Neumann -arkkitehtuuria käyttäville nykytietokoneille, jolla suurien datamäärien käsittely ei ole tehokasta niiden rakenteen vuoksi. Ongelmana on myös tietokoneiden suuri energiankulutus. [1, 2]

Lupaava ratkaisu kasvavaan laskentatehon tarpeeseen on neuromorfinen laskenta, joka ottaa mallia biologisista aivoista. Biologiset aivot ovat energiatehokkaat ja rakenteeltaan kompaktit. Ihmisen aivoissa on  $10^{15}$  synapsia ja  $10^{11}$  neuronia, joiden tehonkulutus on yhteensä vain noin 20 W. Esimerkiksi laskentateholtaan paljon heikompi matkapuhelin, jossa on  $10^{10}$  transistoria, kuluttaa noin 10 W [3]. Rakenteensa ansiosta neuromorfiset tietokoneet kykenevät biologisten aivojen tavoin monimutkaiseen rinnakkaislaskentaan, johon von Neumann -arkkitehtuuri ei pysty [1, 2].

Neuromorfisissa tietokoneissa käytettävät neuroverkot koostuvat biologisten aivojen tavoin hermosoluista eli neuroneista, jotka ovat neuroverkkojen laskennallisia yksiköitä, ja niiden välillä olevista synapseista, jotka mahdollistavat informaation kulkeutumisen neuronista toiseen. Tässä tutkielmassa keskitytään kahteen neuronimalliin sekä niiden ominaisuuksiin ja hyödyntämiseen neuroverkoissa. Nämä mallit ovat Hodgkin-Huxley-malli ja Leaky-integrate-and-fire-malli.

## 1 Jännitepiikkejä käyttävä neuroverkko

Neuroverkot yrittävät keinotekoisesti mallintaa biologisten aivojen toimintaa ja rakennetta. Merkittävin ero nykyisin yleisimmin käytössä olevan von Neumann -arkkitehtuurin



Kuva 1: Kaaviokuva von Neumann -arkkitehtuurin ja neuroverkkojen rakenteista. Von Neumann -arkkitehtuurissa prosessorin ja muistin välillä on sama väylä datalle ja ohjelmille, mikä ei ole tehokasta. Neuroverkoissa prosessori ja muisti eivät ole erillään, vaan neuronit ja synapsit hoitavat molemmat tehtävät.

ja neuroverkkoihin perustuvan systeemin välillä on niiden rakenne. Rakenteiden erot on esitetty kuvassa 1. Von Neumann -arkkitehtuuri koostuu prosessorista ja muistista, johon data ja dataa käyttävät ohjelmat on tallennettu. Prosessori käsittelee syötettyä datan ja ohjelmien avulla, jotka käyttävät muistin ja prosessorin välillä samoja väyliä. Prosessori on siksi suuren osan ajasta toimettomana, jolloin tietokoneet myös kuluttavat paljon energiaa. Tätä kutsutaan von Neumannin pullonkaulaksi. [1, 2]

Neuroverkoissa prosessoria ja muistia ei ole jaettu erillisiin osiin, vaan neuronit ja synapsit prosessoivat dataa ja toimivat myös muistina. Syöte saapuu syöttöneuroneille, jotka käsittelevät sen ja siirtävät signaalin eteenpäin seuraaville neuroneille. Ohjelmat määrittyvät neuroverkon rakenteen avulla, eikä erillisten komentojen kautta. Neuroverkoissa laskenta on siis mahdollista hajautetusti muistin sisällä, jolloin ei synny von Neumannin pullonkaulan kaltaista ongelmaa. Neuroneista ja synapseista koostuvalla rakenteella saavutetaan myös biologisia aivoja vastaava suuri määrä yhteyksiä ja kompakti rakenne. Neuroverkon toimiminen rinnakkaisesti mahdollistaa pienen energiankulutuksen, sillä vain osa systeemistä on kerrallaan aktiivinen. [1, 2]

Neuroverkot voidaan jakaa kolmeen sukupolveen. Ensimmäisen sukupolven neu-


roverkoissa lähtösignaali on diskreetti ja voi saada arvot nolla ja yksi. Toisen sukupolven neuroverkoissa lähtösignaali voi saada arvon nollan ja yhden välillä, jolloin neuroverkko tarvitsee vähemmän neuroneita. Kolmannen sukupolven neuroverkoissa laskennalliset yksiköt ovat jännitepiikkejä tuottavia neuroneja (engl. spiking neurons). Tämänkaltaisen neuroverkko voi prosessoida paljon dataa suhteellisen pienellä jännitepiikkien määrällä. [1]

Jännitepiikkejä käyttävä neuroverkko (engl. spiking neural network, SNN) on kolmannen sukupolven neuroverkko. Se on enemmän biologisten aivojen kaltainen kuin aikaisemmat neuroverkot, sillä kommunikaatio neuronien välillä tapahtuu jännitepiikkien avulla. Informaatiota varastoidaan näiden jännitepiikkien määrän ja ajoituksen muodossa. Kun riittävän tiheä ja voimakas jännitepiikkien sarja syötetään neuroniiin, se reagoi tuottamalla jännitepiikin. Neuronin reagointi muuttuu tulosignaalin muutosten mukaan. SNN:n laskennalliset ominaisuudet sekä samankaltaisuus biologisen systeemin kanssa mahdollistavat niiden käytön useissa teknologisissa sovelluksissa. [4]

## 2 Neuronin biologiset ominaisuudet

Rakenteeltaan neuroni voidaan jakaa kolmeen toiminnalliseen osaan. Solukeskus on neuronin runko-osa ja se on vastuussa jännitepiikin tuottamisesta. Sitä voidaan verrata tietokoneen prosessoriin. Monihaaraiset tuojahaarakkeet vastaanottavat signaalit muista neuroneista ja niitä voidaan pitää neuronin syötteenä. Kuvassa 2 tuojahaarakkeita ovat neuronin vasemmassa reunassa olevat lyhyemmät ulokkeet, jotka kiinnittyvät solukeskukseen. Aksoneja on neuroneissa vain yksi, mutta siinä on useampia haaroja. Aksoni kuljettaa signaalin solukeskuksesta muita neuroneita kohti, joten sitä voidaan pitää neuronin lähtösignaalina. Kuvassa 2 aksoni on solukeskuksesta lähtevä pidempi uloke. [1, 4]

Neuronien välinen kommunikointi tapahtuu neuronista toiseen kulkevien elektro-



Kuva 2: Biologinen neuroni koostuu tuojahaarakkeista (dendrite), solukeskuksesta (soma) sekä aksoneista (axon). Jännitepiikkien suunta on merkitty nuolilla. [5]

nisten pulssien avulla. Pulssien kulkusuunta neuronin rakenteessa on merkitty nuolilla kuvassa 2. Näitä pulsseja kutsutaan jännitepiikeiksi tai toimintajännitteeksi [4]. Toimintajännite on lyhytaikainen kalvojännitteen muutos negatiivisesta positiiviseen, jonka jälkeen kalvojännite palaa lepojännitteeseen [6]. Kalvojännitteen muutoksen aiheuttaa neuronin saapuva jännitepiikki. Jos muutos ei ole tarpeeksi suuri ylittämään kynnysjännitettä, eikä uusia jännitepiikkejä tule, jännite vuotaa pois ja kalvojännite palaa lepojännitteeseen. Kun kalvojännitteen muutos ylittää kynnysjännitteen, neuroni tuottaa jännitepiikin, joka kulkeutuu aksonia pitkin ja aktivoi synapsin. Synapsi vapauttaa välittäjäainetta, joka jälleen vaikuttaa seuraavan neuronin kalvojännitteeseen. [4] Jännitepiikin jälkeen kalvojännite palautuu alkuperäiseen arvoon. Tätä aikaa kutsutaan refraktaariajaksi ja sen aikana ei voi syntyä uutta toimintajännitettä [1].

### 3 Memristorit

Memristori on epälineaarinen ja kaksiterminaalinen komponentti, jonka Leon Chua esitteli vuonna 1971 [7] neljäntenä peruskomponenttina vastuksen, käämin ja kondensaattorin lisäksi. Se on määritetty varauksen ja käämivuon suhteen. Tietyllä ajanhetkellä memristori käyttäytyy vastuksen tavoin, mutta sen resistanssin arvo



riippuu siihen syötetyn virran tai jännitteen historiasta. [7]

Vuonna 1976 Chua esitteli memristiiviset systeemit yleistyksenä aikaisemmasta ideaalisesta memristorista [8]. Memristiivisten systeemien olennaisin piirre on niiden virta-jännite-kuvaajan hystereesikäyrä, joka kulkee aina origon kautta ja taajuuden kasvaessa kutistuu suoraksi [9]. Myös memristiivinen systeemi käyttäytyy kuin vastus, jonka resistanssia voidaan muuttaa jännitteen tai virran avulla. Yleisesti memristiivisistä systeemeistä käytetään nimitystä memristori.

Vaikka memristori on passiivinen komponentti, se voi olla paikallisesti aktiivinen. Paikallisesti aktiivinen memristori voidaan siis upottaa passiiviseen piiriin, joka vahvistaa siihen syötettävää signaalia [10]. Jos memristorilla on haihtuva muisti, sen resistanssin arvo palaa aina tiettyyn arvoon, kun säkövirta katkaistaan. Osalla memristoreista on kuitenkin haihtumaton muisti, jolloin memristorin resistanssi jää viimeisimpään arvoonsa. Esimerkiksi ideaalisilla memristoreilla on haihtumaton muisti [11].

## 4 Hodgkin-Huxley-malli

Hodgkin-Huxley-malli on ensimmäinen jännitepiikkeihin perustuva neuronimalli [1]. Se perustuu Alan Lloyd Hodgkinin ja Andrew Fielding Huxleyn mittauksiin, joista he julkaisivat sarjan artikkeleita [12–16] vuonna 1952 yhdessä Bernard Katzin kanssa. He mittasivat virran kulkua kalmarin aksonin solukalvon läpi, aksonin kalvojännitettä ja tarkastelivat ionien kulkeutumista neuronin sähköisissä reaktioissa. Kyseinen kalmarin aksoni sopi mittauksiin sen suuren koon ja kahden hallitsevan ionivirtauksen vuoksi. Tulosten pohjalta muodostettu Hodgkin-Huxley-malli kuvaa jännitepiikin muodostumista ja kulkeutumista neuronissa ionien avulla [15]. Hodgkin ja Huxley saivat tutkimuksestaan Nobelin lääketieteen tai fysiologian palkinnon vuonna 1963 yhdessä Sir John Carew Ecclen kanssa.

Vaikka Hodgkin-Huxley-malli on yksinkertaistus biologisen neuronin toiminnas-

ta, se on realistinen ja vastaa biologisen neuronin ominaisuuksia [4]. Etuna mallissa on myös sen monipuolisuus. Hodgkin-Huxley-mallilla pystyy toteuttamaan jopa 20 eri tyyppistä biologisen neuronin neurolaskennallista ominaisuutta, mikä on enemmän kuin muilla neuronimalleilla [17]. SNN:n simuloiminen sen avulla on kuitenkin hyvin monimutkaista [4].

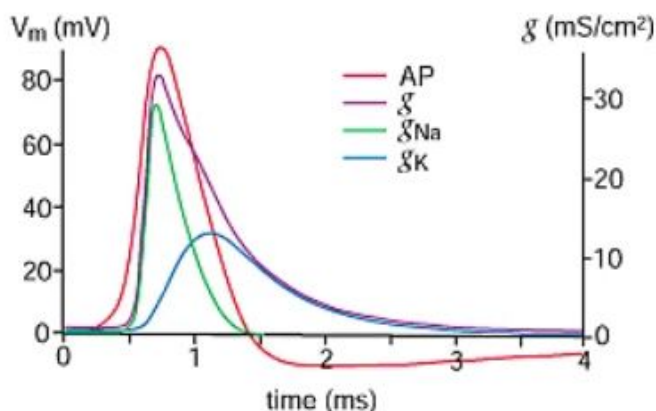
## 4.1 Hodgkin-Huxley-mallin matemaattinen esitys

Hodgkin ja Huxley päättelivät mittaustensa pohjalta, että toimintapotentiaali syntyy, kun  $\text{Na}^+$ -ionit virtaavat nopeasti aksoniin natriumkanavien kautta, jotka aukeavat kalvojännitteen kasvaessa. Natriumkanavien aktiivisuuden loppuessa kaliumkanavat aukeavat ja  $\text{K}^+$ -ioneja virtaa ulos aksonista, jolloin kalvojännite laskee jälleen ja toimintajännite loppuu. Kalvojännite laskee ensin hieman lepojännitteen alapuolelle eikä uutta toimintajännitettä voi syntyä ennen kuin natrium- ja kaliumionit ovat palautuneet alkuperäisille puolilleen solukalvoa ja kalvojännite on palautunut lepojännitteeseen. Tämä aika on neuronin refraktaariaika. [12–16]

Näihin havaintoihin pohjautuen Hodgkin-Huxley-malli kuvaa matemaattisesti aksonin toimintaa neljällä yksinkertaisella ensimmäisen kertaluvun differentiaaliyhtälöllä, joista ensimmäinen

$$I = C_m \frac{dV}{dt} + \bar{g}_K n^4 (V - V_K) + \bar{g}_{\text{Na}} m^3 h (V - V_{\text{Na}}) + \bar{g}_l (V - V_l) \quad (1)$$

kuvaa solukalvon läpi kulkevaa kokonaisvirtaa,  $I$ , ajan  $t$  sekä kalvojännitteen  $V$  funktiona, joka on solukalvon kapasitanssin  $C_m$  virran, kalium- ja natriumkanavien virran sekä vuotovirran (engl. leakage current) summa. Kolme viimeistä virtaa koostuvat kanavan kapasitanssista ja jännitteestä, joista  $V_K$  on kaliumin tasapainojännite,  $V_{\text{Na}}$  natriumin tasapainojännite ja  $V_l$  jännite, jolla vuotovirta on nolla. Kaliumkanavan konduktanssi koostuu vakiosta  $\bar{g}_K$  ja aksonin sisäpuolella olevien kaliumionien osuutta kuvaavasta yksiköttömästä muuttujasta  $n$ . Natriumkanavan konduktanssi koostuu vastaavasti vakiosta  $\bar{g}_{\text{Na}}$  sekä aktivoivien natriumionien osuudesta akso-



Kuva 3: Kalvojännitteen muutos ajan funktiona (AP) voidaan lukea vasemmalta akselilta. Oikeanpuoleiselta akselilta voidaan lukea ajan funktiona natrium- ja kaliumkonduktanssin muutos ( $g_{\text{Na}}$  ja  $g_{\text{K}}$ ) ja näiden summana muodostuva kokonaiskonduktanssin muutos ( $g$ ). [18]

nin sisäpuolella  $m$  ja ei-aktivoivien natriumionien osuudesta aksonin ulkopuolella  $h$ . Vuotovirran konduktanssi koostuu vain vakiosta  $\bar{g}_1$ . Kaikki jännitteet on mitattu suhteessa lepojännitteeseen. [15]

Kolme seuraavaa yhtälöä


$$\frac{dn}{dt} = \alpha_n (1 - n) - \beta_n n, \quad (2)$$

$$\frac{dm}{dt} = \alpha_m (1 - m) - \beta_m m, \quad (3)$$

$$\frac{dh}{dt} = \alpha_h (1 - h) - \beta_h h, \quad (4)$$

kuvaavat muuttujien  $n$ ,  $m$  ja  $h$  käyttäytymistä ajan ja kalvojännitteen funktiona. Ne voivat saada arvoja vain yhden ja nollan välillä. Kun ne vähennetään luvusta yksi, saadaan siis kyseisen ionin osuus aksonin vastakkaisella puolella. Parametrit  $\alpha_n$ ,  $\alpha_m$ ,  $\alpha_h$ ,  $\beta_n$ ,  $\beta_m$  ja  $\beta_h$  kuvaavat ionien liikettä sisään ja ulos aksonista. Ne on määritetty kokeellisten tulosten avulla ja riippuvat vain kalvojännitteestä. [15]

Yhtälöiden käyttäytyminen toimintapotentialin muodostuessa nähdään kuvassa 3. Kuvaajan vihreä käyrä, joka kuvaa natriumkonduktanssia, nousee alussa nopeasti



Kuva 4: a) Hodgkin-Huxley-mallin virtapiiri, joka kuvaa solukalvoa ja sen läpi ulkopuolen (outside) ja sisäpuolen (inside) välillä kulkevia sähkövirtoja. [15] b) Aksoni muodostuu punaisella neliöllä merkityistä Hodgkin-Huxley-soluista, jotka on yhdistetty vastuksilla. [19]

natriumionien virratessa aksonin sisään eli parametrin  $m$  kasvaessa ja  $h$  pienentyessä. Kaliumkonduktanssia kuvaava sininen käyrä nousee hitaammin kaliumionien virratessa ulos aksonista eli parametrin  $n$  kasvaessa. Violetti käyrä kuvaa näiden aiheuttamaa kokonaiskonduktanssin muutosta. Kalvojännite, jota kuvaa punainen käyrä, kasvaa ja laskee nopeasti konduktanssin muutosten mukana. Kuvaajassa nähdään myös refraktaariaika kalvojännitteen laskiessa ensin nollatason alapuolelle.

## 4.2 Virtapiiri

Hodgkin-Huxley-mallilla solukalvo voidaan esittää myös virtapiirinä kuten kuvassa 4a. Koko aksoni koostuu ketjusta näitä Hodgkin-Huxley-soluja, jotka on yhdistetty toisiinsa vastuksilla kuten kuvassa 4b [19]. Virrat  $I_{Na}$ ,  $I_K$  ja  $I_L$  kuvaavat kolmea solukalvon läpi kulkevaa virtaa eli natrium- ja kaliumionien kuljettamia virtoja sekä vuotovirtaa, joka koostuu esimerkiksi kloridi-ioneista. Nämä virrat koostuvat kul-


lekin ominaisesta vastuksesta sekä jännitelähteestä, joka kuvaa kyseisen kanavan tasapainojännitettä. Kondensaattorin kapasitanssi  $C_M$  kuvaa solukalvon kapasitanssia ja sen napojen välinen jännite  $E$  kuvaa kalvojännitettä eli jännite-eroa ulko- ja sisäpuolen välillä. [15]

Virtapiirin komponenttien konduktanssin, kapasitanssin ja jännitteen arvot on määritetty kokeellisten tulosten perusteella [6]. Komponenteista  $E_{Na}$ ,  $E_K$ ,  $E_l$ ,  $C_M$  sekä vastuksen  $R_l$  konduktanssin  $\bar{g}_l$  arvot ovat vakioita, eivätkä ne siis muutu ajan kuluessa. Vastusten  $R_{Na}$  ja  $R_K$  konduktanssit  $\bar{g}_{Na}$  ja  $\bar{g}_K$  kuitenkin muuttuvat kalvojännitteen funktiona sekä ajassa [15].

### 4.3 Memristiivinen Hodgkin-Huxley-malli

Vaikka kalmarin aksoniin perustuva Hodgkin-Huxley-malli jäljitteli hyvin neuronin toimintaa kuten toimintajännitteen muodostumista, siinä ilmeni kolme poikkeamaa, joita ei osattu selittää. Ensimmäinen poikkeama koskee ajassa muuttuvia konduktansseja, jotka kuvaavat neuronin ionikanavia. Kaikki ajassa muuttuvat parametrit täytyy piiriteorian mukaan pystyä esittämään eksplisiittisesti ajan funktiona. Hodgkin-Huxley-mallin konduktansseille tämä ei kuitenkaan ollut mahdollista, vaan niiden muutokset ajassa täytyi ratkaista numeerisesti epälineaaristen differentiaaliyhtälöiden avulla. [11]

Toinen poikkeama ilmeni aksonin piensignaalin mallin impedanssia ja admittanssia mitattaessa. Mittauksissa havaittiin todella suuria induktanssin arvoja tietyillä taajuuksilla ja tasavirran biasoinneilla. Virtapiirissä tämä tarkoittaisi hyvin suurta kelaa, joka myös aiheuttaisi suuren magneettikentän. Kolmas poikkeama ilmeni aksonin suursignaalin mallin jännite-virta-ominaisuuksia mitattaessa, jolloin havaittiin tulosten vastaavan diodin vastaavia ominaisuuksia. Poikkeamat kaksi ja kolme eivät täsmää kuvan 4 Hodgkin-Huxley-mallin kanssa, jossa ei esiinny kelaa eikä diodia. [11]



Kuva 5: a) Memristiivinen Hodgkin-Huxley-malli, jossa kalium- ja natriumkonduktanssit on korvattu memristoreilla. [10] b) Memristiivisen Hodgkin-Huxley-mallin piensignaalmalli. [11]

Leon Chua esitteli vuonna 2012 [19] poikkeamien ratkaisuksi memristiivisen Hodgkin-Huxley-mallin, joka on esitetty kuvassa 5a. Memristiivisessä mallissa ionikanavien ajassa muuttuvat konduktanssit on korvattu ajassa muuttumattomilla paikallisesti aktiivisilla memristoreilla [10, 19]. Natrium- ja kaliummemristorien paikallinen aktiivisuus mahdollistaa jännitepiikkien muodostumisen [10].

Memristorit ratkaisevat ensimmäisen poikkeaman, sillä ne eivät ole ajassa muuttuvia. Memristiivisen Hodgkin-Huxley-malli piensignaalmalli voidaan muodostaa korvaamalla natrium- ja kaliummemristorit niitä vastaavilla lineaarisilla komponenteilla kuten kuvassa 5b. Vastus  $G_T$  on summa memristorien ja niiden rinnalla olevan vastuksen resistansseista. Piensignaalmallin avulla saadaan johdettua admittanssi sekä induktanssi memristiiviselle aksonille. Määritetyt induktanssin arvot vastaavat mittauksissa havaittuja induktanssin arvoja. Memristorit aiheuttavat siis toisessa poikkeamassa ilmenevät suuret induktanssin arvot. Määrittämällä memristiivisen aksonin jännite-virta-kuvaaja voidaan todeta kolmannenkin poikkeaman toteutuvan memristorien avulla, sillä aksonin jännite-virta-kuvaaja vastaa diodin vastaavaa kuvaajaa. [11]

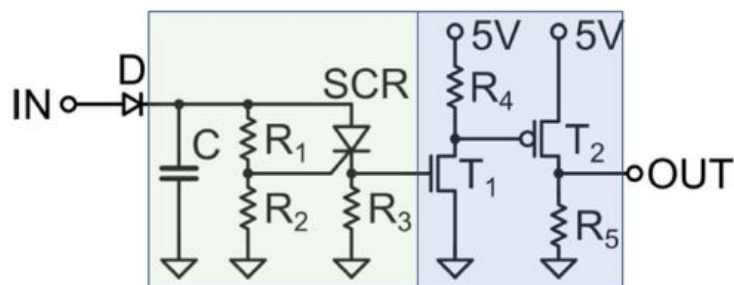
## 5 Leaky-integrate-and-fire-malli

Leaky-integrate-and-fire-mallin (LIF-malli) alkuperä on biologisessa ja matemaattisessa Lapiquen mallissa, jonka kehitti Luis Lapicque [20] vuonna 1907. Hänen malliaan on muokattu vuosien aikana esimerkiksi Hodgkin-Huxley-mallin pohjalta, jolloin siitä on muotoutunut integrate-and-fire-malli [6]. Integrate-and-fire-mallissa informaatio kulkeutuu lyhyinä jännitepiikkeinä, joihin informaatiota on tallennettu jännitepiikkien ajoituksen muodossa [6, 21]. Malli on helppo toteuttaa laskennallisesti ja sen ominaisuuksia voidaan myös mallintaa yksinkertaisen virtapiirin avulla, jossa tulevien jännitepiikkien varaus kerätään kondensaattorin avulla. Jos kondensaattorin kanssa rinnan kytketään vastus, saadaan aikaiseksi vuotovirta, joka vastaa biologisen neuronin toimintaa [6]. Vuotovirran sisältävää mallia kutsutaan LIF-malliksi ja se on enemmän käytetty kuin integrate-and-fire-malli [4].

### 5.1 Virtapiiri

Virtapiiri koostuu biologisen neuronin solukeskusta ja aksonia vastaavista osista. Kuvassa 6 solukeskus, joka vastaa jännitepiikin muodostamisesta, on merkitty vihreällä taustalla. Se koostuu kondensaattorista  $C$ , SCR-tyristorista (engl. silicon controlled rectifier) sekä kolmesta vastuksesta  $R_1$ ,  $R_2$  ja  $R_3$ . SCR-tyristori on epälineaarinen nelikerroksinen puolijohdekomponentti, joka käyttäytyy diodin kaltaisesti. Kynnysjännitteestä riippuvainen SCR-tyristorin hystereesi on olennainen neuronin toiminnassa. Sen ansiosta SCR-tyristori vaihtelee on- ja off-tilojen välillä jännitteen suuruuden mukaan. [3, 21]

Kuvassa 6 sinisellä taustalla merkitty osa vastaa aksonia, joka koostuu kahdesta MOS-transistorista  $T_1$  ja  $T_2$  sekä kahdesta vastuksesta  $R_4$  ja  $R_5$ . MOS-transistori on puolijohdekomponentti, jonka kaksi olennaista ominaisuutta ovat hilan jännitteen määräämä johtavuus ja kyky vahvistaa signaalia. MOS-transistorit sopivat käytettäväksi aksonissa, sillä aksonin tehtävänä on vahvistaa solukeskuksen synnyttämää



Kuva 6: Leaky-integrate-and-fire-mallin virtapiiri. Vasemmanpuoleinen vihreällä taustalla merkitty osa vastaa neuronin solukeskusta ja oikeanpuoleinen sinisellä taustalla merkitty vastaa aksonia. [3]

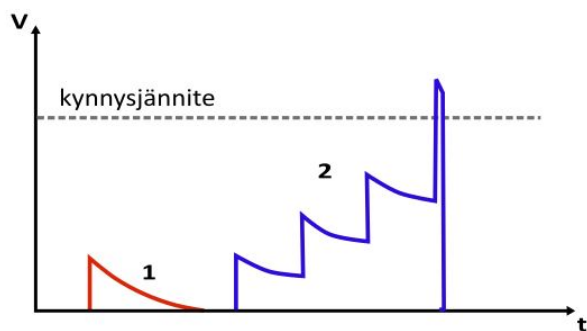
jännitepiikkiä ja kuljettaa sitä eteenpäin. Kuvan 6 vasempaan reunaan merkitty IN kuvaa neuroniiin tulevaa virtaa, joka on summa muista neuroneista tulevista signaaleista. [3, 21]

## 5.2 LIF-neuronien toiminta

Virtapiirin kondensaattori varastoi muista neuroneista tulevat jännitepiikit kalvojännitteeksi. Kondensaattori voi kuitenkin purkautua vastusten  $R_1$  ja  $R_2$  läpi neuroniiin tulevien jännitepiikkien välisenä aikana. Tämä nähdään myös kuvassa 7, jossa kuvaajan osassa 1 kalvojännite  $V$  ensin kasvaa ja tämän jälkeen laskee varauksen vuotaessa vastusten läpi. Kondensaattori siis vastaa mallin integroivasta (engl. integrate) ominaisuudesta sekä yhdessä vastusten  $R_1$  ja  $R_2$  kanssa mallin vuoto-ominaisuudesta (engl. leaky). [3, 21]

Kondensaattorin varastoima kalvojännite on myös anodin ja katodin välinen jännite SCR-tyristorissa. Kun kondensaattorin jännite ylittää kynnsjännitteen, SCR-tyristori aktivoituu ja kondensaattori pääsee purkautumaan SCR-tyristorin ja vastuksen  $R_3$  läpi, mikä vastaa jännitepiikin muodostumista neuronissa. Kuvaajan 7 osassa 2 kalvojännite ei ehdi vuotaa vastusten  $R_1$  ja  $R_2$  läpi ennen seuraavaa jänni-





Kuva 7: Kaaviokuva kalvojäännitteen  $V$  muutoksesta ajan funktiona vuotovirran tapauksessa 1 ja jännitepiikin muodostuessa 2.

tepiikkiä, jolloin kalvojännite kasvaa kynnysjännitettä suuremmaksi ja kondensaattori purkautuu SCR-tyristorin ja vastuksen  $R_3$  läpi. SCR-tyristori siis vastaa mallin liipaisuominaisuudesta (engl. fire). Se määrää myös kynnysjännitteen arvon, jota voidaan säädellä SCR-tyristorin hilan avulla. Kondensaattorin purkautumisen aikana SCR-tyristori pysyy on-tilassa, eikä uuden jännitepiikin syntyminen ole mahdollista. Tämä vastaa biologisen neuronin refraktaariaikaa. Purkauduttuaan kokonaan kondensaattori alkaa kuitenkin latautua uudestaan. [3, 21]

SCR-tyristorin ja vastuksen  $R_3$  läpi kulkenut virta vastaa neuronin tuottamaa jännitepiikkiä, joka kulkeutuu aksonia pitkin seuraavaa neuronია kohti. Jännitepiikkiä täytyy kuitenkin vahvistaa seuraavaa neuronია varten. Tämä voidaan toteuttaa MOS-transistorien avulla, jotka on asetettu yhteisen portin muodostelmaan (engl. common gate). [3, 21]

Neuronin solukalvoa, sen ominaisuuksia ja jännitepiikin muodostumista LIF-mallissa voidaan mallintaa myös matemaattisesti lineaarisella differentiaaliyhtälöllä

$$I(t) = \frac{V(t) - V_{\text{rest}}}{R} + C \frac{dV(t)}{dt}, \quad (5)$$

jossa  $C$  on kondensaattorin kapasitanssi,  $V(t)$  kalvojännite,  $V_{\text{rest}}$  lepojännite,  $I(t)$  muista neuroneista tuleva sähkövirta ja  $R$  resistanssi vastuksille, joista vuotovirta kulkee eli kuvassa 6 vastukset  $R_1$  ja  $R_2$ . [21]

LIF-mallin toimintaa ja ominaisuuksia on tarkasteltu [3] mittaamalla kalvojännitettä sekä tulo- ja lähtöjännitettä, kun virtapiiriin on syötetty jännitepiikkejä eri amplitudeilla. Kalvojännitettä voidaan mitata kondensaattorin varauksen ja kapasitanssin suhteena. Jotta kalvojännite ylittyy ja lähtöjännite havaitaan, tarvitaan jännitepiikki, jolla on tarpeeksi suuri amplitudi, tai jännitepiikkejä tarpeeksi suurella taaajuudella. Mitä suurempi amplitudi syöttöjännitteen jännitepiikeillä on, sitä suurempi taaajuus lähtöjännitteen jännitepiikeillä on. Tämä vastaa biologisten neuronien kykyä tallentaa informaatiota sen tuottamien jännitepiikkien taajuuteen. [3]

Toinen biologisten neuronien ominaisuus, joka LIF-mallilla voidaan toteuttaa, on sensorinen adaptaatio (engl. spike-frequency adaptation) eli neuronien tuottamien jännitepiikkien taaajuuden pieneneminen toistuvan tulojännitteen vaikutuksesta. Tätä ominaisuutta varten kuvan 6 virtapiiriin lisättiin diodista, kahdesta vastuksesta, kondensaattorista ja transistorista koostuva palautesilmukka, joka syöttää lähtöjännitteen takaisin SCR-tyristorin porttiin. Adaptiivinen käyttäytyminen toteutuu transistorin avulla. [3]

LIF-mallin neuroneja voidaan hyödyntää SNN:issä yhdistämällä niitä synapsien avulla. Synapseina voidaan esimerkiksi käyttää memristoreja. Kun kuvan 6 mukaisia neuroneja yhdistetään palautesilmukan sisältävien adaptiivisten neuronien kanssa, synapsin jälkeinen neuroni toimii synapsia edeltäneiden neuronien lähtöjännitesignaalien summan perusteella. [3]

### 5.3 LIF-mallin hyvät ja huonot puolet

Suurimpana etuna LIF-mallissa on sen yksinkertaisuus, sillä virtapiiri on rakennettu pienestä määrästä saatavilla olevia komponentteja. Virtapiirin yksinkertaisuuden ansiosta myös mallin ominaisuuksien tutkiminen ja muokkaaminen on helppoa. Esimerkiksi neuronin purkautumisaika on verrannollinen vastusten  $R_1$  ja  $R_2$  resistanssiin ja refraktaariaika on verrannollinen vastuksen  $R_3$  resistanssiin. Vastusten

resistanssia muokkaamalla voidaan siis muokata neuronille ominaisia aikoja. [3, 21]


SNN:n energiankulutus riippuu jännitepiikin energiasta ja jännitepiikkien tiheydestä [3, 4]. Ihmisen aivoissa on noin  $10^{11}$  neuronia ja niiden tehonkulutukseksi voidaan laskea noin 1 W. Vastaava tehonkulutus LIF-mallin neuroneilla saavutetaan  $10^7$  neuronilla. Tämänhetkisiin neuroverkkojen toteutuksiin verrattuna tämä tulos on kuitenkin lupaava [3]. Ihmisten aivoja vastaavan neuronien määrän saavuttamisen esteenä on esimerkiksi kondensaattorien koko [3, 21].

LIF-mallin pienen energiankulutuksen mahdollistaa SCR-tyristori, joka on suurimman osan ajasta off-tilassa. Tällöin siinä kulkevat virrat ovat merkittäviä vain, kun jännitepiikkejä muodostuu [3, 21]. Yksi mahdollisuus energiankulutuksen pienentämiseen on komponenttien pienentäminen. Esimerkiksi SCR-tyristori on mahdollista korvata Mott-materiaaleilla, sillä niiden virta-jännite-ominaisuudet vastaavat SCR-tyristorin ominaisuuksia [3, 21].

Neuronin tehokkuutta voidaan mitata myös kvalitatiivisesti tarkastelemalla, miten monipuolisesti neuroni reagoi ajasta riippuvaan syöttövirtaan tuottamalla jännitepiikkejä. LIF-mallilla on havaittu kolmea erilaista jännitepiikkien tuottamisen tyyppiä. Verrattuna Hodgkin-Huxley-malliin tämä on selkeästi pienempi määrä. [4]

## 6 Ristikkorakenne

Ristiksoon rakennettu topologia sopii neuroverkoille, sillä sen avulla saavutetaan hyvä komponenttitiheys ja ristikkorakenne voidaan valmistaa alla olevan piirin päälle, jolloin säästetään tilaa. Ristikkorakenteinen neuroverkko voidaan kytkeä tietokone-laitteistoon yhdistämällä tuloneuroni ylempään elektrodiin ja lähtöneuroni alempaan. Tämä rakenne näkyy kuvassa 8b. Kukin tuloneuroni on yksittäisesti yhdistetty kaikkiin lähtöneuroneihin siten, että kussakin liitoksessa on memristiivinen elementti. Tämä memristiivinen elementti muodostaa synapsin, joka säätelee neuronien välistä yhteyttä. Liitoksen rakenne on esitetty kuvassa 8a, jossa memristiivinen



Kuva 8: Neuroverkon ristikkorakenne. a) Neuroneita yhdistää memristiivinen synapsi. b) Ristikkomuodostelmassa tuloneuronit (pre-neurons) on yhdistetty ylempään elektrodiin ja lähtöneuronit (post-neurons) on yhdistetty alempaan elektrodiin. [23]

synapsi yhdistää ylempänä olevan tuloneuronin alempana olevaan lähtöneuroniin. [22]

Memristorit sopivat hyvin käytettäväksi synapseina, sillä ne pystyvät muuttamaan resistanssiaan jännitepiikkien vaikutuksesta. Myös idealisille memristoreille ominainen haihtumaton analoginen muisti on olennainen. Nämä ominaisuudet mahdollistavat oppimisen ja mukautumisen pohjana olevan synaptisen plastisiteetin eli synapsien kyvyn säädellä neuronien välisen yhteyden voimakkuutta neuronien aktiivisuuden mukaan. Ristikkorakenne mahdollistaa suuren määrän yhteyksiä, mikä myös edistää neuroverkon kykyä mukautua ja oppia. [1, 22]

Ongelmana ristikkorakenteessa ovat kuitenkin komponenttien erilaiset resistanssien arvot. Virta pyrkii kulkemaan kohdasta, jossa resistanssi on pienin. Kohdissa, joissa komponenttien resistanssi on suuri saattaa virta päästä vuotamaan, mikä johtaa virheellisiin tuloksiin. Mitä suurempi ristikko, sitä enemmän ongelmia tämä tuottaa. Ongelmat näkyvät myös selkeämmin, kun mitattavat resistanssin arvot ovat muutakin kuin diskreettejä. Ongelma voidaan mahdollisesti ratkaista estämällä virran kulku ei-toivottuihin suuntiin, konfiguraatiota muokkaamalla tai käyttämällä epälineaarista virtaa. [22]

## 7 Yhteenveto

Sopivan neuronimallin valinnassa täytyy ottaa huomioon monta asiaa, kuten energia-  
tehokkuus, laskentateho ja toteutusmahdollisuudet. Tässä tutkielmassa on esitelty  
kaksi neuronimallia, Hodgkin-Huxley-malli ja LIF-malli. Molemmissa malleissa on  
omat hyvät ja huonot puolensa. Hodgkin-Huxley-malli on realistinen ja monipuoli-  
nen, minkä ansiosta se mallintaa hyvin biologisten aivojen kykyä prosessoida suuria  
datamääriä. Se on kuitenkin monimutkainen, minkä vuoksi se voidaan simuloida,  
mutta sen toteuttaminen on haastavaa. LIF-mallin etuna on juuri sen yksinkertai-  
suus ja sen koostuminen pienestä määrästä saatavilla olevia komponentteja. Myös  
SCR-tyristorin mahdollistama energiatehokkuus tekee mallista hyvän vaihtoehdon.

Molempia malleja on kuitenkin mahdollista parantaa uuden tutkimuksen myötä.  
Hodgkin-Huxley-mallissa käytettäviä memristoreja ja niiden käyttöä neuroverkois-  
sa tutkitaan paljon. Memristoreja käytetään neuroneissa ja synapseina eli niiden  
merkitys neuroverkoissa on suuri ja niiden kehittyminen tarkoittaisi suuria edisty-  
saskelia neuromorfisessa laskennassa. LIF-mallissa energiankulutusta ja piirin kokoa  
on mahdollista pienentää uusia materiaaleja, kuten Mott-materiaaleja käyttämällä.

Neuroverkoilla on monia sovelluksia, kuten esimerkiksi hahmontunnistus, joissa  
ne pärjäävät paremmin kuin nykytietokoneet. Sen lisäksi ne voivat olla ratkaisu  
nykytietokoneiden laskentatehon kasvun hidastumiseen ja tarpeeseen käsitellä suuria  
datamääriä tehokkaasti. Tämän vuoksi kiinnostus neuroverkkoihin kasvaa koko ajan  
ja uskon niiden ja samalla neuronimallien kehittyvän tulevaisuudessa paljon.

## Viitteet

- [1] M. Shahsavari, P. Devienne ja P. Boulet, kirjassa *Handbook of Memristor Networks*, toimittanut L. Chua, G. C. Sirakoulis ja A. Adamatzky (Springer International Publishing, 2019), pp. 691–728.
- [2] C. D. Schuman, S. R. Kulkarni, M. Parsa, J. P. Mitchell, P. Date ja B. Kay, *Nature Computational Science* **2**, 10 (2022).
- [3] M. J. Rozenberg, O. Schneegans ja P. Stoliar, *Scientific Reports* **9**, 11123 (2019).
- [4] R. Holker ja S. Susan, *International Journal of Software Science and Computational Intelligence* **13**, 89 (2021).
- [5] H. Wang, N. C. Laurenciu, Y. Jiang ja S. D. Cotofana, kirjassa *2020 IEEE International Symposium on Circuits and Systems (ISCAS)* (IEEE, 2020), pp. 1–5.
- [6] A. Thomas ja C. Kaltschmidt, *Bio-inspired Neural Networks* (Springer Cham, 2014), pp. 151–172.
- [7] L. Chua, *IEEE Transactions on Circuit Theory* **18**, 507 (1971).
- [8] L. Chua ja Sung Mo Kang, *Proceedings of the IEEE* **64**, 209 (1976).
- [9] S. P. Adhikari, M. P. Sah, H. Kim ja L. O. Chua, *IEEE Transactions on Circuits and Systems I: Regular Papers* **60**, 3008 (2013).
- [10] M. P. Sah, Hyongsuk Kim ja L. O. Chua, *IEEE Circuits and Systems Magazine* **14**, 12 (2014).
- [11] L. Chua, *Nanotechnology* **24**, 383001 (2013).
- [12] A. L. Hodgkin ja A. F. Huxley, *The Journal of Physiology* **116**, 449 (1952).

- [13] A. L. Hodgkin ja A. F. Huxley, *The Journal of Physiology* **116**, 473 (1952).
- [14] A. L. Hodgkin ja A. F. Huxley, *The Journal of Physiology* **116**, 497 (1952).
- [15] A. L. Hodgkin ja A. F. Huxley, *The Journal of Physiology* **117**, 500 (1952).
- [16] A. L. Hodgkin, A. F. Huxley ja B. Katz, *The Journal of Physiology* **116**, 424 (1952).
- [17] E. Izhikevich, *IEEE Transactions on Neural Networks* **15**, 1063 (2004).
- [18] M. Häusser, *Nature Neuroscience* **3**, 1165 (2000).
- [19] L. Chua, V. Sbitnev ja H. Kim, *International Journal of Bifurcation and Chaos* **22**, 1230011 (2012).
- [20] L. Lapicque, *Journal de Physiologie et Pathologie General* **9**, 620 (1907).
- [21] J. Gupta, kirjassa *2020 International Conference on Recent Trends on Electronics, Information, Communication & Technology (RTEICT)* (IEEE, 2020), pp. 74–77.
- [22] P. Sheridan ja W. Lu, kirjassa *Memristor Networks*, toimittanut A. Adamatzky ja L. Chua (Springer International Publishing, 2014), pp. 129–149.
- [23] S. Jo, T. Chang, I. Ebong, B. Bhadviya, P. Mazumder ja W. Lu, *Nano letters* **10**, 1297 (2010).