

S-114.240 Laskennallisen tekniikan seminaari

Neurolaskennan sovellukset biologisten systemien mallinnuksessa

Matti Pöllä
EST
matti.polla@hut.fi
49897D
23.4.2004

Sisältö

1	Johdanto neuroverkkoihin	4
2	Neuroverkkojen ominaisuuksia	6
3	Neuroverkkomalli	7
3.1	Neuroni	7
3.2	Neuroverkko	8
3.3	Oppimismenetelmiä	9
4	Yleisiä sovelluksia	11
5	Biologiset neuroverkot	12
6	Biologisia mallinnuskohteita	14
6.1	Sukkulamadon hermoverkosto	14
6.2	Näköaisti	16

Kuvat

1	Mikroskooppikuva biologisesta hermoverkosta.	5
2	Multilayer perceptron -neuroverkko	5
3	Neuroni	7
4	Sigmoidifunktio.	9
5	Kolmesta neuronista koostuva neuroverkko.	9
6	Neuroverkko opetetaan opetusdatalla.	11
7	Opetettu neuroverkko tunnistaa käsinkirjoitetun merkin. . . .	11
8	Biologinen neuroni.	12
9	C.Elegans (sukkulamato).	14
10	Hermosolu RMED.	15
11	Todellisen ja simuloitun madon liikerata.	16
12	Heinäsiirran näkösensori.	17
13	Simuloinnissa käytetty tekstuuri.	17

Tiivistelmä

Neurolaskenta pyrkii mallintamaan eliöissä esiintyvien hermostorakenteiden tehokasta tiedonkäsittelyä. Luonnon neuroverkkojen tehokkuus perustuu suureen määrään toisiinsa kytkettyjä yksinkertaisia laskentayksiköitä, joiden avulla laskenta on rinnakkaistettu.

Neuroverkon perusyksikköä, neuroniam, mallinnetaan painotetulla summalla neuronien sisäänmenojen arvoista, joka on rajoitettu aktivaatiofunktion avulla. Käytettävä aktivaatiofunktio on tyypillisesti epälineaarinen, mikä johtaa neuroverkkojen suureen ja jakautuneeseen epälineaarisuuteen.

Neuronin matemaattinen malli on yksinkertaistus biologisen neuronin toiminnasta. Biologisen neuroverkon toimintaan vaikuttaa lisäksi neuronien erikoistuminen, hormonaalinen säätely ja kahden neuronin välisen synapsin toiminnan kemialliset yksityiskohdat.

Neurolaskennalla voidaan mallintaa biologisten hermostojen toimintaa. Yksinkertaisilla eliöillä, kuten sukkulamadolla, hermoston toiminta on hyvin tunnettu. Silti esim. ihmisaivojen toiminta ymmärretään toistaiseksi vielä hyvin rajallisesti.

1 Johdanto neuroverkkoihin

Ihmisen aivot ja tietokone voidaan molemmat ymmärtää tietokoneina, jotka ratkaisevat ongelmia syötetiedon avulla. Nämä tietokoneet ovat silti toteutustavaltaan toisistaan täysin poikkeavia, mikä selittää ihmisen aivojen ja tietokoneen erilaisen suorituskyvyn erilaisissa tilanteissa. Tietokoneelle 5×5 -matriisin kääntematriisiin laskeminen on hyvin helppo tehtävä, kun ihmiselle tehtävä on hyvin hidas ja virhealtis. Ihmiselle taas ei tuota ongelmia tunnistaa vieraan ihmisen puhetta häiriöisen puhelinlinjan yli. Tietokoneelle ongelma on huomattavan vaikea.

Ihmisaivojen kyky oppia ja suoriutua erinomaisesti hahmontunnistustehtävistä johtuu aivojen laskennan rinnakkaisuudesta. Neuraalilaskenta on tieteen ala, joka tutkii menetelmiä, joilla voidaan keinotekoisesti rakentaa ihmisaivojen toimintaa muistuttavia systeemejä.


Biologinen neuroverkko koostuu tyypillisesti miljoonista toisiinsa kytkevästä hermosoluista (kuva 1). Ihmisen oppiminen on pohjimmiltaan näiden neuronien välisten yhteyksien syntymistä, kuolemista ja yhteyksien vahvuuksien säätämistä sopiviin arvoihin.

Neurolaskennan menetelmiä käytetään tyypillisesti tilanteissa, joissa


- Käsiteltävä ongelma on niin monimutkainen, että yksinkertaista matemaattista mallia ei osata rakentaa.
- Saadulta tulokselta ei edellytetä täsmällisyyttä.
- Laskennan vaativuus ei ole este. Neuroverkkojen simulointi on laskennallisesti vaativaa.

Keinotekoiset neuroverkot ovat matemaattisena mallina siitä erikoisia, että mallin sisäistä toimintaa ei edes pyritä ymmärtämään täsmällisesti. Kun neuroverkon parametrit on valittu, sen toimintaan suhtaudutaan "mustana laatikkona".

Vaikka neuroverkkojen tutkimusta on tehty jo vuosikymmenien ajan, toteutettavat keinotekoiset neuroverkot ovat vielä mittasuhteiltaan ja monimutkaisuudeltaan kaukana biologisista neuroverkoista. Neuroverkkojen rooli biologisten ilmiöiden simuloinnissa on jatkossa yhä kiinnostavampi tutkimuksen ala, koska tietokoneiden laskentateho sallii yhä suurempien, enemmän biologisten esikuviansa kaltaisten, neuroverkkojen toteuttamisen.



Kuva 1: Nisäkkään aivokuoren neuroverkko (tussijäljennös mikroskooppiku-
vasta, Ramòn y Cajal, 1909).



Kuva 2: Multilayer perceptron -neuroverkko

2 Neuroverkkojen ominaisuuksia

Seuraavassa joitakin (keinotekoisille) neuroverkoille tyypillisiä ominaisuuksia, joiden vuoksi niitä käytetään nykyään hyvin monissa sovelluksissa. Lisättuna on myös joitakin neuroverkkoihin liittyviä ongelmia.

Sopeutumiskyky ja vikasietoisuus (+)

Neuroverkot sopivat hyvin tilanteisiin, jossa ratkaisulta ei vaadita täsmällisen oikeaa arvoa. Sen vastineeksi neuroverkot ovat äärimmäisen sopeutumiskykyisiä ja virhesietoisia. Sopeutumiskyky perustuu verkon parametrien dynaamiseen säätämiseen olosuhteiden muutoksien mukaisesti.

Epälineaarisuuden mallinnus (+)

Usein käsiteltävä tieto (esim. puhesignaali) sisältää suuren määrän epälineaarisuutta. Neuroverkko on malli, jossa epälineaarisuus on jakautunut koko verkon alueelle, mikä tekee neuroverkoista erityisen sopivan menetelmän epälineaarisen syötteen käsittelyyn.

Syöte-vaste -kuvaus (+)

Neuroverkolla voidaan toteuttaa mikä tahansa syöte-vaste -kuvaus. Usein käytössä on suuri määrä diskreettiä syöte-vaste -dataa, joka voidaan opettaa neuroverkolle. Onnistuneen opetuksen tuloksena neuroverkko tuottaa mieli-
valtaisen tarkan jatkuvan syöte-vaste -kuvauksen.

Laskennan raskaus (–)

Neuroverkot ovat luonnossa esiintyessään äärimmäisen tehokkaita ja nopeatoimisia, mutta sarjamuotoisella tietokoneella toteutettuna neuroverkko on laskennallisesti raskas toteuttaa. Tämän vuoksi neuroverkkoja ei juuri käytetä tietokoneympäristöissä, joissa laskentateho on pieni.

Bias-varianssi-ongelma (–)

Keinotekoisella neuroverkolla pystytään toteuttamaan mikä tahansa funktion approksimaatio. Approksimaatiosta voi silti helposti tulla huonolaatuinen yli- tai alisovittumisen seurauksena. Neuroverkon suunnittelussa ja opettamisessa on siis oltava erityisen huolellinen. Usein tehtävää vaikeuttaa se, että ei voida tietää kuinka paljon sovitettava data sisältää kohinaa.


3 Neuroverkkomalli

Biologisia hermoverkkoja tutkimalla on huomattu, että hermosoluilla on mm. seuraavia ominaisuuksia:

- Eliöt sisältävät hyvin suuren määrän rinnan kytkettyjä hermosoluja.
- Hermosoluilla on suuri määrä yhteyksiä toisiinsa.
- Hermosto on kykenevä oppimaan uusia toimintoja muuttamalla neuronien välisiä yhteyksiä.
- Hermosolujen välisien yhteyksien voimakkuus on rajoitettu.

Vaikka todellisen hermoverkoston toiminnan kokonaisvaltainen ymmärtäminen vaatisi laajaa biologian, kemian ja neurotieteen osaamista, voidaan jo nämä ominaisuudet huomioon ottamalla rakentaa yksinkertainen matemaattinen malli hermoverkolle. Seuraavassa käsitellään lyhyesti yksittäisen neuronin matemaattinen malli. Mallin yksinkertaisuudesta huolimatta jo tämä malli on riittävä monimutkaistenkin hahmontunnistustehtävien suorittamiseen. Biologisten neuroverkkojen simulaatioissa käytetyt mallit ovat usein toteutukseltaan monimutkaisempia ja tietyn tehtävän suorittamiseen erikoistuneita.

3.1 Neuron



Kuva 3: Neuron

Neuroverkon perusyksikkö on neuron (kuva 3).

Neuronin j toiminta jakautuu lineaariseen ja epälineaariseen osaan. Lineaarissa osassa lasketaan painokertoimilla w_{ij} painotettu summan syötearvoista x_i .

$$v_j = \sum_i w_{ij}x_i \quad (1)$$

Kun yhtälöön (1) lisätään kuvassa 3 näkyvä biassyöte, saa yhtälö muodon

$$v_j = \sum_i w_{ij}x_i + w_{0j}b_j, \quad (2)$$

missä b_j on neuronin j biassyöte ja w_{0j} siihen liittyvä painokerroin.

Neuronin epälineaarisuus syntyy aktivaatiofunktioista, joka rajoittaa neuronin ulostulon rajatulle alueelle

$$y_j = \varphi_j(v_j) \quad (3)$$

Aktivaatiofunktio sisältää tyypillisesti lineaarisen osan ja epälineaarisen osan (kuva 4). Lineaarinen osuus sallii verkon sisääntulojen ja niihin liittyvien painokertoimien muuttumisen näkymisen neuronin ulostulossa. Aktivaatiofunktion saturoituminen suurilla v_j :n arvoilla pitää huolen siitä, että yksittäisen neuronin vaikutus koko neuroverkon toimintaan pysyy rajoitettuna.

Tyypillisiä aktivaatiofunktioita ovat esim.

$$\varphi(v) = \frac{1}{1 + e^{-ax}} \quad (4)$$

ja

$$\varphi(v) = \tanh(av). \quad (5)$$


Yhtälöissä (4) ja (5) kertoimella a voidaan muokata funktion jyrkkyyttä (kuva 4). Joissakin tapauksissa askelfunktion

$$\varphi(v) = \begin{cases} 1 & \text{kun } v \geq 0 \\ 0 & \text{kun } v < 0 \end{cases} \quad (6)$$

käyttäminen aktivaatiofunktiona on järkevää.

3.2 Neuroverkko


Neuroverkot ovat kokonaisuuksia, jotka muodostuvat edellä kuvatuista neuroneista, niiden rinnan- ja sarjaankytkennöistä, mahdollisista takaisinkytkennöistä jne. Joissakin tapauksissa neuroverkko saattaa lisäksi sisältää ylimääräisiä kytkentöjä ja viivelohkoja.



Kuva 4: Sigmoidifunktio $\frac{1}{1+e^{-ax}}$ arvoilla $a = 0.1 \dots 1$.

Koska erilaiset neuroverkkotopologiat ovat oma laaja alueensa, rajoitetaan tarkastelu tässä tapauksessa yhden yksinkertaisen neuroverkon matemaattiseen syöte-vaste-yhteyden tutkimiseen.

Esimerkkineuroverkko (kuva 5) koostuu kolmesta neuronista i , j ja k . Verkolla on kaksi sisääntuloa, x_1 ja x_2 , ja yksi ulostulo.



Kuva 5: Kolmesta neuronista koostuva neuroverkko.

Käyttämällä kaavoja (2) ja (3) voidaan johtaa yhtälö koko neuroverkon ulostulolle.

$$y_k = \varphi_k(v_k) = \varphi_k\{\varphi_i(x_1w_{i1} + x_2w_{i2} + b_iw_{i0})w_{kj} + \varphi_j(x_1w_{j1} + x_2w_{j2} + b_jw_{j0})w_{kj} + b_kw_{k0}\} \quad (7)$$

3.3 Oppimismenetelmiä

Neuroverkon kyky ratkaista ongelmia perustuu oppimiseen. Oppimisen menetelmiä on monia ja joskus niitä käytetään toisiinsa yhdistettyinä.

Oppimismenetelmät voidaan jakaa karkeasti neuroverkon oppimiseen käytetyn onnistumisinformaation lähteen perusteella. Käsinkirjoitettujen merkien tunnistamisen tapauksessa on kyseessä oppiminen opettajan avustuk-

sella. Jokaiselle opetusvektorille on määrätty oikea lopputulos ja neuroverkko oppii saamalla palautetta “opettajalta”.

Esimerkki oppimisesta ilman opettajaa on itseorganisoituva kartta (*Self-Organizin Map*), jossa neuroverkon painokertoimet w_{ij} konvergoituvat ilman ulkopuolisen opettajan vaikutusta. Termillä *reinforcement learning* tarkoitetaan menetelmää, jossa neuroverkko saa palautetta ulkopuoliselta asijantuntijalta, mutta ilman suoraa opetusta.


Oppimismenetelmiä voidaan lajitella tarkemmin käytetyn opetusmetodin perusteella. Oppimismenetelmiä ovat mm.

- Virheenkorjaus-oppiminen (*error-correction learning*), jossa kullakin ajankohdalla n neuroverkon tuottamaa tulosta $y_k(n)$ verrataan tavoitetulokseen $d_k(n)$ ja verkon painokertoimia muutetaan tehdyn virheen $e_k(n) = d_k(n) - y_k(n)$ perusteella.
- Muistiin perustuva oppiminen (*memory-based learning*), jossa neuroverkon opettamista varten on olemassa datajoukko halutuista syöte-vaste-pareista.
- Hebbin oppiminen (*Hebbian learning*), jossa kahden yhtä aikaa aktiivisen neuronin välistä yhteyttä kasvatetaan ja eri aikaan aktivoituvien neuronien välistä yhteyttä heikennetään.
- Kilpailuun perustuva oppiminen (*competitive learning*), jossa neuronit kilpailevat keskenään aktiivisen tilan saavuttamisesta.
- Boltzmann-oppiminen (*Boltzmann learning*), jossa oppiminen tapahtuu termiseen tasapainoon hakeutuvan stokastisen algoritmin avulla.


4 Yleisiä sovelluksia

Yleisin käyttö neuroverkoille on data-analyysi ja hahmontunnistus. Tyypillisesti käytössä on suuri määrä moniulotteista dataa ja vain hyvin vähän tietoa ilmiöstä, joka datan on tuottanut. Tällöin neuroverkko voidaan opettaa olemassa olevalla data-aineistolla tuottamaan syöte-vaste -kuvaus, jonka avulla on mahdollista ennustaa systeemin käyttäytymistä myös tilanteissa, joista ei dataa ole saatavilla.

Esimerkki tällaisesta data-analyysistä on käsinkirjoitettujen merkkien tunnistaminen, jossa verkko opetetaan esittämällä verkolle suuri määrä kuvia käsinkirjoitetuista merkeistä ja kutakin merkkiä vastaava symboli. Opetusvaiheessa (kuva 6) neuroverkon painokertoimia muokataan siten, että annetulle syötteelle saadaan oikeanlainen vaste ja opetuksen jälkeen verkko pystyy tunnistamaan hyvällä tarkkuudella esitettyjä hahmoja (kuva 7).



Kuva 6: Neuroverkko opetetaan opetusdatalla.



Kuva 7: Opetettu neuroverkko tunnistaa käsinkirjoitetun merkin.

Data-analyysin ohella neuroverkoilla voidaan mm. mallintaa erilaisia systeemejä. Tässä tapauksessa keskitytään nimenomaan biologisten systeemien mallintamiseen keinotekoisien neuroverkkojen avulla.

5 Biologiset neuroverkot

Edellä esitetty neuronimalli on yksinkertaistettu malli biologisen neuronin toiminnasta. Se pyrkii ottamaan huomioon biologisen neuronin tärkeimmät ominaisuudet, kuten epälineaarisuus ja neuronien välisten yhteyksien painotus. Myöhemmin tullaan näkemään, että myös matemaattisella neuronilla voidaan simuloida yksinkertaisia biologisia systeemejä. Biologinen neuroni sisältää kuitenkin ominaisuuksia, joita epälineaarisesti rajoitettuun painotettuun summaukseen perustuva malli ei yksin pysty mallintamaan. Näitä ominaisuuksia ovat mm.

- Kahden neuronin välisen yhteyden, synapsin, toiminta on todellisuudessa monimutkainen kemiallinen reaktio. Biologisen neuronin mallin tulee ottaa huomioon välittäjäaineisiin liittyvä kemia.
- Neuroverkkomallissa neuronit ovat usein keskenään samanlaisia, mutta biologisissa neuroverkoissa neuronit ovat usein hyvin erikoistuneita tietyn toiminnon suorittamiseen.
- Hormonitoiminta on koko hermoston laajuinen säätelymekanismi, jota yksinkertainen neuronimalli ei ota huomioon.



Kuva 8: Biologinen neuroni. (Kuva: University of Maryland, Baltimore)

Koska biologisen neuroverkon toiminta on hyvin laaja aihe, tässä tapauksessa rajoitutaan käsittelemään joitakin tärkeimpiä eroja biologisten ja keinoitekoisten neuroverkkojen välillä.

Synapsin toiminta

Biologisessa hermostossa hermoimpulssit liikkuvat neuronin yli sähköisessä muodossa ja neuronien välisen rajapinnan, synapsin, kemiallisessa muodossa. Keinotekoisien neuronien painokertoimet w_{ij} mallintavat siis synaptisten yhteyksien voimakkuuksia hermosolujen välillä.

Neuronin sigmoidifunktiolle voidaan tähän liittyen antaa intuitiivinen tulkinta; synapsi pystyy välittämään vain tietyn suuruisen signaalin. Jos synapsin ylittävän signaalin voimakkuus on synapsille liian suuri, synapsin ylittävän signaalin amplitudi leikkautuu.

Neuronin toiminnan nopeus ja tehonkulutus

Modernien tietokoneiden tehot ovat viime vuosikymmeninä kasvaneet rajusti, mutta ihmisen aivot ovat pysyneet vuosituhansia lähes ennallaan. Siksi on mielenkiintoista vertailla biologisen neuronin ja modernin transistorin ominaisuuksia.

On ehkä yllättävää huomata, että tietokoneen laskentayksiköt ovat ihmisaivojen neuroneja huomattavasti nopeampia toiminnassaan. Modernit lojiikkaportit toimivat nanosekuntien (10^{-9} s) mittakaavassa kun ihmisaivojen neuronien nopeus lasketaan millisekunneissa (10^{-3} s). Ihmisaivojen ylivoimainen tiedonkäsittelykyky perustuukin nopeuden sijasta neuronien massiiviseen rinnankytkentään ja neuronien välisten yhteyksien suureen määrään.

Tehonkulutuksessa ihmisaivot ovat myös omaa luokkaansa. Kun tietokone käyttää energiaa yhteen operaatioon sekunnissa n. 10^{-6} J ihmiselle vastaava lukema on luokkaa 10^{-16} J.

Verkon koko

Merkittävin ero tyypillisen biologisen neuroverkon ja simuloidun neuroverkon välillä on verkon koko, eli neuroverkon sisältämien neuronien määrä. Tyypillisessä hahmontunnistustehtävässä neuronien määrä voi vaihdella yhdestä muutamiin kymmeneen. Joissakin tapauksissa voidaan käyttää neuroverkkoja, joiden koko ylittää sukkulamadon 302 neuronin määrän, mutta ihmisen neuronien määrästä jäädään vielä kauas - niitä on yli kymmenen miljardia.

6 Biologia mallinnuskohteita

Neuroverkoilla tapahtuva biologisten ilmiöiden mallintaminen on hyvin laaja tutkimuksen ala. Valtaosa tutkimuksesta keskittyy biologisten neuroverkkojen imitoimiseen keinotekoisilla malleilla. Mallit ovat tyypillisesti tiettyyn tarkoitukseen kehitettyjä ja pitkälle erikoistuneita ja poikkeavat siis tässä mielessä tavanomaisissa hahmontunnistus- ja data-analyysitehtävissä käytetyistä neuroverkoista.

Seuraavassa tarkastellaan sukkulamadon nermoston toimintaa ja näköaistia neuroverkkomallinnuksen kannalta.

6.1 Sukkulamadon hermoverkosto




Kuva 9: *C.Elegans* (sukkulamato). (Kuva: Max Planck Institute of Neurobiology)

Sukkulamato (*C.elegans*) on yksi biologian alan tutkituimmista eliöistä. Se on vain n. 1,5 millimetrin pituinen maaperässä elävä *phylum Nematoda*-sukuun kuuluva mato. Mielenkiintoista tutkimuksen kannalta sukkulamadossa on se, että sen rakenne on hyvin yksinkertainen. Sukkulamadon läpinäkyvä rakenne mahdollistaa myös sen kuvaamisen mikroskoopilla elävänä (kuva 9).

Sukkulamato koostuu vain 959 solusta, joista neuroneita on 302. Synapseja neuronien välillä on yhteensä n. 5600 kappaletta. Eliön solurakenteen yksinkertaisuudesta saa hyvän kuvan kun ajattelee, että yksi millilitra ihmisen verta sisältää n. 5 miljoonaa punasolua. Äärimmäisen yksinkertaisen rakenteen ansiosta sukkulamadon rakenne tunnetaan hyvin. Yksinkertainen rakenne on tutkimuksen kannalta erityisen hyödyllinen siksi, että matoyksilöiden solurakenteet ovat keskenään lähes identtiset. Tämän vuoksi kokeiden

toistaminen on mahdollista ja mutaatioiden vaikutus eliön solurakenteeseen ja sen toimintaan on helposti havaittavissa.

Erityisesti sukkulamadon hermoverkoston toiminta ymmärretään jo neuronitasolla ja kaikki sukkulamadon neuronit voidaan jakaa sensorisiin, välittäviin ja motorisiin neuroneihin. Lisäksi sukkulamadon koko hermoverkon konnektiivisuus (neronien väliset yhteydet) on tiedossa.

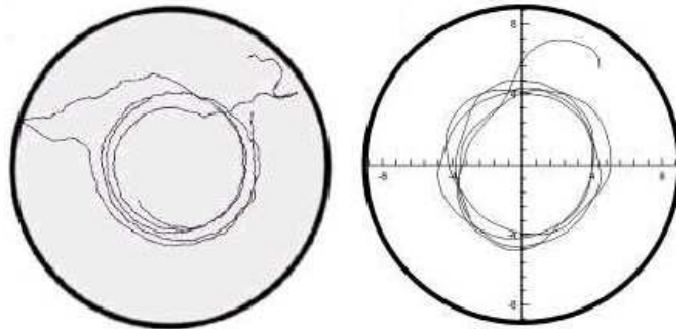


Kuva 10: Hermosolu RMED on sukkulamadon päässä sijaitseva motorinen neuron. (Kuva: <http://www.wormatlas.org/>)

Sukkulamadon hermoverkoston toimintaa on simuloitu kokeessa, joka on erityisen mielenkiintoinen keinotekoisien ja luonnollisten neuroverkkojen eroja ja yhtäläisyyksiä tarkasteltaessa. Kuten edellä todettiin, epälineaarisesti rajoitettuun painotettuun summaukseen perustuva neuronimalli ei vielä riitä kuvaamaan kaikkia biologisen neuronin ominaisuuksia. Siitäkin huolimatta keinotekoisella neuroverkolla on mahdollista mallintaa sukkulamadon kaltaista yksinkertaista biologista hermoverkkoa hämmästyttävän onnistuneesti.

Kuvassa 11 vasemmalla on kuvattu sukkulamadon kulkema liikerata ympyrän muotoisessa ympäristössä, jossa alueen keskellä lämpötila on reunoja korkeampi. Sukkulamadon sensoriset neuronit tekevät havaintoja ympäristön lämpötilasta ja yksinkertaisen käsittelyn jälkeen hermoverkko ohjaa madon lihaksia liikkumaan kohti aluetta, jossa lämpötila on madolle sopiva. Kuvan tapauksessa mato etsii aluksi sopivaa lämpötilaa ja alkaa sen jälkeen kiertää ympyrää kohdalla, jossa lämpötila on sopiva.

Sukkulamadon liikkumista ohjaavaa hermostoa mallinnettiin keinotekoisella neuroverkolla, joka ei pyri mallintamaan täsmällisesti madon neuronien biologista käyttäytymistä. Mallintamiseen käytettiin tavallista MLP-verkkoa (kuva 2), jonka syötteenä oli madon hetkellä t havaitsema lämpötila ja lämpötila muutamana edeltävänä ajanhetkenä $t-1, t-2 \dots$. Kuvan 11 oikeanpuoleisesta osasta näkyy, kuinka simuloidun madon liike muistuttaa hyvin paljon todellisen madon liikkeitä. Tämä osoittaa, että riittävän yksinkertaisissa tapauksissa myös biologisesti epätäsmällinen neuroverkkomalli voi mallintaa biologisia järjestelmiä hyvin.



Kuva 11: Sopivanlämpöistä ympäristöä etsivän todellisen (vasemmalla) ja simuloitun (oikealla) sukkulamadon liikerata. (Kuva: Cory C. Coleman, University of Oregon)

6.2 Näköaisti


Näköaisti on yksi mielenkiintoisimmista tutkimuksen kohteista biologisten neuroverkkojen alueella. Sukkulamatoon verrattuna näköaisti on huomattavasti monimutkaisempi systeemi ja sen toimintaa ei tunneta yhtä hyvin. Yksi keskeisimmistä kysymyksistä on selvittää, kuinka aivojen näkökeskus käsittelee verkkokalvoilta saamansa visuaalisen informaation.

Näköaistin toiminnan tutkiminen on sovelluksien kannalta erityisen mielenkiintoinen, koska konenäköjärjestelmien kehitys hyötyy suuresti biologisen näköaistin tutkimuksesta.


Heinäsirkan näköaisti

Heinäsirkan näköaistia on mallinnettu neuroverkkomallin avulla käyttämällä syötteenä heinäsirkan kymmenistä yksittäisistä näkösensoreista koostuvaa näkösensoria (kuva 12). Tavoitteena on esittää näkösensorille liikkuvaa kuvaa siten, että neuroverkkomalli osaa tunnistaa lähestyvät objektit ja reagoida havaintoon väistäen törmäyksen.

Kokeissa mallinnetulle näkösensorille annettiin stimuluksena erikokoisia hahmoja sisältäviä kuvia (kuva 13). Neuroverkkomallin sisäänmenona käytettiin yksittäisten näköelinten (kuva 12) havaitsemaa informaatiota. Simulaatiossa onnistuttiin saamaan simuloitu näköaistijärjestelmä reagoimaan lähestyviin kohteisiin.



Kuva 12: Heinäsirkan näkösensori. (Kuva: University of Newcastle)



Kuva 13: Heinäsirkan näköaistin simuloinnissa käytetty tekstuuri (Kuva: University of Newcastle)

Viitteet

- [1] Course: Neural networks and biological modeling. Lausannen yliopiston kurssi aiheesta.
http://diwww.epfl.ch/w3mantra/mantra_cours_ph.html.
- [2] A neural network model of the locust lgmd capable of resolving natural images. Heinäsirkan näköaistin simulointia neuroverkoilla.
<http://www.ncl.ac.uk/biol/research/psychology/nsg/insectvision/neuralnetwork.html>.
- [3] Neuronc neural simulation language. Biologisten neuronien simulointiin kehitetty ohjelmointiympäristö.
<http://retina.anatomy.upenn.edu/~rob/neuronc.html>.
- [4] Simulation of neural nets. Artikkelin biologisen neuroverkon simuloinnista.
<http://www.virtualschool.edu/cox/pub/70DECUSNeuralNets/>.
- [5] Wormatlas. Sisältää valtavasti tietoa *C.elegans*-madosta.
<http://www.wormatlas.org/>.
- [6] Xnbc - a software package to simulate biological neural networks for research and education. .
<http://www.b3e.jussieu.fr/xnbc/>.
- [7] C. M. Bishop. *Neural Networks for Pattern Recognition*. Oxford University Press, 1995.
- [8] W. Gerstner and W. M. Kistler. *Spiking Neuron Models*. Cambridge University Press, 2002.
- [9] S. Haykin. *Neural Networks - A Comprehensive Foundation*. Prentice Hall, second edition, 1998.