Kielen ja kognition suhde (toim. A-M. Korpijaakko-Huuhka, S. Pekkala & H. Heimo). Puheen ja kielen tutkimuksen yhdistys ry:n julkaisuja 37, 2005:

MITEN HERMOVERKKOMALLIT SELITTÄVÄT KIELEN OPPIMISTA?

Krista Lagus
Teknillinen korkeakoulu
Neuroverkkojen tutkimusyksikkö

Mielen malli: modulaarinen tietokonearkkitehtuuri vai hajautetut neuroverkot

Keinotekoiset neuroverkot ovat menetelmiä, jotka ovat saaneet inspiraationsa aivojen hermoverkoista. Neuroverkko koostuu tyypillisesti joukosta yksinkertaisia prosessointielementtejä, neuroneita, sekä näiden välisistä kytkennöistä. Neuroverkkomallinnukseen perustuva näkemys kognitiosta ylipäänsä, kielikyky mukaanlukien, korostaa staattisten mallien sijaan oppimisen merkitystä sekä modulaarisen ja sekventiaalisen sijaan yhtäaikaisesti eri puolilla aivoja tapahtuvaa hajautettua tiedon käsittelyä (lisää aiheesta esim. Rumelhart ja McClelland 1986a ja b). Viime vuosikymmeninä tehdyn neuropsykologisen ja aivokuvantamiseen perustuvan tutkimuksen ansiosta tiedetään, että moneen aivoprosessiin osallistuu useita hajautetusti aivoissa sijaitsevia neuraalisia alueita, jotka voivat aktivoitua sekä yhtä aikaa että peräkkäin (Churchland ja Sejnowsky 1992). Yksittäisen homogeenisesti kytketyn neuroverkon ja siinä tapahtuvan oppimisen voitaisiin katsoa mallintavan esimerkiksi yksittäistä neuraalista aivoaluetta. Laajemman ja monimutkaisemman kokonaisongelman ratkaisemiseen (esim. puheen ymmärtäminen) tarvittaisiin tyypillisesti useita toisiinsa kytkettyjä neuroverkkoja, joista osa voi keskittyä vaikkapa piirreanalyysiin.

Keinotekoisten neuroverkkojen tutkimuksen pioneereja 1970- ja 1980-luvuilla oli mm. Teuvo Kohonen, joka 1978 julkaisi kirjan assosiatiivisesta muistista ja 1981 ensimmäisen artikkelin, joka koski itseorganisoivan kartan (SOM) periaatetta (kuvattu laajemmin kirjassa Kohonen 2001). Käänne alalla tapahtui 1980-luvun alkupuolella, Rumelhartin ja McClellandin julkaistua PDP-kirjansa, joiden aiheena oli laajasti kognition mallinnus neuroverkoilla. He mm. osoittivat, että ohjattua

oppimista toteuttava neuroverkko nimeltä monikerrosverkko (multi-layer perceptron, MLP) kykenee oppimaan esimerkeistä englannin verbien taivutukset menneeseen aikamuotoon ja että verkko näin oppiessaan käy läpi samanlaiset oppimisen ja virhetyyppien vaiheet kuin kieltä oppiva lapsi. Verkko käy mm. läpi yliyleistämisen vaiheen, jossa säännöllistä muotoa kuvaavaa ”sääntöä” yritetään soveltaa virheellisesti myös epäsäännöllisesti taipuviin verbeihin sekä generatiivisesti täysin ennennäkemättömiin verbeihin (Rumelhart ja McClelland 1986b). Neuroverkoissa ”säännöt” kuvautuvat implisiittisesti: säännönkaltainen toiminta seuraa yhteisvaikutuksena neuronien välisisten kytkentöjen painoista.

Se, missä määrin mieli toteutuu modulaarisesti, on useita aloja kiinnostava ja ajankohtainen kysymys. Ajatus modulaarisesta mielestä lienee houkutteleva tehokkuuden näkökulmasta: jos jonkin tehtävän voi jakaa itsenäisesti ratkeaviin osaongelmiin, tehtävän ratkaisun vaatima laskennallinen kompleksisuus vähenee merkittävästi. Kielikyvyn osalta tiukasti modulaarisen prosessoinnin kuuluisin puolestapuhuja lienee Noam Chomsky, joka esitti, että kielikyky toteutuu erillisen kieleen keskittyneen osasysteemin kautta. Näkemys korostaa synnynnäistä, staattista kykyä ja nojaa väittämään, että kieli on niin monimutkainen ja informaatiota sitä koskien on niin vähän, että sitä ei voida oppia. Tässä näkemyksessä oletetaan lisäksi, että syntaktinen ja semanttinen prosessointi voidaan eristää toisistaan. Näkökulmaa on kritisoitu laajasti eri tieteenalojen näkökulmista, mm. konnektionismin (Elman 2001) ja kognitiivisen kielitieteen piiristä (ks. esim. Itkonen 2004). Kuitenkin ”modulaarisuudella” on monta variaatiota (ks. esim. Lappi 2004), ja eri tieteenalojen välinen keskustelu aiheesta voi helposti johtaa väärinymmärryksiin.

Nykyisin aiheesta käydään debattia mm. ”herätteen köyhyys” -näkökulman (Poverty of Stimulus) ja oppivien menetelmien kannattajien välillä. Edellisen näkökulman vahvimpia puolestapuhujia ovat Jerry Fodor ja Steven Pinker. He korostavat kielikyvyn synnynnäisyyttä samoin perustein kuin Chomsky (ks. yllä; ks. myös Brattico 2004). Jälkimmäisen, oppivan näkökulman puolestapuhujia taas löytyy konnektionismin piiristä. Heitä ovat mm. Elman (2001) sekä Miikkulainen (ks. esim. 1993), joka on mallintanut neuroverkoilla kielen lisäksi useita muitakin kognition osa-alueita.

Usein myös konnektionistinen (”alisymbolinen”) ja symbolinen paradigma nähdään vastakkaisina, kilpailevina selitysmalleina symbolisen mallin keskittyessä pohtimaan erityisesti tietoista päättelyä. Toisaalta jo varhain on myös esitetty, että symbolinen ja neuroverkkoparadigma eivät olisi toisiaan korvaavia vaan pikemminkin toisiaan täydentäviä kuvauksen tasoja. Näistä neuroverkot keskittyisivät ns. alisymboliseen mallinnukseen

selittäen yksityiskohtaisesti mm. sen, miten käsitteet muuttuvat. Tätä näkemystä edustaa mm. Gärdenfors (2000), joka esittää eksplisiittisesti, miten neuraalinen representaation taso, käsitteiden taso ja symbolinen taso voisivat kytkeytyä yhteen. Hän pitää itseorganisoivaa karttaa eräänä mahdollisena käsitetason mallina.

Itseorganisoiva kartta

Itseorganisoiva kartta (self-organizing map, SOM) (Kohonen 2001) on neuroverkkomenetelmä jossa oppiminen tapahtuu ohjaamattomasti, ts. ilman opettajaa tai tietoa siitä, mitä verkon olisi opittava. Kartta koostuu joukosta soluja, jotka ovat tietyssä naapuruussuhteessa toisiinsa. Kutakin solua vastaa prototyyppi, ja alkutilassa ennen minkäänlaisten havaintojen saamista prototyyppien sisällöt voivat olla täysin satunnaisia. Verkko havainnoi syötteenä saamaansa näytevirtaa ja muodostaa vähitellen siitä järjestyneen kuvauksen tyypillisesti 2-ulotteiselle karttapinnalle. Järjestyneellä kartalla naapurisoluihin kuvautuu keskenään samankaltaisia tapauksia. Kartan eräs hyödyllinen ominaisuus on se, että tyypillisemmät havainnot vievät kartalta enemmän tilaa, jolloin niiden väliset erot kuvataan siis tarkemmin.

Itseorganisoiva kartta voi oppia jonkinlaisia prototyyppikäsitteitä ilman mitään nimitietoa, pelkästään havainnoimalla maailmassa olevia, aistijärjestelmän tai muun mittalaitteiston suodattamia tilastollisia ominaisuuksia ja niiden hahmoja. Esimerkki tällaisesta on foneemien järjestystä kuvaava kartta (Kohonen 1988), joka järjestyy pelkästään lyhyiden puhesegmenttien spektraalisten (akustisten) ominaisuuksien perusteella. Järjestyneelle kartalle muodostuu implisiittisiä foneemikategorioita, jotka heijastavat datassa olleita rykelmiä tai tihentymiä. Mikäli halutaan saada kartan järjestys näkyväksi, voidaan kartta myöhemmin *nimikoida* niiden näytteiden avulla, joiden nimike tiedetään. Foneemikartan tapauksessa tämä tapahtuu käyttämällä ääninäytteitä, joita vastaava foneemin nimi tai muu kategoriatieto on tunnettu.

Eläinkartta ”visuaalisista piirteistä”

Havainnollistan itseorganisoivan kartan toimintaperiaatetta konkreettisen esimerkin avulla. Tämä esimerkki on samantyypinen kuin Ritterin ja Kohosen (1989) itseorganisoivia piirrekarttoja kuvaavassa työssään esittämä.

Oletetaan, että on annettuna järjestelmä, joka jo kykenee jonkinasteiseen havaintotason prosessointiin koskien olioita, joita havainnoidaan. Piirteitä, joita systeemi osaa tunnistaa ovat esimerkiksi ”höyheniä”, ”4 jalkaa” tms. (taulukko 1). Kukin piirre tai piirteistö itsessään voisi muodostua itseorganisoivan kartan avulla foneemikategoriaesimerkin tapaan. Kartan saama data koostuu 10 tapauksesta, joille kullekin on kuultu myös jokin nimi (esim. läsnä ollut toinen henkilö on nimennyt olion). Nimet tässä esimerkissä auttavat meitä tarkastelemaan syntynyttä representaatiota, mutta sen syntyyn niillä ei ole vaikutusta.

höyheniä	neljä jalkaa	siivet	kaviot	lentää	pieni	suuri	
0	1	0	1	0	0	1	lehmä
0	1	0	1	0	0.5	0.5	lammas
0	1	0	0	0	1	0	hiiri
0	1	0	0	0	0.6	0.4	kissa
0	1	0	0	0	0.4	0.6	koira
0	1	0	0	0	0	1	karhu
1	0	1	0	0	0.5	0.5	pingviini
1	0	1	0	1	1	0	varpunen
1	0	1	0	1	1	0	rastas
1	0	1	0	1	0.6	0.4	fasaani

Taulukko 1: Eläinkartalle annettu data. Kullakin rivillä on yhtä tapausta kuvastava piirrejoukko. Piirteet ovat ”ulkomuotopiirteitä”, siis sellaisia, joita voisi mahdollisesti havaita pelkästään visuaalisen prosessoinnin tuloksena.

Taulukon 1 rivit ovat vektoreita jotka annettiin eläinten nimitietoja lukuunottamatta 6x8 kokoiselle itseorganisoivalle kartalle. Kuvassa 1 esitetään kartan järjestymisen (oppimisen) lopputuloksena syntynyt kartta. Kartalla harmaasävyt kuvaavat karttayksiköiden välisiä etäisyyksiä piirreavaruudessa siten, että tumma sävy vastaa pitkää etäisyyttä. Kartta on lopuksi nimikoitu, jolloin sen järjestys on saatu näkyväksi.

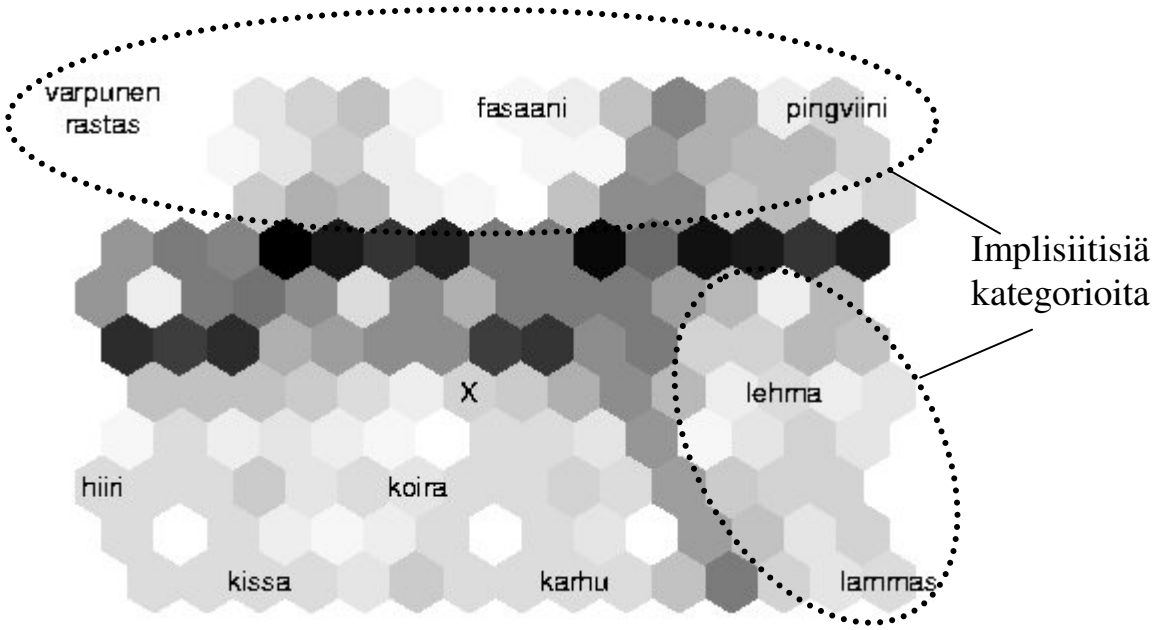

Kuva 1: Havaittujen eläinten ulkomuotopiirteiden perusteella muodostunut eläinkartta. Vaaleat alueet kuvaavat keskenään samankaltaisten näytteiden rykelmiä ja tummat alueet taas niitä erottavia ”rotkoja”. Rotkojen erottamia alueita voi tarkastella implisiittisinä kategorioina. Kartan alaosan implisiittisessä nisäkäs-kategoriassa sorkkaeläimillä on oma alakategoriansa. Muut nisäkkäät taas esiintyvät kartalla kokojärjestyksessä.

Kuvan 1 kartalle on lisäksi kuvautunut uusi havainto X, jonka osalta on tunnettu piirrevektori mutta ei nimitietoa. Tässä kuvassa kartta ei ole vielä muuttunut havaitun näytteen seurauksena, eli X on vain ”kuvattu” aiemmin opittujen eläinten muodostamalle karttapinnalle. Sen sijaan kuvassa 2 uusi näyte on jo vaikuttanut kartan järjestymiseen.

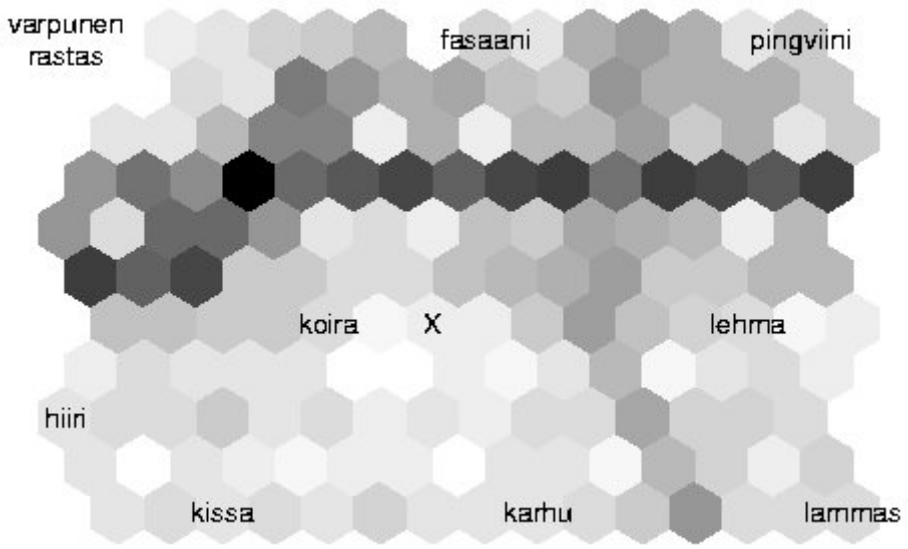

Kuva 2: Eläinkartta, kun uusi näyte X on myös vaikuttanut kartan järjestymiseen. Koira-näytteen representaatiopaikka on muuttunut – uusi näyte on siis vaikuttanut erityisesti lähiympäristönsä representaatioihin. Myös lintu- ja nisäkäsalueita erottava rotko on siirtynyt: nisäkäsalue on vallannut itselleen lisää tilaa.

Eläinesimerkistä näkyy, kuinka kategorioiden ei tarvitse toteutua toisistaan täysin erillisinä, vaan ne voivat olla myös osa jatkuvaa representaatiota, jossa kategoriat näkyvät implisiittisesti ja jopa tilannesidonnaisesti. Toisin sanoen, kaksi erillistä hierarkkisesti ja ajallisesti myöhempää prosessia voisi käyttää syötteenään yhtä ja samaa eläinkarttaa, mutta siten, että siitä havaittujen kategorioiden määrä ja spesifiys on kummallakin hyödyntäjällä erilainen. Jatkuvasta representaatiosta on hyötyä myös virheiden sietämisen kannalta: pieni virhe tai kohina syötteessä johtaa vain pieneen virheeseen kartan antamassa vastineessa (esim. tuotetussa kategoriassa tai nimikkeessä).

Sanojen merkityksen mallinnusta SOMilla

Kun itseorganisoivaa karttaa sovelletaan lyhyisiin tekstikonteksteihin, saadaan aikaan semanttisia ja syntaktisia kategorioita (Ritter ja Kohonen 1989; Honkela, Pukki ja Kohonen 1995). Itseorganisoivan kartan käyttöä kielen ymmärtämisen mallintamiseen ovat lisäksi pohtineet laajemmin mm. Miikkulainen (1993) ja Honkela (1997).

Miikkulainen (1997) on rakentanut yksityiskohtaisen neuroverkkomallin mentaalisesta leksikosta ja tutkinut, seuraako paikallisista mallin häiriöistä afasialle tyypillisiä virheitä. DISLEX-

nimisessä mallissa on komponentteina useita yhteen kytkettyjä itseorganisoivia karttoja. Ortografiselle, fonologiselle ja semanttiselle representaatiotasolle on kullekin oma karttansa. Ortografisella kartalla visuaalisesti samankaltaiset sanahahmot kuvautuvat lähekkäin, ja fonologisella kartalla taas ääniasultaan samankaltaiset sanat löytyvät vierekkäin. Assosiatiivisten kytkentöjen ansiosta sanan ”dog” syöttäminen ortografiselle kartalle sumeutettuna kuvana (bittikarttana) aktivoi hetken kuluttua semanttisella kartalla käsitteen DOG. Kun karttojen välisiin kytkentöihin lisättiin kohinaa, mallin toiminta häiriintyi muistuttaen ihmisen tekemiä virheitä: ortografiselta kartalta semanttiselle kartalle kulkevaan kytkentään lisätty kohina aiheutti syvädysleksialle (deep dyslexia) ominaisen väärän vaikkakin lähekkäisen semanttisen kategorian aktivoitumisen (esim. DOG-käsitteen sijaan PREDATOR tai PREY). Jos taas kohinaa lisättiin semanttisen kartan ulostulokytkentään, joka johti ortografiselle kartalle, saattoi BALL-käsitettä vastaavan sanan tilalla aktivoitua melko samannköinen sana, esimerkiksi DOLL. Miikkulainen (emt.) toteaa, että DISLEX-mallissa paikallisen häiriön aiheuttamat virheet ovat hyvn samankaltaisia kuin afasiassa ilmenevät kategoriaspesifit virheet, joita syntyy mm. paikallisen leesion seurauksena.

Modulaarisuudesta ja hajautetuista representaatioista

Keinotekoisten neuroverkkojen ominaisuuksien näkökulmasta ei ole kovin uskottavaa, että aivot olisivat yksi valtava, homogeenisesti kytketty neuroverkko. Täysin kytketty neuroverkko nimittäin sisältää valtavan määrän vapaita parametreja. Neuroverkon oppimiseen vaadittujen näytteiden määrä taas kasvaa yleisesti samaa tahtia kuin vapaiden parametrien määrä. Näin ollen suuren, täysin kytketyn neuroverkon saattaminen toimintakuntoon veisi kohtuuttoman kauan. Kuitenkin täysin kytketyn, täysin paralleelin neuroverkon ja erittäin modulaarisesti toteutetun tietokonearkkitehtuurin kaltaisen mallin välissä on suuri kirjo vaihtoehtoja, jotka ovat eri määrissä modulaarisia. Mallin korkean tason rakenne voi siis sisältää jonkinasteista neuraalista modulaarisuutta, vaikka mallin kaikki osa-alueet olisi toteutettu neuroverkoin.

Kuvassa 3 on esitetty skemaattisesti, miten käsiterepresentaatiot voisivat koostua useista eri itseorganisoivista kartoista. Voidaan ajatella, että kuvan 3 rakenne on yhtäaikaa esimerkki sekä hajautetuista representaatioista että modulaarisuudesta. Hajautettua representaatiota on se, että tapaus ”karhu” aktivoi jonkin alueen sekä olioiden kartalla että kahdella kartalla, A1 ja A2, jotka kuvaavat eläimiä eri näkökulmista. Neuraalisen tason modulaarisuutta taas heijastaa kunkin erillisen kartan

olemassaolo: yksi kartta saa kaikista mahdollisista piirteistä ja kaikista mahdollisista tapauksista syötteenään vain jonkin osajoukon. Samantyyppistä yhtäaikaista modularisuutta ja hajautettua tiedon representointia edustaa Miikkulaisen (1997) DISLEX-mallissa jako ortografiseen, fonologiseen ja semanttiseen representaatioon.

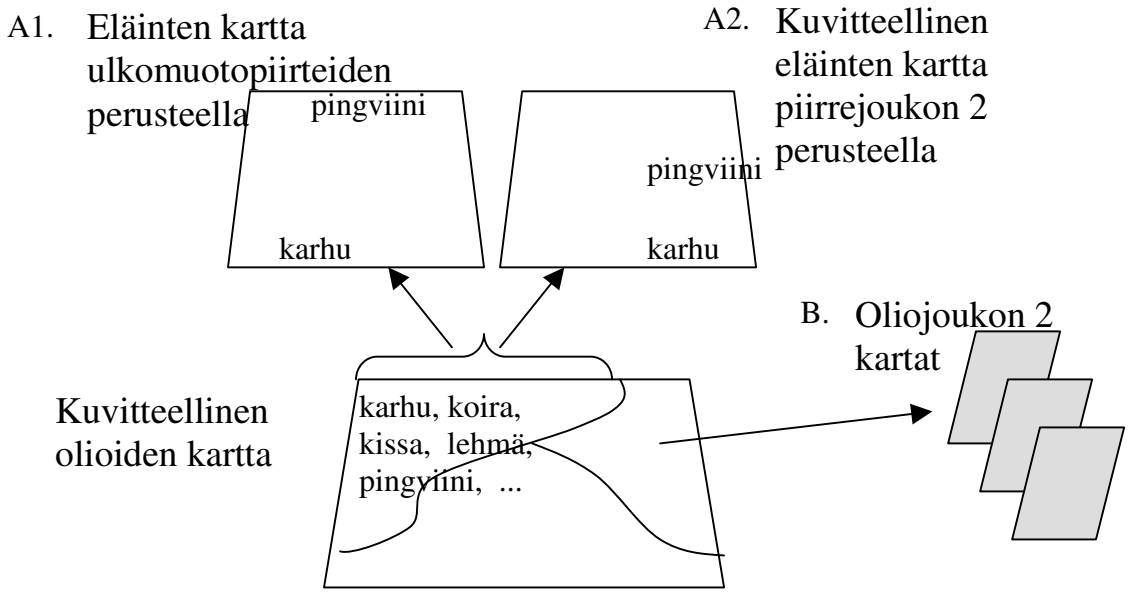

Kuva 3: Eri tyyppisillä piirrejoukoilla saadaan samoille tapauksille eri tavoin järjestyneitä representaatioita. Kuvassa näkyy kahdentyyppistä neuraalisen tason modulaarisuutta: 1. tapausjoukon jakaantuminen aliryhmiin (A1 ja A2 eläinkartat vs. B. oliojoukon 2 kartat). 2. Eri tyyppisen piirretiedon kulkeutuminen eri representaatioille (eläimille on karttaa, A1 ja A2, jotka ovat organisoituneet eri piirteillä).

Neuraalisten moduulien yhteys psykologiseen ja kognitiivisen tason (komputationaaliseen) modulaarisuuteen ei kuitenkaan ole täysin itsestään selvä (ks. Lappi, 2004). Neuraaliset, fysiologisen tai rakenteellisen tason modulit voivat kukin osallistua usean eri osaongelman tai psykologisen tason tehtävän ratkaisemiseen. Churchland ja Sejnowski (1992) erottavat aivoissa ns. systeemien tarkastelutason. Systeemejä ovat esimerkiksi yksittäisen aistin kautta tulevaan tiedonkäsittelyyn liittyvät alueet ja mm. autonominen systeemi. Yksittäiseen systeemiin voi osallistua karttoja tai muita neuronikokoelmia useilta kaukana toisistaan olevia aivoalueilta pitkien, näitä alueita yhdistävien kytkentöjen välityksellä.

Itseorganisoivaa karttaa muistuttavia järjestyneitä representaatioita on toistaiseksi löydetty lähinnä aistikohtaista tietoa keskeisesti prosessoivilta korteksin alueilta (Kohonen, 2001). Korkeamman kognition osalta prosessointia tunnetaan vähemmän, mutta joidenkin abstraktimpien piirteiden järjestyneitä, karttamaisia representaatioita on tiettävästi löydetty (emt). Kuitenkin, koska korteksin fysiologinen rakenne on tiettävästi

samankaltainen alueesta riippumatta, on mielekästä olettaa, että samankaltaiset oppimisperiaatteet pätevät eri alueilla. Tähän viittaa myös se, että useita erillisiä kortikaalisia alueita voidaan mallintaa itseorganisoivan kartan avulla: se mikä muuttuu, on kunkin alueen saama piirretieto. Neuroverkkomalinnuksen näkökulmasta mielekäs hypoteesi olisi siis nähdäkseni se, että korkeampi kognitio, joka usein sijoitetaan korteksin frontaalialueille, ei eroa muusta kognitiosta neuraalisella ”toteutuksen” tasolla, siis esim. neuroverkkomenetelmien tasolla. Ero olisi enemmänkin sisällöllinen, ja ilmenisi esimerkiksi siinä, minkälainen ja miten kytketty kokoelma ko. alineuroverkoista koostuu ja mitkä verkot saavat syötteitä miltäkin aistitietoa prosessoivilta tai muilta alueilta. Myös oikeanlaisten takaisinkytkentöjen merkitys voi olla hyvin suuri, koska niiden avulla korkeamman tason prosessit voivat vaikuttaa aistitietoa lähempänä olevien alueiden toimintaan. Tällaisia takaisinkytkentöjä on havaittu aivoissa, mutta niiden funktiot lienevät vielä suureksi osaksi epäselviä (Churchland ja Sejnowski 1992).

Kielellisen variaation tutkimisesta

Lopuksi haluaisin nostaa huomion kohteeksi kielellisen variaation, aiheen, joka tuntuu usein jäävän vähälle huomiolle kielikykyä tutkittaessa. Ihmiset käyttävät jo kaikkein perustavimpia käsitteitä kovin eri tavoin. Esimerkki tällaisesta variaatiosta löytyy kokeesta, jossa koehenkilöitä pyydettiin arvioimaan värisana-substantiiviparin luontevuutta kysymällä, kuinka sopiva mikin värisana on minkin substantiivin kuvailuun (Honkela ym. 2004). Itseorganisoivalla kartalla tehty analyysi paljasti värisanojen käytössä toisaalta yhtenevyyksiä mutta myös suurta yksilöllistä vaihtelua.

Yleisemmin näkisin, että kuvatun kaltainen vaihtelu ei ole poikkeus vaan sääntö, joka kertoo kielten ja mielten aidosta ja perimmäisestä yksilöllisyydestä. Vaihtelu voi tietenkin olla seurausta sekä synnynnäisperäisistä rakenteellisista ja muista ominaisuuksista että yksilön elinaikanaan saamista kokemuksista eli datasta. Neuroverkkomallinnuksen avulla on mahdollista tutkia kontrolloidusti, mitä kumpikin aspekti asiaan vaikuttaa: toisistaan poikkeavia synnynnäisiä ominaisuuksia voidaan simuloida valitsemalla erilaisia neuroverkkorakenteita. Kokemuksen merkitystä ja reunaehtoja taas voidaan tutkia vaihtelemalla datajoukkoa, joka neuroverkolle annetaan.

Lähteet

Brattico, P. (2004). Miksi kognitiotieteellä ei ole teoriaa keskusprosesseista? *Puhe ja Kieli*, 24: 4, 191-201.

Churchland, P.S. & Sejnowski, T.J. (1992). Neuroscience Overview. Luku 2 kirjassa *The computational brain*, 17-29. Cambridge MA: MIT Press.

Elman, J.L. (2001). Connectionism and Language Acquisition. Teoksessa M. Tomasello & E. Bates (toim.), *Language Development: The Essential Readings*, 295-306. Oxford: Blackwell Publishing.

Gärdenfors, P. (2000). *Conceptual spaces*. Cambridge, MA: MIT Press.

Honkela, T., Pulkki, V. & Kohonen, T. (1995). Contextual relations of words in Grimm tales analyzed by the Self-Organizing Map. Teoksessa Fogelman-Souliè, F. & Gallinari, P. (toim.), *Proceedings of ICANN-95, International Conference on Artificial Neural Networks*, 3-7. Paris: EC2 et Cie.

Honkela, T. (1997). *Self-organizing maps in natural language processing*. PhD dissertation, Helsinki University of Technology, Espoo, Finland.

Kohonen, T. (1988). The 'neural' phonetic typewriter. *IEEE Computer Magazine*, 27: 3, 11-22.

Kohonen, T. (2001) *Self-Organizing Maps*. 3rd extended edition. Berlin: Springer.

Lappi, O. (2004) Mielen, kielen ja aivojen modulaarisuus. *Puhe ja Kieli*, 24: 4, 203-211.

Miikkulainen, R. (1993). *Subsymbolic natural language processing: An integrated model of scripts, lexicon and memory*. Cambridge, MA: MIT Press.

Miikkulainen, R. (1997). Dyslexic and category-specific aphasic impairments in a self-organizing feature map model of the lexicon. *Brain and Language*, 59, 334-366.

Rumelhart D.E. & McClelland, J.L. (1986a). Feature discovery by competitive learning. Teoksessa Rumelhart D. E. & McClelland, J. L. (toim.), *Parallel Distributed Processing: Explorations in the microstructure of cognition,* 151-193. Volume 1: Foundations. Cambridge, MA: MIT Press.

Rumelhart D.E. & McClelland, J.L. (1986b). On learning the past tenses of English verbs. Teoksessa Rumelhart D. E. & McClelland, J. L. (toim.), *Parallel Distributed Processing: Explorations in the microstructure of cognition*, 216-271). Volume 2: Psychological and biological models. Cambridge, MA: MIT Press.