

Neuraaliverkot

Neuraaliverkkoja kohtaan tunnettu kiinnostus on kasvanut huomattavasti viimeisen kymmenen vuoden aikana. Tämä tutkimus koskettaa asioita kuten aivojen tiedonkäsittely, rinnakkainen hajautettu laskenta ja keinotekoiset neuroverkot. Yhteisenä piirteenä näillä on periaate tarkastella aivoja esimerkkinä hyvin toimivasta hajautetusta tietojenkäsittelyjärjestelmästä, joka eroaa huomattavasti tavallisen tietokoneen tiedonkäsittelyn periaatteista. Strategiana on ollut kehittää aivoja jäljitteleviä yksinkertaisia malleja ja sitten tutkia, mihin näitä malleja voidaan käyttää. Toisaalta tämä toimii myös toisin päin, ihmisen aivoja koskeva tutkimus on saanut uusia ideoita keinotekoisien neuraaliverkkojen tutkimuksesta.

Vaikka eri mallit poikkeavat toisistaan joskus varsin paljon, yhteisenä tekijänä niillä on neuronien ja niiden välisten kytkentöjen käyttö. Neuron on verkon toiminnan perusyksikkö. Se suorittaa verkon tiedonkäsittelyn ja vastaa ihmisen lyhytkestoista muistia. Neuron saa syötteensä kytkentöjen avulla muista neuroneista ja lähettää vastaavasti ulostulonsa muihin neuroneihin. Yksinkertaisessa tapauksessa (kuva 1) neuron laskee syötteiden x (n kappaletta) ja painojen w painotetun summan. Tämän jälkeen epälineaarinen funktio muuntaa summan a ulostuloksi y . Vakio T määrittää epälineaarisen funktion jyrkkyyden.

Tiedonvälitys neuronien välillä tapahtuu kytkentöjen avulla. Kytkennät ovat painotettuja ja kytkentöjen avulla neuroneihin tulevia syötteitä muunnetaan. Kytkentöjen painoja taas muutetaan niiden oppimislain avulla. Eli neuraaliverkon kyky sopeutua uusiin ympäristöihin, oppiminen, perustuu kytkentöjen painojen muuttamiseen siten, että verkko suoriutuu tehtävästään mahdollisimman hyvin.

Käytetyin neuraaliverkko on kuvan 1 kaltaisista neuroneista koottu monikerros-perceptron, jolle luonteenomaista verkon arkkitehtuuria esittää kuva 2. Tässä esimerkissä kolmesta neuronista koostuva syötekerros ottaa vastaan syötteen $x = [x_1, x_2, x_3]$. Toinen, ”piilotettu” kerros koostuu neljästä neuronista. Kerroksen tarkoituksena on muodostaa syötteistä oma esitys, jonka ansiosta verkko pystyy ratkaisemaan hyvinkin vaikeita ongelmia. Kolmas, ulostulokerros koostuu kahdesta

NEURAALIVERKOT JA NIIDEN KÄYTTÖ KUVIEN ANALYSOINNISSA

neuronista, ja se välittää syötettä x vastaavan ulostulon $y = [y_1, y_2]$ verkon käyttäjälle. Oppimislakina käytetään virheen takaisinkorjausmenetelmää. Oppimislain englanninkielisestä nimestä *error backpropagation* johtuen verkkoa kutsutaankin yleisesti backpropagation-verkoksi. Oppiminen perustuu esimerkkien käyttöön, eli syöte syötetään verkkoon ja se laskee koko verkon ulostulon. Sitten laskettua ulostuloa verrataan haluttuun ulostuloon ja kytkentöjen painoja muutetaan siten, että seuraavalla kerralla verkko tekee pienemmän virheen.

Backpropagation verkkoa on käytetty varsin menestyksellisesti ongelmiin kuten kirjainten ja puheen tunnistamiseen, backgammonin pelaamiseen, talouden ennustamiseen ja yksinkertaisten lauseiden jäsentämiseen. Kaukokartoituksen piirissä tällaista verkkoa voidaan käyttää luokitteluun (muunnetaan satelliittikuvan pikseli pikseliä vastaavaksi esim. maankäyttöluokaksi) ja regressioanalyysin suorittamiseen (muunnetaan satelliittikuvan pikseli vastaavaksi esim. puuston kuutiomääräksi).

Hyvästä käytännön tuloksista huolimatta backpropagation-verkon käytössä on myös ongelmia. Ensinnäkin, vaikka verkko on soveltunut hyvin käytännön ongelmiin, ei voida matemaattisesti todistaa aina käyvän näin. Tähän liittyy myös verkon arkkitehtuurin valinta, eli

ei ole teoreettista pohjaa neuronien lukumäärän valitsemiseksi. Käytännössä sopiva verkon arkkitehtuuri joudutaan kokeilemaan yrityksen ja erehdyksen avulla. Kokeileminen on lisäksi varsin aikaa vievää, koska käytännössä verkkoa joudutaan simuloimaan tavallisella tietokoneella. Vaihtoehtona on tietenkin käyttää rahaa tietokoneen varustamiseen erikoiskorteilla, jotka hoitavat verkon vaatiman rinnakkaislaskennan. Lopuksi verkolla pitäisi olla kyky yleistää, eli verkon pitäisi antaa läheinen ulostulo läheisille syötteille. Tämän aikaansaaminen vaatii suuren opetusjoukon käyttämistä.

Kohosen itseorganisoituva piirrekartta

Kirjoittajan mielenkiinnon kohteena on hieman toisenlainen neuraaliverkko, nimeltään Kohosen itseorganisoituva piirrekartta. Kun backpropagation-verkko opetetaan käyttäen esimerkkejä syötteistä ja halutuista ulostuloista, niin Kohosen itseorganisoituva piirrekartta muodostaa oman esityksen syötteiden avulla ilman tietoa halutusta ulostulosta. Tätä ominaisuutta kutsutaan itseorganisoinniksi ja se saavutetaan käyttäen kilpailuoppimista. Kilpailuoppimisessa verkon neuroneja kilpailutetaan, eli voittajaneuronin valitaan sopivan kriteerin avulla. Esimerkiksi voittajasolmuksi valitaan se, jonka painovektorin ja syötevektorin välinen etäisyys on

pienin. Voittajaneuronin löydyttyä sen painoja muutetaan oppimislain avulla. Oppimislain periaatteena on siirtää neuronin painovektoria syötevektoria kohti. Tätä toistettaessa painovektorit oppivat syötteiden tiheysfunktion ja löytävät syötteiden tärkeimmät ominaisuudet. Toisin sanoen, syötejoukon tiheimmille kohdille tulee monta painovektoria ja harvemmillä kohdilla vähemmän.


Neuronit järjestetään usein kaksikulotteiseksi hilaksi, kuten kuvassa 3 on tehty, mutta myös muita ulottuvuuksia voidaan käyttää. Kuvassa 3 syötteestä $x = [x_1, x_2, x_3]$ lähtevät viivat kuvaavat painoja, mustat pallot neuroneita ja viivat yhdistävät naapurineuronit toisiinsa. Kohosen itseorganisoituvan piirrekartan oppiminen eroaa perinteisestä kilpailuoppimisesta siten, että pelkän voittajaneuronin sijaan myös muita lähellä olevia naapurineuroneja opetetaan. Opetusprosessin alussa opetetaan suurta määrää naapureita ja päästäessä prosessissa pidemmälle naapureiden määrää pienennetään. Prosessin loppupuolella suoritetaan kartan hienosäätö, jolloin vain voittajaneuronia opetetaan.

Opetusprosessin tuloksena Kohosen itseorganisoituvaa piirrekartta luo topologisesti järjestäytyneen muunnoksen syötteiden ja neuronien välille. Topologinen järjestäytyneisyys tarkoittaa, että tiettyyn syötteeseen suurimmat ulostulot saavat neuronit ovat lähellä toisiaan kartassa. Motivaationa Kohosen itseorganisoituvan piirrekartan kehittämiseksi on ollut huomio, että eräät aistihavainnot käsittelevät alueet ovat järjestäytyneet samalla tavalla.


Kuvassa 4 on pienen Spot-monikanavakuvan (kuva 11) pikselien jakauma. Oikea vaak-akseli tarkoittaa vihreää kanavaa, vasen vaak-akseli punaista kanavaa ja pystyakseli infrapunakanavaa. Kuvassa 5 on kuvattu yksiulotteisen kartan painovektorien (81 kappaletta) paikat tähdillä (*). Viivat yhdistävät kartalla lähinnä olevat painovektorit. Kuvassa 6 on kuvattu kaksikulotteisen kartan painovektorien (9x9 kappaletta) paikat. Huomataan, että oppimisprosessin tuloksena painovektorit ovat sijoittuneet siten, että niillä alueilla, joissa on paljon kuvapikseleitä, on myös paljon painovektoreita lähellä toisiaan ja päinvastoin. Lisäksi lähellä toisiaan olevat painovektorit ovat myös lähellä toisiaan kartalla.

Sovellutuksista


Yksinkertaisuudestaan huolimatta Kohosen itseorganisoituvalla piirrekartalla on käyttöä analysoitaessa kuvia. Näitä




Kuva 1:
Yksinkertainen neuron, joka laskee syötteiden x painotetun summan ja saa ulostulonsa y muuntamalla summaa epälineaarisen funktion avulla.




Kuva 2:
Esimerkki monikerros-perceptron-verkon arkkitehtuurista.




Kuva 3:
Kohosen itseorganisoituvaa piirrekartta järjestettynä kaksikulotteiseksi hilaksi. Syötteestä $x = [x_1, x_2, x_3]$ lähtevät viivat kuvaavat painoja, mustat pallot neuroneita ja viivat yhdistävät naapurineuronit toisiinsa.




Kuva 4:
Spot-monikanavakuvan pikselien jakauma.




Kuva 5:
Yksiulotteisen kartan painovektorien paikat.




Kuva 6:
Kaksikulotteisen kartan painovektorien paikat.




Kuva 7:
Käänteinen kasvillisuusindeksikuva, tummat alueet ovat kasvillisuutta ja vaaleat kasvitonta.




Kuva 8:
Kasvillisuusindeksikuvasta otetuilla 5x5-kuvainneilla opetetun kartan painovektorit.




Kuva 9:
Neuroneja (1,1) ja (2,2) vastaavat alueet on merkitty valkoisella. Kyseiset alueet vastaavat alkuperäisen kuvan laajoja kasvillisuusalueita.



Kuva 10:
Neuroneja (7,4) ja (7,5) vastaavat alueet merkittynä valkoisella. Kyseiset alueet vastaavat alkuperäisen kuvan laajoja kasvittomia alueita.



Kuva 11:
Spot-monikanavakuva. Tummanpunaiset alueet vastaavat puustoa, vaaleamman punaiset alueet peltoja, musta vettä ja vaaleat alueet paljasta maata, teitä tai ihmisen tekemiä kohteita.




Kuva 12:
Ryhmitelty Spot-kuva. Kuusi ryhmää; ruskea ja valkoinen vastaavat paljasta maata ja ihmisen tekemiä kohteita, pelto keltaista, tumman vihreä puustoa, vaalean vihreä muuta kasvillisuutta ja sininen vettä.

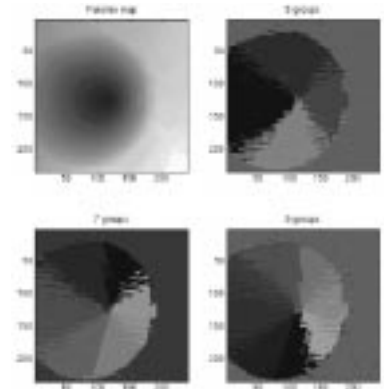
sovellutuksia ovat piirteiden irrotus, ryhmittely ja luokittelu.

Piirteiden irrotus. Satelliittikuvan sisältämä tietomäärä on valtava, joten sitä on syytä tiivistää ja hakea vain se tieto, mikä tarvitaan tehtävän suorittamiseen. Piirteiden irrotuksessa kuvaa tiivistetään siten, että muunnoksen avulla muodostetaan tiivistetty kuva. Jos käytössä on yksi kuva, kuvasta haetaan tarpeelliset asiat (esimerkiksi alueiden reunaviivat). Monikanavakuvan tapauksessa, eli kun kuva sisältää useamman eri aallonpituuksilla otetun kuvan, pyritään pienentämään kuvan ulottuvuutta eli yksittäisten kuvien lukumäärää samalla kuitenkin säilyttäen mahdollisimman paljon kuvien sisältämää

Spot-monikanavakuva on saatu Maanmittauslaitoksen Satelliittikuvakeskuksen esimerkkikuvapakkauksesta WWW-sivulta <http://www.nls.fi/sat/satelesi/allsat.zip>, copyright CNES, Satellitbild, MML/Satelliittikuvakeskus.



Kuva 13:
Karttion parallaksikartta kuvattuna kolmiulotteisena.



Kuva 14:
Vasemmalla ylhäällä parallaksikartta kaksikulotteisena kuvana, oikealla ylhäällä parallaksikartta on jaettu viiteen eri orientaation omaavaan ryhmään, vasemmalla alhaalla seitsemään ryhmään ja oikealla alhaalla yhdeksään ryhmään.

informaatiota.

Kuvassa 7 on käänteinen kasvillisuusindeksikuva, eli kasvillisuutta olevat alueet näkyvät tummina ja kasvittomat alueet vaaleina. Kuvasta otettiin 5x5 pikselin kokoisia kuvaikkunoita ja 7x5 neuronin kokoinen kartta opetettiin käyttäen ko. ikkunoita. Kuvassa 8 ovat neuronien painovektorit opetuksen jälkeen. Kuvasta huomataan, että painovektoreilla on selkeä järjestys ja ne vastaavat erilaisia alkuperäisellä kuvalla olevia asioita eli painovektorit ovat suorittaneet piirteiden irrotuksen. Koordinaateiltaan (1,1) oleva painovektori on kokonaan musta, eli kyseinen neuroni vastaa kasvillisuutta. Vastaavasti painovektori (7,5) on valkoi-

nen, eli kyseinen neuroni vastaa kasvittontaa aluetta. Suurin osa muista neuroneista vastaa siirtymistä kasvittomasta alueesta kasvilliseen alueeseen ja päinvas-toin. Esimerkiksi neuroni (7,1) vastaa siirtymistä kasvillisesta alueesta kasvittomaan ja neuroni (1,5) kasvittomasta alueesta kasvilliseen. Nämäkin neuronit sijaitsevat vastakkaisilla puolilla karttaa. Kuvassa 9 on neuroneja (1,1) ja (2,2) vastaavat alueet merkitty valkoisella. Kyseiset alueet vastaavat alkuperäisen kuvan laajoja kasvillisuusalueita. Kuvassa 10 on neuroneja (7,4) ja (7,5) vastaavat alueet merkittynä valkoisella. Kyseiset alueet vastaavat alkuperäisen kuvan laajoja kasvittomia alueita.

Käytettäessä karttaa monikanavakuvan ulottuvuuden pienentämiseen käytetään hyödyksi neuronien koordinaatteja. Haluttaessa muuntaa Spot-monikanavakuvan kolme kuvaa kahdeksi kuvaksi, ensin kaksiulotteisen kartan painovektorit opetetaan käyttäen kuvapikseleitä, jolloin painovektorit oppivat kuvapikselien jakauman (vertaa kuva 4, 5 ja 6). Tämän jälkeen kullekin kuvapikselille etsitään voittajaneuroni ja kyseisen pikselin koordinaatteja käytetään pikselin uusina arvoina. Jos kartta on pienikokoinen, voidaan pikselin uudet arvot laskea lähimpien painovektorien etäisyyksillä painotettuna keskiarvona. Kokeiltaessa ulottuvuuden pienentämistä Landsat TM-kuvan kuudelta kanavalta (lämpökanavaa ei käytetty) otetut opetusalueet muunnettiin kahdeksi kanavaksi käyttäen karttaa ja pääkomponenttimuunnosta. Muunnetut kanavat luokiteltiin käyttäen Bayesin päätössääntöä pienimmälle virheelle ja tiheysfunktioit estimoitiiin k-lähimmän naapurin menetelmällä. Alkuperäisen opetusjoukon luokitteluvirhe oli 16 %, pääkomponenttimuunnoksella pienennetyn joukon luokitteluvirhe 18 % ja kartan avulla muunnetun joukon luokitteluvirhe 16 %. Eli tässä tapauksessa ulottuvuuden pienentäminen ei ilmeisesti vähennä kuvien sisältämää informaatiota.

Ryhmittely. Ryhmittelyn eli ohjaamattoman luokittelun avulla haetaan datajoukossa olevia kasautumia. Eli datajoukon luokat ovat tuntemattomia ja yleensä myös luokkien lukumäärä on tuntematon. Tällaisessa tapauksessa yritetään löytää ne kuvapikselit jotka ovat lähellä toisiaan ja liittävät ne samaan ryhmään. Vastaavasti kaukana toisistaan olevat kuvapikselit kuuluvat eri ryhmiin

Kohosen itseorganisoituvaa piirrekartta sopii vallan mainiosti ryhmittelyyn. Tällöin yksinkertaisimmassa tapauksessa kukin kartan neuroni vastaa omaa ryh-

mää. Jos neuroneita on paljon, niitä voidaan kasauttaa ja täten pienentää ryhmien lukumäärää. Kuvassa 11 on Spot-monikanavakuva. Tummanpunaiset alueet vastaavat puustoa, vaaleamman punaiset alueet peltoja, musta vettä ja vaaleat alueet paljasta maata, teitä tai ihmisen tekemiä kohteita. Kuvassa 12 on kyseisen Spot-kuva ryhmitelty kuuteen ryhmään; valkea ja ruskea vastaavat paljasta maata ja ihmisen tekemiä kohteita, pelto keltaista, tumman vihreä puustoa, vaalean vihreä muuta kasvillisuutta ja sininen vettä.

Toinen esimerkki ryhmittelystä koskee parallaksikartan segmentointia pinnan orientoinnin mukaan. Parallaksikartta on kahdesta tai useammasta kuvasta laskettu kohteen matriisimuotoinen korkeusmalli. Kuvassa 13 on kartion parallaksikartta kuvattuna kolmiulotteisena. Nyt tämä pitää segmentoida eli jaotella ryhmiin pinnan orientoinnin mukaan. Ensinnä täytyy määrittää kullekin parallaksikartan pikselille paikallinen pinnan orientointi. Tämä tapahtuu ottamalla pikselin ympäriltä 3*3 kuvaikkuna ja vähentämällä reunimmaisista pikseleistä keskimmaisoin pikseli. Näin saadaan tulokseksi 8-ulotteinen vektori, joka määrittää pinnan orientoinnin kyseisen pikselin kohdalla. Tämän jälkeen yksiulotteinen Kohosen itseorganisoituvaa piirrekartta opetetaan käyttäen näitä vektoreita ja vektorit ryhmitellään lähimmän neuronin mukaan. Kuvassa 14 on vasemmalla ylhäällä parallaksikartta kaksiulotteisena kuvana, oikealla ylhäällä parallaksikartta on jaettu viiteen eri orientoinnin omaavaan ryhmään, vasemmalla alhaalla seitsemään ryhmään ja oikealla alhaalla yhdeksään ryhmään. Kuvista huomataan, että syntyneet ryhmät todella vastaavat eri pinnan orientointeja eli Kohosen itseorganisoituvan piirrekartan neuronit ovat oppineet ne.

Luokittelu. Kohosen itseorganisoituvaa piirrekarttaa voidaan käyttää myös luokitteluun. Tällöin kartta opetetaan tavalliseen tapaan. Tämän jälkeen kullekin neuronille annetaan luokka opetusjoukon avulla. Luokitteluvaiheessa kuvapikselille etsitään lähin neuroni ja luokitellaan neuronin vastaavaan luokkaan. Kartan luokittelua voidaan hienosäätää käyttämällä oppivaa vektorikvantisointia. Näitä on useampia hieman toisistaan poikkeavia menetelmiä, mutta yhteisenä piirteenä on hakea opetusjoukon vektorille yksi tai kaksi lähintä painovektoria ja siirtää painovektoreita lähemmäksi, jos ne kuuluvat samaan luokkaan, tai kauemmaksi, jos ne kuuluvat eri luokkiin.

Testissä luokittelu tapahtui käyttäen Kohosen itseorganisoituvaa karttaa, oppivaa vektorikvantisointia ja Bayesin päätössääntöä pienimmälle virheelle (k-lähimmän naapurin tiheysfunktion estimointimenetelmä). Varsin suuri opetus- ja testijoukko saatiin ottamalla alueita 14 eri aikaan otetuista ERS-1 SAR-kuvista. Kun luokittelu suoritettiin Kohosen itseorganisoituvalla piirrekartalla, luokitteluvirhe oli hieman yli 14,6 %. Tätä luokittelua parannettiin oppivan vektorikvantisoinnin avulla, jolloin luokitteluvirheeksi saatiin 11,2 %. Bayesin päätössääntöön luokitteluvirhe oli hieman alle 10 %. Kohosen itseorganisoituvan piirrekartan ja oppivan vektorikvantisoinnin etuna on nopeus, luokittelu näillä menetelmillä tässä tapauksessa kesti hieman toista tuntia, kun luokittelu Bayesin päätössäännöllä kesti yli kymmenen tuntia. Eli saadaan melkein yhtä hyviä tuloksia huomattavasti lyhyemmässä ajassa.

Markus Törmä, Teknillinen korkeakoulu
Fotogrammetrian ja kaukokartoituksen
laboratorio, Otakaari 1, 02150 Espoo
Puh. (09) 451 3896, faksi (09) 465 077,
sähköposti Markus.Torma@hut.fi