

---

**Jukka Louhivuori, Mauri Kaipainen ja Petri Toiviainen**

---

## **Runosävelmiä oppiva ja tuottava itse-organisoituva keinotekoinen hermoverkko**


### **Johdanto**

Viime vuosisadan lopulla folkloristit ja musiikkiteeilijät ryhtyivät tutkimaan eepistä runoutta ja muistinvaraista perinnettä. Eeppisten runojen pituus yllätti tutkijat. Toisinaan runo saattoi kestää useita tunteja ellei peräti koko yötä. Usein kuultu kysymys ”Kuinka on mahdollista muistaa ja toistaa niin pitkiä tarinoita” on itse asiassa väärä kysymys. Pian tutkijat ymmärsivätkin, että ei ole kyse niinkään tietyn tarinan toistamisesta, vaan uudelleen luomisesta.

Albert Lord (1960) joutui pohtimaan näitä kysymyksiä tutkiessaan Balkanilla eepistä runoutta. Hän pyrki ymmärtämään, kuinka pitkien eepisten runojen muistaminen ja tuottaminen voitaisiin ymmärtää aivojen muistikapasiteetin näkökulmasta. Albert Lord oletti, että laulajat ovat lapsuudessaan kuulleet suuren määrän eri muodossa olevia teemoja. Opittuaan useita erilaisia runoudessa esiintyneitä teemoja, joita Albert Lord kutsui formuloiksi, ja niiden yhdistelytapoja, syntyi lapsille kyky tuottaa uusia yhdistelmiä. Kuunnellessaan entuudestaan tuntemattomia eepisiä runoja, laulajat eivät opetelleet niitä sanasta sanaan, vaan kuuntelivat kuinka perinteisiä formuloita yhdisteltiin. Albert Lord ymmärsi, ettei muisti ole staattinen varasto, vaan dynaaminen, jatkuvassa muu-  
tostilassa oleva systeemi. Laulaja ei ”muista lauluja ulkoa”, vaan tuottaa ne aikaisemmin opittujen mallien mukaan. Laulajan taide perustuu traditionaalisten musiikillisten ja runollisten kaavojen (formuloiden) hallintaan. Albert Lord kirjoitti, että ”His (...the singer...) task is to adapt and adjust it (...form of the theme...) to the particular song that he is recreating. It does not have a single ‘pure’ form either for the individual singer or for the tradition as a whole. Its form is ever changing in the singer’s mind, because the theme is in reality protean; in the singer’s mind it has many shapes, all the forms in which he has ever sung it, although his latest rendering of it will naturally be freshest in his mind. It is not a static entity, but a living, changing, adaptable artistic creation” (Lord 1960, 94).

Albert Lord pyrki ymmärtämään mustamistapahtumaa käyttämällä formula-käsitettä. Parryn (1930) mukaan formula on ”sanojen joukko, joka säännöllisesti esiintyy samassa metrisessä kontekstissa ilmaistakseen tietyn olennaisen ajatuksen”. Traditionaaliin formuloihin perustuva uusien laulujen tuottamis-

prosessi on kuvattu kaaviossa 1. Erilaiset graafiset kuviot esittävät traditionaalisia formuloita – kaaviossa näitä on viisi erilaista. Kolme laulajaa (a, b, c) tuottaa kolme erilaista laulua käyttäen samoja formuloita, mutta yhdistämällä niitä eri järjestyksessä. Lopputuloksena olevat toisinnot näkyvät kaavion 1 alla.



Kaavio 1.

Ilmiö on tavattu monista eri musiikkikulttuureista, esimerkiksi gregoriaanisesta laulusta. Leo Teitler (1974) on käsitellyt tutkimuksissaan gregoriaanisissa sävelmissä esiintyviä formuloita. On syytä muistaa, että gregoriaaninen laulu oli kansanmusiikin tapaan muistinvaraista.

## Tutkimuksen tarkoitus

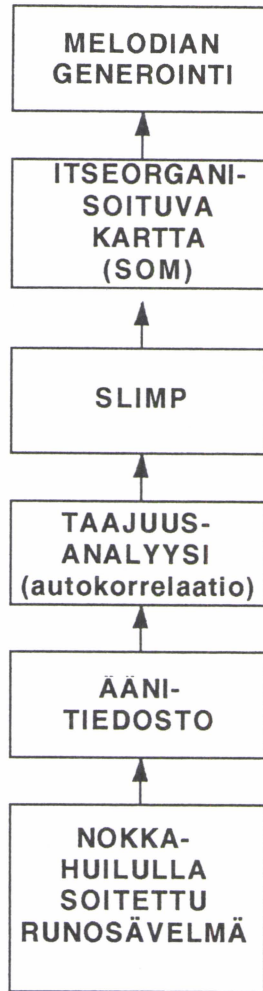
Kognitiivisen psykologian kehitys on tehnyt mahdolliseksi tarkastella formulakäsitetä aikaisempaa laajemmasta näkökulmasta. Kognitiotiede on edistynyt nopeasti erityisesti muistitutkimuksen alueella. Ymmärtämällä muistin toimintamekanismia, on aikaisempaa helpompi ymmärtää ja selittää esimerkiksi muistinvaraisen eepisen runouden tuottamisprosesseja.

Suomalaisella runonlaululla on paljon yhtymäkohtia Balkanilla harjoitetun eepisen laulannan kanssa. Molemmat on opittu lapsuudessa kuuntelemalla ja yrittämällä tuottaa niitä. Tämän tutkimuksen tarkoituksena on pyrkiä ymmärtämään runonlaulun oppimis- ja tuottamisprosesseja käyttämällä kognitiotieteen lähestymistapoja ja menetelmiä. Pyrkimyksenä on saada entistä tarkempi

kuva siitä, mitä runosävelmien oppiminen itse asiassa tarkoittaa. Tuntiessamme paremmin muistin toimintaperiaatteet – samoin kuin myös muut kognitiiviset prosessit – meillä on paremmat mahdollisuudet ymmärtää ja selittää muistinvaraisissa musiikkikulttuureissa vastaan tulevia kysymyksiä. Lähestymme näitä kysymyksiä käyttämällä apuna aivojen toiminnasta inspiraationsa saaneita itsejärjestyviä keinotekoisia hermoverkkoja, jotka oppivat melodioita esimerkkien avulla ja kykenevät tuottamaan mallien kaltaisia melodioita.

Tutkimuksessa käytetty menetelmä on kuvattu seuraavassa (ks. kaavio 2):

- 1) lähtökohtana on nokkahuilulla soitettu äänitiedosto, joka sisältää luonnollista kestoihin ja sävelkorkeuksiin liittyvää muuntelua; mallin kannalta on olennaista, että lähtökohtana ei käytetä symbolista representaatiota (esimerkiksi nuottikuvaa),
- 2) äänitiedosto esikäsitellään (autokorrelaatio) siten, että äänitiedostosta saadaan esiin perustaajuus; tällä tavoin saadaan taajuuskäyrä (melodisen liikkeen kuvaaja),
- 3) melodiakuvaajaa käsitellään edelleen niin, että syntyy useita "muisteja", joiden kesto vaihtelee puolesta sekunnista viiteen sekuntiin; redundanssia vähennetään käyttämällä eksitaatio–inhibitio-mekanismia; lopulta eripituisten muistien sisältö kuvataan vektoreina,
- 4) Kohosen itsejärjestäytyvä keinotekoinen hermoverkko järjestää vektorit topologiseen järjestykseen kaksiulotteiseksi kartaksi,
- 5) malli generoi uusia melodioita seuraamalla syötteenä käytettyjen melodioiden vektorikuvausten karttaan synnyttämiä polkuja (Kaipainen, Toiviainen, Louhivuori 1995).



Kaavio 2.

## Miksi keinotekoiset hermoverkot?

1980-luvulle asti kognitiotiedettä hallitsi käsitys ihmismielestä sääntöpohjaisena ja symbolien prosessointiin perustuvana systeeminä, jonka toimintaa voidaan verrata tietokoneeseen. Kuva muuttui ratkaisevasti, kun aivotutkimus kykeni antamaan alustavan yleiskuvan aivojen toiminnasta. Tämän tiedon varaan voitiin rakentaa aivojen toimintaa kuvaavia ns. konnektionistisia, laskennallisia malleja. Nämä perustuvat käsitykseen, että aivojen toiminta pohjautuu suureen määrään toisiinsa kytkeytyneitä hermosoluja. Tällaisen systeemin merkittävä ominaisuus on sen kyky adaptoitua hyvin erilaisiin ja jatkuvassa muutostilassa

oleviin ympäristöihin. Suuri määrä kirjallisuutta on julkaistu, jossa havainnollistetaan sitä, kuinka laskennallisten mallien avulla voidaan kuvata tiettyjä oletettuja aivotoimintojen peruseräitä.

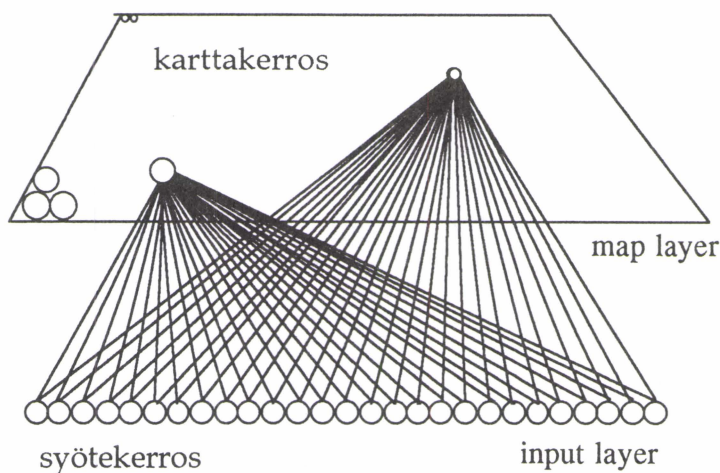
Aivojen toiminnan rinnakkainen luonne, eli kyky käsitellä yhtäaikaista suurta määrää informaatiota, edellytti uusia tapoja kuvata tiedonkäsittelyprosesseja. Tämä kuvaus koostui ympäristön alkeispiirteistä, joiden oletettiin olevan yhteydessä hermojärjestelmän tuotoksiin; abstraktilla tasolla kuvaus on verrattavissa esim. kuulojärjestelmän tai motorisen järjestelmän aivokuorelle lähettämien signaalien kanssa. Alkeispiirteet olivat siinä määrin primitiivisiä, että niiden ei voitu katsoa muodostavan symboleja, käsitteitä tai sääntöjä. Näille piirteille olikin tunnusomaista se, etteivät ne olleet kuvattavissa kielellisesti ja että ne olivat usein tiedostamattomia. Kun hermoverkkoille annetaan tämänkaltaista syötettä, ne pyrkivät adaptoitumaan kyseiseen ympäristöön ja samaan järjestystä, ”mielekkyyttä” kompleksisuuteen. Tämä edellyttää, että hermoverkot järjestävät hermosolujen väliset yhteydet niin, että systeemi järjestäytyy alkeispiirteiden samankaltaisuuksien perusteella.

Uuden lähestymistavan merkittävä seuraus oli, että ihmismieli ymmärrettiin yhtenäisenä, jakamattomana kokonaisuutena. Mieltä ja kehoa ei pitäisi tämän käsityksen mukaan tarkastella toisistaan erillään. Tästä seurasi, että huomiota ryhdyttiin kiinnittämään ajattelun pohjalla mahdollisten olevien sääntöjen sijasta subjektiivisiin, henkilökohtaisten historioiden muovaamiin mentaalisiin taitoihin, jotka emergoivat ympäristöstä noudattaen itsejärjestäytymisen periaatetta.

Keinotekkoisten hermoverkkojen etuna verrattuna symbolien prosessointiin ja eksplisiittisiin sääntöihin perustuviin malleihin on niiden oppimiskyky, yleistämiskyky, ja kyky täydentää epätäydellisiä kuvia. Huomionarvoinen ominaisuus on myös niiden kyky sietää virheellistä ja/tai puutteellista informaatiota, epistemologinen relevanssi (suhde biologisiin hermoverkkoihin) ja kyky käsitellä ei-symbolista informaatiota.

## Itsejärjestävä kartta

Teuvo Kohosen (1982, 1984, 1990) laatima itsejärjestävä kartta-algoritmi (self-organizing map, SOM) on yksi suosittu ja laajalle levinnyt tapa simuloida hermoverkkojen toimintaa. Karttoja voidaan pitää esimerkkinä siitä, kuinka topologisia karttoja (esimerkiksi kuuloaivokuorelle syntyvät tajuuskartat eli tonotopiat, Lauter et al., 1985) saadaan syntymään, vaikka malli perustuu vain hyvin karkeisiin yleistyksiin biologisten hermoverkkojen toiminnasta. Yksi tällaisista yleistyksistä ja oletuksista on nk. Hebbin oppimissääntö, jonka mukaan hermosolujen välinen kytkentä vahvistuu, kun hermosolujen dendriitit (tuoja- haarakkeet) ja aksonit (viejähaarakkeet) ovat yhtä aikaa aktivoituneina.



**Kaavio 3.** Kaavamainen esitys tyypillisestä SOM-arkkitehtuurista (SOM = self-organizing-map).

Tyypillinen SOM-arkkitehtuuri muodostuu syötekerroksesta ja kaksiulotteisesta karttakerroksesta. Kartta koostuu biologisten hermosolujen toimintaa jäljittelevistä yksiköistä, keinotekoisista hermosoluista (kyseinen biologisiin hermosoluihin voimakkaasti assosioituva termi on jossain määrin harhaanjohtava, mielellämme käyttäisimme neutraalimpaa termiä "yksikkö" eli "unit", joka kuitenkin monimerkityksellisyytensä vuoksi voi vaikeuttaa mallin toiminnan ymmärtämistä). Kaikki syötekerroksen yksiköt on yhdistetty kaikkiin kartalla oleviin keinotekoisiiin hermosoluihin karttakerroksen yksiköihin hermosäikeitä jäljittelevien kytkentöjen avulla. Kutakin kytkentää säätelee synaptista kytkentää mallintava muunneltava painokerroin. Kutakin yksikköä kohti on syötekerroksen yksiköiden määrää vastaava määrä painokertoimia, muodostaen yhdessä ns. painovektorin. Syötteenä annetaan ympäristön samanaikaisia piirrekomplekseja kuvaavia vektoreita, piirrevektoreita.

Kartan algoritmi on yksinkertainen. Ensiksi määritellään kartalta keinotekoinen hermosolu, jonka painovektori on lähimpänä syötteen syötevektoria. Tätä hermosolua (yksikköä) nimitetään voittajaksi. Vastaava ilmiö – ”voittaja vie kaiken” – on tavattu myös biologisista hermoverkoista. Tämän jälkeen kartan keinotekoisien hermosolujen painovektoreita muutetaan siten, että ne ovat lähempänä syötevektoria. Tämä adaptoituminen on voimakkainta voittajahermosolulla. Adaptoituminen syötevektoriin vähenee etäisyyden kasvaessa voittajahermosolun ja adaptoituvan hermosolun välillä eli lähellä voittajasolua sijaitsevat solut adaptoituvat enemmän ja kauempana olevat vähemmän. Kun edelläkuvattuja askelia toistetaan koko piirrevektorien joukolle useita kertoja, malli muodostaa automaattisesti topologisen luokitusjärjestelmän.

## Generatiiviset kieliopit

1950-luvulla kielitieteilijät kehittivät nk. generatiivisia kielioppeja. Monet musiikintutkijat ovat olleet kiinnostuneita Chomskyn ajatuksiin perustuvien kielioppien käyttömahdollisuuksista musiikintutkimuksessa. Esimerkiksi Johan Sundberg ja Björn Lindblom (1975) muotoilivat generatiivisia kielioppeja, jotka kykenivät tuottamaan Alice Tegnerin tyyliä noudattavia lastenlauluja. Myöhemmin Johan Sundberg (1976) sovelsi samaa menetelmää pyrkiessään selvittämään kansanmusiikissa ilmenevää muuntelua. Sundbergin ajatuksena oli käyttää luonnontieteellistä tutkimusparadigmaa sellaisen tutkimusongelman selvittämisessä, joka on perinteisesti hahmotettu kuuluvaksi humanistiseen tutkimustraditioon. Sundberg ja Lindblom pyrkivät rakentamaan mallin, joka auttaisi heitä ymmärtämään ja selittämään erityisesti kansanmusiikkiin liittyvää muuntelua. Keskeisenä ajatuksena näissä tutkimuksissa oli vaatimus testata mallit simulaatioiden avulla.

Myös muut tutkijat ovat olleet kiinnostuneita uusien tutkimusmenetelmien käyttämisestä musiikintutkimuksessa. Ebcioğlu (1988) laati asiantuntijajärjestelmän, joka kykeni soinnuttamaan melodian tyylillä, jota J.S.Bachin käytti koraaleissaan. Bernard Bell ja Jim Kippen (1992) ovat käyttäneet generatiivista kielioppia intialaista ragaa koskevissa tutkimuksissaan (ks. myös Kippen 1988).


Ajatus generoida hyvin muotoiltuja lauseita, musiikillisia rakenteita tai muita sekvenssejä, on ollut pitkään tunnettu ja suosittu menetelmä kognitiotieteellisessä tutkimuksessa. Konnektionismi hylkäsi lähes kokonaan generointiperinteen painottaessaan mm. aivojen toiminnan rinnakkaisuutta. Keskittyessään mielen spontaaniin adaptoitumiseen ympäristöönsä ja itsejärjestymiseen konnektionismi otti itse asiassa askeleen taaksepäin. Käsitys staattisesta ihmismielestä ei sovellu musiikintutkimukseen. Musiikintutkimuksen näkökulmasta on olennaista ottaa huomioon mielen pyrkimys katsoa eteenpäin, luoda odotuksia tulevaisuudesta ja toimia ympäristössään.

## Melodioiden generointi

Kaipainen (1994) on esitellyt temporaalisen muunnoksen alkunperin staattisesta SOM algoritmista. Tämä tekee mahdolliseksi tallentaa kartalla tapahtuvia peräkkäisiä siirtymiä (transitiot) ja käyttää näitä hyväksi odotusten ja ennakkointien muodostamisessa. Tämän lisäksi algoritmi antaa mahdollisuuden tuottaa eli generoida ajassa eteneviä sekvenssejä. Myös tämä algoritmi on perusajatuksettaan yksinkertainen. Kahden keinotekoisien hermosolujen välinen kytkentä AB (kartan hermosolut A ja B) vahvistuu aina kun voittajahermosolua A seuraa voittajahermosolu B. Nämä kytkennät tulkitaan tilastollisiksi siirtymätodennä-

köisyyksiksi (tilastollinen todennäköisyys, että voittajahermosolua A seuraa voittajahermosolu B).


Keinotekoisien hermoverkon toimintaa testataan antamalla prosessin edetä seuraamalla suurimpia siirtymätodennäköisyyksiä. Kun polku kohtaa kartalla hermosolun, jossa se on jo kerran käynyt, käytetään seuraavaksisuurinta siirtymätodennäköisyyttä. Generointi päättyy, kun polku johtaa hermosoluun, jonka kaikki siirtymämahdollisuudet on käytetty, eli kun prosessi joutuu silmukkaan. Generointien pituutta voidaan pitää sen indikaattorina, kuinka hyvin keinotekoinen hermoverkko kykenee erottelemaan toisistaan erilaisia musiikillisia ympäristöjä. Kartalla edellä kuvattu siirtymätodennäköisyyksiin perustuva polku voi näyttää esimerkiksi seuraavanlaiselta.



**Kaavio 4.** Kartalla generoitu polku. Nuolen paksuus kuvaa siirtymätodennäköisyyksiä: mitä paksumpi nuoli, sitä suurempi todennäköisyys.

Yllä olevassa kaaviossa näkyvät sävelkorkeudet määräytyvät sen mukaan, mikä 13 osaan jaetusta asteikosta (c, cis, d...c''), jota kuvataan mallissa 13 komponenttisella vektorilla, saa korkeimman arvon. Nuotinnuksessa jokaisen polun askeleen pituus on 1/8-osanuotti, mutta selkeyden vuoksi samaa sävelkorkeutta edustavat nuotit on yhdistetty toisiinsa pidemmiksi nuottiarvoiksi.



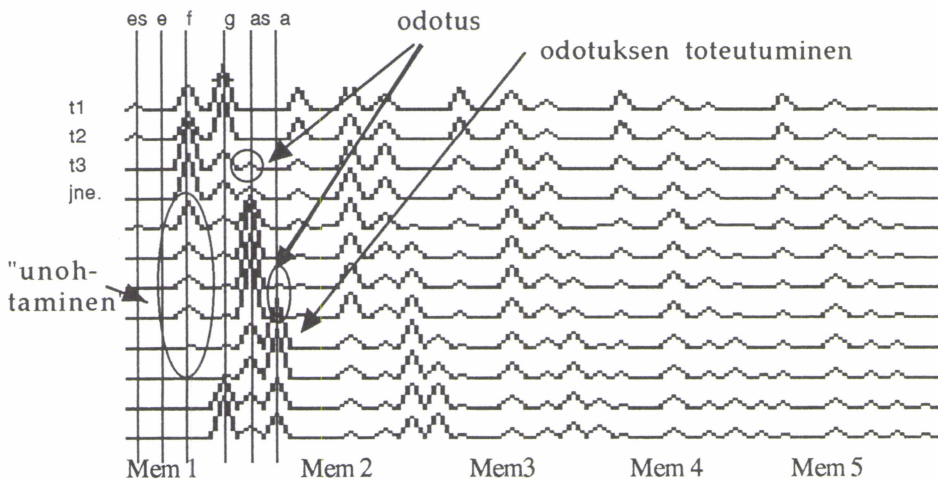


**Kaavio 5.** 13-komponenttisen vektorin painoarvot. Tässä tapauksessa korkeimman painoarvon on saanut sävelkorkeus e4 (=e).

Yllä oleva kaavio 5 näyttää nuoteiksi muutettuna seuraavalta:



Kaaviossa 6 näkyvät mallissa käytettävät eripituiset muistit (Mem1... Mem5) ja eri ajanhetkiä kuvaavat (t1, t2, t3 jne.) vektorit, jotka on kuvattu havainnollisuuden vuoksi graafisesti käyrinä. Ensimmäisen muistin (Mem 1) alueella olevan käyrän korkein kohta (=vektorin korkein painoarvo; vrt. kaavio 5) määrää generoinnissa sävelkorkeuden. Jokainen yksittäinen vektori vastaa 0,5 sekunnin kesto, joka on mallissa tulkittu 1/8-nuottiarvoksi. Esimerkiksi ensimmäisen vektorin sävelkorkeus on g (vektorin kolmas huippu). Kolmannen vektorin sävelkorkeus on f (kolmannen vektorin ensimmäinen huippu) jne.



**Kaavio 6.**

## **Äänitiedoston esikäsittely**

Äänitiedosto muodostuu kymmenestä runonlaulaja Anni Tenisovan (1879–1956) laulamasta säeparista. Äänite on tallennettu 1950-luvun alussa. Nämä säkeet on nuotinnettu ja soitettu tämän jälkeen nokkahuilulla. Näin äänitiedostoon saadaan luonnollista variaatiota ja epätasaisuutta (myöhemmissä kokeissa on käytetty myös alkuperäistä Tenisovan äänitettä, jolloin sekä nuotinnus että nokkahuilun käyttö ja näihin liittyvät ongelmat ovat jääneet pois). Äänitiedostosta on etsitty autokorrelaatiomenetelmää käyttäen (Kaipainen, Toiviainen, Louhivuori 1995) perustaajuus. Aikaresoluutiona on käytetty 0.1 s eli esimerkiksi yhden sekunnin mittaisesta äänitiedostosta on etsitty perustaajuus kymmenenä ajanhetkenä. Taajuudet on kuvattu vektorin avulla, jossa on paikka 13 eri sävelkorkeudelle. Jotta jokainen vektori sisältäisi yksittäisen sävelkorkeuden sijasta myös tietoa musiikillisesta kontekstista, tutkimuksessa on käytetty nk. SLIMP-menetelmää (Short-to-Long term-Inhibitory-Memory-Pools). Siinä sävelkorkeutta kuvaava taajuus syötetään viiteen eripituisen muistiin; ensimmäinen muisti tallettaa taajuutta koskevan tiedon 0.5 sekunnin ja viides muisti 5 sekunnin ajan. SLIMP-menetelmä on kuvattu yksityiskohtaisesti lähteessä Kaipainen, Toiviainen, Louhivuori (1995).

## **Tulokset**

Runonlaululle on tyypillistä toisto. Toisto ei ole tarkkaa, vaan laulaja muuntelee toistettava melodisia ja rytmisiä aiheita alituisesti. Muuntelun määrä vaihtelee laulajakohtaisesti, mutta usein säkeiden alku- ja loppusävelet pysyvät läpi laulun samoina. Laulujen ambitus on suppea, usein kvintti ja joskun seksti tai septimi.

Itsejärjestyvän keinotekoisien hermoverkon tehtävänä oli tässä tutkimuksessa oppia keskeiset runonlaulun musiikilliset piirteet sellaisina kuin ne ilmenevät Anni Tenisovan tyyliin. Keinotekoisien hermoverkon pitäisi siis oppia säkeiden pituus, esi- ja jälkisäkeen vuorottelu, ambitus, tyypilliset melodiset ja rytmiset kuviot, metrinen rakenne sekä tapa, jolla eri musiikillisiä elementtejä muunnellaan.

Liitteessä 1 on nuottiesimerkki, jossa ylinpänä on nuotinnettu Anni Tenisovan runonlaulua. Tämän alle on nuotinnettu itsejärjestyvän keinotekoisien hermoverkon generoinnin tuloksia. Vertailemalla näitä kahta huomataan, että verkko on oppinut kohtuullisesti Tenisovan laulun keskeiset piirteet, kuten esi- ja jälkisäkeen vuorottelun sekä säkeiden alku- ja päätössävelten suhteet. Melodiset kuviot noudattavat melko hyvin Tenisovan tyyliä, mutta kuten runonlaulussakin on tapana, verkko ei yksinomaan toista tarkasti oppimiaan kuvioita, vaan tuottaa uusia muunnelmia. Säkeiden melodinen kaarros noudattaa Tenisovan tyyliä. Malli toimii juuri samoin kuin esim. Albert Lord aikoinaan olet-

ti ihmisen muistin toimivan. Aivan niin kuin Balkanin eepin runouden esittäjät tai suomalaiset runonlaulajat luovat laulujen tuottamishetkellä ne uudelleen aikaisemmin oppimiensa mallien avulla, myös keinotekoinen hermoverkko näyttää uudelleenluovan runonlaulua muistuttavia toisintoja. Nämä toisintot ovat yhdistelmiä kaikesta siitä mitä opettaja – tässä tapauksessa Tennisova – on lauluesimerkeillään opettanut. Mielellämme tulkitsemmekin tulokset Albert Lordin tavoin: keinotekoinen itsejärjestäytyvä hermoverkko ei toista oppimiaan musiikillisia rakenteita, vaan uudelleen luo niitä käyttäen aikaisemmin opittuja musiikillisia malleja. Lopputuloksena on toisintoja, jotka sisältävät uusia rytmisiä ja melodisia aineksia, jotka ovat lähellä alkuperäistä mallia, Anni Tennisovan laulua.

Suurimmat erot Tennisovan laulun ja mallin generoimien toisintojen välillä ilmenevät rytmisissä. Sävelten kestot ovat vain likimäärin oikeita. Rytmiset ideat ovat joissain tapauksissa (ks. esim. tahti 5) täysin samat kuin Anni Tennisovalla, mutta usein sävelten kestot poikkeavat Tennisovan ja muidenkin runonlaulajien tyylistä. Erityisesti on huomattava, että kestojen epätarkkuus aiheuttaa huomattavia virheitä metriin. Sävelten tai iskualojen määrä säkeissä ei ole oikea (ks. esim. tahti 6). Generoimien tulos muistuttaakin laulajaa, joka muistaa kohtalaisen hyvin melodiset kuviot ja muuntelee niitä tyylinmukaisesti, mutta jolta puuttuu lähes kokonaan käsitys metrissä. Nämä piirteet, varsinkin metrin heilahtelu, löytyvät usein alle kouluikäisten lasten lauluista (Fredrikson 1994).

Tässä tutkimuksessa käytetyn mallin merkittävänä piirteenä on se, ettei siinä ole oletettu sisäänrakennettua ”rytmikonetta”, tai modulia, joka käsittelee erikseen sävelten kestoja, rytmiä tai metriä. Tästä huolimatta malli kykenee tuottamaan kohtuullisen hyvin myös rytmin. Sävelten kestot syntyvät ”intuitiivisesti” eli malli oppii, kuinka pitkään pitäisi viipyä tietyillä sävelkorkeuksilla. Ihmisillä on usein laulaessaan tai soittaessaan tapana liikuttaa kehoaan, taputtaa käsiään tai ”polkea jalkaa” säännönmukaisesti. Tämä epäilemättä auttaa ajoittamaan sävelet oikein. Tarkoituksenamme onkin seuraavassa vaiheessa liittää verkon syötteestä muodostettuihin vektoreihin jalan lyönnistä syntyvä uusi vektori, joka todennäköisesti vaikuttaa mallin generoimien toisintojen rytmiseen tarkkuuteen. Mallin tuottamat generaatiot viittaavat joka tapauksessa siihen, että laulajien ja soittajien tapa käyttää metrin hahmottamista auttavia apukeinoja (jalanlyönti jne.) liittyy aivojemme vaikeuksiin käsitellä sävelten kestoja. Tutkimuksen tässä vaiheessa näyttää täysin mahdolliselta, ettei rytmin ja metrin hahmottamiseen ja tuottamiseen tarvitse olettaa sisäistä kelloa tai muuta rytminkäsittelyyn erikoistunutta modulia.

Aikaisemmissa runonlaulua koskevissa tutkimuksissa (Louhivuori 1992) mallin tuottamat generaatiot ovat olleet rytmisesti selvästi lähempänä alkuperäistä mallia kuin tässä tutkimuksessa. Tämä johtuu tavasta, jolla aikaisempi malli oli rakennettu. Siinä sävelten kestot oli etukäteen vakioitu; kyseinen malli ei perustunut itseorganisoitumiseen, vaan tutkija eli mallin rakentaja määräsi sävelten keston perusyksikön (yksi neuronisarake vastasi 1/8-osa kestoja). Otet-

taessa käyttöön ekologisesti validimpi verkkomalli, generoinnin tulokset ovat heikentyneet, mutta mallin uskottavuus lisääntynyt. Samoin kuin alle kouluikäisten lasten laulun, myös keinotekoisien mallien suorituskyvyn voidaan odottaa paranevan rytmikankin osalta, jos sille annetaan enemmän harjoitusta ja rikkaampaa musiikin kuvausta.

## Päätelmät

Lukuunottamatta metriä ja rytmiä koskevia ongelmia, generoiva keinotekoinen hermoverkkomalli kykeni oppimaan keskeiset Anni Tenisovan lauluun liittyvät musiikilliset piirteet. Malli auttaa ymmärtämään entistä paremmin mitä runonlaulu ja laajemmin tulkittuna musiikin oppiminen muistinvaraisesten kulttuurien tuotoksissa (esimerkiksi eepinen runous) itse asiassa tarkoittaa. Samalla saadaan yleisemminkin kognitiivisia prosesseja, erityisesti muistia ja ajankäsittelyä, koskevaa tietoa. Erityisen merkittävänä pidämme tässä artikkelissa esitellyn mallin avulla saatua tietoa, joka koskee kognitiivisen systeemin tapaa käsitellä aikasidonnaisia, dynaamisia ilmiöitä, kuten esimerkiksi kieltä ja musiikkia.

## Huomautus

Tämä tutkimus on toteutettu Suomen Akatemian rahoituksen turvin.

## Lähteet

- Ans, B. & Coiton, Y. & Gilhodes, J.-C. & Velay, J.-L. 1994. A Neural Network Model for Temporal Sequence Learning and Motor Programming. *Neural Networks* 7 (9): 1461–1476.
- Baroni, M. et al. 1984. A grammar for melody. Teoksessa *Musical Grammars and Computer Analysis*. Toim. M. Baroni & L. Callegari. Firenze: Olschki.
- Bel, B & Kippen, J. 1992. Bol processor grammars. Teoksessa *Understanding music with AI: perspectives in music cognition*. Toim. M. Balaban, K. Ebcioglu & O. Laske. Cambridge, MA: MIT Press.
- Bernstein, J. 1981. Profiles: AI, Marvin Minsky. *New Yorker* 1981, Dec 14.
- Bharucha, J. & Todd, P. 1989. Modeling the Perception of Tonal Structure with Neural Nets. *Computer Music Journal* 13 (4): 44–53.
- Chappell, G. J. & Taylor, J. G. 1993. The Temporal Kohonen Map. *Neural Networks* 6 (3): 441–445.

- Cottrell, G. W. & Munro, P. W. & Zipser, D. 1987. Image processing by back-propagation: A demonstration of extensional programming. Teoksessa *Advances in cognitive science (Vol. 2)*. Toim. N. E. Sharkey. Chichester, England: Ellis.
- Ebcioğlu, K. 1988. An expert system for harmonizing four-part chorales. *Computer Music Journal* 12: 43–51.
- Elman, J. 1990. Finding structure in time. *Cognitive Science* 14: 179–211.
- Elman, J. & Zipser, D. 1988. Learning the hidden structure of speech. *Journal of Acoustical Society of America* 83: 615–626.
- Fredrikson, M. 1994. *Spontaanit laulutoisinnot ja enkulturaatioprosessi*. Jyväskylä Studies in the Arts 43. Jyväskylä: University of Jyväskylä.
- Gjerdingen, R. 1989. Using Connectionist Models to Explore Complex Musical Patterns. *Computer Music Journal* 13 (3).
- Gjerdingen, R. 1990. Categorization of Musical Patterns by Self-Organizing Neuronlike Networks. *Music Perception* 7 (4): 339–370.
- Grossberg, S. 1987a. A massively parallel architecture for self-organizing neural pattern recognition machine. *Computer Vision, Graphic and Image Processing* 37: 54–115.
- Grossberg, S. 1987b. Competitive Learning: From Interactive Activation to Adaptive Resonance. *Cognitive Science* 11: 23–63.
- Hanson, S. J. & Kegl, J. 1987. Parsnip: A connectionist network that learns natural language grammar from exposure to natural language sentences. Hillsdale, NJ: Erlbaum. Ninth Conference of the Cognitive Science Society, Seattle, WA.
- Jordan, M. I. 1986. *Serial order: A parallel processing approach*. ICS Report 8604. San Diego: University of California, Center for Human Information Processing.
- Kaipainen, M. 1994. *Dynamics of Musical Knowledge Ecology. Knowing-What and Knowing-How in the World of Sounds*. Helsinki: Acta Musicologica Fennica 19.
- Kaipainen, M. & Toiviainen, P. & Louhivuori, J. 1995. A self-organizing map that generates melodies. *New Directions in Cognitive Science*. Pylkkänen, Pylkkö. Proceedings of the International Symposium: 286–315.
- Kangas, J. 1991. Time-dependent self-organizing maps for speech recognition. Teoksessa *Artificial Neural Networks. Proceedings of the ICANN-91, Espoo, Finland*. T. Kohonen & K. Mäkisara & O. Simula, & J. Kangas. North-Holland: Elsevier Science.
- Kippen, J. 1988. *The tabla of Lucknow: a cultural analysis of a musical tradition*. Cambridge studies in ethnomusicology. Cambridge; New York: Cambridge University Press.
- Kohonen, T. 1982. Self-organized formation of topologically correct feature maps. *Biological Cybernetics* 43: 59–69.

- Kohonen, T. 1984. *Self-Organisation and Associative Memory*. Berlin etc.: Springer-Verlag.
- Kohonen, T. 1990. The Self-Organizing Map. *Proceedings of the IEEE* 78 (9).
- Kunst, J. 1978. *Making Sense in Music: An Enquiry into the Pragmatics of Art*. Ghent: Communication & Cognition.
- Lauter, J. L. & Hersovitch, P. & Formby, C. & Raichle, M. R. 1985. Tonotopic organization in the Human Auditory Cortex Revealed by Positron Emission Tomography. *Hearing Research* 20: 199–205.
- Lerdahl, F. & Jackendoff, R. 1983. *A generative theory of tonal music*. Cambridge: The MIT Press.
- Lord, A. 1960. *The Singer of Tales*. Harvard Studies in Comparative Literature 24. Cambridge, Massachusetts.
- Louhivuori, J. 1992. Keinotekoiset hermoverkot ja sävelmätoisinnot. Teoksessa *Kognitiivinen musiikkitiede*. Jyväskylän yliopiston musiikkitieteen laitoksen julkaisusarja A: tutkielmia ja raportteja 8. S. 169–190.
- Meyer, L. 1956. *Emotion and meaning in music*. Chicago: University of Chicago Press.
- Morasso, P. 1991. Self-organizing feature-maps for cursive script recognition. Teoksessa *Artificial Neural Networks. Proceedings of the ICANN-91, Espoo, Finland*. T. Kohonen & K. Mäkisara & O. Simula & J. Kangas. North-Holland: Elsevier Science.
- Mozer, M. C. 1991. Connectionist Music Composition Based on Melodic, Stylistic, and Psychophysical Constraints. Teoksessa *Connectionism and Music*. P. Todd & G. Loy. Cambridge, MA: MIT Press.
- Narmour, E. 1990. *The analysis and cognition of basic melodic structures: the implication-realization model*. Chicago: University of Chicago Press.
- Page, M. P. A. 1994. Modelling the perception of musical sequences with self-organizing neural networks. *Connection Science* 6 (2) & (3).
- Parry, M. 1930. Studies in the epic technique of oral versemaking: Homer and the Homeric style. *Harvard Studies in Classical Philology* 41: 73–147.
- Port, R. F. 1990. Representation and recognition of temporal patterns. *Connection Science* 2 (1 & 2): 151–175.
- Reiss, M. & Taylor, J. G. 1991. Storing Temporal Sequences. *Neural Networks* 5 (6): 961–970.
- Rumelhart, D. & Hinton, G. & Williams, R. 1986. Learning Internal Representations by Error Propagation. Teoksessa *Parallel Distributed Processing: Explorations in the microstructure of cognition. 1. Foundations*. J. L. McClelland & D. E. Rumelhart and the PDP Research Group 1986. Cambridge: MIT Press. [Myös *Nature* 323, 533–536.]
- Rumelhart, D. & Zipser, D. 1985. Feature Discovery by Competitive Learning. *Cognitive Science* 9: 75–112.

- Sundberg, J. & Lindblom, B. 1975. A Generative Theory of Swedish Nursery Tunes. Teoksessa *Proceedings of the 1st International Congress on Semiotics of Music, Belgrade oct 1973*. Toim. G. Stefani. Pesaro: Centro di Iniziativa Culturale.
- Sundberg J. & Lindblom B. 1976: Generative theories in language and music descriptions. *Cognition* 4: 99–122.
- Szentagothai, J. 1975. The 'module concept' in cerebral cortex architecture. *Brain Research* 95: 475–496.
- Teitler, L. 1974. Homer and Gregory: The Transmission of Epic Poetry and Plainchant. *The Musical Quarterly* 60 (3): 333–372.
- Todd, P. 1989. A connectionist Approach to Algorithmic Composition. *Computer Music Journal* 13 (4): 27–43.
- Toiviainen, P. 1995. Modeling the target-note technique of bebop-style jazz improvisation: an artificial neural network approach. *Music Perception* 12 (4): 399–413.
- Toiviainen, P. 1996. Optimizing Auditory Images and Distance Metrics for Self-Organizing Timbre Maps. *Journal of New Music Research* 25 (1): 1–30.

# Liite

Anni Tenisovan runonlaulua ja keinotekoisien hermoverkon generoimia toisintoja.

The image displays a musical score for a piece titled "Anni Tenisova" and "Keinotekoisien hermoverkon generoimia toisintoja". The score is written in a single system with eight measures, numbered 1 through 8. It consists of seven staves, all in treble clef. The first staff is labeled "Anni Tenisova" and the second staff is labeled "Keinotekoisien hermoverkon generoimia toisintoja". The music is written in a 2/4 time signature. The first four measures (1-4) show the original melody and its imitation by the artificial neural network. The last four measures (5-8) show further variations and imitations of the melody. The notation includes quarter notes, eighth notes, and sixteenth notes, with some rests and dynamic markings.