

TAMPEREEN YLIOPISTO
Johtamiskorkeakoulu

**NEUROVERKKOPOHJAISEN
SIJOITUSSTRATEGIAN HYÖDYNTÄMINEN
INDEKSIOUSUUSRAHASTON ENNUSTAMISESSA**

Taloustiede
Pro gradu -tutkielma
Joulukuu 2017
Ohjaaja: Jari Vainiomäki

Junno Heiskanen

TIIVISTELMÄ

Tampereen yliopisto

Johtamiskorkeakoulu

Heiskanen Junno: Neuroverkkopohjaisen sijoitusstrategian hyödyntäminen indeksiosuusrahaston ennustamisessa

Pro gradu -tutkielma: 82 sivua, 3 liitesivua

Taloustiede

Joulukuu 2017

Tässä tutkimuksessa selvitetään, voiko koulutettua keinotekoista neuroverkkoa hyödyntää indeksiosuusrahaston ennustamisessa. Tutkimuksen teoriataustana käytetään tehokkaiden markkinoiden hypoteesia. Markkinoiden toimiessa tehokkaasti kaikki julkinen ja yrityksen arvon kannalta oleellinen uusi tieto heijastuu välittömästi ja täysimääräisesti arvopapereiden hintoihin. Tehokkailla markkinoilla yksittäinen sijoittaja ei voi saavuttaa säännöllisesti markkinoiden riskikorjattua tuottoa ylittävää ylituottoa.

Tutkimuksen teoriaosuus perustuu rahoituksen taloustieteeseen ja menetelmäosuus koneoppimiseen. Tutkimusmenetelmänä käytetään keinotekoista neuroverkkoa, joka koulutetaan oppimaan rahoitusmarkkinoilta saatavien syötteiden avulla hinnan muodostumisen mekanismia. Koulutuksessa opittua mekanismia hyödynnetään seuraavan päivän indeksiosuusrahaston hintojen ennustamisessa. Oppimisalgoritmina käytetään Levenberg-Marquardt algoritmia. Algoritmin ennusteita muokataan erilaisten sijoitusstrategioiden avulla tarkempien ennusteiden saavuttamiseksi.

Tämän tutkimuksen kohteena ovat pörssinoteeratun iShares Core S&P 500 -rahaston päätöskurssihinnat vuodesta 2005 vuoden 2015 loppuun. Aineistona käytetään S&P 500 -indeksistä johdettua historiallista aikasarja-aineistoa 1950-luvulta lähtien. Tutkimuksen mukaan neuroverkkoa voidaan hyödyntää iShares Core S&P 500 -indeksiosuusrahaston tuottojen suunnan ennustamisessa. Transaktiokustannusten ollessa alhaiset neuroverkosta johdetuilla ennusteilla saavutetaan hyviä tuottoja, muttei kuitenkaan markkinoiden riskikorjattua tuottoa ylittävää ylituottoa.

SISÄLLYS

1 JOHDANTO.....	5
2 TEHOKKAIDEN MARKKINOIDEN HYPOTEESI.....	10
3 NEUROVERKOT	16
3.1 Neuroverkkojen biologiset lähtökohdat.....	16
3.2 Keinotekoisien neuroverkkojen historia.....	18
3.3 Neuroverkot osakemarkkinoiden nykytutkimuksessa.....	19
4 TUTKIMUSMENETELMÄT	25
4.1 Neuroverkkojen elementit	26
4.2 Monikerroksinen neuroverkko	29
4.3 Koneoppiminen	31
4.3.1 Virhefunktiot	31
4.3.2 Delta-säätö.....	33
4.3.3 Taaksepäin levitys -menetelmä	35
4.3.4 Gradientti	36
4.3.5 Gauss-Newton algoritmi.....	40
4.3.6 Levenberg-Marquardt algoritmi	42
5. AINEISTO.....	45
5.1 Aineiston käsittely	48
5.2 Ennustettava aineisto	49
5.3 Sijoitusstrategian luominen	52
5.4 Koulutuksen laadun tarkkailu	57
5.5 Strategian valitsemisjakso	58
5.6 Transaktiokustannukset	59

6 TEHOKKAIDEN MARKKINOIDEN JA NEUROVERKKOPOHJAISTEN STRATEGIOIDEN TESTAUS.....	63
6.1 Aineiston jakaminen strategian valitsemista varten	65
6.2 Strategian valitseminen.....	67
6.2.1 Strategian valitsemisjakson koulutus	67
6.2.2 Strategian valitsemisjakson testaus	69
6.2.3 Strategian lopullinen valitseminen	72
6.3 Valittujen strategioiden testaaminen	73
6.3.1 Neuroverkon kouluttaminen ennustejaksoille	73
6.3.2 Neuroverkon ennusteet	75
6.3.3 Strategioiden ennusteet.....	76
6.3.4 Transaktiokustannusten huomioiminen.....	81
7 JOHTOPÄÄTÖKSET	85
LÄHTEET	87
LIITTEET	93

1 JOHDANTO

Teknologian kautta tallentunut yksityiskohtainen informaatio suurten ihmisjoukkojen päivittäisistä taloudellisista toiminnoista kannustaa uusien tutkimusmenetelmien ja näkökulmien löytämiseen. Myös taloustieteen sisällä on etsitty uusia lähestymistapoja suurten aikasarja-aineistojen tutkimiseen. Tämä tutkimus hyödyntää koneoppimiseen pohjautuvia menetelmiä rahoitusmarkkinoilta saataviin aikasarja-aineistoihin ja esittelee saadut tulokset.

Tutkimuksen lähestymistapoja ja menetelmiä on lainattu muun muassa teknisiltä aloilta. Näkökulmaa kutsutaan nimellä matemaattinen rahoitus tai taloustekniikka (financial engineering). Tällä tarkoitetaan innovatiivisten taloudellisten instrumenttien ja prosessien suunnittelemista, kehittämistä ja implementointia sekä luovien ratkaisujen löytämistä taloudellisiin ongelmiin (Finnerty 1988). Perinteisesti taloustieteessä innovaation määritelmä ei pidä sisällään pelkästään uusien ja erilaisten taloudellisten instrumenttien luomista, vaan se tarkoittaa myös uusien taloudellisten instituutioiden syntymistä ja kehittymistä (Mason, Merton, Perold & Tufano 1995). Innovaatiot, jotka auttavat ymmärtämään muuttuvaa taloudellista ympäristöä, voivat olla suureksi hyödyksi koko yhteiskunnalle. Hyödyllisiä ovat muun muassa innovaatiot, jotka edesauttavat taloudellisten resurssien tehokkaampaa allokaatiota markkinoilla.

Taloustieteessä käsitteiden markkinat ja tehokkuus määrittelemisen sekä niiden tarpeellisuus ovat tutkimuksen kohteita jo itsessään ja tästä syystä hankalia lähestyä. Taloustieteen alahaaralla rahoituksella sen sijaan on ollut pitkään vakiintunut teoriakehikko osakemarkkinoista ja niiden tehokkuudesta ja juuri tästä syystä osakemarkkinat ovat erinomainen tutkimuskohde. Leppiniemen (2000) mukaan rahoituksen taloustieteellä tarkoitetaan taloustieteen alahaaraa, jonka tehtävänä on analysoida taloudellisen arvon syntymistä, rahoitusinstrumenttien hinnoittelua rahoitusmarkkinoilla sekä yrityksen rahoituksen saatavuutta, riittävyttä ja kustannuksia.

Hinnan muodostumista osakemarkkinoilla on jo pitkään tutkittu vertaamalla sitä rahoituksen tunnetuimpaan hypoteesiin, joka tunnetaan nimellä tehokkaiden markkinoiden hypoteesi. Hypoteesin mukaan tehokkailla osakemarkkinoilla osakkeen hinta pitää sisällään kaiken mahdollisen tiedossa olevan fundamentti-informaation, minkä seurauksena vain ennakoimaton uusi informaatio voi muuttaa osakkeen hintaa. (Fama 1970.) Tästä johtuen osakemarkkinoiden hintojen ailahtelun on

sanottu seuraavan satunnaiskulkua (Malkiel 1985). Markkinoiden ollessa tehokkaat yksittäinen sijoittaja ei voi säännöllisesti voittaa markkinoita, eli saavuttaa markkinoiden riskikorjattua tuottoa ylittävää ylituottoa (Knüpfer & Puttonen 2009, 161–167). Hypoteesin seurauksena osakemarkkinoita koskeva tutkimus on kehittynyt suuntaan, jossa markkinoiden tehokkuuden tutkiminen ja markkinoiden hintakehityksen ennustaminen ovat nivoutuneet saman asian tarkastelemiseksi kahdesta eri näkökulmasta.

Tehokkaiden markkinoiden hypoteesi ja satunnaiskulun teoria (random walk theory) ovat saaneet osakseen paljon kritiikkiä. Behavioristinen taloustiede yhdessä älykkään rahoituksen (intelligent finance) kanssa ovat osoittaneet useasti rahoitusmarkkinoiden tehottomuuden. Markkinat eivät edellä mainittujen tutkimushaarojen mukaan seuraa satunnaiskulkua ainakaan jatkuvasti, minkä lisäksi erilaisia hyödynnettäviä tehottomuuksia ilmenee. (Pan 2003, 3–4.)

Menetelmien lisääntyessä ja laskentatehon kehittyessä tutkijoille tarjoutuu jatkuvasti uusia tapoja rahoitusmarkkinoiden liikkeiden ennustamiseen. Erityisesti tekoälyn ja erilaisten keinotekoisien neuroverkkojen hyödyntäminen rahoitusmarkkinoiden ennustamisessa on saanut paljon huomiota 1990-luvun jälkeen tehdyissä tutkimuksissa. Osa tutkijoista uskoo tekoälyn kykyyn ratkaista inhimillisen käyttäytymisen lainalaisuudet rahoitusmarkkinoilla, kun taas osalle tekoälyn epäonnistuminen tai sen nopea muuttuminen hyödyttömäksi on osoitus tehokkaiden markkinoiden hypoteesin paikkansapitävyydestä.

Tässä tutkimuksessa esitellään useita älykkään rahoituksen tutkimuksia, jotka ovat hyödyntäneet erilaisia neuroverkkoja ja sitä kautta osoittaneet, että tietty ryhmä markkinatoimijoita pystyy hyödyntämään menetelmiään keskivertoa suurempien tuottojen tavoittelussa. Tämä antaa aiheutta tehokkaiden markkinoiden hypoteesin epäilemiseen. Ennustamalla markkinoiden hintojen vaihtelua ja toimimalla ennusteiden suuntaisesti markkinatoimijoilla saattaa olla mahdollisuus suuriin taloudellisiin voittoihin. Voittojen tavoittelun voidaankin sanoa olevan pääsääntöinen syy osakemarkkinoiden tutkimiseen.

Rahoitusmarkkinoilta saatavien aikasarjamallien analysoiminen on ollut osakemarkkinoita ennustavien tutkijoiden suosiossa aina 1970-luvulta lähtien. Aikasarjojen mallintamiseen on useita erilaisia lähestymistapoja. Tyypilliset tilastolliset lähestymistavat, kuten liikkuva keskiarvo, eksponenttitasointi ja ARIMA, ovat vain muutamia esimerkkejä perinteisistä lineaarisista malleista, joita on hyödynnetty osakemarkkinoiden ennustamisessa. (Asadi, Hadavandi, Mehmanpazir &

Nakhostin 2012, 246.) Liiallinen epälineaarisuus aineistossa saattaa johtaa siihen, ettei siitä voida muodostaa sopivaa ennalta määriteltyä lineaarista mallia, joka pystyy yleistämään aineiston keskeiset ominaisuudet (Zhang, Patuwo & Hu 1998, 36).

Toinen lähestymistapa aikasarjojen mallintamiseen löytyy näkökulmasta, jossa markkinoiden oletetaan olevan kaoottinen systeemi (chaos system). Matemaattisesti kaoottinen järjestelmä voi olla täysin ennustettavissa, jos alkuarvot ja prosessi tunnetaan. Ainoastaan alkuarvo- ja laskentatarkkuus ovat ennustehorisonttia rajoittavia tekijöitä. Toisin sanoen rahoitusmarkkinat oletetaan epälineaariseksi deterministiseksi systeemiksi, joka vain vaikuttaa satunnaiselta (Asadi ym. 2012, 246). Älykkäät systeemit, jotka oppivat aikaisemmista kokemuksistaan, voivat oppia kaoottisia systeemejä (Lapedes & Farber 1988). Oppimisen lisäksi älykkäät systeemit kykenevät hyödyntämään oppimaansa päätöksentekotilanteissa. Tekoäly on yksi tällainen älykäs systeemi, joka voidaan ohjelmoida selvittämään ihmisen toiminnan säännönmukaisuuksia ja ennustamaan niiden pohjalta tulevia tapahtumia.

Useat tekoälyä apuna käyttäneet tutkimukset ovat löytäneet rahoitusmarkkinoista säännönmukaisuuksia ja onnistuneet hyödyntämään niitä (Asadi ym. 2012, 246). Keinotekoiset neuroverkot ovat osoittautuneet hyväksi tekoälyä hyödyntäväksi menetelmäksi, sillä ne voivat oppia monimutkaisiakin yhteyksiä selittävien muuttujien ja selitettävien muuttujien välillä. Keinotekoiset neuroverkot pohjautuvat fyysisten aivojen biologisiin, neuronien keskenään luomiin verkostoihin, jotka kykenevät käsittelemään puutteellista informaatiota, vahvistamaan keskeisiä yhteyksiä ja yleistämään kokemaansa informaatiota. (Haykin 2009, 2–4.)

Useat tutkijat ovat vertailleet tekoälypohjaisten menetelmien ja perinteisten menetelmien kuten ARIMA- ja regressiomallin tuloksia ja havainneet, että tekoälyyn perustuvilla menetelmillä saadaan parempia tuloksia (esimerkiksi Werbos 1988; Hill, Connor, & Remus 1996; Kohzadi, Boyd, Kermanshahi, & Kaastra 1996; Adya & Collopy 1998; Zhang & Qi 2005; Ghanbari, Hadavandi & Shavandi 2010); Lee & Tong 2011). Tämä on johtanut useisiin uusiin tutkimuksiin, jotka keskittyvät osakemarkkinoiden ennustamiseen tekoälyn avulla. Atsalakis ja Valavanis (2009) esittävät, että osakemarkkinoiden ennustamisesta viime vuosina tehdyistä tutkimuksista 60 prosentissa käytettiin myötäsyytteistä neuroverkkoa (feed forward network) tai toistuvaa neuroverkkoa (recurrent network).

Vaurastumisen tavoittelun lisäksi älykkäiden systeemien hyödyntäminen osakemarkkinoilla voi oikeissa käsissä vakauttaa yhteiskuntaa. Älykkäät systeemit voivat mahdollistaa entistä nopeamman talouspoliittisen reagoimisen talouden shokkeihin ja näin myös auttaa estämään mahdollisten kriisien eskaloitumisen. Älykkäillä systeemeillä on potentiaalia tunnistaa monimutkaisia yhteyksiä yhteiskunnan tuottamasta kokonaisaineistosta, mikä voi auttaa tulevaisuuden riskien hallinnassa ja erilaisten vakausmekanismien luomisessa. Käytännössä älykkäiden systeemien hyödyntäminen suurten aineistojen käsittelyssä on vasta alussa ja siksi se ansaitsee osakseen laajempaa tutkimusta.

Tämän tutkimuksen kohteena ovat pörssinoteeratun iShares Core S&P 500 -rahaston päätöskurssitilatostot vuodesta 2005 vuoden 2015 loppuun. Pörssinoteerattu rahasto on niin sanottu indeksiosuusrahasto eli se pyrkii seuraamaan S&P 500 -indeksin kehitystä mahdollisimman tarkasti. Aineistona käytetään päivittäin noteeratusta S&P 500 -indeksistä johdettua aikasarja-aineistoa alkamisajankohdasta 3.1.1950 eteenpäin aina siihen saakka, kunnes pörssinoteerattu iShares Core S&P 500 -rahasto perustetaan 19.5.2000. Tästä hetkestä eteenpäin aineistona käytetään pörssinoteeratusta rahastosta saatavaa aikasarjaa. Aineistosta muokataan 28 muuttujaa, joita hyödynnetään neuroverkon koulutuksessa.

Tutkimuksessa tutkitaan, voiko keinotekoista neuroverkkoa hyödyntää indeksiosuusrahaston tulevien tuottojen ennustamisessa. Neuroverkon oppimisalgoritmina käytetään Levenberg-Marquardt algoritmia. Ennusteista irrotetaan keskeiset sijoituspäätöksiin vaikuttavat tekijät tutkijan kehittämällä sijoitusstrategioilla. Valittujen sijoitusstrategioiden tuloksia verrataan tehokkaiden markkinoiden hypoteesiin sekä siitä johdettuun osta ja pidä -strategiaan. Kokonaiskustannuksiltaan pienen osta ja pidä -strategian tulisi tehokkaiden markkinoiden hypoteesin vallitessa olla tuottavin sijoitusstrategia suhteessa sijoittajan ottamaan riskiin.

Tutkimuksessa vastataan kysymyksiin:

1. Täyttääkö iShares Core S&P 500 -rahasto tehokkaiden markkinoiden hypoteesin vaatimukset?
2. Tuottaako iShares Core S&P 500 -rahaston arvovaihtelua hyödyntävä neuroverkkopohjainen sijoitusstrategia osta ja pidä -strategiaa enemmän?

Tämän tutkimuksen tulokset osoittavat, että keinotekoista neuroverkkoa voidaan hyödyntää osakemarkkinoiden ennustamisessa huolimatta siitä, että aineisto sisältää kohinaa. Neuroverkokolla luodut ennusteet ovat kohinasta johtuen naiiveja ennusteita ja vaativat jälkikäsitteilyä hyvien tulosten

saavuttamiseksi. Jälkikäsitteilyllä tarkoitetaan tässä yhteydessä sitä, että neuroverkon ennusteet syötetään erilaisille sijoitusstrategioille, jotka tekevät lopullisen ennusteen rahaston tuottojen kehittymisen suunnasta. Neuroverkon ennusteiden pohjalta luodut sijoitusstrategiat voittavat iShares Core S&P 500 -rahastosta tehdyn osta ja pidä -vertailuindeksin. Neuroverkkopohjaiset strategiat ottavat kuitenkin osta ja pidä -strategiaa enemmän riskiä, minkä takia tehokkaiden markkinoiden hypoteesia ei voida hylätä.

Tutkimus etenee siten, että toisessa luvussa esitellään tehokkaiden markkinoiden teorian keskeiset osa-alueet ja rajataan tutkimushypoteesi. Kolmannessa luvussa käsitellään neuroverkkoja yleisesti mukaan lukien sekä neuroverkkojen kehityshistoria että nykytutkimus rahoitusmarkkinoilla. Neljännessä luvussa käydään läpi tutkimuksessa käytettävät neuroverkkopohjaiset tutkimusmenetelmät sekä niistä johdetut sijoitusstrategiat. Viidennessä luvussa esitellään neuroverkon koulutuksessa ja ennustamisessa käytettävä aineisto muokkauksineen. Kuudennessa luvussa esitellään tutkimustulokset, joita vertaillaan osta ja pidä -strategian tuloksiin. Viimeisessä luvussa esitellään jatkotutkimuksen kohteet sekä johtopäätökset tuloksista.

2 TEHOKKAIDEN MARKKINOIDEN HYPOTEESI

Eugene Faman vuonna 1970 kehittämän tehokkaiden markkinoiden hypoteesin mukaan yksittäisten arvopapereiden hinnat heijastavat täysin kaiken saatavilla olevan informaation (Fama 1991, 1575). Toisin sanoen ihanteelliset rahoitusmarkkinat ovat sellaiset, joilla hinnat heijastavat oikeita signaaleja resurssien allokoinnista. Hypoteesissa tehokkuus on rajattu tarkoittamaan informaation tehokkuutta. Informaatiotehokkailla markkinoilla yritysten osakkeiden hinnat reagoivat viiveettä yrityksen varallisuuteen sekä tuotto-odotuksia koskevaan uuteen informaatioon eli fundamentti-informaatioon. Tämän uuden informaation vaikutus tuotto-odotuksiin tai varallisuuteen ja sitä kautta myös yrityksen osakkeen hintaan on luonteeltaan satunnaista tulevaisuudesta johtuvan epävarmuuden vuoksi. (Fama 1970.)

Faman (1970) mukaan informaatiotehokkaille markkinoille asetetaan tiettyjä vaatimuksia. Informaatiotehokkailla markkinoilla arvopaperikaupassa ei saa olla kaupankäynnistä tai informaation keräämisestä syntyviä kustannuksia. Lisäksi kaikkien markkinatoimijoiden tulee tulkita informaation vaikutukset samalla tavalla nykyisiin sekä tuleviin hintajakaumiin. (Fama 1970, 387.) Näistä ehdoista voimme päätellä, että täydellisen informaatiotehokkuuden vaatimuksia täyttäviä markkinoita löytyy tuskin koskaan. Alamme kuitenkin tällä hetkellä lähentyä tilannetta, jossa markkinainformaatio on suurelta osin ilmaista ja helposti saatavilla. Kiristynyt kilpailu arvo-osuustilejä välittävien internetpankkien kesken on myös laskenut transaktiokustannukset murto-osaan edellisten vuosikymmenten kustannuksista.

Edellä esitetyt ehdot eivät kuitenkaan ole välttämättömiä markkinoiden tehokkuudelle, sillä transaktiokustannuksista huolimatta hinnat reagoivat täydellisesti informaatioon transaktioiden toteuduttua. Lisäksi markkinoiden tehokkuuden näkökulmasta on riittävää, että tarpeeksi suuri määrä toimijoita saa kaiken osakkeen hintaan vaikuttavan relevantin informaation. Sijoittajien tulkinta informaatiosta ei myöskään tee markkinoista tehottomia niin kauan kuin mikään toimijaryhmä ei kykene systemaattisesti ylittämään markkinatuottoja omilla sijoituksillaan. (Fama 1970, 387–388.)

Tehokkaiden markkinoiden hypoteesin teoreettisena pohjana on lisäksi kolme oletusta. Ensimmäiseksi sijoittajien oletetaan olevan rationaalisia ja näin arvopapereiden arvostustasot ovat rationaalisesti määräytyneet. Toiseksi epärationaalisten sijoittajien tekemät transaktiot ovat

satunnaisia ja näin kumoavat toisensa. Kolmanneksi irrationaaliset sijoittajat kohtaavat markkinoilla samassa määrin rationaalisia arbitraasin hyödyntäjiä, jotka eliminoivat irrationaalisten toimijoiden vaikutuksen hintoihin. (Sheifer 2000, 2.)

Kun sijoittajat ovat rationaalisia, he arvostavat jokaisen arvopaperin sen fundamenttiarvoon eli yrityksen kassavirtojen nettonykyarvoon. Diskonttauksessa käytetään yrityksen toimintaan vaikuttavia riskitekijöitä. Uusi informaatio, jolla on vaikutusta yrityksen tuloksenteekokykyyn tai varallisuuteen, vaikuttaa välittömästi arvopaperin hintaan nostamalla tai laskelmalla sitä. Tämän seurauksena uusi informaatio sisältyy arvopapereiden hintoihin lähes saman tien ja vastaa tulevien kassavirtojen nettonykyarvoja. Vain uusi ja suunnaltaan satunnainen fundamentti-informaatio voi muuttaa arvopapereiden hintoja. (Sheifer 2000, 2.)

Teknologisesta kehityksestä huolimatta tehokkaan informaatioasetelman täydellistä muotoa, jossa relevantti informaatio on välittömästi kaikkien ulottuvilla, ollaan tuskin saavuttamassa vielä lähitulevaisuudessa. Tehokkaiden markkinoiden hypoteesi onkin äärimmäinen nollahypoteesi, jonka ei odotetakaan toteutuvan kirjaimellisesti. Tämän takia informaatioasetelma on jaettu kolmeen eri luokkaan:

1. Heikon informaatiotason tehokkuus: sisältää kaiken historiallisiin hintoihin tai tuottoihin liittyvän informaation.
2. Puolivahvan informaatiotason tehokkuus: sisältää kaiken julkisesti saatavan informaation.
3. Vahvan informaatiotason tehokkuus: sisältää kaiken informaation, jonka yksittäiset markkinatoimijat tietävät, eli sisäpiiritiedon. (Campbell, Lo & MacKinlay 1997, 22.)

Informaatiotehokkuuden jakaminen empiirisiksi tutkimustasoiksi on hyödyllistä siksi, että se mahdollistaa rajatun hintoihin vaikuttavan informaatiotason havaitsemisen. Seuraava informaatiotehokkuuden taso pitää sisällään edellisen tason informaatiotehokkuuden vaatimukset. Heikon informaation ehtojen tulee täytyä, jotta markkinat ovat tehokkaat puolivahvan muodon perusteella. Myös puolivahvan informaatiotason ehtojen tulee täytyä, jotta vahva muoto olisi voimassa. (Fama 1970, 388.)

Tehokkaiden markkinoiden hypoteesin mukaan heikolla informaatiotasolla sijoittajat eivät voi saada ylituottoja, eli markkinoiden riskikorjattua tuottoa parempaa tuottoa käyttämällä historiallista aineistoa. Tällaisia aineistoja ovat muun muassa hintainformaatioon, historiallisiin volyymeihin ja historiallisiin tuottoihin perustuvat aineistot. Toisin sanoen markkinoilla ei ole muistia, eikä historia

toista itseään. Tämä tarkoittaa sitä, että tekniseen analyysiin pohjautuvat ennusteet eivät tarjoa mahdollisuutta ylituottoihin. Tässä tutkimuksessa keskitytään heikon informaatiotason tehokkuuden tutkimiseen.

Puolivahvassa informaationtehokkuuden tasossa arvopaperien hinnat sisältävät historiallisen informaation lisäksi kaiken nykyisen, julkisesti saatavilla olevan tiedon. Tällöin kaikki arvopaperin arvoon vaikuttava julkinen tieto, kuten tieto tilinpäätöksestä, osinkopolitiikasta ja voittoennusteista, on hinnoiteltu osakekurssin nykyiseen arvoon. Puolivahvan tason ehtojen täytyessä sijoittajat eivät kykene saavuttamaan ylituottoja fundamentti- tai perusteanalyysiä hyödyntämällä. Tutkimuksissa, joissa halutaan analysoida puolivahvaa informaatiotehokkuuden tasoa, tarkkaillaan osakkeen hinnan muutoksen nopeutta suhteessa informaation julkaisuhetkeen. Puolivahvaa informaatiotason tehokkuutta voidaan tutkia esimerkiksi mittaamalla ajallisesti osakkeen hinnan sopeutumista uuteen fundamentti-informaatioon sen julkistamishetkestä eteenpäin. Mitä nopeammin hinta sopeutuu uuteen informaatioon, sitä paremmin puolivahva ehto täyttyy.

Vahvinta informaatiotason tehokkuutta voidaan tutkia sisäpiiri-informaation kautta. Keskeistä on, päästäänkö arvopaperiin liittyvällä sisäpiiri-informaatiolla markkinoiden keskivertotuottoa parempaan tuottoon. Analytikkojen tiedossa on yleisesti, että markkinat täyttävät keskimäärin heikon ja jossain määrin puolivahvan informaatiotason ehdot. Sisäpiiritiedolla on siis yleisten uskomusten mukaan mahdollista saada ylituottoja. (Fama 1970, 409-414.) Fama (1991, 1577–1578) on päivittänyt edellä mainittua informaatioasetelmajaottelua siten, että uudemmassa jaottelussa heikkoon informaatiotasoon on sisällytetty tulevien tuottojen ennustettavuus tilinpäätöksestä saatavilla tunnusluvuilla.

Malkiel (1992) tarjoaa hieman tarkemman selityksen tehokkaille markkinoille. Hänen mukaansa rahoitusmarkkinat ovat tehokkaat, jos arvopapereiden hinnat heijastavat kaiken oleellisen informaation täydellisesti ja oikein osakkeiden hintoihin. Markkinoiden tehokkuuteen vaikuttaa siis informaatioasetelma. Uuden fundamentti-informaation julkituleminen muuttaa välittömästi arvopaperin hintaa, minkä seurauksena yksittäinen sijoittaja ei voi säännöllisesti saavuttaa markkinoiden riskikorjattua tuottoa ylittävää tuottoa eli saada niin sanottua ylituottoa kyseistä informaatiota hyödyntämällä. (Malkiel 1992.) Malkielin (2003) mukaan tehokkailla markkinoilla voi saada keskimääräistä suurempia voittoja, mutta se tarkoittaa samalla keskimääräistä suurempaa riskiä. Näin ollen markkinoita voidaan pitää tehokkaina, vaikka välillä tehdään vääriä arvioita (Malkiel 2003, 60).

Rahoitusmarkkinoilla vallitsevista tasapainoteorioista, kuten CAMP-mallissa (Capital Asset Pricing Model) ja APT:ssä (Arbitrage Pricing Theory), markkinoilla oleva riski jaotetaan kahteen osaan: systemaattiseen ja epäsystemaattiseen riskiin. Rationaalinen toimija pyrkii valitsemaan vain systemaattisia riskejä, koska niille on mahdollista saada rahallista kompensatiota. Sijoittajan tavoitteena on maksimoida sijoitusten odotettua tuottoa ja minimoida sijoituksiin liittyvää riskiä (Jauri 1997, 49; Puttonen & Kivisaari 1997, 73.)

Rahoitusteoriassa riskiä tarkastellaan yleensä todennäköisyysjakaumia hyödyntäen käyttämällä volatilitteettia riskimittarina. Volatilitteetti kuvaa sijoituksen arvon muutoksen heilahtelua, ja laskennallisesti se on tuottojen keskihajonta. Mitä suurempi arvopaperin hinnan vaihteluun liittyvä volatilitteetti on, sitä suurempi on siihen liittyvä riski. (Puttonen & Kivisaari 1997, 78.) Perusajatuksena on, että jokaisella toimijalla on mahdollisuus ansaita lisätuottoa ottamalla suurempaa riskiä (Jauri 1997, 31).

Rahoitusteoriassa riskiä voidaan vertailla esimerkiksi Sharpen luvulla, jonka kehitti Nobel-palkittu taloustieteilijä William F. Sharpe. Menetelmän avulla tutkija voi selvittää sijoituksen tuoton määrän suhteessa sen riskiin. Luku toimii riskin suhdelukuna ja sillä mitataan sijoitusstrategian suorituskykyä. Luku vertaa sijoitukselta odotettua ylituottoa suhteessa sen tuoton volatilitteettiin. Tosin sanoen Sharpen luvulla mitataan sitä, kuinka monta prosenttia lisätuottoa on onnistuttu saaman kutakin riskiyksikköä kohden. (Sharpe 1966, 119–138.) Vertaamalla osta ja pidä -strategian Sharpen lukua valitun sijoitusstrategian Sharpen lukuun tulisi jälkimmäisen olla suurempi kuin osta ja pidä -strategian Sharpen luvun.

Tehokkaiden markkinoiden hypoteesin mukaan pitkäaikaisten sijoittajien tulisi ylituottojen metsästämisestä sijaan keskittyä kustannusten minimoimiseen eli siirtyä aktiivisesta toimijasta passiiviseksi toimijaksi. Uuden arvopaperiin liittyvän fundamentti-informaation nopea leviäminen ja sen tuoma reaaliaikainen arvopaperien hintojen päivittyminen ei välttämättä mahdollista sijoittajalle riittävää kompensatiota suhteessa etsintäkustannuksiin. Passiivinen indeksisijoittaminen taas näyttää houkuttelevammalta vaihtoehdolta. Indeksisijoittamisessa sijoittaja pyrkii tai tyytyy osakepoiminnan sijasta markkinoiden keskivertotuottoihin. Keskivertotuotto on miltei saavutettavissa laajan arvopaperihajauttamisen ja kustannusten minimoimisen myötä. Indeksirahastot tarjoavat helpon keinon juuri tällaisille sijoittajille.

Tehokkaiden markkinoiden hypoteesia on kritisoitu myös sen sisältämien taustaoletusten vuoksi. Hypoteesi ei huomioi kaupankäyntikustannuksia, veroja ja niistä johtuvaa tehottomuutta. Kustannuksista johtuen uusi fundamentti-informaatio ei välttämättä heijastu arvopaperien hintoihin, mikäli tiedon hyödyntämisestä syntyvät kaupankäyntikustannukset ylittävät riskikorjatun tuoton. Jensenin (1978) mukaan riskikorjatun tuoton lisäksi sijoittajien täytyy ottaa huomioon muut kustannukset. Tästä johtuen tehokkaiden markkinoiden hypoteesia testattaessa on myös huomioitava kaupankäyntiin liittyvät kustannukset.

Lisäksi tehokkaiden markkinoiden hypoteesia on kritisoitu muun muassa perustelemalla sitä tehokkaiden markkinoiden -paradoksilla. Sen mukaan markkinoilla tulee olla aina sen verran tehottomuutta, että uuden informaation keräämisestä ja kaupankäynnistä syntyvät kustannukset saadaan katettua. Näin ollen tiedon helppo ja ilmainen saatavuus ei riitä markkinoiden tehokkuuden toteamiseksi. Tämän seurauksena täydellisesti informoidut markkinat ovat käytännön tasolla mahdottomuus, koska markkinatoimijat eivät voi hyötyä uuden informaation keräämisestä, mikä taas johtaa siihen, ettei kaupankäyntiin ole kannustimia. (Grossman & Stiglitz 1980, 400.)

Markkinoiden tehokkuuden testaaminen on osoittautunut empiirisesti haastavaksi tutkimuksen kohteeksi. Tehokkaiden markkinoiden hypoteesin tutkimista on aina tähän päivään asti rajoittanut matemaattisten mallien puutteellisuus. Ongelmasta käytetään nimitystä joint hypothesis -ongelma. Faman (1991) mukaan voimme selvittää, heijastuuko tieto tehokkaasti ja asianmukaisesti rahoitusmarkkinoiden hintoihin, mutta asianmukaisuuden määrittäminen on aina sidoksissa itse tutkimuksessa käytettyyn matemaattiseen malliin ja sen aiheuttamiin rajoituksiin. (Fama 1991, 1575–1617.)

Panin (2003 3–4) mukaan laajat tilastolliset tutkimukset antavat vahvaa näyttöä siitä, että markkinat eivät olet tehokkaat. Hänen mukaansa rahoitusmarkkinat eivät jatkuvasti täytä tehokkaiden markkinoiden vaatimuksia. Toisin sanoen hyödynnettäviä tehottomuuksia ilmenee ja niitä voidaan käyttää markkinoiden keskivertoa suurempien tuottojen tavoittelussa.

Tässä tutkimuksessa tutkitaan tehokkaiden markkinoiden heikkojen informaatioehtojen täyttymistä. Ennustamiseen käytettävä aineisto on rakennettu pelkästään historiallisen hintainformaation pohjalta rakennetuista muuttujista. Tehokkaiden markkinoiden hypoteesin mukaan historiallista aineistoa ei voida hyödyntää markkinoiden keskivertotuottoa korkeampien tuottojen eli ylituottojen tavoittelussa. Tutkimuksessa markkinoiden keskivertotuottoa kuvaa iShares Core S&P 500 -rahastosta luotu osta

ja pidä -strategia. S&P 500 -indeksistä rakennetut pörssinoteeratut rahastot toimivat tyypillisesti analyytikkojen mittapuuna markkinoiden keskiwerolle tuotolle, mitä käytetään myös tässä tutkimuksessa.

3 NEUROVERKOT

Neuroverkot ovat informaation käsittelyn, matematiikan tai laskennan malleja, jotka perustuvat yhdistävään laskentaan. Neuroverkkomallit voivat olla käyttäjälleen mustia laatikoita, jotka toimivat hyvin, mutta joiden yksityiskohtainen toimintaperiaate on niiden sisältämien lukuisten funktioiden vuoksi vaikea ymmärtää (Tähtinen 2009, 46). Tyypillisiä neuroverkon sovelluskohteita ovat ryhmittelyyn, luokitteluun ja regressiomalleihin liittyvät systeemit. Verkon etuna perinteisiin menetelmiin verrattuna on se, ettei malliin valittavien muuttujien välisiä funktiomuotoja tarvitse valita etukäteen (esimerkiksi Adebisi, Adewumi & Ayo 2014, 1; Zhang 2003, 159). Lisäksi neuroverkot ovat tilastollisia menetelmiä, jotka eivät tarvitse minkäänlaista etukäteistietoa tai jakaumaoletuksia. Neuroverkot kykenevät jopa luomaan yleistyksiä annetuista esimerkeistä ja tekemään tietynasteisia mallinnuksia ristiriitaisesta sekä puutteellisesta aineistosta (Tähtinen 2009, 45).

3.1 Neuroverkkojen biologiset lähtökohdat

Biologiset aivosoluverkostot ovat toimineet neuroverkkojen esikuvina kehityksen varhaisessa vaiheessa. Vaikka neuroverkon rakentamisen idea on perustettu aivosoluista koostuvalle verkostolle, poikkeaa se nykymuodossaan hyvin paljon luonnon tarjoamasta esikuvastaan. (Tähtinen 2009, 9.) Neuroverkkoja ei tule mieltää kuvauksena sähkökemiallisesta prosessista vaan pikemminkin pelkistettynä matemaattisena prosessina, jossa määrättyllä syötteellä saadaan ulostulo. Neuroverkkojen tutkimus ja kehitys eroaa jo suurelta osin neurobiologian tarjoamista esimerkeistä.

Matemaattinen kuvaus aivoissa tapahtuvasta neurokemiallisesta prosessista on vielä melko alkeellinen verrattuna ihmisaivojen todellisiin prosesseihin. Ihmisaivot sisältävät arviolta noin 10^{10} laskentayksikköä eli hermosolua, ja näiden hermosolujen välisiä yhteyksiä arvellaan olevan yli 60 biljoonaa. Aivoissa olevien neuronien laaja kytkeytyminen ympäristöön mahdollistaa useiden rinnakkaisten prosessien samanaikaisen suorittamisen, mikä ei ole vielä mahdollista tämän hetkiselte tekoälylle. Aivojen voidaan sanoa olevan monimutkainen, ei-lineaarinen ja rinnakkainen informaation käsittely-yksikkö. (Haykin 1994, 6.) Fausettin (1994, 6–7) mukaan rinnakkain kytketyt pienemmät toimintayksiköt tarjoavat myös varmemman pohjan vikasietoisuudelle. Ihmisaivot

selviytyvät laskentayksikköjen tuhoutumisesta melko hyvin ja oppivat jakamaan hajonneiden yksikköjen tehtäviä ehjänä säilyneille yksiköille. Vikasietoisuus voidaan tässä yhteydessä käsittää aivojen kykyä ymmärtää ennalta tuntemattomia tai aikaisemmasta poikkeavia syötteitä.

Yhteistä tietokoneilla toimiville neuroverkoille ja kemiallisesti toimiville biologisille neuroverkoille on niiden perustoimintalogiikan lisäksi termistö, jolla neuroverkon toimintaa kuvataan. Biologinen hermosolu tai neuroni on aivojen perusyksikkö, jonka voidaan ajatella olevan erillinen analoginen prosessointiyksikkö. Siltä osin, mitä neuronin toiminnasta tiedetään, voidaan sanoa, että neuroni saa useita syötteitä samanaikaisesti ja nämä syötteet summataan yhteen vielä toistaiseksi tuntemattomalla mekanismilla. Mikäli syötteet tai syötteiden summa aktivoi neuronin tarpeeksi siten, että neuronin aktivointikynnysarvo ylittyy, neuroni aktivoituu ja välittää impulssin eteenpäin. Jos syötteet eivät aktivoi neuronin siten, että edellä määrätty aktivoinnin taso tai tiheys saavutetaan, ei neuronin sisäinen aktivoinnin kynnsarvo ylity, ja neuroni jää epäaktiiviseen tilaan. Tällöin neuroni ei välitä informaatiota lainkaan eteenpäin. (Haykin 1994, 6.) Solun toimintamekanismia voidaan kuvata kaikki tai ei mitään -periaatteeksi. Ensimmäisten keinotekoisien neuroverkkojen toisiinsa liitetyt keinotekoiset neuronit toimivat edellä mainitulla mekanismilla ja juuri tästä syystä niitä voidaankin pitää alkeellisena simulaationa hermosolujen toiminnasta.

Aivoissa olevat hermosolut muodostavat monimutkaisen ärsykeisiin ja reaktioihin pohjautuvan verkoston, jossa hermosolut välittävät viestejä keskenään ja vahvistavat usein käytettyjä yhteyksiä harvoin käytettyjen yhteyksien surkastuessa. Neuroverkot ja niihin sovellettava neurolaskenta koettavat jäljitellä ihmisaivojen tapaa toimia ja oppia. Keskeistä biologisille neuroneille on, että ne ovat adaptiivisia järjestelmiä. Näin ollen niitä jäljittelevän neuroverkon on myös oltava adaptiivinen järjestelmä, joka rakentuu ja muokkaa itseään ympäristöstään saamien ärsykkeiden pohjalta. (Haykin 1994, 2.) Keinotekoisien neuroverkon on ensin kyettävä havaitsemaan ympäristöään ja sen jälkeen reagoitava ja mukauduttava ympäristön tarjoaman informaation pohjalta.

Osakemarkkinatutkimuksen näkökulmasta neuroverkon koulutukseen käytettävä aineisto on jo valmiiksi helposti hyödynnettävissä numeerisessa muodossa, eikä erilaisia sensoreita tai hahmontunnistukseen pohjautuvia menetelmiä tarvitse käyttää aineiston saamiseksi. Haykinin (1994) mukaan tekoälyn on havaittu selviytyvän ihmisistä paremmin yksittäisistä, hyvin suunnatuista laskentatehtävistä, jotka eivät vaadi useiden rinnakkaisten prosessien ymmärtämistä samanaikaisesti. Tästä johtuen neuroverkkoihin perustuvaa tekoälyä ei tulisi ensisijaisesti pitää aivojen kaltaisena

laajana informaatiota keräävänä ja käsittelevänä kokonaisuutena vaan pikemminkin pienenä, tarkasti suunnattuna älykkään systeemin osa-alueena.

3.2 Keinotekoisien neuroverkkojen historia

Neuroverkkojen tutkiminen eri akateemisissa piireissä alkoi 1940-luvulla, jolloin lähtökohtana oli tutkimustieto hermojärjestelmän ominaisuuksista. Vastoin useiden tieteenalojen kehitystä neuroverkot ovat ajan saatossa kehittyneet sykleittäin. Ensimmäinen kehityskausi kesti vuodesta 1943 1960-luvulle. Toinen suuri kehityskausi alkoi 1970-luvun lopussa ja on käynnissä edelleen. (Tähtinen 2009, 9.)

Neuroverkkojen tieteellisen tutkimuksen taustalla ovat oppimisen, ehdollistamisen ja neurofysiologian teorit, jotka saivat alkunsa jo 1800- ja 1900-lukujen vaihteessa. Uran uurtajia neuroverkkoihin pohjautuvien teorioiden saralla olivat Hermann von Helmholtz, Ernst Mach ja Ivan Pavlov. Matemaattisten mallien ja sitä kautta neuroverkkojen teorian varsinaisen alun voidaan kuitenkin sanoa alkaneen vasta 1940-luvulla, jolloin Warren McCulloch ja Walter Pitts aloittivat tutkimuksensa. McCulloch oli ammatiltaan psykiatri ja neuroanatom. Hänen tavoitteenaan oli mallintaa hermojärjestelmää ja sen toimintamekanismia matemaatikko Walter Pittsin avustamana. McCulloch-Pitts-neuroneilla kyettiin rakentamaan verkko, joka pystyy mallintamaan loogisia funktioita. (Tähtinen 2009, 9.)

Vuonna 1960 professori Bernard Widrow ja hänen alaisuudessa toimiva jatko-opiskelija Marcian Ted Hoff esittelivät uuden McCullochin ja Pittsin työhön perustuvan neuroverkon opetusalgoritmin, jossa neuronien välisten yhteyksien painoja muutetaan yksikerroksisessa neuroverkossa. Verkkoa kutsuttiin nimellä ADALINE (Adaptive Linear Neuron tai myöhemmin Adaptive Linear Element). Se käyttää apunaan gradienttia ja keskineliövirheen minimointia. Widrowin ja Hoffin keksintöä nimitetään myös Delta-säännöksi. ADALINE:n opetusalgoritmi on vielä nykyäänkin käytössä ja se tunnetaan nimellä LMS tai "least mean squares". Algoritmi poikkeaa Perceptronin opetusalgoritmista siten, että se säätelee neuronien välisiä painoarvoja niin, että neuroverkon tavoitetuloksen ja saadun tuloksen erotus pienenee. (Fausett, 1994, 24.)

1960-luvulla neuroverkkoa opittiin hyödyntämään hahmojen tunnistuksessa, sään ennustamisessa ja säätötekniikassa. Tämä oli neuroverkkojen nopean kehittymisen aikaa, joka päättyi vasta 1969, kun Marvin Minskyn ja Seymour Papertin kirjassaan *Perceptrons: an Introduction to Computational Geometry* esittämä kritiikki neuroverkkoalgoritmin toimivuudelle lähes pysäytti kehityksen. Heidän mukaansa yksikerroksisissa neuroverkoissa syötteen ja vasteen välille saadaan luotua vain lineaarinen riippuvuus, mikä rajoittaa verkon kykyä ratkaista monimutkaisempia ongelmia. (Tähtinen 2009, 10–11.)

Ongelmaan saatiin ratkaisu 1970-luvulla Paul Werbosin toimesta, joka keksi taaksepäin levitys -algoritmin (error backpropagation algoritmi) neuroverkon kouluttamista varten. Tarkempien algoritmin määritelmien puuttuessa menetelmä uudelleen keksittiin useaan otteeseen 1980-luvulla, jolloin kiinnostus neuroverkkoja kohtaan alkoi taas lisääntyä. Taaksepäin levitys -algoritmi on yleistys Widrowin ja Hoffin Delta-säännöstä ja sen avulla voidaan opettaa verkkoja, joissa on neuroneja useassa tasossa. Menetelmä vaatii toimiakseen jo tiedossa olevan toivotun lopputuloksen. Verkon neuronien välisiä painoja muutetaan verkon antaman tuloksen ja todellisen tuloksen välisen virheen perusteella. Virheen perusteella painojen arvoja muutetaan edeten päinvastaiseen suuntaan. Tällöin aloitetaan viimeisestä neuronien tasosta eli ulostulokerroksesta ja edetään kohti sisääntulokerrosta. (Tähtinen 2009, 12.)

Neuroverkkosovellutuksia alettiin julkaista yritysten käyttöön 1990-luvulla. Tähän asti sovellutukset olivat olleet vain tutkijoiden käytössä. Tässä tutkimuksessa neuroverkkolaskentaan käytetään MATLAB R2015a -ohjelmaa, johon on ladattu Neural Network Toolbox -työkalu.

3.3 Neuroverkot osakemarkkinoiden nykytutkimuksessa

Osakemarkkinoita on pidetty perinteisesti dynaamisena, epälineaarisenä, monimutkaisena, ei-parametrisena sekä kaottisena kokonaisuutena. Osakemarkkinoista johdetut aikasarjat ovat monitasapainoisia, kohinaisia ja niissä on säännöllisiä rakenteellisia katkoksia (Tan, Quek & Ng 2005, 2653). Tämän lisäksi osakemarkkinoihin vaikuttavat lukemattomat yleisesti tiedossa olevat mikro- ja makrotaloudelliset tekijät, kuten poliittiset tapahtumat, yritysten toimintatavat, kuluttajahinnat, korkotasot, valuuttojen vaihtokurssit, sijoittajien luottamus sekä useat muut

psykologiset tekijät (Oh & Kim 2002, 249). Monimutkaisuudesta huolimatta tai juuri sen takia osakemarkkinoiden ennustaminen on ollut yksi taloustieteen suosituimpia tutkimusalueita.

1990-luvun vaihteessa ei vielä ollut selvää, että älykkäät systeemit kuten neuroverkot kykenevät parempiin ennusteisiin kuin perinteiset lineaariset menetelmät (White 1988). Perinteisiin lineaarisiin malleihin kuuluvat muun muassa erilaiset integroituneet autoregressiiviset liukuvat keskiarvot (ARIMA), eksponentiaalinen tasoitus, yleistetyt autoregressiiviset ehdollisen heteroskedastisuuden mallit (GARCH), stokastiset volatilititeetti-mallit sekä tasoitetun muutoksen autoregressiiviset mallit (STAR). Nämä mallit pitävät pääsääntöisesti sisällään oletuksen lineaarisuudesta normaalisti jakautuneiden muuttujien kesken. (Durham 2007; Wang, Wang, Zhang & Guo 2011.) Lineaaristen mallien vahvuutena pidetään niiden toimintamekanismin selkeyttä, joka on ymmärrettävissä ja analysoitavissa yksityiskohtaisesti. Tämän lisäksi ne ovat yksinkertaisesti selitettävissä ja implementoitavissa. (Granger & Teräsvirta 1993.)

Tyytymättömyys perinteisiä lineaarisia malleja kohtaan alkoi kuitenkin kasvaa, mikä näkyi epälineaaristen menetelmien lisääntymisenä rahoitusmarkkinoiden liikkeitä ennustavissa tutkimuksissa. Tällaisiin epälineaarisiiin malleihin kuuluvat erilaiset älykkäät systeemit, kuten keinotekoiset neuroverkot (Chen 1994), sumeat systeemit (Wang 2003), tukivektorikoneet (Huang, Nakamori & Wang 2005), partikkeliparviontimointi (Majhi, Panda, Sahoo, Dash, & Das 2007) ja useat muut mallit. Epälineaaristen mallien uskotaan nimensä mukaisesti havaitsevan ei-lineaarisia säännönmukaisuuksia aineistosta, ja näin ne tuottavat lineaarisia malleja parempia ennusteita (Cao, Leggio & Schniederjans 2005).

Epälinearisista menetelmistä neuroverkkojen menestyksekkäs markkinaennustaminen alkoi japanilaisryhmän onnistuttua ennustamaan TOPIX-indeksin liikkeitä (Asakawa, K., Kimoto, T., Takeoka, M., Yoda, M. 1990). He onnistuivat moduulineuroverkkonsa avulla tuottamaan osto- ja myyntisuosituksia erilaisten taloudellisten muuttujien avulla. Samana vuonna 1990 Kamijo ja Tanigawa tutkivat osakemarkkinoita toistuvaa neuroverkkoa hyödyntäen. Ahmadi (1990) taas käytti neuroverkoksa oppimismenetelmänä taaksepäin levitys -menetelmää yhdessä yleistetyn Delta-säännön kanssa tutkiessaan arbitraasi hinnoitteluteoriaa ja osakemarkkinoiden ennustettavuutta. Schöneburg (1990) onnistui ennustamaan kolmen Saksan pörssistä satunnaisesti valitun osakkeen päivittäistä vaihtelua jopa 90 prosentin tarkkuudella käyttämällä Perceptron-, ADALINE-, MADALINE- ja taaksepäin levitys -menetelmää hyödyntäviä verkkoja.

1990-luvun jälkeen älykkäät systeemit kuten neuroverkot ovat menestyneet rahoitusmarkkinatutkimuksissa, minkä on uskottu johtuvan niiden epälineaarisista, ei-parametrisista, itseohjautuvista ja kohinaa sietävistä ominaisuuksista (Hussain, Knowles, Lisoba & El-Deredy 2008; Sewell 2009; Khashei & Bijari, 2010). Nämä ominaisuudet mahdollistavat selittävien muuttujien ja kurssivaihtelun yhteyden tunnistamisen ilman mallille annettavia ennako-oletuksia ja näin parantavat ennustekykä (Zhang, Patuwo & Hu 1998, 55). Useat tutkimukset ovat vertailleet tekoälyyn pohjautuvia tekniikoita ja perinteisiä lineaarisia tekniikoita aikasarjojen ennustamisessa ja tulleet siihen lopputulokseen, että tekoälypohjaiset systeemit ovat tarkempia ennusteissaan perinteisiin menetelmiin verrattuna (Refenes, Zapranis & Francis 1994; Lee & Tong 2011; Asadi ym. 2012, 246).

Osakemarkkinoiden ennustaminen keinotekoisien neuroverkkojen avulla ei kuitenkaan ole osoittautunut täysin ongelmattomaksi. Ongelmat pohjautuvat usein erilaisten oppimisalgoritmien kykenemättömyyteen yleistää oppimaansa koskemaan myös koulutusaineiston ulkopuolelta tulevaa otosta (Sexton, Dorsey ja Johnson 1998b, 180). Lawrence, Tsoin ja Gilesin (1998, 13) mukaan suuren määrän kohinaa sisältävä aineisto saattaa johtaa neuroverkon naiiviin ratkaisuun, jossa verkko antaa ennusteeksi aina yleisimmin esiintyvän arvon. Engozinerin ja Tomesin (1995, 31) mukaan neuroverkkojen epäonnistuminen globaalin minimin löytämisessä saattaa johtua painokertoimien optimoinnissa yleisesti käytössä olevasta gradienttipohjaisesta algoritmista, jota taaksepäin levitys -menetelmä hyödyntää.

Sextonin, Dorsey ja Johnsonin (1998b, 183) mukaan neuroverkot saattavat suoriutua huonosti gradient descent -algoritmeilla kaikkein yksinkertaisimmistakin ongelmista, jos kyseessä on koulutusaineiston ulkopuolelta tuotu otosaineisto. Heidän mukaansa taaksepäin levitys -menetelmässä, joka käyttää gradienttipohjaista algoritmia, on lokaalihakualgoritmi, joka saattaa pudota paikalliseen minimiin globaalin minimin sijaan. Edes toisen asteen menetelmät, kuten Quasi-Newton menetelmä ja Levenberg-Marquardt menetelmä, eivät tuota heidän mukaansa erityisen hyviä tuloksia. Ongelma voidaan jossain määrin korjata toimenpiteillä, kuten aloittamalla koulutus useasta eri satunnaisesta pisteestä, järjestelemällä uudelleen neuroverkon arkkitehtuuria, rajoittamalla sallittua muotoa sekä muuttamalla oppimisen nopeutta. Lupaavia tuloksia saatiin oppimisalgoritmia muuttamalla. (Sexton, Dorsey & Johnson 1998b, 172.)

Sexton, Dorsey ja Johnson (1998b) valjastivat Goldbergin (1989) ja Hollandin (1975) näkemyksiin pohjautuvan geneettisen algoritmin laskemaan neuroverkolle optimaaliset painokertoimet. Samalla

he osoittivat geneettiseen algoritmiin perustuvan oppimisalgoritmin ennusteiden ylivoimaisuuden verrattuna yleisesti käytössä olevaan taaksepäin levitys -menetelmään. Samansuuntaisia tuloksia saivat myös Gupta ja Sexton (1999) sekä Ignizio ja Soltys (1996). Täysin päinvastaisia tuloksia taas saatiin vuonna 1998 tehdyssä tutkimuksessa, jossa selvitettiin konkurssien ennustettavuutta neuroverkon avulla. Tutkimuksen mukaan neuroverkko, jossa käytettiin taaksepäin levitys -menetelmää, suoriutui ennusteista geneettistä algoritmia paremmin. (Shin, Shin ja Han 1998.) Näin ollen geneettinen algoritmi ei aina takaa parempaa lopputulosta gradienttipohjaiseen algoritmiin verrattuna.

Oppimisalgoritmien kehittäminen ja vertailu parempien ennustusten toivossa on ollut neuroverkoja hyödyntävän osakemarkkinatutkimuksen keskiössä viimeiset vuosikymmenet. Tsaih, Hsu, ja Lai (1998) pyrkivät ennustamaan päivittäin noteeratun S&P 500 -osakeindeksin futuurien suuntaa integroimalla sääntöperusteisen tekniikan osaksi keinotekoisia neuroverkkoja. He onnistuivat voittamaan osta ja pidä -strategian kuuden vuoden tarkastelujakson aikana. Burney, Jilani ja Ardil (2005) käyttivät Levenberg-Marquardt algoritmia Pakistanin osakemarkkinoiden ennustamiseen. Heidän tutkimuksensa sisälsi vain 10 päivän mittaisen ennustejakson todella hyvillä tuloksilla. Kim ja Lee (2004) vertasivat tutkimuksessaan geneettisen algoritmin ennusteita perinteisten menetelmien kanssa ja tulivat siihen tulokseen, että geneettinen algoritmi on parempi osakemarkkinoiden ennustamisessa. Chen, Chen ja Zhang (2007) yhdistivät immuuniohjelmoinnin (immune programming) ja geenien ilmentymisohjelmoinnin (gene expression programming) parantaakseen perinteistä oppimisprosessia. Miao, Chen ja Zhao (2007) taas käyttivät neuroverkossaan radiaalipohjaista bakteeriyhdyskuntafunktiota osakemarkkinoiden ennustettavuuden tutkimiseksi. Majhi ym. (2007) hyödynsivät bakteerien juurikasvioptimointia (bacteria foraging optimization) S&P 500 - ja DJIA -indeksien ennustamisessa ja totesivat sen olevan tarkempi ja nopeampi kuin perinteiset myötäsysteemiset menetelmät.

Myös erilaisten sumeiden systeemien on sanottu tuottavan hyviä osakemarkkinaennustuksia. Chang ja Liu (2008, 143) käyttivät TSK-tyyppistä (Takagi–Sugeno–Kang) sumeaa sääntöön perustuvaa systeemiä, mikä tuotti perinteistä taaksepäin -levitys menetelmää tarkempia ennustuksia Taiwanin pörssistä. Zhang ja Wu (2009) vertasivat paranneltua bakteeri kemotaksis -optimointia perinteiseen taaksepäin levitys -menetelmään S&P 500 -indeksin aineistolla saaden hyviä tuloksia. Myös yksittäisten osakkeiden ennustamisesta indeksin sijaan on lupaavaa näyttöä. Ghanbari, Hadavandi & Shavandi (2010) yhdistivät geneettisen sumean systeemin ja keinotekoisien neuroverkon, joiden pohjalta he saivat parempia tuloksia osakeaineistosta pelkkään neuroverkkoon tai perinteiseen

ARIMA-malliin verrattuna. Shen, Guo, Wu ja Wu (2011) esittelivät radiaalifunktiopohjaisen neuroverkon, joka hyödyntää oppimisessa keinotekoisia kalaparvialgoritmia. Osoittaakseen algoritminsa hyödyllisyyden he vertasivat sitä geneettiseen algoritmiin, partikkeliparviontimointiin, ARIMA-malliin, taaksepäin levitys -mekanismiin ja tukivektorikoneeseen käyttäen Shanghai pörssin indeksiaineistoa.

Perinteisten neuroverkkojen ja niissä käytettävän taaksepäin levitys -menetelmän käyttö osakemarkkinoiden ennustamisessa ei kuitenkaan ole vielä kuollut. Wang, Wang, Zhang sekä Guo (2011) loivat uskoa perinteisiin neuroverkkoihin lisäämällä taaksepäin levitys -menetelmään kohinaa vaimentavan komponentin (wavelet de-noising-based back propagation). Nykyään monet osakemarkkinoiden ennustamiseen käytettävät mallit ovat erilaisia yhdistelmiä lineaarisista ja ei-lineaarista malleista (Lee & Tong 2011; Kwon & Moon 2007; Wang, Wang, Zhang & Guo 2012). Lisäksi lupaavia ennusteita on saatu tutkimalla satunnaiskulun mallia yhdistettynä keinotekoiseen neuroverkkoon, joka hyödyntää satunnaiskulkumallin residuaalien epälineaarisia yhteyksiä (Adhikari & Agrawal 2014).

Neuroverkoista on tehty laajasti markkinatutkimusta, mutta voittojen maksimoinnin sijasta useat tutkimukset keskittyvät menetelmien vertailemiseen. Vain muutama neuroverkoilla tehty markkinaennuste on osoittautunut voitolliseksi, kun transaktiokustannukset on otettu huomioon. Kwon ja Moon (2007) onnistuivat voittamaan osta ja pidä -strategian transaktiokustannukset huomioon ottaen useimpien ennustettavien osakkeiden kohdalla hyödyntäen geneettistä algoritmia. Ennusteiden menestys oli myös johdonmukaista. Toisin sanoen ne ennustemallit, jotka menestyivät edellisinä vuosina, menestyivät hyvin myös seuraavina vuosina (Kwon & Moon 2007, 861). He eivät kuitenkaan ottaneet kantaa siihen, olisiko menetelmä ollut kannattava, jos kaikkien osakkeiden tuotot olisi laskettu yhteen transaktiokustannusten jälkeen.

Tehokkaiden markkinoiden hypoteesia ei voida hylätä tässä luvussa esitettyjen uudempien vertaistutkimusten avulla. Panin (2003, 3–4) mukaan markkinoiden tehottomuutta esittelevät tutkimukset ajoittuivat kaikki aikaan ennen 2000-lukua. Tämän jälkeiset tutkimukset, jotka hyödyntävät tekoälypohjaisia menetelmiä, on pääsääntöisesti tehty liian lyhyellä tarkastelujaksolla tai ainoastaan menestyneet mallit on poimittu esiteltäväksi suuremmasta kokonaisuudesta. Vertaistutkimukset osoittavat kuitenkin, että tekoälyä hyödyntävät systeemit kykenevät tuottamaan hyviä ennusteita sijoituspäätösten tueksi. On myös mahdollista, että ylituottoja saavuttaneet tutkijat eivät ole halukkaita jakamaan hallussaan olevia menetelmiä riskikorjattujen ylituottojen

pienentymisen pelossa. Monista eri lähteistä kerätty ja monimutkaisilla menetelmillä käsitelty informaatio voi olla hyödynnettävyydeltään verrattavissa sisäpiiritietoon. Se on hyödyllistä omistajalleen niin pitkään kuin se on yksityistä tai vain hyvin pienen ryhmän tiedossa. Tiedon tullessa julkiseksi sen hyödynnettävyys ylituottoja tavoiteltaessa katoaa markkinoiden uudelleen hinnoittellessa osakekurssit. Tästä syystä myös tehokkaiden markkinoiden sanotaan olevan itseään korjaava prosessi.

Luotettavien tulosten takaamiseksi ennustettujen aikasarjojen tulee olla riittävän pitkiä. Markkinoilta poimittujen pitkien aikasarjojen ongelmana on kuitenkin se, että markkinat muuttuvat jatkuvasti siellä toimivien sijoittajien ja sijoitusstrategioiden vaihtuessa. Tästä syystä markkinoiden muutos tulee huomioida neuroverkon kouluttamisessa pitkien aikasarjaennusteiden kohdalla. Tässä tutkimuksessa markkinoiden muutos on huomioitu siten, että neuroverkon koulutuksessa käytettävä aikasarja on liukuva. Lisäksi aikasarjan pituudeksi on valittu 10 viimeistä vuotta iShares S&P 500 Core -rahastosta. 10 viimeisimmän vuoden tarkastelu mahdollistaa tuoreimman käytössä olevan tiedon testaamisen yhdistettynä riittävän pitkään tarkastelujaksoon luotettavien tulosten saamiseksi.

4 TUTKIMUSMENETELMÄT

Haykinin (2009) mukaan on olemassa useita hyviä syitä neuroverkon käyttöön ja soveltamiseen. Neuroverkon neuronit kykenevät käsittelemään lineaarista ja epälineaarista informaatiota. Ne kykenevät kuvaamaan syötteitä ja syötteiden avulla saatuja tuloksia sekä tuloksia edeltävää prosessia tarkasti. Hänen mukaansa neuroverkolla on myös kyky mukautua koulutuksen yhteydessä ja automatisoida eri vaiheita. Lisäksi neuroverkko osaa punnita antamansa vastauksen todennäköisyyttä pelkän luokittelun sijasta. (Haykin 2009, 2–3.)

Haykin (2009) mainitsee neuroverkon eduksi myös sen, että verkon tuottama tietämys esitetään verkon rakenteessa ja painokertoimissa. Jokaisella neuronilla on mahdollisuus vaikuttaa toisiin neuroneihin, mikä tekee neuroverkon informaatiosta kontekstuaalista. Neuroverkon voidaan myös sanoa olevan vikasietoinen, koska muutaman neuronin puuttuminen ei useinkaan lamautta koko verkon toimivuutta. Lisäksi neuroverkon tekninen kehittäminen on suhteellisen helppoa, sillä verkon laskentakapasiteetti tehostuu suorittavien yksiköiden lisääntyessä. Tämän takia VLSI-teknologian (very-large-scale integration) eli integroitujen piirilevyjen itsenäinen kehittyminen edistää myös neuroverkkojen kehittymistä. (Haykin 2009, 3–4.)

Neuroverkon eduksi voidaan myös luokitella analyysien yhdenmukaisuus toisten neuroverkkojen kanssa. Samankaltaiset piirteet mahdollistavat erilaisten toimintojen yhteensovittamisen eri neuroverkkojen välillä. Lisäksi tutkimuksen ja kehityksen jatkuvuus on turvattu neuroverkkojen ollessa rinnastettavissa biologisiin aivoihin, jotka ovat vielä ihmiskunnalle melko tuntematon mutta silti kaikkein tehokkain tuntemamme laskentakokonaisuus. (Haykin 2009, 3–4.)

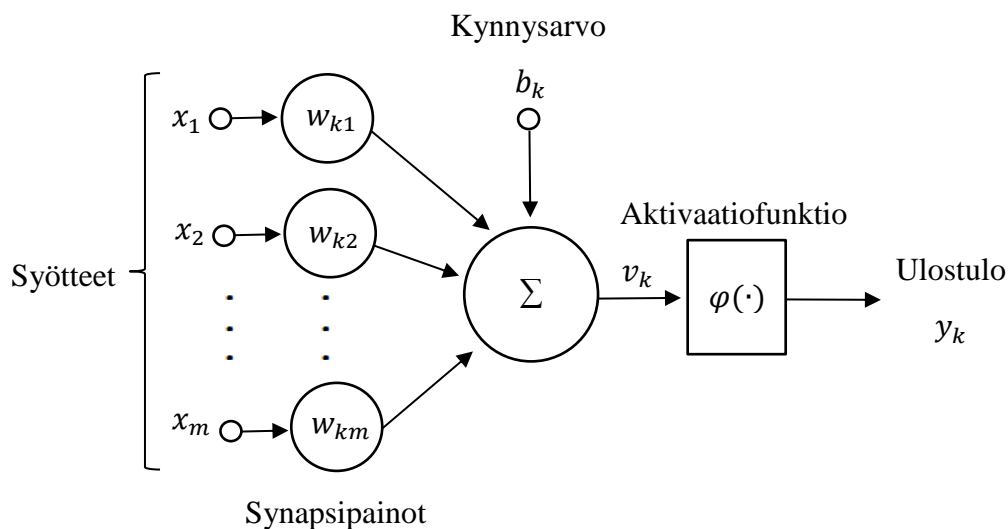
Neuroverkkojen keskeisin ominaisuus on niiden kyky oppia opetusaineistossa olevia säännönmukaisuuksia. Neuroverkoissa käytetyt opetusalgoritmit mahdollistavat haluttujen funktioiden etsimisen opetusaineistosta. Keskeisiksi neuroverkon lajitteluperusteiksi voidaan opetusalgoritmin lisäksi nimetä neuronien välisten yhteyksien topologia ja opetusmenetelmä. Neuronien yhteyksien topologialla tarkoitetaan tässä yhteydessä sitä, miten neuronit on yhdistetty toisiinsa. Voidaan esimerkiksi kysyä, onko kaikki yhden kerroksen neuronit linkitetty kaikkiin seuraavan kerroksen neuroneihin vai vain osa. Opetusalgoritmi määrää sen, miten virhettä toivotun

tuloksen ja saadun tuloksen välillä mitataan ja miten se vaikuttaa neuronien välisten painokertoimien päivittämiseen. Opetusmenetelmällä taas tarkoitetaan verkon opettajan vaikutusta oppimisprosessiin.

4.1 Neuroverkkojen elementit

Tyypillisesti neuroverkko koostuu rinnakkain toimivista yksinkertaisista laskentayksiköistä, joita kutsutaan neuroneiksi. Neuronit koostuvat kolmesta peruselementistä. Niitä ovat (1) synapsit eli liitokset muihin neuroneihin, (2) summayksiköt, jotka kokoavat tiedon ja (3) aktivaatiofunktiot, joiden tehtävänä on punnita informaation merkityksellisyyttä. (Haykin 2009, 10.)

Neuronit ovat yhteydessä toisiinsa eriasteisilla voimakkuuksilla, joita kutsutaan painoiksi. Esimerkiksi syöte x_j on yhteydessä neuronin k painon w_{kj} avulla. Alla oleva kuvio havainnollistaa keinotekoisen neuronin k toimintaa. (Haykin 2009, 10.)



KUVIO 1. Neuronin k toiminta.

Kuviossa 1. syötteitä tai syötevektoreita kuvataan kirjaimella x . Alaindeksi j kertoo, minkä sisääntulon kerroin on kyseessä. Painokertoimia, eli niin sanotun synapsikytkennän voimakkuutta, kuvastaa lyhenne w . Alaindeksi k kertoo, minkä neuronin synapsikytkentä on kyseessä. Jos paino on arvoltaan suuri, kuvastaa se tehokasta yhteyttä, kun taas pieni arvo kuvastaa heikkoa yhteyttä.

Painokerroin voi myös olla negatiivinen, jolloin sillä on neuronin ulostuloa vaimentava vaikutus. Lisäksi kuviossa on havaittavissa kynnysarvo (bias) b_k , joka tässä esimerkissä on positiivinen vakio mutta yleisesti voi saada myös negatiivisia arvoja. \sum kuvastaa summainyksikköä, joka laskee syötteiden painotetun summan lisättynä kynnysarvolla ja antaa vastauksen aktivointipotentiaalin v_k muodossa. (Haykin 2009, 10–11.) Kuvio 1. ei näytä kokonaisyötteen u_k muodostumista. Se on matemaattisesti muotoiltavissa:

$$u_k = \sum_{j=1}^m w_{kj} x_j,$$

mistä saadaan kuviossa näkyvä v_k :

$$v_k = u_k + b_k.$$

Kynnysarvon b_k tarkoituksena on mahdollistaa neuronin ulostulon poikkeaminen nolasta sisääntulojen painotetun summan ollessa nolla. Aktivointipotentiaalin ollessa tiedossa voidaan neuronille laskea ulostulo:

$$y_k = \varphi(u_k + b_k),$$

missä y_k on neuronin ulostulo ja $\varphi(\cdot)$ on aktivointifunktio. (Haykin 2009, 11.)


Kynnysarvosta voidaan luopua kuvaamalla ulostuloa:

$$y_k = \varphi(v_k),$$

kun alkuperäisiin syötteisiin lisätään uusi syöte x_0 , joka on arvoltaan positiivinen ykkönen ja malliin lisätään uuteen syötteeseen liittyvä synapsi w_{k0} , joka saa arvon b_k . Vaikkakin toimenpide muuttaa funktion rakennetta, on matemaattinen lopputulos sama (Haykin 2009, 12). Myöhemmissä esimerkeissä hyödynnetään tätä matemaattista muunnosta. Aktivaatiofunktio $\varphi(v_k)$ määrittelee syötetiedon ja tuloksen keskinäisen riippuvuuden. Koska aktivaatiofunktioilla rajataan usein neuronin ulostuloa halutulle arvoalueelle, sitä voidaan kutsua myös rajoittimeksi. Aktivaatiofunktioita on olemassa erilaisia ja käytettävä funktio tulisi valita aina tilanteen mukaan.

Sopivia aktivaatiofunktioita $\varphi(v)$ on olemassa ääretön määrä, sillä sen ainoat välttämättömät vaatimukset ovat, että se on rajattu ja monotonisesti kasvava. Suurimmassa osassa oppivia neuroverkkoja aktivaatiofunktion tulee myös olla derivoituva, koska oppimisalgoritmi vaatii sitä. Yksinkertaisin aktivaatiofunktio, jota voi käyttää neuroverkossa, on tavallinen porraskuva eli Heavisiden funktio:


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



KUVIO 2. Porraskuva.

Porraskuva ei kuitenkaan ole derivoituva, eikä sitä sen vuoksi voida käyttää kovin useassa sovelluksessa (Tähtinen 2009, 17). Sen antamat ulostulot ovat aina ykkösiä tai nollia, eli se toimii biologisten aivojen tapaan kaikki tai ei mitään -periaatteella (Haykin 2009, 14). Yleisimmin käytettyjä aktivaatiofunktioita ovat hyperbolinen tangenttifunktio ja sigmoid-funktio eli logistinen funktio (Tähtinen 2009, 17). Sigmoid-funktio, joka on muodoltaan S-kirjaimen muotoinen, on kaikista yleisimmin käytössä oleva funktio. Sen formaali määritelmä on nähtävissä alla olevasta kuvasta.


$$\varphi(v) = \frac{1}{1 + \exp(-av)}$$



KUVIO 3. Sigmoid-funktio.

Formaalissa määritelmässä parametri a on kurviparametri. Muuntelemalla parametrin a suuruutta kurvin s-muotoa voidaan muuttaa. Kuten porrasfunktio, se on määritelty välille 0 ja 1. Jos funktiolta vaaditaan negatiivisia tuloksia, on hyödyllistä määrittää tulokset välille 1 ja -1 . Tällainen funktio on hyperpolinen tangenttifunktio. Funktion formaali muoto $\varphi(v) = \tanh(v)$ on nähtävissä alla olevasta kuviosta.

$$\varphi(v) = \frac{1 - \exp(-2v)}{1 + \exp(-2v)}$$



KUVIO 4. Hyperpolinen tangenttifunktio.


Nyt kaikki funktion arvot skaalautuvat välille 1 ja -1 , kuten kuviosta on havaittavissa. Tässä tutkimuksessa aktivaatiofunktiona käytetään hyperbolista tangenttifunktiota, koska se voidaan derivoida (Haykin 2009, 14). Lisäksi tutkimuksessa käytetään monikerroksista neuroverkkoa, joka vaatii epälineaarista aktivaatiofunktioita. Muutoin lopputulos olisi täysin sama kuin yksikerroksista neuroverkkoa käytettäessä (Fausett 1994).

4.2 Monikerroksinen neuroverkko

Monikerroksinen neuroverkko (monikerros-perceptron-verkko) on usein käytetty myötäsyötteinen neuroverkkomalli. Se poikkeaa yksinkertaisesta neuroverkosta siten, että sillä on sisään- ja ulostulokerroksen lisäksi ainakin yksi piilokerros. Yksisuuntaisissa monikerrosverkoissa neuronit on järjestetty kerroksiin, joissa neuronien kytkökset kerrosten välillä kulkevat vain eteenpäin. Lisäksi saman kerroksen neuronien välillä ei koskaan ole kytkentöjä. Tällaiset monikerroksiset neuroverkot ovat niin sanotusti staattisia, eli niillä ei ole muistia. Tällöin neuroverkon ulostulo on riippuvainen vain hetkellisistä sisääntulojen arvoista. (Tähtinen 2009, 15.)

Neuronien useasta samaan aikaan toimivasta kerroksesta muodostuu monikerroksinen neuroverkko. Kuvio 5 on esimerkki kolmikerroksisesta verkosta. Verkossa on nähtävissä signaalin kulkusuunta syötteistä (input layer) ulostuloon (output layer) ja neuronien kaksi kerrosta eli piilokerrokset (hidden layer). (Tähtinen 2009, 15.)

Syötekerros Kaksi piilokerrosta Ulostulokerros Ulostulo



KUVIO 5. Monikerroksinen neuroverkko.

Kuvion 5 mukaan syötevektorit $x = \{x_1, x_2, \dots, x_m\}$ syötetään kaikille piilokerroksen neuroneille, minkä seurauksena saadaan ulostulo y_j . Usein saman kerroksen neuronit käyttävät samanlaista aktivaatiofunktiota. Ensimmäisen piilokerroksen neuronien ulostulot syötetään edelleen seuraavan piilokerroksen kaikille neuroneille. Ulostuloneuronit saavat sisääntulonsa aina edeltävän kerroksen neuronien ulostulosta. Piilokerrosten määrää ei ole rajattu. Ulostulokerros sisältää jokaista haluttua ulostulon muuttujaa kohti yhden ulostuloneuronin. Verkon ulostulona saadaan vektori tai skalaari y jokaista sisääntulon vektoria x vasten. (Tähtinen 2009, 15.)

Ennen neuroverkon kouluttamista on keskeistä mallintaa neuroverkon muoto valitsemalla oikea määrä neuroneita, oikea määrä kerroksia ja sopiva opetusalgoritmi. Erilaisia neuroverkkomalleja ja opetusalgoritmeja sekä niistä tehtyjä muunnelmia on useita. Osa neuroverkoista on räätälöity vain tietynlaisiin laskusuorituksiin, kun taas toisia voi käyttää melkein mihin tahansa regressio-, ryhmittely- tai hahmontunnistusongelmiin. (Tähtinen 2009, 23.)

Tässä tutkimuksessa käytetään vain yhtä piilokerrosta, joka sisältää neljä neuronia. Neuronit eivät ole piilokerroksessa yhteydessä toisiinsa ja ne yhdistyvät vasta ulostulokerroksessa. Monikerroksinen neuroverkko, joka sisältää vain yhden piilokerroksen, kykenee approksimoimaan minkä tahansa rajallisen funktion (Cybenko, 1989, 303; Hornik, Stinchcombe & White 1989, 359). Tutkimuksessa

piilokerroksen aktivaatiofunktiona käytetään hyperpolista tangenttifunktiota. Ulostulokerroksessa käytettävä aktivaatiofunktio on lineaarinen aktivaatiofunktio, joka vain välittää annetun arvon eteenpäin. Suurin hyöty epälineaarisen aktivaatiofunktion käyttämisestä piilokerroksessa on se, että funktio rajaa tulokset jollekin kiinnitetyle alueelle.

4.3 Koneoppiminen

Neuroverkot ovat luokiteltavissa kolmeen luokkaan niissä käytettävän opetusmenetelmän mukaan. Nämä opetusmenetelmät ovat ohjattu (supervised), vahvistava (reinforcement) ja ohjaamaton (unsupervised) oppimismenetelmä. Ohjatussa oppimisessä neuroverkon syötteet ja tavoiteltu tulos tiedetään. Tavoitteena on löytää syötteiden ja tulosten välinen yhteys. Ohjaamattomassa verkossa ainoastaan syötteet ovat tiedossa. Tavoitteena ei välttämättä ole lopputuloksen selvittäminen vaan aineiston ominaisuuksien tutkiminen, mikä saattaa helpottaa aineiston luokittelua. Vahvistavassa verkossa taas ei välttämättä ole tiedossa tarkkaa haluttua tulosta tai tiedossa oleva tulos ei ole yksiselitteinen. Tällaista menetelmää voidaan käyttää silloin, kun tuloksen hyvyyttä voidaan arvioida joillain kriteereillä. (Russell & Norvig 2010, 694–695.)

Tässä tutkimuksessa opetusmenetelmänä käytetään ohjattua oppimista, koska toivotut tulokset aikaisemmilta vuosilta ovat tutkijan tiedossa. Syötteiden lukumäärästä ja niille annettujen optimaalisten painokertoimien lukuisista erilaisista kombinaatioista johtuen kaikista optimaalisimman yhdistelmän löytäminen on työläs prosessi ja vaatii suurta laskutehoa. Tästä johtuen koulutusprosessia tulee yksinkertaistaa oppimisalgoritmillä. Tutkimuksessa neuroverkon suorituskyvyn optimoimiseen käytetään gradienttioptimointialgoritmiin pohjautuvaa toisen asteen optimointialgoritmia nimeltään Levenberg-Marquardt algoritmi. Toisin sanonon toivotun arvon ja neuroverkon tuottaman ulostulon erotusta eli virhettä minimoidaan käyttämällä algoritmia, joka muuttaa painokertoimia pienemmän virheen edellyttämään suuntaan. Virheestä on mahdollista rakentaa kustannusfunktio, joka mittaa neuroverkon suorituskykyä. Virheen minimoimista kutsutaan koneoppimista käsittelevässä kirjallisuudessa neuroverkon kouluttamiseksi.

4.3.1 Virhefunktiot

Ennen koulutusprosessin aloittamista virheen e mittaamiseen käytettävä menetelmä tulee määritellä:

$$e_k(n) = t_k(n) - y_k(n),$$

missä t kuvastaa todellisia arvoja, y kuvastaa neuroverkon antamia tuloksia ja n kuvastaa iteraation askeleita. Oppimisen tarkoituksena on pienentää virhettä minimoimalla kustannusfunktiota. Tässä esimerkissä kustannusfunktiota ε mallinnetaan seuraavasti:

$$\varepsilon_k(n) = \frac{1}{2} e_k^2(n).$$

Jos ulostulokerroksen neuroneita on useita, koko verkon kaikille ulostuloille laskettava kustannusfunktio voidaan esittää muodossa:

$$\varepsilon(n) = \frac{1}{2} \sum_{k \in C} e_k^2(n),$$

missä C kuvastaa kaikkia neuroneita ulostulokerroksessa. Virhefunktio on myös laajennettavissa koskemaan koko neuroverkon kaikkia neuroneita:

$$\varepsilon_{keskiarvo}(N) = \frac{1}{2N} \sum_{n=1}^N \sum_{k \in C} e_k^2(n),$$

missä N kuvastaa otosta. Koneoppimisen kirjallisuudessa edellä esitettyä yhtälöä kutsutaan virheenergian keskiarvoksi koulutettavassa aineistossa tai empiiriseksi riskiksi (Haykin 2009, 127). Edellä esitetyt kaksi viimeistä mallia ovat yksinkertaistuksia, joissa funktioiden riippuvuutta ei ole huomioitu teoreettisen tarkastelun yksinkertaistamiseksi.

Edellä esitetty voidaan muuttaa muotoon, jossa kustannusfunktiolle $\varepsilon(n)$ voidaan määrittää keskineliövirhe (mean squared error) summaamalla kaikkien virheiden energia (error energy) ja normalisoimalla funktio:

$$MSE = \frac{1}{N} \sum_{n=1}^N \varepsilon(n).$$

MSE-funktiota eli keskineliövirhefunktiota voidaan käyttää kustannusfunktiona, jota hyödynnetään oppimisprosessin lisäksi neuroverkon suorituskyvyn arvioimisessa. Opetusprosessin tehtävänä on minimoida tätä funktiota muokkaamalla neuroverkon vapaita parametreja. Neuroverkko tuottaa estimaatin tämän prosessin seurauksena. (Neural Network Toolbox User's Guide 4, 112.) Tässä tutkimuksessa suorituskykyfunktiona käytetään keskineliövirhettä.

4.3.2 Delta-sääntö

Widrow ja Hoff (1960) esittelivät menetelmän kustannusfunktion minimoimiseen. Se tunnetaan nimellä Widrowin ja Hoffin Delta-sääntö. Säännössä neuronien välisiä painokertoimia muunnetaan suuntaan, jossa virhe pienenee. Delta-säännössä lasketaan differentiaalilaskennan ketjutussääntöä käyttäen kustannusfunktiolle ε osittaisderivaatta synapsin w_{kh} suhteen, minkä lopputulemana saadaan synapsipainon haluttu muutos Δw_{kh} . Esimerkiksi neuronin k ja sitä edeltävän neuronin h yhdistävän painon w_{kh} muutosta voidaan kuvata Delta-säännön avulla:

$$\frac{\partial \varepsilon_k}{\partial w_{kh}} = \frac{\partial \left(\frac{1}{2} (t_k - y_k)^2 \right)}{\partial w_{kh}}.$$

Seuraavaksi ketjutussääntöä käyttämällä jaetaan edellä esitetty yhtälö kahteen osaan:

$$\frac{\partial \varepsilon_k}{\partial w_{kh}} = \frac{\partial \left(\frac{1}{2} (t_k - y_k)^2 \right)}{\partial y_k} \frac{\partial y_k}{\partial w_{kh}},$$

josta saadaan:

$$\frac{\partial \varepsilon_k}{\partial w_{kh}} = -(t_k - y_k) \frac{\partial y_k}{\partial w_{kh}}.$$

Löytääkseen yhtälön oikeanpuoleisen termin derivaatan ketjutussääntöä on käytettävä uudestaan. Tällä kertaa derivoidaan painotettu syötteiden summa v_k painon w_{kh} suhteen:

$$\frac{\partial \varepsilon_k}{\partial w_{kh}} = -(t_k - y_k) \frac{\partial y_k}{\partial v_k} \frac{\partial v_k}{\partial w_{kh}}.$$

Tiedostamalla, että neuronin k ulostulo y_k on neuronin aktivaatiofunktio neuronin painotetusta syötteiden summasta eli $\varphi(v_k)$, saadaan yhtälö muotoon:

$$\frac{\partial \varepsilon_k}{\partial w_{kh}} = -(t_k - y_k) \varphi'(v_k) \frac{\partial v_k}{\partial w_{kh}}.$$

Viimeiseksi kirjoitetaan v_k muotoon, jossa summataan kaikki painotetut summat w_{kj} yhteen vastaavien syötteiden x_j kanssa, eli $\sum_j w_{kj} x_j$. Esimerkissä on vain yksi syöte eli:

$$\frac{\partial \varepsilon_k}{\partial w_{kh}} = -(t_k - y_k) \varphi'(v_k) \frac{\partial (\sum w_{kh} x_h)}{\partial w_{kh}}.$$

Lopputulokseksi saadaan yhtälö, jossa x_h kuvastaa neuronin k syötettä:

$$\frac{\partial \varepsilon_k}{\partial w_{kh}} = -(t_k - y_k) \varphi'(v_k) x_h.$$

Kun yhtälöön lisätään suhteellisuusvakio γ , joka eliminoi miinusmerkin, mahdollistetaan painojen negatiivinen muutos gradientin suuntaan virheen minimoimiseksi:

$$\Delta w_{kh} = \gamma (t_k - y_k) \varphi'(v_k) x_h,$$

missä γ on opetusnopeus ja Δw_{kh} painon muutos. Opetusnopeuden tulee olla aina rajoitettu vakio yhden ja nollan välillä. Opetusnopeuden määrittäminen on keskeinen tekijä menetelmän konvergoitumisessa (Haykin 2009, 96). Jos kerroin on liian suuri, virhettä ei välttämättä saada pienennettyä. Jos kerroin taas on liian pieni, verkon oppiminen voi olla erittäin hidasta ja jumiutua paikalliseen optimiin globaalin optimin sijasta. (Tähtinen 2009, 39.)

Linearisella aktivaatiofunktiolla Delta-sääntö on esitettävissä muodossa:

$$\Delta w_{kh} = \gamma (t_k - y_k) x_h$$

(Haykin 2009, 55).

Delta-sääntöä käyttäen seuraavan iteraation painoja tulee muuttaa seuraavan yhtälön mukaan:

$$w_{kh}(n + 1) = w_{kh}(n) + \Delta w_{kh}(n),$$

jotta virhe pienenee (Haykin 2009, 55). Burneyn, Jilanin ja Ardilin (2005, 173) mukaan Delta-sääntöä hyödyntämällä edellä esitetty voidaan määrittää yksinkertaisemmin:

$$\Delta w_{kh} = -\gamma \frac{\partial \varepsilon_k}{\partial w_{kh}},$$

missä miinusmerkki on opetusnopeuskertoimen edessä (Haykin 2009, 131). Tällöin oppimisnopeuskertoimelle annetaan erilaiset iteraatioiden määrään sidotut ehdot. Esimerkiksi $\gamma(n)$ voidaan määrittellä $\gamma(n) = \frac{c}{n}$, missä c on tutkijan määräämä vakio (Haykin 2009, 116). Neuroverkkoa, joka pyrkii muuttamaan toimintaansa virheellisten tulosten pohjalta, kutsutaan takaisin levittäväksi verkoksi tai puhutaan verkon taaksepäin levitys -ominaisuudesta.

4.3.3 Taaksepäin levitys -menetelmä

Taaksepäin levitys -menetelmä on yleisin myötäsytöteisten neuroverkkojen ohjatussa koulutuksessa käytettävä menetelmä (Haykin 2009, 129). Neuroverkon opettaminen lähtee liikkeelle siitä, että neuronien liitoksille eli painoille annetaan sattumanvaraiset arvot ja vakiot. Tämän jälkeen käytetään opetusaineiston havaintoja, joilla lasketaan eri neuronien ulostulot ja koko verkon ulostulo. Verkon laskemaa tulosta verrataan todelliseen tulokseen ja muutetaan painoja opetusalgoritmin mukaan siten, että verkon antama tulos lähenee todellisia tuloksia. Prosessia jatketaan niin pitkään, että saavutetaan haluttu tarkkuus.

Useilla oppimisalgoritmeilla koulutusprosessia säädellään ylisovittamisen välttämiseksi jakamalla koulutettava aineisto kolmeen ryhmään. Ensimmäinen ryhmä on kaikista suurin eli neuroverkon koulutukseen käytettävä ryhmä. Ryhmän tarkoitus on opettaa neuroverkkoa löytämään syötteiden ja tavoitearvojen keskeiset yhteydet virhettä pienentämällä ja painojen muutoksia hyödyntäen. Toinen ryhmä on huomattavasti koulutusryhmää pienempi validointiryhmä. Validointiryhmän vektoreita käytetään koulutuksen ennenaikaiseen keskeyttämiseen silloin, kun verkon suorituskyky hetkellisesti heikkenee tai pysyy pitkään lähes samana. Ennenaikaisen keskeyttämisen tarkoitus on ennaltaehkäistä neuroverkon ylisovittamista koulutusaineistoon, mutta kouluttaa neuroverkkoa

kuitenkin niin pitkään, että verkolle muodostuu yleinen käsitys syötteiden ja ulostulojen suhteesta. Tätä neuroverkon oppimaa yleistä käsitystä voidaan myöhemmin hyödyntää koulutusaineiston ulkopuolelta tuotuun uuteen aineistoon. Kolmas ryhmä on myös huomattavasti koulutusryhmää pienempi. Sitä käytetään neuroverkon yleistämiskyvyn itsenäistä testaamista varten, eli se on niin sanottu testiryhmä. Ei ole yleistä sääntöä siitä, kuinka neuroverkon koulutuksessa käytettävä aineisto tulisi jakaa eri ryhmiin. (Friedman, Hastie & Tibshirani 2009, 222.)

Taaksepäin levitys -menetelmä yhdistää verkon kaksi suuntaa. Ensimmäinen suunta syötteistä piilokerroksen kautta ulostuloihin ei muuta neuronien välisten painojen arvoja. Toinen suunta eli liike taaksepäin siirtää todellisen arvon ja neuroverkon ulostulon erotuksena saatua virhesignaalia ulostulosta takaisin neuroverkon piilokerrokseen. Piilokerroksissa jokaisen neuronin painokertoimia muutetaan edeten yksitellen verkon viimeisestä neuronista ensimmäiseen neuroniin ennalta määrätyn säännön mukaisesti. Toiminnan tarkoituksena on löytää optimaaliset painot, jotka minimoivat kustannusfunktioita. Tehtävän suorittamiseksi on olemassa useita erilaisia optimointialgoritmeja, kuten gradienttipohjaiset menetelmät, stokastiset optimointimenetelmät ja heuristiset menetelmät. Tässä tutkimuksessa keskitytään gradienttipohjaisiin menetelmiin. Seuraavissa luvuissa esitetään tutkimuksen kannalta keskeiset algoritmit, joita käytetään taaksepäin levitys -menetelmän yhteydessä.

4.3.4 Gradientti

Gradientti on matemaattinen differentiaalioperaattori. Termillä gradientti on useita merkityksiä, joista yksinkertaisin on kaltevuus. Tässä luvussa tarkastelen gradientin merkitystä taaksepäin levitys -menetelmässä. Prosessin yksityiskohtaisempi tarkastelu tulee aloittaa ulostuloneuronin l aktivaatiopotentiaalin v_l tarkastelusta:

$$v_l(n) = \sum_{i=0}^m w_{li}(n)y_i(n),$$

missä y_i kuvastaa edellisen neuronin i ulostuloa, m on syötteiden määrä ilman kynnsarvoa ja w_{l0} kuvastaa kynnsarvoa neuronille l . Matemaattinen muunnos on sama kuin luvussa 4.1 esitettiin aktivaatiopotentiaalille v_k . (Haykin 2009, 129.) Nyt neuronin l ulostuloa y_l voidaan kuvata funktiolla:

$$y_l(n) = \varphi_l(v_l(n)),$$

missä $\varphi_l(\cdot)$ on aktivaatiofunktio neuronille l . Taaksepäin levitys -menetelmä muuttaa painoja kustannusfunktion $\varepsilon(n)$ osittaisderivaatan $w_{li}(n)$ suhteen. Käyttämällä ketjutussääntöä derivaatan laskemiseen vastaava gradietti voidaan määrittellä:

$$\frac{\partial \varepsilon(n)}{\partial w_{li}(n)} = \frac{\partial \varepsilon(n)}{\partial e_l(n)} \frac{\partial e_l(n)}{\partial y_l(n)} \frac{\partial y_l(n)}{\partial v_l(n)} \frac{\partial v_l(n)}{\partial w_{li}(n)}.$$

Osittaisderivaatta $\frac{\partial \varepsilon(n)}{\partial w_{li}(n)}$ kuvastaa herkkyystekijää, joka määrää etsimisen suunnan painoavaruudessa painolle $w_{li}(n)$. Koska vektorit ovat synapsipainojen avaruudessa, gradientti voidaan määrittellä jyrkimmän nousun suunnaksi $\varepsilon(n)$:ssä. Koska kaikki osittaisderivoituvat yhtälöt $\varepsilon(n)$, $e_l(n)$, $y_l(n)$ ja $v_l(n)$ ovat tiedossa aikaisemmista luvuista, voidaan ne laskea auki:

$$\frac{\partial \varepsilon(n)}{\partial e_l(n)} = e_l(n), \frac{\partial e_l(n)}{\partial y_l(n)} = -1, \frac{\partial y_l(n)}{\partial v_l(n)} = \varphi'_l(v_l(n)), \frac{\partial v_l(n)}{\partial w_{li}(n)} = y_i(n).$$

Näin ollen edellä mainittu voidaan kirjoittaa yksinkertaisempaan muotoon myöhempää tarkastelua varten:

$$\frac{\partial \varepsilon(n)}{\partial w_{li}(n)} = -e_l(n)\varphi'_l(v_l(n))y_i(n)$$

tai vaihtoehtoisesti muotoon:

$$\Delta w_{li}(n) = -\gamma \frac{\partial \varepsilon(n)}{\partial w_{li}(n)},$$

missä γ on tutkijan määräämä oppimisnopeuskerroin. Miinusmerkin käyttö yhtälössä kuvaa gradient descent -algoritmia painoavaruudessa esimerkiksi etsimällä painojen muutosten suuntaa, mikä vähentää termin $\varepsilon(n)$ arvoa. (Haykin 2009, 130–131.) Yhdistämällä kaksi edellistä kaavaa saadaan painojen muutokseksi:

$$\Delta w_{li}(n) = \gamma e_l(n) \varphi'_l(v_l(n)) y_i(n).$$

Yhtälön osio $e_l(n) \varphi'_l(v_l(n))$ kuvastaa paikallista gradienttia, jota voidaan merkitä lyhenteellä $\mu_l(n)$. Sen formaali määritelmä on:

$$\mu_l(n) = \frac{\partial \varepsilon(n)}{\partial v_l(n)} = e_l(n) \varphi'_l(v_l(n))$$

eli

$$\Delta w_{li}(n) = \gamma \mu_l(n) y_i(n),$$

missä painoa $w_{li}(n)$ päivitetään aina oppimiskertoimen γ avulla, joka kerrotaan paikallisella gradientilla $\mu_l(n)$, joka taas kerrotaan neuronin l syötteellä $y_i(n)$. (Haykin 2009, 131.) Taaksepäin levitys -menetelmässä painojen päivittyminen toimii aina tällä mekanismilla.

Riippuen laskettavan neuronin sijainnista verkossa paikallinen gradientti $\mu_l(n)$ lasketaan eri tavalla. Jos neuroni l sijaitsee neuroverkon viimeisessä kerroksessa, tietyn virhesignaalin $e_l(n)$ laskeminen on helppoa, koska sille on saatavissa todellinen arvo, jota tarvitaan paikallisen gradientin $\mu_l(n)$ laskemiseen. Tällöin edellä esitetty kaava pätee paikallisen gradientin laskemiseen. Jos taas neuroni h sijaitsee piilokerroksessa, sille ei ole laskettavissa todellista virhesignaalia. Näin ollen virhesignaali täytyy määrittää rekursiivisesti kaikkien muiden neuronien painojen virhesignaalin keskiarvosta. (Haykin 2009, 131–132.)

Voimme määrittellä paikallisen gradientin piilokerroksen neuronille h :

$$\mu_h(n) = -\frac{\partial \varepsilon(n)}{\partial y_h(n)} \frac{\partial y_h(n)}{\partial v_h(n)}.$$

Koska $\frac{\partial \varepsilon(n)}{\partial y_h(n)} = \sum_l e_l \frac{\partial e_l(n)}{\partial y_h(n)}$, voimme laskea ketjutussääntöä apuna käyttäen ensimmäisen termin auki:

$$\frac{\partial \varepsilon(n)}{\partial y_h(n)} = \sum_l e_l(n) \frac{\partial e_l(n)}{\partial v_l(n)} \frac{\partial v_l(n)}{\partial y_h(n)},$$

missä:

$$e_l(n) = t_l(n) - y_l(n) = t_l(n) - \varphi_l(v_l(n))$$

eli sen osittaisderivaatta v_l :n suhteen on:

$$\frac{\partial e_l(n)}{\partial v_l(n)} = -\varphi'_l(v_l(n)).$$

Ja termi $\frac{\partial v_l(n)}{\partial y_h(n)}$ on:

$$\frac{\partial v_l(n)}{\partial y_h(n)} = w_{lh}(n).$$

Nyt termit voidaan yhdessä esittää muodossa:

$$\frac{\partial \varepsilon(n)}{\partial y_h(n)} = - \sum_l e_l(n) \varphi'_l(v_l(n)) w_{lh}(n)$$

tai yksinkertaisemmin muodossa:

$$\frac{\partial \varepsilon(n)}{\partial y_h(n)} = - \sum_l \mu_l(n) w_{lh}(n).$$

Kun kaikki termit on laskettu auki, paikallista gradienttia kuvaava kaava piilokerroksen neuronille h voidaan ilmaista seuraavassa muodossa:

$$\mu_h(n) = \varphi'_h(v_h(n)) \sum_l \mu_l(n) w_{lh}(n),$$

missä $\varphi'_h(v_h(n))$ riippuu pääsääntöisesti valitun aktivaatiofunktion valinnasta neuronille h . Termien auki laskeminen kuitenkin paljastaa, että aktivaatiofunktion derivaattaa tarvitaan. Tällöin aktivaatiofunktion tulee olla jokaisessa neuronissa jatkuva. Tästä syystä logistista ja hyperpolista tangenttifunktiota käytetään aktivaatiofunktiona piilokerroksissa. (Haykin 2009, 132–133.)

Haykinin (2009, 137) mukaan liian suuri oppimisnopeuskerroin tekee liian suuria muutoksia synapsipainoihin, jotka saattavat tehdä verkosta epästabiilin. Gradienttipohjaisiin menetelmiin lisätään usein momenttiparametri, joka edesauttaa konvergoitumista. Tällöin painojen muutos määritellään formaalisti:

$$\Delta w_{li}(n) = \gamma \mu_i(n) y_i(n) + \rho \Delta w_{li}(n-1),$$

missä $\Delta w_{li}(n-1)$ kuvastaa synapsin muunnosta iteraatiota aikaisemmin ja ρ on vakiomuotoinen momenttiparametri väliltä 0 ja 1. Kasvattamalla termiä ρ voidaan painojen muunnoksen suuruuteen vaikuttaa joko nopeuttaen tai hidastaen aikasarjan konvergoitumista. Jos momentti on lähellä nollaa, edellisellä iteraatiolla ei ole juuri vaikutusta tämän hetkiseen iteraation. Jos taas momenttiparametri on lähellä ykköstä, vaikuttaa se suuresti hetken n painojen muutokseen. (Haykin 2009, 137–138.)

Taaksepäin levitys -menetelmän käyttö opetusalgoritmina on optimipisteen metsästämistä. Tähtinen (2009, 34) kuvaa taaksepäin levitys -menetelmää hyppykepillä hyppelyksi virhepinnalla. Jos oppimisnopeus eli hyppy on liian suuri, voidaan optimaalisen kohdan yli hypätä monta kertaa. Jos taas oppimisnopeus on liian pieni, oppiminen on hidasta ja voi helposti jumiutua johonkin paikalliseen minimikohtaan. Satunnaisesti tulevat painokertoimien alkuarvot vaikuttavat myös paljon oppimiseen. Tästä syystä koulutus tulee suorittaa useita kertoja eri alkuarvoilla. (Tähtinen 2009, 34.)

4.3.5 Gauss-Newton algoritmi

Kuten edellä oleva kappale osoitti, gradienttialgoritmi pyrkii synapsien muunnosten suunnan selvittämiseen ja painojen muuttamiseen. Kun oikea painojen muutosten suunta synapsiavaruudessa on selvitetty, ongelmaksi muodostuu se, kuinka pitkälle valittua suuntaa tulisi jatkaa. Momenttimuuttuja antaa lisätietoa mutta on tutkijan inhimillisen vaikutuksen alainen. Lisäinformaatiota ongelmaan on saatavissa toisen asteen virhepinnasta. Tätä varten tarvitaan uusia yhtälöitä ongelman ratkaisemiseksi. Newtonin menetelmä hyödyntää toisen asteen derivaattoja ja soveltuu siksi edellä mainitun ongelman ratkaisemiseen.

Newtonin menetelmän perusidea on minimoida neliöihin perustuva approksimaatio kustannusfunktiosta $\varepsilon(\mathbf{w})$. Taylorin sarja on yksinkertainen erikoistapaus potenssisarjasta, jota voidaan hyödyntää toisen asteen ongelmien ratkaisussa. Taylorin sarjakehitelmästä saatavan approksimaation virhe on aina tarkasti tunnettu. Olkoon $w(n)$ sellainen painovektori

painoavaruudessa, jossa toisen asteen Taylorin sarjan approksimaatio virhefunktion muutoksesta voidaan kirjoittaa muotoon:

$$\begin{aligned}\Delta\varepsilon(\mathbf{w}(n)) &= \varepsilon(\mathbf{w}(n+1)) - \varepsilon(\mathbf{w}(n)) \\ &\approx \mathbf{G}^T(n)\Delta\mathbf{w}(n) + \frac{1}{2}(\Delta\mathbf{w}^T(n))\mathbf{H}(n)\Delta\mathbf{w}(n),\end{aligned}$$

missä $\mathbf{G}(n) = \frac{\partial\varepsilon}{\partial\mathbf{w}} \Big|_{\mathbf{w}=\mathbf{w}(n)}$ on lokaali gradienttivektori pisteessä $\mathbf{w}(n)$ ja $\mathbf{H}(n) = \frac{\partial^2\varepsilon}{\partial^2\mathbf{w}} \Big|_{\mathbf{w}=\mathbf{w}(n)}$ on lokaali Hessian matriisi pisteessä $\mathbf{w}(n)$. Yläindeksi T kuvastaa transpoosia. (Haykin 2009, 96.)

Optimaalinen painojen päivitys on Newtonin menetelmän mukaan ratkaistavissa muotoon:

$$\mathbf{w}(n+1) = \mathbf{w}(n) - \mathbf{H}^{-1}(n)\mathbf{G}(n),$$

ja edelleen

$$-\mathbf{H}^{-1}(n)\mathbf{G}(n) = \Delta\mathbf{w}(n),$$

missä $\mathbf{H}^{-1}(n)$ on käänteinen Hessian matriisi (Haykin 2009, 98).

Newtonin menetelmä konvergoituu usein nopeammin kuin konjugaattigradienttimenetelmät. Valitettavasti Hessian matriisin laskeminen myötäsyötteisessä neuroverkossa on työlästä. Lisäksi Hessian matriisin laskeminen vaatii matriisin ominaisuuksilta sitä, että sen tulee olla positiivisesti definiitti kaikilla iteraation askelilla. (Haykin 2009, 98.) Ongelma on ratkaistavissa luopumalla kustannusfunktion Hessian matriisista ja käyttämällä Jacobin matriisia virhevektorin $\mathbf{e}(n)$ osittaisderivaatassa painojen suhteen. Algoritmi on nimeltään Gauss-Newton algoritmi, jolla matriisin positiivisesti definiitti -ominaisuus on helpompi tuottaa.

Jacobin matriisi voidaan laskea Gauss-Newton algoritmista käyttämällä standardia taaksepäin levitys -menetelmää. Hyödyntäen edellä opittua virheiden neliöiden summaa gradienttivektori voidaan määrittää:

$$\mathbf{G}(n) = \mathbf{J}^T(n)\mathbf{e}(n),$$

missä \mathbf{J} on Jacobin matriisi. Jacobin matriisi sisältää virhesignaalin ensimmäisen asteen osittaisderivaatan painokertoimien ja kynnsarvojen suhteen, eli $\mathbf{J}(n) = \frac{\partial e}{\partial \mathbf{w}} \Big|_{\mathbf{w}=\mathbf{w}(n)}$. $\mathbf{e}(n)$ on neuroverkon virheiden vektori. Vastaava Hessian matriisin approksimaatio määritellään seuraavasti:

$$\mathbf{H}(n) \approx \mathbf{J}^T(n)\mathbf{J}(n).$$

(Neural Network Toolbox User's Guide 4, 158.) Painojen muutos Gauss-Newton algoritmissa voidaan kirjoittaa muotoon:

$$\Delta \mathbf{w}(n) = -[\mathbf{J}^T(n)\mathbf{J}(n)]^{-1}\mathbf{J}^T(n)\mathbf{e}(n).$$

missä Jacobin matriisit $\mathbf{J}(n) = \frac{\partial e}{\partial \mathbf{w}}$ ja $\mathbf{J}^T(n)\mathbf{J}(n)$ on aina määritelty positiiviseksi, jotta ne ovat laskettavista. Jotta positiivisuuden vaatimus täyttyy, yhtälöön lisätään diagonaalinen matriisi $\vartheta \mathbf{I}$, jossa \mathbf{I} on identiteettimatriisi ja parametri ϑ pieni positiivinen vakio. Tästä seuraa, että $\mathbf{J}^T(n)\mathbf{J}(n) + \vartheta \mathbf{I}$ on positiivisesti definiitti kaikilla n :n arvoilla. Tällöin lisäys formaalissa muodossa on:

$$\Delta \mathbf{w}(n) = -[\mathbf{J}^T(n)\mathbf{J}(n) + \vartheta \mathbf{I}]^{-1}\mathbf{J}^T(n)\mathbf{e}(n).$$

Termin $\vartheta \mathbf{I}$ vaikutus vähenee progressiivisesti iteraatioiden lisääntyessä. (Haykin 2009, 99–100.)

Lisäksi on huomioitava, että edellä esitettyssä ratkaisussa on hieman muunneltu kustannusfunktio:

$$\boldsymbol{\varepsilon}(\mathbf{w}) = \frac{1}{2} \left\{ \sum_{i=1}^n e^2(i) + \vartheta \|\mathbf{w} - \mathbf{w}(n)\|^2 \right\},$$

missä $w(n)$ on sen hetkinen arvo painovektorista $w(i)$ ja ϑ on sääntelyparametri. Euklidinen normista $\|\mathbf{w} - \mathbf{w}(n)\|^2$ puhutaan yhtälön vakauttajana ja sen muoto riippuu suodatinrakenteesta. (Haykin 2009, 100.)

4.3.6 Levenberg-Marquardt algoritmi

Gauss-Newton algoritmi hyödyntää toisen asteen tietoa ja sen mukanaan tuomaa nopeutta käyttämällä Hessian matriisin approksimaatiota. Näin on myös Levenberg-Marquardt algoritmin

tapauksessa. Algoritmi on saanut nimensä kehittäjiensä Levenbergin (1944) ja Marquardtin (1963) mukaan. Menetelmä sopii hyvin neuroverkkojen koulutukseen, koska se kykenee hyödyntämään kustannusfunktiossa virheiden neliöiden summaa toisista epälineaarista funktioista. Erona Gauss-Newton algoritmiin on parametriin ϑ kohdistuvat toimenpiteet.

Hessian matriisiin $\mathbf{H}(n)$ laskennallisten ongelmien vuoksi Gauss-Newton algoritmissa esitettyä Hessian matriisin approksimaatiota tulee käyttää kuvaamaan painojen päivittymistä:

$$\Delta \mathbf{w}(n) \approx -[\mathbf{J}^T(n)\mathbf{J}(n) + \vartheta \mathbf{I}]^{-1}\mathbf{J}^T(n)\mathbf{e}(n),$$

missä \mathbf{I} on diagonaalinen matriisi, joka koostuu $\mathbf{J}^T(n)\mathbf{J}(n)$ diagonaalialkioista, ja ϑ on Marquardt-sopeuttamisparametri. Jos ϑ on nolla, Levenberg-Marquardt algoritmista tulee Newtonin algoritmi approksimoidulla Hessian matriisilla. Jos taas ϑ :n arvo on suuri, lähenee Levenberg-Marquardt algoritmi gradienttimenetelmää, joka etenee pienin askelin. Newtonin algoritmi on nopeampi ja tarkempi kuin gradienttimenetelmä virheen minimoinnin lähentyessä optimia, minkä takia pyrkimyksenä on siirtyä Newtonin algoritmin suuntaan niin nopeasti kuin mahdollista. ϑ pienenee jokaisella onnistuneella iteraation askeleelle, mikä pienentää suorituskäyfunktiota. ϑ kasvaa ainoastaan silloin, kun alustava tunnusteleva askel kasvattaa suorituskäyfunktiota. Näin suorituskäyfunktio pienenee jokaisen algoritmin iteraation yhteydessä. (Neural Network Toolbox User's Guide 4, 159.)

Levenberg-Marquardt algoritmi päivittää painoja samalla tavalla kuin Gauss-Newton algoritmi. Ainoana erona on ennalta määrätty ehdot, joita ϑ :lle annetaan. Tässä tutkimuksessa ϑ :n alkuarvona käytetään arvoa 0,001. Aina kun suorituskäyfunktio paranee eli pienenee, parametria ϑ pienennetään kertomalla se arvolla 0,1. Jos tuleva askel huonontaa suorituskäyfunktiota eli kasvattaa sitä, arvoa ϑ kasvatetaan kertomalla se kymmenellä. Jos taas ϑ kasvaa yli arvon 1E10, koulutus keskeytetään. Menetelmän suurin etu on siinä, että se etsii tasapainoa gradienttimenetelmän konvergoitumisen ja Newtonin algoritmin nopeuden välillä (Neural Network Toolbox User's Guide 2015, 515).

Levenberg-Marquardt algoritmin väitetään olevan nopein algoritmi keskikokoisten neuroverkkojen koulutuksessa (Neural Network Toolbox User's Guide 4, 159). Hagan ja Menhaj (1994) osoittivat, että Levenberg-Marquardt algoritmilla neuroverkon koulutuksesta voi suoriutua monin kerroin

nopeammin kuin gradient descent -pohjaisella taaksepäin levitys -menetelmällä. Menetelmän huonona puolena voidaan esittää, että siinä käytettävät Jacobin matriisit olettavat suorituskäytännön olevan rajoitettu kahteen vaihtoehtoon, eli joko keskineliövirheeseen (MSE) tai neliövirheiden summaan (SSE). Tässä tutkimuksessa käytettävä suorituskäytännön on MSE-funktio.

5. AINEISTO

S&P 500 -indeksi on Standard & Poor's Financial Services -yrityksen perustama indeksi, joka kuvaa Yhdysvaltain viidensadan markkina-arvoltaan suurimman yrityksen osakearvon kehitystä. S&P 500 -indeksiin noteeraaminen edellyttää yrityksiltä suuren markkina-arvon lisäksi listautumista Yhdysvaltojen suurimpiin pörssiin kuten New Yorkin pörssiin (NYSE) tai NASDAQ-pörssiin. Osakemarkkinaindeksi on painotettu yksittäisen yrityksen osakkeen markkina-arvon perusteella, mikä tarkoittaa, että markkina-arvoltaan suuremmat yritykset vaikuttavat indeksin liikkeisiin enemmän kuin pienet yritykset. Painotetusta keskimääräisestä markkina-arvosta ja indeksin tarjoamasta monipuolisuudesta johtuen S&P 500 -indeksi on maailman seuratuin indeksi. indeksi sisältää noin 80 prosenttia kaikkien Yhdysvalloissa julkisen vaihdon kohteena olevien osakkeiden markkina-arvosta. (Wikipedia 2016.)

S&P 500 -indeksi sisältää useita yrityksiä eri toimialoilta. Tästä johtuen indeksiin sijoittaminen on transaktiokustannusten ja painotetun keskimääräisen markkina-arvon takia sijoittajan näkökulmasta melko hankala sijoitus. Sijoittajille onkin suunniteltu erilaisia sijoitusinstrumentteja, jotka pyrkivät seuraamaan mahdollisimman tarkasti indeksin kehitystä. Tällaisia sijoitusinstrumentteja ovat muun muassa erilaiset pörssinoteeratut rahastot ja futuurit. Tämä tutkimus on rajattu koskemaan valittua pörssinoteerattua rahastoa.

Pörssinoteerattu rahasto eli ETF (exchange-traded fund) on sijoitusrahasto, jolla voidaan käydä kauppaa arvopaperipörssissä osakkeiden tavoin. Pörssinoteeratun rahaston kautta voidaan sijoittaa muun muassa osake-, korko-, hyödyke- tai kiinteistömarkkinoille. Pörssinoteerattujen rahastojen suosio on kasvanut merkittävästi sen jälkeen, kun ensimmäinen pörssinoteerattu rahasto ilmestyi markkinoille vuonna 1993. Pörssinoteerattu rahasto on siis sijoitusrahasto, jolla käydään kauppaa samalla tavalla kuin pörssiosakkeilla. Etuna perinteiseen osakesijoitukseen on se, että yhdellä kaupalla on mahdollista saada hajautettu osakesalkku. (Investment Company Fact Book 2015.)

Pörssinoteeratuilla rahastoilla on usein markkinatakaus, mikä yllä pitää osto- ja myyntitasoja. Lisäksi ETF-kaupankäynnissä ei ole varsinaista minimisijoitussummaa, vaan minimisijoituksen määrittelee pörssierän suuruus, joka suurimmalla osalla pörsseistä on yksi rahasto. Pörssinoteeratuilla rahastoilla sijoittamiseen liittyviä kuluja ovat rahastojen hallinnointipalkkiot sekä kaupankäyntikulut.


Hallinnointipalkkioita syntyy sitä enemmän, mitä useammin rahaston osakepainoa muutetaan. Pörssinoteerattu rahasto voidaan jakaa uudelleensijoittaviin ja tuottoa jakaviin. Uudelleensijoittava ETF sijoittaa saamansa osingot uudelleen eikä jaa omistajalleen tuottoa. Tuottoa jakava ETF maksaa tuoton kvartaaleittain, puolivuositain tai kerran vuodessa riippuen sovitusta ajankohdasta. Kaupankäyntikuluja ovat välityspalkkio sekä osto- ja myyntihintojen välinen ero eli spread. Spreadin ollessa pieni osuuksia voi ostaa ja myydä lähes samaan hintaan. Spread on alhainen ETF-rahastoilla, joiden kaupankäynti on vilkasta. Suurten sijoitusten kulurakennetta arvioitaessa on myös hyvä huomioida rahaston kaupankäynnin vilkkaus. (Investment Company Fact Book 2015.)

Pörssinoteerattuja rahastoja, jotka seuraavat S&P 500 -indeksiä on useita erilaisia. Keskeisiä eroja rahastojen välillä ovat rahastojen hallinnointikustannukset, painotukset ja voitonmaksumenetelmät. Suurimpia S&P 500 -indeksiä kuvaavia pörssinoteerattuja rahastoja on kolme. iShares on tarjonnut S&P 500 -indeksiä seuraavaa rahastoa 0,07 prosentin hallinnointipalkkiolla vuodesta 2000 lähtien. Lisäksi State Street SPDR ja Vanguard tarjoavat samankaltaisia rahastoja sijoittajille. Rahastot eroavat toisistaan alkamisajankohdan, hallinnointipalkkioiden ja vaihtomäärien osalta. Tässä tutkimuksessa keskitytään iSharesin tarjoamaan pörssinoteerattuun Core S&P 500 -rahastoon, jota merkitään pörssissä symbolilla IVV. Syy siihen, miksi kyseinen rahasto valittiin tutkimuksen kohteeksi, johtuu rahaston alkamisajankohdasta 2000-luvun puolella. Tällöin voidaan olettaa, että pörssinoteerattujen rahastojen tulo markkinoille on vakiintunut käytäntö, eikä suurten institutionaalisten sijoittajien mukaantulo vaikuta neuroverkon koulutuksessa käytettävään historialliseen aineistoon. Muita keskeisiä perusteita rahaston valinnalle ovat valuutta, voitonjakomenetelmä ja tasapainotuksen tiheys (Black Rock 2016).

Valuutta, jossa pörssinoteerattu iShares Core S&P 500 -rahasto noteerataan, on dollari. Saman valuutan käyttäminen helpottaa tarkastelua pitkissä aikasarjoissa, koska valuuttakurssien muutos voidaan poissulkea tarkastelusta. Toinen keskeinen valintaperuste on rahaston voitonjakomenettely, jonka perusteella voitot sijoitetaan aina takaisin osakkeisiin. Tällainen voitonjakomenettely helpottaa tarkastelua, koska osinkoja ei tarvitse huomioida tuottoihin. Rahaston tasapainotustiheys on neljännesvuosi, mikä mahdollistaa pienet hallinnointipalkkiot. iSharesin tarjoama Core S&P 500 -rahasto sijoittaa vähintään 90 prosenttia kaikesta varallisuudestaan kohteisiin, joita S&P 500 -indeksi sisältää. Ylimääräiset varat voidaan sijoittaa futuureihin, optioihin, swap-sopimuksiin, käteiseen tai johonkin käteistä vastaavaan sopimukseen, jos pörssinoteeratun rahaston tarjoaja uskoo sen edistävän S&P 500 -indeksin seuraamista. Tämä mahdollistaa Core S&P 500 -rahaston täsmällisen indeksin seuraamisen, vaikka osakepainoja muutetaan vain neljästi vuodessa. (Black Rock 2016.)

Tutkimuksessa käytettävä aineisto on peräisin yahoo.finance-verkkosivulta, joka tarjoaa pörssinoteeratun iShares Core S&P 500 -rahaston hintatiedot 19.5.2000 eteenpäin tunnuksella IVV sekä S&P 500 -indeksin tiedot tunnuksella GSPC aina 3.1.1950 eteenpäin. Pörssinoteeratusta Core S&P 500 -rahastosta saatavan aineiston vähäisyydestä johtuen aikasarjaa on jouduttu täydentämään S&P 500 -indeksistä saatavalla aikasarjalla. Haasteena on erilainen merkitsemistapa, sillä S&P 500 -indeksi ilmoitetaan pisteinä (1155,969971) ja pörssinoteerattu Core S&P 500 -rahasto dollareina (116,209999). Tästä johtuen tutkimuksessa käytetään parasta mahdollista arviota rahaston alkamispäivää edeltäneestä ajasta. Arvojen erilaisesta merkitsemistavasta syntyvä ongelma on ratkaistu jakamalla päivittäiset S&P 500 -indeksin arvot kymmenellä ylimääräisen desimaalin poistamiseksi S&P 500 -indeksin aineistosta. Näin luodaan oletettu hinta 3.1.1950 – 18.5.2000 väliselle ajanjaksolle. Aineistot on ladattu muodossa, jossa pörssinoteeratun rahaston dollarimääräinen hinta tai indeksin arvo on nähtävissä päivittäin. Tutkimuksessa aineiston tarkastelu on rajattu vain päivän päätöskurssiin ja siitä johdettuihin neuroverkon syötteisiin.

Päivän päätös



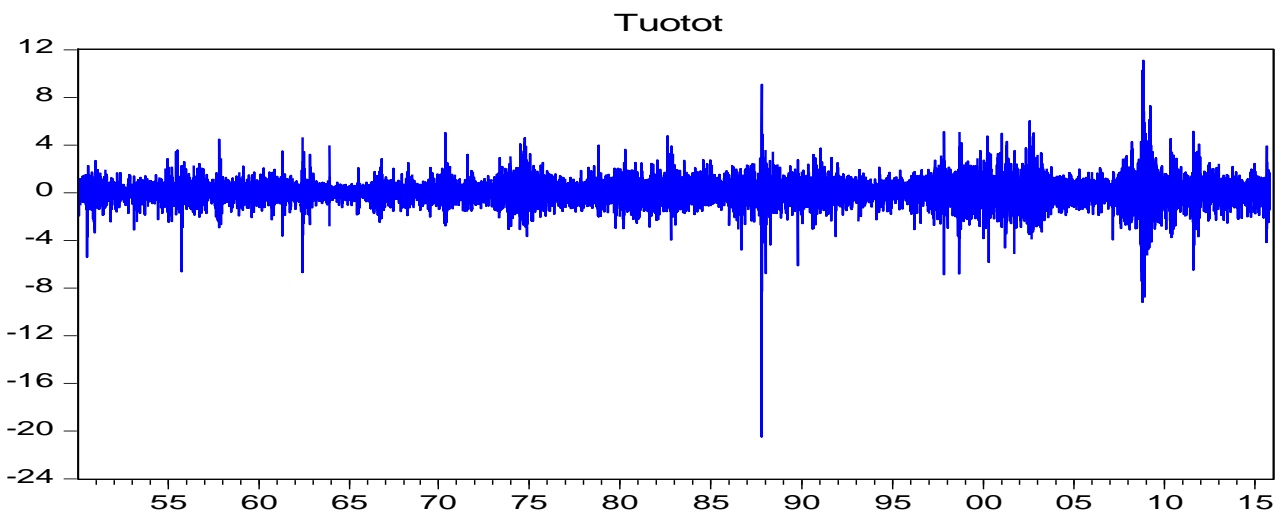
KUVIO 6. Päivän päätöskurssin kehitys.

Kuvio 6 esittää pörssinoteeratun Core S&P 500 -rahaston ja S&P 500 -indeksin yhdistelmän päivittäisen päätösarvon kehittymisen 3.1.1950 – 30.12.2015 välisellä aikajaksolla. Pystyakseli kuvaa päivän päätösarvoa ja vaaka-akseli ajanhetkeä.

5.1 Aineiston käsittely


Pörssinoteeratun Core S&P 500 -rahaston aineiston täydentäminen S&P 500 -indeksin aineistolla mahdollistaa 28 erilaisen muuttujan luomisen. Nämä muuttujat toimivat koulutettavan neuroverkon syötteinä. Syötteet on luotu aineistosta yksinkertaisilla yhteen-, vähennys-, kerto- ja jakolaskuilla. Syötteitä luodessa on varmistuttu siitä, että tieto on saatavilla kaupankäyntihetkellä. Neuroverkon pyrkimyksenä on ennustaa päivän päätöshinnasta huomisen päivän tuoton kehittymisen suunta, mikä ei tosi elämässä ole mahdollista, koska täysin luotettavaa päivän päätöshintaa ei ole pörssin aukioloaikana saatavilla. Päivän päätöshintaa ei kuitenkaan ole otettu pois laskelmista, sillä pörssin aukioloajan viimeisellä minuutilla tehtyjen kauppajen hinnat eivät juuri poikkea päätöskurssihinnasta tai, jos ne poikkeavat, voidaan olettaa, että virhe tapahtuu yhtä suurella todennäköisyydellä kumpaankin suuntaan.

Kuten kaikissa kvantitatiivissa tutkimuksissa, aineisto vaatii usein ennakkokäsittelyä. Linearisista malleista poiketen neuroverkon syötteille ei tarvitse erikseen tehdä logaritmuunnoksia tai tutkia logaritmuunnosten differenssien stationaarisuutta. Ennustettava aikasarja on kuitenkin päätetty muuttaa tässä tutkimuksessa tuotoiksi, sillä empiiriset kokeilut paljastavat, että käytössä oleva oppimisalgoritmi korostaa helposti viimeisten syötteiden painojen arvoja muutosten ollessa pieniä. Tämän seurauksena kumulatiivisia tuottoja tarkasteltaessa algoritmi antaa usein ennusteen, joka laahaa päivän jäljessä oppimisalgoritmin pyrkiessä replikoimaan viimeistä noteerattua arvoa.



KUVIO 7. Prosentuaaliset tuotot.

Kuvio 7 paljastaa, että aikasarja on tyypillinen osakemarkkinoilta poimittu aikasarja, joka sisältää suuria prosentuaalisia muutoksia yksittäisten päivien välillä. Kuvion pystyakselilla on prosentuaaliset tuotot ja vaaka-akselilla ajanjakso 1.2.1950 – 12.31.2015. Lisäksi alla olevan kuvion 8 histogrammi paljastaa, että päivittäiset tuotot ovat keskittyneet pääsääntöisesti nollan kummallekin puolelle tasaisesti.



KUVIO 8 Tuottojen histogrammi desimaalimuodossa.

Kuviosta 8 on lisäksi havaittavissa, että suurin osa päivittäisistä tuotoista on positiivisia. Tämä ei kuitenkaan tee osakemarkkinoista johdetun aikasarjan ennustamisesta helpompaa, sillä yhden yksittäisen päivän ennustaminen väärin saattaa kumota satojen onnistuneiden ennusteiden vaikutuksen kumuloituneissa tuotoissa mitattuna. Tätä havaintoa vahvistaa kuvion oikeassa laidassa oleva taulukko, jossa tuottojen minimiarvo on yli 20 prosenttia. Se kuvaa samalla mahdollisten päivittäisten tappioiden suuruutta. Toisaalta jo muutama oikeasuuntainen ennuste saattaa riittää osta ja pidä -strategian voittamiseen. Suuria ailahteluita ei ole poistettu aineistosta, vaan aineisto on pidetty mahdollisimman todenmukaisena, vaikka suuret ailahtelut aineistossa vaikeuttavat oppimisalgoritmin konvergoitumista. Suurten yksittäisten päiväheilahteluiden jälkeen ihmisten käytös markkinoilla saattaa olla hyvinkin ennustettavaa.

5.2 Ennustettava aineisto

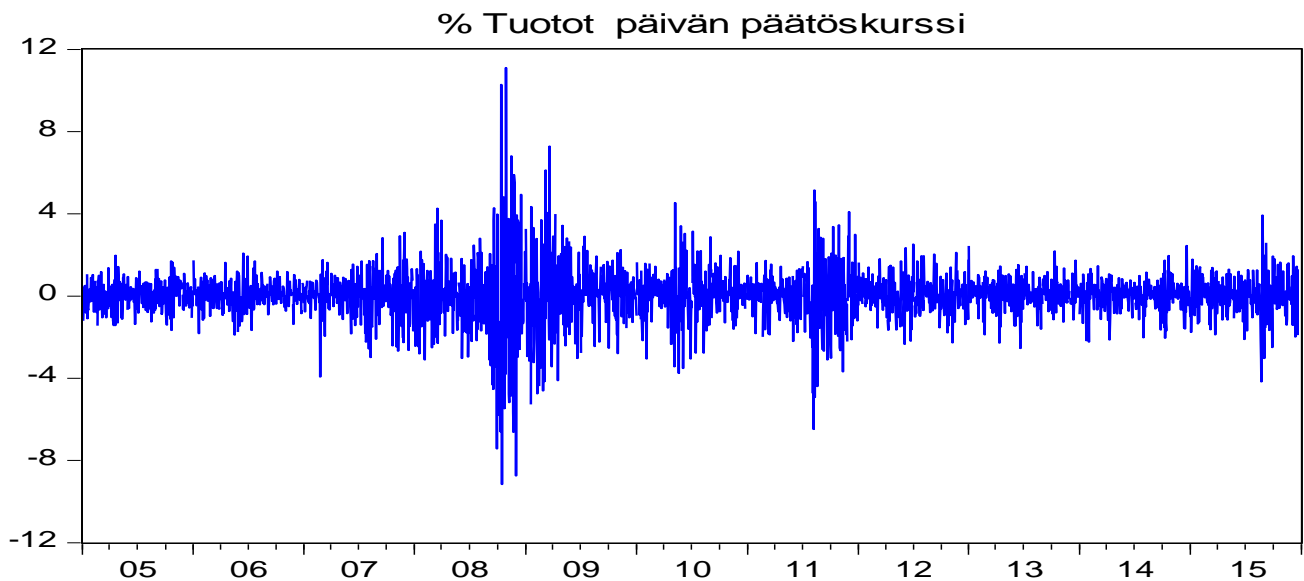
Ennustettava jakso alkaa 3.1.2005 ja päättyy 31.12.2015. Ennustettavat vuodet ovat 2005 – 2015 eli yhteensä 11 vuotta. Kullekin vuodelle koulutetaan oma neuroverkko, joka käyttää aineistonaan viittä

ennustetta edeltävää vuotta. Ennustejakson syöteinä käytetään aikaväliltä 3.1.2000 – 31.12.2014 saatu aineistoa. Syötteet ovat teoreettisia ja S&P 500 -indeksistä muokattuja 3.1.2000 – 19.5.2000, jonka jälkeen pörssinoteerattu Core S&P 500 -rahasto perustettiin. Ennustettavat ajanjaksot 3.1.2005 – 31.12.2015 ovat pörssissä noteerattuja todellisia rahaston dollarimääräisiä arvoja.



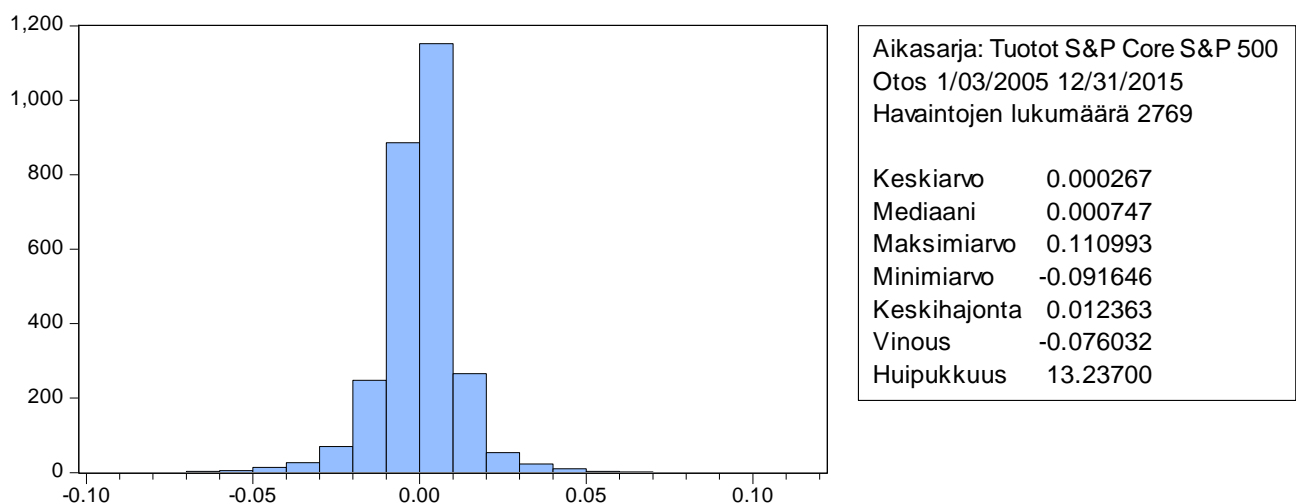
KUVIO 9. Päivän päätöskurssi.

Yllä olevassa kuviossa 9 on nähtävissä ennustettavan ajanjakson 3.1.2005 – 31.12.2015 dollarimääräinen kehitys. Pystyakselilla on dollareissa noteerattu päivän päätöskurssi ja vaakakselilla aika. Pörssinoteeratun rahaston tuotot ovat 11 vuoden ajanjaksolla noin 70 prosenttia. Vuositasolla tuotoissa on nähtävissä suurta vaihtelua.



KUVIO 10. Tuottojen prosentuaalinen jakautuminen.

Kuviossa 10 on nähtävissä päivän päätöskurssin tuottojen prosentuaalinen jakautuminen ennustejakson ajalle. Pystyakselilla on tuottojen prosentuaalinen muutos ja vaaka-akselilla aika. Vuoden 2008 finanssikriisin aikaisten tuottojen heittelehtiminen molempiin suuntiin on helposti havaittavissa aikasarjasta. Lisäksi myös vuosien 2010, 2011 ja 2015 aikana on tapahtunut muusta aikasarjasta poikkeavaa tuottojen suurta heittelehtimistä.



KUVIO 11. Tuottojen prosentuaalinen jakautuminen desimaalimuodossa.

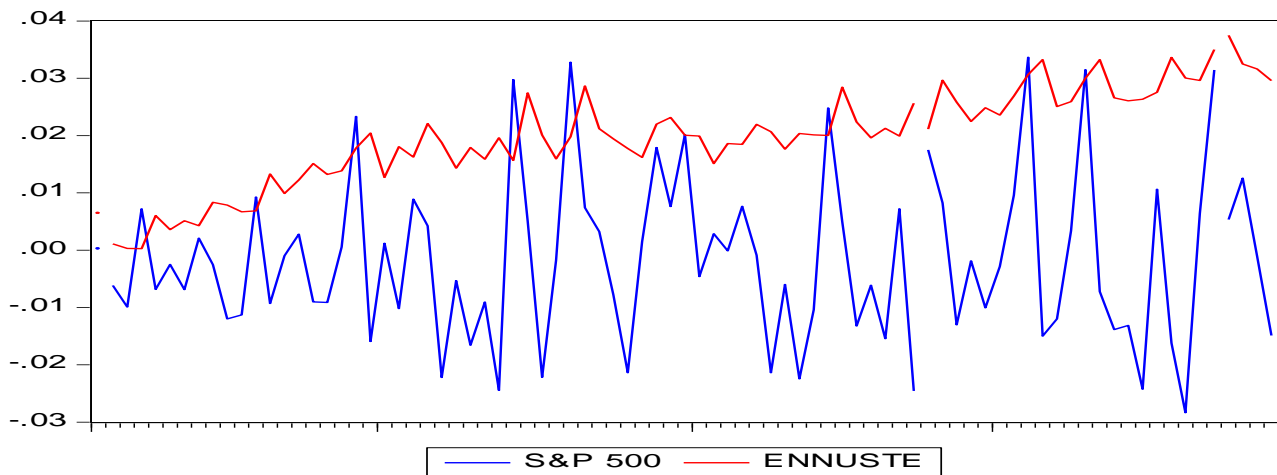
Kuviossa 11 pystyakselilla on päivien lukumäärä ja vaaka-akselilla tuotot desimaalimuodossa. Kuvioista on nähtävissä, että Core S&P 500 -rahaston tuotot ovat jakautuneet samalla tavoin kuin kuviossa 8, joka kuvastaa koko aineistoa. Positiivisia arvoja on useammin kuin negatiivisia. Keskeisenä erona koko aineiston 3.1.1950 – 31.12.2015 ja ennustettavan aineiston 3.1.2005 –

31.12.2015 välillä on minimiarvo, joka on ennustejaksolla -9,2 prosenttia, kun taas koko aineistossa se on paljon suurempi eli -20,5 prosenttia. Toisin sanoen finanssikriisin tuottamat suuret tappiot eivät ole poikkeuksellisia verrattaessa niitä koko aineistoon. Maksimiarvo kummankin histogrammin taulukossa on sama. Tämä kertoo siitä, että ennustettavalla ajanjaksolla tapahtuu poikkeuksellisen hyviä pörssikurssien nousuja. Lisäksi keskihajonta on suurempi ennustejaksolla kuin koko aineistossa, mikä tarkoittaa, että ennustejakson tuotot ailahtelevat enemmän kuin kokonaisaineistossa.

5.3 Sijoitusstrategian luominen

Tutkimuksessa käytössä oleva taaksepäin levitys -menetelmä hyödyntää Levenberg-Marquardt algoritmia, joka johtaa usein naiiviin ratkaisuun koulutusaineiston sisältäessä paljon kohinaa. Lisäksi empiiriset kokeilut algoritmilla antavat näyttöä siitä, että Levenberg-Marquardt algoritmi päättyy usein ratkaisuun, jossa ennustettujen tuottojen arvo on jatkuvasti yli tai alle todellisten arvojen. Ilmiöstä ei ole raportoitu aikaisemmissa rahoitusmarkkinoita koskevissa tutkimuksissa, joten sen alkuperää voi vain arvailla. Levenberg-Marquardt algoritmilla luotu ennuste toistaa todennäköisesti koulutusaineistossa eniten esiintyvän tuoton suuntaa. Siksi myös sitä voidaan kutsua naiiviksi ratkaisuksi.

Algoritmilla saadut tuottoennusteet reagoivat usein oikeasuuntaisesti todellisten tuottojen kehitykseen. Toisin sanoen ennustettujen ja todellisten tuottojen differenssit kehittyvät usein samansuuntaisesti. Alla oleva kuvio 12 havainnollistaa ongelmaa Levenberg-Marquardt algoritmilla ennustettujen tuottojen ja todellisten tuottojen välillä.



KUVIO 12. S&P 500 -indeksin todellinen arvo ja naiivi ennuste.

Kuviossa 12 pystyakseli kuvaa tuottoja desimaalimuodossa ja vaaka-akseli aikaa päivinä. Kuvioista on nähtävissä, että S&P 500 -indeksin tuotot liikkuvat jatkuvasti nollatuoton kummallakin puolella stationaarisesti. Neuroverkolla tehty ennuste sen sijaan on jatkuvasti positiivinen, vaikka verkko onnistuu usein arvaamaan seuraavan päivän tuottojen kehittymisen suunnan suhteessa edellisen päivän tuottoihin. Ilmiötä voidaan mahdollisesti hyödyntää markkinoiden ennustamisessa.

Valitettavasti mikään markkinoilla oleva neuroverkkosovellutus ei tarjoa välineitä ennusteiden ja todellisten arvojen differenssien tutkimiseen. Tehokkaiden markkinoiden hypoteesin tutkimisen näkökulmasta ongelma on ratkaistavissa menetelmällä, jossa keskitytään ennustusteiden ja ennusteita edeltävien ennusteiden differensseihin. Sijoitusstrategia, joka pohjautuu neuroverkon antamien tarkkojen ennusteiden sijasta huomisen ja nykyisen ennusteen erotukseen ja sen perusteella luotuun osta-signaaliin tai lyhyeksi myy -signaaliin, saattaa kyetä voittamaan tehokkaiden markkinoiden teoriaa tukevan osta ja pidä -strategian. Toisin sanoen neuroverkon ennuste ei ota kantaa siihen, milloin positio otetaan tai siitä luovutaan, vaan ainoastaan siihen, onko seuraavan päivän päätöskurssi suurempi tai pienempi kuin tämän päivän päätöskurssi.

Tutkimuksessa käytettävät ennustettujen tuottojen differenssit kykenevät jossain määrin replikoimaan markkinoiden todellisia tuottoja. Ongelmaksi muodostuu kuitenkin se, ettei täydellisenkään differenssien ennustaminen takaa onnistunutta lopputulosta. Näin voi käydä esimerkiksi tilanteessa, jossa todelliset tuotot ovat tänään 2 prosenttia ja huomenna 1 prosentin. Pelkästään yhden differenssin perusteella luotu oikean ennuste ehdottaisi vastaukseksi negatiivisen arvon ($1 - 2 = -1$). Tällöin sijoittajan, joka luottaa neuroverkon kahden edellisen päivän erotuksen pohjalta luotuun strategiaan, tulisi ottaa lyhyeksi myynti -positio. Tässä tilanteessa tämä olisi

kuitenkin huono valinta, koska markkinat nousivat yhden prosentin aiheuttaen näin sijoittajalle yhden prosentin tappiota. Päätöksenteon tueksi tarvitaan myös muita muuttujia.

Tutkimuksessani laadin strategioiden luomiseksi kaksi erityyppistä menetelmää, jotka pohjautuvat seuraavan päivän tuottoennusteen lisäksi 1–4 edellisen päivän ennusteisiin. Strategioissa 1–4 eri päivän ennusteen suhdetta tarkkaillaan edellisiin ennusteisiin, minkä perusteella otetaan kantaa pörssinoteeratun rahaston seuraavan päivän tuoton kehittymisen suuntaan. Ennustettujen tuottojen keskinäistä suhdetta vertaillaan ja luodaan useaan edelliseen ennusteeseen perustuva strategia.

Kolmeen ennustettavaan arvoon perustuva strategia toimii melko yksinkertaisella mekanismilla. Oletetaan esimerkiksi, että tänään tehty tuottoennuste on suurempi kuin edellisen päivän tuottoennuste. Näin ollen niiden erotus on positiivinen. Matemaattisesti tämä on kuvattavissa:

$$e_{t+1} - e_t = d_t^1,$$

missä e tarkoittaa tuottoennustetta. d kuvaa ennustettujen arvojen erotusta eli differenssiä, yläindeksi differenssin astetta ja alaindeksi t ajanhetkeä. Aikasarjan ennusteiden esittäminen differenssimuodossa on jatkettavissa niin pitkälle kuin edellisiä arvoja riittää:

$$e_t - e_{t-1} = d_{t-1}^1.$$

Differensseistä voidaan ottaa erotus:

$$d_t^1 - d_{t-1}^1 = d_t^2.$$

Myös eriasteisia differenssejä voidaan muodostaa niin pitkään kuin edellisiä arvoja riittää. Kaikkiin differensseihin liittyvä tieto on saatavilla samalla ajan hetkellä, kun uusi ennuste luodaan. Nyt differenssien pohjalta voidaan luoda sijoitusstrategia, joka huomioi ensimmäisen asteen differenssin ja toisen asteen differenssin etumerkin. Differensseihin pohjautuva sijoitusstrategia irrottautuu pelkän ennusteen perusteella tehdyistä sijoituspäätöksistä eikä näin ole sidottu niiden menestykseen. Tämä mahdollistaa kokeen toistamisen suunnaltaan naiivin ensimmäisen tuottoennusteen ollessa pois kuvioista.

Kolmeen ennustettuun ajanhetkeen perustuva strategiajoukko määräytyy vain kahden differenssin suhteesta nolnaan, kun ”yhtä suuri” -vaihtoehto on suljettu pois. Tuottoennusteiden kahteen eriaisteiseen differenssiin pohjautuvia erilaisia muunnelmia on neljä:

$$d_t^1 > 0, d_t^2 > 0$$

$$d_t^1 < 0, d_t^2 < 0$$

$$d_t^1 > 0, d_t^2 < 0$$

$$d_t^1 < 0, d_t^2 > 0$$

Ainoastaan yksi edellä mainituista neljästä vaihtoehdosta voi olla voimassa kerrallaan. Jokaiseen vaihtoehtoon voidaan reagoida kahdella tapaa joko ostamalla pörssinoteerattua rahastoa tai lyhyeksi myymällä sitä. Toisin sanoen edellä mainituista neljästä vaihtoehdosta on johdettavissa $2^4 = 16$ erilaista strategiaa, jotka reagoivat yksityiskohtaisesti pörssinoteeratun rahaston seuraavan päivän kehitykseen.

Kolmeen eriaisteiseen differenssiin pohjautuva strategia on hieman monimutkaisempi:

$$d_t^1 < 0, \quad d_t^2 > 0, \quad d_t^3 > 0$$

Kolmen eri differenssin asteen suhteesta nolnaan on saatavissa kahdeksan erilaista kombinaatiota yhtäsuuruus merkin ollessa pois käytöstä. Kuten kahden eriaistisen differenssin tapauksessa, jokaiseen kahdeksaan tapaan on strategian näkökulmasta olemassa kaksi erilaista tapaa reagoida, eli osta tai myy lyhyeksi. Näin ollen kolmesta eriaisteisesta differenssistä on johdettavissa $2^8 = 256$ erilaista strategiaa, jotka antavat yksityiskohtaisen vastauksen markkinoihin osallistumisen suunnasta.

Tutkimuksessa tarkastellaan kaikkia $16 + 256 = 272$ erilaista strategiaa. Strategioiden edustavat kaikkia mahdollisia tapoja yhdistää kolme eriaisteista differenssiä suhteessa nolnaan silloin, kun markkinatoimenpiteitä tehdään päivittäin. Lisäksi differenssien viiveitä voidaan muuttaa, jolloin tutkijalle tarjoutuu uusi 272 strategian valikoima. Strategioiden lukuisa määrä mahdollistaa myös useita strategioita, jotka menestyvät surkeasti. Menestyvien strategioiden löytämiseksi on luotava johdonmukainen strategian valitsemismenettely satunnaisten menestyjien karsimiseksi.

Satunnaisluvuilla toistettu tutkimus ei kykene menestymään tarkasteltavasta periodista toiseen aikavälin ollessa tarpeeksi pitkä.


Ongelma on ratkaistavissa jakamalla aineisto kahteen osaan siten, että ensimmäistä osaa voidaan soveltaa sopivan strategian valitsemiseen, kun taas toinen osa toimii varsinaisena ennustejaksona. Strategian valitsemiseen käytettävän aikajakson tulee olla tarpeeksi pitkä, jotta satunnaisesti menestyvät strategiat voidaan tunnistaa ja poissulkea joukosta. Tarkastelun laajentamiseksi ja sijoittajan näkökulmasta riskin hajauttamiseksi valintaprosessiin on myös syytä sisällyttää useampia strategioita vain yhden menestyneimmän strategian sijasta. Tässä tutkimuksessa strategian valitsemisjaksolta valitaan yksi parhaiten menestyvä kahden eri differenssin asteeseen perustuva strategia ja 3 parasta kolmeen eri differenssiin perustuvaa strategiaa. Lisäksi joukkoon valitaan vielä yksi strategia kolmeen eri differenssiin perustuvista strategioista siten, että toisen asteen differenssiä viivästetään yhdellä viiveellä. Eri strategioiden menestystä testataan kymmenen vuoden ennustejaksossa ja verrataan tuloksia osta ja pidä -strategiaan.

Sijoituspäätös tapahtuu käytännössä siten, että voitot tai tappio realisoidaan pörssipäivän viimeisellä minuutilla, jonka yhteydessä laaditaan myös uusi huomisen tuottoennuste. Viimeisellä pörssin aukiolominuutilla saatava informaatio on todennäköisesti likimain päivän päätöskurssia, minkä seurauksena aikasarjan historiallista päätöskurssia voidaan käyttää ennustusten laatimiseen. Jos viimeisen minuutin hinta poikkeaa historiallisesta päätösarvosta, on muutos todennäköisesti merkityksettömän pieni. Lisäksi voidaan olettaa, että muutos rahaston hinnassa viimeisen minuutin aikana vaikuttaa ennustettuun positioon joko positiivisesti tai negatiivisesti yhtä suurella todennäköisyydellä. Näin ollen viimeisen minuutin hinta on tarpeeksi tarkka approksimaatio päätöskurssista ja mahdollistaa päätöskurssin hinnan käytön tutkimuksen aineistona.

Strategiassa kaupankäyntikustannuksia minimoidaan siten, että neuroverkon ennustamasta positioista ei luovuta ennen kuin uusi siitä poikkeava ennuste ilmaantuu. Tätä voidaan kuvata keinotekoisena pidä-asetelmana, osta-asetelman tai lyhyeksi myy -asetelman lisäksi. Jos uusi ennuste poikkeaa edellisestä asetelmasta, edellinen asetelma realisoidaan ja uusi ostetaan. Rahasto-osuuden nousuun uskova ennustetta kutsutaan tässä tutkimuksessa long-positioksi ja pörssinoteeratun rahaston laskua ennustavaa asetelmaa kutsutaan short-positioksi.

5.4 Koulutuksen laadun tarkkailu

Ennen koulutusta aineisto normalisoidaan koulutuksen laadun parantamiseksi. Neuroverkon koulutuksen laatua tarkkaillaan neljän tekijä avulla, jotka ovat suorituskky, virheiden jakaantuminen nollavirheen ympärille histogrammissa, ennusteen osumien määrä sekä ensimmäisen ja toisen differenssin osumien todennäköisyys. Näistä eniten painoarvoa annetaan ensimmäisen differenssin osumatarkkuudelle, koska kaikki sijoitusstrategiat nojaavat ensimmäiseen differenssiin. Lisäksi MATLAB tarjoaa käyttäjälleen useita erilaisia mittareita ennusteiden laadun arvioimiseen, mutta niille ei annettu suurta painoarvoa tässä tutkimuksessa ja siksi ne on jätetty esittelemättä.



KUVIO 13. Suorituskyvyn paraneminen koulutus-, validointi- ja testiryhmällä epokkien lisääntyessä.

Kuvio 13 havainnollistaa suorituskyvyn paranemista koulutus-, validointi- ja testiryhmällä epokkien lisääntyessä. Kuviossa viivat kuvastavat koulutusaineistolle tehtävää jaottelua. Sininen viiva kuvastaa koulutusryhmää, vihreä viiva kuvastaa validointiryhmää ja punainen viiva kuvastaa testiryhmää. Kuviossa on havaittavissa keskineliövirheen (suorituskykyfunktion) pieneminen kaikilla koulutusryhmillä aina kymmenenteen epokkiin eli aikakauteen asti, jolloin niin sanottu paras piste eli paras epok saavutetaan. Vihreä viiva eli validointiryhmän suorituskyvyn kasvaminen aikaansaa virhesignaalin, joka keskeyttää koulutuksen ylisovittamisen välttämiseksi. Koulutuksen jatkaminen parhaasta pisteestä eteenpäin ei enää lisää neuroverkon kykyä tunnistaa syötteiden ja tavoitearvojen

välistä suhdetta. Neuroverkon koulutus pysäytetään ja palautetaan painokertoimet, jotka olivat voimassa parhaan pisteen kohdalla.

Toinen menetelmä koulutuslaadun tarkkailuun on ennustevirheiden tarkkailu histogrammissa. Visuaalinen tarkkailu auttaa valitsemaan sellaisen neuroverkon, jonka painot tuottavat tuloksia, jotka asettuvat nollavirheen läheisyyteen. Neuroverkko, joka kykenee minimoimaan ennustevirheet lähelle nollavirhettä ja joka ei ole ylisovitettu suhteessa koulutettavaan aineistoon, kykenee suuremmalla todennäköisyydellä samankaltaisiin tuloksiin ennusteaineistossa.

Kolmas menetelmä koulutuksen laadun tarkkailuun on koulutusaineiston ja ennustettavan aineiston välisen suunnan osumatarkkuus. Osumaksi lasketaan sellainen ennuste, joka kykenee ennustamaan kehityksen samansuuntaiseksi todellisten arvojen kehittymisen kanssa. Lisäksi tuottoennusteista johdettujen ensimmäisen asteen differenssien ja toisen asteen differenssien osumatarkkuutta tarkastellaan suhteessa todellisten tuottojen eriasteisiin differensseihin. Osumatarkkuus merkitään aina päivittäisellä aineistolla ja on luonteeltaan joko negatiivinen tai positiivinen. Näin ollen osumatarkkuuden tulee ylittää reilusti yli 50 prosenttia, jotta neuroverkko hyväksytään. Differenssien tarkastelu otettiin mukaan koulutuksen laadun tarkkailuun, koska se saattaa tarjota lisätietoa seuraavan päivän tuottojen kehittymisen suunnasta. Satunnaisluvuilla replikoidussa ennustettujen tuottojen tutkimuksessa eriasteisten differenssien osumatarkkuus ei ylitä 50 prosenttia aineiston ollessa riittävän suuri.

5.5 Strategian valitsemisjakso

Ennustettava aineisto on jaettu kahteen osaan. Toista osaa käytetään strategian valitsemiseen ja toista osaa itse ennusteen tekemiseen. Strategian valitsemisjaksoksi valittiin vuosi 2005. Kyseinen vuosi sisältää voimakkaita nousu- ja laskukausia mutta asettuu kuitenkin vuoden päätteeksi aloitusarvoaan korkeammalle. Strategia, joka menestyy tällaisella ajanjaksolla, kykenee sopeutumaan sekä nousu- että laskukausiin ja samalla huomioi aikasarjan jatkuvan nousutrendin.



KUVIO 14. Osta ja pidä -strategian kumulatiivinen kehitys.

Yllä oleva kuvio 14. havainnollistaa osta ja pidä -strategian kehittymistä kyseisellä aikaperiodilla alkuvarojen ollessa 100 000 dollaria. Kuvion pystyakselilla on kumulatiiviset tuotot ja vaaka-akselilla aika.

5.6 Transaktiokustannukset

Tässä tutkimuksessa tutkitaan 100 000 dollarin arvolla ostetun pörssinoteerattuun iShares Core S&P 500 -rahastoon tehdyn sijoituksen kehittymistä 3.1.2005 – 31.12.2015 välisenä aikana. Kiinteät transaktioiden hinnat ovat tyypillisin osakevälittäjien tarjoama ratkaisu alle 100 000 dollarin sijoituksille. Keskihinta eri välittäjien veloittamista kiinteämääräisistä transaktiopalkkioista vaihteli vuoden 2015 lopussa 2,5 – 9,99 dollarin välillä. Lisäksi jotkut välittäjät tarjoavat pörssinoteerattuun Core S&P 500 -rahastoon sijoittamista ilmaiseksi, kunhan positioksi valitaan long-positio, joka pidetään yli 30 päivää. (Stock Trader 2016.)

Palveluntarjoajilla on useita erilaisia tapoja laskuttaa sijoittajia. Kustannukset syntyvät usein positioiden ottamisesta johtuvien transaktiokustannuksien lisäksi short-position lainan korosta, ostetusta informaatiosta, tilinhoitopalkkiosta, korottomasta talletustilistä, valuutanvaihtokustannuksista, kaupankäyntialustan maksullisuudesta ja useista muista eri palveluntarjoajien kehittämistä palveluista. Lisäksi välittäjät saattavat ottaa lisäpalkkion sijoituksen määrän ylittäessä ennalta määrätyn kynnsarvon. Kynnsarvo vaihtelee 1000 - 2000 rahasto-osuuden välillä riippuen välittäjästä. Rahasto-osuuden kasvaessa yli kynnsarvon välittäjät ottavat usein

prosentuaalisen palkkion koko ostoksen dollarimääräisestä arvosta tai palkkio on sidottu rahasto-osuuksien lukumäärään.


100 000 dollarista ylöspäin transaktiokustannukset hinnoitellaan tyypillisesti ostettujen osakkeiden perusteella. Esimerkiksi pörssinoteerattuja rahastoja välittävä Interactive Brokers tarjosi vuonna 2016 ostettujen rahastojen määrään sidottua hinnoittelua. Hinnoittelu alkaa noin 0,0035 dollarista jokaista ostettua pörssinoteerattua rahastoa kohti ja on halvimmillaan 0,0005 dollaria per rahasto-osuus. Edullisiin 0,0005 dollarin transaktiokustannuksiin pääseminen vaatii todella suuria transaktiomääriä. Transaktiomäärien tulee ylittää 100 000 000 osaketta kuukaudessa, mikä ei käytännössä ole mahdollista kuin penniosakkeilla tai todella suurilla pääomilla. Esimerkiksi 100 000 dollarin sijoituksella saisi vuoden 2015 lopussa 488 osaketta pörssinoteeratun rahaston hinnan ollessa 204,87 dollaria. Jokaisesta ostetusta pörssinoteeratusta rahastosta peritään 0,0035 dollarin transaktiokustannus. Näin ollen transaktiokustannusten kokonaishinnaksi tulee noin 1,71 dollaria per transaktio. Sijoittaja, jolla on mahdollisuus suurempien välittäjien vaatimiin yli 100 000 dollarin minimitalletuksiin, voi vuonna 2016 nauttia huomattavasti pienemmistä transaktiokustannuksista. (Interactive Brokers 2016.)

Transaktiokustannusten määrittäminen tässä tutkimuksessa on haasteellista, koska testattava aikaperiodi on kymmenen vuotta. Tässä ajanjaksossa kaupankäyntikustannukset ovat laskeneet tutkimuksen kannalta merkittävästi ja aiheuttavat vaikeuksia hypoteesin testaamisessa. Lisäksi on haasteellista rakentaa malleja, joissa kaupankäyntikustannukset vähennetään kumuloituvasta pääomasta. Tästä johtuen kaupankäyntikustannukset on otettu tässä tutkimuksessa huomioon kahdella eri tavalla.

Ensimmäisessä menetelmässä oletetaan, että kustannukset kertyvät erilliselle velkatilille, josta transaktiokustannukset kuitataan kymmenen vuoden ennusteperiodin lopuksi kerralla, eikä korkokuluja makseta (bullet-laina). Tällainen menettely kuvaa sijoittajan näkökulmasta tilannetta, jossa rahaa on saatu nollakorolla kaupankäyntikustannuksiin tai 100 000 dollarin rahastosijoituksen lisäksi sijoittajalla on erillinen tili, jonka pääoma on varattu kaupankäyntikustannuksiin. Toisessa tavassa transaktiokustannusten kumulatiivinen vaikutus huomioidaan muuttamalla tuotot ja transaktiokustannukset logaritmuotoon, jolloin prosentuaalisten kustannusten huomioiminen on helppoa. Lyhyeksi myynnin kustannusten laskemiseen käytetään Yhdysvaltojen valtion liikkeelle laskemaa yhden kuukauden viitekorkoa (Treasury Bill 1-month). Lisäksi lyhyeksi myynnin kustannuksiin on huomioitu välittäjän ottama marginaali.

Li, Mooradian ja Zhang (2006, 15) arvioivat NYSE:n (New York Stock Exchange) keskimääräisen välittäjän komissiokustannuksen olleen vuonna 2003 noin 0,079 prosenttia vaihdon arvosta. Osakekohtaiseksi keskikustannukseksi he arvioivat 0,0205 dollaria per osake. Tämä tarkoittaisi 100 000 dollarin sijoitukselle 75 dollarin transaktiokustannusta. Vuoden 2006 alussa 100 000 dollarilla ostaisi 802,12 Core S&P 500 -rahaston osuutta, mikä tarkoittaisi vuoden 2003 osakekohtaisella hinnalla 16,44 dollarin kaupankäyntikustannusta. Lisäksi Li, Mooradian ja Zhang (2006) osoittivat kaupankäyntikustannusten laskeneen huomasti osakekaupan volyymin kasvaessa 1980-luvulta 2000-luvulle (liite 1).

Tässä tutkimuksessa position vaihdosta syntyväksi kustannukseksi valittiin 0,02125 prosenttia. Tämä on peruskustannus, joka syntyy jokaisen position vaihdosta. Tähän kustannukseen lisätään vielä pankin short-positioista syntyvät korkokulut, kuten marginaali ja viitekoron kustannukset. Tutkimuksessa pankin vuotuiseksi marginaaliksi valittiin 2 prosenttia, joka veloitetaan vain päiviltä, jolloin short-positio on valittu. Lisäksi short-position kustannuksiin lisätään viitekorko, joka on tässä tutkimuksessa yhden kuukauden Yhdysvaltojen valtionlainan korko (1-month T-bill). Prosentuaaliset transaktioiden kokonaiskustannukset vaihtelevat tutkittavan periodin aikana 0,02125 - 0,05069 prosentin välillä. Tämä tarkoittaa, että kustannukset arvoltaan 100 000 dollarin sijoitukselle ovat vaihdelleet 21,25 – 50,69 dollarin välillä. Pääoman kasvaessa prosentuaalinen kustannus kasvaa dollarimääräisesti. Korkeimmillaan short-position tuoma lisäkustannus oli ennen vuoden 2007 loppua ja edullisimmillaan vuodesta 2008 eteenpäin. Tästä lähtien korot ovat olleet todella lähellä nollaa tai jopa nolla (kuvio 15).



KUVIO 15. Yhdysvaltojen valtionlainan korko.

Muita kustannuksia tai etuja tässä tutkimuksessa ei ole huomioita. Tällaisia kustannuksia tai etuja ovat muun muassa ajassa muuttuvat transaktiomaksut, osto- ja myyntikurssien erotus sekä palveluntarjoajan rahasto-osuusmääräisen kynnyksarvon ylittämisestä syntyvät kustannukset tai alennukset. Lisäksi osake-eristä syntyviä hyötyjä tai haittoja ei huomioida, vaan tutkimuksessa käytetään osakkeiden osamääriä. Esimerkiksi vuoden 2004 lopussa pörssinoteeratun osakkeen arvon ollessa 121 dollaria tutkija voi ostaa 100 000 dollarilla 826,45 pörssinoteerattua rahasto-osuutta, vaikka puolikkaita rahasto-osuuksia ei todellisuudessa myydä. Lisäksi useiden välittäjien tarjoamasta yli 30 päivän ilmaisesta long-positiosta on luovuttu. Mukaan ei myöskään lasketa arvo-osuustilin ylläpitämiskustannuksia tai eri välittäjien tarjoamia bonuksia, kuten 50 ensimmäistä kauppaa ilmaiseksi -tarjousta.

6 TEHOKKAIDEN MARKKINOIDEN JA NEUROVERKKOPOHJAISTEN STRATEGIOIDEN TESTAUS

Ennen aineiston varsinaista testaamista on selvitettävä, täyttääkö ennustettava ajanjakso tehokkaiden markkinoiden hypoteesiin vaadittavan satunnaisen käyttäytymisen. Satunnaiskulkuprosessin tulee olla epästationaarinen stokastinen prosessi, mutta siitä muodostettujen tuottojen tulee olla stationaarisia (Koop 2008, 184). Tämä tarkoittaa sitä, että ennustettavan päätöskurssiaineiston tulee sisältää yksikköjuuri, mutta siitä johdettavat tuotot eivät saa sisältää yksikköjuurta.

Edellä mainitun testin aikasarjan stationaarisuudelle kehittivät Dickey ja Fuller vuonna 1981. Myöhemmin testiä paranneltiin aikasarjan askelten mahdollisesta autokorreloitumisesta aiheutuvan harhan vuoksi. Autokorreloitumisen seurauksena kehitettiin augmentoitu Dickey–Fuller-testi (ADF-testi), jossa lisätään lineaarisen mallin viiveitä niin pitkään, että virhetermi ε_t on jaksoittain korreloimaton. Näin ensimmäisen viiveen kertoimesta saadaan harhaton estimaatti. ADF-testin sopiva viivepituus on määriteltävissä informaatiokriteereillä kuten Akaike-informaatiokriteerillä. Mallin kriittiset arvot seuraavat testissä käytettävää τ -jakaumaa (tau-jakaumaa). (Gujarati & Porter 2009.)

iShares Core S&P 500 -rahastosta saatavaa aikasarjaa väliltä 3.1.2005 – 31.12.2015 tulee testata augmentoidulla Dickey–Fuller-testillä. Alla oleva taulukko 1 kuvaa rahaston päätöskurssiaineistolle tehtävän yksikköjuuritestin tuloksia. Testattavaan aineistoon on otettu mukaan tau-jakaumasta saatavat kriittiset arvot, havaintojen lukumäärä, testin t-arvo ja Akaike-informaatiokriteerillä (AIC) valittu viivepituus autokorreloituneisuuden välttämiseksi. Lisäksi testi on suoritettu lineaarisille malleille, joissa on huomioitu deterministisen aikatrendin ja vakion mukanaolo.

TAULUKKO 1. ADF-testi päätöskurssiaineistolle.

AIC		$\Delta p_t = \delta p_{t-1} + \sum_{i=1}^m \alpha_i \Delta p_{t-i} + \varepsilon_t$	
havaintojen lkm	viiveiden lkm.	kriittinen arvo 5%	t-arvo
2570	18	-1.940939	1.292488
AIC		$\Delta p_t = \mu + \delta p_{t-1} + \sum_{i=1}^m \alpha_i \Delta p_{t-i} + \varepsilon_t$	
havaintojen lkm	viiveiden lkm.	kriittinen arvo 5%	t-arvo
2570	18	-2.862392	-0.171098
AIC		$\Delta p_t = \mu + \theta_1 t + \delta p_{t-1} + \sum_{i=1}^m \alpha_i \Delta p_{t-i} + \varepsilon_t$	
havaintojen lkm	viiveiden lkm.	kriittinen arvo 5%	t-arvo
2570	18	-3.411441	-1.188842

Taulukossa 1 Δ kuvastaa ensimmäistä differenssiä, p rahaston hintaa, t ajanhetkeä, μ vakiota, δ estimoitavaa kerrointa, m viiveiden määrää, θ_1 determinististä aikatrendiä ja ε_t virhetermiä. (PcGive Help, 16.4.)

Edellä esitetyn testin hypoteesi on muotoiltavissa δ -kerroimen avulla muotoon: H_0 hypoteesi on $\delta = 0$ eli testattava aikasarja on epästationaarinen ja H_1 hypoteesi on $\delta < 0$ eli testattava aikasarja on stationaarinen.

Tulkinta taulukon 1 tuloksista tapahtuu siten, että jos testin kriittinen arvo on pienempi kuin t-arvo, H_0 -hypoteesi jää voimaan. Taulukossa 1 esitettyjen tulosten perusteella H_0 -hypoteesi jää voimaan kaikissa testin yhtälömuodoissa. Toisin sanoen päätöskurssi aikasarjalla on yksikköjuuri eli se on epästationaarinen.

Sama testi toistetaan aineiston tuotoille. Tuotoille tehtyjen yksikköjuuritestien tulokset ovat nähtävissä alla olevasta taulukossa 2. Kaikkien testattavien yhtälömuotojen t-arvo on pienempi kuin kriittinen arvoa.

TAULUKKO 2. ADF-testi tuotoilla.

AIC		$\Delta^2 p_t = \delta \Delta p_{t-1} + \gamma p_{t-1} + \sum_{i=1}^m \alpha_i \Delta^2 p_{t-i} + \varepsilon_t$	
havaintojen lkm	viiveiden lkm.	kriittinen arvo 5%	t-arvo
2746	21	-1.940939	-11.40615
AIC		$\Delta^2 p_t = \mu + \delta \Delta p_{t-1} + \gamma p_{t-1} + \sum_{i=1}^m \alpha_i \Delta^2 p_{t-i} + \varepsilon_t$	
havaintojen lkm	viiveiden lkm.	kriittinen arvo 5%	t-arvo
2746	21	-2.862393	-11.50421
AIC		$\Delta^2 p_t = \mu + \theta_1 t + \delta p_{t-1} + \gamma p_{t-1} + \sum_{i=1}^m \alpha_i \Delta^2 p_{t-i} + \varepsilon_t$	
havaintojen lkm	viiveiden lkm.	kriittinen arvo 5%	t-arvo
2746	21	-3.411444	-11.52740

Näin ollen H_0 hylätään. Tuotoilla ei siis ole yksikköjuurta eli ne ovat stationaarisia. Tulokset ovat samanlaisia myös aikasarjojen logaritimuodoilla. Tuottojen H_0 -hypoteesin hylkääminen ei kuitenkaan yksin riitä tehokkaiden markkinoiden hypoteesin hyväksymiseksi. Tämän lisäksi tarvitaan näyttöä siitä, etteivät aikasarjan askeleet ole ennustettavissa (Campbell, Lo & MacKinlay 1997, 65).

Tuottojen ennustettavuutta voidaan testata muun muassa Portmanteau-testillä, jossa testataan tuottojen autokorrelaatiokertoimien poikkeavuutta nolasta valitulla viivepituudella (Box & Pierce 1970). Tässä tutkimuksessa käytettävät viivepituudet ovat 6, 12, 18 ja 24 viivettä. Testattava H_0 -hypoteesi on ”tuotot eivät ole autokorreloituneita”. Kun tuottoaineistoa testataan kaikilla edellä mainituilla viiveillä, p-arvot alittavat reilusti tilastollisesti merkitsevän 0,05 prosentin rajan (liite 2). Tulokset eivät muuttuneet, vaikka tuotot muutettiin logaritmuotoon. Toisin sanoen tuotot-aikasarja on voimakkaasti autokorreloitunut. Tämä saattaa tarkoittaa sitä, että tuotoista muodostettua historiallista aikasarjaa voidaan mahdollisesti hyödyntää ylituottojen saavuttamisessa tai osta ja pidä -strategiaa suurempien tuottojen saamisessa.


6.1 Aineiston jakaminen strategian valitsemista varten

Strategian valitsemiseen käytettäväksi ennusteajanjaksoksi on valittu 3.1.2005 - 31.12.2005. Strategian valitsemisvaiheessa neuroverkkoja koulutetaan ennustettavan vuoden viideltä edeltävältä vuodelta saatavalla aineistolla. Strategian valitsemisvaiheessa koulutukseen käytettävä ajanjakso on

3.1.1996 - 31.12.2004 välinen jakso. Tutkimuksessa oletetaan, että ennustusvuoden viisi edellistä vuotta kuvaavat riittävällä tarkkuudella ennustettavan vuoden tapahtumia.

Koulutuksessa käytetään 28 syötettä, jotka kaikki on muodostettu 3.1.1996 - 31.12.2004 väliseltä aikaperiodilta. Aikaperiodin syötteet sisältävät kuitenkin tietoa aina 1950-luvulta ennustettavan periodin alkuun asti. Perinteisten riippumattomien syötteiden lisäksi neuroverkon koulutuksessa käytetään oikean tuloksen yhtä viivästettyä arvoa syötteenä. Kyseessä on niin sanottu NARX-verkko (Nonlinear Autoregressive with External Input). Tällöin todellisen vastauksen y oletetaan muodostuvan kahden eri muuttujan funktiosta $f(x_{t-1}, y_{t-1})$.

Piilokerroksessa kummallekin muuttujalle määritellään omat painokertoimet mahdollisimman hyvän tuloksen saavuttamiseksi. Koulutuksessa käytetään vain neljää neuronia mahdollisen ylisovittamisen välttämiseksi. Lopuksi tulokset summataan summainyksikössä, joka on tässä tapauksessa tansigmoid-aktivaatiofunktio. Aktivaatiofunktio päättää, ylittyykö annettu kynnsarvo vai ei. Jos kynnsarvo ylittyy, lähettää aktivaatiofunktio lasketut arvot ulostulokerrokseen. Ulostulokerroksessa arvoille annetaan uudet painot ja kynnsarvot sekä uusi aktivaatiofunktio, joka on tässä tutkimuksessa purelin-aktivaatiofunktio eli lineaarinen aktivaatiofunktio. Tämän jälkeen ennustetta verrataan toivottuun arvoon ja arvojen erotuksesta saadaan virhe. Koulutuksessa käytettävä Levenberg-Marquardt oppimisalgoritmi pyrkii minimoimaan virhettä muuttamalla edellisten vaiheiden painokertoimien arvoja iteroimalla funktiota useita kertoja. Kuviossa 16 havainnollistetaan edellä mainittua prosessia.



KUVIO 16. Neuroverkon rakenne.

Tässä tutkimuksessa koulutuksessa käytettävät syötteet jaetaan satunnaisesti kolmeen ryhmään, jotka ovat koulutusryhmä, validointiryhmä sekä testausryhmä. Koulutukseen käytettävä ryhmä on kooltaan

kaikkein suurin. Se pitää sisällään 80 prosenttia kaikista syötteistä. Validointiin ja testaukseen käytettävä aineisto on vain 10 prosenttia kummassakin tapauksessa. Tässä tutkimuksessa eri ryhmien suorituskky lasketaan keskineliövirheestä (mean squared error) muodostetun suorituskkyfunktion avulla kaikille kolmelle koulutettavalle aineistoryhmälle. Keskineliövirheen tulisi pienentyä oppimisalgoritmin painojen muutoksen seurauksena.

Ylikoulutuksen välttämiseksi validointiryhmälle on määriteltävä epäonnistuneiden painokertoimien muunnosten suurin sallittu määrä. Tutkimuksessa maksimaaliseksi epäonnistuneiden koulutusten määräksi on valittu 6 epäonnistunutta iteraatiota. Epäonnistuminen tapahtuu vain silloin, kun tutkimuksessa käytetty suorituskkyfunktio ei enää pienene validointiryhmällä tai pysyy koulutuksen toistamisen jälkeen samana. Virheiden määrän täytyessä koulutusprosessi keskeytetään ja painot palautetaan parhaan iteraation edellyttämille arvoille. Lisäksi, jos minimoitu gradientti alittaa arvon $1.0e-07$, koulutus lopetetaan mahdollisen ylisovittamisesta välttämiseksi. Koulutukselle asetettuja rajoituksia ylisovittamisen välttämiseksi ovat koulutuksen määrälle asetettu 1000 epokin iteraatoraja sekä aikaisemmin esitetyt rajoitteet Marquardt-sopeuttamisparametrille.

6.2 Strategian valitseminen

Strategian valitsemista varten koulutetaan yksi neuroverkko vuodelle 2005. Neuroverkon koulutus toistetaan niin monta kertaa, että luvussa 5.4 esitetyt koulutuksen laadun kriteerit täyttyvät. Koulutetulta neuroverkolta vaaditaan hyvää suorituskkyä, jokseenkin keskittyntä virheiden histogrammia, koulutusaineiston osumatarkkuutta ja kahden eri asteen differenssin osumatarkkuutta. Lisäksi MATLAB tarjoaa useita muita kriteereitä koulutuksen onnistumisen valvomiseksi, mutta niille ei anneta tässä tutkimuksessa suurta painoarvoa. Yhden neuroverkon koulutukseen käytetään enintään 10 koulutuskertaa. Jokaisella uudella koulutuskerralla neuroverkon painot satunnaistetaan uusilla painojen alkuarvoilla. Näistä kymmenestä verkosta valitaan aina parhaiten suoriutuva verkko.

6.2.1 Strategian valitsemisjakson koulutus


Alla oleva taulukko 3 näyttää valitun neuroverkonverkon suorituskvyn keskineliövirheellä laskettuna. Ensimmäisessä sarakkeessa on ennustejakson vuosiluku, toisessa sarakkeessa on koulutuksessa käytettävän aineiston aikaväli, kolmannessa sarakkeessa on koulutukseen käytettyjen

ajanjaksojen eli epokkien lukumäärä, neljännessä sarakkeessa on paras epokki ja kolmessa viimeisessä sarakkeessa on eri ryhmien suorituskyyky.

TAULUKKO 3. Koulutuksen suorituskyyky.

Ajanjaksot		Koulutuksen määrä		Suorituskyyky		
Ennustevuosi	Koulutusjakso	Epokkien määrä	Paras epok	Koulutusryhmä 80 %	Validoitiryhmä 10%	Testiryhmä 10%
	3.1.2000					
	-					
2005	31.12.2004	11	5	1,57E-04	1,67E-04	2,18E-04

Taulukosta on nähtävissä, että koulutus loppuu ennen maksimaalisen epokin saavuttamista. Tässä tapauksessa koulutus keskeytetään validointiryhmän suorituskyyvyn alkaessa huonontua jo 5 epokin jälkeen. Vähäinen epokkien määrä kertoo siitä, ettei neuroverkko pysty iterointimääriä lisäämällä pienentämään replikoitujen ennusteiden ja tavoitearvojen välistä virhettä. Vähäinen epokkien määrä saattaa johtua siitä, että neuroverkko löytää helposti keskeiset lainalaisuudet syötteiden ja tavoitearvojen välisestä suhteesta, eikä painokertoimien muutos enää paranna suorituskyykyä. Taulukkoa tarkastelemalla voidaan kuitenkin sanoa, että virheet ovat hyvin pieniä jo muutaman iteraation jälkeen. Joissain tapauksissa neuroverkon painot saattavat saada optimaaliset arvot heti ensimmäisessä satunnaislukujen luonnissa. Näin ollen koulutusmäärän lisääminen vain muuttaa painojen arvoja poispäin optimaalisista arvoista.



KUVIO 17. Virheiden histogrammi nollavirheen ympärillä.

Kuvion 17 koulutusaineiston histogrammin tarkastelu paljastaa, että suurin osa todellisten tuottojen ja koulutuksessa saatujen replikoitujen tuottojen erotuksista eli virheistä asettuu nolllavirheen kohdalle tai sen tuntumaan. Histogrammi on hieman toispuolinen, mutta virheiden esiintymistiheys laskee tasaisesti niiden loitotessa nolllavirheestä poispäin. Jos neuroverkko kykenee tuottamaan samankaltaisia tuloksia koulutettavan aineiston ulkopuolelta tuodusta aineistosta, ennusteet ovat todennäköisesti hyviä.


TAULUKKO 4 Replikoitujen tuottojen osumatarkkuus koulutusaineistossa.

Replikoitujen tuottojen osumatarkkuus koulutusaineistossa				
Ennustevuosi	Koulutusjakso	Replikoituennuste	Replikoitujenennusteiden d_t^1	Replikoitujenennusteiden d_t^2
2005	3.1.2000 - 31.12.2004	54 %	68 %	72 %

Taulukko 4 esittää koulutuksessa saavutettujen replikoitujen tuottojen suunnan osumatarkkuuden todellisiin tuottoihin verrattuna. Edes koulutusaineistossa replikoidun ennusteen osumatarkkuus ei nouse yli 54 prosentin. Tämä johtuu siitä, että neuroverkon replikoidut tuottoennusteet ovat jääneet naiiviin ratkaisuun tuottojen positiiviselle puolelle. Sen sijaan ensimmäisen ja toisen asteen differenssit ovat osumatarkkuudeltaan huomattavasti parempia 70 prosentin kummallakin puolella. Jos neuroverkko kykenee yhtä hyvään differenssien osumatarkkuuteen myös 2005 vuoden testiaineistossa, voidaan sen pohjalta varmasti rakentaa toimiva sijoitusstrategia.

6.2.2 Strategian valitsemisjakson testaus


Koulutusjakson jälkeen neuroverkko on valmis ennustamaan seuraavaa vuotta eli testivuotta. Ennen ennustamisen aloittamista koulutetun verkon rakennetta tulee muuttaa siten, että syötematriisien viiveet (x_{t-1}, y_{t-1}) poistetaan ja tilalle otetaan todelliset arvot. Tämän lisäksi verkon rakennetta tulee muuttaa siten, että verkko antaa ulostuloksi seuraavan päivän tuottoennusteen y_{t+1} . Alla oleva kuvio 18 havainnollistaa edellä mainittua.



KUVIO 18. Neuroverkon rakenne ennustejaksolla.

Nyt verkko on valmis ennustamaan koulutuksen ulkopuolisesta aineistosta. Syötteet ovat ajanjaksolta 31.12.2004 - 29.12.2005. Ennustettava ajanjakso on aina syötteen seuraava päivä ajanjaksolta 3.1.2005 – 30.12.2005. Kaupankäyntipäiviä tälle aikavälille mahtuu 252 kappaletta.

Alla oleva kuvio 19 kuvaa neuroverkon ennusteiden virhettä histogrammin muodossa koulutuksen ulkopuolelta tulleeseen aineistoon. Kuvioista on nähtävissä, että ennustettavan aineiston virheet aikajaksolta 3.1.2005 – 30.12.2005 eivät jakautuneet yhtä tasaisesti nollavirheen ympärille kuin ne jakautuivat koulutuksen yhteydessä esitetystä histogrammissa (Kuvio 16). Virheiden perusteella voidaan päätellä, etteivät ennusteet yllä yhtä hyvään suoritukseen kuin koulutusvaiheessa. Histogrammista on kuitenkin havaittavissa huipukkuutta, vaikka se ei olekaan jakautunut tasaisesti nollavirheen ympärillä.



KUVIO 19. Ennustevirheiden histogrammikuvaaja.

Histogrammin virheet ovat jakautuneet enemmän positiiviselle puolelle kuin negatiiviselle. Tämä tarkoittaa sitä, että ennustettujen tuottojen vähentäminen todellisista tuotoista tuottaa useammin positiivisia tuloksia. Toisin sanoen ennustetut tuotot ovat liian pieniä todellisiin tuottoihin verrattuna. Sijoittaja, joka rakentaa strategiansa pelkän neuroverkon luoman ennusteen varaan, tulee todennäköisesti menettämään omaisuutensa havaintojen lukumäärän kasvaessa.

TAULUKKO 5. Ennusteiden osumatarkkuus testiaineistolla.

Ennusteiden osumatarkkuus testiaineistolla			
Ennustevuosi	Ennuste	Ennusteen d_t^1	Ennusteen d_t^2
2005	47 %	65 %	63 %

Taulukosta 5 on myös nähtävissä ennusteiden osumatarkkuuden heikentyminen verrattuna koulutusaineiston vastaaviin arvoihin (taulukko 4). Pelkän ennusteen osumatarkkuus putosi 7 prosenttia, mille ei kuitenkaan tule antaa paljon painoarvoa, koska sijoitusstrategiat eivät nojaa kuin epäsuorasti ennustettuihin tuottoihin. Ensimmäisen differenssin osumatarkkuus on jossain määrin pysynyt ennallaan vain 3 prosentin laskulla. Toisen differenssin osumatarkkuus on laskenut enemmän

eli 9 prosenttia. Ensimmäisen differenssin sekä toisen differenssin osumatarkkuus on kuitenkin pysynyt yli 60 prosentissa, mikä saattaa riittää sijoitusstrategioiden menestymiseen.

6.2.3 Strategian lopullinen valitseminen

Vertailtaessa 272 erilaista strategiaa, jotka kaikki on nimetty numeroin, strategiat numero 5, 159, 167, 175, 179 tuottavat kaikista suurimmat tuotot ilman transaktiokustannusten huomioimista. Strategia numero 5 perustuu kahteen eriasteiseen differenssiin ja kaikki loput strategiat pohjautuvat kolmeen eriasteiseen differenssiin. Strategia numero 5 kuvastaa pelkän ensimmäisen differenssin pohjalta tehtäviä sijoituspäätöksiä, koska se käyttäytyy täsmälleen samalla tavalla kuin ensimmäinen differenssi. Lisäksi mukaan tarkasteluun on otettu strategia, jonka toisen asteen differenssiä on viivästytetty yhdellä ajanhetkellä. Muutoksen seurauksena sen kolmannen asteen differenssi on viivästynyt. Ennustejakson alussa 31.12.2004 jokaisella strategialla oli käytössä 100 000 dollaria. Alla oleva taulukko 6 kuvaa eri strategioiden menestymistä 2005 vuoden aikana osta ja pidä -strategiaan verrattuna.

TAULUKKO 6. Valitut strategiat.

Strategiat	O&P	5.	159. d_{t-1}^2	167.	175.	179.
Pääoma 30.12.2005	103033	124607	127302,8	122642	126663	124300
Vuosituotto %	3,03 %	24,61 %	27,30 %	22,64 %	26,66 %	24,30 %
Transaktio määrä	2	335	309	325	335	319
Long-positio päivien määrä	1	119	113	122	126	137
Short-positio päivien määrä	0	132	138	129	125	114
Tuotto % per transaktio	1,517 %	0,073 %	0,088 %	0,070 %	0,080 %	0,076 %
Strategian osumatarkkuus	54,37 %	52,78 %	48,02 %	52,38 %	53,17 %	53,57 %

Taulukosta on nähtävissä, että kaikki parhaiten menestyvät strategiat tuottavat yli 20 prosentin vuosituoton osta ja pidä -strategian tuottaessa vain noin 3 prosentin vuosituoton. Kaikkien menestyvien strategioiden transaktiomäärät ovat päälle 300 transaktiota. Long- ja short-positiot jakautuvat kaikissa strategioissa liki tasan. Prosentuaalinen tuotto per transaktio on vertailtavien strategioiden kesken suurin piirtein sama. Strategioiden osumatarkkuus positioiden valinnassa ei pärjää osta ja pidä -strategian osumatarkkuudelle, joka on jatkuvasti long-positiossa. Tästä voidaankin päätellä, että menestyvät strategiat eivät osaa ennustaa kolikon heittoa paremmin pörssinoteeratun rahaston tuottoja. Vuosituotto on kuitenkin epäilyttävän suuri suhteessa vain noin 50 prosentin onnistumiseen positioiden valinnassa. On mahdollista, että eriasteiset differenssit

sisältävät informaatiota voittojen kannalta keskeisten tuottojen muodostumisesta ja siksi strategiat ovat niin tuottoisia.

Transaktioiden huomioiminen ei muuta strategioiden menestymisen järjestystä transaktiomäärien ollessa toistensa kaltaisia. Kumuloituneet tuotot mahdollistavat suurienkin transaktiokustannusten maksamisen. Luonnollisesti vähiten transaktioita tekevien strategioiden merkitys korostuu kustannusten noustessa. Paras strategia tarkastelujaksolla on strategia numero 159. Riskineutraalin sijoittajan tulisi edellä esitetyn perusteella laittaa kaikki varansa tähän strategiaan maksimaalisten tuottojen toivossa.

6.3 Valittujen strategioiden testaaminen

Strategian valitsemisen jälkeen toistetaan edelliset vaiheet uudella aineistoilla. Strategian testausvaiheessa koulutukseen käytettävä aikajakso alkaa 3.1.2001 ja päättyy 31.12.2014. Ennustettavat ajanjaksot ovat 3.1.2006 – 31.12.2015. Jokaiselle 10 ennustettavalle vuodelle koulutetaan oma neuroverkko, joka saa syötteensä viidestä ennustevuotta edeltävästä vuodesta, kuten strategian valitsemisvaiheessa. Ennustettavien havaintojen lukumäärä 10 vuoden aikajaksolla on 2517 kappaletta.

6.3.1 Neuroverkon kouluttaminen ennustejaksoille

Liitteessä 3 on nähtävissä kaikkien 10 ennustevuoden koulutuksessa käytettyjen epokkien lukumäärä, koulutuksen paras epokki ja suorituskky kaikille kolmelle koulutettavalle ryhmälle. Vertailun vuoksi liitteeseen on lisätty mukaan vuoden 2005 ennustevuosi. Keskimäärin neuroverkko löytää keskeiset yhteydet 17 epokin aikana parhaan epokin ollessa keskimäärin 11. Koulutus vei eniten aikaa vuosien 2006 ja 2007 ennustejaksoilla. Kummassakin tapauksessa koulutus päättyi 33 epokin kohdalla parhaan epokin ollessa 27. Toinen ääripää koulutuksessa käytettävien epokkien määrässä olivat vuodet 2013 ja 2014. Vuoden 2013 ennustejaksolla neuroverkko selvisi koulutuksesta yhdeksällä epokilla ja vuoden 2014 ennustejaksolla koulutettujen epokkien määrä oli 10. Paras epokki oli vuonna 2013 kolmas epokki ja vuonna 2014 neljäs epokki.

Kaikissa tapauksissa koulutus keskeytyi validointiryhmän suorituskyvyn heikkenemiseen ja sitä kautta keskeytettyyn koulutukseen. Vähäisestä epokkien määrästä voidaan päätellä, etteivät tutkimukseen valitut muuttajat kyenneet löytämään keskeisiä yhteyksiä syötteiden ja toivottujen tulosten väliltä. Suorituskyky kaikilla vuosilla ja kaikissa ryhmissä on kuitenkin pysynyt hyvin pienenä, eikä se todennäköisesti aiheuta ongelmia tutkimuksessa käytettävien strategioiden näkökulmasta. Liitteestä 4 on myös nähtävissä, että koulutetut neuroverkot tuottivat keskittyneen histogrammin, jonka pitäisi edesauttaa tasalaatuinen ennustetta.

Strategioiden menestymisen kannalta keskeisempää on ennusteiden differenssien osumatarkkuus verrattuna todellisten tuottojen differensseihin koulutusaineistossa. Taulukko 8 kuvaa ennustevuosia edeltänyttä viiden vuoden koulutusjaksoa. Koulutusjaksojen keskimääräinen osumatarkkuus on 56 prosenttia, kun verrataan replikoituja ennusteita todellisiin arvoihin. Parhaimpana ennustevuotena 2007 osumatarkkuus oli 60 prosenttia. Jos tällainen osumatarkkuus säilyisi koulutuksen ulkopuolelta tuotuun aineistoon, tarkoittaisi se todennäköisesti todella suuria voittoja ilman minkäänlaisia strategioita. Huonoin osumatarkkuus taas on viimeisellä koulutusjaksolla, jonka on tarkoitus ennustaa vuotta 2015.

TAULUKKO 8. Osumatarkkuus.

Ennusteiden osumatarkkuus koulutusaineistossa				
Ennustevuosi	Koulutusjakso	Replikoitu ennuste	Replikoitu ennuste d_t^1	Replikoitu ennuste d_t^2
2006	2.1.2001 - 30.12.2005	58 %	71 %	74 %
2007	2.1.2002 - 29.12.2006	60 %	66 %	69 %
2008	2.1.2003 - 31.12.2007	57 %	70 %	75 %
2009	2.1.2004 - 31.12.2008	55 %	73 %	71 %
2010	3.1.2005 - 31.12.2009	56 %	67 %	71 %
2011	3.1.2006 - 31.12.2010	58 %	71 %	74 %
2012	3.1.2007 - 30.12.2011	57 %	67 %	68 %
2013	2.1.2008 - 31.12.2012	55 %	59 %	61 %
2014	2.1.2009 - 31.12.2013	57 %	68 %	75 %
2015	4.1.2010 - 31.12.2014	53 %	59 %	63 %

Replikoitujen ennusteiden ensimmäisen asteen differenssien osumatarkkuuksien keskiarvo on koulutusjaksolla 67 prosenttia, mikä on melko hyvä osumatarkkuus. Tällainen osumatarkkuus riittäisi todennäköisesti voitollisen ennusteen laatimiseen pelkkien tuottojen ensimmäisten differenssien pohjalta. Toisen asteen differenssien osumatarkkuus on kaikista suurin 70 prosentin keskiarvolla. Koulutuksen hyväksymisen tärkeimpänä kriteerinä pidetään ennusteen ensimmäisen differenssin ja ennusteen toisen differenssin suhteen tarkkailua. Koulutuksen keskeinen pyrkimys on pitää ennusteen

osumatarkkuus pienempänä kuin ensimmäinen differenssin osumatarkkuus, jonka taas tulisi olla pienempi kuin toisen differenssin osumatarkkuus. Jos tällainen säännönmukaisuusilmiö pystytään toistamaan koulutuksen ulkopuoliseen testiaineistoon, voidaan sen perusteella todennäköisesti rakentaa osta ja pidä -strategian voittava sijoitusstrategia.

6.3.2 Neuroverkon ennusteet

Koulutusvaiheen jälkeen siirrytään ennustevaiheeseen. Neuroverkoille toistetaan strategian valitsemisvaiheessa suoritettu viiveiden karsiminen syötteistä. Lisäksi ulostulot määrätään tuottamaan ennusteita. Syötteenä toimiva aikajakso on aina päivää edeltävä arvo, eli mukaan lasketaan myös ennustevuotta edeltävän vuoden viimeinen päivä.

Alhaalla oleva taulukko 9 kuvaa koulutuksen ulkopuolisen aineiston osumatarkkuutta. Ennusteiden osalta osumatarkkuus suhteessa todellisiin tuottoihin laskee keskimäärin 51 prosenttiin. Laskua koulutus- ja testivaiheen välillä on 5 prosenttia. Voidaankin todeta, että 51 prosentin ennusteiden osumatarkkuus ei ole juuri kolikon heittoa parempi tulos. Todennäköisesti verkot ovat jääneet pelkkiin naiiveihin ratkaisuihin, joissa ne ovat ottaneet position joko tuottojen positiiviselta tai negatiiviselta puolelta.

TAULUKKO 9. Ennusteiden osumatarkkuus testiaineistolla.

Ennusteiden osumatarkkuus testiaineistolla			
Ennuste vuosi	Ennuste	Ennusteen d_t^1	Ennusteen d_t^2
2006	50 %	69 %	73 %
2007	54 %	73 %	76 %
2008	54 %	69 %	76 %
2009	50 %	68 %	78 %
2010	51 %	63 %	70 %
2011	54 %	64 %	68 %
2012	48 %	47 %	42 %
2013	52 %	61 %	64 %
2014	41 %	73 %	74 %
2015	53 %	55 %	49 %

Ensimmäisen asteen differenssien osumatarkkuus on testiaineistolla keskimäärin 64 prosenttia, mikä on vain 3 prosenttia vähemmän kuin koulutusvaiheessa. Jo tästä tuloksesta voidaan päätellä, että testausvaiheessa käytettävät neuroverkot pystyvät todennäköisesti tuottamaan ennusteita, jotka

osaavat arvioida tuottojen kehittymisen suuntaa. Tämä ei kuitenkaan vielä takaa voitollista ennustetta, minkä takia strategioita tarvitaan.

Voitollisiin strategioihin saatetaan tarvita myös muita syötteitä, joita toisen ja kolmannen asteen differenssit tarjoavat. Toisen asteen differenssien osumatarkkuus on testiaineistolla keskimäärin 67 prosenttia, mikä on vain prosenttia vähemmän kuin koulutusaineistossa. Kolmannen asteen differenssit eivät olleet tarkkailun kohteena, vaikka niitäkin hyödynnetään strategioissa. Osumatarkkuus testiaineistossa myötäilee koulutusaineiston osumatarkkuuksien säännönmukaisuusilmiötä siinä mielessä, että suuressa osassa ennusteita ennusteen osumatarkkuus on pienempi kuin ensimmäisen differenssin osumatarkkuus, joka on pienempi kuin toisen differenssin osumatarkkuus. Ainoastaan ennustevuosina 2012 ja 2015 näin ei tapahtunut. Näiden vuosien vaikutus strategioihin voi olla poikkeuksellisen positiivinen tai poikkeuksellisen negatiivinen.

6.3.3 Strategioiden ennusteet

Seuraavaksi voimme siirtyä tutkimuksen viimeiseen vaiheeseen, jossa syötämme ennusteet viidelle jo valitulle sijoitusstrategialle ja tarkkailemme tuloksia. Testijakson alussa kaikille strategioille annetaan taas 100 000 dollaria alkupääomaa. Kaikilla strategioilla 10 vuoden aikana kumuloitunut pääoma ylittää osta ja pidä -strategian kumuloituneet tuotot. Viiden valitun sijoitusstrategian kumuloitunut pääoma on keskimäärin 232 779 dollaria, kun osta ja pidä -strategialla vastaava luku on 164 330 dollaria.

Alla oleva taulukko 10 havainnollistaa eri strategioiden menestymistä ilman transaktiokustannusten huomioimista ja samalla se vertaa valittuja sijoitusstrategioita osta ja pidä -strategiaan. Valitut strategiat tuottavat 10 vuoden aikana keskimäärin voittoa 132 779 dollaria, mikä tarkoittaa jälkeenpäin tarkasteltuna 52,75 dollarin keskimääräistä päiväpalkkaa, kun pörssin aukiolopäiviä oli 2517 kappaletta. Automatisoidulle järjestelmälle se riittäisi tietokoneen ylläpitämiskustannusten kattamiseen. Riskineutraalin toimijan näkökulmasta strategia numero 159 tuottaa strategioista parhaiten eli 179 383 dollaria. Päiväpalkaksi jälkikäteen tarkasteltuna hän olisi saanut 71,27 dollaria. Vaihtoehtoiskustannuksen eli osta ja pidä -strategian valinneen sijoittajan päiväpalkka olisi vastaavasti yltänyt 25,56 dollariin.

TAULUKKO 10 Strategioiden menestyminen.

Strategia	O&P	5.	159. d_{t-1}^2	167.	175.	179.	Keskiarvo
Kumuloitunut pääoma	164330	192400	279383	247098	229976	215036	232779
Voitto \$	64330	92400	179383	147098	129976	115036	132779
Tuotto %	64,33 %	92,40 %	179,38 %	147,10 %	129,98 %	115,04 %	132,78 %
Transaktioiden määrä	2	3027	2637	3099	3059	3083	2981
Long-positioiden määrä	1	1343	1378	1181	1364	1492	1352
Short-positioiden määrä	0	1174	1139	1336	1153	1025	1165
Tuotto % per transaktio	32,16 %	0,031 %	0,068 %	0,047 %	0,042 %	0,037 %	0,045 %
Keskituotto per vuosi	5,09 %	6,76 %	10,82 %	9,47 %	8,68 %	7,96 %	8,74 %
Osumatarkkuus	54,11 %	51,49 %	51,67 %	51,01 %	51,77 %	52,01 %	51,59 %

Taulukossa 10 on laskettu eri strategioiden tuotto prosenttien keskiarvo, joka on 132,78 prosenttia. Osta ja pidä -strategian tuotto prosentti on vastaavasti 64,33 prosenttia. Strategian valitsemisvaiheessa valitut strategiat pystyivät keskimäärin tuplaamaan aluksi annetun pääoman. Ainoastaan strategia numero 5 ei kyennyt tuplaamaan annettua alkupääomaa. Suuri keskimääräinen transaktioiden määrä 2981 kappaletta pienentää merkittävästi kaikkien valittujen strategioiden voittoja. Näille strategioille yhteinen piirre on se, että ne painottavat long-positiota yli short-position. Prosentuaalinen tuotto per transaktio on tarkastelujakson lopuksi keskimäärin likimain 0,045 prosenttia. Keskituotto per vuosi on valituilla strategioilla keskimäärin 8,74 prosenttia, mikä on vain yli 3 prosenttia korkeampi kuin osta ja pidä -strategialla. Lisäksi taulukosta 10 havaitaan, etteivät valitut strategiat kyenneet positiota valitessaan osta ja pidä -strategian osumatarkkuuteen. Osumatarkkuudesta voidaan havaita sama kuin kuvion 11 histogrammista, eli long-positioita on aina keskimäärin enemmän kuin short-positioita S&P 500 -indeksissä. Osta ja pidä -strategian osumatarkkuus 54,11 prosenttia on muita strategioita parempi. Osta ja pidä -strategia osuu aina oikeaan, jos rahasto nousee. Indeksien laskupäivät ovat kuitenkin usein prosentuaalisesti suurempia kuin nousupäivien nousut. Valitut sijoitusstrategiat ottavat vähemmän long-positioita kuin, mikä olisi optimaalista, mutta kykenevät löytämään aineistoista keskeiset positiot, koska voitot ovat osta ja pidä -strategiaa suuremmat.

Alla oleva taulukko 11 esittää tuottojen muodostumisen prosentuaalisesti edellisvuoteen verrattuna. Taulukosta on nähtävissä, että ennustejakso alkaa huonoimmalla mahdollisella tavalla kaikkien valittujen sijoitusstrategioiden osalta. Strategiat menettävät keskimäärin 10 prosenttia 100 000 dollarin alkuinvestoinnistaan. Tällä on suuri vaikutus kumuloituneeseen pääomaan, sillä pääoman pieneneminen heti tarkastelujakson alussa tulee vaikuttamaan kaikkien tulevien vuosien kumuloituneisiin tuottoihin.

TAULUKKO 11. Vuosituotot prosentteina.

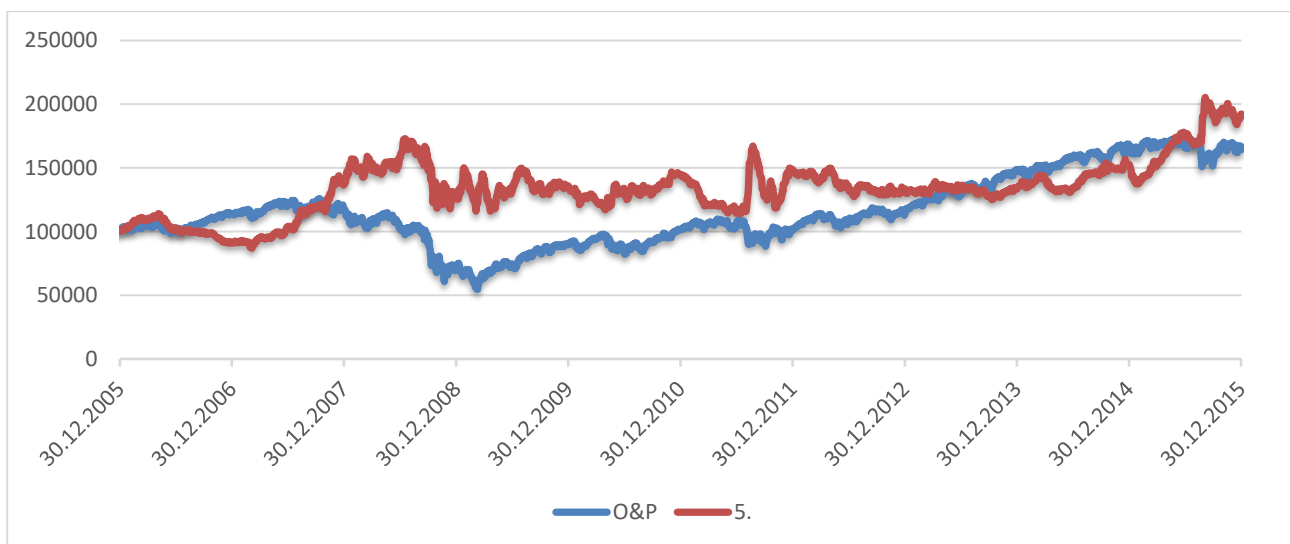
Tuottojen prosentuaalinen kehitys edelliseen vuoteen verrattuna						
Päivämäärä	O&P	5.	159. d_{t-1}^2	167.	175.	179.
29.12.2006	13,90 %	-8,82 %	-2,46 %	-15,69 %	-8,05 %	-13,51 %
31.12.2007	3,34 %	50,48 %	45,07 %	46,24 %	50,48 %	49,70 %
31.12.2008	-38,46 %	-5,54 %	16,55 %	-20,67 %	-5,73 %	-14,00 %
31.12.2009	23,81 %	3,65 %	-6,22 %	56,75 %	24,15 %	24,04 %
31.12.2010	12,91 %	7,65 %	2,59 %	12,14 %	7,65 %	20,40 %
30.12.2011	-0,23 %	2,97 %	24,40 %	18,69 %	4,83 %	4,88 %
31.12.2012	13,64 %	-10,37 %	0,40 %	-19,16 %	-13,00 %	-8,80 %
31.12.2013	29,70 %	0,36 %	14,00 %	-2,53 %	0,36 %	8,81 %
31.12.2014	11,43 %	13,02 %	8,55 %	7,99 %	13,62 %	0,27 %
31.12.2015	-0,97 %	27,10 %	13,92 %	42,31 %	26,85 %	23,92 %

Vuosi 2007 oli edeltäjänsä huomattavasti parempi. Kaikki valitut sijoitusstrategiat kykenivät keskimäärin noin 50 prosentin tuottoihin 2006 vuoden loppuun verrattuna. 2008 vuoden aikana tuotot olivat raskaasti tappiolliset muilla paitsi strategialla numero 159, joka onnistui kumuloimaan varoja myös vaikeassa tilanteessa. Valittujen strategioiden tappiot eivät kuitenkaan vedä vertoja osta ja pidä -strategian suuriin lähes 40 prosentin tappioihin. Vuoden 2009 aikana osta ja pidä -strategia palautui lähes lähtöasetelmiin saavuttamalla 23,81 prosentin tuotot. Vuoden 2009 aikaperiodilla valittujen sijoitusstrategioiden keskimääräiset tuotot olivat suurin piirtein samat kuin osta ja pidä -strategialla. Valituissa strategioissa on kuitenkin suuria eroa, mikä näkyy strategioista otettuna suurena keskihajontana. Strategia numero 159, joka menestyi finanssikriisin alkuvaiheissa, ei pystynyt tunnistamaan nousukauden alkua. Valitut strategiat kykenivät siis keskimäärin osta ja pidä -strategiaa pienempiin tappioihin finanssikriisin aikana, eivätkä myöskään jääneet tuottojen näkökulmasta pahasti jälkeen osakemarkkinoiden elpymisen alettua.

Vuonna 2010 kaikki valitut sijoitusstrategiat, kuten myös osta ja pidä -strategia, olivat voitollisia. Keskimäärin eroa oli osta ja pidä -strategian hyväksi kuitenkin melkein 3 prosenttia. Vuoden 2011 aikana kaikki valitut strategiat voittivat osta ja pidä -strategian sen ollessa hieman tappiollinen. Vuosi 2012 taas oli valittujen strategioiden osalta katastrofaalinen. Kyseisenä vuonna osta ja pidä -strategia tuotti edellisvuoteen verrattuna yli 13 prosentin tuotot, kun taas valitut strategiat tuottivat keskimäärin yli 10 prosentin tappiot. On mahdollista, että koulutuksessa käytettävät viisi edellistä vuotta eivät kyenneet kuvaamaan tarpeeksi suurella tarkkuudella vuotta 2012. Lisäksi replikoidut ennustukset testiaineistolla eivät kyenneet samaan tarkkuuteen differenssien osumatarkkuudessa vuonna 2012 kuin, mitä aikaisemmin. Osta ja pidä -strategialle häviäminen jatkuu myös seuraavien vuosien 2013 ja 2014 aikana. Sijoitusstrategiat, jotka menestyivät vuoden 2005 aikana, jolloin oli sekä nousu- että

laskukausia, eivät pysty vastaamaan osta ja pidä -strategian kolmen vuoden pelkkään nousuputkeen. Valitut strategiat pystyvät kuitenkin kasvattamaan tuottoja vuoden 2015 aikana osta ja pidä -strategian polkiessa paikallaan. Viimeisen neljän vuoden replikoidut ennusteet differenssien osumatarkkuudella mitattuna poikkeavat aikaisempien kuuden vuoden tuloksista. Tämän seurauksena myös strategiat, jotka nojaavat verkon koulutuksen onnistumiseen, epäonnistuvat.


Alla oleva kuvio 19 havainnollistaa strategian numero 5 kumuloituneen tuoton kehittymistä tarkastelujaksolla. Strategia numero 5 kuvaa myös pelkästään ensimmäiseen differenssiin pohjautuvan strategian kehittymistä. Sen tarkempi tarkasteleminen selventää näin kaikkien strategioiden kehittymistä, koska kaikki strategiat nojaavat ensimmäiseen differenssiin. Kuvioista on havaittavissa, että strategia numero 5 ailahtelee osta ja pidä -strategiaa enemmän. Lisäksi se pärjää huonosti osta ja pidä -strategian pitkinä nousukausina, kuten vuonna 2006, finanssikriisin jälkeisenä elpymisajanjaksona ja vuosien 2012 -2014 nousukautena.



KUVIO 22. Strategian numero 5 kumulatiivinen kehitys.


Alla oleva kuvio 20 esittää strategioiden numero 167, 175 ja 179 kumulatiivista kehitystä. Kun näitä strategioita verrataan strategiaan numero 5, ainoa merkittävä ero on se, että ne tuovat mukaan muuttujia perustuen toiseen ja kolmanteen differenssiin. Nämä neljä strategiaa ovat toistensa kaltaisia johtuen strategiavalintajaksolla menestymisestä. Syy, minkä takia strategiat numero 5, 167, 175 ja 179 voittavat osta ja pidä -strategian lopullisessa tarkastelussa, johtuu markkinoiden epävarmoina aikoina tehdyistä tuotoista. Lisäksi strategiat 167, 175 ja 179 menestyvät strategiaa 5 paremmin kaikissa tilanteissa erityisesti pitkinä osta ja pidä -strategian nousukausina. Jos tarkastelu olisi

lopetettu vuotta aikaisemmin vuonna 2014, ainoastaan strategia numero 159 olisi voittanut osta ja pidä -strategian.



KUVIO 23. Strategioiden numero 167, 175 ja 179 kumulatiivinen kehitys.

Kuviossa 21 havainnollistetaan strategiaa numero 159, jossa toisen asteen differenssiä on viivästytetty. Strategian numero 159 menestys on hieman muita valittuja sijoitusstrategioita parempi, vaikka se kärsii samoista ongelmista kuin muutkin strategiat. Ainoana erona voidaan sanoa, että se pysyy paremmin osta ja pidä -strategian perässä pitkien nousukausien aikana ja tuottaa vähemmän tappioita kuin muut valitut strategiat kyseisillä ajanjaksoilla. Lisäksi strategia numero 159 kykenee jopa kumuloimaan tuottoja vuosien 2011 - 2015 välillä olevana pitkänä nousukautena.



KUVIO 24. Strategian numero 159 kumulatiivinen kehitys.

6.3.4 Transaktiokustannusten huomioiminen

TAULUKKO 11 Transaktiokustannusten vaikutus voittoihin.

Transaktiokustannusten vaikutus voittoihin							
Strategia	O&P	5.	159. d_{t-1}^2	167.	175.	179.	Keskiarvo
Voitto \$	64330	92400	179383	147098	129976	115036	132778
Transaktioiden määrä	2	3027	2637	3099	3059	3083	2981
\$ 2,5 per transaktio	64325	84832	172790	139351	122329	107328	125326
\$ 6,99 per transaktio	64316	71241	160950	125436	108594	93485	111941
\$ 9,99 per transaktio	64310	62160	153039	116139	99417	84236	102998
\$ 19,99 per transaktio	64290	31890	126669	85149	68827	53406	73188

Transaktiokustannusten vaikutus voittoihin jälkikäteen tarkasteltuna on nähtävissä yllä olevasta taulukosta 11. Suurin osa valituista sijoitusstrategioista voittaa osta ja pidä -strategian transaktiokustannusten ollessa 19,99 dollaria. Kun transaktiokustannukset huomioidaan 9,99 dollariksi, keskimääräiset voitot valituilla strategioilla ovat 102 998 dollaria. Tämä tarkoittaa keskimäärin 40,79 dollarin päiväpalkkaa. Strategian numero 159 menestys korostuu entisestään sen transaktioiden määrän ollessa muita strategioita vähäisempi. Samalla transaktiokustannusten hinnalla riskineutraalin sijoittajan päiväpalkka olisi ylittänyt 60 dollarin päiväpalkan. Lisäksi on hyvä huomioida, että suuremmilla pääomilla ja sen tuomilla pienemmillä transaktiokustannuksilla ero strategian numero 159 tuottamien voittojen ja osta ja pidä -strategian tuottamien voittojen välillä

kasvaa strategian 159 hyväksi. Kaikki valitut sijoitusstrategiat voittavat osta ja pidä -strategian 6,99 dollarin transaktiokustannuksiin asti.

Kiinteät transaktiokustannukset mahdollistava myös vertailun siten, että sijoittaja jakaa sijoitettavan potin kahteen osaan. Toinen osa sijoitetaan päivittäin markkinoille ja toinen varataan tuleviin transaktiokustannuksiin pankkitilillä. Tällaisessa tarkastelussa osta ja pidä -strategian 64,33 prosentin tuotot kertovat, että osta ja pidä -strategian alkupääoma tulisi olla noin 170 000 dollaria, jotta se vastaisi tuotoiltaan 100 000 dollarin sijoitusta strategiaan numero 159. 170 000 dollarin sijoitus osta ja pidä -strategiaan tuottaisi 10 vuodessa alkupääoman lisäksi voittoa noin 179 361 dollaria. Vastaavasti strategia 159 tuottaa 100 000 dollarilla voittoa samassa ajassa 179 383 dollaria. Toisin sanoen transaktiokustannusten kokonaissumma 2637 transaktiolle voi yhteensä olla noin 70 000 dollaria ja silti strategia 159 voittaa osta ja pidä -strategian. Transaktion keskimääräinen hinta voi olla näin laskettuna noin 26,55 dollaria.

Jos transaktiokustannuksena käytetään Lin, Mooradianin ja Zhangin (2006, 15) ehdottamaa 0,0205 dollarin keskimääräistä transaktiokustannusta per osake, olipa transaktio long- tai short-positio, voidaan strategian 159 menestystä määrittää tarkemmin. Strategiassa 159 käytiin kauppaa tarkastelujakson aikana 3 229 997 osakkeella. Jos jokaisesta transaktiosta syntyy 0,0205 dollarin kustannus, tarkoittaa se 66 214,93 dollarin transaktiokustannusta kyseiseltä periodilta. Arvo-osuustili, jolle on varattu 70 000 dollaria kulujen kattamiseksi, riittää maksamaan koko tarkastelukauden aikana syntyneet kaupankäyntikustannukset. Näin ollen strategian 159 voitot ovat osta ja pidä -strategiaa suuremmat kunhan kaupankäyntikustannuksille on varattu erillinen pääoma, joka ei ylitä noin 70 000 euroa. Vaikka short-position korkokustannuksia ei huomioida, voidaan olettaa, että keskimääräinen transaktiokustannus per osake on laskenut vuoteen 2015 mennessä Liin, Mooradianin ja Zhangin (2006, 15) vuodelle 2003 ehdottamasta 0,0205 dollarin kustannuksesta.

Toinen tapa testata tuottoja transaktiokustannukset huomioiden on muuttaa tuotot logaritmuotoon. Log-tuotot mahdollistavat myös Sharpen luvun testaamisen (Sharpe 1966). Lisäksi prosentuaalisten transaktiokustannusten vaikutus voidaan vähentää log-tuottojen summasta. Sharpen lukua laskettaessa riskittömänä korkona käytetään yhden kuukauden viitelainan korkoa (1-month T-bill). Sharpen luvussa lasketaan osamäärä, jossa osoittajassa on tuoton ja riskittömän koron erotus ja nimittäjässä aikasarjan volatilitteetti. Mitä suurempi Sharpen luku on, sitä paremmin strategia tuottaa suhteessa riskiin. (Sharpe 1996, 119-138.)

Taulukosta 12 on nähtävissä, että jokainen strategia voittaa osta ja pidä -strategia kumuloituneilla log-tuotoilla mitattuna, kun transaktiokustannuksia ei huomioida. Samoin jokaisen strategian Sharpen luku on parempi kuin osta ja pidä -strategian. Tämä indikoi, että tuoton kasvaessa riski ei ole kasvanut samassa suhteessa. Tuloksen tilastollinen merkitsevyys pitää vielä testata t-testillä. Tarkoituksena on selvittää, poikkeako Sharpen luvun tulos tilastollisesti nollassa. Testin H0 hypoteesi on, että osta ja pidä -strategian tuotto–riski-suhde on suurempi tai vähintään yhtä suuri kuin eri sijoitusstrategioilla saatu tuotto–riski-suhde. Tällöin H1 hypoteesi on, että sijoitusstrategioilla saavutetaan parempi tuotto–riski-suhde kuin osta ja pidä -strategialla.

TAULUKKO 12 Kumuloituneet log-tuotot ja Sharpen luku ennen transaktiokustannuksia.

	O&P	5	159	167	175	179
Kumulatiiviset log-tuotot	0,496705	0,842614	1,217143	1,117177	1,01784	0,93686
Sharpen luku	0,010632	0,021361	0,032985	0,029879	0,026797	0,024283
Autokorrelaatio korjattu t-testi	0,581637	1,168548	1,804473	1,634545	1,465959	1,328434

Log-tuotot ovat kaikki voimakkaasti autokorreloituneita kuten alkuperäisen aineiston aikasarja. Tästä johtuen t-testin tuloksista joudutaan korjaamaan pois autokorrelaation vaikutus (Pav 2016, 10). Korjauksen jälkeen tuloksista on havaittavissa, ettei mikään t-testin tulos ylitä tilastollisesti merkitsevän 1,94 kriittisen arvon rajapyykkiä. H0 hypoteesi jää voimaan eli osta ja pidä -strategian tuotto–riski-suhde on suurempi tai vähintään yhtä suuri kuin eri sijoitusstrategioilla saatu tuotto–riski-suhde. Strategia numero 159 on lähempänä tilastollista merkitsevyyttä kuin muut strategiat mutta ei aivan yllä tilastollisesti merkitsevän 5 prosentin kriittisen arvon yli. Toisin sanoen, vaikka transaktiokustannukset onnistuttaisiin pitämään nollassa, ei tämän tutkimuksen pohjalta voida väittää, että strategiat pystyisivät ylituottoihin testattavalla ajanjaksolla. Tämä tutkimus ei kumoa tehokkaiden markkinoiden hypoteesia, vaan suurempien tuottojen saamiseksi on otettu osta ja pidä -strategiaa suurempia riskejä.

TAULUKKO 13 Kumulatiiviset log-tuotot ja Sharpen luku kustannusten huomioimisen jälkeen.

	O&P	5	159	167	175	179
Kumulatiiviset log-tuotot	0,496705	0,035476	0,497003	0,27159	0,206502	0,137574
Sharpen luku	0,010632	-0,00366	0,010646	0,003655	0,001638	-0,0005
Autokorrelaatio korjattu t-testi	0,581637	-0,20027	0,582367	0,199944	0,089583	-0,02725

Taulukosta 13 on nähtävissä strategioiden menestys kokonaistransaktiokustannukset huomioituna. Position vaihdosta syntyväksi perustransaktiokustannukseksi valittiin 0,02125 prosenttia. Kun tähän kustannukseen lisätään vielä pankin short-posiitioista syntyvät korkokulut, kuten 2 prosentin vuotuinen marginaali päivittäiseksi korkokustannukseksi muutettuna ja päivittäin vaihtuva viitekorko (1-month T-bill), kokonaiskustannukset vaihtelevat 0,02125 - 0,05069 prosentin välillä. Tällöinkin strategia 159 voittaa osta ja pidä -strategian. Jos sijoittaja onnistuu löytämään osakevälittäjän, joka kykenee tarjoamaan vuosien 2005 ja 2016 välisenä aikana pienempiä transaktiokustannuksia, voivat muutkin strategiat voittaa osta ja pidä -strategian. Short-position kustannukset ovat merkitykseltään suuret ennen vuotta 2008, minkä jälkeen ne eivät enää näyttele suurta roolia kokonaistransaktiokustannusten muodostumisessa.

Taulukosta 13 voidaan havaita, että autokorrelaatiosta korjatun Sharpen luvun arvo ei eroa tilastollisesti nolasta transaktiokustannusten huomioimisen jälkeen, joten H_0 jää voimaan. Voidaan siis todeta, että tehokkaiden markkinoiden hypoteesi pitää paikkansa. Lisäksi voidaan todeta, että jos vuoden 2003 keskimääräiset välittäjien prosentuaaliset transaktiokustannukset ovat olleet Liin, Mooradianin ja Zhangin (2006, 15) arvioimat noin 0,079 prosenttia vaihdon arvosta tarkasteltavana ajanjaksona, mikään strategia ei voita osta ja pidä -strategiaa logaritmiaineistolla tarkasteltuna.

7 JOHTOPÄÄTÖKSET

Tutkimuksen tarkoituksena oli ennustaa koneoppimisen avulla Yhdysvaltalaisen S&P 500 -indeksistä johdetun pörssinoteeratun iShares Core S&P 500 -rahaston seuraavan päivän päätöskurssia ja verrata tuloksia tehokkaiden markkinoiden hypoteesiin ja osta ja pidä -strategian tuottoihin. Aineistona käytettiin julkisesti noteeratun iShares Core S&P 500 -rahaston historiallisia päätöskurssiarvoja ja niistä johdettuja syötteitä. Tutkimus eteni loogisesti vaiheittain. Johdanto esitteli tutkimuksessa käytettävän aineiston, tutkimuksen keskeiset rajaukset sekä teoreettisen keskustelukehikon, joka muodostettiin tehokkaiden markkinoiden hypoteesin ja älykkään rahoituksen ympärille. Tutkimuksen teoriaosuus esitteli, miten markkinatehokkuus ja osta ja pidä -strategia liittyvät toisiinsa sekä mitä ominaisuuksia markkinaennusteilta vaaditaan markkinatehokkuuden toteamiseksi. Rahoitusteorian tarkastelun jälkeen tutkimuksessa siirryttiin tarkastelemaan koneoppimisen biologisia lähtökohtia, koneoppimisen kehittymisen historiaa sekä rahoitusmarkkinoiden nykytutkimusta tekoälypohjaisten menetelmien näkökulmasta. Tutkimuksessa esiteltyjen aikaisemmin tehtyjen tutkimusten pohjalta tehokkaiden markkinoiden hypoteesia ei voitu hylätä.

Tutkimuksen menetelmäosio esitteli tutkimuksessa käytettävät koneoppimiseen pohjautuvat menetelmät ja niiden vaiheet sekä ennustettujen tuottojen differensseihin perustuvien sijoitusstrategioiden luomisen. Itse testaaminen aloitettiin perinteisillä lineaarisilla malleilla, jotka antoivat viitteitä siitä, että aikasarja saattaa olla ennustettavissa. Yksikköjuuritestin ja autokorrelaatiotestin jälkeen siirryttiin neuroverkkopohjaiseen testaukseen. Ennustetut tulokset syötettiin aikaisemmin valituille sijoitusstrategioille, jotka tuottivat markkinaennusteita. Tuloksia verrattiin osta ja pidä -strategiaan tarkempien johtopäätösten tekemiseksi.

Tutkimuksen pohjalta voidaan esittää, että pörssinoteerattu iShares Core S&P 500 -rahasto täyttää tehokkaiden markkinoiden minimivaatimuksen ehdot. Ehdot täyttyvät, koska menneisyyden hintainformaatiota ei voida hyödyntää ylituottojen saavuttamiseksi. Tulokset osoittavat kuitenkin, että sijoitusstrategioilla voi mahdollisesti tehdä osta ja pidä -strategiaa suurempaa tuottoa, mutta sijoitusstrategiat ottavat tällöin osta ja pidä -strategiaa suurempaa riskiä. Näin ollen voidaan todeta, että iShares Core S&P 500 -rahaston arvovaihtelua hyödyntävä neuroverkkopohjainen sijoitusstrategia tuottaa osta ja pidä -strategiaa enemmän.

Tärkeitä jatkotutkimuksen kohteita ovat transaktiokustannusten sisällyttäminen reaaliajassa kaupankäyntistrategioihin ja transaktiokustannusten suuruuden selkeä määrittäminen. On selvää, että korkeilla kaupankäyntikustannuksilla aktiivisesti samaan kohteeseen sijoittava toimija ei voi voittaa passiivista osta ja pidä -strategiaa. Lisäksi tutkimusta toistettaessa strategian valitsemisjaksoa tulee kasvattaa yli vuoden mittaiseksi tasaisempien tulosten saamiseksi. Myös neuroverkon koulutusta tulisi toistaa enemmän kuin kymmenen kertaa. Näin saataisiin mahdollisesti koulutettua paremmin kriteerit täyttäviä neuroverkkoja. Kriteerinä differenssien osumatarkkuuden painoarvoa voisi nostaa suhteessa voittoihin. Näin voitot eivät muodostuisi muutamien oikein ennustettujen päivien pohjalta. Lisäksi strategioiden valitsemiseen käytettäviä kriteereitä tulisi tarkistaa ja koulutuksen onnistumisen mittareita kehittää edelleen. Syötteitä neuroverkkoon voisi etsiä myös muualta kuin S&P 500 -indeksin historiasta.

Vaikka tutkimuksessa valitut sijoitusstrategiat eivät voita osta ja pidä -strategiaa joka vuosi, tulokset ovat silti hyviä ottaen huomioon sen, että strategiat ja neuroverkkojen koulutus on luotu systemaattisella menettelyllä, joka on toistettavissa. Tuloksia tarkasteltaessa on myös hyvä huomioida, että S&P 500 -indeksi on maailman seuratuin osakeindeksi. Tehokkaiden markkinoiden hypoteesin mukaan indeksin tulisi tällöin olla informaatiotehokkuudeltaan yksi tehokkaimmista indekseistä. Informaatiotehokkuuden tason ollessa hyvin suuri indeksistä johdetun rahaston ennustamisen tulisi myös olla poikkeuksellisen vaikeaa.

Tulevaisuuden tutkimuksia ajatellen olisi mielenkiintoista tutkia tässä tutkimuksessa käytettyjen lokaalien oppimisalgoritmien sijasta globaalien oppimisalgoritmien hyödynnettävyyttä osakemarkkinoiden ennustamisessa. Kiinnostava jatkotutkimuksen kohde olisi markkinatehottomuutta aiheuttavien tekijöiden tunnistaminen sisäisistä ja ulkoisista syötteistä sekä niiden hyödyntäminen neuroverkon ennusteissa. Sisäisistä syötteistä tuottojen historiallisen aineiston tilastollisesti merkitsevien viiveiden hyödyntäminen ennusteissa olisi myös hyvä jatkotutkimuksen kohde. Ulkoisista syötteistä S&P 500 -indeksin futuurimarkkinoiden vaikutuksen selvittäminen rahastomarkkinoiden ennustettavuuteen voisi avata uusia ovia menestyksekkääseen ennustamiseen. Neuroverkon hyödyntäminen futuurimarkkinoilla voisi mahdollistaa huomattavasti rahastoja edullisemmat kaupankäyntikustannukset.

LÄHTEET

Kirjallisuus

- Adebiyi, A. A., Adewumi, A. O. & Ayo C. K. (2014). Comparison of ARIMA and Artificial Neural Networks Models for Stock Price Prediction. *Journal of Applied Mathematics*, ID 614342, 1–7.
- Adhikari, R. & Agrawal, R. K. (2014). A combination of artificial neural network and random walk models for financial time series forecasting. *Neural Computing and Applications*, 24(6), 1441–1449.
- Adya, M. & Collopy, F. (1998). How effective are neural networks at forecasting and prediction? A review and evaluation. *J. Forecasting*, 17, 481–495.
- Ahmadi, H. (1990). Testability of the arbitrage pricing theory by neural networks. In *Proceedings of the international joint conference on neural networks (IJCNN)*, june, 385–393, Washington DC.
- Asadi, S., Hadavandi, E., Mehmanpazir, F. & Nakhostin, M. M. (2012). Hybridization of evolutionary Levenberg–Marquardt neural networks and data pre-processing for stock market prediction. *Knowledge-Based Systems*, 35, 245–258.
- Asakawa, K., Kimoto, T., Takeoka, M. & Yoda, M. (1990). Stock market prediction system with modular neural networks. *Neural Networks*, 1, 1–6
- Atsalakis, G. S. & Valavanis, K. P. (2009). Surveying stock market forecasting techniques – Part II: Soft computing methods. *Expert Systems with Applications*, 36(3), 5932–5941.
- Box, G. E. P. & Pierce, D. A. (1970). Distribution of residual autocorrelations in autoregressive-integrated moving average time series models. *Journal of the American Statistical Association*, 65(332), 1509–1526.
- Burney, S. M. A., Jilani, T. A. & Ardil, C. (2005). Levenberg-Marquardt algorithm for Karachi Stock Exchange share rates forecasting. *World Academy of Science, Engineering and Technology*, 3, 171–176.
- Campbell, J. Y., Lo, A. W. & MacKinlay, A. C. (1997). *The econometrics of financial markets* (1st ed.). New Jersey: Princeton University Press.
- Cao, Q., Leggio, K. B. & Schniederjans, M. J. (2005). A comparison between Fama and French's model and artificial neural networks in predicting the Chinese stock market. *Computers & Operations Research*, 32(10), 2499–2512.
- Chang, P. C. & Liu, C. H. (2008). A TSK type fuzzy rule based system for stock price prediction. *Expert Systems with applications*, 34(1), 135–144.

- Chen, C. H. (1994). Neural networks for financial market prediction. *Neural Networks, IEEE World Congress on Computational Intelligence. IEEE International Conference*, 2, 1199–1202.
- Chen, F., Chen, Y. H. & Zhang, J. Z. (2007). Stock index modeling using IP based gene expression programming. *Computer Engineering and Applications*, 42(26), 227–229.
- Cybenko, G. (1989). Approximation by superpositions of a sigmoidal function. *Mathematics of control, signals and systems*, 2(4), 303–314.
- Durham, G. B. (2007). Sv mixture models with application to S & P 500 index returns. *Journal of Financial Economics*, 85, 822–856
- Fama, E. (1970). Efficient capital markets: a review of theory and empirical work. *Journal of Finance*, 25(2), 383–417.
- Fama, E. (1991). Efficient capital markets: II. *The Journal of Finance*, 46(5), 1575–1617.
- Fausett, L. (1994). *Fundamentals of neural networks*. New Jersey: Prentice Hall.
- Finnerty, J. D. (1988). Financial engineering in corporate finance: an overview. *Financial Management*, 14–33.
- Friedman, J., Hastie, T. & Tibshirani, R. (2009). *The elements of statistical learning*, Springer series in statistics, 2, Berlin.
- Ghanbari, A., Hadavandi, E. & Shavandi, H. (2010). Integration of genetic fuzzy systems and artificial neural networks for stock price forecasting, *Knowledge-Based Systems*, 23, 800–808.
- Goldberg, D. E. (1989). *Genetic algorithms in search and machine learning*. Reading, Addison Wesley.
- Gujarati, D. N. & Porter, D. C. (2009). *Basic econometrics* (5th ed.). New York: McGraw-Hill.
- Granger, C. W. & Teräsvirta, T. (1993). *Modelling non-linear economic relationships*. OUP Catalogue.
- Grossman, S. J. & Stiglitz, J. E. (1980). On the impossibility of informationally efficient markets. *The American Economic Review*, 70(3), 400–403.
- Gupta, J. N. D. & Sexton, R. S. (1999). Comparing backpropagation with a genetic algorithm for neural network training. *Omega*, 27(6), 679–684.
- Hagan, M. T. & Menhaj, M. B. (1994). Training feedforward networks with the Marquardt algorithm. *Neural Networks, IEEE Transactions on*, 5(6), 989–993.
- Haykin, S. (1994). *Neural networks: A comprehensive foundation*. New Jersey: Prentice Hall.
- Haykin, S. (2009). *Neural networks and learning machines* (3rd ed.) New Jersey: Pearson.

- Hill, T., O'Connor, M. & Remus, W. (1996). Neural network models for time series forecasts. *Management science*, 42(7), 1082–1092.
- Holland, J. H. (1975). *Adaptation in natural and artificial systems: an introductory analysis with applications to biology, control, and artificial intelligence*. U Michigan Press.
- Hornik, K., Stinchcombe, M. & White, H. (1989). Multilayer feedforward networks are universal approximators. *Neural networks*, 2(5), 359–366.
- Huang, W., Nakamori, Y. & Wang, S. Y. (2005). Forecasting stock market movement direction with support vector machine. *Computers & Operations Research*, 32(10), 2513–2522.
- Hussain, A. J., Knowles, A., Lisoba, P. J. G. & El-Deredy, W. (2008) Financial time series prediction using polynomial pipelined neural networks. *J Expert Syst Appl*, 35, 1186–1199
- Ignizio, J. P. & Soltys, R. (1996). Simultaneous design and training of ontogenic neural network classifiers. *Computers and Operations Research*, 23(6), 535–546.
- Jensen, M. C. (1978) Some Anomalous Evidence Regarding Market Efficiency. *Journal of Financial Economics*, 6(2–3), 95–101.
- Kamijo, K. & Tanigawa, T. (1990). Stock price pattern recognition: a recurrent neural network approach. *Proceedings of the International Joint Conference on Neural Networks*, 215–221, San Diego, CA.
- Khashei, M. & Bijari, M. (2010.) An artificial neural network (p, d, q) model for time series forecasting. *J Expert Syst Appl*, 37, 479–489-
- Kim, K. J. & Lee, W. B. (2004). Stock market prediction using artificial neural networks with optimal feature transformation. *Neural computing & applications*, 13(3), 255–260.
- Knüpfner, S. & Puttonen, V. (2009). *Moderni rahoitus*. WSOYpro.
- Kohzadi, N., Boyd, M. S., Kermanshahi, B. & Kaastra, I. (1996). A comparison of artificial neural network and time series models for forecasting commodity prices. *Neurocomputing*, 10(2), 169–181.
- Koop, G. (2008). *Introduction to econometrics* (1st ed.). Lontoo: John Wiley & Sons, Ltd.
- Lapedes, A. S. & Farber, R. M. (1988). How neural nets work. *Neural information processing systems*, 442–456.
- Lawrence, S., Tsoi, A. C. & Giles, C. L. (1998). Noisy time series prediction using symbolic representation and recurrent neural network grammatical inference. Technical Report, Institute for Advanced Computer Studies, University of Maryland, MD 20742.
- Lee, Y. S. & Tong, L. I. (2011). Forecasting time series using a methodology based on autoregressive integrated moving average and genetic programming. *Knowledge-Based Systems*, 24(1), 66–72.

- Li, J., Mooradian, R. & Zhang, W. D. (2006). Commission Costs, Illiquidity and Stock Returns, Researchgate.
- Majhi, R., Panda, G., Sahoo, G., Dash, P. K. & Das, D. P. (2007). Stock market prediction of S&P 500 and DJIA using bacterial foraging optimization technique. *Evolutionary Computation, IEEE Congress*, 2569–2575.
- Malkiel, B. G. (1985). *A random walk down Wall Street*. New York: Norton.
- Malkiel, B. G. (1992), Efficient market hypothesis. Teoksessa P. Newman, M. Milgate & J. Eatwell (toim.) *New palgrave dictionary of money and finance*. Lontoo: Macmillan.
- Mason, S. P., Merton, R. C., Perold, A. F. & Tufano, P. (1995). *Cases in Financial Engineering: Applied Studies of Financial Innovation*, Prentice Hall, Englewood Cliffs, NJ.
- Miao, K., Chen, F. & Zhao, Z. G. (2007). Stock Price Forecast Based on Bacterial Colony RBF Neural Network. *Journal of Qingdao University (Natural Science Edition)*, 20(2), 50–54.
- Oh, K. J. & Kim, K. J. (2002). Analyzing stock market tick data using piecewise nonlinear model. *Expert Systems with Applications*, 22(3), 249–255.
- Pan, H. (2003). A joint review of technical and quantitative analysis of the financial markets towards a unified science of intelligent finance. *Hawaii International Conference on Statistics and Related Fields*, 5–9.
- Pav, S. E. (2016). Notes on the Sharpe ratio, *Semantic Scholar*, 1–49.
- Refenes, A. N., Zaprani A. & Francis G., (1994). Stock performance modeling using neural networks: A comparative study with regression models. *Neural Networks*, 7(2), 375–388.
- Russell, S. & Norvig, P. (2010). *Artificial Intelligence - A Modern Approach* (3rd ed.)
- Schöneburg, E. (1990). Stock price prediction using neural networks: A project report. *Neurocomputing*, 2(1), 17–27.
- Sewell, M. V. (2009) *The application of intelligent systems to financial time series analysis*. PhD thesis, Department of Computer Science, UCL, London
- Sexton, R. S., Alidaee, B., Dorsey, R. E. & Johnson, J. D. (1998a). Global optimization for artificial neural networks: a tabu search application. *European Journal of Operational Research*, 106(2/3), 570–584.
- Sexton, R. S., Dorsey, R. E. & Johnson, J. D. (1998b). Toward global optimization of neural networks: a comparison of the genetic algorithm and backpropagation. *Decision Support Systems*, 22(2), 171–185.
- Sharpe, W. F. (1966) Mutual Fund Performance. *The Journal of Business*, 1, 119–138.

- Shin, K., Shin, T. & Han, I. (1998). Neuro-genetic approach for bankruptcy prediction: a comparison to back-propagation algorithms. Proceedings of the International Conference of the Korea Society of Management Information Systems, 585–597, Seoul, South Korea.
- Tan, T. Z., Quek, C. & Ng, G. S. (2005). Brain inspired genetic complimentary learning for stock market prediction. IEEE congress on evolutionary computation, 3, 2653–2660.
- Tsaih, R., Hsu, Y. & Lai, C. C. (1998). Forecasting S&P 500 stock index futures with a hybrid AI system. Decision Support Systems, 23(2), 161–174.
- Tähtinen, S. (2009). Neuroverkkolaskenta ja sen soveltaminen vakuutusdataan. Working papers, ISSN 0781- 4410, Suomen aktuaariyhdistys.
- Wang, Y. F. (2003). Mining stock price using fuzzy rough set system. Expert Systems with Applications, 24(1), 13–23.
- Wang, J. Z., Wang, J. J., Zhang, Z. G. & Guo, S. P. (2011). Forecasting stock indices with back propagation neural network. Expert Systems with Applications, 38(11), 14346–14355
- Wang, J. J., Wang, J. Z., Zhang, Z. G. & Guo, S. P. (2012). Stock index forecasting based on a hybrid model. Omega, 40(6), 758–766.
- Werbos, P. J. (1988). Generalization of backpropagation with application to a recurrent gas market model. Neural Networks, 1(4), 339–356.
- White, H. (1988). Economic prediction using neural networks: the case of IBM daily stock returns. Neural Networks, 2, 451–458.
- Widrow, B. & Hoff, M. E. (1960). Adaptive switching circuits. WESCON Convention Record Part IV, 96–104 (reprinted in Anderson, J. A. & Rosenfeld, E. Neurocomputing: Foundations of Research).
- Zhang, G., Patuwo, B. E. & Hu, M. Y. (1998). Forecasting with artificial neural networks: The state of the art. International journal of forecasting, 14(1), 35–62.
- Zhang, G. P. (2003). Time series forecasting using a hybrid ARIMA and neural network model. Neurocomputing, 50, 159–175.
- Zhang, G. P. & Qi, M. (2005). Neural network forecasting for seasonal and trend time series. European journal of operational research, 160(2), 501–514.
- Zhang, Y. & Wu, L. (2009). Stock market prediction of S&P 500 via combination of improved BCO approach and BP neural network. Expert systems with applications, 36(5), 8849–8854.
- Elektroniset lähteet, internet:
- Black Rock (2016). iShares Core S&P 500 ETF.
<https://www.ishares.com/us/products/239726/ishares-core-sp-500-etf> Maaliskuu 2016

Interactive Brokers (2016). Commissions.

<https://www.interactivebrokers.com/en/index.php?f=1590&p=stocks2> Maaliskuu 2016

Investment Company Fact Book (2015). Exchange-Traded Funds.

http://www.icifactbook.org/fb_ch3.html Maaliskuu 2016

Stock Trader (2016). Compare Online Brokers. <https://www.stocktrader.com/compare-online-brokers/>

Maaliskuu 2016

Wikipedia (2016). S&P 500 Index.


https://en.wikipedia.org/wiki/S%26P_500_Index Maaliskuu 2016

Ohjekirjat

Matlab 7 neural network toolbox

LIITTEET

LIITE 1. Transaktiokustannusten kehitys 1980-2003.



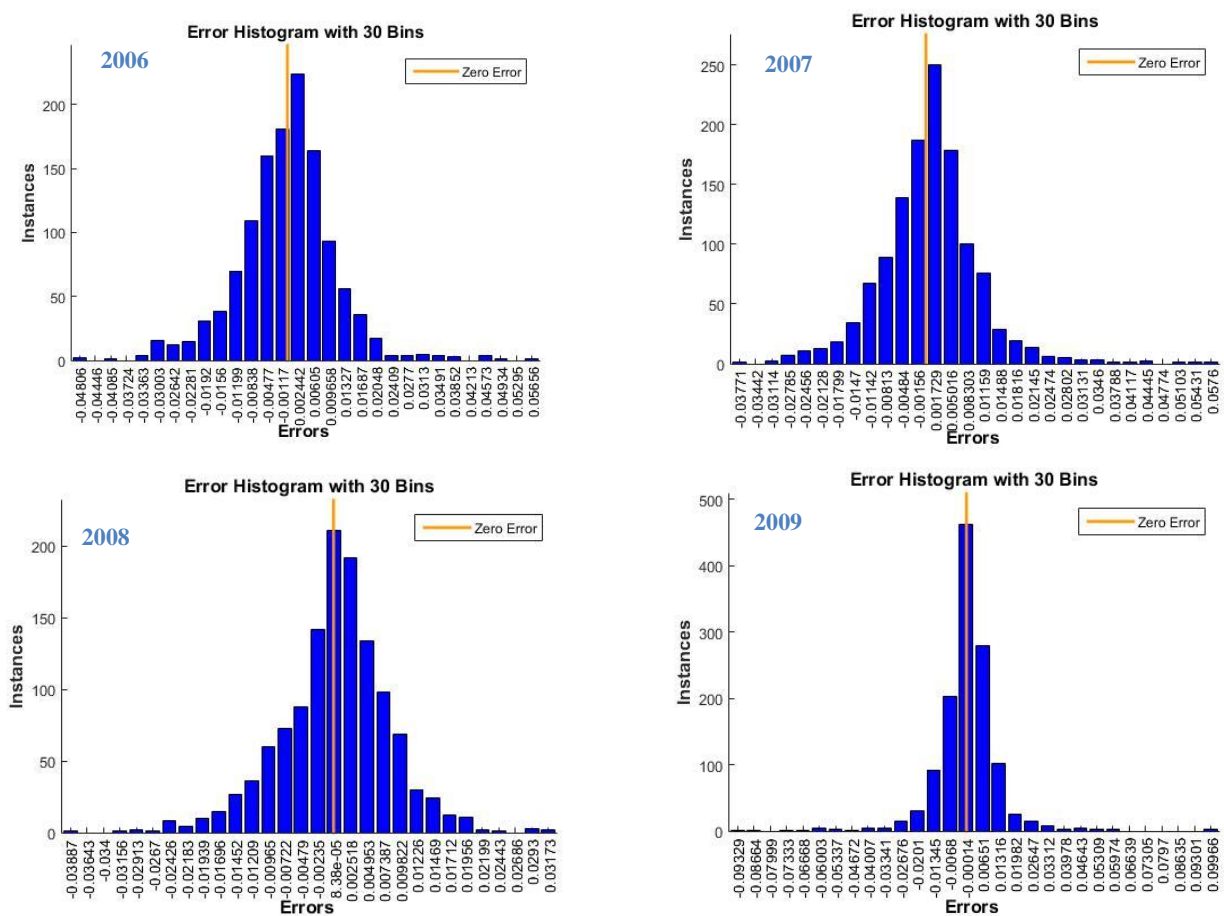
LIITE 2. Autokorrelaatiotestin tulokset tuotot-aikasarjalle eri viive pituuksilla.

Portmanteau testin tulokset	p-arvo
Portmanteau(6): $\text{Chi}^2(6) = 44.948$	[0.0000]**
Portmanteau(12): $\text{Chi}^2(12) = 60.363$	[0.0000]**
Portmanteau(18): $\text{Chi}^2(18) = 105.50$	[0.0000]**
Portmanteau(24): $\text{Chi}^2(24) = 126.07$	[0.0000]**

LIITE 3. Koulutuksen tarkkailu.

Ajanjaksot		Koulutuksen määrä		Surituskyky		
Ennustevuosi	Koulutusjakso	Epokkien määrä	Paras epok	Koulutusryhmä	Validoitiryhmän	Testiryhmän
2005	3.1.2000-31.12.2004	11	5	1,57E-04	1,67E-04	2,18E-04
2006	2.1.2001-30.12.2005	33	27	1,35E-04	8,95E-05	1,15E-04
2007	2.1.2002-29.12.2006	33	27	9,93E-05	8,62E-05	8,62E-05
2008	2.1.2003-31.12.2007	13	7	7,02E-05	5,07E-05	4,60E-05
2009	2.1.2004-31.12.2008	11	5	1,69E-04	1,16E-04	1,45E-04
2010	3.1.2005-31.12.2009	21	15	1,94E-04	1,86E-04	2,41E-04
2011	3.1.2006-31.12.2010	12	6	2,24E-04	2,52E-04	1,98E-04
2012	3.1.2007-30.12.2011	15	9	2,23E-04	3,00E-04	4,18E-04
2013	2.1.2008-31.12.2012	9	3	2,47E-04	2,57E-04	3,22E-04
2014	2.1.2009-31.12.2013	10	4	1,49E-04	1,46E-04	9,71E-05
2015	4.1.2010-31.12.2014	14	8	1,01E-04	9,56E-05	5,65E-05
Keskiarvo		16,55	10,55	1,61E-04	1,59E-04	1,77E-04
Mediaani		13	7	1,57E-04	1,46E-04	1,45E-04

LIITE 4. Koulutuksen virheiden histogrammit, jotka ovat nimetty ennustejakojen mukaan.



LIITE 4. Jatkuu

