



**NEUROVERKKOJEN HYÖDYNTÄMINEN OSAKEMARKKINOIDEN HINTA-  
KEHITYKSEN ANALYSOINNISSA**

Kandidaatintutkielma

Lappeenrannan–Lahden teknillinen yliopisto LUT

Kauppätieteiden kandidaatintutkielman tutkimussuunnitelma

2022

Elviira Kairamo

Tarkastaja: Tutkijatohtori Jyrki Savolainen

## TIIVISTELMÄ

Lappeenrannan–Lahden teknillinen yliopisto LUT

LUT-kauppakorkeakoulu

Kauppatieteet

Elviira Kairamo

### **Neuroverkkojen hyödyntäminen osakemarkkinoiden hintakehityksen analysoinnissa**

Kauppatieteiden kandidaatintutkielma

24 sivua, 5 kuvaa, 2 taulukkoa ja 5 liitettä

Tarkastaja: Tutkijatohtori Jyrki Savolainen

Avainsanat: Neuroverkot, osakemarkkinat, koneoppiminen

Tässä kandidaatintyössä tutkitaan neuroverkkojen hyödyntämistä osakemarkkinoiden analysoinnissa ja pyritään ennustamaan osakkeille tulevaisuuden hintoja. Tutkimus toteutettiin tutustumalla ensin neuroverkkojen teoriaan ja näin selvittämällä niiden hyödyt ja mahdollisuudet osakemarkkinoiden ennustamisessa. Kirjallisuuskatsauksessa käytiin läpi tarkemmin myös Multilayer perceptron neural networkia (MLP) ja Nonlinear Artificial neural networkia (NAR). Tässä tutkimuksessa tutkittiin myös neuroverkon toimintaa rakentamalla NAR-neuroverkko MATLAB tietokoneohjelmistolla ja näin ennustettiin neljän suomalaisen teollisuusalan yrityksen osakkeiden tulevia hintoja (Kone Oyj, Ponsse Oyj, Valmet Oyj ja Wärtsilä Oyj Abp) perustuen niiden historialliseen kurssikehitykseen. Tutkimus on toteutettu kvantitatiivisena eli määrällisenä tutkimuksena. Tutkimus osoittaa, että neuroverkot soveltuvat osakemarkkinoiden ja osakkeiden hintojen ennustamiseen, mutta vaativuuden ja

suuren vaadittavan laskentatehon takia tämä ei välttämättä ole tehokkain tapa ennustaa hintoja ja tehokkaampia tapoja voidaan käyttää.

## ABSTRACT

Lappeenranta–Lahti University of Technology LUT

School of Business and Management

Business Administration

Elviira Kairamo

### **Utilization of neural networks in the analysis of stock market price developments**

Bachelor's thesis

2022

24 pages, 5 figures, 2 tables and 5 appendices

Examiners: Postdoctoral researcher Jyrki Savolainen

Keywords: Neural networks, stock markets, machine learning

This bachelor's thesis examines the utilization of neural networks in stock market analysis and seeks to predict future prices for stocks. The research was carried out by first getting acquainted with the theory of neural networks and thus finding out their benefits and possibilities in predicting the stock market. The Multilayer Perceptron neural network and the Nonlinear Artificial neural network were also reviewed in more detail in the literature review. This study also examined the operation of the neural network by building the NAR neural network with MATLAB computer software and thus predicted the future prices of shares of 4 industrial companies.

The study has been carried out as a quantitative study. The research material was collected from the historical share price data of four selected companies (Kone Oyj, Ponsse Oyj, Valmet Oyj and Wärtsilä Oyj Abp).

The study found that neural networks are suitable for forecasting stock markets and stock prices, but due to the complexity and computational power required, this is not the most efficient way to forecast prices.

# Sisällysluettelo

1. Johdanto .....	1
1.1 Rajaukset .....	2
1.2 Työn rakenne.....	2
1.2. Tutkimuskysymykset ja -hypoteesit.....	3
2. Teoreettinen viitekehys .....	4
3. 1 Neuroverkot .....	4
3.1.1 Kerrokset.....	5
3.1.2 Neuronit .....	6
3. 2 Multilayer Perceptron Network (MLP).....	9
3.3 Nonlinear Autoregressive neural network (NAR) .....	12
3.4 Neuroverkkojen käyttäminen .....	14
3.5 Osakehintojen kehityksen analysointi.....	15
3.6 Mallin sovitus.....	16
3.7 Levenberg Marquardt back propagation algorithm.....	16
3.8 Laadulliset suorituskykymittarit.....	17
4. Tutkimusmenetelmät ja -aineisto .....	17
4. Tutkimuksen toteutus .....	19
5. Tutkimuksen tulokset.....	21
7. Johtopäätökset.....	23
8. Lähteet .....	25

## Liitteet

Liite 1: KNEBV, PON1V, VALMT ja WRT1V-osakkeiden kurssit

Liite 2: KNEBV, PON1V, VALMT ja WRT1V-osakkeiden ennusteiden virhe histogrammit.

Liite 3 KNEBV, PON1V, VALMT ja WRT1V-osakkeiden ennusteiden vastekaaviot

Liite 4: KNEBV, PON1V, VALMT ja WRT1V-osakkeiden ennusteiden korrelaatiot, R-arvo

Liite 5: KNEBV, PON1V, VALMT, WRT1V-osakkeiden hinnat aineiston 10 viimeisenä päivänä ja ennuste 10 viimeiselle päivälle+ 1 lisäpäivälle

## Kuvat

Kuva 1: Neuroverkon rakenne

Kuva 2: Neuronin rakenne

Kuva 3: Kissa/Koira-esimerkki ja neuronien syttyminen

Kuva 4: NAR rakenne (MATLAB, 2022)

Kuva 5: Tutkimuksen NAR-verkon rakenne 10 piiloneuronilla ja 2 viiveellä (MATLAB, 2022)

## Taulukot

Taulukko 1: Ennusteiden MSE- ja R-arvot jokaisella datan jaolla

Taulukko 2: Osakkeiden hinnat ja neuroverkon luomat ennusteet viimeiselle tutkimusaineiston 10+1 päivälle

## 1. Johdanto

Tässä kandidaatin tutkielmassa tutkitaan sitä, kuinka neuroverkkoja voidaan hyödyntää osakemarkkinoiden analysoinnissa. Pyritään selvittämään, onko tämä mahdollista ja kuinka tehokas tapa se on analysoida pitkän aikavälin osakkeiden menestymistä. Neuroverkolla on monenlaisia sovelluksia aina kuvan tunnistamisesta luottoriskien ennustamiseen. Tarkemmin keskitytään tutkimaan Multilayer Perceptron networkin, MLP:n ja Nonlinear Autoregressive neural networkin NAR:n toimintaan ja sovelluksia. Ensin tässä kandidaattitutkielmassa tehdään kirjallisuuskatsaus neuroverkoista. Löydettyä materiaalia käytetään tutkimuksen toisessa osassa, empiriassa, jossa pyrin ennustamaan valittujen osakkeiden menestystä valitulla aikasarjalla teollisuusalan osakemarkkinoilta välillä 2016–2021.

Neuroverkot ovat sopeutuvia tilastollisia malleja, jotka perustuvat analogiaan aivojen rakenteen kanssa. Neuroverkoilla pystyy pienelläkin otoskoollla tutkimaan haluttuja ilmiöitä, mikäli tähän käytetty data on yksinkertaista. Neuroverkkoja hyödynnetään monella eri alalla, kuten tilastotieteessä ja ekonometriassa, joten nämä sopeutuvat hyvin osakemarkkinoiden analysointiin. (Abdi, Valentin, Edelman, 1999.) Neuroverkot ovat siis erittäin hyviä löytämään malleja ja kuviota riippumatta siitä, onko käytetty aineisto jatkuvaa, diskreettiä tai ajasta erillistä. Neuroverkkojen suosio on lisääntynyt merkittävästi 2010-luvulla, kun koneiden laskentateho on kasvanut huomattavasti ja dataa on enemmän käytettävissä. (Kananen, Puolitaival, Puntti, Metsola, I. 2019)

Neuroverkko koostuu yksinkertaisista prosessoreista, joita kutsutaan neuroneiksi. Nämä neuronit ovat yhteydessä toisiinsa painotettujen linkkien välityksellä. Neuroverkon toiminta perustuu siihen, että neuroverkko oppii muuttamaan painokertoimia neuroneiden välillä. (Haykin, 1999)

## 1.1 Rajaukset

Tämä työ keskittyy syväoppimiseen ja tarkemmin neuroverkkoihin ja niiden käyttämiseen juuri osakemerkinnöiden analysoinnissa. Työhön valitussa aineistossa käytettävien osakkeiden toimialaksi valittiin teollisuus ja valittujen osakkeiden hintoja analysoidaan pitkällä aikavälillä. Maantieteellisenä rajauksena toimii Suomi ja valitut yritykset ovatkin suuria suomalaisia teollisuusalan yrityksiä.

Tutkimuksessa rajataan tutkittava aikaväli lyhyelle aikavälille. Tutkimusaineisto kuitenkin kerätään pitkältä aikaväliltä, mutta neuroverkko hyödyntää sitä osissa, joten Nonlinear Autoregressiivisellä neuroverkolla satavat ennusteet ovat lyhyen aikaväli ennusteita. Suuri tutkimusaineisto on helpompi jakaa neuroverkon käyttämiin osiin ja näin ennusteista saadaan tarkempia.

## 1.2 Työn rakenne

Teoriaosuuden avulla toteutetaan empiirinen tutkimus, jossa testataan Multilayer Perceptron network-mallisen neuroverkon toimivuutta ja soveltuvuutta valitulle osakemarkkinadatalle. Tutkimusta varten neuroverkko rakennetaan hyödyntäen MATLAB-tietokoneohjelmiston sisältämiä apusovelluksia. Tutkimuksen toteuttamisen jälkeen raportoidaan tulokset, arvioidaan niiden luotettavuutta ja käydään läpi mahdollisia jatkotutkimusaiheita.

## 1.2. Tutkimuskysymykset ja -hypoteesit

Työn tarkoituksena on tehdä yleistävä katsaus neuroverkkojen käyttöön osakemarkkinoiden analysointiin pitkällä aikavälillä. Pitkällä aikavälillä tässä työssä tarkoitetaan 10 vuotta ja hintoja tarkastellaan kuukausi tasolla. Tarkoituksena on myös selvittää, ovatko neuroverkot soveltuvia osakemarkkinoiden hintakehityksen analysoimiseen. Tarkemmin tutkitaan että onko Multilayer Perceptron networkin ja Nonlinear Autoregressive neural networkin käyttäminen tehokas tapa analysoida hintojen kehittymistä. Tämän selvittämiseksi tutkielman päätutkimuskysymys on seuraava:

*Millä tavoin neuroverkkoja voi hyödyntää osakkeiden hintojen analysoinnissa?*

Pääkysymyksen tueksi ja menetelmän tehokkuuden selvittämiseksi apukysymyksenä toimii:

*Miten tehokkaasti neuroverkot toimivat osakkeiden tulevien hintojen ennustamisessa?*

Vastauksia näihin kysymyksiin saadaan kirjallisuuskatsauksen avulla ja teoriasta sovelletun tutkimuksen avulla.

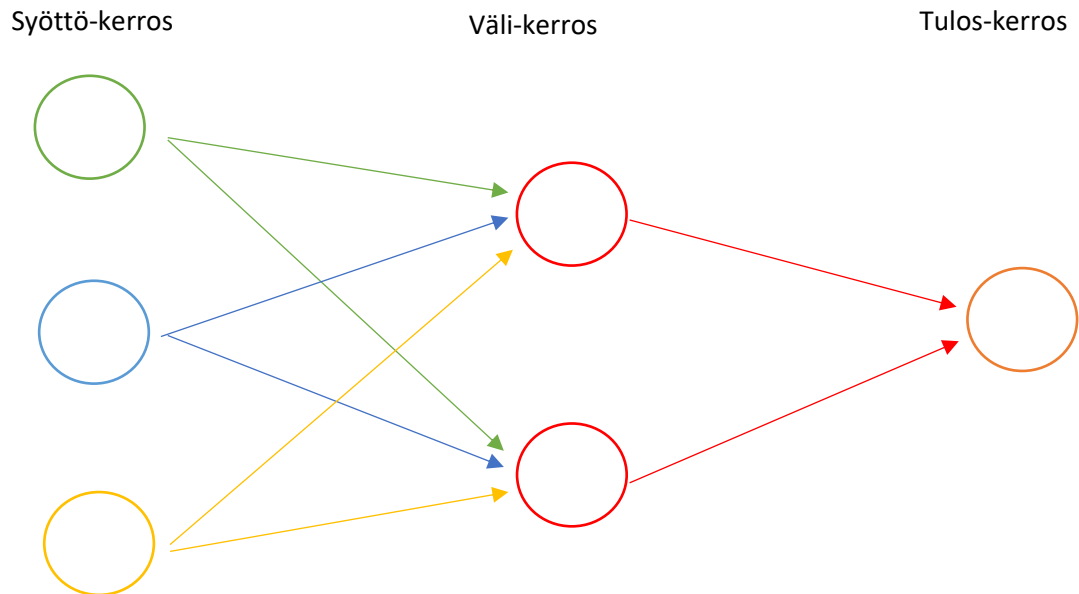
Alustavana hypoteesina on, että tutkimukseen valittua neuroverkko pystytään käyttämään valittujen osakkeiden hintojen analysoinnissa. Neuroverkolla pystytään ennustamaan tulevia hintoja aineiston ulkopuolelta, mutta oletuksena on, että mitä kauemmas arvoja yritetään ennustaa, sitä epäluotettavammaksi malli käy ja saadut tulokset eivät ole luotettavia ja todenmukaisia. Myös osakemarkkinoiden ennustaminen on monessa lähteessä todettu hankalaksi, joten oikeiden tulosten saaminen ei välttämättä ole helppoa ja neuroverkkojen hankaluus saattaa vaikuttaa osaltaan tutkimuksen toteutukseen ja tuloksiin.

## 2. Teoreettinen viitekehys

Kirjallisuuskatsauksena toimii systemaattinen kirjallisuuskatsaus. Systemaattinen kirjallisuuskatsaus keskittyy tiivistämään tietoa jonkin tietyn aihepiirin sisällä. Tässä työssä pyritään tiivistämään neuroverkoista löydettyä tietoa yhtenäiseksi ja ymmärrettäväksi sisällöksi, jota soveltaan empiirisessä osiossa. (Petticrew 2001, Kallio 2006). Kirjallisuuskatsauksessa käydään läpi tieteellistä tekstiä, jotta hypoteesia voidaan testata ja tulokset voidaan esittää selkeästi tutkimuksen lopussa.

### 3. 1 Neuroverkot

Neuroverkko (eng. Neural network) ovat syväoppimisen ja koneoppimisen menetelmiä, jotka pyrkivät toimimaan ja matkimaan aivojen toimintaan ja kykyä jatkuvaan oppimiseen. Ihmisen aivoissa on miljoonia neuroneita, joiden välillä tieto liikkuu. Neuroverkkojen toiminta on samantyylistä, mutta yksinkertaisemmin rakennettua. Tutkimuksen elinikäisen oppimisen neurofysiologiasta ovat inspiroineet koneoppimista ja näin neuroverkkojen kehittämistä. (German et al, 2019) Neuroverkot ovat ohjelmoituja matemaattisia malleja, joiden tavoitteensa on etsiä yhtäläisiä malleja sille annetusta datasta (Chollet, 2018). Neuroverkkoja hyödynnetään monella eri alalla kuten matematiikassa, fysiikassa, tilastotieteessä ja tekniikan eri aloilla (Yadav, 2015). Neuroverkkoja voidaan hyödyntää tehokkaasti aikasarja ennustamiseen (Chen, 2020). Neuroverkot eivät juurikaan eroa muista tilastollisista malleista ja niillä onkin yhtäläisyyksiä esimerkiksi erotteluanalyysin, pääkomponenttianalyysin ja logistisen regression kanssa (Aldi et al 1999, 2)



Kuva 1 Neuroverkon rakenne

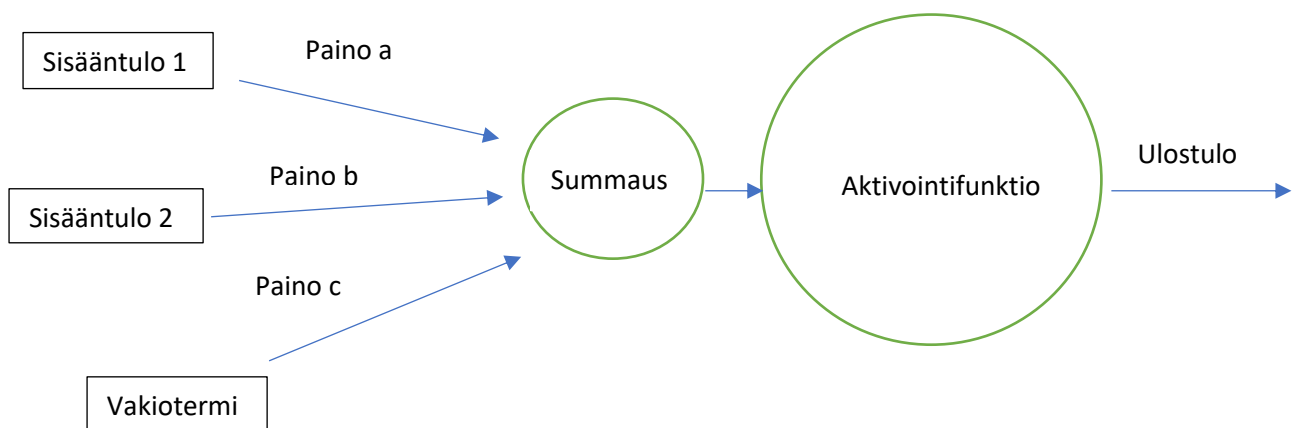
### 3.1.1 Kerrokset

Neuroverkot koostuvat kerroksista, joiden sisällä on neuroneita. Nämä kerrokset linkittyvät yhteen, josta tulee nimi neuroverkko. Nämä kerrokset yhdistyvät toisiinsa painotettujen liitosten avulla (Aldi et al 1999, 2). Kerroksia on monissa neuroverkoissa vähintään kolme. Yleisin kerrosten rakenne on eteepäinsyöttävä (feedforward), jossa kaikki neuronit edellisestä kerroksesta kytkeytyy seuraavaan kerrokseen. Näitä kerroksia ovat siis syöttö-, väli- ja tuloskerrokset. Nämä kerrokset sisältävät neuroneita, joiden välillä annettu data kulkee. Kuvassa 1 näkyy kerrosten paikat ja niiden väliset neuronit nuolina. Välikerroksia neuroverkoissa voi olla useampia ja kerrosten lukumäärä riippuu, minkälainen neuroverkko on ja mitä sillä halutaan tutkia (Noriega, 2005). Piilokerroksessa (Hidden layers) neuroverkko säätelee saadun syötteen niin, että neuroverkon virhemarginaali on mahdollisimman pieni. Tieto

kulkee näiden kerrosten välillä neuroneiden avulla. Jokainen kerros saa jonkin verran tietoa edellisestä kerroksesta ja käsittelee tämä tiedon ja lähettää sen joko eteenpäin tai ei, riippuen ongelmasta (Aldi et al 1999, 2).

### 3.1.2 Neuronit

Neuronit ovat yksittäisiä yksinkertaisia tehtäviä suorittavia osasia. Kaikista yksinkertaisimmassa neuroverkossa on vain yksi neuroni ja tämän kehittäjä Frank Rosenblatt nimitti yhden neuronin verkkoa perceptroniksi. Monissa neuroverkoissa on kuitenkin enemmän neuroneita ja näin myös kerroksia (Shiffman 2012, 448.) Neuronit kerää ja luokittelee saatua informaatiota tietynlaisen rakenteen mukaan, joka tälle neuronille on annettu (Chen, 2020). Neuronit koostuu synapseista, summaajasta ja aktivaatiofunktioista.



Kuva 2. Neuronin rakenne

Neuronilla voi olla yksi tai useampi sisääntulo, mutta vain yksi ulostulo. Näiden lisäksi neuronilla on yksi vakiotermi, jonka arvo on aina yksi. Aktivaatiofunktion

sisälle tulee summa, kun sisääntulon tulot on kerrottu omilla painoarvoillaan ja summattu yhteen. Lisäksi summaan lisätään vakiotermi 1 kerrottuna sen omalla painoarvolla (Brownlee 2016).

$$Summa = \sum_{i=1}^n i_1 \cdot w_1 + i_2 \cdot w_2 + \dots + i_n \cdot w_n + 1 \cdot w_b \quad (1)$$

Missä  $i_n$ =neuronin sisääntulo

$w_n$ =sisääntulonpaino

$w_b$ =vakioterminpaino

Yleisin aktivaatiofunktio on logistinen funktio

$$f(x) = \frac{1}{1+e^{-x}} \quad (2)$$

*jossa e = neperinluku*


Usein neuronit ovat ”jos-niin” rakenteisia lauseita. Eli jos neuronille syötetty tieto on tietynlaista, niin se kulkee eteenpäin toiseen neuroniin, niille asetettujen ehtojen mukaan. Tavoitteena on saada neuroverkko oppimaan datan epälineaarisia riippuvuussuhteita parhaan mahdollisen lopputuloksen löytämiseen.

Neuroni on joko aktiivinen tai ei-aktiivinen. Mikäli neuroni on käytössä, se siirtää input tietonsa eteenpäin. Näitä välejä, joissa neuronien välinen tieto liikkuu, kutsutaan synapseiksi. (Noriega, 2005). Kun nämä kerrokset yhdistyvät verkoksi ja tästä tuleekin nimitys neuroverkko.

Neuroverkko on osa koneoppimista ja sen toiminta perustuukin siis itsestään oppimiseen. Neuroverkon tavoitteena on oppia tai löytää yhtäläisyyksiä input/syötteen ja output/tulosten välillä. Tämä oppimisen prosessi saavutetaan muuttamalla painokerroimia kerrosten välillä. (Aldi et al 1999, 2). Neuroverkko oppii esimerkkien avulla

ja näin neuroverkoille voi opettaa paljon tutkittavasta mallista. Neuroverkkoon esitetään koulutuksen aikana esimerkkejä, kuten kuvia, joista se oppii hahmottamaan mitä asioita annetusta datasta tulee löytää, jotta se voi siirtyä neuronista toiseen onnistuneesti. Kun neuroverkon kouluttaminen on tehty oikein ja onnistuneesti, neuroverkkoa voidaan alkaa käyttää tehokkaasti tutkittavan ongelman ratkaisemiseen.

Esimerkkinä neuroverkkojen toiminnasta usein käytetään Kissa/Koira-esimerkkiä. Tässä neuroverkko on rakennettu niin, että se pyrkii tunnistamaan kissoja ja koiria. Neuroverkolle syötetään kuvia, joissa on joko kissa tai koira ja neuroverkko kerroksissaan etsii tiettyjä piirteitä kuvista ratkaistakseen ongelman. Neuronit saattaa esimerkiksi etsiä pikseleitä pitkistä vs. lyhyistä korvista, isosta vs. pienestä kuonosta ja näin tieto kulkee neuronista neuroniin ja päästään lopputulokseen, että onko kuvassa kissa vai koira.



*Kuva 3. Kissa/Koira-esimerkki ja neuronien syttyminen*

Neuroverkon kouluttaminen voi olla valvottua tai valvomatonta. (Yadaw et al, 2015). Valvotussa kouluttamisessa oppimista ohjataan määräämällä jokaiselle syötteelle

luokka tai väli, johon sen arvojen oletetaan kuuluvan. Mikäli koulutus on valvomatonta, neuroverkko muodostaa oman luokkansa perustuen syötedatan yhteisiin piirteisiin ja ominaisuuksiin, joita se havaitsee. Neuroverkon kouluttaminen on rajaton epälineaarinen minimointi ongelma, jossa painoarvoja muuttamalla pyritään minimoimaan kokonaiskeskiarvon tai -neliön virhettä halutun arvon, eli tuloksen ja todellisen arvon, eli lähtöarvon välillä. (Devadoss, Ligori, 2013).

Neuroverkkoja voidaan siis soveltaa monella eri tavalla ja myös kaupallisia ja liiketoiminnallisia sovelluksia on paljon. Neuroverkot ovat myös saavuttaneet laajaa käyttöä yrityssovelluksissa, kuten ennuste- ja markkinointitutkimusratkaisuissa, peptosten havaitsemisessa ja riskien arvioinnissa. Neuroverkkojen etuina ovat hyvä laskentateho, viansieto ja kyky yleistää ja myös ne pystyvät sovittamaan epälineaarisia funktioita melkeinpä mihinkä vain, mutta erityisesti ne toimivat mallintamaan epälineaarisia malleja. Tähän tutkimukseen olennaisena tietona on, että neuroverkoilla pystytään arvioimaan hintatietoja ja näin on mahdollisuuksia tehdä ostopäätöksiä ja muita johtopäätöksiä datasta. (Chen, 2020).

Neuroverkkojen heikkoutena on sen vaatimat laskentaresurssit. Jopa kohtuullisen määrän epälineaarisia yhtälöparametreja sisältävä neuroverkko vaatii paljon resursseja ennen kuin edes tyydyttävän mallin voi saada aikaiseksi. Tulokset saattavat olla monimutkaisia ja vaikeasti analysoitavia ja tämän takia neuroverkko ei välttämättä ole paras mahdollinen malli rakentaa osakemarkkinoiden analysoimiseksi. (Miner et al, 2012)

### 3. 2 Multilayer Perceptron Network (MLP)

Multilayer Perceptron network, suomennoksena monikerrosperseptorni ja lyhennettynä MLP on ohjatun oppimisen menetelmä. MLP:ssä on tietty määrä nimettyjä neuroneita ja kerroksia (Aldana-Bobadila, E. et al. 2019). MLP on eniten käytetty neuroverkkojen malli. MLP on osoitettu olevan hyödyllinen työkalu ennustamiseen, approksimaatioon ja luokitteluun. MLP:n käyttämisen etuja ovat sen monet

sovellukset sellaisiin ongelmiin, joissa täysin teoreettista mallia on hankala rakentaa, varsinkin mikäli ongelman ratkaisuun käytettävä data on epälineaarista (Gardner, Dorling, 1998).

MLP:n keinotekoinen neuroverkko, jota käytettyään monien erilaisten ongelmien ratkaisemiseen, esimerkiksi kaavojen hahmottamiseen. Multilayer Perceptron network perustuu 1960-luvulla kehitettyyn Perceptronin neuroverkkoon. MPL soveltaa tätä pidemmälle, koska alkuperäisessä Perceptronissa havaittiin paljon rajoitteita. (Noriega, 2005)

MPL on hyödyllinen asioiden ja ilmiöiden tutkimiseen, koska ne pystyvät ratkaisemaan ongelmia stokastisesti ja näin mahdollistaa ratkaisujen löytämistä monimutkaisiin ongelmiin. Ongelman ei tarvitse olla lineaarisesti separoituva ongelma. Monikerroksinen neuroverkko antaa mahdollisuuden monimutkaisempien ongelmien ratkaisemiseen. Toisin kuin muut tilastolliset menetelmät, MPL ei tee ennako oletuksia datan jakautumisesta. Sillä pystytään mallintamaan epälineaarisia funktioita ja niitä pystytään yleistämään tämä neuroverkon avulla. Nämä ominaisuudet tekevät MPL:stä hyvän vaihtoehdon, kun etsitään hyvää lähestymistapaa ongelmaan, jossa data ei ole lineaarista, kuten esimerkiksi juuri osakkeiden hinnat. (Gardner et al, 1998)

MLP:n rakenne on todella kriittinen neuroverkon toimimisen kannalta. Verkossa tulee olla juuri oikea määrä kerroksia ja neuroneita, jotta se toimii oikealla tavalla. Mikäli liitäntöjä kerrosten välillä on liian vähän, ei verkko pysty ratkaisemaan haluttua ongelmaa riittämättömien painoarvojen säädettävien parametrien takia. Mikäli liitäntöjä on liikaa, voi se aiheuttaa harjoitusvaiheessa liiallista malin sovittamista ja näin vaikuttaa virhemarginaalien löytämisen ja tulosten vääristymiseen. (Ramchoun, Idrissi, Ghanou, Ettaouil, 2016)

Multilayer Perceptron networkin kerrokset koostuvat perceptorneista, joissa neuronit/solmut kohtaavat. Nämä perceptorit ovat järjestetään toisiinsa kietoutuneisiin kerroksiin. Multilayer Perceptron networkissä on vähintään kolme kerrosta. Näissä kerroksissa on neuroneita, joita ovat Input/syötoneuronit, Hidden/piilo-neuronit ja Output/tulokset-neuronit. Näitä piilotettuja kerroksia voi kuitenkin olla enemmän. Neuroneilla kerroksissa on myös painokertoimet. Painokerroin  $w$  on  $-1$  ja  $+1$

välillä ja neuroverkko yrittää löytää oikean painokertoimen, jotta se voi ratkaista annetun ongelman. Neuroverkon kouluttaminen aloitetaan laittamalla neuroverkkoon satunnaisia painokertoimia, (Noriega, 2005) Painokertoimet mittaavat korrelaatiota neuroneiden välisessä aktiivisuudessa (Pal et al, 1992).

Multilayer neural networkin neuronin neuronin perustuu McCulloch-Pitts:n malliin (Noriega, 2005). Tämä on ensimmäinen tietokoneellinen malli ihmisen aivojen neuronista ja se luotiin vuonna 1943. Tämän pohjalta muodostuu neuronin aktivointi funktio. Eli siirtyykö tieto neuronista eteenpäin vai ei. McCulloch-Pitts mallin neuronit ovat yksinkertaisia hermosoluja mallintavia keinotekoisia malleja, jotka voidaan tulkita yksinkertaisiksi loogisiksi koneiksi. Tälläkin neuronilla voi olla vain kaksi tilaa, kuten aikaisemmin jo kerrottiin, eli aktiivinen 1 ja ei aktiivinen 0. (Aldi et al 1999, 2).

$$\text{Funktio: } f(x) = \begin{cases} 1 & x > 0 \\ 0 & \text{muulloin} \end{cases} \quad (3)$$

Eli, mikäli  $f(x)=1$ , neuronin aktivoituu ja siirtää saadun tiedon eteenpäin. Mikäli  $f(x)=0$ , neuronin ei syty ja näin ei siirrä tietoa eteenpäin seuraavaan kerrokseen.

MPL etsii ratkaisuja monimutkaisiin ongelmiin sen mallin avulla. MPL toimii approksimaatio menetelmänä, jonka tuloksena on malli  $F(x)$ , missä laskettavan mallin  $f(x)$  virhe minimoidaan. Approksimaatiossa ei välttämättä löydetä täydellistä vastausta vaan koitetaan päästä mahdollisimman lähelle oikeaa. Malli  $F(X)$  saadaan

$$\text{Funktioilla: } F(x) = \sum_{i=1}^m \alpha_i \varphi(\sum_{j=1}^d w_{i,j} x_j + b_i) \quad x \in R^d \quad (4)$$

Missä  $w$  on painokerroin,  $m$  on kokonaislukua,  $\alpha_i$  ja  $b_i$  ovat todellisia vakioita ja  $\varphi$  on ei-vakio, rajoitettu ja monotoninen lisäävä jatkuva toiminta (Albana-Bobadila et al 2018).

Multilayer perceptron networkeilla on kuitenkin myös heikkouksia, miksi tämän käyttäminen saattaa olla hankalaa. Yksi syy MPL ja muiden neuroverkkojen hankalaan käyttämiseen on, että niiden toteuttaminen eli itse neuroverkon rakentaminen on vaikeaa. Myös tulosten tulkitseminen saattaa osoittautua hankalaksi. Toinen ongelma on MPL:n verkon rakenne. Rakenteen tulee olla juuri oikea, mutta suoria sääntöjä näihin ei ole, joten tekijälle saattaa olla hankalaa löytää oikea määrä kerroksia ja liitäntöjä. Vaikka teknisesti MPL:llä tulee olla vain 3 kerrosta, syöte, piilotettu ja tulos kerrokset, niin saattaa olla, että piilokerroksia on useampia ja näiden lukumäärä on ratkaistava itse. Lisäksi verkon vaatima laskentateho ja harjoitteluun tarvittava datan määrä voi aiheuttaa hankaluuksia. (Gardner et al, 1998)

### 3.3 Nonlinear Autoregressive neural network (NAR)


Monikerroksinen perseptroni neuroverkko oli yksi ensimmäisistä neuroverkoista, joka otettiin käyttöön monimutkaisten luokitusongelmien ratkaisemiseen. Kuitenkin niiden arkkitehtuurin määrittäminen havaittiin hankalaksi, niiden pitkälle kehittyneiden estimointitekniikoiden takia. Näin kehiteltiinkin neuroverkkomalleja, jotka eivät ole niin monimutkaisia ja yliparametrisoituneita ja yksi näistä on Nonlinear Autoregressiver neural network.

Nonlinear Autoregressive neural network, Epälineaarinen autoregressiivinen neuroverkko, NAR on monikerroksinen neuroverkko. Se toimii hyvin samalla tavalla kuin MPL, mutta siinä on pieniä eroavaisuuksia, jotka tekevät siitä hyvän etenkin arvojen ennustamiseen. NAR on tulevien arvojen ennustamiseen ja olettamiseen käytetty neuroverkko. Se soveltuu hyvin ennustamaan tulevia arvoja aikaisempien arvojen avulla käyttäen syöteviiveitä (feedback delays).

Neuroverkko luodaan avoimeksi silmukaksi. Neuroverkkoa koulutetaan myös avoisena silmukkana, jossa tavoitearvoja, jotka syötetään neuroverkkoon syötedatana, käytetään ongelman vastauksena ja näin saadaan varmistettua, että neuroverkon koulutus tuottaa mahdollisimman hyviä arvoja, jotka ovat lähellä todellisia arvoja. Kun kouluttaminen on saatu

päätökseen, neuroverkko muutetaan suljetuksi silmukaksi ja näin eillä ennustettuja arvoja voidaan käyttää tulosten saantiin. (Benrhmach, Namir, Namir, Bouyaghroumni, 2020)

NAR-neuroverkon rakenne on esitelty kuvassa x. Neuroverkko koostuu n-lukumäärän pisteen sisääntulokerroksesta, lähtökerroksesta ja piilokerroksesta, jotka koostuvat ennalta määrätystä määrästä neuroneja. Tämän verkon kouluttaminen perustuu back-propagation menetelmään, missä neuroverkko suorittaa taaksepäin ajon ja samalla säätää mallin painoarvoja ja näin painotukset paranevat ja mallin tarkkuus paranee. Back propagation-algoritmi tarjoaa alhaisen virhesuhteen ja hyvän tarkkuuden ennustuksille. (Namasudra et al 2021)



Kuva 4. NAR rakenne (MATLAB, 2022)

Epälineaarinen autoregressiivinen neuroverkko voidaan kirjoittaa kaavana muotoon:

$$\text{Funktioilla: } Y_t = \alpha_0 + \sum_{j=1}^k \alpha_j \varphi \left( \sum_{i=1}^{\alpha} \beta_{ij} * Y_{t-i} + \beta_{0j} \right) + \varepsilon_t \quad (5)$$

Missä  $\alpha$  on syöttöjen lukumäärä,  $k$  on piilotettujen kerrosten määrä,  $\varphi$  on aktivointifunktio,  $\beta_{ij}$  on parametri, joka vastaa painoa  $i$  ja piiloyksikön  $j$  välillä,  $\alpha_j$  on paino  $j$  ja ulostulo yksikön kanssa,  $\beta_{0j}$  ja  $\alpha_0$  ovat vakiot, jotka korreloivat piiloyksikkö  $j$  kanssa. (Benrhmach et al, 2020)

### 3.4 Neuroverkkojen käyttäminen

Kuinka sitten neuroverkkoja käytetään? Neuroverkon käyttäminen tutkimukseen lähtee siitä, että ensin valitaan tutkimusaineisto, mitä halutaan käyttää. Tämän jälkeen tutkimusaineisto tulee esikäsitellä sellaiseksi, että se sopii neuroverkkoon syötettäväksi, esimerkiksi se tulee saattaa matriisimuotoiseksi tai kuvat tulee muuttaa pikseleiksi, jotta neuroverkko pystyy lukemaan datan sisäänsä. Sieltä tulee poistaa sellainen tieto mikä ei sovi tai kuulu tutkimukseen. Myöskin tämä tutkimusaineisto jaetaan harjoitusdatasetiksi ja testidatasetiksi, josta lopulliset tulokset saadaan. Harjoitusdatasettiä hyödynnetään neuroverkon kouluttamiseen ennen oikeaa testaamista, jolloin neuroverkko saadaan optimoitua ratkaisemaan juuri se ongelma, johon vastauksia halutaan.

Mallia ajetaan ensin harjoitussetillä, niin pitkään, että tulokset alkavat olemaan kunnollisia ja luetettavia ja tämän jälkeen siirrytään itse testisetin ajamiseen. Tällä saadaan lopullisia tuloksia tutkimuksesta. Yleensä testidata on suurempi kuin harjoitusdata. Tulokset ovat sen mukaisia millaisia niistä on haluttu saada harjoitusvaiheessa. Tuloksia voi olla esimerkiksi monta kappaletta, mikäli näin halutaan, esimerkiksi monen päivän edestä tuloksia tai sitten vain yksi tietty tulos.

Eli tässä järjestyksessä myös tämän kandidaatintutkimuksen tutkimusosuus etenee:

1. Otetaan tutkimusaineisto
2. Esikäsitellään tutkimusaineisto
3. Jaetaan tutkimusaineisto harjoitusdatasettiin ja testidatasettiin.
4. Ajetaan harjoitussetti
5. Ajetaan tutkimussetti
6. Tulosten tulkitseminen

### 3.5 Osakehintojen kehityksen analysointi

Osakemarkkinoiden ja osakkeiden hintojen ennustaminen on haastava tehtävä, koska markkinoiden käyttäytyminen on niin epävakaata ja suoraa oikeaa vastausta heitteilyihin ja trendeihin ei ole. Se kuitenkin on tutkijoiden suuressa kiinnostuksessa, joten tutkittavaa aiheesta riittää. (Devadoss, Ligori, 2013) Keinotekoisia neuroverkkoja voidaan kuitenkin soveltaa osakemarkkinoiden hintojen analysoinnissa ja ennustamisessa ja näin käyttää niitä lisävälineenä riskien vähentämiseksi ja voittojen maksimoimiseksi. (Medic et al 2020). Myös Devadoksen ja Ligorin vuonna 2013 julkaistun tutkimuksen mukaan neuroverkoilla, etenkin Multilayer Perceptron Networki:lla on kyky ennustaa osakkeiden hintoja, vaikka markkinoilla vallitseekin epävakaas. Neuroverkot sopivat osakemarkkinoiden ennustamiseen, koska niillä pystytään löytää syötetietojen epälineaarinen suhde ilman ennako oletusta syötteen korrelaatiosta ja näin soveltuvat hyvin osakemarkkinoiden dynaamiseen ja epälineaariseen käyttäytymiseen (Devados et al, 2013).

Osakkeen hinta markkinoilla muodostuu ostajien ja myyjien yhteisymmärryisestä. Osakkeen hintaan vaikuttaa sen arvo ja nämä ovat keskenään vuorovaikutuksessa toisiinsa. Osakkeen hinta muuttuu todella nopealla tahdilla. Siihen vaikuttaa monia tekijöitä, joiden takia heittely hinnoissa voi olla suurtakin vain yhden päivän aikana.

Osakkeiden hintojen ennustaminen voi olla hankalaa. Ennustamisen menetelmän löytäminen pienimmällä ennustusvirheellä on yksi rahoitusmarkkina-analyttikoiden vaikeimmista ongelmista (Benrhmach et al, 2020). Hintoihin vaikuttaa todella moni asia ja näin matemaattisella mallilla ennustettu hinta ei välttämättä tule pitämään paikkaansa, vaikka se olisi hyvinkin tarkka. Kuitenkin historiallisista osakkeiden hinnoista voimme saada selville trendejä ja samankaltaisuuksia ja näin mahdollisesti päästä lähelle ennustuksissa. (Taylor et al 2011). Kuitenkaan täysin 100 % varmaa ennustusta on mahdoton tehdä, koska osamarkkinoilla voi nopeallakin aikataululla tapahtumapaljon. Esimerkiksi COVID-19 vaikutuksia osakemarkkinoiden ja hintojen laskuun oli mahdoton arvioida heti pandemian alussa, koska virusta ja sen vaikutuksia kohtaan oli paljon epätietoisuutta.

Kuitenkin yksi mahdollinen osakkeiden hintojen ennustamiseen käytettävä tapa on käyttää apuna neuroverkkoja. Neuroverkkojen kyky oppia esimerkkien kautta ja oppimisen avulla yleistää dataa on todettu toimivan asioiden ennustamisessa ja voitaisiin näin hyödyntää osakkeiden hintojen analysointiin. (Benrhmach et al, 2020).

### 3.6 Mallin sovitus

Tässä tutkimuksessa käytetään valvottua oppimista, koska oikeat vastaukset ovat jo selvillä tutkimusaineiston rajausten avulla. Neuroverkon tuloksia pystytään suoraan vertaamaan osakemarkkinoiden hintoihin, jotka saadaan tarkastamalla niiden päivien hinnat, joille pystytään ennustamaan hintoja tässä tutkimuksessa. Näin pystytään valitsemaan oikeanlaiset painoarvot neuroverkolle parhaan mahdollisen ratkaisun löytämiseksi. Kun tuloksia saadaan koulutuksen aikana neuroverkosta ulos, niin pystytään näitä vertailemaan oikeisiin osakkeiden hintoihin ja muuttamaan painoarvoja sen mukaisiksi, että mahdollisimman tarkka ja oikea vastaus saadaan. Kun neuroverkko on saatu ratkaisemaan hinnat mahdollisimman oikeiksi, pystyttäisiin sitä käyttämään mudenkin kuin valittujen osakkeiden hintojen ennustamiseen

### 3.7 Levenberg Marquardt back propagation algorithm.

Leverberg-Marquard algoritmiin kehitettiin 1960-luvun alkupuolella ratkaisemaan epälineaarisia pienimmän neliösumman ongelmia. Pienimmän nelisumman ongelman liittyvät sellaisiin matemaattisiin ongelmiin, joissa mallia, tässä tapauksessa epälineaarista autoregressiivistä neuroverkkoa koitetaan saada sopimaan mahdollisimman hyvin annetuille datapisteille ja näin minimoimaan mallifunktion välisten virheiden summaa. (Henri P.Gavin 2020). Tämä on yksi tehokkaimmista algoritmeista keinokehoisten neuroverkkojen kouluttamiseen. Se soveltuu todella hyvin monikerroksisten perceptroni neuroverkkojen arkkitehtuuriin.

Levenberg Marquardt back propagation algoritmi on Deep Learning toolboxin nopein koulutus algoritmi. Sitä suositellaankin ensimmäiseksi valvotun oppimisen algoritmiksi. Se kuitenkin vaatii enemmän muistia kuin moni muu algoritmi ja voi näin haitata neuroverkon kouluttamista. (MathWorks, 2022) Kuitenkaan tämän tutkimuksen toteuttamiseen tämä ei ollut ongelma, vaan tätä algoritmia käytettiin neuroverkon kouluttamiseksi.

### 3.8 Laadulliset suorituskykymittarit

Mean Squared Error (MSE) eli keskimääräinen neliövirhe pyritään neuroverkon kouluttamisella Levenberg Marquardt back propagation algoritmilla saamaan mahdollisimman pieneksi. MSE on arvioitujen arvojen ja todellisen arvon keskimääräinen neliöero. Se lasketaan varianssina ennustettujen ja oikeiden arvojen väliltä. Mitä pienempi MSE on, sitä parempi sovitus on ja neuroverkko on koulutettu mahdollisimman hyvin. MSE arvo 0 kertoo, että eroa neuroverkon arvioitujen ja todellisten arvojen välillä ei ole lainkaan ja näin ei virhettäkään siis ole. (Namasudra et al, 2021)

R-arvo kertoo kahden arvon välisen korrelaation. Tässä tapauksessa se kertoo korrelaation ennustettujen ja oikeiden arvojen välillä. Se saa arvon 0 ja 1 väliltä. 1 kertoo, että arvojen välillä on korrelaatiota ja 0 tarkoittaa, että korrelaatio on satunnaista. Tässä tutkimuksessa R-arvo lasketaan datapisteiden ja tulosten väliltä. Tässä tutkimuksessa R-arvo halutaan mahdollisimman lähelle arvoa 1.(Namasudra et al 2021).

## 4. Tutkimusmenetelmät ja -aineisto

Tämä kandidaatintutkielma on kvantitatiivinen tutkimus. Tutkimusaineistona käytetään tilastollista aineistoa.

Itse tutkimuksen tekemiseen Multilayer Perceptron Networkilla käytetään tutkimusaineistona suomalaisten teollisuusalan yritysten osakkeiden historiallista osakehintadataa.

Itse tämän kandidaatintyön tutkimukseen käytetyllä aineistolla toteutetaan tutkimus ja tutkimuskysymyksiin vastaamiseen. Tutkimuksessa on valittu tutkittavaksi osakkeiden hintojen arvoja pitkältä aikaväliltä, tässä tapauksessa 2016–2021 vuosien kuukausihinta dataa. Aineisto rajautuu molempiin yrityksiin päiviltä 29.11.2016–29.11.2021. Ja osakkeenhinta on jokaisen päivän loppukurssi. Aineisto on siis molempien osakkeiden viimeisten 5 vuoden ajalta. Aineisto on kerätty Nordnet Bank AB, osake- ja rahastonvälittäjän nettisivujen kautta. Ennusteen pohjana käytetään vain näiden osakkeiden kurssseja. Hinnat ovat kolmen desimaalin tarkkuudella.

Tutkimuksessa keskitytään 4 suomalaiseen teollisuusalan yritykseen ja niiden osakkeisiin. Näin tutkimusaineistosta ei tule liian laaja ja neuroverkon toimimiseen pystytään keskittymään tässä työssä paremmin. Valitut yritykset ovat Kone Oyj, Ponsse Oyj, Valmet Corporation ja Wärtsilä Corporation. Näiden vastaavat osakkeet ovat KNEBV, PON1V, VALMT ja WRT1V. Nämä yritykset ovat suuria suomalaisia teollisuusalan yrityksiä, jotka on noteerattu Nasdaq Helsingissä eli Helsingin Pörsissä. Liitteessä 1 näkyy valittujen osakkeiden kurssin kehitys valitulla välillä.

Tutkimusaineiston muokkaamiseen ja tarkasteluun on käytetty Excel-ohjelmistoa. Aineisto on Excelissä ja siinä on 1255 riviä ja 4 saraketta. Aineistoa muokattiin Excelissä jonkin verran, koska netistä löytyneet tiedot eivät siirtyneet oikean muotoisina ohjelmaan. Kuitenkaan minkään päivän lukuja ei puuttunut ja arvoja ei muutettu.

Neuroverkoihin voi käyttää minkäläistä dataa tahansa ja näin ei ole väliä, että onko käytetty aineisto jatkuvaa, diskreettiä tai ajasta erillistä. Kuitenkin ei-taulukkomuotoinen data tulee muuttaa matriisi muotoon ja sen jälkeen data tulee annostella neuroverkkoon sopivan kokoisina otoksina. Aineistoa ei siis tarvinnut muokata juuri vaan se sopii tutkimukseen sellaisenaan, koska aineisto on aikasarjadata.

Tutkimus toteutetaan käyttäen MATLAB-ohjelmistoa ja sen lisäosia. MATLAB on numeeriseen laskentaan tarkoitettu tietokoneohjelmisto. Neuroverkon rakentamiseen on käytetty MATLAB Deep Learning-lisäosan Neural Net sovellusta. Sovelluksessa pystyy rakentamaan erilaisia neuroverkkoja riippuen sen

käyttötarkoituksesta. Näistä parhaiten tämän tutkimuksen toteuttamiseen sopii Neural Net Time Series Forecasting lisäosa. Tällä lisäosalla pystytään ratkaisemaan epälineaarisia aikasarja ongelmia dynaamisilla neuroverkoilla.

## 4. Tutkimuksen toteutus

Tutkimukseen käytetty MATLAB-lisäosa Deep Learning sisältää 4 erilaista neuroverkko-sovellusta, joilla pystytään helposti ja tehokkaasti rakentamaan monenlaisia neuroverkkoja ilman, että itse monien kymmenien rivien pituista koodia tulee kirjoittaa alusta asti itse.

Deep Learning Toolbox™:ssa pystyy suunnitella ja toteuttaa syväoppimisen neuroverkkojen ja niiden algoritmeja esikoulutetuilla malleilla ja sovelluksilla. Sovelluksia löytyy niin kuva-, aikasarja- ja tekstidatalle. Ja näistä tähän tutkimukseen sopii aikasarjadataalle sopiva malli. (Namasudra et al. 2021)

Nämä sovellukset ovat: Neural Net Clustering, Neural Net Fitting, Neural Net Pattern Recognition ja Neural Net Time Series. Näillä jokaisella pystytään ratkomaan erilaisia ongelmia.

Neural Net-sovellukset luovat nämä koodit ja näitä pystyy muuttamaan sovelluksessa halumallaan tavalla. Muokkauksia pystyy tekemään syötettävän datan ja haluttujen tulosten muotoon, neuronien ja viivästyksien lukumäärään ja pystytään päättämään, kuinka monta kertaa rakennettua neuroverkkoa halutaan kouluttaa. Sovelluksessa pystytään myös päättämään harjoitus, validointi ja testausdatan prosentuaalinen määrä sisään syötetystä datasta. Myöskin koulutus algoritmia pystytään muuttamaan.

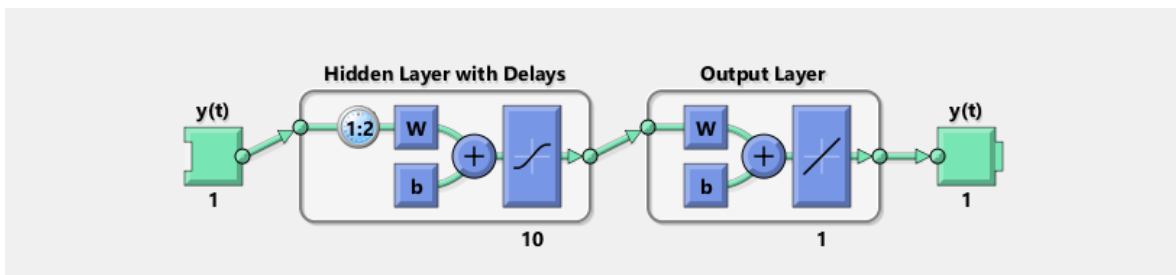
Valittu neuroverkko osakkeiden tulevien hintojen ennustamiseksi on Nonlinear Autoregressive neural network, Epälineaarinen autoregressiivinen neuroverkko, NAR. Tässä tutkimuksessa jokaiselle neljälle osakkeelle tehtiin tutkimus erikseen. Tutkimusaineisto jaettiin neljään osaan, jolloin jokaisen osakkeen hinnat syötettiin omiin neuroverkkoihinsa erikseen. Datapisteitä oli yhteensä jokaisessa 1254 kpl ja nämä syötettiin epälineaariseen autoregressiiviseen neuroverkkoon matriisi riveinä. Näin saadaan jokaiselle osakkeelle ennustettua tulokset niin, että ne eivät riipu toisistaan ja neuroverkko ei koita yhdistää osakkeiden hintoja

yhdeksi ennustettavaksi dataksi. Tuloksia saatiin siis 4 kpl, eli jokaiselle tutkimukseen valitulle osakkeelle saatiin ennustettua tutkimusaineiston viimeisen arvon seuraava arvo.

Neuroverkon sisällä jokainen syötetty data jaettiin 3 osaan. 70 % datasta on neuroverkon koulutukseen käytettyä dataa. Tämä koulutus-data tuodaan neuroverkkoon koulutuksen aikana ja neuroverkko soveltuu tästä syntyvien virheiden avulla. Loput 30 % datasta jaetaan puoliksi validointiin ja testaamiseen. 15 % validointi-dataa käytetään mittaamaan neuroverkon yleistämistä ja näin pysäyttämään koulutuksen kun yleistäminen ei enää parannu. Loput 15 % käytetään itse neuroverkon testaamiseen ja tulosten saamiseen. Tällä datalla ei ole enää vaikutusta koulutukseen, joten se antaa itsenäisen mittauksen neuroverkon toiminnasta. (MATLAB, 2022)

Koulutusta jatkettiin niin kauan jokaiselle neuroverkolle, että MSE saatiin mahdollisimman pieneksi. MSE ja R-arvo lasketaan training, validation ja testing datoilta jokaiselle erikseen. Kun MSE saatiin mahdollisimman pieneksi, päätettiin neuroverkon koulutus ja tulokset tallennettiin.

Epälineaariseen autoregressiiviseen neuroverkkoon valittiin 10 piiloneuronia ja viiveeksi valittiin 2 ja kuvassa 5 näkyy tutkimukseen käytetyn neuroverkon rakenne.



*Kuva 5 Tutkimuksen NAR-verkon rakenne 10 piiloneuronilla ja 2 viiveellä (MATLAB, 2022)*

MATLAB:n Time Series Neural Net sovelluksessa luodulle Non linear neural networkille valittiin koulutusmenetelmäksi Levenberg Marquardt Back Propagation algoritmi. Tällä pyrittiin minimoimaan Mean Squared Error:n ja saamaan R-arvon mahdollisimman lähelle arvoa 1(MathWorks, 2021).

## 5. Tutkimuksen tulokset

Tämän kandidaatintutkielman tutkimuksen tuloksien käsittely aloitetaan tarkistelemalla tutkimuksen aikana saatuja MSE-arvoja ja R-arvoja. Tämän jälkeen keskitytään lopullisiin tuloksiin, eli valittujen osakkeiden ennustettuihin hintoihin.

MSE-arvot ja R-arvot on listattu taulukossa 1 jokaiselle osakkeelle ja niiden jaotellulle datalle. R-arvot jokaisella osakkeella ovat hyvin lähellä arvoa 1, eli data ja ennuste ovat hyvin korreloituneita keskenään. Kahden muuttujan välinen korrelaatio on vahvaa, mikäli r-arvo on yli 0.7 (Westga, 2022) Korkea korrelaatio neuroverkko-tutkimuksessa on hyvä ja kertoo, että malli sopii tähän tutkimukseen (Namasudra et al, 2021).

MSE-arvot vaihtelevat enemmän keskenään. Wärtsilä saa jokaiselle data jaolle parhaimmat MSE-arvot ja näin sen sovitus on kaikista parhain, jolloin neuroverkon ennusteet ovat luotettavimpia. Huonoimmat MSE-arvot saa Kone, joten sen ennusteiden voidaan olettaa olevan huonompia kuin muiden ja ei niin luotettavia. Liitteissä 2 on esitetty graafisesti ennusteiden virheet histogrammeina.

Arvo	Kone	Ponsse	Valmet	Wärtsilä
MSE(Training)	0.496570	0.285896	0.180269	0.102227
MSE(Validation)	0.553963	0.285703	0.164023	0.0871949
MSE(Testing)	0.449567	0.261762	0.150901	0.106910
R-value(Training)	0.997810	0.996110	0.997635	0.997266
R-value(Validation)	0.997675	0.995983	0.997673	0.97441
R-value(Testing)	0.997880	0.996765	0.998201	0.997124

Taulukko 1 Ennusteiden MSE- ja R-arvot jokaisella datan jaolla

Liite 3 havainnollistaa osakkeiden ennusteiden aikasarjan vastekaaviota palautuneille tuloksille jokaiselle osakkeelle. Tässä x-akseli ja y-akseli edustavat vasteen lähtöä ja kohdelähtöä ja liitteet 4 esittävät jokaisen osakkeen korrelaatiokäyriä, joissa on vaihteleva viive. Tässä x-akseli edustaa viivearvoja ja y-akseli edustaa vahvistettujen tapausten korrelaatioarvoja. Melkein kaikki arvot sisältyvät luottamusrajojen sisälle. Yleensä

virheautokorrelaatiokaaviota käytetään osoittamaan, kuinka paljon mallin ennustettu arvo liittyy sen todelliseen arvoon.

Ennustettuja hintoja osakkeille KNEBV, PON1V, VALMT ja WRT1V, saatiin jokaiselle 1 kpl. Taulukossa 2 on esitetty tutkimusaineiston 10 viimeisintä arvoa jokaiselle osakkeelle, jotka edustavat tutkimukseen käytetyn aikavälin kymmentä viimeistä päivää. Nämä ovat havainnollistamassa tuloksia, mutta itse tutkimukseen käytettiin koko tutkimusaineisto mahdollisimman tarkkojen tulosten saamiseksi. Taulukossa 2 on myös listattu jokaisen osakkeen neuroverkolla saatu ennuste kymmenelle viimeiselle päivälle ja yksi ennuste, joka edustaa tutkimusaineiston aikavälin seuraavaa päivää.

Ennustetut arvot ovat pyöristettynä KNEVBV 59,73 €, PON1V 44.07 €, VALMT 36,77 € ja WRT1V 12.22 €.

Kone	Kone(ennuste)	Ponsse	Ponsse(ennuste)	Valmet	Valmet(ennuste)	Wärtsilä	Wärtsilä(ennuste)
60,32	59,71639331	44,25	44,32965853	36,58	36,44688327	13,32	12,2215015
62,16	61,1520664	45,3	43,91835343	36,66	36,5584825	13,70	12,21704883
62,86	60,32792235	44,75	44,16760637	36,71	36,62615865	13,41	13,18624921
61,82	61,98897312	44,7	45,287199	37,18	36,66912622	13,16	13,60609961
62,58	62,85396571	44,2	44,61626592	36,91	36,93025665	12,2	13,42687144
61,58	61,94724832	43,95	44,64136983	37,35	36,84781562	12,2	13,17357097
60,3	62,55097638	43,6	43,98725007	36,4	36,7690182	12,2	12,27296285
59,3	61,64632873	43,65	43,76658781	36,31	37,03186065	12,195	12,22177229
59,84	60,33207824	44,1	43,37951541	37,05	36,51597956	12,20	12,22177229
58,66	59,44877883	43,1	43,53091474	35,93	36,37615561	12,80	12,21704883
	59,72894039		44,07093166		36,7748913		12,2215015

Taulukko 2 Osakkeiden hinnat ja neuroverkon luomat ennusteet viimeiselle tutkimusaineiston 10+1 päivälle

Nonlinear autoregressiivisen neuroverkon ennustamat arvot ja tutkimusaineiston 10 viimeistä arvoa on esitetty graafisesti liitteessä 5. Näitä tarkastellessa voidaan huomata, että oranssit ennusteet eivät ole täysin samat kuin siniset oikeat arvot. Kuitenkin arvot heittävät vain hieman keskenään, joten voidaan ainakin Koneen ja Ponsen kaavioiden perusteella olettaa ennustuksien olevan jotenkin paikkaansa pitäviä. Valmetin ja Wärtsilän tapauksissa kaavioiden viivat ovat huomattavasti erilaiset, mikä saa epäilemään tutkimuksen tulosten luotettavuutta, vaikkakin molempien MSE-arvot olivat alhaisempia kuin Koneen ja Ponsen ja R-arvotkin olivat hyvin lähellä arvoa 1.

## 7. Johtopäätökset

Tämän tutkimuksen perusteella niin Multilayer Perceptron network kuin Nonlinear Autoregressive Neural network toimivat osakkeiden hintojen analysoimiseen ja uusien hintojen ennustamiseen. Hintoja varmasti pystyy ennustamaan tarkastikin neuroverkkojen avulla, mutta tutkimuksessa tuotetut mallit eivät ehkä ole tehokkaimpia mahdollisia. Kuittenkin kirjallisuuskatsauksen perusteella on mahdollista ennustaa osakkeiden tulevia hintoja tarkasti neuroverkkojen avulla ja Multilayer Perceptron network ja Nonlinear Autoregressive neural network ovat hyviä esimerkkejä siihen.

Osakemarkkinoiden ennustaminen on muutenkin hankalaa ja täysin tarkkojen ennusteiden saaminen on lähes mahdotonta. Kuitenkin historiallisista osakkeiden hinnoista voimme saada selville trendejä ja samankaltaisuuksia ja sovittaa neuroverkon näihin, jotta pääsimme mahdollisimman lähelle ennustuksilla oikeita arvoja. (Taylor et al 2011).

Käyttäjän kannalta neuroverkot ovat hieman haastavia osakkeiden hintojen ja näin markkinoiden ennustamiseen. Ne vaativat paljon tietotaitoa, matemaattista osaamista, datan käsittelyä ja tietoteknistä osaamista. Tuloksia saatiin myös ennustettua vain päivän päähän tutkimusaineistosta ja saadut tulokset olivat hieman epäluotettavia. Näin ollen osakkeiden hintojen ennustaminen neuroverkolle ei vaikuttaisi olevan tehokkain tapa tämän tutkimuksen pohjalta. Tehokkaampiakin tapoja yhden arvon ennustamiselle on. Myös helpommalla tavalla voidaan saada tarkempia ja luetettavampia tuloksia kuin neuroverkolla. Tällainen tapa on esimerkiksi hyödyntää ARIMA-mallia eli Autoregressive integrated moving average:a.

Kuitenkin mikäli perehtyy neuroverkkoihin syvällisesti ja ymmärtää niiden toimintaa enemmän ja käytössä on ohjelmistoja ja koneita, joilla laskenta onnistuu, niin neuroverkoilla voidaan saada hyviäkin ennustuksia aikaiseksi.

Jatkotutkimuksena ehdottaisinkin käyttämään eri koulutus menetelmiä, kuten esimerkiksi Scaled Conjugate Gradient- ja Bayesian Regularization- algoritmeja ja vertailla näiden toimivuutta ja tuottavatko ne parempia tai tarkempia tuloksia. Näin voitaisiin nähdä, että mikä koulutus menetelmistä sopii tällaisen tutkimuksen data käsittelyyn tarkastelemalla MSE-arvoa ja R-arvoa. Myös jatkotutkimuksina voitaisiin tutkia muiden mallien hyödyntämistä

osakkeiden ennustamiseen, esimerkiksi tutkia toimiiko ARIMA-malli tällaiseen ja kuinka tehokkaasti se toimii.

## 8. Lähteet

Adedeji, P. A., Akinlabi, S., Ajayi, O., & Madushele, N. (2019). *Non-linear autoregressive neural network (NARNET) with SSA filtering for a university energy consumption forecast. Procedia Manufacturing, 33, 176–183*

Abdi, H., Valentin, D. and Edelman, B. (1999) The Perceptron. In: *Neural Networks, Quantitative Applications in the Social Sciences*. Thousand Oaks, CA: SAGE Publications, Inc. pp. 4-21. [Online], Saatavilla:

<http://www.doi.org.ezproxy.cc.lut.fi/10.4135/9781412985277> [Viitattu 24.11, 2021]

Aldana-Bobadila, E., Kuri, K., Lopez-Arevalo, I., Rios-Alvaros, A.B., (2018), An unsupervised learning approach for multilayer perceptron networks: Learning driven by validity indices. *Soft computing (Berlin, Germany)*. [Online] 23 (21), 11001–11013., [Viitattu 21.22.2021]

Brownlee, J. (2016). Crash Course On Multi-Layer Perceptron Neural Networks. Blogi. Päivitetty 19.8.2019. Saatavissa: <https://machinelearningmastery.com/neural-networks-crash-course/> [viitattu: 24.11.2021].

Benrhmach, G., Namir, K., Namir, A., Bouyaghroumni, J., (2020). “Nonlinear Autoregressive Neural Network and Extended Kalman Filters for Prediction of Financial Time Series”, *Journal of Applied Mathematics*, vol 2020, Article ID 5057801, online, Saatavilla: <https://doi.org/10.1155/2020/5057801>

Denoeux, T. (2019) Logistic regression, neural networks and Dempster–Shafer theory: A new perspective. *Knowledge-based systems*. [Online] 17654–67. Saatavilla:

<https://doi.org/10.1016/j.knosys.2019.03.030>,

Devadoss, A. V., & Ligor, T. A. A. (2013). Forecasting of stock prices using multi layer perceptron. *International journal of computing algorithm*, 2(1), 440-449

Chollet, F. (2018). *Deep Learning with Python*. Greenwich, CT, USA: Manning Publications Co.

Gardner, M.W., Dorling, S.R., (1998), Artificial neural networks (the multilayer perceptron)—a review of applications in the atmospheric sciences, *Atmospheric Environment*, Volume 32, Issues 14–15, Pages 2627–2636, ISSN 1352-2310, [https://doi.org/10.1016/S1352-2310\(97\)00447-0](https://doi.org/10.1016/S1352-2310(97)00447-0).

Gavin, H.P., (2020), The Levenberg-Marquardt algorithm for nonlinear least squares curve-fitting problems © Department of Civil and Environmental Engineering Duke University

Haykin, S. (1999). *Neural networks: A comprehensive foundation*. 2nd ed. Upper Saddle River (NJ): Prentice Hall.

Kallio, Tomi J, (2006), Laadullinen review-tutkimus metodina ja yhteiskunnallinen lähestymistapa. *Hallinnon tutkimus* 25: 2, 18–28. Online, Saatavilla: <https://journal.fi/hallinnon-tutkimus/article/view/99500>

Kananen, H., Puolitaival, H., Puntti, S. & Metsola, I. (2019). *Tekoäly: Bisneksen uudet työkalut*. Helsinki: Alma Talent.

Kostenko, V.A., Seleznev, L.E. (2021). Random Search Algorithm with Self-Learning for Neural Network Training. *Opt. Mem. Neural Networks* 30, 180–186 [Online], Saatavilla: <https://doi-org.ezproxy.cc.lut.fi/10.3103/S1060992X2102003X>

Kryzhanovskii, B.V., Kryzhanovskii, M.V. & Magomedov, B.M. (2007). New accelerated algorithm based on domain neural network for solving optimization tasks. *Opt. Mem. Neural Networks* 16, 31–39[Online], Saatavilla: <https://doi-org.ezproxy.cc.lut.fi/10.3103/S1060992X07010043>

Li, Y., Ni, P., Chang, V. (2020) Application of deep reinforcement learning in stock trading strategies and stock forecasting. *Computing*. [Online] 102 (6), 1305–1322. Saatavilla: <https://link.springer.com/article/10.1007/s00607-019-00773-w>

MathWorks, *Neural Network Toolbox 7.0*, MathWorks Announces Release 2010a of the MATLAB and Simulink Product Families, 2010, MathWorks, Inc. [www.mathworks.com/trademarks](http://www.mathworks.com/trademarks).

Medić, T., Bach, M. P., Jaković, B. (2020). *Stock Market Analysis And Price Prediction Using Deep Learning And Artificial Neural Networks*. Zagreb: University of Zagreb,

Faculty of Economics and Business. [Online], Saatavilla: <https://ezproxy.cc.lut.fi/conference-papers-proceedings/stock-market-analysis-price-prediction-using-deep/docview/2458971071/se-2?accountid=27292>

Mindrila, D., Balentyne, P., (2013), Scatterplots and Correlation. Chapter 4 of The Basic Practice of Statistics (6th ed.)

Online, saatavilla: [https://www.westga.edu/academics/research/vrc/assets/docs/scatterplots\\_and\\_correlation\\_notes.pdf](https://www.westga.edu/academics/research/vrc/assets/docs/scatterplots_and_correlation_notes.pdf)

Miner, G., Delen, D., Elder, J., Fast, A., Hill, T., Nisbet, R.A., (2012). Practical Text Mining and Statistical Analysis for Non-structured Text Data Applications

Namasudra, S., Dhamodharavadhani, S., Rathipriya, R. (2021) Nonlinear Neural Network Based Forecasting Model for Predicting COVID-19 Cases. [Online], Saatavilla: <https://doi.org/10.1007/s11063-021-10495-w>

Noriega. L. (2005) Multilayer Perceptron Tutorial School of Computing Staffordshire University Beaconside Staffordshire ST18 0DG email: l.a.noriega@staffs.ac.uk November 17, 2005 <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.608.2530&rep=rep1&type=pdf>

Oreilly, (2022). Prediction in Text Mining: The Data Mining Algorithms of Predictive Analytics, ,Pages 893-919, Saatavilla: <https://doi.org/10.1016/B978-0-12-386979-1.00036-0>.

Osipov, V., Osipova, M., (2018). Space–time signal binding in recurrent neural networks with controlled elements, Neurocomputing,, Volume 308, Pages 194-204, Saatavilla: <https://www.sciencedirect.com/science/article/pii/S092523121830540X>

Pal, S. K., & Mitra, S. (1992). Multilayer perceptron, fuzzy sets, classification.

Parisi, G.I., Kemker, R., Jose, L., Kanan, C., Wermter, S.,(2019). Continual lifelong learning with neural networks: A review,

Petticrew, M., (2001). Systematic Reviews from Astronomy to Zoology: Myths and Misconceptions. British Medical Journal 322: 7278, 98–101.


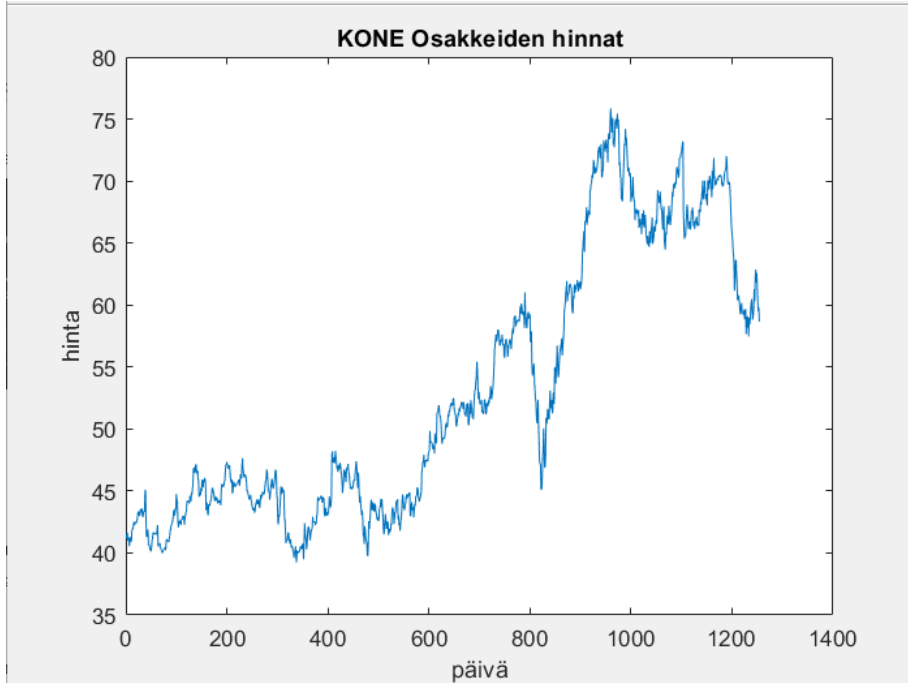
Ramchoun, H., Idrissi, M. A. J., Ghanou, Y., & Ettaouil, M. (2016). Multilayer Perceptron: Architecture Optimization and Training. *Int. J. Interact. Multim. Artif. Intell.*, 4(1), 26-30.


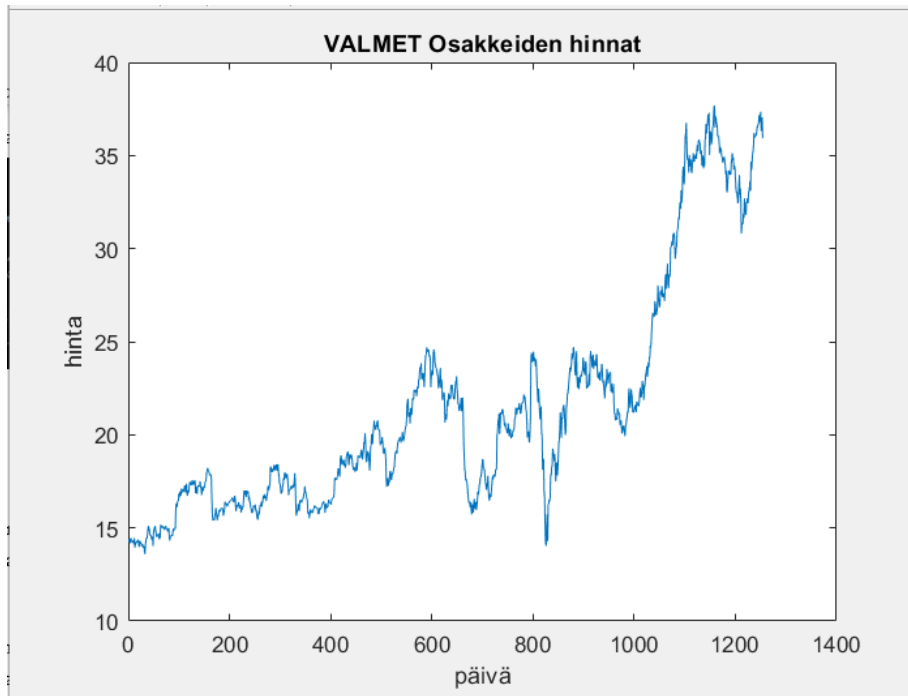
Shiffman, D. (2012). The Nature of Code. PDF-dokumentti. Saatavissa: <https://natureofcode.com/> [viitattu 24.11.2021].

Taylor, S. J. & Taylor, S. J. (2011) Asset price dynamics, volatility, and prediction. STU - Student edition. Princeton: Princeton University Press.



Yadav, Neha. (2015). An Introduction to Neural Network Methods for Differential Equations. [Online]. Dordrecht: Springer Netherlands., Saatavilla: <https://link-springer-com.ezproxy.cc.lut.fi/book/10.1007/978-94-017-9816-7>



Liite 1: KNEBV, PON1V, VALMT ja WRT1V-osakkeiden kurssit









Liite 2: KNEBV, PON1V, VALMT ja WRT1V-osakkeiden ennusteiden virhe histogrammit.









## Liite 3 KNEBV, PON1V, VALMT ja WRT1V-osakkeiden ennusteiden vastekaaviot





Liite 4: KNEBV, PON1V, VALMT ja WRT1V-osakkeiden ennusteiden korrelaatiot, R-arvo





Liite 5: KNEBV, PON1V, VALMT, WRT1V-osakkeiden hinnat aineiston 10 viimeisenä päivänä ja ennuste 10 viimeiselle päivälle+ 1 lisäpäivälle

