

Jaakko Vuorinen

**SYVÄOPPIMISMENETELMIEN KÄYTTÖ  
OSAKEKURSSIEN ENNUSTAMISESSA**



JYVÄSKYLÄN YLIOPISTO  
INFORMAATIOTEKNOLOGIAN TIEDEKUNTA  
2023

# TIIVISTELMÄ

Vuorinen, Jaakko

Syväoppimismenetelmien käyttö osakekurssien ennustamisessa

Jyväskylä: Jyväskylän yliopisto, 2023, 24 s.

Tietojärjestelmätiede, Kandidaatintutkielma

Ohjaaja: Mehtälä, Saana

Tämän kandidaatintutkielman aiheena on syväoppimismenetelmien käytettävyys osakekurssien ennustamisessa. Tutkielma toteutetaan kirjallisuuskatsauksena. Aineistossa on painotettu tieteellisiä julkaisuja, joissa syväoppimismenetelmien käyttöä osakekurssien ennustamisessa on tutkittu empiirisesti. Tutkielmassa käsitellään lisäksi lyhyesti osakekurssien toimintaa sekä tehokkaiden markkinoiden teoriaa. Lisäksi tutkielmassa on huomioitu syväoppimismenetelmiä yksinkertaisemmat aikasarja-analyysin menetelmät. Syväoppimisen ja tekoälyn menetelmät ovat kehittyneet viime vuosina nopeasti. Tavot ennustaa osakemarkkinoiden liikkeitä ovat aina kiinnostaneet niin piensijoittajia kuin institutionaalisia sijoittajia, sillä ennusteiden onnistuessa sijoittajat voivat saavuttaa taloudellista hyötyä. Tutkielman tavoitteena on selvittää, voidaanko moderneja syväoppimismenetelmiä hyödyntämällä saavuttaa yleisindeksejä parempia tuottoja, ja millä syväoppimismenetelmällä saavutetaan parhaita tuloksia. Tutkielman tuloksista voidaan todeta, että syväoppimismenetelmiä käyttämällä on useissa tilanteissa mahdollista saavuttaa parempia tuottoja kuin yleisindekseihin sijoittamalla. Aineistojen välillä on ristiriitoja siitä, mikä menetelmästä suoriutuu parhaiten. Voidaan kuitenkin todeta, että enemmän tietoa huomioonottavat mallit suoriutuvat yksinkertaisempia malleja paremmin. Sijoitusstrategiasta riippumatta sijoittamisen riskejä on hyvin hankala määrittää, sillä osakemarkkinoiden luonteeseen kuuluu niiden ennalta-arvaamattomuus. Tulosten perusteella ei siis voida todeta, että syväoppimismenetelmiä käyttämällä pystyisi joka tilanteessa saavuttamaan parempia tuottoja kuin yleisindekseihin sijoittamalla.

Asiasanat: syväoppiminen, osakemarkkina, aikasarja-analyysi, ARIMA, LSTM, BERT

## ABSTRACT

Vuorinen, Jaakko

The use of deep learning methods in predicting stock prices

Jyväskylä: University of Jyväskylä, 2023, 24 pp.

Information Systems, Bachelor's Thesis

Supervisor: Mehtälä, Saana

This bachelor's thesis examines the use of deep learning methods in predicting stock prices. The thesis is carried out as a literature review. The literature is focused on scientific publications that have empirically investigated the use of deep learning methods in stock price forecasting. The thesis also briefly discusses the functioning of stock markets and the theory of efficient markets. In addition, time series analysis methods, which are simpler than deep learning methods, are discussed. Deep learning and artificial intelligence methods have developed rapidly in recent years. Ways of predicting the stock market have always been a topic of interest to both retail and institutional investors, since successful predictions can help investors to achieve financial gains. The aim of this thesis is to investigate whether modern deep learning methods can be used to achieve better results than general stock market indices, and which deep learning methods achieve the best results. The results of this thesis show that in many situations it is possible to achieve better results using deep learning methods than by investing in general stock market indices. There is disagreement between the studies as to which method performs best. However, it can be concluded that models that incorporate more information perform better than simpler models. Whether the investment strategy, the risks of investing are very difficult to quantify, and the very nature of stock market is unpredictability, so the results do not suggest that deep learning methods can in all circumstances deliver better returns than general index investing.

Keywords: deep learning, stock market, time series analysis, ARIMA, LSTM, BERT

## KUVIOT

KUVIO 1 Yksinkertainen neuroverkko

# SISÄLLYS

TIIVISTELMÄ

ABSTRACT

KUVIOT JA TAULUKOT

1	JOHDANTO.....	6
2	OSAKEMARKKINAT .....	8
	2.1 Osakemarkkinoiden toiminta .....	8
	2.2 Osakkeiden arvon määräytyminen.....	9
	2.3 Tehokkaiden markkinoiden teoria.....	11
3	OSAKEKURSSIEN ENNUSTAMISEEN KÄYTETYT MENETELMÄT .....	12
	3.1 Aikasarja-analyysi .....	12
	3.2 ARIMA ja Box-Jenkins metodi.....	13
	3.3 Syväoppiminen .....	13
	3.3.1 Rekursiiviset neuroverkot ja LSTM.....	15
	3.3.2 Luonnollisen kielen prosessointi ja BERT.....	15
4	AIKASARJA-ANALYYSIN JA SYVÄOPPIMISMALLIEN KÄYTTÖ OSAKEKURSSIEN ENNUSTAMISESSA.....	17
	4.1 ARIMA .....	17
	4.2 LSTM.....	18
	4.3 BERT .....	19
5	YHTEENVETO JA POHDINTA .....	20
	LÄHTEET.....	22

# 1 JOHDANTO

Osakesijoittaminen on vuosisatojen ajan ollut niin yksityissijoittajien kuin institutionaalisten sijoittajien keskuudessa suosittu tapa hakea tuottoa pääomalle. Historiallisesti osakesijoittaminen on tarjonnut sijoittajille parempia tuottoja kuin esimerkiksi kiinteistöihin tai velkakirjoihin sijoittaminen (Szumilo ym., 2018). Osakesijoittaminen sisältää kuitenkin riskejä. Turvallisimmaksi tavaksi sijoittaa osakkeisiin on todettu osakeomistusten kansainvälinen hajauttaminen sekä eri toimialoille hajauttaminen (Onali & Mascia, 2022). Toisaalta niin sijoittajien, kuin alan tutkijoiden keskuudessa on aina herättänyt mielenkiintoa tavat pyrkiä ennustamaan osakemarkkinoiden liikkeitä ja saavuttaa ennusteiden avulla suurempia tuottoja kuin hajautettuihin osakemarkkinaindekseihin sijoittamalla.

Williamsin (1938) kirjan mukaan sijoittajien on tiedettävä, että osakkeen todellinen arvo sekä markkina-arvo ovat kaksi toisistaan erillään olevaa asiaa (Williams, 1938). Useilla tutkijoilla ja sijoittajilla on kuitenkin olemassa käsitys, ettei osakkeiden hintakehitystä pystytä ennustamaan. Eugene Faman (1970) esittelemän tehokkaiden markkinoiden teorian mukaisesti kaikki saatavilla tieto on jo sisällytetty osakkeiden hintoihin, joka tekee niiden ennustamisesta mahdotonta. Tehokkaiden markkinoiden teoria on ohjannut alan tutkimusta sekä ihmisten mielipiteitä osakekursien ennustettavuudesta. Lisäksi aktiivisen kaupankäynnin hyödyt ovat tutkimuksissa osoittautuneet heikoiksi, sillä enemmän kauppvoja tehneet sijoittajat suoriutuvat markkinalla keskimäärin huonommin kuin osakemarkkinaindeksit (Barber & Odean, 2000).

Syväoppiminen ja tekoäly ovat viime vuosina saavuttaneet merkittäviä kehityskaskelia. Syväoppimista on pystytty hyödyntämään onnistuneesti useisiin käyttötarkoituksiin, kuten puheentunnistukseen, tekstin analysointiin ja tuottamiseen, lääketieteellisiin ennusteisiin ja erilaisiin teollisuuden prosesseihin. Tietokoneiden kasvaneen laskentatehon ja syväoppimisen kehityksen vuoksi myös syväoppimisen hyödyntäminen rahoitusallalla on noussut kiinnostavaksi tutkimuskohteeksi. Syväoppimismalleja voidaan kouluttaa valtavalla määrällä osakkeiden historiallisia hintatietoja ja muita teknisiä tunnuslukuja. Lisäksi kehittyneillä luonnollisen tekstin prosessoinnin menetelmillä on mahdollista hyödyntää ennusteissa muita oleellisia osakkeen hintaan vaikuttavia tekijöitä, kuten uutisten ja sosiaalisen median vaikutusta.

Tässä kirjallisuuskatsauksessa pyritään vastaamaan tutkimuskysymykseen: "Miten aikasarja-analyysin ja syväoppimisen mallit soveltuvat osakekursien ennustamiseen?". Tutkielmaan haetaan aineistoa Jykdok- sekä Google Scholar -tietokannoista. Hakusanoina käytetään seuraavia termejä: "deep learning stock market", "time series analysis stock market", "lstm stock market", "stock market prediction", "arima stock market" ja "nlp stock market". Käytetyssä aineistossa painotetaan mahdollisimman uusia tutkimuksia, sillä tutkittavalla alalla on tehty merkittävää edistystä viime vuosina. Tavoitteena on löytää aineistoa, jossa menetelmien suoriutumista on mitattu perustuen oikean maailman kurssidataan ja muuhun osakkeisiin liittyvään tietoon.

Tutkielman tuloksista voidaan todeta, että aikasarja-analyysiä sekä syväoppimismenetelmiä hyödyntämällä on mahdollista saavuttaa osakemarkkinoilla parempaa tuottoa kuin osakemarkkinaindekseihin sijoittamalla. Tutkimuksissa saavutetut tulokset vaihtelevat huomattavasti tutkimuksen toteutustavan sekä käytetyn menetelmän mukaan. Lisäksi jotkin aineistoista ovat toisiinsa nähden ristiriidassa. Parhaiten osakekurssien ennustamisessa suoriutuvaa syväoppimismenetelmää ei voida tulosten perusteella määrittää, mutta tulokset osoittavat, että enemmän tietoa huomioonottavat mallit suoriutuvat tehtävästä yksinkertaisia malleja paremmin. Osakemarkkinoiden ennalta-arvaamattomuuden vuoksi on myös syytä todeta, että aikaisemmin hyvin suoriutunut malli ei välttämättä kykene samoihin tuloksiin tulevaisuudessa.

Tutkielma rakentuu luvusta 2, jossa käsitellään osakekurssien toimintaan, ennustettavuuteen ja osakkeiden hinnanmäärittelyyn liittyvää kirjallisuutta. Tätä seuraavassa luvussa 3. käsitellään kirjallisuuden perusteella oleellisimpien aikasarja-analyysin sekä syväoppimisen mallien toimintaperiaatteita. Luvussa 4. käsitellään aikasarja-analyysillä sekä syväoppimismenetelmillä saavutettuja tuloksia osakekurssien ennustamisessa. Luvussa 5. on yhteenveto ja pohdinta, jossa käsitellään ja tiivistetään tutkielman tulokset.

## 2 OSAKEMARKKINAT

Osakemarkkinat ovat rahoitusmarkkinan osa, jossa käydään kauppaa osakkeilla. Tässä luvussa käsitellään osakemarkkinoiden toimintaan, sen ennustettavuuteen sekä osakkeiden arvonmääräytymiseen liittyvää kirjallisuutta.

### 2.1 Osakemarkkinoiden toiminta

Kemp & Pape (2016) esittävät kirjassaan, että Yhdysvallat tunnetaan suurimmasta ja arvokkaimmasta osakemarkkinastaan, mutta ensimmäisen osakemarkkinan katsotaan saaneen alkunsa Euroopassa. Kirjan osoittaa, että Hollannissa vuonna 1602 luotiin ensimmäinen yritys, Dutch East India Company (holl. Verenigde Oostindische Compagnie, VOC), jonka osakkeilla käytiin julkista kauppaa. Pian tämän jälkeen Amsterdamiin rakennettiin myös fyysinen kauppapaikka osakkeille, jonka kirja katsoo olevan ensimmäinen järjestäytynyt osakemarkkina (Kemp & Pape, 2016).

Antelo & Peon (2012) osoittavat kirjassaan osakemarkkinan olevan fyysinen paikka tai verkkopalvelu, jossa käydään kauppaa osakkeilla. Kun kaupankäyntiä tapahtuu järjestäytyneessä kaupankäyntiin luodussa ympäristössä, puhutaan osakemarkkinasta. Jotta osakkeella voidaan käydä kauppaa tietyn osakemarkkinan kautta, sen tulee olla listattuna kyseisellä markkinalla. Historiassa osakkeiden vaihto tapahtui fyysisissä paikoissa, mutta moderni osakemarkkina toimii pitkälti verkkopalveluissa (Antelo & Peon, 2012).

Antelo & Peon (2012) määrittelevät kirjassaan osakkeen olevan arvopaperi, jonka omistaja hallitsee osuutta yksityisestä yrityksestä. Kirjassa kerrotaan, että Bloombergin mukaan maailman osakemarkkinan arvo oli noin 53 triljoonaa Yhdysvaltain dollaria vuonna 2011. Kirjassa todetaan osakemarkkinan olevan paikka, jossa neljä eri tahoja kohtaavat: pääoman hakijat, pääoman tarjoajat, välittäjät ja sääntelyvirastot. Pääoman hakijoilla tarkoitetaan yksityisiä yrityksiä, jotka hakevat rahoitusta. Yrityksille pääomaa osakemarkkinoilla tarjoavat sijoittajat, jotka ovat pääomalleen tuottoa tavoittelevia yksityishenkilöitä tai instituutioita. Välittäjät ovat kirjan mukaan tahoja, jotka yhdistävät sijoittajat ja yritykset



tarjoamalla alustoja ja palveluita kaupankäynnin helpottamiseksi. Sääntelyvirastojen rooliksi kirjassa määritellään kaupankäynnin läpinäkyvyyden sekä sijoittajien turvallisuuden takaaminen (Antelo & Peon, 2012).

Kapitalistisissa markkinatalouksissa osakkeilla ja niiden kaupankäynnillä voidaan sanoa siis olevan keskeinen rooli. Antelo & Peon (2012) ovat kirjassaan määritelleet seuraavia osakemarkkinoiden tärkeimpiä tehtäviä. Osakemarkkinat tarjoavat yrityksille tavan hakea rahoitusta toiminnalleen, sekä antavat sijoittajille mahdollisuuden osallistua yrityksen hallintoon, sillä osakkeenomistajille kuuluu usein myös vaikutusvaltaa yrityksen päätöksenteossa. Lisäksi markkinat tarjoavat helpon tavan myydä ja ostaa osakkeita, joka madaltaa sijoittajien kynnystä tehdä sijoituksia. Sijoittajat saavat osakemarkkinoiden kautta myös tietoa yritysten toiminnasta. Osakemarkkinoista voidaan myös tehdä päätelmiä yksittäisten yritysten tai esimerkiksi kokonaisten markkinoiden tai kansantalouksien tilanteesta (Antelo & Peon, 2012).

## 2.2 Osakkeiden arvon määräytyminen

Yksi tutkielman kannalta oleellisimmista tarkastelukohteista onkin osakkeen arvon määräytyminen ja siihen liittyvät yksityiskohdat. Yksinkertaisimmillaan osakkeen tai minkä tahansa kaupankäynnin kohteena olevan asian hinta määräytyy sen mukaan, missä hinnassa myyjän hintapyyntö kohtaa hinnan, jonka ostaja on valmis maksamaan. Yksiselitteistä oikeaa hintaa osakkeelle on hyvin vaikeaa laskea, sillä kaikkia hintaan vaikuttavia tekijöitä on käytännössä mahdotonta määritellä, ja lopulliset sijoituspäätökset tekevät sijoittajat itse. Sijoittajat voivat myös käyttää muihin sijoittajiin verrattuna erilaisia tapoja arvioidessaan sijoituspäätöksiään, ja saattavat arvioissaan painottaa erilaisia tekijöitä kuin muut sijoittajat. Erilaisia matemaattisia malleja on kuitenkin kehitetty osakkeen hinnan laskemiselle. Nämä mallit hyödyntävät osakkeen tunnuslukuja kuten maksettavan osingon määrää ja tuotto-odotuksia.

Kemp & Pape (2016) kertovat kirjassaan osakkeiden arvonmääräytymisen historiasta seuraavaa. Vuonna 1688, kun Amsterdamin osakemarkkina oli ollut olemassa alle vuosisadan, osakekauppaa siellä harjoittanut Joseph de la Vega määritteli aikaisemmin tässä luvussa käsitellyn yrityksen, Dutch East India Companyn, osakkeen hintaan vaikuttavia tekijöitä. Näihin kuului muun muassa yrityksen liiketoimien edistyminen, liiketoimien menestyminen Japanissa, Persiassa ja Kiinassa, seilaako sieltä paljon laivoja Amsterdamiin ja ovatko ne täynnä arvokkaita mausteita. Lisäksi hän näki yleisen asenteen markkinaa kohtaan tärkeänä hintaan vaikuttavana tekijänä (Kemp & Pape, 2016). Kun katsotaan osakkeiden arvon muodostumista nykypäivänä, Vegan satoja vuosia sitten tekemissä havainnoissa on paljon yhtäläisyyksiä. Yrityksen tulevaisuudennäkymät sekä yleinen markkinatilanne ovat edelleen keskeisiä osakkeen hintaan vaikuttavia tekijöitä (Investopedia, 2022). Tulevaisuudennäkymillä tarkoitetaan käytännössä sitä, kuinka paljon osinkoja yritys tuottaa, kuinka pitkään sen odotetaan tuottavan osinkoa, odotetaanko osinkojen tai yrityksen arvon nousevan ja kuinka paljon näiden lukujen kehitykseen liittyy epävarmuutta.

Osakkeiden arvonmäärittäystä käsittelevän kirjallisuuden voidaan sanoa alkaneen Williamsin (1938) kirjasta "The Theory of Investment Value". Teoksessa esitetään osakkeen hinnan määräytyvän kaikkien sitä vastaan maksettavien osinkojen nykyarvon mukaan. Williamsin (1938) teoksen mukaan osakekaupassa vaihdetaan tämänhetkistä pääomaa tulevaisuuden pääomaan, joten nykyarvon ennustaminen huomioimalla inflaatio ja ostovoiman kehitys on olennaista määriteltäessä osakkeen oikeaa kauppahintaa. Osaketta vastaan maksettavien osinkojen kautta osakkeen arvostusta laskiessa tuleekin väistämättä ilmi, että laskutoimitukseen tarvitaan jonkinlainen arvio tai ennuste siitä, mihin suuntaan osakkeen arvo ja osingot ovat kehittymässä (Mishkin, 2022). Mishkinin (2022) kirjan mukaan nykyarvon määrittämiseen voidaan käyttää yleistettyä osinkomallia, joka ottaa huomioon tuotto-odotuksen (Mishkin, 2022, s. 191):

$$P_0 = \sum_{t=1}^{\infty} \frac{D_t}{(1 + k_e)^t}$$

jossa

$P_0$  = nykyarvo

$D$  = maksettava osinko

$T$  = ajanjakso

$K_e$  = tuotto-odotus

Kirjan mukaan tämä kaava ottaa huomioon myös riskin, sillä tuotto-odotus määräytyy riskin mukaan. Mitä korkeampia riskejä osakkeeseen liittyy, sitä korkeammaksi sijoittaja voi arvioida tuotto-odotuksen. Matalamman riskin osakkeissa puolestaan tuotto-odotus on pienempi. Yleistettyyn osinkomalliin liittyy kirjan mukaan kuitenkin seuraava oleellinen ongelma. Useat yritykset eivät maksa lainkaan osinkoa, vaan osakkeen hinta perustuu ainoastaan odotukseen siitä, että yritys maksaa osinkoa tulevaisuudessa. Yritykset saattavat keskittyä nopeaan kasvuun aikomuksenaan maksaa osinkoja kasvun tapahduttua. Jos yleistetyyn osinkomallin kaavaan asetetaan osingon arvoksi 0, huomataan tuloksen saamisen olevan vähintäänkin vaikeaa (Mishkin, 2022).

Toinen yleisesti käytössä oleva malli osakkeen arvon laskemiselle on Gordonin varallisuuden kasvumalli, joka pyrkii Pinton (2015) kirjan mukaan ottamaan osinkojen kasvun paremmin huomioon kuin yleistetty osinkomalli. Gordonin varallisuuden kasvumallin osoitetaan kirjassa toimivan parhaiten, kun lasketaan arvoa yritykselle, jonka osingonmaksu on vakaata ja kasvuvauhti verrattavissa talouden yleiseen kasvuun. Malli perustuu oletukseen siitä, että osingot kasvavat tasaisesti loputtomuuksiin. Kirjan mukaan Gordonin varallisuuden kasvumalli voidaan kirjoittaa muotoon (Pinto ym., 2015, s. 245):

$$V_0 = \frac{D_1}{r - g}$$

, jossa

V= Osakkeen nykyarvo  
D= Viimeisin osingon määrä  
r= Tuotto-odotus  
g= Osingon kasvukerroin

Kirjassa osoitetaan, että Gordonin varallisuuden kasvumallilla luotettavin tulos saavutetaan, kun yrityksen kasvu ja osingonmaksu vastaavat pääpiirteittäin sijoittajine odotuksia. Tulevaisuuden osinkojen, niiden ajoituksen ja kasvun ennustaminen luotettavalla ja puolueettomalla tavalla on keskeinen haaste Gordonin kasvumallissa ja muissa sitä vastaavissa malleissa, joilla lasketaan osinkojen nykyarvoa (Pinto ym., 2015). Voidaan siis todeta, että osakkeen arvon laskeminen matemaattisten kaavojen avulla sisältää paljon epävarmuutta aiheuttavia tekijöitä. Nämä menetelmät ovat hyödyllisiä lähinnä hyvin tasaisesti ja ennustettavasti kasvavien ja osinkoa maksavien yritysten arvostuksessa.

## 2.3 Tehokkaiden markkinoiden teoria

Eugene Faman artikkeli "Efficient Capital Markets: A Review of Theory and Empirical Work, 1970" on toiminut sunnannäyttäjänä monessa rahoitusalaan koskevassa tutkimuksessa. Fama esittää artikkelissa tehokkaiden markkinoiden teoriaa ja todisteita sen toteutumisesta. Tehokkaiden markkinoiden teorian mukaan kaikkien avoimella markkinalla vaihdettavien rahoitusinstrumenttien, mukaan lukien osakkeiden, hintaan on sisällytetty kaiken saatavilla olevan tiedon vaikutus. Kun uutta tietoa julkaistaan saataville, tehokkaiden markkinoiden toteutuksessa sen vaikutus näkyy välittömästi osakkeen hinnassa. Tämä puolestaan tarkoittaisi sitä, että sijoittajan olisi mahdotonta saavuttaa etua markkinalla keräämänsä tiedon avulla (Fama, 1970).

Faman (1970) artikkelissa käsitellään tehokkaiden markkinoiden teoriaa kolmesta eri näkökulmasta: heikosti toteutuva- (Weak-form), osittain toteutuva- (Semi-strong) ja vahvasti toteutuva (Strong-form) tehokkaiden markkinoiden teoria. Heikosti toteutuvalla tarkoitetaan, että aikaisempi hintakehitys ja osakkeen vaihtomäärä eivät sisällä tietoa, jolla voisi ennustaa osakkeen hintakehitystä. Osittain toteutuvalla tarkoitetaan, että julkinen tieto, kuten vuosikatsaukset tai yrityksen uutiset, näkyvät osakkeen hinnassa. Vahvasti toteutuvalla tarkoitetaan, että myös yksityinen tieto on sisällytetty hintoihin, tehden tiedon avulla edunsaamisen mahdottomaksi (Fama, 1970). Faman löydökset osittain toteutuvien tehokkaiden markkinoiden puolesta ovat vahvoja. Tutkijat tosin eivät ole asiasta täysin yksimielisiä. Granger (1992) osoittaa tutkimuksessaan, että osakemarkkinoita voidaan ainakin jollain tapaa ennustaa käsittelemällä dataa pitkältä aikaväliltä ja tunnistamalla osakkeissa kausittaista vaihtelua (Granger, 1992).

### 3 OSAKEKURSSIEN ENNUSTAMISEEN KÄYTETYT MENETELMÄT

Tässä luvussa käsitellään tutkielman kannalta oleellista kirjallisuutta aikasarja-analyysistä, syväoppimisesta sekä näiden menetelmistä, joita on kirjallisuudessa käytetty osakekurssien ennustamiseen. Aikasarja-analyysin käsittely on tutkielman kannalta oleellista, sillä osakkeen hintakehitys on aikasarja, jossa osakkeen hinta kehittyy ajan kuluessa. Kirjallisuudessa, jossa käsitellään osakekurssien ennustamista syväoppimisen keinoilla, on usein käytetty myös jonkinlaista aikasarja-analyysin menetelmää tai niitä on vertailtu toisiinsa.

#### 3.1 Aikasarja-analyysi

Chen ym. (2014) toteavat artikkelissaan aikasarjan olevan joukko tarkasti määritellyjä tietoja, jotka ovat kerätty peräkkäisinä ajankohtina yhtenäisenä ajanjaksona. Aikasarja-analyysi on artikkelin mukaan tärkeä osa tilastotiedettä, jossa sitä käytetään datan ominaisuuksien tutkimiseen ja ennustuksien tekemiseen perustuen aikasarjaan. Lisäksi artikkelissa todetaan, että aikasarja-analyysin käyttö ennustamisessa on hyödyllistä rahoitusalan lisäksi myös esimerkiksi teollisuuden alalla ja vähittäismyynnissä (Chen ym., 2014).

George E. P. ym. (2016) kirjan mukaan suurin osa tietojoukoista (engl. datasets) ovat aikasarjoja, kuten viikoittainen liikenneonnettomuuksien määrä, kuukausittainen sademäärä, päivittäinen osakkeen hinta tai tunnin välein tehdyt havainnot kemikaalisen prosessin aikana. Kirjassa todetaan aikasarjan luontaisiin ominaisuuksiin kuuluvan, että peräkkäiset havainnot ovat toisistaan riippuvaisia. Aikasarja-analyysin menetelmät keskittyvätkin tämän riippuvuussuhteen analysointiin (George E. P. ym. 2016).

### 3.2 ARIMA ja Box-Jenkins metodi

Makridakis & Hibon (1997) kertovat artikkelissaan ARIMA-mallista seuraavaa. ARIMA (Autoregressive integrated moving average) koostuu kolmesta osasta: AR, I ja MA. Ensimmäiset autoregressiiviset (AR) mallit esiteltiin Yulen toimesta vuonna 1926. Slutsky kehitti vuonna 1937 liukuvan keskiarvon (MA), joka täydensi Yulen esittelemiä malleja. Vuonna 1938 Wold yhdisti autoregressiiviset mallit ja liukuvan keskiarvon mallit ja näytti, että ARMA-prosesseja voidaan hyödyntää yhdessä stationaarisen aikasarjan mallintamisessa. Tällä tarkoitetaan sitä, että aikasarjan voidaan mallintaa olevan yhdistelmä aikaisempia arvoja ja satunnaisia virheitä. Artikkelin mukaan Woldin teoreettisia tuloksia pystyttiin hyödyntämään vasta 1960-luvulla, kun ARMA-metodin parametrien optimointiin riittävän laskentatehon omaavat tietokoneet tulivat saataville ja taloudellisesti kannattaviksi. Box ja Jenkins tekivät 1970-luvulla tunnetuksi ARMA-mallien käytön tavalla, jossa ei-stationaarisia aikasarjoja voitiin analysoida stationaarisen aikasarjan tavoin. Tämä lähestymistapa tuli tunnetuksi ARIMA-mallien Box-Jenkins metodina. Kirjain I AR:n ja MA:n välissä tarkoittaa integroitua, jolla viitataan metodin tarpeeseen muuttaa ei-stationaarinen aikasarja stationaariseksi (Makridakis & Hibon, 1997).

George E. P. ym. (2016) toteavat kirjassaan, että stationaarisuudella tarkoitetaan sitä, että aikasarjan keskiarvossa ja varianssissa ei ole vaihtelua. Ei-stationaarisen aikasarjan tilastolliset ominaisuudet kuten keskiarvo tai varianssi voivat muuttua esimerkiksi kausivaihtelun muodossa tai trendien mukana. Osakkeen hintakehityksen voidaan siis sanoa olevan ei-stationaarinen aikasarja, sillä sen tilastollisten parametrien kehitykseen vaikuttaa oleellisesti kausivaihtelu, trendit ja osakkeen vaihtomäärä. ARIMA-mallien Box Jenkins metodi pyrkii siis löytämään ei-stationaarisesta aikasarjasta stationaarisen aikasarjan ominaisuuksia muuttamalla se stationaariseksi (George E. P. ym. 2016). Tämän vuoksi tutkielman kannalta on oleellisinta käsitellä ARIMA-mallin käyttöä, sillä sen voidaan olettaa olevan aikasarja-analyysin metodeista parhaiten soveltuva osakekurssien ennustamisessa.


### 3.3 Syväoppiminen

Selvinin ym. (2017) artikkelin mukaan osakemarkkinasta saatua dataa on valtavasti ja se on hyvin epälineaarista. Epälineaarisuudella tarkoitetaan tässä yhteydessä sitä, että yksikään osakkeen hintaan vaikuttava tekijä ei ole varsin suorassa tai ennustettavassa yhteydessä hinnankehitykseen. Tämänkaltaisen datan analysointiin tarvitaan työkaluja, jotka pystyvät löytämään ja analysoimaan datan taustalla olevaa dynamiikkaa (Selvin ym., 2017).

Kwon (2011) määrittelee kirjassaan syväoppimisen olevan koneoppimisen alalaji, joka käyttää monitasoisia neuroverkkoja oppiakseen toistuvia kaavoja suurista datamääristä. Neuroverkot ovat kirjan mukaan järjestelmiä, jotka

mukailevat ihmisaivojen oppimisprosesseja. Kirjassa todetaan, että neuroverkot voivat itsenäisesti oppia löytämään toistuvia kaavoja ja ominaisuuksia datasta tutkimalla parametrien yhteyksiä ja niiden painoarvoja sekä vaikutuksia toisiinsa. Toisin kuin muut algoritmit, kuten useat aikasarja-analyysin menetelmät, neuroverkoilla voidaan siis paremmin tutkia ja löytää parametrien välisiä yhteyksiä ja muita piilossa olevia tekijöitä (Kwon, 2011). Yksinkertaista neuroverkkoa voidaan havainnollistaa kuviolla:

Kuvio 1. Yksinkertainen neuroverkko



Kwonin (2011) kirjassa kerrotaan neuroverkoista lisäksi seuraavaa. Neuroverkot koostuvat vähintään kolmesta kerroksesta. Ensimmäisenä on syötekerros, jonka neuronit ovat neuroverkolle syötettävät muuttujat. Muuttujia voi olla useampia. Toisena kerroksena on piilokerros, joka ei ole suorassa yhteydessä verkon ulkopuoleen. Piilokerroksen neuronit sisältävät erilaisia funktioita, ja niiden välillä vaihtuu tietoa määrittelemättömiä reittejä. Piilokerroksia ja sen neuroneita voi olla useampia. Kolmantena kerroksena on tulostekerros. Sen neuronit antavat neuroverkon prosessoiman tuloksen. Tulostekerroksen neuroneita voi olla useampia (Kwon, 2011).

Neuroverkkojen ominaisuuksiin siis kuuluu kyky oppia datan perusteella automaattisesti asioita, jotka ovat liian monimutkaisia ihmisaivoille prosessoitavaksi, ilman että neuroverkon luoja erikseen määrittelee opittavia asioita.

Neuroverkot tyypillisesti jaotellaan kolmeen tyyppiin: keinotekoinen neuroverkko (Artificial Neural Network, ANN), konvoluutioneuroverkko (Convolution Neural Network, CNN) ja rekursiivinen neuroverkko (Recurrent Neural Network, RNN). Näihin tyyppeihin perustuvia variaatioita ja niiden käyttökohteita on useita, kuten puheentunnistus, kuvantunnistus, lääketieteen ennusteet ja rahoitusalan ennusteet. Seuraavana käydään läpi tämän tutkielman ja rahoitusalan kannalta oleelliset neuroverkot hyödyntävät syväoppimisen menetelmät.

### 3.3.1 Rekursiiviset neuroverkot ja LSTM

Graves (2012) toteaa kirjassaan, että rekursiivisten neuroverkkojen erikoisuus on kyky luoda eräänlainen muistiominaisuus, jonka avulla malli pystyy hyödyntämään ja oppimaan aikaisempien iteraatioiden tuloksista. Rekursiiviset neuroverkot ovat kirjan mukaan osoitettu hyödyllisiksi useissa käyttötarkoituksissa, kuten puheen tai tekstin analysoinnissa. Kirjan mukaan muihin neuroverkkoihin verrattuna huomattavana etuna rekursiivisissa neuroverkoissa on kyky oppia, mitä tietoa aineistosta kannattaa hyödyntää ja mitä jättää huomiotta, sekä kyky tunnistaa toistuvuutta myös aineiston sisältäessä vääristymiä. Rekursiivisiin neuroverkkoihin liittyy kuitenkin kirjan mukaan yksi oleellinen puute, jota kutsutaan häviävän gradientin ongelmaksi. Häviävän gradientin ongelma voi toteutua, jos rekursiivisen neuroverkon avulla pyritään analysoimaan tietoa hyvin pitkältä aikaväliltä. Sen toteutuessa voidaan päätyä tilanteeseen, jossa tulos alkaa vääristyä sen kulkiessa liian useita kertoja neuroverkon läpi (Graves, 2012).

Hochreiter ja Schmidhuber kehittivät vuonna 1997 uudelleensuunnitellun rekursiivisten neuroverkkojen mallin, joka pyrkii estämään häviävän gradientin ongelmaa muistisolujen avulla. Tätä mallia kutsutaan LSTM:ksi (Long-short term memory). LSTM:n on osoitettu olevan kykenevä käsittelemään tietoa hyvin pitkiltäkin aikaväleiltä. Se on myös todettu eteväksi monessa tosimaailman käyttötarkoituksessa, kuten puheentunnistuksessa ja bioinformatiikassa. (Graves, 2012) LSTM on todistettu normaalia rekursiivista neuroverkkoa tehokkaammaksi, ja siksi kirjallisuudessa sitä on sovellettu myös osakekurssien ennustamisessa (Bao, 2017).

### 3.3.2 Luonnollisen kielen prosessointi ja BERT

Dogran ym. (2022) artikkelin mukaan luonnollisen kielen prosessointi (engl. Natural Language Processing, NLP) on ihmisen kirjoittaman kielen ja tietokoneen vuorovaikutusta käsittelevä aihealue. Luonnollisen kielen prosessoinnissa käytetään erilaisia tekoälyn, syväoppimisen ja tilastotieteen menetelmiä. Artikkeleissa todetaan, että oleelliset haasteet luonnollisen kielen prosessoinnissa liittyvät tekstien kontekstin ymmärtämiseen, ihmisen kirjoittaman kielen monimutkaisuuteen, tekstin suureen määrään ja slangisanoihin. Jotta tekoälyyn perustuva malli voi ymmärtää ihmisen kirjoittamaa tekstiä, sen täytyy usein olla hyvin pitkälle koulutettu ja kyetä ymmärtämään syvällisempiäkin asiayhteyksiä (Dogra ym., 2022). Viime vuosien aikana tekoälyn, syväoppimisen ja tietokoneiden laskeutteen kehittyessä luonnollisen kielen prosessoinnissa on tehty kuitenkin

suuria edistysaskelia, joten on aiheellista selvittää sen soveltuvuutta myös tämän tutkielman aiheeseen.

De Oliveira Carosia ym. (2022) artikkelin mukaan BERT (Bidirectional Encoded Representation from Transformers) on luonnollisen kielen prosessoinnin malli. Artikkelissa kerrotaan, että alun perin BERT on koulutettu suurella määrällä merkitsemätöntä, pääosin Wikipedian sisältämää tekstiä. BERT on artikkelin mukaan laajasti todettu yhdeksi onnistuneimmista koneoppimisen malleista, jotka käyttävät tekstidataa. Artikkelissa todetaan, että huomattavin kehitysaskel BERT-mallissa aikaisempiin vastaaviin malleihin verrattuna on sen edistyneempi kyky ottaa lauseiden konteksteja huomioon (de Oliveira Carosia ym., 2022). Osakekurssien ennustettavuutta käsittelevässä kirjallisuudessa BERT-mallia on käytetty esimerkiksi analysoitaessa uutisten tai sosiaalisen median vaikutusta osakekursseihin.



## 4 AIKASARJA-ANALYYSIN JA SYVÄOPPIMISMALLIEN KÄYTTÖ OSAKEKURSSIEN ENNUSTAMISESSA

Tässä luvussa esitellään tuloksia, joita edellä esitellyillä aikasarja-analyysin sekä syväoppimisen malleilla on saavutettu osakekurssien ennustamisessa. Useissa tutkimuksissa on lisäksi käytetty jonkinlaista yhdistelmää edellisistä malleista, muita syväoppimisen malleja tai niiden variaatioita.

### 4.1 ARIMA

Kirjallisuudessa ARIMA-malli on laajasti todettu aikasarja-analyysin menetelmästä parhaiten osakekurssien ennustamiseen soveltuvaksi. ARIMA-mallin käytön on osoitettu olevan tuloksellisinta soveltaessa sitä lyhyen aikavälin ennusteisiin. Tamerlanin (2022) artikkelissa ARIMA-mallia sovelletaan käytännössä Istanbulin osakemarkkinaindeksin kehityksen ennustamiseen. Artikkelissa luodaan ennuste vuoden 2009 tammikuun ja 2020 joulukuun välisen kurssikehitysdatan perusteella käyttäen ARIMA-mallia. ARIMA-mallilla saatua ennustetta verrataan artikkelissa 2021 tammikuun ja 2021 maaliskuun väliseen todelliseen kurssikehitykseen. Tulokset osoittavat ennusteen olevan hyvin lähellä todellista kurssikehitystä (Tamerlan, 2022).

Mondalin ym. (2014) artikkelin löydökset pitkälti vastaavat Tamerlanin (2022) saamia tuloksia. Artikkelissa sovellettiin ARIMA-mallia 56 Intian NSE-pörssissä listatun osakkeen kurssikehityksen ennustamiseen. Osakkeet olivat valittu seitsemältä eri toimialalta. ARIMA-mallilla tehdyt ennusteet toteutettiin 23 kuukauden mittaisen kurssidatan pohjalta. ARIMA-mallilla saadut ennusteet vastasivat kaikilla sektoreilla osakekurssin todellista kehitystä yli 85 % tarkkuudella (Mondal ym., 2014).

Alp ym. (2021) artikkelissa verrataan ARIMA-mallin ennustustarkkuutta LSTM- ja GRU-syväoppimismalleihin. Ennustuskohteena artikkelissa on kolme erillistä Turkin osakemarkkinaindeksiä. Artikkelissa osoitetaan ARIMA-mallin suoriutuvan paremmin kuin LSTM- tai GRU-mallit. Tuloksen voidaan sanoa olevan yllättävä, sillä LSTM- ja GRU-mallit pystyvät ottamaan suuremman määrän dataa huomioon, joten niiden voisi olettaa kykenevän tarkempiin ennusteisiin kuin ARIMA-malli. Alp ym. (2021) uskovat tämän johtuvan mahdollisesti siitä, että tutkimuksessa käytetyn datan määrä oli suhteellisen pieni, joten syväoppimismallien edut eivät tulleet esiin (Alp ym., 2021).

## 4.2 LSTM

Kuten aikaisemmin todettu, syväoppimisen käyttö osakekurssien ennustamisessa ei välttämättä takaa parempia tuloksia kuin lineaarisella aikasarja-analyysillä saadut tulokset. Hiranshan ym. (2018) tutkimuksessa verrataan ARIMA-mallia LSTM-malliin sekä muihin syväoppimisen menetelmiin osakekurssien ennustamisessa. Syväoppimismallit koulutetaan yhdellä Intian NSE-pörssiin listatulla osakkeella. Koulutetuilla malleilla pyritään ennustamaan usean Intian NSE-pörssiin listatun osakkeen sekä usean New Yorkin NYSE-osakepörssiin listatun osakkeen kurssikehitystä. Tutkimuksella pystytään osoittamaan, että käytetyt syväoppimismallit pystyvät löytämään toistuvia kaavoja molemmista osakepörsseistä. Tulokset myös osoittavat, että osakekurssit sisältävät taustalla olevaa dynamiikkaa, jota lineaariset mallit kuten ARIMA eivät pysty tunnistamaan (Hiransha ym., 2018).

Baon ym. (2017) artikkelissa käytetään osakekurssien ennustamiseen LSTM-mallia sekä yhdistelmää, johon kuuluu aaltomuunnos (engl. Wavelet Transform, WT), kasatut autoenkooderit (engl. Stacked Autoencoders, SAE) ja LSTM. Aaltomuunnosta käytetään tutkimuksessa kohinan poistoon ennen datan syöttämistä syväoppimismallille. Kasatut autoenkooderit pyrkivät oppimaan osakkeiden ominaisuuksista piilossa olevia ominaisuuksia. Tämän yhdistelmän nimeksi tutkimuksessa määritellään WSAEs-LSTM. Artikkelissa mallille syötetään suuri määrä dataa, joka sisältää hintojen ja vaihtomäärän lisäksi useita teknisiä indikaattoreita kuten hinnanvaihtelun nopeus ja liukuvat keskiarvot. Dataa syötetään malleille kuuden vuoden ajalta. Ennustuksen kohteena ovat useat suuret osakemarkkinaindeksit eri puolilta maailmaa. Malleja verrataan tutkimuksessa myös niin sanottuun "buy and hold"-strategiaan, eli tilanteeseen, jossa sijoittaja ostaa indeksiin sidottua arvopaperia ja ei käy sillä aktiivisesti kauppaa tutkitavan ajanjakson aikana. Tutkimuksessa pystytään osoittamaan, että kaikki tutkitut syväoppimismallit suoriutuvat paremmin, kuin "buy and hold" strategia, riippumatta siitä, millä osakemarkkinaindeksillä niitä verrataan. Syväoppimismalleista parhaiten suoriutuu aikaisemmin WSAEs-LSTM-malli. WSAEs-LSTM-mallilla pystyttiin saavuttamaan tutkitun kuuden vuoden ajalta jopa yli 64 % vuosituotto Hong Kongin Hang Seng-indeksissä, vaikka indeksi itsessään laski ajanjaksolla noin 1 %. Tutkimuksen luotettavuutta lisää myös se, että ennustuksen kohteena olivat useat osakemarkkinaindeksit, jotka sijaitsevat eri puolilla maailmaa ja ovat eri kokoisia (Bao ym., 2017).

Nelson ym. (2017) artikkelin löydökset tukevat edellisiä tuloksia. Artikkelissa tutkitaan LSTM-mallin soveltuvuutta osakekurssien kehityksen ennustamisessa. Mallia koulutetaan useilla Brasilian osakemarkkinalla (Bovespa) listatuilla osakkeilla ja suurella määrällä niihin liittyvää dataa. Mallin tavoitteena on ennustaa, nouseeko tietyn osakkeen kurssi seuraavan 15 minuutin aikana. Aikaisemmin esiteltyjen tutkimuksien tuloksia tukien, myös tässä artikkelissa pystytään osoittamaan LSTM-mallin kykeneväisyys osakekurssien ennustamisessa. LSTM-mallin avulla pystyttiin saavuttamaan huomattavasti suurempia tuottoja kuin "buy and hold"-strategialla (Nelson ym., 2017).

### 4.3 BERT

Ni ym. (2021) soveltaa tutkimuksessaan luonnollisen kielen prosessoinnin BERT-mallia sekä LSTM-mallia osakekurssien ennustamiseen. Tutkimuksessa BERT-mallille syötetään sosiaalisen median palvelu Twitteristä sekä uutisista kerättyä tiettyihin osakkeisiin liittyvää tekstisisältöä. Malli on kykeneväinen myös ottamaan huomioon tekstien suhteita toisiinsa sekä tekstien positiivista tai negatiivista sävyä. Twitteristä ja uutisista kerätyn datan lisäksi tutkimuksessa kerätään osakkeen historiallisia hintatietoja, ja nämä tiedot syötetään LSTM-mallille. Tutkimuksessa käytetään Twitterissä eniten mainittuja osakkeita, jotka ovat listattuna New Yorkin NYSE-osakepörssissä. Tutkimuksessa pystyttiin osoittamaan BERT-mallin ja LSTM-mallin yhdistelmän tuottavan tarkempia ennusteita, kuin pelkkä LSTM-malli. Lisäksi tutkimuksessa voitiin todeta, että mallin kyky ottaa twiittien keskinäiset suhteet huomioon paransivat ennustustarkkuutta. Ainoastaan twiitin tekstisisällön analysointi ei tuottanut yhtä hyvää tulosta kuin tekstin sekä twiittien välisten suhteiden analysointi. Tulokset esitetään tutkimuksessa binäärisellä tavalla, eli tuloksessa otettiin huomioon pelkästään se, nousiko vai laskiko osakkeen hinta. Esitelty malli pystyi ennustamaan osakekurssin kehityksen suunnan keskimäärin 64,19 % tarkkuudella, jota voidaan pitää erinomaisena tuloksena (Ni ym., 2021).

De Oliveira Carosian ym. (2022) tutkimus tukee edellisiä löydöksiä. De Oliveira Carosian tutkimuksen tavoitteena on BERT-mallin sekä MLP-syväoppimismallin avulla ennustaa Brasilian Ibovespa-osakemarkkinaindeksin kehitystä. Tutkimuksessa koulutetaan BERT-mallille Ibovespa-osakemarkkinaindeksiin liittyviä uutisia, jotka ovat julkaistu tammikuun 2013 ja heinäkuun 2017 välillä. Mallilla saatuja tuloksia verrataan tutkimuksessa "buy and hold"-strategialla saavutettaviin tuottoihin. De Oliveira Carosia pystyy osoittamaan uutisilla koulutetun BERT-mallin ja MLP-syväoppimismallin yhdistelmän nostavan sijoituksen tuottoa verrattuna "buy and hold"-strategiaan sekä vähentämään sijoituksen riskejä (de Oliveira Carosia ym., 2022).

## 5 YHTEENVETO JA POHDINTA

Tässä tutkielmassa tutkittiin syväoppimismenetelmien soveltuvuutta osakekursien ennustamiseen. Tutkielmassa esiteltiin osakemarkkinoiden toimintaa, niiden ennustettavuutta käsittelevää kirjallisuutta, tutkielman kannalta tärkeimpien aikasarja-analyysin sekä syväoppimisen menetelmiä ja niillä saavutettuja tuloksia osakekurssien ennustamisessa.

Tutkielman tavoitteena oli selvittää, kuinka tarkasti osakekursseja pystytään ennustamaan käyttäen syväoppimismenetelmiä, mikä syväoppimismalli suoriutuu osakekursseja ennustaessa parhaiten sekä voidaanko syväoppimismalleja käyttämällä saavuttaa osakesijoittamisessa parempia tuottoja kuin osakemarkkinaindekseihin sijoittamisella tai ”buy and hold” -strategiaa käyttämällä. Tutkielma toteutettiin kirjallisuuskatsauksena. Tutkielman aineisto kerättiin JYKDOK- ja Google Scholar -tietokannoista. Käytetyssä aineistossa painotettiin mahdollisimman uusia tutkimuksia, sillä tutkittavalla alalla on tehty merkittävää edistystä viime vuosina. Entistä monimutkaisempien syväoppimismallien käyttö on tullut paremmin sijoittajien ja tutkijoiden saataville tietokoneiden laskentatehon kasvun myötä. Tavoitteena oli löytää aineistoa, jossa menetelmien suoriutumista on mitattu perustuen oikean maailman kurssidataan ja muuhun osakkeisiin liittyvään tietoon.

Syväoppimismenetelmillä osakekurssien ennustettavuutta on tähän tutkielmaan käytetyssä aineistossa tutkittu useita eri menetelmiä hyödyntäen. Aineisto keskittyy ARIMA- (Auroregressive Integrated Moving Average), LSTM- (Long-short term memory) ja BERT- (Bidirectional Encored Representation from Transformers) malleja sekä niiden variaatioita hyödyntäviin tutkimuksiin, sillä ne ovat aikaisemmissa tutkimuksissa todettu soveltuviksi osakekurssien ennustamiseen. Tutkielmassa käsitellyt aineistot eivät rajoitu tiettyihin osakkeisiin tai tiettyihin osakepörsseihin, vaan eri maiden sekä eri toimialojen osakkeiden ennustettavuutta käsittelevää kirjallisuutta on hyödynnetty. Aineistossa käsitellään osakekurssien ennustettavuutta myös nopeitempisen kaupankäynnin sekä pitkäaikaisen sijoittamisen näkökulmista. Tutkielman aiheeseen liittyvää aineistoa on saatavilla paljon. Aihetta on tutkittu laajasti oletettavasti siksi, että taloudellinen hyöty on luonnollisesti aina kiinnostanut sijoittajia tehden siitä tärkeän tutkittavan, sekä siksi, että julkisissa pörsseissä listattujen osakkeiden hintatiedot ja muu kurssidata on vapaasti saatavilla mahdollistaen helpon pääsyn tutkittavaan aineistoon.

Tutkielman tuloksista voidaan todeta, että osakekurssien ennustaminen syväoppimisen sekä aikasarja-analyysin menetelmin sisältää sijoittajille mahdollisuuksia saavuttaa parempia tuottoja kuin osakemarkkinaindekseihin sijoittamisella. Osakekurssien ennustamiseen käytetään valtaosassa tutkimuksia jonkinlaista variaatiota tai yhdistelmää syväoppimismenetelmistä, joten yksiselitteisesti parhaiten suoriutuvaa mallia on vaikea määritellä. Tulosten perusteella vaikuttaa kuitenkin siltä, että monimutkaisemmat ja enemmän tietoa huomioonottavat mallit suoriutuvat yksinkertaisia malleja paremmin. Tulosten esitystapa myös vaihtelee tutkimusten välillä, joka tekee mallien vertailusta epävarmaa. Joidenkin tutkimusten tulokset ovat ristiriidassa keskenään, johtuen oletettavasti

menetelmistä, joilla tutkimukset ovat toteutettu. Tässä tutkielmassa esitellyille osakekurssien ennustettavuutta käsitteleville tutkimuksille yhteneväistä on kuitenkin se, että niistä jokaisessa pystyttiin todistamaan tutkimuksessa käytetyn mallin pystyvän ainakin tietyllä tasolla ennustamaan osakekurssien liikkeitä.

Osakkeiden hintakehitykseen liittyy joka tapauksessa paljon tekijöitä, joita ihmisen tai syväoppimismallin on käytännössä mahdotonta ennustaa. Erilaisilla odottamattomilla tilanteilla, jotka voivat olla täysin osakemarkkinaan liittymättömiä, on usein suuri vaikutus osakkeiden hintoihin. Jatkotutkimuksissa olisi syytä selvittää, miten syväoppimismallit reagoivat näissä tilanteissa. Syväoppimismenetelmien avulla voitaisiin myös tutkia, mitkä osakkeen teknisistä tunnusluvuista ovat merkityksellisimpiä ottaa huomioon kurssikehitystä ennustaessa. Jatkotutkimuksissa olisi myös mielenkiintoista selvittää kuinka laajasti syväoppimismalleja on käytössä tällä hetkellä esimerkiksi rahoitusalan instituutioilla. Sen tutkiminen voi kuitenkin olla haastavaa, sillä hyvin toimivien syväoppimismallien julkistaminen ei olisi sen kehittäneelle organisaatiolle taloudellisesti järkevää. Jos tulevaisuudessa päädytään tilanteeseen, jossa sijoituspäätöksiä tekee pääsääntöisesti jonkinlaiset syväoppimismallit eivätkä ihmiset, olisi lisäksi tärkeää tutkia miten mallit reagoivat toisiinsa.

## LÄHTEET

- Alp, S., Yiğit, Ö. E., & Öz, E. (2021). PREDICTION OF BIST PRICE INDICES: A COMPARATIVE STUDY BETWEEN TRADITIONAL AND DEEP LEARNING METHODS. *Sigma Journal of Engineering and Natural Sciences*, 38(4), Article 4.
- Antelo, M., & Peon, D. (2012). *Financial Markets: A Guided Tour*. Nova Science Publishers, Incorporated. <http://ebookcentral.proquest.com/lib/jyvaskyla-ebooks/detail.action?docID=3023412>
- Bao, W. (2017). A deep learning framework for financial time series using stacked autoencoders and long-short term memory. *PloS One*, 12(7), e0180944–e0180944. <https://doi.org/10.1371/journal.pone.0180944>
- Barber, B. M., & Odean, T. (2000). Trading Is Hazardous to Your Wealth: The Common Stock Investment Performance of Individual Investors. *The Journal of Finance*, 55(2), 773–806.
- Chen, S., Lan, X., Hu, Y., Liu, Q., & Deng, Y. (2014). The time series forecasting: From the aspect of network. *arXiv.Org*. <https://www.proquest.com/docview/2083978719?parentSessionId=YhfqUO-tEgTiX3ZZGKgsBbwLs2F0jgmV1UzVqmAqUITk%3D&#quick-search-wrapper>
- de Oliveira Carosia, A. E., da Silva, A. E. A., & Coelho, G. P. (2022). Using BERT to Predict the Brazilian Stock Market. Teoksessa J. C. Xavier-Junior & R. A. Rios (Toim.), *Intelligent Systems* (ss. 56–70). Springer International Publishing. [https://doi.org/10.1007/978-3-031-21689-3\\_5](https://doi.org/10.1007/978-3-031-21689-3_5)
- Dogra, V., Alharithi, F. S., Álvarez, R. M., Singh, A., & Qahtani, A. M. (2022). NLP-Based Application for Analyzing Private and Public Banks Stocks Reaction to News Events in the Indian Stock Exchange. *Systems*, 10(6), Article 6. <https://doi.org/10.3390/systems10060233>
- Fama, E. F. (1970). Efficient Capital Markets: A Review of Theory and Empirical Work. *The Journal of Finance*, 25(2), 383–417. <https://doi.org/10.2307/2325486>
- George E. P. Box, Gwilym M. Jenkins, Gregory C. Reinsel, & Greta M. Ljung. (2016). *Time Series Analysis: Forecasting and Control: Vsk. Fifth edition* George E.P. Box, Gwilym M. Jenkins, Gregory C. Reinsel, Greta M. Ljung. Wiley. <https://search.ebscohost.com/login.aspx?direct=true&db=nlebk&AN=1061322&site=ehost-live>

- Granger, C. W. J. (1992). Forecasting stock market prices: Lessons for forecasters. *International Journal of Forecasting*, 8(1), 3–13. [https://doi.org/10.1016/0169-2070\(92\)90003-R](https://doi.org/10.1016/0169-2070(92)90003-R)
- Graves, A. (2012). *Supervised Sequence Labelling with Recurrent Neural Networks* (Vsk. 385). Springer. <https://doi.org/10.1007/978-3-642-24797-2>
- Hiransha, M., Gopalakrishnan, E. A., Menon, V. K., & Soman, K. P. (2018). NSE stock market prediction using deep-learning models. *Procedia computer science*, 132, 1351-1362.
- What Drives the Stock Market?* (2022). Investopedia. Noudettu 16. marraskuuta 2023, osoitteesta <https://www.investopedia.com/articles/basics/04/100804.asp>
- Kemp, M., & Pape, S. (2016). *Uncommon Sense: Investment Wisdom since the Stock Market's Dawn*. John Wiley & Sons, Incorporated. <http://ebookcentral.proquest.com/lib/jyvaskyla-ebooks/detail.action?docID=4029290>
- Kwon, S. J. (2011). *Artificial Neural Networks*. Nova Science Publishers, Inc. <https://search.ebscohost.com/login.aspx?direct=true&db=nlebk&AN=439593&site=ehost-live>
- Makridakis, S., & Hibon, M. (1997). ARMA Models and the Box–Jenkins Methodology. *Journal of Forecasting*, 16(3), 147–163. [https://doi.org/10.1002/\(SICI\)1099-131X\(199705\)16:3<147::AID-FOR652>3.0.CO;2-X](https://doi.org/10.1002/(SICI)1099-131X(199705)16:3<147::AID-FOR652>3.0.CO;2-X)
- Mishkin, F. S. (2022). *The economics of money, banking and financial markets* (Thirteenth edition). Pearson Education.
- Mondal, P., Shit, L., & Goswami, S. (2014). Study of Effectiveness of Time Series Modeling (Arima) in Forecasting Stock Prices. *International Journal of Computer Science, Engineering and Applications*, 4, 13–29. <https://doi.org/10.5121/ijcsea.2014.4202>
- Nelson, D. M. Q., Pereira, A. C. M., & de Oliveira, R. A. (2017). Stock market's price movement prediction with LSTM neural networks. *2017 International Joint Conference on Neural Networks (IJCNN)*, 1419–1426. <https://doi.org/10.1109/IJCNN.2017.7966019>
- Ni, H. (2021). A hybrid approach for stock trend prediction based on tweets embedding and historical prices. *World Wide Web (Bussum)*, 24(3), 849–868. <https://doi.org/10.1007/s11280-021-00880-9>

- Pinto, J. E., Henry, E., Robinson, T. R., Stowe, J. D., & Miller, P. F., Jr. (2015). *Equity Asset Valuation*. John Wiley & Sons, Incorporated. <http://ebookcentral.proquest.com/lib/jyvaskyla-ebooks/detail.action?docID=4094468>
- Selvin, S., Vinayakumar, R., Gopalakrishnan, E. A., Menon, V. K., & Soman, K. P. (2017). Stock price prediction using LSTM, RNN and CNN-sliding window model. *2017 International Conference on Advances in Computing, Communications and Informatics (ICACCI)*, 1643–1647. <https://doi.org/10.1109/ICACCI.2017.8126078>
- Szumilo, N., Wiegelmann, T., Łaskiewicz, E., Pietrzak, M. B., & Balcerzak, A. P. (2018). The real alternative? A comparison of German real estate returns with bonds and stocks. *Journal of Property Investment & Finance*, 36(1), 19–31. <https://doi.org/10.1108/JPIF-02-2017-0012>
- Tamerlan, M. (2022). Stock Market Price Forecasting Using the Arima Model: An Application to Istanbul, Turkiye. *Journal of Economic Policy Researches*, 9(2), Article 2. <https://doi.org/10.26650/JEPR1056771>
- Williams, J. B. (1938). *The theory of investment value*.