

Vernerri Komulainen

# Osakekurssin ennustaminen LSTM- neuroverkon avulla

Insinööri (AMK)

Tieto- ja viestintäteknikka

Syksy 2024



**KAMK • University  
of Applied Sciences**

## Tiivistelmä

**Tekijä:** Komulainen Verner

**Työn nimi:** Osakekurssin ennustaminen LSTM-neuroverkon avulla

**Tutkintonimike:** Insinööri (AMK) Tieto- ja viestintätekniikka

**Asiasanat:** Tekoäly, koneoppiminen, neuroverkko, osakemarkkinat, ennustaminen

Tässä opinnäytetyössä kehitettiin LSTM-neuroverkko osakekurssin ennustamiseen. LSTM-neuroverkko on todettu monessa aiemmassa tutkimuksessa erityisen tehokkaaksi, kun ennustetaan osakemarkkinoiden tulevaisuuden hintoja. Tämän työn tavoitteena oli tutkia mallin suorituskykyä eri aikajäniteillä ja selvittää, miten lisämuuttujat, kuten HEX25 indeksin lisääminen vaikuttavat mallin ennustetarkkuuteen.

Opinnäytetyössä käytettiin koulutukseen viiden vuoden historiallista dataa kolmesta eri suomalaisesta osakkeesta sekä Helsingin pörssin HEX25 osakeindeksin dataa samalta ajanjaksolta. Ennusteita tehtiin yhden viikon, yhden kuukauden, kolmen kuukauden ja kuuden kuukauden ajanjaksoille käyttäen vain yksittäisen osakkeen dataa sekä käyttäen osakkeen ja HEX25 osakeindeksin dataa.

Mallin tuloksien arviointimenetelmänä työssä käytettiin keskimääräistä neliövirhettä (MSE) sekä keskimääräistä absoluuttista virhettä (MAE), jotka mahdollistavat ennusteiden kvantitatiivisen analysoinnin ja vertailun.

Tulokset osoittivat, että LSTM-malli pystyy mallintamaan osakekurssien kehityssuuntia kohtalaisella tasolla, mutta absoluuttista tarkkuutta tämän työn mallilla ei voi saavuttaa. HEX25 osakeindeksin lisääminen tuo parempia tuloksia, kun osakkeen hintoja ennustetaan pitkällä aikavälillä, kun taas lyhyellä aikavälillä indeksin lisääminen tuo jopa negatiivisia vaikutuksia mallin tuottamiin ennusteisiin. Tämä viittaa siihen, että indeksi auttaa mallia ymmärtämään laajempia taloudellisia suhdanteita ja yleisiä markkinatrendejä.

Tämä opinnäytetyö tarjoaa tietoa syväoppimisen soveltamisesta osakemarkkinoilla ja avaa mahdollisuuksia entistä tarkempien ja monipuolisempien ennustemallien kehittämiseksi.

## **Abstract**

**Author:** Komulainen Verner

**Title of the Publication:** Stock Price Prediction Using LSTM Neural Network

**Degree Title:** Bachelor of Engineering, Information and Communication Technology

**Keywords:** LSTM, artificial intelligence, stock market, neural network, forecast

In this thesis, an LSTM neural network was developed for stock price prediction. The LSTM neural network has been found in many previous studies to be particularly effective when predicting future prices of the stock market. The objective of this thesis was to study the performance of the model over different time spans and to find out how additional variables, such as addition of the HEX25 index, affect the forecast accuracy of the model.

In the thesis, five years of historical data from three different Finnish stocks, as well as data from the Helsinki Stock Exchange's HEX25 index from the same period, were used for training the model. Forecasts were made for periods of one week, one month, three months and six months using only individual stock data or using stock and HEX25 stock index data.

The mean square error (MSE) and the mean absolute error (MAE) were used as the evaluation method of the model's results in the work, which enable quantitative analysis and comparison of the predictions.

The results show that the LSTM model can forecast stock price trends at a moderate level, but absolute accuracy cannot be achieved with the model of this work. Adding the HEX25 stock index brings better results when stock prices are predicted over the long term, while adding an index in the short term even has negative effects on the predictions produced by the model. This suggests that the index helps the model understand broader economic cycles and general market trends.

This thesis provides information on the application of deep learning in the stock market and opens opportunities for the development of even more accurate and versatile forecasting models.

## **Alkusanat**

Tämä opinnäytetyö yhdistää kaksi intohimoani: osakemarkkinat ja tekoälyn. Osakekurssien ennustaminen on aina ollut haastavaa, mutta nopeasti kehittyvä teknologia tarjoaa uusia mahdollisuuksia lähestyä tätä kiehtovaa aihetta.

Finanssialan murros ja teknologian nopea kehitys ovat luoneet ainutlaatuisen ympäristön tutkia uusia lähestymistapoja ja ratkaisuja tähän kiehtovaan aiheeseen. LSTM-mallin kehitysprosessi on ollut paitsi opettavainen myös innostava, ja se on syventänyt käsitystäni tekoälyn mahdollisuuksista käytännön ongelmien ratkaisemisessa.

Toivon, että tämä työ tarjoaa uutta tietoa sekä sijoittamisen että tekoälyn soveltamisen aloilta ja toimii lähtökohtana uusille ideoille ja kehityssuunnille. Samalla toivon, että opinnäytetyö innostaa lukijoita pohtimaan teknologian roolia osakemarkkinoiden analysoinnissa ja sen tulevaisuuden mahdollisuuksia.

## Sisällys

1	Johdanto .....	1
2	Osakemarkkinat.....	2
2.1	Osakemarkkinoiden perusteet .....	2
2.2	Osakkeiden arvostus .....	3
2.3	Teknologian muutoksen merkitys osakemarkkinoilla.....	4
3	Syväoppiminen .....	5
3.1	Syväoppimisen perusteet.....	5
3.2	LSTM-neuroverkko .....	6
4	Data ja käsittely .....	7
4.1	Aineiston keräys .....	7
4.2	Työhön kerätty data .....	8
4.3	Datan käsittely.....	8
5	Malli ja kouluttaminen .....	10
5.1	LSTM-malli osakekurssin ennustamisessa.....	10
5.2	LSTM-mallin koulutus.....	11
5.3	Mallin optimointi.....	11
5.4	Mallin suorituskyvyn arviointi ja mittaaminen.....	12
6	Tulokset .....	13
6.1	Tulosten esittely .....	13
6.2	Analyysi ja tulkinta .....	16
6.3	Mahdolliset jatkotutkimukset .....	17

## Termit ja lyhenteet

LSTM	Lyhenne sanoista "Long Short-Term Memory". Pitkäkestoinen muisti-verkko on syväoppimisen algoritmi, joka on erityisen tehokas pitkäaikaisen riippuvuuksien mallintamisessa.
Neuroverkko	Tietojenkäsittelymalli, joka matkii ihmisen aivojen toimintaa ja kykenee oppimaan monimutkaisia malleja.
Algoritmi	Tietokoneohjelma tai prosessi, joka suorittaa tietyn tehtävän määriteltujen ohjeiden perusteella.
MSE	Lyhenne sanoista "Mean Squared Error".
MAE	Lyhenne sanoista "Mean Absolute Error".

## 1 Johdanto

Osakekurssien ennustaminen on innoittanut tutkijoita ja sijoittajia kehittämään tarkempia menetelmiä. Tässä opinnäytetyössä tarkastellaan, miten teknologian kehityksen myötä osakekurssien ennustaminen on muuttunut syväoppimisen näkökulmasta, erityisesti hyödyntämällä LSTM-neuroverkkoja. Finanssimarkkinoiden monimutkaisuus ja jatkuva muutos on asettanut perinteiset ennustamismenetelmät haasteeseen.

Aiemmissa tutkimuksissa LSTM-neuroverkot erottuvat edukseen erityisesti kyvyssään käsitellä pitkäaikaisia riippuvuuksia aikasarjoissa, mikä tekee niistä parhaan vaihtoehdon osakekurssien ennustamisessa [1]. Tämän opinnäytetyön tavoitteena on arvioida, miten syväoppiminen voi tuoda uusia mahdollisuuksia osakemarkkinoita seuraaville sijoittajille ja aiheesta kiinnostuneille ihmisille.

Tämän työn merkitys ulottuu omasta kiinnostuksestani sijoittamiseen ja sen maailmaan sekä ammatillisiin tavoitteisiini tietotekniikan osalta. Toivon, että tieto tästä aiheesta ei avaa vain uusia ovia henkilökohtaiselle kasvulleni, vaan myös tarjoaa arvokasta tietoa sijoittamisesta kiinnostuneille.

## 2 Osakemarkkinat

Tässä kappaleessa käsitellään osakemarkkinoiden perusteita sekä osakkeiden arvostusta, millä voidaan luoda vahva perusta myöhemmälle analyysille ja mallintamiselle. Kappaleessa käsitellään myös, miten teknologian nopea kehitys on vaikuttanut osakemarkkoihin ja tuonut uusia mahdollisuuksia osakemarkkinoiden tulkintaan. Tämä tieto on arvokasta, kun yritetään ymmärtää markkinoiden käyttäytymistä ja kehittää työkaluja niiden ennustamiseen.

### 2.1 Osakemarkkinoiden perusteet

Osakemarkkinat on rahoitusjärjestelmä, joka mahdollistaa sijoittajille arvopaperien ostamisen ja myymisen. Osakemarkkinat tarjoavat kaupankäyntiä pörsien kautta. Osake oikeuttaa omistukseen yrityksestä, joka mahdollistaa sijoittajalle tuottoa osinkojen tai yrityksen arvonnousun muodossa. Osakemarkkinat muodostuvat pörseistä esimerkiksi Suomessa on Helsingin pörssi ”OMX Helsinki” ja New Yorkissa on oma pörssi ”NYSE”. [2.]

Sijoittajalle osakemarkkinat tarjoaa mahdollisuutta osallistua yrityksen arvon kehitykseen taloudellisen riskin jakamiseen. Osakemarkkinoiden ymmärtäminen vaatii kuitenkin perehtymistä peruskäsitteisiin. Oleellisia rahoitusmarkkinoiden tehtäviä on arvopaperien ja erityisesti osakkeiden hinnoittelu. [3.]

## 2.2 Osakkeiden arvostus

Osakkeiden arvostuksen määräytyminen on monimutkainen prosessi, jossa yhdistyvät taloudelliset realiteetit, markkinapsykologia ja makrotaloudelliset tekijät. Suosittuja arvonmääritysmalleja ovat matemaattiset mallit, kuten osingon nykyarvomalli, jossa osakkeen arvostus lasketaan diskonttaamalla tulevaisuuden osingot nykyhetkeen, mikä auttaa määrittelemään, onko osake yli- vai aliarvostettu. Toinen tunnettu matemaattinen arvostuksen laskentamenetelmä on diskontatun kassavirran menetelmä, jossa arvioidaan yrityksen tuottamaa tulevaisuuden kassavirtaa ja diskontataan se nykyhetkeen. Sen avulla saadaan näkemys yrityksen taloudellisesta potentiaalista pitkällä aikavälillä. [4.]

Nopea teknologian kehitys on muuttanut osakkeiden arvon määräytymistä. Algoritmi-kauppa ja syväoppimisen menetelmät mahdollistavat suurten tietomäärien analysoinnin ja monimutkaisten markkinakuvioiden tunnistamisen. LSTM-mallit ovat hyödyllisiä, kun käsitellään aikasarjoja, kuten osakekurssien historiaa. Ne voivat havaita piileviä trendejä, joita ei välttämättä tunnisteta perinteisillä menetelmillä ja siten tuottaa tarkempia ennusteita osakemarkkinoiden tulevasta kehityksestä.

Vaikka taloudelliset mallit tuovat vahvan teoreettisen pohjan osakkeen arvon määrittämiseen, vaikuttavat osakkeiden arvostuksen muodostumiseen myös taloudelliset ja poliittiset olosuhteet. Arvon määräytymiseen vaikuttaa myös makrotaloudelliset tekijät, kuten inflaatio, korkotaso ja talouskasvu, jotka vaikuttavat yritysten kannattavuuteen ja sijoittajien halukkuuteen sijoittaa tiettyyn yritykseen. Esimerkiksi nouseva korkotaso voi nostaa yritysten lainanhoitokustannuksia, mikä heikentää yrityksen tulosta, jonka seurauksen osakekurssi voi laskea. Myös geopoliittiset riskit, kuten luonnonkatastrofit, pandemiat tai sodat, voivat vaikuttaa osakekursseihin, sillä ne lisäävät epävarmuutta sijoitusmarkkinoilla.

### 2.3 Teknologian muutoksen merkitys osakemarkkinoilla

Teknologian nopea kehittyminen on muuttanut myös osakemarkkinoita viime vuosikymmeninä. Vaikka teknologia on tuonut merkittäviä hyötyjä osakemarkkinoille, se on myös tuonut mukanaan uusia haasteita. Algoritmikaupan aiheuttama markkinoiden volatilitteetti on yksi suurimmista riskeistä. Lisäksi tekoälyn ja syväoppimismallien käyttö voi johtaa ennennäkemättömän nopeisiin ja odottamattomiin markkinareaktioihin, jos markkinat reagoivat samanaikaisesti lukuisien algoritmien tekemiin päätöksiin. Esimerkiksi vuonna 2010 tapahtui "Flash Crash", jossa tietokoneohjelmat tekevät kauppvoja automaattisesti ennalta määriteltujen kriteerien perusteella, minkä seurauksena tapahtui nopea mutta dramaattinen laskun osakekurseissa. [5].

Tekoälyn suosion kasvu ja erityisesti syväoppiminen ovat muuttaneet tapaa, jolla markkina-analysejä tehdään. Syväoppimismallit, kuten tässäkin opinnäytetyössä hyödynnetty LSTM-neuroverkko pystyy käsittelemään aikasarjatoja ja tunnistaa monimutkaisia kuvioita pitkän aikavälin osakkeiden kurssikehityksessä. LSTM-mallit pystyvät hyödyntämään historiallista dataa ja analysoimaan menneiden tapahtumien vaikutuksia tuleviin markkinakehityksiin. Tämän ansiosta ne voivat tehdä tarkempia ennusteita ja löytää markkinatrendejä, joita perinteiset mallit eivät havaitse.

### 3 Syväoppiminen

Syväoppiminen on koneoppimisen osa-alue, joka hyödyntää monikerroksisia neuroverkkoja monimutkaisten datarakenteiden oppimiseen ja analysointiin. Sen peruseriaatteena on se, että data kulkee useiden kerrosten kautta, jossa jokaisen kerroksen kohdalla malli oppii datasta yhä hienojakoisempia piirteitä. [6.]

#### 3.1 Syväoppimisen perusteet

Syväoppimisen juuret ulottuvat 1940-luvulle, jolloin Warren McCulloch ja Walter Pitts julkistivat ensimmäisen neuroverkkomallin. Neuroverkkojen kehitys eteni 1980-luvulla, jolloin oppimiskyky parani huomattavasti. Geoffrey Hinton, Yoshua Bengio ja Yann Le-Cun kehittivät takaisinkytkentäalgoritmin, jossa virheelliset ennusteet palautetaan verkkoon ja mallin painoja päivitetään, jotta seuraava ennuste on tarkempi. Kuitenkin vasta myöhemmin 2000-luvulla vuoden 2012 Alex-Net-mallin läpimurron myötä, syväoppimisesta tuli keskeinen osa monia käytännön sovelluksia. [7.]

Syväoppimisen vahvuus perustuu sen kykyyn käsitellä suuria tietomääriä ja oppia monimutkaisia kuvioita. Tämän mahdollistaa verkkojen kerroksellisuus ja takaisinkytkentäalgoritmi. Käytännön sovelluksissa syväoppiminen on mullistanut esimerkiksi lääketieteellisen kuvantamisen, jossa sen avulla voidaan havaita syövän kaltaisia sairauksia niiden aikaisessa vaiheessa. Lisäksi syväoppimista hyödynnetään luonnollisen kielen käsittelyssä, jossa mallit pystyvät analysoimaan tekstin merkitystä ja rakennetta tarkemmin. [7.]

Syväoppimista on hyödynnetty laajasti myös taloudellisessa analyysissä, kuten osakekurssien ennustamisessa. Osakemarkkinat ovat monimutkainen järjestelmä, jossa osakkeiden hinnat riippuvat useista muuttujista ja pitkän aikavälin riippuvuuksista. Perinteiset neuroverkot, kuten rekursiiviset neuroverkot (RNN) eivät pysty tehokkaasti käsittelemään tällaisia aikasarjoja, koska niihin liittyy häviävän gradientin ongelma, jossa pitkän aikavälin riippuvuudet häviävät, kun dataa ajetaan monien kerrosten läpi. [8.]

### 3.2 LSTM-neuroverkko

Hochreiter ja Schmidhuber kehittivät LSTM-neuroverkon, jossa on erityinen muistiyksikköjen rakenne. Tämä rakenne mahdollistaa informaation säilyttämisen pidempään sekä hallitsee, mitä tietoa päivitetään ja mitä unohdetaan. LSTM käyttää kolmeporttista rakennetta sisääntulo-, unohtamis- ja ulosmenoporttia, jotka auttavat säilyttämään olennaiset tiedot ja poistamaan epäolennaiset. Tämä tekee LSTM-mallista erityisen tehokkaan silloin, kun analysoidaan pitkiä aikasarjoja tai monimutkaisia riippuvuuksia. [9.]

LSTM-neuroverkon avulla voidaan ratkaista RNN-verkkojen perinteisen heikkouden eli häviävän gradientin ongelman. Ongelma ilmenee, kun neuroverkko yrittää oppia pitkän aikavälin riippuvuuksia ja signaalit heikkenevät, kun ne kulkevat monien kerroksien läpi. Tämä johtaa siihen, että malli ei pysty muistamaan ja hyödyntämään pitkän aikavälin tietoa tehokkaasti. [8].

LSTM-neuroverkot, jotka ovat kehitetty ratkaisemaan häviävän gradientin ongelman, mahdollistavat pitkän aikavälin tietojen säilyttämisen ja hyödyntämisen osakekurssien ennustamisessa. [9]. LSTM-verkot soveltuvat erityisen hyvin aikasarjojen analysointiin, sillä ne pystyvät oppimaan, mitkä tiedot ovat olennaisia tulevien hintamuutosten ennustamiseksi ja mitkä tiedoista eivät ole olennaisia ja voidaan unohtaa pois koulutuksesta. Tämän vuoksi LSTM-neuroverkkoja on hyödynnetty laajasti osakemarkkinoiden ennustamisessa. Niiden on todettu parantavan ennusteiden tarkkuutta verrattuna perinteisiin menetelmiin. [10].

Osakemarkkinoilla pitkän aikavälin riippuvuuksien ymmärtäminen on tärkeää. LSTM-verkkojen kyky oppia, mitkä tiedot ovat oleellisia ja mitkä eivät, auttaa mallia tekemään parempia ennusteita. Näin ollen LSTM-verkkojen rooli osakekurssien ennustamisessa perustuu niiden kykyyn säilyttää ja hyödyntää pitkiä ajallisia riippuvuuksia, minkä ansiosta se on parempi vaihtoehto osakekurssien ennustamisessa verrattuna perinteisiin rekursiivisiin neuroverkkoihin. [1.]

## 4 Data ja käsittely

Tässä kappaleessa keskitytään datan keräykseen ja käsittelyyn. Data on koneoppimisprojektin ydin ja määrittää pitkälti, kuinka hyvin malli pystyy oppimaan ja tekemään ennusteita. Datan keruu ja esikäsittely ovat tärkeitä vaiheita, jotka vaikuttavat opinnäytetyön lopputulokseen. Tässä opinnäytetyössä käytettävä tutkimusaineisto koostuu historiallisista osakekurseista, jotka kerätään Yahoo Finance -palvelusta, joka tarjoaa laajoja aikasarjadatointa osakemarkkinoilta.

### 4.1 Aineiston keräys

Tässä opinnäytetyössä data haetaan Yahoo Financen tietokannasta python-kirjasto Yfinancen avulla. Yfinance-kirjasto sisältää tämän opinnäytetyön kannalta riittävän laajat ja helppokäyttöiset rajapinnat osakedatan hakemiseen. Muitakin kirjastoja osakedatan hakemiseen on olemassa, mutta valitsin Yfinancen tähän opinnäytetyöhön, sillä sen kautta saatava data pystyttiin hyödyntämään sellaisenaan, ilman konversioita tai datan tallentamista tiedostoon välissä. Toinen tärkeä syy Yahoo Financen tietokannan käyttöön oli maksuton suomalaisen osakedatan saatavuus, sillä monet muut palvelut tarjoavat vain Yhdysvaltojen pörssien dataa maksutta. [11.]

Käyttämällä Yahoo Finanea datalähteenä varmistetaan pääsy luotettavaan ja kattavaan aikasarjadatamateriaaliin, joka kattaa tarvittavat ajanjaksot opinnäytetyön kannalta. Tämä mahdollistaa mallin ymmärtämisen ja osakemarkkinoiden monimutkaisten dynamiikkojen ennustamisen. Yahoo Financen tarjoamat tiedot auttavat myös varmistamaan, että data on laadukasta, mikä on kriittistä tarkkojen ja luotettavien ennusteiden tuottamisessa.

#### 4.2 Työhön kerätty data

Dataa on kerätty kolmesta suomalaisesta osakkeesta, joita ovat Neste, Nokia sekä Keskon b-sarjan osake. Lisäksi mukana on myös Helsingin pörssin OMX25 indeksi. Haetusta datasta käytettiin ennustamiseen päivän sulkuhinta("Close") sekä päivittäisen kaupankäynnin volyyymi ("Volume"). Lisäksi mallin suorituskykyä on tarkoitettu vertailla, kun lisätään OMX25 indeksi mukaan koulutusvaiheeseen, kerätään dataa myös OMX25 osakeindeksistä jokaista osaketta ja indeksiä kohti haettiin dataa aikaväliltä 1.1.2018–28.6.2024.

#### 4.3 Datan käsittely

Kun data on haettu Yahoo Financesta, se esikäsitellään. Tässä vaiheessa valitaan vain tarvittavat sarakkeet "Date", joka tuo päivämäärän ja "Close", joka kertoo osakkeen markkina-arvon päivän lopussa sekä "Volume", joka kertoo päivittäisen kaupankäyntimäärän, joka antaa tietoa siitä, kuinka aktiivisesti osakkeella on käyty kauppaa. Käytetty data on kuvattu taulukossa 1.

Osake	Date	Close	Volume
NESTE	28.6.2024	16,625	1721651
NESTE	27.6.2024	16,78	986332
NESTE	26.6.2024	16,71	1151565
NESTE	25.6.2024	16,855	1325519
NESTE	24.6.2024	16,785	3399949
NESTE	20.6.2024	17,045	4353844
NESTE	19.6.2024	16,635	3078070
NESTE	18.6.2024	17,65	1393096
NESTE	17.6.2024	17,44	1673601
NESTE	14.6.2024	17,79	1434665
NESTE	13.6.2024	18,03	1376650
NESTE	12.6.2024	18,45	864609
NESTE	11.6.2024	18,55	966071
NESTE	10.6.2024	18,555	1202916

Taulukko 1.

Data jaetaan koulutus- ja testiosioihin. Jako tehdään siten, että mallin koulutukseen käytössä oleva data on 1.1.2018–31.12.2023, jolloin testattavaksi jää data 1.1.2024–28.6.2024. Jaon avulla saadaan mallille riittävästi dataa koulutusjaksolle, mutta voidaan kuitenkin verrata ennustettuja hintoja toteutuneisiin osakekurssien hintoihin alkuvuodelle 2024. Taulukossa 2 on esitelty datan jako.

Data	Alku (pvm)	Loppu (pvm)	Tavoite
Koulutus (Train)	1.1.2018	31.12.2023	Kouluttaa malli
Testi (Test)	1.1.2024	30.6.2024	Testata mallin suorituskyky

Taulukko 2.

Datan skaalaus on yksi tärkeimmistä esikäsittelyvaiheista. Tässä työssä on käytössä MinMaxScaler-funktiota, joka skaalaa datan arvot välille 0 ja 1. Skaalaus parantaa neuroverkon oppimista ja auttaa estämään mallin vääristymistä suurten arvojen vaikutuksesta.

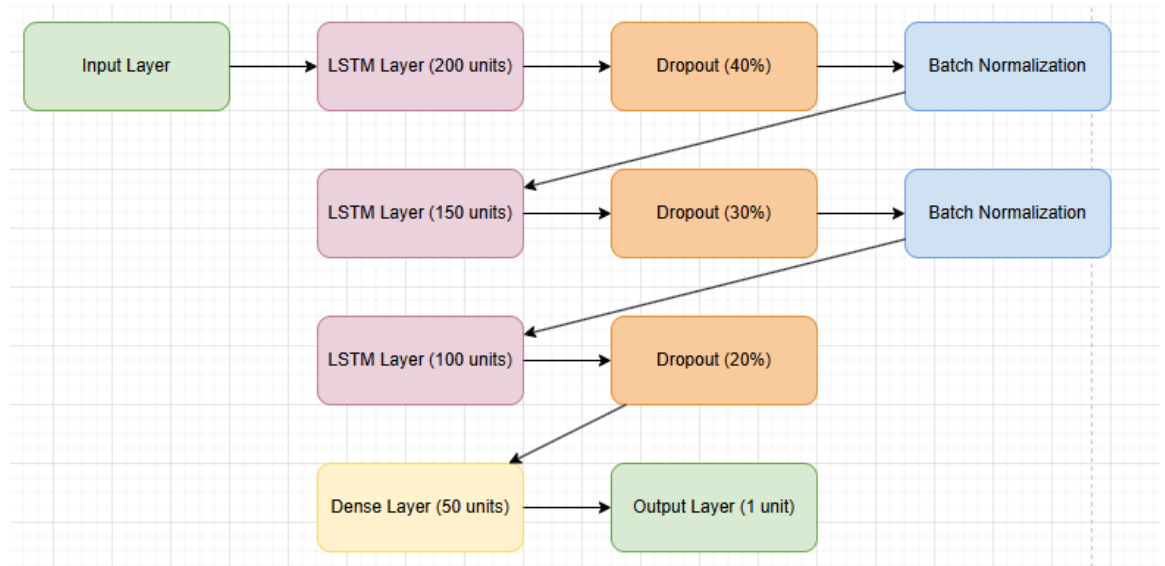
LSTM-mallin syötteenä käytetään 180 päivän liukuvaa ikkunaa. Tämä tarkoittaa, että mallille syötetään aina 180 peräkkäisen päivän tiedot (päätošhinta ja volyyymi), joiden perusteella malli pyrkii ennustamaan seuraavan päivän päätöshinnan.

## 5 Malli ja kouluttaminen

Tässä kappaleessa on tarkoitus käsitellä LSTM-neuroverkkoa ja miten sitä on hyödynnetty tässä oppinäytetyössä. Kappaleen on tarkoitus tuoda lukijalle perustason ymmärryksen kyseisestä neuroverkosta ja sen koulutuksen vaiheista.

### 5.1 LSTM-malli osakekurssin ennustamisessa

LSTM-neuroverkon koulutus osakekurssin ennustamisessa perustuu sen kykyyn hyödyntää ja analysoida pitkän aikavälin riippuvuuksia aikasarjadatasta. Mallin ytimen muodostaa LSTM-kerrokset, joiden erityispiirre on ”muistiyksiköt”, jotka käsittelevät syötedataa kolmen eri portin kautta. Nämä portit ovat sisääntulo-, unohtamis- ja ulostuloportit. Näiden porttien avulla malli pystyy säilyttämään relevanttia tietoa ja unohtamaan epäolennaisen tiedon. Kyseisten porttien ansiosta LSTM-malli on erityisen tehokas taloudellisten aikasarjojen analysoinnissa, sillä ne tunnistavat pitkäaikaisia riippuvuuksia ja monimutkaisia trendejä, jotka ovat tyypillisiä osakemarkkinoilla. [9.]



Kuva 1. Käytetyn neuroverkon kuvaus.

Mallin liukuva ikkuna mahdollistaa myös reaaliaikaisen päivittymisen, jolloin malli hyödyntää aina uusimman saatavilla olevan datan ja tarjoaa jatkuvasti ajantasaisia ennusteita. Näiden ominaisuuksiensa ansiosta LSTM on osoittautunut useissa tutkimuksissa tehokkaammaksi kuin esimerkiksi RNN-, GRU- tai CNN-mallit osakemarkkinadatan ennustamisessa.

## 5.2 LSTM-mallin koulutus

LSTM-mallin koulutuksen syötteenä käytetään historiallisia osakekurssien päätöshintoja. Tässä tutkimuksessa mallia on koulutettu viiden vuoden päivittäisellä kurssidatalla, mikä mahdollistaa mallille riittävän pitkän ajanjakson tunnistaa osakemarkkinoilla tapahtuvia trendejä ja kausivaihteluita. [6.]

Aineisto skaalataan MinMaxScalerin avulla, jotta datasta tulee mallille helpommin käsiteltävää. Tämän jälkeen data jaetaan 180 päivän mittaisiksi liukuviksi ikkunoiksi, joissa jokaisessa ikkunassa viimeinen luku on seuraavan päivän päätöskurssi. Liukuvan ikkunan käyttö ennustamisessa tarkoittaa, että mallin syöteikkuna siirtyy yhden päivän eteenpäin jokaisen ennusteen jälkeen, jolloin malli ennustaa jokaisen päivän osakekurssin käyttäen aina uusinta dataa [6].

Pitkän aikavälin datalla varmistetaan, että malli oppii laajat markkinanäkemykset ja trendit. Kun taas lyhyen aikavälin data tuo ennustusvaiheessa tarkemmat ja ajankohtaisemmat ennusteet. Tätä yhdistelmää, jossa voidaan käyttää viiden vuoden dataa mallin kouluttamiseen ja 180 vuorokauden liukuvaa ikkunaa ennustamiseen. Tämä varmistaa sen, että malli hyödyntää niin pitkän että lyhyen aikavälin piirteitä.

## 5.3 Mallin optimointi

Mallin optimointiin käytettiin Nadam-algoritmia, joka dynaamisesti säätää mallin oppimisnopeutta koulutusten aikana. Nadam yhdistää perinteisemmän Adamin ja Nesterovin kiihtyvyyden vahvuudet nopeuttaakseen ja vakauttaakseen oppimisprosessia. Nadam tuo mukana niin Adamin mukautuvan oppimisnopeuden, että Nesterovin kiihdytyksen ennakoivan laskentatavan.

Adam perustuu kahteen liukuvaan keskiarvoon: ensimmäinen keskittyy gradientin arviointiin ja toinen laskee varianssin, mikä tasoittaa oppimista erityisesti vaihtelevien gradienttien osalta. [12]. Nesterovin kiihtyvyys taas parantaa mallin reagointikykyä tekemällä ennakoivan laskelman

seuraavasta pisteestä, mikä auttaa suuntaamaan oppimista tehokkaammin ja estää sen jumitu-  
mista paikallisiin minimeihin, joka on tyypillinen ongelma syväoppimisessa [11]. Nadam toimii hy-  
vin sekventiaalisen datan analysoinnissa ja on suosittu erityisesti LSTM-verkkojen yhteydessä, ku-  
ten osakekurssien ennustamisessa, sillä se sopeutuu dynaamisesti uusiin oppimistilanteisiin,  
minkä ansiosta se voi optimoida painoja vakaammin ja tarkemmin monimutkaisessa ei-lineaari-  
sessa datassa. Mallissa hyödynnetään MSE-lukemaa loss-funktiossa. Optimoinnin tarkoitus on vä-  
hentää MSE-lukemaa jokaisessa koulutusvaiheessa säätämällä mallin painoja ja parametrejä.

Koulutuksen aikana käytettiin Early Stopping -menetelmää, joka estää mallin ylisovittamisen.  
Early Stopping tunnistaa, kun mallin suorituskyky ei parane ja lopettaa kouluttamisen. Early Stop-  
pingin lisäksi mallissa on käytössä Dropout-kerrokset, jonka perusidea on poistaa satunnaisesti  
tietty määrä neuroneja jokaisen koulutusvaiheen aikana. Valitut neuronit jätetään tilapäisesti  
pois laskennasta kyseisellä koulutusajolla, jolloin verkko ei voi riippua liikaa yksittäisistä neuro-  
neista ja niiden yhteyksistä. Ylikouluttamisen estäminen on erityisen tärkeää osakemarkkinoiden  
ennusteissa, sillä ylikoulutettu malli voi olla tarkka koulutusdatassa, mutta uudessa ennusteessa  
toistaa identtistä kehitystä historian kanssa. [4.]

#### 5.4 Mallin suorituskyvyn arviointi ja mittaaminen

Tässä työssä mallin tarkkuutta mitataan kahdella virhemittareilla, jotka ovat keskineliö-virheellä  
(MSE) ja keskivirheellä (MAE). Nämä antavat käsityksen mallin tarkkuudesta suhteessa toteutu-  
neisiin arvoihin. MSE mittaa keskimääräistä neliöityä eroa ennustettujen ja todellisten arvojen  
välillä korostamalla suurempia virheitä neliöimällä jokaisen yksittäisen virheen, kun taas MAE las-  
kee virheiden keskiarvon ottamalla kunkin ennusteen ja todellisen arvon erotuksen itseisarvon ja  
keskiarvottamalla ne. Tämä antaa tasapainoisen arvion virheestä korostamatta erityisesti suuria  
virheitä. Tässä työssä näitä mittareita käytetään varmistamaan, että malli ei ennusta poikkeavan  
suuria tai pieniä arvoja, vaan yleistää tuloksensa tasapainoisesti. [15.]

## 6 Tulokset

Tässä kappaleessa esitetään neuroverkon saavuttamat tulokset. Työn tarkoitus on tutkia miten HEX25 indeksin lisääminen yksittäisten osaketietojen lisäksi, miten koulutusvaiheessa vaikuttaa yksittäisen osakkeen ennustettuihin hintoihin.

### 6.1 Tulosten esittely

Ennusteita tuotetaan siis kolmen eri osakkeen hinnoista, joita ovat Nokia, Neste ja Keskon B-sarjan osake. Koulutuksessa on käytetty dataa aikaväliltä 1.1.2018–31.12.2023. Mallin tuottamien tulosten vertailuun käytettävä data on aikaväliltä 1.1.2024–28.6.2024.

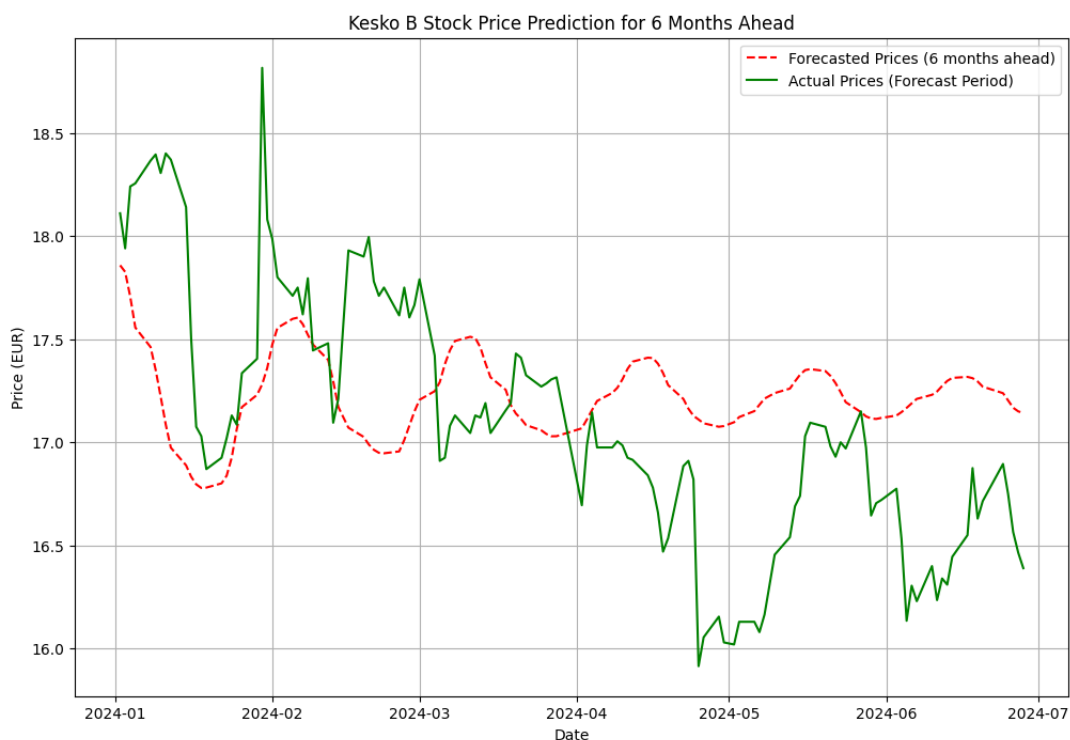
Ennusteet on rakennettu siten, että sieltä löytyy jokaisesta osakkeesta niin viikon, kuukauden, kolmen kuukauden ja kuuden kuukauden ennusteet, joiden avulla voidaan vertailla, miten mallin luomat ennusteet pitävät paikkaansa.

Mallin ennusteiden tulokset (Taulukko 3). MSE ja MAE kuvaavat mittareina ennusteen ja todellisen hinnan välistä virhettä, joten mitä pienempi tulos on, sitä parempi ennusteen tarkkuus on. Kuvassa muutettu aina parempi arvo vihreäksi ja heikompi arvo punaiseksi, vertailukohteina malli pelkällä osakkeella ja osake ja HEX25 indeksi.

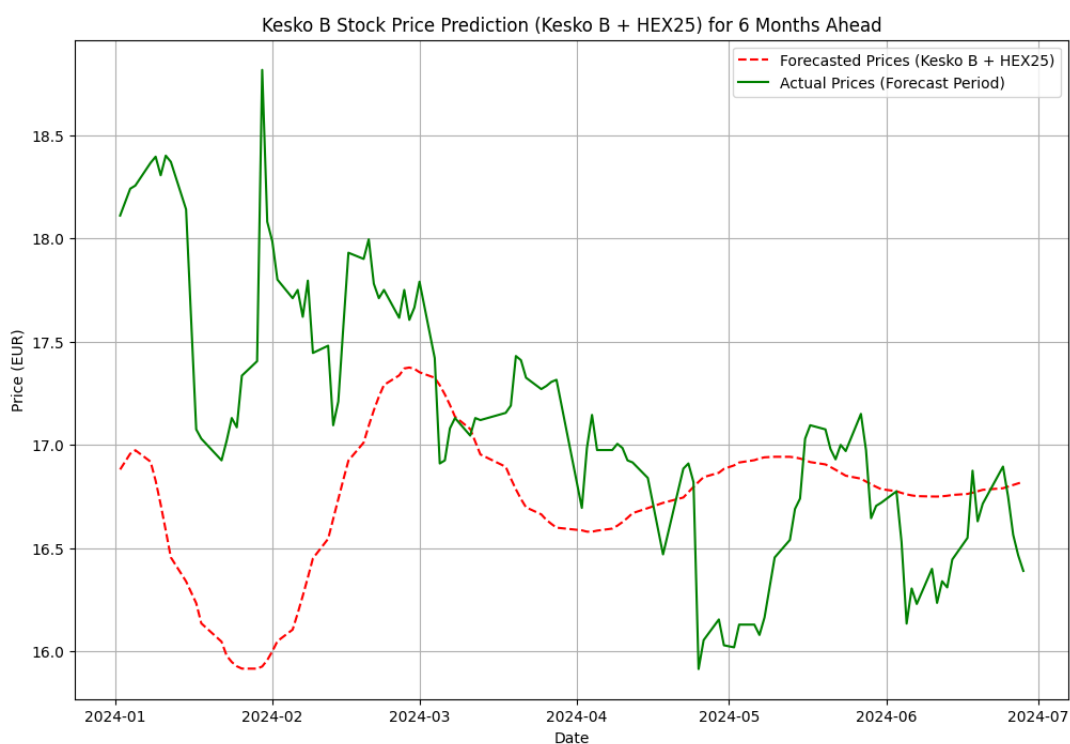
Lisäksi tuloksista (Kuva 2, Kuva 3) kuvastaa osakkeen ennustetun hinnan ja toteutuneen hinnan erotusta kuuden kuukauden ajanjaksolta, ja se antaa visuaalisen näkemyksen siitä, miten tuotama ennuste eroaa tapahtuneista hinnoista. Kuvista voi myös erottaa miten HEX25 indeksin lisääminen koulutukseen muuttaa ennustetta.

1VIIKKO	MSE	MAE
NOKIA 1 VIIKKO	0,0008	0,0229
NESTE 1 VIIKKO	0,0819	0,2203
KESKO B 1 VIIKKO	0,2358	0,4679
NOKIA+HEX 1 VIIKKO	0.0039	0.0613
NESTE+HEX 1VIIKKO	1,5855	1,2114
KESKOB+HEX 1VIIKKO	1,6464	1,2814
1KK	MSE	MAE
NOKIA 1KK	0,0199	0,0965
NESTE 1KK	0,3463	0,5077
KESKO B 1KK	0,3397	0,4962
NOKIA+HEX 1KK	0,0234	0,1036
NESTE+HEX 1KK	15,3173	3,6317
KESKOB+HEX 1KK	1,4935	1,116
3KK	MSE	MAE
NOKIA 3KK	0,0405	0,1825
NESTE 3KK	8,1979	2,3985
KESKO B 3KK	0,471	0,5303
NOKIA+HEX 3KK	0,0209	0,1229
NESTE+HEX 3KK	14,2015	3,3712
KESKOB+HEX 3KK	1,2103	0,9785
6KK	MSE	MAE
NOKIA 6KK	0,1473	0,3507
NESTE 6KK	33,8064	4,6932
KESKO B 6KK	0,3949	0,5231
NOKIA+HEX 6KK	0,0532	0,187
NESTE+HEX 6KK	45,1177	5,5018
KESKOB+HEX 6KK	0,7061	0,6315

Taulukko 3.



Kuva 2 Keskon B osakkeen mallin ennustus kuuden kuukauden ajanjaksolle, kun HEX indeksi ei ole mukana.



Kuva 3 Keskon B osakkeen mallin ennustus kuuden kuukauden ajanjaksolle, kun HEX25 indeksi on mukana.

## 6.2 Analyysi ja tulkinta

Ennustuksista käy ilmi, että osakemarkkinoiden ennustaminen on haastavaa, eikä absoluuttisen tarkka ennustaminen onnistu pelkästään historiallisten hintatietojen ja volyymien avulla. Yleisesti saatujen tulosten valossa voidaan todeta, että lyhyellä aikavälillä ennustaessa markkinaindeksiin lisääminen koulutusvaiheessa ei paranna tarkkuutta, vaan päinvastoin. Tämä johtuu siitä, että yksittäisen osakkeen lyhyen aikavälin arvovaihteluun vaikuttavat usein yrityskohtaiset tekijät, kuten tulosjulkistukset sekä uutiset, jotka koskevat tiettyä yritystä tai toimialaa.

Ennusteen pidentyessä myös yleisen markkinaindeksiin mukaan ottaminen ennusteen luomiseen tuo vakautta ja parantaa ennusteen tarkkuutta. Markkinaindeksi heijastaa laajemmin yleisiä markkinatrendejä ja talouden suhdanteita, jotka usein vaikuttavat yksittäisten osakkeiden kehitykseen. Indeksien mukanaolo auttaa mallia huomioimaan makrotalouden vaikutukset osakekursseihin erityisesti pidemmän aikavälin ennusteissa, joissa yksittäisten osakkeiden historiallinen kehitys ei välttämättä yksin riitä selittämään tulevia muutoksia.

Tulosten perusteella voidaan todeta, että lyhyellä aikavälillä on järkevämpää pitäytyä pelkästään yksittäisen osakkeen tietoihin ja jättää markkinaindeksi pois koulutuksesta. Markkinaindeksiin mukaan ottaminen mallin koulutukseen kannattaa, kun tarkoitus on tuottaa pidemmän aikavälin ennustetta. Silloin mukaan voidaan ottaa yleiset markkinasuhdanteet ja trendit, jotka vaikuttavat selkeämmin myös yksittäisiin osakkeisiin.

### 6.3 Mahdolliset jatkotutkimukset

Tämä herättää mielenkiintoisia ajatuksia aiheen ympärille sekä mahdollisuuksia jatkotutkimukselle. Tutkimusaiheita voisivat olla reaaliaikaisen uutisdatan ja ESG-datan hyödyntäminen syväoppimismalleissa, mitkä tarjoaisivat merkittäviä mahdollisuuksia osakemarkkinoiden ennustamisessa.

Luonnollisen kielen käsittely (NLP-mallien) integrointi LSTM-malleihin voisi avata täysin uusia mahdollisuuksia hyödyntää uutisotsikoiden ja artikkeleiden sentimenttianalyysiä markkinoiden käyttäytymisen ymmärtämisessä. Esimerkiksi yritysten tulosraportit, poliittiset päätökset tai makrotaloudelliset muutokset voivat vaikuttaa markkinoihin hyvin nopeasti. NLP-mallien avulla LSTM voisi ottaa huomioon suuria määriä tekstidataa, joka syötetään ennustemalliin, mikä mahdollistaisi entistä tarkemmat ja nopeammat ennusteet.

Toinen mahdollinen jatkotutkimuksen kohde voisi olla ESG-datan (Environmental, Social, Governance) integrointi osakekurssien ennustemalleihin. ESG-kriteerit ovat nousseet keskeisiksi tekijöiksi sijoittajien päätöksenteossa, ja ne heijastavat yrityksen kestävästä kehitystä, sosiaalista vastuullisuutta ja hallintotapoja. Näiden tietojen hyödyntäminen voisi lisätä mallin kykyä tehdä pitkän aikavälin ennusteita, joissa huomioidaan kestävästä kehityksen suuntaukset ja niiden vaikutukset yritysten arvoon. ESG-datan avulla LSTM voisi yhdistää perinteiset taloudelliset indikaattorit vastuullisuusnäkökulmiin, mikä tarjoaisi uudenlaisen ja kattavamman kuvan markkinoiden dynamiikasta.

## Lähteet

- 1 Hoikkala K. Osakekurssien ennustaminen koneoppimisen menetelmillä. Julkaisuvuosi 2021 Saatavilla: URN:NBN:fi: jyu-202111025476.pdf
- 2 Chen, J. (2005). Investopedia. Haettu 2.11.2024 osoitteesta <https://www.investopedia.com/terms/s/stockmarket.asp>
- 3 Hämäläinen Karo ja Jukka Oksaharju. 2016. Sijoita kuin guru. Hansaprint.
- 4 Hiransha M, Gopalakrishnan E.A., Vijay Krishna Menon, Soman K.P. (2016) NSE Stock Market Prediction Using Deep-Learning Models haettu 15.9.2024 osoitteesta [main.pdf](#)
- 5 Zuss, N. (2021). IFLR. Haettu 8.10.2024 osoitteesta <https://www.iflr.com/article/b1sjckt2md0cg2/primer-high-frequency-trading>
- 6 Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep Learning. MIT Press.
- 7 LeCun, Bengio & Hinton, 2015 Haettu 9.10.2024 osoitteesta [https://www.researchgate.net/publication/277411157\\_Deep\\_Learning](https://www.researchgate.net/publication/277411157_Deep_Learning)
- 8 Graves, 2012 Supervised Sequence Labelling with Recurrent Neural Networks. haettu 12.10.2024 osoitteesta <https://www.cs.toronto.edu/~graves/preprint.pdf>
- 9 Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. Neural Computation
- 10 Bao, W., Yue, J., & Rao, Y. (2017). A deep learning framework for financial time series using LSTM networks. Expert Systems with Applications. haettu 10.10.2024 osoitteesta <https://journals.plos.org/plosone/article?id=10.1371/journal.pone.0180944>
- 11 Yahoo Finance - Stock Market Live, Quotes, Business & Finance News [Internet]. Saatavilla: <https://finance.yahoo.com>
- 12 Kingma & Ba, 2015 haettu 14.9.2024 osoitteesta <https://arxiv.org/pdf/1412.6980>
- 13 Dozat, 2016 haettu 14.9.2024 osoitteesta <https://openreview.net/pdf?id=OM0jvwB8jlp57ZjtNEZ>

- 14 Kallunki, Juha-Pekka & Martikainen, Minna & Niemelä, Jaakko 2019. Ammattimainen sijoittaminen. Alma Talent, Helsinki.
- 15 Timothy O. Hodson Root-mean-square error (RMSE) or mean absolute error (MAE): when to use them or not. Haettu 7.11.2024 osoitteesta <https://gmd.copernicus.org/articles/15/5481/2022/gmd-15-5481-2022-discussion.html>