

TALLINNA TEHNIKAÜLIKOOL
Infotehnoloogia teaduskond
Tarkvarateaduse instituut

Lauri Ülper 153521IABM

**USA JA TALLINNA BÖRSI ETTEVÕTETE
AKTSIATE SULGEMISHINDADE
ENNUSTAMINE ENNUSTUSMUDELIGA**

Magistritöö

Juhendaja: Ahti Lohk
Doktor

Tallinn 2017

Autorideklaratsioon

Kinnitan, et olen koostanud antud lõputöö iseseisvalt ning seda ei ole kellegi teise poolt varem kaitsmisele esitatud. Kõik töö koostamisel kasutatud teiste autorite tööd, olulised seisukohad, kirjandusallikatest ja mujalt pärinevad andmed on töös viidatud.

Autor: Lauri Ülper

08.05.2017

Annotatsioon

Käesoleva töö eesmärk on rakenda aktsiate hinnasuuna ennustusmodelit USA aktsiaturu üheksa suurima turuväärtusega ettevõtte ning Tallinna börsil noteeritud ettevõtete vahel. Ennustusmodel kasutab masinõppe meetodit, mis võtab algandmetena arvesse aktsiate mineviku sulgemishindu (2010-2017), et selle põhjal ennustada tuleviku sulgemishindu.

Mainitud eesmärgi saavutamiseks tehakse teoreetiline tutvustus teemasse ja kogutakse kokku algandmed. Järgnevalt luuakse keskkond ehk installitakse uuringuks vajaminevad paketid ning seejärel rakendatakse ennustusmodelit valitud ettevõtete andmetel nii USA-st kui ka Tallinna börsilt.

Töö põhitulemuseks on ennustusmodeli toimimise võrdlemine kahel erineval turul ning ennustusmodeli hindamine. Kokkuvõttes annab töö autor omapoolsed soovitused tulevikuks.

Lõputöö on kirjutatud eesti keeles ning sisaldab teksti 81 leheküljel, 3 peatükki, 35 joonist, 48 tabelit.

Abstract

USA and Tallinn stock exchange companies stocks closing price prediction with prediction model

The purpose of this thesis is to apply a stock price prediction model to the nine biggest market capitalization companies listed on the USA stock market and on companies trading on the Tallinn stock exchange. The prediction model uses a machine learning method that takes into account previous stock closing prices (period 2010-2017) to predict closing prices.

To achieve this goal, a theoretical introduction to the topic is made after which the author collects initial data. Next, an environment is created, where necessary libraries like Keras and Tensorflow are installed. The prediction model is applied on USA and Tallinn stock exchange listed companies.

The main outcome of this thesis is a comparison of the performance of the prediction model on two different markets and an evaluation of that model. In the concluding part the author gives his recommendations for future research.

The thesis is in Estonian and contains 81 pages of text, 3 chapters, 35 figures, 48 tables.

Lühendite ja mõistete sõnastik

RNN	Rekurrentne närvivõrk
LSTM	Pikk lühiajaline mälu
SVM	Toetusvektor masin

Sisukord

Sissejuhatus	11
1 Efektiivse turu mõiste ja olemus	13
1.1 S&P 500 indeksi tutvustus.....	14
1.2 Tallinna börs	16
1.3 Masinõpe	16
1.3.1 Rekurrentsed närvivõrgud	18
1.3.2 LSTM	20
1.4 Keras.....	22
1.5 Tensorflow.....	22
1.6 Python ja Matplotlib	23
2 Uuringu tutvustus	24
2.1 Antud valdkonna varasemad uuringud.....	25
2.2 S&P 500 indeksisse kuuluvad uuringus osalevad ettevõtted.....	26
2.3 Tallinna börsinimekirjas olevad uuringusse kuuluvad ettevõtted	28
3 Uuringu läbiviimine.....	32
3.1 USA ettevõtete tulemused	34
3.1.1 USA aktsiaturu uuringutulemuste kokkuvõte	49
3.2 Tallinna börsi ettevõtete tulemused.....	50
3.2.1 Tallinna börsi uuringutulemuste kokkuvõte.....	69
3.3 Uuringutulemuste võrdlemine	70
3.4 Esinenud probleemid	71
3.5 Hinnang ennustusmodelile	73
3.6 Järeldused ja ettepanekud	74
Kokkuvõte	75
Summary.....	77
Kasutatud kirjandus	79
Lisa 1 – Pakettide installimine ja keskkonna loomine	82
Lisa 2 – Graafikute koordinaadid	88

Jooniste loetelu

Joonis 1. S&P 500 ajalooline graafik (Macrotrends)	15
Joonis 2. RNN-l on silmused	18
Joonis 3. Lahti rullunud RNN	19
Joonis 4. RNN on ketilaadne	19
Joonis 5. Jada	20
Joonis 6. Kordusmoodul	20
Joonis 7. LSTM kordusmoodul sisaldab nelja suhtlevat kihti	21
Joonis 8. LSTM suudab lisada või eraldada informatsiooni	21
Joonis 9. Sigmoidfunktsioon	22
Joonis 10. Ennustusmudel S&P 500 aktsiaindeksi näitel	25
Joonis 11. Ennustusmudeli kood	33
Joonis 12. Apple ennustusmudel graafiliselt	35
Joonis 13. Microsoft ennustusmudel graafiliselt	37
Joonis 14. Exxon Mobil ennustusmudel graafiliselt	39
Joonis 15. Johnson & Johnson ennustusmudel graafiliselt	40
Joonis 16. Berkshire Hathaway ennustusmudel graafiliselt	42
Joonis 17. JP Morgan Chase ennustusmudel graafiliselt	43
Joonis 18. Amazon ennustusmudel graafiliselt	45
Joonis 19. General Electric ennustusmudel graafiliselt	46
Joonis 20. AT&T ennustusmudel graafiliselt	48
Joonis 21. Arco Vara ennustusmudel graafiliselt	50
Joonis 22. Baltika ennustusmudel graafiliselt	52
Joonis 23. Ekspress Grupp ennustusmudel graafiliselt	53
Joonis 24. Harju Elekter ennustusmudel graafiliselt	55
Joonis 25. Merko Ehitus graafiliselt	56
Joonis 26. Nordecon ennustusmudel graafiliselt	58
Joonis 27. Olympic Entertainment Group ennustusmudel graafiliselt	59
Joonis 28. PRFoods ennustusmudel graafiliselt	61
Joonis 29. Silvano Fashion Group ennustusmudel graafiliselt	62

Joonis 30. Skano ennustusmudel graafiliselt.....	64
Joonis 31. Tallink ennustusmudel graafiliselt.....	65
Joonis 32. Tallinna Kaubamaja ennustusmudel graafiliselt.....	67
Joonis 33. Tallinna Vesi ennustusmudel graafiliselt	68
Joonis 34. Apple ennustusmudel esimesel korral	71
Joonis 35. Apple ennustusmudel teisel korral.....	72

Tabelite loetelu

Tabel 1. Suurimad osalusprotsendid indeksis (ishares)	15
Tabel 2. Apple ennustuse ja hinna korrelatsioon	35
Tabel 3. Apple ennustusmodeli täpsus	36
Tabel 4. Microsoft ennustuse ja hinna korrelatsioon	37
Tabel 5. Microsoft ennustusmodeli täpsus	38
Tabel 6. Exxon Mobil ennustuse ja hinna korrelatsioon	39
Tabel 7. Exxon Mobil ennustusmodeli täpsus	39
Tabel 8. Johnson & Johnson ennustuse ja hinna korrelatsioon	40
Tabel 9. Johnson & Johnson ennustusmodeli täpsus	41
Tabel 10. Berkshire Hathaway ennustuse ja hinna korrelatsioon	42
Tabel 11. Berkshire Hathaway ennustusmodeli täpsus	42
Tabel 12. JP Morgan Chase ennustuse ja hinna korrelatsioon	43
Tabel 13. JP Morgan Chase ennustusmodeli täpsus	44
Tabel 14. Amazon ennustuse ja hinna korrelatsioon	45
Tabel 15. Amazon ennustusmodeli täpsus	45
Tabel 16. General Electric ennustuse ja hinna korrelatsioon	47
Tabel 17. General Electric ennustusmodeli täpsus	47
Tabel 18. AT&T ennustuse ja hinna korrelatsioon	48
Tabel 19. AT&T ennustusmodeli täpsus	48
Tabel 20. USA uuringutulemuste kokkuvõte	49
Tabel 21. Arco Vara ennustuse ja hinna korrelatsioon	51
Tabel 22. Arco Vara ennustusmodeli täpsus	51
Tabel 23. Baltika ennustuse ja hinna korrelatsioon	52
Tabel 24. Baltika ennustusmodeli täpsus	52
Tabel 25. Ekspress Grupp ennustuse ja hinna korrelatsioon	53
Tabel 26. Ekspress Grupp ennustusmodeli täpsus	54
Tabel 27. Harju Elekter ennustuse ja hinna korrelatsioon	55
Tabel 28. Harju Elekter ennustusmodeli täpsus	55
Tabel 29. Merko Ehitus ennustuse ja hinna korrelatsioon	56

Tabel 30. Merko Ehitus ennustusmudeli täpsus	57
Tabel 31. Nordecon ennustuse ja hinna korrelatsioon	58
Tabel 32. Nordecon ennustusmudeli täpsus	58
Tabel 33. Olympic Entertainment Group ennustuse ja hinna korrelatsioon	59
Tabel 34. Olympic Entertainment Group ennustusmudeli täpsus	60
Tabel 35. PRFoods ennustuse ja hinna korrelatsioon	61
Tabel 36. PRFoods ennustusmudeli täpsus	61
Tabel 37. Silvano Fashion Group ennustuse ja hinna korrelatsioon	62
Tabel 38. Silvano Fashion Group ennustusmudeli täpsus	63
Tabel 39. Skano ennustuse ja hinna korrelatsioon	64
Tabel 40. Skano ennustusmudeli täpsus	64
Tabel 41. Tallink ennustuse ja hinna korrelatsioon	65
Tabel 42. Tallink ennustusmudeli täpsus	66
Tabel 43. Tallinna Kaubamaja ennustuse ja hinna korrelatsioon	67
Tabel 44. Tallinna Kaubamaja ennustusmudeli täpsus	67
Tabel 45. Tallinna Vesi ennustuse ja hinna korrelatsioon	68
Tabel 46. Tallinna Vesi ennustusmudeli täpsus	69
Tabel 47. Tallinna börsi uuringutulemuste kokkuvõte	69
Tabel 48. Aktsiaturgude võrdlus	70

Sissejuhatus

Maailma esimene moodne börs avati 1602. aastal Hollandis ning seal avanes võimalus esimest korda eraisikutele aktsiatega kaubelda. Sellest ajast peale on börside populaarsus kasvanud ning tänaseks päevaks on võimalik kaubelda umbes 120000 ettevõtte aktsiatega üle maailma. Kuigi aktsaiturg on oma ajaloo jooksul läbi elanud mitmeid valusaid langusi, on aktsiad läbi ajaloo olnud väga hea tootlusega varaklass.

Börsid on aja jooksul palju muutunud. Kui algusaastatel oli eraisikute osakaal väga suur, siis tänaseks on nende osakaal vähenenud, kuna turule on tulnud suured institutsionaalsed investorid, kes haldavad väga suuri summasid. Nii nagu ajaloo jooksul on börsid arenenud, on seda sama teinud ka tehnoloogia. Kui vanasti tehti tehinguid paberi ja pliiatsiga, siis nüüd sooritatakse tehingud läbi infosüsteemide. Lisaks sellele kasutatakse paljusid erinevaid keerukaid algoritme ning turul tegutsevad robotid, kes teevad arvestatava osa tehingutest. Lisaks sellele on veel olemas välkkauplemine (ingl k *high frequency trading*), mis teeb tehinguid millisekunditega ning sellele kiirusele ei saa vastu ükski inimene. Kuna tehnoloogia on tohutult arenenud, siis proovib töö autor rakendada ennustusmudelit, mis ennustaks aktsia sulgemishindu, kasutades selleks varasema perioodi sulgemishindu.

USA-s on maailma kõige arenenum ning efektiivseim kapitaliturg, tänu millele sobivad sealsed ettevõtted uuringu läbiviimiseks. Seevastu Tallinna börs on tuntud oma ebaefektiivsuse ja vähese likviidsuse poolest. Võrdlusmomendi loomiseks uuritakse ka Tallinna börsil noteeritud ettevõtteid. Uuritavateks ettevõteteks valis autor välja S&P 500 aktsiaindeksi üheksa suurima osakaaluga ettevõtet ning kõik Tallinna börsil noteeritud ettevõtted (välja arvatud LHV, kuna see ettevõtte on börsil olnud lühikest aega). Ennustusmudelit rakendatakse perioodil 2010 juuni kuni 2017 aprill. Autori parima teadmise juures pole sellist uuringut eelnevalt läbi viidud.

Teema on aktuaalne, kuna uuringus kasutatakse tensorflow, mis on uudne avatud lähtekoodiga tarkavarateek (stabiilse versiooni väljalaskmine 15. veebruar 2017). Lisaks sellele on mitmed börsiindeksid tõusnud kõigi aegade rekorditeni ehk „börsipidu“ käib

täie hooga. Teemavalikul lähtuti autori enda huvist aktsiaturgude vastu. Kuigi autori peamine strateegia on pikaajaline investeerimine, mis põhineb eelkõige fundamentaalanalüüsil, siis oli soov uurida, kas mudel suudab ennustada aktsiate sulgemishindu. Töö eesmärk on rakendada mudelit erinevate ettevõtete peal ning anda hinnang mudelile. Rakendades mudelit erinevate aktsiaturgude ja ettevõtete peal, tekib ka võrdlusmoment. Kui uuringu tulemused on head, siis on võimalik, et seda saaks kasutada reaalsete tehingute tegemisel ühe abivahendina.

Töö jaguneb kolmeks suuremaks osaks: esmalt alustatakse teema teoreetilisest tutvustusest, mille hulgas räägitakse efektiivse turu teooriast, S&P 500 indeksist, Tallinna börsist ning masinõppest. Seejärel tutvustatakse uuringut, andmeid, läbi viidavat perioodi, rakendatavat ennustusmudelit ning uuringus osalevaid ettevõtteid. Kolmandas osas viiakse läbi uuring ning esitatakse tulemused visuaalselt. Järgneb põhjalik analüüs, võrreldakse mudeli toimimist erinevatel aktsiaturgudel ning antakse hinnang mudelile. Kolmanda osa lõpetuseks tehakse järeldused ning antakse soovitusel tulevikuks.

Töö autor tänab antud töö valmimise eest oma juhendajat Ahti Lohk'i.

1 Efektiivse turu mõiste ja olemus

1950-ndate lõpus püstitasid majandusteadlased hüpoteesi, mille kohaselt aktsiate hinnad ekslevad, s.t nende muutused ajas on ettearvamatud (ingl k *random walk hypothesis*). Selle baasil kujunes välja efektiivse turu hüpotees (ingl k *efficient market hypothesis*), mis vaatles aktsiate hinnamuutuste seotust erinevate informatsioonikogumitega (Sander, 2003, 92).

Efektiivse turu hüpotees on professor Eugene Fama poolt loodud teooria, mida ta esitles esmakordselt 1964. aastal, kaitstes oma doktoritööd Chicago Ülikoolis. Tema teos avaldati täies mahus ajakirja *Journal of Business* poolt pealkirjaga *The Behaviour of Stock Market Prices* ning hiljem hiljem ajakirjas *Financial Analysts Journal* pealkirjaga *Random Walks In Stock Market Prices*. Hiljem on ta väitnud, et „Vara hind kajastab efektiivsel turul täielikult kogu kättesaadavat informatsiooni” (Veskimägi, 2006).

Efektiivse turu teooria väidab, et efektiivne turg reageerib kohe uuele infole ja seega ei õnnestu sama riskitaseme puhul ühelgi investoril teenida rohkem kui teistel. Et efektiivsel turul peegeldavad finantsvarade hinnad kogu olulist infot, siis võivad investorid kindlad olla, et nad maksavad varade eest alati õiget hinda, st hinda, mis väljendab varade tegelikku väärtust (Roos jt, 2012, 153).

Olenemata sellest, et paljud erinevad uuringud on turgude efektiivsust tõestanud, on ilmnenu ka vastupidiseid näiteid. See tuleneb sellest, et finantsturg ei saa olla alati efektiivne, kuna turul võib leiduda infot, mis pole kõigile kättesaadav, investorid ei oska sellele tähelepanu pöörata või finantsturg käitub niimoodi, et see ei vasta efektiivse turu reeglitele. See võib tuleneda sellest, et pidevalt tekib juurde väärtpabereid ning nende tundmaõppimine võtab aega. Hiljem õpitakse uusi aktiivseid tundma ning eelised kaovad ja turg muutub taas efektiivseks.

Üldlevinud tõdemus on, et lühiajaliselt on aktsiahinnad juhuslikud. Neid mõjutavad erinevad faktorid nagu uudised ettevõtte kohta, sektori väljavaated, üldine meelestatus börsil, fundamentaalnäitajad jne. Vaatamata sellele levinud arvamusele on paljud

finantsinstitutsioonid panustanud väga palju ressursi erinevate algoritmide väljatöötamisele, mis võiksid aidata ette näha aktsiate hinnaliikumist. Autor proovib samuti tänapäevaseid tehnoloogilisi võimalusi kasutades aktsiate hindu ennustada. Järgnevalt antakse lühiülevaade S&P 500 indeksist ning tutvustatakse indeksisse kuuluvaid ettevõtteid, mis osalevad uuringus.

1.1 S&P 500 indeksi tutvustus

S&P 500 tähendab Standard & Poor's 500 indeksit. See on aktsiaturu indeks, mis jäljendab 500 suurima börsiettevõtte käekäiku. Ettevõtete aktsiad peavad olema noteeritud kas New Yorki aktsiaturul (ingl k *New York Stock Exchange*) või NASDAQ'il.

Indeksisse kuulumiseks peab ettevõtte turukapitalisatsioon olema vähemalt 5,3 miljardit dollarit. Lisaks sellele peab olema vähemalt 50% ettevõtte aktsaitest börsil kaubeldavad ning aktsia hind peab olema vähemalt 1 dollar. Täiendav kriteerium on nõue, et ettevõtte peab olema kasumis vähemalt 4 kvartalit järjest (Amadeo, 2016).

S&P 500 indeksit peetakse kõige täpsemaks mõõteriistaks, mis mõõdab suurte USA aktsiate sooritust. See annab hea ülevaate aktsiaturgude üldisest käekäigust, kuna suur osa kogu turuväärtusest kuulub sinna indeksisse. Kõik 500 ettevõtet valib indeksisse S&P indeksi komitee, mis koosneb Standard & Poor's analüütikutest ning majandusteadlastest.

Indeks on läbi oma ajaloo pidevalt ülespoole rühkinud, kuid selle perioodi sisse on jäänud ka valusaid börsikrahhe nagu 1929. aastal alanud „Suur depressioon“ või 2008 aasta ülemaailmne finantskriis (vt joonis 1).



Joonis 1. S&P 500 ajalooline graafik (Macrotrends)

Suurimad osalused indeksis on järgmistel ettevõtetel (seisuga 31.12.2017):

Tabel 1. Suurimad osalusprotsendid indeksis (ishares)

APPLE INC	3.20
MICROSOFT CORP	2.50
EXXON MOBIL CORP	1.94
JOHNSON & JOHNSON	1.62
BERKSHIRE HATHAWAY INC CLASS B	1.60
JPMORGAN CHASE & CO	1.60
AMAZON COM INC	1.53
GENERAL ELECTRIC	1.45
FACEBOOK CLASS A INC	1.39
AT&T INC	1.35
	<hr/>
	18.18

Kuna USA kapitaliturg on maailma efektiivseim, siis seetõttu valis töö autor uuringu läbiviimiseks just need üheksa suurimat S&P 500 indeksisse kuuluvat ettevõtet (Facebook ei osale uuringus, kuna ettevõtte tuli börsile 2012 veebruaris). S&P 500 indeks

on tähtis mõõdupuu paljude investeerimisfondide ja erainvestorite jaoks, mille järgi oma tootlust ja sooritust mõõdetakse. Kui näiteks aktiivselt juhitud fondi tootlus jääb võrdlusindeksile alla, siis tekib õigustatud küsimus, miks mitte investeerida passiivsesse indeksifondi, mis tagab investorile jälgitava indeksi tootluse ning kus teenustasud on väga madalad. S&P 500 indeks on indikaator, mis näitab, kuidas USA majandusel läheb. Kuna majandus on globaalselt põimunud, mõjutavad sealsed sündmused otseselt ka muid maailma osi, sh Euroopat. Järgnev peatükk tutvustab Tallinna börsi.

1.2 Tallinna börs

„Nasdaq Tallinn ja Eesti väärtpaberikeskus on juhtivad Eesti väärtpaberituru ettevõtted, millede kaudu toimub väärtpaberitega kauplemiseks vajaliku keskkonna haldamine, väärtpaberitehingute arveldamine, ettevõtete noteerimine, väärtpaberite keskregistri ja kogumispensioni registri pidamine Eestis. Börs viib kokku raha paigutavad investorid, täiendavat kapitali kaasata soovivad ettevõtted ning börsi liikmed, kes vahendavad investorite väärtpaberitehinguid ühtses elektroonilises kauplemissüsteemis. Nasdaq Tallinna börs kasutab Põhja- ja Baltimaade kauplemisplatvorme INET ja SAEXESS, kuhu lisaks Tallinnale on ühendatud veel kuue riigi börsid: Soome, Rootsi, Taani, Island, Läti ja Leedu. Nasdaq Tallinn on alates 2004. aastast Põhja- ja Baltimaade börsiliidu NOREX liige“. (Nasdaq Tallinn ... 21.03.2017)

Tallinna börsinimekirjas on hetkel (aprill 2017) 14 ettevõtet ning 13 neist kasutatakse uuringu läbiviimisel (LHV tuli börsile alles 2016 mais ning seetõttu uuringus ei osale). Kuna uuringu läbiviimisel kasutatakse masinõppe meetodit, siis järgnev peatükk juhatab teema sisse.

1.3 Masinõpe

Masinõpe (ingl k *machine learning*) pole uus, see on olemas olnud vähemalt alates 1970-ndatest, kui ilmusid välja esimesed algoritmid. Muutunud on see, et arvutite arvutusvõime on plahvatuslikult kasvanud ning see on lubanud masinõppel lahendada järjest keerulisemaid probleeme. Enamik masinõppe meetodeid põhineb ideel, et arvuti õpib ülesannet sooritama läbi eelneva õppimise või treeningu (Louridas jt, 2016).

Väljend masinõpe viitab tähendusrikaste mustrite automaatsele tuvastamisele andmete hulgast. Viimase paari aastakümne jooksul on sellest saanud tavapärane tööriist peaaegu iga ülesande jaoks, mis vajab informatsiooni eraldamist suurtest andmehulkadest. Me oleme ümbritsetud masinõppel põhinevast tehnoloogiast: otsingumootorid õpivad, kuidas tuua meieni parimaid tulemusi (ning kuidas paigaldada reklaami), spämmivastane tarkvara õpib, kuidas filtreerida meie e-maile ja krediitkaardi tehingud on turvatud tarkvara poolt, mis õpib, kuidas tuvastada pettusi. Digitaalkaamerad õpivad tuvastama nägusid ning intelligentsed personaalabi rakendused õpivad tundma häälkäsklusi. Autod on varustatud avarii ärahoidmise süsteemidega, mis on ehitatud kasutades masinõppe algoritme. Masinõpe leiab laialdast kasutust sellistes valdkondades nagu bioinformaatika, meditsiin ning astroloogia. Kogu selle valdkonna ühine nimetaja vastupidiselt traditsioonilisele arvutikasutamisele on see, et mustrid, mis vajavad tuvastamist, on liiga keerulisused programmeerija jaoks. Seetõttu ei saa programmeerija pakkuda selgesõnalist, detailset kirjeldust, kuidas ülesanne tuleks sooritada. Näiteks paljud meie oskused omandatakse läbi kogemuste (rohkem kui järgides selgesõnalist juhendit). Masinõppe tööriistad võimaldavad õppimist ning kohanemist (Shai, 2014).

Masinõppe jaguneb kolmeks suuremaks kategooriaks:

- juhendamisega õpe (ingl k *supervised learning*)
- juhendamata õpe (ingl k *unsupervised learning*)
- abistatud õpe (ingl k *reinforcement learning*).

Masinõppes on palju erinevaid meetodeid, mida saab sõltuvalt ülesandest rakendada. Meetodid on näiteks assotsiatsiooni reeglite õppimine (ingl k *Association rule learning*), otsustuspuu põhjal õppimine (ingl k *Decision tree learning*), tehislikud närvivõrgud (*Artificial neural networks*), klasterdamine (*Clustering*) jne. Antud töös kasutatav meetod kuulub juhendamisega õppe kategooriasse ning ennustusmudeli loomiseks kasutatakse tehislikke närvivõrke ehk süvaõpet (ingl k *deep learning*).

Süvaõpe on tehnoloogia, mis kasutab tehisnärvivõrke, et õpetada arvutitele massiivsete andmehulkade kiiret läbi töötamist ja sealt mustrite otsimist. Mida rohkem andmeid õppimiseks kasutatakse, seda täpsemaid ennustusi suudavad algoritmid teha. Süvaõppe algoritme kasutavad ka Apple Siri tarkvaras, Google otsingusüsteemides ja Facebook


ftodelt nãgude leidmiseks (Conner-Simmons, 2015). Jãrgnevalt seletab autor põhjalikumalt, kuidas rekurrentsed nãrvivõrgud (ingl k *recurrent neural network*, (edaspidid RNN) tãõtavad.

1.3.1 Rekurrentsed nãrvivõrgud

Inimesed ei alusta oma mõtlemist iga kord algusest peale. Kui loetakse referaati, siis mõistetakse iga sõna vastavalt sellele, kuidas mõisteti sellele eelnevat sõna. Iga uue sõna juures ei pühita mälust minema kõik eelnev ning ei hakata otsast peale. Mõtted peavad jääma püsima. Selle probleemi lahendab RNN (Olah, 2015).


RNN on seda tüüpi tehisnãrvivõrgud, mis on disainitud tundma ära mustreid andmejadades, nagu nãiteks tekst, kãekiri, õeldud sõna või numbrid. Need võrgud on kahtlemata kõige võimsamad RNN tüübid (A beginne ... 12.04.2017). Jãrgnevad joonised ning tutvustav tekst pärineb eelpool viidatud Christopher Olah'i tekstidel.

See on nãrvivõrk silmustega (ingl k *loops*), mis lubab infol püsima jääda. Vaata joonist:




Joonis 2. RNN-l on silmused

RNN nãrvivõrku saab õpetada mitmete koopiatena ühe ja sama võrguna. Iga koopia edastab sõnumi oma järglasele. Vaata joonist:




Joonis 3. Lahti rullunud RNN

Selline ketilaadne olemus näitab, et RNN-id on lähedaselt seotud jadade (ingl k *sequence*) ning nimekirjadega. See võimaldab eelnevatel andmetel ühilduda praeguste ülesannetega. Mõnikord on vaja vaadata ainult hiljutist informatsiooni, et sooritada praegust ülesannet. Näiteks keelemudel (ingl k *language model*) proovib ennustada järgmist sõna tuginedes eelnevatele sõnadele. Kui on soov ennustada viimast sõna lauses „pilved on *taevas*“, siis ei vajata lisakonteksti, kuna on üsna selge, et järgnev sõna on taevas. Sellisel juhul, kui vähetähtsa informatsiooni ja koha vahel, kus seda vajatakse, on väike, siis RNN suudab õppida kasutama mineviku informatsiooni. Vaata joonist:



Joonis 4. RNN on ketilaadne

Kuid on olemas ülesanded, mis vajavad rohkem konteksti. Näiteks proovitakse ennustada viimast sõna lauses „Ma kasvasin üles Prantsusmaal....Ma räägin puhast *Prantsuse keelt*“. Viimane info soovitab, et otsitav sõna võiks olla keelt, kuid kui on soov teada saada, mis keel täpsemalt, siis on vaja Prantsuse konteksti kaugemalt. On väga võimalik, et vahe vajaliku informatsiooni ja koha vahel, kus seda vaja on, on väga suur. Mida suuremaks vahe kasvab, seda vähem suudab RNN infot ühendada. Vaata joonist:




Joonis 5. Jada

Siinkohal tekib probleem. RNN ei suuda õppida pikaajalisi sõltuvusi (ingl k *long term dependencies*). Seda probleemi uuriti süviti 1990.ndate aastate alguses Hochreiteri ja Bengio poolt. Seda probleemi kutsuti haihtuva gradiendi probleemiks (ingl k *vanishing gradient problem*). Lahendus sellele probleemile on LSTM ehk modifitseeritud variant RNN-st.


1.3.2 LSTM

LSTM tähendab pikka lühiajalist mälu (ingl k *long short term memory*, edaspidi LSTM), mis suudab õppida pikaajalisi sõltuvusi. Seda tutvustati 1997. aastal Hochreiteri ja Schmidhuberi poolt ning LSTM on kavandatud spetsiaalselt selliselt, et see väldiks eelpool kirjeldatud probleemi. Standardse RNN-i puhul on kordusmoodulil (ingl k *repeating module*) väga lihtne struktuur (vt joonist):




Joonis 6. Kordusmoodul

LSTM-l on ka ketilaadne struktuur, kuid kordusmoodulil on erinev struktuur. Ühe närvivõrgu kihi asemel on neli, mis toimivad väga erilisel viisil.



Joonis 7. LSTM kordusmoodul sisaldab nelja suhtlevat kihti


Iga joon üllemisel joonisel kannab tervet vektorit väljundi sõlmest sisendisse. Roosa ring esindab puntihaaval toimivat tegevust, nagu vektori täiendus. Kollased kastid on õpetatud närvivõrgu kihid. Ühinevad jooned tähistavad ahelikke, samal ajal hargnevad jooned tähistavad kopeeritud sisu ning koopiad lähevad erinevatesse asukohtadesse. LSTM-i põhielement on raku olek (ingl k *cell state*), mis on horisontaalne joon, mis jookseb diagrammi ülasos (vt joonist).



Joonis 8. LSTM suudab lisada või eraldada informatsiooni

LSTM-l on võime kas kustutada või lisada informatsiooni raku olekusse, mis on ettevaatlikult reguleeritud struktuuri poolt ning mida kutsutakse väravateks (ingl k *gates*). Väravad saavad lasta valikuliselt informatsiooni läbi. Nad on koostatud väljaspool

sigmoid närvivõrgu kihti ja punktihaaval korrutamistehtes (ingl k *pointwise multiplication operation*).



Joonis 9. Sigmoidfunktsioon

Sigmoid kiht väljastab numbreid ühe ja nulli vahel, samal ajal kirjeldades kui palju igat komponenti peaks läbi laskma. Väärtus null tähendab „ära lase midagi läbi“ ja väärtus 1 tähendab „lase kõik läbi“ (Olah, 2015). Magistritöö uuringu läbiviimiseks kasutatakse LSTM-i. Selleks installis autor enda arvutisse Anaconda ning lõi sinna keskkonna, kuhu installis Keras ja Tensorflow. Lisaks sellele installiti veel mõned paketid, nagu jupyter notebook ja matplotlib. Järgnevalt lühiülevaade kasutatud tööriistadest.

1.4 Keras

Keras on närvivõrgu teek, mis on kirjutatud programmeerimiskeeles Python ning kasutab backend'ina kas Theanot või Tensorflowd. On lihtsam ehitada täislahendusi ning lihtsam neid lugeda, kui iga koodirida tekitab ühe võrgukihi. See tööriistakomplekt sisaldab parimat valikut tipptasemel algoritmidest. Projekt on hästi dokumenteeritud ning sisaldab näiteid suurele ringile probleemidele. Keras looja on Francois Chollet, kes on Google tarkvarainsener (Erickson jt, 2017). Antud uuring viiakse läbi kasutades tensorflow bacend'i.

1.5 Tensorflow

Tensorflow on avatud lähtekoodiga tarkvarateek numbriliseks arvutamiseks, kasutades andmevoogude graafikuid. Graafikute sõlmed (ingl k *nodes*) esindavad matemaatilisi operatsioone, samas kui graafikute küljed esindavad mitmemõõtmelisi andmete massiive (tensoreid), mis suhtlevad nende vahel. Paindlik arhitektuur lubab paigutada arvutused ühte või mitmesse CPU-sse, GPU-sse desktopil, serverisse või mobiili üheainsa API-ga.

Tensorflow oli algelt arendatud Google uurijate ja inseneride poolt, kes töötasid Google Brain Teamis masinintelligentsi osakonnas eesmärgiga viia läbi masinõppe ja närvivõrkude uuringut, kuid süsteem on piisavalt üldine, mistõttu saab seda kasutada paljudes erinevates valdkondades (An open so ... 15.04.2017).

Tensorflow platvorm avalikustati 2015 aasta novembris. Eelnevalt olid olemas juba sellised keskkonnad nagu Torch ja Theano. Avaldamisest peale on platvorm olnud pidevas arenduses ja täiustamises. Tensorflowl on palju positiivseid omadusi, nagu näiteks paketi avatud kood, mis muudab selle läbipaistvaks ning kohandatavaks. Lisaks sellele on tensorflow kohta käiv dokumentatsioon põhjalik, mis on väga tähtis, et kasutajad saaksid selle omaks võtta. Suur pluss on ka see, et seda projekti toetatakse Google poolt ning et ta ühildub Pythoniga (Saxena, 2016).

Tensorflow on masinõppe süsteem, mis opereerib suuremahuliselt heterogeensetes keskkondades. Selle arvutuslik mudel põhineb andmevoogude graafikutel koos muudetava olekuga (ingl k *mutable state*). Tensorflow toetab mitmeid erinevaid aplikatsioone, kuid on spetsiaalselt mõeldud süvaõppe treenimiseks ja järelduste tegemiseks. See on platvorm uurimustöö ja masinõppe rakendamise jaoks üle mitme erineva valdkonna, nagu näiteks häälte tuvastamine, tehisenägemine, robotika, informatsiooni taas leidmine ning keeltöötlemine (Abadi, 2016).

1.6 Python ja Matplotlib

Python on lihtne, ent sellegipoolest võimas programmeerimiskeel, mida kasutatakse laialdaselt andmeteaduses. Antud töös kasutatakse python 3.5 versiooni, kuna ainult see versioon ühildub tensorflowga windows operatsioonisüsteemis.

Matplotlib on Pythoni peamine teaduslik joonestamistee. See pakub kasutajale väga kvaliteetseid visualiseerimise võimalusi, nagu joondiagramme, histogramme, hajuvusdiagramme jne. Andmete visualiseerimine võib anda väärtuslikke teadmisi ning nende teadmiste põhjal on parem analüüsi läbi viia (Müller jt, 2016).

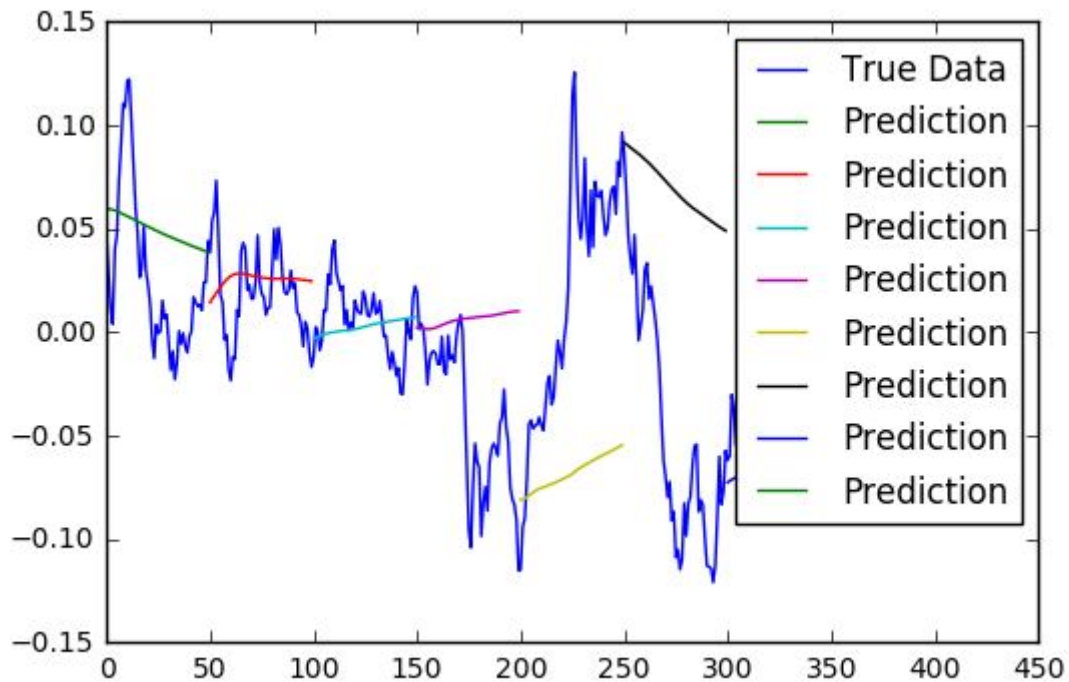
2 Uuringu tutvustus

USA aktsiaturgu peetakse maailma efektiivseimaks kapitalituruks, seevastu Tallinna börsile on ennegi ette heidetud vähest efektiivsust. Seega võrreldakse mudeli toimimist kahel väga erineval turul. USA poole pealt osalevad uuringus üheksa S&P 500 indeksisse kuuluvat ettevõtet ning Eesti poole pealt kõik Tallinna börsil noteeritud ettevõtted (välja arvatud LHV, kuna ettevõtte on börsil olnud liiga lühikest aega).

Ennustusmudel kasutab andmetena aktsiate sulgemishindu ning pärast treenimist ennustab aktsia sulgemishindu. Uuritava perioodi pikkus on 01.06.2010-21.04.2017. Periood valiti selliselt, et võimalikult paljud Tallinna Börsi ettevõtted saaksid uuringus osaleda. Valdavalt on tegemist tõusvate turgudega, kui paar äkilisemat langust välja arvata.

Kõikide USA ettevõtete andmed laetakse alla google finance lehelt csv. formaadis ning failist kustutatakse kõik muu info peale sulgemishindade ära. Lisaks sellele tõstetakse failis olevad sulgemishinnad ümber niimoodi, et nad algaksid kaugemast ajast ehk 01.06.2010. Tallinna börsil noteeritud ettevõtete hinnad laetakse alla tallinna börsi kodulehelt csv. failina ning failist kustutatakse kõik muu info peale sulgemishindade ära. Selles failis on sulgemishinnad juba ajaliselt korrektses järjekorras.

Ennustusmudelit on rakendanud Columbia ülikooli taustaga veebikoolitaja ning andmeteadlane Siraj Raval S&P 500 aktsiaindeksi peal (Raval, 2017). Siraj Raval on muuhulgas töötanud Twilios ning teinud videosid Elon Muskile ja Google'le. Tulemus oli järgmine:



Joonis 10. Ennustusmodel S&P 500 aktsiaindeksi näitel

Nagu jooniselt näha, varasemalt rakendatud spetsiifiline masinõppe algoritm andis korralikke tulemusi. Autori huvi on teada saada, kui hästi toimib ennustusmodel üksikettevõtete puhul, sealhulgas saades teada, kas algoritm ennustab mõne ettevõtte puhul paremini kui teise puhul. Autori parima teadmise juures pole sellist uuringut varasemalt läbi viidud. Enne uuringu tutvustuse juurde minekut antakse ülevaade, mida on selles valdkonnas varem uuritud.

2.1 Antud valdkonna varasemad uuringud

Aktsiaturge on masinõppe meetodiga palju uuritud. Autor toob välja mõned näited, kus on kasutatud masinõpet aktsia hinnaliikumise ennustamiseks. Phua sooritas uuringu, kus ennustas viie suure aktsiaindeksi hinnaliikumisi. Indeksid olid DAX, DJIA, FTSE-100, HSI ja NASDAQ. Kasutati tehisklikke närvivõrke ning nad suutsid ennustada märki hinnaliikumisest 60% täpsusega. Toetusvektor masinat (ingl k *support vector machine*, edaspidi SVM) kasutati, et ennustada aegridade suunda. Kim treenis SVM'i päevaste aegridadega Korea aktsiaturul. Ta raporteeris ennustustäpsusega 56 % ümber. Huang proovis kasutada SVM-i, et ennustada Jaapani Nikkei 225 indeksi nädalasi liikumisi. Tema lähenemine saavutas 73% täpsuse kasutades SVM'i ning 75% täpsuse kasutades

kombineeritud mudelit. Lisaks sellele on Schumacher ja Chen uurinud, milliseid tulemusi on võimalik saavutada analüüsidest artikleid, kasutades selleks SVM-i. Nad proovisid ennustada S&P 500 indeksi hinnaliikumist 20 minutit pärast uudise avaldamist. Nad kasutasid mitmeid erinevaid lähenemisi ning saavutasid 57% ennustustäpsuse. Nikola Milosevic kasutas masinõppe lähenemist ning erinevaid fundamentaalnäitajaid, et ennustada aktsia tulevikuhinda pikaajaliselt. Tema meetod suutis ennustada, kas ettevõtte väärtus on aasta pärast 10% kõrgem või madalam 76,5% täpsusega (Milosevic, 2016).

Eelnevaid uuringuid silmas pidades, ootas magistr töö autor ennustusmudelilt ennustustäpsust, mis oleks parem kui 50%. Järgnevalt antakse ülevaade autori poolt välja valitud USA ettevõtetest, mis osalevad uuringus.

2.2 S&P 500 indeksisse kuuluvad uuringus osalevad ettevõtted

Ettevõtete tutvustused pärinevad google finance, yahoo finance ja nasdaq kodulehelt.

1. Apple Inc - Apple on maailma üks juhtivatest tarbimiselektronika ja personaalarvutite ettevõtte. Ettevõtte asutajad on Steve Jobs, Steve Wozniak ja Ronald Wayne. Firma asutati 1977 aastal ning algusest keskenduti personaalarvutitele. Viimasel ajal on rohkem keskendatud tarbijaelektronikale, milleks on tooted nagu iPhone, iPad ja iPod. Lisaks sellele kuulub nende tooteportfelli iCloud, Apple TV, App Store ja palju muud. Magistr töö kirjutamise ajal oli Apple maailma suurima turuväärtusega ettevõtte (752,3 miljardit dollarit).
2. Microsoft Corp on tehnoloogiaetevõtte. Ettevõtte arendab, litsenseerib ning toetab suurt hulka tarkvaratooteid, teenuseid ning seadmeid. Tuntumad tooted on windows operatsioonisüsteem ning kontoritarkvara Office. Viimasel ajal on ettevõtte panustanud jõuliselt pilvetehnoloogiasse. Ettevõtte üks asutaja on Bill Gates, kes on olnud aastaid maailma rikkaim inimene.
3. Exxon Mobil Corporation asutati New Jersey osariigis 1882. aastal. Ettevõtte divisjonid ning tütar ettevõtted opereerivad või turustavad tooteid USA-s ning enamikes maailma riikides. Exxoni põhitegevusvaldkond on energia, mis hõlmab endas toornafta ja maagaasi tootmist ning selle müümist ja transportimist. Euroopas müüakse mootorikütust Esso tanklates. Tegemist on maailma ühe suurima naftaetevõttega

4. Johnson & Johnson on valdusfirma, millel on üle 230 ettevõtte ning need üksused asuvad pea kõikides maailma riikides. Ettevõtetel on umbes 126 000 töötajat, kes tegelevad teadus- ja arendustegevusega, tootmise ning müübiga tervisehoiu valdkonnas. Firmal on väga lai valik tooteid ning peamiselt keskendutakse inimeste tervisele ning heaolule. Firma asutati 1887. aastal New Jerseys.
5. Berkshire Hathaway Inc (Class B) on valdusettevõtte, mida juhib maailma kuulsaim investor Warren Buffett. Ettevõtte omab paljusid ettevõtteid ning lisaks sellele investeerib teistesse börsiettevõtetesse. Berkshire Hathaway osaleb mitmetes erinevates sektorites, nagu kindlustus, pangandus, lennundus, toitlustus jne. Peakontor asub Nebraska osariigis Omahas.
6. JP Morgan Chase & CO - Firma tegeleb investeerimispanganduse ja finantsteenuste osutamisega. Ettevõtte pakub laia valikut teenuseid laenudest kuni varahalduseni. JP Morgan on varade mahult maailma suurim pank ning kuulub süsteemselt oluliste pankade nimekirja.
7. Amazon alustas 1994. aastal e-raamatupoena. Tänapäevaks on sellest arenenud laiahaardeline internetifirma. Ettevõtte tegeleb andmekäsitluse, tehisintellekti loomise, pilvetehnoloogia arendamise ning mitmete muude huvitavate projektidega. Just pilvetehnoloogia valdkonnas on nad näidanud väga häid tulemusi ning on turuosalt järgmisest ettevõttest Microsoftist kaugel ees ära.
8. General Electric on USA tööstuskonglomeraat. Ettevõtte üksused on energia, lennundus, tervishoid, transport, energiaühenduste rajamine ja valgustus ning finants. Valmistatavate toodete hulka kuuluvad näiteks lennukimootoreid, elektrigeneraatoreid, nafta ja gaasi tootmisvarustust ja tööstustooteid. Maakeeli öeldes tegelevad nad kõigega, mis raha sisse toob.
9. AT&T pakub telekommunikatsiooni ning digitaalse meelelahutuse teenust. Ettevõtte tegutseb neljas segmendis: äriühendused, meelelahutus, tarbijate mobiilsus ja rahvusvaheline. Tegemist on USA suurima tavatelefooni teenuse pakkujaga. Firma eelnev nimi oli SBC Communications, kuid 2005. aasta novembris sai nimeks AT&T Inc. Ettevõtte asutati 1983. aastal ning selle peakontor on Dallases.

Eelpool kirjeldatud ettevõtted esindavad erinevaid tööstussektoreid tehnoloogiast panganduseni. Järgnevalt teeb autor lühitutvustuse Tallinna börsinimekirjas olevatest ettevõtetest.

2.3 Tallinna börsinimekirjas olevad uuringusse kuuluvad ettevõtted

Ettevõtete tutvustused pärinevad Tallinna börsi kodulehelt:

1. Arco Vara on ettevõte, mis pakub kinnisvaraga seonduvaid teenuseid. Firma tegeleb kinnisvara vahenduse, analüüsi ning hindamisega. Lisaks sellele tegeletakse ka arenduse ja haldusteenusega. Ettevõte on asutatud 1992. aastal. Ettevõte on esindatud Eestis, Lätis ning Bulgaarias, andes tööd ligi 200-le inimesele.
2. Baltika Grupp on rõivakaubandusettevõte, mis tegutseb eelkõige Baltikumis. Lisaks sellele tegutsetakse ka Kesk- ja Ida-Euroopa turgudel. Baltikale kuuluvad kaubamärgid on järgmised: Monton, Mosaic, Baltman ja Ivo Nikkolo. „Baltika kasutab vertikaalselt integreeritud ärimudelit, mis ühendab rõivakollektsioonide loomise, tootmise ja jaekaubanduse ning võimaldab pakkuda uusi moerõivaid iga nädal“.
3. AS Ekspress Grupp on ettevõte, mis tegeleb kirjastamise, trükiteenuste pakkumise ning online-meedia sisutootmisega. Ekspress Grupp on seadnud endale eesmärgiks olla Baltimaade juhtiv meediaettevõte. Ekspress grupi alla kuuluvad mitmed erinevad ajalehed, nagu näiteks Eesti Päevaleht ja Õhtuleht. Antakse välja ka Eesti suurimat nädalalehte Eesti Ekspressi. Lisaks sellele antakse välja erinevaid ajakirju nagu näiteks Kroonika ning Kodukiri. Kontserni kuulub veel Delfi grupp, mis on Baltikumi suurim meedia ettevõte. Omatakse ka Eesti suurimat trükikoda Printalli.
4. Harju Elekter alustas elektriseadmete tootmist juba 1968. aastal. Ettevõte on Tallinna Börsi põhinimekirjas aastast 2003. Harju Elekter tegutseb peamiselt kahes valdkonnas: tootmine ja kinnisvara ning muud jaotamata tegevused. „Harju Elektri kontserni tootmissegment hõlmab elektriseadmete tehaseid Eestis, kus tehaste põhitoodangu moodustavad elektrienergia jaotusseadmeid (alajaamad,

kaablijaotus- ja liitumiskilbid) ning automaatika- ja juhtimiskeskused energia- ja tööstussektori ning infrastruktuuri tarbeks“.

5. AS Merko Ehitus on ehitus- ja kinnisvaraettevõtte, mis tegutseb Eestis, Lätis ning Leedus. Merko Ehitus on valdusettevõtte, mis ise reaalselt tootmisega ei tegele, kuid talle kuuluvad mitmed täisosalused erinevates ehitusettevõtetes, läbi mille antakse tööd umbes 800-le inimesele. Ettevõtte asutati 1990. aastal ning Merko suudab ehitada praktiliselt kõike hotellidest kuni jäätmekäitlusrajatisteni. Lisaks sellele pakutakse teedehitusvaldkonnas täisteenusust ehk ehitatakse teid, tehakse hooldusremonti ning sooritatakse teeseisundi järelvalvet.
6. Nordecon AS alustas tegevust 1989. aastal. „Nordecon kontsern hõlmab ettevõtteid, mis on keskendunud hoonete ja rajatiste ehitamise projektijuhtimisele ja peatöövõtule. Hoonete valdkonnas ollakse tegevad äri-, tööstus- ja avalike hoonete ning elamute ehitamisel. Rajatiste valdkonnas keskendutakse teedehitusele ja -hooldusele, insenerehitusele (sh vesiehitus), keskkonnaehitusele ning vee- ja kanalisatsioonivõrkude ehitusele. Lisaks kuulub Kontserni betoneerimistöodele spetsialiseerunud ettevõtte. Geograafiliselt tegutsevad kontserni ettevõtted Eestis, Soomes ja Ukrainas. Kontserni emaettevõtte Nordecon AS on registreeritud ja asub Tallinnas, Eestis. Kontserni kuulub lisaks emaettevõttele üle 10 tütarettevõtte. Nordecon kontsern annab tööd ligi 700 inimesele“.
7. „Olympic Entertainment Group AS ja tema tütarettevõtted on juhtiv hasartmänguteenuste osutaja Balti riikides ning opereerib kasiinosid Slovakkias, Maltal ja Itaalias. Olympic Entertainment Group AS on kontserni põhivaldusühing, mille kaudu toimub Kontserni tegevuse strateegiline juhtimine ja finantseerimine. Kohalike kasiinode tegevust juhivad kohalikud tütarettevõtted“.
8. AS PRFoods on toiduainete töötlemise ja müügiga tegelev firma. Ettevõtte on noteeritud Tallinna börsil alates 2010. aastast. „Ettevõtte tegeleb kalatoodete tootmise ja müügiga Soome ja Eesti turul ning kalakasvatusega Rootsis ja Soomes. Grupi vaieldamatuks konkurentsieeliseks on vertikaalne integratsioon – kalakasvatus, tootmine ja müük. Forell, mis on kasvatatud Rootsi järvedes ja

Soome Turu piirkonna arhipelaagis, ja lõhe, mis on toodud Norrast, töödeldakse Heimona Kala OY Soomes Renkos asuvas ja Vettel OÜ Eestis Saaremaal asuvas moodsates tootmishoonetes“. Ettevõtte toodete hulgas on ka Gurme ja Polar Fish, mida müüakse Grupi muude kaubamärkide hulgas on „Gurmé” ja „Polar Fish”, mida müüakse Balti riikides.

9. „Silvano Fashion Group AS on naiste pesu disaini, tootmise, hulgimüügi, frantsiisi ja jaemüügiga tegelev rahvusvaheline kontsern. Grupp arendab kuut naiste pesu, rannarõivaste ja meeste pesu kaubamärki: Milavitsa, Lauma Lingerie, Alisee, Avelin ja Laumelle naistele, Hidalgo meestele. Silvano Fashion Group müüb pesutooteid 23 erinevas riigis. Võtmeturud on Venemaa, Valgevene, Ukraina ja Balti riigid. Kokku on brändide nii oma kui frantsiisikauplusi erinevates riikides ligi 680. Grupi peamine tootmisvõimsus koosneb Minskis (Valgevenes) asuvas Milavitsa pesuvabrikust ja Liepajas (Lätis) asuvas Lauma Lingerie pesuvabrikust. Silvano Fashion Groupis töötab üle 2000 inimese 5 riigis“.
10. Skano Group AS on Eesti üks suuremaid puidutöötlemisettevõtteid, mis omab enam kui 50. aastast kogemust eelpool mainitud valdkonnas. Tegemist on ainsa puidutöötlemisettevõttega, mis on Tallinna Börsil. Skano Grupp hoolib oma töötajatest, klientidest ning aktsionäridest. Lisaks sellele pööratakse tähelepanu sellele, millise jälje jätab ettevõtte keskkonnale.
11. AS Tallink Grupp on laevandusettevõtte, mis pakub lühi-kruuise, reisijate- ja kaubavedu. Ettevõtte käsutuses on 18 alust. Tegutsetakse kahe kaubamärgi all: Tallink ja Silja Line. Laevad sõidavad Eesti, Soome, Rootsi ja Läti vahel. Enamikel liinidel hoitakse juhtivat positsiooni. Tallink on teinud märkimisväärseid investeeringuid – viimase kümne aasta jooksul umbes 1,8 miljardit eurot. Sellest tulenevalt on ettevõtte laenukoormus küllaltki suur. Ettevõtte annab tööd umbes 6800-le inimesele.
12. Tallinna Kaubamaja avati 1960. aastal. „Gruppi kuuluvad tuntud kaubamärgid nagu Kaubamaja, Selver, Selveri Köök, Tartu Kaubamaja keskus, Viking Motors, KIA, ABC King, SHU, I.L.U. ja Topsec Turvateenused. 2014. aastal tegutseb Selveri kaubamärgi all kokku 44 kauplust, nendest 14 kauplust Tallinnas ja 30

mujal Eestis. Selveri tütarettevõtte Kulinaaria OÜ on Baltikumi suurim keskusköök. Jalatsikaupluseid on kokku 28, neist kõik tegutsevad Eestis“. Tegemist on Eesti ühe populaarseima kaubandusketiga.

13. „Tallinna Vesi on Eesti suurim vee-ettevõtte, mis pakub joogivee- ning reoveeteenuseid üle 400 000 inimesele Tallinnas ning mitmes ümbruskaudses omavalitsuses. Ettevõttel on antud piirkonnas teenuste osutamise ainuõigus kuni 2020. aastani. Täna on Ettevõtte aktsionärideks: 35,3% UU Tallinn B.V., 34,7% Tallinna Linn ning 30% aktsiatest on vabalt kaubeldavad. Ettevõtte peamisteks tugevusteks on tulude läbipaistvus, kuna tariifid on lepinguliselt fikseeritud aastani 2020 ning võimalus laiendada oma tegevust Tallinna lähiümbruses“. Siiski on hetkel käimas Tallinna Vee ja konkurentsiameti vaheline kohtuvaidlus, mille kaotamine võib aktsia hinda tunduvalt langetada.

Eelpool kirjeldatud ettevõtted esindavad erinevaid tööstussektoreid jaekaubandusest ehitusettevõteteni. Kõik kirjeldatud ettevõtted osalevad uuringus.

3 Uuringu läbiviimine

Uuringus osalevad üheksa ettevõtet USA aktsiaturult ning 13 ettevõtet Tallinna börsilt. Uuringu läbiviimiseks vajaminevate pakettide installimine ning kasutatud algandmete kohta saab rohkem infot Lisa-st 1. Ennustusmudeli rakendamiseks kasutati järgnevat koodi:


```
In [1]: from keras.layers.core import Dense, Activation, Dropout
from keras.layers.recurrent import LSTM
from keras.models import Sequential
import lstm, time #helper Libraries

Using TensorFlow backend.
```

```
In [2]: #Step 1 Load Data
X_train, y_train, X_test, y_test = lstm.load_data('C:\\Users\\Lauri Uiper\\Anaconda3\\envs\\Magister\\amzn.csv', 50, True)
```

```
In [3]: #Step 2 Build Model
model = Sequential()

model.add(LSTM(
    input_dim=1,
    output_dim=50,
    return_sequences=True))
model.add(Dropout(0.2))

model.add(LSTM(
    100,
    return_sequences=False))
model.add(Dropout(0.2))

model.add(Dense(
    output_dim=1))
model.add(Activation('linear'))

start = time.time()
model.compile(loss='mse', optimizer='rmsprop')
print ('compilation time : '), time.time() - start

compilation time :
```

```
Out[3]: (None, 0.032001495361328125)
```

```
In [4]: #Step 3 Train the model
model.fit(
    X_train,
    y_train,
    batch_size=512,
    nb_epoch=1,
    validation_split=0.05)
```

```
Train on 1441 samples, validate on 76 samples
Epoch 1/1
1441/1441 [=====] - 5s - loss: 0.0124 - val_loss: 0.0050
```

```
Out[4]: <keras.callbacks.History at 0x55ae411940>
```

```
In [5]: #Step 4 - Plot the predictions!
predictions = lstm.predict_sequences_multiple(model, X_test, 50, 50)
lstm.plot_results_multiple(predictions, y_test, 50)
```

yo

Joonis 11. Ennustumudeli kood


Kood koosneb kuuest erinevast ploki. Esimeses ploki imporditakse vajalikud paketid. Teises osas loeb kood andmeid ning normaliseerib need. Normaliseerimine parandab andmete koonduvust. Mudel normaliseerib andmed ning ennustuse tegemiseks denormaliseeritakse andmed, et saada kätte päris number. Seejärel ehitatakse mudel. Esimene kiht on LSTM. Selles kihis on 50 ühikut ning seades tagasta funktsioon 'true' peale, tähendab see, et selle kihi väljund söödetakse alati järgmisele kihile. Teises kihis on 100 ühikut ning seades tagasta funktsioon 'false' peale, tähendab see, et selle kihi

väljund söödetakse edasi ainult jada lõpus. Mõlemale kihile lisatakse väljakukkumine (ingl k *dropout*) 20%, mis eemaldab ühikuid (nii nähtavaid kui peidetuid). Lisatakse lineaarne tihe kiht (ingl k *linear dense layer*), mis summeerib selle ennustusvektori andmed üheks väärtuseks. Järgnevalt treenitakse mudelit ning lõpetuseks väljastatakse graafik ennustustega.

3.1 USA ettevõtete tulemused

Ennustusmudel ennustab iga ettevõtte kohta kolm ennustusjoont ning toob tulemused välja graafiliselt. Graafik kujutab Apple'i reaalset hinnamuutust ning algoritmi poolt ennustatud hinnamuutust selle perioodi jooksul. X- teljel on kujutatud aeg. Vaatlusalune periood on 7 aastat ning aastas on keskmiselt 252 börsil kauplemise päeva. X telje ühikud on ajasammud ning üks ajasamm vastab tegelikkuses kümnele börsipäevale. Y-teljel on kujutatud aktsia sulgemishinna muutus protsendipunktides võrreldes eelmise ajasammuga. Sinine joon on reaalne hinnamuutus ning värvilised ennustusjooned on algoritmi poolt koostatud. Kasutatud ennustusmudel genereerib ennustusjoone pikkuseks 50 sammu, mis realses elus vastab umbes 500-le börsipäevale.

1. Tulemused Apple näitel:



Joonis 12. Apple ennustusmodel graafiliselt

Pealtnäha tundub ennustusmodel ebatäpne. Kuid selleks, et teha konkreetseid järeldusi, viis autor läbi teadusliku analüüsi, kasutades Stata statistikapaketti ning Excelit.

Ennustusmodeli täpsuse hindamiseks kasutas autor statistikaprogrammi Stata korrelatsioonanalüüsi, mis näitab ennustusgraafiku kaasliikumist reaalinna graafikuga. Statistika tavast tulenevalt näitab suurem koefitsient kui 0,7 tugevat kaasliikumist ja väiksem kui 0,3 nõrka. Apple suhtes on korrelatsiooni tulemus järgnev:

Tabel 2. Apple ennustuse ja hinna korrelatsioon

Koefitsient	-0.1761*
P-väärtus	0.0311

Mida lähemal nullile koefitsient on, seda vähem kasulik on ennustusmodel, sest nullkoefitsient tähendab, et ennustuse ja pärisinnaliikumise vahel puudub igasugune seos. Kõige parem oleks koefitsient +1, sest sellisel juhul järgib reaalne hinnamuutus

ennustust 100 % täpsusega. Sama loogika põhjal võib ka negatiivne tugev korrelatsioon olla kasulik, sest sellisel juhul on reaalne hinnaliikumine ikkagi ette ennustatav, ainult vastupidises suunas. Näiteks kui ennustus soovib võtta pikk positsioon, siis investor seevastu peaks aktsia lühikeseks müüa.

P-väärtus näitab kui kindel saab koefitsiendi numbris olla. Nullhüpotees tähendab, et koefitsiendi väärtus on 0, alternatiivhüpotees tähendab, et nullist erinev. P-väärtus näitab nullhüpoteesi kehtivuse tõenäosust. Kui P-väärtus on suur, siis on väga tõenäoline, et koefitsient on juhuslikult saadud. Kui P-väärtus on väike, siis on äärmiselt ebatõenäoline, et saadud koefitsient oleks juhuslik, järelikult saadud koefitsient näitabki reaalselt kehtivat seost. Statistika tavade kohaselt 5 või enama protsendi suurune P-väärtus tähistab statistilist ebaolulisust ehk me ei saa saadud tulemusel väga kindlad olla. Seevastu alla 5 % P-väärtus on tavade kohaselt statistiliselt oluline, järelikult me võime korrelatsiooni koefitsiendi kehtivuse osas olla küllaltki kindlad.

Apple puhul 3,1 % P-väärtus (tähistatud tärniga) näitab, võime koefitsiendi kehtivuses kindlad olla. Koefitsient -0,1761 näitab aga väga nõrka pöördvõrdelist koosliikumist. Antud juhul on Apple koefitsient liiga nullilähedane, et mingitki kasutegurit omada. Investori seisukohast on ennustused liiga ebatäpsed, et seda ennustusmudelit praktikas kasutada.

Kuna Apple korrelatsiooninäitaja on väiksem kui 1, esineb ennustushinna ja reaalse hinna vahel erinevusi. Korrelatsiooni koefitsient näitab hinna arengusuunda, mitte tulevase hinna täpsust. Selleks, et leida iga ennustatud hinnajoone keskmine eksimusmäär, arvutas autor välja kahe hinnajoone erinevused igal ajasammul. Arvutused viidi läbi Excelis ning tulemused on järgnevad:


Tabel 3. Apple ennustusmudeli täpsus

	Keskmine eksimusmäär protsendipunktides	Vähim eksimusmäär protsendipunktides	Suurim eksimusmäär protsendipunktides
Ennustusjoon kollane (1-50)	8,57	0,12	28,99
Ennustusjoon roheline (51-100)	17,85	5,8	29,49
Ennustusjoon punane (101-150)	4,4	0,04	11,02

Ennustusperiood kokku (1-150)	10,27	0,04	29,49
-------------------------------	--------------	-------------	--------------

Tabel 3 annab ülevaate ennustusmudeli täpsusest ja kasulikkusest. Üldiselt investorid ei saaks leppida mudeliga, mille keskmine eksimusmäär on 10 protsendipunkti võrra erinev reaalsest hinnatasemest.

2. Tulemused Microsofti näitel:



Joonis 13. Microsoft ennustusmudel graafiliselt

Pealtnäha tundub ennustusmudel ebatäpne. Kuid selleks, et teha konkreetseid järeldusi, viis autor läbi teadusliku analüüsi, kasutades Stata statistikapaketti ning Excelit.

Tabel 4. Microsoft ennustuse ja hinna korrelatsioon

Koefitsient	-0.2781*
P-väärtus	0.0006


P-väärtus 0,06 % näitab, et võib olla suhteliselt kindel, et korrelatsioonikoefitsient pole null, vaid hoopis -0,2781. Koefitsient -0,2781 näitab, et kaasliikumine on liiga nõrk, et mudelit praktikas kasutada. Excelis uuris autor ennustusmudeli sooritust detailsemalt ning tulemused olid järgnevad:

Tabel 5. Microsoft ennustusmudeli täpsus

	Keskmine eksimusmäär protsendipunktides	Vähim eksimusmäär protsendipunktides	Suurim eksimusmäär protsendipunktides
Ennustusjoon kollane (1-50)	22,95	0,11	47,93
Ennustusjoon roheline (51-100)	10,31	1,22	25,26
Ennustusjoon punane (101-150)	15,15	1,17	32,37
Ennustusperiood kokku (1-150)	16,14	0,11	47,93

Tabel 5 annab ülevaate ennustusmudeli täpsusest ja kasulikkusest. Üldiselt investorid ei saaks leppida mudeliga, mille keskmine eksimusmäär on 16,14 protsendipunkti võrra erinev reaalsest hinnatasemest.

3. Exxon Mobil



Joonis 14. Exxon Mobil ennustusmodel graafiliselt

Pealtnäha tundub ennustusmodel ebatäpne. Kuid selleks, et teha konkreetseid järeldusi, viis autor läbi teadusliku analüüsi, kasutades Stata statistikapaketti ning Excelit.

Tabel 6. Exxon Mobil ennustuse ja hinna korrelatsioon

Koefitsient	-0.0728
P-väärtus	0.3763

P-väärtus 37,6 % näitab, et ei ole võimalik nullhüpooteesi ümber lükata ehk teisisõnu võib koefitsient -0,0728 asemel olla 0. Excelis uuris autor ennustusmodeli sooritust detailsemalt ning tulemused olid järgnevad:


Tabel 7. Exxon Mobil ennustusmodeli täpsus

	Keskmine eksimusmäär protsendipunktides	Vähim eksimusmäär protsendipunktides	Suurim eksimusmäär protsendipunktides
Ennustusjoon kollane (1-50)	7,74	2	15,95

Ennustusjoo roheline (51-100)	2,51	0,0042	6,73
Ennustusjoo punane (101-150)	12,29	2,38	19,01
Ennustusperiood kokku (1-150)	7,51	0,0042	19,01

Tabel 7 annab ülevaate ennustusmudeli täpsusest ja kasulikkusest. Üldiselt investorid ei saaks leppida mudeliga, mille keskmine eksimusmäär on 7,51 protsendipunkti võrra erinev reaalsest hinnatasemest. Samas minimaalne erinevus oli 0,0042 %, mis on küllaltki hea tulemus.

4. Johnson & Johnson



Joonis 15. Johnson & Johnson ennustusmudel graafiliselt

Pealtnäha tundub ennustusmudel ebatäpne. Kuid selleks, et teha konkreetseid järeldusi, viis autor läbi teadusliku analüüsi, kasutades Stata statistikapaketti ning Excelit.

Tabel 8. Johnson & Johnson ennustuse ja hinna korrelatsioon

Koefitsient	0.1972*
-------------	---------

P-väärtus	0.0156
-----------	--------


P-väärtus 1,5 % näitab, et võib olla suhteliselt kindel, et korrelatsioonikoefitsient pole null, vaid hoopis 0,1972. Koefitsient 0,1972 näitab, et kaasliikumine on liiga nõrk, et mudelit praktikas kasutada. Excelis uuris autor ennustusmudeli sooritust detailsemalt ning tulemused olid järgnevad:

Tabel 9. Johnson & Johnson ennustusmudeli täpsus

	Keskmine eksimusmäär protsendipunktides	Vähim eksimusmäär protsendipunktides	Suurim eksimusmäär protsendipunktides
Ennustusjoon kollane (1-50)	8,29	1,5	13,99
Ennustusjoon roheline (51-100)	6,48	1,37	11,73
Ennustusjoon punane (101-150)	3,79	0,19	10,51
Ennustusperiood kokku (1-150)	6,19	0,19	13,99

Tabel 9 annab ülevaate ennustusmudeli täpsusest ja kasulikkusest. Üldiselt investorid ei saaks leppida mudeliga, mille keskmine eksimusmäär on 6,19 protsendipunkti võrra erinev reaalsest hinnatasemest. Samas minimaalne erinevus oli 0,19 %, mis on küllaltki hea tulemus.

5. Berkshire Hathaway



Joonis 16. Berkshire Hathaway ennustusmodell graafiliselt

Pealtnäha tundub ennustusmodell ebatäpne. Kuid selleks, et teha konkreetseid järeldusi, viis autor läbi teadusliku analüüsi, kasutades Stata statistikapaketti ning Excelit.

Tabel 10. Berkshire Hathaway ennustuse ja hinna korrelatsioon

Koefitsient	0.0964
P-väärtus	0.2404

P-väärtus 24 % näitab, et ei ole võimalik nullhüpooteesi ümber lükata ehk teisisõnu võib koefitsient 0,0964 asemel olla 0. Excelis uuris autor ennustusmodeli sooritust detailsemalt ning tulemused olid järgnevad:


Tabel 11. Berkshire Hathaway ennustusmodeli täpsus

	Keskmine eksimusmäär protsendipunktides	Vähim eksimusmäär protsendipunktides	Suurim eksimusmäär protsendipunktides
Ennustusjoon kollane (1-50)	5,31	0,08	10,51
Ennustusjoon roheline (51-100)	5,71	1,26	10,37

Ennustusjooon punane (101-150)	3,88	0,25	6,67
Ennustusperiood kokku (1-150)	4,97	0,08	10,51

Tabel 11 annab ülevaate ennustusmudeli täpsusest ja kasulikkusest. Mudeli keskmine eksimusmäär on 4,97 protsendipunkti võrra erinev reaalsest hinnatasemest, mis on parem näitaja, kui eelnevatel firmadel.

6. JP Morgan Chase



Joonis 17. JP Morgan Chase ennustusmudel graafiliselt

Pealtnäha tundub ennustusmudel ebatäpne. Kuid selleks, et teha konkreetseid järeldusi, viis autor läbi teadusliku analüüsi, kasutades Stata statistikapaketti ning Excelit.

Tabel 12. JP Morgan Chase ennustuse ja hinna korrelatsioon

Koefitsient	-0.1414
P-väärtus	0.0843


P-väärtus 8,4 % näitab, et ei ole võimalik nullhüpoteesi ümber lükata ehk teisisõnu võib koefitsient -0,1414 asemel olla 0. Excelis uuris autor ennustusmodeli sooritust detailsemalt ning tulemused olid järgnevad:

Tabel 13. JP Morgan Chase ennustusmodeli täpsus

	Keskmine eksimusmäär protsendipunktides	Vähim eksimusmäär protsendipunktides	Suurim eksimusmäär protsendipunktides
Ennustusjoon kollane (1-50)	5,59	0,02	12,45
Ennustusjoon roheline (51-100)	7,98	0,77	16,3
Ennustusjoon punane (101-150)	29,87	3,04	52,14
Ennustusperiood kokku (1-150)	14,48	0,02	52,14

Tabel 13 annab ülevaate ennustusmodeli täpsusest ja kasulikkusest. Üldiselt investorid ei saaks leppida mudeliga, mille keskmine eksimusmäär on 14,48 protsendipunkti võrra erinev reaalsest hinnatasemest. Suurim eksimusmäär 52,14 protsendipunkti on väga suur eksimus. Samas minimaalne erinevus oli 0,0042 %, mis on küllaltki hea tulemus.

7. Amazon



Joonis 18. Amazon ennustusmodel graafiliselt

Pealtnäha tundub ennustusmodel ebatäpne. Kuid selleks, et teha konkreetseid järeldusi, viis autor läbi teadusliku analüüsi, kasutades Stata statistikapaketti ning Excelit.

Tabel 14. Amazon ennustuse ja hinna korrelatsioon

Koefitsient	-0.4749*
P-väärtus	0.0000

P-väärtus 0,0000 näitab, et võib olla suhteliselt kindel, et korrelatsioonikoefitsient pole null, vaid hoopis -0,4749. Koefitsient -0,4749 näitab, et kaasliikumine on keskmise tugevusega pöördvõrdeline. Excelis uuris autor ennustusmodeli sooritust detailsemalt ning tulemused olid järgnevad:


Tabel 15. Amazon ennustusmodeli täpsus

	Keskmine eksimusmäär protsendipunktides	Vähim eksimusmäär protsendipunktides	Suurim eksimusmäär protsendipunktides
--	---	--------------------------------------	---------------------------------------

Ennustusjoon kollane (1-50)	3,27	0,09	9,47
Ennustusjoon roheline (51-100)	10,22	2,7	15,84
Ennustusjoon punane (101-150)	5,96	0,05	14,06
Ennustusperiood kokku (1-150)	6,48	0,05	15,84

Tabel 15 annab ülevaate ennustusmudeli täpsusest ja kasulikkusest. Üldiselt investorid ei saaks leppida mudeliga, mille keskmine eksimusmäär on 6,48 protsendipunkti võrra erinev reaalsest hinnatasemest.

8. General Electric



Joonis 19. General Electric ennustusmudel graafiliselt

Pealtnäha tundub ennustusmudel ebatäpne. Kuid selleks, et teha konkreetseid järeldusi, viis autor läbi teadusliku analüüsi, kasutades Stata statistikapaketti ning Excelit.

Tabel 16. General Electric ennustuse ja hinna korrelatsioon

Koefitsient	-0.4471*
P-väärtus	0.0000


P-väärtus 0,0000 % näitab, et võib olla suhteliselt kindel, et korrelatsioonikoefitsient pole null, vaid hoopis -0,4471. Koefitsient -0,4471 näitab, et kaasliikumine on keskmise tugevusega pöördvõrdeline. Excelis uuris autor ennustusmodeli sooritust detailsemalt ning tulemused olid järgnevad:

Tabel 17. General Electric ennustusmodeli täpsus

	Keskmine eksimusmäär protsendipunktides	Vähim eksimusmäär protsendipunktides	Suurim eksimusmäär protsendipunktides
Ennustusjoon kollane (1-50)	16,26	1,95	27,07
Ennustusjoon roheline (51-100)	3,44	0,05	7,27
Ennustusjoon punane (101-150)	19,76	1,29	30,49
Ennustusperiood kokku (1-150)	13,16	0,05	30,49

Tabel 17 annab ülevaate ennustusmodeli täpsusest ja kasulikkusest. Üldiselt investorid ei saaks leppida mudeliga, mille keskmine eksimusmäär on 13,16 protsendipunkti võrra erinev reaalsest hinnatasemest.

9. AT&T



Joonis 20. AT&T ennustusmudel graafiliselt

Pealtnäha tundub ennustusmudel ebatäpne. Kuid selleks, et teha konkreetseid järeldusi, viis autor läbi teadusliku analüüsi, kasutades Stata statistikapaketti ning Excelit.

Tabel 18. AT&T ennustuse ja hinna korrelatsioon

Koefitsient	0.5731*
P-väärtus	0.0000

P-väärtus 0,0000 % näitab, et võib olla suhteliselt kindel, et korrelatsioonikoefitsient pole null, vaid hoopis 0,5731. Koefitsient 0,5731 näitab, et kaasliikumine on keskmise tugevusega. Excelis uuris autor ennustusmudeli sooritust detailsemalt ning tulemused olid järgnevad:

Tabel 19. AT&T ennustusmudeli täpsus

	Keskmine eksimusmäär protsendipunktides	Vähim eksimusmäär protsendipunktides	Suurim eksimusmäär protsendipunktides
--	---	--------------------------------------	---------------------------------------

Ennustusjoon kollane (1-50)	10,72	3,63	19,62
Ennustusjoon roheline (51-100)	6,67	0,3	11,93
Ennustusjoon punane (101-150)	3,8	0,25	8,37
Ennustusperiood kokku (1-150)	7,07	0,25	19,62

Tabel 19 annab ülevaate ennustusemudeli täpsusest ja kasulikkusest. Üldiselt investorid ei saaks leppida mudeliga, mille keskmine eksimusmäär on 7,07 protsendipunkti võrra erinev reaalsest hinnatasemest. Järgnevalt võetakse USA ettevõtete tulemused kokku.

3.1.1 USA aktsiaturu uuringutulemuste kokkuvõte

Järgnevalt võetakse USA ettevõtete uuringutulemused kokku ning arvutatakse keskmine koefitsient ja eksimusmäär:

Tabel 20. USA uuringutulemuste kokkuvõte


	Koefitsient	Keskmine eksimusmäär
Apple	-0,1761	10,27
Microsoft	-0,2781	16,14
Exxon Mobil	-0,0728	7,51
Johnson & Johnson	0,1972	6,19
Berkshire Hathaway	0,0964	4,97
JP Morgan Chase	-0,1414	14,48
Amazon	-0,4749	6,48
General Electric	-0,4471	13,16
AT&T	0,5731	7,07
Kokku:	-	9,58

Üks ennustusmudel üheksast andis rahuldava tulemuse: keskmiselt tugev positiivne seos. Ennustus tehti AT&T kohta. Ülejäänud seosed olid kas liiga nõrgad või negatiivsed. Keskmine eksimusmäär tuli 9,58 protsendipunkti, mis investori seisukohast ei ole väga hea tulemus. USA ettevõtete kohta andis ennustusmudel üldiselt mitterahuldavad tulemused. Tulemusi võrreldakse hiljem Tallinna börsi tulemustega.

3.2 Tallinna börsi ettevõtete tulemused

Ennustusmudel ennustab iga ettevõtte kohta kolm ennustusjoont ning toob tulemused välja graafiliselt.

1. Arco Vara



Joonis 21. Arco Vara ennustusmudel graafiliselt

Pealtnäha tundub ennustusmudel ebatäpne. Kuid selleks, et teha konkreetseid järeldusi, viis autor läbi teadusliku analüüsi, kasutades Stata statistikapaketti ning Excelit.

Tabel 21. Arco Vara ennustuse ja hinna korrelatsioon

Koefitsient	0.5129*
P-väärtus	0.0000


P-väärtus 0,0000 % näitab, et võib olla suhteliselt kindel, et korrelatsioonikoefitsient pole null, vaid hoopis 0,5129. Koefitsient 0,5129 näitab, et kaasliikumine on keskmise tugevusega. Excelis uuris autor ennustusmodeli sooritust detailsemalt ning tulemused olid järgnevad:

Tabel 22. Arco Vara ennustusmodeli täpsus

	Keskmine eksimusmäär protsendipunktides	Vähim eksimusmäär protsendipunktides	Suurim eksimusmäär protsendipunktides
Ennustusjoon kollane (1-50)	14,26	2,4	24,04
Ennustusjoon roheline (51-100)	17,62	1,07	42,46
Ennustusjoon punane (101-150)	15,48	3,82	27,57
Ennustusperiood kokku (1-150)	15,78	1,07	42,46

Tabel 22 annab ülevaate ennustusmodeli täpsusest ja kasulikkusest. Üldiselt investoriid ei saaks leppida mudeliga, mille keskmine eksimusmäär on 15,78 protsendipunkti võrra erinev reaalsest hinnatasemest.

2. Baltika



Joonis 22. Baltika ennustusmodel graafiliselt

Pealtnäha tundub ennustusmodel ebatäpne. Kuid selleks, et teha konkreetseid järeldusi, viis autor läbi teadusliku analüüsi, kasutades Stata statistikapaketti ning Excelit.

Tabel 23. Baltika ennustuse ja hinna korrelatsioon

Koefitsient	0.4646*
P-väärtus	0.0000

P-väärtus 0,0000 % näitab, et võib olla suhteliselt kindel, et korrelatsioonikoefitsient pole null, vaid hoopis 0,4646. Koefitsient 0,4646 näitab, et kaasliikumine on keskmise tugevusega. Excelis uuris autor ennustusmodeli sooritust detailsemalt ning tulemused olid järgnevad:


Tabel 24. Baltika ennustusmodeli täpsus

	Keskmine eksimusmäär protsendipunktides	Vähim eksimusmäär protsendipunktides	Suurim eksimusmäär protsendipunktides
Ennustusjoon kollane (1-50)	16,17	0,83	28,52

Ennustusjoo roheline (51-100)	6,14	0,02	14,5
Ennustusjoo punane (101-150)	27,79	2,81	69,4
Ennustusperiood kokku (1-150)	16,7	0,02	69,4

Tabel 24 annab ülevaate ennustusmudeli täpsusest ja kasulikkusest. Üldiselt investorid ei saaks leppida mudeliga, mille keskmine eksimusmäär on 16,7 protsendipunkti võrra erinev reaalsest hinnatasemest. Samas minimaalne erinevus oli 0,02 %, mis on küllaltki hea tulemus.

3. Ekspress Grupp



Joonis 23. Ekspress Grupp ennustusmudel graafiliselt

Pealtnäha tundub ennustusmudel ebatäpne. Kuid selleks, et teha konkreetseid järeldusi, viis autor läbi teadusliku analüüsi, kasutades Stata statistikapaketti ning Excelit.

Tabel 25. Ekspress Grupp ennustuse ja hinna korrelatsioon

Koefitsient	-0.2652*
-------------	----------

P-väärtus	0.0010
-----------	--------

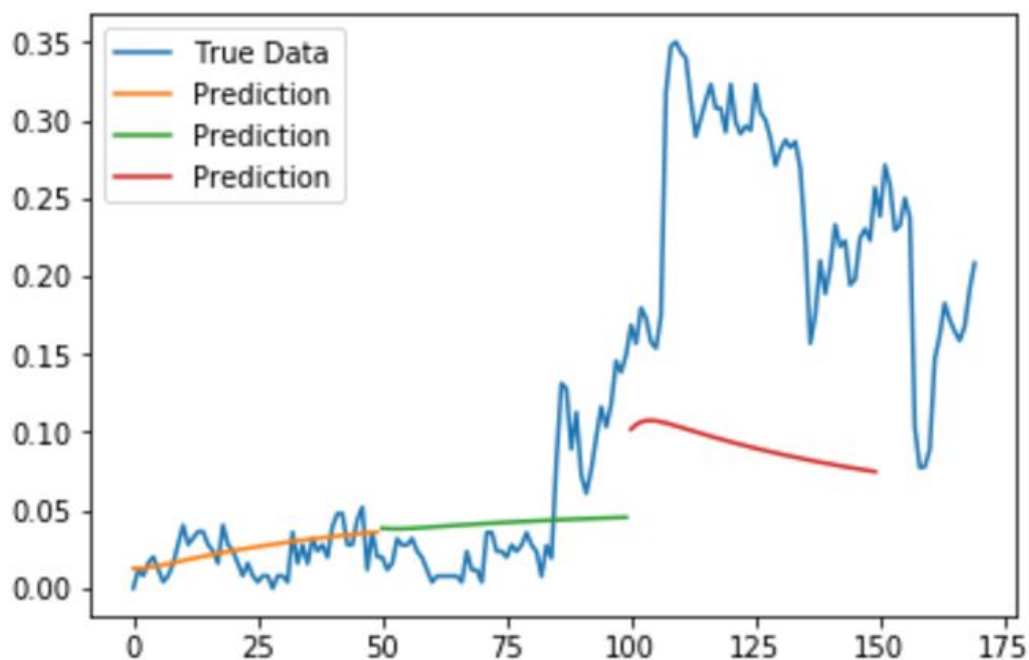
P-väärtus 0,0010 % näitab, et võib olla suhteliselt kindel, et korrelatsioonikoefitsient pole null, vaid hoopis -0,2652. Koefitsient -0,2652 näitab, et kaasliikumine on liiga nõrk, et mudelit praktikas kasutada. Excelis uuris autor ennustusmudeli sooritust detailsemalt ning tulemused olid järgnevad:

Tabel 26. Ekspress Grupp ennustusmudeli täpsus

	Keskmine eksimusmäär protsendipunktides	Vähim eksimusmäär protsendipunktides	Suurim eksimusmäär protsendipunktides
Ennustusjoon kollane (1-50)	2,46	0,01	6,57
Ennustusjoon roheline (51-100)	5,78	1,63	10,44
Ennustusjoon punane (101-150)	3,32	0,24	6,18
Ennustusperiood kokku (1-150)	3,85	0,01	10,44

Tabel 26 annab ülevaate ennustusmudeli täpsusest ja kasulikkusest. Senini vaieldamatult parim esitus ennustusmudeli poolt - keskmine eksimusmäär on 3,85 protsendipunkti võrra erinev reaalsest hinnatasemest. Minimaalne erinevus oli 0,01 %, mis on küllaltki hea tulemus.

4. Harju Elekter



Joonis 24. Harju Elekter ennustusmudel graafiliselt

Pealtnäha tundub ennustusmudel ebatäpne. Kuid selleks, et teha konkreetseid järeldusi, viis autor läbi teadusliku analüüsi, kasutades Stata statistikapaketti ning Excelit.

Tabel 27. Harju Elekter ennustuse ja hinna korrelatsioon

Koefitsient	0.9052*
P-väärtus	0.0000

P-väärtus 0,0000 % näitab, et võib olla suhteliselt kindel, et korrelatsioonikoefitsient pole null, vaid hoopis 0,9052. Koefitsient 0,9052 näitab, et kaasliikumine on väga tugev. Siiamaani parim näitaja. Excelis uuris autor ennustusmudeli sooritust detailsemalt ning tulemused olid järgnevad:


Tabel 28. Harju Elekter ennustusmudeli täpsus

	Keskmine eksimusmäär protsendipunktides	Vähim eksimusmäär protsendipunktides	Suurim eksimusmäär protsendipunktides
Ennustusjoon kollane (1-50)	1,13	0,002	2,80
Ennustusjoon roheline (51-100)	3,39	0,57	10,41

Ennustusjoo punane (101-150)	16,64	4,65	24,61
Ennustusperiood kokku (1-150)	7,05	0,002	24,61

Tabel 28 annab ülevaate ennustusmudeli täpsusest ja kasulikkusest. Üldiselt investorid ei saaks leppida mudeliga, mille keskmine eksimusmäär on 7,05 protsendipunkti võrra erinev reaalsest hinnatasemest. Samas minimaalne erinevus oli 0,002 %, mis on küllaltki hea tulemus.

5. Merko Ehitus



Joonis 25. Merko Ehitus graafiliselt

Pealtnäha tundub ennustusmudel ebatäpne. Kuid selleks, et teha konkreetseid järeldusi, viis autor läbi teadusliku analüüsi, kasutades Stata statistikapaketti ning Excelit.

Tabel 29. Merko Ehitus ennustuse ja hinna korrelatsioon

Koefitsient	-0.1271
P-väärtus	0.1213


P-väärtus 12 % näitab, et ei ole võimalik nullhüpoteesi ümber lükata ehk teisisõnu võib koefitsient -0,1271 asemel olla 0. Koefitsient -0,1271 näitab, et kaasliikumine on liiga nõrk, et mudelit praktikas kasutada. Excelis uuris autor ennustusmudeli sooritust detailsemalt ning tulemused olid järgnevad:

Tabel 30. Merko Ehitus ennustusmudeli täpsus

	Keskmine eksimusmäär protsendipunktides	Vähim eksimusmäär protsendipunktides	Suurim eksimusmäär protsendipunktides
Ennustusjoon kollane (1-50)	3,11	0,04	6,75
Ennustusjoon roheline (51-100)	6,13	0,26	11,53
Ennustusjoon punane (101-150)	7,54	0,02	17,47
Ennustusperiood kokku (1-150)	5,59	0,02	17,47

Tabel 30 annab ülevaate ennustusmudeli täpsusest ja kasulikkusest. Üldiselt investorid ei saaks leppida mudeliga, mille keskmine eksimusmäär on 5,59 protsendipunkti võrra erinev reaalsest hinnatasemest.

6. Nordecon



Joonis 26. Nordecon ennustumudel graafiliselt

Pealtnäha tundub ennustumudel ebatäpne. Kuid selleks, et teha konkreetseid järeldusi, viis autor läbi teadusliku analüüsi, kasutades Stata statistikapaketti ning Excelit.

Tabel 31. Nordecon ennustuse ja hinna korrelatsioon

Koefitsient	0.3457*
P-väärtus	0.0000

P-väärtus 0,0000 % näitab, et võib olla suhteliselt kindel, et korrelatsioonikoefitsient pole null, vaid hoopis -0,3457. Koefitsient -0,3457 näitab, et kaasliikumine on nõrgalt keskmise tugevusega. Excelis uuris autor ennustumudeli sooritust detailsemalt ning tulemused olid järgnevad:


Tabel 32. Nordecon ennustumudeli täpsus

	Keskmine eksimusmäär protsendipunktides	Vähim eksimusmäär protsendipunktides	Suurim eksimusmäär protsendipunktides
Ennustusjoon kollane (1-50)	3,32	0,09	8,79
Ennustusjoon roheline (51-100)	8,00	3,35	13,42

Ennustusjooon punane (101-150)	2,08	0,12	5,25
Ennustusperiood kokku (1-150)	4,47	0,09	13,42

Tabel 32 annab ülevaate ennustusmudeli täpsusest ja kasulikkusest. Üldiselt investorid ei saaks leppida mudeliga, mille keskmine eksimusmäär on 4,47 protsendipunkti võrra erinev reaalsest hinnatasemest.

7. Olympic Entertainment Group



Joonis 27. Olympic Entertainment Group ennustusmudel graafiliselt

Pealtnäha tundub ennustusmudel ebatäpne. Kuid selleks, et teha konkreetseid järeldusi, viis autor läbi teadusliku analüüsi, kasutades Stata statistikapaketti ning Excelit.

Tabel 33. Olympic Entertainment Group ennustuse ja hinna korrelatsioon

Koefitsient	0.7609*
P-väärtus	0.0000


P-väärtus 0,0000 % näitab, et võib olla suhteliselt kindel, et korrelatsioonikoefitsient pole null, vaid hoopis 0,7609. Koefitsient 0,7609 näitab, et kaasliikumine on tugev. Excelis uuris autor ennustusmudeli sooritust detailsemalt ning tulemused olid järgnevad:

Tabel 34. Olympic Entertainment Group ennustusmudeli täpsus

	Keskmine eksimusmäär protsendipunktides	Vähim eksimusmäär protsendipunktides	Suurim eksimusmäär protsendipunktides
Ennustusjoon kollane (1-50)	6,32	1,37	9,64
Ennustusjoon roheline (51-100)	6,12	2,74	9,32
Ennustusjoon punane (101-150)	3,45	0,04	7,82
Ennustusperiood kokku (1-150)	5,30	0,04	9,64

Tabel 34 annab ülevaate ennustusmudeli täpsusest ja kasulikkusest. Üldiselt investorid ei saaks leppida mudeliga, mille keskmine eksimusmäär on 5,3 protsendipunkti võrra erinev reaalsest hinnatasemest.

8. PRFoods



Joonis 28. PRFoods ennustusmudel graafiliselt

Pealtnäha tundub ennustusmudel ebatäpne. Kuid selleks, et teha konkreetseid järeldusi, viis autor läbi teadusliku analüüsi, kasutades Stata statistikapaketti ning Excelit.

Tabel 35. PRFoods ennustuse ja hinna korrelatsioon

Koefitsient	-0.3395*
P-väärtus	0.0000

P-väärtus 0,0000 % näitab, et võib olla suhteliselt kindel, et korrelatsioonikoefitsient pole null, vaid hoopis -0,3395. Koefitsient -0,3395 näitab, et kaasliikumine on nõrgalt keskmise pöördvõrdelise tugevusega. Excelis uuris autor ennustusmudeli sooritust detailsemalt ning tulemused olid järgnevad:


Tabel 36. PRFoods ennustusmudeli täpsus

	Keskmine eksimusmäär protsendipunktides	Vähim eksimusmäär protsendipunktides	Suurim eksimusmäär protsendipunktides
Ennustusjoon kollane (1-50)	4,09	0,01	9,75

Ennustusjooon roheline (51-100)	5,04	0,11	11,41
Ennustusjooon punane (101-150)	11,25	0,74	22,28
Ennustusperiood kokku (1-150)	6,79	0,01	22,28

Tabel 36 annab ülevaate ennustusmudeli täpsusest ja kasulikkusest. Üldiselt investorid ei saaks leppida mudeliga, mille keskmine eksimusmäär on 6,79 protsendipunkti võrra erinev reaalsest hinnatasemest. Samas minimaalne erinevus oli 0,01 %, mis on küllaltki hea tulemus.

9. Silvano Fashion Group



Joonis 29. Silvano Fashion Group ennustusmudel graafiliselt

Pealtnäha tundub ennustusmudel ebatäpne. Kuid selleks, et teha konkreetseid järeldusi, viis autor läbi teadusliku analüüsi, kasutades Stata statistikapaketti ning Excelit.

Tabel 37. Silvano Fashion Group ennustuse ja hinna korrelatsioon

Koefitsient	-0.3294*
-------------	----------

P-väärtus	0.0000
-----------	--------


P-väärtus 0,0000 % näitab, et võib olla suhteliselt kindel, et korrelatsioonikoefitsient pole null, vaid hoopis -0,3294. Koefitsient -0,3294 näitab, et kaasliikumine on nõrgalt keskmise pöördvõrdelise tugevusega. Excelis uuris autor ennustusmudeli sooritust detailsemalt ning tulemused olid järgnevad:

Tabel 38. Silvano Fashion Group ennustusmudeli täpsus

	Keskmine eksimusmäär protsendipunktides	Vähim eksimusmäär protsendipunktides	Suurim eksimusmäär protsendipunktides
Ennustusjoon kollane (1-50)	4,87	0,19	15,18
Ennustusjoon roheline (51-100)	6,18	1,36	22,15
Ennustusjoon punane (101-150)	37,35	0,33	71,60
Ennustusperiood kokku (1-150)	16,13	0,19	71,60

Tabel 38 annab ülevaate ennustusmudeli täpsusest ja kasulikkusest. Üldiselt investorid ei saaks leppida mudeliga, mille keskmine eksimusmäär on 16,13 protsendipunkti võrra erinev reaalsest hinnatasemest.

10. Skano



Joonis 30. Skano ennustumudel graafiliselt

Pealtnäha tundub ennustumudel ebatäpne. Kuid selleks, et teha konkreetseid järeldusi, viis autor läbi teadusliku analüüsi, kasutades Stata statistikapaketti ning Excelit.

Tabel 39. Skano ennustuse ja hinna korrelatsioon

Koefitsient	0.1453
P-väärtus	0.0761

P-väärtus 7,6 % näitab, et ei ole võimalik nullhüpoteesi ümber lükata ehk teisisõnu võib koefitsient 0,1453 asemel olla 0. Koefitsient 0,1453 näitab, et kaasliikumine on liiga nõrk, et mudelit praktikas kasutada. Excelis uuris autor ennustumudeli sooritust detailsemalt ning tulemused olid järgnevad:


Tabel 40. Skano ennustumudeli täpsus

	Keskmine eksimusmäär protsendipunktides	Vähim eksimusmäär protsendipunktides	Suurim eksimusmäär protsendipunktides
Ennustusjoon kollane (1-50)	6,91	2,09	14,04
Ennustusjoon roheline (51-100)	10,09	0,52	19,24

Ennustusjoo punane (101-150)	16,56	1,01	45,21
Ennustusperiood kokku (1-150)	11,19	0,52	45,21

Tabel 40 annab ülevaate ennustusmudeli täpsusest ja kasulikkusest. Üldiselt investorid ei saaks leppida mudeliga, mille keskmine eksimusmäär on 11,19 protsendipunkti võrra erinev reaalsest hinnatasemest.

11. Tallink



Joonis 31. Tallink ennustusmudel graafiliselt

Pealtnäha tundub ennustusmudel ebatäpne. Kuid selleks, et teha konkreetseid järeldusi, viis autor läbi teadusliku analüüsi, kasutades Stata statistikapaketti ning Excelit.

Tabel 41. Tallink ennustuse ja hinna korrelatsioon

Koefitsient	0.5728*
P-väärtus	0.0000


P-väärtus 0,00 % näitab, et võib olla suhteliselt kindel, et korrelatsioonikoefitsient pole null, vaid hoopis 0,5728. Koefitsient 0,5728 näitab, et kaasliikumine on keskmise tugevusega. Excelis uuris autor ennustusmodeli sooritust detailsemalt ning tulemused olid järgnevad:

Tabel 42. Tallink ennustusmodeli täpsus

	Keskmine eksimusmäär protsendipunktides	Vähim eksimusmäär protsendipunktides	Suurim eksimusmäär protsendipunktides
Ennustusjoon kollane (1-50)	4,79	0,006	9,44
Ennustusjoon roheline (51-100)	12,48	3,74	19,13
Ennustusjoon punane (101-150)	4,32	0,02	14,36
Ennustusperiood kokku (1-150)	7,20	0,02	19,13

Tabel 42 annab ülevaate ennustusmodeli täpsusest ja kasulikkusest. Üldiselt investorid ei saaks leppida mudeliga, mille keskmine eksimusmäär on 7,20 protsendipunkti võrra erinev reaalsest hinnatasemest. Samas minimaalne erinevus oli 0,02 %, mis on küllaltki hea tulemus.

12. Tallinna Kaubamaja



Joonis 32. Tallinna Kaubamaja ennustusmudel graafiliselt

Pealtnäha tundub ennustusmudel ebatäpne. Kuid selleks, et teha konkreetseid järeldusi, viis autor läbi teadusliku analüüsi, kasutades Stata statistikapaketti ning Excelit.

Tabel 43. Tallinna Kaubamaja ennustuse ja hinna korrelatsioon

Koefitsient	-0.0429
P-väärtus	0.6021

P-väärtus 60 % näitab, et ei ole võimalik nullhüpoteesi ümber lükata ehk teisisõnu võib koefitsient -0,0429 asemel olla 0. Koefitsient -0,0429 näitab, et kaasliikumine on liiga nõrk, et mudelit praktikas kasutada. Excelis uuris autor ennustusmudeli sooritust detailsemalt ning tulemused olid järgnevad:


Tabel 44. Tallinna Kaubamaja ennustusmudeli täpsus

	Keskmine eksimusmäär protsendipunktides	Vähim eksimusmäär protsendipunktides	Suurim eksimusmäär protsendipunktides
Ennustusjoon kollane (1-50)	6,17	0,009	13,14
Ennustusjoon roheline (51-100)	3,98	0,002	9,35

Ennustusjoo punane (101-150)	2,55	0,01	7,39
Ennustusperiood kokku (1-150)	4,23	0,002	13,14

Tabel 44 annab ülevaate ennustusmudeli täpsusest ja kasulikkusest. Üldiselt investorid ei saaks leppida mudeliga, mille keskmine eksimusmäär on 4,23 protsendipunkti võrra erinev reaalsest hinnatasemest. Samas minimaalne erinevus oli 0,002 %, mis on küllaltki hea tulemus.

13. Tallinna Vesi



Joonis 33. Tallinna Vesi ennustusmudel graafiliselt

Pealtnäha tundub ennustusmudel ebatäpne. Kuid selleks, et teha konkreetseid järeldusi, viis autor läbi teadusliku analüüsi, kasutades Stata statistikapaketti ning Excelit.

Tabel 45. Tallinna Vesi ennustuse ja hinna korrelatsioon

Koefitsient	-0.3090*
P-väärtus	0.0001

P-väärtus 0,0001 % näitab, et võib olla suhteliselt kindel, et korrelatsioonikoefitsient pole null, vaid hoopis -0,3090. Koefitsient -0,3090 näitab, et kaasliikumine on nõrga negatiivse tugevusega. Excelis uuris autor ennustusmudeli sooritust detailsemalt ning tulemused olid järgnevad:

Tabel 46. Tallina Vesi ennustusmudeli täpsus

	Keskmine eksimusmäär protsendipunktides	Vähim eksimusmäär protsendipunktides	Suurim eksimusmäär protsendipunktides
Ennustusjoon kollane (1-50)	4,52	0,23	9,63
Ennustusjoon roheline (51-100)	8,79	3,12	12,19
Ennustusjoon punane (101-150)	7,13	1,08	11,68
Ennustusperiood kokku (1-150)	6,81	0,23	12,19

Tabel 46 annab ülevaate ennustusmudeli täpsusest ja kasulikkusest. Üldiselt investorid ei saaks leppida mudeliga, mille keskmine eksimusmäär on 6,81 protsendipunkti võrra erinev reaalsest hinnatasemest. Järgnevalt võetakse Tallinna börsi tulemused kokku.

3.2.1 Tallinna börsi uuringutulemuste kokkuvõte

Järgnevalt võetakse Tallinna börsi uuringutulemused kokku ning arvutatakse keskmine koefitsient ja eksimusmäär:

Tabel 47. Tallinna börsi uuringutulemuste kokkuvõte

	Koefitsient	Keskmine eksimusmäär
Arco Vara	0,5129	15,78
Baltika	0,4646	16,7
Ekspress Grupp	-0,2652	3,85
Harju Elekter	0,9052	7,05
Merko Ehitus	-0,1271	5,59

Nordecon	0,3457	4,47
Olympic Entertainment Group	0,7609	5,3
PRFoods	-0,3395	6,79
Silvano Fashion Group	-0,3294	16,13
Skano	0,1453	11,19
Tallink	0,0528	7,20
Tallinna Kaubamaja	-0,0429	4,23
Tallinna Vesi	-0,3090	6,81
Kokku:	-	8,54

Positiivse tulemuse andsid 5 ennustusmodelit kolmeteistkümnest. Kaks ennustusmodelit (Harju Elekter ja Olympic Entertainment Group) andsid väga hea tulemuse: tugev positiivne seos. Kolm ennustusmodelit (Arco Vara, Baltika ja Nordecon) andsid rahuldava tulemuse: keskmiselt tugev positiivne seos. Ülejäänud seosed olid kas liiga nõrgad või negatiivsed. Keskmise eksimusmäär tuli 8,54 mis investori seisukohast ei ole väga hea tulemus. Üldiselt andis ennustusmodel Tallinna börsiettevõtete ettevõtete kohta andis mitterahuldavad tulemused. Tulemusi võrreldakse järgnevalt USA tulemustega.

3.3 Uuringutulemuste võrdlemine

Kahe börsi võrdlemiseks kasutati väljaarvutatud koefitsiente ning keskmist eksimusmäära. Võrdlus on järgmine:

Tabel 48. Aktsiaturgude võrdlus

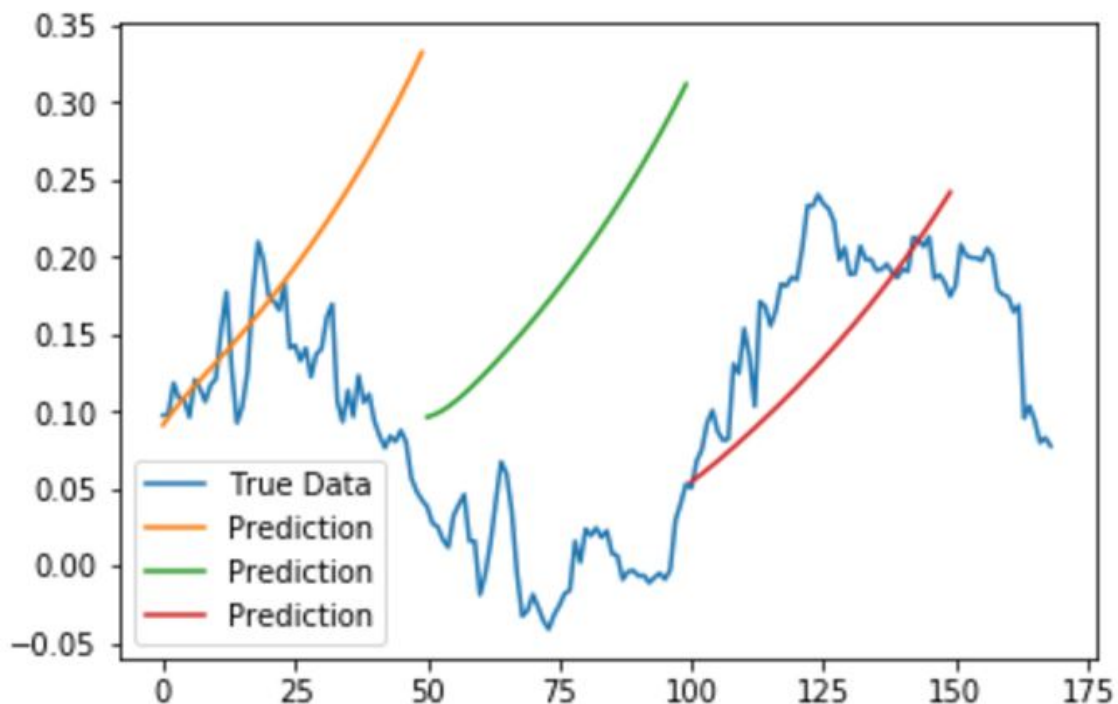
	Koefitsient	Keskmine eksimusmäär
USA ettevõtted	9/1	9,58

Tallinna Börs	13/5	8,54
---------------	------	------

Turge võrreldes toimis ennustusmodel Tallinna börsil paremini. Koefitsiendi alusel läbis testi üks USA ettevõtte, seevastu Tallinna börsilt viis. USA keskmine eksimusmäär oli 9,58, Tallinna börsil 8,54. Kuigi Tallinna börsil olid tulemused paremad, esines ennustusmodel mõlema turu ettevõtete peal äärmiselt halvasti. Peale selle ilmnes uuringu lõpus ennustusmodeli kohta veel teinegi murettekitav aspekt, mida kirjeldab järgnev peatükk.


3.4 Esinenud probleemid

Pärast uuringu läbiviimist otsustas autor kontrolli mõttes rakendada ennustusmodelit teist korda kõikide ettevõtete peal. Ilmnes probleem, et osade ettevõtete teine ennustusgraafik oli esimesest erinev. Alljärgnev joonis illustreerib probleemi:



Joonis 34. Apple ennustusmodel esimesel korral

Teisel katsel oli tulemus tunduvalt erinev esimesest katsest:



Joonis 35. Apple ennustusmudel teisel korral

Ruumi kokkuhoiu mõttes ei hakka autor teisi erineva ennustusega pilte lisama. USA poole pealt andsid erineva tulemuse järgmised ettevõtted:

- Apple
- Microsoft
- Berkshire Hathaway

Tallinna börsi poole pealt andsid erineva tulemuse järgmised ettevõtted:

- Arco vara
- Baltika
- Ekspress Grupp
- Merko Ehitus
- Tallink

Uuringus osales 22 ettevõtet. Kaheksa ettevõtte ennustusjooned olid teistkordsel mudeli kasutamisel erinevad. See seab ennustusmudeli usaldusväarsuse kahtluse alla, kuna samade andmete puhul peaks ennustusmudel genereerima samad tulemused.

3.5 Hinnang ennustusmudelile

Ennustusmudeli täpsuse hindamiseks kasutas autor statistikaprogrammi Stata korrelatsioonanalüüsi, mis näitab ennustusgraafiku kaasliikumist reaalinna graafikuga. Statistikatavast tulenevalt näitab suurem koefitsient kui 0,7 tugevat kaasliikumist ja väiksem kui 0,3 nõrka. USA ettevõtete puhul andis üks ennustusmudel üheksast rahuldava tulemuse, milleks oli keskmiselt tugev positiivne seos. Ennustus tehti AT&T kohta (telekommunikatsioon). Ülejäänud seosed olid kas liiga nõrgad või negatiivsed. Keskmine eksimismäär tuli 9,58 protsendipunkti, mis investori seisukohast ei ole väga hea tulemus.

Tallinna börsi puhul andsid positiivse tulemuse 5 ennustusmudelit kolmeteistkümnest. Keskmine eksimismäär tuli 8,54 protsendipunkti, millega investor kindlasti rahule ei saa jääda. Lisaks sellele oli mõlemal turul mitme ettevõtte P-väärtus suur, mis tähendab, et tõenäoliselt oli saadud koefitsient juhuslik. P-väärtus näitab kui kindel saab koefitsiendi numbris olla.

Eelnevat kokku võttes saab ennustusmudeli sooritust hinnata mitterahuldavalt, kuna korrelatsioon oli nõrk ning eksimismäär väga kõrge. Samuti ei ole mõtet tuua välja ettevõtteid sektoripõhiselt, kuna ennustusmudel esines kõikjal halvasti. Rahalise näitena välja tuues oletame, et Äripäeva poolt loodud Investor Toomas investeerib ettevõttesse 20000 eurot, siis 8,54 % eksimus tähendab juba 1708 eurost rahalist kaotust. Just selline oli Tallinna börsi keskmine eksimismäär.

Mõnes kohas oli teatud perioodil ennustusmudeli esitus küllaltki hea (nt Harju Elektri esimene periood). Mudel suutis enamasti näidata ära aktsia hinnasuuna, kuid ei tabanud turuolukorra muutusi. Sellest tulenesidki suured eksimismäärad.

Peale selle andis ennustusmudel mitmete ettevõtete kohta erinevaid ennustusjooni, mis seab tema usaldusväarsuse veelgi enam kahtluse alla. Kuna magistritöö eesmärk oli anda hinnang ennustusmudelile, siis põhjuste väljaselgitamine, miks ennustab algoritm erinevalt, võib jääda järgnevateks uuringuteks. Võttes kõike eelpool mainitud arvesse,

saab hinnata ennustumudelit mitterahuldavalt ning investor ei saa seda reaalses keskkonnas rakendada.

3.6 Järeldused ja ettepanekud

Kuna tasuta lõunaid ei ole olemas, siis ei tasu eeldada, et vabalt kättesaadavad ennustumudelid annavad suurepäraseid tulemusi, millega saab börsidel kiirelt raha teenima hakata. Üldiselt on teada, et pangad ning erinevad investeerimisfondid kasutavad aktsiaturgudel ennustusalgoritme, kuid need on laiale üldsuse eest varjatud. Algoritmide väljatöötamiseks on loodud eraldi osakonnad.

Autor usub, et on parema tulemuse saamiseks peaks ennustumudel kasutama rohkem sisendeid kui ainult aktsiate sulgemishinnad. Praegune mudel suutis enamasti hinnasuunda näidata, aga ei tunnetanud turu muutumishetke, seetõttu võiks algoritm kasutada mitmeid erinevaid sisendeid.

Näiteks võiks kombineerida algoritmi selliselt, et arvestatakse erinevaid fundamentaalnäitajaid, olulisi uudiseid ning hinnaliikumisi. See teema võiks sobida edasiseks uurimiseks.

Kokkuvõte

Käesoleva töö eesmärk oli rakenda aktsiate hinnasuuna ennustusmudelit USA aktsiaturu üheksa suurima turuväärtusega ettevõtte ning Tallinna börsil noteeritud ettevõtete vahel. Selleks tutvuti masinõppe meetodiga, mis võtab algandmetena arvesse aktsiate mineviku sulgemishindu, et selle põhjal ennustada treenitud andmete tuleviku sulgemishindu. Selleks kasutati pikka lühiajalist mälu (ingl k *long short term memory*). Uuringu läbiviimiseks koguti kokku algandmed (aktsiate sulgemishinnad perioodil 2010-2017), installiti vajalikud programme nagu Keras ja Tensorflow. Tulemused kuvati graafiliselt. Autori parima teadmise juures polnud sellist uuringut varem läbi viidud.

Töö olulisemaks tulemuseks on ennustusmudeli toimimise võrdlemine kahel erineval turul ning ennustusmudeli hindamine. Ennustusmudeli hindamiseks kasutati statistikaprogrammi Statat ning Excelit. Mudelit hinnati korrelatsioonikoefitsiendi, P-väärtuse ja keskmise eksimusmääraga protsendipunktides reaalse hinnamuutuse ja ennustusjoonte vahel.

Autor ootas enne uuringu läbiviimist ennustusmudelilt paremaid tulemusi. Ennustusmudel esines Tallinna börsil paremini, kuigi mõlemal puhul olid tulemused mitterahuldavad. Korrelatsioonikoefitsiendi puhul andis üks USA-s rakendatud ennustusmudel üheksast rahuldava tulemuse, Tallinna börsi puhul viis ennustusmudelit kolmeteistkümnest. Lisaks sellele oli mitme ettevõtte puhul P-väärtus suur, mis tähendab, et tõenäoliselt oli saadud koefitsient juhuslik. Keskmise eksimusmäär USA-s oli 9,58 protsendipunkti, Tallinna börsil 8,54 protsendipunkti. Uuringu teistkordsel läbiviimisel andis ennustusmudel mitmete ettevõtete kohta erinevad ennustusjooned, mis seab mudeli usaldusväärse kahtluse alla. Kuna uuringu eesmärk oli ennustusmudelile hinnangu andmine, siis selle probleemi uurimine võib sobida tulevaseks uurimisteenaks. Investor ei saa antud ennustusmudelit reaalses olukorras kasutada.

Praegune mudel suutis enamasti näidata hinnasuunda, aga ei tunnetanud turu muutumishetke, seetõttu võiks algoritm kasutada mitmeid erinevaid sisendeid. Autor usub, et masinõppe meetodit kasutades saab ehitada parema mudeli. Selleks peaks mudel

võtma arvesse rohkem sisendeid, nagu fundamentaalnäitajad, uudised ning hinnaliikumised. Järgnevatiks uurimisteedeks võib jääda just sellise mudeli loomine.

Summary

The purpose of this thesis is to apply a stock price prediction model to the nine biggest market capitalization companies listed on the USA stock market and on companies trading on the Tallinn stock exchange. The prediction model uses a machine learning method that takes into account previous stock closing prices (period 2010-2017) to predict future closing prices. Used method is called long short-term memory (LSTM). To achieve this goal, a theoretical introduction to the topic is made after which the author collects initial data. Next, an environment is created, where necessary libraries like Keras and Tensorflow are installed. The prediction model is applied on USA and Tallinn stock exchange listed companies. Results are presented graphically. To the author's best knowledge, there has never been performed that kind of research.

The main outcome of this thesis is a comparison of the performance of the prediction model on two different markets and an evaluation of that model. For evaluation there are used statistical program Stata and Excel. Model was evaluated with correlation coefficient, P-value and average error rate compared to real price change and prediction line.

Performance of the prediction model was better on the Tallinn stock exchange, although results were unsatisfactory. Correlation coefficient gave satisfied result for only one USA company from nine, Tallinn's stock exchange number was five from 13. In addition to that, the P-value of various companies was very large and that means that coefficient was randomly selected. Average error rate in USA was 9,58 percentage points and Tallinn stock exchange error rate was 8,54 percentage points. When author carried out the research for the second time, then prediction model gave different prediction lines for several companies. That puts prediction model's credibility under question. Since the thesis main goal was to evaluate prediction of the model's performance, then solving that problem can be future examine topic. From investor point of view, model can not be used in real situations.

Current model was able to show price directions in some cases, but could not sense market changing moments. Author believes that by using machine learning method there is a chance to build a better prediction model. For that, model must use more inputs, like fundamentals, news and price movement for example. Mentioned subject can also be the topic for future studies.

Kasutatud kirjandus

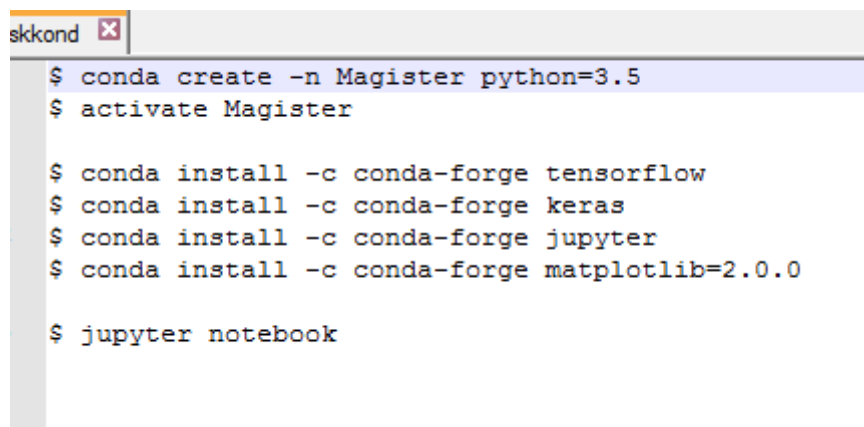
1. A Beginner's Guide to Recurrent Networks and LSTMs. [WWW]
<https://deeplearning4j.org/lstm.html#recurrent> (12.04.2017)
2. Abadi, M. (2016). Tensorflow: Learning Functions at Scale. [WWW]
http://delivery.acm.org/10.1145/2980000/2976746/p1-abadi.pdf?ip=193.40.244.196&id=2976746&acc=ACTIVE%20SERVICE&key=D2103A8F5527A3D9%2E5764A7F6B87355B6%2E4D4702B0C3E38B35%2E4D4702B0C3E38B35&CFID=759465292&CFTOKEN=32875271&__acm__=1494087817_ecf76f7467ce8f5114ae69872f77cd9f#URLTOKEN#
(02.04.2017)
3. Amadeo, K. (2016). What does the S & P 500 tell you about stocks. [WWW]
<https://www.thebalance.com/what-is-the-sandp-500-3305888> (05.03.2017)
4. An open-source software library for Machine Intelligence. [WWW]
<https://www.tensorflow.org/> (15.04.2017)
5. Conner-Simons, A. (2015). Deep-learning algorithm predicts photos memorability at "near-human" levels. [WWW] <http://news.mit.edu/2015/csail-deep-learning-algorithm-predicts-photo-memorability-near-human-levels-1215>
(07.04.2017)
6. Erickson, B., Korfiatis, P., Akkus, Z., Kline, T., Philbrick, K. (2017). Toolkits and Libraries for Deep Learning. [WWW]
(<https://link.springer.com/article/10.1007/s10278-017-9965-6>) (15.04.2017)
7. Google finance koduleht. [WWW] <https://www.google.com/finance>
(05.03.2017)
8. IT terministandardi sõnastik. [WWW] <http://www.eki.ee/dict/its/>

9. iShares Core S&P 500 ETF. [WWW] <https://www.ishares.com/us/literature/fact-sheet/ivv-ishares-core-s-p-500-etf-fund-fact-sheet-en-us.pdf> (06.03.2017)
10. Louridas, P., Ebert, C. Machine Learning (2016). [WWW] <http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=7548905> (07.04.2017)
11. Milosevic, N. (2016) Equity forecast: Predicting long term stock price movement using machine learning. [WWW] <https://arxiv.org/abs/1603.00751v1> (02.05.2017)
12. Müller, C., Guido, S. (2016). Introduction to Machine Learning with Python. [WWW] [http://proquestcombo.safaribooksonline.com/book/programming/machine-learning/9781449369880/1dot-introduction/scikit_learn_html?query=\(\(scikit+learn\)\)#X2ludGVybmFsX0h0bWxWaWV3P3htbGlkPTk3ODE0NDkzNjk4ODAlMkZtYXRwbG90bGliX2h0bWwmcXVlcnk9KChzY2lraXQIMjBsZWYybikp](http://proquestcombo.safaribooksonline.com/book/programming/machine-learning/9781449369880/1dot-introduction/scikit_learn_html?query=((scikit+learn))#X2ludGVybmFsX0h0bWxWaWV3P3htbGlkPTk3ODE0NDkzNjk4ODAlMkZtYXRwbG90bGliX2h0bWwmcXVlcnk9KChzY2lraXQIMjBsZWYybikp) (27.04.2017)
13. Nasdaq koduleht. [WWW] <http://www.nasdaq.com/> (05.03.2017)
14. Nasdaq Tallinn ja Eesti Väärtpaberikeskus. [WWW] <http://www.nasdaqbaltic.com/et/bors/ettevottest/nasdaq-omx-tallinn/> (01.03.2017)
15. Olah, C. (2015). Understanding LSTM Networks. [WWW] <http://colah.github.io/posts/2015-08-Understanding-LSTMs/> (12.04.2017)
16. Raval, S. (2017). How To Predict Stock Prices Easily Demo. [WWW] <https://github.com/IISourceCell/How-to-Predict-Stock-Prices-Easily-Demo/blob/master/stockdemo.ipynb> (01.03.2017)
17. Roos, A., Ivanova, N., Sander, P., Nurmet, M. Finantsturud-ja institutsioonid. Tartu: Tartu Ülikooli Kirjastus, 2012, lk 153). (01.03.2017)
18. Sander, P. Portfelliteooria II, Tartu: Tartu Ülikooli Kirjastus, 2003, lk 72. (01.03.2017)

19. Saxena, A. (2016). Convolutional Neural Networks: An illustration in Tensorflow. [WWW] http://delivery.acm.org/10.1145/2960000/2951024/p56-saxena.pdf?ip=193.40.244.196&id=2951024&acc=ACTIVE%20SERVICE&key=D2103A8F5527A3D9%2E5764A7F6B87355B6%2E4D4702B0C3E38B35%2E4D4702B0C3E38B35&CFID=759465292&CFTOKEN=32875271&__acm__=1494087516_06b54af6455a6c028f5d6e3c3c66eb54#URLTOKEN#
(26.04.2017)
20. Shai, S. S., Shai, B. D. (2014) Understanding machine learning. [WWW] https://books.google.ee/books?id=ttJkAAQBAJ&printsec=frontcover&source=gbs_ViewAPI&redir_esc=y#v=onepage&q&f=false (26.04.2017)
21. S&P 500 Index – 90 Year Historical Chart. [WWW] <http://www.macrotrends.net/2324/sp-500-historical-chart-data> (01.03.2017)
22. Veskimägi, M. (2006). Efektiivse turu hüpoteesi empiiriline testimine Tallinna Börsil: magistritöö. Tartu Ülikool, Tartu 2006. (03.03.2017)
23. Yahoo finance koduleht. [WWW] <https://finance.yahoo.com/> (05.03.2017)

Lisa 1 – Pakettide installimine ja keskkonna loomine

Järgnevalt on esitatud uuringuks vajamineva keskkonna loomine. Autor installis oma arvutisse keskkonna Anaconda3 versiooni 4.3.1. Seejärel avati Anaconda käsurida ning loodi keskkond programmeerimiskeeles python 3.5, kuna windows operatsioonisüsteemis töötab tensorflow ainult eelpool mainitud versiooniga. Järgnevalt installiti vajalikud paketid. Vaata joonist:



```
skkond x
$ conda create -n Magister python=3.5
$ activate Magister

$ conda install -c conda-forge tensorflow
$ conda install -c conda-forge keras
$ conda install -c conda-forge jupyter
$ conda install -c conda-forge matplotlib=2.0.0

$ jupyter notebook
```

Joonis L1-1. Keskkonna loomine

Loodud keskkonna 'Lib' kausta tuleb lisada lstm.py fail, mis näeb välja järgmine:

```

1  import time
2
3  import warnings
4
5  import numpy as np
6
7  from numpy import newaxis
8
9  from keras.layers.core import Dense, Activation, Dropout
10
11 from keras.layers.recurrent import LSTM
12
13 from keras.models import Sequential
14
15 import matplotlib.pyplot as plt
16
17
18
19
20
21 warnings.filterwarnings("ignore")
22
23
24
25 def plot_results_multiple(predicted_data, true_data, prediction_len):
26     fig = plt.figure(facecolor='white')
27
28     ax = fig.add_subplot(111)
29
30     ax.plot(true_data, label='True Data')
31
32     print ('yo')
33
34     #Pad the list of predictions to shift it in the graph to it's correct start
35
36
37     for i, data in enumerate(predicted_data):
38
39         padding = [None for p in range(i * prediction_len)]
40
41         plt.plot(padding + data, label='Prediction')
42
43         plt.legend()
44
45     plt.show()
46

```

```

48
49 def load_data(filename, seq_len, normalise_window):
50
51     f = open(filename, 'r').read()
52
53     data = f.split('\n')
54
55
56
57     sequence_length = seq_len + 1
58
59     result = []
60
61     for index in range(len(data) - sequence_length):
62         result.append(data[index: index + sequence_length])
63
64
65
66
67     if normalise_window:
68         result = normalise_windows(result)
69
70
71
72
73     result = np.array(result)
74
75
76
77     row = round(0.9 * result.shape[0])
78
79     train = result[:int(row), :]
80
81     np.random.shuffle(train)
82
83     x_train = train[:, :-1]
84
85     y_train = train[:, -1]
86
87     x_test = result[int(row):, :-1]
88
89     y_test = result[int(row):, -1]
90
91
92
93     x_train = np.reshape(x_train, (x_train.shape[0], x_train.shape[1], 1))
94
95     x_test = np.reshape(x_test, (x_test.shape[0], x_test.shape[1], 1))
96
97
98
99     return [x_train, y_train, x_test, y_test]
100
101
102
103 def normalise_windows(window_data):
104
105     normalised_data = []
106
107     for window in window_data:
108         normalised_window = [(float(p) / float(window[0])) - 1 for p in window]
109         normalised_data.append(normalised_window)
110
111
112     return normalised_data
113
114

```

```

116
117 def build_model(layers):
118
119     model = Sequential()
120
121
122
123     model.add(LSTM(
124         input_dim=layers[0],
125         output_dim=layers[1],
126         return_sequences=True))
127
128
129     model.add(Dropout(0.2))
130
131
132
133
134
135     model.add(LSTM(
136         layers[2],
137         return_sequences=False))
138
139
140     model.add(Dropout(0.2))
141
142
143
144
145     model.add(Dense(
146         output_dim=layers[3]))
147
148     model.add(Activation("linear"))
149
150
151
152
153     start = time.time()
154
155     model.compile(loss="mse", optimizer="rmsprop")
156
157     print ("Compilation Time : "), time.time() - start
158
159     return model
160
161

```

```

163 def predict_point_by_point(model, data):
164     #Predict each timestep given the last sequence of true data, in effect only predicting 1 step ahead each time
165     predicted = model.predict(data)
166     predicted = np.reshape(predicted, (predicted.size,))
167     return predicted
168
169
170
171
172
173
174
175 def predict_sequence_full(model, data, window_size):
176     #Shift the window by 1 new prediction each time, re-run predictions on new window
177     curr_frame = data[0]
178     predicted = []
179     for i in range(len(data)):
180         predicted.append(model.predict(curr_frame[newaxis,:,:])[0,0])
181         curr_frame = curr_frame[1:]
182         curr_frame = np.insert(curr_frame, [window_size-1], predicted[-1], axis=0)
183     return predicted
184
185
186
187
188
189
190
191
192
193
194
195 def predict_sequences_multiple(model, data, window_size, prediction_len):
196     #Predict sequence of 50 steps before shifting prediction run forward by 50 steps
197     prediction_seqs = []
198     for i in range(int(len(data)/prediction_len)):
199         curr_frame = data[i*prediction_len]
200         predicted = []
201         for j in range(prediction_len):
202             predicted.append(model.predict(curr_frame[newaxis,:,:])[0,0])
203             curr_frame = curr_frame[1:]
204             curr_frame = np.insert(curr_frame, [window_size-1], predicted[-1], axis=0)
205         prediction_seqs.append(predicted)
206     return prediction_seqs
207
208
209
210
211
212
213
214
215
216
217

```

Joonis L1-2. Lstm fail

Loodud keskkonda lisati uuritava firma fail (csv), kuhu oli jäetud ainult uuritava perioodi aktsia sulgemishinnad alustades kaugemast kuupäevast. Kõik muu info failist kustutati.

Vaata joonist:

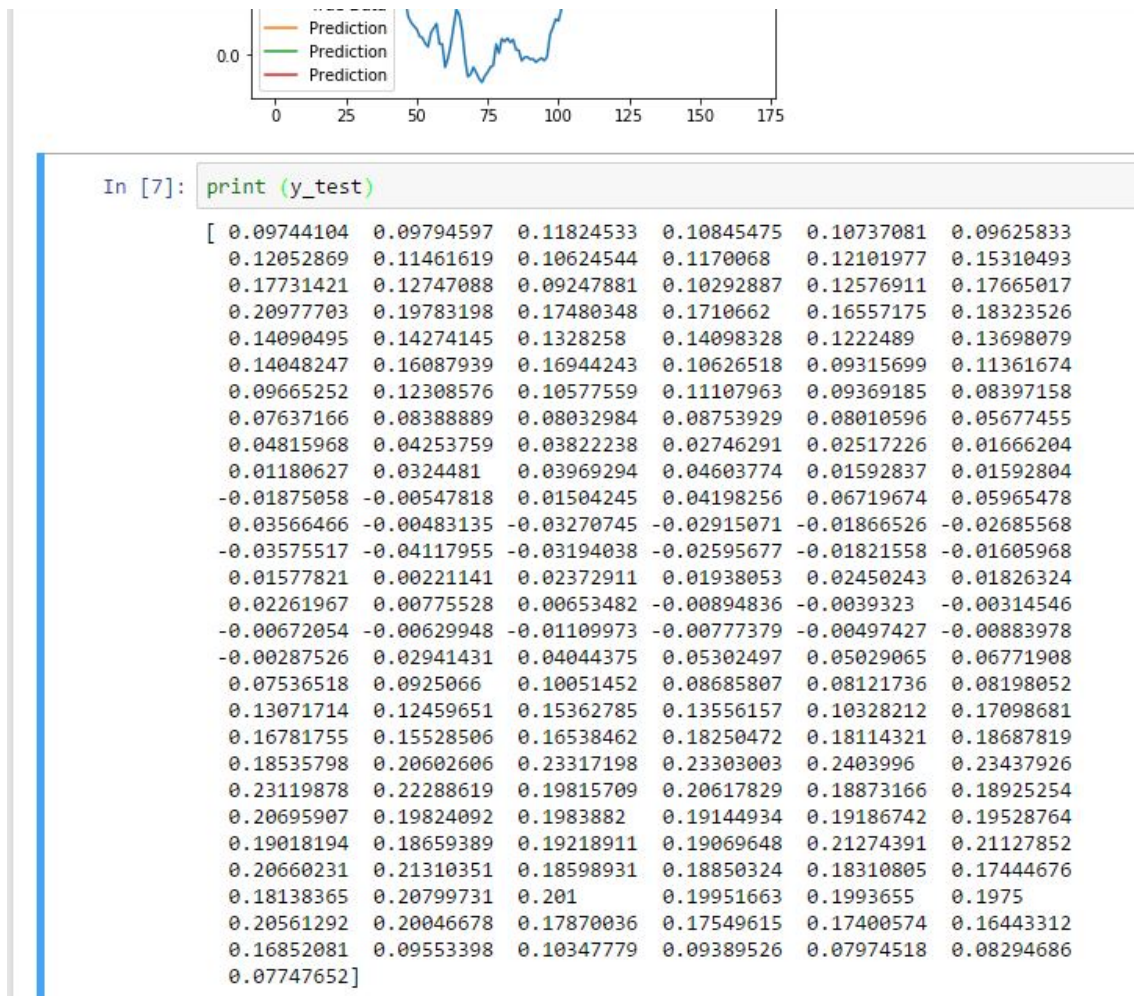
	A	B	C
1	123.24		
2	126.31		
3	128.76		
4	122.77		
5	122.01		
6	118.84		
7	117.91		
8	123.21		
9	123.03		
10	123.83		
11	126.84		
12	126.90		
13	125.89		
14	125.83		
15	122.55		
16	122.31		
17	121.45		
18	118.33		
19	121.00		
20	117.80		
21	108.61		
22	109.26		
23	110.96		
24	109.14		
25	110.06		
26	113.43		
27	116.22		
28	117.26		
29	119.51		
--	---		

Joonis L1-3. Aktsia sulgumishinnad

Lõpetuseks avati loodud keskkonnas jupyter notebook, kuhu kirjutati kood ning viidi läbi uuring.

Lisa 2 – Graafikute koordinaadid

Graafikute analüüsimiseks on vaja andmeid. Andmed saab kätte kasutades 'print' käsklust. Vaata joonist:



Joonis L2-1. True data

Käsklus kuvab pärishinnad, mida kasutatakse analüüsimiseks nii Statas kui ka excelis. Järgnevalt vajatakse ennustusjoonte andmeid. Vaata joonist:



```
In [8]: print (predictions)

[[0.11274496, 0.11742227, 0.12215122, 0.12694296, 0.13179481, 0.13670583, 0.14167137, 0.14669472, 0.15176886, 0.15689006, 0.16206084, 0.16727909, 0.17255312, 0.17787991, 0.18325354, 0.18867774, 0.1941532, 0.19968396, 0.20527488, 0.21092358, 0.21663252, 0.22240275, 0.22823742, 0.23413838, 0.24011026, 0.24614839, 0.25226071, 0.25844646, 0.26471078, 0.27105597, 0.27748591, 0.28400388, 0.29061365, 0.29731601, 0.30409375, 0.31096572, 0.31793931, 0.32501122, 0.33219504, 0.3394846, 0.34688711, 0.35440096, 0.36203268, 0.36978692, 0.37767136, 0.38568717, 0.39383709, 0.40212187, 0.41055104, 0.41912848], [0.11374238, 0.11507922, 0.11729582, 0.12023874, 0.12375588, 0.127711, 0.13199534, 0.13652429, 0.14123811, 0.14609061, 0.15105017, 0.15609518, 0.16121426, 0.16639701, 0.17164582, 0.17695597, 0.18231472, 0.18772206, 0.19317605, 0.19867833, 0.20424114, 0.209867, 0.2155537, 0.22130302, 0.22711399, 0.23299624, 0.23894623, 0.24496599, 0.25105643, 0.2572265, 0.2634716, 0.26979792, 0.27620521, 0.28269762, 0.28927541, 0.2959435, 0.30269977, 0.3095521, 0.31650129, 0.32355425, 0.33071098, 0.33797675, 0.34535468, 0.35284907, 0.36046243, 0.36819932, 0.37605914, 0.3840476, 0.39217815, 0.4004494], [0.075299509, 0.078213543, 0.081612073, 0.085386768, 0.089451879, 0.0937341, 0.098174043, 0.10273428, 0.10738826, 0.11212213, 0.11691451, 0.12176383, 0.12665586, 0.13158491, 0.13655597, 0.14156799, 0.1466179, 0.15170984, 0.15684594, 0.16202487, 0.16724963, 0.17252138, 0.17784341, 0.1832173, 0.18864153, 0.19412063, 0.19965272, 0.20523937, 0.21088265, 0.2165831, 0.22234853, 0.22817473, 0.23406851, 0.24003029, 0.24606331, 0.25216851, 0.25834915, 0.26460791, 0.27094924, 0.27737296, 0.28388041, 0.29047763, 0.2971659, 0.30395004, 0.31082994, 0.31780979, 0.32489061, 0.33207417, 0.33936444, 0.34676743]]
```

Joonis L2-2. Predictions

Käsklus kuvab pärishinnad, mida kasutatakse analüüsimiseks nii Statas kui ka excelis.