

Tuomas Mäkäräinen

SYVÄOPPIMINEN OSAKE- JA KULU- TUSLUOTTOMARKKINOILLA

Kandidaatintutkielma

Kandidaatintyö
Tekniikan ja luonnontieteiden tiedekunta
Tarkastaja: Emma Partanen
Huhtikuu 2021

TIIVISTELMÄ

Tuomas Mäkäräinen: Syväoppiminen osake- ja kulutusluottomarkkinoilla
Deep learning in the stock and consumer credit markets
Tampereen yliopisto
Tietojohtamisen tutkinto-ohjelma
Kandidaatintyö
Huhtikuu 2021

Syväoppimistutkimus on tehnyt viime vuosikymmenen aikana huomattavia edistysaskeleita, joiden myötä sen avulla on onnistuttu kehittämään useita erilaisia älykkäitä sovelluksia. Eräs syväoppimisen tutkituimmista toimialoista on rahoitusala, jossa sille on onnistuttu löytämään useita liiketoiminnallista hyötyä tuottavia käyttökohteita. Tässä tutkielmassa tavoitteena on selvittää, millaisia sovelluskohteita osake- ja kulutusluottomarkkinoilla on ohjatulle syväoppimiselle, ja millaisia ohjatun syväoppimisen malleja niihin käytetään.

Tutkimusmenetelmänä tässä kandidaatintutkielmassa käytetään kirjallisuuskatsausta. Keskeimpänä aineistona tutkielmassa hyödynnettiin vertaisarvioituja tieteellisiä artikkeleja, joiden lisäksi aineistoa täydensivät yksittäiset kirja- sekä verkkoartikkelilähteet. Käytetyt lähteet olivat suurimmalta osin 1–3 vuotta vanhoja. Aineiston pohjalta käsitellyt keskeiset teoriat liittyivät osakemarkkinoihin, kulutusluottomarkkinoihin, koneoppimiseen, ohjattuun oppimiseen sekä syväoppimiseen. Näiden teoriataustoitusten pohjalta lähdettiin tarkastelemaan aineistosta havaittuja ohjattuun syväoppimiseen pohjautuvia sovelluksia osake- ja kulutusluottomarkkinoilta.

Tutkielmassa havaittiin, että osake- ja kulutusluottomarkkinoilta on löydetty syväoppimiselle useita erilaisia sovelluskohteita. Näistä kohteista työssä tarkastellaan algoritmista kaupankäyntiä, arvopaperisalkkujen hallintaa, taloudellisten riskien arviointia sekä petosten havaitsemista. Tämän lisäksi kävi ilmi, että LSTM- sekä CNN-syväoppimisverkot ovat muodostuneet hyvin keskeiseksi osiksi osake- ja kulutusluottomarkkinoiden sovelluksiin käytettäviä malleja. Myös malleissa käytettävän datan monipuolisuudesta sekä saatavuudesta tehdään huomioita. Tutkielmassa saatujen tulosten on tarkoitus muodostaa näkökulma syväoppimisen laajasta tutkimusaineistosta sekä laajentaa suomenkielistä syväoppimistutkimusta osake- ja kulutusluottomarkkinoiden kontekstissa. Tuloksista voi hyötyä syväoppimisesta kiinnostuneet osake- tai kulutusluottomarkkinoilla toimivat tahot.

Avainsanat: syväoppiminen, ohjattu oppiminen, osakemarkkinat, kulutusluottomarkkinat

Tämän julkaisun alkuperäisyys on tarkastettu Turnitin OriginalityCheck –ohjelmalla.

ALKUSANAT

Tämä tutkimus on Tampereen yliopiston tietojohdamisen koulutusohjelman kandidaatin-työ. Tässä kirjallisuuskatsauksena toteutetussa tutkielmassa tarkastellaan syväoppimisen sovelluskohteita osake- ja kulutusluottomarkkinoilla. Aihekokonaisuus muovautui mielenkiinnostani koneoppimista ja rahoitusmarkkinoita kohtaan.

Kiitän ohjaajaani Emma Partasta sekä kandidaatintyöryhmääni laadukkaasta palautteesta sekä mukavista keskusteluhetkistä. Tämän lisäksi haluan kiittää myös kaikkia muita tutkimusprosessin aikana minua tukeneita tahoja.

Tampereella, 19.4.2021

Tuomas Mäkräinen

SISÄLLYSLUETTELO

1.	JOHDANTO	1
1.1	Tutkimuksen taustat	1
1.2	Tutkimusongelma ja rajaukset	2
1.3	Tutkimuksen rakenne	3
2.	TUTKIMUKSEN TOTEUTTAMINEN	4
2.1	Tutkimusmenetelmä	4
2.2	Tutkimusaineisto.....	7
3.	OSAKE- JA KULUTUSLUOTTOMARKKINAT	8
3.1	Osakemarkkinat.....	8
3.2	Kulutusuottomarkkinat	10
4.	KONE- JA SYVÄOPPIMINEN	12
4.1	Koneoppiminen.....	12
4.2	Syväoppiminen	14
4.3	Yleisiä ohjatun syväoppimisen verkkoja.....	16
5.	SYVÄOPPIMISEN KESKEISET SOVELLUSKOHTEET OSAKE- JA KULUTUSLUOTTOMARKKINOILLA	20
5.1	Algoritminen kaupankäynti.....	20
5.2	Arvopaperisalkkujen hallinta	21
5.3	Taloudellisten riskien arviointi	22
5.4	Petosten havaitseminen	23
5.5	Havaintoja tarkastelluista sovelluskohteista	25
6.	YHTEENVETO.....	27
6.1	Johtopäätökset	27
6.2	Tutkielman arviointi.....	29
6.3	Jatkotutkimuksen tarve.....	29
	LÄHTEET	31
	LIITE A: TUTKIELMASSA OLEELLISEKSI MUODOSTUNEITA AINEISTOJA	34

LYHENTEET JA MERKINNÄT

AI	<i>Artificial Intelligence</i> , Tekoäly
ANN	<i>Artificial Neural Network</i> , Keinotekoinen neuroverkko
AT	<i>Algorithmic Trading</i> , Algoritminen kaupankäynti
DL	<i>Deep Learning</i> , Syväoppiminen
DMLP	<i>Deep Multilayer Perceptron</i> , Syvä monikerroksinen perseptroni
DNN	<i>Deep Neural Network</i> , Syvä neuroverkko
ETF	<i>Exchange Traded Fund</i> , Pörssinoteerattu rahasto
HFT	<i>High-Frequency Trading</i> , Suuren volyymin kaupankäynti
LSTM	<i>Long Short-Term Memory</i> , Pitkäkestoinen lyhytkestomuisti
ML	<i>Machine Learning</i> , Koneoppiminen
MLP	<i>Multilayer Perceptron</i> , Monikerroksinen perseptroniverkko
NLP	<i>Natural Language Processing</i> , Luonnollisen kielen käsittely
NYSE	<i>New York Stock Exchange</i> , New Yorkin pörssi
OTC	<i>Over-The-Counter</i> , Rahoitusvälineiden kaupankäyntiä ilman pörssiä
ReLU	<i>Rectified Linear Unit</i> , Oikaistu lineaarinen yksikkö

1. JOHDANTO

Tässä luvussa käsitellään tutkimuksen aihepiiriä, tutkimusongelmaa ja rakennetta. Ensiksi taustoitetaan tutkimuksen aihepiiriä sekä lähtökohtia, minkä jälkeen esittelyn kohde vaihtuu tutkimusongelmaan, -kysymyksiin sekä niille kohdistettaviin rajoituksiin. Lopuksi esitellään vielä tutkimuskysymykset sekä tutkielman rakenne.

1.1 Tutkimuksen taustat

Tekoälyteknologiat ovat saaneet paljon näkyvyyttä viime vuosina niin tutkimusartikkeleissa kuin yleisemmissä joukkoviestintävälineissäkin. Tekoälypohjaisille sovelluksille on onnistuttu löytämään useita käyttökohteita eri liiketoiminta-aloilta (Lee & Shin, 2020), minkä vuoksi niistä on tullut kiinteä osa päivittäin käytettyjä palveluita. Yleisiä internetissä vastaantulevia sovelluksia ovat esimerkiksi suosittelujärjestelmät, joita hyödynnetään paljon sosiaalisessa mediassa ja verkkokaupoissa (Jesse & Jannach, 2021). Tulevaisuudessa tekoälypohjaiset sovellukset yleistyvät todennäköisesti entisestään (Gartner, 2020; Deloitte, 2021).

Tekoälyteknologiaan pohjautuvien ratkaisujen suosio on siis kasvanut huomattavasti viime vuosien aikana, ja yritykset panostavat niihin edelleen yhä enemmän. Ajureina suosion taustalla ovat olleet massadatan kehittyminen, tiedonhallinta- ja laskentakapasiteetin kasvu sekä koneoppimistutkimuksen edistyminen (Lee & Shin, 2020). Erityisesti koneoppimiseen kuuluvan syväoppimisen taholla on tehty suuria harppauksia, jotka ovat mahdollistaneet muun muassa kasvojen- ja puheentunnistusteknologioiden sekä niin sanottujen syväväärengösten (*deepfake*) kehittymisen (Suwajanakorn et al., 2017; Kaplan & Haenlein, 2019).

Eräs syväoppimisen tutkituimmista liiketoiminta-aloista on rahoitusala, jossa sille on onnistuttu löytämään useita eri sovelluskohteita (Ozbyoglu et al., 2020). Esimerkiksi Accenturen (2018, s. 9) mukaan pankit voivat saavuttaa jopa 20–25 % pienemmät ylläpito- ja kehityskustannukset koneoppimiseen pohjautuvan automatisoinnin avulla. Tämän lisäksi esimerkiksi sijoitusorganisaatiot hyödyntävät syväoppimisella muodostettuja ennusteita esimerkiksi arvopaperisalkkujensa hallinnassa (Lee & Shin, 2020; Ozbyoglu et

al., 2020). Syväoppimisella voidaan siis saavuttaa merkittäviä taloudellisia hyötyjä ja mahdollisuuksia rahoitusalaalla, minkä takia sitä on oleellista tutkia.

Aihepiirin ajankohtaisuuden lisäksi alustavan tiedonhaun yhteydessä havaittiin myös varsinainen tutkimusaukko, jolloin kävi ilmi, että suomenkielistä tutkimusaineistoa aihepiiriin liittyen on vähän. Tarkoituksena tällä tutkielmalla on siis tehdä katsaus syväoppimisen rahoitusalaan liittyvään laajaan tutkimusaineistoon ja käsitellä sen pohjalta syväoppimisen sovelluskohteita ja -tapoja osake- ja kulutusluottomarkkinoilla, ja täten täydentää aihepiiriin liittyvää suomenkielistä tutkimusaineistoa.

1.2 Tutkimusongelma ja rajaukset

Keskeisimpänä tutkimusongelmana ja päätutkimuskysymyksenä tässä tutkielmassa toimii, *millaisia sovelluskohteita syväoppimisella on osake- ja kulutusluottomarkkinoilla*. Oleellista on siis, mihin käyttötarkoituksiin syväoppimista sovelletaan, sekä millaisia verkkomalleja kyseisissä sovelluksissa käytetään. Päätutkimuskysymyksen pohjalta on muodostettu sitä tukevat alatutkimuskysymykset, joita esitellään seuraavaksi taulukossa 1.

Taulukko 1: Tutkielmassa käsiteltävät tutkimuskysymykset.

Päätutkimuskysymys	Millaisia sovelluskohteita syväoppimisella on osake- ja kulutusluottomarkkinoilla?
Alatutkimuskysymykset	Mitä ovat osake- ja kulutusluottomarkkinat?
	Mitä on syväoppiminen? - Mitä on koneoppiminen? - Mitä on ohjattu oppiminen?
	Mitä keskeisiä syväoppimisen sovelluskohteita osake- ja kulutusluottomarkkinoilla on? - Mitä syväoppimismalleja näissä sovelluksissa käytetään?

Alatutkimuskysymysten avulla pohjustetaan siis tutkielman aihepiiriä ja muodostetaan vastaus tarkasteltavalle päätutkimuskysymykselle. Tutkielmassa on tarkoitus vastata alatutkimuskysymysten kautta päätutkimuskysymykseen ja tutkimusongelmaan.

Tutkielman aihepiirin laajuuden huomioiden on esitelty tutkimusongelman ja -kysymysten tarkastelualuea kohdennettavaksi pienemmäksi ja helpommin käsiteltäväksi kokonaisuudeksi. Tarkasteltavina rahoitusalan osa-alueina tässä tutkielmassa toimivat osake- ja kulutusluottomarkkinat. Tämän lisäksi lähtökohtaisesti oletetaan, että syväoppimisen eri sovellustapoja on käytännössä useita, joten tarkastelua rajataan 3–5 tutkimusaineistosta keskeisimmäksi muodostuvaan sovellukseen. Eri syväoppimismallien suuren määrän vuoksi tutkielmassa tarkastellaan vain ohjatun oppimisen kategoriaan kuuluvia malleja, sillä niistä oletetaan löytyvän parhaiten tutkittua tietoa tutkielman aihepiiriin liittyen. Niin syväoppimiseen kuin rahoitusmarkkinoiden toimintaan liittyy myös suuri määrä matemaattista taustateoriaa, jonka sisällyttäminen tämän työn tarkasteluun laajentaisi aihepiiriä liian suureksi, joten sen käsittely jätetään mahdollisimman vähäiseksi.

1.3 Tutkimuksen rakenne

Tutkielman rakenne koostuu kuudesta pääluvusta. Ensimmäisenä on johdantoluku, jossa kuvataan tutkimusaiheen taustoja sekä perustellaan tutkimuksen tarvetta. Seuraavassa luvussa selostetaan tutkimuksen toteuttamiseen liittyviä yksityiskohtia, kuten käytettävää tutkimusmenetelmää sekä lähdeaineistoa. Nämä ensimmäiset luvut esittelevät siis itse tutkielmaa ja sen toteutusta, kun taas seuraavat luvut puolestaan keskittyvät enemmän tutkielman aihepiirin varsinaiseen sisältöön.

Kolmannessa luvussa käsitellään osake- ja kulutusluottomarkkinoiden taustoja. Neljäs luku sisältää koneoppimisen, ohjatun oppimisen sekä syväoppimismallien esittelyn. Yleisen käsittelyn lisäksi tässä luvussa myös esitellään yleisiä ohjatun syväoppimisen verkkomalleja. Viidennessä luvussa selostetaan ja käsitellään aineistosta ilmenneitä osake- ja kulutusluottomarkkinoiden ohjatun syväoppimisen sovelluksia. Viimeisessä luvussa tehdään edellisten kappaleiden pohjalta yhteenveto, päätelmät, sekä arvioidaan saatujen tulosten merkitystä sekä tarvetta jatkotutkimukselle.

2. TUTKIMUKSEN TOTEUTTAMINEN

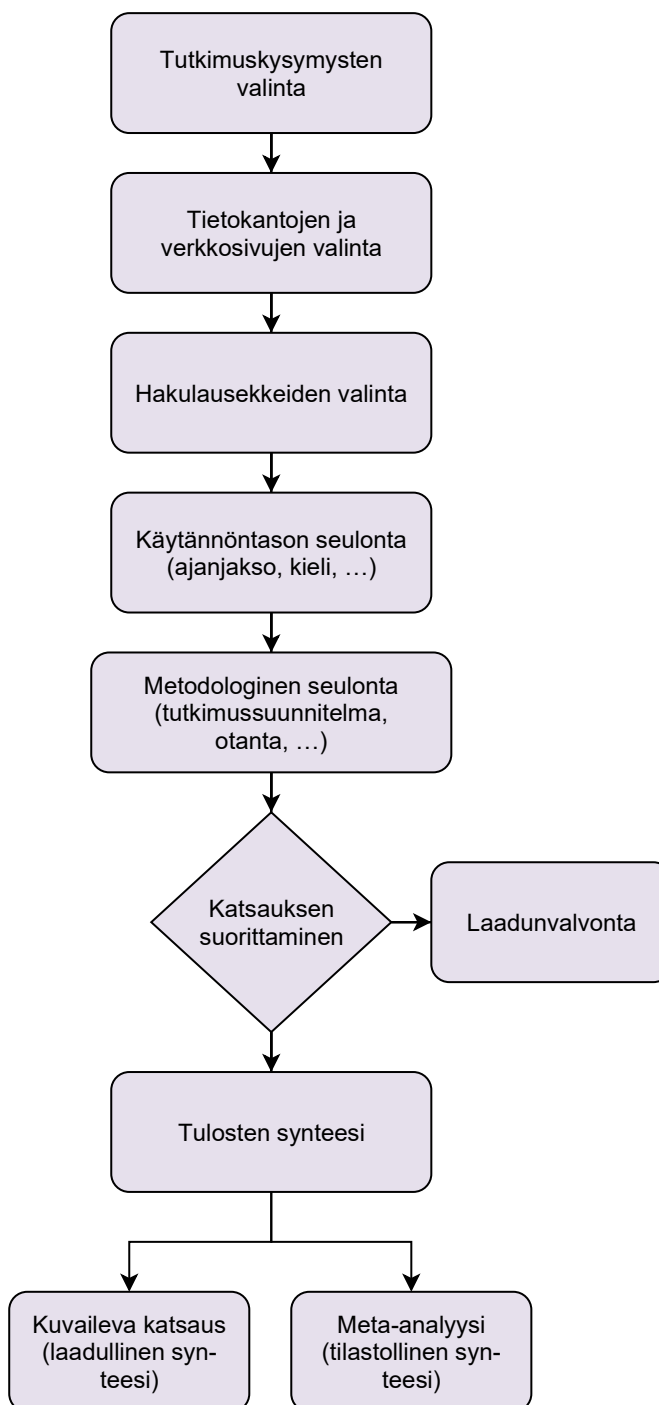
Tässä luvussa esitellään tutkielman toteutuksessa käytettävää tutkimusmenetelmää sekä toteutettua tiedonhakuprosessia. Tiedonhaun esittelyn yhteydessä käsitellään muun muassa käytettyjä tietokantoja, sekä hakulausekkeita.

2.1 Tutkimusmenetelmä

Tämä tutkielma toteutetaan kirjallisuuskatsauksena. Kirjallisuuskatsaukset ovat järjestelmällisiä ja toistettavissa olevia esityksiä, joiden tarkoituksena on havainnoida, arvioida sekä yhdistää muiden tutkijoiden ja ammatinharjoittajien toteuttamia kirjallisia tuotoksia (Fink, 2014, s. 3). Niissä tehtävät päätelmät pohjautuvat siis tähän mennessä tehtyihin ja julkaistuihin tutkimustuloksiin ja kirjallisuuteen.

Seuraavaksi esitellään kirjallisuuskatsausprosessin (Kuva 1) etenemistä. Ensiksi tutkielmassa tullaan rajaamaan ja määrittelemään tutkimusongelman pohjalta varsinaiset tutkimuskysymykset. (Fink, 2014, s. 3) Sen jälkeen valitaan käytettävät tietokannat ja verkkosivut, joista aineistoa lähdetään hakemaan. Ennen varsinaista tiedonhakua pitää kuitenkin määritellä myös käytettävät hakulausekkeet. (Fink, 2014, s. 3) Näiden määritelmien jälkeen voidaan alkaa seuloa niillä saatuja tuloksia. Ensimmäisenä seulana toimivat tulosten käytännöntason ominaisuudet kuten julkaisuvuosi sekä -kieli (Fink, 2014, s. 51). Toisena seulana toimii niin sanotut menetelmälliset seulat, joiden avulla valikoidaan laadukkaaksi mielletty aineistot esimerkiksi niiden sopivuuden, luotettavuuden sekä merkittävyyden perusteella (Fink, 2014, s. 54–55).

Määritelmien ja seulonnan jälkeen päästään varsinaisesti katsauksen toteuttamiseen. Tässä vaiheessa tutkimusta on erityisen tärkeää seurata aikaan saadun tuotoksen laatua, jotta se säilyisi tutkimuksen loppuun saakka hyvänä. Katsauksen suorittamisen jälkeen on aika muodostaa sen pohjalta synteesi, jossa saadut tulokset muovataan sopivaan muotoon. Kuvailevat synteesit pohjautuvat katsauksen tekijän kokemuksiin, työn laatuun sekä käytettyyn aineistoon (Fink, 2014, s. 199). Toinen vaihtoehto synteesille on niin sanottu meta-analyysi, jossa tarkoituksena on yhdistää kahden tai useamman tutkimuksen tuloksia tilastollisia menetelmiä hyödyntämällä (Fink, 2014, s. 204). Tässä tutkielmassa on tarkoituksena muodostaa kuvaileva synteesi.



Kuva 1: Kirjallisuuskatsausprosessin eteneminen (mukaillen Fink 2014, s. 4)

Kokonaisuudessaan tutkielmassa on siis haettu, yhdistelty sekä vertailtu sen aihepiiriin liittyvien aineistojen yksityiskohtia sekä näkökulmia. Tämän avulla niiden eroista ja yhtäläisyyksistä on muodostettu havaintoja ja päätelmiä, joiden avulla pyritään edistämään alan tutkimusta.

Kirjallisuuskatsauksen tiedonhaku alkaa soveltuvien hakulähteiden, kuten esimerkiksi tietokantojen ja kirjastojen valinnalla. (Fink, 2014, s. 3) Lähteiden soveltuvuus riippuu

määritetystä tutkimusongelmasta, ja sen aihepiiristä. Internetissä on tarjolla useita vapaasti käytettäviä tietokantoja, joista kuka tahansa voi hakea tieteellisiä artikkeleita (Fink, 2014, s. 15–16). Monet kirjastot tarjoavat vapaan pääsyn myös useisiin yksityisiin tietokantoihin.

Tässä tutkielmassa aineiston hakuun käytetään pääosin Tampereen yliopiston tarjoamaa Andor-hakupalvelua, sekä sen käyttämiä tietokantoja, kuten Web of Science, ScienceDirect, ja Scopus. Näiden palvelujen aineistoa on haettu myös Tampereen yliopiston kirjaston tarjonnasta, sekä muiden yliopistojen vapaasti tarjoamista teoksista. Koska alustavassa tiedonhaussa huomattiin aihepiirin aineiston olevan pitkälti englanniksi, käytettäviksi hakusanoiksi valikoitiin aiheeseen liittyviä englanninkielisiä termejä, kuten "deep learning", "stock market" sekä "consumer credit". Näitä hakusanoista muodostettiin seuraavaksi hakulausekkeita.

Aineistoa hakiessa hakukoneelle syötetään hakulauseke, joka koostuu valituista hakusanoista sekä Boolean *AND*, *OR* ja *NOT*-logiikkaoperaattoreista. (Fink, 2014, s 24–25) Niiden avulla voidaan määrittää, mitkä avainsanat tulee ainakin löytyä, mitkä avainsanat ovat vaihtoehtoisia keskenään sekä mitkä eivät ainakaan saa olla haetuissa tuloksissa. Sulkeiden avulla voidaan vaikuttaa operaattoreiden tarkastelujärjestyksen logiikkaan. Asteriskin (*) avulla voidaan jättää sanan pääte määrittämättä, jolloin hakukone tarjoaa tuloksissa sanan eri taivutusmuotoja. Moniosaiset käsitteet voidaan yhdistää kokonaisuudeksi lainausmerkkien avulla. Lausekelogiikan lisäksi hakutuloksia voidaan rajoittaa esimerkiksi julkaisuvuoden, aineistotyypin sekä saatavuuden perusteella.

Taulukko 2: Esimerkkejä tiedonhakuun käytetyistä lausekkeista ja niiden tulosmääriä

Hakulauseke	Andor	Scopus	Web of Science
("deep learning" OR "DL") AND "stock market"	21 895	367	176
("deep learning" OR "DL") AND "consumer credit"	853	5	6
("deep learning" OR "DL") AND "portfolio management"	2 541	16	34
("deep learning" OR "DL") AND "credit scoring"	1 000	31	24

Taulukossa 2 esitellään erilaisten hakulausekkeiden tuottamien tulosten määrää eri tietokannoissa. Tuloksista voidaan nähdä tarjolla olevan aineiston painottuvan hyvin vahvasti osakemarkkinoihin liittyviin tutkimuksiin, ja kulutusluottoihin liittyvää syväoppimis- tutkimuksia olevan tarjolla vähiten.

2.2 Tutkimusaineisto

Tiedonhaun tuloksena löydettiin useita aihepiiriin liittyviä artikkeleita ja teoksia. Kriteereinä tulosten läpikäynnissä toimivat ennen kaikkea aineiston luotettavuus, ajankohtaisuus sekä relevanttius tämän tutkielman näkökulmasta. Artikkeleiden viittausmääriä tarkasteltiin myös joissain määrin, mutta ne eivät toimineet ensisijaisena kriteerinä. Haasteita aineiston valintaan aiheuttivat artikkeleissa käytettyjen käsitteistöjen pienet erot, minkä seurauksena asiayhteyksistä varmistuminen vaati enemmän työtä. Eräitä tutkielmalle oleellisimmaksi muodostuneita teoksia esitellään liitteessä A.

Osake- ja kulutusluottomarkkinoiden taustoitukseen hyödynnettiin pitkälti verkkoartikkeleita, joista osa oli vertaisarvioituja. Näin pyrittiin saamaan kyseisistä aihepiireistä mahdollisimman tuoretta ja ajankohtaista tietoa. Syväoppimisen yleisempään teoriataustoitukseen hyödynnettiin myös yliopistojen oppikirjoja, jotka olivat 4–5 vuotta vanhoja. Osake- ja kulutusluottomarkkinoiden syväoppimissovelluksiin liittyvä aineisto koostuu puolestaan 1–3 vuotta vanhoista, pääsääntöisesti vertaisarvioiduista tutkimusartikkeleista, millä pyrittiin saamaan mahdollisimman tuore näkökulma tutkimusalan nykytilasta. Tyypiltään työssä käytetyt artikkelit ovat teoreettisia tutkimuksia.

3. OSAKE- JA KULUTUSLUOTTOMARKKINAT

Tässä luvussa esitellään osake- ja kulutusluottomarkkinoita. Alaluvuissa tutustutaan muun muassa osakkeiden myyntitapoihin ja -paikkoihin sekä kulutusluottoja myöntäviin tahoihin ja niiden käyttökohteisiin.

3.1 Osakemarkkinat

Osakemarkkinat (*stock market*) ovat erilaisista pörsseistä ja välittäjistä koostuva joukko osakkeiden markkinapaikkoja, joissa tarkoituksena on käydä kauppaa osakeyhtiöiden osuuksilla eli osakkeilla (*stocks*) (Chen, 2021a). Nykyään kaupankäynti tapahtuu pitkälti internetin välityksellä sähköisillä kauppapaikoilla (Harper, 2020), ja myös esimerkiksi älypuhelinien välityksellä käytävästä kaupasta (*mobile trading*) on tullut suosittua (Scott, 2019).

Osakemarkkinoiden avulla osakeyhtiöt, eli julkisessa omistuksessa olevat yritykset voivat hakea rahoitusta toiminnalleen myymällä, eli toisin sanoen liikkeelle laskemalla omia osakkeitaan sijoittajien ostettavaksi (Chen, 2021a). Sijoittajan ostaessa yrityksen osakkeen hänestä tulee yrityksen osakas (*shareholder, stockholder*) ja vastineeksi osakkuudesta yritys saa käyttöönsä pääomaa.

Niin yritykset kuin yksityishenkilötkin voivat pyrkiä saavuttamaan voittoja käymällä kauppaa osakkeista (Chen, 2021a). Yksinkertaisimmillaan tämä onnistuu, kun saa myytyä osakkeen kalliimmalla kuin sen on ostanut. Myynnin lisäksi osakkeista voidaan saada tuottoa myös niiden liikkeelle laskeneen yrityksen jakokelpoisista tuotoista osinkojen muodossa (Chen, 2021a). Osinkojen suuruus riippuu sijoittajan osakkuuden suuruudesta eli siitä, kuinka paljon hän omistaa yhtiön osakkeita.

Pörssit ovat keskitettyjä ja tarkkaan valvottuja kauppapaikkoja, joissa tavallisten osakkeiden lisäksi voidaan käydä kauppaa monilla kohteilla kuten esimerkiksi pörssinoteerautuille rahastoilla (*ETF*) sekä johdannaisilla kuten arvometallit ja öljy. (Harper, 2020) Näiden lisäksi tarjolla on vielä monia muita rahoitusvälineitä. Pörsseissä tehtyjen kauppojen tiedot ovat julkisia, eli kuka tahansa voi siis käydä tarkistamassa kaupattujen osakkeiden määrän ja hinnan (Chen, 2021a). Tunnettuja pörssejä maailmalta ovat muun muassa New Yorkin pörssi (*NYSE*), Tokion pörssi (*TSE*) sekä Lontoon pörssi (*LSE*) (Fuhrmann, 2019). Suomessa toimii Helsingin pörssi.

OTC-kaupankäynti on valvottujen ja keskitettyjen kauppapaikkojen ulkopuolella tapahtuvaa kaupankäyntiä (Harper, 2020; Murphy, 2021). Tällainen suora kahden osapuolen välinen kaupankäynti ei ole yhtä valvottua ja standardoitua kuin pörssiessä, minkä seurauksena toteutuneiden kauppajien tiedot eivät ole yhtä julkisia. OTC-kauppaa voidaan käydä suunnilleen samoilla rahoitusvälineillä kuin pörssiessäkin, mutta koska se ei ole yhtä valvottua, ei kaupattavilla kohteilla ole yhtä suuria vaatimuksia kuin pörssi-kohteilla. (Murphy, 2021) Tämä mahdollistaa siis esimerkiksi sellaisten yritysten osakkeiden myynnin, joille pörssiin listautuminen ei ole mahdollista.


Arvopaperisalkut eli **portfoliot** ovat sijoittajien valikoimia kokonaisuuksia heidän omistamistaan osakkeista, käteisestä sekä muista rahoitusvälineistä ja sijoituksista kuten kiinteistöt tai taide (Chen, 2021b). Portfolioiden muodostamista ja hallintaa voidaan lähestyä erilaisin strategioin.

Esimerkiksi pelkästään osakkeista koostuva portfolio on yleensä herkkä hintojen heilahdelle eli toisin sanoen niiden volatiliiteetti on suuri. (Chen, 2021b) Osakkeille suurempi volatiliiteetti tarkoittaa suuremman tuottomahdollisuuden lisäksi myös suurempaa riskiä eli häviöiden mahdollisuutta. Portfolion riskin pienentämiseksi siihen kannattaa sisällyttää osakkeiden lisäksi myös pidempiaikaisia ja vakaampia kohteita kuten esimerkiksi valtioiden joukkovelkoja (Chen, 2021b). Olennaisia työkaluja arvopaperisalkun hallintaan ovat varojen kohdentaminen, uudelleen tasapainottaminen sekä hajauttaminen (Hayes, 2020).

Sijoituskohteiden hajautuksella pyritään minimoimaan yksittäisten kohteiden aiheuttamia riskejä, ja siksi hajauttamista on olennaista toteuttaa niin maantieteellisesti, toimialakohtaisesti kuin ajallisestikin (Makkonen, 2020). Käytännössä tämä tarkoittaa, että portfolio kannattaa rakentaa siten, että se sisältää maantieteellisesti eri alueilla toimivia eri toimialojen yrityksiä. Tällöin yksittäisten markkina-alueiden, tai toimialojen sisäiset epävakaisuudet eivät vaikuta niin suurissa määrin koko portfolion arvoon. Ajallisella hajautuksella puolestaan tarkoitetaan sijoitettavien varojen jakamista useampaan eri aikoihin sijoitettavaan erään yksittäisen suuren kertsijoituksen sijaan, sillä tällöin markkinahintojen muutoksista aiheutuva riski on pienempi (Makkonen, 2020).

Osakeindeksit (*stock index*) ovat vakioitu tapa seurata valikoidun osakejoukon markkinakehitystä ja kilpailukykyä (Chen, 2021b). Eri osakeindeksien on tarkoitus siis jäljitellä markkinoiden eri osa-alueita esimerkiksi pörssi- tai toimialakohtaisesti. Laaja-alaiset (*broad-based*) indeksit kuvaavat suurempia markkina-alueita (Chen, 2021b). Tästä esimerkkinä S&P 500-indeksi (Kuva 2), joka koostuu 500 Yhdysvaltalaisen suuryrityksen

osakkeesta (Kenton, 2021). Laaja-alaisten indeksien on siis tarkoitus antaa katsaus suurempien markkinakohteiden nykytilaan.



Kuva 2: S&P 500-indeksin kehitys yhden vuoden ajalta (datan lähde Yahoo Finance 2021)

Laaja-alaisten indeksien lisäksi voidaan olla kiinnostuneita myös pienemmistä markkinoista. Tällöin tarkastelun kohteena ovat erikoistuneemmat indeksit, joiden avulla voidaan seurata esimerkiksi tiettyä toimialaa ja sen osa-alueita (Chen, 2021b). Osakeindeksit toimivat usein vertailukohteena sijoittajien arvopaperisalkkujen suoriutumiselle markkinoilla (Chen, 2021b; Kenton, 2021).

3.2 Kulutusluottomarkkinat

Kulutusluottomarkkinoilla tarkoitetaan pankeista ja muista rahoitusyhtiöistä muodostuvaa joukkoa, jotka tarjoavat yksityishenkilöille kulutuskykyä lisääviä lainasopimuksia. (Kagan, 2021) Luottokortti on yksi yleinen kulutusluoton muoto. Myös esimerkiksi asunnon hankintaan otettu laina voidaan mieltää kulutusluotoksi, mutta yleensä ne ovat kuitenkin pidemmän ajan sijoituksia, minkä takia ne luokitellaan usein erilliseksi nimikkeeksi eli asuntolainoiksi (Kagan, 2021).

Kulutusluotot voidaan karkeasti jakaa osamaksuluottoihin sekä jatkuviin luottoihin, sillä niillä on erilaiset käyttötarkoitukset. (Kagan, 2021) Osamaksuluotot ovat yleensä suurempiin yksittäisiin hankintoihin tarkoitettuja lainoja, joiden kohde, suurus sekä maksuaika ovat ennalta määritettyjä. Hankinnan kokonaissumma jaetaan tasan sovitulle maksuajalle usein kuukausittaisiin eriin siten, että maksuajan päättyessä itse summa ja siihen lisättävä sopimuksessa määritelty korko ovat maksettuna sopimusajan päättyessä. (Kagan, 2021) Jos asiakas jostain syystä laiminlyö tehtyä luottosopimusta, toimii siihen liitetty hankinta usein vakuutena.

Luottokortit ovat hyvin yleinen esimerkki jatkuvasta luotosta. Jatkuvat luotot eivät ole sidonnaisia mihinkään tiettyyn hankintaan, joten niillä voi ostaa melkein mitä vaan lain ja luotonmyöntäjän säännösten puitteissa. Suomessa arpajaislaki kieltää erilaisten raha- ja

uhkapelien ostamisen lainarahalla (Harala, 2013), joten esimerkiksi lottokuponkia ei voi täten ostaa luottokortilla. Jatkuva luotto saa nimityksensä siitä, että sitä voi käyttää vapaasti sopimuksen mukaiseen ylärajaan asti, kunhan lainaaja maksaa sovitut vähimmäismaksut ajallaan. (Kagan, 2021) Jatkuvien luottojen korot ovat yleensä korkeampia kuin osamaksuluottojen, koska niillä ei ole vakuutta, ja täten ne ovat riskikkäämpiä lainanmyöntäjille.

Perinteisiä kulutusluottojen myöntäjiä ovat pankit ja rahoituslaitokset. Internet on mahdollistanut kulutusluottomarkkinoilla toimimisen myös useille online-palveluille (Kontkanen & Lång, 2018, s. 17). Rahoitusyhtiöiden ja asiakkaiden välisen luotonmyönnön lisäksi markkinoille on ilmaantunut myös niin sanotuista vertaislainaajista muodostuvia verkostoja. (Kontkanen & Lång, 2018, s. 17) Vertaislainaamisessa kotitaloudet muodostavat keskenään lainasopimuksen ilman kolmantena osapuolena toimivaa yritystä. Vertaislainaamiseen on tarjolla myös välittäjäpalveluita, jotka ohjaavat lainaa hakevat ja niitä tarjoavat osapuolet yhteen (Kontkanen & Lång, 2018, s. 17).

Luottoluokitus on lainaa hakevalle taholle määritetty numeerinen pisteytys, jonka tarkoituksena on kuvata hakijan luottokelpoisuutta eli takaisinmaksukykyä (Dhir, 2020). Yleisin luottoluokituksen määrittelemiseen käytävä pisteytysjärjestelmä on FICO-luokitus, jonka asteikko on 300–850 pistettä, josta pisteet 670–739 vastaavat hyvää luottoluokitusta (Kagan, 2021). Luokituksen avulla pankit ja rahoituslaitokset pyrkivät arvioimaan asiakkaansa kykyä ja todennäköisyyttä maksaa hakemansa laina takaisin sovituksessa ajassa, ja täten vähentää epäluotettavista asiakkaista aiheutuvia taloudellisia tappioita (Li et al., 2017).

4. KONE- JA SYVÄOPPIMINEN

Tässä kappaleessa esitellään koneoppimiselle, ohjatulle oppimiselle sekä syväoppimiselle ominaisia piirteitä. Tämän lisäksi tutustutaan kolmeen yleiseen syväoppimisverkkoarakeenteeseen.

4.1 Koneoppiminen

Koneoppiminen on tekoälytutkimuksen alahaara, joka keskittyy koneälytoimijoiden havainnointi- ja toimintakyvyn parantamiseen tiedon, kokemuksen sekä vuorovaikutuksen pohjalta. (Veloso, 2021) Koneoppimisessa käsitellään suuria määriä monimuotoista dataa, mikä vaatii useiden eri menetelmien, kuten esimerkiksi tilastotieteiden, konenäön, luonnollisen kielen käsittelyn sekä tietokantojen hyödyntämistä. Koneoppimisen avulla tekoälyjärjestelmät pyrkivät siis mukautumaan uusiin olosuhteisiin, sekä havaitsemaan ja erottelamaan datasta uusia rakenteita ja riippuvuussuhteita (Russell & Norvig, 2016, s. 2).

Toimiakseen koneoppimismallit tarvitsevat dataa. Niiden on ensiksi päästävä tutustumaan haluttuun syötedataan, jotta ne voivat muodostaa vastaavanlaisen datan pohjalta uusia tuloksia ja arvioita (Goodfellow et al., 2017, s. 105). Tätä tutustumisprosessia kutsutaan koneoppimismallin kouluttamiseksi (*training*). Toisinaan mallien koulutus menee liian pitkälle, mikä johtaa mallin ylisovittumiseen, joka on yksi syväoppimisen keskeisimmistä haasteista (Goodfellow et al., 2017, s. 111). Eri sovitetasoja havainnollistetaan kuvassa 3.



Kuva 3: Esimerkki mallin eri sovitetasoista (mukaillen Goodfellow et al. 2017)

Ylisovittaminen (*overfitting*) tarkoittaa sitä, että malli opettelee sille annetun koulutusdatan liian hyvin, jolloin sen tuottamien tulosten yleistettävyyks kärsii huomattavasti sille ennestään vierailta datapisteillä (Russell & Norvig, 2016, s. 705; Goodfellow et al., 2017, s. 110-111). Tällöin siis muodostettu sääntöfunktio kuvaa koulutusdataa lähes täydellisesti, eli sen funktion sopivuuden virhe on hyvin pieni, mutta uudelle datalle kuvauksen laatu

on huomattavasti huonompi, eli funktion sopivuuden virhe on suuri. Tämän takia mallia kouluttaessa käytössä oleva data jaetaan usein kahteen osaan: *koulutusdataan (training data)* ja *testidataan (test data)*. Tällöin malli koulutetaan koulutusdataa käyttäen, jonka jälkeen sen tuottamien arvioiden yleistettävyyttä kokeillaan testidatan avulla (Goodfellow et al., 2017, s. 110–111).

Koneoppiminen jaetaan yleisellä tasolla kolmeen eri pääluokkaan, jotka ovat *ohjattu oppiminen (supervised learning)*, *ohjaamaton oppiminen (unsupervised learning)* sekä *vahvistusoppiminen (reinforcement learning)*. (Russell & Norvig, 2016, s. 694-695; Lee & Shin, 2020; Reis et al., 2020) Näiden lisäksi mallit, jotka yhdistelevät sekä ohjattua, että ohjaamatonta oppimista sijoitetaan usein *puoliohjatus oppimisen (semisupervised learning)* luokkaan. Tässä tutkielmassa keskitytään ohjatun oppimiseen kuuluviin malleihin, jotka oppivat niin sanotusti esimerkkitaustan pohjalta.


Ohjatussa oppimisessa koneoppimismallin tarkoituksena on ratkaista luokitteluongelmia (*classification*), tai tehdä numeerisia arvioita (*regression*) syötedatan pohjalta. (Russell & Norvig, 2016, s. 695-696; Lee & Shin, 2020) Mallille annetaan tällöin koulutusdatana halutut ominaisuudet, sekä niitä vastaava varsinainen arvo tai luokka, jota malli pyrkii koulutuksen jälkeen arvioimaan. Ohjatun oppimisen mallit pyrkivät siis oppimaan esimerkkitaupauksia tarkastelemalla ja tulkitsemalla.

Esimerkiksi asuntojen hintoja ennustavan ohjatun oppimisen mallin kouluttamiseen tarvittaisiin arviointiin käytettäviä ominaisuuksia, kuten rakennusvuosia, neliökokoja, ja sijainteja, sekä kyseisiä ominaisuuksia vastaavien asuntojen oikeita hintoja. Ohjatun oppimisen mallit yrittävät tulkita datasta sille syötettyjen ominaisuuksien ja määritettävien tavoitearvojen tai luokkien välisiä riippuvuussuhteita. (Russell & Norvig, 2016, s. 695-696) Käytännössä tämä tapahtuu toisteisena koulutusprosessina, jossa malli kokeilee sen hetkisen riippuvuutta kuvaavan funktion sopivuutta, ja yrittää parantaa sitä muuttelemalla sen parametreja oppimisalgoritmin hyväksi havaitsemaan suuntaan.

Ohjatun oppimisen ero ohjaamattomaan oppimiseen on peräisin siinä tarvittavasta datasta. Kuten aikaisemmin esitellyssä asuntoesimerkissä, ohjattu oppiminen tarvitsee haluttujen ominaisuuksien lisäksi kyseisiä piirteitä vastaavia tavoitearvoja (*label data*), kun taas ohjaamattomassa oppimisessä riippuvuussuhteiden tunnistamiseen käytetään vain haluttuja ominaisuuksia. (Lee & Shin, 2020) Täten esimerkiksi luokitteluongelmissa ohjattua oppimista käyttäessä tulee kaikkien eri luokitteluvaihtoehtojen olla tiedossa, kun taas ohjaamattomassa oppimisessä luokkien tarkasta määrästä ei välttämättä ole tietoa.

4.2 Syväoppiminen

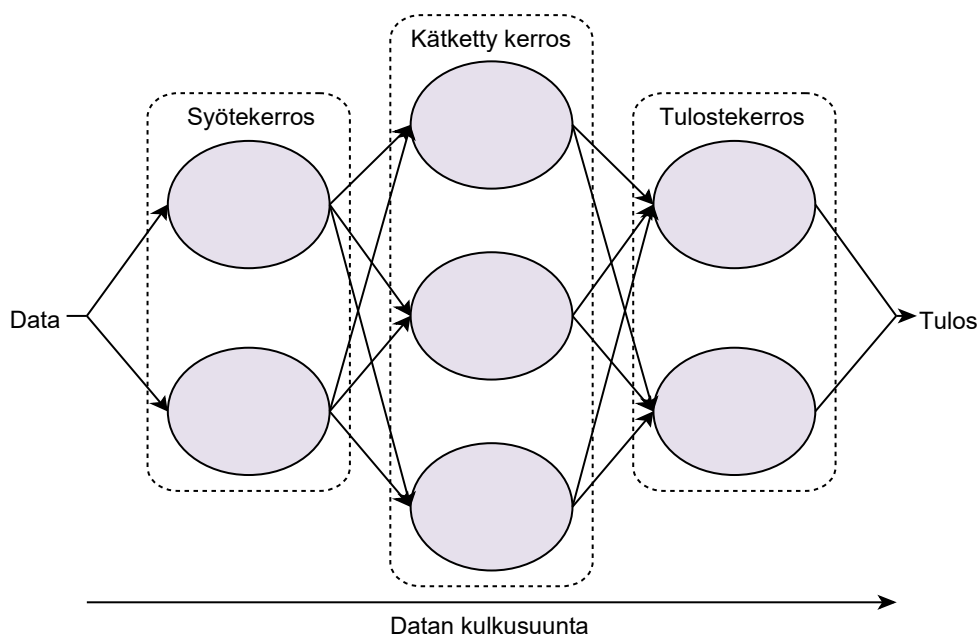
Syväoppiminen (deep learning) on koneoppimiseen kuuluva alahaara (Kuva 4), jonka avulla tietokoneet pystyvät kehittämään toimintaansa kokemuksen ja uuden datan myötä (Goodfellow et al., 2017, s. 8). Se sai alkunsa neurotieteellisestä tutkimuksesta, jonka tarkoituksena oli luoda laskennallinen malli biologisten aivojen oppimisprosessista, minkä seurauksena syväoppimismalleista käytettiin pitkään nimitystä *keinotekoinen neuroverkko (artificial neural network)*. (Goodfellow et al., 2017, s. 13-15) Syväoppimismallit ovat saaneet siis inspiraatiota biologisten neuroverkkojen toiminnasta, mutta nykyään ne eivät enää toimi tutkimusalaan yleisellä tasolla ohjaavana tekijänä.



Kuva 4: *Tekoälyn, koneoppimisen ja syväoppimisen välinen suhde. (mukaillen Lee & Shin, 2020)*

Syväoppimisen neuroverkot koostuvat useammasta erilaisesta kerroksesta (*layer*), jotka puolestaan koostuvat yhdestä tai useammasta keinotekoisista hermosolusta (*unit, node*). Yksinkertaisimmillaan verkolla on ainoastaan niin sanotut näkyvät kerrokset, jotka ovat syötekerros (*input layer*) ja tulostekerros (*output layer*).

Esimerkiksi valokuvista esineen tunnistaminen vaatii hyvin monimutkaisen riippuvuussuhdetta kuvaavan funktion, ja siksi verkkojen on vaikeaa ymmärtää raakaa syötedataa (Goodfellow et al., 2017, s. 6). Jotta verkko voisi paremmin oppia sille annettusta datasta, on sen näkyvien kerroksien välille lisättävä niin sanottuja kätettyjä kerroksia (*hidden layer*). Kätettyjen kerrosten nimitys tulee siitä, että niiden sisältämät arvot eivät ole suoraan datasta, vaan ne ovat tavallaan verkon itse muodostamia tulkintoja merkittävistä ominaisuuksista, joista se yrittää valita datan sisäisiä riippuvuussuhteita parhaiten kuvaavat (Goodfellow et al., 2017, s. 6).



Kuva 5: Esimerkki klassisesta täysin kytketystä MLP-verkosta (mukaillen Sezer et al., 2020)

Verkon toiminta perustuu syötedatan kulkuun verkon läpi sen rakenteen määrittämässä järjestyksessä. Klassisessa täysin kytketyssä neuroverkossa (Kuva 5) jokainen kerrokseen kuuluvista keinotekoisista hermosoluista on yhteydessä seuraavan kerroksen jokaiseen hermosoluun (Sezer et al., 2020). Vaikka jokainen verkon hermosoluista ovat yhteydessä viereisten kerrosten solujen kanssa, ei data kuitenkaan virtaa välttämättä kaikkien solujen läpi, sillä virtaukseen vaikuttavat niille määritetyt painoarvot (*weight term*), vinouma-arvot (*bias term*) sekä aktivaatiofunktiot (*activation function*). (Sezer et al., 2020) Aktivaatiofunktiot ovat epälineaarisia funktioita, jotka määrittävät reagoiko solu sille edeltäviltä soluilta tulevien syötteisiin vai ei. Eräitä yleisimpiä soluissa käytettyjä aktivaatiofunktioita ovat sigmoid-, RELU- ja softmax-funktiot (Ozbyoglu et al., 2020), mutta niitä ei tutkielman rajoitteen takia esitellä tämän enempää.


Oppimisprosessin aikana verkon oppimisalgoritmi säätää solujen painoarvoja siten, että datassa havaitut olennaisiksi mielletyt piirteet korostuisivat enemmän. Ominaista klassisille malleille on myös, että ne ovat niin sanotusti eteenpäin kytkettyjä (*feedforward*). Tämä tarkoittaa, että data virtaa mallissa vain yhteen suuntaan toisin kuin uudemmissa neuroverkkoarkkitehtuureissa, jossa virtausta voi tapahtua myös samaan tai edellisiin kerroksiin. Tällaisista klassisista verkkomalleista käytetään myös nimeä *monikerroksinen perseptroniverkko* (*Multi Layer Perceptron*).

4.3 Yleisiä ohjatun syväoppimisen verkkoja

Tässä aluvuossa esitellään aineiston pohjalta yleiseksi ilmenneitä syväoppimisverkkojen rakenteita. Käytännön sovelluksissa käytettävät verkot ovat huomattavasti yksityiskohtaisempia ja monimutkaisempia, joten käsiteltäviä malleja esitellään yleisellä tasolla.

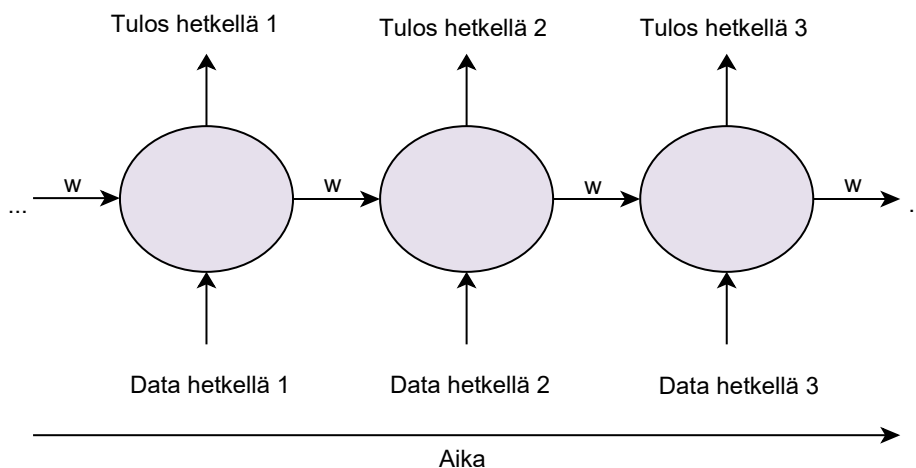
Syvät monikerroksiset perseptroniverkot (*Deep Multi Layer Perceptron, DMLP*) ovat yksiä ensimmäisistä keinotekoisista neuroverkkotyypeistä (Ozbayoglu et al., 2020), joiden avulla voidaan ratkaista sekä ennuste- että luokittelutehtäviä. DMLP-verkkojen kerrokset vastaavat yksinkertaisempien MLP-verkkojen (Kuva 5) kerroksia, mutta niiden sisältämien kätkeytyjen kerrosten määrä on suurempi, mistä nimitys ”syvä” juontuu. (Sezer et al., 2020) Kerrosmäärän lisääminen heijastuu suoraan opeteltävien ominaisuuksien määrään, mikä lisää myös DMLP-verkkojen laskennallisia vaatimuksia.

Takaisinkytketyt neuroverkot (*Recurrent Neural Network, RNN*) poikkeavat perinteisistä MLP-verkoista (Kuva 5) niiden sisältämien solujen rakenteen suhteen. Toisin kuin täysin kytketyissä verkoissa, RNN-verkon solussa (Kuva 6) on taaksepäin suuntautuva lenkki (kuvassa merkitty w), joka mahdollistaa syötteiden tallentamisen solujen sisäiseen muistiin, jolloin niitä voidaan hyödyntää myös myöhemmin käsiteltävien datavirtojen yhteydessä (Patterson & Gibson, 2017, s. 143-144). Tämän takia RNN-verkkoja käytetään pääosin aika-askelittain etenevän datan kuten tekstin, käsialan ja äänen tunnistamiseen ja tuottamiseen (Sezer et al., 2020).



Kuva 6: Yksittäisen takaisinkytketyn solun rakenne (mukaillen Sezer et al, 2020)

RNN-verkossa solulle syötetään kyseisen aika-askelen datan lisäksi edellisen ajankohdan syöte sisäisen muistin kautta, jolloin solun tuloste on riippuvainen sekä nykyisestä että edellisen askeleen syötedatasta. Kuva 7 esittää yksittäisen RNN-solun toimintaperiaatetta kolmen aika-askelen jaksolta. Siinä RNN-solun (Kuva 6) taaksepäin suuntautuvaa lenkkiä w vastaavat aika-akselin suuntaiset muistiyhteydet w , sillä kyseessä on sama solu ajan eri hetkillä.




Kuva 7: RNN-solun toiminta aika-akselilla (mukaiillen Sezer et al., 2020)

RNN-verkkojen vahvan taaksepäin suuntautuvan riippuvuuden takia käsiteltävien ajanjaksojen kasvaessa verkoista tulee entistä monimutkaisempia ja haastavampia kouluttaa. (Sezer et al., 2020) Tämän seurauksena RNN-verkkojen oppimiskyky heikkenee pidempien ajanjaksojen välisiä riippuvuussuhteita oppiessa (Patterson & Gibson, 2017, s. 149). Tätä haastetta varten on kehitetty niin sanottu pitkäkestoisen lyhytkestomustin (*Long Short Term Memory*) malli, jonka avulla myös pidempien jaksojen mallintaminen on mahdollista (Ozbayoglu et al., 2020).


Konvoluutioneuroverkot (*Convolutional Neural Network, CNN*) ovat syvien neuroverkkojen (*Deep Neural Network*) alatyyppejä, joita käytetään usein konenäköön liittyviin haasteisiin, kuten kuvien tunnistamis- ja luokittelutehtäviin (Ozbayoglu et al., 2020). Tietokoneiden näkökulmasta digitaaliset valokuvat ovat eri pikseliarvoista koostuvia matriiseja, mitä Kuva 8 havainnollistaakin konenäköpiireissä tunnetun MNIST-datan (LeCun et al., 1998) 28x28 pikselin kokoisella näytteellä. Nykyajan digikameroiden tuottamien korkealaatuisten kuvien pikselimäärät voivat olla useita miljoonia, jolloin esimerkiksi DMLP-verkkojen laskennalliset vaatimukset nousevat valtavan suuriksi.

Pikseleiden arvot vaihtelevat arvojen 0–255 välillä, jolta mustavalkoisen kuvan tapauksessa arvo 0 vastaa mustaa, 255 valkoista ja muut luvut niiden väliltä ovat harmaan eri sävyjä (Patterson & Gibson, 2017, s. 336).



Kuva 8: Esimerkkikuva käsin kirjoitetusta numerosta 5 ja siitä kuinka kone näkee sen.

Rakenteeltaan CNN-verkot (Kuva 9) koostuvat täysin kytketyn rakenteen (Kuva 5) kerrosten lisäksi konvoluutiokerroksista (*convolution layer*) sekä osanäytekerroksista (*pooling layer*). (Ozbayoglu et al., 2020) Konvoluutiokerrokset skannaavat syötettävän kuvan läpi esimerkiksi 1x1, 3x3 tai 5x5 pikselin kokoisilla suodattimilla (*filter, kernel*), minkä tarkoituksena on muodostaa kuvalle ominaispiirrekartta (*feature map*). Ominaispiirrekartta sisältää konvoluutiokerroksen tunnistamia mahdollisesti merkittäviä piirteitä kuten kulmia ja nurkkia (Patterson & Gibson, 2017, s. 131).



Kuva 9: Esimerkki CNN-verkon arkkitehtuurista (mukaillen Ozbayoglu et al., 2020)

Konvoluutiokerrosta seuraa usein osanäytekerros, minkä tarkoituksena on porrasteisesti pienentää muodostettujen ominaispiirrekarttojen kokoa. Osanäytekerrokset skannaavat myös kuvan määritellyn kokoisella suodattimella, joka piirteiden tulokseen sijaan hakee joko suodatinikkunassa sillä hetkellä olevan suurimman arvon (*max pooling*) tai kaikkien kyseisessä ikkunassa olevien arvojen keskiarvon (*average pooling*) (Goodfellow et al., 2017, s. 339-341, 346). Määritetty arvo edustaa siis kuvan ominaispiirrekartan kyseistä kohtaa sen pienennetyssä esityksessä, joka on osanäytekerroksen tuloste. Esimerkiksi

32x32 pikselin kokoisen kuvan käsittely yleistä 2x2 pikselin suodatinta käyttävällä osanäytekerroksella tuottaa 16x16 pikselin kokoisen lopputuloksen. Ominaispiirrekarttojen koostamisen lisäksi osanäytekerrokset vähentävät myös ylisovittamisen riskiä (Patterson & Gibson, 2017, s. 140).

Konvoluutio- ja osanäytekerrospareja voi verkon rakenteessa olla useita sen syvyydestä riippuen, ja joissain CNN-verkoissa pelkkiä konvoluutiokerroksia voi olla peräkkäin useampiakin (Simonyan & Zisserman, 2015). Jotta CNN-verkko voisi varsinaisesti tuottaa arvioita sille syötetystä datasta, on sillä oltava myös täysin kytkettyjä kerroksia, kuten MLP-verkossa (Patterson & Gibson, 2017, s. 140).

5. SYVÄOPPIMISEN KESKEISET SOVELLUSKOHTEET OSAKE- JA KULUTUSLUOTTO-MARKKINOILLA

Tässä luvussa esitellään eräitä tutkimuksen aikana tunnistettuja syväoppimisen sovelluksia osake- ja kulutusluottomarkkinoilta. Kokonaisuudessaan sovelluskohteita havaittiin tutkielman aihepiirin ympäriltä useita, mutta tarkasteltavaksi tähän tutkielmaan valittiin ne, jotka liittyivät selkeimmin määriteltyyn tarkastelualueeseen, ja jotka miellettiin eniten tutkituiksi tiedonhaun yhteydessä löydetyn aineiston perusteella.

5.1 Algoritminen kaupankäynti

Algoritminen kaupankäynti (algorithmic trading) on pörseissä käytettävä kaupankäyntistrategia, jossa tietokoneet toteuttavat rahoitusvälineiden, kuten osakkeiden, valuuttojen, tai johdannaisten osto- ja myyntitoimeksiantoja niille määritettyjen sääntöjen ja muuttujien pohjalta. (Ozbayoglu et al., 2020) Sen suosio on kasvanut huomattavasti parin viimeisimmän vuosikymmenen aikana sähköisten markkina-alustojen kehittymisen myötä. Toinen merkittävä tekijä suosion taustalla on myös korkean taajuuden kaupankäynti-, eli HFT-tekniikan kehittyminen, jonka avulla tietokoneet pystyvät tekemään jopa kymmeniä tuhansia osto- ja myyntitoimeksiantoja sekunnissa (Chen, 2020). Algoritmisen kaupankäynnin keskeinen haaste on siis osto- ja myyntipäätöksen automaattinen muodostaminen saatavilla olevan datan pohjalta.

Syväoppimisen keskeisiä tehtäviä tähän sovellukseen liittyen ovat kurssihintojen ennustaminen, erilaisten osto- ja myyntisignaalien tunnistaminen, sekä markkinoiden suuntauksien tunnistaminen (Ozbayoglu et al., 2020). Kurssihintojen ennustamiseen on usein hyödynnetty RNN-verkkoihin kuuluvaa LSTM-mallia, joka onkin tarkoitettu käytettäväksi erityisesti ajallisesti jaksottuneen datan kuten osakekurssien käsittelyyn. (Sezer et al., 2020) Datana LSTM-mallien kanssa hyödynnetään ennustettavien kohteiden teknisiä tietoja kuten historiallisia hinta- ja myyntimääriä. Rahoitusvälinekohtaisten tietojen lisäksi voidaan hyödyntää esimerkiksi eri osake- tai korkoindexien teknisiä tietoja, joiden avulla saadaan piirteitä markkina-alueiden liikkeistä sekä taloudellisesta ilmapiiristä.

Perinteisesti luokittelutehtäviin on usein hyödynnetty DMLP-verkkoja, mutta aineistossa osto- ja myyntisignaalien sekä markkinoiden suuntauksien tunnistukseen käytettiin erilaisia CNN- ja LSTM-verkkojen yhdistelmiä (S. Liu et al., 2017). Erikoista tässä on se,

että CNN-verkkoja käytetään yleisesti piirteiden erotteluun kuvadatasta. Ilmi kävikin, että tällainen soveltaminen on vaatinut erilaisia mielikuvituksellisia ratkaisuja, joissa markkinadataa on syötetty CNN-verkolle kuvien muodossa. Esimerkiksi Gudelek et al. (2017) esikäsittelevät käyttämäänsä aikasarjadataa siten, että päiväkohtaiset tekniset tiedot saatettiin neliömatriisimuotoon, minkä avulla data saatiin kuvia vastaavaan muotoon. Toisessa tapauksessa käytettiin kuvia datasta muodostetuista kuvaajakäyristä, jotka syötettiin CNN-verkon käsiteltäväksi ja luokiteltaviksi. Myös LSTM-verkkoja hyödynnettiin luokittelutehtäviin siten, että LSTM-kerros ennusti tuleville mahdollisille skenaarioille todennäköisyysjakautumia, joiden pohjalta malli teki päätöksensä. Vargas et al. (2017) esimerkiksi muodostivat S&P 500-indeksin liikkeitä ennustavan LSTM-mallin, joka käyttää datanaan indeksin teknisiä tietoja sekä talousuutisartikkelien otsikoita.

Dataa algoritmisen kaupankäyntiin tarkoitetuille verkkomalleille on tarjolla siis laajalti. Mallien kouluttamiseen voidaan käyttää esimerkiksi eri rahoitusvälineiden teknisiä tietoja kuten historiallisia hintoja sekä myyntimääriä (Sezer et al., 2020). Luonnollisen kielen käsittelyn avulla voidaan muuntaa erilaisia tekstiaineistoja, kuten talousuutisartikkeleita luokittelijalle (Rönnqvist & Sarlin, 2015) tai hintaa ennustavalle mallille (Vargas et al., 2017) sopivaan muotoon, minkä avulla voidaan arvioida kohteita esimerkiksi taho- tai markkinakohtaisia osatekijöitä kaupankäynnin kannattavuuden näkökulmasta.

Siirtämällä toimeksiantoihin liittyvää päätöksentekoa henkilöiltä tietokoneelle mahdollistaa siis huomattavasti suurempien ja nopeampien osto- ja myyntitapahtumien toteuttamisen, mikä heijastuu myös taloudellisiin tuottoihin mallin toimiessa oikein. Tämän lisäksi päätöksentekoon vaikuttavat inhimilliset virheet ja oletukset vähenevät päätösten pohjautuessa täysin mallille annettavaan dataan, minkä myötä toisaalta käytettävän datan laatu ja paikkansapitävyys korostuvat oleellisesti.

5.2 Arvopaperisalkkujen hallinta

Arvopaperisalkkujen tai toiselta nimeltään portfolioiden hallinnalla tarkoitetaan sijoitusten muodostaman joukon valikointia, sekä valvontaa, minkä avulla pyritään saavuttamaan asetetut taloudelliset tavoitteet määritetyn riskitason puitteissa. (Hayes, 2020) Käytännössä tämä vaatii salkunhoitajalta kykyä tehdä erilaisia riskianalyysejä, sekä kompromisseja parhaan kokonaisuuden, ja lopputuloksen muodostamiseksi.

Syväoppimisen näkökulmasta arvopaperisalkkujen hallinnan keskeisiä tehtäviä ovat sopivimpien sijoituskohteiden tunnistaminen annetulle ajanjaksolle (Ozbayoglu et al., 2020). Käytännössä tämä toteutuu luomalla ennusteita portfolioissa oleville kohteille, ja vertailemalla niitä vaihtoehtoisin, minkä pohjalta portfolioon voidaan valikoida parhaalta

vaikuttavat kohteet. Ohjatun syväoppimisen verkkomalleista MLP- ja LSTM-verkot, sekä niiden erilaiset yhdistelmät muodostuivat keskeisiksi tälle sovelluskohteelle. Esimerkiksi Zhou (2018) yhdistää nämä kaksi verkkomallia yhdeksi hybridiverkoksi, ja osoittaa sen tuottavan laadukkaampia kuukausittaisia tuottoennusteita kuin yksittäinen MLP-verkko tai kaksi perinteisempää tuottoennustetekniikkaa. Wang et al. (2020) puolestaan yhdistävät LSTM-verkon klassiseen portfolioiden hallinnan keskiarvo–varianssimalliin, minkä avulla he ennustavat portfolionsa eri osakkeiden tuottoja.

Arvopaperisalkkujen hallintaan käytettävä data vaikuttaa aineiston pohjalta yksipuolisemmalta kuin muiden tarkasteltavien sovellusten. Zhou (2018) hyödyntää hybridimallinsa datana osakkeiden viime kuukausien tuottotietoja sekä vuositason kirjanpitolietoja. Myös useammassa muussa tutkimuksessa datana käytetään pääosin kohteiden teknisiä tietoja kuten hintaa ja muodostuneita tuottoja, sekä niistä johdettuja taloudellisia indikaattoreita ja suhdelukuja (Ozbyoglu et al., 2020).

Portfolioiden hallinnan voidaan ajatella siis olevan optimointiongelma, jossa pyritään maksimoimaan portfolion muodostamat tuotot, ja minimoimaan siitä aiheutuneet tappiot. Esimerkkien pohjalta tämä tapahtuu käytännössä tunnistamalla ja karsimalla nykyisistä sijoituksista vähiten kannattavimmat, sekä luomalla ennusteita potentiaalisten sijoituskohteiden odotetuista tuotoista, ja valikoimalla niistä kannattavimmat. Syväoppimisen avulla tällaista sijoituskohteiden valikointia voidaan suorittaa suhteellisen helposti, sillä esimerkiksi osakkeiden teknistä dataa voidaan hakea suoraan erilaisista rajapinnoista ohjelmallisesti, mikä mahdollistaa suurienkin osakejoukkojen vertailun automatisoidusti.

5.3 Taloudellisten riskien arviointi

Taloudellisten riskien arvioinnista (*financial risk assesment*) on kehittynyt erittäin keskeinen osa-alue rahoitusalan liiketoimintaa. Arvioitavia kohteita voivat olla esimerkiksi erilaiset varat, tuotteet, yritykset, pankit, tai kokonaiset markkinasegmentit. Kohteille voidaan arvioida muun muassa sijoituskelpoisuutta, luottoluokitusta tai mahdollisen konkurssin todennäköisyyttä. (Ozbyoglu et al., 2020) Näiden kaltaisista piirteistä muodostuvat riskitasot heijaustuvat suoraan pääomavarojen hinnoitteluun eli korkotasoon, ja siksi niiden onnistunut arviointi on hyvin olennaista niin osake- kuin kulutusluottomarkkinoiden näkökulmasta.

Syväoppimisen keskeisiä tehtäviä osake- ja kulutusluottomarkkinoiden riskienarvioinnissa ovat taloudellisen epätasapainon ennustaminen sekä luottoluokituksen määrittä-

minen. (Ozbyoglu et al., 2020) Oleellisiksi syväoppimismalleiksi taloudellisen epätasapainon ennustamisessa muodostuivat CNN- ja LSTM-pohjaiset verkot. Kävi myös ilmi, että kyseistä sovelluskohdetta on tutkittu paljon perinteisiä koneoppimismalleja käyttäen.

Riskien arviointiin voidaan käyttää myös monipuolisesti erilaista dataa. Rönnqvist ja Sarlin (2015) esimerkiksi hyödyntävät pankkien talousahdinkoa arvioivassa mallissaan datana 6,6 miljoonaa talousuutisartikkeliä, ja liittävät ne 243:een eri rahoitusmaailman tapahtumaan. Artikkelit esikäsitellään ensin luonnollisen kielen käsittelyn avulla, minkä jälkeen heidän määrittelemänsä RNN-pohjainen syväoppimismalli pystyy ennustamaan pankkien taloudellista ahdinkoa niiden pohjalta (Rönnqvist & Sarlin, 2015).

Luottoluokituksen määrittelyssä oleellinen data vaihtelee hakijakohtaisesti. Yksityishenkilöiden luottoluokituksen määrittämiseen hyödynnetään yleensä asiakkaiden henkilökohtaisia ja taloudellisia muuttujia, kuten esimerkiksi ikää, koulutusta, sekä nykyisten lainojen määrää ja suuruutta (Dželihodžić et al., 2018; Ozbyoglu et al., 2020). Esimerkiksi Neagoe et al. (2018) hyödyntävät vastaavanlaisia piirteitä, ja vertailevat CNN- ja MLP-pohjaisten luottoluokitusta määrittelevien verkkojen suorituskykyä. Parhaat tulokset he saavuttavat syvällä CNN-verkolla.

Taloudellinen epävarmuus on ollut hyvin ajankohtainen aihe näin maailmanlaajuisen pandemian aikana, ja markkinoiden liikkeet ovat olleet hyvin ennalta-arvaamattomia, mikä on viestinyt sijoittajien epävarmuudesta ja yritysten taloudellisesta ahdingosta. Tällaisessa tilanteessa sijoituskohteiden historialliset tekniset tiedot ovat mitä luultavimmin menettäneet merkitystään suurien ja epänormaalien hintojen vaihtelun myötä. Menneinä vuosina muodostuneet pidemmän aikavälin markkinatrendit eivät todennäköisesti pidä enää paikkaansa, vaan niiden tilalle on muodostunut uusia suuntauksia, kuten esimerkiksi videoneuvottelupalveluita tarjoavien yritysten markkinaosuuksien huomattava kasvu etätyön laajan lisääntymisen myötä. Tämän pohjalta voidaan ajatella luonnollisen kielen käsittelyyn ja RNN-verkkoihin pohjautuvien mallien muodostuneen merkittäviksi työkaluiksi tällä osa-alueella, sillä niiden avulla voidaan analysoida erilaisia tekstilähteitä reaaliaikaisesti. Tämä mahdollistaa esimerkiksi uutisartikkeleiden tai sosiaalisen median päivitysten ohjelmallisen muuntamisen syväoppimisverkoille sopivaan muotoon, jolloin niitä voidaan hyödyntää malleissa markkinaolosuhteita kuvaavina piirteinä epänormaalien tunnuslukujen sekä teknisten tietojen sijaan.

5.4 Petosten havaitseminen

Taloudellisten petosten havaitseminen on hyvin merkittävä haaste niin rahoitusalan yritysten kuin yhteiskunnallisen lainvalvonnan näkökulmasta. Tämän seurauksena se on

muodostunutkin yhdeksi tutkituimmaksi sovelluskohteeksi kone- ja syväoppimistutkimuksissa. (Ozbayoglu et al., 2020) Erilaisia petostyyppisiä on tunnistettavissa useita kuten esimerkiksi veronkierto, vakuutuspetokset, rahanpesu sekä luottopetokset.

Verkkokauppojen, verkkomaksuliikenteen sekä älypuhelinien määrän kasvun myötä luottokorttipetosten määrä on kasvanut huomattavasti, minkä seurauksena on aiheutunut huomattavia taloudellisia tappioita niin verkkokauppiaille kuin rahoituslaitoksille (Pandey, 2017; Jurgovsky et al., 2018; Nguyen et al., 2020). Petosten jatkuva kehittyminen on yksi keskeisimmistä haasteista niiden havaitsemisessa (Nguyen et al., 2020).

Syväoppimisen luokittelijan näkökulmasta esimerkiksi luottokorttipetokset voidaan mieltää kaksisuuntaiseksi luokitteluongelmaksi, sillä maksutapahtumia analysoitaessa niille pyritään määrittämään totuusarvo siitä, onko kyseessä petoksellinen tapahtuma vai ei. Aineistossa tähänkin ongelmaan oli onnistuttu muodostamaan ratkaisuja useammalla eri verkkomallilla. Esimerkiksi Jurgovsky et al. (2018) hyödyntävät luottokorttipetoksia käsittelevässä artikkelissaan LSTM-verkkomallia kehittyneen piirteidenkoostamistekniikkaan kanssa, mikä vähentää syväoppimismallien taipumusta ylisovittua. Nguyen et al. (2020) puolestaan toteuttavat LSTM-mallin vertailukohtaksi CNN-verkkomallin, joka osanäytekerroksen avulla koostaa datavirran yksilotteiseen muotoon, ja onnistuu tällä tavoin saavuttamaan myös huomattavan hyviä tuloksia luottokorttipetosten tunnistamisessa.

Vaikka talouspetosten tunnistaminen on yksi tutkituimmista kone- ja syväoppimisen sovelluskohteista, on siihen liittyvällä kehitystyöllä huomattavia haasteita tarvittavan datan saatavuuden kanssa. Esimerkiksi luottokorttien maksuliikennedatan kanssa käyttäjien yksityisyydensuoja muodostuu merkittäväksi haasteeksi sen vapaalle jakamiselle. Tutkimuskäyttöön vapaasti tarjolla olevan datan piirteet ja arvot ovat siis tarkasti anonymisoituja ja skaalattuja siten, ettei esimerkiksi numeerisista arvoista voida tulkita mitä ne oikeasti tarkoittavat, vaan jäljellä on ainoastaan arvojen väliset suhteet. Tietosuojan mahdollistamisen lisäksi tämä tekee toisaalta siis eri piirteiden ja arvojen syvemmän analysoinnin ja taustojen ymmärtämisen mahdottomaksi. Toinen haaste on datan sisältämien tapausten huomattavan suuri epätasapaino. Käytännössä tämä tarkoittaa sitä, että data sisältää hyvin paljon vähemmän petollisia tapauksia suhteessa vilpittömiin ostoksiin. Syväoppimisverkot saattavat tulkita tämän huomattavan vinouman koulutusprosessin jälkeen merkittävänä piirteenä, mikä voi johtaa epätarkkoihin lopputuloksiin.

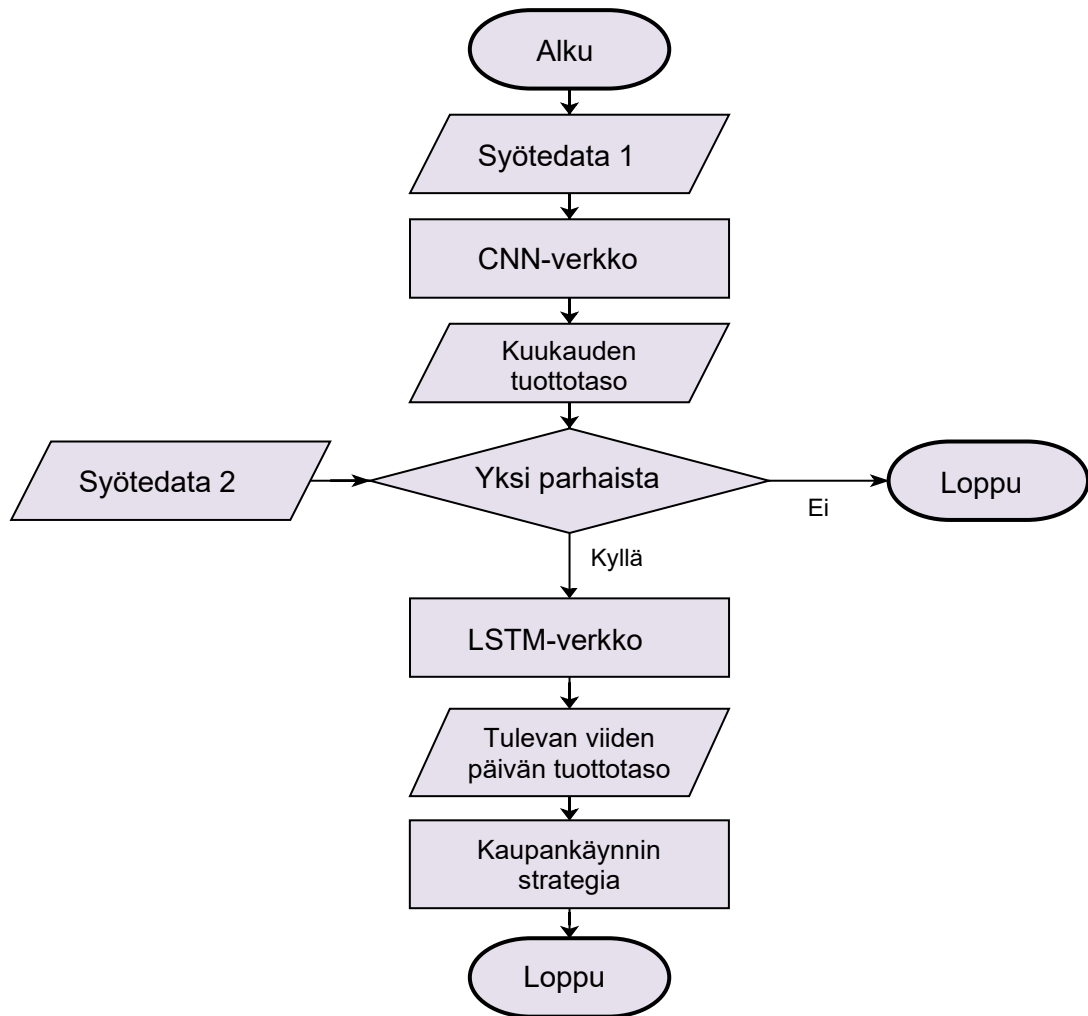
Luottokorttipetokset muodostuivat keskeiseen rooliin tämän sovelluksen aihepiirin suhteen, sillä niihin kohdistuvia tutkimuksia löydettiin useita. Syynä tälle puolestaan on todennäköisesti se, että luottokortit toimivat pääasiallisena verkkomaksuliikenteen välineenä, jolloin niihin kohdistuu myös paljon huijauksia ja tietovuotoja, jotka voivat helposti

johtaa niillä tehtyihin petollisiin maksutapahtumiin. Syväoppiminen soveltuu hyvin tällaisen verkkomaksuliikenteen analysointiin ja poikkeavien, eli oletettavasti petollisten maksutapahtumien tunnistamiseen, sillä maksutapahtumista tallentuu oletettavasti laajalti teknisiä yksityiskohtia ohjelmallisesti hallittavassa muodossa. Tällaisia tietoja voivat olla esimerkiksi ostosten aikaleimat ja sijaintitiedot, joiden pohjalta mallit pystyvät havaitsemaan poikkeavat tapahtumat tavallisen kulutuksen seasta, ja toteuttamaan tarvittavat jatkotoimenpiteet.

5.5 Havaintoja tarkastelluista sovelluskohteista

Käsiteltyjen sovelluskohteiden pohjalta LSTM- sekä CNN-verkot ovat siis huomattavan keskeisiä syväoppimisverkkoja osake- ja kulutusluottomarkkinoilla. Myös joitain MLP- ja DMLP-verkkoihin pohjautuvia ratkaisuja käytettiin, mutta kuitenkin selkeästi vähemmissä määrin. Eräs syy tälle voisi olla niiden laskennallisen tehokkuuden huono skaalautuvuus datan sisältämien piirteiden määrän kasvaessa. Toinen syy voisi olla osake- ja kulutusluottomarkkinoilla liikkuvan datan tyypit, jotka aineistojen pohjalta painottuvat enemmän LSTM-verkoille sopivaan aikajaksotteiseen dataan sekä CNN-verkoille sopivaan kuvadataan. Joissain tapauksissa dataa myös muunnettiin kuvadataa muistuttavaan muotoon, jolloin sitä pystyttiin käsittelemään CNN-verkon avulla.

Yleisiä malleja olivat myös erilaiset yhdistelmä- eli hybridiverkot, jotka koostuvat useammasta verkkoarkkitehtuurista sekä muista mahdollisista välivaiheista. Tällaisia yhdistelmiä käyttivät esimerkiksi Liu et al. (2017) sellaisessa sijoituskohdetta arvioivassa mallissa (Kuva 10), jossa sille syötetään ensin vertailtavien sijoituskohteiden historiallisia tuottotasoja (syötedata 1), joiden pohjalta CNN-verkko muodostaa arviot eri kohteiden tämänhetkisistä kuukausittaisista tuotoista. Tämän jälkeen malli suodattaa CNN-verkon muodostamien arvioiden pohjalta tuottoisimpaan yhteen prosenttiin kuuluvat kohteet, joiden käsittely mallissa jatkuu. Seuraavassa vaiheessa mallille syötetään suodatettujen, kannattavimpien kohteiden teknisiä markkinatietoja (syötedata 2), joiden pohjalta LSTM-verkko muodostaa ennusteita kohteiden tulevista viiden päivän tuotoista. Näiden tuotennusteiden pohjalta kohteille määritetään totuusarvot, onko niiden tulevat tuotot positiivisia vai ei. Tämän jälkeen saatujen tietojen pohjalta voidaan lähteä toteuttamaan haluttua kaupankäyntistrategiaa. Voitaisiin siis esimerkiksi ostaa niitä kohteita, joiden ennustetut tuotot ovat positiivisia tai myydä lyhyeksi niitä kohteita, joiden tuotot ovat negatiivisia. Hybridiverkot ovat siis useammasta välivaiheista ja syväoppimisverkosta muodostuvia prosessikokonaisuuksia, jotka tuottavat niille syötetystä datasta halutun tyyppisiä lopputuloksia.



Kuva 10: Osakkeen kannattavuutta ennustavan hybridiverkon toimintalogiikka
(mukaillen Liu et al. 2017)

Kokonaisuudessaan löydettyjen tutkimusartikkelien, tarkasteltujen sovelluskohteiden sekä eräiden käytettyjen lähteiden (Lee & Shin, 2020; Ozbayoglu et al., 2020; Sezer et al., 2020) perusteella osake- ja kulutusluottomarkkinoiden tutkituimmaksi syväoppimisen tehtävätyypiksi on muodostunut erilaisten aikasarjaennusteiden luominen. Kyseinen tehtävä on keskeinen osa myös esimerkiksi edellä esiteltyä hybridiverkkoa (Kuva 10). Käytetyintä dataa oli puolestaan kohteiden erilaiset tekniset tiedot. Numeerisen luonteensa puolesta ne sopivat syväoppimisverkkojen käsittelyyn hyvin, ja toisena syynä tälle voisi olla myös niiden ohjelmallisen keräyksen sekä käsittelyn helppous. Tämän lisäksi ilmi tuli myös muita datalähteitä, kuten esimerkiksi erilaisten tekstidatojen hyödyntäminen luonnollisen kielen käsittelyn avulla.

6. YHTEENVETO

Tässä luvussa tehdään tutkielmasta yhteenveto, ja arvioidaan saatuja tuloksia. Lopuksi määritellään vielä jatkotutkimukselle avoimet aihepiirit tämän tutkielman pohjalta.

6.1 Johtopäätökset

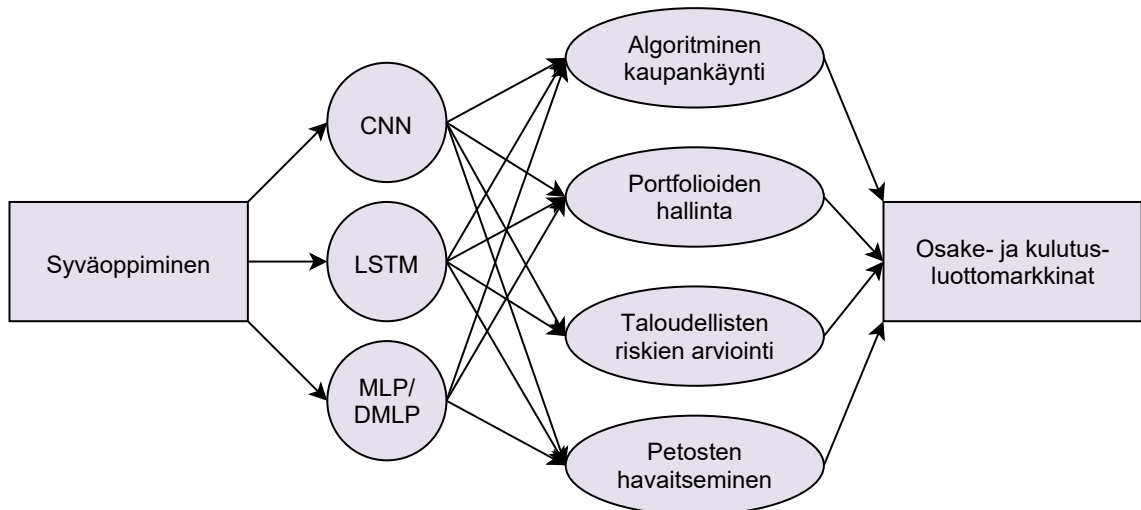
Tutkielmassa tutkittiin syväoppimisen soveltamiskohteita osake- ja kulutusluottomarkkinoilla kirjallisuuskatsauksen muodossa. Siinä tutustuttiin niin syväoppimisen kuin osake- ja kulutusluottomarkkinoiden taustoihin ja ominaispiirteisiin, minkä jälkeen lähdettiin selvittämään aineistossa ilmeneviä syväoppimisen sovelluskohteita osake- ja kulutusluottomarkkinoilla, joita onnistuttiinkin löytämään useita. Päätutkimuskysymyksenä toimi, millaisia sovelluskohteita syväoppimisella on osake- ja kulutusluottomarkkinoilla.

Ensiksi lähdettiin selvittämään, mitä tarkoittavat osake- ja kulutusluottomarkkinat. Osakemarkkinoiden kautta osakeyhtiöt pystyvät hakemaan rahoitusta toiminnalleen myymällä pieniä osuuksia eli osakkeita yrityksestään sijoittaville tahoille. Sijoittajat ovat osakkeenomistuksen myötä oikeutettuja kyseisen yhtiön jakokelpoisista tuotoista maksettaviin osinkoihin, joiden suuruus määrittyy sijoittajan omistajuuden suuruuden mukaan. Kulutusluottomarkkinat ovat puolestaan tarkoitettu ennen kaikkea yksityishenkilöiden kulutuskyvyn parantamiseen. Kulutusluotot voidaan karkeasti jakaa ennalta määritettyihin hankintoihin tarkoitettuihin osamaksulainoihin sekä jatkuviin luottoihin, joita voidaan käyttää tehdyn sopimuksen mukaan melkein mihin tahansa hankintoihin. Korvaukseksi lainasta kuluttajat maksavat lainanmyöntäneelle taholle lainasopimuksessa määritellyä korkoa. Osake- ja kulutusluottomarkkinat mahdollistavat maksukyvyn parantamisen niin yrityksille kuin yksityishenkilöille, ja ovat täten siis hyvin keskeinen osa kapitalistista talousjärjestelmää,

Seuraavaksi selvityksen kohteena oli syväoppiminen ja sen taustat. Syväoppiminen on koneoppimiseen kuuluva alahaara, joka on erikoistunut muun muassa erilaisten aistien tuottaman datan, kuten esimerkiksi kuvien ja äänen käsittelyyn. Syväoppimismallit ovat datalla toimivia keinotekoisia neuroverkkoja, jotka ovat alun perin saaneet innoituksensa biologisten aivojen toiminnasta. Tutkielmassa rajattiin tarkasteltavat mallit ohjattuun oppimiseen kuuluviin syväoppimisverkkoihin. Ohjatun oppimisen mallit oppivat niin sanotusti esimerkin pohjalta, eli ne tarvitsevat esimerkkiominaisuuksia sekä niitä vastaavia tavoitearvoja, joita ne pyrkivät määrittämään. Näiden esimerkkitapausten avulla mallit

muodostavat sääntöfunktioita, joiden on tarkoitus kuvata eri ominaisuuksien ja tavoitearvojen välisiä riippuvuussuhteita. Tutkielmassa tutustuttiin yleiseen ennustamiseen ja luokitteluun käytettäviin DMLP-verkkoihin, aikajaksotteisen datan kuten äänen käsittelyyn erikoistuneihin RNN-verkkoihin sekä kuvadatan käsittelyyn erikoistuneihin CNN-verkkoihin.

Syväoppimisen yleisemmän selvityksen jälkeen lähdettiin käsittelemään sitä osake- ja kulutusluottomarkkinoiden näkökulmasta ja hakemaan tutkielman päätutkimuskysymykselle vastausta. Kuten tutkielman rajoitusten määrittämisen yhteydessä oletettiin, osake- ja kulutusluottomarkkinoilta löytyi aineistosta useita eri sovelluskohteita, joista tämän tutkielman tarkasteluun valittiin parhaiten tutkielman aihepiiriin sopivat sovellukset, joista löydettiin tiedonhaun yhteydessä eniten tietoa. Nämä sovellukset ovat algoritminen kaupankäynti, arvopaperisalkkujen hallinta, taloudellisten riskien arviointi sekä petosten havaitseminen.



Kuva 11: Yhteenveto tutkielmassa saaduista tuloksista

Saaduista tuloksista keskeisimpiä esitellään Kuva 11. Tutkielmassa havaittiin siis, että osake- ja kulutusluottomarkkinoilla on useita erilaisia sovelluskohteita syväoppimiselle. Tarkasteltujen sovellusten pohjalta LSTM- sekä CNN-verkot ovat muodostuneet erityisen olennaisiksi osiksi käytettäviä malleja. Näitä verkkoarkkitehtuureja yhdisteltiin niin keskenään kuin muidenkin verkkojen kanssa niin sanotuiksi hybridimalleiksi, jotka koostuvat verkkojen lisäksi muista erilaisista välivaiheista, kuten datasyötteistä, suodattimista sekä tulosteista. Havaittiin myös, että sovelluksissa käytettiin erityisen paljon eri kohteiden teknisiä tietoja, jota saatettiin täydentää myös tekstidatalla luonnollisen kielen käsittelyä hyödyntäen.

Tietoliikenne yhteyksien nopeutumisen, laskentatehojen ja -kapasiteetin kasvun sekä datan määrällisen lisääntymisen myötä dataan pohjautuva automaatio on siis muodostunut oleelliseksi osaksi osake- ja kulutusluottomarkkinoita. Syväoppiminen on tuonut tälle automaatiolle uusia mahdollisuuksia oppia entistä monimutkaisempia riippuvuussuhteita eri tahojen ja muuttujien väliltä. Tämän seurauksena sen avulla on kehitetty useita erilaisia sovelluksia, joilla voidaan saavuttaa huomattavia taloudellisia hyötyjä muun muassa automatisoidun päätöksenteon muodossa.

6.2 Tutkielman arviointi

Tämän tutkielman tarkoituksena oli muodostaa lukijalle yleistason käsitys osake- ja luottomarkkinoista, syväoppimisesta sekä niitä yhdistävistä sovelluskohteista. Syväisemmän ymmärryksen muodostamiseen oleellista olisi ollut tarkasteltavien aihepiirien matemaattisten yksityiskohtien käsittely, mutta tämän työn laajuuden kaventamiseksi sekä yleisen ymmärrettävyyden säilyttämiseksi siitä päätettiin luopua.

Aineiston puolesta tutkielmalla oli hyvät lähtökohdat, sillä sitä oli kattavasti saatavilla. Tämän pohjalta oli selkeästi havaittavissa, että osake- ja kulutusluottomarkkinat ovat yksiä tutkituimpia syväoppimisen sovellusaloista. Aineistossa oli havaittavissa pieniä taho-kohtaisia merkintä- ja käsite-eroja, mutta ei kuitenkaan mitään sen suurempia ristiriitaisuuksia.

Tutkielman keskeisimpinä tuloksina tunnistettiin osake- ja kulutusluottomarkkinoille sopivia syväoppimiseen pohjautuvia sovelluksia sekä niihin käytettäviä verkkomalleja. Tämän lisäksi huomioita tehtiin myös malleihin käytettävästä datasta sekä aihepiirin keskeisimmästä tehtävyydestä. Tutkimusprosessin alussa määritettyyn päätutkimuskysymykseen, sekä siitä johdettuihin alatutkimuskysymyksiin onnistuttiin siis vastaamaan, minkä puolesta tutkielman voidaan ajatella onnistuneen.

6.3 Jatkotutkimuksen tarve

Erilaisia jatkotutkimusmahdollisuuksia on tämän tutkielman pohjalta tarjolla runsaasti. Kuten tutkielman arvioinnin yhteydessä mainittiinkin, jäi niin syväoppimisen kuin osake- ja kulutusluottomarkkinoiden matemaattinen käsittely pois tästä tutkielmasta. Matemaattisella käsittelyllä voitaisiin saada laajempaa ymmärrystä mallien ja markkinoiden eri ilmiöiden taustoista. Merkittävä tutkimuksellisen näkökulman laajennus voisi olla myös ohjaamattomaan oppimiseen kuuluvien verkkomallien kuten esimerkiksi autokooderei-

den (*autoencoder*) piiriin, sillä myös niillä on varmasti paljon tarjottavaa erilaisten sovel-
lusten muodossa. Tiedonhaun yhteydessä tehtiin myös huomio pelkästään kulutusluot-
tomarkkinoihin keskittyvän syväoppimistutkimuksen suhteellisesta vähyydestä, minkä
perusteella myös siihen liittyen voisi toteuttaa jatkotutkimusta.

Osake- ja kulutusluottomarkkinoiden puolelta voitaisiin varmasti löytää myös monen-
laista syvennettävää yksityiskohtaa. Esimerkiksi teknisten indikaattoreiden merkitykseen
syväoppimisen kannalta voisi tutustua paremmin, sillä niistä saataisiin niin sanottuja joh-
dannaisominaisuuksia dataa täydentämään. Tarkastelua voitaisiin toisaalta laajentaa
myös muihin rahoitusvälineisiin kuten joukkolainoihin, optioihin sekä valuuttoihin. Esi-
merkiksi kryptovaluuttojen kaupankäynti syväoppimisen avulla voisi olla melko ajankoh-
tainen tutkimuskohde. Tiedonhaun pohjalta tutkimusta voitaisiin laajentaa myös esimer-
kiksi kulutusluottoihin liittyen, sillä siitä löytyi selkeästi vähiten aineistoa, vaikka hakukie-
lenä käytettiin englantiä.

LÄHTEET

Accenture. (2018). *Redefining Banking with Artificial Intelligence*. Saatavilla: https://www.accenture.com/%20_acnmedia/pdf-68/accenture-redefine-banking.%20pdf (Haettu 24.3.2021)

Chen, J. (2020, August 26). *Algorithmic Trading*. Investopedia. Saatavilla: <https://www.investopedia.com/terms/a/algorithmictrading.asp> (Haettu 25.3.2021)

Chen, J. (2021a, March 20). *Stock Market*. Investopedia. Saatavilla: <https://www.investopedia.com/terms/s/stockmarket.asp> (Haettu 25.3.2021)

Chen, J. (2021b, March 31). *What Is an Index?* Investopedia. Saatavilla: <https://www.investopedia.com/terms/i/index.asp> (Haettu 25.3.2021)

Deloitte. (2021). *Technology, Media, and Telecommunications Predictions 2021* (No. 35). Adrenalin Publishing Ltd. Saatavilla: https://www2.deloitte.com/content/dam/insights/articles/US93838_TMT_Predictions_2021/DI_2021-TMT-predictions.pdf (Haettu 24.3.2021)

Dhir, R. (2020, May 15). *Creditworthiness*. Investopedia. Saatavilla: <https://www.investopedia.com/terms/c/credit-worthiness.asp> (Haettu 25.3.2021)

Dželihodžić, A., Đonko, D., & Kevrić, J. (2018). Improved Credit Scoring Model Based on Bagging Neural Network. *International Journal of Information Technology & Decision Making*, 17(06), 1725–1741. Saatavilla: <https://doi.org/10.1142/S0219622018500293>

Fink, A. (2014). *Conducting research literature reviews: From the Internet to paper* (4th ed.). Sage.

Fuhrmann, R. (2019, January 25). *Stock Exchanges Around The World*. Investopedia. Saatavilla: <https://www.investopedia.com/financial-edge/1212/stock-exchanges-around-the-world.aspx> (Haettu 30.3.2021)

Gartner. (2020). *2 Megatrends Dominate the Gartner Hype Cycle for Artificial Intelligence* (Vol. 2021). Saatavilla: <https://www.gartner.com/smarterwithgartner/2-megatrends-dominate-the-gartner-hype-cycle-for-artificial-intelligence-2020/>

Goodfellow, I., Bengio, Y., & Courville, A. (2017). *Deep Learning*. MIT.

Harala, S. (2013, July 18). *Oletko yrittänyt ostaa lottoriviä luottokortilla? Ei onnistu*. Yle Uutiset. Saatavilla: http://yle.fi/uutiset/oletko_yrittanynt_ostaa_lottorivia_luottokortilla_ei_onnistu/6735850 (Haettu 25.3.2021)

Harper, D. R. (2020, December 12). *Getting to Know the Stock Exchanges*. Investopedia. Saatavilla: <https://www.investopedia.com/articles/basics/04/092404.asp> (Haettu 24.3.2021)

Hayes, A. (2020, February 27). *Portfolio Management*. Investopedia. Saatavilla: <https://www.investopedia.com/terms/p/portfoliomangement.asp> (Haettu 24.3.2021)

Jesse, M., & Jannach, D. (2021). Digital nudging with recommender systems: Survey and future directions. In *Computers in Human Behavior Reports* (Vol. 3). Saatavilla: <https://doi.org/10.1016/j.chbr.2020.100052>

Jurgovsky, J., Granitzer, M., Ziegler, K., Calabretto, S., Portier, P.-E., He-Guelton, L., & Caelen, O. (2018). Sequence classification for credit-card fraud detection. *Expert Systems with Applications*, 100, 234–245. Saatavilla: <https://doi.org/10.1016/j.eswa.2018.01.037>

Kagan, J. (2021, April 6). *What Is Consumer Credit?* Investopedia. Saatavilla: <https://www.investopedia.com/terms/c/consumercredit.asp> (Haettu 24.3.2021)

- Kaplan, A., & Haenlein, M. (2019). Siri, Siri, in my hand: Who's the fairest in the land? On the interpretations, illustrations, and implications of artificial intelligence. *Business Horizons*, 62(1), 15–25. Saatavilla: <https://doi.org/10.1016/j.bushor.2018.08.004>
- Kenton, W. (2021, March 23). *S&P 500 Index – Standard & Poor's 500 Index*. Investopedia. Saatavilla: <https://www.investopedia.com/terms/s/sp500.asp>
- Kontkanen, E., & Lång, J. (2018). Selvitys positiivisia luottotietoja koskevan järjestelmän edellytyksistä. *Selvityksiä ja ohjeita*, 128.
- LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278–2324. Saatavilla: <https://doi.org/10.1109/5.726791>
- Lee, I., & Shin, Y. J. (2020). Machine learning for enterprises: Applications, algorithm selection, and challenges. *Business Horizons*, 63(2), 157–170. Saatavilla: <https://doi.org/10.1016/j.bushor.2019.10.005>
- Li, Y., Lin, X., Wang, X., Shen, F., & Gong, Z. (2017). Credit Risk Assessment Algorithm Using Deep Neural Networks with Clustering and Merging. *2017 13th International Conference on Computational Intelligence and Security (CIS)*, 173–176. Saatavilla: <https://doi.org/10.1109/CIS.2017.00045>
- Liu, S., Zhang, C., & Ma, J. (2017). CNN-LSTM Neural Network Model for Quantitative Strategy Analysis in Stock Markets. In D. Liu, S. Xie, Y. Li, D. Zhao, & E.-S. M. El-Alfy (Eds.), *Neural Information Processing* (Vol. 10635, pp. 198–206). Springer International Publishing. Saatavilla: https://doi.org/10.1007/978-3-319-70096-0_21
- Makkonen, J. (2020). *Sijoittaminen for Dummies osa 21: Hajauttaminen*. Sijoitustieto. Saatavilla: <https://www.sijoitustieto.fi/sijoitusartikkelit/sijoittaminen-dummies-osa-21-hajauttaminen> (Haettu 24.3.2021)
- Murphy, C. B. (2021, March 5). *Over-The-Counter (OTC)*. Investopedia. Saatavilla: <https://www.investopedia.com/terms/o/otc.asp> (Haettu 24.3.2021)
- Neagoe, Victor-Emil, Adrian-Dumitru Ciotec, & George-Sorin Cucu. n.d. (2018) *Deep Convolutional Neural Networks Versus Multilayer Perceptron for Financial Prediction* .
- Nguyen, T. T., Tahir, H., Abdelrazek, M., & Babar, A. (2020). *Deep Learning Methods for Credit Card Fraud Detection*. 8.
- Ozbayoglu, A. M., Gudelek, M. U., & Sezer, O. B. (2020). Deep learning for financial applications: A survey. *Applied Soft Computing*, 93, 106384. Saatavilla: <https://doi.org/10.1016/j.asoc.2020.106384>
- Pandey, Y. (2017). Credit Card Fraud Detection using Deep Learning. *International Journal of Advanced Research in Computer Science*, 5.
- Patterson, J., & Gibson, A. (2017). *Deep Learning: A Practitioner's Approach*. O'Reilly Media, Incorporated.
- Reis, C., Ruivo, P., Oliveira, T., & Faroleiro, P. (2020). Assessing the drivers of machine learning business value. *Journal of Business Research*, 117, 232–243. Saatavilla: <https://doi.org/10.1016/j.jbusres.2020.05.053>
- Rönnqvist, S., & Sarlin, P. (2015). Detect & Describe: Deep learning of bank stress in the news. *ArXiv:1507.07870 [Cs, q-Fin]*. Saatavilla: <http://arxiv.org/abs/1507.07870>
- Russell, S., & Norvig, P. (2016). *Artificial intelligence a modern approach* (3rd ed.). Pearson.

- Scott, G. (2019, September 10). *Mobile Trading*. Investopedia. Saatavilla: <https://www.investopedia.com/terms/m/mobile-trading.asp> (Haettu 22.3.2021)
- Sezer, O. B., Gudelek, M. U., & Ozbayoglu, A. M. (2020). Financial time series forecasting with deep learning: A systematic literature review: 2005–2019. *Applied Soft Computing*, *90*, 106181. Saatavilla: <https://doi.org/10.1016/j.asoc.2020.106181>
- Simonyan, K., & Zisserman, A. (2015). Very Deep Convolutional Networks for Large-Scale Image Recognition. *ArXiv:1409.1556 [Cs]*. Saatavilla: <http://arxiv.org/abs/1409.1556>
- Suwajanakorn, S., Seitz, S. M., & Kemelmacher-Shlizerman, I. (2017). Synthesizing Obama: Learning Lip Sync from Audio. *ACM Trans. Graph.*, *36*(4). Saatavilla: <https://doi.org/10.1145/3072959.3073640>
- Vargas, M. R., de Lima, B. S. L. P., & Evsukoff, A. G. (2017). Deep learning for stock market prediction from financial news articles. *2017 IEEE International Conference on Computational Intelligence and Virtual Environments for Measurement Systems and Applications (CIVEMSA)*, 60–65. Saatavilla: <https://doi.org/10.1109/CIVEMSA.2017.7995302>
- Veloso, M. (2021). What is Machine Learning? *Carnegie Mellon University*. Saatavilla: <https://www.ml.cmu.edu/> (Haettu 24.3.2021)
- Wang, W., Li, W., Zhang, N., & Liu, K. (2020). *Portfolio formation with preselection using deep learning from long-term financial data*. *Expert Systems with Applications*, *143*, 113042. Saatavilla: <https://doi.org/10.1016/j.eswa.2019.113042>
- Yahoo Finance. (2021, April 17). *S&P 500 (^GSPC) Charts, Data & News—Yahoo Finance*. Saatavilla: <https://finance.yahoo.com/quote/%5EGSPC/> (Haettu 17.4.2021)

LIITE A: TUTKIELMASSA OLEELLISEKSI MUODOSTUNEITA AINEISTOJA

Tekijä(t)	Otsikko	Kuvaus	Tyyppi
Lee & Shin 2020	Machine learning for enterprises: Applications, algorithm selection, and challenges.	Koneoppimislajien yleistä esittelyä, sekä niiden liiketoiminnalliseen soveltamiseen liittyvien haasteiden käsittelyä.	Vertaisarvioitu artikkeli
Ozbayoglu et al. 2020	Deep learning for financial applications: A survey	Kyselypohjainen tutkimus syväoppimismallien soveltamisesta rahoitusalueella.	Vertaisarvioitu artikkeli
Reis et al. 2020	Assessing the drivers of machine learning business value	Tutkimus koneoppimis- pohjaisesta arvonluonnista avulla yrityksissä.	Vertaisarvioitu artikkeli
Russell & Norvig 2016	Artificial Intelligence: A Modern Approach	Kattava katsaus tekoälysovellusten toimintaan ja historiaan.	Kirja
Sezer et al. 2020	Financial time series forecasting with deep learning: A systematic literature review: 2005–2019	Systemaattinen kirjallisuuskatsaus aikajaksotteisen datan ennustamiseen käytettävistä syväoppimismalleista	Vertaisarvioitu artikkeli