Examensarbete

HÖGSKOLAN I SKÖVDE

Algoritmisk aktiehandel

Ett experiment i att förutsäga aktiemarknaden med hjälp av neurala nätverk

Algorithmic stocktrading

An experiment in predicting the stockmarket using neural networks

Examensarbete inom huvudområdet informationsteknologi
Grundnivå nivå 30 Högskolepoäng
VT - 2019

Student: Henrik Mellgren

Handledare: Christian Lennerholt
Examinator: Mikael Berndtsson

Sammanfattning

Ursprungligen fungerade aktier som ett medel för företag att säkerställa finansiering för nya satsningar och investeringar. Företag ställde ut aktiebrev som investerare köpte och till skillnad mot ett vanligt banklån behövde inte företagen betala tillbaka dessa aktier. Detta säkerställde att de investerar som köpte aktier var tvungna att vara långsiktiga för ett aktieköp kunde vara för livet.

Aktiemarknaden är en marknad där dessa aktier kan handlas mellan investerare. Fördelen med detta är att en investerare kan avbryta sin investering och växla in den i förtid. Nackdelen med aktiemarknaden är att detta innebar att det långsiktiga perspektivet inte längre var nödvändigt för en investerare. För många investerare blev det viktigare hur aktiemarknaden kommer utvecklas ”imorgon” snarare än om företaget hen investerare i gör en lönsam investering på tio års sikt. Koppling till företagens egentliga värde riskerar därmed brytas. Konsekvens av detta är att spekulativa bubblar byggs upp på aktiemarknaden i cykler med efterföljande krascher som medför stora förmögenhetsförluster för vanliga privatpersoner och stora omvälvningar i samhället i stort.

Denna uppsats utforskar möjligheten att använda maskininlärning som ett verktyg för att kunna värdera aktier och förutspå kommande kursrörelser med syfte att hjälp investerare på aktiemarknaden att fatta bättre investeringsbeslut. Den tar avstamp i de datakällor som aktiemarknadsanalytiker använder för att studera denna marknad – det vill säga med hjälp av tekniska och fundamentala data. Ett system har konstruerats för att dels klassificera bolag med hjälp av algoritmen ”artificiella neurala nätverk” och fundamentala data och dels för att förutsäga kommande dagskurser med hjälp av algoritmen ”Long Short Term Memory network” och tekniska data. Algoritmerna har utvärderats var för sig och som ett gemensamt system genom att simulerad handel utförs på en given test och valideringsperiod. Den hypotes som prövats är att ”att processa fundamentala data genom ett ANN och tekniska data genom ett LSTM kommer genera bra investeringsrekommendationer”. Resultaten som studien genererat har givet som konsekvens att denna hypotes inte har kunnat motbevisas.

.

Förord

Utöver Högskolan i Skövde finns det ett antal aktörer som bidragit och möjliggjort denna studie. Följande förtjänar ett extra stort tack och dessa är:

- Christian Lennerholt, som agerat som handledare och bidragit med råd och tips gällande utformning av studien
- Henrik Ahlgren, som har varit ett fantastiska bollplank med tankar och idéer under resans gång med denna uppsats.

Innehåll

1 INLEDNING 1

2 BAKGRUND 2

2.1 Fundamental analys 2

2.2 Teknisk analys 3

2.3 Algoritmisk aktiehandel 4

2.3.1 Beslutsstödsystem 5

2.4 Maskinlärning 6

2.5 ANN – Artificiell Neural Network 8

2.5.1 RNN – Recurrent Neural Network 9

2.5.2 LSTM – Long Short Term Memory neural network 10

2.6 Tidigare forskning 11

3 PROBLEMOMRÅDE 13

3.1 Problem/fråga 13

3.2 Motivering 14

3.3 Avgränsningar 14

3.4 Delmål 15

3.5 Förväntat resultat 15

4 METOD 16

4.1 Forskningsmetodik – kvantitativ och deduktiv 16

4.2 Metodteknik - experimentell 16

4.3 Validitet / reliabilitet 18

4.4 Implementering 18

4.4.1 Datainsamling 19

4.4.2 Implementering av algoritmer 19

5 RESULTAT 23

5.1 Resultat – artificiellt neuralt network 23

5.2 Resultat – Long Short Term Memory network 26

5.3 Resultat – systemlösning 31

6 ANALYS / SLUTSATSER 34

6.1 Analys implementation ANN 35

6.2 Analys implementation LSTM 36

6.3 Analys – systemlösning 37

7 DISKUSSION 39

7.1 Vetenskapliga aspekter 39

7.2 Etiska aspekter 41

8 REFERENSER: 43

1 Inledning

Alkemi är en pseudovetenskap och en form av tidig vetenskap varifrån den moderna vetenskapliga kemin växte fram. Den gångna tidens alkemister sökte efter att försöka framställa guld och för att lyckas med detta sökte de efter ett urämne varifrån alla andra ämnen var skapade – det fulländande ämnet. Denna uppsats ämnar inte vila inte på alkemistens tveksamma grunder, men en parallell finns för där medeltidens alkemister en gång sökte efter ett ”fulländat ämne” för att blanda med andra ämnen med syfte att skapa guld ämnar denna uppsats söka efter en algoritm som kan blandas med information för att skapa värdefulla insikter för investerare på aktiemarknaden.

Aktiemarknaden är en marknadsplats där andelar i bolag handlas. Den drivande kraften bakom denna marknadsplats liksom många andra är viljan att göra vinst. Både för företagen som handlas samt de som investerar i dessa bolag. Generellt sett tenderar aktiemarknaden att röra sig uppåt över tiden, men det är viktigt, som investerare, att välja rätt bolag för det finns både vinnare och förlorare över tiden trots denna generella uppåtgående trend.

Aktiehandel som koncept har funnits under en väldigt lång tidsperiod till exempel började de första aktierna handlas i Stockholm någon gång kring 1760-talet. Vid denna tidpunkten fanns det bara ett ytterst fåtal aktier att handla med och det går ganska enkelt att föreställa sig att en investerare vid denna tidpunkten kunde samla på sig, analysera och fatta goda rationella investeringsbeslut rörande de aktier som var listade. Dagens investerare står inför en mycket svårare utmaning. Några exempel på detta är som Azrak (2018) beskriver att det finns ca 45 740 företag att handla i runt om i världen på en bit över 50 olika börser. Schults (2018) skriver även att det generas ca 2.5 quintilloner bytes med data dagligen på internet. Nath (2018) förklarar även att på bara New York börsen i USA fångas det ca 1 terabyte med information dagligdags. Den norska oljefonden brukar räknas som världens största statsfond med ett förvaltat kapital om ca 3 500 miljarder svenska kronor och fondchefen för denna fond Yngve Slyngstad beskriver i en artikel i dagens industri att kraven på en investerares kompetenser har förändrats genom åren och att det i dagsläget är ett krav att kunna skära sig genom och urskilja det väsentliga i en informationsmängd som växer exponentiellt snabbare för varje år (Bolter 2019).

Mängden information som en investerare har att tillgå idag är alltså väldigt stor och det har nästan blivit omöjligt att enkelt skaffa sig en bra överblick och fatta rationella investeringsbeslut utan olika former av stöd. Det gäller speciellt för de många enskilda och privata investerare som handlar på börsen. Den här uppsatsen ämnar undersöka om användning av algoritmiska aktiehandel med hjälp av artificiella neurala nätverk kan vara en tillämpbar strategi för att hjälpa privata investerarare, men även större aktörer, att urskilja det väsentliga i denna stora tillgängliga informationsmängd.

2 Bakgrund

I detta kapitel kommer en genomgång av de koncept som används i denna rapport att göras. I figur 1 nedan visas en schematisk bild över hur de olika koncepten relaterar till varandra och avsnittsindelningen följer dessa relationer.

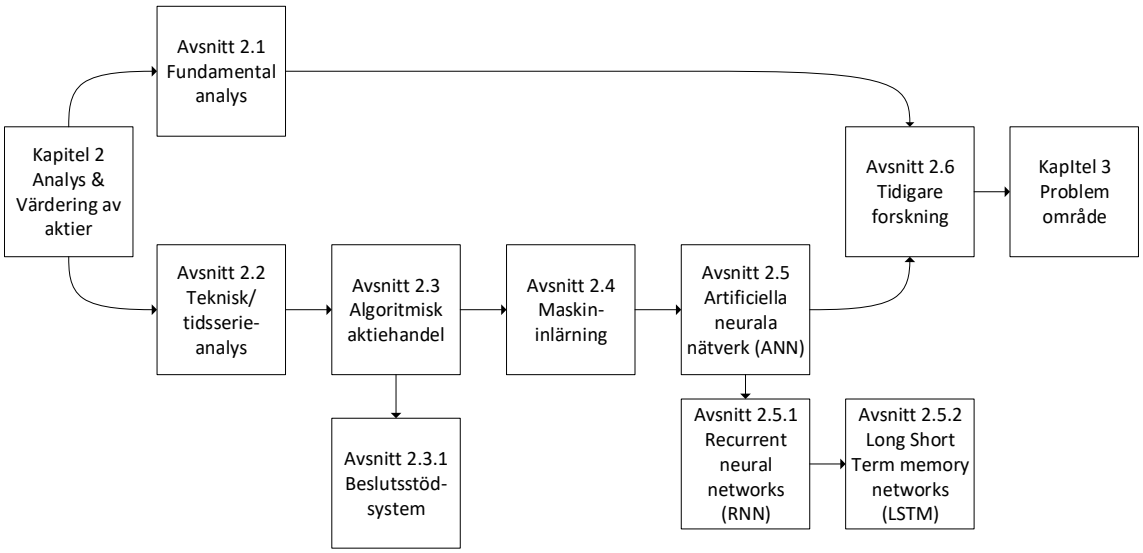

Figur 1. översikt koncept

2.1 Fundamental analys

Det finns två generella skolor för att analysera om ett företags aktie är felaktigt prissatt och därmed eventuellt intressant ur ett investeringsperspektiv, fundamental analys respektive teknisk analys (Nilsson, Isaksson & Martikainen 2002). Den ena typen av analys behöver inte utesluta den andra då den fundamentala analysen ofta används för att hitta intressanta bolag på lång sikt och den tekniska för att hitta optimala tidpunkter att investera i aktien. I stora drag innebär fundamental analys att ett bolag eller en aktie värderas på basis av informationen om företaget och dess framtidsutsikter (Nilsson et al. 2002). Bodie, Kane och Marcus (2011) beskriver även fundamental analys som långsiktig då investerare baserat på dessa analyser skaffar sig en position i en aktie, som hen i framtiden bedömer kommer värderas upp, efter att andra marknadsaktörer ändra sin uppfattning om bolaget. Huang, Huan, Xu, Zheng & Zou (2019) beskriver även på liknande spår att fundamental analys är fokuserad på att hitta det ”sanna” värdet för ett bolag och för att göra det undersöker analytikern tidigare prestationer och framtida förväntningar på ett specifikt bolag med hänsyn tagen till det politiska och ekonomiska klimatet. Ett sätt att göra denna typen av analys på är att beräkna ett företags nyckeltal för att dels se en historisk utveckling över tid dels se hur väl de står sig mot liknande företag i samma bransch. Begreppet nyckeltal kan förklaras vara ett värde som ger koncentrerad och förenklad information om ett mer komplext förhållande och ger en uppfattning om hur utvalda variabler förhåller sig till varandra. Ett vanligt nyckeltal som brukar nämnas är till exempel P/E-talet.

$$\frac{P}{E} = \frac{Marknadsvärde\ per\ aktie}{Vinst\ per\ akie}$$

P/E-talet ses ofta som en enkel indikation på om ett företag är högt eller lågt värderat i och med att det berättar hur mycket en investerare är beredd att betala för ett specifikt företags vinst. Det finns många liknande tal som kan beräknas, baserat på ett företags räkenskaper.

Ett sätt att hitta aktier som är undervärderade är till exempel att börja med att räkna ut olika nyckeltal för alla företag i en viss bransch och utifrån detta sedan beräkna medelvärdet för samtliga av dessa företags nyckeltal. Hittar analytikern ett företag som till exempel då har väsentligt lägre P/E-tal än medelvärdet i en specifik bransch med jämförbara konkurrenter, och diskrepansen inte kan förklaras med hjälp av andra företagsspecifika faktorer, då kan företags anses vara undervärderat (Damodaran 1996). Ofta i denna typen av analyser är det inte bara ett enskilt nyckeltal som används utan ett flertal olika nyckeltal som ger en kompletterande bild till varandra rörande företaget. Ofta anses en analytiker följa en form av strategi när hen väljer ett paket av nyckeltal för att analysera ett företag. Det finns ett antal vedertagna strategier som specificerar vilka nyckeltal som bör ingå i denna typen av analyser.

En vedertagen strategi är till exempel F-score av Piotroski (2002). I denna artikeln beskrivs ett antal nyckeltal, se bilaga 1, som om de i kombination används för att analysera ett företags räkenskaper kan förväntas ge en överavkastning gentemot konkurrerande strategier iallafall för utvärderingsperioden 1976 – 1996. Strategin går ut på att vaska fram, från en lista med aktier, de aktier som är intressant att köpa utifrån en poängsammanräkning där aktierna får poäng om de olika nyckeltal i strategin uppfyller vissa nivåer. Strategin innehåller nio nyckeltal som ämnar indikera om företaget har ett högt bokfört värde i sina räkenskaper kontra marknadsvärdering på bolaget. Ett annat exempel på en strategi är ”the magic formula” som beskrivs av Greenblatt (2010) där två enkla nyckeltal används, se bilaga 1, för att välja ut intressant aktier.

2.2 Teknisk analys

Teknisk analys tar hänsyn till statistik och hur den historiska utvecklingen av börskursen har sett ut (Nilsson et al. 2002). Denna typ av analys brukar ses som mer kortsiktig då investerare försöker fånga en trend eller ett så kallat momentum, som skapar ett handelsmönster i en specifik aktie, och använda detta för att skapa vinst. Huan et al. (2019) beskriver att tekniska analys inte är fokuserade på fundamental information utan koncentrerar sig enbart på att försöka exploatera historiska data rörande aktien i form av pris och i vilka volymer aktien har köpts och sålts. Den tekniska analysen förutsätter att historiken kommer upprepa sig självt och skapar genom regler, diagram och liknande instrument handelsregler för köp och säljordrar. Essensen är att användaren av teknisk analys försöker göra en prognos över det framtida värdet på en aktie baserat på de historiska värdena. I stora drag vilar all prognosverksamhet på det fundamentala antagandet att historien upprepar sig det vill säga ett antagande om att observerade

regelbundenheter består i framtiden (Andersson, Jorner & Ågren 2007). Teknisk analys kan därmed sägas vara en form av tidsserieanalys/ prognosverksamhet.

En tidsserie är en serie observationer gjorda vid olika tidpunkter och i regel ligger dessa tidpunkter på lika stora avstånd från varandra, till exempel en dag eller en vecka. Syftet med tidsserieanalys är att försöka bestämma ett framtida förlopp baserat på historisk utveckling (Andersson et al., 2007). Analysen fyller alltså en form av behov att göra en prognos in i framtiden. En stor fördel med tidsserieanalys i två dimensioner är att dessa serien kan knytas ihop med andra serier då dessa delar en gemensam nämnare på den ena axeln – tid. En datapunkt i en tidsserie består av fyra komponenter och brukar skrivas:

$$Y = T + C + S + E$$

Y = Observation

T = Trend

C = Cykel

S = Säsong

E = slumpmässig komponent

En trend är den långsiktiga utvecklingen av det som plottas (Andersson et al. 2007). En säsong är en återkommande regelbundenhet inom ett specifikt tidsintervall i datamaterialet (Andersson et al. 2007). Ibland talas det även om cykler som är väldigt långa återkommande säsongsmönster (Andersson et al. 2007). Ofta används denna term inom det ekonomiska området, till exempel en konjunkturcykel som rör sig över flera år. Till slut finns det även en slumpmässig komponent och denna komponent är mindre naturliga förekommande oregelbundenheter (Andersson et al. 2007).

Det finns två typer av skolor inom tidsserieanalys och dessa benämns kvalitativa och kvantitativa (Andersson et al. 2007). Denna uppsats kommer fokusera på den kvantitativa delen av tidsserieanalys då teknisk analys kan sägas falla inom den grenen av tidsserieanalys då teknisk analys använder många tekniker för att kunna utröna trender och momentum i aktiehandel som till exempel glidande medelvärden. De tekniker som används i experimentet återfinns beskrivna i bilaga 2.

2.3 Algoritmisk aktiehandel

En form av teknisk analys utförs av mänskliga analytiker som bland annat applicerar de olika måtten som beskrivits i bilaga 2 och därigenom försöker utröna bra tillfällen att köpa och sälja aktier för att genera vinst. En annan form av teknisk analys är genom algoritmisk aktiehandel. Huan et al. (2019) beskriver att de flesta former av automatiserad eller algoritmisk handel med aktier tar sin utgångspunkt från teknisk analys. Det vill säga från historiska handelsmönster i aktien förväntas upprepas i

framtiden och baserat på detta skapas regler för köp och säljsignaler i den specifika aktien som sedan det automatiserad systemet följer.

På Computer Swedens (2018) hemsida finns det i deras resurs *IT-ord: Ord och uttryck i IT branschen* en definition rörande algoritmisk aktiehandel och denna beskriver sammanfattningsvis att begreppet handlar om att utnyttja sig av aktiehandel styrd av kraftfulla datorprogram eller algoritmer. Algoritmerna är konstruerade för att utnyttja små förändringar i aktiekurser och baserat på dessa köper och säljer maskinerna aktier snabbare än en människa klarar av. Denna typen av handel har pågått sedan 1990-talet och har utvecklats i takt med att datorerna blir mer och mer kraftfulla och verktygen och algoritmer mer finstämda. Huan et al. (2019) beskriver även algoritmisk aktiehandel som att i stora drag vara en form av ett realtids beslutsstödsystem där datorprogrammet, med hjälp av olika förprogrammerade regler, köper och säljer aktier ofta baserat på olika former av historiska handelsmönster i aktien.

2.3.1 Beslutsstödsystem

Algoritmisk aktiehandel kan därmed ses vara en form av beslutsstödsystem eller ”decision support system” (fortsatt benämnt DSS). Sharda, Delen & Turban (2014) beskriver att ett sådant system syftar till att stödja beslutsfattare i olika former av strukturerade och semi-strukturerade situationer samt att de ofta är utvecklade för en typ av problem. De beskrivs även vidare att det finns olika sorter av sådana system för olika typer av problem och nämner följande uppräkning:

- Communication driven and group
- Data driven
- Knowledge driven
- Model driven
- Compund driven

Denna uppsats ämnar fokusera kring konceptet ”model driven” beslutsstödsystem. Denna typen av system är ofta utveckla med målsättningen att optimera en eller flera mål och byggs ofta upp av någon form av statistisk modellering över verkliga förhållanden (Sharda et al. 2014). En visualisering av hur ett sådant system och hur dess komponenter kan byggas upp kan ses i figur 2 nedan. Som kan förstås från föregående stycken ligger mycket av fokuset inom forskningsområdet algoritmiska aktiehandel på att skapa så kallade ”Models”, som kan ligga till grund för goda beslutsrekommendationer alternativt helt automatiserade system som handlar autonomt från en beslutsfattare.

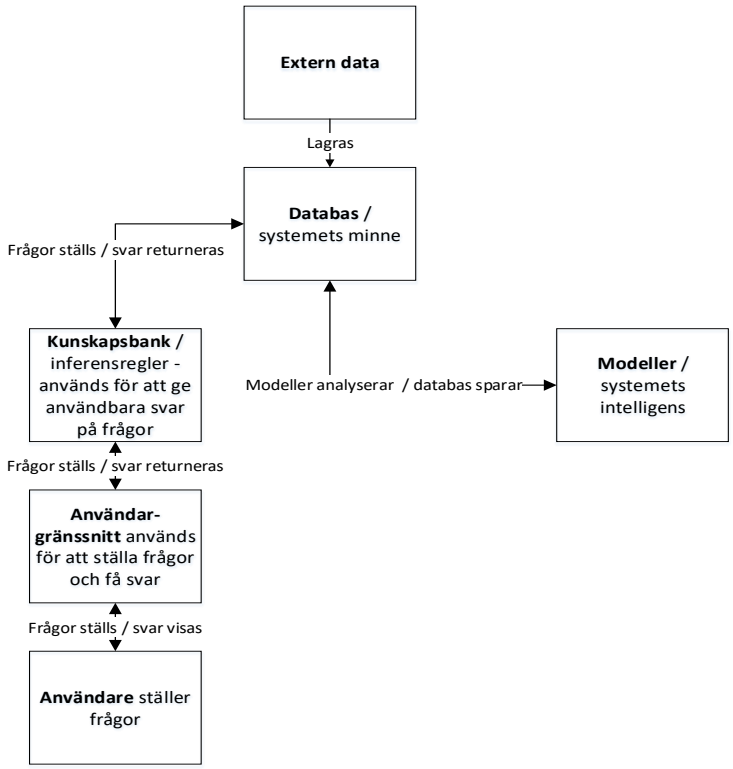

Figur 2. visualisering av ett "model driven" beslutsstödsystem, inspirerad av Sharda et al. (2014)

2.4 Maskinlärning

En tidig definition av detta begrepp gavs av Mitchell (1997) då han beskrev att ett datorprogram kan sägas lära sig med erfarenhet "E" att utföra uppgifterna "U" med respekt till prestandamåttet "M" om det förhåller sig så att dess prestanda "M" blir bättre på uppgifterna "U" allteftersom erfarenheten "E" ökar. Essensen i denna beskrivning av maskinlärning är att begreppet handlar om att få datorprogram att lära sig bli bättre på uppgifter på ett liknande sätt som oss människor – genom träning. Det finns ett antal olika algoritmer för att skapa dataprogram som använder sig av maskininlärning och ofta delas dessa in i några olika kategorier. Ett försök att nämna tre grova kategorier kan utmynna i övervakad (supervised) inlärning, oövervakad (unsupervised) inlärning samt även förstärkt (reinforced) inlärning.

Vid oövervakad träning finns det inga korrekta svar som ges till algoritmen vid inlärningen och de är ofta av typen klustring. En kort beskrivning av klustring är att det handlar om att hitta kluster av datapunkter som har saker och ting gemensamt med varandra till skillnad från datapunkter i andra kluster. Denna typ av algoritmer används ofta när användaren vill hitta okända, men användbara klasser av saker till exempel genom "datamining".

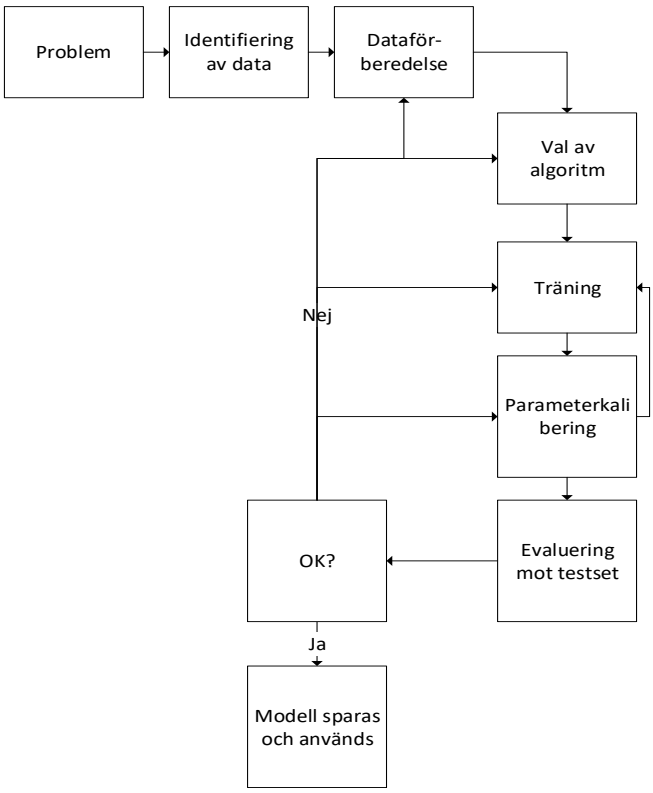

Figur 3. process övervakad inlärning

Att använda sig av övervakad inlärning till skillnad från föregående tillvägagångssätt är att använda sig av algoritmer designade för att resonera och lära sig med utgångspunkt från att ett korrekt svar ges till den vid inlärningen (Kotsiantis 2007). Fokuset i denna uppsats kommer ligga kring denna typ av inlärning och i figur 3 ovan kan en schematisk skiss över den process som tillämpats ses. Valet av algoritm är viktigt vid maskinlärning och detta valet beror mycket på det problem som användaren försöker lösa. Fokuset i denna uppsats ligger på problem som rör tidsserier och aktiehandel och i avsnitt 2.6 nedan kommer en genomgång att göras kring vilka algoritmer som ofta används för denna typen av problem.

En annan typ av inlärning som nämnts ovan är förstärkt inlärning (Barto & Sutton 1997). I detta fallet så presenteras algoritmen med ett antal alternativ och provar sig igenom dessa alternativ ett efter ett och återkoppling till dessa val är genom en skalande signal som berättar hur väsentligt felet är när algoritmen väljer olika alternativ. Det finns inget som berättar exakt vilket alternativ algoritmen ska ta utan de måste algoritmen resonera sig fram till utifrån den återkopplande skalande signalen. Förstärkt inlärning kan ses ligga i gränslandet mellan övervakad och oövervakad inlärning och lånar koncept från båda fälten.

2.5 ANN – Artificiell Neural Network

En beskrivning av ANN är att det är en form av statiska modeller där de matematiska strukturerna ämnar avbilda den biologiska organisationen i den mänskliga hjärnan ur aspekten inlärning (Bertolaccini, Solli, Pardolesi & Pasini 2017). Det kan alltså hävdas att ett neuralt nätverk kan sägas vara en form av datoriserat system som är inspirerat av hur biologiska varelsers hjärnor fungerar. Precis som sin förebild lär sig denna typ av system att bli bättre på en specifik uppgift genom att träna sig på insamlade data. Detta ofta med syftet att förutspå den effekt en eller fler oberoende variabler har på en beroende variabel. En styrka som framhävs med ANN kontra andra algoritmer, till exempel enkel linjär regression, är att den har kapaciteten att lära sig komplexa och icke linjära samband mellan oberoende och beroende variabler.

Konkret sett innebär det att ett neuralt nätverk är uppbyggt av en samling noder eller artificiella neuroner och mellan dessa finns det kopplingar eller synapser precis om i den mänskliga hjärnan. Synapserna skickar signaler till neuronerna och dessa neuroner bearbetar dessa signaler på olika sätt och skickar signaler vidare med hjälp av synapser till andra neuroner och schematiskt kan detta åskådliggöras i figur 6 nedan. I figuren kan det ses att ett neuralt nätverk är uppbyggt av tre olika lager av neuroner samman-bundna med kopplingar/synapser. Input lagret längst till vänster i figuren är en typ av neuroner som tar emot information externt utifrån systemet. Den neuron längst till höger i bilden som är benämnda outputnod är den neuron som förmedlar nätverkets prediktion. I denna bild finns det bara en outputneuron, men det behöver inte alltid vara så utan det beror på vilket typ av problem nätverket är tänkt att lösa. Mellan inputlagret och outputlagret finns det i figuren nedan ett gömt lager och det är i detta gömda lager som beräkningarna sker som översätter den data som ges till nätverk till någon form av output. I en praktisk applikation av ett nätverk behöver det inte vara begränsat till ett lager utan det varierar från implementation till implementation beroende på den typ av modell som utvecklas.

I figur 4 symboliserar X1, X2 och X3 oberoende variabler. Dessa variabler läses in i nätverket genom de tre noderna längst till vänster i figuren. Dessa inputnoder kopplas ihop med det gömda lagret via synapser och varje synaps har en vikt. Mening med dessa vikter är att förstärka eller förminska signifikansen av de olika inputvärden på resultatet och det är dessa vikter som nätverket justerar i en inlärningsprocess. När ett värde skickas via en synaps transformeras de till att vara i intervallet 0 – 1 med hjälp av en aktiveringsfunktion. I det gömda lagret summeras sedan varje enskilt inputvärde med sin specifika vikt.

$$viktad\ summa = X1 * W1 + X2 * W2 + X3 * W3 + X_i * W_i$$

Denna summa passeras sedan in i en aktiveringsfunktion som avgör vad som skickas vidare till outputlagret längst till höger i bilden och från detta lager generas sedan ett resultat från nätverket. Aktiveringsfunktionen har en stor vikt på prestandan av nätverket då varje nod i det gömda lagret använder sig av denna funktion för att transformera alla de viktade summeringarna till att fortsatt vara i intervallet 0–1. Hur denna transformering

går till påverkar slutresultatet väsentligt och beroende på vilket problem ett nätverk är tänkt att lösa finns det olika funktioner som fungerar olika bra.

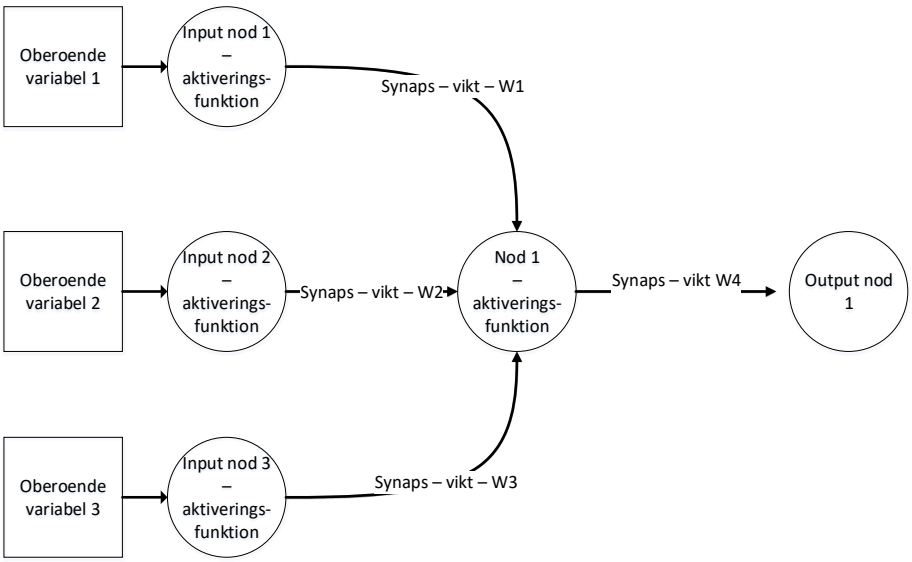

Figur 4. Beskrivning, ANN

Inlärningsprocessen är en av form övervakad träning och i en praktisk tillämpning så utförs inlärning på det sättet att nätverket introduceras för ett flertal set av inputdata och får utföra gissningar baserat på denna data som sedan jämförs med korrekta värden. Det vill säga det som kommer ut från outputlagret jämförs med faktiska värden och felet däremellan matas tillbaka till nätverket och det är utifrån detta mått nätverket sedan justerar vikterna på de synapser som sammanbinder noderna. Detta i sin tur påverkar påföljande gissningar med målet att minimera felet mellan gissningar och sanna värden.

2.5.1 RNN – Recurrent Neural Network

Zachary & Berkowitz (2015) beskriver att det finns en speciell typ av artificiella neurala nätverk som är benämnda ”Recurrent Neural Network” (nedan benämnt RNN). Dessa nätverk introducerar kopplingar mellan noderna över tid. När nätverk körs tar det därmed inte bara hänsyn till det värde som introduceras till det via inputnoden som visas i figur 4 ovan utan det tar också hänsyn till det värde noden hade i en tidigare iteration. Denna förmågan gör att dessa nätverk är specifikt anpassad för att arbeta med så kallade tidsserieproblem (se avsnitt 2.2) då de blir bättre på att ta hänsyn till den temporala aspekten av datan – trender, säsonger, cykler samt slumpmässiga komponenter.

I figur 5 nedan kan en enkel visualisering åskådliggöras för ett RNN. I figuren tränas nätverket över två tidssteg, men i princip kommer inlärning ske över många flera steg. Det som har tillkommit från ett vanligt ANN är alltså de streckade pilarna som binder samman noderna i det gömda lagret över samtliga inlärningssteg. Det är dessa kopplingar som ger ett RNN dess kapacitet att jobba med tidsserieproblem.

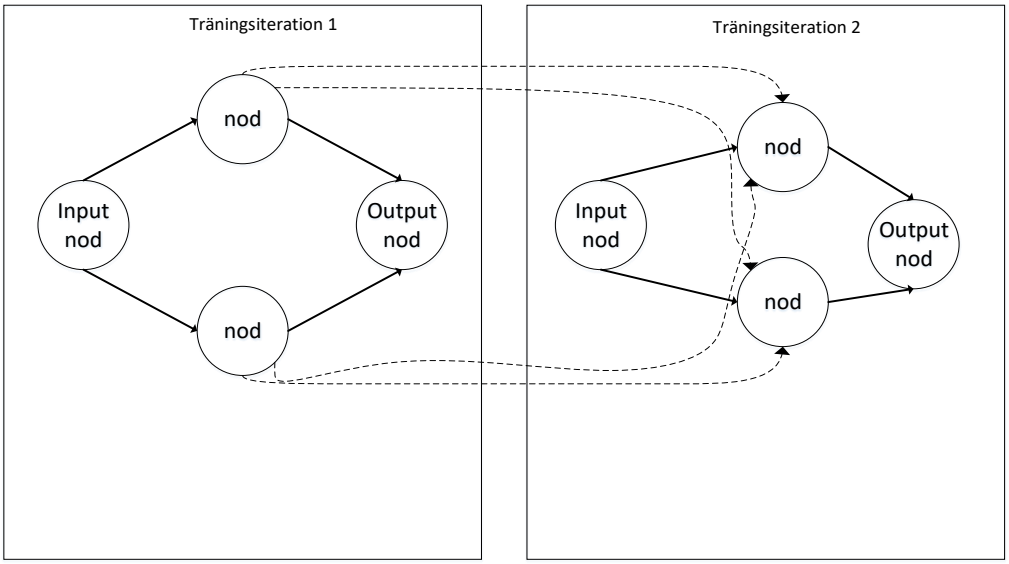

Figur 5. beskrivning, RNN

Zachary & Berkowitz (2015) beskriver att det finns ett problem med att träna denna typen av nätverk och detta problem benämns försvinnande eller exploderade gradient. Denna rapport ämnar inte i detalj gå in och förklara detta problem. En enkel förklaring kan dock göras från figur 5 ovan. I en inlärningsprocess i det första tidsteget ovan så kommer det i det gömda lagret beräknas ett värde som går igenom en aktiveringsfunktion. Detta värde skickas vidare då till dels outputlagret och över tiden framåt till kommande gömda lager och precis som i ett ANN så styr en vikt hur mycket som skickas vidare framåt i tiden i nätverket. Det är här då problemet kommer då denna vikt antingen kommer närma sig noll, om vikten är under 1, alt explodera, om vikten är över 1, när nätverket körs över väldigt många tidssteg. Detta resulterar i att nätverket blir svårare och mer komplicerat att träna upp och anseddes under lång tid vara ett stort problem tills Hochreiter & Schmidhuber (1997) introducerade LSTM –" Long Short Term Memory neural network" – mer om detta i kommande avsnitt.

2.5.2 LSTM – Long Short Term Memory neural network

De mest vedertagna arkitekturerna för ett nätverk av typen RNN introducerades i två vetenskapliga artiklar enligt Zachary & Berkowitz (2015). Dessa två artiklar är *Long Short-Term Memory* av Hochreiter & Schmidhuber (1997), som introducerar konceptet memory-cell som ersättning till noder/neuroner i det neurala nätverket, samt *Bi-directional Recurrent Neural Network,* som introducerar konceptet med att använda information både från senare steg i inlärningen samt tidigare, för att avgöra output i den nuvarande tidssteget, av Schuster och Paliwal (1997). Det senare alltså i kontrast till tidigare former av RNN som kan ses i figur 5 ovan bara tar hänsyn till tidigare tidssteg vid inlärningen

Som beskrivits i avsnitt 2.4 har en nod i det gömda lagret som arbetsuppgift att den tar emot värden via synapser från andra noder och summerar. Denna summering passeras in

en aktiveringsfunktion som skickar en output vidare. Som nämnts tidigare avsnitt introducerade Hochreiter & Schmidhuber (1997) konceptet ”memory cell” som ersättning till noder. Anledningen till detta är noder som konceptet inte fungerar fullt ut i samband med upplärning av RNN och detta problem beskrevs närmare i avsnitt kring RNN. En ”memory cell” är mer komplicerad än en nod då den göra ett flertal olika arbetssysslor i nätverket.

Denna uppsats ämnar inte i detalj fokusera på vad som sker inuti i en sådan cell. På en hög och konceptuell nivå bör det dock nämnas att vad konceptet introducerar är vissa nya egenskaper hos noderna. Dels tilldelas en cell ett ”internal state” som är själva hjärtat i cellen och är det som är kopplat över tiden med andra celler – detta motsvarar det summerade värdet en nod haft i tidigare beskrivningar. Till skillnad från ett RNN så är kopplingarna över tiden med den fixa vikten 1, vilket löser det inlärningsproblem som nämndes under avsnittet ovan med noder kopplade över tid. Utöver det så tillkommer också ett antal portar i cellen som styr över dels vilka värden som passerar in i cellens ”internal state” och dels vad som lämnar cellen och skickas vidare. I många senare implementationer har det även tillkommit en port som benämns ”forget gate” i litteraturen. Denna port kan lära sig förstå när cellen bör återställas till ”default”, vilket är väldigt användbart i ett nätverk som är designat för att köra kontinuerligt utan stopp. Detta koncept introducerades av Felix, Schmidhuber & Cummins (1999). I figur 6 nedan åskådliggjorts denna arkitektur och som kan ses är arkitekturen och kopplingarna över tid väsentligt mer komplexa än i tidigare lösningar med enbart noder.

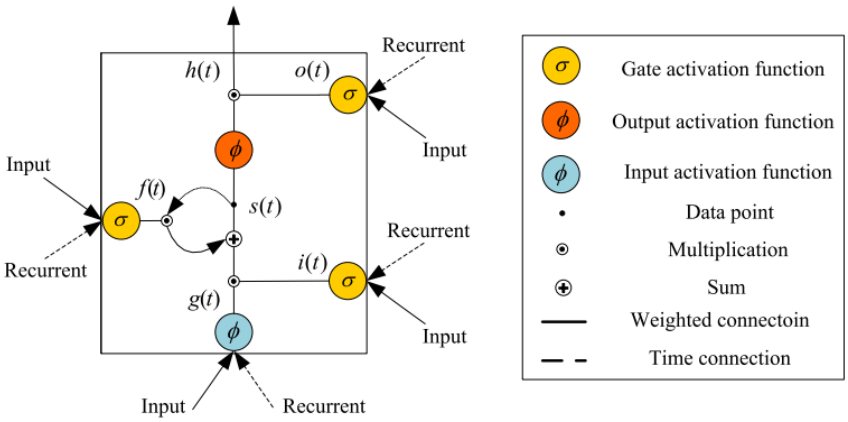

Figur 6. visualisering LSTM memory cell, Guo & Jia & Li and Lei (2017)

2.6 Tidigare forskning

Som beskrivits i avsnitt 2.4 är så kallade RNN och LSTM en form av nätverk som är specifikt anpassade till att jobba med tidsserieproblem. Detta gör att denna typen av nätverk är lämpliga att använda i samband med algoritmiska aktiehandel då detta problem handlar om att förutse kommande värden på aktier baserat på en tidsserie av historiska data. I detta avsnitt kommer några olika projekt sammanfattas med utgångspunkt att de använder sig av olika former av neurala nätverk för att prognostisera rörelser på aktiemarknaden.

Heaton, Polson & Witte (2016) beskriver utmaningen att göra finansiella förutsägelser som ett område med stort praktiskt och teoretiskt intresse. Informationen finns tillgängliga för att göra dessa förutsägelser, men den är sprid över flera datakällor och olika marknadsaktörer tittar på olika datakällor för att bilda sig sin uppfattning om framtiden. Ett ytterligare problem är att den uppsättning av data som innehåller informationen är av icke-linjära och komplexa natur. Dessa olika komplexa icke-linjära sammanband är i dagens ekonomiska teori dåligt förstått, vilket har resulterat i en stor uppsättning av olika prediktiva modeller med dålig teoretisk förankring och icke tillfredsställande prognoser för de marknadsaktörer som ska använda dem. Heaton et al. (2016) drar slutsatsen att en ny metod behövs för att kunna lära sig alla dessa datakällor och de komplexa sambanden som finns mellan dem med syfte att ge goda prediktioner för tillgångars framtida värde. Heaton et al. (2016) bedömer att med stor sannolikhet artificiella neuralt nätverk kan vara den metoden som kan använda för detta syfte och att algoritmen kommer utöva ett större och större inflytande inom finansiell ekonomi och då specifikt när det kommer till att göra prognoser.

Kelly, Gu & Xiu (2018) beskriver i sin artikel ”Empirical Asset Pricing via Machine Learning” hur de genomfört en jämförande analys av ett flertal metoder inom maskininlärning för att värdera aktier med syfte att hitta bra investeringar. I breda termer drar de slutsatsen att maskininlärning har potential att förbättra de prognosmetoderna som finns i dagsläget på finansiella marknader för att förutsäga framtida avkastning på investeringar. De finner även att den bästa metoden/algoritmen för att göra detta är användning av ANN. Anledningen till detta menar de på är att dessa metoder har en förmåga att fånga upp komplexa icke linjära samband som inte andra metoder har.

Chen, Qiao, Minggang, Wang, Du & Stanley (2018) beskriver i sin artikel att oförutsägbara faktorer som påverkar aktiemarknaden gör det svårt att förutsäga utvecklingen för ett aktieindex. Vidare trots svårigheten i problemet att det finns en lång historik med att försöka utveckla olika former av prognosmodeller med detta syfte. En form av genombrott har skett de senaste åren med användning av AI och specifikt ANN för att identifiera komplexa icke-linjära samband. I sin artikel beskriver de hur de använt sig av högfrekvens data och tre olika former av ANN för att försöka förutsäga hur aktieindex kommer utvecklas i framtiden. Med högfrekvens data menas att de använt sig av alla de transaktioner som genomförs över börsen dagligdags och minut för minut för att försöka förutsäga framtida indexrörelser. Chen et al. (2018) drar ett flertal slutsatser varav en är att tesen stärks att ANN är en effektiv metod för att prognostisera indexrörelser samt generellt analysera finansiella marknaders rörelser.

Patel, Shah, Thakkar & Kotecha (2014) utför i sin artikel ett experiment då de tar ett flertal s k tekniska indikatorer (nyckeltal) och efter en typ av transformering använder dessa som träningsunderlag i ett antal olika algoritmer däribland en implementation av ett ANN. Slutsatserna i deras rapport utmynnar i att det finns stor potential i upplägget med att använda tekniska indikatorer som träningsmaterial för bland annat ett ANN.

3 Problemområde

En väsentlig anledning till att algoritmisk aktiehandel är ett viktigt forskningsområde är för att metoder, som mer tillförlitligt kunde prissätta aktier, skulle kunna ha potential att minska eller förhindra kommande börskrascher såsom ”it-bubbla” kring sekelskiftet samt ”Lehman brother” år 2008. Dessa börskrascher var förenad med stora omvälvningar och efterdyningarna av dessa krascher sätter avtryck i våra samhällen fortsatt. Effekterna av dessa krascher förstärktes av spekulationer på aktiemarknaden baserad på felaktiga värderingsmodeller.

I avsnittet 2.6 ovan har ett axplock av all den forskning som gjorts på området algoritmisk handel de senaste åren, med fokus på användning av artificiella neurala nätverk, sammanfattats. Ett generellt tema för samtliga dessa artiklar är att utgångspunkten för vilken data algoritmerna ska använda är olika former av tekniska indikatorer alternativt rå transaktionsdata. En slutsats av det ovanstående är att en förhärskande ansats inom algoritmiska aktiehandel är att samtliga aktier egentligen är rätt värderade utifrån en fundamental utgångspunkt. Det vill säga all information om bolaget finns tillgängligt för alla investerare och de har utifrån denna information prissatt bolaget korrekt. Förlängs denna tanke så innebär det att algoritmerna egentligen används till att hitta köp och säljlägen i olika aktier baserat på kortsiktiga och tillfälliga störningar i värderingen grundat i transaktioner mellan olika aktörer på aktiemarknaden. Målsättningen för denna typen av nätverk är därmed ofta om de kan förutse marknaden på kort sikt, det vill säga en tidshorisont på upp till några dagar, vad aktiekursen kommer vara i framtiden.

Chen et al. (2018) beskriver dock i sin artikel att utöver transaktionsdata borde andra faktorer sannolikt skulle kunna stärka prognosförmågan hos ett ANN. Specifikt föreslås de olika makrofaktorer såsom till exempel politik, miljö, kultur, forskningsinvestering, BNP, företags nyckeltal och växelkurser med mera (fundamental analys).

Patel et al (2014) föreslår även i sin artikel att så kallade makrofaktorer (fundamental analys) borde ha potential att ytterligare höja träffsäkerheten i de prognoser som modellerna skapat i deras projekt. En poäng som dras av dessa författare rörande detta experiment, och även liknande projekt, är att fokuset när tekniska indikatorer används blir på att göra kortsiktiga prognoser. Det vill säga vad kommer utvecklingen för indexet var imorgon eller de närmaste dagarna. De föreslår att användning av komponenter inom fundamental analys borde utreddas närmare för att se om det går att göra längre former av prognoser. Specifikt föreslås användning av nyckeltal såsom bolagsvinster, aktieutdelningar, belåningsgrad i bolaget etcetera

3.1 Problem/fråga

Såsom beskrivets i föregående avsnitt tar algoritmisk aktiehandel ofta avstamp utifrån tekniska analys och de mått och indikatorer som använts inom detta området. Chen et al. (2018) samt Patel et al. (2014) föreslår dock i sin forskning att användning av fundamentala data tillsammans med algoritmen artificiella neurala nätverk borde kunna

stärka prognosförmågan hos denna typen av system. Denna uppsats ämnar därmed bygga vidare på deras forskningsresultat och tankar med frågeställningen:

> *Att utvärdera i vilken utsträckning ett system uppbyggt av ett ANN och ett LSTM, som kombinerar tekniska och fundamentala data, kan fungera som stöd åt en investerare?*

3.2 Motivering

Finansiella prognosproblem av typen värdering av aktier, som de denna uppsatsen fokuserar på, involverar ofta stora dataset med komplexa och icke-linjära interaktioner. Denna typen av problem är svåra till gränsen på omöjliga att lösa med dagens ekonomiska modeller. Algoritmen ANN har visat på potential att kunna leverera mer användbara resultat än många av de standardmetoder som finns inom finansiell ekonomi (Heaton et al. 2016; Patel et al. 2018; Chen et al. 2014; Kelly et al. 2018). Mer forskning behövs dock för att utveckla dessa metoder och modeller och det är utifrån denna utgångspunkten denna uppsats tar avstamp. Att skapa ett expertsystem eller DSS för att kunna göra bra prognoser kommer kräva ett system som emulerar det sätt en människan gör sina analyser på. Dvs det räcker inte bara med tekniska indikatorer utan den andra grenen av analys borde vävas in - fundamental analys.

3.3 Avgränsningar

Inom forskningsområdet finns det ett flertal olika algoritmer som det experimenteras med genom åren. Några exempel är beslutsträd, artificiella neurala nätverk och support vector machine med flera. Denna rapport ämnar fokusera på användning av ANN.

När det kommer till datamaterial så kommer rapporten fokusera uteslutande på svenska börsen och ett specifikt index av bolag på denna börs – OMX30. Ett index väger samman utvecklingen i flera olika aktier och kan därmed användas som ett jämförelsetal. Indexets utveckling mäts alltid i förhållande till en startdag som ofta har värdet 100 och indexet visar den procentuella utvecklingen sedan dess. När indexet står i 150 har det alltså stigit 50 procent sedan startdagen (Nasdaq Inc 2019). Indexet OMX30 är ett specifikt index som innehåller de 30 bolag på svenska börsen som är störst sett till marknadsvärdering och även handlas mest frekvent. Dessa bolag är även mest omskrivna och analyserade, vilket bedöms vara en fördel för studien. Två av bolagen i detta indexet har valts bort från att ingå i experimentet och det är SCA och Essity. Anledning till detta är Essity är en avknoppning från bolaget SCA och inte har någon längre historik på börsen. SCA tappade en väsentlig del av sitt marknadsvärde i samband med avknoppning i sin tur då priset per aktie sjönk från ca 300 kr till 65 kr. En tillkommande anledning är att denna händelsen inträffade sommaren 2018, vilket är mitt i den planerade test/valideringsperioden av experimentet. Det finns därmed ingen möjlighet att träna upp en modell för att hantera bolaget Essity med dess korta historik på börsen och det bedöms som en stor risk att resultaten skulle bli väsentlig mer svårtolkade genom att ta med bolaget SCA då

modellerna skulle tränats upp på data innan avknoppningen och förväntas göra prognoser på bolaget efter avknoppningen,

I avsnitt 2.2 diskuterades att det finns många olika tekniska indikatorer att ta till inom den tekniska analysen. Denna uppsats fokuserar på de indikatorer som återfinns i bilaga 2. I avsnitt 2.1 diskuterades det även att det finns ett batteri av nyckeltal att använda för att analysera bolag med hjälp av fundamental analys. Denna uppsats fokuserar på de nyckeltal som tas upp i bilaga 1.

3.4 Delmål

För att kunna besvara forskningsfrågan så har det för studien definierats ett antal delmål som behöver uppnås. Dessa är som följer:

- Samla in data som kommer behövs för experimentet.

- Implementera algoritmen ANN samt LSTM och träna upp dem med den definierade träningsdatan.

- Validera den konstruerade modellen med hjälp av valideringsdata samt evaluera den genom ”backtesting” för att se om den generar användbara resultat för en investerare.

3.5 Förväntat resultat

Chen et al. (2018) samt Patel et al. (2014) forskningsresultat antyder att ett sätt att stärka prognosförmåga hos ANN i samband med prognostisering av aktiekurser är att väva in fundamentala data. Denna studie ämnar utforska denna möjlighet genom ett experiment.

4 Metod

I de föregående kapitlen till denna uppsats har en kontext givets och ett problem som ämnas besvaras definierats. Berndtsson, Hansson, Olsson & Lundell (2008) beskriver att en bra arbetsgång efter att det har gjorts är att skifta fokuset till att fundera kring hur arbetet med att besvara frågan är tänkt att struktureras. Detta kommer beskrivas i kommande avsnitt i detta kapitel.

4.1 Forskningsmetodik – kvantitativ och deduktiv

Det finns initialt två generella metodansatser att välja mellan när arbetet ska struktureras för att systematiskt besvara en fråga. Den första av dessa är kvalitativ och den andra är kvantitativ och dessa båda ansatser har båda sina för/nackdelar (Patton 2014). I kvalitativ forskning ses forskaren som ett mätinstrument och inom denna ansats ligger fokuset på att få fram ”djup och rik” data från en mindre population och det är upp till forskaren hur denna data skall tolkas. Syftet med dessa typer av undersökningar är ofta att undersöka problemet på djupet och i detalj (Patton 2014). I kontrast till denna kvalitativa ansatsen använder sig en kvantitativ forskningsmetod ofta av statistiska metoder som mätinstrument och fokuset inom denna ansats ligger därmed ofta på större populationer, men med mer ytligt data om varje observation. Sechrest & Sidani (1995) förklarar att detta innebär att forskaren jobbar med statistik för att hitta kvantifierbara och generaliserbara resultat. Detta görs med hjälp av statistiska hypotesprövningar och det innebär också att man i höga grad använder sig av och studerar högt strukturerade data. Kvantitativa metoder möjliggör mätningar från ett större antal observationer, vilket i sin tur möjliggör statistiska analyser i syfte att generalisera slutsatser med statistisk signifikans (Patton 2014). Den inriktning som kommer användas i detta arbetet är en kvantitativ ansats. Det kommer inte genomföras några statistiska hypotesprövningar för att generalisera resultat. Resultaten kommer dock att förstärkas genom att de valideras i flera omgångar på data som inte ingår i konstruktionen av modellerna.

Ett viktigt förhållningssätt att reflektera över innan studien startar är om forskning är deduktiv alternativ induktiv. Bryman (2002) menar att en forskare som arbetar deduktivt utgår ifrån befintlig teori och väljer sedan att deducera fram en eller flera hypoteser, vilka ska undersökas med en empirisk undersökning. Den induktiva ansatsen innebär snarare ett omvänt arbetssätt då forskaren först studera empirin och efteråt sammanbinder denna och formulerar en teori (Bryman 2002; Patel 2003). Denna studie är deduktiv då den tar avstamp i befintlig forskning och därifrån formulerar en form av hypotes som avses utvärderas om den håller gentemot ett empiriskt material.

4.2 Metodteknik - experimentell

Då en forskningsmetodik har valts ut samt ett generellt angreppssätt bestämts är det motiverat att konkretisera vad detta innebär för den specifika studien. Berndtsson et al. (2008) beskriver att det finns sex tekniker för att samla in, tolka samt analysera data. Valet av teknik i denna uppsats stod mellan implementation alternativt experimentell.

Implementation som teknik används ofta inom forskningsfältet datavetenskap och informationssystem och består i att utveckla nya lösningar (Berndtsson et al. 2008). Ofta så involverar detta att skapa nya metoder, algoritmer eller procedurer som löser ett problem på ett nytt sätt och ofta betyder detta att den nya lösningen behöver implementeras för att kunna demonstrera förbättringen (Berndtsson et al. 2008). Denna teknik hade sannolikt kunnat fungera väl då projektet kretsar kring att implementera en uppsättning algoritmer på ett specifikt sätt. Resultatet av detta hade sedan kunnat jämföras med en uppsättning existerande lösningar för algoritmisk aktiehandel och utifrån detta hade sedan en analys kunnat göras om den föreslagna lösningen håller måttet. En nackdel som identifierades med detta tillvägagångssätt var att välja ut vilka system som lösningen skulle jämföras med samt att få tillgång till dessa system.

Experimentell teknik innebär att forskaren undersöker ett antal variabler för att se hur dessa påverkas vid olika experimentella förhållanden med syfte att verifiera eller falsifiera en formulerad hypotes (Berndtsson et al. 2008). Ofta är denna hypotes uppställd genom någon form av kausal relation mellan variablerna som ingår i experimentet. Det experimentella upplägget bedöms vara den bästa lämpade för denna studie då en modell kommer utvecklas för att förutse aktiemarknaden, indexet OMX30, och utifrån dessa förutsägelser ge en användare rekommendationer. Effekten av dessa rekommendationer kommer sedan jämföras med utvecklingen av indexet OMX30 för att utvärdera ifall rekommendationer har optimerat alternativet suboptimerat handeln.

Det finns ett antal aspekter att ta hänsyn till vid ett experimentellt upplägg på en studie och vid god forskning generellt. Oates (2005) beskriver att för att kunna dra slutsatser från ett experiment måste det repeteras flera gånger av andra forskargrupper med ett liknande resultat. För att säkerställa detta kommer implementationerna diskuteras i detalj vid genomgång av resultaten samt vilken data som används och för vilka perioder kommer specificeras. Oates (2005) beskriver även att ett experiment är baserat på en hypotes, som ska testas. Hypotesen bör vara någon form av påstående som inte testas hittills, men som skulle kunna testas genom någon form av empirisk test och med hjälp av insamlade fältdata. I denna studien har följande hypotes formulerats baserad på den generella problemformuleringen i avsnitt 3.1.

Att processa fundamentala data genom ett ANN och tekniska data genom ett LSTM kommer genera bra investeringsrekommendationer

Denna hypotes kommer utvärderas genom att studera utvecklingen från OMX30 för en given tidsperiod och sedan utföra virtuell handel med hjälp av de prognoser som systemet generar för samma tidsperiod. Skulle den virtuella handeln generera en överavkastning gentemot utvecklingen för OMX30 bör hypotes anses verifierad då systemet givet investeraren bra rekommendationer. Därmed finns det två grupper i experiment. Denna ena gruppen är resultatet av handel genomförd med hjälp av den föreslag systemlösningen och den andra gruppen, kontrollgruppen, är resultatet av att passivt

investera samma belopp i samtliga ingående bolag i OMX30. Utvärdering och analys av experimentets resultat kommer ske genom en jämförelse mellan dessa två grupper.

4.3 Validitet / reliabilitet

För att undersökningsmetoden, testet, parametern, mätinstrumentet och måttet skall vara användbart och lämpligt, krävs det att denne är reliabel och valid. Uppfylls inte dessa två krav har inte forskningsresultatet något vetenskapligt värde enligt Ejvegård (2003). Har mätinstrumentet en förhållandevis låg reliabilitet så innebär detta även låg validitet, men det motsatta förhållande råder inte alltid. Detta innebär sammanfattningsvis att reliabiliteten kan vara hög, men sakna validitet (Ejvegård 2003). Bell (2000) förklarar detta med att en fråga kan ge liknande svar, men frågan behöver inte nödvändigtvis mäta det som ska mätas.

En viktig aspekt i detta projekt är därmed om de mätningar och test som genomförs är reliabla och valida. Ejvegård (2003) menar att Reliabiliteten även kan benämnas tillförlitlighet, med detta menas tillförlitlighet och användbarhet av mätinstrumentet och måttenheten. Bell (2000) menar att den mätning som görs ska frambringa samma resultat vid olika tillfällen, där det råder lika förhållanden som vid första mätningen. Det finns några olika hot mot reliabiliteten i detta experiment och det största av dem bedöms vara att det vilar i stor utsträckning på programmeringsspråket Python och ramverket Keras. Både Python och Keras genomgår löpande uppdateringar och förändringar och dessa skulle eventuellt i framtiden kunna innebära att experiment blir svår att reproducera av olika skäl. Dels på grund av att den implementerade algoritmen inte går att använda alternativt går att använda, men har modifierats och ger ett annat resultat. Detta har konfirmerats under experimentets gång då en versionsuppgradering av Keras gjorde att tidigare resultat inte kunde reproduceras fullt ut. Det finns även ett visst mått av slump när de artificiella neurala nätverken tränas upp och det kan göra att resultaten från experimentet inte går att återskapa så som de redovisas i denna rapport.

Det finns även några stycken olika hot mot validiteten i denna undersökningen. Det första är om den uppdelning som gjorts mellan träningsdata och testdata. För att bibehålla den sekventiella och kronologiska ordningen i materialet har perioden 2018–10-02 – 2019-03-08 satts som valideringsperiod och träning har utförts på perioden 2010-01-02 – 2018-09-07. Att bibehålla den kronologiska ordningen av materialet är helt nödvändigt för att LSTM:et ska kunna bearbeta datan korrekt. Att bara använda sig av en enda valideringsperiod i detta fallet anses riskfyllt dock då den kanske är specifikt lämpad för den genomförda implementationen. Därmed har ytterligare validering gjorts på andra tidsperioder i datamaterialet och om detta rapporteras det ytterligare under resultatredovisningen.

4.4 Implementering

Detta kapitel ämnar beskriva hur experimentet har genomförts och hur resultaten har tagits fram.

4.4.1 Datainsamling

För de bolag som ingår i experimentet samlades transaktionsdata in från Nasdaq OMX hemsida (http://www.nasdaqomxnordic.com/aktier). Transaktionsdatan är på detaljnivån dag för dag för tidsrymden år 2000 – 2019-kv1. Datan fördelar sig på 11 kolumner och ett litet urklipp som exempel på hur den är formad kan ses i tabell 1 nedan. Denna data användes för att beräkna de tekniska indikatorer som behövdes för experimentet, vilka återfinns i bilaga 2. Fundamentala data hämtades från webbsidan Börsdata (https://borsdata.se/) där de utvalda bolagens nyckeltal finns sparade för den valda tidsperioden och dessa nyckeltal återfinns i bilaga 1.

Tabell 1. Exempel på rådata fångad från Nasdaq OMX hemsida

Date	Bid	Ask	Opening price	High price	Low price	Closing price	Average price	Total volume	Turnover	Trades
20181228	216,9	217,1	214,8	219,6	214,6	217,6	217,703	1272325	276994252,3	2870
20181227	214	214,1	218	218,8	213,6	214	215	1342510	288891883,7	4466
20181221	217,8	218	218,7	219,4	215,3	218,2	217,577	2115333	460166237,8	5849
20181220	219,9	220	223,1	223,7	218,6	218,6	220,113	2022241	445196551,7	4971
20181219	225,4	225,6	225	227,3	224,3	225,1	225,561	1274934	287582595,9	3170
20181218	224,9	225,1	224,2	225,7	223,4	225,1	224,647	1147059	257648037,6	4002

4.4.2 Implementering av algoritmer

För att genomföra experimentet har två algoritmer implementerats och ett virtuellt handelssystem skapats. De arbetar tillsammans i en form av system, som kan ses i figur 7 nedan. Den första implementering är ett ANN som behandlar den fundamentala data och klassificerar ifall specifika bolag är köpvärda eller ej. Dessa signaler skickas vidare till nästa algoritm, som är i form av ett LSTM, vars arbete det är att hitta bra tidpunkter att agera på dessa signaler. Dessa signaler översätts i det virtuella handelssystem som kan beräkna vad modellens rekommendationer hade givet för resultat under en given tidsperiod. Både algoritmerna och handelssystemet har implementerats i programmeringsspråket Python med hjälp av ramverket Keras för nätverken (Keras 2019).

ANN:et har, som tidigare nämnts, implementerats som en binär klassificerar och denna klassificerar samtliga bolag som ingår i experimentet på kvartalsbasis. Det vill säga en modell klassificerar samtliga bolag. Detta är motiverat i och med att strategierna som ligger till grund för den fundamentala data inte förespråkar att nyckeltal ska sättas i relation till andra bolag eller tar avstamp från något bolagsspecifikt. Snarare så tittar de på hur nyckeltal utvecklats över ett kvartal alternativ att bolaget uppfyller något specifikt villkor. Har till exempel ett bolag inte genomfört en nyemission är det bra sett till vad ”F-score” strategin förespråkar och det gäller oavsett bolag.

LSTM:et har implementerats som en tidsserieregressionsmodell och det har skapats en sådan modell per bolag som ingår i experimentet. Detta bedömdes som nödvändigt i och med att varje bolag är unikt och dess tekniska data likaså. En tidsseriemodell tränad på

till exempel Volvo är inte användbart för att förutsäga kursutvecklingen i bolaget Getinge. Handelsmönster, marknadsvärdering och antalet aktier i bolaget är unikt för varje bolag och det är inte sannolikt att en generell modell skulle ge ett gott utfall.

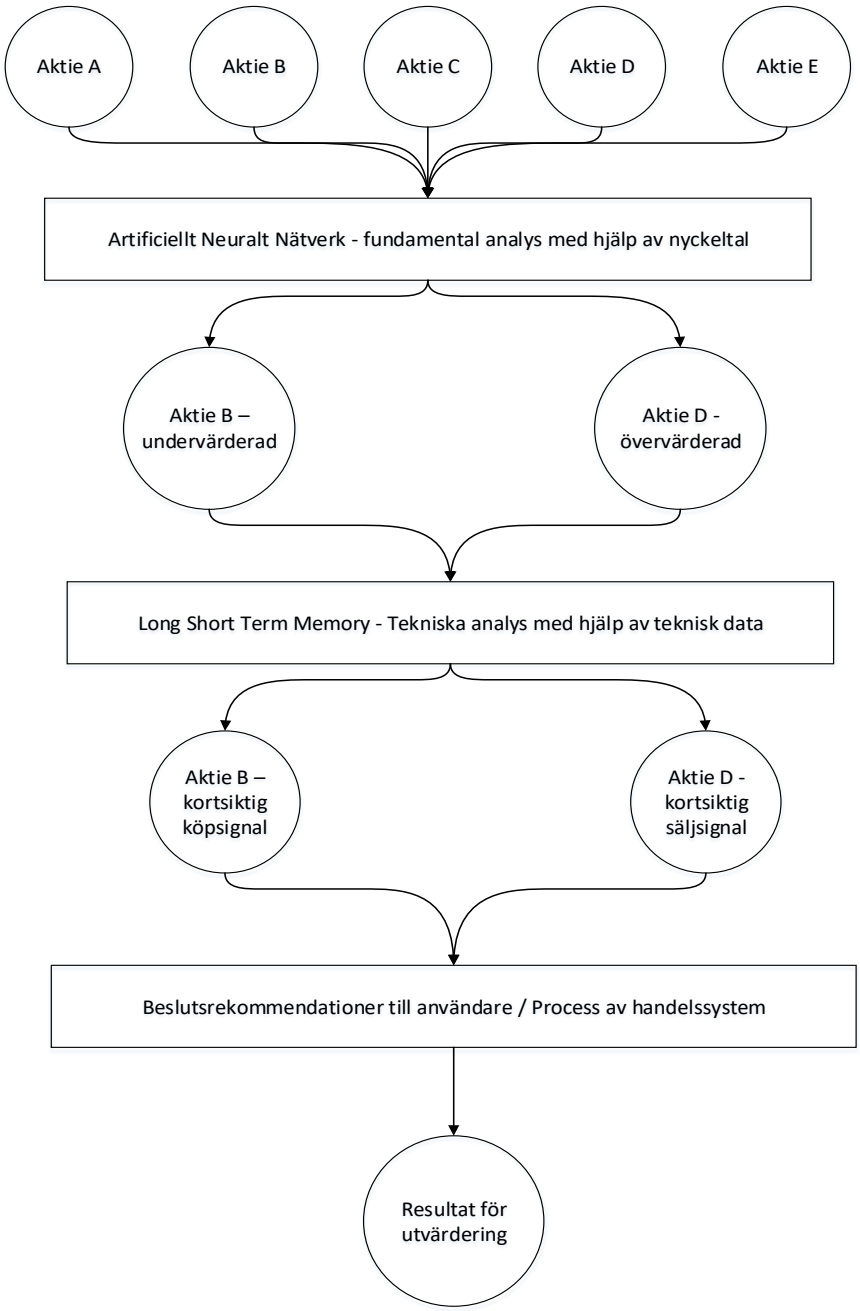

Figur 7. beskrivning implementerat system

En viktig aspekt vid kalibrering av modellerna som konstruerats av algoritmerna är vilka metriker som används för att värdera hur väl de fungerar. Ett vanligt sätt att utvärdera en binär klassificerar är genom ett s k ”Confusion matrix”. Från figur 8 kan det ses att fyra mått beräknas i en sådan matris. Det är dels hur många sanna positiva förutsägelser som klassificeraren ger. Detta inträffar när klassificerar säger att något är av den positiva klassen och det faktiskt också förhåller sig så. I detta experiment motsvaras detta av att bolaget borde köpas. Ett annat potentiellt scenario är det omvända det vill säga en sann

negativ förutsägelse och detta motsvaras i detta experiment av att bolaget borde säljas. Båda dessa mått räknar med andra ord förekomsten av korrekta klassificeringar. De övriga två måtten räknar hur många falska klassificeringar som genereras.

		True class	
		Positive	Negative
Predicited Class	Positive	True Positive Count	False Positive Count
	Negative	False Negative Count	True Negative Count

Figur 8. Confusion Matrix, inspirerad av Sharda, R., Delen, D. & Turban, E. (2014).

På dessa fyra summeringar har sedan fyra vedertagna mått beräknats. Det första av dessa mått är ”accuracy”:

$$Accuracy = \frac{True\ Positive + True\ Negative}{True\ Positive + True\ Negative + False\ Positive + False\ Negative}$$

Detta mått ger i princip en procentsiffra av hur stor andel av samtliga klassificeringar som är korrekta. Det andra måttet är ”specificity”:

$$Specificity = \frac{True\ Negative}{True\ Negative + False\ Positive}$$

”Specificity” återkopplar med en procentsiffra över hur många sanna förutsägelser modellen gör för den negativa klassen i relation till hur många sådana som finns i datasetet. Detta i och med att en ”false positive” i praktiken är en felklassificerad säljsignal och de sanna negativa är en korrekt klassificerad säljsignal.

Det tredje som måttet som använts är ”recall”:

$$Recall = \frac{True\ Positive}{True\ Positive + False\ Negative}$$

Fungerar som det föregående måttet fast i omvänd ordning då det återkopplar en metrik för den positiva klassen. Till sist användes måttet ”F1 – score” som bäst kan beskrivas som

ett mer sammanvägt och harmoniserande mått över väl modellen är på att både göra negativa och positiva förutsägelser:

$$F1 - score = \frac{2 * True\ Positive}{2 * True\ Positive + False\ Positive + Falske\ Negative}$$

För att utvärdera LSTM i kalibreringsfasen användes måttet MAPE som är det genomsnittliga absoluta felet mellan prediktion och sant värde. I formeln nedan representerar A det aktuella värdet och F det prognostiserade värdet.

$$MAPE = \frac{100\%}{n} \sum_{t=1}^{n} ABS(\frac{A_{t-}\ F_t}{A_t})$$

En viktig aspekt i detta experiment är dock att ett lågt MAPE inte nödvändigtvis innebär att modellen är användbar för en investerare utan det säkerställer bara att prognoserna ligger nära det sanna värdet. Så för att säkerställa att LSTM:et ger bra prognoser, ur hänseende nära ”sanna” värden, för framtida kurser är MAPE användbart. För att ge svar på forskningsfrågan och kunna utvärdera om prognoser ger bra investerings-rekommendationer har dock prognoserna som systemet generar även översatts in i ett virtuellt handelssystem. Detta system handlar på de givna signalerna från systemet enligt en handelsstrategi och resultatet av vad systemet gör översätts i faktiskt kronor och ören baserat på de historiska kurserna som rådde under testperioden.

Denna handel går till så att för varje bolag tilldels en kassa om 100 000 kr och testsetet gås igenom kronologisk dag för dag. Strategin är enkel då handel påbörjas dag 1 och då tittar systemet på vad är prognosen för morgondagen och sen jämför det med den sista dagen i prognosperioden. Så till exempel är nätverket inställ på att göra prognoser för 10 dagar görs en jämförelse med den första och den tionde dagen. Är prognosen en uppgång så genomförs ett köp för hela kassan och sedan behålls det innehavet i minst tio dagar, eller så långt som nätverket är inställt att göra prognoser för. Efter tio dagar så är då kassan slut, men då letar nätverket efter prognoser i det omvända förhållande och när en sådan dyker upp görs en försäljning till den dagens rådande kurs. En ny kassa tillförs då och systemet börja leta efter nya köplägen. På detta sättet gås samtliga dagar igenom för samtliga bolag i experimentet och efter det sammanställs den handeln. Det är denna handeln som sedan används för att utvärdera om nätverket eventuellt skulle kunna vara användbart för en investerare.

5 Resultat

I detta kapitel ämnas de resultat som framkommit i experimentet att presenteras. Kapitlet påbörjas med en genomgång över resultaten från implementation av ANN:et. Sedan följer en genomgång av de resultat som implementation från LSTM:et gav. Till sist görs även en genomgång för resultaten från när de båda implementeringarna fungerade som ett sammanhållet system.

5.1 Resultat – artificiellt neuralt network

Denna algoritmen har använts som en klassificerar och i praktiken har tränings, test och valideringsdata inhämtats för perioden 2011 - 2018 i form av bolags nyckeltal och genomsnittliga dagskurser. År 2011 är speciellt i och med att för detta året finns bara ett värde för hela året i datasetet. Detta beror på att innan 2011 rapporterade bolag sina räkenskaper helårsvis och först efter år 2011 började bolag rapportera sina resultat i kvartalsredovisningar. För varje kvartal i perioden har ett värde beräknats per nyckeltal och kopplat till dessa värden har en etikett skapats, denna etikett är antingen 0 för sälj alternativt 1 för köp. Etiketten har skapts genom regeln att om det genomsnittliga värdet på dagskurserna i det kvartal som följer efter att nyckeltalen presenterades var högre än de genomsnittliga dagskurserna på kvartalet som just passerat då flaggas det som ett bolag som det hade varit värt att köpa. Då sätts klassen till 1 och vice versa 0 om genomsnittskursen var lägre till följande kvartalet. För varje bolag skapades därmed fyra poster per år för åren 2012 - 2018 och en post för helåret 2011 baserat på årsredovisningen 2011.

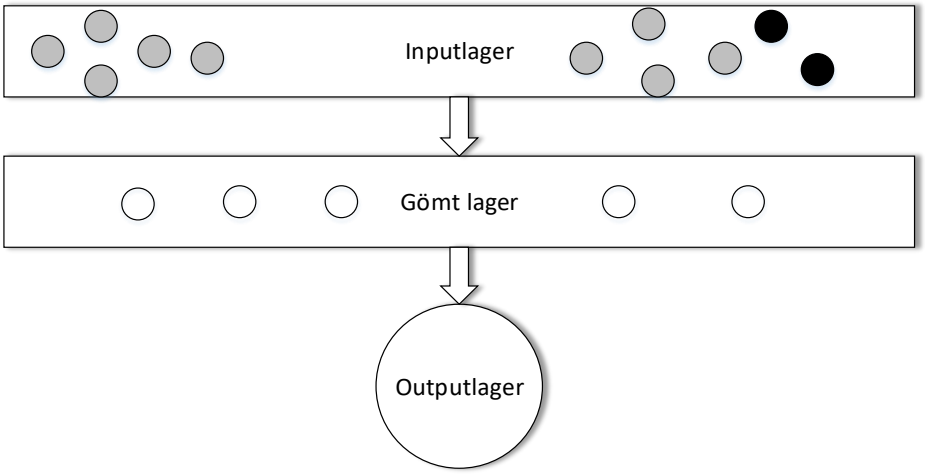

Figur 9. schematisk bild över uppbyggnad ANN

Designen är uppbyggd enligt figur 9 ovan. I det första lagret benämnt inputlayer finns det en nod per nyckeltal i det två strategierna som experimentet använder. Det vill säga nio för F-scorestrategin och två styck för magic formula. I det gömda lagret finns det fem noder och i outputlagret enbart en nod i och med nätverket förväntas genomföra binära klassificeringar mellan antingen köp eller sälj. Output noden använder sig av en Sigmoid aktiveringsfunktion som kan åskådliggöras i figur 10 nedan. Användning av denna

aktiveringsfunktion ger konsekvens att det värdet som skickas från det gömda lagret konverteras till att vara i intervallet 0 – 1. Värdet som outputnoden generar kan ses som en sannolikhet då ett värde kring 0,5 kan ses som osäkert. Ett värde nära 1 kan ses som starkt sannolikt köpläge och ett värde nära 0 som starkt sannolikt säljläge. Vid tolkning av resultat kommer därmed samtliga klassificeringar över 0,5 anses vara köpsignal och alla klassificeringar under 0,5 anses vara en säljsignal.

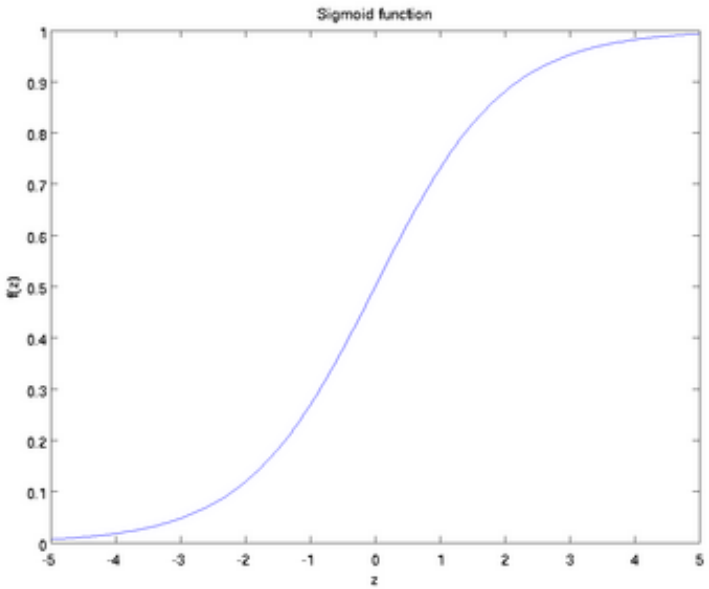

Figur 10. sigmoid funktion, stanford education (2013)

Det finns ett flertal olika hyperparameterar eller inställningar som Keras stöder för att möjliggöra en optimering av de klassificeringar som nätverket skapar. En noggrann systematisk genomgång av ett flertal av dessa inställningar har gjorts med utgångspunkt att maximera de mått som beskrevs i avsnitt 4.4.2. För detta ändamål har modellen tränats med data för perioden 2011 – 2017 Q2 och sedan testats mot perioden 2017 Q3 – 2018 Q2.

En essentiell första inställning är valet av optimiseringsfunktionen som nätverket ska använda. Valet av optimiseringsfunktioner kan ses vara som ett val av matematiska strategi för att minimera felmåttet när nätverket tränar upp sig på träningsdata. För detta nätverk har optimiseringsfunktionen RMSprop valts att använda. Detta beslut grundar sig i att ”accruacy” med denna optimiseringsfunktion uppnådde bäst resultat under testperioden, se bilaga 6. En annan viktig inställning vara även på vilket sättet noderna initialiserades i nätverket. Innan nätverket tränas så instansieras nätverket och hur detta görs kan ha stor betydelse för slutresultatet. Samtliga inställningar som Keras erbjuder testades systematiskt igenom och valet resulterade till slut i användningen av ”Orthogonal” initialisering.

Det felmått som återkopplas efter en gissning till nätverket är också av väsentlig vikt och det finns olika sätt detta mått kan beräknas på. Det finns en specifik så kallad ”loss

function” som är implementerad i ramverket Keras för användning vid binära klassificeringar. Denna heter ”binary crossentropy” och det är denna som använts. En annan viktig inställning är hur länge ett nätverk ska tränas innan den testas. Tränas det för länge blir det ofta för anpassat för träningsdatan och oanvändbart för att göra klassificering på ny data. För kort tid så hinner inte nätverket tränas väl nog för att bli användbart. I facktermer talas det här om hur många epoker nätverket ska tränas. Där en epok motsvarar att nätverket har gått över all data i träningssetet en gång. En systematisk genomgång från 250 epoker – 7 500 epoker testades och det bästa och mest tidseffektiva resultatet blev 1 000 epoker, underlagen till detta val kan finnas i bilaga 7. Det finns ett flertal andra inställningar som också användes för nätverket, men dessa bedöms vara av mindre betydelse för slutresultatet efter testning.

För att säkerställa att inställningar som valts resulterar i en modell som är generaliserbart bra. Det vill säga inte bara med en specifik uppsättning träningsdata och en annan specifik uppsättning testdata har följande strategi använts. Först konstruerades en modell med de valda inställningarna med träningsdata för år 2011 - 2017 och sedan testades denna modellen mot de första två kvartalen året 2018 och resultaten noterades. Sedan konstruerades en ny modell med träningsdata för åren 2011 - 2016 samt de första två kvartalen året 2018 och testades mot året 2017. På detta sätt gick samtliga år förutom år 2011, som är speciellt i och med att det bara finns helårssiffror för detta år, i datasetet igenom och totalt sett skapades därmed sju modeller som testades och sedan gjordes en utvärdering för de genomsnittliga resultateten för samtliga dessa modeller. Att de sista två kvartalen 2018 inte användes var för att dessa två kvartal planerades användes för en sista validering.

I tabell 2 nedan kan resultaten år för år ses och i figur 11 nedan kan även de genomsnittliga metrikerna för de sju konstruerade modellerna med de valda inställningarna åskådliggöras.

Tabell 2. Resultat träning/test ANN

TP	TN	FP	FN	Recall	Accruacy	Specificity	F1-score	Year
27	36	11	38	41.54%	56.25%	76.60%	52.43%	2012
40	19	13	40	50.00%	52.68%	59.38%	60.15%	2013
78	0	27	7	91.76%	69.64%	0.00%	82.11%	2014
15	52	20	25	37.50%	59.82%	72.22%	40.00%	2015
78	1	33	0	100.00%	70.54%	2.94%	82.54%	2016
1	46	3	62	1.59%	41.96%	93.88%	2.99%	2017
20	5	24	7	74.07%	44.64%	17.24%	56.34%	2018

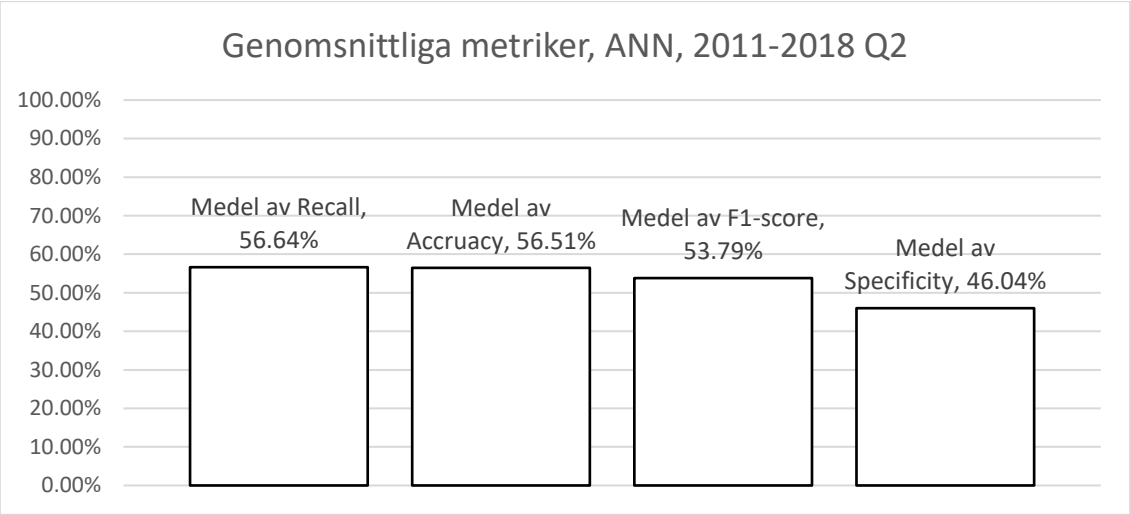

Figur 11. Visualisering resultat träning/test, ANN

Detta resultatet validerades då till sist mot de sista två kvartalen i 2018 som hållits separerade från tränings och testsetet i samband med att inställningarna optimerades. I tabell 3 och figur 12 kan dessa resultat åskådliggöras.

Tabell 3. Resultat validering, ANN

TP	TN	FP	FN	Recall	Accruacy	Specificity	F1-score	Year
4	28	13	11	26.67%	57.14%	68.29%	25.00%	2018

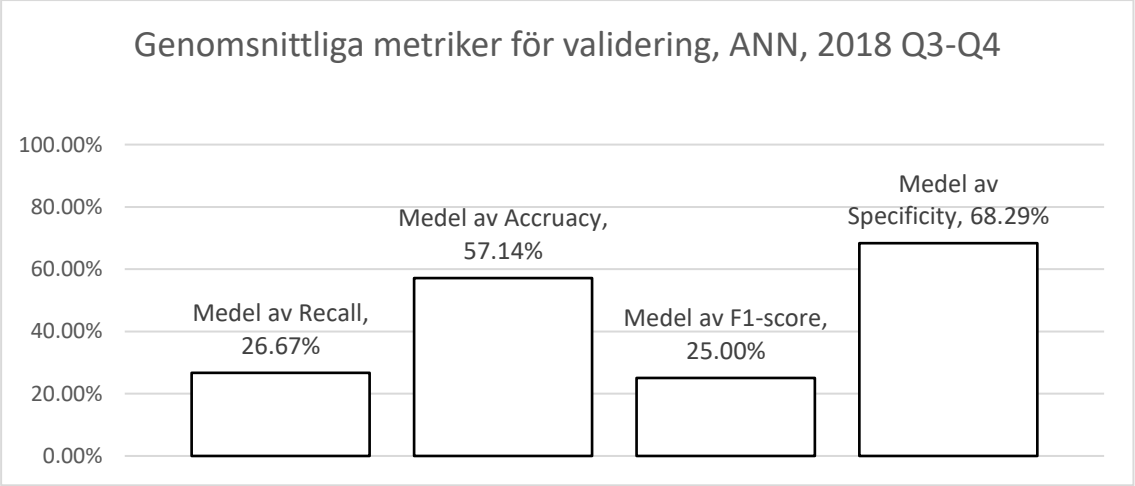

Figur 12. Visualisering resultat validering, ANN

5.2 Resultat – Long Short Term Memory network

Denna algoritm har implementerats med syfte att skapa en tidsserieregressionsmodell för att prognostisera aktiekurser i framtiden baserad på transaktionsdata för de olika aktierna som ingår i experimentet. Totalt sett har data för åren 2000 - 2019 Q1 samlats in för samtliga de ingående bolagen. I en första fas har modeller tränats på data för perioden 2010-01-01 – 2016-10-16 och sedan testats modellerna på perioden 2016-10-17 – 2018-

12-04. Dessa resultat har sedan validerats på två olika sätt för att säkra upp att resultaten är generaliserbara. Dels har även modeller tränats på perioden 2010-01-01 – 2018-09-30 och testats 2018-10-02– 2019-03-08. Denna validering innehåll dock en del data för testperioden för att skapa modellerna så därför gjordes även en extra validering där modellerna tränades på data för år 2003-01-02 – 2007-12-31 och sedan testades på perioden 2008-04-16 – 2009-12-07. En extra fördel med denna validering var att det fångade in den stora finanskraschen hösten år 2008, vilket sågs som ett extra test för att stärka resultaten.

På samma sätt som för ANN:et finns det även för denna algoritm en mängd olika inställningar eller hyperparameterar som påverkar sättet modellerna skapas på i Keras. En systematisk genomgång har dock visat på att för detta specifika problemet är det några som har större påverkan än andra. Den mest centrala inställning är som för ANN:et valet av optimieringsfunktion och denna gången föll valet på Adadelta och underlaget till detta valet återfinns i bilaga 5. Antalet epoker som nätverket behövde tränas på slutade 75. Antalet gömda lager som ingår i modellen har en påverkan och till skillnad från ANN:et så implementerades denna algoritm med två gömda lager. I dessa lager testades det med olika antal ingående så kallade ”memory cells”, vilket kan ses som en motsvarighet till noder i ett ANN. Här visades det sig att 40 memory cells per lager gav bäst resultat. Felmåttet som återkopplar till nätverket vid inlärning är satt till ”mean squared error” och är alltså det genomsnittliga felet i kvadrat, vilket är ett vanligt använt felmått i samband med regression. För ett regressionsproblem används generellt sätt aktiveringsfunktionen ”Linear” på outputnoderna. Detta innebär att det värde som nätverket levererar passeras vidare i sin ursprungliga form och inte som i fallet vid en klassificerar pressas in i en Sigmoid för att ligga i intervallet 0 - 1. Anledning här är att syftet med nätverket är att ange ett specifikt pris per aktie och inte som för ANN:et genomföra någon form av klassifikation. Nätverk initialiserades med hjälp av ”Glorot_uniform”.

Resultaten efter denna kalibreringsprocess visade på en MAPE på i genomsnitt 1.83% för samtliga ingående bolag i experimentet för testperioden 2016 Q4 – 2018 Q3. I bilaga 3 återfinns en tabelluppställning där MAPE beräknats för varje enskilt bolag som ingår i experimentet. En poäng att notera vid denna sammanställning är att bolagen Getinge och Autoliv ligger i toppen på denna lista. Båda dessa bolag har haft mindre avknoppningar under testperioden då bolaget Autoliv har knoppat av en del av sitt marknadsvärde till bolaget Veoneer och bolaget Getinge till bolaget Arjo. I avgränsningarna till experimentet, avsnitt 3.3, nämndes att SCA och Essity lämnat utanför experimentet på grund av liknande händelser. En aspekt på denna avgränsning är dock att denna avgränsning gjordes för att avknoppning i sig, Essity, efter avknoppning ingick i OMX30. Detta till skillnad från fallet med Autoliv och Getinge. Det kan noteras dock att dessa typer av bolagshändelser i testperioden antagligen påverkar resultaten för experimentet negativ i och med att det inte finns något i träningsdatan som kan hjälpa nätverket att kunna hantera denna typen av extrema händelser då marknadsvärde från en dag till nästa tappar flera tiotals procentenheter.

En annan central aspekt för upplärning av ett LSTM-nätverk är dels hur mycket data nätverket ska titta på när den gör en regression samt hur långt i framtiden den ska försöka göra prognoser. I ANN implementation så tittar nätverket på ett fall och gör en klassificering. I implementationen av ett LSTM kan det ställas in hur många historiska fall (dagar) nätverket ska titta på när den gör sina prognoser och även hur många framtida dagar den ska generera prognoser för en specifik dag. Till skillnad från ett ANN, där fallen vid en tränings och testsituation matas till nätverk utan någon egentlig ordning, så matas ett LSTM nätverk i en tillrättalagd kronologisk ordning. Möjligheten att kunna ställ in hur många fall den tittar på när nätverk gör sina prognoser är den central styrka i denna algoritm och det som gör den så bra på att arbeta med så kallade tidsserieproblem och att fånga trender i ett datamaterial. I en binär klassificerar finns det en outputnod i det sista lagret för att det finns bara två klasser att välja på och då kan ett värde mellan 0 - 0,5 representera en klass och ett värde mellan 0,5 - 1 representera den andra. I denna implementation är antalet dagar nätverket försöka göra prognoser in i framtiden representerade med en nod vardera. Så görs en tio dagars prognos behöver antalet outputnoder motsvara det, vilket innebär att tio noder hade behövt användas.

En viktig aspekt vid utvärdering för hur långa tidsperioder nätverket ska titta på samt hur långt in i framtiden den ska göra prognoser är att måttet MAPE till viss del saknade relevans ur hänsyn av forskningsfrågan. Detta i och med att syftet med nätverket inte är att skapa prognoser som ligger väldigt nära det sanna värde utan snarare faktiskt fånga trender där kursen antingen är på väg upp eller ned och det ska gärna vara tydliga så att det lätt kan snappas upp. Ett högt fel, det vill säga ett prognostiserat värde långt ifrån det sanna värdet, kan vara acceptabelt om det ändå ger en signal till investeraren som är användbar. Så för denna utvärdering påbörjades en utvärdering med hjälp av det konstruerade virtuella handelssystemet.

I detta experiment testades och utvärderas alltifrån en dag bakåt till femtio dagar bakåt för att göra prognoser en dag framåt till femtio dagar framåt och många möjliga kombinationer där mellan. Det bästa resultatet uppkom när nätverket tittar tio dagar bakåt tiden och försöka göra prognoser för de kommande femton dagarna. En sammanställning för MAPE för samtliga bolag återfinns i bilaga 4 och det genomsnittliga värdet på detta mått har då stigit till 4,15% jämfört med precis efter kalibrering då måttet var 1,83% i genomsnitt för samtliga bolag. Så för till exempel 28 bolag, en prognoshorisont om 10 dagar och en testperiod om 500 dagar så finns det 140 000 datapunkter då det för varje dag skapas 10 prognoser. MAPE återkopplar det genomsnittliga procentuella felet för samtliga dessa 140 000 datapunkterna.

Resultaten av den simulerade handeln i bolagen återfinns först i tabell 4 nedan för testperioden 2016-10-17 – 2018-12-04 som innehåller 541 handelsdagar.

Tabell 4. Resultat test simulerad handel, LSTM

Mått	Resultat
Total vinst	1 080 849.28 kr
Total förlust	- 676 357.08 kr
Resultat	404 492.20 kr
Totalt antal vinstgivande affärer	181
Totalt antal förlustgivande affärer	117
Avkastning på insatt kapital	14,5 %

En visuell jämförelse med OMX30 kan även åskådliggöras i figur 13 nedan.

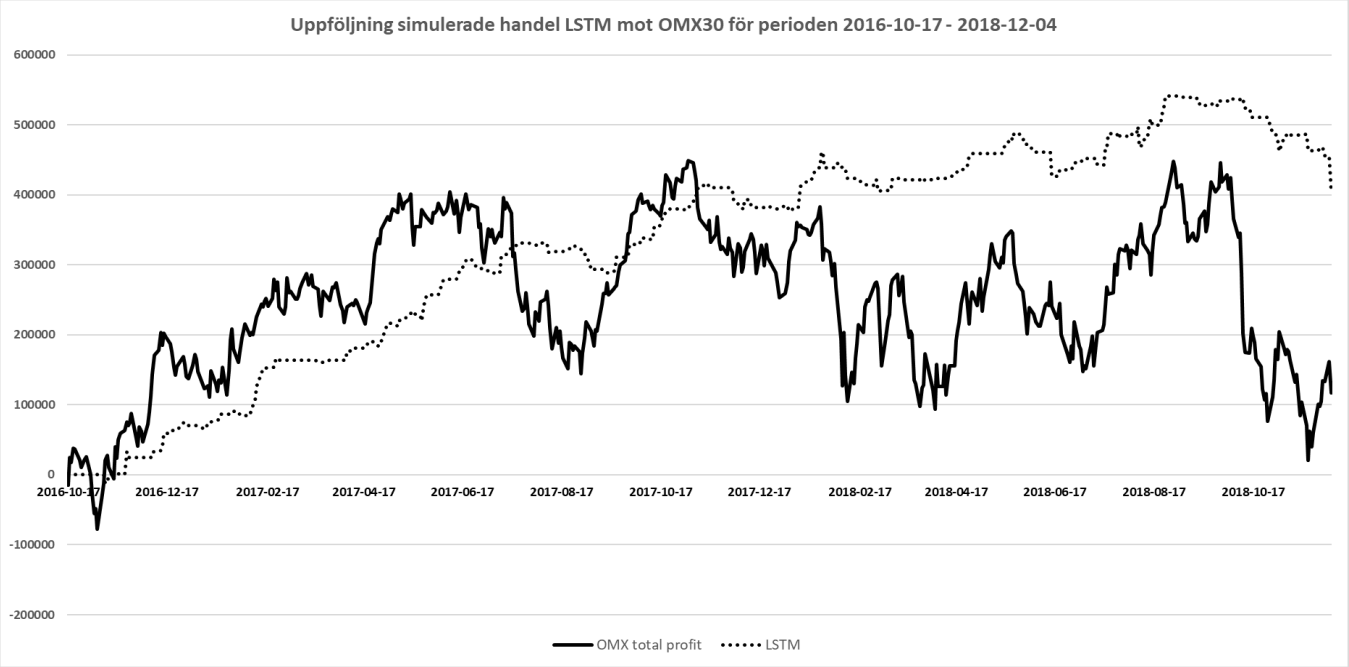

Figur 13. Jämförelse utveckling handel dels passivt ägande OMX30 och dels med hjälp av LSTM, test

I figur 13 ovan representerar den streckade linjen handeln i de 28 bolagen som ingår i experimentet med en initial kassa om 100 000 kr i varje bolag. Den svarta linjen visar på utvecklingen investering skulle haft om den köpt aktier för 100 000 kr i varje bolag vid testperiodens början och passivt behållit dem. Från tabell 4 ovan så avkastade handel med hjälp av nätverket 404 492 kr eller ca 14,5% på insatt kapital. OMX30 avkastade under samma period 117 015 kr eller ca 4,2%. En viktig aspekt att ta hänsyn till vid tolkning av dessa resultat är att för beräkning av OMX30 innehavet så värderas innehavet löpande till den dagens kurs. För LSTM:et dock så görs beräkningen löpande på realiserade vinster och förluster när de inträffar. Vid testperioden slut så hade portföljen som handlade med hjälp av LSTM kvar aktier som inte var sålda på grund av att igen säljsignal uppenbart sig som nätverket valt att agera på. I sammanställningar ovan så har dessa innehav realiserats den 2018-12-04 för att göra det jämförbart med OMX30 och det är dessa som skapar det relativt stora tappet den sista dagen i testperioden. Värdet på denna realisering

uppgick till – 51 265 kr, men hade testperioden fortsatt skulle LSTM:et eventuellt realiserat dessa poster till andra värden.

En första validering genomfördes för handel i perioden 2018-10-02 – 2019-03-08, vilket motsvarar 109 handelsdagar, och resultaten för denna handel kan ses i tabell 5 och i figur 14 nedan. Vid perioden slut värderades kvarvarande innehavet för LSTM:et till 78 249 kr.

Tabell 5. Resultat första validering simulerad handel, LSTM

Mått	Resultat
Total vinst	189 710.00 kr
Total förlust	-65 076.60 kr
Resultat	124 634.40 kr
Totalt antal vinstgivande affärer	21
Totalt antal förlustgivande affärer	9
Avkastning på insatt kapital	4.39 %

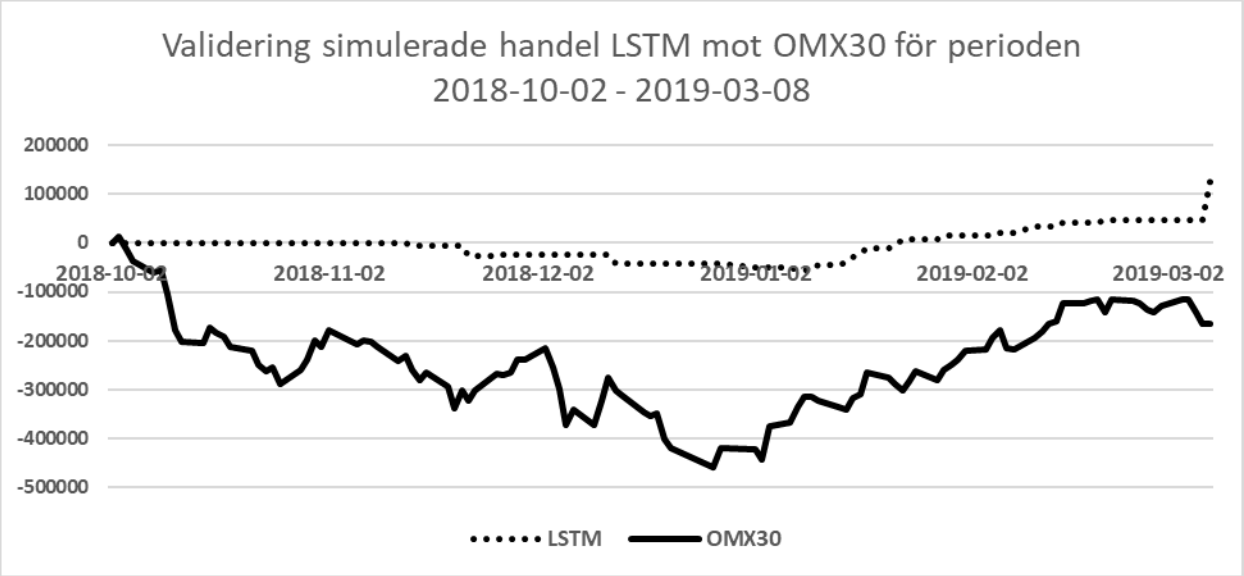

Figur 14. Jämförelse utveckling handel dels passivt ägande OMX30 och dels med hjälp av LSTM, första validering

En andra validering genomfördes för handel i perioden 2008-04-16 – 2009-12-07, vilket motsvarar 415 handelsdagar, och resultaten för denna handel kan ses i tabell 6 och i figur 15 nedan. Vid perioden slut värderades kvarvarande innehavet för LSTM:et till 245 954 kr.

Tabell 6. Resultat andra validering simulerad handel, LSTM

Mått	Resultat
Total vinst	1 714 530.00 kr
Total förlust	-83 130.00 kr
Resultat	861 400.00 kr
Totalt antal vinstgivande affärer	116
Totalt antal förlustgivande affärer	63
Avkastning på insatt kapital	30.80 %

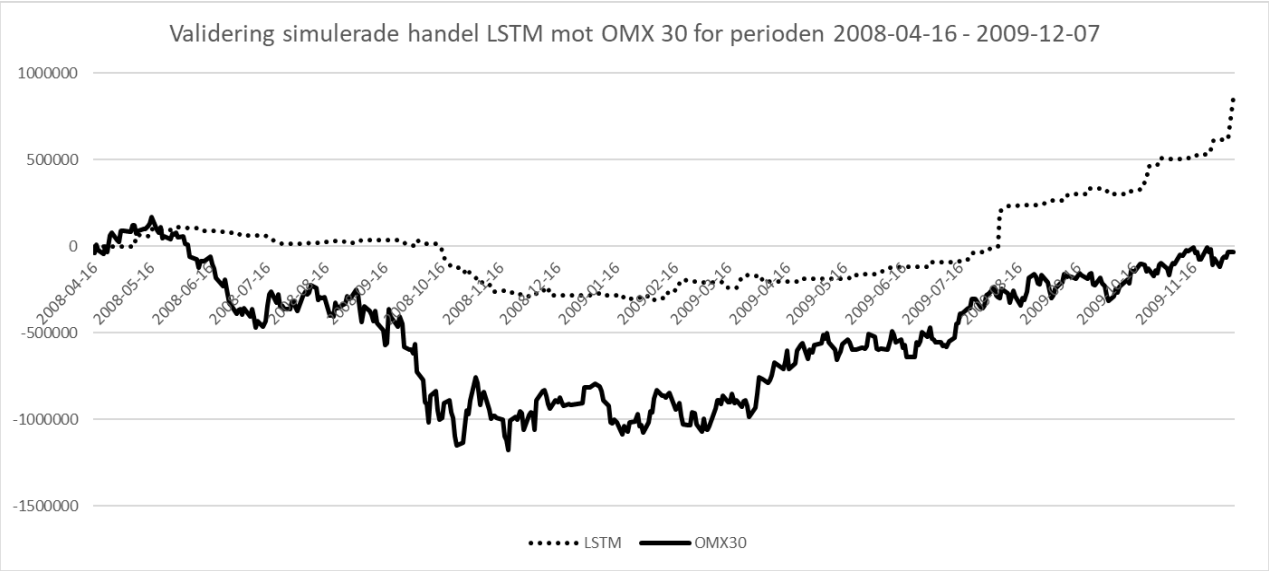

Figur 15. Jämförelse utveckling handel dels passivt ägande OMX30 och dels med hjälp av LSTM, andra validering

5.3 Resultat – systemlösning

I detta delavsnitt redovisas resultaten från att använda båda ANN:et och LSTM:et som ett sammanhängande system. Från ANN:et kommer klassificeringar för varje bolag och kvartal om det är en köpkandidat alternativt en säljkandidat. LSTM:et och handelssystemet fungerar precis som tidigare beskrivit, men en tillkommande regel i handelsmodulen som stoppar denna modul från att köpa aktier där ANN:et angivet att det är en säljkandidat för den givna tidsperioden och vice versa. Testperioden för detta system har varit 2010-01-02 – 2018-09-30 och den simulerade handeln har då utförts i perioden 2016-08-11 – 2018-09-07 sedan har ett slutgiltig validerande test genomförts för perioden 2018-10-02 – 2019-03-08. Testerna har genomförts på så vis att för varje period så körs först handeln utan stöd av klassificeringar av ANN:et och sedan med användning av klassificeringarna. Detta innebär att totalt sett fyra resultat skapades och dessa redovisas i tabellform nedan.

I figur 16 kan utvecklingen över tid ses för en handel bedriven dels enbart med hjälp av LSTM och dels med stödd av klassificeringar från ANN:et för testperioden 2016-08-11 – 2018-09-07. Såsom tidigare sker en värdering av de eventuellt återstående innehaven den sista dagen i testperioden till rådande kurs den dagen.

Tabell 7. Resultat testperiod 2016-08-11 – 2018-09-30

LSTM utan stöd från ANN		**LSTM med stöd från ANN**	
Mått	**Resultat**	**Mått**	**Resultat**
Total vinst	1 236 230 kr	Total vinst	1 057 385 kr
Total förlust	-639 500 kr	Total förlust	-431 187 kr
Resultat	596 730 kr	Resultat	626 198 kr
Totalt antal vinstgivande affärer	175	Totalt antal vinstgivande affärer	135
Totalt antal förlustgivande affärer	108	Totalt antal förlustgivande affärer	75
Avkastning på insatt kapital	21.32 %	Avkastning på insatt kapital	22.32 %

Tabell 8. Resultat validering 2018-10-02 – 2019-03-08

LSTM utan stöd från ANN		**LSTM med stöd från ANN**	
Mått	**Resultat**	**Mått**	**Resultat**
Total vinst	189 710.00 kr	Total vinst	79 101.86 kr
Total förlust	-65 075.60 kr	Total förlust	-27 061.30 kr
Resultat	124 634.40 kr	Resultat	52 040.56 kr
Totalt antal vinstgivande affärer	21	Totalt antal vinstgivande affärer	9
Totalt antal förlustgivande affärer	9	Totalt antal förlustgivande affärer	3
Avkastning på insatt kapital	4.39 %	Avkastning på insatt kapital	1.78 %

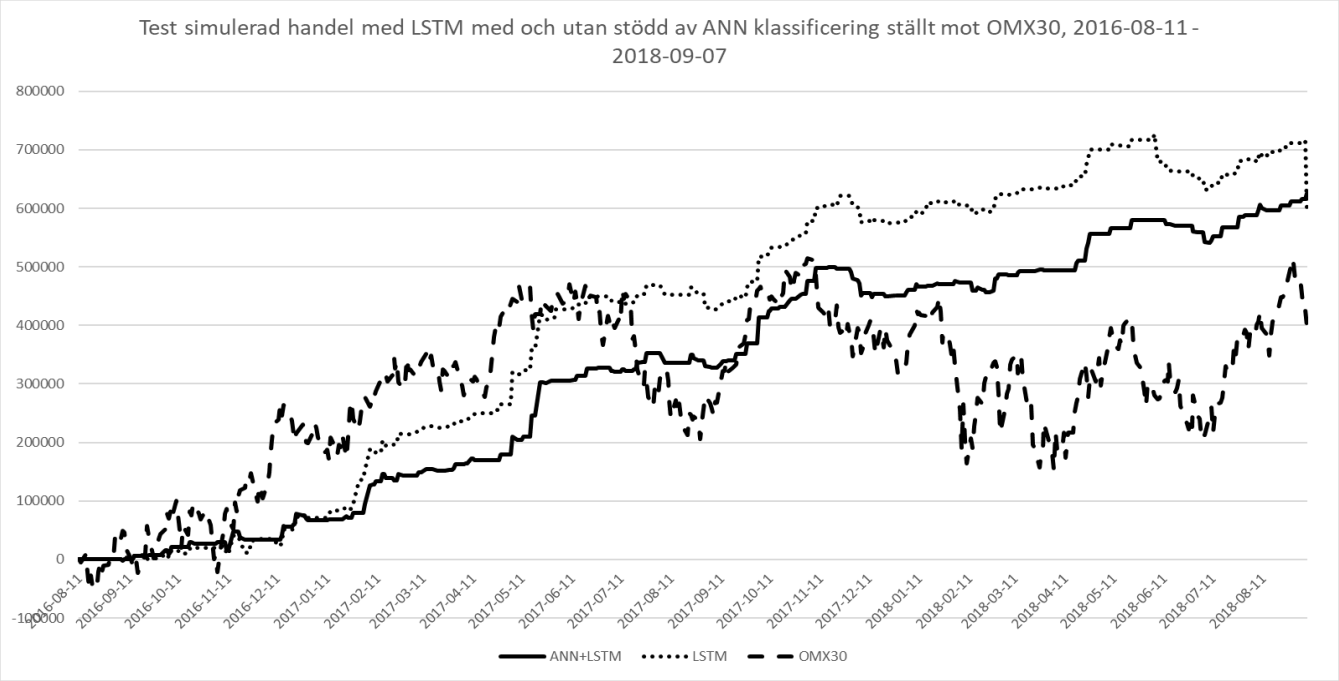

Figur 16. Simulerade handel under testperiod 2016-08-11 – 2018-09-07 med stöd och utan stöd av klassificering från ANN

I figur 17 kan utvecklingen över tid ses för en handel bedriven dels enbart med hjälp av LSTM och dels med stödd av klassificeringar från ANN:et för valideringsperioden 2018-

10-02 – 2019-03-08. Såsom tidigare sker en värdering av de eventuellt återstående innehaven den sista dagen i testperioden till rådande kurs den dagen.

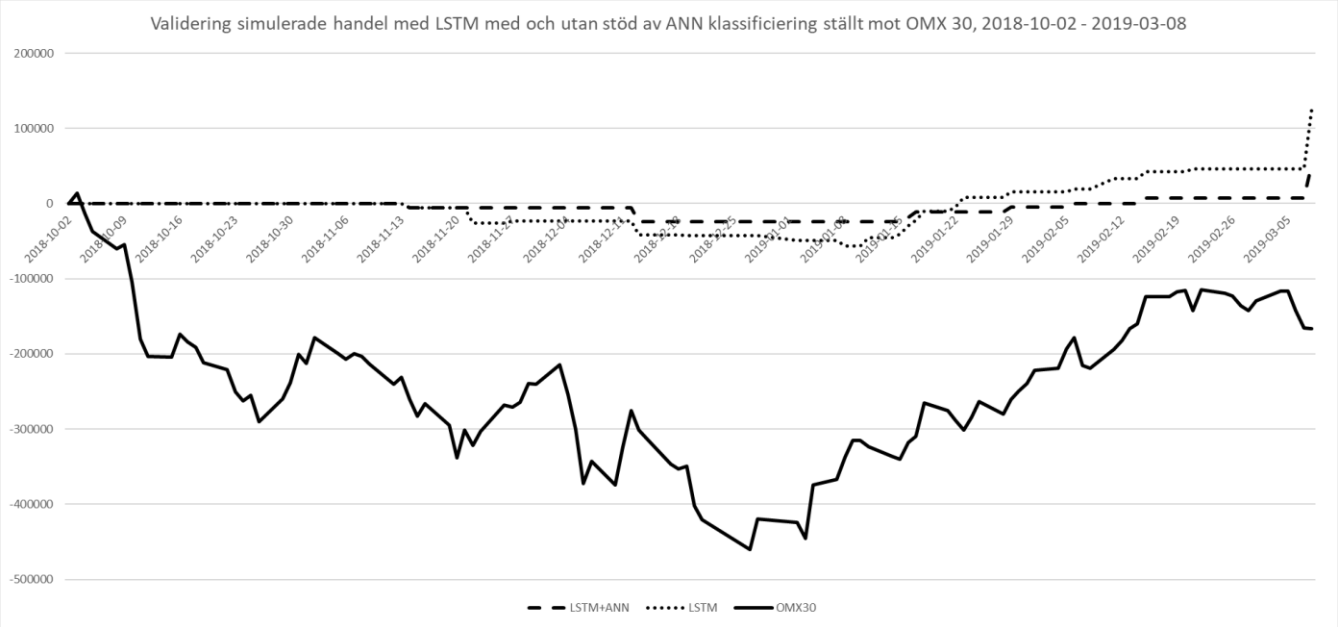

Figur 17. Simulerade handel under testperiod 2018-10-02 – 2019-03-08 med stöd och utan stöd av klassificering från ANN

6 Analys / slutsatser

I detta kapitel kommer en analys av resultaten som presenterades i föregående kapitel att genomföras samt en presentation rörande de slutsatser som kan dras av denna analys. Uppsatsens problemformulering har varit att utvärdera i vilken utsträckning ett system uppbyggt av ett ANN och ett LSTM, som kombinerar tekniska och fundamentala data, kan fungera som ett stöd åt en investerare. Från denna utgångspunkt formulerades en hypotes som denna analys ämnar utvärdera:

Att processa fundamentala data genom ett ANN och tekniska data genom ett LSTM kommer genera bra investeringsbeslut.

I figur 7 visualiseras det system som använts för att samla in data för att kunna validera alternativt falsifiera denna hypotes. I avsnitt 5.1.3 har de resultat rapporterats som avser den helhetliga systemlösningen. Slutsatsen från detta material är att hypotesen har validerats inom ramen för denna studie.

Den grundläggande orsaken till detta är att vid både testning av systemet för perioden 2016-08-11 – 2018-09-07 och sedan validering för perioden 2018-10-02 – 2019-03-08 så kunde en positiv avkastning påvisas. Vidare generade handel baserat på rekommendationer från systemet även en klart bättre avkastning än en passiv placering i den underliggande tillgången OMX30. I testperioden generade systemet 22,32% i avkastning jämfört med OMX30 som under samma period avkastade 14,4% och i valideringsperioden 1,78% respektive ca -5,92%. I testperioden genomfördes 210 försäljningar och 135 av dessa eller ca 64,3% generade vinst. I valideringsperioden genomfördes väsentligt färre affärer på grund av tidsperiodens längd. Då genomfördes totalt sett 12 försäljningar baserat på rekommendationer från systemet och 75% av dessa generade vinst.

Kommande avsnitt i denna analys kommer fokusera på att utvärdera de olika delarna av systemet med utgångspunkt från den vetenskapliga motiveringen till uppsatsen som togs upp i avsnitt 3.2. Resultaten från denna studie bör därmed först ställas i relation till de resultat som Kelly et al. (2018), Heaton et al. (2016), Chen et al. (2018) samt Patel et al. (2014) presenterat rörande värderingsproblematiken och neurala nätverk. Samtliga av dessa studier har använt tekniska data i olika former kombinerat med olika implementationer av neurala nätverk med ansatsen att försöka värdera aktier och prognostisera framtida kursutvecklingar. Samtliga studier utmynnade i slutsatsen att det fungerade väl. Resultaten från denna studien rörande detta återfinns i avsnitt 5.1.2, där algoritmen LSTM används i kombination med tekniska data. Slutsatsen från de resultat som presenteras i detta avsnitt är att tidigare resultat stärks då samtliga test och valideringsperioder generade en överavkastning gentemot OMX30 och hade fler vinstgivande försäljningar än förlustbringande. Mer om detta i avsnitt 6.2 nedan.

Ställs studiens resultat i relation till Chen et al. (2018) samt Patel et al. (2014) föreslag att berikning av den tekniska datan med hjälp av fundamentala data borde ha potential att

stärka de neurala nätverkens möjligheter att värdera aktier och prognostisera kommande kursutveckling kan dock inte samma slutsats dras. Med det experimentella upplägg som valts för denna uppsats har det inte visat sig försämra prediktionerna generellt sett i detta experiment, men inte hellre förbättra dem i någon väsentlig utsträckning. I avsnitt 5.1.3 ställs lösningen med enbart LSTM och tekniska data i relation till en lösning med ANN+LSTM som använder både tekniska och fundamentala data. I testperioden kunde en något bättre avkastning noteras, men dessa resultat kunde inte valideras på ny data. Slutsatsen kring detta är därmed att mer forskning kommer behövas på detta område och några uppslag kring detta kommer tas upp nedan i kapitel sju.

6.1 Analys implementation ANN

Ett flertal resultat presenterades i avsnitt 5.1.1. I tabell 3 presenterades en generaliserad form av resultat för implementation av ANN:et då det i tabellen återfinns de resultat som uppnåddes när modellen tränades om och testades på varje år i datasetet. Ett viktigt mått i denna uppställningen är ”accruacy” då det mäter hur stor andel av klassificeringarna som faktiskt var korrekta. I genomsnitt för samtliga år i datasetet uppnåddes ca 56,5% ”accruacy”. En viktig notering är att för det sista året i datasetet är bara två kvartal medtagna då resten användes för validerings syften. Skulle detta året elimineras från sammanräkning summerar genomsnittlig ”accruacy” till ca 58,5%. Måttet ”recall” mäter hur väl modellen kan klassificera så kallad köpsignaler och i genomsnittssiffran för samtliga år blev ca 56,6% och omvänt för måttet ”specificity” som klassificerar säljsignaler ca 56,3%. Summeras inte det sista året in så blir resultaten motsvarande ca 46% och 53,9%. Resultaten validerades på ny data som bestod av Q3 och Q4 2018 och då uppnåddes snarlika resultat för ”accruacy”, men måttet ”recall” sjönk till ca 26,5% och ”specificity” ökade till ca 68,3%.

En reflektion som gjordes vid utvärderingen av denna implementation rör användning av den sigmoida funktionen för att översätta resultaten från ANN:et till en sannolikhet från 0 - 1 där ett resultat under 0,5 motsvarar en säljsignal och över 0,5 en köpsignal. Ett resultat kring 0,5 bör tolkas som att gissningen från nätverket och att fallet den ställs inför är diffust och svårklassificerat. En gissning nära noll eller nära ett däremot är ett enkelt fall med en klar sälj alternativ köpsignal. Flera experiment utfördes med att justera var gränserna för vad som ska tolkas som en säljsignal/köpsignal gick samt om ett visst intervall skulle kunna tolkas som en tredje klass – behåll/oklart. Det experiment som gav bäst resultat med fokus på ”accruacy” var där alla resultat över eller lika med 0,6 skulle tolkas som en köpsignal och alla resultat under eller lika med 0,1 som en säljsignal. Då summerade ”accruacy” till ca 62,8% med enskilda år uppåt 80%. Det visade sig dock att en förbättrade ”accruacy” i kombination med den tredje klassen inte nödvändigtvis motsvarade en förbättring för systemets prestanda som helhet. En tillbakablick på tabell 3 skapar insikten att det görs 728 klassificeringar totalt för de 7 åren. Stryps gränserna till köp 0,6 och sälj 0,1 gav modellen enbart 239 klara köp alternativt sälj signaler och de resterande 489 tolkades då som behåll/diffust. När dessa resultat omsattes i handelssystemet så visades det sig att dessa resultaten inte förbättrade systems resultat

som helhet. LSTM delen av systemet kunde kompensera för en längre ”accruacy” från ANN:et om den fick möjlighet att handla även på de diffusa signalerna enligt de prognoser som generades från den tekniska datan.

Sammantaget antyder dessa resultat att den implementerade modellen har något bättre prediktionskraft än att singla en slant, vilket är en baslinje som resultaten kan jämföras med då den utför binära prediktioner. Singlas en slant ett stort antal gånger kan det förväntas att krona och klave i genomsnitt kommer vissas ungefär lika många gånger det vill säga 50% krona och 50% klave. Detta slår modellen och det finns en viss slagsida mot att den är bättre på att tolka säljsignaler då ”specificity” var klart högre vid validering och när året 2018 eliminerades från testresultaten. Använder sig en investerar av denna modell systematiskt över en lång tidsperiod så talar resultaten för att ett visst stöd kan ges. Att fatta enskilda beslut på enskilda klassificeringar måste dock tolkas som vanskligt.

6.2 Analys implementation LSTM

För testperioden 2016-10-17 – 2018-12-04 summerade handel i LSTM:et till en avkastning om 404 492 kr eller ca 14,5% på ett insatt kapital om 2 800 000 kr och en passiv placering i OMX30 till samma belopp avkastade under samma period 117 015 kr eller ca 4,2%. Detta resultat valideras i två omgångar. Dels först 2018-10-02 – 2019-03-08 som summerade till 124 634 kr avkastning, vilket motsvarade 4,39% i avkastning. Dels sedan 2008-04-06 – 2009-12-07 som summerade till 861 400 kr, vilket motsvarar 30,8% i avkastning. I både figur 14 och 15 kan det uttydas att handeln med nätverket gav väsentligt bättre avkastning än att passivt placera i den underliggande tillgången.

Den andra valideringen genomfördes för att den första valideringen innehåll två månader ur testperioden. Valet av valideringsperioder har baserats på att de karakteriseras av stor volatilitet på marknaden med dels stora nedgångar dels stora uppgångar. Detta val gjordes med utgångspunkt för att testperioden som modellen utvecklats och optimerats i karakteriserades av en positiv och uppåtgående marknaden, vilket gör det något enklare att generar avkastning då bolagen generellt sett blir högre och högre värderade över tid. Att använda perioder som karakteriseras av helt andra förutsättningar bedömdes därmed stärka resultaten. I datasetet finns tre mer eller mindre stora krascher under 2008, 2011 och 2018 då marknaden snabbt sjönk ca 20% eller mer.

En utvärdering gjordes även därför för 2003 – 2012 och då sattes utvärderingsperioden till 2010-07-23 – 2012-12-04 för att fånga in 2011. Då tränades nätverket på data från perioden 2003-01-02 - 2010-07-23. Handel med hjälp av modellen generade 637 640 kr i avkastning för denna period vilket motsvarar en procentuell avkastning om ca 22,7% motsvarande avkastning för en passiv placering OMX30 blev 81 609 kr eller ca 2,9%.

Ytterligare en utvärdering gjordes även för tidsperioden 2003-01-02 – 2018-12-04. Då sattes testperioden till 2014-04-28 – 2018-12-04. Då generades en avkastning om 902 090 kr, vilket motsvarar en procentuell avkastning om ca 32,2% i kontrast till passiv placering i OMX30, som hade generat en avkastning om ca 8,5% eller 240 230 kr.

En orsak till detta delexperiment var att utröna ifall längden på datamaterialet i antalet år skulle kunna ha påverkan på slutresultaten. Det visades sig dock att tidigare resultat konfirmerades. Det ska noteras att de två sistnämnda valideringarnas testperiod överlappar tidigare test och valideringsperioder bitvis varför dessa resultat inte rapporterades i föregående kapitel. Flera valideringar av liknande karaktär har utförts under studiens gång, men kommer inte redovisas ytterligare på grund av detta. Det bör dock nämnas att ingen validering har gjorts som utmynnat i att handel med stöd av LSTM utmynnat i en sämre avkastning än att investera passivt i den underliggande tillgången. Detta stärker tesen om att maskininlärning med hjälp av neurala nätverk har potential att kunna värdera aktier och prognostisera framtida värdeutveckling väl.

En generell slutsats som kan dras är även att nätverket agerar bra i samband med uppgång på aktiemarknaden och följer utvecklingen på OMX30 väl i dessa perioder med både vältajmade köp och säljordrar, men det som skapar mest överavkastning mot OMX30 är dess tendens att vara försiktig i nedåtgående marknader. Från både figur 13 och 15 kan det konstanternas att nätverket inte generar många säljsignaler i skarpt nedåtgående marknadsrörelser som handelssystemet kan agera på och därmed realiseras heller inga förluster. Utvärderas till exempel valideringsperioden 2008-04-06 – 2009-12-07 lite närmare kan det konstateras att en bråkdel affärer gjorde i början av nedgången i augusti-september 2008, men sen valde nätverket att inte genera säljsignaler under den resterande nedgången fram till december månad och behåll alternativ fyllde på de innehav som fanns. Detta visades sig i efterhand vara en lyckosam strategi då börsen under 2009 sedan vände upp och OMX30 som index summerade till ca 0% utveckling under testperioden. Detta innebär att nätverkets rekommendationer att behålla befintliga innehav alternativ fylla på periodvis var lyckosamt då marknaden senare normaliserades.

En reflektion som kan göras rörande detta är att nätverket fungerar väl i perioder med relativt korta nedgångar med påföljande uppgångar då dess inneboende tendens att vara optimistisk om marknaden gör att den inte gärna säljer innehav och är duktig på att agera i en positiv marknad. Detta skulle kunna ha att göra med att de träningsperioder nätverket tränats på har till stor övervikt varit ”positiva” år med börsuppgångar, vilket kan ha gett den ett ”öga” för att vara bättre på att se och agera i positiva marknadstendenser. Frågan väcks dock hur väl detta skulle fungera i en lång och utdragen nedgång som sträcker sig över ett eller fler år. Tyvärr finns det ingen sådan lång och utdragen nedgångsperiod att tillgå i den insamlade datamaterialet för utvärdering utan bara kortare och skarp ras till exempel vid åren 2008, 2011 och 2018, som valts ut för test alternativt validering.

6.3 Analys – systemlösning

Den total systemlösning testades och optimerades på perioden 2010-01-02 – 2018-09-07 och när både ANN:et och LSTM:et agerade ihop under testperioden 2016-08-11 – 2018-09-07 så summerades avkastning till 626 198 kr vilket motsvarar 22,32%. I jämförelse kunde LSTM:et ensamt under samma period skapa en avkastning om 596 730 kr och det motsvarar 21,32%.

Dessa resultat validerades sedan genom att samma modeller som användes för testperioden användes på helt ny data specifikt 2018-10-02 – 2019-03-08 och då resulterade handel med ANN tillsammans med LSTM 79 102 kr i avkastning, vilket motsvarar 1,78% på insatt kapital om 2 800 000 kr. LSTM:et ensamt kunde under samma period genera 124 634 kr i avkastning, vilket motsvarar 4,39% på 2 800 000 kr på insatt kapital.

Från figur 16 och 17 var handel ensamt med LSTM och den helhetliga lösning med både ANN + LSTM bättre än en passiv investering i OMX30 som är den underliggande tillgången. Det är detta resultat som främst stärker slutsatsen om att processa fundamentala data genom ett ANN och tekniska data genom ett LSTM kommer genera bra investeringsrekommendationer generellt sätt. ANN:ets bidrag till detta slutresultat är dock inte starkt inom ramen för denna studie.

Dessa resultat konfirmerar även den tanke som återfanns i delavsnitt 6.1 rörande ANN:ets prediktionskraft och tidsaspekten. I testperioden presterade systemlösning något bättre än att enbart förlita sig på LSTM nätverket, men det resultat kunde inte valideras när system utsattes för nya data som inte ingått i träning och optimering av modellerna. Med tanke på resultaten från ANN:et skulle eventuellt en längre test och valideringsperiod varit att föredra. En ”accruacy” på ca 56,5% innebär som tidigare nämnt en svagt förbättrad prognoskraft jämfört med att singla en slant och enbart över en längre utvärderingsperiod kan ett sådant resultat få en eventuell genomslagskraft på slutresultat.

7 Diskussion

I detta kapitel kommer de resultat som framkommit och analysen av dessa resultat att diskuteras. Kapitlet är indelat i dels en diskussion kring de vetenskapliga aspekterna på studien dels en diskussion rörande de etiska aspekterna.

7.1 Vetenskapliga aspekter

I denna studie har ett antal vetenskapliga resultat framkommit. Studiens hypotes var:

"att processa fundamentala data genom ett ANN och tekniska data genom ett LSTM kommer genera bra investeringsbeslut."

Ett av de första vetenskapliga resultaten är att denna hypotes har validerats till att stämma enligt de resultat som framkom i kapitel fem och analysen i kapitel sex. Detta resultat kan sedan analyseras ur två aspekter, som motsvaras av de båda delarna i det implementerade systemet.

De första forskningsresultaten generas av den delen av systemet som bearbetar fundamental data och använder sig av algoritmen ANN. Analysen av denna delen i systemet i kapitel 6.1 utmynnade i att den prediktionskraft som ANN:et kunde generar motsvarar ett något bättre resultat än att singla en slant och att det därmed inte går att använda för att fatta enskilda investeringsbeslut. Litar en investerare på dess prediktioner under en lång tid systematiskt har det dock potential att ge ett visst stöd.

Detta resultat underbygger den analysen, som togs upp i bland annat kapitel sex, av Chen et al. (2018) samt Patel et al. (2014) förslag. Deras förslag var att berikning av den teknisk data med hjälp av fundamentala data borde ha potential att stärka de neurala nätverkens möjligheter att värdera aktier och prognostisera kommande kursutveckling. Det sätt som detta förslag har omsatts i denna studien visar inte på att detta stämmer. Det har inte väsentligt försämrat prediktionskraften, men har inte stärkt den heller. Under studiens gång har dock ett flertal förslag framkommit som borde ha potential att utvärderas genom vidare forskning.

Det första förslaget berör själva algoritmen. I denna implementation så lär sig ANN:et genom att studera ett kvartal och försöka göra en klassificering om siffrorna för detta kvartal föranleder att ett köp alternativ säljsignal ska genereras. Det är detta strategierna, som ligger till grund för vilka siffror ANN:et ska studera, förespråkar. Frågan är nog om inte en investerar dock vid en analys av ett företag kanske inte enbart nöjer sig med att studera ett enskilt kvartal vid ett eventuellt köp eller säljbeslut utan även gör en ytterligare bedömning rörande hur nyckeltalen utvecklats över tid. Det vill säga har ett specifikt nyckeltal utvecklats positivt över ett antal kvartal så säger det något om den framtida kursutvecklingen i sig också utöver att strategins villkor uppfylls. Detta kan inte ANN implementation fånga upp på grund av dess arkitektur och hur inputdatan är utformad. Vissa delexperiment genomfördes där inputdata berikades med olika former av konstruerade trendindikator över tid, men det förbättrade inte resultaten nämnvärt.

Att säga att dessa möjligheter är uttömda vore felaktigt dock så här skulle mer forskning behövas. Förslagsvis kunde en liknande implementation som denna göras, men med användning av algoritm RNN som beskrivs i kapitel 2.5.1. Denna algoritm har fördelen, på samma sätt som ett LSTM, att kunna arbeta och lägga vikt vid tidsseriedata. På detta sätt skulle en bättre hänsyn tas till tidsserieaspekten av inputdatan på samma sätt som görs för den tekniska datan i experimentet.

Det andra förslaget berör inputdatan som använts. För den fundamentala datan valdes i detta experiment två specifika strategier ut för att ligga till grund för vilken inputdata som skulle användas. Det finns dock som nämndes i avsnitt 2.1 många sådana strategier och även många fler nyckeltal som används flitigt för att analysera bolag. Här krävs mer forskning då det finns potential att ett utökat dataset med fler nyckeltal från andra strategier mycket väl skulle kunna ha positiv påverkan på slutresultaten. Andra typer av inputvariabler skulle även kunna ha potential att ha positiv påverka. Ett uppslag på detta skulle kunna vara konjunkturindikatorer som BNP-tillväxt, inflation och valutakurser. Ett annat förslag är att studera hur samtliga analytiker som bevakar ett bolag ställer sig till bolag i det innevarande kvartalet och göra en metrik som sammanfattar detta. Ett tredje och sista förslag skulle vara att använda sig av de insynsregister som ger information om hur så kallade ”insiders” på bolag agerar vid olika tidpunkter. Dessa förslag är på intet sätt uttömmande och kortfattat och sammanfattande finns det fortsatt goda möjligheter att omsätta detta forskningsuppslag i potentiellt gynnsamma resultat.

Andra forskningsresultat som framkommit generas av den delen som består av ett LSTM och som arbetar med teknisk data. Ett första resultat framkom i kapitel sex när resultat från studien ställdes i relation till de resultat som Kelly et al. (2018), Heaton et al. (2016), Chen et al. (2018) samt Patel et al. (2014) presenterat rörande värderingsproblematiken och neurala nätverk. Samtliga av dessa studier har använt tekniska data i olika former kombinerat med olika implementationer av neurala nätverk med ansatsen att försöka värdera aktier och prognostisera framtida kursutvecklingar. Samtliga studier utmynnade i slutsatsen att det fungerade väl. Resultaten från denna studien rörande detta återfinns i avsnitt 5.1.2, där algoritmen LSTM används i kombination med tekniska data. Slutsatsen från de resultat som presenteras i detta avsnitt är att tidigare resultat stärks då samtliga test och valideringsperioder generade en överavkastning gentemot OMX30 och hade fler vinstgivande försäljningar än förlustbringande.

En viktig notering till dessa resultat är att de generaliserar de ovannämnda studierna ytterligare ur flera aspekter. Dels är denna studie fokuserad på den svenska börsen, vilket ingen av de ovannämnda studierna är. En annan aspekt är att i detta experiment är inte fokuset på nivån att förutse en Indexutveckling ackumulerat utan i denna studie konstrueras modellerna på varje enskilt bolag som ingår i indexet och försöker därmed förutse varje enskild komponent som ingår i indexet. Till sist har de resultat som framkommer i studien valideras över flera olika tidsperioder och inte bara fokuserat på en enskild utvald tidsperiod. Sammantaget stärker det resultaten från Kelly et al. (2018), Heaton et al. (2016), Chen et al. (2018) samt Patel et al. (2014) väsentligt.

Till sist finns det även en unik aspekt på denna studie och det är att det finns en komponent som utvärderar hur väl prognoserna som kommer från modellerna faktiskt hade kunnat omsättas i praktiken omräknat i kronor och åren samt antalet gynnsamma förslag. Det var något författaren av denna uppsats inte noterade i någon av de övriga studierna som han tog del av vid förberedelse av detta experiment. En uttömmande litteratursökning genomfördes inför detta experiment, men ingen relevant sådan studie kunde finnas. Detta är en aspekt som det läggs för lite vikt på vid forskningsprojekt av denna arten då det faktiskt inte räcker med att en prognos är ”nära” det verkliga värdet utan det är faktiskt om beslutsrekommendationen var korrekt eller ej som borde utvärderas.

En viktig infallsvinkel på detta är även rörande genomförande av den simulerade handel som utförts på historiska data. Handelsreglerna i systemet är satta till att köp sker till stängningskurser för den aktuella dagen då det är dessa kurser som nätverk har blivit upptränade på att förutse. Skulle en verklig investerare använda prognoser från systemet som underlag för handel skulle det därmed vara viktigt att handel utförs på ett sättet som närmar sig de förutsättningar experimentet bygger på. I och med att kursen ett bolag kan köpas till under dagen kan fluktuera kraftigt är det en extra utmaning som tillkommer. Skulle ett sådant experiment genomföras, där ”riktig” handel utförs utanför en simulerad miljö med alla de utmaningar som tillkommer kring detta, skulle det vara väldigt intressant ur en vetenskaplig aspekt då det ytterligare skulle generalisera de resultat som framkommit i denna studie och de resultat studien bygger på. Under studiens gång har ett flertal försök gjorts att finna en studie där ett sådan har experiment utförts i en ”skarp” miljö, men utan lycka.

Avslutningsvis så borde fortsatt ansatser att med hjälp av maskininlärning använda sig av både teknisk och fundamental data genomföras. Då ofta bara halva verktygslådan inom aktieanalys i dagsläget används i samband med maskininlärning för aktieanalys finns det stor potential att stärka de modeller som i dagsläget konstrueras. För att återknyta till syftet med studien, så skulle en vedertagen och vetenskapligt förankrad modell för att kunna värdera tillgångar av typen aktier kunna ha stor potential att motverka och minimera att spekulativa bubblor byggs upp på aktiemarknaden i cykler. Detta skulle kunna ha som konsekvens att effekten av efterföljande krascher till sådana spekulationsbubblor minimeras och förmögenhetsförluster för vanliga privatpersoner blir mindre. Ofta följs stora krascher på aktiemarknaden med år av sämre tillväxt, hög arbetslöshet och omvälvningar i samhället i stort och kan dessa effekter minimeras skulle det ha stort värde på både individ samt samhällsnivå.

7.2 Etiska och samhälleliga aspekter

En etisk och samhällelig aspekt på detta arbetet är att aktiemarknaden, som marknadsplats, har som utgångspunkt att alla aktörer på den ska ha tillgång till samma information och ha samma förutsättningar att lyckas. Detta är en av anledningar att till

exempel så kallade ”insider” person, det vill säga personer på exempelvis chefsnivå inom ett företag, bara har tillåtelse att handla i specifika perioder i de bolag de är en del av. Det på grund av att de står på insidan av bolaget och har ett informationsövertag rörande dess verksamhet jämfört med de investerare som inte är en del av företaget. Det är av vikt att ingen aktörer har ett orimligt övertag för att marknaden ska kunna fungera effektivt och bibehålla sitt förtroende.

Då potentialen med maskininlärning kopplat till att prognostisera aktiekurser har visats i denna uppsats och i de artiklar denna uppsats vilar på så kommer det i framtiden bli viktigt att kunskapen om dessa tekniker sprids till alla aktörer på denna marknad. På samma sätt som verktygslådan för fundamental och teknisk analys är öppen för alla att använda, grundligt utforskat vetenskapligt och spridd till allmänheten så borde även kunskapen om dessa tekniker utforskas ytterligare och spriddas till allmänheten. En överhängande risk finns annars för några få aktörer att skaffa sig ett stort informationsövertag gentemot övriga aktörer och förvrida den jämna spelplan aktiemarknadens förtroende och effektivitet nu vilar på.

8 Referenser:

Andersson, G., Jorner, U. & Ågren, A. (2007). *Regressions- och tidsserieanalys*. Lund: Studentlitteratur AB. ISBN: 978-91-44-02987-0

Azrak, E. (2018). *How many publicly traded companies are in the world?.* Hämtat från: https://www.quora.com/How-many-publicly-traded-companies-are-in-the-world [togs 2018-12-16]

Barto, A. G. & Sutton, R. (1997). *Introduction to Reinforcement Learning.* Cambridge: MIT Press

Bell, J. (2000). *Introduktion till forskningsmetodik.* Trelleborg: Berlings skogs

Berndtsson, M., Hansson, J., Olsson, B., & Lundell, B. (2008). *Thesis Projects: A Guide for Students in Computer Science and Information Systems*. London: Springer-Verlag Limited

Bertolaccini, L., Solli, P., Pardolesi, A. & Pasini. A. (2017). *An overview of the use of artificial neural networks in lung cancer research*. Journal of Thorasic Disease, 9(4), ss. 924-931.

Bodie, Z., Kane, A. & Marcus, A.J. (2011). *Investments and Portfolio Managements*. 9:e ed. New York: McGraw-Hill/Irwin

Bolter, L. (2019 februari 3). *Ingen i vår generation har särskild rätt till intäkterna.* Hämtad från: https://www.di.se/nyheter/norska-oljefondens-chef-ingen-i-var-generation-har-sarskild-ratt-till-intakterna/ [togs 2019-02-06]

Brownlee, J. (2016 augusti 9). *How to Grid Search Hyperparameters for Deep Learning Models in Python with Keras.* hämtat från: https://machinelearningmastery.com/grid-search-hyperparameters-deep-learning-models-python-keras/ [togs: 2019-02-28]

Bryman, A. (2002). *Samhällsvetenskapliga metoder,* Trelleborg: Berlings Skogs

Chang, S. V., Gan, K. S., Chin, K. O., Rayner, A., & Anthony P. (2013).
A Review of Stock Market Prediction with Artificial Neural Network (ANN). *International Conference on Control System, Computing and Engineering.* Penang, Malaysia 29 nov - 1 dec 2013. ss. 477–482.
Hämtad från: https://www.researchgate.net/publication/ 261206036_A_review_of_ stock_market_prediction_with_Artificial_neural_network_ANN [togs 2019-02-06]

Chen, J. (2010). *Essentials of Technical analysis for Financial Markets.* New York: John Wiley & Son

Chen, J. (2018). *Backtesting*. Hämtat från: https://www.investopedia.com/terms/b /backtesting.asp [togs 2019-03-01]

Chen, L., Qiao, Z., Minggang, M., Wang, C., Du, R. & Stanley, E. H. (2018). *Which Artificial Intelligence Algorithm Better Predicts the Chinese Stock Market*?. ss. 48625 – 48633. Hämtad: https://ieeexplore.ieee.org/document/8419702 [togs 2019-01-30]

Computer Sweden. (2018). *IT-ord: Ord och uttryck i IT-branschen*. Hämtad från: https://it-ord.idg.se/ord/algoritmisk-aktiehandel/ [togs 2018-12-16]

Damodaran, A. (1996). *Investment Valuation.* New York: John Wiley & Sons, Inc.

Ejvegård, Rolf. (2003). *Vetenskaplig metod*. Studentlitteratur: Lund

Eric, D., Andjelic, G. and Redzepagic, S. (2009). Application of macd and rvi indicators as functions of investment strategy optimization on the financial market. *Sveuciliste u Rijeci*. vol. 27, issue. 1, ss. 171–195.

Felix A. G., Schmidhuber, J. & Cummins, A. F. (1999). *Learning to Forget Continual Prediction with LSTM*. Technical Report IDSIA-01-99 januari, 1999 [togs 2019-02-19]

Greenblatt, J. & Tobias, A. (2006). *The Little book that beats the market.* New York: John Wiley & Sons, Inc.

Guo, L., Jia, F., Li, N. & Lei, Y. (2017). *A recurrent neural network based health indicator for remaining prediction of bearings.* Neurocomputing 240 (2017), february. ss. 98 - 109. Hämtad från: https://www.researchgate.net /publication/ 314251130_ A_recurrent_neural_network_based_health_indicator_for_remaining_useful_life_prediction_of_bearings [togs 2019-02-24]

Heaton, J. B., Polson, N. G. & Witte, J. H. (2016). *Deep Learning in Finance.* Hämtad: https://arxiv.org/pdf/1602.06561.pdf [togs 2019-01-30]

Hochreiter, S. & Schmidhuber, J. (1997). *Long Short-Term Memory.* Neural Computation 9(8):1735-1780. Hämtat från: http://citeseerx.ist.psu.edu/viewdoc/ download ?doi=10.1.1.676.4320&rep=rep1&type=pdf [togs 2019-02-19]

Huang, B., Huan, Y., Xu, D. L., Zheng, L. & Zou, Z. (2019). *Automated trading systems statistical and machine learning methods and hardware implementation: a survey*. Enterprise Information Systems Vol 13, 2019, Issue 1, ss. 132-144. Hämtad från: https://www.tandfonline.com/doi/full/10.1080/ 17517575.2018.1493145 [togs 2019-02-06]

Kelly, B., Gu, S. & Xiu, D. (2018). Empirical Asset Pricing via Machine Learning. *31st Australasian Finance and Banking Conference 2018.* Chicago Booth Research Paper No. 18-04. Hämtat från: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=3159577 [togs 2019-01-30]

Keras open documentation. (2019). hämtat från: https://keras.io/ [togs: 2019-02-28]

Liu, Z, W. (2011). *Stochastic volatility model and technical analysis of stockprice.* Acta Mathematica Sinica, vol. 27, no. 7, ss. 1283–1296.

Nasdaq. Inc. (2019). *Vad är aktieindex?.* Hämtat från: http://www.nasdaqomxnordic.com/utbildning/aktier/vadaraktieindex?languageId=3 [togs 2019-02-24]

Kotsiantis,. B. S. (2007). *Supervised Machine Learning: A review of classification techniques.* hämtat från: http://www.informatica.si/index.php/informatica /article/viewFile/148/140 [togs 2019-02-23]

Mitchell, T. (1997). *Machine Learning.* McGraw Hill. P. 2.

Narendra, N. (2013 april). *Use on balance volume & chaikin money flow index to track price movement in markets [analysis]*. Hämtat från: https://economictimes.indiatimes.com/use-on-balance-volume-chaikin-money-flow-index-to-track-price-movement-in-markets/articleshow/19649182.cms [togs: 2019-02-28].

Nath, T. (2018). *How Big Data has Changed Finance.* Hämtat från: https://www.investopedia.com/articles/active-trading/040915/how-big-data-has-changed-finance.asp [togs 2018-12-16]

Nilsson, H., Isaksson, A., & Martikainen, A. 2002. *Företagsvärdering med fundamental analys*, Lund: Studentlitteratur AB. ISBN: 91-44-00548-2

Oates, B. J. (2005). Researching Information Systems and Computing. Thousand Oaks: Sage Publications Ltd

Patel, J,. Shah, S,. Thakkar, P. & Kotecha, K. (2014). *Predicting stock and stock price index movement using Trend Deterministic Data Preparation and machine learning techniques.* Expert systems with applications, vol 42, issue 1, january 2015, ss. 259-268 Hämtat från: https://www.sciencedirect.com/science/article/pii/S0957417414004473 [togs 2019-01-30]

Patel, R & Davidsson, B. (2003). *Forskningsmetodikens grunder – att planera, genomföra och rapportera en undersökning*. Lund: Studentlitteratur

Patton, M. Q. (2014). *Qualitative Research & Evaluation Methods.* Fjärde upplagan. Thousand Oaks: Sage Publications

Piotroski, D. J. (2002). *Value investing: The Use of historical financial statement information to separate winners from losers.* The University of Chicago, Graduate School of Business, 1101 East 58th Street, Chicago, Illinois 60637

Ponniah, P. (2001). *Data Warehousing Fundamentals: A Comprehensive Guide for IT Professionals. 2*. uppl. New York: John Wiley & Sons, Inc.

Schults, J. (2017). *How Much Data is Created on the Internet Each Day?.* Hämtat från: https://blog.microfocus.com/how-much-data-is-created-on-the-internet-each-day/ [togs 2018-12-16].

Schuster. M. & Paliwal, K., K. (1997). *Bidirectional Recurrent Neural Networks*. Deep transactions on signal processing, Vol 45, no 11, november. ss. 2673-2681. Hämtat från: https://www.researchgate.net/profile/Mike_Schuster/publication/3316656_Bidirectional_recurrent_neural_networks/links/56861d4008ae19758395f85c.pdf [togs 2019-02-19]

Sharda, R., Delen, D. & Turban, E. (2014). *Business Intelligence and Analytics: systems for decision support.* 10., uppl. Pearson Education, Essex: Pearson Education Limited.

Smith, W. S. (1997). *The Scientist and Engineer's Guide to Digital Signal Processing*. California Technical Publishing

Stanford education. (2013). *Neural Networks.* Hämtat från adressen: http://ufldl.stanford.edu/wiki/index.php/Neural_Networks [togs 2019-04-15]

Zachary C. L. & Berkowitz, J. (2015). *A Critical Review of Recurrent Neural Networks for sequence learning*. Hämtat från: https://arxiv.org/pdf/1506.00019.pdf [togs 2019-02-19]

Bilaga 1 – nyckeltal i strategin ”F-score” och ”the magic formula”

F-score

Nyckeltal	**Definition**
BM	Bokfört eget kapital vid slutet av år t skalat med marknadsvärde vid slutet av år t
ROA	Rörelseresultat före extraordinära poster skalat med totala tillgångar, år t
Delta ROA	Förändring i ROA från år t-1 till år t
Delta marginal	Bruttomarginal skalat med rörelseresultat för år t minus samma kvot år t-1
Delta hävstång	Långfristiga skulder skalat med genomsnittliga tillgångar år t – samma kvot år t-1
Delta turn	Rörelseresultat skalat med genomsnittliga tillgångar år t – samma kvot år t-1
Accrual	Rörelseresultat – operativt kassaflöde skalat med totala tillgångar för år t

The Magic Formula

Nyckeltal	**Definition**
Return on capital (ROC)	ROC = EBIT / investerat kapital
Earnings Yield (EY)	EBIT / EV

Bilaga 2

Glidande medelvärde

Glidande medelvärde är en teknik som bildar medelvärden av närliggande observationer. Då ett medelvärde har en mindre variation än en enskild observation kommer slumpens påverkan på dessa medelvärden minskas (Andersson et al. 2007). Syftet med tekniken är att genom att göra en serie glidande medelvärde över en tidsserie kunna hitta en trend i tillgångens värdering över tid och är ett av de enklaste filter som används för detta ändamål (Smith, W. S. 1997). För en analytiker och investerare blir det sedan intressant när tillgången periodvis värderas högre alternativt under sin trend. Formlerna för att beräkna ett glidande medelvärde kan ses nedan och antalet tidpunkter varierar beroende på vilken typ av trend som vill hittas. En kort trend kan till exempel sättas till 20 dagar, en medellång till 50 dagar och en längre till 100 alt 200 dagar.

$$SMA_t = \frac{1}{k}\sum_{N=0}^{k-1} P_{t-n}$$

d.v.s.

$$SMA_t = \frac{P_t + P_{t-1} + \cdots + P_{(t-k+1)}}{k}$$

Exponentiellt glidande medelvärde.

Ett exponentiellt glidande medelvärde (nedan benämnt EMA) är en teknik för att hitta en trend i en tillgångs utveckling över tid och det är en prognosteknik, som är avsedd för en tidsserie, som i stort utvecklas efter en konstant nivå (Andersson et al. 2007). I den andra formeln nedan sätts k till det antalet dagar som trenden försöker hittas för. En kort trend kan till exempel sättas till 20 dagar, en medellång till 50 dagar och en längre till 100 alt 200 dagar.

I den första formeln är P det priset som gäller för tillgången idag och EMA_{t-1} är det värdet för EMA som beräknades en tidpunkt bakåt i tidsserien.

$$EMA = \alpha \cdot P_t + (1 - \alpha) \cdot EMA_{t-1}$$

Där:

$$\alpha = \frac{2}{k+1}$$

Analysen går till så att trenden för tillgången beräknas och uppdateras löpande allt med att tiden fortlöper. När en tillgång bryter sin trendkurva på uppsidan så indikerar det en

köpsignal för analytikern och bryter den ned under trenden en säljsignal. EMA beräknas, som kan ses ovan, rekursivt och den första iterationen kräver ett startvärde för EMA_{t-1}. Detta startvärde sätts till det glidande medelvärdet av de första k dagarna. Detta innebär att det krävs en viss startsträcka innan EMA blir korrekt (Eric, Andjelic and Redzepagic 2009)

MACD

Chen (2010) beskriver Moving Average Convergence Divergence (nedan benämnt MACD) som en metod som hittar uppåt alt nedåttrender alternativt divergenser i en pågående trend. MACD består ofta av följande mått:

- MACD-linjen: (12-dagars EMA - 26-dagars EMA)
- Signallinjen: (9-dagars EMA av MACD-linjen)
- Histogram: (MACD-linjen - signallinjen)

I måtten används beteckningen EMA för exponentiellt glidande medelvärde och om detta kan läsas under föregående punkt. Chen (2010) beskriver måttet som en kombination av en trendindikator, som beskrivits i de två föregående avsnitten, och en så kallad oscillator. Oscillator anger kraften i utbrottet från signallinjen och varierar mellan värdet 0 och 1.

Stokastisk oscillator

Chen (2010) beskriver även en annan typ av oscillator, vilket är den stokastisk oscillator, som används för att indikera lägen då marknaden anses vara ”överköpt” eller ”översåld”. Formeln för denna oscillator kan ses nedan:

$$\%K = \frac{Slutkurs - \text{Lägsta}_d}{\text{Högsta}_d - \text{Lägsta}_d}$$

Oscillatorn kommer variera mellan värdet 0 och 100 och vedertaget är att om den uppgår till ett värde högre än 80 anses tillgången vara tillfälligt överköpt. Understiger den 20 anses den vara undersåld. Ibland används följande formel för att hitta en trend i detta måttet.

$$\%D = 3\ dagars\ flytande\ medelvärde\ av\ \%K$$

Chen (2010) anger att ett vanligt sätt att använda metoden är att identifiera tillfällen då linjen för %K och linjen för %D korsar varandra. Till exempel korsar linjen %K linjen %D så anses det indikera en köpsignal och vice versa.

ROC

”Rate of change”, ROC eller förändringstakt är en indikator som kan användas inom teknisk analys. ROC ger för ett visst datum t och en viss aktie S förändringen i procent mellan stängningskursen för S och stängningskursen för samma aktie en viss period n bakåt i tiden likt följande formel nedan (Liu 2011):

$$ROC_t = 100 \cdot \frac{S_t - S_{t-n}}{S_{t-n}}$$

Om detta görs för en mängd olika t:n så utfås en oscillator som rör sig runt noll. En positiv utläsning tyder på en överköpt marknad medan en negativ utläsning tyder på en underköpt marknad. Formen på oscillatorns kurva beror på hur lång perioden (n) som används för beräkningen är. Om perioden är längre, till exempel om n är 20 börsdagar, kommer det bli en mjukare kurva.

Chaikin money flow index

Chaikin money flow index (nedan benämnt CMFI) utvecklades av Marc Chaikin och för att beräkna detta mått behövs aktiens A/D värde först tas fram (Narendra 2013). A/D står för Ackumulation/Distribution och räknas ut genom att volymen multipliceras med ett förhållande mellan högsta och lägsta värdet för en aktie under en dag samt slutkursen:

$$\frac{A}{D} = Volym \cdot \frac{(Slutkurs - Lägsta) - (Högsta - Slutkurs)}{Högsta - Lägsta}$$

För att sedan beräkna CMFI divideras summan av A/D med summan av volymen för samma period, ofta 21 löpande marknadsdagar. CMF för 21 dagar räknas ut enligt nedan:

$$CM\,F_{21} = \frac{A/D_{21}}{Volym_{21}}$$

Resultatet blir ett värde mellan 1.0 och -1.0. Alla resultat på den övre sidan av nollstrecket tolkas som positiva, och desto högre värde, desto starkare indikation.

Bilaga 3 – MAPE samtliga bolag efter kalibrering, nätverket tittar en dag bakåt och gör prognoser 1 dag framåt.

Aktie	MAPE
Getinge	3.19%
Autoliv	2.79%
Boliden	2.34%
SSAB	2.27%
Swedish match	2.23%
Tele2	2.22%
ABB	2.19%
Sandvik	2.17%
Astra	2.14%
HM	2.08%
Atlas	1.92%
Ericsson	1.92%
Skanska	1.81%
Volvo	1.81%
Hexagon	1.75%
Handelsbanken	1.69%
Kinnevik	1.69%
Assa	1.67%
Atlas	1.67%
Alfa	1.60%
Electrolux	1.49%
SKF	1.39%
Swedbank	1.38%
Nordea	1.27%
SEB	1.25%
Investor	1.20%
Securitas	1.20%
Telia	0.97%
Genomsnitt	**1.83%**

Bilaga 4 – MAPE samtliga bolag efter kalibrering, nätverket tittar tio dagar bakåt och gör prognoser femton dagar framåt.

Aktie	MAPE
HM	7.70%
Volvo	6.68%
Boliden	6.21%
Getinge	5.99%
SSAB	5.29%
Autoliv	5.28%
Ericsson	5.00%
Swedish match	4.95%
Atlas Copco A	4.65%
Tele2	4.47%
Alfa Laval	4.40%
Sandvik	4.31%
Hexagon	4.09%
SKF	4.04%
Atlas Copco B	4.01%
AstraZeneca	4.00%
Electrolux	3.57%
ABB	3.48%
Skanska	3.48%
Kinnevik	3.09%
Assa Abloy	3.06%
Nordea	3.01%
Handelsbanken	2.90%
Swedbank	2.71%
SEB	2.64%
Securitas	2.48%
Investor	2.43%
Telia	2.39%
Genomsnitt	**4.15%**

Bilaga 5 – Underlag val av ”optimizer” för LSTM implementation

Optimizer - mått MAPE								
Bolag	**adadelta**	**adagrad**	**adam**	**adamax**	**nadam**	**rmsprop**	**sgd**	**Medel totalt**
Ericsson	5.42%	5.24%	6.26%	5.80%	7.27%	5.74%	4.97%	5.81%
Autoliv	5.15%	5.40%	5.42%	5.53%	5.75%	5.48%	5.83%	5.51%
HM	2.55%	4.38%	5.90%	3.58%	7.59%	6.64%	5.54%	5.17%
Atlas Copco B	4.08%	4.42%	4.44%	4.16%	4.50%	4.12%	4.95%	4.38%
Boliden	2.35%	3.62%	5.06%	3.96%	4.94%	4.44%	2.98%	3.91%
Kinnevik	1.93%	2.97%	3.91%	3.65%	5.80%	4.12%	3.36%	3.68%
Atlas Copco A	1.86%	2.95%	3.11%	2.05%	3.61%	3.20%	3.45%	2.89%
Nordea	1.61%	2.42%	3.25%	2.42%	3.08%	2.94%	3.05%	2.68%
Alfa Laval	1.43%	2.39%	3.07%	2.31%	3.25%	3.53%	2.42%	2.63%
Securitas	1.57%	2.22%	2.59%	2.36%	3.23%	2.71%	1.77%	2.35%
Tele2	3.02%	2.09%	2.14%	1.64%	1.98%	2.98%	2.40%	2.32%
Medel totalt	1.61%	2.00%	2.24%	1.86%	2.49%	2.30%	2.50%	2.14%
SSAB	1.63%	1.94%	1.61%	1.78%	1.68%	1.84%	3.20%	1.95%
Volvo	1.40%	1.54%	1.58%	1.34%	1.69%	1.59%	3.48%	1.80%
Investor	1.26%	1.84%	1.77%	1.59%	1.68%	1.47%	2.03%	1.66%
Getinge	1.35%	1.43%	1.77%	1.39%	1.99%	1.44%	2.14%	1.64%
Assa Abloy	1.26%	1.65%	1.46%	1.41%	1.63%	1.57%	1.75%	1.53%
Swedish	0.91%	1.09%	1.29%	1.04%	1.54%	1.78%	2.12%	1.40%
Handelsbanken	1.32%	1.35%	1.24%	1.09%	1.44%	1.29%	1.89%	1.37%
SEB	1.04%	1.43%	1.39%	1.23%	1.21%	1.21%	1.80%	1.33%
Sandvik	1.17%	1.28%	1.24%	1.31%	1.35%	1.20%	1.73%	1.33%
ABB	1.26%	1.27%	1.27%	1.24%	1.21%	1.19%	1.72%	1.31%
Hexagon	1.13%	1.31%	1.05%	1.04%	1.15%	1.67%	1.79%	1.31%
SKF	1.18%	1.20%	1.16%	1.15%	1.24%	1.19%	1.91%	1.29%
Electrolux	1.14%	1.21%	1.14%	1.15%	1.14%	1.15%	1.80%	1.25%
Astra Zeneca	1.08%	1.21%	1.07%	1.02%	1.04%	1.04%	1.71%	1.17%
Skanska	0.97%	1.05%	1.02%	0.97%	1.03%	0.96%	1.49%	1.07%
Telia	0.90%	0.92%	0.94%	0.89%	0.88%	1.10%	1.84%	1.07%
Swedbank	0.88%	1.17%	0.97%	0.88%	0.90%	0.85%	1.67%	1.05%
Medel	**1.81%**	**2.17%**	**2.39%**	**2.06%**	**2.63%**	**2.44%**	**2.67%**	**2.31%**

Bilaga 6 – Underlag val av ”optimizer” för ANN implementation

TP	TN	FP	FN	Accruacy	Optimizer
75	1	42	0	64.41%	RMSprop
68	6	37	7	62.71%	SGD
72	2	41	3	62.71%	Adagrad
71	2	41	4	61.86%	Adadelta
70	3	40	5	61.86%	Adam
68	5	38	7	61.86%	Adamax
62	6	37	13	57.63%	Nadam

Bilaga 7 – Underlag val av antal epoker för ANN implementation

TP	TN	FP	FN	Accruacy	Epoker
78	1	33	0	65.18%	250
78	1	33	0	65.18%	500
78	1	33	0	68.75%	750
78	1	33	0	70.54%	1000
71	2	32	7	65.18%	1250
78	1	33	0	70.54%	1500
74	3	31	4	68.75%	1750
78	1	33	0	70.54%	5000
77	2	32	1	70.54%	5500
78	1	33	0	70.54%	6000
76	2	32	2	69.64%	6500
77	2	32	1	70.54%	7000
69	4	30	9	65.18%	7500