



CHALMERS

Fondrobotar, privatspararens bästa vän?

En kartläggning av dagens fondrobotar och studie på morgondagens AI integrerade portföljhantering

Kandidatarbete inom Industriell ekonomi

IDA HANSSON HÄGGSTRAND
GABRIEL LEVIN HANE
ANTON PETTERSSON

AXEL RAHM
AXEL RAMHULT
JONAS RÖST

**INSTITUTIONEN FÖR TEKNIKENS EKONOMI OCH ORGANISATION
AVDELNINGEN FÖR SCIENCE, TECHNOLOGY AND SOCIETY**

CHALMERS TEKNISKA HÖGSKOLA

Göteborg, Sverige 2022

www.chalmers.se

Kandidatarbete TEKX04-22-19

Fondrobotar, privatspararens bästa vän?

En kartläggning av dagens fondrobotar och studie på
morgondagens AI integrerade portföljhantering

Robo-Advisors, the Private Investor's Best Friend?

A Survey of Today's Robo-Advisors and a Study on
Tomorrow's AI Integrated Portfolio Management

IDA HANSSON HÄGGSTRAND
GABRIEL LEVIN HANE
ANTON PETTERSSON

AXEL RAHM
AXEL RAMHULT
JONAS RÖST

TEKNIKENS EKONOMI OCH ORGANISATION

Avdelning för Science, Technology and Society

CHALMERS TEKNISKA HÖGSKOLA

Göteborg, Sverige 2022

Fondrobotar, privatspararens bästa vän?

En kartläggning av dagens fondrobotar och studie på morgondagens AI integrerade portföljhantering

IDA HANSSON HÄGGSTRAND	AXEL RAHM
GABRIEL LEVIN HANE	AXEL RAMHULT
ANTON PETTERSSON	JONAS RÖST

© IDA HANSSON HÄGGSTRAND, 2022

© GABRIEL LEVIN HANE, 2022

© ANTON PETTERSSON, 2022

© AXEL RAHM, 2022

© AXEL RAMHULT, 2022

© JONAS RÖST, 2022

Kandidatarbete TEKX04-22-19

Teknikens ekonomi och organisation

Chalmers tekniska högskola

412 96 Göteborg

Sverige

Telefon + 46 (0)31-772 1000

Göteborg, Sverige 2022

Gothenburg, Sweden 2022

Fondrobotar, privatspararens bästa vän?

En kartläggning av dagens fondrobotar och studie på morgondagens AI integrerade portföljhantering

IDA HANSSON HÄGGSTRAND AXEL RAHM
GABRIEL LEVIN HANE AXEL RAMHULT
ANTON PETTERSSON JONAS RÖST

Department of Technology Management and Economics
Chalmers University of Technology

Summary

Problem: The use of robo-advisors has increased rapidly in recent years, as well as the number of robo-advisor services on the Swedish market. Due to the tendencies of stock markets to be volatile and uncertain, high pressure is put on the emerging form of savings in the form of risk and crisis management. A survey of robo-advisors is thus necessary to provide an opportunity to understand the automated form of savings that more and more customers are turning to.

Aim: The study aims to map today's robo-advisors on the Swedish market and create an understanding of how these handle fluctuations in the stock market. Furthermore, the purpose is to analyze how AI and machine learning can be implemented in robo-advisors, and its effects.

Method: The method used in the study can be divided into three parts; a literature study, an interview study and a delphi-study. The interview study was conducted to gather data for the mapping of today's robo-advisors, while the literature study and the delphi-study aimed to investigate future possibilities of AI and machine learning implementation.

Results and analysis: The results show that the degree of automation of today's robo-advisors differs. One similarity is that all surveyed robo-advisor companies use algorithms to profile their customers, while one difference is how potential holdings are analyzed. Furthermore, the results indicate that belief in how AI will be implemented and its effects varies. Discovered is also that data availability is a crucial factor to consider when discussing AI's ability to perform well.

Conclusion: The study shows that the degree of automation of the robo-advisors differs. The reason for this is the difference in investment philosophy and belief in the Efficient Market Hypothesis. To reduce risk, all robo-advisors use diversification. Rebalancing is used in some cases to manage risk, which correlates with their investment philosophy. In five years from now, AI will most likely function as an analysis tool. Furthermore, AI will not be able to predict stock market crashes within five to ten years from now because of the lack of required data.

Keywords: robo advisors, automated trading, fund management, portfolio management, artificial intelligence, fintech, investing, personal finance, finance

Note: The report is written in Swedish

Sammanfattning

Problem: Användningen av fondrobotar har under de senaste åren ökat kraftigt och antalet fondrobottjänster som erbjuds likaså. På grund av börsmarknaders tendenser att vara volatila och osäkra ställs höga krav på den framväxande sparformen i form av riskhantering och krishantering. En kartläggning av fondrobotar är således nödvändig för att ge möjlighet till förståelse för den automatiserade sparformen som fler och fler kunder vänder sig till.

Syfte: Studien syftar till att kartlägga dagens fondrobotar på den svenska marknaden och skapa en förståelse för hur dessa hanterar svängningar på börsmarknaden. Fortsättningsvis är syftet att analysera hur AI och maskininlärning kan implementeras i fondrobotar, samt dess effekter.

Metod: Metoden som använts i studien går att dela upp i tre delar; en litteraturstudie, en intervjustudie och en delfistudie. Intervjustudien genomfördes för att samla in underlag till kartläggningen av dagens fondrobotar medan litteraturstudien samt delfistudien hade som syfte att undersöka framtidsfrågor om implementation av AI och maskininlärning.

Resultat och analys: Resultatet visar att automatiseringsgraden hos dagens fondrobotar skiljer sig åt. En av likheterna är att samtliga undersökta fondrobotföretag använder sig av algoritmer för att profilera sina kunder, medan en skillnad är hur potentiella innehav analyseras. Vidare indikerar resultatet att tron på hur AI kan implementeras samt vilka effekter det skulle medföra varierar. Tydligt är även att datatillgänglighet är en avgörande faktor för AI:s prestanda.

Slutsats: Studien visar att fondrobotarnas automatiseringsgrad skiljer sig åt. Orsaken går att härleda till investeringsfilosofi och tron på Efficient Market Hypothesis. För att minska risk använder samtliga fondrobotar diversifiering. Ombalansering används i vissa fall för att hantera risk, vilket korrelerar med deras investeringsfilosofi. AI:s framtida påverkan kommer med stor sannolikhet bestå av att fungera som ett analysverktyg. AI kommer inte kunna förutse börskrascher inom en femårsperiod eftersom den inte har tillgång till all data som krävs.

Nyckelord: fondrobot, automatiserad trading, fondförvaltning, portföljhantering, artificiell intelligens, fintech, investering, privatekonomi, finans

Notera: Rapporten är skriven på svenska

Förord

När vi påbörjade arbetet strax efter årsskiftet till år 2022 hade vi i gruppen en tydlig bild av att vi ville undersöka kombinationen av vad vi tycker är två väldigt spännande ämnen. Dels finansbranschen som är så oerhört komplex och som i princip påverkar hela världens befolkning, både direkt och indirekt. Dels artificiell intelligens och maskininlärning där såg vi en hög innovationstakt och en kraftigt ökad kunskap. Vi hade en klar hypotes om att artificiell intelligens borde gå att integrera betydligt bättre i finans än vad som gjordes i dagsläget.

Vägen till den rapport som ni nu förhoppningsvis ska läsa har dock varit långt ifrån spikrak. Det har många gånger känts som att vi sprungit in i betongvägg på betongvägg utan större framgång att navigera rätt i två långt mer komplexa ämnen än vad vi kunnat föreställa oss. Hypotesen vi först hade har visat sig stämma mer eller mindre, men upptäckt problem och svårigheter där vi först inte anade att det fanns. Processen har varit givande, lärorik men framförallt väldigt kul. Vi känner att det enorma arbete vi lagt ner, till slut, har resulterat i en väldigt spännande rapport som vi nu kan dela med oss av.

Rapporten hade dock inte blivit det den är idag utan ett par nyckelpersoner. Vi skulle därför först vilja rikta ett stort tack till vår handledare på Chalmers, Erik Bohlin, som många gånger fått oss att lugna ner oss, ta ett steg tillbaka och gjort att vi kunnat se allt ur ett bredare perspektiv. Eriks erfarenhet inom rapportskrivande och forskningsmetodik har gjort att vi kunnat höja kvaliteten på rapporten ett par nivåer.

Vi vill även rikta ett stort och uppriktigt tack till Sverker Janson på RISE som väglett oss genom hela arbetet och som hela tiden utmanat oss. Sverkers stora engagemang och höga nivå har accelererat arbetet framåt vilket bidragit i hög grad till rapporten. Fortsättningsvis har Sverkers breda kunskap inom framförallt artificiell intelligens lett till många spännande diskussioner och gjort att vi kunnat gå vidare till nästa steg i processen snabbare än vad vi annars kunnat göra.

Avslutningsvis vill vi rikta ett stort tack till alla som ställt upp på intervjuer i rapporten samt till opponentgrupper som bidragit med värdefull feedback vid seminarier under processens gång. Tack!

Ordlista

Artificiell intelligens (AI) - Artificiell intelligens är förmågan hos maskiner och datorer att uppvisa mänskliga egenskaper. Detta görs genom att efterlikna kognitiva funktioner som exempelvis inlärning, generalisering, att förstå naturligt språk och till viss del även kreativitet.

Big Data - Begreppet avser stora och komplexa datamängder vilket kräver ny teknik, såsom AI, för att kunna bearbetas och analyseras.

Black Swan Events - Ett Black Swan Event är en oväntad händelse med stor påverkan som ej gick att förutse baserat på händelser som skett tidigare i historien.

Buy and Hold - Detta är en strategi där investeringar köps och sedan behåller dem under en lång tid, oavsett hur marknaden går. Viktigt i denna strategi är inte lägga värdering i hur innehavet utvecklas på kort tid.

Efficient Market Hypothesis (EMH) - En teori som menar att det är i princip omöjligt att slå marknaden kontinuerligt under en lång tid. Teorin utgår från att marknaden är effektiv och att all tillgänglig information används för att sätta rätt pris på tillgången som uppdateras i realtid. Eftersom all information används går de inte att slå marknaden kontinuerligt under en längre tid utan att detta endast sker på grund av slumpen.

Environmental, Social and Governance (ESG) - ESG handlar om hållbarhet i företagets affärsmodell, det vill säga hur dess produkter och tjänster bidrar till en hållbar utveckling.

Exchange Traded Fund (ETF) - En ETF, börshandlad fond på svenska, är en fond som är noterad på börsmarknaden. Därav handlas den precis som en vanlig aktie.

Fundamental analys - Begreppet avser en analys av ett företag med fokus på mjuka värden. Faktorer som hur personer på beslutsfattande personer agerar och upplevs, samt hur verksamheten fungerar dag till dag blir viktiga här. Även bolagets årsredovisning samt nyckeltal inkluderas i den fundamentala analysen.

Fondrobot - Fondrobotar är en sparform som utifrån en persons risktolerans automatiskt investerar dennes pengar i diverse sorters värdepapper.

Home Bias - En investerares vilja att investera oproportionerligt stor del av sin portfölj i inhemska innehav. En möjlig bieffekt kan vara att diversifiering förbises till fördel för inhemska innehav.

Index - Ett index mäter hur en samling värdepapper presterar. Värdepapperna i det givna indexet är oftast representativa för en viss del av marknaden.

Kvantitativ analys - Begreppet avser den analys av ett företag där faktorer som kan sättas i faktiska värden beaktas. Exempel på dessa är värden som står i en årsredovisning. Även teknisk analys innefattas i detta begrepp och som är ett samlingsnamn för grafisk information och utifrån den historiska kursutvecklingen för aktier och andra innehav försöka förutsäga den framtida utvecklingen.

Optioner - En option är ett värdepapper. Det den som utfärdat optionen som vid en förutbestämd tidpunkt i framtiden till ett förutbestämt pris kan köpa eller sälja något till den som har innehavaren. Det är endast optionsinnehavaren som är kan kräva att avtalet fullföljs.

Publik information - Den informationen som alla har tillgång till på nätet och även den information som en potentiell AI skulle kunna använda i sin beslutsfattning.

Privat information - Den information som skulle kunna fås vid en interaktion med en beslutsfattande person på ett företag. Exempel på sådan information är den känsla som en investerare kan få av en verksamhet eller av en beslutsfattare i ett företag vid ett besök. Privat information är viktig att skilja från inside information då inside information är illegal att agera på, något som privat information inte är.

SPY - SPDR S&P 500 EFT Trust är en av de mest populära fonderna vars mål är att följa de 500 large cap USA aktierna.

Innehållsförteckning

1. Introduktion	1
1.1 Problemformulering	2
1.2 Syfte	5
1.3 Frågeställning	6
1.4 Avgränsningar	6
2. Metod	7
2.1 Metodval	7
2.2 Litteraturstudie	8
2.3 Delfistudie	9
2.4 Intervjuer	9
2.4.1 Design och utförande av intervjuer	10
2.4.2 Respondenter	10
2.4.3 Analys av intervjuer	11
2.5 Metodkritik	12
3. Nyckelkoncept inom finans, statistik och maskininläring	14
3.1 Finansiella teorier	14
3.1.1 Modern Portfolio Theory (MPT)	14
3.1.2 Efficient Market Hypothesis	15
3.1.3 Value at Risk (VaR)	15
3.1.4 Sharpekvot	16
3.1.5 GARCH Process	16
3.1.6 Markov Switching Model	16
3.1.7 Hedging	17
3.2 Statistiska metoder och maskininläring	17
3.2.1 Ginis Mean Difference	17
3.2.2 Logistic regression	17
3.2.3 Maskininläring	17
4. Existerande forskning inom framtidens fondrobotar, portföljhantering och marknadssvängningar	19
4.1 Framtidens fondrobotar	19
4.2 Portföljhantering och marknadsutveckling	20
4.2.1 AI-integrerad portföljhantering och prediktiv modellering	20
4.2.2 Automatiserad avläsning av sociala medier för marknadsanalys	22
4.2.3 Portföljoptimering med avseende på marknadsfaser	23
5. Resultat	25
5.1 Kartläggning av den svenska fondrobotmarknaden	25
5.1.1 Lysa	26

5.1.2 Funder	29
5.1.3 Sigmastocks	32
5.1.4 BetterWealth	35
5.2 Intervjuer med fondförvaltare	38
5.3 Resultat av experters syn på AI integrerade fondrobotar om fem år	42
5.3.1 Fondrobotar om fem år	44
5.3.2 AI:s påverkan på portföljhantering inom fem år	47
5.3.3 AI:s förmåga att förutse och hantera börskrascher inom fem år	50
6. Analys	54
6.1 Analys av dagens fondrobotar	54
6.2 Framtidens fondrobotar	60
7. Slutsats	67
8. Avslutande reflektioner	69
8.1 Framtida forskning	69
8.2 Hållbarhets- och etikreflektion	69
Referenser	73
Appendix	84
Appendix 1. Kartläggningsfrågor	84
Appendix 2. Delfrågor	86

1. Introduktion

Sedan 1600-talet när de första moderna aktiebolagen skapades, har antalet aktiebolag ökat exponentiellt och aktiemarknaden ser ut på ett helt annat sätt nu än den gjorde då (Funnell & Robertson, 2012). Att spara i aktier och fonder har gått från att vara för samhällstoppen till att vara något för individer i alla samhällsskikt, vilket har gjort att det i Sverige under slutet på 2020 fanns ca 1,2 miljoner aktiesparare (SCB, 2021).

Antalet sätt att placera sina pengar är oräkneligt många och för en privatsparare kan det vara svårt att navigera i denna djungel. Med facit i hand är det lätt att se tillbaka över ett tidsintervall och se hur en optimal strategi skulle sett ut. Däremot är det med framtiden framför sig betydligt svårare att veta vilken strategi som kommer lyckas till följd av att marknaden är extremt komplex.

På lång sikt har sannolikheten att börsen stiger varit hög (RikaTillsammans, 2020). Historiska data har dock visat att det marknaden är betydligt mindre förutsägbar på kort sikt, vilket belyser riskerna och svårigheterna med att ha pengarna på börsen. Exempelvis har Stockholmsbörsen, SIX Return Index (SIXRX) som anses vara det mest rättvisande indexet på Stockholmsbörsen, haft en genomsnittlig årsavkastning på 9,24 % mellan år 1870-2019 (RikaTillsammans, 2020). Under samma tidsintervall har standardavvikelsen varit 19,8 % och med ett konfidensintervall på 95 % har utfallet under ett enskilt år under tidsperioden varierat mellan - 28,6 % till + 50,5 %, en spridning på 79,1 procentenheter (RikaTillsammans, 2020).

För att underlätta för privata investerare att göra så bra investeringsval som möjligt erbjuds flera tjänster. Kombinationen av att finansbranschen kan vara svårförståelig, att kunder vill undvika onödiga risker samt att det under en lång tidsperiod inte gick att komma åt börserna som privatperson har gjort att det alltid funnits börsmäklare (Klimashousky, 2021). Det finns olika typer av börsmäklare, men undantagslöst är att alla tar ett arvode för sina tjänster, där den procentuella arvodessatsen både beror på status på mäklare men framför allt hur aktivt rådgivningen sker. En annan populär sparform är fonder, där fondförvaltare tar ett arvode för sin tjänst. Något som är anmärkningsvärt är att många fonder tar en höjd ersättning för överavkastning. Det vill säga, slår fonden index så tar fondförvaltaren extra betalt (Finansinspektionen, 2006).

En relativt ny tjänst som fått mycket uppmärksamhet och allt fler användare är fondrobotar. Fondroboten placerar kunders pengar utifrån en given etik- och riskstrategi men där företagen har valt att diversifiera sina produkter beroende på vilken investeringsfilosofi som skaparna har (Fisch et al., 2019). Anledningen till att denna typ av robotar har börjat användas är flera. En väsentlig del som möjliggjort tjänsten är den ökade digitaliseringen och automatisering av börser där köp och säljorder genomförs per automatik (Park et al., 2016; Shanmuganathan, 2020). Andra centrala delar till fondrobotarnas frammarsch är förmågan att förvalta pengar och placera i tillgångar utan subjektiva värderingar samt att de kan göra det till en lägre avgift än vad en konventionell börsmäklare gör. En nackdel skulle vara att de endast kan köpa och sälja med avseende på ett fåtal parametrar som sällan ger en helt korrekt bild av hur verkligheten ser ut (Fein, 2015; Jung et al., 2018). Men hur fungerar fondrobotar egentligen och hur hanterar de kraftiga svängningar på börserna?

Samtidigt som fondrobotarna har introducerats på den svenska marknaden sker det stora tekniska framsteg inom artificiell intelligens (AI) och maskininlärning, vilket somliga fondrobotarna till viss del använder idag. Skulle en utvecklad AI och maskininlärning kunna integreras i tjänsten för att hantera marknadssvängningar bättre än i dagsläget, eller till och med förutspå börskrascher, trots den höga komplexiteten i marknaden?

Hur fondrobotar på den svenska marknaden fungerar är ett relativt outforskat område. Informationen som finns kring tjänsterna går främst att hitta på respektive företags hemsida och det finns heller inte någon standard för hur fondrobotföretagen ska förklara sina tjänster för kunderna. Denna problematik kan således göra tjänster svåröversämblika samt svåra att jämföra med varandra.


1.1 Problemformulering

Till följd av att fondrobotar genomgått en stor utveckling de senaste åren på den svenska marknaden, från introduktionen i början på 2010-talet till den pågående etableringen där tjänsterna får allt fler kunder, är det av vikt att göra en kartläggning av hur tjänsterna faktiskt fungerar. Detta är nödvändigt för att privatsparare i form av gamla- och potentiella kunder ska förstå tjänsten till fullo med både styrkor, svagheter, möjligheter och begränsningar.

En viktig del att granska när en spartjänst ska kartläggas är hur riskhanteringen ser ut. Att hantera en portfölj när marknaden går bra är sällan svårt, eftersom de flesta branscherna går positivt. Det är då snarare en fråga om hur mycket positiv avkastning portföljen genererade. Istället blir det viktigt att se vilken risk en portfölj har när marknaden inte längre går bra, eller om det oväntade sker. Marknadsrisken är svår att undvika men risker som en portfölj istället kan ha, och bör parera, är risker som till exempel koncentrationsrisk med korrelerade tillgångar, ränterisk och politisk risk (Nordea, u.å.).

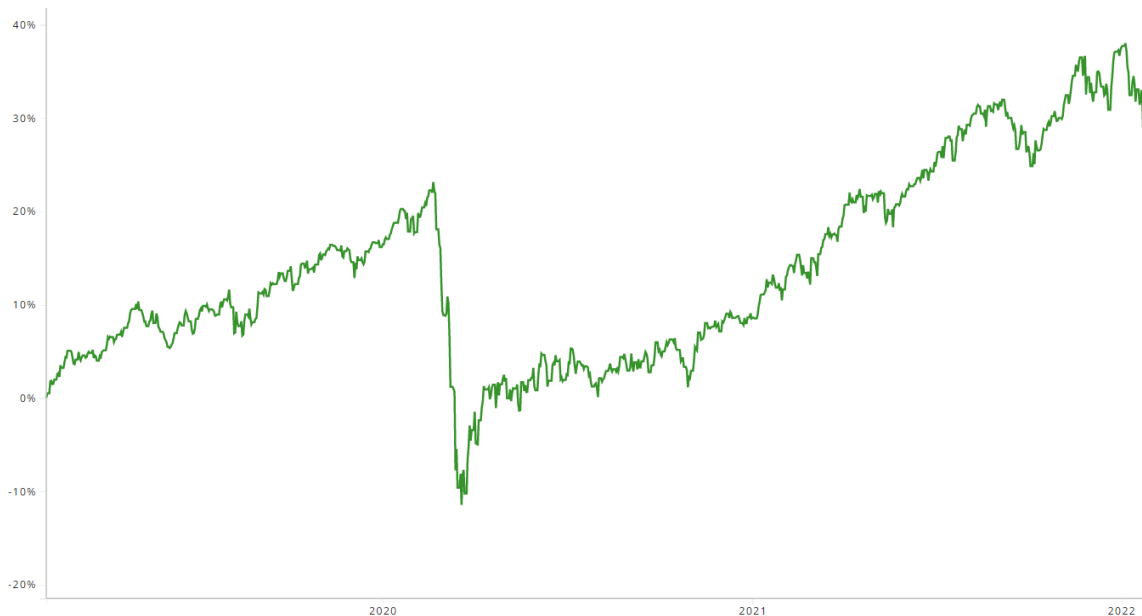
Ett exempel på när marknaden var instabil är år 2020 då Stockholmsbörsen hade sitt största fall någonsin till följd av ett ras i förväntningar på ekonomin i stort efter att World Health Organization (WHO) meddelade att SARS-CoV-2 klassades som en pandemi (Rognerud, 2020; Mazur et al., 2021). Händelserna på aktiemarknaden mellan februari och april 2020 var något som aldrig hade skådats tidigare. Världen över rasade aktiepriser i magnituder som var större än tidigare krascher vilket orsakade några av de största intradagsfallen någonsin på index, däribland S&P500 och Dow Jones (Blakeley, 2020; Daube, 2020). Händelserna väckte stor oro hos investerare och ledde till att många sålde i panik vilket i sin tur förvärra konsekvenserna på aktiemarknaden (Mahata et al., 2021). Stockholmsbörsen återhämtade sig dock efter nedgången och slutade 2020 cirka 6 % upp (Nasdaq OMX Nordic, u.å.).

Tydligt är att svenska fondrobotar som grupp inte förutspådde börsrasen 2020. Samtliga aktörer föll i samband med raset och alla var även, mer eller mindre med på den kraftiga uppgången som skedde kort därefter. Detta går att se i *figur 1* som visar hur fondroboten Funder (turkost) gick jämfört med ett jämförelseindex (streckad linje) under samma treåriga tidsintervall.



Figur 1. Fundlers avkastning (turkost) och jämförelseindex (streckad linje) under perioden mellan februari 2019 och februari 2022 (Fundler, 2022a).

Ett av företagen vars fonderbotar presterade sämre än det svenska indexet OMXS30 år 2020 var BetterWealth och i synnerhet deras så kallade dynamiska portföljer. Avkastning från dessa slutade 2020 i intervallet -0,3 % och -6,8 % medan OMXS30, som nämnts tidigare, slutade cirka 6 % upp (BetterWealth, u.å.). I *figur 2* visas utvecklingen för den dynamiska portfölj med högst risk, vilket även var den dynamiska portfölj som presterade sämst under 2020. (BetterWealth, u.å.). Dessa dynamiska portföljer använder sig bland annat av maskininlärning för att utföra analyser och utifrån dessa konstruera samt ombalansera portföljerna (BetterWealth, 2021). Drömmen om det perfekta sparandet, att kunna sälja eller balansera om portföljen precis innan ett stort ras för att sedan köpa in sig på marknadens botten för att maximera avkastningen är således fortfarande en dröm.



Figur 2. BetterWealths avkastning för deras portfölj dynamisk 7 (VaR 25 %), under perioden februari 2019 och februari 2022 (BetterWealth, 2022).

Samtidigt sker det stora framsteg inom AI och maskininläring. Tekniker som eventuellt skulle kunna implementeras i finansbranschen på flera ställen. Det är därför intressant att se hur mycket AI och maskininläring som implementeras i dagsläget samt hur AI och maskininläring skulle kunna implementeras i framtiden för att hantera liknande krascher eller stora marknadssvängningar som den år 2020.

1.2 Syfte

Studiens syfte är att undersöka hur dagens fondrobotar fungerar tekniskt samt hur de hanterar stora svängningar på börsmarknaden. Vidare ämnar studien att undersöka vilken utvecklingspotential framtidens fondrobotar har och om de kan komma att prognostisera en stor svängning på börserna likt den som skedde i samband med SARS-CoV-2 utbrott. Avslutningsvis är syftet att undersöka om det går att motverka marknadsnedgångar genom användningen av AI och maskininläring.

1.3 Frågeställning

Med bakgrund i det syfte som har presenterats är frågeställningarna i arbetet således:

- Hur fungerar dagens fondrobotar på den svenska marknaden och hur hanterar de kraftiga svängningar på börsmarknaden likt den år 2020 i samband med att SARS-CoV-2 klassificerades som en pandemi?
- Hur skulle AI integrerade fondrobotar om fem år kunna hantera liknande situationer där det sker stora förändringar på börsmarknaden?

1.4 Avgränsningar

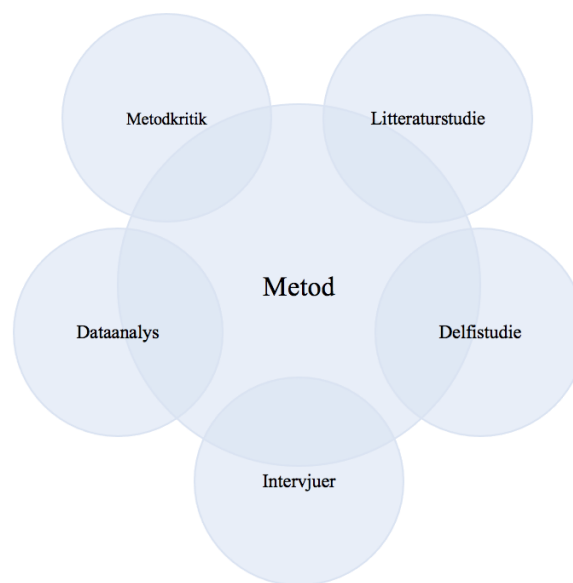
Tidsintervallet som framtidsfrågorna kommer att behandla är fem år. Anledningen till detta är att ett längre tidsperspektiv blir för svårt att undersöka. Beroende på hur den tekniska utvecklingen fortgår inom olika områden blir antalet olika utfall fler och osäkerheten hög kring vad som faktiskt är troligt. Det finns därför hög risk att resultatet skulle kunna bli vagt eller inte kunna fastställas med tillräckligt hög signifikansnivå.

Fortsättningsvis kommer rapporten enbart behandla de fondrobotar som i regel sköter ett långsiktigt sparande. Begreppet high frequency trading och allt som inkluderas i konceptet kommer alltså inte att undersökas. Vidare kommer enbart fondrobotar som i grunden har börsinnehav att undersökas. Det som inkluderas är alltså robotar som i huvudsak hanterar aktier, fonder eller andra börshandlade tillgångar. Robotar som hanterar enbart kryptovalutor, Non Fungible Tokens (NFT), Over The Counter (OTC)-innehav, icke-reglerade råvaror eller andra tillgångar som inte finns på en reglerad börs kommer alltså inte att undersökas.

Avslutningsvis kommer enbart svenska fondrobotbolag att undersökas. Anledningen till detta är för att få en mer homogen grupp av intervjuobjekt. Orsaken till att en svensk grupp kan ses som mer homogen är för att företagen är verksamma inom samma land med snarlika produkter vilket borde innebära att externa faktorer är snarlika. Skillnaden i hur företagen opererar blir således skillnader i strategi eller teknik snarare än olikheter orsakade av externa faktorer.

2. Metod

I detta avsnitt beskrivs den metodik som har använts för att besvara arbetets frågeställning och syfte. Metoden har delats upp i delmomenten litteraturstudie, delfistudie, intervju, dataanalys och metodkritik. Avslutningsvis förs en diskussion kring val av metod. I *figur 3* illustreras de delar metoden består av i en schematisk figur. Metoden har valts för att kunna identifiera och analysera AI:s eventuella framtida implementering inom fondrobotar samt att kartlägga hur dagens fondrobotar ser ut.



Figur 3. En schematisk figur av metodens centrala delar.

Metodens delar har inte utförts linjärt då information och kunskap har adderats under arbetets gång och därmed har gjort att delar i metoden har skett parallellt. Under arbetets gång har även kontakt hållits med handledare och expert inom artificiell intelligens för att handleda gruppen genom rapportskrivandet för att möjliggöra en så bra rapport som möjligt.

2.1 Metodval

Arbetet har använt en kvalitativ forskningsmetod, vilket inneburit att analysen har utformats av semistrukturerade data. På grund av valet av forskningsmetod har intervjuer med öppna frågor kunnat användas (David & Sutton, 2016).

Vidare har studien även varit av utforskande karaktär. Ellram (1996) beskriver hur utforskande forskning vanligtvis besvarar frågor som “hur” och “varför” någonting sker. Denna typ av studie passar väl in för att besvara frågeställningen då den utforskande formen hjälper till att besvara hur fondrobotar fungerar idag och hur de hanterar kraftiga marknadssvängningar. Även den andra frågeställningen besvaras med en utforskande metod som undersöker hur AI kan implementeras i framtidens fondrobotar samt varför implementation kommer ske i större eller mindre utsträckning.

Metodperspektivet som används i denna rapport är av abduktiv karaktär vilket innebär en kombination av en deduktiv och induktiv studie (Reichertz, 2010). En induktiv studie används främst vid kvalitativa studier med ett tydligt teoretiskt ramverk (David & Sutton, 2016). Deduktiv är motsatsen och används istället när en förutbestämd hypotes finns och syftet då är att bekräfta eller motbevisa denna hypotes. Då denna studie utgår från både en förutbestämd teori samt erfarenhet och kunskap från respondenter är denna studie således abduktiv.

2.2 Litteraturstudie

En litteraturstudie användes, vilket enligt Snyder (2019) är användbart för att få en överblick över specifika frågeställningar. Syftet med denna studie är att utforska hur fondrobotar fungerar idag och hanterar kraftiga svängningar på börsen, samt om AI skulle kunna integreras i framtiden. Med detta syfte har litteratur om artificiell intelligens och finansiella teorier presenterats i avsnitt 3 och 4 för att ge förståelse samt ytterligare perspektiv till analysen.

Litteraturstudien genomfördes med semistrukturerade sökningar i Scopus och Google Scholar. Semistrukturerad sökning innebär att sökningen sker över flera områden och inte strikt måste innefattas i ett specifikt forskningsområde. Snyder (2019) beskriver att detta upplägg är det mest föredragna sättet att strukturera upp sökningar när ämnet är brett och studeras av flera olika grupper av forskare. Litteraturstudien har delats upp i två centrala områden för arbetet; framtidens fondrobotar samt portföljhantering och marknadsutveckling.

Relevanta nyckelord som använts som utgångspunkt vid sök av litteratur var följande: “robo advisors”, “AI”, “journal of financial data analytics”, “portfolio”, “finance”, “robo advisor

active management”, “portfolio management”, “use case”, “rebalancing portfolio”, “machine learning” och “reinforcement learning”.

Tillsammans med de semistrukturerade sökningarna har samtal med insatta inom området gjort att ytterligare artiklar hittades. De artiklar som ansågs mest relevanta användes därefter för att jämföra med respondenternas svar från intervjuerna.

2.3 Delfistudie

För att svara på studiens andra frågeställning om hur framtidens fondrobotar kommer att fungera har en delfistudie använts. Turoff och Linstone (2002) beskriver att en delfistudie är en prognosmetod som används för att analysera komplexa problem. En expertgrupp samlas ihop för att kunna uttrycka sina åsikter. Enligt Melander et al (2019) är det vanligaste syftet med en delfistudie att få någon form av samstämmighet bland experterna eller få bättre uppfattning om olika experters åsikter. Det är även syftet med denna studie vilket gjort att en delfistudie använts.

Två intervjuomgångar har hållits med experter inom AI, fondrobotar samt traditionella fondförvaltare. Syftet med den första intervjun var att få en förståelse för hur experter med olika synvinklar tror att fondrobotar kommer att utvecklas. Efter att första intervjun med samtliga experter hållits, sammanställdes intervjuerna i skalor beroende på hur positivt inställda de var till artificiell intelligens i framtidens fondrobotar.

Inför den andra intervjun skickades denna sammanställning ut till respondenterna för att på den andra intervjun se om sammanfattningen stämde överens med den bild de hade av första intervjun samt om de ändrat åsikt efter att ha läst vad andra experter svarat på samma frågor. Några intervjuobjekt hade inte möjlighet att ställa upp på en andra intervju fysiskt och valde därför att svara på frågorna i skrift istället.

2.4 Intervjuer

Intervjuer används ofta för att få in stora mängder information, åsikter och erfarenhet från ett fåtal personer (David & Sutton, 2016). Vidare är intervjuer ofta ett effektivt sätt att få in information och bidrar till en djupare förståelse.

I detta kandidatarbete har intervjuer använts för att få en bredare förståelse för fondrobotar och hur dessa fungerar. Intervjuobjekten som har valts för att uppnå denna förståelse är de fyra svenska fondrobotbolagen BetterWealth, Funder, Lysa samt Sigmastocks. För att få en djupare förståelse för hur AI kan implementeras i framtiden har intervjuer hållits med tre olika parter; traditionella fondförvaltare, fondrobotförvaltare samt AI-experter. Anledningen till att dessa grupper valts ut är för att få olika perspektiv och föreställningar av framtiden.

2.4.1 Design och utförande av intervjuer

I denna studie har halvstrukturerade intervjuer använts. Både öppna och slutna slutfrågor har utgjort intervjumaterialet. Ofta har dessa frågor följts av följdfrågor i form av hur och varför. David och Sutton (2016) beskriver att genom att använda sig av följdfrågor kan intervjuaren lättare styra intervjun åt en specifik riktning. Intervjuerna blev därmed mer som konversationer än formella intervjuer vilket bidrog till en mer avslappnad stämning och till att mer högkvalitativa svar kunde erhållas.

Förberedelsefasen bestod av att hitta lämpliga experter att intervjua inom de tre valda områdena. Detta arbete gjordes främst via mejl och telefon där en kortare beskrivning av projektet och dess syfte presenterades. När kontakt hade etablerats skickades frågorna över på förhand till respondenten så att denne kunde förbereda sig inför intervjun. Mall över frågor hittas i appendix.

De flesta intervjuer hölls online via plattformarna Microsoft Teams eller Zoom då det geografiska avståndet till respondenterna var stort. En intervju hölls fysiskt på plats. På intervjuerna medverkare mellan tre och sex gruppmedlemmar vilket gjorde att fler perspektiv i form av följdfrågor kunde fås med. Respondenterna var tillfrågade om det var möjligt att spela in intervjun vilket majoriteten tillät. Anteckningar togs även under samtliga intervjuer.

2.4.2 Respondenter

Här presenteras varför studien valt att använda oss av fyra fondrobotbolag, tre fondförvaltare respektive tre AI-experter. I *tabell 1* presenteras de intervjuer som utförts.

Intervjuerna har hållits med experter inom området där respondenterna kategoriserats upp i tre kategorier; fondrobotförvaltare, fondförvaltare respektive AI-expert. För att få en bättre

förståelse för de olika grupperna och deras perspektiv har antalet respondenter i respektive grupp bestämts till fyra fondrobotbolag, tre fondförvaltare respektive tre AI-experter. Dessa gruppstorlekar har valts för att minska risken för partisk information samt för att få ett bredare perspektiv. För att få ytterligare förståelse och kunna hitta mönster i intervjuobjektens uttalanden utformades en andra intervju i form av en delfistudie där experterna endast svarade på delfrågorna. Delfrågorna var en delmängd av samtliga frågor, vilket går att se i bilaga 2. Det är viktigt att notera att respondenterna inte svarade för de bolag som de representerar när delfrågorna besvarades utan som en egen person.

Tabell 1. Tabell över intervjuerna som hållits och information om respektive intervjuobjekt.

Intervjuer							
Respondent	Företag	Kategori	Titel	Datum intervju 1	Längd intervju 1 (min)	Datum intervju 2	Längd intervju 2 (min)
Ahrner, Ulf	Fundler	Fondrobotförvaltare	Grundare och investeringsansvarig	5 april 2022	60	21 april 2022	Mailsvar
Björklund, Oscar	Lysa fonder	Fondrobotförvaltare	VD	4 mars 2022	90	21 april 2022	15
Elliot, Viktor	Göteborgs Universitet	AI-expert	Doktor företagsekonomi	23 mars 2022	60	20 april 2022	30
Jönsson, Henrik	Better Wealth	Fondrobotförvaltare	Medgrundare och investeringsansvarig	16 mars 2022	45	28 april 2022	30
Lee, Francis	Chalmers Tekniska Högskola	AI-expert	Docent och forskare	8 april 2022	45	25 april 2022	30
Lindberg, Carl	Sigmastocks	Fondrobotförvaltare	Medgrundare och investeringsansvarig	29 mars 2022	60	27 april 2022	Mailsvar
Listo Zec, Edvin	RISE	AI-expert	Doktorand med fokus på federated learning och distribuerad maskininlärning	6 april 2022	60	20 april 2022	15
Skoglund, Fredrik	Spiltan Fonder	Fondförvaltare	Assisterande förvaltare och analytiker	13 april 2022	30	26 april 2022	Mailsvar
Stenkil, Fredrik	Swedbank	Fondförvaltare	Portfolio manager-Swedbank Robur	22/ mars 2022	60	21 april 2022	Mailsvar
Westfeldt, Stefan	Vinga Coperate Bond	Fondförvaltare	Principal PM	21 mars 2022	90	27 april 2022	Mailsvar

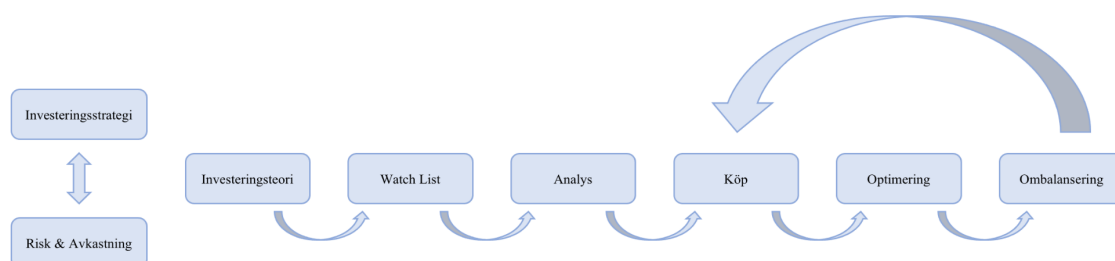
2.4.3 Analys av intervjuer

För att svara på rapportens första frågeställning har data från fondrobotarnas hemsidor samt whitepapers hämtats. Intervjuerna med respektive fondrobotföretag har använts för att komplettera denna data och även förtydliga informationen. För den andra frågeställningen och delfistudien har Systematic Text Condensation (STC) använts för att hitta mönster och

förstå framtidens frondrobotar. STC är ett analysverktyg som används för utvärdering av kvalitativa data.

De intervjuer som utförts i syfte att få en förståelse för hur fondrobotar på den svenska marknaden fungerar idag har transkriberats och sammanställts. Transkriberingar strukturerades i enlighet med den investeringsmodell som gruppen tagit fram, vilket innebar att varje del från investeringsmodellen motsvarade en underrubrik. Investeringsmodellen presenteras nedan i *figur 4*. Genom att transkribera på detta vis kunde likheter och skillnader lättare upptäckas när intervjumaterialet skulle analyseras.

Investeringsmodellen togs fram i syfte att etablera en gemensam grund under intervjuerna. Genom att utgå från investeringsmodellen när frågor ställdes kunde det säkerställas att intervjuobjektet höll sig inom ramen för vad som efterfrågades. Vidare byggdes även frågemallen som användes under intervjuerna med fondrobotföretagen upp utifrån den framtagna investeringsmodellen. Frågemallen strukturerades på detta vis för att underlätta sammanställningen av den data som samlades in under intervjuerna. Nämnvärt är att samtliga intervjuobjekt godkände och validerade investeringsmodellen.



Figur 4. Gruppens framtagna investeringsmodell

För att kunna analysera delfiintervjuerna systematiskt har även dessa transkriberats. Svaren från intervjuerna kategoriserades och sammanfattades därefter under nyckelrubriker. För att göra det har STC metoden använts, vilket är en metod i fyra steg. Malterud (2012), som tagit fram STC, beskriver att det första steget går ut på att få en överblick av den insamlade datan genom att kategorisera dessa i olika kategorier som därefter kan kopplas till studiens frågeställning. Det är då av vikt att inkludera mer information än som vid första anblick kan tyckas behövas för att inte riskera att exkludera viktig information. Då nyckelkoncepten var

identifierade sammanlänkades dessa med frågeställningen. Malterud (2012) beskriver hur detta steg är av stor vikt för att kunna hitta mönster och dra korrekta slutsatser i det sista steget som är att beskriva de koncept som den samlade informationen givit.

2.5 Metodkritik

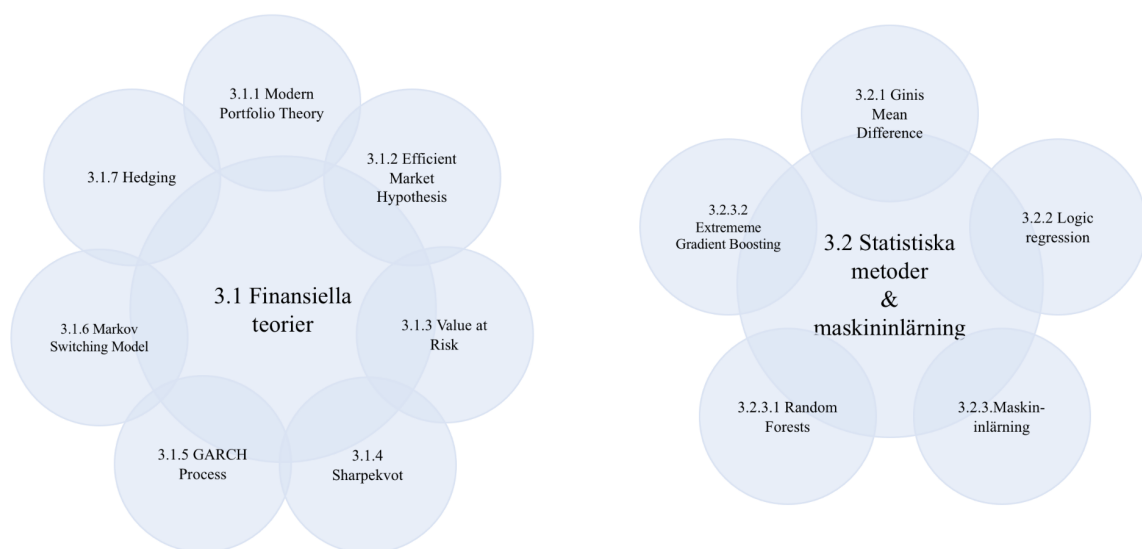
Under denna rubrik presenteras metodkritik. Detta görs för att ge en förståelse kring vilka brister som funnits i studiens utförande samt hur dessa kan undvikas om studien utförs igen.

Det finns enligt Bryman (2011) tre huvudsakliga risker med kvalitativ studie. Den första är att den kvalitativa studien blir för subjektiv. Detta problem orsakas av att studiens författare inte kan strukturera informationen på ett bra sätt och vad de anser är väsentlig information och inte. Information från intervjuer kan därmed tas emot olika beroende på vem personen som tolkar informationen är och kan främst bli ett problem vid fastställning av resultatet. Det andra problemet menar Bryman (2011) är att forskare ofta har ett intresse i sin forskning vilket ger svårighet att återskapa studien. Den tredje och sista risken är svårighet med transparens som har att göra med svårigheten att tydligt formulera hur studien utfördes samt planerades (Bryman, 2011).

För att minska risken att studien blir subjektiv har handledare från Chalmers tekniska högskola samt handledare från RISE varit med under arbetets gång vilket gjort gruppen medveten om hur informationen skulle struktureras. Under delfistudien har experter med olika bakgrund intervjuats för att öka möjligheten att få in olika vinklar i resultatet och på så sätt minska risken för ensidig information. En delfistudie är dock beroende av experter och deras åsikter vilket kan ses som en negativ aspekt till valet av metod. Valet av experter gjordes för att försöka motverka att resultatet av delfistudien skulle bli partiskt. För ett bredare perspektiv och minska risken för partisk information ytterligare hade fler intervjuer med experter behövt hållas. Genom detta metodavsnitt och tydlig beskrivning av arbetsprocessen har även det sista av de eventuella problemen försökt förhindras.

3. Nyckelkoncept inom finans, statistik och maskininläring

I följande avsnitt presenteras den teoretiska bakgrunden som krävs för att läsa resultatet samt förstå efterföljande analys. Först förklaras finansiella teorier om portföljhantering, effektiva marknader och finansiell risk. Därefter presenteras statistiska metoder som används för att mäta skillnader mellan modell och resultat. Avslutningsvis presenteras även ett urval av maskininlärningsmetoder. Samtliga koncept som förklaras i detta avsnitt åskådliggörs i *figur 5*.



Figur 5. En schematisk figur över den teoretiska bakgrundens centrala delar.

3.1 Finansiella teorier

Litteraturen kring finansiella teorier är omfattande. I detta avsnitt presenteras ett urval av portföljteorier, finansiella teorier samt finansiella mått som är relevanta för detta arbete. Urvalet har gjorts baserat på den data som erhållits i studierna som utförts.

3.1.1 Modern Portfolio Theory (MPT)

Modern Portfolio Theory (MPT) är en praktisk metod som beskriver hur maximal utdelning för en given risk uppnås i en portfölj (Markowitz, 1971). MPT beräknar hur stor andel varje tillgång har i portföljen för att uppnå optimal avkastning med hänsyn till risk. Enligt

Markowitz (1971) är risk sannolikheten att en förlust uppstår. En tillgång med stor varians har därför större sannolikhet till förlust och bör därför betraktas som mer riskfyllda (Francis & Dongcheol, 2013).

MPT anser samtidigt att en tillgång inte ska värderas i dess isolation utan bör värderas tillsammans med hela portföljen. På så sätt kan en ökad avkastning uppnås utan att portföljens hela risk ökar menar Markowitz (1971). MPT beskriver diversifiering som ett kraftfullt verktyg eftersom olika tillgångar har olika nivåer av korrelation och antingen positiv eller negativ kovarians med varandra (Markowitz, 1971). Kovarians och korrelation beskriver hur två tillgångar samverkar och kan förändras över tid, under en börskrasch ökar vanligtvis korrelationen mellan tillgångar (Chesnay & Jondeau, 2001; Loretan & English, 2000).

3.1.2 Efficient Market Hypothesis

Efficient Market Hypothesis (EMH) som är framtagen av Eugene Famas 1970, menar att det är i princip omöjligt att slå marknaden kontinuerligt under en lång tid (Corporate Finance Institute, u.å.). I artikeln menar Famas att marknaden är effektiv och att all tillgänglig information används för att sätta rätt pris på tillgången som uppdateras i realtid. Eftersom all information används går det inte att slå marknaden kontinuerligt under en längre tid utan att detta endast sker på grund av slumpen (Nath, 2015). Teorin är inte vedertagen utan olika investerare har olika syn och tilltro till EMH.

3.1.3 Value at Risk (VaR)

Value at Risk (VaR) är det mest använda måttet på marknadsrisk inom finansbranschen och definieras som en låg kvantil i fördelningen av finansiella vinster och förluster (Lauridsen, 2000). Måttet används för att kunna se hur stor finansiell risk en aktör tar på en marknad. VaR för en aktörs portfölj är en låg kvantil av fördelningen av vinster och förluster på portföljen. Exempelvis kan det vara 5 % kvantilen av fördelningen under en dag, vilket brukar kallas för 95 %, 1 dagars VaR. Detta kan tolkas som att nivån på VaR, alltså en given endagsförlust, kommer att överträffas en gång var 20:e dag. Riskmålet VaR säger dock inget om hur stor den förväntade förlusten eller hur stor den maximala förlusten kan vara om VaR överträffas, enbart sannolikheten att den överträffas (Lauridsen, 2000).

3.1.4 Sharpekvot

Sharpekvoten är ett mått som används för att räkna ut riskjusterad avkastning (Sharpe, 1998). En portfölj med hög sharpekvot jämfört med andra portföljer indikerar på bättre riskjusterad avkastning (Sharpe, 1998). Sharpekvot för en portfölj beräknas enligt ekvation 1 nedan:

$$\text{Sharpekvot} = \frac{R_p - R_f}{\sigma_p} \quad (1)$$

I ekvation 1 står R_p för portföljens avkastning, R_f för avkastningen från riskfria tillgångar och σ_p för portföljens volatilitet (Sharpe, 1998).

3.1.5 GARCH Process

Generalized Autoregressive Conditional Heteroskedasticity (GARCH) är en statistisk modell som är vanligt förekommande för att estimeras framtida volatilitet i finansiella marknader. Institutioner använder modellen för att estimeras volatiliteten för avkastning av aktier, obligationer och marknadsindex (Engle, u.å.). Genom att använda den statistiska modellen kan analyser av olika typer av finansiell data göras för att bestämma priset på tillgången. Därefter kan undersökningar göras för att finna vilka tillgångar som kommer att ge högst avkastning och därefter optimera portföljen utefter denna information (Engle, u.å.).

3.1.6 Markov Switching Model

Song och Woźniak (2021) beskriver att det finns en familj av olika Markov Switching modeller som baseras på tidsvariationen som i sin tur avspeglar i vilket stadium marknaden befinner sig i. Tidsvariationerna grundas i av en underliggande stokastisk process. Denna process har begränsat minne och tar endast hänsyn till det nuvarande värdet och genom att använda Markov property, vilket är definitionen av Markov property (Song & Woźniak, 2021). Författarna skriver att med hjälp av en övergångsmatris av Markov processen kan sannolikheten för att varje nästa stadi ska inträffa beräknas med avseende på den nuvarande fasen. Det finns flertalet fördelar med denna typ av modell, den möjliggör estimering av sannolikheten för ett stadi i nästa fas med hjälp av den nuvarande fasen. Estimeringen gör det i sin tur möjligt att förutspå parametrar som associeras med en viss marknadsfas vilket kan användas till sin fördel (Song & Woźniak, 2021).

3.1.7 Hedging

Hedging är en strategi för investerare att hantera risken hos tillgångar (Corporate Finance Institute, u.å.). Strategin kan dessutom användas för att minska förluster under marknadsnedgångar (Boyabatli & Toktay, 2004). Implementation av strategin görs genom att investera i tillgångar som uppvisar låg korrelation mot huvudtillgången, vilket kan åstadkommas på flera sätt (Boyabatli & Toktay, 2004). Bland annat kan investeringar göras i optioner eller tillgångar som visat sig vara säkra i specifika marknadsfaser.

3.2 Statistiska metoder och maskininlärning

I detta avsnitt presenteras två statistiska metoder, Ginis Mean Difference och Logistic regression. Även centrala begrepp inom maskininlärning såsom Random Forests och Extreme Gradient Boosting presenteras.

3.2.1 Ginis Mean Difference

Ginis Mean Difference är ett statistiskt mått på spridning. Måttet definieras som det förväntade värdet av den absoluta skillnaden mellan två slumpvariabler X och Y , oberoende och likafördelade med samma okända fördelning (Jasso, 1979). Ginis Mean Difference är det mått på risk som används när Mean-Gini Model används vid portföljoptimering (Jiang et. al., 2020).

3.2.2 Logistic regression

Logistic Regression är en matematisk metod för att analysera mätdata. Metoden används oftast för prediktiv analys. Metoden bygger på en ändlig eller kategorisk variabel, antingen A eller B (binär regression) eller en uppsättning alternativ A , B , C , D , och så vidare (multidimensionell regression). Metoden används vanligen tillsammans med statistisk programvara för att förstå samband mellan en beroende variabel och en eller flera oberoende variabler genom att uppskatta sannolikheter med av en logistisk regressionsekvation (IBM, u.å.).

3.2.3 Maskininlärning

Maskininlärning är ett område inom datavetenskap som behandlar statistiska modeller och algoritmer som tillåter datorer att lära sig och utföra uppgifter utan att en människa programmerat hur uppgiften ska lösas (Mahesh, 2020). Det finns tre huvudsakliga områden

inom maskininlärning, supervised learning, unsupervised learning och reinforcement learning (Mahesh, 2020). Supervised learning-algoritmer används främst för klassificeringsproblem såsom att klassificera bilder eller profilera kunder (Cunningham et al., 2008). Unsupervised learning-algoritmer är användbara inom dataanalys eftersom dessa algoritmer är bra på att finna mönster i stora datamängder och bilda kluster av data utifrån dessa mönster (Berry et al., 2019). Reinforcement learning-algoritmer tillåter datorn (agenten) att interagera med sin omgivning för att finna en strategi som maximerar agentens kumulativa belöning (Mahesh, 2020; Sutton & Barto, 2018). Ett exempel där reinforcement learning är användbart är vid problem där det inte är känt vilken som är den bästa strategin för att lösa problemet (Sutton & Barto, 2018). Nedan följer en beskrivning av några specifika maskininlärningsmetoder i syfte att underlätta läsarens fortsatta läsning.

3.2.3.1 Random Forests

Random Forests är en maskininlärningsalgoritm och effektiv klassificerare (Breiman, 2001). En random forest är uppbyggd av flera klassificerare med trädstruktur, hädanefter benämnda träd (Breiman, 2001). Utdatan som genereras från en random forest beror på utdatan från alla de enskilda träden (Breiman, 2001). Vissa random forests utdata är den output som genererats i majoritet av de enskilda träden medan andra random forests utdata är medelvärdet av varje träds utdata, bland annat (Breiman, 2001; Pinelis & Ruppert, 2022). Genom att väga samman flera träds utdata minskas bias i den klassificering som görs (Breiman, 2001).

3.2.3.2 Extreme Gradient Boosting

Extreme Gradient Boosting (XGBoost) är en trädbaserad maskininlärningsalgoritm. Den används främst för regression, klassificering, och ranking genom linjär modellösning (Chen, T., & He, T., 2022). Dess främsta styrka är att den på ett snabbt sätt kan bearbeta data och lära sig i en hög takt.

4. Existerande forskning inom framtidens fondrobotar, portföljhantering och marknadssvängningar

I följande avsnitt presenteras litteratur från den litteraturstudie som utförts. Ämnen som tas upp är hur framtidens fondrobotar kan komma att se ut samt existerande forskning inom portföljhantering och marknadsutveckling.

4.1 Framtidens fondrobotar

De senaste åren har det skett ett uppsving i forskning om fintech. En utvecklingspotential inom området är hur text kan tolkas genom maskininlärning (Chen et al., 2018). En textläsande robot skulle kunna ha flera tillämpningsområden, bland annat en chattande fondrobot, som hade konversationer med sina kunder. Chen et al. (2018) menar på att en chattfunktion skulle kunna hjälpa fondroboten bedöma kundens risk bättre än nuvarande riskbedömningsmetoder.

Även för de som idag har möjlighet att använda sig av mänskliga rådgivare kommer det finnas värde i framtidens fondrobotar enligt en studie som kartlade fondrobotar idag och i framtiden (Abraham et al., 2019). Datan som människor idag kan hantera är begränsad och människor är partiska, medvetet eller omedvetet. Dessa mänskliga brister kan leda till att personer överskattar eller förbiser något.

För att fondrobotar ska kunna bli det dominanta alternativet behöver tre delar finnas på plats (Abraham et al., 2019). För det första måste regleringar införas som alla fondrobotar kan förhålla sig till. För det andra behöver en översikt över vad robotrådgivare kan åstadkomma men också vilka begränsningar som finns ges. För det tredje ska det vara transparent hur fondroboten kom fram till de beslut som togs och även profileringen behöver vara tydlig. Således är det nödvändigt att algoritmerna är transparenta. Delarna bör finnas på plats för att kunden ska kunna skyddas och för att någon ska kunna hållas ansvarig för besluten. Enligt Bartram et al. (2020) kan en lösning till svårigheterna att hålla någon ansvarig vid beslut av fondrobotar vara att skapa komplementär modeller som syftar till att vara enkla och kunna förtydliga hur besluten togs.

För att få bra output vid användandet av AI krävs det bra input menar Bartram et al. (2020). Ett problem som ofta uppstår om inputen är dålig är att även outputen blir det. Detta fenomen brukar kallas för “garbage in, garbage out”. Fenomenet gör att integriteten och validiteten av besluten som fondroboten tar beror på kvaliteten av datan. Därför är det viktigt att undersöka hur AI kan validera datan, speciellt om det ska användas till något nyanserat som fundamental analysen (Bartram et al., 2020).

I en studie av Bartram et al. (2020) gjordes en kartläggning över möjliga problem med AI i framtiden. Ett av problemen som belystes var hur AI kan hantera händelser som är svåra att förutse eller händelser som inte skett tidigare. I dessa scenarier kan det leda till att algoritmerna kraschar.

4.2 Portföljhantering och marknadsutveckling

I följande avsnitt presenteras existerande forskning inom AI-integrerad portföljhantering och prediktionsmodeller, automatiserad avläsning av sociala medier för marknadsanalys samt portföljoptimering med avseende på marknadsfaser.

4.2.1 AI-integrerad portföljhantering och prediktiv modellering

I Modern Portfolio Theory (MPT), och i de ramverk samt teorier som bygger vidare på MPT, handlar portföljoptimering om att sätta samman den portfölj som åstadkommer bäst riskjusterad avkastning. Diverse olika AI-metoder kan i detta sammanhang användas för att skapa prognoser över framtida förväntad avkastning som sedan kan användas för att fördela tillgångarna i portföljen optimalt och även för att, i vissa fall, försöka tajma marknaden (Bartram et al., 2020; Jiang et al., 2020). Både Gu et al. (2020) och Chen et al. (2018) finner att artificiella neuronät bättre förutsäger framtida avkastning, out-of-sample, än andra AI-tekniker när de jämförs. Förklaringen till resultatet är att artificiella neuronät är mångsidiga samt kan upptäcka komplexa, icke-linjära samband i data. Bartram et al. (2020) menar att dessa egenskaper hos artificiella neuronät medför att tekniken kan användas inom MPT ramverket för att implementera kriterier som annars är för komplexa, såsom VaR-kriterier.

Tekniska indikatorer beräknas på historiska data, som pris och volymer, på specifika innehav för att få fram användbar data som därefter kan ligga till grund för framtida justeringar av

portföljen. Jiang et al. (2020) föreslår att flertalet tekniska indikatorer skall användas för att skapa en så bra modell som möjligt. I rapporten utreds om maskininlärning kan användas för att vikta risk på marknader för att parera prognostiserade svängningar på en marknad. Maskininlärningsmodellen matas med flertalet tekniska indikatorer för att i så stor utsträckning som möjligt ha möjlighet att hitta korrelerade faktorer som påverkar hur en marknad rör sig. Pinelis och Ruppert (2022) har utgått från en liknande idé och utvecklat ett ramverk för portföljoptimering som baseras på prognoser kring både förväntad avkastning och volatilitet. Deras ramverk använder sig av två random forest-modeller, en för att prognostisera förväntad avkastning och en för att prognostisera förväntad volatilitet. Båda prognoserna baseras på data från samma elva finansiella prediktorer och makroekonomiska mått. Genom att ta hänsyn till både volatilitet och avkastning föreslår Pinelis och Ruppert (2022) att bättre riskjusterad avkastning åstadkoms, vilket resultatet också visar på. Den föreslagna modellen genererar en portfölj som har 28 % högre sharpekvot än portföljer som följer en buy-and-hold strategi. I majoriteten av fallen lyckades även strategin undvika att investera i marknaden då det rådde förhållanden med hög risk och låg avkastning.

Även Jiang et al. (2020) föreslår en modell baserad på maskininlärning. Tillsammans med Gini's Mean Difference (GMD) kan marknaden klassificeras och prognoser för hur kursen kommer röra sig. Valet att använda GMD istället för MPT, som anses vara den vedertagna metoden, beror på flera faktorer. MPT gör antaganden om att avkastningen för en tillgång ska vara normalfördelad vilket sällan stämmer i verkligheten (Jiang et al, 2020). Detta antagande gör inte GMD vilket gör att denna metod anses vara ett bättre sammanhängande mått av risk. Två maskininlärningsmetoder föreslås för att på ett effektivt sätt klassificera marknaden (Jiang et al, 2020). Den första metoden kallas Logistic Regression (LR) och den andra Extreme Gradient Boosting (XGBoost). Båda metoderna testades på olika portföljer och resultatet visade att användningen av XGBoost resulterade i högst avkastning (Jiang et al, 2020).

Det existerar en stor mängd publicerad forskning som visar på AI:s brukbarhet inom portföljhantering (Bartram et al., 2020; Ferreira et al., 2021; Milana & Ashta, 2021). Forskning genomförs på ett flertal olika metoder inom området, bland annat, allokera tillgångar på bästa sätt, minimera risk och förutspå marknadsrörelser. Resultaten från den forskning som Bartram et al. (2020), Ferreira et al. (2021) och Milana och Ashta (2021) granskar, samt den forskning som nämnts ovan, är att många av metoderna fungerar och

presterar bra inom ramen för vad de syftar till att användas för. Bevisligen kan AI användas som ett verktyg inom portföljhantering och investeringsanalys. Relaterat till användningen av AI inom dessa områden finns det dock utmaningar (Bartram et al., 2020).

En av dessa utmaningar är grundad i den data som krävs för att AI ska kunna användas samt finansmarknadens karaktär. AI modeller tränas med hjälp av historisk data men denna data innehåller nödvändigtvis inte information som gör den representativ för framtida händelser (Bartram et al., 2020). Detta faktum i kombination med informationsasymmetrier på finansmarknaden kan leda till att det blir svårt för AI att hantera krascher. Nära kopplat till detta problem med historisk data är fenomenet black swan events (Bartram et al., 2020). Avsaknaden av tidigare data om händelser som liknar dessa black swan events gör det komplicerat att använda AI för att förutse dem och skapa korrekta prognoser.

4.2.2 Automatiserad avläsning av sociala medier för marknadsanalys

I en studie konstruerad av Leow et al. (2021) användes, till skillnad från andra studier som riktat in sig på företagsspecifika tweets, en övergripande miljö inom ett segment på Twitter genom att följa specifika finans Twitterkonton. För de enskilda Twitter kontona användes Valance Aware Dictionary and sEntiment Reasoner (VADER) och Financial Bidirectional Transformer (FinBERT) (Araci, 2019; Hutto & Gilbert, 2014). VADER som är ett lexikon som specifikt är utformat för att läsa av känslor utifrån ord i sociala medier. Det känslomässiga poänget som en mening får kan sammanfattas som en summa av intensiteten av varje ord i meningen. FinBERT är en ytterligare finansiell utvecklad BERT modell som är specialiserad inom det finansiella språket då positiva respektive negativa ord kan vara olika från det generella språket.

Leow et al. (2021) et al beskriver att FinBERT var verktyget med bäst precision för att bedöma finansiellt relaterade twitterinlägg. Twitterkontot CNBC, vilket är en amerikansk nyhetsbyrå med inriktning på affärer och finans, twitterinlägg hade en stark korrelation gentemot fonden SPYs aktiedata utan tidseftersläpning. Slutsatsen som Leow et al. (2021) drar är att en hybridmetod med användning av traditionella portfolio tekniker tillsammans med tolkade känslor från Twitter kan förbättra portföljens prestanda genom att använda Generiska Algoritmer för olika syften (minska volatilitet eller maximera avkastning). De

beskriver dock att det varit flertalet förenklingar i deras forskning och kan utvecklas i framtida forskning.

Bartram et al. (2020) beskriver hur en Natural Language Process (NLP) kan ta ut meningsfull ekonomisk information från olika typer av texter. Exempel på sådana texter är bland annat årsredovisningar, nyhetsartiklar och Twitter inlägg. Författarna beskriver hur AI till skillnad från de traditionella tekniker där varje enskilt ord värderas i en text, så kan AI förstå kontexten och meningens uppbyggnad. Emellertid finns det fortfarande utmaningar gällande att kunna läsa av mänsklig skrift automatiskt med hjälp av AI.

En av dessa utmaningar handlar om att få AI att kunna förstå och tolka sarkasm (Kumar & Goel, 2020). För att förstå sarkasm krävs det allmänbildning och en förmåga att läsa mellan raderna vilket är ett problem för AI. Problemet är ett viktigt sådant dessutom eftersom en stor del av det som skrivs på sociala medier innehåller sarkasm (Kumar & Goel, 2020). För att AI ska kunna läsa av sociala medier effektivt och tolka innehållet med hög precision krävs det därav metoder för att hantera sarkasm, vilket det finns omfattande forskning kring (Prasad et al., 2017; Tay et al., 2018; Sarsam et al., 2020).

Least Absolute Shrinkage and Selection Operator (LASSO) regression kan automatiskt välja faktorer med högst beskrivande förmåga för framtida avkastning från en stor mängd förutspående signaler för avkastning som dokumenteras i litteraturen (Feng et al., 2017; Freyberger et al., 2018). LASSO tekniken kan även användas för att hitta ledande och släpande relationer mellan tillgångar eller marknader. Exempelvis kan tekniken avgöra vilken industris vinst som spiller av sig på andra industrier (Rapach et al., 2013; Rapach et al., 2019).

4.2.3 Portföljoptimering med avseende på marknadsfaser

Beroende på vilken fas som marknaden befinner sig i förändras portföljens risk. I detta avsnitt presenteras metoder och modeller som försöker förutspå framtida marknadsfaser att. Genom att förutspå framtida faser är det möjligt att optimera portföljen för att generera en överavkastning.

4.2.3.1 Användning av GARCH och ARCH modeller för marknadsanalys

Obalansfaktorer inkluderades tillsammans med GARCH modeller för en mer precis beräkning av framtida risk. Alberg et al. (2008) beskriver hur risken för asymmetri ökar med högre avkastningsvolatilitet. Det finns även forskare som anser att andra ekonomiska tekniker och modeller måste utvecklas för att beräkna asymmetriskt beteende. Detta eftersom den finansiella avkastningen är så oförutsägbara i sin natur och volatilitet kommer ge det mest användbara resultatet. Det är därför av stor vikt menar Alberg et al. (2008) att välja en lämplig riskmodell för att få tillförlitliga resultat.

Khan et al. (2019) beskriver att ARCH familjens modeller används för att hantera detta problem. Modellerna anses vara bättre på att hantera och mäta den givna volatiliteten i en marknad och få fram en villkorlig varians. Exponential- GARCH modell för att avgöra volatilitetsklustring och asymmetri framtofs av Nelson (1991) vilket har varit användbart för att identifiera obalanser i en positiv eller negativ marknadschock.

Under senare år har forskare i högre utsträckning försökt identifiera riskfaktorer som inkluderas i finansiell marknadsdata och har tagit fram ramverk där investerare kan lägga till dessa obalansfaktorer till GARCH modeller för att få mer tillförlitliga resultat och ha möjlighet att förutsäga risken på en högre nivå (Rizvi et al., 2014).

Relativt lugna perioder av ekonomisk tillväxt präglas av låg volatilitet (Engle, u.å.). Ett exempel på detta var åren innan finanskrisen 2007 som präglades av låg volatilitet. Åren som följde efter finanskrisen var volatiliteten mycket hög och en enklare regressionsmodell som GARCH kan inte förutspå dessa black swan event då ingenting innan eventet pekar på att det ska ske (Engle, u.å.).

4.2.3.2 Användning av Markov Switching Model för att förutse marknadsfaser

I forskning gjord av Chauvet och Piger (2008) studerades MSMs effektivitet att ta fram datum för marknadsfasförändringar. Studien fastställer att med hjälp av MSM kan marknadsfasförändringar bestämmas korrekt. Fördelen som Chauvet och Piger (2008) menar är att MSM kan bestämma fasskiften på ett kortare tidsspann än the National Bureau of Economics Research (NBER). NBER har ansvaret att i efterhand fastställa när en marknadsfasförändring har skett . Goodwin (1993) undersöker MSMs effekt för att förutspå

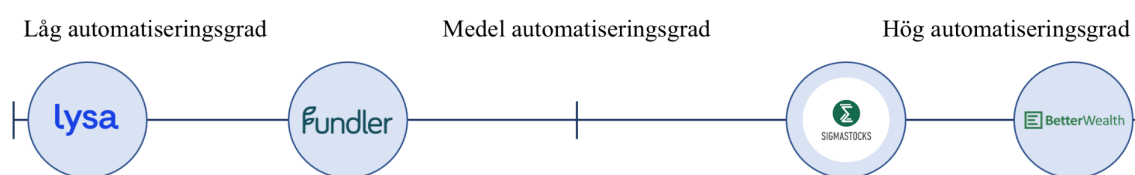
marknadsfasförändringar men kommer till liknande insikter som Chauvet och Piger (2008). Båda studierna menar att MSMs styrka inte ligger i att kunna förutse utan att snabbt kunna fastställa att skiften har uppstått. Dessa resultat står i kontrast mot vad Hamilton (1989) trodde i sitt framtagande av modellen där han snarare antog att MSM var en grundpelare för att kunna förutse framtida faser.

5. Resultat

I följande avsnitt presenteras resultat från de intervjuer som gjorts under arbetet. Först presenteras hur de svenska fondrobotföretagens fondrobotar fungerar, därefter en kort sammanfattning av traditionell fondförvaltning baserat på intervjuer. Avslutningsvis presenteras resultaten från den genomförda delfistudien med samtliga experter inom fondrobotar, traditionell förvaltning och AI-expert.

5.1 Kartläggning av den svenska fondrobotmarknaden

Nedan presenteras hur Lysa, Fundlers, Sigmastocks och BetterWealth fondrobotar fungerar. Resultatet bygger på information från intervjuerna och även företagens hemsidor. För att få en överblick över hur intervjuobjekten står i relation till varandra sett till automatiseringsgrad har *figur 6* sammanställts. Resultatet presenteras i ordningen vänster till höger i figuren, från låg automatiseringsgrad till hög automatiseringsgrad.



Figur 6. En schematisk bild hur automatiseringsgraden hos fondrobotarna förhåller sig till varandra.

Nedan i *tabell 2* presenteras återigen respondenterna från respektive fondrobotföretag. Fortsättningsvis kommer denna tabell refereras till när någon av respondenterna nämns i text.

Tabell 2. Tabell över intervjuerna som hållits med respondenter från fondrobotföretag.

Intervjuer				
Respondent	Företag	Titel	Datum intervju 1	Datum intervju 2
Ahrner, Ulf	Funder	Grundare och investeringsansvarig	5 april 2022	21 april 2022
Björklund, Oscar	Lysa fonder	VD	4 mars 2022	21 april 2022
Jönsson, Henrik	BetterWealth	Medgrundare och investeringsansvarig	16 mars 2022	28 april 2022
Lindberg, Carl	Sigmastocks	Medgrundare och investeringsansvarig	29 mars 2022	27 april 2022

5.1.1 Lysa

Lysa är ett svenskt fondrobotbolag med målet att, givet kundens risktolerans, ekonomiska situation samt mål, maximera avkastning (Lysa, u.å.). Att maximera avkastning syftar i detta avseende inte till att hitta undervärderade tillgångar. Istället anser Lysa att breda och väl riskavvägda portföljer skapar bäst förutsättningar för att åstadkomma hög riskjusterad avkastning på lång sikt (Lysa, u.å.; Björklund, se *tabell 2*). För att kunna konstruera portföljer som uppvisar dessa egenskaper investerar Lysa i två olika tillgångsslag, aktier och räntor (Lysa, u.å.). Fördelningen mellan dessa tillgångsslag i respektive portfölj beror på kundens ekonomiska situation och sparhorisont efter risktolerans. Låg risktolerans innebär en portfölj med större andel räntor medan en hög risktolerans innebär en portfölj med större andel aktier.

Varje tillgångsslag delar Lysa upp i fler lager (Lysa, u.å.). Aktier delas upp efter geografi, 20 % i Sverige och 80 % internationellt, samt storlek på bolagen medan räntor delas upp baserat på geografi samt kreditrisk (Lysa, u.å.; Björklund, se *tabell 2*). Fördelningen mellan de olika lagren inom de två tillgångsslagen är fast och samma oavsett vilken risktolerans en kund har.

För att få exponering mot önskade tillgångsslag investerar Lysa i fonder och ETF:er som har som mål att följa ett index (Lysa, u.å.; Björklund). Vilka fonder som bör ingå i deras fondportfölj analyseras utefter kriterierna i *tabell 3*. Arbetet för att hitta nya fondalternativ

sker manuellt (Björklund). Varje kvartal sker en utvärdering av marknadsläget, den existerande fondportföljen samt nya alternativ som skulle kunna vara aktuella att köpa. Utvärderingen görs för att komma fram till om några förändringar behöver göras, vilket ofta inte behövs enligt Björklund. Ett exempel på en förändring som kan ske är uppdatering av den fasta fördelningen mellan lagren.

Tabell 3. Sammanställning av Lysas investeringskriterier vid analys av nya fonder och ETF:er (Lysa, u.å.).

Kriterium	Förklaring
Fondavgifter	Lysa eftersträvar att investera i fonder som tillhör de med lägst avgift inom sin respektive tillgångsklass.
Transaktionskostnader	Lysa eftersträvar att välja fonder som handlar effektivt och till låga transaktionskostnader.
Courtage, spread och settlement fees	Lysa eftersträvar kostnader förknippade med att förvärva och avyttra fonden.
Hur fonden handlas	Så kallade börshandlade fonder, ETFer, kan handlas när som helst under dagen. En traditionell fond handlas direkt hos fondbolaget vid ett tillfälle varje dag. Lysa har inga preferenser mellan vanliga fonder och ETF:er. Lysa handlar enbart på välrenommerade marknader
Likviditet och "money under management"	Lysa föredrar att investera i likvida fonder som är lätta att köpa och sälja utan att påverka marknadsprissättningen.
"Tracking difference" och "Tracking error"	Lysa utvärderar hur väl fonden följer sitt underliggande index. Lysa föredrar fonder med så låg avvikelse som möjligt
Fondens hemvist	Lysa föredrar fonder som uppfyller UCITS-kraven och står under tillsyn av en tillståndsmyndighet inom EES
Hur fonden replikerar sitt underliggande index	Lysa föredrar fysisk replikering

Renommé	Lysa väljer enbart fondförvaltare som är stabila och har kapacitet att förvalta fonden.
Skattesituation för fonden	Lysa investerar i fonder som är domicilierade i EES och har en effektiv skattesituation. Utöver fondens hemvist kan denna påverkas till exempel av på vilken marknad den handlas. Vad fonden investerar i och om fonden är utdelande eller ej.

Lysa använder diverse mått för att mäta den underliggande risken hos tillgångarna de investerar i (Björklund). Ett av dessa mått är volatilitet (Lysa, u.å.). Vidare tar de hänsyn till olika faktorer när de sätter samman portföljer för att inte skapa överexponering mot en viss typ av tillgång (Lysa, u.å.). Genom att analysera tillgångar utifrån ett faktorperspektiv försöker Lysa minska korrelationen mellan tillgångarna i portföljen. Detta tillvägagångssätt används främst för att mäta korrelation inom räntor samt mellan räntor och aktier i portföljen. Eftersom de har som mål att följa marknadsportföljen för aktier medför det att den kortsiktiga korrelationen mellan aktier ej är relevant att ta i beaktning (Björklund). Björklund poängterar även att Lysa ej följer detta värde pedantiskt eftersom det ofta är komplext att använda det till något konstruktivt.

Regulatoriska krav för att garantera kundsäkerhet gör att köpprocessen i Lysas fondrobot är en blandning av automatiska och manuella steg (Björklund). Automatisering av köpprocessen, bland annat det slutgiltiga beskedet att köpa tillgångar, förhindras av att Lysas verksamhet räknas som fondförvaltning vilket innebär att de måste följa vissa regelverk. Utöver de manuella avstämningspunkter som implementerats för att möta de regulatoriska kraven så har Lysa automatiserat stora delar av systemet för handel samt allokeringen så att fördelningen i kundernas portföljer förblir korrekt. Det senare är det som Lysa benämner som deras ombalansering.

Ombalansering av portföljer utförs genom kontinuerlig övervakning av portföljerna som genererar köpordrar när en portföljs fördelning avviker från dess målfördelning under ett antal dagar i rad (Lysa, u.å.; Björklund). Vid var och ett av dessa köp utvärderas fördelningen av tillgångsklasser och sedan genomförs köp för att återgå till portföljens målfördelning.


Lysas mål att deras portföljer ska följa hur marknaden påverkar hur de hanterar svängningar på börsmarknaden (Björklund). Att följa marknaden innebär att följa med på nedgångar likaväl som på uppgångar. På grund av detta synsätt görs inga aktiva försök att undvika till exempel börskrascher.

5.1.2 Fundler

Fundler är ett svenskt fondrobotbolag som kombinerar mänsklig kompetens med robot för att i deras åsikt skapa en så bra tjänst som möjligt (Fundler, u.å.). Förhållandet mellan robot och människa beskriver Fundler är att människorna sätter ihop portföljerna samt sköter all kundkontakt medan roboten har i syfte att se till att portföljens risk hela tiden är i nivå med den riskpreferens som kunden valt (Fundler, u.å.). Kontrollen av portföljerna görs av roboten genom att hålla koll på kursutvecklingen och ombalansera portföljen utifrån förändringar på marknaden. Processen beskriver Ahrner (se *tabell 2*) är nästintill helt automatiserad, dock behöver roboten fortfarande få ett godkännande på en köp- eller säljorder. Han säger att roboten ger förslag på köp- och säljorder men att det är människor som manuellt måste trycka på knappen för att godkänna ett köp eller sälj.

Totalt erbjuder företaget åtta olika portföljer som kunder kan investera i baserat på kundens risk- och investerings preferens. Av de åtta portföljerna finns det fyra smart index portföljer med olika risknivåer samt fyra mer nischade portföljer med olika inriktningar och risknivå. Smart index är en indexbaserad portfölj som inte nödvändigtvis är ett tvärsnitt av alla börsens aktier utan kan bestå av mer nischade indexfonder såsom småbolag eller läkemedel. (Fundler, u.å.).

Fundlers fyra smart index portföljer har olika grad av risk i stigande skala; försiktig, stabil, tillväxt samt potential. Portföljerna med låg risk har större andel obligationer och lägre andel aktier vilket gör att de lämpas bäst för en kortare investeringshorisont (Fundler, u.å.). Portföljerna med högre risk har istället lägre andel obligationer och högre andel aktier vilket gör att de lämpar sig bättre för kunder med en längre investeringshorisont.



Figur 7. Fundlers Smart Hedge portfölj (turkos), jämfört med jämförelseindex (streckad linje) under ettårstidsperioden maj 2021 - maj 2022 (Fundler, 2022b.).

Utöver indexbaserad portfölj erbjuder Fundler även fyra avancerade portföljer (Fundler, u.å.). Namnen på dessa och information kring vilket fokus respektive portfölj har åskådliggörs i *tabell 4*. Nämnvärt är att Smart Hedge portföljen lämpar sig bra när marknaden är orolig. Sedan Rysslands invasion av Ukraina i slutet på februari 2022 har portföljen gått upp medan marknaden gått ner, vilket går att se i *figur 7*. Portföljen har alltså haft en invers relation med marknadens utveckling.

Tabell 4. Sammanställning av information kring Fundlers avancerade portföljer (Fundler, u.å.).

Namn på portfölj	Information om portföljen
Global Framtid	Fokuserar på framtidens bolag på en global nivå. Investeringar görs främst i fonder innehållande lönsamma teknikföretag, stora och medelstora bolag som tillhör hälsovårdssektorn med sin primära marknad i tillväxtländer.
Hållbar Framtid	Fokuserar på fonder med bolag som aktivt arbetar kring hållbarhet och jämställdhet. Investeringar sker främst inom sektorerna teknologi, finans och industri.
Real Vision	Fokuserar på god avkastning utan hög risk. Investeringarna sprids primärt över fonder innehållande företag som äger stora reala tillgångar
Smart Hedge	Fokuserar på börstillväxt i ett långsiktigt perspektiv. Portföljen innehåller även guld som skydd vid eventuella marknadsnedgångar.

Fundler handlar inte enskilda aktier utan bedriver allokerad förvaltning med fokus på grupper av tillgångar i form av fonder och ETF:er (Fundler, u.å.). Tillgångsslagen som investeras i är obligationer, aktier, råvaror och optioner. Ahrner menar att den allokerade förvaltning som Fundler ägnar sig åt medför att analyser av marknader, branscher och länder måste ske på en aggregerad nivå. Fortsättningsvis berättar Ahrner att Fundler, genom att investera i fonder, erbjuder sina kunder väldiversifierade portföljer i och med att de investerade fonderna innehåller hundratals bolag.

Ahrner nämner att analysen av marknad och segment fortfarande sker av människor. Han fortsätter med att beskriva att dagens AI är reaktiv och inte proaktiv, vilket gör att människor lämpar sig bättre för analyser i dagsläget. Ahrner menar också på att det inte enbart går att följa konsensus för att slå index och tar upp börskraschen från 2008 som exempel. Datan som fanns tillgänglig 2007 visade att allt såg bra ut något som senare inte visade sig stämma. Ahrner menar att det ibland krävs antagningar för att lyckas med investeringar, vilket är något som AI ej är duktiga på vilket gör att människorna fortfarande behövs för att ta beslut.

Fundlers portföljer skapas i ett förvaltarteam säger Ahrner. Han beskriver vidare att portföljerna optimeras baserat på en avvägning mellan förväntad avkastning, risk och

kovarians. Genom att analysera kovariansmodeller försöker Funder minimera korrelationen mellan enskilda tillgångar i portföljerna för att på så vis minska risken. Avvägningen mellan risk och avkastning mäts genom sharpekvoten. Ytterligare något som Funder gör enligt Ahrner är att köpa fonder som gått ner och sälja de som gått upp vilket resulterar i att de kan åstadkomma en ökad avkastning med 0,3 % utan högre risk.

Sett till var Funder har sina investeringar geografiskt är ungefär 60 procent investerat i Norden (Funder, u.å.). För att diversifiera och minimera risk undersöker Funder hela marknader, dess storlek och värdering jämfört med ett historiskt genomsnitt. Ahrner nämner att Sverige historiskt har haft en av världens bästa börser sett till tillväxt, men att marknaden haft hög risk. Därför vill Funder allokera en stor del av portföljerna till Sverige men med diversifiering till andra länder för att få lägre risk och korrelation.

Ytterligare en anledning till att Funder har en stor andel investerat i Norden är för att valutakurser medför stora risker. Om Funder skulle ha stora investeringar i amerikanska tillgångar handlat i dollar är de exponerade för en stor valutarisk menar Ahrner på. Det skulle inte spela någon roll om tillgången växer i värde, om valutan av någon anledning sjunker i liknande magnituder säger han.

5.1.3 Sigmastocks

Sigmastocks är ett svenskt fondrobotbolag som erbjuder sina kunder individuella aktieportföljer baserat på kundernas riskprofiler. När nya kunder registrerar sig hos Sigmastocks genomgår kunden en process där en riskprofil skapas (Sigmastocks, u.å.). Kunden får svara på frågor om sparhorisont, risktolerans, om det är en engångsinsättning eller ett kontinuerligt sparande. Även frågor om det finns marknader och företag som kunden vill undvika ställs för att ge en möjlighet att skapa en portfölj som kunden är bekväm med. Portföljen innehåller till större del aktier men också räntor från en blandning av olika marknader och geografiska delar (Lindberg, se *tabell 2*).

Investeringsmålet är att skapa en diversifierad portfölj som slår ett jämförelseindex med ca. 1 % berättar Lindberg. Det finns olika strategier och olika sätt att se på sparande menar han. Å ena sidan läggs fokus på att följa ett jämförelseindex. Att göra det skapar dock mycket lite för kunden eftersom att köpa index är näst intill gratis. Att å andra sidan satsa på enskilda aktier

och marknader utsätter kunden för en stor risk och gör att kunden är utsatt för volatilitet som inte är önskvärd. Dessutom skapar detta risktagande inte något större värde för kunden i det avseende att det är något som varje individ kan göra själv utan större svårigheter. Sigmastocks har som mål att hamna någonstans emellan dessa två ytterligheter (Lindberg). Det värde som skapas för kunden är att denne får en diversifierad portfölj med väsentligt lägre risk än enskilda aktier men med en förväntad avkastning som är något bättre än jämförelseindex.

Avvägningen mellan avkastning och risk mäts framför allt i volatilitet på enskilda aktier och på hela portföljer. En avvägning sker även mellan räntor och aktier som kan ses som mindre riskfyllda respektive mer riskfyllda (Stranne, personlig kommunikation, 24 mars, 2022). Däremot använder sig Sigmastocks inte av någon av de etablerade investeringsmodeller som MTP eller Black-Litterman vilket det finns en anledning till berättar Lindberg. Problematiken med investeringsmodeller är att de inte fungerar i verkligheten menar han. Modellerna fungerar oftast bra i fiktiva fall, dessvärre sällan i verkligheten. Modellerna bygger oftast på så många antaganden att det inte längre avspeglar den verklighet vi lever och investerar i. Lindberg förklarar att det brus som finns hos en aktie, alltså den dagliga svängningen är i förhållande till den årliga utvecklingen för en marknad är för stor för att modellerna ska bli trovärdiga.

I stället använder sig Sigmastocks av faktoranalys (Lindberg; Sigmastocks, u.å.). Utifrån kvantitativa data kan en bild om hur lovande ett bolag är ur ett investeringsperspektiv skapas. Företag inom samma segment kan därefter jämföras och på så vis kan de bästa bolagen väljas ut till portföljen. Mönster kan utläsas ur data från bolag som valts ut som sedan gått bra vilket gör att processen med att välja ut bolag förbättras. Den modell Sigmastocks använder är automatiserad och som relativt oövervakat kan ta fram de portföljer som passar en kunds riskprofil (Lindberg). Modellen anpassar sig helt efter de svar som kunderna ger i frågeformuläret samt nuvarande marknadsläge, vilket resulterar i att ingens portfölj är någon annans lik. Den höga graden automatisering gör också att avgiften för förvaltningen kan hållas låg.

Lindberg är noga med att understryka varför fondens utvecklingsmål är på 1 % över index. Hans personliga åsikt är att det inte går att förutsäga marknaden i någon större utsträckning och att detta avspeglas i hur Sigmastocks arbetar. På kort sikt kan större vinster än några

enstaka procent göras men i ett längre perspektiv är det ej troligt. Lindberg säger att de som påstår sig kunna åstadkomma en överavkastning på flertalet procent jämfört med börsen sätter sig själva i en konstig sits. Han menar att det inte går att förutspå hur en marknad kommer röra sig och därför blir påståendet vågat.

Sigmastocks arbetar med cirka 900 aktier i sin watchlist vilken kompletteras med ett fåtal räntefonder (Sigmastocks, u.å.). Urvalet av aktier i watchlist sker genom väletablerade bolag som ingår i index berättar Lindberg. Anledningen till valet av aktier grundar sig framför allt i två faktorer. Den första faktorn bygger på att hitta likvida bolag på större marknader för att få en stabilitet i sitt utbud med lägre risk. Den andra faktorn är i stort sett psykologisk. Lindberg berättar att en viktig del i Sigmastocks affärsmodell är att ha en hög transparens mot sina kunder. Det finns möjlighet för alla kunder att se vad just de har i sina individuella portföljer och de vill se aktier som de känner igen och en standardportfölj innehåller då 50 % aktier från den svenska marknaden. För att skapa ett så stort värde som möjligt eftersträvas att innehaven ska vara aktier som kunden hade kunnat tänka sig att köpa själv.

Processen med att ta fram bolag till Sigmastocks är helt automatiserad säger Lindberg. Algoritmen bakom processen är bra på att utföra kvantitativ analys av bolags aktier på ett sätt och i en hastighet människor inte är. I dagsläget görs inga fundamentala analyser eftersom Sigmastocks eftersträvar en bredd i sitt utbud, samtidigt som avgiften skall hållas låg menar Lindberg.

När portföljerna är satta arbetar Sigmastocks aktivt med optimering av allokeringsmixen (Sigmastocks, u.å.). Processen är i stort automatiserad och testas på historiska data samt livedata (Lindberg). Modellen anpassas hela tiden efter föränderliga förutsättningar, dock är det svårt att få en modell som fungerat historiskt att fungera i framtiden enligt Lindberg. Modellen är en vidareutveckling av vad som kallas faktorinvestering (Sigmastocks, u.å.). Metoden går ut på att bolagets aktier bryts ner till olika mätetal, så kallade faktorer, som sedan kan jämföras med andra bolags mätetal. De faktorer som Sigmastocks analyserar är; marknadsvärde, kassaflöde, bokfört värde, skuldsättning, utdelning, PE-tal, vinsttillväxt, momentum och vinstmarginal. Det är dessa faktorer som den automatiserade modellen använder som analysgrundande data för att optimera den allokeringsmix som finns i kundernas portföljer.

Den huvudsakliga ombalanseringen av portföljer sker för att upprätthålla önskvärd nivå av diversifiering menar N. Stranne (personlig kommunikation, 24 mars 2022), VD på Sigmastocks. Portföljerna ses över dagligen och handeln sker ca en gång per vecka. Alla kunders portföljer som behöver ombalanseras eller har behov av nya inköp samlas för att optimeras. En grundlig översyn av alla Sigmastocks innehav sker årligen för att hålla portföljen långsiktigt uppdaterad (Stranne, personlig kommunikation, 24 mars, 2022).

För att volatiliteten inte ska bli för hög vid stora marknadssvängningar ombalanserar Sigmastocks mellan räntor och aktier berättar Stranne (personlig kommunikation, 24 mars 2022). När det råder volatil marknad ombalanseras portföljerna till att innehålla mer räntor. Det sker dock inget arbete med att försöka förutspå hur marknaden kommer att röra sig i framtiden menar N.Stranne utan ombalansering sker i efterhand när volatiliteten på marknaden har ökat kraftigt (Stranne, personlig kommunikation 24 mars, 2022).

5.1.4 BetterWealth

BetterWealth är en svensk fondrobot som erbjuder sina kunder två portföljstrategier, en strategisk och en dynamisk strategi (BetterWealth, u.å.). Den strategiska strategin har ett på förhand bestämt, fast förhållande mellan fyra olika underliggande tillgångsslag; aktier, räntor, alternativa tillgångar och råvaror. Skillnaden mot den dynamiska portföljen är att denna istället balanserar om tillgångsslagen beroende på marknadssituationen. Är marknaden mer osäker ombalanseras portföljen mot säkra underliggande tillgångar såsom räntor. Är marknaden istället mer stabil balanseras portföljen mot underliggande tillgångar som aktier, vilka potentiellt genererar högre avkastning (BetterWealth, u.å.).

Beroende på kundens investeringshorisont och ekonomiska situation föreslår BetterWealth en risknivå på sparandet (BetterWealth, u.å.). Baserat på risknivån kommer fördelningen av fonder mellan de fyra olika underliggande tillgångsslag att se annorlunda ut. En högre risknivå medför mer riskfyllda tillgångsslag, medan en lägre risknivå innebär högre andel säkra tillgångar. I den strategiska portföljen hålls alltså detta förhållande mellan tillgångsslagen konstant till skillnad mot den dynamiska portföljen där förhållandet istället används som ett utgångsläge och som sedan kan förändras.

BetterWealth diversifierar sina investeringar i fyra lager. Det första lagret är som nämnt; aktier, räntor, alternativa tillgångsslag eller råvaror (BetterWealth, u.å.). Det andra lagret är aningen högre grad på diversifieringen med fokus på geografi och landets utvecklingsnivå, där länderna delas in i tre klasser; utvecklade länder, utvecklingsländer och frontiermarknader. Därefter specificeras den geografiska placeringen ytterligare i det tredje lagret, vilket innebär länder eller regioner. BetterWealth (u.å) är dock tydliga med att de inte lägger större vikt vid svenska innehav än någon annan region. Det fjärde lagret består av än mer detaljerad fördelning baserat på investeringsfokus samt på investeringslag och geografisk fördelning.

BetterWealth använder en diversifierad portfölj för att undvika risken med korrelerade tillgångar (BetterWealth, u.å.). Metoden har sin grund i MPT, vilket innebär att fokus ligger på avkastning och diversifiering. Jönsson (se *tabell 2*) menar på att om en portfölj har hög grad av diversifiering visar all forskning på att den portföljen kommer ha hög avkastning per risk. En skillnad med BetterWealths metod är dock att de även använder max drawdown, eller maximal förlustrisk, för optimering istället för att endast använda estimat av förväntad avkastning och risk. Max drawdown används för att begränsa portföljens maximala fall från toppen till botten.

Risken i BetterWealth dynamiska portfölj mäts i huvudsak med VaR95 % (BetterWealth, u.å.). Enligt Jönsson används en sammanvägning av data från ett, fem och tio år för att estimerar VaR. BetterWealth mäter även risk genom att titta på flertalet andra faktorer som volatilitet och korrelation mellan aktier/räntor. Jönsson poängterar dock att det i princip går att konstruera hur många faktorer som helst baserat på hur marknaden förväntas påverkas.

För att på ett effektivt sätt kunna avgöra hur marknaden reagerar och vilka faktorer som bäst avgör risken i marknaden beskriver Jönsson att de använder klustermetoder för att kunna avgöra hur faktorerna och marknaden samverkar baserat på historisk data. Med klustermetoderna menar han att det går att få ett tidsperspektiv i vilka faktorer som samverkar med risken på marknaden. Med tidsperspektivet går det att avgöra vilka faktorer som idag mest lämpligen bör användas som riskmått. Allt för att bättre kunna estimerar den förväntade risken i portföljen.

Övervakningen av risken i portföljen sker enligt Jönsson dagligen eftersom det hela tiden genereras ny data. Beroende på hur marknaden utvecklas och vilken data som finns kan BetterWealths marknadsfasklassificering ändras. När den nya klassificeringen sker, säger Jönsson att det kan ske en om-allokering av hela portföljen för att optimera för den nya fasen. Det kostar dock att ombalansera och med relativt lång investeringshorisont blir det oftast långa cykler med små justeringar som tillämpas. Även om datan analyseras dagligen så har det historiskt skett tre till fyra re-optimeringar per år beroende på vad som har hänt på marknaden säger Jönsson . Skulle marknadsfasen inte ändras, re-optimeras ändå portföljvikterna minst årligen för att bäst matcha kundens risknivå.

Optimeringen som görs baseras framför allt på marknadsfaserna säger Jönsson. Att det inte går att förutspå avkastningen är Jönsson tydlig med, men han tror samtidigt att det kan gå att förutspå risken och även korrelationen, trots att det är svårare. Det handlar alltså om, givet vissa restriktioner, att optimera inom de olika tillgångsslagen.

Filosofin som BetterWealth har är att estimeras risk och korrelationen och utefter det optimera portföljen. Jönsson säger att de försöker se trender i olika faktorer och ibland använda dessa för att optimera portföljerna i förväg. Det handlar om att förutse marknadsfaserna och marknadsrisken för att använda det som input till optimeringen av portföljerna. Optimeringen av BetterWealths portföljer görs alltså dels baserat på vilken marknadsfas marknaden är i just nu, dels baserat på vilken som är den förväntade marknadsfasen.

För att identifiera marknadsfaserna säger Jönsson att de använder klustermetoderna som är en form av maskininlärning. Ett stort fokusområde som BetterWealth har just nu är dock att förutspå marknadsfaser vilket kräver mer avancerade metoder än de som används idag enligt Jönsson. En metod de ser över är XGBoost för att plocka upp trender och vilka marknadsfaser marknaden estimeras befinna sig i om en, sex eller tolv månaders period. Jönsson poängterar dock att det är svårt. Det finns en historia som går att optimera på, men att det är lätt att överanpassa om mer komplexa maskininlärningsmetoder används.

Ombalansering sker i den strategiska portföljen kontinuerligt för att säkerhetsställa att fördelningen mellan fonderna av de fyra olika tillgångsslagen har den på förhand bestämda fördelningen (BetterWealth, u.å.). Den dynamiska portföljen balanseras istället om för att matcha den på förhand bestämda VaR-riskprofilen. Om risken har ändrats signifikant kommer

det ske en om-allokering för att nå målriskén säger Jönsson. Fortsättningsvis menar han på att ombalansering sker systematiskt och att allt baseras på data, det är alltså ingen människa som gör detta arbete manuellt.

När det kommer till den dynamiska modellen bygger den på volatilitet och allokeringen av tillgångar baserar på risk och volatilitet säger Jönsson. Han menar på att en sådan typ av portföljstrategi går bra i långa perioder av hög volatilitet på marknaden. Anledningen till det är att portföljen klarar sig bra under marknadsnedgångar då portföljen ombalanserar och håller sig mer stabil gentemot om ingen ombalansering skulle skett då den skulle fortsatt följa med marknaden nedåt.

Det som hände under våren 2020 när Coronakraschen skedde var att de dynamiska portföljerna klarade sig bra under marknadsnedgången men sämre under uppgången som följde. Problemet, säger Jönsson var inte nedgången eftersom modellen allokerade om till säkrare tillgångar för att klara eventuella fortsatta marknadsnedgångar. Problemet var snarare att det hände något som aldrig hänt innan med en kraftig uppgång precis efter nedgången, vilket gjorde att BetterWealths dynamiska portföljer inte hängde med upp på samma sätt som portföljer som legat stabilt i samma allokering hela tiden säger Jönsson. Han poängterar dock att BetterWealths dynamiska portföljer har levererat bättre avkastningar än portföljer med liknande strategier under den perioden. Anledningen till detta säger han är att de flesta andra är långsamma och att det därför tar mer tid innan de allokerar om. Efter kraschen allokerades tillgångarna tillbaka i BetterWealths portföljer efter fem-sex månader, medan det för andra tog längre tid. Enligt Jönsson gjordes ombalanseringen först efter fem-sex månader på grund av den fasmodell som BetterWealth använder som signalerade att det var en stressad marknadsfas i totalt fem till sex månader.

5.2 Intervjuer med fondförvaltare

Traditionella fondförvaltare arbetar inte på samma sätt som fondrobotar. Till skillnad från fondrobotar kan denna typ av förvaltning anses vara den traditionella formen av portföljhantering och är den form som majoriteten av dagens fonder hanteras genom idag. Under uppbyggnaden av denna rapport har tre fondförvaltare, vilka går att se i *tabell 5*, kontaktats och intervjuats för att få en bild av hur de hanterar investeringar och fonder, samt för att förstå hur det skiljer sig från fondrobotar.

Tabell 5. Tabell över intervjuerna som hållits med respondenter som arbetar med fondförvaltning.

Intervjuer				
Respondent	Företag	Titel	Datum intervju 1	Datum intervju 2
Skoglund, Fredrik	Spiltan Fonder	Assisterande förvaltare och analytiker	13 april 2022	26 april 2022
Stenkil, Fredrik	Swedbank	Portfolio manager-Swedbank Robur	22/ mars 2022	21 april 2022
Westfeldt, Stefan	Vinga Corporate Bond	Principal PM	21 mars 2022	27 april 2022

Fondförvaltarna i denna del kan delas upp i två kategorier, den ena kategorin där fonden handlar med aktier och den andra där fonden handlar med företagsobligationer. Upplägget kring de båda kategorierna ser olika ut och fungerar på relativt olika sätt. Det finns dock likheter som nedan lyfts fram.

I den första kategorin består fondens substansdelar av aktieinnehav. De handlas på en aktiebörs och är direkta ägandeandelar av ett företag. Stenkil (se *tabell 5*) arbetar på Swedbank som förvaltare till fonden Robur Ny Teknik. Traditionell fondförvaltning hanteras med en relativt svårdefinierad metodik berättar han. Från början måste fondens syfte utvärderas. Vilken marknad, bransch och geografiskt område ska fonden investera i? Ska fonden hantera aktier i företag av en viss storlek? Dessa frågor är de grundläggande byggstenarna för fonden. Att ta fram en watchlist med relevanta bolag blir nästa steg vilket är en relativt manuell process. Det sker en avsyning av marknaden där Stenkil tillsammans med kollegor analyserar bolag som kan tänkas vara relevanta. Dessvärre finns det ingen specifikt repeterbar metod för detta arbete enligt Stenkil, utan analysen varierar från bolag till bolag och involverar många kvantitativa faktorer. En stor del av jobbet går ut på att känna av marknaden, titta på trender i samhället och försöka avgöra vilka företag som kommer gå bra och vilka som kommer utvecklas sämre. Därifrån byggs portföljen upp.

Förvaltarna övervakar innehaven fonden har för att se till att inget innehav blir en för stor andel av fondens totala värde berättar Stenkil. Således kontrolleras även att risken inte ökar till för höga nivåer. Liknande tillvägagångssätt appliceras på branscher och geografiska områden för att minska risken och för att hålla korrelationen låg. Vid eventuell överrepresentation av någon bransch eller företag sker en ombalansering mot företag och branscher som för närvarande inte är lika stora i fonden.

Det finns ingen fullt automatiserad process i arbetet säger Stenkil. De flesta beräkningar som han tillsammans med andra fondförvaltare gör sker manuellt. Det finns en avdelning på Swedbank som ser till att fonden håller sig inom de ramar och regler som finns för kommersiella fonder och det finns stora delar i deras arbetssätt som är automatiserat påpekar han. Däremot är det ovanligt att deras arbete får någon påverkan på fondens upplägg då förvaltaren självmant håller sig inom tillåten utformning.

Skoglund (se *tabell 5*) är analytiker och förvaltare på Spiltan Fonder. Spiltan handlar likt Swedbank med aktier, dock ser deras investeringsprocess något annorlunda ut. Skoglund berättar att Spiltan har en noga genomtänkt investeringsprocess med flera olika steg för att hitta de innehav som passar in i Spiltans fonder. Skoglund beskriver att processen börjar med att företag som Spiltan inte anser vara hållbara sållas. Företag som handlar med exempelvis vapen och tobak väljs bort. Efter det väljer Spiltan bort företag som är för tidigt i sin resa, så kallade förhoppningsbolag. Det som karaktäriserar sådana företag är att de ännu inte är lönsamma säger Skoglund.

Efter denna process med att välja bort företag på ett ytligt sätt övergår processen till att se över hur verksamheten fungerar berättar Skoglund. Åtta investeringskriterier, vilka återfinns i *tabell 6*, går igenom för varje potentiell investering. Bolagen som uppfyller de åtta kriterierna och klarat de tidigare stegen i processen kan Spiltan sedan investera i säger Skoglund. Varje investerare har då en egen möjlighet att göra investeringen eller välja att avstå. Mycket handlar om en känsla berättar Skoglund. Hur det kändes under besöken på kontoren, hur väl investeraren tror ledningen kan klara av att hantera förändringar. Skoglund är också tydlig med att ingen av dessa steg är automatiserade. Det är faktiska investerare som ser över de ovan beskrivna stegen.

Tabell 6. Sammanställning av Spiltans investeringskriterier som potentiella investeringar utvärderas efter (Skoglund).

Investeringskriterium	Förklaring
1.	<p>Verksamhet som vi förstår Vi vill förstå hur produkten/tjänsten används, varför den efterfrågas och hur affärsmodellen fungerar. Hur ser konkurrensen ut?</p>
2.	<p>Förutsägbar verksamhet Bolagen vars verksamhet inte är alltför utsatt för yttre faktorer.</p>
3.	<p>Långsiktigt uthållig verksamhet Bolag vars verksamhet bedöms lönsam och efterfrågad även i framtiden.</p>
4.	<p>Uthålligt stabil marginal Gärna hög och växande, men inte för stor variation från år till år.</p>
5.	<p>Stabila intäkter och vinster Som inte fluktuerar för kraftigt mellan åren pga. yttre faktorer.</p>
6.	<p>Ärlig och rationell ledning Som fokuserar på långsiktigt aktievärde. Gärna också starka huvudägare.</p>
7.	<p>Stabil historik Vi vill att bolaget har bevisat sig kunna tjäna pengar och generera vinst i olika typer av marknadsklimat.</p>
8.	<p>Hållbar verksamhet Att bolagens verksamheter är långsiktigt hållbara. Bolag som arbetar långsiktigt med att minska eventuell negativ påverkan på miljö, människor och samhälle.</p>

I den andra kategorin består substanserna i fonden av företagsobligationer i högräntesegmentet. Stefan Westfeldt (se *tabell 5*) arbetar på företaget Vinga Corporate Bond som hamnar i denna kategori. Westfeldt beskriver att köpprocessen ser helt annorlunda ut jämfört med dagens aktiehandel. Det finns ingen börs för företagsobligationer utan de måste

köpas av obligationsförmedlare. Han beskriver köpprocessen som aktiemarknadens köpprocess på 80-talet då orderna rings in till ett aktiekontor som i sin tur genomför köpen.

För att välja ut vilka obligationer som ska vara med i Vingas fond görs noggranna analyser, både fundamentala och tekniska analyser (Westfeldt). Alla företag som potentiellt är aktuella för fonden definieras ur ett likviditetsperspektiv som utgår från daglig omsättning och hur den har förändrats över tid. Utifrån sådana analyser skapas en intern kreditrating säger Westfeldt, som sedan ligger till grund för köpbeslut. Stort fokus ligger på att hitta företag som haft god likviditet över tid för att få en stabilitet i portföljen. Den fundamentala delen lägger fokus på att förstå vad företaget har för potentialer genom att titta på bland annat humankapital i bolaget.

Det pågår en aktiv översyn av portföljen berättar Westfeldt. Varje vecka sker en kontroll där innehaven ses över för att på så vis se om något värdepapper blivit en för stor andel av den totala portföljen. Metoden de använder för denna översyn är delvis manuell men det finns automatiserade inslag. Till sin hjälp används en modell som kontinuerligt matas med data i realtid från Bloomberg. Westfeldt nämner flera parametrar som modellen övervakar i portföljen, bland annat storleken på innehaven, valutakurser och branschtäthet. Innehaven viktas och om modellen antyder att ombalansering behövs ser fondförvaltarna på Vinga det.

När marknaden är skakig, som våren 2020, märker Vinga av ett tryck att ta ut pengar berättar Westfeldt. En effekt av detta kundbeteende har blivit att vissa positioner säljs av vid snabba marknadsnedgångar för att skapa likviditet i fonden och på så vis vara beredda på uttag. Under vintern år 2022, till följd av att Ryssland invaderade Ukraina, skedde således en likvidering av del av Vingas positioner. Westfeldt trycker också på att det är viktigt att parera tidigt, innan det är för sent i en nedgång.

5.3 Resultat av experters syn på AI integrerade fondrobotar om fem år

I följande avsnitt redovisas resultatet från den genomförda delfistudien. Fokuset var på fondrobotbranschens framtid och teknikens utveckling, vilket undersöktes genom tre olika frågor. Intervjuobjekten har alla fått svara på dessa en gång under första intervjun. Efter att alla intervjuer genomförts sammanställdes svaren och skickades ut igen för att


intervjuobjekten skulle få ta del av panelens åsikter. En andra intervju genomfördes där personerna fått ta ställning till om sammanställningen påverkat deras tidigare svar. Svaren från andra omgången redovisas fråga för fråga och grupp för grupp för att lättare se likheter och skillnader som kommer tas upp i analysen. För att kunna tolka figurerna i underrubrikerna så hittas initialerna i *tabell 7*.

Tabell 7. En tabell som beskriver vilket intervjuobjekt som har vilka initialer.

Initialer			
Respondent	Företag	Kategori	Initial
Ahrner, Ulf	Fundler	Fondrobotförvaltare	U.A
Björklund, Oscar	Lysa fonder	Fondrobotförvaltare	O.B
Elliot, Viktor	Göteborgs Universitet	AI-expert	V.E
Jönsson, Henrik	Better Wealth	Fondrobotförvaltare	H.J
Lee, Francis	Chalmers Tekniska Högskola	AI-expert	F.L
Lindberg, Carl	Sigmastocks	Fondrobotförvaltare	C.L
Listo Zec, Edvin	RISE	AI-expert	E.L-Z
Skoglund, Fredrik	Spiltan Fonder	Fondförvaltare	F.S
Stenkil, Fredrik	Swedbank	Fondförvaltare	F.S*
Westfeldt, Stefan	Vinga Coperate Bond	Fondförvaltare	S.W

5.3.1 Fondrobotar om fem år

I detta avsnitt kommer svaren på frågan “Hur tror du fondrobotar kommer fungera om fem år?” presenteras. Resultatet delas upp mellan grupperna fondrobotföretag, fondförvaltare och AI-experter. Hur svaren förhåller sig till varandra åskådliggörs i *figur 8*.



Figur 8. Fördelning av svar på frågan “Hur tror du fondrobotar kommer att fungera om fem år?”

5.3.1.1 Svar från fondrobotföretag

Björklund (se *tabell 2*) på Lysa lyfter fram att skillnaderna troligtvis inte kommer vara så stora mot hur det ser ut idag. Marknaden är trögrörlig vilket leder till att det är svårt att se att några större förändringar kommer ske inom fem till tio år. Det finns stora aktörer i branschen som fortfarande vill att köpordrar faxas till dem berättar Björklund.

Jönsson (se *tabell 2*) på BetterWealth tror på en viss tillväxt för teknik inom fondrobotar. Marknaden blir generellt sett avskräckt när det kommer nya komplicerade produkter, dock finns det en strävan efter att skapa bättre analysmetoder och bättre sätt att optimera portföljer. Jönsson tror att hela sektorn kommer utvecklas under de kommande fem till tio åren då flera företag lägger stora resurser på maskininlärning och AI.

Lindberg (se *tabell 2*) på Sigmastocks säger att det finns en tudelad syn. Det hela beror på vad kunderna efterfrågar. Om kunderna efterfrågar Lysas koncept, alltså att följa ett index till så lågt pris som möjligt så är marknaden redan färdigutvecklad. Lindberg menar att det i så

fall inte finns någon större vinning i att fortsätta utveckla AI-integration då konceptet redan fungerar. Om kunderna istället efterfrågar det som Sigmastocks erbjuder finns det mycket kvar att erbjuda. Aktiv förvaltning med hjälp av AI och maskininlärning kommer fortsätta utvecklas och datainsamling kommer bli en vital del i varje förvaltningsbolags verksamhet. Samtidigt är finanssektorn en stängd marknad i den bemärkelsen att nya idéer och lösningar inte sprids vidare för att företags konkurrenskraft ska bestå. På grund av detta fenomen kommer mindre företag som de existerande fondrobotföretagen på den svenska marknaden inte att få tillgång till metoder och tekniker som stora finansinstitut använder, vilket hämmar utvecklingen menar Lindberg.

Ahrner (se *tabell 2*) på Funder tror att fondrobotar kommer förändras marginellt när det kommer till hur de tekniskt fungerar under en femårsperiod. Fondrobotar kommer inte jobba helt autonomt utan kommer behöva stöd av en mänsklig förvaltare så länge ett sparande ser ut som det gör idag med portföljer och innehav. Anledningen till detta är att det finns mycket information som ligger till grund för ett investeringsbeslut som inte finns i skrift eller digitalt. En AI-algoritm har inte möjlighet att ta del av den informationen på samma sätt som en mänsklig investerare har. För att en AI skulle kunna få samma förutsättningar som en mänsklig investerare hade all information behövt finnas digitalt, alternativt att all information som inte finns digital förbjuds och inom en överskådlig framtid är ingen av dessa är särskilt troligt. Däremot tror Ahrner att det kommer kunna ske förändringar kring hur produkten förändras mot kund.

5.3.1.2 Svar från fondförvaltare

Stenkil (se *tabell 5*) på Swedbank tror att konceptet med fondrobotar kommer bli allt vanligare. Orsaken är att det på en grundläggande nivå inte är svårt att vara fonrådgivare utan det är relativt enkla parametrar som kollas på. Kostnaden blir relativt hög när fonrådgivningen är manuell och som kund blir det relativt dyrt. Vad gäller förvaltning kommer algoritmer troligtvis bli bättre på att screena nyheter och presskonferenser och på så vis kunna göra en analys som är mer åt det fundamentala hållet. En algoritm skulle då kunna koppla ihop bolag med speciella sökord och skapa sig en bättre bild av företaget säger Stenkil. Sådana funktioner kommer troligtvis fungera som analysstöd istället för renodlad automatiserad förvaltning.

Skoglund (se *tabell 5*) på Spiltan fonder tror att fondrobotar kommer växa, inte minst på grund av att de har en relativt liten del av marknaden idag. Rent tekniskt är det svårt att avgöra hur de kommer fungera i framtiden säger Skoglund. Konceptuellt ser fondrobotar ut att fungera som en fond-i-fond vilket gör att fondrobotarna kan förhandla till sig lägre avgifter än privatpersoner.

Westfeldt (se *tabell 5*) på Vinga tror att AI-integrerade verktyg kommer att bli större och allt vanligare i framtiden. Analyser som tidigare inte kunnat göras genom AI kommer bli möjliga tack vare värderingsramverk som ESG men också genom att AI kan läsa av text i större utsträckning. Med utgångspunkt i investeringsmodellen som beskrivits i rapporten kommer automatisering att röra sig mer mot den tidigare delen av processen. Genom tidigare nämnda användningsområden kommer den att kunna vara en del av en fundamental analys i större utsträckning än idag (Westfeldt).

5.3.1.3 Svar från AI-expertter

Tabell 8. Tabell över intervjuerna som hållits med AI-expertter.

Intervjuer				
Respondent	Företag	Titel	Datum intervju 1	Datum intervju 2
Elliot, Viktor	Göteborgs Universitet	Doktor företagsekonomi	23 mars 2022	20 april 2022
Lee, Francis	Chalmers Tekniska Högskola	Docent och forskare	8 april 2022	25 april 2022
Listo Zec, Edvin	RISE	Doktorand med fokus på federated learning och distribuerad maskininlärning	6 april 2022	20 april 2022

Elliot (se *tabell 8*) är doktorand inom företagsekonomi och arbetar på Göteborgs universitet. Elliot tror på en fortsatt automatisering av fondrobotar även i framtiden. AI kommer troligtvis inte användas helt självständigt för att ta investeringsbeslut, dock finns redan idag rådgivning

som bygger på maskininlärning/AI. Den utveckling som kommer ske under fem till tio år kommer i större utsträckning innebära en ökad automatisering vilket leder till förändrade arbetsuppgifter för fondföretagen. AI har stor potential att analysera stora datamängder, vilket det finns gott om i finansbranschen.

Lee (se *tabell 8*) är docent i teknik och sociala förändringar på Chalmers tekniska högskola. Lee lyfter fram några problem som kommer begränsa fondrobotars tekniska framväxt. Ett av de större problemen är att det är svårt att spåra besluten en AI tar. Vad var det som fick en AI att agera på ett visst sätt är något som kommer vara svårt att svara på. Kopplat till detta problem finns dessutom lagmässiga hinder. Enligt EU:s lagstiftning ska investeringsbeslut kunna spåras och redovisas, vilket kan vara svårt att göra om det är en AI som tagit beslutet.

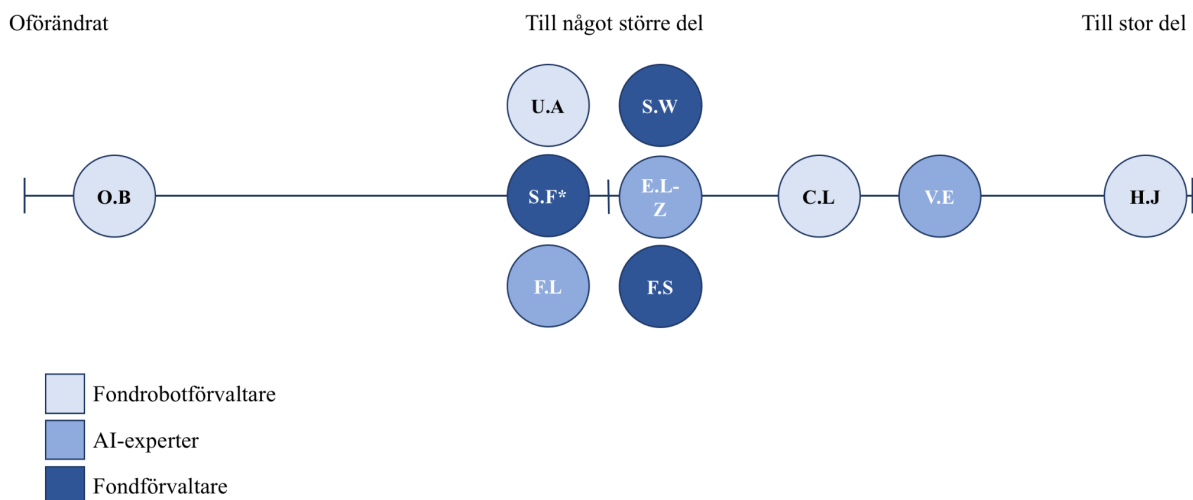
Lee tror fortsättningsvis att AI-implementation kommer öka i alla investeringsformer. Större investmentbolag kommer använda dessa avancerade AI-algoritmer för att hitta mönster som människor inte klarar av att se långt före fondrobotbolagen kommer använda sig av sådan teknik.

Listo Zec (se *tabell 8*) jobbar på RISE med forskning inom maskininlärning med fokus på deep learning. Listo Zec tror att fondrobotar troligtvis kommer fungera på liknande sätt om fem år som de gör idag. Ny teknik kommer implementerats och AI kommer bli vanligare och vanligare i fondrobotarna. Däremot är det inte sannolikt att algoritmerna kommer operera på helt egen hand, den kommer troligtvis mer fungera som ett beslutsstöd. AI har implementerats i många branscher och marknader men ännu har vi inte sett att AI tagit över människans jobb helt och hållet.

5.3.2 AI:s påverkan på portföljhantering inom fem år

I detta avsnitt kommer svaren för frågeställningen “Tror du att AI kommer att vara en stor del av (er) portföljhantering om fem år” att presenteras. Resultatet från varje grupp av panelen kommer att presenteras separat i enlighet med strukturen från avsnitt 5.3.1. För AI-experten och traditionella fondförvaltare har frågan ställts utan “er” eftersom dessa grupper med största sannolikhet ej kommer bedriva någon form av AI-baserad portföljhantering. Hur svaren förhåller sig till varandra åskådliggörs i *figur 9*.

Tror du att AI kommer att vara en stor del av (er) portföljhantering om fem år?



Figur 9. Fördelning av svar på frågan “Tror du att AI kommer att vara en stor del av (er) portföljhantering om fem år?” utplacerade på en skala mellan “Oförändrat” och “Till stor del”.

5.3.2.1 Svar från fondrobotar

Björklund (se *tabell 2*) tror att AI och maskininlärning kommer utgöra en större del av Lysas verksamhet än vad den gör idag men främst som ett verktyg. Eftersom det finns flera olika lagar som måste följas kan helt AI styrda portföljer bli problematiska och han har även sett på andra försök att driva portföljer enbart med AI/maskininlärning inte varit så lyckosamt. För Lysa kommer AI och maskininlärning främst att hjälpa till att screena marknaden för bättre fonder att utöka den redan existerande portföljen.

BetterWealths Jönsson (se *tabell 2*) förklarar att AI har stora möjligheter inom finansbranschen. Samtidigt poängterar han att det krävs väl definierade problem samt data för att den ska kunna nå upp till sin fulla potential. I princip alla aktörer på marknaden investerar eller studerar utvecklingen. Samtidigt är det viktigt att veta att AI inte är någon magisk lösning som kommer kunna förutse krascher eller berätta vilka företag som kommer gå upp imorgon understryker han. BetterWealth och Jönsson har en stor tilltro till AI:s potential och vill ligga i framkant av användningen utav AI-integrerade verktyg. Anledningen till detta är AI:s förmåga att hantera stora volymer av data något som människor inte är i närheten av att kunna göra.

Lindberg (se *tabell 2*) anser likt föregående fråga att utvecklingen beror på hur kapplöpningen om marknadsandelar utspelar sig. Om marknaden efterfrågar produkter som inte enbart följer index finns det utrymme för vidareutveckling och en ökad användning av AI inom portföljhantering. Dock kommer data troligtvis inte hanteras utav företagen själva utan den kommer finnas i genererade datamängder som levereras av andra företag. Företag som exempelvis Google kommer generera dessa datamängder tror Lindberg. AI skulle kunna användas för att avgöra om olika signaler/ faktorer kommer påverka portföljen samt aktier på ett positivt eller negativt sätt.

Ahrner (se *tabell 2*) på Funder tror att inom de fem kommande åren kommer produkten digital rådgivning att ha utvecklats och möjligtvis förändrats där AI kan få en större betydelse. Eftersom tjänsten är så ny kommer det ske mycket på just denna marknad. Största problemet med att ha en helt AI styrd portfölj är att så mycket information fortfarande inte finns digitalt som kan vara av yttersta vikt. På grund av bland annat detta problem kommer inte något större skifte ske i branschen men Ahrner tror samtidigt att AI verktyg kommer fortsätta utvecklas till att vara ett allt viktigare verktyg för människan.

5.3.2.2 Svar från fondförvaltare

Stenkil (se *tabell 5*) på Swedbank tror att AI-baserade hjälpmedel kommer bli allt vanligare, verktyg som screenar olika nyhetskällor som bolagsstämmor och nyhetsartiklar. Inom en femårsperiod kommer inte portföljhantering att bli helt AI-styrt utan endast ett större verktyg.

Skoglund (se *tabell 5*) på Spiltan Fonder anser inte att AI kommer kunna hantera portföljer helt på egen hand i framtiden utan kommer bli ett mer avancerat verktyg som används i större utsträckning. Utvecklingen kommer gå framåt och AI kommer bli en viktigare del i förvaltning men på en femårsperiod endast som ett verktyg. Troligtvis kommer inte heller verktygen utvecklas internt utan köpas in av andra företag som innehar en större expertis på just tillverkning och skapandet av verktyget.

Westfeldt (se *tabell 5*) på Vinga förklarar att fundamental analys byggd på personalens skicklighet och erfarenheter är kärnan i deras verksamhet. På grund av att stor vikt läggs på denna typ av analys kommer Spiltan ej använda sig av portföljer som styrs helt av AI. Han tror främst att AI kommer användas som ett kraftfullare analysverktyg. Genom dessa verktyg

kommer den fundamentala analysen kunna kompletteras med en teknisk analys i större utsträckning något som inte är möjligt idag för dem menar Westfeldt.

5.3.2.3 Svar från AI-expert

Elliot (se *tabell 8*) berättar att redan idag testas dessa typer av portföljer. Förmågan att hantera större mängder ostrukturerad data kommer bara att öka. Det kommer inte finnas någon AI som kan hantera alla typer av data utan vara specialiserade på olika områden. Troligtvis kommer det användas som ett beslutsverktyg för att ta snabbare och bättre beslut vid förändringar i marknaden.

Lee (se *tabell 8*) anser att problematiken med lagstiftningen är något som måste lösas innan AI styrd portföljhantering kan användas. Eftersom alla beslut måste kunna redovisas behövs nya funktioner som för närvarande inte finns. På grund av dessa krav kommer AI främst användas som ett beslutsverktyg till mänskliga förvaltare. AI:s styrka att hitta korrelationer i stora datamängder är något som går långt utöver den mänskliga förmågan och något som kommer vidareutvecklas i framtiden. Dessa mönster kan sen människor använda för att göra ytterligare analyser.

Listo Zec (se *tabell 8*) tror inte helt AI styrda portföljer kommer finnas utan att de kommer användas i större delar av beslutsprocessen. Inom områdena analys och optimering kommer AI främst att ta en större plats. AI kan ge underlag till beslut men de krävs kunskap kring vilken typ av data som ska användas för träning. Största hindret är troligtvis att bruset är så stort och svårfilterat, eftersom AI bygger alla sina beslut på tidigare erfarenheter är bra träningsdata av yttersta vikt något som inte finns idag.

5.3.3 AI:s förmåga att förutse och hantera börskrascher inom fem år

I detta avsnitt kommer svaren på frågan "Oavsett om ni använder AI idag eller inte, tror du att AI skulle kunna förutspå innan marknaden blir mer orolig för att eventuellt balansera om till mer räntor?" presenteras. Resultatet delas upp mellan grupperna fondrobotföretag, fondförvaltare och AI-expert. Hur svaren som erhållits förhåller sig till varandra åskådliggörs i *figur 10*.

mot förmodan ändå skulle finnas möjlighet att förutse marknadsnedgångar kommer små aktörer som de som finns på den svenska marknaden aldrig kommer få reda på det. Däremot tror Lindberg att det med AI kommer vara möjligt att estimerar risken för stora nedgångar på ett bättre sätt än idag. Med hjälp av avläsning av nyheter, sociala medier och så vidare införskaffas mycket data som kan bearbetas. Det viktiga blir att hantera det brus som uppstår på ett bättre sätt än alla andra.

Ahrner (se *tabell 2*) på Funder menar att om AI skulle kunna förutspå marknadsnedgångar skulle det i så fall bygga på vissa saker. En AI kan leta efter fel där konsensus avviker från verkligheten. Felaktiga värderingar som exempelvis ett övervärderat bolag skulle en AI kunna hitta på ett effektivare sätt än en människa vilket är ett möjligt sätt för AI att identifiera marknadsnedgångar. En AI kommer dock inte kunna identifiera alla sådana signaler. Det finns så mycket information som en AI inte kommer ha tillgång till som är vital för att förutspå en börsnedgång. Ahrner drar en parallell till Rysslands invasion av Ukraina. För att förutspå den börsnedgång som kom till följd av denna händelse hade en AI behövt veta hur Putin tänker. Det är information som alltså inte finns i skrift eller på något sätt tillgänglig för allmänheten. Det finns alltså så mycket information som en AI inte kan komma åt som är nödvändig för att förutspå hur en marknad kommer röra sig.

5.3.3.2 Svar från fondförvaltare

Stenkil (se *tabell 5*) på Swedbank menar att det krävs information kring hur beslutsfattare tänker och vad de har för planer för att kunna förutspå hur marknaden kommer röra sig. Att en algoritm skulle kunna veta allt detta är osannolikt, framför allt inom en femårsperiod. Det är så många faktorer som samspelar och påverkas av faktorer som inte har faktisk data att det är svårt att bygga den helhetsbild som krävs för att förutspå en marknadsnedgång.

Skoglund (se *tabell 5*) på Spiltan Fonder säger att det inte är sannolikt att AI skulle kunna användas för att förutspå börskrascher. Om alla vet att en marknad ska krascha om en månad kommer alla vilja sälja idag och vad händer då? Det hela kommer bli en hönan-eller-ägget situation där det är svårt att säga vad som kommer först och vad som utlöser vad. Det kommer alltså vara mycket svårt att förutspå framtida marknadsvängningar.

5.3.3.3 Svar från AI-experten

Elliot (se *tabell 8*) tror att AI kommer få en ökad förmåga att göra prediktiva analyser som kommer vara till hjälp vid ombalansering, dock inget som en AI gör helt själv. En AI kommer säkerligen kunna ge förslag på ombalansering, det är dock inget som garanterar att dessa förslag är rätt eller att de kommer vara till fördel. Det finns en problematik i vilken information som en AI har möjlighet att nå. Den information som finns digitalt i form av exempelvis siffror, samt årsredovisningar, det som kallas publik information, är inga problem för en AI. Däremot blir det problematiskt med privat information, vilket är information som kan sägas på en bolagsstämma eller information som kan införskaffas vid besök hos företag. Denna information är extremt svår för en AI att nå då den inte finns digitalt. Avsaknad av viss information är alltså något som kraftigt begränsar en AI i detta avseende säger Elliot.

Lee (se *tabell 8*) trycker på att historisk data inte förutsäger framtiden. En AI kan tränas på historisk data och till slut prestera mycket bra på historiska data, vilket dock säger mycket lite om hur den kommer hantera framtida data och om dess prediktioner faktiskt är bra. Det är dessutom mycket svårt att se vilka faktorer som utlöser exempelvis en krasch. Vad var egentligen den bakomliggande orsaken till att marknaden gick ner och vad får det för följd på framtiden? Det är oerhört komplexa samband säger Lee. Att då passa in denna mycket komplexa värld i en algoritm är svårt. Lee lyfter även fram att det kan vara bra att fundera på om det verkligen är önskvärt att kunna förutspå marknaden. Om det går att tjäna pengar på det kommer folk göra det vilket kan leda till att funktionen inte används på det sätt som är önskvärt.

Listo Zec (se *tabell 8*) på RISE säger att det är ett mycket komplext problem. Grunden bygger på att det ska finnas data att träna AI på och att det faktiskt finns signaler i den datan på att det sker en krasch. Om det då går att träna en AI och den lär sig att se signaler finns dock risken att det blir fel ändå. Det kan uppstå signaler som en AI ser som ett tecken på att marknaden är på väg ner utan att det faktiskt sker en krasch. Ett annat problem är det finns mycket hemligheter inom finansbranschen, alltså information som inte finns tillgänglig för allmänheten, vilket definitivt påverkar möjligheterna för en AI att förutspå framtiden. Det handlar alltså till stor del om det går att få tag på den data som krävs vilket det inte gör just nu.

6. Analys

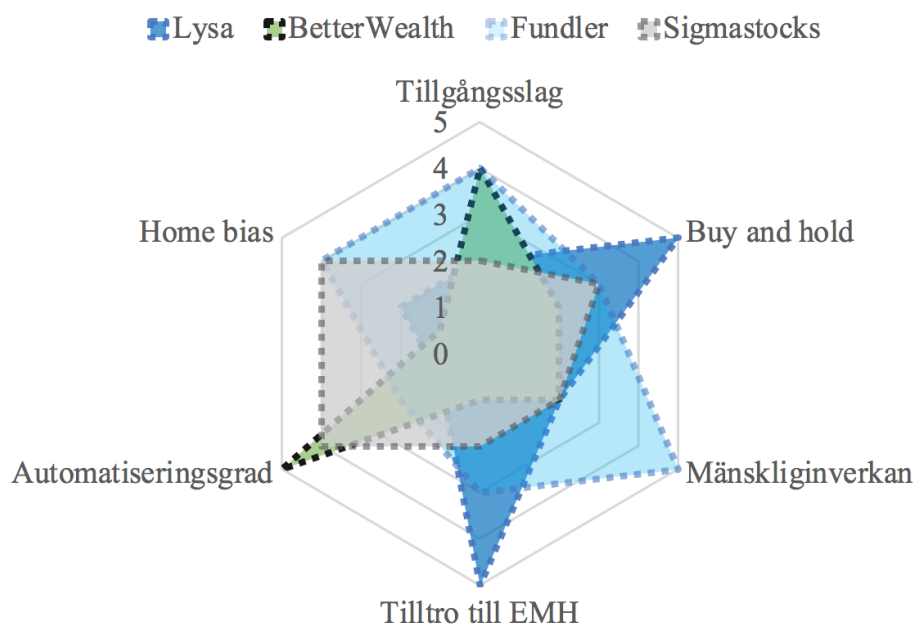
I detta kapitel kommer en kritisk analys av resultatet att genomföras med stöd av litteraturen från tidigare kapitel. Analysen kommer delas upp i två delar, en del för varje frågeställning. Första delen är en analys av den svenska fondrobotmarknaden. Vilket följs av den andra delen som är en analys av hur AI integrerad portföljhantering om fem år skulle kunna hantera stora marknadsnedgångar. Analysen kommer vara grunden till slutsatser som fastställs i nästkommande kapitel.

6.1 Analys av dagens fondrobotar

Efter att ha kartlagt fondrobotarna BetterWealth, Funder, Lysa och Sigmastocks är det tydligt att det finns flertalet likheter och olikheter mellan de respektive aktörerna. De många likheterna som finns skulle kunna ses som ett bevis på att de delarna fungerar bra och att dessa har blivit marknadsstandard. Trots detta finns det tro på att även områden där fondrobotarna har samma strategi skulle kunna effektiviseras. Där aktörernas strategier skiljer sig åt grundar det sig ofta i investeringsfilosofi och hur respektive företag valt att utforma sina tjänster. Nedan följer analys av hur fondrobotarna ser ut i dagsläget men beroende på hur teknikutvecklingen sker och vilken tjänst som lyckas bäst, både sett till antal användare men även avkastning och risknivå, kan det i framtiden vara ett koncept som vinner över de andra. Det skulle isåfall betyda att tjänsterna kommer konvergera mot detta och blir mer snarlika. Det som talar mot konvergeringen är att det inom finansbranschen är extra viktigt att ha en nisch för att hitta investeringar som andra inte gör och därmed kunna göra vinster.

För att lätt kunna jämföra företagen mot varandra presenteras fondrobotarna och några av deras egenskaper i relation till varandra i polärddiagrammet i *figur 11*. I diagrammet visas tydligt hur stor grad varje företag använder sig av respektive faktor. Viktigt att notera är att värdena är tydligt kopplade till deras investeringsfilosofi och är således inte ett betyg. Det blir i diagrammet tydligt att alla fondrobotarna har unika egenskaper och var de skiljer sig från varandra. Funder har totalt mest mänsklig inverkan, något som de anser förbättrar tjänsten medan Lysas strategi kan kopplas till en stark tilltro till Efficient Market Hypothesis (EMH). BetterWealth är unika i sin höga utsträckning av automatisering inom optimering och ombalansering. Sigmastocks särskiljer sig mest mot övriga genom att hantera aktier direkt

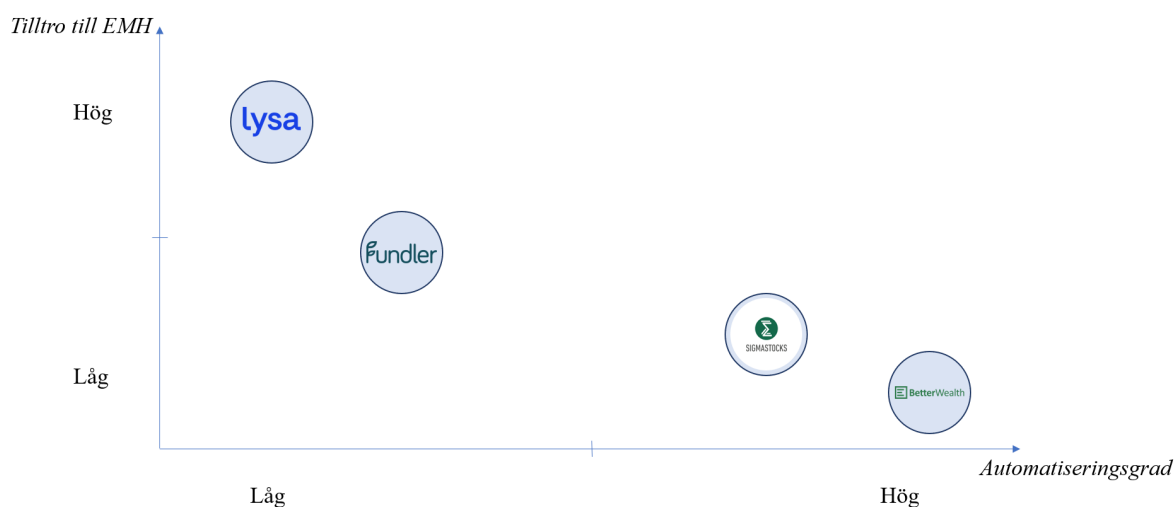
och inte fonder, vilket gör att Sigmastocks kan göra varje portfölj unik jämfört med resterande företag.



Figur 11. Övergripande analys av de respektive fonderobotarna och vilka fokusområden de har i dagsläget, visualiserat i ett polärtdiagram.

Synen på marknaden och dess effektivitet gör att företagen väljer olika strategier för att uppnå en så god avkastning som möjligt givet en viss risk. Efter intervjuerna är det tydligt att strategierna direkt kan kopplas till EMH trots att detta inte nämns rakt ut. Lysa som har det mest blygsamma avkastningsmålet av företagen har samtidigt en relativt stark tilltro till EMH. Björklund (se *tabell 2*) förklarade under en av intervjuerna att det är svårt att kontinuerligt generera överavkastning. Med hänsyn till detta vill Lysa försöka följa marknaden och genom låga avgifter skapa en överavkastning för kunden. Strategin står i kontrast mot de övriga företagen och främst BetterWealth som med hjälp av maskininlärning vill balansera om flera av sina dynamiska portföljer beroende på marknadsfas och på det sättet få en överavkastning utan en högre risk. Efter intervjuerna kan det konstateras att Funder och Sigmastocks befinner sig mellan ytterligheterna; Lysa och BetterWealth. Både Funder och Sigmastocks anser att det går att skapa någon form av överavkastning men att målsättningen att slå marknaden med mer än någon enstaka procent är vågat. Genom att använda sig av olika strategier inom optimering och ombalansering kan de få små fördelar men sällan mer än några enstaka procent beskriver Lindberg (se *tabell 2*).

Trots att Fundler befinner sig i mitten av företagens tilltro till EMH sticker de ut med sin kombination av robot och människa. Till skillnad från övriga så belyser Fundler att de använder sig av mänskliga förvaltare som hjälper till att optimera portföljen. Arhner (se *tabell 2*) beskrev att de i denna process behöver göra antaganden och att en människa är bättre på detta än en robot. Även förmågan att göra en fundamental analys är människan bättre på menar Ahrner. Kontrasten är stor eftersom resterande inte uttalat använder sig av människor i samma utsträckning utan låter förvaltare se över processer vid ombalansering och köp istället.



Figur 12. Fondrobotarnas respektive automatiseringsgrad och tilltro till EMH gentemot varandra.

En iakttagelse som kan göras i *figur 12* är att automatiseringsgraden för respektive fondrobots portföljhantering, framförallt beträffande analys, portföljoptimering och ombalansering, har ett starkt samband med respektive företags tilltro på EMH. Lysa och Fundler som har en högre tilltro till EMH har relativt sett en lägre automatiseringsgrad gentemot Sigmastocks och BetterWealth som har en högre automatiseringsgrad men lägre tilltro till EMH. Anledningen är att företagen som vill slå ett index måste prestera bättre än marknaden, där hög automatisering med maskininlärning eller AI skulle kunna vara en väg att gå för att slå index. Å andra sidan skulle ett annat sätt att slå index vara att lägga mer tid på fundamental analys och bearbeta privat information i större utsträckning, vilket är det traditionella fondförvaltare med aktiv förvaltning gör. Problemet med det är att den låga förvaltningsavgiften som fondrobotarna har i så fall uteblir. Skulle AI:n istället utvecklas så att den kan hantera och analysera privat information uppstår istället problemet att den informationen är svår att komma åt digitalt.

För att uppnå riskavvägda portföljer som genererar avkastning motsvarande risken diversifierar samtliga aktörer sina portföljer med olika tillgångsslag. Som kan utläsas i *tabell 9* går det att diversifiera på olika sätt. Sigmastocks och Lysa använder sig endast av två tillgångsslag och använder sig av samma tillgångsslag samtidigt som BetterWealth och Fundler skiljer sig åt i sina fyra olika tillgångsslag. Flera av företagen har lyft värdet av att produkten ska vara lättförståelig vilket är något som kan ligga till grund till varför Lysa och Sigmastocks endast valt att använda sig av samma och just dessa två tillgångsslag. Aktier och räntor är de två tillgångsslagen som flest människor känner sig bekväma att investera i. Som tydligt illustreras i *figur 11* har Fundler och BetterWealth fyra tillgångsslag samt en vilja att överprestera marknaden. De två företagen har dock varsin strategi för åstadkomma överavkastning. Fundler använder sig av mänsklig påverkan i hög utsträckning jämfört med BetterWealth som använder sig av datorkraft. Denna skillnad i strategi visas tydligt i *figur 11*.

Tabell 9. Tabell för tillgångsslagen som respektive fondrobot investerar i.

Bolag	Tillgångsslag
Lysa	Aktier och räntor
Fundler	Aktier, guld, obligationer och optioner
Sigmastocks	Aktier och räntor
BetterWealth	Aktier, räntor, alternativa tillgångsslag och råvaror

Fondrobotarna använder sig av flera tillgångsslag vilket syns i de olika typerna av tjänster som erbjuds. Lysa som kan förknippas med en något starkare tilltro till EMH vill uppnå en jämn fördelning med hela marknaden vilket är anledningen till att de vill uppnå en god diversifiering med endast aktier och räntor. BetterWealth använder istället sina tillgångsslag för att försöka skapa en överavkastning oavsett marknadsfas och anser därför att flera sorter behövs. Till skillnad från Sigmastocks och Lysa använder både Fundler och BetterWealth sig av guld i flera portföljer för att säkra upp när volatiliteten ökar eftersom guld generellt har en negativ korrelation mot marknaden och därför presterar bättre vid nedgångar.

Diversifiering är även den huvudsakliga metoden som svenska fondrobotar använder för att minska marknadssvängningars påverkan på portföljerna. Samtliga fondrobotar använder någon form av diversifiering för att minska korrelationen mellan tillgångarna i varje portfölj. Att samtliga fondrobotar använder någon form av Modern Portfolio Theory (MPT) kan därför konstateras. Det är dock ingen av dem som beskriver sin teori som MPT. Tydligt är att tankesättet är detsamma då de diversifierar portföljerna och vill ha låg korrelation mellan tillgångarna. Samtliga har ett eget sätt att tolka teorin för att uppnå en diversifierad portfölj. Genom att åstadkomma låg korrelation i portföljerna kan avkastning från olika tillgångar balansera ut varandra eftersom fallet sällan är så att samtliga marknadssegment eller länders tillgångar presterar bra samtidigt.

Samtidigt fokuserar tre av fyra fondrobotar som kartlagts i denna studie på att använda sig av home bias, alltså att tillgångar i hög utsträckning väljs från den svenska börsen. BetterWealth är de enda som ställer sig mot denna metod och påstår att det inte är hållbart att arbeta med home bias. Det finns dock vissa fördelar menar Sigmastocks, Lysa och Funder. De tre fondrobotarna beskriver valutarisken som uppstår vid handel av tillgångar utanför den svenska marknaden. Den skulle potentiellt kunna motverka fördelen som den höga diversifieringen av tillgångar i marknader i olika världsdelar. Ett annat motiv till att placera stora delar av portföljen i den svenska marknaden och norden lyfts fram av Ahrner som beskriver att den svenska börsen är en av de börser som historiskt genererat högst avkastning i världen.

För att kunna hantera kraftiga marknadsnedgångar krävs fler metoder än bara diversifiering. Dessa metoder varierar hos de undersökta fondrobotarna beroende på investeringsfilosofi samt investeringsmål. Lysa och Sigmastocks tror inte att det går att förutspå marknadssvängningar. Lysa, som vill följa index, gör inget aktivt försök att undvika kraftiga marknadsnedgångar vilket innebär att de följer nedgångar likaväl som uppgångar. De har en stark buy and hold strategi vilket illustreras i *figur 11*. Funder och Sigmastocks utför dock en mer kontinuerlig analys för att eventuellt optimera om portföljerna och har därmed inte en lika hög grad av buy and hold som Lysa. Även Sigmastocks anser att det inte är lönt att försöka förutsäga och tajma marknaden. Istället sker kontinuerlig analys av volatiliteten på marknaden för att kunna ombalansera sina portföljer om signifikanta förändringar skett. Då ombalanseringen sker i efterhand kan strategin benämnas som reaktiv.

Fundlers erbjuder sina kunder flera portföljer. De har likt Lysa, index baserade portföljer. Utöver de index baserade portföljerna erbjuder de även mer avancerade portföljer, exempelvis deras hedgeportfölj. Hedgeportföljen använder sig av en hedging strategi och innehåller bland annat guld eftersom det historiskt varit en säker tillgång under nedgångar. I *figur 7* går det att se att portföljen hade positiv avkastning vid marknadsnedgången 2022 som orsakades av att Ryssland invaderade Ukraina, vilket åskådliggör effektiviteten i strategin. Dock krävs det att portföljen konstant innehåller dessa säkrare tillgångar vilka ofta har lägre förväntad avkastning än andra tillgångar vid normala marknadsförhållanden. Således kan portföljer som inkorporerar denna strategi ha lägre förväntad avkastning än andra under normala marknadsförhållanden.

Den stora skillnaden mellan Fundlers hedgeportfölj och BetterWealths dynamiska portfölj är att BetterWealths strategi är mer aktiv i dess karaktär. De använder sig av klustermetoder, likt GARCH för att identifiera vilken marknadsfas marknaden befinner sig i. BetterWealths portföljer optimeras och ombalanseras sedan för att prestera bra i både den rådande och den framtida, förväntade marknadsfasen. Om den prediktiva modellen indikerar att nästkommande marknadsfas kommer vara mer volatil kan en portfölj komma att byggas med säkrare tillgångar. Detta sker för att anpassa risken i portföljen i förhållande till marknaden. Fundlers hedgeportfölj är till skillnad från BetterWealths portföljer varken proaktiv eller reaktiv då den hela tiden innehar tillgångar med negativ korrelation mot övriga marknaden samt optioner.

BetterWealths modell saknar dock förmågan att exakt tajma marknadshändelser genom ombalansering av portföljerna. Vid Coronakraschen 2020 skedde en ombalansering av de dynamiska portföljerna först efter det att nedgången inletts. Under den kraftiga uppgång som följde fortsatte dock BetterWealths modell indikera på att marknaden var stressad vilket ledde till att deras dynamiska portföljer underpresterade den generella marknaden.

Händelserna 2020 indikerar att BetterWealths modell presterar sämre då plötsliga och kraftiga förändringar sker på börsmarknaden. Då modellen syftar till att identifiera marknadsfaser bör den således ombalansera med bättre resultat vid långsammare marknadssvängningar. En möjlig förklaring till problematiken vid Coronakraschen 2020 är att de plötsliga händelser som sker på börsmarknaden ofta klassas som black swan events. Dessa händelser innebär en

avsaknad av förklarande data innan händelsen ägt rum vilket gör det i stort sett omöjligt för en modell att kunna agera på förhand.

Utöver att det kan ske händelser på börsmarknaden som aldrig inträffat tidigare kan avsaknaden av data även vara orsakad av människor. All information finns inte alltid tillgänglig på marknaden eller så är denna datan felaktig vilket är något som flera av de intervjuade fondrobotföretagen och fondförvaltarna nämnt. Ett exempel som gavs var att datan 2007 innan finanskrisen 2008 pekade på att allt såg bra ut. I grund och botten var detta ett fall av felaktig publik information vilket ledde till att analyser och prognoser som gjordes på denna data även de blev felaktiga. Då finansbranschen idag bygger på så stora mängder data är det inte omöjligt att liknande problem förekommer eller kommer fortsätta förekomma i framtiden. Då de undersökta fondrobotarna kräver data för att deras strategier ska fungera kan denna problematik vara ett hinder som minskar deras handlingsförmåga.

Sammanfattningsvis finns det flertalet skillnader mellan fondrobotarna på den svenska marknaden bland flera parametrar där bland annat tillgångsslag, Buy and hold- strategi, mänsklig inverkan, tilltro till EMH, automatiseringsgrad och home bias skiljer sig åt mellan dem. En koppling mellan företagets investeringsteori och strategierna kan ses. Ingen av fondrobotarna använder en av de klassiska investeringsteorierna rakt av. Att strategierna grundar sig i MPT kan dock tydligt ses. Vem som kommer vinna racet beror dock helt på vad kunderna kommer efterfråga. Kommer AI eller människor att användas i högre utsträckning för att kunna nå en överavkastning eller är det index och förståelse för portföljen som vinner?

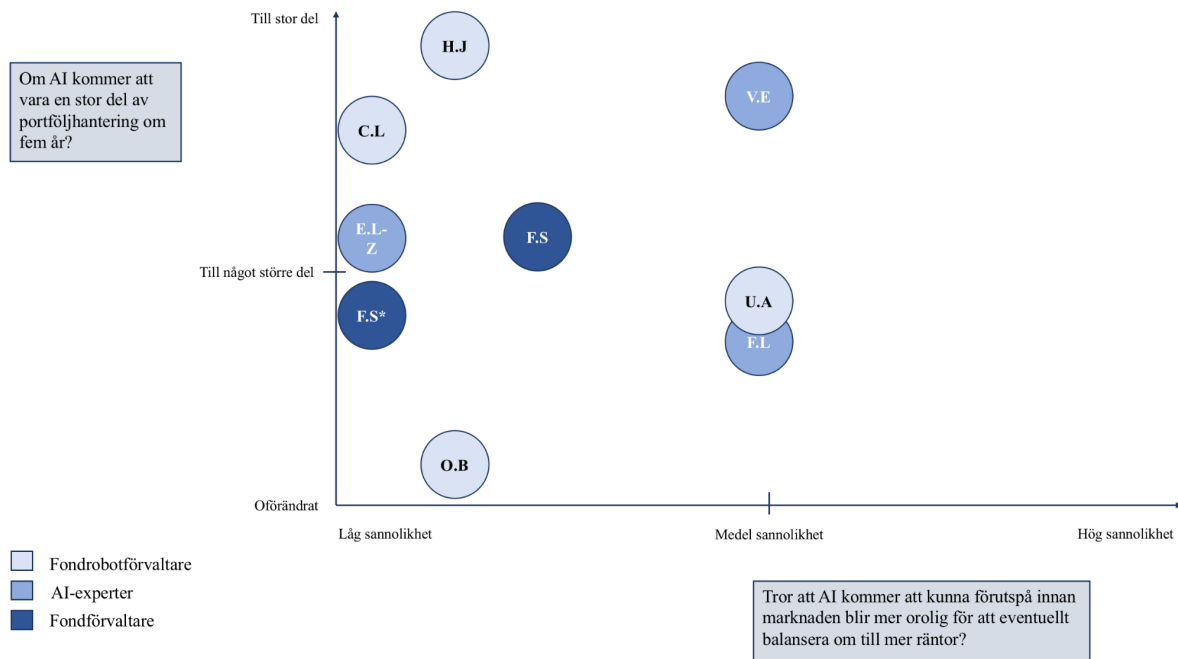
6.2 Framtidens fondrobotar

Analysen för frågeställningen "Hur skulle AI integrerade fondrobotar om fem år kunna hantera liknande situationer där det sker stora förändringar på börsmarknaden?" kommer bygga på två delar, litteraturstudie och delfistudie. Analysen ska bilda en uppfattning om vad områdets experter tror om framtiden och vad som kommer att förändras inom fondrobotbranschen. För att analysen ska breddas används experter från olika branscher med kunskap inom området. En iakttagelse som gjorts är att samtliga av de utfrågade tror att AI kan komma att vara nytta i någon grad inom portföljhanteringen och att AI kommer fungera som ett stöd. Ingen tror dock att AI på egen hand kommer att sköta förvaltningen, vilket är på grund av bristen på bra träningsdata.

Det finns skillnader bland experternas åsikter angående hur stor utsträckning AI tros kunna hjälpa till med analys av marknaden och bolag. Björklund (se *tabell 2*) på Lysa tror inte AI kommer ha någon större inverkan på deras verksamhet i detta steg, medan Jönsson (se *tabell 2*) på BetterWealth tror att AI har stor potential när det kommer till att analysera marknader och bolag. Lindberg (se *tabell 2*) från Sigmastocks sammanfattar just detta när han får frågan om hur fondrobotar kommer fungera om fem år genom att säga att det beror på vilket koncept som vinner, ett mer indexfokuserat koncept eller ett koncept med fokus på överavkastning.

Uppfattningen om att AI kommer fungera just som ett analysverktyg, och inte som en autonom funktion som ombalanserar helt själv, är gemensam för samtliga intervjuobjekt. Framför allt två argument lyfts fram som styrker denna uppfattning. Dels legala hinder och dels att AI inte kommer vara tillräckligt utvecklad om fem år. Fondrobotföretagen ser att de legala hinder som finns idag gör det svårt för dem att fungera på något annat sätt. Investeringsbeslut ska kunna redovisas och för att göra det behöver besluten kunna spåras, vilket idag inte går. Orsaken till detta är att en AI oftast uppför sig som en svart låda, vilket får effekten att det är svårt att härleda vilka faktorer som ligger till grund för ett beslut. Den andra anledningen, att teknikutvecklingen troligtvis inte kommer ha gått så fort, gör att AI-experterna inte tror att AI kommer operera felfritt. Således kommer fortfarande övervakning av en mänsklig fondförvaltare att krävas.

Om besluten går att spåra finns förutsättningar för att portföljhantering kan automatiseras. Abraham et al. (2019) presenterade i sin studie en möjlig lösning till detta problem. För det första måste regleringar införas som alla fondrobotar kan förhålla sig till. För det andra behöver en översikt över vad robotrådgivare kan åstadkomma men också vilka begränsningar som finns ges. Precis som Abraham et al. (2019) påpekar Elliot (se *tabell 8*) just detta. Reglerna behövs för att skydda kunderna och kunna hålla någon ansvarig för investeringsbesluten som tagits.



Figur 13. I denna figur åskådliggörs i vilken grad fondrobotförvaltare, AI-experter och fondförvaltare tror att AI kommer vara en del av portföljhantering samt om AI kommer kunna förutspå att en marknad kommer bli mer orolig. Se *tabell 7* för initialer.

I *figur 13* presenteras det tydligt att expertpanelen generellt är positiva i frågan om att AI kommer att användas mer vid portföljhantering i framtiden än vad som görs idag. Det är dock ingen av experterna som i någon större utsträckning tror att AI kommer kunna förutspå en krasch och då potentiellt balansera om till mer säkra tillgångar för att undvika ett börsras. Expertgruppens åsikt är istället att AI kommer att användas till andra analyser.

Att ingen av experterna tror att AI, inom fem år, kommer att kunna förutspå en marknadskrasch har bland annat att göra med avsaknad av bra träningsdata. Både Listo Zec (se *tabell 8*) från RISE och Skoglund (se *tabell 5*) från Spiltan lyfter fram detta som anledningar. Skoglund poängterar även att parametrar har olika betydelser i olika situationer. Bara för att något har varit lyckosamt tidigare betyder det inte att det kommer vara så i framtiden. Detta understryker Listo Zecs resonemang om svårigheterna med att få fram bra träningsdata. Även Lee (se *tabell 8*) ser problematiken och varnar för att det är svårt att avgöra hur en AI skulle agera i nya situationer vilket gör den oförutsägbar. Uppenbart är att nya situationer uppstår konstant på marknaden vilket ställer stora krav på den AI som utvecklas.

Stenkil från Swedbank tror att AI i framtiden kan hjälpa till att screena marknaden för att sammanställa en watchlist av potentiella investeringsobjekt. AI:s potential att läsa och tolka texter är en förmåga som kommer kunna hjälpa förvaltare att hitta intressanta företag vilket är något som även styrks av bland annat Bartram et al. (2020) och Elliot från Göteborgs Universitet. Bartram beskriver hur algoritmer har visat sig kunna ta ut meningsfull ekonomisk information från olika typer av texter med hjälp av en Natural Language Process. I framtiden kommer även mindre strukturerad data att kunna läsas och förstås beskriver Elliot. Tekniker som använts för dessa ändamål har redan testats i studier av både Hutto och Gillbert (2014) samt Araci (2019) med lyckade resultat. De två intervjuobjekten och litteraturen beskriver därmed AI som ett potentiellt verktyg för att få in mer information att kunna ta hänsyn till vid ett investeringsbeslut. Det hade varit av extra intresse för att göra en första screening vid flera potentiella investeringsalternativ.

Hutto och Gillbert (2014), samt Araci (2019) visar att det finns AI-modeller som kan läsa av twitterflöden med hjälp av VADER och FinBERT. Least Absolute Shrinkage and Selection Operator (LASSO), beskriver Feng et al. (2017) och Freyberger et al. (2018), är också ett verktyg för att förstå samband på marknaden. Kan sådan data integreras i AI-modeller för analys kan en mer komplett kombinationen av kvantitativ analys och fundamental analys användas. Kumar och Goel (2020) påpekar dock att det inte är helt oproblematiskt med dessa algoritmer då exempelvis sarkasm är svårt för en AI att tolka.

En annan svårighet med att använda AI i framtiden grundar sig i hur framtida händelser förhåller sig till historiska. Eftersom AI behöver data att utgå ifrån blir det problematiskt när det sker en händelse som inte är lik något som tidigare skett. Lee anser att världen är för komplex för att helt beskrivas i siffror, det finns för många parametrar att ta hänsyn till. AI kan inte förutse hur beslutsfattarna kommer agera och det kan därför anses orimligt att AI i framtiden kommer agera helt autonomt. Lee poängterar dock att AI är bra på att hitta korrelationer. På grund av detta anser han att AI helt kommer kunna ta fram kvantitativ data åt beslutstagare. Dock kommer människor därefter behöva göra ytterligare analyser innan ett beslut kan tas. Det är alltså inte enbart problematiken med att beslut behöver kunna spåras som förhindrar AI från att kunna agera autonomt utan Lee anser också att världen är för komplex för att kunna analyseras utan människor. Komplexiteten är något som även Stenkil (se tabell 5) på Swedbank poängterar när han förklarar att AI inte kommer kunna ta reda på förvaltarens humör och andra parametrar som spelar in ett investeringsbeslut.

Lee beskriver att det inte bara är kvantitativ data som analyseras när ett investeringsbeslut ska tas utan det krävs också att antaganden görs. AI är dålig på att göra antaganden då den kräver fullständig data, vilket är ytterligare en anledning till att Lee anser att människor fortfarande kommer vara nödvändiga inom portföljhantering. Ahrner (se *tabell 2*) från Funder tror att AI har potential för att i framtiden kunna hjälpa till att ta fram beslutsunderlag till människor. Han ser framförallt att AI skulle kunna hitta fel när konsensus inte stämmer överens med verkligheten. Dock skiljer sig Ahrner och Lee åt i synen på applikationsområden. Ahrner anser att analys av stora datamängder för att exempelvis hitta övervärderade bolag är något som AI hade kunnat göra effektivare än en människa. Lee anser istället att marknaden är irrationell och att AI därmed inte är lämplig för denna typ av analys då det krävs att för många antaganden görs.

Det går även att utläsa skillnader i tron på AI som ett analytiskt verktyg. Skillnaderna i åsikt uppkommer till följd av vad personen anser vara de viktigaste faktorerna att ta i beaktning när investeringar ska göras. Skoglund på Spiltan Fonder tror att AI har begränsat med utrymme i detta stadiet i deras verksamhet trots ett mål på överavkastning. Anledningen är att Spiltan lägger stort fokus på fundamental analys. Spiltan finner stort värde i att besöka företagen de är intresserade av för att prata med VD:n och skapa sig en bild av den dagliga verksamheten. Elliot från Göteborgs Universitet lyfter fram skillnaden på tillgången mellan publik och privat information. En AI har inte samma förutsättningar att skaffa privat information och kommer på så vis gå miste om viktiga indikatorer som kan ha stor inverkan på riskprediktion och tron på framtida marknadsrörelser. Detta faktum förklarar även varför ingen av de tillfrågade experterna tror att AI om fem år kommer kunna förutspå en krasch, då all data inte finns tillgänglig för en AI och kan översättas i algoritmer.

Westfeldt (se *tabell 5*) på Vinga ser trots ovanstående svårigheter, att AI kommer bli allt bättre på att göra även fundamentala analyser. Användningen av konceptet ESG är en bidragande faktor till detta då metoden är datadriven. Här finns det alltså möjlighet för en AI att samla in data om ett företags miljömässiga påverkan, sociala ansvar, samt bolagets styrning. Dessa faktorer ger upphov till möjlighet för en AI att skapa sig en mer nyanserad bild av företaget och med det en mer komplett uppfattning. Stenkil på Swedbank stärker bilden av att AI inom kort kommer kunna genomföra fundamentala analyser på ett bättre sätt. Det finns fler och fler algoritmer som läser av nyhetsflöden och presskonferenser vilket

indikerar på att det är möjligt att skapa en relativt komplett bild av ett företag bara genom digital information.

Jönsson beskriver hur BetterWealth använder sig av klustermetoder för att optimera portföljerna beroende på marknadsfas. Att denna metod fungerar stärks av forskning gjord av Kim och White (2004) och Rizvi et al. (2014) på olika typer av GARCH modeller som försöker prediktera marknaden. Jönsson tror att denna typ av optimering bara kommer bli bättre. Även Lindberg tror att optimering, utan att nämna speciella metoder, är ett område som i framtiden fortsätter att bli viktigare för att kunna få konkurrensfördel mot marknaden. Dessa åsikter styrks av studier gjorda av Jiang et al (2020) och Pinelis och Ruppert (2022) som uppgett goda resultat. Studierna som använt sig av bland annat metoderna XGBoost och Logistic Regression visar att det går att skapa överavkastning med hjälp av maskininlärning och AI-integrerade system. Samma metoder kan användas för att ta fram en watchlist. Frågor som väcks är återigen kopplade till kvaliteten på den data som systemet tränas på och om historiska händelser kan antas förutsäga framtida händelser.

AI gör det möjligt att i framtiden utföra prediktiva riskanalyser på ett bättre sätt än vad som görs idag menar Elliot. Att AI helt automatiskt skulle ombalansera är inte särskilt troligt men en AI skulle troligen kunna ge ett mått på hur stor sannolikhet det är att börsen skulle vända nedåt förklarar Elliot. AI:n hade alltså fungerat som ett analysverktyg för fondförvaltare att använda. Jiang et al (2020) och Pinelis och Ruppert (2022) stärker bilden som Elliot uttrycker. De menar att med hjälp av random forest modeller kan bra bedömningar av riskjusterad avkastning göras. Metoderna skapar alltså bättre förutsättningar för att på ett mer träffsäkert sätt ombalansera mot säkra tillgångar vid ostadig marknad. Dock tror inte Elliot att tekniken inom fem år kommer att vara så utvecklad att den skulle kunna ombalansera till mer räntor innan ett börsras. Elliot tillsammans med Ahrner från Funder och Lee har högst tilltro till detta av intervjuobjekten trots att ingen av dem tror att det kommer ske med en hög sannolikhet.

Elliot beskriver att när en kraftig nedgång väl sker har en AI möjlighet att på ett snabbt och effektivt sätt ombalansera för att minimera effekterna av en nedgång. Studier gjorda av Chauvet och Piger (2008) och Goodwin (1993) resulterar i liknande slutsatser. Genom att använda sig av Markov Switching Model kan det snabbt noteras när marknaden går in i en ny marknadsfas som möjliggör snabbare ombalansering.

Flera olika tjänster och mjukvaror kommer inte produceras av fondrobotföretagen själva utan kommer köpas in av externa aktörer berättar Skoglund på Spiltan. Han får medhåll från Lindberg på Sigmastocks samt Elliot som förklarar att olika dataset i framtiden troligtvis kommer köpas av stora aktörer som exempelvis Google. Denna handel av data kommer att påverka branschens förmåga till utveckling eftersom den ligger utanför företagets kontroll. Tillsammans med den saknade kontrollen präglas finansmarknadens av långsam informationsspridning då aktörer vill hemlighålla alla typer av värdefull information. På grund av detta kan värdefulla tjänster och mjukvaror hemlighållas från aktörer likt fondrobotarna på den svenska marknaden.

Expertgruppen och forskningen är enig om att det kan komma att integreras mer AI i portföljhantering inom fem år, men i vilken grad varierar mellan intervjuobjekten. Expertgruppen är dock eniga om att det är låg sannolikhet att AI kommer kunna förutspå krascher. Algoritmerna kommer inte kunna få tillgång till tillräckligt med information då privat och ibland även insiderinformation hade behövts för att mer proaktivt hanterat stora marknadssvängningar. Om AI hade haft möjlighet att förutspå en marknadskrash, hade kraschen i så fall triggats tidigare?

7. Slutsats

På frågan hur fondrobotar på den svenska marknaden fungerar och hur de hanterar kraftiga svängningar på börsmarknaden skulle svaret kunna vara relativt rakt. Det kan kort sammanfattas som att fondrobotföretagen har den gemensamma bilden att det genom automatisering finns möjlighet att effektivisera investeringsrådgivningen som i idag ges till privatsparare. Kartläggningen som gjorts indikerar dock på att det även finns stora skillnader mellan fondrobotarna.

Dagens fondrobotar skiljer sig åt i många aspekter, vilket till viss del kan förklaras av förhållningssättet till Efficient Market Hypothesis (EMH). Fondrobotföretag med större tilltro till EMH tenderar att inte se lika stora möjligheter till överavkastning. Vidare kan detta förhållningssätt kopplas till hur automatiserade fondrobotarna är. Den höga tilltron till EMH korrelerar med en lägre automatiseringsgrad hos de undersökta fondrobotarna. Korrelationen kan förklaras med det ökade kravet på prestation som följer av målet att generera överavkastning. Högre automatiseringsgrad har visat sig vara ett potentiellt hjälpmedel för att uppnå detta mål.

Fondrobotföretagen är dock överens om att ett effektivt tillvägagångssätt för att minska risk och skydda portföljerna mot nedgångar är diversifiering, både mellan och inom tillgångsslag. Effekten blir en låg korrelation mellan tillgångarna, något som visat sig vara väsentligt för att bibehålla en låg risk. Trots detta är samtliga fondrobotföretag eniga om att de inte använder sig av någon traditionell portföljteori till fullo. Utöver detta går åsikterna isär om hur marknadssvängningar kan hanteras. Spannet mellan ytterligheterna är stort, från en passiv strategi där inga försök till hantering av marknadssvängningar sker, till en aktiv strategi där beräkning av marknadsfaser används för att optimera och ombalansera. Kanske är det så att framtiden kommer avgöra vilken strategi som är bäst?

Vad som ligger framåt i tiden är dock tvetydigt. Frågan hur AI integrerade fondrobotar om fem år skulle kunna hantera stora förändringar på börsmarknaden visade sig ha ett långt ifrån rakt svar. Vad som står klart är att AI om fem år kommer kunna användas som ett verktyg för fondförvaltare som kan ge förslag på ombalansering och hjälpa till med analys av potentiella investeringar. Att hitta mönster och korrelationer mellan tiotusentals olika dimensioner gör en

AI mycket bättre än en människa redan idag. Åsikterna om i vilken utsträckning verktygen kommer användas går däremot isär. Mycket förefaller handla om vilken investeringsfilosofi som växer sig störst på marknaden. Om en passiv investeringsmodell visar sig vara mest efterfrågad på marknaden kommer produkterna likna de mer passiva produkter som finns idag, medan om en mer aktiv modell vinner majoriteten av marknaden kommer utvecklingen av AI och automatisering fortsatt öka.

Samtidigt kommer AI möta vissa svårigheter relaterat till att människor, och med det marknaden, inte betar sig rationellt. Det blir alltså svårt att hitta tydliga mönster och indikatorer som kan användas för att förutspå framtiden. Det råder också skilda åsikter om vilken information en AI har möjlighet att nå. Att AI kommer kunna använda publik information har ingen motsatt sig, däremot råder det delade meningar om AI kommer ha möjlighet att nå privat information, vilket vissa menar på är avgörande för att kunna förutse en marknadstrend.

Att AI skulle kunna förutsäga framtida börskrascher och då skydda sina portföljer mot den kommande nedgången får ses som osannolikt. Respondenterna står enade i att AI inte kommer kunna förutse börsnedgångar. Mycket handlar om att informationen som skulle krävas för att förutspå en börskrasch inte kommer vara nåbar för AI:n, men heller inte en människa. Att inte integrera AI är dock helt fel slutsats. AI:s många kvaliteter överträffar människans förmågor. Trots detta förblir drömmen om det perfekta sparandet, att sälja på toppen och köpa på botten, bara en dröm. Tills vidare.

8. Avslutande reflektioner

I ett avslutande diskussionsavsnitt kommer framtida forskningstankar att presenteras och varför dessa skulle vara av intresse. Avsnittet avslutas med en hållbarhets- och etikreflektion som är kopplat till rapportens fokusområde.

8.1 Framtida forskning

Under studiens gång har flera intressanta problem iakttagits och skapat möjligheter för framtida forskning. Flera av intervjuobjekten har förklarat problemen och potentialen med en mer generell AI som kan hantera flera olika sorters data. Därför finns det ett stort intresse i att fortsätta forska kring AI:s förmåga och roll att utföra fundamental analys. Eftersom en fundamental analys behandlar både strukturerad och ostrukturerad data är detta ett område som måste vidareutvecklas innan full användning är möjligt.

Ett liknande problem som nämnts är AI:s hantering av ostrukturerad data i form av exempelvis sociala medier. Trots att detta är ett område som det forskas flitigt inom kommer ytterligare studier att krävas för att förmågan ska kunna utvecklas vidare. Fortsatt forskning inom området kan även leda till att information som idag inte kan hanteras, går att användas i exempelvis en screening av marknaden.

Sökandet och drömmen om den perfekta portföljen fortlöper. Att hitta en portfölj som lyckas utpresteras marknaden oavsett marknadsfas och vad den i teorin kan tänkas innehålla. Efter framtagandet av rapporten är detta ett område som väckt intresse och som fortsatt bör forskas på.

8.2 Hållbarhets- och etikreflektion

Samhällets digitalisering medför att stora mängder data, även kallat big data, sparas, processas och används. För att kunna fastställa exakta prognoser och ta korrekta beslut inom områden där stora mängder information finns är hantering, lagring och användning av big data avgörande (Jeble et al., 2017). Detta gäller inte minst inom finanssektorn där kravet på relevant information är stort. Informationen som används kan bero på flera olika faktorer och i vissa fall är detta känslig information. På grund av att stora mängder data som analyseras

eventuellt är känslig ställs det höga krav på säkerheten. I takt med att volymen, hastigheten och variationen av big data blir allt större ökar riskerna för säkerhetsbrister (Ogbuke et al., 2022). Hur information sparas samt används är något som bör diskuteras och tas i beaktning. Om en säkerhetsbrist skulle utnyttjas kan många människor och även företag fara illa då känslig information kan spridas. För att öka säkerheten bör en hybridlösning användas där man kombinerar molntjänster tillsammans med lokala servrar (Dell Technologies, 2021).

För att hantera all denna information krävs det enorma serverhallar vilka används som samlingspunkter för datalagring (Svenska Dagbladet, 2022). Serverhallarna ägs av stora IT-bolag som Amazon, Google samt Microsoft. Dominansen gör att informationslagring har konvergerat till ett fåtal aktörer som helt styr marknaden på global nivå. IT-bolagens stora kapital har gjort att deras säkerhetssystem är av yttersta världsklass och få mindre aktörer kan matcha säkerheten de erbjuder. En konvergerad infrastruktur medför stora risker, om någon av de stora aktörerna skulle hackas kan detta resultera i stora konsekvenser världen över (Svenska Dagbladet, 2022).

Serverhallarna kräver stora mängder energi och deras energiförbrukningen kan liknas med en liten svensk stad (Ny Teknik, 2019). Dessa anläggningar sätter stor press på Sveriges elnät och har en negativ påverkan på flera områden (Ny Teknik, 2019). För att Sverige ska kunna följa FN:s Globala Mål 7 ”hållbar energi för alla” kräver detta att stora mängder energi kan erhållas på ett hållbart sätt. Om utvecklingen inte kan hanteras på ett hållbart sätt finns risker att energi från fossila källor används för att kunna möta energibehovet. Användningen av dessa energikällor skulle stå i motsägelse mot FN:s 13:e mål ”bekämpa klimatförändringarna” eftersom förbränning av fossila bränslen producerar stora mängder växthusgaser (UNDP, u.å.). Ytterligare ett av FN:s mål som påverkas av utökningen av dessa serverhallar är mål 9 ”Hållbar industri, innovationer och infrastruktur” (UNDP, u.å.). Främst genom materialet som används vid tillverkning eftersom ett flertal metaller utvinns på ett icke-miljövänligt vis. Samtliga tre mål måste tas i beaktning när finanssektorn och samhället digitaliseras. Emellertid, för att utvecklingen som sker ska kunna fortsätta, krävs det att infrastrukturen rustas upp i samma takt. De närmaste åren kommer därav vara kritiska då miljarder satsas på utveckling, forskning och uppbyggnad av infrastrukturen inom datasamling och lagring vilket i sin tur möjliggör komplexare AI-system.

Vad systemen väljer att investera i tål att diskuteras och kan skilja sig stort beroende på vilka parametrar företag och individer väljer att prioritera. Genom användandet av en fondrobot kan varje portfölj kundanpassas beroende på individens inställning till risk men också hållbarhet samt etik. Dessa beslut påverkar portföljen stort och vilken avkastning som kan förväntas (Beccalli et al., 2020). Eftersom robotarna följer bestämda parametrar möjliggör detta att investeringar och placeringar genomförs som annars inte gjorts. Fördelen med dessa oberoende beslut möjliggör att FN:s 8:e mål ”anständiga arbetsvillkor och ekonomisk tillväxt” följs (UNDP, u.å.). Robotarna följer bestämda graderingar som företagen satt eller listor från externa parter. Därför krävs det stor noggrannhet vid dessa graderingar eftersom robotarna följer dessa listor villkorslöst.

Hur graderingarna sker och i vilken skala är en diskussion som blivit allt hetare i takt med att fondrobotar och olika AI-system blivit allt vanligare som investeringsverktyg. Eftersom strikta gränser påverkar stort vilka placeringar som genomförs och inte diskuterar Radclyffe (2020) alternativa metoder i sin artikel för Financial Times. Radclyffe (2020) menar att man borde fokusera på en mer flytande skala där olika områden får olika prioritet beroende på individens värderingar i stället för att använda sig av förutsatta standards. Fördelar med detta menar Radclyffe (2020) är att individanpassningen blir högre samtidigt krävs det komplexare system och högre beräkningskraft för att kunna ta hänsyn till dessa extra parametrar.

Det finns etiska svårigheter kopplat till AI och finansvärlden. Några av de nämner intervjuobjekten ovan i rapporten där det är problematiskt med framtagningen av rätt data, samt att all information inte finns tillgänglig som digital information, något som AI är beroende av för att fungera (MDOTM, u.å.a). Detta problem är dock av mer praktisk karaktär än etisk. Svårigheterna fortsätter när AI används för att ta beslut. Frågor som vem som hålls ansvarig om en AI:s investeringar går dåligt lyfts fram (MDOTM, u.å.a). AI behandlas i flera sammanhang som en svart låda där det är svårt att få någon större insikt i hur beslut tas, samt vilka parametrar som var avgörande.

Vidare diskuteras vilken sorts data som en AI algoritm tränas med och matas med. En algoritm är aldrig bättre än den data den matas med påstår MDOTM (u.å.b). Garbage in kommer leda till garbage out. Tidigare har AI mött svårigheter, inte minst i Microsoft Twitterbot Tay (Hunt, 2016). Den skulle operera på Twitter och bemöta personer mellan 18

och 24 år. Målet var att skapa förståelse för hur konversationer fungerade. Tay fick snabbt efter lansering stängas ner då den skrev antisemitiska och rasistiska tweets (Hunt, 2016).

Liknande problem uppstod för google med sin fotoigenkänningsalgoritm. Den var tänkt att tagga objekt i bilder för att strukturera upp bilderna efter olika kategorier (Zhang, 2015). Dessvärre skedde kategoriseringen inte smärtfritt då den taggade några mörkhyade personer som gorillor. Google fick snabbt åtgärda detta genom att ta bort gorilla som tagg (Zhang, 2015).

Ovanstående händelser visar på vilka problem som kan uppstå. MDOTM (u.å.a) beskriver vikten av att sätta ihop ett komplett och täckande etiskt ramverk för den AI som ska hantera investeringar. Detta ramverk bör grundas i ESG för att åstadkomma hållbara investeringar som kan anses vara etiskt korrekta.

Referenser

Abraham, F., Schmukler, S. L., & Tessada, J. (2019). Robo-Advisors: Investing Through Machines. *World Bank Research and Policy Briefs*, (134881).
<https://documents1.worldbank.org/curated/en/275041551196836758/pdf/Robo-Advisors-Investing-through-Machines.pdf>

Alberg, D., Shalit, H., & Yosef, R. Y. (2008). Estimating Stock Market Volatility Using Asymmetric GARCH Models. *Applied Financial Economics*, 18(15), 1201-1208
<https://doi.org/10.1080/09603100701604225>

Araci, D. (2019). FinBERT: Financial Sentiment Analysis with Pre-Trained Language Models. *University of Amsterdam*. <https://doi.org/10.48550/arXiv.1908.10063>

Bartram, S. M., Branke, J., & Motahari, M. (2020). Artificial Intelligence in Asset Management (No. 14525). *CFA Institute Research Foundation*.
<https://www.cfainstitute.org/-/media/documents/book/rlr-lit-review/2020/rflr-artificial-intelligence-in-asset-management.pdf>

Beccalli, E. (2020). Artificial Intelligence and Ethics in Portfolio Management. *Digital Business Transformation*, 19-30. https://doi.org/10.1007/978-3-030-47355-6_2

Berry, M. W., Mohamed, A., & Yap, B. W. (Red.). (2019). Supervised and Unsupervised Learning for Data Science. *Springer Nature*. <https://doi.org/10.1007/978-3-030-22475-2>

BetterWealth. (u.å.). *Jämför portfölj*. Hämtad 15 mars, 2022, från
<https://www.betterwealth.se/compare-portfolio>

BetterWealth. (2021). *Investeringsfilosofi*.
<https://www.betterwealth.se/investment-philosophy>

Blakeley, G. (2020). *The Corona Crash: How the pandemic Will Change Capitalism*. Verso Books.

Boyabatli, O., Toktay, L, B. (2004). Operational Hedging: A Review with Discussion. *Research Collection Lee Kong Chian School Of Business*.

https://ink.library.smu.edu.sg/lkcsb_research/3758/

Breiman, L. (2001). Random Forests. *Machine Learning*, 45(1), 5-32.

<https://doi.org/10.1023/A:1010933404324>

Bryman, A. (2011). *Samhällsvetenskapliga metoder*. Malmö: Liber.

Campbell, J. Y., & Hentschel, L. (1992). No News is Good News: An Asymmetric Model of Changing Volatility in Stock Returns. *Journal of Financial Economics*, 31(3), 281-318.

[https://doi.org/10.1016/0304-405X\(92\)90037-X](https://doi.org/10.1016/0304-405X(92)90037-X)

Cao, Y., Liu, J., Wei, Y., & Yu, Q., (2017). Hot Money and China's Stock Market Volatility: Further Evidence Using the GARCH–MIDAS Model. *Physica A: Statistical Mechanics and its Applications*, 492, 923-930. <https://doi.org/10.1016/j.physa.2017.11.022>

Chauvet, M., & Piger, J. (2008). A Comparison of the Real-Time Performance of Business Cycle Dating Methods. *Journal of Business & Economic Statistics*, 26(1), 42–49.

<http://www.jstor.org/stable/27638960>

Chen, Y., Day, M., & Lin, J. (2018). Artificial Intelligence for Conversational Robo-Advisor [Conference Paper]. *2018 IEEE/ACM International Conference on Advances in Social Networks Analysis and Mining (ASONAM)*, 1057-1064.

<https://doi.org/10.1109/ASONAM.2018.8508269>

Chen, T., & He, T. (2022). XGBoost: eXtreme Gradient Boosting. *R Package Version 0.4-2*, 1(4), 1-4. <https://cran.r-project.org/web/packages/xgboost/vignettes/xgboost.pdf>

Chesnay, F., & Jondeau, E. (2001). Does Correlation Between Stock Returns Really Increase During Turbulent Periods?. *Economic Notes*, 30(1), 53-80.

<http://dx.doi.org/10.1111/1468-0300.00047>

Corporate Finance Institute. (u.å.). *Efficient Market Hypothesis*.

<https://corporatefinanceinstitute.com/resources/knowledge/trading-investing/efficient-market-hypothesis/>

Cunningham, P., Cord, M., & Delany, S. J. (2008). Supervised Learning. *Machine Learning Techniques for Multimedia* (pp. 21-49). Springer, Berlin, Heidelberg.

Daube, C. H. (2020). *The Corona Virus Stock Exchange Crash*. EconStor.

<https://www.econstor.eu/bitstream/10419/214881/1/The%20Corona%20Virus%20Stock%20Exchange%20Crash.pdf>

David, M., & Sutton, C. D. (2016). *Samhällsvetenskaplig Metod*. (2 uppl.). Studentlitteratur.

Dell Technologies. (2021, 25 november). *En anpassad infrastruktur är grunden för att dra nytta av AI*.

<https://www.dell.com/sv-se/blog/en-anpassad-infrastruktur-aer-grunden-foer-att-dra-nytta-av-ai/>

Ellram, L.M. (1996). The Use of the Case Study Method in Logistics Research. *Journal of Business Logistics*, 17(2).

https://www.researchgate.net/publication/248055854_The_Use_of_Case_Study_Method_in_Logistics_Research

Engle, R. (u.å.). GARCH 101: An Introduction to the Use of ARCH/GARCH Models in Applied Econometrics. *Journal of Economic Perspectives*, 15(4), 157-168.

<https://web-static.stern.nyu.edu/rengle/GARCH101.PDF>

Fein, M. L. (2015). Robo-Advisors: A Closer Look. SSRN.

<https://dx.doi.org/10.2139/ssrn.2658701>

Feng, G., Giglio, S., & Xiu, D. (2017). Taming the Factor Zoo: A Test of New Factors. *The Journal of Finance*, 75(3), 1327-1370. <https://ssrn.com/abstract=2934020>

Ferreira, F. G., Gandomi, A. H., & Cardoso, R. T. (2021). Artificial Intelligence Applied to Stock Market Trading: A Review. *IEEE Access*, 9, 30898-30917.

<https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=9350582>

Finansinspektionen. (2006). *Avgift efter prestation? En granskning av avgifter i 47 fondbolag*. (2006:5).

https://www.fi.se/contentassets/b122d51c886442bda8e1fee8531aedac/rapport2006_5.pdf

Fisch, J. E., Labouré, M., & Turner, J. A. (2019). The Emergence of the Robo-Advisor.

<https://pensionresearchcouncil.wharton.upenn.edu/wp-content/uploads/2018/12/WP-2018-12-Fisch-et-al.pdf>

Francis, J. C., & Dongcheol, K. (2013). *Modern Portfolio Theory: Foundations, Analysis, and New Development*. John Wiley & Sons.

<https://ebookcentral.proquest.com/lib/chalmers/detail.action?docID=1113504>

Freyberger, J., Neuhi, A., & Weber, M. (2018). Dissecting Characteristics Nonparametrically. *The Review of Financial Studies*, 33(5), 2326-2377. <https://ssrn.com/abstract=3223630>

Fundler (u.å.). *Fondrobot*. <https://fundler.se/fondrobot/>

Funnell, W., & Robertson, J. (2012). The Dutch East-India Company and Accounting for Social Capital at the Dawn of Modern Capitalism 1602-1623. *Accounting, Organizations and Society*, 37(5), 342-360. <https://doi.org/10.1016/j.aos.2012.03.002>

Goodwin, T. H. (1993). Business-Cycle Analysis with a Markov-Switching Model. *Journal of Business & Economic Statistics*, 11(3), 331-339. <https://doi.org/10.2307/1391958>

Gu, S., Kelly, B., & Xiu, D. (2020). Empirical Asset Pricing via Machine Learning. *The Review of Financial Studies*, 33(5), 2223-2273. <https://doi.org/10.1093/rfs/hhaa009>

Hamilton, J. D. (1989). A New Approach to the Economic Analysis of Nonstationary Time Series and the Business Cycle. *Econometrica*, 57(2), 357-384.

<https://doi.org/10.2307/1912559>

Hunt, E. (2016). Tay, Microsoft's AI Chatbot, Gets a Crash Course in Racism From Twitter. *The Guardian*.

<https://www.theguardian.com/technology/2016/mar/24/tay-microsofts-ai-chatbot-gets-a-crash-course-in-racism-from-twitter>

Hutto, C. J., & Gilbert, E. (2014). VADER: A Parsimonious Rule-Based Model for Sentiment Analysis of Social Media Text. *In Proceedings of the 8th international AAAI Conference on Weblogs and Social Media (ICWSM 2014)* (pp. 216–225).

<https://ojs.aaai.org/index.php/ICWSM/article/view/14550/14399>

IBM. (u.å.). *What is Logistic Regression?*. <https://www.ibm.com/topics/logistic-regression>

Janiesch, C., Zschech, P., & Heinrich, K. (2021). Machine Learning and Deep Learning. *Electronic Markets*, 31(3), 685-695. <https://doi.org/10.1007/s12525-021-00475-2>

Jasso, G. (1979). On Gini's Mean Difference and Gini's Index of Concentration. *American Sociological Review*, 44, 867-870. <https://doi.org/10.2307/2094535>

Jeble, S., Kumari, S., & Patil, Y. (2017). Role of Big Data in Decision Making. *Operations and Supply Chain Management: An International Journal*, 11(1), 36-44.

<http://doi.org/10.31387/oscm0300198>

Jiang, Z., Ji, R., & Chang, K. (2020). A Machine Learning Integrated Portfolio Rebalance Framework with Risk-Aversion Adjustment. *Risk and Financial Management*, 13(7).

<https://doi.org/10.3390/jrfm13070155>.

Jung, D., Dorner, V., Glaser, F., & Morana, S. (2018). Robo-advisory. *Business & Information Systems Engineering*, 60(1), 81-86. <https://doi.org/10.1007/s12599-018-0521-9>

Khan, M. S., Khan, K. I., Mahmood, S., & Sheeraz, M. (2019). Symmetric and Asymmetric Volatility Clustering via GARCH Family Models: An Evidence from Religion Dominant Countries. <https://ssrn.com/abstract=3418388>

Kim, T. H., & White, H. (2004). On More Robust Estimation of Skewness and Kurtosis. *Finance Research Letters*. [https://doi.org/10.1016/S1544-6123\(03\)00003-5](https://doi.org/10.1016/S1544-6123(03)00003-5)

Klimashousky, D. (3 november 2021). *What is an Investment Broker?*. Smartasset. <https://smartasset.com/financial-advisor/what-is-an-investment-broker>

Kumar, Y., & Goel, N. (2020). AI-Based Learning Techniques for Sarcasm Detection of Social Media Tweets: State-of-the-Art Survey. *SN Computer Science*, 1(6), 1-14. <https://doi.org/10.1007/s42979-020-00336-3>

Lauridsen, S. (2000). Estimation of Value at Risk by Extreme Value Methods. *Extremes* 3, 107–144. <https://doi.org/10.1023/A:1009979331996>

Leow, E., Nguyen, B., & Chua, M. (2021). Robo-Advisor Using Genetic Algorithm and BERT Sentiments from Tweets for Hybrid Portfolio Optimisation. *Expert Systems with Applications*. <https://doi.org/10.1016/j.eswa.2021.115060>

Loretan, M., & English, W. B. (2000). Evaluating “Correlation Breakdowns” During Periods of Market Volatility [Conference Paper]. *International Financial Markets and the Implications for Monetary and Financial Stability*, 8, 214. <https://dx.doi.org/10.2139/ssrn.231857>

Lysa. (u.å.). *Whitepaper*. <https://lysa.se/whitepaper/#fn1>

Mahata, A., Rai, A., Nurujjaman, M., Prakash, O., & Prasad Bal, D. (2021). Characteristics of 2020 Stock Market Crash: The COVID-19 Induced Extreme Event. *Chaos: An Interdisciplinary Journal of Nonlinear Science*, 31(5), Artikel 053115. <https://doi.org/10.1063/5.0046704>

Mahesh, B. (2020). Machine Learning Algorithms-a Review. *International Journal of Science and Research (IJSR)*. 9(1), 381-386. <https://www.ijsr.net/archive/v9i1/ART20203995.pdf>

Malterud, K. (2012). Systematic Text Condensation: A Strategy for Qualitative Analysis. *Scandinavian Journal of Public Health*, 40(8), 795–805.
<https://doi.org/10.1177/1403494812465030>

Markowitz, H. M. (1971). Portfolio Selection: Efficient Diversification of Investments. *Yale University Press*.
<https://ebookcentral.proquest.com/lib/chalmers/reader.action?docID=3421285>

Mazur, M., Dang, M., & Vega, M. (2021). COVID-19 and the March 2020 Stock Market Crash. Evidence from S&P1500. *Finance Research Letters*, 38, Artikel 101690.
<https://doi.org/10.1016/j.frl.2020.101690>

MDOTM. (u.å. a) *ESG is not Enough - The Missing Piece to Turn Values into Value*. MDOTM. <https://www.mdotm.eu/insights/esg-is-not-enough/>

MDOTM. (u.å. b) *Building AI that Investors Can Rely on - The Essentials to Build Investment Strategies that Deliver on what they Promise*. MDOTM. <https://www.mdotm.eu/insights/building-ai-that-investors-can-rely-on/>

Melander, L., Dubois, A., Hedvall, K., & Lind, F. (2019). Future Goods Transport in Sweden 2050: Using a Delphi-Based Scenario Analysis. *Technological Forecasting and Social Change*, 138, 178-189. <https://doi.org/10.1016/j.techfore.2018.08.019>

Milana, C., & Ashta, A. (2021). Artificial Intelligence Techniques in Finance and Financial Markets: A Survey of the Literature. *Strategic Change*, 30(3), 189-209.
https://onlinelibrary.wiley.com/doi/epdf/10.1002/jsc.2403?saml_referrer

Nath, T. (2015). *Investing Basics: What is the Efficient Market Hypothesis, and What are the Shortcomings?*.
<https://www.nasdaq.com/article/investing-basics-what-is-the-efficientmarket-hypothesis-and-what-are-its-shortcomings-cm530860>

Nasdaq OMX Nordic. (u.å.). *Historiska kurser*.

http://www.nasdaqomxnordic.com/index/historiska_kurser?languageId=3&Instrument=SE0000337842

Nelson, D. B. (1991). Conditional Heteroskedasticity in Asset Returns: A New Approach. *Econometrica*, 59(2), 347-370. <https://www.jstor.org/stable/2938260>

Nordea. (u.å.). *Risk och riskspridning vid fondsparande*.

<https://www.nordea.se/privat/produkter/spara-investera/fonder/risk-och-riskspridning.html>

Ny Teknik. (2019, 30 augusti). *Nya etableringar pressar svenska elnät: "Klarar inte en till Amazon"*.

<https://www.nyteknik.se/energi/nya-etableringar-pressar-svenska-elnatet-klaras-inte-en-till-amazon-6969729>

Ogbuke N. J., Yusuf Y. Y., Dharma K., & Mercangoz B. A. (2022). Big Data Supply Chain Analytics: Ethical, Privacy and Security Challenges Posed to Business, Industries and Society. *Production Planning & Control*, 33(2-3), 123-137.

<https://doi.org/10.1080/09537287.2020.1810764>

Park, J. Y., Ryu, J. P., & Shin, H. J. (2016). Robo Advisors for Portfolio Management. *Advanced Science and Technology Letters*, 141(1), 104-108.

https://web.archive.org/web/20180619152839id_/http://onlinepresent.org:80/proceedings/vol141_2016/21.pdf

Prasad, A. G., Sanjana, S., Bhat, S. M., & Harish, B. S. (2017). Sentiment Analysis for Sarcasm Detection on Streaming Short Text Data [Conference Paper]. *2017 2nd International Conference on Knowledge Engineering and Applications (ICKEA)* (pp. 1-5).

<https://doi.org/10.1109/ICKEA.2017.8169892>

Pinelis, M., & Ruppert, D. (2022). Machine Learning Portfolio Allocation. *The Journal of Finance and Data Science*, 8, 35-54. <https://doi.org/10.1016/j.jfds.2021.12.001>

Radclyffe, C. (2020, 9 november). *AI Can Drive Ethical Investment Only if we Grasp the Messy Reality*. <https://www.ft.com/content/b238b8f2-8645-4654-a806-681c9a461d0b>

Rapach, D., Strauss, J., Tu, J., & Zhou, G. (2013). International Stock Return Predictability: What is the Role of the United States?. *Journal of Finance*, 68(4), 1633–62. <https://doi.org/10.1111/jofi.12041>

Rapach, D., Strauss, J., Tu, J., & Zhou, G. (2019). Industry Return Predictability: A Machine Learning Approach. *Journal of Financial Data Science*, 1(3), 9–28. <https://doi.org/10.3905/jfds.2019.1.3.009>

Reichertz, J. (2010). Abduction: The Logic of Discovery of Grounded Theory. *Qualitative Social Research*. <https://doi.org/10.4135/9781848607941.n10>

RikaTillsammans. (7 januari 2020). *Stockholmsbörsen (SIXRX) historisk avkastning 1870-2019*. <https://rikatillsammans.se/historik/sixrx/>

Rizvi, S. K., Naqvi, B., Bordes, C., & Mirza, N. (2014). Inflation Volatility: An Asian Perspective. *Economic Research-Ekonomska Istraživanja*, 27(1), 280-303. <https://doi.org/10.1080/1331677X.2014.952090>

Rognerud, K. K. (12 mars 2020). Mörkaste dagen på Stockholmsbörsen i modern tid. *SVT*. <https://www.svt.se/nyheter/ekonomi/fem-ars-borsuppgang-utraderad-1>

Sarsam, S. M., Al-Samarraie, H., Alzahrani, A. I., & Wright, B. (2020). Sarcasm Detection Using Machine Learning Algorithms in Twitter: A Systematic Review. *International Journal of Market Research*, 62(5), 578-598. <https://doi.org/10.1177/1470785320921779>

SCB. (2021, 9 mars). *Fler unga satsade på aktieköp under 2020*. <https://www.scb.se/hitta-statistik/redaktionellt/fler-unga-satsade-pa-aktiekop-under-2020/>

Shanmuganathan, M. (2020). Behavioural Finance in an Era of Artificial Intelligence: Longitudinal Case Study of Robo-Advisors in Investment Decisions. *Journal of Behavioral and Experimental Finance*, 27, Artikel 100297. <https://doi.org/10.1016/j.jbef.2020.100297>

Sharpe, W. F. (1998). The Sharpe Ratio. *Streetwise—The Best of the Journal of Portfolio Management*, 169-185.

Sigmastocks. (u.å.). *Sigmastocks matematiska investeringsmodeller*.

<https://artiklar.sigmastocks.com/sigmastocks-matematiska-investeringsmodeller/>

Snyder, H. (2019). Literature Review as a Research Methodology: An Overview and Guidelines. *Journal of Business Research*, 104, 333-339.

<https://doi.org/10.1016/j.jbusres.2019.07.039>

Song, Y., & Woźniak, T. (2021). Markow Switching Model. I *Oxford Research Encyclopedia of Economics and Finance*. <https://doi.org/10.1093/acrefore/9780190625979.013.174>

Sutton, R. S., & Barto, A. G. (2018). *Reinforcement Learning: An Introduction*. (2. uppl.) MIT press.

Svenska Dagbladet. (2022, 3 februari). *Explosion i molnen - kommer elen att räcka?*.

<https://www.svd.se/trion-vaxer-lavinartat--med-dina-data-i-molnen>

Taleb, N. N. (2008). *The Black Swan*. Penguin Books.

Tay, Y., Tuan, L. A., Hui, S. C., & Su, J. (2018). Reasoning with Sarcasm by Reading In-Between. *Institute for Infocomm Research, Singapore*.

<https://doi.org/10.48550/arXiv.1805.02856>

Tseng, J.J., & Li, S.P. (2012). Quantifying Volatility Clustering in Financial Time Series. *International Review of Financial Analysis*. <https://doi.org/10.1016/j.irfa.2011.06.017>

Turoff, M., & Linstone, H. A. (2002). The Delphi Method-Techniques and Applications. *Journal of Marketing Research*. <http://dx.doi.org/10.2307/3150755>

UNDP. (u.å.). *Globala målen*. Hämtad 2022-02-02.

<https://www.globalamalen.se/om-globala-malen/>

Zhang, M. (2015). Google Photos Tags Two African-Americans as Gorillas Through Facial Recognition Software. *Forbes*.

<https://www.forbes.com/sites/mzhang/2015/07/01/google-photos-tags-two-african-americans-as-gorillas-through-facial-recognition-software/>

Figurer:

Från Funder. (2022a). *Jämför avkastningen på våra portföljer* [fotografi].

<https://funder.se/fondrobot/>

Från Funder. (2022b). *Jämför avkastningen på våra portföljer* [fotografi].

<https://funder.se/fondrobot/>

Från BetterWealth. (2022). *Jämför portfölj* [fotografi].

<https://www.betterwealth.se/compare-portfolio>

Appendix

I appendix 1 presenteras först kartläggningsfrågorna som använt i rapporten. I appendix 2 presenteras delfrågorna som ställts två gånger till samtliga intervjuobjekt för att göra framtidsanalysen.

Appendix 1. Kartläggningsfrågor

Nedan följer de frågor som ställts till fondrobotar för att kunna kartlägga deras verksamhet. Beroende på vilken information som funnits tillgänglig på hemsidan har alla eller delar av frågorna ställts för att få en helhetsuppfattning av deras koncept.

Investeringsstrategi

- Siktar ni på överavkastning eller vill ni följa ert jämförelseindex?
 - Vad är ert jämförelseindex?

Frågor risk- och avkastningsnivå

- Hur mäter ni risken i era portföljer?
 - Sker det automatiskt?
 - Hur isåfall?
- Vad använder ni för riskmått?
 - Använder ni några av portföljteorierna?
 - Vi tänker att det eventuellt skulle kunna vara så att olika portföljuppbyggnader skulle kunna fungera bättre eller sämre under vissa externa marknadsförutsättningar, men att det kanske är svårt att identifiera när marknaden är i ett visst stadie. Ex. låg/hög - konjunktur.
 - Rätt av eller har ni optimerat den?
 - Hur isåfall?
- Hur diversifierar ni?
 - I hur många olika lager diversifierar ni?
 - Vilka parametrar tittar ni på?
 - Har ni några verktyg ni använder för att mäta korrelation?
 - Hur ofta mäter ni detta/analyserar ni detta?

- Hur automatiserad/manuell är den riskbedömningen?

Watch List

- Hur väljer ni ut er watchlist?
 - Vilka parametrar tittar ni på? Branscher, diversifiering, låga avgifter etc.
 - Hur går analysen av fonder som ska in på watchlisten in?
- Hur många fonder har ni i er watchlist?
 - Vad är optimalt för er?

Köp

- Använder ni er av automatiserade köp eller manuella?

Optimering

- Hur optimeras allokeringsmixen i portföljerna?
 - Hur automatiserad är processen för att hitta den optimala avkastningen och risken?
 - Om de använder AI:
 - Vilka dataset använder ni er av?
 - Är det unsupervised, supervised eller reinforcement learning?
 - Sker detta helt utan mänsklig uppsyn?

Ombalansering

- Hur ofta sker ombalansering i era portföljer?
 - Hur avgör ni om portföljer måste balanseras om?
 - Hur automatiserad är denna?
 - Finns det några “red flags”?
- Hur hanterar ni stora svängningar på marknaden?
 - Exempel raset 2020
- Hur identifierar ni att marknaden är i ett visst stadie?
 - Hur går processen till för att bestämma det nya förhållandet mellan olika tillgångsslag? (ML/AI?)

Appendix 2. Delfifrågor

Nedan följer de frågor vi ställt till fondrobotar, traditionella fondförvaltare samt AI-experter för att få en förståelse för hur framtidens fondrobotar kommer att se ut.

Vårt kandidatarbete har fokus på framtiden samt framförallt AI och implementation av detta i framtiden. Så fokus på följande frågor kommer att ha inriktning på den tekniska delen.

Känner du att frågan som ställs inte rör ditt område är det okej att säga pass.

- Hur tror du att fondrobotarna tekniskt kommer fungera om 5 år?
- Tror du att AI kommer att vara en stor del av er portföljhantering om 5 år?
 - Om JA:
 - Inom vilka områden?- VISA bild
 - Tror du att AI skulle kunna användas för att avgöra när det är mest lämpligt att balansera om?
 - Om Nej:
 - Varför inte?
 - Tror du att AI kommer att användas mer om 5 år än vad det gör idag?
- Oavsett om ni använder AI idag eller inte, tror du att AI skulle kunna förutspå innan marknaden blir mer orolig för att eventuellt balansera om till mer räntor?
 - På vilket sätt?

INSTITUTIONEN FÖR TEKNIKENS EKONOMI OCH ORGANISATION
AVDELNINGEN FÖR SCIENCE, TECHNOLOGY AND SOCIETY
CHALMERS TEKNISKA HÖGSKOLA
Göteborg, Sverige 2022
www.chalmers.se



CHALMERS