



UiT Norges arktiske universitet

Fakultet for biokjemi, fiskeri og økonomi

Prediksjon og analyse av Bitcoins volatilitet: En integrert tilnærming med GARCH og maskinlæring
“Hvordan presterer tradisjonelle GARCH modeller mot maskinlæring i prediksjon av et høyt volatilt marked”

Steffen Skeimo og Terje Fagerli Pedersen

Masteroppgave i Økonomi og administrasjon, BED-3901, juni.24

Innholdsfortegnelse

1	Innledning	5
1.1	Problemstilling	6
1.2	Litteraturgjennomgang	6
2	Teoretisk rammeverk	8
2.1	Hva er kryptovaluta?	8
2.1.1	Bitcoin (BTC)	8
2.2	Finansiell teori	9
2.3	Value at Risk	10
2.4	Makroøkonomiske forhold	11
2.5	Økonomisk politisk usikkerhet	12
2.6	Implikasjoner med økonometriske teorier	12
3	Metode	13
3.1	Maskinlæring	13
3.1.1	Random forest	14
3.1.2	Support Vector Machine	15
3.1.3	Neural Network	16
3.1.4	Kritikk av maskinlæring	17
3.2	GARCH	17
4	Data	19
4.1	Dataforberedelse	19
4.2	Variabler	20
4.3	Deskriptiv statistikk	22
4.3.1	Stasjonaritet	24
4.3.2	Korrelasjonsanalyse	25
4.4	Modellering og analyse	26
4.4.1	Maskinlæringsmodellene	27
4.4.2	GARCH-modellene	31
4.4.3	Value at risk	32
4.4.4	Forventet tap	33
5	Empiriske resultater	33

5.1	<i>Variabelbetydning</i>	34
5.2	<i>Modellenes prediktive evne</i>	35
5.2.1	RF og GARCH.....	37
5.2.2	SVM, NN og kombinert modell	39
5.2.3	Oppsummering av modellenes prediktive evne.....	41
5.3	<i>Praktisk tilnærming</i>	42
5.3.1	VaR estimering.....	44
5.3.2	Backtesting	44
5.3.3	Forventet tap.....	44
6	konklusjon	45
6.1	<i>Videre forskning</i>	47
7	Referanseliste	48

Forord

Denne avhandlingen markerer slutten på en toåring masterstudie i økonomi og administrasjon ved Handelshøgskolen i Tromsø. Avhandlingen er skrevet innenfor forfatternes hovedprofil, Økonomisk analyse og finans, og utgjør 30 studiepoeng.

Arbeidet med masteroppgaven har både vært interessant og lærerikt, og vi har tilegnet oss kunnskap innenfor flere fagfelt. Prosessen har vært tidkrevende, og til tider frustrerende, men resultatet er et akademisk verk som vi er meget stolt over. Vi håper at vår avhandling kan være til nytte for andre, og kanskje inspirere noen.

Vi ønsker å benytte anledningen til å rette en stor takk til vår veileder, Thomas Leirvik, for et godt samarbeid, uendelig med gode innspill og masse god kompetanse. Videre vil vi gjerne takke våre familier, venner, klassekamerater, kjærester og samboere. De har gjort de siste 5 årene til en fantastisk opplevelse med mye latter, kunnskap og gode minner. Vi vil også rekke en ekstra takk til brødrene Reitan Brynjulfsen, som vi har hatt glede av å tilbringe nesten hver dag med de siste to årene. Sist, men ikke minst, ønsker vi å takke hverandre for 5 år med gode opplevelser og vennskap. God lesning!

Steffen Skeimo og Terje Fagerli Pedersen

Tromsø, 2. juni, 2024

Sammendrag

Denne masteroppgaven utforsker hvordan maskinlæringsmodeller og tradisjonelle GARCH-modeller evner seg til å predikere volatilitet i kryptovalutamarkedet, med Bitcoin som case-studie. Bitcoin som er kjent for sin høye volatilitet, påvirkes av både interne markedsdynamikker og eksterne økonomiske faktorer. Ved å kombinere teori fra finans og økonomi med moderne algoritmer, søker vi å forbedre prediksjonene for volatiliteten.

Studien vurderer ytelsen til modeller som Random forest, support vector machine, neural network og en kombinert modell og sammenligner disse med GARCH-modellene sGARCH (1,1) og TGARCH (1,1). Resultatene viser at RF-modellen utmerker seg i generell nøyaktighet, mens GARCH-modellene gir bedre resultater i perioder med lav volatilitet. Samtidig demonstrerer maskinlæringsmodellene potensialet for å håndtere høyere volatilitet, men med større feilmarginer.

For å gi en praktisk tilnærming til forskningen, anvender vi Value at risk (VaR) og forventet tap (ES) for å måle modellens evne til å estimere fremtidig risiko. Resultatene understreker viktigheten av å velge riktig modell.

Denne oppgaven bidrar til en dypere forståelse av Bitcoin-markedets dynamikk og gir innsikt i hvordan man kan anvende avanserte prediksjonsmetoder for å forbedre risikostyring og investeringsbeslutninger i kryptovalutamarkedet. Videre forskning kan bygge videre på disse funnene.

1 Innledning

Den økonomiske uroen forårsaket av finanskrisen i 2007-2008 førte til mistillit til det etablerte finanssystemet, og særlig banknæringen ble møtt med skepsis. Denne perioden avdekket fundamentale svakheter ved tradisjonelle betalingssystemer. Satoshi Nakamoto (2008) kritiserte deres høye transaksjonskostnader og mangel på anonymitet, i tillegg til at transaksjonene var reversible. Som en direkte respons på disse utfordringene ble konseptet kryptovaluta introdusert – en digital valutaform designet for å fungere desentralisert og tillate anonyme transaksjoner. Bitcoin, den første og mest dominerende kryptovalutaen, ble skapt for å tilby en alternativ monetær struktur, og har siden vært en sentral aktør i diskusjoner om digital økonomi og finansiell innovasjon.

I 2023, femten år etter Bitcoins introduksjon, er dens markedspris notert til omkring 36 000 USD, men fortsatt preget av betydelig prisvolatilitet og særlige oppsving i pris, som de bemerkelsesverdige toppene i 2017 og 2021. Dette vitner om en kryptovaluta som er dypt påvirket av variabler utover de umiddelbare markedskreftene. For eksempel var prisen, i følge investing.com, for én Bitcoin per 31.12.2023 på omtrent 42300 USD, mens prisen per 30.05.2024 var på omtrent 68300 dollar. Dette tilsvarer en økning på omtrent 61% på 5 måneder og understreker en betydelig prisvolatilitet.

Mange hevder at Bitcoin er en boble som kan gå i oppløsning når som helst. Man kan forklare en boble som “*forskjellen mellom investeringsobjektets fundamentale verdi og markedspris*” (Stiglitz, 1990, s. 13). Dersom prisen utelukkende skyldes et håp om høy salgspris i fremtiden, eksisterer det i en boble. Dette innebærer at den høye prisen ikke er rettferdiggjort av fundamentale faktorer (Stiglitz, 1990). Det skal dog nevnes at det ikke er like rett frem som det høres ut, og en boble er svært vanskelig å se, og ikke minst predikere. I mange tilfeller velger investorer å investere i en aksje eller lignende selv om den fundamentale verdien ikke er lik markedsverdien. Formålet er å kjøpe en del, for så å selge videre med profitt før boblen sprekker. Dette er forklart i *The Greater Fool Theory*. Santoni (1987) forklarer denne teorien kort som at mennesker investerer i en aksje og antar at det finnes andre som vil betale en høyere pris for den i fremtiden, uavhengig av den fundamentale verdien.

Kjennetegnet for kryptovaluta er at de ikke er støttet eller regulert av sentralbanker eller myndigheter. Dermed skiller denne desentraliseringen seg fra tradisjonelle valutaer som for

eksempel USD. Uavhengig om kryptovaluta er en boble, er det av interesse å undersøke hva som har ført til prisøkningen og volatiliteten til Bitcoin.

I denne avhandlingen behandler vi kryptovaluta som et investeringsobjekt, som aksjer eller andre investeringer, og ikke som en valuta. Formålet med oppgaven er å predikere risikoen i kryptovaluta ved å bruke tradisjonelle og nyere modeller, og sammenligne disse. Det vil bli brukt volatilitet som et mål for risiko.

1.1 Problemstilling

Målet med denne oppgaven er å utføre en detaljert analyse av volatiliteten i Bitcoin ved å anvende metoder som maskinlæring og GARCH-modeller. Gjennom en kombinasjon av kvantitative analyser og teoretiske modeller ønsker oppgaven å belyse hvilke eksterne faktorer som mest signifikant påvirker prisendringer i kryptovalutamarkedet. Ved å bruke disse innsiktene håper oppgaven å tilby nyttige strategiske anbefalinger og dermed bidra til en dypere forståelse av dynamikken i et stadig mer innflytelsesrikt finansmarked. Basert på dette har vi valgt følgende problemstilling for oppgaven:

“Hvordan presterer tradisjonelle GARCH modeller mot maskinlæring i prediksjon av et høyt volatil marked”

1.2 Litteraturgjennomgang

Kryptovaluta baserer seg på blokkjede-teknologi som tilbyr pålitelige overføringer av eiendeler gjennom innovative kryptografiteknikker. Glaser et al. (2014) påpeker at kryptovaluta hovedsakelig brukes som et investeringsobjekt, imidlertid kan kryptovaluta også brukes som et betalingsmiddel ettersom flere store selskaper har begynt å akseptere dette for sine transaksjoner. I tillegg kan kryptovaluta brukes som et instrument for å samle kapital gjennom en ICO (Initial Coin Offering) (Momtaz, 2019).

For å ta veloverveide investeringsbeslutninger er det nødvendig å forstå markedets struktur og dets funksjon. Ifølge hypotesen om effisiente markeder reflekterer priser all tilgjengelig informasjon, mens atferdsfinansteorien argumenterer for at psykologiske faktorer også påvirker prisdannelsen (Almansour, 2015; Bashar et al., (2017); Barber & Odean, 2008; Fama, 1970). Madhavan (2000) hevder at markedets informasjonseffektivitet, samt informasjonsstrukturen, spiller en essensiell rolle i prisformasjonen. Jiang et al. (2018) og Alvarez-Ramirez et al. (2018) hevder at prissettingen og informasjonen i

kryptovalutamarkedet er ineffektiv, noe som betyr at kryptovalutamarkedet anses som ineffektiv.

Ineffektive markeder er ofte volatile, noe som har ført til at en rekke studier har blitt gjennomført med et formål om å studere volatiliteten i kryptovalutamarkedet. Bouoiyour et al. (2016) utførte en studie hvor de sammenlignet Bitcoins volatilitet med USAs implisitte volatilitetsindeks (VIX), og fant en negativ sammenheng mellom den realiserte volatiliteten til Bitcoin og VIX. Videre undersøkte Kim et al. (2017) Bitcoins popularitet ved å bruke antall tweets om Bitcoin. Ved å bruke lineær og ikke-lineær Granger kausalitets analyse fant de ut at antall tweets var en signifikant driver for neste dags handelsvolum og realisert volatilitet (Kim et al., 2017). I denne avhandlingen inkluderes AI-analyserte Kabel TV Nyheter som en variabel. Tidligere forskning har vist at medieoppmerksomhet påvirker markedsvolatilitet. Ved å bruke AI til å analysere sentimentet i nyhetsdekningen, er målet å få en bedre forstå hvordan nyheter påvirker Bitcoins volatilitet, og dermed utvide forståelsen fra tidligere studier om sosiale medier og markedsdynamikk.

Ved høy volatilitet kreves det nøyaktige prognosemodeller for å kunne forutsi dette. I en studie fra Ardia et al. (2019) brukte en GARCH modell for å analysere Bitcoin volatiliteten ved hjelp av tidsseriedata fra 2011 til 2018. Resultatet av studien visste at GARCH modellen er svært pålitelig når det kommer til å forutsi Bitcoins volatilitet. Det er gjort flere studier som bruker GARCH modeller til å forutsi volatilitet i kryptomarkedet. Chu et al. (2017) analyserte volatiliteten til syv kryptovalutaer, blant annet Bitcoin. I studien benyttet de seg av tidsseriedata fra 2014 til 2017 og fant at GARCH spesifikasjoner gir den prestasjonen innad i utvalget. Videre anvendte Cermak (2017) en GARCH-modell for å studere Bitcoins volatilitet ved å ta hensyn til flere makroøkonomiske faktorer i Kina, Japan, USA og Europa. Resultatene fra studien indikerte at i Kina, USA og Europa oppfører Bitcoin seg på samme måte som tradisjonelle valutaer, og at hvis trenden fortsetter så ville Bitcoin fungere som tradisjonelle valutaer løpet av 2020, noe som ikke skjedde.

Sammenlignet med valutaer, obligasjoner, råvarer og aksjer er Bitcoin prisen per enhet blant de aller største (Briere et al., 2013; Chowdhury, 2016; Chowdhury og Mendelson, 2013). Almansour et al. (2020) undersøkte forholdet mellom avkastningen på valutakurser og Bitcoin avkastninger ved å bruke tidsserieanalyse, da spesielt Autoregressive modeller (ARMA) til analysene. Studiet viste at valutakurser ikke påvirker avkastningen til Bitcoin betydelig. I en tilsvarende studie undersøkte Dyhrberg (2016) atferden til Bitcoin volatiliteten

sammenlignet med valutakurser og gull ved å bruke en T-GARCH (1,1) modell. Resultatet av studien indikerte en positiv sammenheng mellom volatiliteten til Bitcoin og gull.

I nyere tid er det også brukt en rekke maskinlæringsteknikker for å forutsi volatilitet. Wang et al. (2023) bruker ulike maskinlæringsteknikker for å forutsi volatiliteten til en rekke kryptovalutaer, blant annet Bitcoin og Ethereum. I studien bruker de tidsseriedata fra 2017 til 2022 og undersøker om maskinlæringsteknikker er bedre til å forutsi volatilitet enn tradisjonelle GARCH modeller. Studiets funn indikerer at maskinlæringsteknikkers evne til å forutsi volatilitet overgår de tradisjonelle GARCH modellene.

2 Teoretisk rammeverk

2.1 Hva er kryptovaluta?

Nian & Chuen, (2015) definerer kryptovaluta som en undergruppe av digital valuta. Bitcoin gjør det mulig for forbrukeren å sende penger direkte til en annen uten at dette går gjennom en finansinstitusjon (Nakamoto, 2008).

Kryptovaluta er en type digital eller virtuell valuta som bruker kryptografi for sikkerhet. Kryptovalutaer er karakteristisk desentraliserte systemer basert på blokkjede-teknologi, som er en distribuert hovedbok håndhevet av et nettverk av datamaskiner. Bitcoin er den mest kjente kryptovalutaen. Kryptovalutaene kan kjøpes på ulike børser og lagres i lommebøker (Zohuri B., et al, 2022). De siste årene har det fått enorm oppmerksomhet og flere har investert stort i kryptoaktiva. Dette har medført at markedsverdien har skutt i været.

2.1.1 Bitcoin (BTC)

Bitcoin er en såkalt virtuell valuta som er utviklet for anonyme betalinger som utføres uavhengig av regjeringer og banker. I de siste årene har Bitcoin fått mye oppmerksomhet på flere fronter. Bitcoinbetalinger er basert på en ny teknisk løsning som fungerer annerledes enn andre tradisjonelle betalinger. Det kan gi fordeler som lavere kostnader, høyere hastighet og anonymitet. Det kan imidlertid være mer risikabelt fordi Bitcoin ikke er direkte dekket av lovene som styrer andre betalingsformidlinger. Siden forbrukervern er lavt, kan det også være vanskelig for Bitcoin å bli akseptert og et bærekraftig betalingsmiddel (Segendorf, 2014).

Bruken av Bitcoin er lav i dag, men det er en interessant innovasjon som fortjener en beskrivelse.

Nakamoto (2008) påpekte problemene med konvensjonell valuta, som krever tillit til sentralbanker og banker som tidligere har brutt denne tilliten. Han mente at Bitcoin kunne være en løsning på slike urettferdige systemer, der institusjoner mottok offentlige midler for å unngå konsekvensene av deres uansvarlige atferd (Warmke, 2020).

De siste årene har regjeringer over hele verden økt pengetrykningen for å unngå en økonomisk depresjon. Nakamotos ide pekte på at Bitcoin forble en alternativ valuta som var delbar, bærbar og vanskelig å beslaglegge. Bitcoin skulle også være motstandsdyktig mot sensur fordi den overførte verdier direkte mellom folk uten behov for en mellommann. (Warmke 2020).

Blokkjede-teknologien er en relativt ny tilnærming innenfor informasjonsteknologibransjen. Som en av dens første implementeringer har Bitcoin fokus på smarte kontrakter som representerer kjernen i moderne kryptovaluta utvikling. Behovet for en desentralisert valuta har blitt benyttet mer som teoretisk konsept, men i det siste tiåret ble det mer realistisk etter Satoshi Nakamoto introduserte sin ide. Selv om Nakamotos sanne identitet er ukjent har han introdusert noe revolusjonerende til verden og det er opp til hver og enkelt å bestemme hva man skal gjøre med det. Noen vil gripe muligheten å utvikle egne applikasjoner for å løse problemer, andre vil investere penger i disse ideene eller trade mellom opp- og nedgangene i kryptovalutaenes verdier på markedet (Vujicic, et al. 2018)

Teknologien representerer en distribuert database som sikrer og transparerer lagring av data gjennom en serie av kryptografisk sikrede blokker. Teknologien samler transaksjonsdata i blokker, som krypteres og lenkes sammen med unike hash-verdier og skaper en uforanderlig rekkefølge. Fordelene inkluderer nøyaktighet, kostnadsreduksjon, sikkerhet og effektivitet, mens ulempene omfatter høye teknologikostnader, lav transaksjonskapasitet, bruk i ulovlige aktiviteter og reguleringsutfordringer. Bitcoin-miningen er en prosess der komplekse matematiske gåter løses for å legge til nye blokker i kjeden, noe som krever betydelig beregningskraft og resulterer i høyt energiforbruk (Kufeoglu & Ozkuran, 2019).

2.2 Finansiell teori

Risiko og avkastning er tett sammenknyttet (Lundblad, 2007), og evnen til å forutsi risiko kan derfor direkte påvirke forventet avkastning. Risikoavkastningsavveining er et fundamentalt

prinsipp innen finans som beskriver sammenhengen mellom risikoen knyttet til en investering og den forventede avkastningen. Dette prinsippet sier at forventet avkastning øker når risikoen øker, og at jo høyere risiko jo høyere potensiell avkastning (Chen, 2024).

I kjernen av risikoavkastningsavveiningen ligger forståelsen av at enhver investering med høy forventet avkastning også innebærer en tilsvarende høy risiko. Dette prinsippet kan formuleres som et krav om at investorer må kompenseres for å påta seg ekstra risiko. For å forstå dette konseptet fullt ut, må vi dykke ned i de teoretiske og praktiske implikasjonene av risiko og avkastning. Disse teoriene vil ikke bli brukt direkte i oppgaven, men forståelsen av disse teoriene er essensielle for å kontekstualisere risikoavkastningsavveiningen.

Teorien om effisiente markeder antyder at det er umulig å "slå markedet" over tid uten å ta på seg ekstra risiko. I et effisient marked reflekteres all tilgjengelig informasjon i prisen på verdipapirer, noe som betyr at overnormale avkastninger kun kan oppnås gjennom høyere risiko (Fama, 1970).

Kapitalverdimodellen (CAPM) gir en metodologisk tilnærming til å kvantifisere sammenhengen mellom systematisk risiko og forventet avkastning. Ifølge CAPM er forventet avkastning på en investering lik den risikofrie renten pluss en risikopremie, som er avhengig av investeringens beta (β), et mål på dens markedsrisiko. Modellen formuleres som:

$$E(R_i) = R_f + \beta_i(E(R_m) - R_f) \quad (1)$$

Hvor $E(R_i)$ er forventet avkastning på investering i , R_f er den risikofrie renten, β_i er beta for investeringen i , og $E(R_m)$ er forventet avkastning på markedet (Sharpe, 1964; Lintner, 1965).

Selv om både teorien om effisiente markeder og CAPM ikke vil bli anvendt direkte i denne oppgaven, gir de en nødvendig bakgrunn for å forstå det fundamentale prinsippet om risikoavkastningsavveining. Ved å etablere denne teoretiske rammen, kan vi bedre forstå hvordan denne oppgaven kan bli brukt i praksis gjennom å tolke hvordan risiko og avkastning samspiller i praktiske investeringsbeslutninger.

2.3 Value at Risk

Value at Risk (VaR) er en statistisk metode som brukes for å estimere det verste mulige monetære tapet fra en finansiell investering over en bestemt tidsperiode, for eksempel en dag

eller en måned. For de fleste finansielle investeringer er avkastningen over en fremtidig periode en stokastisk variabel. Dette innebærer at den faktiske fremtidige avkastningen alltid vil avvike noe fra ethvert estimat av fremtidig avkastning. Derfor har en VaR-erklæring et konfidensnivå knyttet til seg, hvor "konfidens" er definert som sannsynligheten for at det faktiske monetære tapet ikke vil overstige VaR-beløpet (Sollis, 2009).

VaR har blitt et standardverktøy i risikostyring fordi det gir ett enkelt tall som oppsummerer det potensielle tapet i en portefølje eller enkeltaksje. Dette gjør det lettere for risikostyrere å kommunisere risikonivåer og for beslutningstakere å sette risikorammer. Det er viktig å merke seg at VaR ikke forutsier det maksimale mulige tapet, men bare det maksimalt sannsynlige tapet innenfor det gitte konfidensnivået. Dette betyr at ekstreme hendelser, som ligger utenfor konfidensnivået, ikke nødvendigvis fanges opp av VaR (Sollis, 2009).

I finansielle institusjoner er VaR integrert i den bredere risikostyringsrammen. Det brukes til å allokere kapital for å dekke potensielle tap, sette handelsgrenser, og vurdere risikoen i ulike forretningsenheter. Reguleringsorganer krever også at banker og finansinstitusjoner rapporterer sin VaR for å sikre at de holder tilstrekkelig kapital mot potensielle tap (Sollis, 2009). Reguleringen av VaR har som hovedmål å beskytte finanssystemet, øke transparensten og forhindre systemiske risikoer. Ved å sikre at finansinstitusjonene har tilstrekkelig kapital til å absorbere tap under stressede markedsforhold, bidrar regulatoriske krav til å opprettholde stabiliteten i det bredere finansielle systemet (Sollis, 2009).

Reguleringen av VaR innebærer at banker bruker interne modeller for å beregne VaR, men disse modellene må godkjennes av regulatoriske myndigheter. Godkjenningsprosessen inkluderer strenge krav til modellens nøyaktighet og robusthet. For å supplere VaR, krever regulatorer også at banker gjennomfører stresstester som simulerer ekstreme markedsforhold. Dette hjelper med å identifisere svakheter i modellene og sikre at bankene har tilstrekkelig kapital til å overleve ekstreme markedsbevegelser (Sollis, 2009).

2.4 Makroøkonomiske forhold

I denne avhandlingen vil det bli undersøkt hvordan Bitcoin blir påvirket av makroøkonomiske forhold, med et hovedfokus på finansiell risiko og økonomisk politikk, som for eksempel ulike tradisjonelle finansmarkeder, politisk usikkerhet og vurdering av risiko. Disse faktorene spiller alle en betydelig rolle i den brede økonomiske sammenhengen og kan potensielt gi implikasjoner for kryptovalutamarkedet. Finansiell risiko og volatiliteten i markedet er også

av stor betydning da det kan påvirke risikotoleranse og investeringsstrategier. Når man tar med økonomisk politikk som en sentralbanks tiltak og offentlige reguleringer, kan det påvirke stabiliteten til kryptovalutamarkedet.

2.5 Økonomisk politisk usikkerhet

Politisk usikkerhet er den økonomiske risikoen knyttet til udefinert fremtidig statlig politikk og regulatoriske rammer. Dette øker ytterligere risikoen for at både bedrifter og enkeltpersoner vil utsette sine investeringer på grunn av markedsusikkerhet (Al-Thaqeb & Algharabali, 2019). Baker, Bloom & Davies (2016) utviklet en ny indeks kalt “Economic Policy Uncertainty (EPU)”. EPU er en indeks konstruert basert på avisartikler om politisk usikkerhet fra de største nyhetskildene i USA. Den teller antall avisartikler som inneholder begrepene usikker eller usikkerhet, økonomisk eller økonomi, og ett eller flere politikkrelevante begreper.

Ifølge Baker et al. (2016), er politisk usikkerhet knyttet til økte aksjepriser og lavere investeringer på selskapsnivå. På et mer generelt plan indikerer nye usikkerhetsmomenter i politikken en reduksjon i investeringer, produksjon og sysselsetting i USA og andre ledende økonomier. Det betyr at politisk usikkerhet påvirker både prisen og volatiliteten til investeringsobjekter. Kryptomarkedet er kjent for å være et svært volatilt marked med store svigninger i markedet, og siden politisk usikkerhet påvirker volatiliteten i investeringsobjekter, vil det også kunne påvirke volatiliteten i kryptokurser (Bergbrant & Bradley, 2023)

2.6 Implikasjoner med økonometriske teorier

Når man skal analysere kryptovaluta basert på tradisjonelle økonometriske teorier kan det støte på ulike utfordringer. Primært kan dette være vanskelig fordi kryptovaluta har egenskaper som skiller seg fra tradisjonelle verdipapirer som aksjer og fond.

Et eksempel på en utfordring er volatilitet og spekulasjon. Kryptovaluta er som sagt kjent for sin betydelige volatilitet, noe som delvis kan skyldes en høy andel av spekulativ handel. Dette kan medføre at standardmodeller for prising og risiko kan bli utilstrekkelig.

Videre kan man også se på manglende historiske data. Siden kryptovaluta er såpass nytt, kan det være vanskelig å se hvordan det utvikler seg. Hvis man sammenligner med aksjer og andre finansielle markeder som har lengre perioder med data og lignende, kan det medføre at det er

lettere å predikere priser samt utvikle en nøyaktig modell. Dermed kan det resultere i mindre pålitelige analyser.

Siden kryptovalutamarkedet er desentralisert og uregulert sammenlignet med tradisjonelle finansmarkeder kan det gi forskjellige markedsdynamikker som tradisjonelle økonomiske teorier har vanskeligheter med å forklare eller forutsi. Det samme gjelder prisingen som også kan påvirkes av andre faktorer enn det økonomiske, eksempelvis gjennom teknologiske endringer og utvikling, nyheter rundt reguleringen av kryptovaluta og lignende. Det kan bety at tradisjonelle økonometriske modeller kan være mindre effektive. Dette kan eksempelvis bety at diversifisering av en portefølje kan bli utfordrende når risiko er ukjent.

3 Metode

3.1 Maskinlæring

Maskinlæring kan sies å være et bredt spekter av algoritmer og teknikker som tillater datamaskiner «å lære» fra data for å gjøre forutsigelser eller ta beslutninger uten å være eksplisitt programmert til å utføre oppgaven. Denne læringen kan innebære å gjenkjenne mønstre, tolke komplekse data eller gjøre informerte gjetninger om fremtidige hendelser (Akyildirim., et al, 2021). Maskinlæring er et område innenfor kunstig intelligens (KI) som blir benyttet av flere ulike virksomheter for å utføre ulike oppgaver, deriblant til å utføre analyser, gjenkjenne mønstre og som beslutningsstøtte.

Det er flere ulike definisjoner av maskinlæring. Datatilsynet definerer maskinlæring som *“et sett teknikker og verktøy som lar maskiner “tenke” ved å lage matematiske algoritmer basert på akkumulert data”* (Datatilsynet, 2018, s. 5). Maskinlæringsteknikker går ut på at maskiner justerer eller tilpasser sine handlinger for å forbedre nøyaktigheten (Marsland, 2014).

Maskinlæring bygger på statistiske metoder som gjør det mulig for systemet å identifisere mønstre i datasett, slik at maskinen kan lære selv i stedet for å være eksplisitt programmert (Tidemann & Elster, 2021).

For å oppnå dette er systemet avhengig av tilgang på store mengder data (Datatilsynet, 2018). For at en maskin skal kunne håndtere komplekse oppgaver ved hjelp av maskinlæring, må den trenes (Das et al., 2015). Det finnes flere forskjellige metoder for å trene en

maskinlæringsalgoritme, inkludert veiledet læring (supervised learning), ikke-veiledet læring (unsupervised learning) og forsterket læring (reinforced learning).

Veiledet læring betyr at man har en responsvariabel man ønsker å predikere. Eksempelvis kan predikering av avkastning til aksjer, hvor man i utgangspunktet vet hva avkastningen er, og at algoritmen dermed forsøker å predikere den observerte verdien. Ikke-veiledet læring betyr at det ikke er noen responsvariabel, slik at algoritmen prøver å finne mønster i datasettet. Et eksempel er bildegjenkjenning. Forsterket læring er en gren av maskinlæring hvor en agent lærer å ta beslutninger ved å utføre handlinger i et miljø for å maksimere en kumulativ belønning, eksempelvis en algoritme som lærer å spille sjakk (Datatilsynet, 2018). I denne avhandlingen vil det utelukkende kun bli brukt veiledet læring.

Veiledet læring deles ofte inn i to hovedkategorier, regresjon og klassifisering. Klassifisering er en type maskinlæringsteknikk som brukes når målet er å kategorisere eller klassifisere data i forskjellige klasser eller kategorier. Modellen trenes opp på et datasett med kjente kategorier og den lærer å forutsi kategorier for nye, ukjente data. Regresjon er en type maskinlæringsteknikk som brukes når målet er å forutsi en kontinuerlig numerisk verdi. Modellen trenes opp på et datasett med kjente verdier, og den lærer å forutsi numeriske verdier for nye data. I denne avhandlingen brukes regresjon da ønsket er å forutsi nøyaktige verdier.

3.1.1 **Random forest**

Random Forest (RF) er beskrevet som en algoritme som lager flere modeller (El Naqa & Murphy, 2015). Det er en veiledet læremetode som fungerer ved å bygge flere beslutningstrær og lage en endelig beslutning basert på flertallet av trærne. Hovedfordelen er at det reduserer risiko for overtilpasning og reduserer den nødvendige «treningstiden». Det er også en nøyaktig modell som kjører store datasett og kan brukes til klassifisering og regresjonsproblemer (Akyildirim., et al, 2021).

Kjernen i RF er opprettelsen av mange beslutningstrær under treningen. Hvert tre bygges ved hjelp av en forskjellig tilfeldig utvalgt delmengde av treningsdataene, en prosess også kjent som «Bootstrapping». Dette bidrar til å redusere korrelasjonen mellom trærne og vil øke modellens robusthet, noe som er et vanlig problem med maskinlæring.

Når et datapunkt skal klassifiseres, blir det sendt gjennom hvert tre. Videre gir det individuelle treet sin stemme basert på kriterier, og den endelige klassifiseringen bestemmes gjennom et flertall av stemmene. Dette prinsippet om «Flertallsavstemming» sikrer at modellen er mindre sensitiv for støy i individuelle trær og måler en mer balansert og pålitelig prediksjon (Livingston, 2005).

Et annet poeng i RF er et tilfeldig utvalg av attributter som brukes til å bygge beslutningspunkter i trærne. I stedet for å bruke alle tilgjengelige attributter i hver avgjørelse, velger algoritmen en tilfeldig delmengde. Dette vil bidraytterligere til diversifiseringen av trærne og målet er å sikre at enkeltattributter ikke dominerer prediksjonen (Livingston, 2005). Da kan man snakke om variabelbetydning som også diskuteres i denne avhandlingen.

Variabelbetydning måler hvor mye hvert attributt bidrar til nøyaktigheten av prediksjonene. Dermed er det viktig å identifisere og prioritere de riktige attributtene slik at man kan forbedre modellens nøyaktighet og effektivitet. Dette vil bli brukt for å analysere kryptovalutamarkedsdata ved å håndtere komplekse datasett og finne mønstre som kan indikere hvordan kryptovalutaer kan bli påvirket av økonomiske forhold.

3.1.2 Support Vector Machine

Support Vector Machine (SVM) er også en veiledet metode som kan brukes til å klassifisere og forutsi prisbevegelser (El Naqa & Murphy 2015), og kan brukes på kryptovalutaer basert på ulike økonomiske indikatorer og markedsdata. Det er blitt brukt med suksess for å forutsi aktivavkastning og andre anvendelser hvor det er små eller støyende data. SVM er kjent for å gi optimale verdier og deres ytelse avhenger av valget kjernefunksjoner som brukes til å transformere data før klassifiseringen skjer (Akyildirim., et al, 2021).

Hovedpoenget med SVM ligger i dens evne til å skille data i et høydimensjonalt rom. Teknikken gjør dette ved å finne hva som best skiller de ulike klassene av data. Sammenhengen blir valgt ved at den maksimerer marginen mellom to klasser slik at den utvikler robusthet. Et sentralt begrep er «Kernel»-funksjonen. Den transformerer inngangsdataene slik at det blir lettere å skille klassene. Det gjør SVM effektivt for ikke-lineært separerbare data. Dette gjør det også mulig å håndtere data som ellers ville vært vanskelig å klassifisere med lineære metoder (Noble, 2006).

SVM har vist seg å være spesielt effektive i situasjoner der antall dimensjoner er større enn antall observasjoner. Dermed skiller det SVM fra andre maskinlæringsmetoder under slike forhold. Noble (2006) påpeker også at valg av riktig kjernefunksjon og parametere kan være utfordrende og krever en viss grad av kunnskap og erfaring. Samtidig kan SVM være treg å bruke på store datasett da treningsprosessen kan være beregningssensitiv. Dette gjør at det kan være vanskelig å tolke.

3.1.3 Neural Network

Neural Network (NN) kan beskrives som kunstige nevrane nettverk som kan trene historiske data (El Naqa & Murphy, 2015) og kan potensielt oppdage subtile sammenhenger mellom kryptovalutapriser og økonomiske forhold som ikke lett kan sees av mennesker eller tradisjonelle statistiske metoder.

Det kan beskrives som en sentral teknologi innen maskinlæring. Målet med NN er at det skal etterligne hjernens måte å lære og ta beslutninger på. Det består av noder som er koblet sammen og behandler informasjon ved hjelp av et sett med inngangsdata og tilhørende vektinger (Jung & Kim, 2016).

Ved hjelp av NN kan man få et «Dypere nettverk» som kan fange opp mer komplekse mønstre. Samtidig skal det kunne være allsidig og brukes i et bredt spekter av situasjoner som gjenkjenning, behandling av data og lignende. Dette gjør NN fleksible. Jung & Kim (2016) anerkjenner imidlertid i sin studie at også NN har sine begrensninger. For eksempel kan det være mindre nøyaktige tilfeller som ikke er godt representert i treningsdataene. Dermed understrekes viktigheten av å ha et godt og representativt datasett for å trene det riktig og få det mest mulig effektivt. Siden det er datadrevet, er det avhengig av kvaliteten og mengden treningsdata.

Analysen som gjennomføres er en “Feedforward” NN. Dette er en metode som inneholder økt dybde i nettverket som kan forbedre nettverkets evne til å forstå komplekse funksjoner som ellers ville kreve eksponentielt mange nevroner i et nettverk med færre lags (Ronen & Ohad, 2016). En feedforward NN-modell er en av de enkleste typene for kunstige nevrane nettverk. I en feedforward flyter informasjonen kun i en retning – fremover, fra inngangsnodene, gjennom skjulte noder (om nødvendig) og til utgangsnodene (Ronen & Ohad, 2016).

I analysen av volatiliteten i Bitcoin er feedforward NN verdifullt. Den strukturelle metoden tillater nettverket å behandle og lære fra historiske prisdata på Bitcoin ved å etablere relasjoner mellom de utvalgte inngangsvariablene og den etterfølgende volatiliteten. Ved å trene nettverket med relevante inngangsdata, utvikler man en modell som kan predikere volatilitetsmønstre basert på gjenkjente mønstre.

3.1.4 **Kritikk av maskinlæring**

Det eksisterer også en del kritikk rundt maskinlæring. Artikkelen skrevet av Abdullah et al. (2023) understreker at maskinlæring potensiale for skjevhet i klassifisering og kvantifisering, men påpeker risikoen for feilaktig implementering som kan lede til misvisende konklusjoner. Dette kan medføre at det blir feil innspill til dataene man ønsker å trene. Videre kan også maskinlæringsteknikker som NN være vanskelig å forstå og tolke, noe som skaper utfordringer for tilliten.

En annen utfordring med maskinlæring er det som kalles for “black boxes”. Det vil si at selv om disse modellene kan produsere nøyaktige forutsigelser eller klassifiseringer, er det ofte uklart hvordan man kommer frem til disse resultatene (Castelvecchi, 2016). Denne mangelen på åpenhet gjør det vanskelig å forstå de underliggende årsakene til prediksjonene, og er dermed vanskelig å knytte til etablerte teoretiske rammer. Innenfor mange fagfelt, spesielt økonomi, er forståelsen av årsakssammenhengen minst like viktig som selve prediksjonen. Denne utfordringen blir problematisk i situasjoner der beslutningstaking krever en klar forståelse av de underliggende faktorene og mekanismene, for eksempel som i policy utforming. Videre kan mangel på teoretisk forankring i maskinlæringsmodeller føre til overtilpasning og misforståelser av viktige variabler og relasjoner, noe som kan gi misvisende resultater eller videre anbefalinger.

3.2 **GARCH**

GARCH (Generalized Autoregressive conditional Heteroskedasticity) modellen er en utvidelse av ARCH modellen og er designet for å gi en mer fleksibel og effektiv måte å modellere endringer i volatilitet i finansielle tidsserier. GARCH-modellen ble introdusert av Tim Bollerslev i 1986 og er i hovedsak en generalisert form av Engels ARCH-modell. Bollerslev erkjente at selv om ARCH-modeller var nyttige for å modellere volatilitet, krever de ofte et stort antall parametere for å skjønne volatilitetsdynamikken tilstrekkelig i finansielle tidsserier (Bollerslev, 1986). Den viktigste forskjellen mellom ARCH og GARCH-modeller

er at GARCH inkluderer forsinket varians og forsinket kvadrerte feil. Dette gjør at modellen kan forstå og ha et større minne av volatiliteten uten å bruke et stort antall parametere. GARCH-modellen er ofte betegnet som GARCH (p,q) der «p» er lagget varians, og «q» er lagget kvadrerte feil.

Modellen har følgende formel:

$$\sigma_t^2 = \alpha_0 + \sum_{i=1}^q \alpha_i \varepsilon_{t-1}^2 + \sum_{j=1}^p \beta_j \sigma_{t-j}^2 \quad (2)$$

σ_t^2 representerer den betingede variansen på tidspunkt t. Videre er α_0 en konstant som bidrar til å sikre baseline-nivået av volatilitet, den er avhengig av å være større enn 0. ε_{t-1}^2 er forsinkede kvadrerte residualer fra middelverdien og representerer ARCH-leddene. Videre er σ_{t-j}^2 Forsinkede betingede varianser og viser GARCH leddene. α_i og β_j er koeffisienter som må estimeres. Og indikerer påvirkningen av tidligere kvadrerte residualer og tidligere varianser på den nåværende variansen. Til slutt er p og q antall forsinkede varianser og antall kvadrerte residualer inkludert i modellen. (Miah & Rahman, 2016)

Det finnes også andre utvidelser av GARCH-modellen. En av de mest populære er TGARCH (p,q) (Threshold GARCH) som også inkluderer ulike reaksjoner på positive og negative sjokk.

Denne er gitt som:

$$\sigma_t^2 = \alpha_0 + \sum_{i=1}^q \left(\alpha_i \varepsilon_{t-i}^2 + \gamma_i \varepsilon_{t-i}^2 I(\varepsilon_{t-i} < 0) \right) + \sum_{j=1}^p \beta_j \sigma_{t-j}^2 \quad (3)$$

σ_t^2 Er variansen til den betingede avkastningen til tid t. Det er det modellen prøver å predikere, da det gir en ide om volatiliteten i avkastningen over tid. Videre er α_0 et konstant ledd som representerer den langsiktige variansen eller det langvarige nivået av volatilitet i avkastningen. ε_{t-i}^2 er de forsinkede kvadrerte residualene, som representerer “sjokk”. $I(\varepsilon_{t-i}^2 < 0)$ er en indikatorfunksjon som er lik 1 hvis $\varepsilon_{t-i}^2 < 0$ og 0 ellers. Dette fanger opp de negative sjokkene. γ_i er koeffisienten som måler den ekstra effekten av de negative sjokkene på variansen. Videre er σ_{t-j}^2 de forsinkede betingede variansene som representerer GARCH leddene. α_i og β_j er i likhet med GARCH (p,q) koeffisientene som må estimeres og indikerer påvirkningen av tidligere kvadrerte residualer og tidligere varianser på den nåværende variansen.

4 Data

For å utforske og analysere kryptovalutamarkedet vil det i oppgaven bli tatt i bruk daglige bitcoindata for perioden 2010-2023 for å forstå volatiliteten i markedet. Fordi kryptovalutamarkedet kan trades 365 dager i året og 24 timer i døgnet vil det være nødvendig med daglige data. Perioden er interessant å analysere da den inneholder betydelige hendelser i markedet. Samtidig får man undersøkt de store pristoppene som blir nådd, samt utviklingen av volatiliteten. All data er målt i USD, og er hentet fra investing.com og Yahoo Finance.

4.1 Dataforberedelse

Dataene ble først rengjort for manglende verdier og unøyaktigheter, hvor et femdagers glidende gjennomsnitt ble anvendt for å imputere manglende data. Det innebærer å beregne et fem dagers glidende gjennomsnitt for hver variabel, og deretter erstatte manglende verdier med dette gjennomsnittet. Denne metoden ble valgt fordi den gir en jevn tilnærming som bevarer den generelle trenden i dataene. Det er en av de mest tekniske indikatorene som brukes til å forutsi fremtidige data i tidsserieanalyser (Hansun, 2013).

For å dykke dypere inn i analysen av prisbevegelser over tid, blir datasettet ytterligere transformert ved å innlemme den prosentvise endringen i pris fra én dag til den neste for de samme variablene. Denne tilnærmingen er sentral for å forstå prisfluktuasjoner over tid. Ved å kombinere denne med femdagers glidende gjennomsnitt og standardavvik for de angitte prisene, oppnår man et mer nyansert bilde av markedsvolatiliteten.

Analyseprosessen videre beregnes ved å kalkulere forsinket logaritmisk avkastning, forsinket volatilitet og momentumvariabler. Målet med dette steget er å generere forsinkede versjoner av de tidligere beregnede prosentvise endringene og volatiliteten. Dette tillater en grundig undersøkelse av hvordan historiske prisendringer og volatilitetsnivåer påvirker de nåværende markedsforholdene. I tillegg spiller momentumvariabler en kritisk rolle i å identifisere langvarige prisbevegelser og trender, som er avgjørende for å forstå markedsretningen og ofte utgjør en viktig del av handelsstrategier.

Disse elementene er også fundamentale i anvendelsen av maskinlæringsmodeller, ettersom de bidrar til en dypere forståelse og forutsigelse av markedsdynamikken. Studier viser at ved å inkludere de forsinkede variablene i volatilitetsberegninger gir fordeler som hvis man er

bekymret for å underpredikere markedets volatilitet og gir større økonomiske fordeler ettersom graden av risikoaversjon øker (Demirer et al., 2020).

4.2 Variabler

Tabellen nedenfor presenterer inkluderte variabler som består av interne BTC priser, makroøkonomiske variabler og finansielle variabler.

Tabell 1: Variabler anvendt i oppgaven

Variabel	Kategori	Forklaring
BTC	Intern	De interne variablene fokuserer direkte på Bitcoin og inkluderer forsinket priser, forsinket volatilitetsmål, og momentum.
S&P500	Finansiell	Representerer et bredt spekter av de mest populære aksjene i USA og gir en indikasjon på den generelle markedsdynamikken.
Dow Jones	Finansiell	Tilbyr et industrielt perspektiv ved å måle ytelsen til 30 store, offentlig eide selskaper i USA.
Nasdaq	Finansiell	Gir et teknologisk perspektiv gjennom sin representasjon av teknologitunge og bioteknologiske selskaper.
USD (DXY)	Finansiell	Dette er et mål på den amerikanske dollarens styrke sammenlignet med en rekke andre viktige valutaer.
XLE	Finansiell	En Exchange-Traded Fund (ETF) som representerer energisektoren.

Olje	Makroøkonomisk	Inkludert som en global økonomisk indikator gitt oljens sentrale rolle i verdensøkonomien. I dette tilfellet er det da brukt WTI.
Gull	Makroøkonomisk	Historisk sett en "sikker havn" under økonomisk usikkerhet og høy inflasjon.
VIX	Makroøkonomisk	Dette er den opprinnelige CBOE volatility index som kan kjennetegnes som "Investors fryktindeks". Denne måler forventet markedsvolatilitet i løpet av de neste 30 dagene basert på opsjonspriser på S&P500-indeksen.
Kabel TV nyheter	Makroøkonomisk	AI Cable News EPU index er en videreutvikling av Economic Policy Uncertainty (EPU) indeksen, som måler økonomisk usikkerhet ved å analysere frekvensen av spesifikke ledd i nyhetsinnhold.

Av tabell 1 observeres "Kabel TV nyheter" variabelen. Siden alle de ulike indeksene i EPUen er høyt korrelerte, blir det brukt en gjennomsnittlig verdi av alle disse. Dette er for å unngå manglende verdier, da flere av indeksene har manglende verdier for enkelte dager.

Ved å inkludere disse variablene i en analyse av volatiliteten i kryptovalutamarkedet gir det en dypere forståelse av makroøkonomiske påvirkninger. USD er verdens reservevaluta og spiller en kritisk rolle i prisfastsettingen av kryptovaluta, noe som gjør det relevant å overvåke dens styrke eller svakhet målt opp mot andre valutaer. Energisektoren, representert med XLE, reflekterer endringer i energipriser som kan ha bredere økonomiske implikasjoner. Gull kan gi innsikt i investorers risikoaversjon og flytting av kapital mellom aktiva. VIX måler forventet markedsvolatilitet og kan dermed hjelpe å forutse svingninger i kryptovalutamarkedet. Til sist gir de store aksjene S&P500, Nasdaq og Dow Jones en indikasjon på generelle

markedstrender og risikovilje, som også kan korrelere med bevegelser i kryptovalutamarkedet. En sterk sammenheng med disse kan for eksempel påvirke investeringer i kryptovaluta. Eksempelvis i perioder med høy risikovilje kan investorer også være mer villig til å investere i risikofylte aktiva som Bitcoin. Det kan også være med på å gi innsikt i likviditetsnivåer og kapitalflyt i markedene, noe som kan føre til at investorer flytter kapital, noe som også kan påvirke kryptovalutamarkedet.

Dermed kan man analysere disse variablene, og sikte mot å avdekke innsikter i hvordan interne og eksterne faktorer samlet påvirker Bitcoins volatilitet, og gir en helhetlig forståelse av markedets dynamikk.

4.3 Deskriptiv statistikk

Tabell 2: Deskriptiv statistikk for variabler anvendt i oppgaven

Stats	BTC	VIX	KabelTV	Olje	XLE	SP500	DJ	Gull	Nasdaq	USD
Gjennomsnitt	0,0041	0,0026	0,0041	-0,0004	0,0001	0,0003	0,0003	0,0001	0,0004	0,0001
Median	0,0005	-0,0036	0,0042	0,0005	0,0002	0,0004	0,0003	0,0002	0,0006	0,0000
Standardavvik	0,0726	0,0777	0,0705	0,0496	0,0167	0,0104	0,0100	0,0094	0,0122	0,0043
Min	-0,5721	-0,3203	-0,7967	-2,9460	-0,2417	-0,0976	-0,1085	-0,1163	-0,1005	-0,0256
Max	3,3675	1,5262	3,0798	0,2510	0,1604	0,0938	0,1137	0,0610	0,0935	0,0245
Varians	0,0053	0,0060	0,0050	0,0025	0,0003	0,0001	0,0001	0,0001	0,0001	0,0000
Skjevhet	22,6355	3,2981	15,9332	-44,9962	-0,6389	-0,5682	-0,5179	-0,4477	-0,5025	0,0273
Kurtose	1015,2735	43,1172	799,6608	2670,9030	17,4667	12,5600	17,1777	9,0135	7,3875	2,9052
Observasjoner	4649	4649	4649	4649	4649	4649	4649	4649	4649	4649

Når man skal predikere volatilitet ved hjelp av GARCH-modeller og maskinlæringsmodeller, er inkluderingen av daglige avkastninger en sentral del i analysen. Disse dataene tjener som et grunnlag for å forstå de underliggende dynamikkene i Bitcoin-markedet, og spiller en avgjørende rolle i modelleringen og prediksjonen av volatiliteten. Daglige avkastninger gir en grunnleggende forståelse på hvordan verdien av Bitcoin endrer seg fra dag til dag. Å forstå disse bevegelsene er kritiske for å modellere volatilitet, ettersom volatiliteten er et mål på risiko eller usikkerhet knyttet til prisvariasjoner over tid.

Det er også med på å avsløre mønstre i markedets oppførsel. Eksempelvis kan perioder med høyere volatilitet, som kan korrespondere med spesifikke hendelser eller markedsforhold som politiske endringer, regulatoriske nyheter eller påvirkning av andre markeder. Analyse av avkastningene kan også identifisere volatilitetsklustere som er perioder hvor store avkastninger følges av lignende store avkastninger. Det er et viktig grunnlag for blant annet GARCH-modellen da disse antar at volatilitet varierer over tid og er påvirket av tidligere hendelser.

Tabell 2 presenterer den deskriptive statistikken for daglige avkastninger for variablene i analysen. Den gjennomsnittlige daglige avkastningen varierer lite mellom variablene, men man legger spesielt merke til Bitcoin og Kabel TV som har den samme gjennomsnittlige avkastningen, og som også er høyest for hele utvalget. Disse skiller seg også ut når det kommer til standardavviket, som måler volatiliteten, som er det høyeste for hele utvalget på henholdsvis 0,0762 og 0,0777.

Skjevheten til Bitcoin er ekstremt høy (22,6355), noe som tyder på at det er flere små negative avkastninger, og noen store positive avkastninger. Dette mønsteret kan skyldes spekulativ handel og markedsdynamikk som ofte fører til store, brå prisendringer. Høy kurtose observeres hos flere av variablene, inkludert Bitcoin (1015), Kabel TV (799) og Olje (2671) noe som indikerer at fordeling av avkastningene har "fat tails". Dette betyr at det er flere ekstreme verdier enn i en normalfordeling, noe som reflekterer høy risiko for ekstreme markedsbevegelser. Den høye kurtoseverdien gjenspeiles i det store spriket mellom gjennomsnitt, minimum- og maksimumsverdier.

Bitcoin og olje skiller seg spesielt ut i denne statistikken. Bitcoin viser høy volatilitet, betydelig positiv skjevhet og ekstremt høy kurtose. Dette reflekterer et marked som er strekt preget av spekulasjon, hvor prisene kan svinge voldsomt, noe som er typisk for kryptomarkedet. For investorer innebærer dette både mulighet for høy avkastning og betydelig risiko for store tap. Videre viser olje også høy volatilitet og kurtose, men med en negativ skjevhet, noe som indikerer mange små positive avkastninger og noen store negative avkastninger. En mulig forklaring på dette kan være oljemarkedets følsomhet for geopolitiske hendelser, og endring i tilbud og etterspørsel. Det skal nevnes at den ekstreme kurtose- og skjevhetsverdien også kan skyldes et spesifikt datapunkt, nemlig 20. april 2020. Denne datoen huskes som dagen hvor prisen på en tønne med WTI olje stupte til under 0 USD (Kearney,

2020). Dette kunne blitt betraktet som en outlier i henhold til analysen, men for enkelthetens skyld har vi valgt å ta det med, da vi tenker at det vil ha minimalt å si for selve oppgaven.

4.3.1 Stasjonaritet

Tabell 3: Test for stasjonaritet

Variabel	ADF.test	P.verdi
BTC	-16,62	<0,01
VIX	-18,25	<0,01
KabelTV	-18,34	<0,01
Olje	-18,47	<0,01
XLE	-16,39	<0,01
SP500	-17,03	<0,01
DJ	-17,07	<0,01
Gull	-16,98	<0,01
Nasdaq	-16,62	<0,01
USD	-17,24	<0,01

Tabell 3 presenterer resultatene fra Augmented Dickey-Fuller (ADF) testen for stasjonaritet for variablene anvendt i oppgaven. ADF testen viser at testverdiene og tilhørende p-verdien for variablene. Testen er en statistisk metode som brukes for å avgjøre om tidsserien er stasjonær, det vil si om dens statistiske egenskaper som middelerverdi og varians forblir konstante over tid (Mushtaq, 2011).

For BTC viser ADF testverdien -16,62 og p-verdien <0,01. Det betyr at man kan med høy sikkerhet avvise nullhypotese om at BTC-tidsserien har en enhetsrot. Med andre ord er BTC-tidsserien stasjonær. Tilsvarende resultater for de andre variablene i tabellen viser lignende resultater.

Når det gjelder modellering av volatiliteten i BTC, er stasjonaritet et viktig aspekt. Dette er spesielt viktig når det blir gjennomført en volatilitetsanalyse med GARCH-modellene. Dette fordi GARCH er designet for å modellere og forutsi volatilitet ved å ta hensyn til at

volatiliteten ved å ta hensyn til at variansen i tidsserien kan endre seg over tid, men de forutsetter at tidsserien som helhet er stasjonær. Det gir stabile og forutsigbare resultater, som gjør det enklere å modellere og forutsi volatiliteten mer nøyaktig. GARCH krever også stasjonaritet for å kunne gi pålitelige resultater. Hvis tidsserien ikke er stasjonær, kan modellens antagelser brytes og dermed føre til misvisende resultater (Mushtaq, 2011).

4.3.2 Korrelasjonsanalyse

Korrelasjon i finansmarkedene defineres ofte som den statistiske sammenhengen mellom forskjellige finansielle aktiva. Stosic et al. (2018) diskuterer hvordan finansielle markeder er komplekse systemer som ha blitt studert ved bruk av korrelasjonsanalyser for få forstå den økonomiske dynamikken og for å kvantifisere investeringsrisiko. Det bemerkes i artikkelen at det finansielle eiendeler både direkte og indirekte interagerer med hverandre, men at det disse interaksjonene ofte er ukjent.

I Stosic et al. (2018) analyse av kryptomarkedet, brukes korrelasjonsmatriser til å undersøke prisendringer blant forskjellige kryptovalutaer. Det oppdages at korreleasjonsmatrisen viser strukturer og grupperinger av kryptovalutaer som ikke er til stede i delkorrelasjoner. Disse funnene antyder at korrelasjoner i kryptomarkedet kan være forskjellige fra andre finansmarkeder. Dermed er å analysere for å se hvordan en korreleasjonsmatrise med de utvalgte variablene følger hverandre.

Tabell 4: Korrelasjonsmatrise

Variabel	BTC	VIX	KabelTV	Olje	XLE	SP500	DJ	Gull	Nasdaq	USD
BTC	1,000	0,163	0,999	0,031	-0,210	0,872	0,842	0,610	0,903	0,420
VIX		1,000	0,163	-0,073	-0,460	0,100	0,084	0,400	0,160	0,063
KabelTV			1,000	0,032	-0,210	0,872	0,842	0,610	0,900	0,422
Olje				1,000	0,610	-0,170	-0,206	0,299	-0,180	-0,526
XLE					1,000	-0,160	-0,170	-0,190	-0,260	-0,110
SP500						1,000	0,992	0,518	0,990	0,728
DJ							1,000	0,580	0,976	0,740
Gull								1,000	0,570	0,066
Nasdaq									1,000	0,668
USD										1,000

Tabell 4 avdekker korrelasjonene mellom Bitcoin-priser og de utvalgte finansielle og makroøkonomiske variablene, og belyser hvordan Bitcoin samspiller med større økonomiske trender. Disse funnene er essensielle for å forstå Bitcoins rolle i det globale finansmarkedet.

Korrelasjonsmatrisen viser at Bitcoin har en nesten perfekt positiv korrelasjon med Kabel TV på 0,999, noe som indikerer at bevegelsene i Bitcoin-prisen er sterkt synkronisert med denne nyhetsindeksen. Dette antyder at faktorer som påvirker Kabel TV også er betydelige drivere for Bitcoins pris, hvor nyheter og spekulasjon spiller en kritisk rolle. Bitcoin-markedet kan være følsomt for nyheter, og omfattende mediedekning kan øke investorenes interesse og aktivitet, noe som forsterker prisbevegelsene. Dette kan også innebære tilgang til informasjon på sosiale medier. Mediaeffekten påvirker investorers følelser og handlinger, og rask tilgang til informasjon kan føre til synkroniserte bevegelser. Psykologien kan påvirkes av den generelle markedstemningen i nyhetene, og dermed påvirke kjøps- og salgsbeslutninger.

Videre viser Bitcoin også en sterk positiv korrelasjon på 0,903 med Nasdaq, noe som understreker dens sterke bånd til teknologisektoren. Når det gjelder de andre aksjeindeksene, viser Bitcoin en betydelig positiv korrelasjon på 0,872 med S&P 500 og en korrelasjon på 0,842 med Dow Jones, noe som indikerer at Bitcoin ofte beveger seg i takt med de større markedene. Gull viser også en korrelasjon på 0,61, noe som understreker at det kan betraktes som en trygg havn i tider med høy inflasjon.

Det er en også en positiv korrelasjon på 0,42 mellom Bitcoin og USD, noe som indikerer et forhold der Bitcoin kan stige når USD stiger. Dette kan reflektere kapitalflyten mellom tradisjonelle valutaer og Bitcoin under visse økonomiske forhold. Bitcoin har en svakt positiv korrelasjon med oljepriser på 0,031, og en større negativ korrelasjon på -0,21 med XLE, noe som antyder at Bitcoins ytelse er relativt uavhengig av tradisjonelle energimarkeder.

Den positive korrelasjonen med VIX på 0,163 indikerer at selv om Bitcoin viser volatilitet, speiler den nødvendigvis bredere markedsoppfatninger av risiko så tett som andre tradisjonelle risikoaktiva. Disse observasjonene understreker Bitcoins unike stilling innen finansmarkedet, der den opererer uavhengig av flere konvensjonelle markedsdrivere.

4.4 Modellering og analyse

I denne delen vil det bli gjennomgått hvordan ulike modellerings- og analysemetoder som er anvendt i oppgaven. Først blir det presentert en detaljert beskrivelse av maskinlæringsmodellene og hvordan disse er implementert og evaluert. Videre vil det bli sett

på hvordan GARCH-modellene er utført. Til slutt vil det vil det forklares hvordan VaR og forventet tap beregnes og analyseres med vekt på vurderingen av risikostyring.

4.4.1 Maskinlæringsmodellene

En vanlig praksis i maskinlæring er å dele datasettet inn i en 80/20 splitt for trening og testdata. Dette innebærer at modellen trenes på de første 80% av observasjonene, og deretter testes på de siste 20% av observasjonene. Dette er vanlig praksis da det tillater modellen å lære seg generelle mønstre og gi en pålitelig vurdering av hvordan modellen presterer på nye usette data (Geron, 2022, s. 31). Det skal nevnes at selv om dette er vanlig praksis betyr det ikke at det nødvendigvis er beste praksis, og det finnes flere ulike måter å splitte et datasett. I denne avhandlingen bruker vi en 80/20 splitt både for enkelthetens skyld, men også fordi vi har et relativt stort datasett slik at treningssettet har tilstrekkelig med data til å gjenkjenne mønster samtidig testsettet forblir pålitelig.

Videre er det brukt backward selection som er en av hovedtilnærmingene til regresjon. I statistikk er backward selection en metode for å tilpasse regresjonsmodeller der valget av forklaringsvariabler utføres gjennom automatisk prosedyre. Dette innebærer å starte med en modell som inkluderer samtlige variabler, for så å evaluere variablenes betydning etter et valgt kriterium for modelltilpasning, i dette tilfellet prosentvis økning i MSE. De variablene som bidrar minst vil så bli fjernet før prosessen gjentas til ingen flere variabler kan fjernes uten at det fører til en statistisk signifikant forverring av modellens tilpasning (Halinski & Feldt, 1970).

Målet med denne seleksjonen er å redusere antall forklaringsvariabler uten noen markant reduksjon i prestasjonen til modellen. Dette gjøres ettersom flere variabler ikke vil bidra til økt prediksjonsnøyaktighet, men heller kun med støy som vil redusere prediksjonsevnen. I sin essens hjelper seleksjonen til å bestemme nivået av betydning for hver forklaringsvariabel. Den bidrar også til å vurdere effektene når de andre forklaringsvariablene er statistisk eliminert.

Random Forest (RF)

Etter gjennomført backward selection ble det også utført hyperparametertuning på RF-modellen. Den har flere hyperparametere som må settes som for eksempel antall observasjoner trukket for hvert tre og om de trekkes med eller uten erstatning, antall variabler trukket tilfeldig for hver deling, antall prøver som en nspode må inneholde og antall trær ble

justert. Det er velkjent at i de fleste tilfeller fungerer RF bra med standardverdiene for hyperparameterne som er spesifisert i programvarene. Likevel kan justeringen av hyperparametertuningen forbedre ytelsen til RF (Probst et al., 2019).

For Random Forest-modellen er antall trær ett sentralt parameter. Dette angir hvor mange beslutningstrær modellen skal bygges på. Flere trær kan øke modellens nøyaktighet ved å stabilisere prediksjonene, men dette vil også øke beregningstiden (Akyildirim., et al, 2021). I denne avhandlingen er antall trær satt til 1000, noe som balanserer mellom høy prediksjonsnøyaktighet og akseptabel beregningstid.

Support Vector Machine (SVM)

SVM er en metode som bruker forskjellige funksjoner for å transformere datasettet slik at det blir lineært separerbart. Valget av funksjon er avgjørende for modellens prestasjon, dog kan det variere fra anvendelse til anvendelse. (Akyildirim., et al, 2021). Vanlige funksjoner inkluderer "lineær", "polynom", "radiell", og "sigmoid". I denne avhandlingen er funksjonen satt til "radiell", som ofte fungerer godt for ikke-lineære relasjoner.

Nevrale Nettverk (NN)

To viktige parametere i oppsettet av et nevralt nettverk er "maxit" og "hidden". "Maxit" spesifiserer maksimalt antall iterasjoner under treningen, som påvirker modellens evne til å konvergere til en optimal løsning. "Hidden" definerer strukturen på de skjulte lagene i nettverket (Ripley, 1996; Venables, 2002). I denne avhandlingen er "maxit" satt til 100 for å gi tilstrekkelig treningsiterasjoner, og hidden lags er satt til 1 og 2 for å teste en enkel nettverksstruktur.

Prestasjonsmål

For å vurdere effektiviteten av de beskrevne modellene, beregnes det fire metrikker: Mean squared error (MSE), Root Mean Squared Error (RMSE), Mean Absolute Percentage Error (MAPE), Normalized Mean Squared Error (NMSE), og Directional Accuracy (DA). RMSE, MAPE, og NMSE er vanlig brukte i regresjonsoppgaver, der lavere verdier indikerer en bedre modelltilpasning. Både NMSE og MAPE uttrykkes som prosenter, som reflekterer gjennomsnittlig avvik i prosent. DA vurderer modellens evne til å forutsi retningen på endringer og oppgis også i prosent, der høyere verdier indikerer en bedre prediksjon av retning. Denne metrikken er spesielt viktig i finansiell prognostisering og

investeringsbeslutninger på grunn av fokuset på å forutsi retningen av volatilitet i kryptovaluta (Wang et al., 2023).

Ytelsesmålingene er definert som følger:

MSE: Måler gjennomsnittet av kvadrerte feil mellom predikerte og faktiske verdier. En lav MSE indikerer at modellen har god tilpasning til de observerte dataene, etter som det innebærer små avvik mellom predikerte og faktiske verdier (Wang et al., 2023).

Formelen er gitt ved:

$$MSE = \frac{1}{n} \cdot \sum_{j=1}^n (y_j - \hat{y}_j)^2 \quad (4)$$

Her er MSE gjennomsnittet av kvadrerte feil, gitt ved n som er antall observasjoner i datasettet, y_j er den faktiske verdien av i i observasjonen og \hat{y}_j er den predikerte eller estimerte verdien av i i observasjonen. Man beregner avviket for hver observasjon ved å trekke den estimerte verdien fra den faktiske verdien, kvadrerer hvert av avvikene for å gjøre dem positive og for å legge mer vekt på feil. Deretter summerer man avvikene og deler summen av de kvadrerte avvikene med antall observasjoner (n) for å finne gjennomsnittet.

RMSE: Måler gjennomsnittlig størrelse på feilen, noe som gir en måte å kvantifisere avviket mellom de predikerte og faktiske verdiene (Wang et al., 2023).

Formelen er gitt ved:

$$RMSE = \sqrt{MSE} \quad (5)$$

RMSE er enkelt forklart roten av MSE. Ved å ta roten konverterer man målet tilbake til de opprinnelige enhetene til responsvariabelen, noe som gjør det enklere å tolke størrelsene på feilene til de faktiske verdiene. Det er nyttig fordi det gir en intuitiv forståelse av gjennomsnittlig feil og at RMSE er sensitiv for større feil, på grunn av kvadreringen av avvikene, noe som gjør det til et nyttig ytelsesmål for å vurdere nøyaktigheten av en modell i prediktive analyser.

MAPE: Beregner gjennomsnittlig absolutt prosentvis forskjell mellom de faktiske og predikerte verdiene, og gir en indikasjon på relativ feil (Wang et al., 2023).

Formelen er gitt ved:

$$MAPE = \frac{1}{n} \sum_{t=1}^n \frac{y_t - \hat{y}_t}{y_t} \quad (6)$$

MAPE beregner ved å ta den absolutte verdien av differansen mellom den faktiske verdien (\hat{y}_t) og den predikerte verdien (y) for hver observasjon. Dette fjerner eventuelle negative tegn og vektlegger alle feil likt, uavhengig av retning. Deretter divideres det absolutte avviket med den faktiske verdien for å beregne den relative feilen for hver observasjon, og uttrykkes som en prosent. Videre summeres alle disse individuelle prosentvise feilene over alle observasjoner. Så deles summen av de prosentvise feilene med antall observasjoner (n) for å beregne gjennomsnittet. Dette gir til slutt et mål på nøyaktighet på hvor god modellen er til å forutsi resultatene.

NMSE: måler gjennomsnittlig kvadrert relativ feil mellom de forutsagte verdiene og de faktiske verdiene (Wang et al., 2023).

Formelen er gitt ved:

$$NMSE = \frac{1}{n} \cdot \sum_{t=1}^n \left(\frac{y_t - \hat{y}_t}{y_t} \right)^2 \quad (7)$$

NMSE er et relativt mål som gjør den enklere å sammenligne feil på tvers av forskjellige datasett eller modeller. Dette skyldes at ved å normalisere den gjennomsnittlige kvadrerte verdien av den faktiske variabelen, tar man hensyn til størrelse på de faktiske verdiene. Eksempelvis indikerer en NMSE på 0 perfekt prediksjon uten feil, mens verdier nærmere 1 indikerer større feil i forhold til variabiliteten av de faktiske dataene.

DA: Måler modellens evne til å forutsi endringsretningen i volatiliteten (Wang et al., 2023).

Formelen er gitt ved:

$$DA = \frac{\text{Antall riktige prediksjoner}}{\text{Totalt antall prediksjoner}} \cdot 100\% \quad (8)$$

Av formelen vises det enkelt at DA gir en prosentandel som reflekterer andelen av tiden modellen har korrekt i å forutsi retningen av volatilitet. Da ønsker man naturligvis en høyest mulig DA.

Gjennom denne prosessen er det utviklet en robust tilnærming for å analysere og forutsi volatiliteten i kryptovalutamarkedet, og demonstrert viktigheten av både intern, finansiell, og

makroøkonomisk informasjon i denne sammenhengen samt presentert hvordan man måler effektiviteten av volatilitetspredikering gjennom ulike ytelsesmålinger.

4.4.2 GARCH-modellene

I finansiell modellering er en av hovedutfordringene å velge en passende modell fra en rekke muligheter. Det samme gjelder GARCH-modeller. Valget av en optimal modell i anvendelse av analysen er helt avgjørende. Hele prosessen kan ikke automatiseres siden kontekst er avgjørende og aldri finnes en perfekt eller unik modell (Miah & Rahman, 2016).

Modellseleksjonskriteriene gir nyttig informasjon i denne sammenheng og man kan vurdere om en tilpasset modell tilbyr optimal balanse og tilpasningsdyktighet. Ideelt sett vil et kriterium være å identifisere modeller som enten er for enkle til å håndtere datasettet eller unødvendig komplekse. De mest vanlige modellseleksjonskriteriene er Akaike Information Criterion (AIC) og Bayesian Information Criterion (BIC) (Miah & Rahman., 2016).

$$\mathbf{AIC: } T \cdot \ln(\text{residual sum of squares}) + 2n \quad (9)$$

$$\mathbf{BIC: } T \cdot \ln(\text{residual sum of squares}) + n \ln(T) \quad (10)$$

Hvor T er antall brukbare observasjoner og n er antall parametere som skal estimeres. I praksis velges modellen med den minste AIC og BIC som den beste modellen (Miah & Rahman., 2016). Modellene for sGARCH og TGARCH er valgt ut ifra modellene med lavest AIC og BIC.

Alberg et al. (2008) viser til at et problem som kan oppstå ved bruk av GARCH-modeller er at de ikke alltid fullt ut omfavner egenskapen med *fat tails*, det vil si større sannsynlighet for utfall langt overgjennomsnittet enn hva normalfordelingen tilsier som ofte sees i finansielle tidsserier med høy frekvens. For å overkomme ulempen bruker Bollerslev (1986), Baillie & Bollerslev, (1989) og Laurent et al. (2002) brukt students t-fordelingen. Denne fordelingen fanger også opp skjevhet og en asymmetrisk stabil tetthet i likhet med normalfordelingen. For å forbedre tilpasningen av de ulike GARCH-modellene er det brukt student t-fordeling for å få en best mulig tilpasset modell til Bitcoin. Dette er fordi t-fordelingen har bedre tilpasning i data som har ekstreme verdier og fat tails som observert i tabell 2. Dette gjør at modellen bedre kan fange opp og forutsi store svingninger i volatiliteten.

I likhet med Wang et al. (2023) benytter vi en utvidet vindusstrategi for GARCH-modelleringen. Dette innebærer kontinuerlig inkludering av nye datapunkter i treningssettet, som deretter danner grunnlaget for prediksjonene i testsettet (Shin, 2017). Denne tilnærmingen er tatt i bruk da GARCH-modeller, i motsetning til maskinlæringsmodeller, tradisjonelt krever kontinuerlig oppdatering med nye data for å reflektere de nyeste markedsf forholdene og gi mer presise volatilitetsprediksjoner. Maskinlæringsmodeller har en iboende fleksibilitet og evne til å lære seg komplekse mønstre fra store datasett, noe som gjør at de ikke trenger å benytte seg av en slik tilnærming.

For å kunne sammenligne resultatene fra maskinlæringsmodellene mot mer tradisjonelle modeller som GARCH vil disse også bli målt etter ytelsesmålingene MSE, RMSE, MAPE, NMSE og DA.

4.4.3 Value at risk

VaR kan defineres som det maksimale forventede tapet av en eiendel ved et forhåndsbestemt signifikansnivå og en bestemt beholdningsperiode (Orhan & Köksal, 2012).

Tidligere beregninger av VaR brukte en varians-kovarians tilnærming som antok normalfordeling. En svakhet med denne tilnærmingen er at den forutsetter normalfordelte avkastninger, noe som er utfordrende da et høyt volatile markeder har *fat tails*. En løsning for å omgå denne utfordringen var å bruke den historiske simuleringstilnærmingen. Denne tilnærmingen registrerer og simuleres av tidligere avkastninger for å estimere fremtidige avkastninger med en underforstått antakelse om at historien må gjenta seg selv. Det har at det er blitt inkludert forskjellige volatiliteter på forskjellige tidspunkt. Denne tilnærmingen trengte en metode for å beregne VaR slik at den kunne håndtere slik klustering av volatilitet (Orhan & Köksal, 2012).

Spierdijk (2016) Diskuterer betydningen av konfidensintervaller i beregningen av VaR ved å vektlegge viktigheten av å kvantifisere usikkerheten knyttet til de estimerte parametere. Konfidensintervaller gir et mål på nøyaktigheten av VaR-estimatet ved å spesifisere et område der det sanne estimatet sannsynligvis vil falle. For eksempel, et estimat på VaR på \$100 millioner med et 95% konfidensintervall på [\$95, \$105] er mer presist enn et punkttestimat på \$100 millioner med et 95% konfidensintervall på [\$50, \$150]. Dette viser at konfidensintervaller gir viktig informasjon om påliteligheten av estimatene. Videre påpekes det at brede konfidensintervaller krever omhu ved beslutningstaking basert på VaR-estimer,

spesielt i risikostyringssammenhenger der ekstra kapital kan være nødvendig for å dekke den underliggende usikkerheten.

For et gitt risikonivå er den viktigste praktiske utfordringen å estimere det nøyaktig for statistiske modeller og validere estimatene ved å sjekke realiserte tap. Derfor er det gjennomført testing og backtesting av både 95% og 99% konfidensintervaller. Backtestingen innebærer å teste modellens prediksjoner mot faktiske historiske data for å vurdere dens nøyaktighet og pålitelighet. I kontekst av denne avhandlingen er dette et avgjørende steg da VaR estimatene er basert på prediksjoner og dermed krever en høy grad med nøyaktighet for å kunne forutsi fremtidige tap. Dette betyr at disse resultatene er med 95% sannsynlighet for det faktiske tapet ikke vil overstige VaR-verdien i perioden. Med andre ord er det 5% sjanse for at tapet vil være større enn den estimerte VaR-verdien (Kratz et al., 2018). Dette er med på å gi en indikasjon på potensielt tap under normale markedforhold. Det samme gjelder for konfidensintervall på 99%. På en annen side er dette nivået høyere og tar hensyn til mer ekstreme tapsscenarioer og er derfor ofte større enn en VaR estimert med 95% konfidensintervall.

4.4.4 Forventet tap

Acerbi et al. (2001) definerer Forventet tap (Expected shortfall), heretter "ES", som «Den forventede verdien av tapet i porteføljen i de 5% verste tilfellene på 7 dager». Det kan sies å være et risikomål som blir foretrukket når VaR ikke klarer å skille mellom ulike risikonivåer i ulike porteføljer. Det betyr at ES fokuserer på de mest ekstreme tapssituasjonene og tar hensyn til både sannsynlighet og størrelsen på tapene.

I motsetning til VaR, som bare gir en indikasjon på det maksimale tapet innenfor en bestemt sannsynlighetsgrense, tar ES også for seg fordelingen av de verste tapene. Den tar derfor et mer nøyaktig hensyn til risikoen knyttet til ekstreme hendelser, og tar med informasjonen om både hyppigheten og størrelsen på tapene.

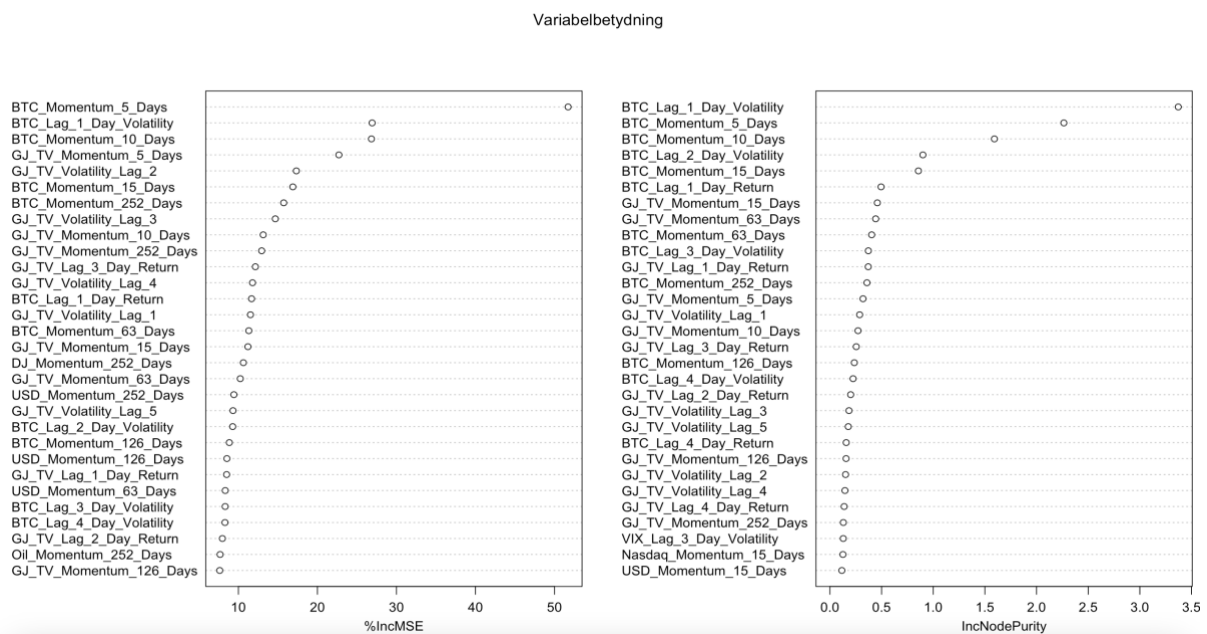
5 Empiriske resultater

I denne seksjonen gjennomgås resultatene av analysen. Først fokuseres det på variabelbetydning og identifiseres hvilke variabler som har størst innvirkning på prediksjonen av volatilitet. Deretter presenteres resultatene for volatilitetsprediksjonen, og de ulike

maskinlæringsmetodenes prediksjonsevne sammenlignes med de tradisjonelle GARCH-modellene. Til slutt analyseres resultatene fra VaR-analysen for å gi en praktisk forståelse av oppgavens anvendelse

5.1 Variabelbetydning

For å innlede de empiriske resultatene for oppgaven på volatilitetsprediksjon i Bitcoin-markedet, er det viktig å fremheve den strategiske utvelgelsen av forklarende variabler og deres betydning for modelleringen. Variablene som er vist i figur 1 reflekterer de mest innflytelsesrike faktorene identifisert gjennom en prosess av backward selection og hyperparameter tuning. Disse metodene sikrer at kun de mest relevante og statistisk signifikante variablene inkluderes i de endelige prediktive modellene.



Figur 1: Variabelbetydning for modellene

Fra figurene observeres det at grafer som illustrerer viktigheten av hver variabel i modellen, representert gjennom «%IncMSE» og «IncNodePurity». Disse målene gir innsikt i hvor mye hver variabel bidrar til å øke modellens nøyaktighet. %IncMSE måler hvor mye modellens prediksjonsfeil øker når en gitt variabel blir utelatt. En høy verdi indikerer at variabelen er mer betydningsfull. Eksempelvis varianter av «BTC_momentum» over forskjellige tidsperioder og «BTC_Lag_1_Day Volatilty» viser seg å være viktig for å predikere volatilitet. IncNodePurity er et mål som er basert på hvor mye hver variabel bidrar til å redusere usikkerheten i modellens beslutninger, eller hvor mye den renser nodene i RF modellen. Variabler som viser

høy node renhet indikerer at de hjelper med å gjøre modellens beslutninger mer definitive og mindre varierte.


Fra Figur 1 er det visse variabler, som for eksempel «BTC Momentum_5_Days», «BTC Lag_1_Day Volatility», og «BTC Momentum_252_Days», har en høy betydning i begge målene, noe som indikerer deres kritiske rolle i å forutse markedsbevegelser. Variabler relatert til volatilitet og momentum i både Bitcoin, Kabel TV (GJ_TV_volatility) og volatilitetsindeksen «VIX» viser seg også å være vesentlige for å forstå de komplekse markedsdynamikkene.

Figuren viser at de interne variablene direkte knyttet til Bitcoin er de viktigste variablene for denne analysen, noe som er forventet. På en annen side observeres det også at makroøkonomiske variabler, spesielt Kabel TV, også vesentlig bidrar til å øke modellens nøyaktighet. Dette indikerer at makroøkonomiske variabler i stor grad kan brukes til å predikere volatilitet i Bitcoin i likhet med de interne variablene.

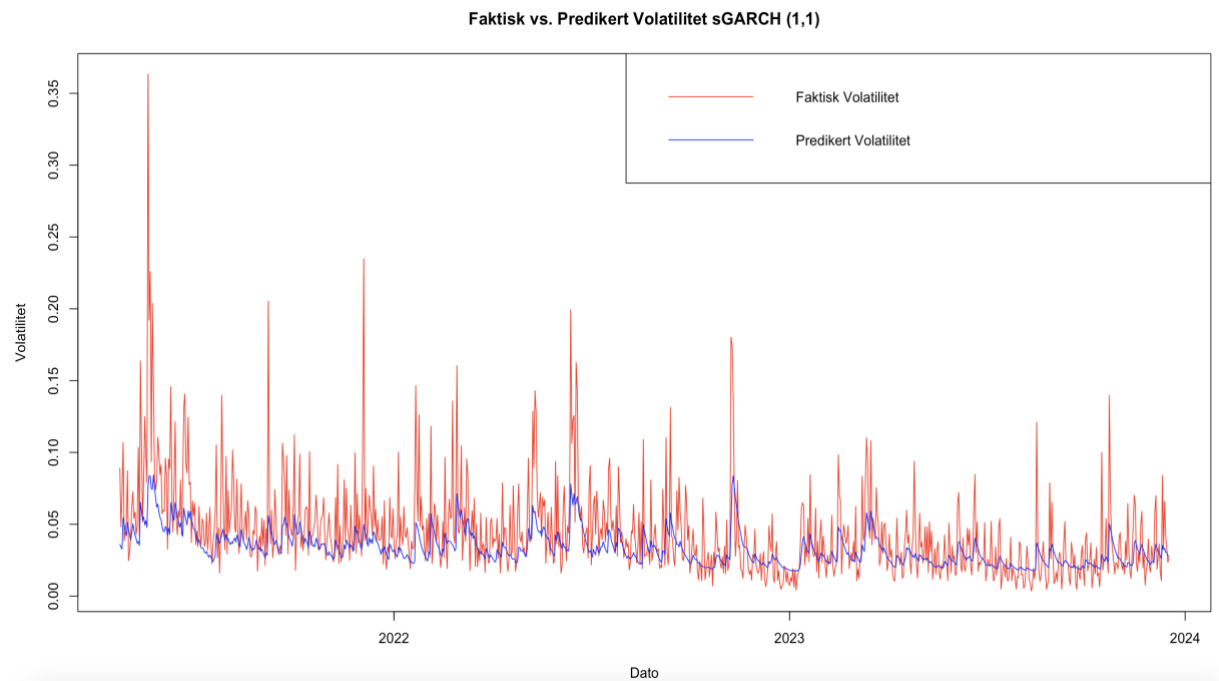
Inkluderingen av disse variablene i modellene støtter en mer grundig og nøyaktig analyse av volatiliteten i Bitcoin. Ved å fokusere på de mest innflytelsesrike variablene sikrer man at modellene ikke bare er robuste, men også relevante for de spesifikke egenskapene og oppførelsen til markedet. Det legger grunnlaget for presise og pålitelige prediksjoner, som er avgjørende for beslutningstaking i et volatilt og uforutsigbart marked som Bitcoin-markedet.

5.2 Modellenes prediktive evne


Den prediktive evnen for modellene gir en grundig vurdering av modellenes evne til å predikere volatiliteten i Bitcoin. Et av formålene med denne avhandlingen var å undersøke om maskinlæringsmodeller er bedre rustet til å predikere volatilitet i et høyt volatilt marked enn tradisjonelle GARCH-modeller. I forbindelse med dette blir det tatt i bruk en rekke ytelsesmål for å vurdere modellene. I en tidligere studie av Wang et al. (2023) viste det seg at maskinlæringsmodellenes evne til å predikere volatilitet i kryptomarkedet var overlegne i sammenligning med GARCH modeller. Gjennom analysen og evaluering blir modellenes kapasitet til å forutse volatilitet og deres effektivitet i risikovurdering nøye vurdert. Dette skaper et robust grunnlag for å forstå hvordan ulike modeller presterer under de dynamiske og ofte utfordrende forholdene som kjennetegner Bitcoin-markedet.



Figur 2: Faktisk VS. Predikert volatilitet – Random Forest



Figur 3: Faktisk VS. Predikert volatilitet – sGARCH (1,1)



Figur 4: Faktisk VS. Predikert volatilitet T-GARCH (1,1)

5.2.1 RF og GARCH

Ytelsesmålene fra modellenes prediksjon er presentert i tabell 5. Det blir lagt merke til at i at RF modellen viser til de beste resultatene når det kommer til MSE, RMSE og NMSE. Spesielt er MSE og RMSE betydelige for å evaluere modeller da de gir direkte kvantitative målinger av modellens feil.

På grunn av disse resultatene er det valgt å sammenligne RF og GARCH, da RF er den metoden som gir de beste resultatene for maskinlæring. Ett mål for oppgaven var å sammenligne hvordan GARCH- og maskinlæringsmetoder predikerer volatilitet best i BTC. Ved å inkludere RF som en representant for maskinlæringsmetoder, kan man bedre forstå hvilken tilnærming som er mest effektiv for prediksjon av volatilitet i Bitcoin.

Tabell 5: Ytelsesmålinger til modellene

Ytelsesmål	RF	SVM	NN	Kombinert	sGARCH	TGARCH
MSE	0,00059	0,00091	0,00073	0,00061	0,00076	0,00072
RMSE	0,0244	0,0302	0,0271	0,0246	0,0275	0,0268
MAPE*	58,74	76,24	58,13	58,13	40,90	41,04
NMSE	0,57	0,87	0,69	0,58	0,72	0,69
DA*	49,48	49,38	45,97	48,76	70,66	70,86

Ytelseevalueringen for RF-modellen viser en MSE-verdi på 0,00059 og en RMSE-verdi på 0,0244. Begge disse målingene indikerer høy nøyaktighet i modellens prediksjonsevner. MSE viser at RF-modellen i gjennomsnitt produserer relativt små feil. Dette indikerer at modellen er godt tilpasset treningsdataen, uten å produsere store individuelle feil. Den lave RMSE-verdien demonstrer at de typiske prediksjonsfeilene er minimale.

Totalt sett kan man konkludere med at RF-modellen er den modellen som er best rustet til predikere volatilitet for Bitcoin. RF-modellen presterer best basert på flere av ytelsesmålene, men for DA og MAPE er det GARCH-modellene som presterer best. I likhet med Wang et al. (2023) stiller vi oss kritisk til å bruke DA som et ytelsesmål for GARCH modellene, ettersom det brukes en utvidende vindusstrategi for prediksjonen i GARCH-modellene. Etter dette gjenstår kun MAPE som ytelsesmål hvor RF ikke viser sin overlegenhet. En MAPE verdi på 58,74% for RF-modellen indikerer et relativt høyt avvik mellom predikerte verdier og faktisk verdier, spesielt sammenlignet med GARCH-modellene med henholdsvis 40,9 og 41,04%.

En mulig forklaring på den høye MAPE-verdien er hvordan man behandler verdier nær null. MAPE beregningen er vært sensitiv når det kommer til nær null og null-verdier. Hvis de faktiske verdiene er svært lave, vil eventuelle feil i prediksjonene bli forstørret i MAPE beregningen.


Figur 2, 3 og 4 viser predikerte volatilitetsverdier og faktiske volatilitetsverdier for henholdsvis RF, SGARCH og TGARCH-modellene. Visuelt fra disse plottene kan man se at

RF-modellen gjør en bedre jobb med å fange periodene med høy volatilitet sammenlignet med GARCH-modellene.

Imidlertid observeres det at GARCH modellene klarer å fange opp volatilitetstrender på en mer effektiv måte, samt at de klarer å predikere lavere volatilitetsnivåer mer nøyaktig enn RF-modellen. Dette er ikke overraskende ettersom RF er kjent for å gjøre gode prediksjoner på typiske utfall, men strever mer med prediksjoner av store og markante utfall (Yuan & Leirvik, 2021). Sistnevnte er trolig en forklaring på hvorfor GARCH-modellene gir en bedre MAPE ytelse sammenlignet med RF-modellen.

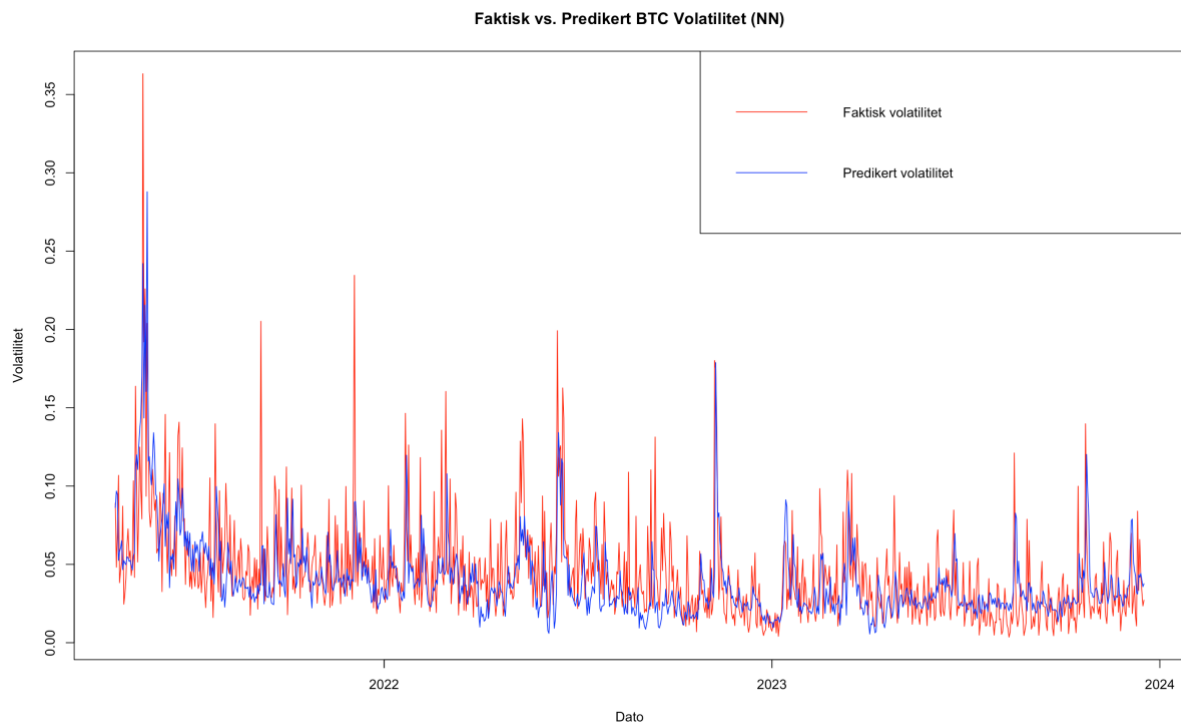
5.2.2 SVM, NN og kombinert modell

SVM-modellen viser en moderat tilpasning til dataen, reflektert i MSE og RMSE verdiene, som er høyere enn de for NN og den kombinerte modellen. Dette indikerer at selv om modellen klarer å fange opp noen volatilitetsmønstre, er nøyaktigheten begrenset, spesielt i perioder med høye volatilitetsutsving. Den høye MAPE-verdien på 76,24% bekrefter at modellens prediksjoner ofte avviker fra de faktiske observasjonene. Dette er nok et bevis på at denne verdien forklares med at modellen sliter med å predikere verdier nært null. Videre viser modellens høye NMSE verdi at modellen har begrenset evne til å normalisere feil, samt at DA-verdien er relativt lav, noe som viser til modellens begrensede evne til å forutsi retningsforandringene i volatilitetsmønsteret.




Figur 5: Faktisk VS. Predikert volatilitet – Support vector machine

Sammenlignet med SVM viser NN-modellen en sterk tilpasning til dataen, gjenspeilet i lavere MSE og RMSE verdier. Den lavere MAPE-verdien på 52,56% tyder på at NN-modellen har en overlegen evne til å estimere de faktiske verdiene sammenlignet med SVM, selv om den fortsatt har utfordringer med å predikere ekstreme volatilitetstopper nøyaktig. NMSE og DA indikerer at selv om NN er mer nøyaktig i sine estimeringer enn SVM, sliter den fortsatt med å forutsi de korrekte retningene i volatilitetsmønsteret.



Figur 6: Faktisk VS. Predikert volatilitet – Neural Network

Den kombinerte modellen fremstår som den mest effektive i å håndtere volatilitetsprediksjoner. Denne modellen har de laveste verdiene for MSE og RMSE, som indikerer en høy grad av tilpasning til de faktiske volatilitetsdataene. Selv om MAPE-verdien er høyere enn for NN, er dens NMSE den laveste blant de tre modellene, noe som understreker dens evne til å jevne ut feil mer effektivt. Likevel, med en DA som nærmer seg det tilfeldige utvalget (nær 50%), er det tydelig at også den kombinerte modellen står overfor utfordringer med å nøyaktig forutsi markedets retning.



Figur 7: Faktisk VS. Predikert volatilitet – Kombinert modell

Gjennom den grafiske fremstillingen av modellenes prediksjoner mot de faktiske volatilitetsdataene viser SVM og NN betydelige avvik, spesielt i perioder med markante utslag i faktisk volatilitet, mens den kombinerte modellen tilbyr en jevnere og tettere korrespondanse med de faktiske verdiene. Samlet sett indikerer analysen at mens ingen av modellene perfekt forutsier Bitcoin-volatilitet, tilbyr den kombinerte modellen en mer robust tilnærming ved å balansere svakhetene til de enkelte modellene.

5.2.3 Oppsummering av modellenes prediktive evne

RF-modellen viser overlegen ytelse på flere nøkkelindikatorer for modellnøyaktighet, spesielt MSE og RMSE, som er kritiske for å evaluere prediktiv effektivitet i kvantitative modeller. En MSE på 0,00059 og en RMSE på 0,0244 indikerer at RF-modellen gjennomsnittlig produserer meget små kvadrerte og skala-tro feil, noe som tyder på en sterk modelltilpasning til de historiske dataene. Til tross for sin sterke generelle ytelse, viser RF-modellen høyere feil i MAPE (58,74%) sammenlignet med GARCH-modellene, som registrerer MAPE-verdier på henholdsvis 40,9% og 41,04%. Dette kan skyldes RF-modellens følsomhet for hvordan feil håndteres når de faktiske verdiene er nær null, et kjent problem i MAPE-beregninger.

GARCH-modeller, både standard og Threshold GARCH, viser lavere MAPE, noe som indikerer bedre prediktiv nøyaktighet i lavere volatilitetsperioder. Dette understreker GARCH-

modellenes styrke i å modellere og forutsi volatilitetstrender over tid, selv om de kan ha vanskeligheter med å håndtere store, uforutsette utslag. Visuelle representasjoner fra figurene støtter dette, hvor GARCH-modellene demonstrerer evnen til å følge mer jevne volatilitetsmønstre sammenlignet med de mer sprikende prediksjonene fra RF-modellen.

SVM og NN-modellene, samt den kombinerte modellen, varierer i deres tilpasning og prediktiv ytelse. SVM, mens den fanger opp visse volatilitetsmønstre, viser generelt høyere MSE og RMSE og en høy MAPE på 76,24%, noe som indikerer signifikante avvik fra de faktiske verdiene, spesielt i perioder med lav volatilitet hvor modellen straffer hardt for små absolutte feil.

NN-modellen forbedrer seg sammenlignet SVM i form av lavere MSE og RMSE, og en mer moderat MAPE på 52,56%. Dette tyder på at mens NN-modellen har bedre overordnet tilpasning enn SVM, sliter den fortsatt med å nøyaktig fange de største volatilitetstopper. Den kombinerte modellen viser den laveste MSE og RMSE av disse tre, noe som reflekterer den beste tilpasningsevnen til de faktiske volatilitetsdataene, men også denne modellen strever med høye MAPE-verdier og begrensede evner til å forutsi markedets retning, som indikert av en DA-verdi nær 50%.

En viktig observasjon er at alle maskinlæringsmodellene viser DA-verdier nær 50%. Dette illustrerer en fundamental begrensning i disse modellenes evne til å forutsi retningen på volatilitetsbevegelser, noe som er avgjørende i finansielle markeder. Denne utfordringen er ikke unik for denne studien. I studien av Wang et al. (2023), observeres lignende mønstre hvor deres modeller også rapporterte DA-verdier omkring 50%. Dette fremhever en systemisk begrensning i nåværende maskinlæringsmodellens evne til å tolke og reagere på volatilitetsdynamikk i Bitcoinmarkedet. Denne konsistente svakheten peker på en mulig grunnleggende utfordring i bruken av maskinlæring til dette formålet, eller en indikasjon på at modellene kanskje trenger ytterligere justering eller integrasjon av ytterligere variabler for å bedre fange opp og forstå markedsdynamikken i markedet.

5.3 Praktisk tilnærming

Bruken av Value at Risk (VaR) i denne studien er sentral for å forstå og sammenligne prediksjonseffektiviteten til GARCH- og maskinlæringsmodeller for Bitcoin-volatilitet. VaR er en veletablert risikomåling som kvantifiserer det potensielle tapet av en portefølje over en gitt tidsperiode, med et spesifisert konfidensnivå. I finansnæringen er VaR et standardverktøy

for risikostyring, og anvendelsen i denne oppgaven gir en praktisk dimensjon som direkte knytter forskningsresultatene til reelle anvendelser innen risikostyring. Ved å bruke VaR kan man objektivt sammenligne nøyaktigheten og påliteligheten til GARCH- og maskinlæringsmodeller ved å evaluere deres evne til å estimere fremtidig risiko.

Inkluderingen av VaR er ikke bare en teoretisk forankring, men også en praktisk tilnærming som fremhever modellens anvendbarhet i risikostyringskontekster, og viser hvordan akademisk forskning kan oversettes til praktiske løsninger for finansielle beslutningstagere. Videre inkluderes backtesting av VaR resultatene, som innebærer å evaluere nøyaktigheten og påliteligheten til VaR-modellen ved å sammenligne de predikerte risikoestimaterne med faktiske utfall i historiske data. Dette bidrar til en praktisk validering av VaR-modellen, og sikrer at den gir pålitelige estimater som kan brukes til effektiv risikostyring. Til slutt estimeres ES, som gir oss et mål på forventede tap i de verste scenarioene. Resultatene er presentert i tabell 6.

Tabell 6: VaR, backtesting og forventet tap for de ulike modellene

Testing	RF	SVM	NN	Kombinert	sGARCH	TGARCH
VaR 95%	9,46%	9,68%	7,80%	8,98%	6,50%	6,70%
VaR 99%	12,40%	12,70%	10,27%	11,82%	8,60%	8,80%
Backtest 95%	1,23%	1,23%	1,20%	1,34%	2,57%	2,57%
Backtest 99%	0,41%	0,41%	0,17%	0,61%	1,54%	1,44%
ES 95%	-11,77%	-11,77%	-10,56%	-11,58%	-9,76%	-9,76%
ES 99%	-14,29%	-14,29%	-12,67%	-14,29%	-11,21%	-11,38%

5.3.1 VaR estimering

Ved 95% konfidensnivå viser sGARCH og TGARCH de laveste VaR-verdiene på henholdsvis 6,50% og 6,70%, noe som indikerer at GARCH-modellene gir mer konservative risikoestimer sammenlignet med maskinlæringsmodellene. Dette kan forklares med GARCH-modellenes evne til å fange opp volatilitetstrender over tid, noe som gir dem en fordel i perioder med lav volatilitet. Maskinlæringsmodellene, spesielt NN med en VaR-verdi på 7,80%, viser høyere verdier som tyder på en bedre evne til å håndtere høy volatilitet.

Ved 99% konfidensnivå følger resultatene et lignende mønster, med sGARCH og TGARCH som de mest konservative modellene med VaR-verdier på 8,60% og 8,80%.

Maskinlæringsmodellene viser høyere verdier, med NN på 10,27%, noe som indikerer at de tar høyde for større risiko i ekstreme markedsforhold. SVM og RF viser de høyeste VaR-verdiene på henholdsvis 12,70% og 12,40%, noe som antyder at disse modellene overestimerer risikoen i svært volatile perioder.

5.3.2 Backtesting

Backtesting av VaR-estimatene ved 95% konfidensnivå viser at maskinlæringsmodellene generelt har lavere feilrater mellom 1,20% og 1,34% sammenlignet med GARCH-modellene som har feilrater på 2,57%. En mulig forklaring på dette er at maskinlæringsmodellene gir mer nøyaktige prediksjoner i vanlige markedsforhold, noe som gir dem en fordel når det gjelder å håndtere daglig risiko.

Ved 99% konfidensnivå viser backtestingresultatene et lignende mønster, hvor maskinlæringsmodellene har lavere feilrater 0,17% og 0,61%, mens sGARCH-modellen har en feilrate på 1,54% og TGARCH-modellen har en feilrate på 1,44%. Dette reflekterer at GARCH-modellene, mens de er konservative ikke alltid klarer å forutsi ekstreme markedsbevegelser like godt som maskinlæringsmodellene.

5.3.3 Forventet tap

Forventet tap (ES) gir en ytterligere dimensjon til risikoberegningen ved å estimere det forventede tapet gitt at VaR-nivået er overskredet. Ved 95% konfidensnivå viser sGARCH og TGARCH de laveste ES-verdiene på -9,76%, mens maskinlæringsmodellene har høyere ES-verdier, med SVM på -11,77% og NN på -10,56%. Den kombinerte maskinlæringsmodellen har en ES-verdi på -11,58%. Dette indikerer at GARCH-modellene effektivt kan begrense

tapene i høyrisikoscenarier, mens maskinlæringsmodellene kan ha en tendens til å overestimere potensielle tap i disse situasjonene.

Ved 99% konfidensnivå følger ES-resultatene et lignende mønster, hvor sGARCH og TGARCH har lavere ES-verdier på henholdsvis -11,21% og -11,38%.

Maskinlæringsmodellene viser høyere ES-verdier, med SVM på -14,29% og NN på -12,67%.

Dette tyder på at GARCH-modellene fortsatt er mer pålitelige i å håndtere ekstreme markedsforhold sammenlignet med maskinlæringsmodellene

6 konklusjon

I denne oppgaven har målet vært å sikte oss inn på å forklare problemstillingen: *“Hvordan presterer tradisjonelle GARCH modeller mot maskinlæring i prediksjon av et høyt volatilt marked?”*. Formålet med oppgaven har vært å gi en detaljert analyse av volatiliteten i Bitcoinmarkedet og evaluere ytelsen til de utvalgte prediktive modellene. Ved å integrere økonomiske teorier med avanserte maskinlærings- og GARCH-modeller har vi kunne undersøke de komplekse dynamikkene i markedet og identifisere hvilke modeller som gir de mest nøyaktige prediksjonene.

Analysen av volatilitetsprediksjon i Bitcoin-markedet avdekker viktigheten av strategisk utvelgelse av forklarende variabler, hvor de mest relevante og statistisk signifikante variablene er identifisert gjennom metoder som backward selection og hyperparameter tuning. De empiriske resultatene, illustrert i Figur 1, fremhever variabler som «BTC Momentum_5_Days», «BTC Lag_1_Day Volatility», og «BTC Momentum_252_Days» som kritiske faktorer for modellens nøyaktighet, målt gjennom %IncMSE og IncNodePurity. Disse variablene bidrar betydelig til både å redusere prediksjonsfeil og øke node renhet, hvilket gjør modellens beslutninger mer definitive.

Figur 1 viser også at makroøkonomiske variabler, som volatilitetsindeksen «VIX» og «Kabel TY», har en vesentlig rolle i å forstå markedsdynamikkene, noe som indikerer at eksterne faktorer i stor grad kan brukes til å predikere Bitcoin-volatilitet. Dette funnet er viktig da det viser at både interne Bitcoin-relaterte variabler og eksterne makroøkonomiske faktorer er nødvendige for en omfattende analyse

Studien bygger på et solid teoretisk rammeverk som kombinerer økonomiske teorier og metodeutførelse. RF-modellen viste seg å være overlegen når det gjelder MSE og RMSE, noe som indikerer høy nøyaktighet i modellens prediksjonsevner. GARCH-modellene som NN og SVM hadde styrker i å fange opp høy volatilitet, men med større feilmarginer (MAPE). Det viser viktigheten av å bruke en kombinasjon av modeller avhengig av markedsforholdene.

Videre tyder resultatene på en sterk tilpasning til treningsdataene og gode prediktive evner. Når det gjelder GARCH-modellene viser de en styrke i å modellere og forutsi volatilitetstrendene over tid grunnet deres lavere MAPE verdier. Det indikerer bedre prediktive evner i perioder med lavere volatilitet, noe som gjør disse modellene mer pålitelige for å håndtere utslag i volatilitet. Dette bekrefter også figurene, hvor de viser en jevnere prediksjon sammenlignet med for eksempel RF. På den andre siden gir RF en mer nøyaktig prediksjon. Det observeres av SVM-modellen at den reflekterer modellens svakheter i å håndtere lav volatilitet og utfordringer med å predikere nøyaktig. NN viser bedre evner, men sliter også med å predikere ekstreme volatilitetstopper.

Bruken av VaR og ES i studien gir en praktisk tilnærming til forskningen, som er direkte anvendelig for risikostyring. GARCH-modellene viste seg å være bedre i sine risikoestimerer på 95% og 99% konfidensnivå, mens maskinlæringsmodellene tok høyde for større risiko i ekstreme markedsforhold. Maskinlæringsmodellene gir høyere VaR verdier, noe som tyder på bedre håndtering av høy volatilitet, men kan overestimere risiko i ekstreme markedsforhold. Backtestingen bekrefter at maskinlæringsmodellene har lavere feilrater, som viser deres nøyaktighet i normale markedsforhold. Dette er viktige punkt for en som ønsker å investere som søker å minimere risiko og optimalisere avkastning i et svært volatilt marked som Bitcoin-markedet.

Resultatene viser at ingen enkeltmodell er perfekt, men RF-modellen gir de mest nøyaktige prediksjonene generelt, men GARCH-modellene er bedre til å håndtere perioder med lavere volatilitet. Den kombinerte maskinlæringsmodellen tilbyr en mer robust tilnærming ved å balansere svakheter til de enkelte modellene. Dette indikerer at en hybrid modell kan bære effektiv for å forutsi volatilitet i kryptomarkedet.

Avslutningsvis kan det sies at integrasjonen av maskinlæringsmetoder og tradisjonelle GARCH-modeller gir en dypere forståelse av Bitcoin-markedets volatilitet. Valget av modell bør derfor baseres på spesifikke markedsforhold og risikotoleranse.

6.1 Videre forskning

Videre forskning kan utvides ved å inkludere andre kryptovalutaer og flere makroøkonomiske variabler for å forbedre modellenes robusthet og nøyaktighet, samt ukentlige og månedlige data. Det kan for eksempel være spennende å se på ulike splits i datasettene som for eksempel 70/30, 60/40 og 50/50 for å undersøke hvordan påvirkning det har på resultatene. En annen faktor kan også være å utforske andre nevrale nettverk som LSTM og se om disse kan gi bedre prediksjoner. I tillegg kan man Integrere flere ulike variabler som får data fra sosiale medier og nyhetskilder, samt en variabel som kan inneholde Google-søk, tweets eller lignende kan gi verdifulle svar på om markedet påvirkes stort av spekulasjon.

7 Referanseliste

- Abdullah, A. S., Kailash, P. J. S., Ramesh, D. & Guntha, P. (2023, 1-2 Sept. 2023). Evaluating Employee Attrition And Its Factors Using Machine Learning Approaches. 2023 International Conference on Network, Multimedia and Information Technology (NMITCON), <https://doi.org/10.1109/NMITCON58196.2023.10276069>
- Acerbi, C., Nordio, C. & Sirtori, C. (2001). Expected Shortfall as a Tool for Financial Risk Management. <https://doi.org/10.48550/arxiv.cond-mat/0102304>
- Akyildirim, E., Goncu, A. & Sensoy, A. (2021). Prediction of cryptocurrency returns using machine learning. *Annals of operations research*, 297(1-2), 3-36. <https://doi.org/10.1007/s10479-020-03575-y>
- Al-Thaqeb, S. A. & Algharabali, B. G. (2019). Economic policy uncertainty: A literature review. *Journal of economic asymmetries*, 20, e00133. <https://doi.org/10.1016/j.jeca.2019.e00133>
- Alberg, D., Shalit, H. & Yosef, R. (2008). Estimating stock market volatility using asymmetric GARCH models. *Applied Financial Economics*, 18(15), 1201-1208. <https://doi.org/10.1080/09603100701604225>
- Almansour, B. (2015). THE IMPACT OF MARKET SENTIMENT INDEX ON STOCK RETURNS: AN EMPIRICAL INVESTIGATION ON KUALA LUMPUR STOCK EXCHANGE INTRODUCTION. https://www.researchgate.net/publication/331166420_THE_IMPACT_OF_MARKET_SENTIMENT_INDEX_ON_STOCK_RETURNS_AN_EMPIRICAL_INVESTIGATION_ON_KUALA_LUMPUR_STOCK_EXCHANGE_INTRODUCTION
- Almansour, B., Almansour, A. & In'airat, M. (2020). The Impact Of Exchange Rates On Bitcoin Returns: Further Evidence From A Time Series Framework. *International Journal of Scientific & Technology Research*, 9, 4577-4581. https://www.researchgate.net/publication/339326011_The_Impact_Of_Exchange_Rates_On_Bitcoin_Returns_Further_Evidence_From_A_Time_Series_Framework
- Alvarez-Ramirez, J., Rodriguez, E. & Ibarra-Valdez, C. (2018). Long-range correlations and asymmetry in the Bitcoin market. *Physica A*, 492, 948-955. <https://doi.org/10.1016/j.physa.2017.11.025>

- Ardia, D., Bluteau, K. & Rüede, M. (2019). Regime changes in Bitcoin GARCH volatility dynamics. *Finance Research Letters*, 29, 266-271.
<https://doi.org/10.1016/j.frl.2018.08.009>
- Baillie, R. T. & Bollerslev, T. (1989). COMMON STOCHASTIC TRENDS IN A SYSTEM OF EXCHANGE-RATES. *The Journal of finance (New York)*, 44(1), 167-181.
<https://doi.org/10.2307/2328281>
- Baker, S. R., Bloom, N. & Davis, S. J. (2016). Measuring Economic Policy Uncertainty*. *The Quarterly Journal of Economics*, 131(4), 1593-1636.
<https://doi.org/10.1093/qje/qjw024>
- Barber, B. & Odean, T. (2008). All That Glitters: The Effect of Attention and News on the Buying Behavior of Individual and Institutional Investors. *Review of Financial Studies*, 21, 785-818. <https://doi.org/10.2139/ssrn.460660>
- Bashar, Y., Almansour, B. & Arabyat, Y. (2017). INVESTMENT DECISION MAKING AMONG GULF INVESTORS: BEHAVIOURAL FINANCE PERSPECTIVE. *International Journal of Management Studies*, 24.
<https://doi.org/10.32890/ijms.24.1.2017.10476>
- Bergbrant, M. & Bradley, D. (2022). Did They Just Say That? Cable News, Policy Uncertainty and Market Volatility. *SSRN Electronic Journal*.
<https://doi.org/10.2139/ssrn.4059681>
- Bollerslev, T. (1986). Generalized autoregressive conditional heteroskedasticity. *Journal of Econometrics*, 31(3), 307-327. [https://doi.org/10.1016/0304-4076\(86\)90063-1](https://doi.org/10.1016/0304-4076(86)90063-1)
- Bouoiyour, J., Selmi, R. & Tiwari, A. K. (2016). What drives Bitcoin price? *Economics Bulletin*, 36(2), 843-850. <http://www.accessecon.com/Pubs/EB/2016/Volume36/EB-16-V36-I2-P82.pdf>
- Brière, M., Oosterlinck, K. & Szafarz, A. (2013). Virtual Currency, Tangible Return: Portfolio Diversification with Bitcoin. *SSRN Electronic Journal*, 16.
<https://doi.org/10.2139/ssrn.2324780>
- Castelvecchi, D. (2016). Can we open the black box of AI? *Nature*, 538(7623), 20-23.
<https://doi.org/10.1038/538020a>
- Cermak, V. (2017). Can Bitcoin Become a Viable Alternative to Fiat Currencies? An Empirical Analysis of Bitcoin's Volatility Based on a GARCH Model. *ERN: International Finance (Topic)*. <https://www.semanticscholar.org/paper/Can-Bitcoin-Become-a-Viable-Alternative-to-Fiat-An-Cermak/a27f245ead36a2cfec2c0a71be2efb35a16b8035>

- Chowdhury, A. (2016). Is Bitcoin the “Paris Hilton” of the Currency World? Or Are the Early Investors onto Something That Will Make Them Rich? *The Journal of Investing*, 25, 64 - 72. <https://www.semanticscholar.org/paper/Is-Bitcoin-the-%E2%80%9CParis-Hilton%E2%80%9D-of-the-Currency-World-Chowdhury/10964012bd2eb4195b2b7b6e444b378c5b494766>
- Chowdhury, A. M., Barry K. (2013). *Virtual Currency and the Financial System: The Case of Bitcoin* [Working Papers and Research]. <https://ideas.repec.org/p/mrq/wpaper/2013-09.html>
- Chu, J., Chan, S., Nadarajah, S. & Osterrieder, J. (2017). GARCH Modelling of Cryptocurrencies. *Journal of Risk and Financial Management*, 10, 17. <https://doi.org/10.3390/jrfm10040017>
- CoinMarketCap. (u.å.). Bitcoin. Hentet [28.11.23], fra <https://coinmarketcap.com/currencies/bitcoin/>
- Das, S., dey, A., Pal, A. & Roy, N. (2015). Applications of Artificial Intelligence in Machine Learning: Review and Prospect. *International Journal of Computer Applications*, 115, 31-41. <https://doi.org/10.5120/20182-2402>
- Datatilynet. (2018). *Kunstig intelligens og personvern* (Hvordan fungerer kunstig intelligens?, Issue. Datatilynet. Datatilynet. <https://www.datatilynet.no/globalassets/global/dokumenter-pdf-er-skjema-ol/rettigheter-og-plikter/rapporter/rapport-om-ki-og-personvern.pdf>
- Demirer, R., Gupta, R. & Pierdzioch, C. (2020). Forecasting Realized Stock-Market Volatility: Do Industry Returns Have Predictive Value? *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.3744537>
- Dyhrberg, A. H. (2016). Bitcoin, gold and the dollar – A GARCH volatility analysis. *Finance Research Letters*, 16, 85-92. <https://doi.org/https://doi.org/10.1016/j.frl.2015.10.008>
- El Naqa, I. & Murphy, M. J. (2015). What Is Machine Learning? I I. El Naqa, R. Li & M. J. Murphy (Red.), *Machine Learning in Radiation Oncology: Theory and Applications* (s. 3-11). Springer International Publishing. https://doi.org/10.1007/978-3-319-18305-3_1
- Fama, E. F. (1970). Efficient Capital Markets: A Review of Theory and Empirical Work. *The Journal of Finance*, 25(2), 383-417. <https://doi.org/10.2307/2325486>
- Géron, A. (2022). *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow*. " O'Reilly Media, Inc."

- Glaser, F., Zimmermann, K., Haferkorn, M., Weber, M. C. & Siering, M. (2014). Bitcoin-asset or currency? revealing users' hidden intentions. *Revealing Users' Hidden Intentions* (April 15, 2014). *ECIS*.
https://papers.ssrn.com/sol3/papers.cfm?abstract_id=2425247
- Halinski, R. S. & Feldt, L. S. (1970). THE SELECTION OF VARIABLES IN MULTIPLE REGRESSION ANALYSIS. *Journal of Educational Measurement*, 7(3), 151-157.
<https://doi.org/10.1111/j.1745-3984.1970.tb00709.x>
- Hansun, S. (2013, 27-28 Nov. 2013). A new approach of moving average method in time series analysis. 2013 Conference on New Media Studies (CoNMedia),
<https://doi.org/10.1109/CoNMedia.2013.6708545>
- Investing.com: Bitcoin. Investing.com [Dataseit]
<https://www.investing.com/crypto/bitcoin/historical-data>
- Investing.com: CBOE Volatility Index (VIX). Investing.com [Dataseit]
<https://www.investing.com/indices/volatility-s-p-500>
- Investing.com: Crude Oil WTI Futures (CLM4). Investing.com [Dataseit]
<https://www.investing.com/commodities/crude-oil-historical-data>
- Investing.com: Dow Jones Industrial Average (DJI). Investing.com [Dataseit]
<https://www.investing.com/indices/us-30>
- Investing.com: Energy Select Sector SPDR Fund (XLE). Investing.com [Dataseit]
<https://www.investing.com/etfs/spdr-energy-select-sector-fund-historical-data>
- Investing.com: NASDAQ Composite (IXIC). Investing.com [Dataseit]
<https://www.investing.com/indices/nasdaq-composite-historical-data>
- Investing.com: S&P 500 (SPX). Investing.com [Dataseit]
<https://www.investing.com/indices/us-spx-500-historical-data>
- Investing.com: US Dollar Index (DXY). Investing.com [Dataseit]
<https://www.investing.com/indices/usdollar-historical-data>
- Jiang, Y., Nie, H. & Ruan, W. (2018). Time-varying long-term memory in Bitcoin market. *Finance Research Letters*, 25, 280-284. <https://doi.org/10.1016/j.frl.2017.12.009>
- Jung, S.-K. & Kim, T.-W. (2016). New approach for the diagnosis of extractions with neural network machine learning. *Am J Orthod Dentofacial Orthop*, 149(1), 127-133.
<https://doi.org/10.1016/j.ajodo.2015.07.030>
- Kearney, L. (2020). Why oil prices are crashing and what it means. World Economic Forum. <https://www.weforum.org/agenda/2020/04/oil-barrel-prices-economic-supply-demand-coronavirus-covid19-united-states/>

- Kim, Y. B., Lee, J., Park, N., Choo, J., Kim, J.-H. & Kim, C.-H. (2017). When Bitcoin encounters information in an online forum: Using text mining to analyse user opinions and predict value fluctuation. *PLOS ONE*, 12, e0177630.
<https://doi.org/10.1371/journal.pone.0177630>
- Kratz, M., Lok, Y. H. & McNeil, A. J. (2018). Multinomial VaR backtests: A simple implicit approach to backtesting expected shortfall. *Journal of banking & finance*, 88, 393-407.
<https://doi.org/10.1016/j.jbankfin.2018.01.002>
- Küfeoğlu, S. & Özkuran, M. (2019). Bitcoin mining: A global review of energy and power demand. *Energy Research & Social Science*, 58, 101273.
<https://doi.org/10.1016/j.erss.2019.101273>
- Laurent, S., Beine, M., Laurent, S. & Lecourt, C. (2002). Accounting for conditional leptokurtosis and closing day effects in FIGARCH models of daily exchange rates. *Applied Financial Economics*, 12, 589-600.
<https://doi.org/10.1080/09603100010014041>
- Leirvik, T. & Yuan, M. (2021). A Machine Learning Technique for Spatial Interpolation of Solar Radiation Observations. *Earth and Space Science*, 8(4), e2020EA001527.
<https://doi.org/https://doi.org/10.1029/2020EA001527>
- Lintner, J. (1965). The Valuation of Risk Assets and the Selection of Risky Investments in Stock Portfolios and Capital Budgets. *The review of economics and statistics*, 47(1), 13-37. <https://doi.org/10.2307/1924119>
- Livingston, F. (2005). Implementation of Breiman's random forest machine learning algorithm. *ECE591Q Machine Learning Journal Paper*, 1-13.
[http://datajobstest.com/data-science-repo/Random-Forest-\[Frederick-Livingston\].pdf](http://datajobstest.com/data-science-repo/Random-Forest-[Frederick-Livingston].pdf)
- Lundblad, C. (2007). The risk return tradeoff in the long run: 1836–2003. *Journal of Financial Economics*, 85(1), 123-150. <https://doi.org/10.1016/j.jfineco.2006.06.003>
- Madhavan, A. (2000). Market microstructure: A survey. *Journal of financial markets (Amsterdam, Netherlands)*, 3(3), 205-258. [https://doi.org/10.1016/S1386-4181\(00\)00007-0](https://doi.org/10.1016/S1386-4181(00)00007-0)
- Marsland, S. (2014). *Machine Learning: An Algorithmic Perspective, Second Edition* (2nd ed.). Chapman and Hall/CRC. <https://doi.org/10.1201/b17476>
- Miah, M. & Rahman, A. (2016). Modelling volatility of daily stock returns: Is GARCH (1, 1) enough. *American Scientific Research Journal for Engineering, Technology, and Sciences (ASRJETS)*, 18(1), 29-39. <https://www.researchgate.net/profile/Mamun-Miah->

[2/publication/335749475 Modelling Volatility of Daily Stock Returns Is GARCH
11 Enough/links/5d78ffaa4585151ee4aedf25/Modelling-Volatility-of-Daily-Stock-
Returns-Is-GARCH1-1-Enough.pdf](https://doi.org/10.1080/1351847X.2019.1647259)

Momtaz, P. P. (2021). The Pricing and Performance of Cryptocurrency. *The European Journal of Finance*, 27(4-5), 367-380.

<https://doi.org/10.1080/1351847X.2019.1647259>

Mushtaq, R. (2011). Augmented Dickey Fuller Test. *SSRN Electronic Journal*.

<https://doi.org/10.2139/ssrn.1911068>

Nakamoto, S. (2008). Bitcoin: A Peer-to-Peer Electronic Cash System. Hentet fra

<https://bitcoin.org/bitcoin.pdf>

Nian, L. & Chuen, D. (2015). Introduction to Bitcoin. I (s. 5-30).

<https://doi.org/10.1016/B978-0-12-802117-0.00001-1>

Noble, W. S. (2006). What is a support vector machine? *Nature Biotechnology*, 24(12), 1565-1567. <https://doi.org/10.1038/nbt1206-1565>

Orhan, M. & Köksal, B. (2012). A comparison of GARCH models for VaR estimation.

Expert Systems with Applications, 39(3), 3582-3592.

<https://doi.org/10.1016/j.eswa.2011.09.048>

Probst, P., Wright, M. N. & Boulesteix, A. L. (2019). Hyperparameters and tuning strategies for random forest. *Wiley interdisciplinary reviews. Data mining and knowledge discovery*, 9(3), n/a. <https://doi.org/10.1002/widm.1301>

Ripley, B. D. (1996). Pattern recognition and neural networks. Cambridge University Press.

Ronen, E. & Ohad, S. (2016/06/06). *The Power of Depth for Feedforward Neural Networks*.

<https://proceedings.mlr.press/v49/eldan16.html>

Santoni, G. J. (1987). The great bull markets 1924-29 and 1982-87: speculative bubbles or economic fundamentals? *Review - Federal Reserve Bank of St. Louis*, 69, 16-29.

<https://www.proquest.com/docview/227737670/fulltextPDF/A8D8FFE7524C43D8PQ/1?accountid=17260&sourcetype=Trade%20Journals>

Sharpe, W. F. (1964). CAPITAL-ASSET PRICES - A THEORY OF MARKET

EQUILIBRIUM UNDER CONDITIONS OF RISK. *The Journal of finance (New York)*, 19(3), 425-442. <https://doi.org/10.2307/2977928>

Shin, J.-S. (2017). Dynamic catch-up strategy, capability expansion and changing windows of opportunity in the memory industry. *Research policy*, 46(2), 404-416.

<https://doi.org/10.1016/j.respol.2016.09.009>

- Sollis, R. (2009). Value at risk: a critical overview. *Journal of Financial Regulation and Compliance*, 17(4), 398–414. <https://doi.org/10.1108/13581980911004370>
- Spierdijk, L. (2016). Confidence intervals for ARMA–GARCH Value-at-Risk: The case of heavy tails and skewness. *Computational Statistics & Data Analysis*, 100, 545-559. <https://doi.org/10.1016/j.csda.2014.08.011>
- Stiglitz, J. E. (1990). Symposium on Bubbles. *The Journal of Economic Perspectives*, 4(2), 13-18. <http://www.jstor.org/stable/1942887>
- Stosic, D., Stosic, D., Ludermir, T. B. & Stosic, T. (2018). Collective behavior of cryptocurrency price changes. *Physica A*, 507, 499-509. <https://doi.org/10.1016/j.physa.2018.05.050>
- Sveriges Riksbank. & Segendorf, Bjørn., (2014). [What is Bitcoin?]. Hentet fra https://archive.riksbank.se/Documents/Rapporter/POV/2014/2014_2/rap_pov_140091_8_eng.pdf
- The mechanisms of market efficiency. *Virginia law review*. 549-644
- Tidemann, A. & Elster, A.C. (2019, 7. juni). Maskinlæring. Store Norske Leksikon. Hentet fra <https://snl.no/maskinl%C3%A6ring>
- Venables, W. N. (2002). *Modern applied statistics with S* (4th. utg.). Springer.
- Vujičić, D., Jagodić, D. & Randić, S. (2018, 21-23 March 2018). Blockchain technology, bitcoin, and Ethereum: A brief overview. 2018 17th International Symposium INFOTEH-JAHORINA (INFOTEH), <https://doi.org/10.1109/INFOTEH.2018.8345547>
- Wang, Y., Andreeva, G. & Martin-Barragan, B. (2023). Machine learning approaches to forecasting cryptocurrency volatility: Considering internal and external determinants. *International Review of Financial Analysis*, 90, 102914. <https://doi.org/10.1016/j.irfa.2023.102914>
- Warmke, C. (2020) What is bitcoin? *Inquiry*, 1-43. <https://doi.org/10.1080/0020174X.2020.1860123>
- Warmke, C. What is bitcoin? *Inquiry*, 1-43. <https://doi.org/10.1080/0020174X.2020.1860123>
- Yahoo Finance: SPDR Gold Shares (GLD). Yahoo Finance [Datasett] <https://finance.yahoo.com/quote/GLD?.tsrc=fin-srch>
- Zohuri, B., Nguyen, H. & Moghaddam, M. (2022). What is the Cryptocurrency? Is it a Threat to Our National Security, Domestically and Globally? , 3, 1-14. https://www.researchgate.net/publication/358380563_What_is_the_Cryptocurrency_Is_it_a_Threat_to_Our_National_Security_Domestically_and_Globally/citation/download

[oad? tp=eyJjb250ZXh0Ijp7InBhZ2UiOiJwdWJsaWNhdGlvbGlzInByZXZpb3VzUGFnZSI6bnVsbH19](#)

