

Kim Anders Berglund  
Vymi Thoai Nguyen Le

## **Modellering av volatilitet i kryptovaluta – En sammenligning ved bruk av ulike GARCH-modeller**

Volatility modeling of cryptocurrencies – A comparison using different GARCH models

**MASTEROPPGAVE - Økonomi og administrasjon/siviløkonom  
Trondheim, mai 2018**

Hovedprofil: Finansiering og investering

Veileder: Denis Becker

## **Forord**

Denne avhandlingen markerer avslutningen på vår mastergrad i økonomi og administrasjon med hovedprofil i finansiering og investering ved NTNU Handelshøyskolen. Arbeidet med masteroppgaven har blitt utført i løpet av våren 2018 og utgjør 30 studiepoeng. Gjennomføringen har vært krevende, men samtidig spennende og lærerik.

Vi vil takke vår veileder Denis Becker for gode råd og tilbakemeldinger underveis i skriveprosessen.

Innholdet i denne avhandlingen står for forfatterens egen regning.

Trondheim, 24. mai 2018

---

Kim Anders Berglund

---

Vymi Thoai Nguyen Le

## Sammendrag

Denne masteravhandlingen undersøker kryptovalutaene: Bitcoin, Ethereum, Ripple, DASH og Litecoin. Formålet var først å avdekke om variablene for etterspørsel etter informasjon, historiske begivenheter og kunngjøringer, samt volatiliteten i det amerikanske aksjemarkedet påvirker volatiliteten i disse kryptovalutaene. Deretter undersøkte den om det eksisterer «leverage effects» i kryptovaluta. Til slutt, svarer den på hvorvidt implementeringen av variablene forbedrer tilpasningen i forskjellige GARCH-modeller basert på mål som AIC og BIC. Det statistiske programmet, EViews 7, har blitt brukt til å modellere GARCH-, EGARCH- og GJRARCH-modellene.

Resultatene viser at variabelen for etterspørsel etter informasjon er statistisk signifikant for alle kryptovaluta. Videre avdekket resultatene at negative historiske begivenheter og kunngjøringer påvirker volatiliteten i større grad enn det de positive gjør. Analysen fant også en sammenheng mellom volatiliteten i det amerikanske aksjemarkedet og volatiliteten i 3 av 5 kryptovalutaer. I tillegg viser resultatene at «leverage effects» kun er signifikant i GJRARCH-modellen for DASH. Avslutningsvis, fant vi at implementeringen av variablene forbedrer AIC i de fleste modeller, mens BIC viste blandede resultater.

På bakgrunn av at kryptovaluta fortsatt er relativt lite etablert innenfor økonomisk forskning, kan ny innsikt gi verdi til områder der kalkulering, spekulasjon og styring av risiko er viktig. Dette kan være nyttig for interessenter ved beslutningstaking innenfor porteføljeoptimering, hedging strategier og prising av derivater. Bortsett fra dette, kan det hjelpe investorer som ønsker å investere i kryptovaluta eller andre som ønsker å forbedre kunnskapen om kryptovaluta som et finansiell aktiva.

## **Abstract**

This master thesis examines the cryptocurrencies; Bitcoin, Ethereum, Ripple, DASH, and Litecoin. The purpose was first to investigate whether the variables for information demand, historical events, and the volatility of the US stock market affect the volatility of these cryptocurrencies. Then, it examined if leverage effects exist in cryptocurrencies. Finally, it answered whether the implementation of the variables improves the volatility modelling in the different GARCH models based on AIC and BIC. Hereby, the statistical programme, EViews 7 is used to model the GARCH, EGARCH and GJRGARCH models.

The results show that the variable for information demand is statistically significant for all cryptocurrencies. Further, the results revealed that negative historical events and announcements affect the volatility to a greater extent than positive ones. The analysis also showed that the volatility of the US stock market is statistically significant for 3 out of 5 cryptocurrencies. This indicates that there is a positive correlation between the volatility of cryptocurrencies and the volatility of the US stock market. Additionally, the outcomes prove that leverage effects are only significant in the GJRGARCH model for DASH. Finally, the implementation of the variables improves AIC for most of the models, while BIC shows mixed results.

Because cryptocurrency has not yet been well established in economic research, these insights can give value to areas where calculating, speculation and management of risk are important. This can be useful for stakeholders for decision making within the areas of portfolio optimisation, hedging strategies and pricing of derivatives. Apart from this, it can help investors that want to invest in cryptocurrencies or simply people who want to improve their understanding of cryptocurrency as a financial asset.

# Innholdsfortegnelse

<b>1. Introduksjon</b> .....	<b>1</b>
<b>2. Tidligere forskning</b> .....	<b>3</b>
<b>3. Metode</b> .....	<b>6</b>
3.1 Viktige egenskaper ved finansiell data .....	6
3.2 Kryptovaluta .....	7
3.3 Variabler og hypoteser .....	7
3.4 Stasjonaritet.....	11
3.5 Normalitet .....	12
3.6 Autokorrelasjon.....	12
3.7 ARCH-effekter.....	13
3.8 Volatilitetsmodeller.....	14
3.8.1 Generalised ARCH (GARCH).....	14
3.8.2 GJRGARCH .....	16
3.8.3 Exponential GARCH (EGARCH) .....	17
3.9 Evaluering av modellene.....	19
<b>4. Empiriske resultater</b> .....	<b>20</b>
4.1 Bitcoin (BTC) .....	20
4.2 Ethereum (ETH).....	23
4.3 Ripple (XRP) .....	26
4.4 DASH.....	28
4.5 Litecoin (LTC) .....	31
<b>5. Diskusjon av resultater</b> .....	<b>34</b>
<b>6. Konklusjon</b> .....	<b>37</b>
<b>Referanseliste</b> .....	<b>39</b>
<b>Vedlegg</b> .....	<b>45</b>

## Figurliste

Figur 1: Utvikling i pris og log-avkastning for Bitcoin/USD. ....	20
Figur 2: Utvikling i pris og log-avkastningen til Ethereum/USD.....	23
Figur 3: Utvikling i pris og log-avkastningen til Ripple/USD.....	26
Figur 4: Utvikling i pris og log-avkastningen til DASH/USD. ....	29
Figur 5: Utvikling i pris og log-avkastningen til Litecoin/USD. ....	31

## Tabelliste

Tabell 1: Oversikt over kryptovalutaer med tilhørende ticker og søkeord. ....	9
Tabell 2: Deskriptiv statistikk for Bitcoin. ....	21
Tabell 3: Parameterestimater for Bitcoin. ....	22
Tabell 4: AIC og BIC for GARCH-modellene i Bitcoin. ....	23
Tabell 5: Deskriptiv statistikk av Ethereum.....	24
Tabell 6: Parameterestimater for Ethereum. ....	25
Tabell 7: AIC og BIC for GARCH-modellene i Ethereum. ....	25
Tabell 8: Deskriptiv statistikk for Ripple.....	26
Tabell 9: Parameterestimaterne for Ripple.....	27
Tabell 10: AIC og BIC for GARCH-modellene i Ripple. ....	28
Tabell 11: Deskriptiv statistikk for DASH. ....	29
Tabell 12: Parameterestimaterne for DASH. ....	30
Tabell 13: AIC og BIC for GARCH-modellene i DASH. ....	31
Tabell 14: Deskriptiv statistikk for Litecoin. ....	32
Tabell 15: Parameterestimaterne for Litecoin. ....	32
Tabell 16: AIC og BIC for GARCH-modellene i Litecoin.....	33

# 1. Introduksjon

Kryptovaluta er en samlebetegnelse for ulike former av digital valuta som bruker kryptografi<sup>1</sup> til å regulere antall enheter av valutaen som blir generert, og til å verifisere transaksjonene (Schueffel, 2017). På grunn av idéen, teknologien og den ekstreme volatiliteten bak kryptovaluta, samt økt kaos i verden som fører til mindre tiltro til banker og stat, har interessen for kryptovaluta eksplodert (Chuen, 2015, s. xxi-xxiii). En Bitcoin (BTC), som er den mest populære kryptovalutaen og størst i markedsverdi<sup>2</sup>, nådde toppen mot slutten av 2017 da verdien nesten var på 20 000 USD (ca. 155 000 NOK). I februar kostet den ca. 6000 USD, og i skrivende stund (20. mai 2018) er en Bitcoin verdt 8 349,56 USD (CoinMarketCap, u.å.).

Bitcoin ble i utgangspunktet skapt for å overføre penger direkte mellom mennesker over hele verden uten behov for tredjepartsaktører som banker og finansielle institusjoner (Nakamoto, 2008). Per dags dato ser det ut til at Bitcoin ikke kan karakteriseres som en valuta, men heller som et spekulasjons- og investeringsobjekt grunnet den ekstreme volatiliteten som påvirker verdien (Yermack, 2014; Dyhrberg, 2016a; Cermak, 2017; Valebrokk, 2018). Motivasjonen for denne oppgaven er derfor å finne ut om etterspørsel etter informasjon, historiske begivenheter og volatilitet i aksjemarkedet påvirker volatiliteten i kryptovaluta. Videre har vi undersøkt om det eksisterer «leverage effects» i kryptovaluta. Vi undersøker også om implementering av disse variablene forbedrer tilpasningen i GARCH-, GJRGARCH- og EGARCH-modellene basert på mål som AIC og BIC. På bakgrunn av dette, er følgende problemstilling formulert:

*«Hva driver prisvolatiliteten i kryptovaluta?»*

Volatilitet er et essensielt begrep innenfor finans og beskriver svingninger i verdien på finansielle aktiva. Volatilitet er et mål på risiko og uttrykkes enten gjennom standardavviket ( $\sigma$ ) eller variansen ( $\sigma^2$ ) til aktivumets avkastning (Brooks, 2008, s. 383). På grunn av risikoens viktige rolle innenfor finans, har mange forsøkt å finne presise metoder for å kunne styre og for å

---

<sup>1</sup> Kryptografi er prinsipper og teknikker ved skiving eller løsning av koder for å skjule informasjon. Ved kryptografi er det kun autoriserte personer som kan avsløre den skjulte informasjonen (OxfordDictionaries, u.å.; Knapskog og Eilertsen, 2018).

<sup>2</sup> I skrivende stund (20. mai 2018) finnes det 1593 forskjellige kryptovalutaer ute på markedet (CoinMarketCap, u.å.).

predikere den. Når det kommer til kryptovalutaer er det fortsatt et relativt nytt fenomen som fortsatt er krevende å klassifisere. De er annerledes fra andre eksisterende aktiva på det finansielle markedet, og mye mer volatilt enn tradisjonelle valutaer (Cermak, 2017). Samtidig har de mange av de samme egenskapene som finansielle data har. Disse er blant annet tidsvarierende volatilitet, ekstreme observasjoner og asymmetrisk respons av sjokk i volatiliteten (Catania, Grassi og Ravazzolo, 2018). Dette skaper nye muligheter for interessenter innenfor områder der kalkulering, spekulasjon og styring av risiko er viktig.

Utgangspunktet i vår avhandling ligger nært opptil studiene til Chronopoulos, Papadimitriou og Vlastakis (2017) og Katsiampa (2017). Chronopoulos, Papadimitriou og Vlastakis (2017) inkluderer en variabel for daglige antall Google søk som proxy for informasjonsetterspørsel i ulike GARCH-modeller for amerikanske aksjeavkastninger. Resultatene viste at denne inkluderingen ga signifikant forbedret prediksjoner av volatilitet på aksjeavkastninger. Katsiampa (2017) undersøkte hvordan flere ulike GARCH-modeller er i stand til å forklare volatiliteten til Bitcoin. Hun fant at AR-CGARCH, som tar hensyn til både en kortsiktig og langsiktig komponent i den betingede variansen, har best evne til å forklare volatiliteten i Bitcoin-prisen. Så vidt vi vet, har ikke noen studier undersøkt om implementering av variabler i form av positive og negative sjokk i GARCH-modeller gir signifikant påvirkning på volatiliteten i ulike kryptovaluta. Vi har heller ikke funnet annen forskning som har undersøkt om det eksisterer «leverage effects». Analysen vår tar utgangspunkt i flere kryptovalutaer og vil dermed også gi en dypere innsikt på temaet. Dette blir derfor vårt hovedbidrag til forskningen. Denne innsikten kan være nyttig for investorer ved utvikling av metoder til å forbedre beslutningstaking innenfor porteføljeoptimering, hedging strategier og prising av derivater på et tema som er relativt lite etablert i forskning.

Videre vil avhandlingen være organisert som følger: Del 2 går gjennom tidligere nærliggende forskning som er relevant for vår studie. Del 3 gjennomgår det metodiske rammeverket som har blitt brukt for å besvare problemstillingen. Del 4 presenterer empiriske resultater av hver kryptovaluta og de ulike modellene. Del 5 diskuterer de ulike resultatene. Til slutt presenteres konklusjonen i del 6.



## 2. Tidligere forskning

Dette kapittelet starter med å presentere tidligere forskning som har forsøkt å klassifisere kryptovaluta. Deretter går vi videre inn på drivere av prisen på kryptovaluta. Til slutt presenterer vi forskning som ligger nærmere vår avhandling.

Kryptovaluta er fremdeles et tema som ikke er godt etablert innenfor økonomisk forskning. Som følge av den økende interessen i kryptovaluta er det allikevel et behov for mer forskning på feltet, og litteraturen har økt mye bare på det siste året. Det som er av forskning innenfor temaet er hovedsakelig av Bitcoin, som er den første kryptovalutaen som klarte å slå gjennom til allmennheten (Halaburda og Sarvary, 2016).

### Klassifisering av kryptovaluta

Flere har forsøkt å studere hva fenomenet Bitcoin er (Hobson, 2013; Jenssen, 2014; Segendorf, 2014; Šurda, 2014) og om det egner seg til å være en egen eller alternativ valuta i likhet med fiatvaluta. Flere studier er enige i at Bitcoin ikke kan betraktes på lik linje som en tradisjonell valuta på grunn av sin desentraliserte natur og begrensede markedsstørrelse<sup>3</sup> (Dyhrberg, 2016a), den ekstreme høye volatiliteten (Yermack, 2014) og at den ikke oppfører seg effektivt som byttemiddel, til oppbevaring av verdier eller som en regneenhet (Cermak, 2017). Glaser *et al.* (2014a) fant at brukere av kryptovaluta, spesielt de uinformerte, i hovedsak ikke er interessert i et alternativt transaksjonssystem, men bruker det heller som en alternativ investering. Derfor har andre studert Bitcoin ut i fra et investeringsperspektiv. Bouri *et al.* (2017) undersøker om Bitcoin kan brukes som hedge og safe haven for aksjeindekser, obligasjoner, olje, gull, den generelle råvareindeksen og indeksen til amerikanske dollar. De finner at Bitcoin kan fungere til diversifisering, men ikke som en hedge. Derimot fant Stavroyiannis og Babalos (2017) at Bitcoin ikke innehar egenskaper for diversifisering og safe haven, men at det heller har sin egen risikovurdering reflektert i at den er uregulert og kriminaliteten som er forbundet med den. Dyhrberg (2016a; 2016b) bruker GARCH-modeller til å undersøke Bitcoins finansielle evner og fant at det kan bli brukt til å hedge mot aksjer i Financial Times' børsindeks og mot den amerikanske dollaren på kort sikt. Videre argumenterer hun for at Bitcoin kan klassifiseres som

---

<sup>3</sup> Det eksisterer bare 21 millioner Bitcoin (Nakamoto, 2008).

noe mellom gull og den amerikanske dollaren og dermed er brukbar innenfor både finansielle markeder og porteføljeforvaltning.

### **Prisdrivere i kryptovaluta**

Det er flere studier som undersøker potensielle drivere av Bitcoin-prisen og sammenhengen mellom disse. Kristoufek (2015) undersøker hvordan fundamentale-, spekulative- og tekniske variabler driver Bitcoin prisene, og fant blant annet at standard fundamentale faktorer, som bruken i handel, pengetilbud og prisnivå, spiller en rolle på den langsiktige Bitcoin-prisen. Prisen på Bitcoin er også drevet av investorenes interesse for kryptovalutaen og er mest tydelig i et langsiktig perspektiv. Andre drivere som har vist en påvirkende effekt på Bitcoin-prisen er oppmerksomhet fra media og spekulasjon i Bitcoin (Glaser *et al.*, 2014b; Bouoiyour *et al.*, 2016) politiske uttalelser og sjokk, interesse for Bitcoin målt med Google søk (Meland og Øyen, 2017), psykologiske faktorer som popularitet og hvordan folk oppfatter det som (Mai *et al.*, 2015; Matta, Lunesu og Marchesi, 2015; Polasik *et al.*, 2015). Kristoufek (2013) fant også en sterk korrelasjon mellom prisnivået til Bitcoin og søkemotorene til både Google og Wikipedia. Denne effekten virket begge veier; søkemotorene påvirker prisen, og prisen påvirker også søkemotorene. Letra (2016) analyserer også daglige Bitcoin-priser med antall Google søkeord og Wikipedia, i tillegg til tweets på Twitter ved bruk av GARCH (1,1)-modellen. Resultatet viste at Bitcoin-priser i hovedsak er påvirket av dets popularitet, at Bitcoin-priser og nettinhold har en sammenheng og at de innehar noe prediksjonsegenskaper. På en annen side finner Ciaian, Rajcaniova og Kancs (2016) at påvirkningen av Dow Jones Indeksen, valutakurs og oljepriser på Bitcoin-prisen ikke er signifikant i det lange løp.

### **Google søk**

Det har vært flere studier som bruker Google sin søkeaktivitet til å undersøke hvor godt det kan bli brukt til å predikere blant annet boligpriser (Kulkarni *et al.*, 2009), arbeidsledighetsraten (Askitas og Zimmermann, 2009; D'Amuri og Marcucci, 2009), private forbruksutgifter (Kholodilin, Podstawski og Siliverstovs, 2010; Vosen og Schmidt, 2011), utenlandske valuta (Smith, 2012), volum i aksjehandel og volatilitet i aksjeavkastning (Da, Engelberg og Gao, 2011; Vlastakis og Markellos, 2012). Felles enighet for disse studiene er at inkluderingen av Google sin søkeaktivitet forbedrer prediksjonsevnen i modellene.

## **Volatilitetsmodeller**

ARCH- og GARCH-modeller er et populært og mye brukt verktøy for modellering og predikering av volatilitet (Engle, 2001; Brooks, 2008, s. 381). Chu *et al.* (2017) foretok en GARCH-modellering av de daværende syv mest populære kryptovalutaene, og fant at IGARCH- og GJRGARCH-modellene ga best resultater for estimering av volatilitet. Bouoiyour og Selmi (2015; 2016) ser på volatiliteten fra et annet perspektiv. Ved bruk av optimal GARCH-modell, undersøker de om Bitcoins volatilitet har stabilisert seg eller avtatt. De finner at selv om Bitcoins volatilitet har avtatt siden januar i 2015, kan man ikke med sikkerhet konkludere om hvorvidt kryptovalutamarkedet er modent. Grunnen til dette er at asymmetrien i positive og negative sjokk fortsatt er sterk, hvorav Bitcoin-prisen er mer drevet av negative sjokk enn positive.

Oppsummering av tidligere økonomisk forskning viser at det er relativt lite forskning på kryptovaluta, og det som finnes er hovedsakelig om Bitcoin. Flere studier viser at Bitcoin-prisen er mer påvirket av sentimentale faktorer (f. eks. oppmerksomhet i media, popularitet, oppfatning) enn fundamentale økonomiske faktorer (f. eks. aksjepris, oljepris, valutakurs). Så vidt vi vet, er det få studier som benytter seg av ulike GARCH-modeller til å undersøke flere ulike kryptovaluta. Vi har heller ikke funnet studier som inkluderer flere variabler i GARCH-modeller til å undersøke hvordan volatiliteten påvirkes i ulike kryptovaluta.

### 3. Metode

Dette kapittelet gjennomgår først viktige egenskaper ved finansiell data, deretter presenteres det metodiske rammeverket som benyttes i analysen. Vi gjør rede for hvordan data har blitt innsamlet og bearbeidet, hvilke variabler som er brukt og begrunnelse for de valgte modellene i avhandlingen.

#### 3.1 Viktige egenskaper ved finansiell data

Modeller som er lineære i parameterne brukes ofte til å predikere en avhengig variabel. Men i mange tilfeller kan ikke-lineære forhold gjøres lineære ved bruk av logaritmer eller passende transformering. Dette er utfordrende med finansiell data da de har viktige egenskaper som tradisjonelle regresjonsmodeller ikke er i stand til å forklare. Disse egenskapene er blant annet (Brooks, 2008, s. 380):

- **«Leptokurtose»:** Tendens til at finansielle avkastninger har en fordeling med tykke haler og en mer spissere topp rundt forventningen enn en normalfordeling. Ved at fordelingen har tykke haler, er det større sannsynlighet for at man kan observere ekstremverdier. I tradisjonell finansiell teori forutsetter man ofte en normalfordelt avkastning, noe som har blitt bevist at ikke alltid er tilfellet (Andersen *et al.*, 2001).
- **«Volatilitetsklumping»:** Tendens til at en periode med høy (lav) volatilitet er ofte etterfulgt av en periode med høy (lav) volatilitet. En forklaring kan være at informasjonen som påvirker prisendringer ofte oppstår i perioder og ikke jevnlig fordelt (Cermak, 2017).
- **«Leverage effects»:** Tendens til at volatiliteten til et aktivum øker mer i perioder med høyt prisfall enn i perioder med høy prisstigning. Det har blitt bevist at negative sjokk ofte har en større påvirkning på volatiliteten enn positive sjokk av samme grad når det gjelder finansielle tidsserier (Black, 1976; Christie, 1982; Engle og Ng, 1993). Grunnen til dette kan være at risikostyring ofte handler om negativ avkastning som representerer framtidig tap, mens positiv avkastning gir profitt og er dermed ikke sett på som risiko (Ramasamy og Munisamy, 2012).

Mange av disse egenskapene gjelder også for kryptovalutaer. De har blant annet tidsvarierende volatilitet, ekstreme observasjoner, og asymmetrisk respons av sjokk i volatiliteten. (Catania, Grassi og Ravazzolo, 2018)

### **3.2 Kryptovaluta**

Vår analyse tar utgangspunkt i at kryptovaluta er finansielle aktiva som blir handlet til spekulasjons- og investeringsformål. Det kan enten være som en langsiktig investering i ny teknologi eller for å skape kortsiktig profitt. På bakgrunn av at det ikke eksisterer like mye data i enkelte kryptovalutaer grunnet ulike utgivelsesdatoer, setter dette naturlige begrensinger i hvilke kryptovalutaer vi har valgt å undersøke. De vi har valgt å se nærmere på er Bitcoin, Ripple, Litecoin, Ethereum og Dash.

Data er hentet fra Quandl<sup>4</sup> av den historiske globale prisindeksen i amerikanske dollar. Data er av daglig frekvens som dekker ulike perioder for kryptovalutaene grunnet ulik levetid og datatilgjengelighet. Alle periodene for kryptovalutaene ender den 28.02.2018.

### **3.3 Variabler og hypoteser**

#### **Logaritmisk avkastning**

Ved undersøkelser av tidsserier er det vanlig å studere prisendringer. Vi skal her se på den logaritmiske avkastningen som er definert som:

$$R_t = \ln\left(\frac{P_t}{P_{t-1}}\right) \quad (1)$$

Den logaritmiske avkastningen brukes som den avhengige variabelen til ligningen for forventning (se [delkapittel 3.8.1](#)). Den er kontinuerlig og gir et mer riktig bilde av reell avkastning. I tillegg gjør logaritmisk avkastning at variabelen blir stasjonær, noe som er en forutsetning for å kunne utføre hypotesetester (se [delkapittel 3.4](#)).

---

<sup>4</sup> quandl.com er en plattform som tilbyr finansiell-, makroøkonomisk- og alternativ data til analytiske formål.

## Google søkeindeks

Tidligere forskning finner at en inkludering av Google sin søkeaktivitet forbedrer prediksjonsevnen i ulike aktiva (se [kapittel 2](#)). Det antas at mindre erfarne investorer og privatpersoner investerer pengene sine i kryptovalutamarkedet. For disse er søkemotorer (f. eks. Google og Bing) ofte enklere og lettere tilgjengelig, sammenlignet med investorer i aksjemarkedet som har tilgang til ulike finansielle databaser. Hypotesen vår blir dermed:

**H<sub>1</sub>:** *Google søkeindeks øker volatiliteten i kryptovaluta.*

Vi undersøker dette ved å bruke en proxy for etterspørsel etter informasjon. Proxien representerer totale Google søkeord for hver av kryptovalutaene, og vi kaller denne GSI. Data er i form av en indeks og hentet fra Google Trends<sup>5</sup>. I indeksen er den høyeste verdien i perioden 100 og den laveste er 1. Daglige konsistente tall av GSI-variabelen har blitt hentet ut ved en spesiell teknikk adoptert fra Chronopoulos, Papadimitriou og Vlastakis (2017). Den går ut på at data hentes ut for 90 dagers intervaller fra forskjellige tidsperioder, før disse blir satt sammen til én tidsserie etter at de er lastet ned. Data blir da skalert riktig i forhold til hverandre slik at det i løpet av tidsperioden kun er én dag som har score på 100.

Det er viktig å velge søkeord som er relevante for vårt formål og som gir den informasjonen vi er ute etter. Det kan derfor være mest naturlig å velge enten tickeren eller navnet på kryptovalutaen. Da, Engelberg og Gao (2011) argumenterer for at en ticker kan være beste alternativ siden søk på navn kan forekomme av andre årsaker enn investeringsgrunner. De skriver også at det er flere måter å skrive et selskapsnavn på, spesielt for de som ikke er kjent med aktivumet. Vi mener at dette kan stemme med etablerte aktiva, men at kryptovaluta er et relativt nytt fenomen der mange, kanskje mindre erfarne investorer, investerer. Vi har derfor valgt ut søkeord på bakgrunn av prosessen som er brukt i Chronopoulos, Papadimitriou og Vlastakis (2017). Den går ut på at man legger inn navnet på en indeks eller en valuta og sjekker ut alle lignende søk foreslått av Google Trends. Etter å ha sjekket flere av dem, har vi kommet frem til at «Bitcoin», «Ethereum», «Ripple», «Litecoin» og «Dash coin» passet best på bakgrunn av at søkeordene hadde høyest volum. Søkeordet til Dash måtte bli ytterligere spesifisert på grunn av mye irrelevante søkeresultater med kun «Dash».

---

<sup>5</sup> trends.google.com tilbyr muligheten til å få tilgang til statistikk på ethvert søkeord på Google sin søkemotor.

For å fange opp endringen i antall Google søk, blir variabelen for Google søkeindeksen videre definert som differansen til GSI i nåværende periode  $t$  og foregående periode  $t - 1$ :

$$\Delta GSI_t = GSI_t - GSI_{t-1} \quad (2)$$

Kryptovaluta	Ticker	Søkeord
Bitcoin	BTC	«Bitcoin»
Ethereum	ETH	«Ethereum»
Ripple	XRP	«Ripple»
Litecoin	LTC	«Litecoin»
Dash	DASH	«Dash coin»

Tabell 1: Oversikt over kryptovalutaer med tilhørende ticker og søkeord.

## Historiske begivenheter og kunngjøringer

Historiske begivenheter og kunngjøringer kan ha påvirkning på prisen til Bitcoin (Meland og Øyen, 2017). På bakgrunn av dette tror vi at dette kan ha påvirkning på volatiliteten til kryptovaluta generelt, og inkluderer dermed variabler for positive og negative begivenheter og kunngjøringer i modellene. Hypotesen blir dermed:

**H<sub>2</sub>:** *Historiske begivenheter og kunngjøringer øker volatiliteten i kryptovaluta.*

Data er hentet inn manuelt fra 99Bitcoins.com<sup>6</sup>, og perioden er tilpasset for de forskjellige kryptovalutaene. Begivenhetene og kunngjøringene er hovedsakelig om Bitcoin, men de fleste dreier seg også generelt om kryptovaluta. Eksempler er nyheter om lov- og skattereguleringer av kryptovalutahandel i Kina, Sør-Korea og USA, sikkerhetsbrudd på ulike handelsplattformer og bankkrisen på Kypros. Vi antar i vår analyse at begivenheter og kunngjøringer om Bitcoin også påvirker de andre kryptovalutaene.

De historiske variablene er representert ved to binære dummyvariabler. Vi har en dummy for begivenheter og kunngjøringer som forventes å påvirke positivt på de ulike kryptovalutaene («positive sjokk»), og en dummy for begivenheter og kunngjøringer som forventes å påvirke negativt på de ulike kryptovalutaene («negative sjokk»). Her er 1 brukt for perioder hvor begivenheter og kunngjøringer finner sted, og 0 for ingen begivenheter og kunngjøringer.

<sup>6</sup> <https://99bitcoins.com/price-chart-history/>

## Volatilitetsindeks

Bouri *et al.* (2017) fant at det var en negativ korrelasjon mellom volatiliteten i Bitcoin og VIX-indeksen. Vi vil dermed undersøke om volatiliteten i kryptovalutamarkedet blir påvirket av volatiliteten i aksjemarkedet. Hypotesen blir dermed:

**H3:** *Økt forventet volatilitet i aksjemarkedet gir redusert volatilitet i kryptovaluta.*

Vi undersøker dette ved å inkludere en variabel for CBOE volatilitetsindeks, også kalt VIX-indeksen. Den måler markedets forventninger om framtidig volatilitet. VIX-indeksen er basert på opsjoner i S&P 500 Indeksen og sett på som en av de beste representasjonene av det amerikanske finansmarkedet (Cboe, u.å.).

Daglige data er hentet fra Yahoo Finance<sup>7</sup>, og er for ulike perioder avhengig av de forskjellige kryptovalutaene. Observasjoner for VIX-indeksen er ikke tilgjengelig for lørdager, søndager og helligdager. Dermed har vi foretatt en lineær interpolering for å fylle inn for manglende observasjoner. Variabelen for VIX-indeksen er definert i ligning 3:

$$\Delta VIX_t = VIX_t - VIX_{t-1} \quad (3)$$

### «Leverage effects»

Abdalla (2012) beviste at «leverage effects» kan forekomme i valutaavkastninger, mens Kisinbay (2010) kun avdekket asymmetriske effekter i aksjeavkastninger. Derimot fant Catania, Grassi og Ravazzolo (2018) at mer sofistikerte volatilitetsmodeller som inkluderer en asymmetrisk reaksjon av volatilitetsprosessen kan forbedre volatilitetsprediksjoner av kryptovaluta. Med bakgrunn i dette og at kryptovaluta er finansielle aktiva som blir handlet til spekulasjons- og investeringsformål, vil vi undersøke om volatiliteten i kryptovaluta responderer asymmetrisk til positive og negative sjokk. Hypotesen blir dermed:

**H4:** *Det finnes «leverage effects» i kryptovaluta.*

Vi undersøker dette ved å benytte oss av de asymmetriske GARCH-modellene, EGARCH og GJR-GARCH, sammenlignet med en standard GARCH-modell.

---

<sup>7</sup> <https://finance.yahoo.com/quote/%5EVIX/history?p=%5EVIX>



## Tilpasning av modellen

Chronopoulos, Papadimitriou og Vlastakis (2017) fant at implementeringen av variabelen for Google søk forbedrer estimeringen og predikeringen av volatilitet i aksjeavkastninger. Vi vil derfor undersøke om vi kommer frem til lignende resultat ved å implementere flere variabler som Google søkeindeks og VIX-indeks, samt positive og negative sjokk. Hypotesen vår blir dermed:

*H<sub>5</sub>: Implementering av variabler forbedrer tilpasningen i modellen.*

Vi undersøker dette ved å sammenligne de ulike GARCH-modellene med og uten de inkluderte variablene. Mål som blir brukt til evaluering av modellene blir AIC og BIC (se [delkapittel 3.9](#)).

## 3.4 Stasjonaritet

Forutsetningen for stasjonaritet i variablene er viktig innenfor analyse av tidsseriedata for å kunne utføre hypotesetester. Bruk av ikke-stasjonære variabler kan gi spuriøse sammenhenger. Det vil si at to observerte variabler kan vise en sammenheng uten at det virkelig eksisterer og at det dermed er en falsk sammenheng. Årsaken kan være en bakenforliggende variabel, og man kan dermed ikke påstå at en endring i den ene variabelen forårsaker endring i den andre variabelen (kausalt forhold). Variabler er stasjonære dersom de statistiske egenskapene, som gjennomsnitt, varians og autokovarians, er stabile over tid (Brooks, 2008, s. 318-320).

### Augmented Dickey-Fuller (ADF) test

Vi tester for stasjonaritet ved å bruke en utvidelse av Dickey-Fuller test (Brooks, 2008, s. 329). En forutsetning for Dickey-Fuller testen er at  $u_t$  er hvit støy. Dette betyr at variabelen har et konstant gjennomsnitt og varians, og ingen autokorrelasjon. Ved autokorrelasjon vil testen være overdimensjonert og den sanne størrelsen til testen blir høyere enn den nominale størrelsen brukt. Dermed bruker vi en utvidelse av Dickey-Fuller testen som sørger for at  $u_t$  ikke er autokorrelert. Dette gjøres ved å legge på  $p$  tidsforskjøvne verdier av  $\Delta R_t$  for å fange autokorrelasjon i den avhengige variabelen. For enkelthets skyld fokuserer vi kun på Augmented Dickey-Fuller (ADF) test.

Her testes nullhypotesen,  $H_0$ , for ikke-stasjonaritet i serien mot alternativhypotesen,  $H_1$ , for stasjonaritet i serien. Testobservatoren er gitt ved:

$$T = \frac{\psi}{SE(\hat{\psi})} \sim DF\text{-fordeling} \quad (4)$$

Nullhypotesen,  $H_0$ , forkastes dersom T-verdien er lavere enn kritisk verdi og data tyder da på at serien er stasjonær.

### 3.5 Normalitet

Ved å teste for normalitet undersøker man om variablene og/eller residualene er normalfordelte. Dette er viktig for statistisk inferens og for om andre metoder bør benyttes (Jarque og Bera, 1987).

#### Jarque-Bera (JB) test

For å sjekke om avkastningen til kryptovalutaene og om de standardiserte residualene er normalfordelte, benytter vi oss av Jarque-Bera (JB) normalitetstest (Jarque og Bera, 1987). Den er en kombinert test av kurtose og skjevhet, hvor  $S = 0$  og  $K \leq 3$  ved normalfordeling. Jo nærmere JB er null, desto nærmere kommer man antagelsen om normalfordeling.

Her testes nullhypotesen,  $H_0$ , for normalfordeling mot alternativhypotesen,  $H_1$ , for ingen normalfordeling. Testobservatoren er gitt ved:

$$JB = \frac{T - k}{6} \left( S^2 + \frac{(K - 3)^2}{4} \right) \sim \chi_{(2)}^2 \quad (5)$$

Hvor  $T$  er antall observasjoner,  $k$  er antall estimerte parametere,  $S$  er skjevhet og  $K$  er kurtose. Nullhypotesen,  $H_0$ , forkastes dersom testobservatoren,  $JB$ , er større enn den kritiske verdien fra  $\chi_{(2)}^2$ -fordelingen.

### 3.6 Autokorrelasjon

Autokorrelasjon er et statistisk begrep som brukes for å beskrive samvariasjonen mellom feilleddene. Ved autokorrelasjon er feilleddene avhengige av hverandre og man bør spesifisere en modell som fjerner korrelasjonen. Vi vil med andre ord at feilleddet på tidspunkt  $t$  skal være

uavhengig av feilleddet på tidspunkt  $t - 1$ . Ifølge Hull (2012, s. 508) vil en velfungerende GARCH-modell fjerne autokorrelasjon, og man kan teste dette ved å undersøke autokorrelasjonsstrukturen til de standardiserte residualene definert som  $\varepsilon_i^2/\sigma_i^2$ .

### Ljung-Box test

For å teste for autokorrelasjon kan vi benytte oss av en Ljung-Box test (Ljung og Box, 1978). Her testes nullhypotesen,  $H_0$ , for ingen autokorrelasjon mot alternativhypotesen,  $H_1$ , for autokorrelasjon. Testobservatoren er gitt ved:

$$Q_k = T(T + 2) \sum_{i=1}^k \frac{\tau_k^2}{T - k} \sim \chi_k^2 \quad (6)$$

Hvor  $T$  er antall i utvalget,  $k$  er antall lag,  $\tau_k$  er autokorrelasjon i tidspunkt  $k$  og testobservatoren er kjikvadratfordelt. Nullhypotesen,  $H_0$ , forkastes dersom testobservatoren,  $Q_k$ , er større eller lik den kritiske verdien fra  $\chi^2$ -fordelingen. Data tyder da på autokorrelasjon i restleddene.

### 3.7 ARCH-effekter

Ved estimering av parameterne med GARCH-modeller, er det en forutsetning med ARCH-effekter i residualene. Dette er tilfellet i modellen dersom en tidsserie innehar betinget heteroskedastisitet. ARCH-effekter kan indikere feilspesifikasjon i modellen enten ved at viktige variabler er utelatt eller gjennom strukturendringer (Engle, 1982).

### Engle's ARCH test

For å teste om vi har ARCH-effekter, benytter vi oss av Engle's ARCH test. Her testes nullhypotesen,  $H_0$ , for ingen ARCH-effekter mot alternativhypotesen,  $H_1$ , for ARCH-effekter. Testobservatoren er gitt ved:

$$TR^2 \sim \chi^2(q) \quad (7)$$

Hvor  $T$  er antall observasjoner,  $R^2$  er koeffisienten av flere korrelasjoner og testobservatoren er kjikvadratfordelt. Nullhypotesen,  $H_0$ , forkastes dersom testobservatoren er større enn den kritiske verdien fra  $\chi^2$ -fordelingen. Data tyder da på at modellen har ARCH-effekter.

### **3.8 Volatilitetsmodeller**

Volatilitetsmodeller beskriver utviklingen av den betingede variansen,  $\sigma_t^2$ . Volatilitet blir da en funksjon av et gitt sett med variabler (Jondeau, Poon og Rockinger, 2007, s. 80). For å forklare egenskapene for finansielle data beskrevet i [delkapittel 3.1](#), vil ikke-lineære modeller være bedre enn lineære modeller. I tradisjonelle regresjonsmodeller antar man at variansen til feilledet er konstant og ikke vil variere over tid (homoskedastisk). Dette er ofte ikke tilfellet ved finansielle avkastningsdata, hvor restleddet ikke har konstant varians (heteroskedastisk). Grunnen til dette er at mange økonomiske tidsserier har perioder med unormalt høy volatilitet etterfulgt av relativt rolige perioder (Brooks, 2008, s. 386).

Generelt er ARCH- og GARCH-modeller i bedre stand til å fange opp egenskaper som finansielle data innehar enn tradisjonelle regresjonsmodeller. Dermed er det et av de mest populære verktøyene for å modellere og predikere volatilitet (Engle, 2001; Brooks, 2008, s. 381). Allikevel har ARCH-modellen, som først var presentert av Robert Engle (1982), flere utfordringer som gjør den lite anvendbar i praksis. Dermed har den dannet grunnlag for senere utvikling av ulike varianter og utvidelser av modellen.

Vi benytter oss hovedsakelig av GARCH(1,1)-, EGARCH(1,1)- og GJRARCH(1,1)-modellene til å modellere volatiliteten. Hovedforskjellen mellom de ulike modellene er at standard GARCH-modell er symmetrisk, mens EGARCH- og GJRARCH-modellen er asymmetriske. Det vil si at GARCH-modellen ikke tar hensyn til en asymmetrisk respons av volatilitet på sjokk, mens EGARCH- og GJRARCH-modellen gjør det. Vi har dermed kun benyttet oss av ett lag for p og q. Ifølge Hansen og Lunde (2005) vil beste modell med andre lags av p og q ikke nødvendigvis prestere signifikant bedre enn en GARCH(1,1)-modell.

#### **3.8.1 Generalised ARCH (GARCH)**

GARCH-modellen ble introdusert av Bollerslev (1986) og Taylor (1986). Den er en utvidelse av ARCH-modellen ved at den i tillegg til heteroskedastisk volatilitet, fanger opp volatilitetsklumping. Dette gjøres ved at volatiliteten i nåværende periode  $t$  er avhengig av både forrige perioders volatilitet og forrige perioders kvadrerte forventningskorrigerede avkastninger.

GARCH-modeller består av to likninger: en for betinget forventning (se likning 10) og en for betinget varians. Vi har inkludert et autoregressivt (AR(1)) ledd for å ta høyde for at avkastningene kan være autokorrelerert (Alexander, 2008, s. 136). I denne avhandlingen vil likningen for betinget forventning være lik for de ulike modellene.

For å forstå den grunnleggende oppbyggingen definerer vi først den generelle formen av en GARCH(p,q)-modell, gitt ved:

$$\sigma_t^2 = \omega + \sum_{i=1}^p \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^q \beta_j \sigma_{t-j}^2 \quad (8)$$

Hvor  $p$  er antall lag av kvadrert residual avkastning,  $q$  er antall tidligere kvadrerte feilledd som inkluderes i modellen,  $\sigma_t^2$  er den betingede variansen i nåværende periode,  $\omega$  er vektet gjennomsnittlig varians i det lange løp,  $\alpha$  er et mål på hvor stor påvirkning et sjokk har på volatiliteten (ARCH-effekt),  $\varepsilon_{t-i}^2$  er kvadrert residual avkastning i periode  $t - i$ ,  $\beta$  er et mål på hvor vedvarende tidligere sjokk er på volatiliteten (GARCH-effekt) og  $\sigma_{t-i}^2$  er varians i periode  $t - i$ .

Her er den betingede variansen avhengig av tidligere ledd (antall  $q$ ), og alle sjokk fra  $\varepsilon_{t-1}^2$  til  $\varepsilon_{t-q}^2$  påvirker  $\sigma_t^2$  direkte (Enders, 2015, s. 128). Forutsetninger for en gyldig modell er positiv betinget varians og stasjonaritet i variablene (se [delkapittel 4.2](#)). I tillegg må residualen være betinget heteroskedastisk og ARCH-effekter (se [delkapittel 4.5](#)) må være tilstede. Parameterne må tilfredsstillende følgende restriksjoner:  $p \geq 0, q > 0, \omega > 0, \alpha_i \geq 0, i = 1, \dots, p, \beta_j \geq 0, \text{ for } j = 1, \dots, q$  (Bollerslev, 1986).

En høy  $\alpha$ -verdi (eksempelvis over 0,1) betyr at volatiliteten er sensitiv mot markedssjokk og modellen reagerer raskt på store bevegelser i tidsserien. En høy  $\beta$ -verdi (eksempelvis over 0,9) betyr at det tar lenger tid før sjokk i den betingede volatiliteten «dør ut» etter en krise i markedet (Alexander, 2008, s. 137).

Videre kan vi i enkleste form definere GARCH(1,1)-modellen som:

$$\sigma_t^2 = \omega + \alpha \varepsilon_{t-1}^2 + \beta \sigma_{t-1}^2 \quad (9)$$

Her er den betingende variansen en funksjon av vektet gjennomsnittlig varians i det lange løp ( $\omega$ ), kvadrert residual avkastning i forrige periode ( $\varepsilon_{t-1}^2$ ) og varians i forrige periode ( $\sigma_{t-1}^2$ ). Parameterne må tilfredsstille følgende restriksjoner:  $\omega > 0, \alpha \geq 0, \beta \geq 0$  og  $\alpha + \beta < 1$  (Bollerslev, 1986).

På grunn av dens simpelhet, har GARCH(1,1)-modellen vært mye brukt til å estimere volatilitet i finans (Hansen og Lunde, 2005). Allikevel er en av svakhetene til GARCH-modeller at de kun kan anta hvordan størrelsen av et sjokk påvirker volatiliteten. Den er ikke i stand til å ta hensyn til asymmetriske effekter. De laggede leddene i ligningen for den betingede variansen er kvadrert og viser dermed at positive sjokk og negative sjokk har lik påvirkning på den betingede variansen.

For å studere om prediksjonen av volatilitet kan forbedres, utvider vi GARCH-modellen til en GARCH(V)-modell ved å inkludere variablene for Google søkeindeksen, positive og negative sjokk og VIX-indeksen:

$$R_t = a + bR_{t-1} + \varepsilon_t \quad (10)$$

$$\begin{aligned} \sigma_t^2 = \omega + \beta \sigma_{t-1}^2 + \alpha \varepsilon_{t-1}^2 + \delta \Delta GSI_t + \rho d. \text{positivtsjokk} \\ + \vartheta d. \text{negativtsjokk} + \phi \Delta VIX_t \end{aligned} \quad (11)$$

### 3.8.2 GJRGARCH

GJRGARCH-modellen ble introdusert av Glosten, Jagannathan og Runkle (1993). Den er en utvidelse av den grunnleggende GARCH-modellen med et ekstra ledd for asymmetri i variansen.

GJRGARCH(1,1)-modellen er gitt ved:

$$\sigma_t^2 = \omega + \alpha \varepsilon_{t-1}^2 + \beta \sigma_{t-1}^2 + \gamma \varepsilon_{t-1}^2 I_{t-1} \quad (12)$$

Hvor  $\sigma_t^2$ ,  $\omega$ ,  $\alpha$ ,  $\varepsilon_{t-i}^2$ ,  $\beta$  og  $\sigma_{t-i}^2$  er definert på samme måte som i GARCH-modellen. Den store forskjellen er  $\gamma$  som er en parameter for asymmetrieffekter.

Dersom  $\gamma > 0$ , betyr det at sjokk har en asymmetrisk effekt på volatilitet, og at positive sjokk påvirker volatiliteten mer enn det negative sjokk gjør. Dette er normalt ved råvareavkastning. Dersom  $\gamma < 0$ , øker volatilitet mer ved negative sjokk enn positive sjokk («leverage effects»). Dette er normalt ved aksjeavkastning. Dersom  $\gamma = 0$ , betyr det at positive og negative sjokk har lik påvirkning på volatiliteten, og modellen er symmetrisk (Brooks, 2008, s. 406).

I tillegg har vi  $I_{t-1}$  som er en dummyvariabel som kun aktiveres dersom tidligere sjokk er negative. Vi har at:  $I_{t-1} = 1$  hvis  $\varepsilon_{t-1} < 0$  og  $I_{t-1} = 0$  hvis  $\varepsilon_{t-1} \geq 0$  (Glosten, Jagannathan og Runkle, 1993). I likhet med svakheter i GARCH-modellen, må betingelsen for ikke-negativitet være oppfylt for en gyldig GJR-GARCH-modell slik at:  $\omega \geq 0$ ,  $\alpha \geq 0$ ,  $\beta \geq 0$  og  $\alpha + \gamma \geq 0$ . Disse betingelsene har blitt kritisert av Nelson og Cao (1992) som for strengt.

I likhet med GARCH-modellen, utvider vi GJR-GARCH-modellen til en GJR-GARCH(V)-modell ved å inkludere variablene for Google søkeindeksen, positive og negative sjokk og VIX-indeksen i funksjonen for varians:

$$R_t = a + bR_{t-1} + \varepsilon_t \quad (13)$$

$$\begin{aligned} \sigma_t^2 = & \omega + \beta\sigma_{t-1}^2 + \alpha\varepsilon_{t-1}^2 + \gamma\varepsilon_{t-1}^2 I_{t-1} + \delta\Delta GSI_t + \rho d. posny \\ & + \vartheta d. negny + \phi\Delta VIX \end{aligned} \quad (14)$$

### 3.8.3 Exponential GARCH (EGARCH)

EGARCH-modellen ble introdusert av Nelson (1991) for å forbedre to aspekter av GARCH-modellen. For det første, begrenser den ikke parameterne for å sikre positiv varians. For det andre, foreslår den en asymmetrisk respons av volatilitet på sjokk. EGARCH-modellen sier altså både noe om fortegnseffekter og nivå av persistens på volatilitet ved sjokk (Dutta, 2014).

EGARCH(1,1)-modellen er gitt ved:

$$\ln(\sigma_t^2) = \omega + \beta \ln(\sigma_{t-1}^2) + \gamma \frac{\varepsilon_{t-1}}{\sqrt{\sigma_{t-1}^2}} + \alpha \left[ \frac{|\varepsilon_{t-1}|}{\sqrt{\sigma_{t-1}^2}} - \sqrt{\frac{2}{\pi}} \right] \quad (15)$$

Hvor  $\sigma_t^2$ ,  $\omega$ ,  $\alpha$ ,  $\varepsilon_{t-i}^2$ ,  $\beta$  og  $\sigma_{t-i}^2$  er definert på samme måte som i GARCH-modellen. I likhet med GJRARCH-modellen, tar EGARCH-modellen også hensyn til asymmetrieffekter med parameteren  $\gamma$ . «Leverage effects» er tilstede dersom  $\gamma > 0$ . Modellen er symmetrisk dersom  $\gamma = 0$ .

Her blir den naturlige logaritmen av den betingede variansen modellert, og modellen har dermed ingen restriksjoner på parameterne som sørger for at den betingede variansen er positiv slik som de andre nevnte modellene.

EGARCH-modellen har flere fordeler i forhold til GARCH-modellen. For det første, vil negative parametere fortsatt gjøre  $\sigma_t^2$  positiv på grunn av at vi modellerer  $\ln(\sigma_t^2)$ . Dermed er det ikke nødvendig med betingelsen for ikke-negativitet slik GARCH har. For det andre, tar EGARCH-modellen hensyn til asymmetriske effekter, i motsetning til ARCH- og GARCH-modellen som går ut i fra at negative og positive sjokk gir samme effekt på volatiliteten. Duan (1997) argumenterer for at forskjellen mellom EGARCH og GJRARCH ligger i at volatilitetssjokket som inngår i tidsserien er additivt for EGARCH, men multiplikativt for GJRARCH.

På samme måte som de andre modellene, utvider vi EGARCH-modellen til en EGARCH(V)-modell ved å inkludere variablene for Google søkeindeksen, positive og negative sjokk og VIX-indeksen i funksjonen for varians:

$$R_t = a + bR_{t-1} + \varepsilon_t \quad (16)$$

$$\begin{aligned} \ln(\sigma_t^2) = & \omega + \beta \ln(\sigma_{t-1}^2) + \gamma \frac{\varepsilon_{t-1}}{\sqrt{\sigma_{t-1}^2}} + \alpha \left[ \frac{|\varepsilon_{t-1}|}{\sqrt{\sigma_{t-1}^2}} - \sqrt{\frac{2}{\pi}} \right] + \delta \Delta GSI_t \\ & + \rho d. \text{positivtsjokk} + \vartheta d. \text{negativtsjokk} + \phi \Delta VIX_t \end{aligned} \quad (17)$$



### ***3.9 Evaluering av modellene***

Det er flere evalueringsmål som kan brukes til å evaluere modellene. Vi har benyttet oss av informasjonskriteriene: Akaike Information Criterion (AIC) og Bayesian Information Criterion (BIC) uttrykt som følgende (Akaike, 1974; Schwarz, 1978):

$$AIC = -2l/T + 2k/T \quad (18)$$

$$BIC = -2(l/T) + k \log(T)/T \quad (19)$$

Hvor  $l$  er verdien av log likelihood funksjonen,  $k$  er antall parametere og  $T$  er antall observasjoner.


Infomasjonskriteriene er «goodness of fit»-mål som brukes til å sammenligne kvaliteten av en modell i forhold til en annen modell. De kan være både positiv og negativ, og modellen med lavest verdi er best tilpasset. Det er ingen av kriteriene som dominerer den andre, men BIC pålegger en større straff for modeller med flere parametere (Brooks, 2008, s. 233).

## 4. Empiriske resultater

I kapittel 3 så vi hvordan vi har fremskaffet data og hvordan denne er bearbeidet før analysen. I dette kapittelet vil vi se nærmere på resultatene for de forskjellige kryptovalutaene.

### 4.1 Bitcoin (BTC)

Datasettet til Bitcoin består av 1520 daglige observasjoner hentet i perioden 01.01.2014 til 28.02.2018. Som vi ser i figur 1 har Bitcoin hatt en ganske turbulent utvikling i perioden. Rett før årsskiftet 2017/2018 nådde prisen sin «all time high» på nesten 20 000 USD. I ettertid har valutaen hatt en negativ trend og falt betraktelig fra toppen. Det er stor spredning i avkastningene i perioden og vi kan tydelig se volatilitetsklumpingen som ofte kjennetegnes fra finansielle avkastningsserier.



Figur 1: Utvikling i pris og log-avkastning for Bitcoin/USD.

### Deskriptiv statistikk

Tabell 2 viser deskriptiv statistikk for log-avkastningen til Bitcoin,  $\Delta GSI_t$  og  $\Delta VIX_t$ . Samtlige variabler har høye verdier av skjevhet og kurtose. Dette tyder på det er leptokurtiske karakteristikk i variablene, som betyr at fordelingen har tykkere haler og er spissere rundt forventningen. Det er da større sannsynlighet for å observere ekstremverdier. Vi kan se at log-avkastningen til Bitcoin har negativ skjevhet, noe som betyr at halen på venstre side av gjennomsnittet er lengre, se [vedlegg 1A](#). Det vil da være større sannsynlighet for negative avkastninger enn hvis data hadde vært symmetrisk. Dette er indikasjoner på at data ikke er normalfordelt, noe som i utgangspunktet er ønskelig.

Til slutt undersøker vi variablene grundigere med Jarque-Bera test for normalitet. Testen viser at alle variabler er signifikante på 1% nivå og vi forkaster nullhypotesen om normalfordelte data.

Ikke-normalitet er et relativt vanlig fenomen for finansielle avkastningsserier. For eksempel kan aksjemarkeder ha store fall, men ikke like store hopp oppover.

	BTC	$\Delta GSI_t$	$\Delta VIX_t$
Gjennomsnitt	0,0017	0,0079	0,0121
Median	0,0007	0,0000	0,0133
Standard avvik	0,0408	2,9261	1,1438
Skjevhet	-0,4001	3,5310	1,9638
Kurtose	8,4461	129,3144	2748791
JB	1917,74***	1013661,00***	38955,34***
ADF	-40,0480***	-9,8387***	-36,8049***

Tabell 2: Deskriptiv statistikk for Bitcoin.

\* Signifikant på 10% nivå    \*\* Signifikant på 5% nivå    \*\*\*Signifikant på 1% nivå

Videre er testverdiene for Augmented Dickey-Fuller test signifikante på 1% nivå, og vi forkaster nullhypotesen om ikke-stasjonaritet. Da vi undersøkte de standardiserte residualene ved estimering av parameterne i GARCH-modellene oppdaget vi at de heller ikke var normalfordelte. Ifølge Bollerslev (1987) vil GARCH-modeller derfor nødvendigvis ikke fange opp leptokurtosen i finansielle tidsserier godt nok og at Student's t fordeling kan fange opp denne bedre. På bakgrunn av dette har vi derfor valgt å benytte oss av Student's t fordeling videre i oppgaven.

### Ljung-Box - og Engle's ARCH test

I [vedlegg 1B](#) ser vi Ljung-Box test og Engle's ARCH test for henholdsvis autokorrelasjon og ARCH-effekter. I Ljung-Box testen er p-verdier for lag 5 og 10 mindre enn 0,10 og vi forkaster derfor nullhypotesen om ingen autokorrelasjon. I ARCH-testen er alle p-verdier mindre enn 0,01, og vi forkaster dermed nullhypotesen om ingen ARCH-effekter. Data tyder dermed på at det eksisterer autokorrelasjon og betinget heteroskedastisitet i restleddet.

### Modellestimatene

I tabell 3 kan vi observere estimatene for de tre GARCH-modellene estimert med Student's t fordeling. Estimatene er kalkulert med og uten variabler for Google søk og VIX-indeksen, samt positive og negative sjokk. Symbolet (V) under navnet på modellen, indikerer modellen med variabler.

	GARCH	GARCH (V)	GJRGARCH	GJRGARCH (V)	EGARCH	EGARCH (V)
C	0,001435***	0,001598***	0,001505**	0,001593***	0,001492***	0,001497***
AR (1)	-0,043941**	-0,041974*	-0,046693**	-0,041841*	-0,049353**	-0,051801**
$\omega$	0,000022**	0,000029***	0,000021**	0,000029***	-0,331623***	-0,329334***
$\alpha$	0,249954***	0,168569***	0,281074***	0,166194***	0,368949***	0,308882***
$\gamma$			-0,062573	0,003814	0,020541	0,016991
$\beta$	0,856279***	0,858449***	0,858485***	0,858582***	0,979819***	0,9779136***
$\Delta GSI_t$		0,000243***		0,000243***		0,047110***
Positivt sjokk		0,000335		0,000344		0,381062
Negativt sjokk		0,004150*		0,004131*		0,790941**
$\Delta VIX_t$		0,000020		0,000020		0,049692*
ARCH	0,663602	0,227637	0,986610	0,215008	1,653236	3,340064*
Q (5)	3,8875	2,8989	4,3063	2,8733	4,6060	5,5208
Jarque-Bera	2813,919***	2254,803***	2866,907***	2254,991***	2733,156***	1772,989***

Tabell 3: Parameterestimer for Bitcoin.

\* Signifikant på 10% nivå \*\* Signifikant på 5% nivå \*\*\*Signifikant på 1% nivå

$\Delta GSI_t$ -variabelen er positiv og statistisk signifikant for alle modellene. Dette indikerer at Google søk har signifikant påvirkning på den betingende variansen i Bitcoin. Dette er i overensstemmelse med hypotese  $H_1$  om at Google søk øker volatiliteten. Denne variabelen kan dermed gi nyttig informasjon for variasjonen i markedet. Videre er dummyvariabelen for negative sjokk positiv og signifikant for alle modeller på 5% og 10% nivå. Dette gir en indikasjon på at negative sjokk øker den betingede variansen i Bitcoin og er i overensstemmelse med hypotese  $H_2$ . Derimot er positive sjokk ikke signifikant, noe som samlet sett indikerer at negative nyheter er mer destabiliserende enn positive nyheter. Til slutt er  $\Delta VIX_t$ -variabelen positiv og signifikant på 10% nivå for EGARCH(V)-modellen. Det kan tolkes som at høyere forventet volatilitet i aksjemarkedet øker den betingede variansen i Bitcoin. Dette strider imot hypotese  $H_3$ .

### Diagnostikk av modellene

For at GARCH-modellene skal gi valide resultater undersøker vi først om de standardiserte residualene, definert som  $u_t/\sigma_t^2$  har fanget opp det meste av ARCH-effektene. Vi tester deretter for gjenværende autokorrelasjon. I tabell 3 observerer vi at de fleste modellene fanger opp det meste av ARCH-effektene. Dette gjelder imidlertid ikke EGARCH(V)-modellen der vi

fremdeles har påvist ARCH-effekter. Dette vil dermed ikke være en god modell. Til slutt ser vi at autokorrelasjonen har blitt fjernet for samtlige modeller.

### Evaluering av modellene


Tabell 4 viser oversikt over informasjonskriteriene for GARCH-modellene. Ved undersøkelse av hvor godt modellene er tilpasset i henhold til kriteriene AIC og BIC, blir de fleste forbedret når vi inkluderer variabler for Google søk, VIX-indeksen, samt positive og negative sjokk. For EGARCH-modellen blir BIC imidlertid lavere enn modellen med variabler. AIC er lavest (mest negativ) for GARCH(V)-modellen og BIC er lavest for EGARCH-modellen.

	GARCH	GARCH (V)	GJRGARCH	GJRGARCH (V)	EGARCH	EGARCH (V)
AIC	-4,104848	<b>-4,125893</b>	-4,104362	-4,124580	-4,106221	-4,116946
BIC	-4,083800	-4,090813	-4,079806	-4,085992	<b>-4,097079</b>	-4,078358
LL	3121,580	3141,553	3122,211	3141,556	3123,622	3135,762

Tabell 4: AIC og BIC for GARCH-modellene i Bitcoin.

## 4.2 Ethereum (ETH)

Datasettet for Ethereum består av 912 daglige observasjoner hentet i perioden 01.09.2015 til 28.02.2018. Vi ser også her volatilitetsklumping i log-avkastningene. Ethereum nådde sin høyeste verdi rundt samme periode som Bitcoin.



Figur 2: Utvikling i pris og log-avkastningen til Ethereum/USD.

## Deskriptiv statistikk

Tabell 5 under viser deskriptiv statistikk av log-avkastningene for ETH,  $\Delta GSI_t$  og  $\Delta VIX_t$ .

Alle variabler har høye verdier av skjevhet og kurtose. I likhet med Bitcoin har også Ethereum tykker haler og er mer spiss rundt forventningen. Log-avkastningen til Ethereum har, i motsetning til Bitcoin, positiv skjevhet. Dette betyr at halen på høyre side av gjennomsnittet er lengre. Det vil da være større sannsynlighet for positive avkastninger enn hvis data hadde vært symmetrisk, se [vedlegg 2A](#). Jarque-Bera testen er signifikant, og vi forkaster nullhypotesen om normalfordeling. Videre forkaster vi nullhypotesen om ikke-stasjonaritet i alle variablene.

	ETH	$\Delta GSI_t$	$\Delta VIX$
Gjennomsnitt	0,0071	0,0197	0,0202
Median	0,0000	0,0000	0,0100
Standard avvik	0,0700	4,1163	1,5010
Skjevhet	0,2690	0,9348	10,1979
Kurtose	6,1980	20,0042	210,0056
JB	399,1900***	11120,21***	1644158***
ADF	-28,9081***	-23,7307***	-43,7490***

Tabell 5: *Deskriptiv statistikk av Ethereum.*

\* Signifikant på 10% nivå    \*\* Signifikant på 5% nivå    \*\*\* Signifikant på 1% nivå

## Ljung-Box - og Engle's ARCH test

Ljung-Box testen viser at p-verdien for lag 20 og 40 er mindre enn 0,05, og vi forkaster dermed nullhypotesen om ingen autokorrelasjon. Videre er ARCH-testen signifikant på 1% nivå for alle lags. Testen gir støtte for at det eksisterer signifikant autokorrelasjon og betinget heteroskedastisitet i restleddet, se [vedlegg 2B](#).

## Modellestimatene

Tabell 6 under viser estimatene for de tre GARCH-modellene. Estimatene er kalkulert med og uten variablene for Google søk og VIX-indeksen, samt positive og negative sjokk.

$\Delta GSI_t$ -variabelen er positiv og statistisk signifikant for alle modellene. Det er i overensstemmelse med hypotese  $H_1$  om at Google søk øker den betingede variansen i Ethereum. Det er samme resultat som vi fikk i Bitcoin. Videre er  $\Delta VIX_t$ -variabelen positiv og signifikant på 10% nivå for EGARCH(V)-modellen. Ellers er det resterende variabler ikke signifikante for noen av modellene.

	GARCH	GARCH (V)	GJRGARCH	GJRGARCH (V)	EGARCH	EGARCH (V)
C	0,001361	0,001318	0,000756	0,001933	0,000792	0,000677
AR (1)	-0,009476	-0,034710	-0,011220	-0,005176	-0,020434	-0,042349
$\omega$	0,000241	0,000123***	0,000257***	0,000118***	-0,810297***	-0,760219***
$\alpha$	0,238548***	0,264755***	0,344996***	0,191121***	0,530188***	0,498963***
$\gamma$			0,093143	0,052234	-0,018465	-0,049196
$\beta$	0,712718***	0,762416***	0,693424***	0,761918***	0,915054***	0,925491***
$\Delta GSI_t$		0,000202***		0,000167***		0,068040***
Positivt sjokk		0,001024		0,000808		0,000500
Negativt sjokk		0,001956		0,001719		0,409646
$\Delta VIX_t$		0,000073		0,000063		0,076026*
ARCH	0,083246	0,035634	0,001686	0,059695	0,006154	0,002790
Q (5)	1,2918	1,2296	1,7640	1,0013	1,6297	1,2877
Jarque-Bera	367,5613***	290,6963***	410,0837***	271,0054***	393,5825***	293,1613***

Tabell 6: Parameterestimer for Ethereum.

\* Signifikant på 10% nivå \*\* Signifikant på 5% nivå \*\*\*Signifikant på 1% nivå

## Diagnostikk av modellene

I tabell 6 over observerer vi at alle modellene fanger opp det meste av ARCH-effektene. Vi har heller ingen problemer med autokorrelasjon.

## Evaluering av modellene

Informasjonskriteriene i tabell 7 viser at AIC og BIC blir forbedret for de fleste modeller ved inkludering av variabler for Google søk, VIX-indeksen, samt positive og negative sjokk.


Unntaket er i BIC for GJRGARCH-modellen, der modellen uten variabler er bedre tilpasset enn modellen med variabler. Totalt sett er AIC og BIC lavest for EGARCH(V)-modellen.

	GARCH	GARCH (V)	GJRGARCH	GJRGARCH (V)	EGARCH	EGARCH (V)
AIC	-2,831451	-2,862451	-2,836314	-2,838785	-2,843303	<b>-2,876016</b>
BIC	-2,805003	-2,809556	-2,799287	-2,785890	-2,806276	<b>-2,817832</b>
LL	1293,310	1312,415	1297,523	1301,647	1300,703	1319,587

Tabell 7: AIC og BIC for GARCH-modellene i Ethereum.

### 4.3 Ripple (XRP)

Datasettet for Ripple består av 1520 daglige observasjoner hentet i tidsperioden 01.01.2014 til 28.02.2014. Figur 3 viser en oversikt over kursutviklingen og log-avkastningene for perioden. Vi ser også her perioder med volatilitetsklumping i log-avkastningene.



Figur 3: Utvikling i pris og log-avkastningen til Ripple/USD.

#### Deskriptiv statistikk

Tabell 8 viser deskriptiv statistikk for log-avkastningen til Ripple,  $\Delta GSI_t$  og  $\Delta VIX_t$ . I likhet Bitcoin og Ethereum har samtlige variabler høye verdier av skjevhet og kurtose. Log-avkastningen til Ripple har positiv skjevhet, som betyr at halen på høyere side av gjennomsnittet er lengre, se [vedlegg 3A](#).

Jarque-Bera testen indikerer at alle variabler er signifikante på 1% nivå. Vi forkaster dermed nullhypotesen om at data er normalfordelt. Til slutt ser vi at Augmented Dickey-Fuller test er signifikant på 1% nivå for alle variabler, og vi forkaster nullhypotesen om ikke-stasjonaritet.

	XRP	$\Delta GSI_t$	$\Delta VIX_t$
Gjennomsnitt	0,0023	0,0046	0,0121
Median	-0,0031	0,0000	0,0133
Standard avvik	0,0732	2,7305	1,1438
Skjevhet	1,9363	0,5161	1,9638
Kurtose	40,9611	112,1788	27,4879
JB	92727,11***	755001,2***	38955,34***
ADF	-25,2712***	-6,8453***	-36,8050***

Tabell 8: Deskriptiv statistikk for Ripple.

\* Signifikant på 10% nivå    \*\* Signifikant på 5% nivå    \*\*\* Signifikant på 1% nivå



## Ljung-Box - og Engle's ARCH-test

Ljung-Box testen viser at p-verdien for alle lags er mindre enn 0,05, og vi forkaster dermed nullhypotesen om ingen autokorrelasjon. Videre er ARCH-testen signifikant på 1% nivå for alle lags. Testen gir støtte for at det eksisterer signifikant autokorrelasjon og betinget heteroskedastisitet i restleddet, se [vedlegg 3B](#).

## Modellestimatene

Tabell 9 under viser estimatene for de tre GARCH-modellene for Ripple. Estimaten er kalkulert med og uten variablene for Google søk og VIX-indeksen, samt positive og negative sjokk.

	GARCH	GARCH (V)	GJRGARCH	GJRGARCH (V)	EGARCH	EGARCH (V)
C	-0,00297***	-0,002817***	-0,002458**	0,001428	-0,002994***	-0,002941***
AR (1)	0,015136	0,010630	0,039202	0,061666*	0,013066	0,0113891
$\omega$	0,000164***	0,000279***	0,00129***	0,002493***	-1,021038***	-1,090511***
$\alpha$	0,296187***	0,074695***	0,341490***	0,177211***	0,873378***	0,785343***
$\gamma$			-0,086614**	-0,123840**	-0,012003	-0,012379
$\beta$	0,673273***	0,873382***	0,656946***	0,395865***	0,875831***	0,872550***
$\Delta GSI_t$		0,000186***		0,000205***		0,086251***
Positivt sjokk		-0,002104***		-0,003626***		0,530143
Negativt sjokk		-0,000083		0,001833		1,549379**
$\Delta VIX_t$		0,000538***		0,000489***		0,024648
ARCH	0,044769	3,155164*	0,105595	5,735798**	0,198741	0,048483
Q (5)	1,4005	1,1001	7,6660	52,137***	1,7917	0,53498
Jarque-Bera	26473,13***	34224,48***	15518,75***	9234,828***	39771,59***	82921***

Tabell 9: Parameterestimaten for Ripple.  
\* Signifikant på 10% nivå \*\* Signifikant på 5% nivå \*\*\*Signifikant på 1% nivå

Først ser vi at parameteren  $\gamma$  for asymmetriske effekter er negativ og signifikant for GJRGARCH-modellene. Dette indikerer at det eksisterer asymmetrieffekter i den betingende avkastningsdistribusjonen, se [delkapittel 3.8](#). Videre er  $\Delta GSI_t$ -variabelen positiv og statistisk signifikant for alle modellene. Dette er på linje med tidligere beskrevne modeller og i overenstemmelse med hypotese  $H_1$ . Dernest er dummyvariabelen for positive sjokk negativ og signifikant for GARCH(V)- og GJRGARCH(V)-modellen. Det betyr at den betingede variansen er lavere ved et positivt sjokk, enn hvis det ikke hadde kommet et sjokk. Videre ser vi også at

negative sjokk har positiv og signifikant påvirkning på den betingende variansen for EGARCH(V)-modellen. Dette er i overenstemmelse med hypotese H<sub>2</sub>. Til slutt er  $\Delta VIX_t$  positiv og signifikant for GJRGARCH-modellen. Det kan tolkes som at høyere forventet volatilitet i aksjemarkedet øker den betingede variansen i Ripple. Dette strider med hypotese H<sub>3</sub>.

### Diagnostikk av modellene

I tabell 9 over observerer vi at det fremdeles er signifikante ARCH-effekter i GARCH(V)- og GJRGARCH(V)-modellene. Mens de resterende modellene fanger opp det meste av ARCH-effektene. Til slutt ser vi at vi fremdeles har problemer med autokorrelasjon i GJRGARCH-modellen.

### Modellevaluering

I tabell 10 ser vi AIC blir forbedret for EGARCH-modellene når vi inkluderer variablene. For BIC blir alle resultater dårligere. Totalt sett er AIC lavest for EGARCH(V)-modellen og BIC er lavest for EGARCH-modellen.


	GARCH	GARCH (V)	GJRGARCH H	GJRGARCH (V)	EGARCH	EGARCH (V)
AIC	-3,418552	-3,015655	-3,292130	-2,871116	-3,432671	<b>-3,444798</b>
BIC	-3,401012	-2,984083	-3,271082	-2,832528	<b>-3,408115</b>	-3,406210
LL	2599,681	2297,882	2504,726	2190,177	2612,397	2625,601

*Tabell 10: AIC og BIC for GARCH-modellene i Ripple.*

\* Signifikant på 10% nivå    \*\* Signifikant på 5% nivå    \*\*\*Signifikant på 1% nivå

## 4.4 DASH

Datasettet for DASH består av 1461 daglige observasjoner hentet i tidsperioden 01.03.2014 til 28.02.2014. Utviklingen i prisen har likheter med Bitcoin, Ethereum og Ripple. Vi ser også her at avkastningene viser tydelige tegn til volatilitetsklumping.



Figur 4: Utvikling i pris og log-avkastningen til DASH/USD.

## Deskriptiv statistikk

Tabell 11 under viser deskriptiv statistikk av variablene som er inkludert i modellen. Samtlige variabler har høye verdier av skjevhet og kurtose. DASH har positiv skjevhet, noe som indikerer at halen på høyre side er lenger, se [vedlegg 4A](#). Jarque-Bera testen viser at alle variabler er signifikante på 1% nivå. Vi forkaster nullhypotesen om at data er normalfordelt. Videre viser Augmented Dickey Fuller test at alle variabler er signifikante på 1% nivå, og vi forkaster nullhypotesen om ikke-stasjonaritet.

	DASH	$\Delta GSI_t$	$\Delta VIX$
Gjennomsnitt	0,0044	0,0082	0,0126
Median	-0,0020	0,0000	0,0175
Standard avvik	0,0757	4,9152	1,1569
Skjevhet	1,3102	-0,3161	2,1575
Kurtose	15,2306	19,3616	30,4810
JB	9517,662***	16320,75***	47106,57***
ADF	-38,5386***	-6,5906***	-36,2461***

Tabell 11: Deskriptiv statistikk for DASH.

\* Signifikant på 10% nivå    \*\* Signifikant på 5% nivå    \*\*\* Signifikant på 1% nivå

## Ljung-Box - og Engle's ARCH test

Ljung-Box testen viser at p-verdien for lag 20 er mindre enn 0,05, og vi forkaster dermed nullhypotesen om ingen autokorrelasjon. Videre er ARCH-testen signifikant på 1% nivå for alle lags. Testen gir støtte for at det eksisterer signifikant autokorrelasjon og betinget heteroskedastisitet i restleddet, se [vedlegg 4B](#).

## Modellestimatene

Tabell 12 viser estimatene for de tre GARCH-modellene for DASH. Estimaten er kalkulert både med og uten variabler for Google søk, VIX-indeks, samt positive og negative sjokk.

	GARCH	GARCH (V)	GJRGARCH	GJRGARCH (V)	EGARCH	EGARCH (V)
C	-0,000904	-0,001015	-0,001406	-0,001414	-0,001578	-0,001613
AR (1)	-0,047481	-0,047260*	-0,049053*	-0,048958*	-0,047653*	-0,060577**
$\omega$	0,000214	0,000265***	0,000253***	0,000266***	-0,685240***	-0,673172***
$\alpha$	0,211531***	0,285988***	0,290073***	0,245948***	0,507514***	0,472429***
$\gamma$			0,142721	0,144546*	-0,053256	-0,044602
$\beta$	0,753128***	0,725186***	0,725479***	0,716848***	0,932222***	0,935139***
$\Delta GSI_t$		0,000084***		0,000091***		0,043578***
Positivt sjokk		0,000308		0,000120		-0,104818
Negativt sjokk		0,016084**		0,016235**		1,087910***
$\Delta VIX_t$		0,000138*		0,000132		0,062559**
ARCH	0,2922	0,14770	0,0130	0,084986	0,0952	0,273737
Q (5)	2,0323	5,2207	1,8455	5,4979	1,9531	4,6082
Jarque-Bera	3025,489***	1140,731***	3772,705***	1261,756***	2957,094***	1056,599***

Tabell 12: Parameterestimatene for DASH.

\* Signifikant på 10% nivå    \*\* Signifikant på 5% nivå    \*\*\* Signifikant på 1% nivå

Først ser vi at parameteren  $\gamma$  for asymmetriske effekter er positiv og signifikant for GJRGARCH(V)-modellen. Dette impliserer at vi har «leverage effects», og støtter dermed hypotese H<sub>4</sub>. Videre er  $\Delta GSI_t$ -variabelen positiv og statistisk signifikant for alle modellene. Dette er i overensstemmelse med hypotese H<sub>1</sub> og funnene i Bitcoin, Ethereum og Ripple.

Dernest er dummyvariabel for negative sjokk positiv og signifikant for alle modeller på 1% og 5% nivå. Dette er også forventede resultater med bakgrunn i H<sub>2</sub>. Til slutt observerer vi at  $\Delta VIX_t$  er positiv og signifikant for GARCH(V)- og EGARCH(V)-modellene på 5% og 10% nivå. Det kan tolkes som at høyere volatilitet i aksjemarkedet gir høyere volatilitet i DASH.

## Diagnostikk av modellene

I tabell 12 observerer vi at modellen fanger opp det meste av ARCH-effektene. Vi har heller ingen problemer med autokorrelasjon.

## Modellevaluering

Ved undersøkelse av hvor godt modellene er tilpasset i henhold til kriteriene AIC og BIC blir samtlige AIC verdier forbedret når ved inkludering av variablene i modellene. For BIC derimot, blir samtlige modeller dårligere tilpasset. EGARCH(V)-modellen gir de best resultat totalt sett basert på AIC. Til slutt ser vi at BIC gir best resultater for GJRGARCH-modellen.


	GARCH	GARCH (V)	GJRGARCH	GJRGARCH (V)	EGARCH	EGARCH (V)
AIC	-2,909110	-2,921596	-2,914176	-2,922923	-2,915467	<b>-2,929525</b>
BIC	-2,890997	2,885369	<b>-2,888817</b>	-2,883073	-2,890108	-2,889876
LL	2127,196	2141,304	2132,891	2143,704	2133,833	2148,089

Tabell 13: AIC og BIC for GARCH-modellene i DASH.

\* Signifikant på 10% nivå    \*\* Signifikant på 5% nivå    \*\*\* Signifikant på 1% nivå

## 4.5 Litecoin (LTC)

Datasettet for Litecoin består av 1416 daglige observasjoner hentet i tidsperioden 01.04.2014 til 28.02.2018. Figur 5 viser en oversikt over kursutviklingen og log-avkastningene for perioden. Vi ser tendenser til volatilitetsklumping slik som vi har sett på de andre kryptovalutaene.



Figur 5: Utvikling i pris og log-avkastningen til Litecoin/USD.

## Deskriptiv statistikk

Tabell 14 under viser deskriptiv statistikk av variablene som er inkludert i modellen. Samtlige variabler har høye verdier av skjevhet og kurtose. Log-avkastningen til LTC har også positiv skjevhet, se [vedlegg 5A](#). I Jarque-Bera testen er alle variabler signifikante på 1% nivå. Data tyder dermed på at vi kan forkaste nullhypotesen om at data er normalfordelt.

Augmented Dickey Fuller testen viser at alle variabler er signifikante på 1% nivå, og vi forkaster nullhypotesen om ikke-stasjonaritet.

	LTC	$\Delta\text{GSI}_t$	$\Delta\text{VIX}_t$
Gjennomsnitt	0,0019	0,0021	0,0130
Median	0,0000	0,0000	0,0175
Standard avvik	0,0604	2,3954	1,1772
Skjevhet	0,5180	10,7888	2,4349
Kurtose	19,2363	441,0277	34,8863
JB	15605,78***	11347697***	61386,80***
ADF	-38,5081***	-14,7347***	-36,6760***

Tabell 14: Deskriptiv statistikk for Litecoin.

\* Signifikant på 10% nivå \*\* Signifikant på 5% nivå \*\*\*Signifikant på 1% nivå

### Ljung-Box test og Engle's ARCH test

Ljung-Box testen viser at p-verdien for lag 10 og 20 er mindre enn 0,01, og vi forkaster dermed nullhypotesen om ingen autokorrelasjon. Videre er ARCH-testen signifikant på 1% nivå for alle lags. Testen gir støtte for at det eksisterer signifikant autokorrelasjon og betinget heteroskedastisitet i restleddet, se [vedlegg 5B](#).

### Modellestimatene

Tabell 15 viser modellestimatene for Litecoin. Estimatene er kalkulert både med og uten variabler for Google søk, VIX-indeks, samt positive og negative sjokk.

	GARCH	GARCH (V)	GJRGARCH	GJRGARCH (V)	EGARCH	EGARCH (V)
C	-0,000359	-0,000369	-0,000302	-0,000299	-0,000323	-0,000309
AR (1)	-0,08935***	-0,088779***	-0,094318***	-0,092509***	-0,097233***	-0,096767***
$\omega$	0,000020	0,000028	0,000045	0,000054**	-0,235042***	-0,234472***
$\alpha$	0,107873***	0,109883***	0,451068*	0,349882**	0,375429***	0,325321***
$\gamma$			-0,1801577	-0,123009	0,0338369	0,028573
$\beta$	0,886633***	0,882588***	0,878645***	0,874246***	0,987106***	0,986239***
$\Delta\text{GSI}_t$		0,000643***		0,001414**		0,061073***
Positivt sjokk		-0,000284**		-0,000608*		0,035261
Negativt sjokk		0,006910**		0,013290		0,771859**
$\Delta\text{VIX}_t$		0,000028		0,000042		0,042427*
ARCH	0,0499	0,045435	0,079193	0,117249	0,025902	0,017525
Q (5)	0,6453	0,3439	0,8524	0,3298	0,6476	0,5830
Jarque-Bera	106090,9***	288967,7***	104128,6***	380182,1***	119761,7***	137038,8***

Tabell 15: Parameterestimatene for Litecoin.

\* Signifikant på 10% nivå \*\* Signifikant på 5% nivå \*\*\*Signifikant på 1% nivå

Resultatene viser at  $\Delta GSI_t$ -variabelen er positiv og signifikant på 1% og 5% nivå for alle modellene. Dette er på linje med Bitcoin, Ethereum, Ripple og DASH. Videre observerer vi at positive sjokk er signifikant på 5% og 10% nivå for GARCH(V)- og GJRGARCH(V)-modellen. Negative sjokk er derimot kun signifikant på 5% nivå for EGARCH-modellen. Til slutt ser vi at  $\Delta VIX_t$ -variabelen positiv og signifikant for GARCH(V)-modellen.

### Diagnostikk av modellene

I tabell 15 over observerer vi at modellene fanger opp det meste av ARCH-effektene. Vi har heller ingen problemer med autokorrelasjon.

### Modellevaluering

Ved undersøkelse av hvor godt modellene er tilpasset i henhold til kriteriene AIC blir alle modeller forbedret. Derimot blir modellene dårligere tilpasset basert på BIC i GJRGARCH- og EGARCH-modellen.

	GARCH	GARCH (V)	GJRGARCH	GJRGARCH (V)	EGARCH	EGARCH (V)
AIC	-3,686675	-3,703497	-3,700842	<b>-3,711600</b>	-3,697783	-3,704643
BIC	-3,668096	-3,670054	<b>-3,674831</b>	3,670726	-3,671773	-3,663769
LL	2611,480	2627,468	2623,495	2635,101	2621,333	2630,183

*Tabell 16: AIC og BIC for GARCH-modellene i Litecoin.*

\* Signifikant på 10% nivå    \*\* Signifikant på 5% nivå    \*\*\*Signifikant på 1% nivå

## 5. Diskusjon av resultater

Vi skal i dette kapittelet diskutere funnene vi har gjort opp mot tidligere formulerte hypoteser i kapittel 3. Funnene vil deretter bli sammenlignet med tidligere forskning og økonomisk teori. Utfordringen her er at det ikke er etablert mye teori på kryptovaluta, så mye av diskusjonen vil rettes mot funn i nyere artikler.

### **H<sub>1</sub>: Google søkeindeks øker volatiliteten i kryptovaluta.**

Resultatene fra analysen viser at Google søkeindeksen har signifikant påvirkning på den betingede variansen i alle kryptovalutaer. Resultatene er forventet basert på tidligere forskning beskrevet i kapittel 2. Eksempelvis fant både Letra (2016) og Kristoufek (2013) en positiv korrelasjon mellom Google søkeaktivitet og prisen på Bitcoin. Videre fant Chronopoulos, Papadimitriou og Vlastakis (2017) at man kunne forbedre predikert varians i aksjer ved å inkludere en variabel for Google søk i GARCH-modeller. Kristoufek (2013) argumenterte i sin artikkel om at Bitcoin sin manglende fundamentale verdi gjorde at verdien i hovedsak var drevet av tilbud og etterspørsel. Derfor vil etterspørselen etter informasjon også reflektere etterspørselen etter kryptovaluta, og dermed påvirke prisvolatiliteten. En annen årsak er at investorer som investerer i kryptovaluta ofte kjennetegnes ved at de tar høy risiko (Moore, 2013). På grunn av den høye risikoen vil de mer iherdig oppsøke søkemotorer for å finne ny informasjon om valutaen og bruke denne informasjon til beslutninger for kjøp og salg. Våre funn støtter dermed majoriteten av tidligere funn om at Google søk er en god proxy for informasjonsetterspørsel og kan påvirke volatiliteten i kryptovaluta. Det som imidlertid skiller våre funn fra tidligere forskning er at vi har funnet bevis for dette i flere kryptovalutaer, og dermed støtte for hypotese H<sub>1</sub>.

### **H<sub>2</sub>: Historiske begivenheter og kunngjøringer øker volatiliteten i kryptovaluta.**

Resultatene fra analysen tyder på at positive sjokk i form av begivenheter og kunngjøringer om kryptovaluta er signifikant i Ripple for GARCH(V)- og GJRGARCH(V)-modellene. I Litecoin er positive sjokk signifikant for GARCH(V) og GJRGARCH(V). Koeffisienten er negativ, som isolert sett impliserer at den betingende variansen reduseres når vi får et positivt sjokk. Det er imidlertid ingen signifikante entydige resultater i de andre kryptovalutaene. Dette indikerer at positive sjokk ikke har stor betydning for volatiliteten når vi ser på alle kryptovalutaer under et.



Hvis vi derimot ser på negative sjokk, er denne signifikant for Bitcoin, Ripple, DASH og Litecoin for de fleste modeller. Alle koeffisientene har positivt fortegn hvilket impliserer at den betingede variansen øker når det kommer et negativt sjokk, alt annet likt. Vi har ikke funnet annen forskning der de har implementert binære variabler for positive og negative sjokk i GARCH-modeller for kryptovaluta. Men noe lignende fant Meland og Øyen (2017) i sin studie på Bitcoin om at negative og positive sjokk hadde en signifikant påvirkning på prisen. På bakgrunn av at kryptovaluta tilsynelatende ikke har fundamental verdi (Kristoufek, 2013), kan man bare bruke tradisjonell teori om effisiente markeder som en pekepin under tolkningen av volatiliteten i kryptovaluta. Skulle vi undersøkt dette nærmere måtte vi ha sett nærmere på teori for beslutningstagning under risiko, se blant annet Kahneman og Tversky (1979). Dette vil imidlertid være utenfor rammene av denne oppgaven og vil derfor ikke ytterligere bli gjennomgått. Avslutningsvis kan vi konkludere med at vi har funnet støtte for hypotese H<sub>2</sub>.

### **H<sub>3</sub>: Økt forventet volatilitet i aksjemarkedet gir redusert volatilitet i kryptovaluta.**

VIX-indeksen er signifikant og positiv i EGARCH-modellene for Bitcoin, Ethereum, DASH og Litecoin. Videre er VIX-indeksen signifikant for GARCH- og EGARCH-modellen for Ripple, og GARCH-modellen for DASH. Alle signifikante variabler har positivt fortegn. Dette impliserer at høyere volatilitet i aksjemarkedet også gir høyere volatilitet i kryptovaluta. Dette strider mot tidligere funn, blant annet fant Bouri *et al.* (2017) at det var negativ korrelasjon mellom volatiliteten i Bitcoin og VIX. Disse resultatene endrer seg derimot etter det de kaller krasjet i desember 2013. Da fant de ingen sammenheng mellom aktivaene. Data som er brukt i våre undersøkelser er av nyere dato, og kan derfor gi ny innsikt. Vi har dermed ikke funnet støtte for hypotese H<sub>3</sub> da koeffisientene har feil fortegn.

### **H<sub>4</sub>: Det finnes «leverage effects» i kryptovaluta**

Analysen avdekket at det er signifikant asymmetri i Ripple for GJRGARCH-modellene. Videre ble det påvist «leverage effects» i GJRGARCH(V)-modellen for DASH. «Leverage effects» er relativt vanlig i tradisjonelle aktiva. Abdalla (2012) fant bevis for at «leverage effects» også kan forekomme i valuta. Forklaringen bak er at sjokk påvirker volatiliteten i markedet og øker risikoen for å holde valutaen. Dette er i kontrast med våre resultater som er mer på linje med Kisinbay (2010). Han fant asymmetriske effekter i aksjeavkastninger, men ikke i

valutakursavkastninger. Dette fører oss igjen videre til diskusjonen vedrørende om kryptovaluta er et investeringsobjekt eller en valuta. Blant annet diskuterer Dyhrberg (2016a) at Bitcoin kan klassifiseres som noe mellom gull og den amerikanske dollaren. Videre fant Catania, Grassi og Ravazzalo (2018) at mer sofistikerte volatilitetsmodeller som inkluderte en asymmetrisk reaksjon av volatilitetsprosessen kunne forbedre volatilitetsprediksjoner. Vi har imidlertid ikke funnet støtte for det i kryptovaluta, da modellene med signifikant asymmetri har dårligere tilpasningsmål (AIC og BIC) enn modellene uten. I tillegg har vi bare funnet signifikant asymmetri og «leverage effects» i to modeller. Vi har derfor ikke tilfredsstillende grunnlag for påstanden i hypotese H<sub>4</sub>.

#### **H<sub>5</sub>: Implementering av variabler forbedrer tilpasningen i modellen.**

Til slutt har vi funnet at implementering av variabler har forbedret tilpasningsmålet AIC i 87% av modellene. For BIC derimot, har vi kun fått bedre tilpasningsmål for 38% av modellene. Oppsummert virker det som inkluderingen av variabler i variansligningen forbedrer tilpasningen i modellen for AIC, mens for BIC er det mer blandende resultater. Dette kan komme av at BIC pålegger større straff for modeller med flere parameterne (Brooks, 2008, s. 233). Vi konkluderer derfor med at hypotese H<sub>5</sub> får delvis støtte om å bedre tilpasningen i modellen.

## 6. Konklusjon

Motivasjonen for denne oppgaven har vært å finne ut om etterspørsel etter informasjon, historiske begivenheter og volatilitet i aksjemarkedet påvirker volatiliteten i kryptovaluta. Vi har også undersøkt om det eksisterer «leverage effects» i kryptovaluta. Til slutt undersøkte vi om implementering av disse variablene forbedrer prestasjonen i GARCH-modellene basert på mål som AIC og BIC.

Analysen viste at Google søk variabelen var statistisk signifikant for alle kryptovaluta. Samtlige fortegn var positive som impliserer at Google søk øker den betingede variansen. Videre fant vi indikasjoner på at positive sjokk har signifikant påvirkning på den betingede variansen i Ripple og Litecoin. Fortegnet var her negativt, hvilket betyr at den betingede variansen reduseres når det kommer et positivt sjokk. Hvis vi derimot ser på negative sjokk, er denne signifikant for Bitcoin, Ripple, DASH og Litecoin. Fortegnet er positivt, som impliserer at et negativt sjokk øker den betingede variansen. Da vi så nærmere på VIX-indeksen var denne signifikant og positiv i EGARCH-modellene for Bitcoin, Ethereum, DASH og Litecoin. Videre er VIX signifikant for GARCH- og EGARCH-modellen for Ripple, og GARCH-modellen for DASH. Fortegnet var positivt for alle, som dermed impliserer at kryptovalutaene korrelerer positivt med VIX-indeksen. Vi fant også signifikant «leverage effects» i GJRGARCH-modellen for DASH og innslag av signifikante asymmetrieffekter i GJRGARCH-modellen for Ripple. Avslutningsvis fant vi at implementeringen av variabler i ligningen for varians kunne forbedre målene AIC i 87% av modellene. Mens for BIC forbedret målene seg i 38% av modellene. Da vi endret fordelingen fra standard normalfordeling til Student's t fordeling forbedret AIC og BIC seg ytterligere for alle modeller.

Våre undersøkelser avdekket at det er en sammenheng mellom kryptovaluta og Google søkeindeks, negative sjokk og VIX-indeksen. Spesielt Google søk og negative nyheter ga gode entydige resultater for de fleste modeller. Disse resultatene kan bidra til økt forståelse for hvordan prisvolatiliteten i kryptovaluta utvikler seg. Disse funnene bør tas i betraktning ved videre forskning på temaet og kan være til hjelp for investorer og myndigheter for å forstå kryptovaluta bedre.

### **Forslag til videre forskning**

Kryptovaluta er et relativt nytt fenomen som har vært utfordrende å studere da det fortsatt ikke er etablert mye teori. Vi har dermed måttet benytte en viss grad av innovativitet og lignende forskning som en pekepinn ved arbeid av avhandlingen.

Det har dukket opp flere veivalg der vi har måttet ta beslutninger om begrensinger underveis i avhandlingen. Disse kan være gode utgangspunkt for videre forskning. Blant annet tok vi for oss hele perioden for de forskjellige kryptovalutene med formål om å konstruere bedre modeller. Det kan imidlertid være interessant å dele perioden opp i to eller flere delperioder. Man kan dermed undersøke hvor godt modellene predikerer volatilitet på bakgrunn av mål som RMSE, MAE eller andre evalueringsmål. Å sammenligne prediksjonsresultater mellom flere modeller innenfor kryptovaluta kan være et viktig bidrag til forskningen.

Vi brukte også ett lag for  $p$  og  $q$  i GARCH-modellene, men ofte kan det også være nødvendig med flere lags i  $p$  og  $q$  for å få en god modell.

## Referanseliste

- Abdalla, S. Z. (2012) Modelling exchange rate volatility using GARCH models: Empirical evidence from Arab countries, *International Journal of Economics and Finance*, 4(3), s. 216-229.
- Akaike, H. (1974) A new look at the statistical model identification, *IEEE transactions on automatic control*, 19(6), s. 716-723.
- Alexander, C. (2008) *Market Risk Analysis, Practical Financial Econometrics (Volume II)*. Chichester: John Wiley & Sons Ltd.
- Andersen, T. G., Bollerslev, T., Diebold, F. X. og Ebens, H. (2001) The distribution of realized stock return volatility, *Journal of Financial Economics*, 61(1), s. 43-76.
- Askitas, N. og Zimmermann, K. F. (2009) Google Econometrics and Unemployment Forecasting, *Applied Economics Quarterly*, 55(2), s. 107-120.
- Black, F. (1976) Studies of stock price volatility changes. American Statistical Association, Alexandria, VA: Proceedings of the 1976 American Statistical Association, Business and Economical Statistics Section.
- Bollerslev, T. (1986) Generalized autoregressive conditional heteroskedasticity, *Journal of Econometrics*, 31(3), s. 307-327.
- Bollerslev, T. (1987) *A Conditional Heteroskedastic Time Series Model for Speculative Prices and Rates of Return*, 69(3), s. 542-547.
- Bouoiyour, J. og Selmi, R. (2015) *Bitcoin Price: Is it really that New Round of Volatility can be on way?* MPRA Paper No. 65580. Tilgjengelig fra: <https://mpra.ub.uni-muenchen.de/65580/> (Hentet: 25. januar 2018)
- Bouoiyour, J. og Selmi, R. (2016) Bitcoin: A beginning of a new phase. *Economics Bulletin*, 36(3), s. 1430-1440.
- Bouoiyour, J., Selmi, R., Tiwari, A. K. og Olayeni, O. R. (2016) What drives Bitcoin price?, *Economics Bulletin*, 36(2), s. 843-850.
- Bouri, E., Molnár, P., Azzi, G., Roubaud, D. og Hagfors, L. (2017) On the hedge and safe haven properties of Bitcoin: Is it really more than a diversifier?, *Finance Research Letters*, 20, s. 192-198.
- Brooks, C. (2008) *Introductory Econometrics for Finance*. 2. utg. New York: Cambridge University Press.
- Catania, L., Grassi, S. og Ravazzolo, F. (2018) *Forecasting Cryptocurrencies Financial Time Series*. CAMP Working Paper Series; 5. Oslo: BI Norwegian Business School, Centre for

- Applied Macro- and Petroleum Economics. Tilgjengelig fra:  
<https://brage.bibsys.no/xmlui/handle/11250/2489408> (Hentet: 20. mars 2018)
- Cboe (u.å.) VIX. Tilgjengelig fra: <http://www.cboe.com/vix> (Hentet: 27. april 2018)
- Cermak, V. (2017) *Can Bitcoin Become a Viable Alternative to Fiat Currencies? An Empirical Analysis of Bitcoin's Volatility Based on a GARCH Model*. Tilgjengelig fra:  
<https://ssrn.com/abstract=2961405> (Hentet: 25. januar 2018)
- Chan, S., Chu, J., Nadarajah, S. og Osterrieder, J. (2017) A Statistical Analysis of Cryptocurrencies, *Journal of Risk and Financial Management*, 10(12), s. 1-23.
- Christie, A. A. (1982) The Stochastic Behavior of Common Stock Variances: Value, Leverage and Interest Rate Effects, *Journal of Financial Economics*, 10(4), s. 407-432.
- Chronopoulos, D. K., Papadimitriou, F. I. og Vlastakis, N. (2017) Information Demand and Stock Return Predictability, *Journal of International Money and Finance*, 80, s. 59-74.
- Chu, J., Chan, S., Nadarajah, S. og Osterrieder, J. (2017) GARCH Modelling of Cryptocurrencies, *Journal of Risk and Financial Management*, 10(4), s. 1-17.
- Chuen, D. L. (2015) *Handbook of digital currency: Bitcoin, innovation, financial instruments, and big data*. Elsevier Inc.
- Ciaian, P., Rajcaniova, M. og Kancs, D. A. (2016) The Economics of BitCoin Price Formation, *Applied Economics*, 48(19), s. 1799-1815.
- CoinMarketCap (u.å.) *All cryptocurrencies*. Tilgjengelig fra:  
<https://coinmarketcap.com/all/views/all/> (Hentet: 20. mai 2018)
- Da, Z., Engelberg, J. og Gao, P. (2011) In search of attention, *The Journal of Finance*, 66(5), s. 1461-1499.
- D'Amuri, F. og Marcucci, J. (2009) "Google it!" Forecasting the US unemployment rate with a Google job search index. MPRA Paper No. 18248. Tilgjengelig fra: <https://mpra.ub.uni-muenchen.de/18248/> (Hentet: 25. januar 2018)
- Duan, J. C. (1997) Augmented GARCH(p,q) Process and its Diffusion Limit, *Journal of Econometrics*, 79, s. 97-127.
- Dutta, A. (2014) Modelling volatility: Symmetric or asymmetric GARCH models, *Journal of Statistics: Advances in Theory and Applications*, 12(2), s. 99-108.
- Dyhrberg, A. H. (2016a) Bitcoin, gold and the dollar—A GARCH volatility analysis, *Finance Research Letters*, 16, s. 85-92.

- Dyhrberg, A. H. (2016b) Hedging capabilities of Bitcoin. Is it the virtual gold?, *Finance Research Letters*, 16, s. 139-144.
- Enders, W. (2015) *Applied Econometric Time Series*. 4. utg. USA: John Wiley & Sons.
- Engle, R. (2001) GARCH 101: The use of ARCH/GARCH models in applied econometrics, *Journal of economic perspectives*, 15(4), s. 157-168.
- Engle, R. F. (1982) Autoregressive Conditional Heteroskedasticity with Estimates of the Variance of United Kingdom Inflation, *Econometrica*, 50(4), s. 987-1007.
- Engle, R. F. og Ng, V. K. (1993) Measuring and testing the impact of news on volatility. *Journal of Finance*, 48(5), 1749-1778.
- Glaser, F., Zimmermann, K., Haferkorn, M., Weber, M. C. og Siering, M. (2014a) Bitcoin - Asset or Currency? Revealing Users' Hidden Intentions, *22nd European Conference on Information Systems*. Tel Aviv, juni 2014. SSRN, s. 1-14.
- Glaser, F., Haferkorn, M., Weber, M. C. og Zimmerman, K. (2014b) How to Price a Digital Currency? Empirical Insights on the Influence of Media Coverage on the Bitcoin Bubble. *MKWI 2014 (Paderborn) & Banking and Information Technology*, 15(1).
- Glosten, L. R., Jagannathan, R. og Runkle, D. E. (1993) On the relation between the expected value and the volatility of the nominal excess return on stocks, *Journal of Finance*, 48(5), s. 1779-1801.
- Halaburda, H. og Sarvary, M. (2016) *Beyond Bitcoin*. Houndmills: Palgrave Macmillan.
- Hansen, P. R. og Lunde, A. (2005) A forecast comparison of volatility models: does anything beat a GARCH (1,1)?, *Journal of applied econometrics*, 20(7), s. 873-889.
- Hobson, D. (2013) What is Bitcoin?, *XRDS: Crossroads, The ACM Magazine for Students*, 20(1), s. 40-44.
- Hull, J. C. (2012) *Options, futures and other derivatives*. 8. utg. USA: Prentice Hall.
- Jarque, C. M. og Bera, A. K. (1987) A test for normality of observations and regression residuals, *International Statistical Review/Revue Internationale de Statistique*, 55(2), s. 163-172.
- Jenssen, T. (2014) *Why Bitcoins Have Value, and Why Governments Are Sceptical*. Masteroppgave: Universitetet i Oslo.
- Jondeau, E., Poon, S. H. og Rockinger, M. (2007) *Financial modeling under non-Gaussian distributions*. USA: Springer-Verlag London.

- Kahneman, D. og Tversky, A. (1979) Prospect Theory: An Analysis of Decision under Risk, *Econometrica*, 47(2), s. 263-292.
- Katsiampa, P. (2017) Volatility estimation for Bitcoin: A comparison of GARCH models, *Economics Letters*, 158, s. 3-6.
- Kholodilin, K. A., Podstawski, M. og Siliverstovs, B. (2010) *Do Google searches help in nowcasting private consumption? A real-time evidence for the US*. KOF Swiss Economic Institute Working Paper No. 256. Tilgjengelig fra: <https://ssrn.com/abstract=1615453> (Hentet: 25. januar 2018)
- Kışınbay, T. (2003) Predictive ability of asymmetric volatility models at medium-term horizons, *Applied Economics*, 42(30), s. 3813-3829.
- Knapskog, S. J. og Eilertsen, Ø. (2018) *Kryptografi*. Tilgjengelig fra: <https://snl.no/kryptografi> (Hentet: 22. februar 2018)
- Kristoufek, L. (2013) BitCoin meets Google Trends and Wikipedia: Quantifying the relationship between phenomena of the Internet era, *Scientific reports*, 3, s. 1-7.
- Kristoufek, L. (2015) What are the main drivers of the Bitcoin price? Evidence from wavelet coherence analysis, *PLoS ONE*, 10(4), s. 1-15.
- Kulkarni, R., Haynes, K. E., Stough, R. R. og Paelinck, J. H. (2009) *Forecasting Housing Prices with Google Econometrics*. GMU School of Public Policy Research Paper No. 2009-10. Tilgjengelig: <https://ssrn.com/abstract=1438286> (Hentet: 25. januar 2018)
- Letra, I. J. (2016) *What drives cryptocurrency value? A volatility and predictability analysis*. Masteroppgave: Instituto Superior de Economia e Gestão. Tilgjengelig fra: <http://hdl.handle.net/10400.5/12556> (Hentet: 22. februar 2018)
- Ljung, G. M. og Box, G. E. (1978) On a measure of lack of fit in time series models, *Biometrika*, 65(2), s. 297-303.
- Mai, F., Bai, Q., Shan, Z., Wang, X. og Chiang, R. (2015) *From Bitcoin to Big Coin: The Impacts of Social Media on Bitcoin Performance*. Tilgjengelig fra: [http://www.fmaconferences.org/Orlando/Papers/Bitcoin\\_FMA.pdf](http://www.fmaconferences.org/Orlando/Papers/Bitcoin_FMA.pdf) (Hentet: 22. januar 2018)
- Matta, M., Lunesu, I. og Marchesi, M. (2015) The predictor impact of Web search media on Bitcoin trading volumes, *Knowledge Discovery, Knowledge Engineering and Knowledge Management (IC3K): 7th International Joint Conference*, Lisboa, 12.-14. november 2015. IEEE, s. 620-626.




- Meland, M. og Øyen, V. (2017) *Explaining Bitcoin's price fluctuations*. Masteroppgave: NTNU Handelshøyskolen.
- Moore, T. (2013) The promise and perils of digital currencies, *International Journal of Critical Infrastructure Protection*, 6(3-4), s. 147-149.
- Nakamoto, S. (2008) *Bitcoin: A Peer-to-Peer Electronic Cash System*. Tilgjengelig fra: <https://bitcoin.org/bitcoin.pdf> (Hentet: 15. februar 2018)
- Nelson, D. (1991) Conditional heteroskedasticity in asset returns: A new approach, *Econometrica: Journal of the Econometric Society*, 59(2), s. 347-370.
- Nelson, D. B. og Cao, C. Q. (1992) Inequality constraints in the univariate GARCH model, *Journal of Business & Economic Statistics*, 10(2), s. 229-235.
- OxfordDictionaries (u.å.) *Cryptography*. Tilgjengelig fra: <https://en.oxforddictionaries.com/definition/cryptography> (Hentet: 22. februar 2018)
- Polasik, M., Piotrowska, A., Wisniewski, T. P., Kotkowski, R. og Lightfoot, G. (2015) Price Fluctuations and the Use of Bitcoin: An Empirical Inquiry, *International Journal of Electronic Commerce*, 20(1), s. 9-49.
- Ramasamy, R. og Munisamy, S. (2012) Predictive accuracy of GARCH, GJR and EGARCH models select exchange rates application, *Global Journal of Management and Business Research*, 12(15), s. 88-100.
- Schueffel, P. (2017) *The Concise FINTECH COMPENDIUM*. Fribourg: School of Management Fribourg (HEG-FR). Tilgjengelig fra: <http://www.heg-fr.ch/EN/School-of-Management/Communication-and-Events/events/Pages/EventViewer.aspx?Event=patrick-schuffel.aspx> (Hentet: 13. februar 2018)
- Schwarz, G. (1978) Estimating the Dimension of a Model, *The annals of statistics*, 6(2), s. 461-464.
- Segendorf, B. (2014) What is Bitcoin?, *Sveriges Riksbank Economic Review*, 2, s. 71-87. Tilgjengelig fra: [http://archive.riksbank.se/Documents/Rapporter/POV/2014/2014\\_2/rap\\_pov\\_artikel\\_4\\_1400918\\_eng.pdf](http://archive.riksbank.se/Documents/Rapporter/POV/2014/2014_2/rap_pov_artikel_4_1400918_eng.pdf) (Hentet: 25. februar 2018)
- Smith, G. P. (2012) Google Internet search activity and volatility prediction in the market for foreign currency. *Finance Research Letters*, 9(2), s. 103-110.
- Stavroyiannis, S. og Babalos, V. (2017) *Dynamic Properties of the Bitcoin and the US Market*. Tilgjengelig fra: <https://ssrn.com/abstract=2966998> (Hentet: 25. januar 2018)


- Šurda, P. (2014) *The origin, classification and utility of Bitcoin*. Tilgjengelig fra: <https://ssrn.com/abstract=2436823> (Hentet: 25. februar 2018)
- Taylor, S. (1986) *Modelling Financial Time Series*. Chichester: John Wiley & Sons.
- Valebrokk, P. (2018) Meningsløs som valuta, *E24.no*. Tilgjengelig fra: <https://e24.no/kommentarer/bitcoin/kommentar-bitcoin-meningsloes-som-valuta/24238489> (Hentet: 20. februar 2018)
- Vlastakis, N. og Markellos, R. N. (2012) Information demand and stock market volatility. *Journal of Banking & Finance*, 36(6), s. 1808-1821.
- Vosen, S. og Schmidt, T. (2011) Forecasting private consumption: survey-based indicators vs. Google trends, *Journal of Forecasting*, 30(6), s. 565-578.
- Yermack, D. (2014) *Is Bitcoin a real currency? An economic appraisal*. Tilgjengelig fra: <https://ssrn.com/abstract=2361599> (Hentet: 25. januar 2018)

# Vedlegg


Vedlegg 1A: Bitcoin




Vedlegg 2A: Ethereum




Vedlegg 3A: Ripple



Vedlegg 4A: DASH



Vedlegg 5A: Litecoin



Vedlegg 1B: Bitcoin

Q (5)	11,017*	[0,051]	ARCH 1	84,55196***	[0,000]
Q (10)	17,257*	[0,069]	ARCH 2	43,14042***	[0,000]
Q (20)	27,985	[0,110]	ARCH 3	30,38317***	[0,000]

*Ljung-Box test og Engle's ARCH test for Bitcoin.*

Vedlegg 2B: Ethereum

Q (5)	6,9989	[0,221]	ARCH 1	63,45003***	[0,000]
Q (10)	8,6120	[0,569]	ARCH 2	46,21197***	[0,000]
Q (20)	35,954**	[0,016]	ARCH 3	31,96889***	[0,000]

*Ljung-Box test og Engle's ARCH test for Ethereum*

Vedlegg 3B: Ripple

Q (5)	14,537***	[0,013]	ARCH 1	132,1336***	[0,000]
Q (10)	35,403***	[0,000]	ARCH 2	75,83896***	[0,000]
Q (20)	58,904***	[0,000]	ARCH 3	50,79598***	[0,000]

*Ljung-Box test og Engle's ARCH test for Ripple*

Vedlegg 4B: DASH

Q (5)	5,9709	[0,704]	ARCH 1	135,0165***	[0,000]
Q (10)	10,724	[0,379]	ARCH 2	68,96309***	[0,000]
Q (20)	33,061**	[0,033]	ARCH 3	48,42982***	[0,000]

*Ljung-Box test og Engle's ARCH test for DASH*

Vedlegg 5B: Litecoin

Q (5)	4,1919	[0,522]	ARCH 1	17,21373***	[0,0000]
Q (10)	31,020***	[0,001]	ARCH 2	19,57648***	[0,0000]
Q (20)	48,570***	[0,000]	ARCH 3	13,44546***	[0,0000]

*Ljung-Box test og Engle's ARCH test for Litecoin*