

# Googlen hakuvolyymien arvorelevanssi suomalaisissa pörssiyhtiöissä

Jyväskylän yliopisto  
Kauppakorkeakoulu

Pro gradu -tutkielma

2023

Tekijä: Elias Laitinen ja Lauri Valkonen  
Oppiaine: Laskentatoimi  
Ohjaaja: Antti Rautiainen



JYVÄSKYLÄN YLIOPISTO

## TIIVISTELMÄ

Tekijä Elias Laitinen ja Lauri Valkonen	
Työn nimi Googlen hakuvolyymien arvorelevanssi suomalaisissa pörssiyhtiöissä	
Oppiaine Laskentatoimi	Työn laji Pro gradu -tutkielma
Aika (pvm.) 21.6.2023	Sivumäärä 39
<p>Internet ja sosiaalinen media mahdollistavat uusia tapoja ennustaa osakkeiden hintojen muutoksia. Tässä pro gradu -tutkimuksessa tutkimme Google Trends -applikaation arvojen yhteyttä suomalaisten pörssiyhtiöiden osaketuottoihin ja osakkeiden volatiliteettiin. Tutkimuksessa analysoimme, voiko Google Trends -applikaation dataa hyödyntää osaketuottojen ja osakkeiden volatiliteetin ennustamisessa kolmen kuukauden aikajänteellä. Aikaisemmissa tutkimuksissa on havaittu yhteys Google Trends -arvojen ja osakkeiden volatiliteetin sekä osakkeiden vaihdon välillä. Sen sijaan osaketuoton ja Google Trends -arvojen yhteydelle ei ole yhtä vahvaa näyttöä aikaisempien tutkimusten perusteella. Tutkimuksen kohteena on yhteensä 97 suomalaista pörssiyhtiötä. Osakedatan ja Google Trends -datan lisäksi käytämme analyysissä kontrollimuuttujina yhtiöiden tilinpäätöstietoja sekä taloudellisia tunnuslukuja. Analyysi toteutettiin tilastollisten menetelmien avulla SPSS-ohjelmistolla. Aineistolle suoritettiin lineaarinen monimuuttujaregressioanalyysi ja lisäksi suoritettiin korrelaatiolaskelmia. Tulosten perusteella Google Trends -lukujen avulla voidaan ennustaa yhtiöiden osaketuottoja kolmen kuukauden aikajänteellä. Tulokset myös osoittavat, että osakkeiden volatiliteetin ja Google Trends -lukujen välillä on heikko positiivinen yhteys.</p>	
Asiasanat Arvorelevanssi, Google Trends, Gin Tonic	
Säilytyspaikka Jyväskylän yliopiston kirjasto	



## SISÄLLYS

TIIVISTELMÄ .....	2
SISÄLLYS.....	4
1 JOHDANTO.....	5
2 TEORIA.....	7
2.1 Tehokkaat markkinat ja käyttäytymispsykologia.....	7
2.2 Perinteiset osaketuoton ennustamisen mallit .....	8
2.3 Arvorelevanssi .....	9
2.4 Sijoittajien kollektiivisen huomion yhteys osakkeen hinnan muutokseen .....	10
2.5 Google Trends ja osaketuoton ennustaminen .....	12
3 AINEISTO JA MENETELMÄ.....	14
3.1 Aineisto .....	14
3.2 Menetelmä .....	17
4 TUTKIMUKSEN TULOKSET.....	21
4.1 Tulokset.....	21
4.1.1 Diagnostiset tarkastelut.....	21
4.1.2 Lineaarinen regressioanalyysi osakkeen volatilitiitti.....	27
4.1.3 Lineaarinen regressioanalyysi osaketuotto .....	30
5 JOHTOPÄÄTÖKSET JA ARVIOINTI.....	34
5.1 Johtopäätökset.....	34
5.2 Arviointi ja jatkotutkimusaiheet.....	35
LÄHTEET .....	37
LIITE .....	40

# 1 JOHDANTO

Internet ja sosiaalinen media ovat avanneet sijoittajan kannalta uusia mahdollisuuksia osakemarkkinoiden ennustamiseen. Informaatio on tänä päivänä saatavilla vaivattomasti, minkä lisäksi informaation määrä on lisääntynyt internetin ja sosiaalisen median myötä. Myös keinot tämän informaation, niin taloudellisen kuin ei-taloudellisen tiedon, analysoimiseksi ovat kehittyneet. On myös havaittavissa aivan uudenlaisia keinoja osakemarkkinoiden ennustamiseksi. Esimerkiksi yhtiön sosiaalisen median seuraaja- ja julkaisumäärien on havaittu olevan relevantteja muuttujia yhtiön osakkeen hinnan muutosta ennustettaessa (Rautiainen & Jokinen, 2022). On myös havaittu, että Twitter-keskustelujen sävyä analysoimalla voidaan ennustaa osakemarkkinoiden liikkeitä (Zhang, Fuehres & Gloor, 2011). Kasvava informaation määrä ja saavutettavuus yhdistettynä aikaisempien tutkimusten havaintoihin luo mielenkiintoisen pohjan mahdollisuudelle tutkia hakukonehakujen mahdollista ennustavaa voimaa osakemarkkinoilla. Tavoitteenamme on viedä eteenpäin tutkimusta sijoittajien informaatiotarpeen sekä sijoittajien sentimentin eli markkinoilla vallitsevan mielialan vaikutuksesta osakkeen volatilitettiin ja osakkeen tuottoihin. (Berger, 2022; Vlastakis & Markellos, 2012). Esittelemme lisää tämän kaltaisia esimerkkejä kappaleessa 2.5.

Tämän tutkimuksen tarkoitus on tutkia Google Trends -applikaation käyttökelpoisuutta yhtiökohtaisen osakkeen volatilitettiin sekä osaketuoton ennustamisessa Suomen pörssissä. Google Trends -applikaatio näyttää kuinka paljon tiettyä hakusanaa on haettu suhteessa valitun ajanjakson korkeimpaan hakumäärään Googlen hakukoneessa (Google, 2022). Uskomme, että muutokset hakuvolyymeissa heijastelevat muun muassa sijoittajien kiinnostusta yhtiötä kohtaan. Lisäksi uskomme hakuvolyymien muutosten kertovan yhtiötä koskevan uuden informaation saatavuudesta. Kun yhtiötä koskevaa uutta informaatiota tulee julki, päättyy informaatio ennemmin tai myöhemmin sijoittajien tietoon ja tulee täten hinnoitelluksi osakkeen kurssiin. Koska Google on länsimaiden käytetyin hakukone, on todennäköistä, että sijoittajat etsivät tietoa muun muassa "googlaamalla", mikä puolestaan heijastuisi kasvavina volyymeina Google Trends (GT) -lukuissa, kun uutta informaatiota on tarjolla.

Aikaisemmat tutkimukset osoittavat, että GT-luvut ovat jossain määrin relevantteja muuttujia sekä koko osakemarkkinan että yhtiökohtaisen osakkeen käytöksen ennustamisessa. Osakkeen volatilitietin tai osakkeen vaihdon sekä GT-volyymien välinen yhteys on havaittu useassa tutkimuksessa, sen sijaan yhtiökohtaisten osaketuottojen ja GT-volyymien yhteys vaikuttaa heikommalta. (Hamid & Heiden, 2015) (Heiberger, 2015; Takeda & Wakao, 2014; Salisu, Ogbonna ja Adediran, 2021; Nguyen, Schinckus ja Hong Nguyen, 2019; Neri, Katarína, Peter & Roviél, 2019).

Tässä tutkimuksessa siis tutkitaan, löytyykö suomalaisten osakkeiden volatilitietin ja osaketuoton sekä Googlen hakuvolyyymien väliltä yhteyttä. Aikaisemmat tutkimukset ovat kattaneet suurimmaksi osaksi Yhdysvaltojen markkinaa (Bijl ym. 2016), minkä lisäksi yksittäisiä tutkimustuloksia aiheesta on esimerkiksi Japanin (Takeda & Wakao, 2022), Norjan (Kim ym. 2019) sekä muutaman kehittyvän maan (Indonesia, Malesia, Filippiinit, Thaimaa, ja Vietnam) markkinoilta (Nguyen, 2019). Suomen osakemarkkinoilta ei tietääksemme ole vielä tutkimuksia aiheesta.

Aineistona käytämme suomalaisten pörssiyhtiöiden GT-dataa, osakedataa sekä taloudellisia tunnuslukuja. Aineisto on koottu taulukkolaskentatyökaluun ja analysoitu lopulta SPSS-ohjelmistolla. Aineistoa analysoidaan laskemalla korrelaatiolaskelmia sekä suorittamalla lineaarinen monen muuttujan regressioanalyysi. Alla on tutkimuksen tutkimuskysymys:

*Onko yhtiökohtaisilla Googlen hakuvolyyymeilla yhteyttä yhtiön osakkeen hinnan muutokseen?*

## 2 TEORIA

### 2.1 Tehokkaat markkinat ja käyttäytymispsykologia

Tehokkaiden markkinoiden hypoteesin mukaan kaikki saatavilla oleva julkinen informaatio on jo hinnoiteltu osakekursseihin. Osakkeiden hinnat sekä osakemarkkina kokonaisuudessaan heijastelevat tehokkaasti uutta informaatiota, eikä näin ollen osakkeiden tulevia hintoja ole mahdollista ennustaa sen hetkisellä tiedolla, koska markkinat ovat jo hinnoitelleet tämän tiedon osakekursseihin. Tällöin tämän päivän informaation hyödyntäminen huomisen hintojen ennustamisessa ei voisi säännöllisesti johtaa markkinatuottoa parempaan tuottoon ilman, että vastaavasti riski kasvaa markkinatuottoa vastaavaa riskiä suuremmaksi. (Fama 1970.)

Tehokkaiden markkinoiden hypoteesi on kohdannut vuosien varrella kritiikkiä, esimerkiksi käyttäytymispsykologia on nostanut esiin teorian heikkouksia. Rahoitusmarkkinoiden ilmiöitä ennustettaessa tulee ottaa huomioon, miten ihmiset tosiasiallisesti käyttäytyvät toimiessaan rahoitusmarkkinoilla. Esimerkki ei-rationaalisesta käyttäytymisestä osakemarkkinoilla ovat niin kutsutut "noise traderit". He eivät tee sijoituspäätöksiään tilinpäätösanalyysin ja loogisen järjestyksen perusteella vaan heidän ostopäätöksensä syntyvät jonkin muun kuin rationaalisen analyysin seurauksena. Toisin sanoen "meluun" pohjaten (Burton, Shah & Shah. 2013, s. 38). Fisher Black (1986) mukaan jotkut sijoittajat käyttävät "melua" kuin se olisi tietoa tehdessään sijoituspäätöstä. Tällöin osakkeen hinta heijastelee osaketta koskevan tiedon lisäksi myös melua, jonka perusteella ostopäätöksiä tehdään. Black arvioi, että jotkut sijoittajat tekevät osakekauppoja kaupanteon ilosta, jotkut taas eivät tajua tekevänsä ostopäätöksiä melun perusteella.

Tekninen analyysi tarkoittaa osakkeen hinnan muutoksen ennustamista käyttäen muuttujina pelkästään osaketta koskevaa historiallista hintadataa sekä kaupankäynnin volyyymia. (Burton ym., 2013). Teknisen analyysin taustalla on ajatus, että osaketta koskevat fundamentaalit on jo hinnoiteltu sisään osakkeen hintaan (Investopedia 2023). Fundamentaaleilla tarkoitetaan yhtiön taloudellista tilaa ja suorituskykyä sekä toimintaympäristöä kuvaavia tunnuslukuja kuten inflaatio, korot, teollisuuden alan elinkaari ja tilinpäätöksen tunnusluvut (Nikiforos, 2012).

Vaikka tekninen analyysi pohjautuu oletuksiin, jotka ovat tehokkaiden markkinoiden hypoteesin vastaiset, teknistä analyysia käytetään silti osakemarkkinoiden ennustamiseen. Teknisen analyysin pohjalta tehdyt sijoituspäätökset aiheuttavat osakkeiden hinnoissa liikkeitä, joita ei voida selittää muutoksilla fundamentaaleissa. On toisaalta esitetty, ettei tällä ole merkitystä koska ei-rationaalisten toimijoiden päätökset niin sanotusti kumoavat toisensa. Jos ei-rationaaliset arviot osakkeen tulevaisuuden hinnasta osuvat keskimäärin molemmille puolille fundamentaaleihin perustuvaa hintaa, on nettovaikutus

osakkeen hintaan mitätön. Käytännössä tämä ei kuitenkaan välttämättä toteudu. Sekä teknisen analyysin käyttäjät, että noise traderit vaikuttavat päätyvän systemaattisesti samankaltaisiin päätelmiin. Täten ei-rationaalisen analyysin pohjalta tehdyt ostopäätökset väkisin heijastuvat osakkeiden hintoihin poikkeamina, joita ei voida selittää tehokkaiden markkinoiden hypoteesin avulla. (Burton ym., 2013).

Tämän kappaleen tarkoituksena ei ole asettua tehokkaiden markkinoiden hypoteesia vastaan vaan pyrkiä osoittamaan, että markkinoilla voi välillä tulla tilanteita, joissa tehokkaiden markkinoiden hypoteesi ei toteudu täydellisesti. Tällöin markkinahinta ei vastaa sitä mikä se yhtiön tulevien kassavirtojen perusteella tulisi olla. Tällöin hyvin informoidun sijoittajan olisi mahdollista pystyä säännöllisesti tekemään tuottoja, joiden ei pitäisi olla mahdollisia tehokkaiden markkinoiden hypoteesin valossa.

## 2.2 Perinteiset osaketuoton ennustamisen mallit

Perinteisesti osaketuottoja eli yhtiön tulevia kassavirtoja ennustetaan hyödyntämällä analyyseja, jotka pohjautuvat taloudelliseen tietoon. Sekä yritystä että koko markkinaa koskevilla numeroilla ja tunnusluvuilla pyritään ennakoimaan yhtiön osakkeen arvon kehitystä (Lev & Thiagarajan, 1993). Tärkeinä tiedon lähteinä toimivat yrityksen tilinpäätös sekä muut, usein yrityksen itse julkaisemat raportit. Tämän lisäksi hyödynnetään paljon niin yhtiökohtaista kuin koko markkinaa koskevaa osakedataa, sekä koko makrotalouden tilaa kuvaavaa tietoa. Taloudellisen tiedon lisäksi analyyseissa käytetään myös ei taloudellista tietoa, josta esimerkkeinä työntekijöiden määrä, johdon kommentit, analyytikkojen arviot sekä luottoluokitukset (Bill Rees, 1990).

Fundamentaalianalyysi on tärkeä osa yhtiön arvonmäärittäystä. Analyysi pyrkii määrittämään yhtiön arvopapereiden arvon tarkastelemalla olennaisia arvon ajureita kuten tulosta, riskiä, kasvua ja asemaa suhteessa kilpailijoihin (Lev & Thiagarajan, 1993). Fundamentaalianalyysin tavoitteena on indikoida yhtiön taloudellista arvoa ottaen huomioon yhtiötä, toimialaa sekä koko taloutta koskevia muuttujia (Lev & Thiagarajan, 1993). Yksittäinen yhtiö toimii osana koko taloutta, joten muutokset talouden tilaa kuvaavissa muuttujissa, kuten BKT, rahapoliittiset päätökset tai työttömyysaste, vaikuttavat yksittäiseen yhtiöön. Keskeisiä yhtiökohtaisia muuttujia yrityksen arvonmäärittämisessä ovat esimerkiksi P/B-luku, osinko ja ROE (return on equity) (Nikiforos, 2012).

Capital Asset Pricing Model (CAPM-malli) on yleisesti käytetty malli odotetun hyödyn arvioimiseksi. Tärkeä oletus mallissa on, että tuottoennuste kulkee käsi kädessä riskin kanssa. Malli ennustaa yhtiökohtaista tuottoa lisäämällä riskittömään tuottoon markkinatuoton kerrottuna yhtiökohtaisella riskikerroimella,  $\beta$  kerralla. Riskikerroin perustuu yhtiön historialliseen volatilitettiin suhteessa markkinan volatilitettiin, minkä ajatellaan heijastelevan yhtiön riskiä. (Rees, 1990).



Vaikka CAPM-mallia hyödynnetään edelleen tuotto-odotusten arvioinnissa muun muassa yrityksissä, sekä opetetaan kaupallisen alan tutkinnoissa, on se kohdannut olemassaolonsa aikana paljon kritiikkiä. CAPM-mallin yhtälön muodostavat riskitön tuotto, markkinapremio sekä yhtiökohtainen Beta, joiden jokaisen muodostamiseen liittyy omat käytännön ongelmansa. Roll (1977) argumentoi, että CAPM-mallin markkinapremiota kuvaavan muuttujan todellista arvoa on vaikeaa, ellei mahdotonta selvittää käytännössä. Samoin riskittömän tuoton määrittely käytännössä tietylle ajankohdalle on vaikeaa. Todellista riskitöntä tuottoa, joka olisi immuuni markkinan vaihtelevuudelle, ei ole olemassa (Rees, 1990). Fama ja French (2004) taas toteavat yhdeksi mallin heikkoudeksi, että betan ja oman pääoman tuoton yhteys on heikompi kuin aikaisemmin on ajateltu. Onkin esitetty, että CAPM-mallin toimivuuden empiirisen testauksen vaikeuden takia CAPM-mallin toimivuutta ei ole koskaan käytännössä validoitu, eikä mallilla täten ole suurta käytännöllistä arvoa (Roll, 1997).

## 2.3 Arvorelevanssi

Tilinpäätösinformaatio on arvorelevanttia, jos sen ja markkina-arvon välillä toteutuu yhteys, eli tilinpäätösinformaatio vaikuttaa ja ennustaa osakehintoja (Barth, Beaver & Landsman, 2001; Rautiainen & Jokinen, 2022). Barth, Li & McClure, (2022) havaitsivat, että yrityksen liikevoiton arvorelevanssi on menettänyt merkitystään, vaikka tilinpäätösinformaation arvorelevanssi kokonaisuutena ei ole menettänyt merkitystään. He esittävät, että aineettoman omaisuuden, vaihtoehtoisten suorituskykymittareiden ja kasvumahdollisuuksien arvorelevanssi on kasvanut.

Barth, Li & McClure (2022) tutkivat tilinpäätösinformaation arvorelevanssin kehitystä NYSE, NASDAQ ja AMEX listatuissa yrityksissä aikavälillä 1962-2018. Heidän tutkimustuloksensa, eivät osoittaneet, että tilinpäätösinformaation arvorelevanssi olisi laskenut. Barth ym. (2022) kuitenkin löysivät, että relevanttien tunnuslukujen määrä on kasvanut, etenkin aineettomia ja kasvumahdollisuuksia mittaavien tunnuslukujen, sekä vaihtoehtoisten tunnuslukujen osalta. Näin ollen tilinpäätöstiedon arvorelevanssi on siirtynyt liikevoitosta ja pääoman tasearvosta aineettomaan omaisuuteen ja kasvumahdollisuuksien mittareihin. Tämä näkyy etenkin korkeanteknologian yrityksissä, mutta ei ole rajoittunut pelkästään näihin vaan näkyy myös muiden alojen yrityksissä. (Barth, ym., 2022). Dunhamin ja Grandstaffin (2022) mukaan liikevoiton ja tasearvon arvorelevanssi on merkittävämpää laskusuhdanteessa, kuin noususuhdanteessa, mutta myös heidän näkemyksensä mukaan liikevoiton arvorelevanssi on vähentynyt muun tilinpäätösinformaation nostaessa merkitystään.

Barth ym. (2022) havaitsivat, että omanpääoman tasearvolla ja liikevoitolla on suurin korrelaatio osakkeen hinnan kanssa  $r = 0.62$  ja  $r = 0.60$ , mutta liikevoiton relevanttius on laskenut 1960-luvun tasosta (59,4 %) 2010-luvulle (36,5 %) tultaessa, missä taas oman pääoman tasearvon relevanttius on noussut 1980-luvun tasosta (6,5 %) 2010-luvulle (14,4 %) tultaessa Barth ym. (2022). Barth ym. (2022) havaitsivat myös, että kassavirran arvorelevanssi on kasvanut nopeimmin viime aikoina 1990-luvulla 2,2 % ja 2010-luvulla 11,0 %.

Neljännesvuosikatsausten ympärille sijoittuva osakehintojen korkea volatilitteetti ja aikaisemmat tutkimukset indikoivat, että tilinpäätösinformaatio on vielä arvorelevanttia. Internet on kuitenkin tuonut sijoittajille mahdollisuuden hyödyntää tilinpäätösinformaation ulkopuolista reaaliaikaista tietoa päätöksentekoprosessissa, kuten erilaisten sijoittajien tunnetilamittareita ja sosiaalisen median kautta saatavaa tietoa. (Dunham & Grandstaff, 2023.) Tästä muutoksesta voi nähdä sijoittajien etsivän tilinpäätösinformaation rinnalle vaihtoehtoisia tietokanavia ja Google Trendsin kaltaisten työkalujen avulla voi olla mahdollista havaita mihin osakkeisiin sijoittajien mielenkiinto suuntautuu kullakin hetkellä.

## 2.4 Sijoittajien kollektiivisen huomion yhteys osakkeen hinnan muutokseen

Monet sijoittajat etsivät tietoa internetistä ja yritysten tilinpäätökset sekä yhtiötä koskevat uutiset ovat internetissä kaikkien saatavilla muutamana klikkauksen päässä nopeammin kuin fyysisten tilinpäätösten ja lehtien kautta. Internetistä informaatiota etsittäessä merkittävässä asemassa ovat erilaiset hakukoneet, joista länsimaissa suurin on Google, jolla on Suomessa 93,38% hakukonemarkkinaosuus (Statcounter, 2022). Sijoittajan etsiessä yhtiön tilinpäätöstä, yhtiötä koskevaa uutista tai sosiaalisen median päivitystä yhtiöön liittyen, on todennäköistä, että informaation etsinnän yhtenä vaiheena on aiheeseen liittyvän hakusanan syöttäminen hakukoneeseen. Tätä logiikkaa seuraten yhtiöön liittyvien hakuvolyymien tulisi jossain määrin heijastella sijoittajien kollektiivista huomiota. Sijoittajien huomion taas on havaittu olevan yhteydessä osakkeen volatilitettiin. Osakkeen volatilitteetti ja riskipreemio kasvavat osakkeeseen kohdistuvan huomion kasvaessa. Kun osakkeeseen kohdistunut huomio on pientä, uusi tieto hinnoitellaan osakekursseihin hiljalleen viiveellä. Kun taas osakkeeseen kohdistunut huomio on suurta, tieto siirtyy hintoihin nopeana purkauksena. (Andrei & Hasler, 2015).

Tutkimusten perusteella ainakin yksityissijoittajien keskuudessa on havaittu epärationaalista laumakäyttäytymistä osakemarkkinoilla (Kumar & Lee, 2006). Ennen hakuvolyymien ja osakehintojen suhteen tutkimista tarkastelemme, onko yksityissijoittajien osto- ja myyntikäyttäytymisellä markkinoita liikuttavaa voimaa. Boehmer, Jones, Zhang & Zhang, (2021) Tutkivat yksityissijoittajien

aktiivisuutta ja sen vaikutusta osakehintoihin. He seurasivat yksityissijoittajien aktiivisuutta Yhdysvaltojen osakemarkkinoilla osakevälittäjien toimeksiantojen määristä, jotka FINRA (Financial Industry Regulatory Authority) julkaisee. Näiden toimeksiantojen määristä Boehmer ym. (2021) havaitsivat, että jos yksityissijoittajat ostivat enemmän, kuin myivät osaketta tiettyinä viikkona, oli seuraavana viikkona osakkeen hinta korkeampi. Tämä indikoi, että yksityissijoittajien päätökset liikuttavat markkinahintoja. Kyseisten muutosten ennustettavuus on suurempaa pienen pääoman, alhaisen osakehinnan ja alhaisen likviditeetin yrityksissä (Boehmer ym., 2021).

Myös Kumarin ja Leen (2006) aikaisempi tutkimus teki samankaltaisia havaintoja yksityissijoittajien käyttäytymisestä, he havaitsivat yksityissijoittajien myynti- ja ostoepätasapainon vaikuttavan osakehintoihin etenkin alhaisen pääoman, korkean yksityissijoittaja omistajuuden yhtiöissä ja korkean "book to market" arvon omaavissa yhtiöissä. Nämä löydökset osoittavat, että yksityissijoittajilla on voima vaikuttaa osakehintoihin, varsinkin edellä mainittujen olosuhteiden vallitessa. Näin ollen myös syntyy mahdollisuus ennustaa mahdollisia hinnan muutoksia heidän käyttäytymistensä tutkimalla.

Jotkut sijoittajat sijoittavat laumamentaliteetilla ja etsivät informaation vapaista lähteistä kuten hakukoneiden avulla, näin ollen voi olla mahdollista ennustaa joidenkin sijoittajien käyttäytymistä Google Trendsin kaltaisilla työkaluilla, joista voi nähdä sijoittajien nousseen informaatio tarpeen (Hsieh, Chan & Wang 2020). Hsieh ym., (2020) havaitsivat tutkimuksessaan, että yksityissijoittajien ostokäyttäytyminen laumana on voimakkaampaa nousumarkkinassa etenkin pienen pääoman yhtiöissä, kun taas laskumarkkinassa yksityissijoittajien laumakäyttäytyminen on voimakkaampaa osakkeiden myyjinä etenkin isomman pääoman yhtiöissä. Kumar ja Lee (2006) havaitsivat, että yksityissijoittajat myyvät ja ostavat osakkeita yhtenäisesti ja heillä on tapana ostaa tiettyä osaketta yhtenäisesti samanaikaisesti, kun he myyvät toista.

Tätä sijoittajien yhtenevää käyttäytymistä kutsutaan sijoittajasentimentiksi, eli tunnetilaksi tai mielialaksi, joka vallitsee markkinoilla ja ohjaa sijoittajien päätöksen tekoa. Aikaisemmat tutkimukset ovat löytäneet linkkejä sijoittajasentimentin ja markkinoiden hinnanmuutosten välillä ja sijoittajasentimentti on myös yhdistetty väärinhinnoitteluun. (Berger, 2022). Yksityissijoittajien ajamaa hinnan muutosta onkin pyritty selittämään heidän taipumuksellaan laumakäyttäytymiseen (Hsieh, Chan & Wang, 2020).

Tutkimustulokset osoittavat, että yksityissijoittajien sentimentti vaikuttaa osakkeiden hintoihin voimakkaimmin, kun markkinoille virtaa uusia sijoittajia ja sijoittajat ovat ylioptimistisia. Lisäksi on havaittu, että yksityissijoittajat allokoivat ison osan varallisuudestaan osakepääomaan (Berger, 2022). Sijoittajasentimentillä on havaittu olevan erityisesti vaikutus uusissa pienissä yrityksissä, joiden osakehintana on volatiili (Berger, 2022). Tämä on linjassa Boehmerin ym. (2021) sekä Kumarin ja Leen (2006) havaintojen kanssa, siitä minkä tyyppisiin osakkeisiin yksityissijoittajien käyttäytyminen vaikuttaa.

Laumakäyttäytymiselle löytyy informaatio- ja käyttäytymisselitteisiä motiiveja. Aikaisemmat tutkimukset ovat havainneet, että informaationselitteinen laumakäyttäytyminen on mahdollista etenkin, kun sijoittajilla on pääsy samaan tietoon ja he omaavat samanlaisen koulutus- ja urataustan. Vlastakis ja Markellos (2012) havaitsivat, että sijoittajien informaatiotarve nousee, kun markkinat ovat volatiilit ja voimistuu entisestään korkeiden tuottojen aikana. Hamid ja Heiden (2015) vievät tätä näkemystä pidemmälle ja esittävät markkina vaihteluiden olevan seuraus sijoittajien osoittamasta kiinnostuksesta, eikä toisinpäin.

Berger (2022) löysi tutkimuksessaan, että yksityissijoittajien sijoitusaktiivisuus ajoittuu samalle ajalle epänormaalien osakehintojen kanssa. Yksityissijoittajien kaupankäynnin onkin havaittu liikuttavan markkinoita viikon mittaisissa aikajaksoissa. Berger (2022) havaitsi tutkimuksessaan, että osakkeissa, joiden volatilitteetti oli suuri, ilmeni epänormaaleja tuottoja korkean positiivisen ja negatiivisen sijoittajasentimentin jälkeisenä kuukautena. Epänormaaleilla tuotoilla tarkoitetaan tietyllä aikajaksolla sijoitukselle kertynyttä positiivista tai negatiivista tuottoa, joka poikkeaa CAPM -mallin tuotto-odotuksesta tai pitkänaikavälin historiallisesta tuotto-odotuksesta (investopedia, 2022). Epänormaaleja tuottoja saattaa ilmentyä, kun sijoittajat havaitsevat osakkeen väärinhinnoittelun, mutta "noise trader" riskin pelossa eivät pyri hyödyntämään väärinhinnoittelua (Berger, 2022). "Noise trader" -riski nostaa arbitraasin kustannuksia eli väärinhinnoittelusta hyötymistä. Eli vaikka sijoittajat havaitsevat väärinhinnoittelun, he eivät välttämättä kykene hyödyntämään sitä, koska noise traderit pitävät osakkeen hintaa korkealla eikä heidän voi olettaa korjaavaan sijoituskäyttäytymistään ennalta annetussa ajassa. Näin ollen osakkeen hinnan palautuminen yrityksen taloudellisiin tietoihin pohjautuvalle tasolle on epävarmaa. (D'Hondt & Roger 2017).

## 2.5 Google Trends ja osaketuoton ennustaminen

Google Trends on Googlen tarjoama työkalu, joka kertoo paljonko jotain hakusanaa, on haettu tietynä aikana. Hakuvolyymeista ei ole saatavilla absoluuttisia arvoja, vaan arvot on suhteutettu haetun ajanjakson suurimpaan arvoon nähden. Haetun ajanjakson suurin arvo saa suhdeluvun 100 ja muut kyseisen ajanjakson arvot suhteutetaan tähän arvoon. Esimerkiksi haettaessa päivittäisiä hakuvolyymeja kuukauden ajalta, saa päivä, jona tapahtui eniten hakuja arvon 100 ja loput päivät suhteutetaan tähän.

Tutkimuksessaan Hamid ja Heiden (2015) tutkivat Google Trends volyymin muutosten yhteyttä koko USA:n osakemarkkinan volatilitettiin. Heidän käyttämä osakedata oli Dow Jones Industrial Average indeksi ja Google Trends -aplikaatiossa käytetty hakuterminä oli "dow". Heidän käyttämänsä aikajänne volatilitettiin ennustamisessa oli viikko. Tutkimuksessa todettiin, että sijoittajien huomio on yksi volatilitettiin aiheuttajista, ja että Google Trends toimii välineenä sijoittajien huomion seuraamiseen. Tutkijat huomasivat myös, että

aikoina, jolloin pörssissä on nähty suurta volatiliutta, tarkkuus Google Trendsin avulla tehdyissä ennusteissa on kasvanut. (Hamid & Heiden 2015). Samaan johtopäätökseen koskien Googlen hakuvolyymien avulla ennustamisen tarkkuutta epävarmoina aikoina, tulee myös Heiberger (2015). Hänen tutkimuksensa Google Trends hakuvolyymien nousua pidettiin merkinä yritysten ja markkinan kannalta huonoista uutisista. Tutkimuksessa tultiin johtopäätökseen, että Google Trends hakutulosten äkkinäinen nousu epävarmoina aikoina ennakoii osakekurssin laskua. Aikaisemmat tutkimukset siis osoittavat, että koko osakemarkkinan volatiliteetin ennustamisessa Google Trends volyymit saattavat olla relevantti muuttuja. Seuraavaksi käydään läpi tutkimuksia, joissa tutkitaan voiko yhtiökohtaisilla Google Trends arvoilla ennustaa yhtiökohtaista volatiliteettia tai osaketuottoa.

Ajatusta, jonka mukaan Google Trends hakuvolyymeilla on yhteys yhtiön osakkeen hinnan muutoksiin tai osakekaupan aktiivisuuteen tukevat useat tutkimukset. Japanilaisten yhtiöiden hakuvolyymit korreloivat vahvasti osakkeen vaihdon kanssa sekä jossain määrin osaketuoton kanssa. Korrelaatio hakuvolyymien ja osaketuoton kanssa oli todennäköisin pienillä yhtiöillä verrattuna suuriin (Takeda & Wakao. 2014). Tutkimuksessaan Salisu ym., (2021) käyttivät Google Trends arvoja sijoittajien huomion mittarina tutkiessaan voiko Google Trends arvojen avulla ennustaa alakohtaisia osaketuottoja. He käyttivät Google Trends lukuja itsenäisenä alakohtaisten tuottojen ennustajana sekä usean muuttujan mallissa yhtenä muuttujana makrotalouden tilaa kuvaavien muuttujien rinnalla. Heidän tuloksensa osoittavat Google Trends -arvojen käytön tarkentavan ennusteita verrattuna mittapuuna käytettyyn satunnaiskävelymalliin. Eräässä tutkimuksessa Google Trends -arvoja käytettiin muuttujana Fama-French kolmen muuttujan mallissa tutkittaessa kehittyvien markkinoiden (Malesia, Indonesia, Vietnam, Filippiinit ja Thaimaa) osaketuottojen ja Google Trends -arvojen yhteyttä. Filippiinien, Thaimaan ja Vietnamin tapauksessa Google Trends -arvoilla havaittiin tilastollisesti merkitsevä negatiivinen korrelaatio. Lisäksi tutkimuksessa käytetyn Google Trends -muuttujan havaittiin selittävän osaketuottoa osana Fama-French kolmen muuttujan mallia. (Nguyen ym., 2019). Oman tutkimuksemme kannalta relevantein tutkimus on Norjan osakeyhtiöiden, ja Google Trends -arvojen yhteyttä tarkastellut tutkimus. Tutkijat havaitsivat, ettei Google Trends -arvoilla pystynyt ennustamaan osaketuottoa, mutta Google Trends -arvojen kasvu korreloi positiivisesti vaihdon kanssa ja ennusti volatiliteetin kasvua (Neri ym., 2019). Nämä aiemmat tutkimukset ovat jo osin hieman ikääntyneitä. Lisäksi viimeiset vuodet ovat olleet turbulenteja ja Suomi kontekstina voi olla erilainen. Niinpä esitämme seuraavat hypoteesit koskien Google Trends -arvojen sekä osakkeen hinnan muutoksen yhteyttä:

## **Hypoteesi 1**

*H1: Google Trends (GT) -hakuvolyymia tai sen muutosta kuvaava arvo korreloi positiivisesti ja tilastollisesti merkitsevästi osakkeen volatilitiitin ja osaketuoton kanssa.*

## **Hypoteesi 2**

*H2: Google Trends -arvot auttavat ennustamaan suomalaisten osakkeiden tulevaa tuottoa 3 kk. aikavälillä etenkin yhdistettynä yhtiötä koskevien taloudellisten tunnuslukujen kanssa.*

## **3 AINEISTO JA MENETELMÄ**

### **3.1 Aineisto**

Tutkimuksen aineisto on kerätty useasta eri lähteestä suurimmaksi osaksi manuaalisesti. Aineistomme koostuu osakedatasta, Google Trends -hakuvolyymeista sekä taloudellisista kontrollimuuttujista. Tutkimuksen kohteena on 97 Helsingin pörssiin yhtiötä. Tutkimuksessamme tarkastellaan vuoden 2021 ensimmäisellä vuosineljänneksellä tapahtuneita muutoksia osakekursseissa. Kokonaisuudessaan aineistomme kattaa dataa ajalta 2019–2021.

Olemme joutuneet sulkemaan joitakin yhtiöitä pois aineistostamme. Yhtiöiltä, jotka on listattu pörssiin vasta vuosien 2019–2021 aikana ei luonnollisesti ole saatavilla osakedataa koko kyseiseltä aikaväliltä, joten pitääksemme aineistomme täysin yhdenmukaisena, olemme jättäneet kyseiset yhtiöt tarkastelun ulkopuolelle. Olemme myös sulkeneet aineistosta pois yhtiöt, joita koskeva GT-data pitää sisällään liikaa nollatuloksia. Nämä yhtiöt ovat pieniä yhtiöitä, joita on haettu Googelta suhteellisen vähän, jolloin nollatulosten määrä kasvaa, ja toisaalta jo pieni hakumäärien kasvu nostaa arvoa merkittävästi, tehden kyseisiä yhtiöitä koskevan aineiston keskihajonnasta erittäin suuren sekä tutkimuksemme kannalta vähemmän luotettavan.

Osakedatana käytämme Helsingin pörssin päiväkohtaisia osakekursseja. Osakekurssit on haettu osoitteesta [www.nasdaqomxnordic.com](http://www.nasdaqomxnordic.com). Osakekurssit on haettu kolmen vuoden ajanjaksolta vuodesta 2019 vuoteen 2021. Tutkimuksessa muuttujina käytetyt osakkeen volatilitteetti ja osaketuotto ovat molemmat laskettu perustuen tähän dataan. Osaketuottona käytämme puhtaasti osakkeen hinnan muutoksen tuomaan arvon nousua. Olemme laskeneet, paljonko yhtiön osakkeen arvo on prosentuaalisesti kasvanut määrättyinä aikoina. Emme siis tässä tutkimuksessa ota huomioon esimerkiksi yhtiöiden maksamia osinkoja, vaikka ne ovatkin yksi kassavirran lähde osakkeen omistajille.

Google hakuvolyymit on haettu Google Trends applikaatiosta. Myös hakuvolyymit on haettu kolmen vuoden ajanjaksolta vuodesta 2019 vuoteen 2021. Data koostuu viikoittaisista hakuvolyymia kuvaavista luvuista. Nämä luvut perustuvat tietyn hakusanan tietyn ajankohdan hakuvolyymeihin, jotka on suhteutettu kaikkien hakusanojen hakuvolyymeihin samana ajankohtana. Tällöin, vaikka tiettyä hakusanaa haettaisiin enemmän kuin vuosi aikaisemmin, ei Google Trends arvo näytä isompaa lukua, mikäli ylipäätään kaikkien hakutermien hakuvolyymi on kasvanut. Tällä tavoin hakuvolyymia kuvaavista arvoista saadaan vertailukelpoisempia keskenään. Lisäksi Google Trends arvot voivat hieman vaihdella riippuen ajankohdasta, jolloin arvot on haettu. Suhteutus historiallisiin hakuvolyymeihin nimittäin perustuu satunnaisesti valittuun historialliseen datasettiin. Kuitenkin datan pitäisi olla luotettavaa ja vertailukelpoista itsensä kanssa riippumatta ajankohdasta, jolloin se on haettu. Da, Engelberg & Gao. (2011) hakivat google trends arvoja samoille hakutermeille eri ajankohdilta ja havaitsivat, että niiden korrelaatiot keskenään ovat säännöllisesti yli 97 %.

Kontrollimuuttujina olemme käyttäneet taloudellisia tunnuslukuja, jotka olemme keränneet manuaalisesti Kauppalehden sivuilta. Taloudelliset tunnusluvut perustuvat vuoden 2020 tilinpäätökseen. Tutkimuksessa käytetyt kontrollimuuttujat ovat seuraavat. Sijoitetun pääoman tuotto (ROI%) ja Oman pääoman tuotto (ROE%), jotka kuvaavat yhtiön tulosta suhteessa investoituun pääomaan sekä tulosta suhteessa yhtiön oman pääoman määrään. Nettotulos% ja käyttökate% kuvaavat yhtiön kannattavuutta. Omavaraisuusaste kuvaa yhtiön vakavaraisuutta ja lasketaan suhteuttamalla yhtiön oma pääoma taseen loppusummaan. Quick ratio ja current ratio kuvaavat yhtiön maksuvalmiutta eli kykyä selviytyä lyhyen aikavälin vastuista. P/B luku sekä P/E luku ottavat huomioon yhtiön puhtaasti taloudellisten muuttujien lisäksi myös yhtiön arvostuksen pörssissä. P/B-luku lasketaan jakamalla yhtiön markkina-arvo yhtiön omalla pääomalla. P/E-luku lasketaan jakamalla yhtiön markkina-arvo yhtiön tuloksella. Yhtiökohtainen Beta, joka kuvaa osakkeen hinnan volatiiliutta tiettyinä aikoina sekä CAP-mallin mukainen tuotto-odotus, joka lasketaan yhtiökohtaisen Betan sekä markkinoiden riskittömän tuoton ja markkinoiden tuotto-odotuksen pohjalta.

Vuoden 2020 tilinpäätöksen tunnusluvut ovat mielestämme relevantteja tutkimuksemme kannalta, koska tilinpäätökset julkaistaan pääsääntöisesti seuraavan vuoden ensimmäisen vuosineljänneksen aikana, tässä tapauksessa siis

vuoden 2021 ensimmäisen vuosineljänneksen aikana. Eli aikana, jolle varsinainen tutkimuksemme ajoittuu. Kaikki käyttämämme kontrollimuuttajat, lukuun ottamatta nettotulos%:a ja käyttökate%:a, on poimittu sellaisenaan Kauppalehden sivuilta. Nettotulos% ja käyttökate% on laskettu Kauppalehdestä otettujen liikevaihtojen sekä nettotulosten ja käyttökatteiden perusteella taulukkolaskentaohjelmalla.

Joissain Google Trends arvojen ja osakemarkkinan käyttäytymistä tutkivissa papereissa on käytetty Google Trends hakuterminä yhtiön kaupankäyntitunnusta (Nguyen ym. 2019). Tämä on tehty siksi, että yrityksen nimellä Googlasta tietoa hakevien joukossa on sijoittajien lisäksi paljon ihmisiä, jotka eivät hae tietoa sijoitusmielessä. Sen sijaan kaupankäyntitunnuksella tietoa hakevat ovat suurella todennäköisyydellä sijoittajia. Käyttämällä kaupankäyntitunnusta aineiston "melua" saadaan pienennettyä. Samalla pienenee se hakutulosten määrä, johon Google Trends luku perustuu. Tämä johtuu siitä, että yhtiötä koskevaa tietoa haetaan enemmän yhtiön nimellä kuin kaupankäyntitunnuksella. Kuten Neri ym. (2019) aineistossa, joka koostui norjalaisista osakkeista, myös meidän aineistoamme koskien on huomioitava, että Suomalaisia yhtiöitä haetaan Googlessa suhteellisen vähän. Tämä tarkoittaa, että emme voi asettaa merkittäviä rajoitteita hakukriteereille, jotta aineistoomme ei tulisi liikaa nollatuloksia. Lisäksi kaupankäyntitunnukset ovat joissain tapauksissa lyhenteitä, joilla on eri merkitys eri kontekstissa, mikä tekee kaupankäyntitunnuksen käyttämisen tässä tapauksessa hyödyttömäksi. Google Trends applikaatiossa on myös mahdollista rajata hakutuloksia kategorioittain. Kategorioita on yhteensä 25, esimerkkeinä: uutiset, taide & viihde, terveys, rahoitus. Yritimme hakea tietoja käyttämällä kategoriaa rahoitus, mutta nollatulosten määrä kyseisellä rajauksella kasvoi merkittävästi. Tämän takia, kuten myös Bijl ym. (2016) ja Kim ym. (2019), haemme tiedot ilman rajaavaa kriteeriä, eli sallimme kaikki kategoriat.

Aineiston "melun" vähentämiseksi on mahdollista tehdä toimenpiteitä lisäämättä nollatulosten määrää samalla liian suureksi. Hakusanoina olemme käyttäneet yhtiöiden koko nimiä sekä applikaation ehdottamaa hakua tarkentavaa rajausta. Esimerkiksi haettaessa yhtiötä Elisa, applikaatio ehdottaa hakutuloksia kohteelle Elisa Telecommunications company, tai vaihtoehtoisesti haettaessa yhtiötä Kone, applikaatio ehdottaa hakutuloksia kohteelle Kone engineering company. Tällöin haut koskevat nimenomaan yhtiötä ja haun ulkopuolelle on jätetty esimerkiksi Elisa nimisiä ihmisiä koskevat haut, tai vaihtoehtoisesti mitä tahansa epämääräistä "konetta" tarkoittavat haut.



## 3.2 Menetelmä

Aineistomme koostuu täysin numeerisesta datasta, joten sen analysoimiseksi käytämme tilastollisia menetelmiä. Analysointi on toteutettu taulukkolaskentaohjelmalla sekä SPSS-ohjelmistolla. Tärkeimpänä yksittäisenä analyysin menetelmänä tutkimuksessamme on regressioanalyysi. Regressioanalyysi on yksi keskeisimpiä analyysimenetelmiä tilastollisen mallintamisen saralla. Regressioanalyysiä käytetään, kun halutaan löytää sellaisia muuttujia, jotka selittävät vaihtelua kohdemuuttujassa. Toisin sanoen, halutaan löytää muuttujia, jotka ovat kohdeilmion kannalta relevantteja. (Metsämuuronen, 2017, s. 227-228).

Korrelaatio kuvaa kahden muuttujan yhteyttä toisiinsa. Korrelaatiokerroin eli regressiokerroin taas kuvaa sitä määrää yhden muuttujan hajonnasta, joka on selitettävissä toisella muuttujalla. Toisin sanoen korrelaatio kuvaa muuttujien riippuvuutta ja regressiokerroin kuvaa vaikutuksen voimakkuutta eli kuinka iso vaikutus selittävällä muuttujalla on kohdemuuttujaan (Alkula, Pöntinen & Ylöstalo 1994, s. 247). Regressioanalyysi mahdollistaa useiden muuttujien välisten riippuvuussuhteiden tutkimisen. Regressioanalyysissä selitettävää muuttujaa kutsutaan nimellä dependent variable ja selittäviä muuttujia nimellä independent variable. Selittäviä muuttujia voi olla yksi tai useita yhdessä mallissa. Kun selittäviä muuttujia on useita, näiden kaikkien muuttujien selitysvoiman yhteisvaikutusta suhteessa selitettävän muuttujan vaihteluun voidaan mitata. Selittäviä muuttujia voidaan valita useita, kun pyrkimyksenä on löytää suuresta muuttujien valikoimasta ne muuttujat, jotka selittävät kohdemuuttujan vaihtelua. Tällöin puhutaan eksploratiivisesta regressioanalyysistä. Toinen tapa on valita vain teoreettisen viitekehyksen kannalta relevantteiksi tunnettuja muuttujia (Metsämuuronen, 2017, s. 228–230). Olemme valinneet muuttujat perustuen edellisiin tutkimuksiin, joissa on havaittu tilastollisesti merkitseviä tuloksia kyseisten muuttujien ja osakkeen hinnan muutoksen välillä. Täten emme varsinaisesti etsi kokonaan uusia muuttujia, joilla yritämme selittää kohdeilmiötä. Ennemmin, pyrimme tutkimaan selittävätkö jo aikaisemmin relevantteiksi havaitut muuttujat ilmiötä myös meidän kohdeympäristössämme, eli Suomen osakemarkkinoilla. Tutkimuksessamme on mukana tosin myös muuttuja, jota emme ole havainneet muissa tutkimuksissa. GT vs KA-muuttuja, joka vertaa GT-luvun viimeaikaista muutosta GT-luvun pitkäaikaiseen trendiin. Olemme itse laskeneet kyseisen muuttujan taulukkolaskentaohjelmalla.

Aikaisemmat tutkimukset ovat osoittaneet, että varsinkin osakkeen volatiliteettia pystytään selittämään Google hakuvolyymia kuvaavilla muuttujilla. Pyrimme tässä tutkimuksessa selvittämään, pystyykö malli, joka muilla osakemarkkinoilla on selittänyt kohdeilmiötä, selittämään kyseistä ilmiötä myös Suomen osakemarkkinoilla.

Ohessa kaava regressioanalyysille:

$$Y = A + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_i X_i + \varepsilon$$

Kaavan muuttuja  $Y$  kuvaa selitettävää muuttujaa, ja muuttujat  $X_1$ - $X_i$  selittäviä muuttujia. Muuttuja  $A$  on vakio, joka saa arvon vasta analyysin edetessä. Vakio kuvaa tilannetta, jossa millään muuttujista ei ole selittävää voimaa mallissa. Muuttujat  $\beta$  ovat painokertoimia, joita on yhtä suuri määrä kuin selittäviä muuttujia.  $\beta$  muuttujat lasketaan datan perusteella siten, että mallin selittämättä jäänyt hajonta jää mahdollisimman pieneksi. (Metsämuuronen, 2017, s. 234–236). Toisin sanoen kertoimet  $A$  ja  $\beta$  määräytyvät aineiston mukaan ja kuvaavat muuttujien  $X$  vaikutusta muuttujaan  $Y$ . Koska malli ei käytännössä tule olemaan täysin lineaarinen vaan otoksen arvot tulevat olemaan hieman hajallaan yhtälön ennustamista arvoista, tulee yhtälöön lisätä virhetermi, joka ottaa huomioon tämän otoksen arvojen hajonnan suhteessa yhtälön ennustukseen (Alkula ym., 1994, s. 248).

Regressioanalyysiin liittyy oletuksia, joiden paikkansapitävyyttä tulee arvioida analyysia suoritettaessa. Yksi oletus on, että mallin selittämättä jäänyt osa eli residuaalit ovat normaalisti jakautuneet ja vakiovarianssiset. On myös tavallista tarkistaa, ettei aineisto sisällä suuria poikkeavia arvoja, sillä näillä on, suhteessa ei-poikkeaviin havaintoihin, todella suuri vaikutus korrelaatiokertoimiin. Lisäksi on suotavaa, että selittävät muuttujat korreloivat selitettävien muuttujien kanssa. Sen sijaan selittävien muuttujien välillä ei tulisi olla merkittäviä korrelaatioita. (Metsämuuronen, 2017, s. 230).

Regressioanalyysiä voidaan käyttää kolmeen eri tarkoitukseen. Ensinnäkin sitä hyödyntäen voidaan pyrkiä mallintamaan jotakin ilmiötä. Toisin sanoen etsiä ilmiön kannalta merkittäviä muuttujia. Toiseksi regressioanalyysiä voidaan käyttää jo ennestään käytetyn mallin toimivuuden testaamiseen. Viimeiseksi analyysiä hyödyntäen voidaan myös pyrkiä ennustamaan ilmiön käyttäytymistä tulevaisuudessa. (Metsämuuronen, 2017, s. 230–231).

Tutkimuksemme regressioanalyysissä selitettäviä muuttujia ovat osakkeen tuotto sekä osakkeen volatilitteetti. Selittävinä muuttujina taas on käytetty taloudellisia tunnuslukuja, GT luvun kolmen kuukauden keskihajontaa, GT luvun kolmen kuukauden keskiarvoa sekä GT luvun kolmen kuukauden keskiarvon poikkeamaa pitkän aikavälin keskiarvoon verrattuna. GT luvun keskiarvo on laskettu yksinkertaisesti ottamalla keskiarvo viikoittaisista GT luvuista kyseisten kolmen kuukauden ajalta, samalla tavalla on laskettu myös GT luvun keskihajonta. GT luvun poikkeama pitkän aikavälin keskiarvoon on puolestaan laskettu vertaamalla kolmen kuukauden keskiarvoa kolmen vuoden keskiarvoon, laskemalla montako prosenttia kolmen kuukauden keskiarvo eroaa kolmen vuoden keskiarvosta. Tämän muuttujan tarkoituksena on, havainnollistaa onko yhtiötä koskevissa hakujen määrässä ollut kyseisenä

ajankohtana nousevaa tai laskevaa trendiä verrattuna normaaliin hakumäärään. Erityisesti olemme kiinnostuneita tästä muuttujasta, koska keskiverto hakuvolyymia suurempi hakuvolyymi indikoi kasvavaa kiinnostusta yhtiötä kohtaan, tai yhtiötä koskevia muutoksia. Tutkimuksessa muuttujina käytetyt taloudelliset tunnusluvut kokonaisuudessaan ovat: sijoitetun pääoman tuotto (ROI%), Oman pääoman tuotto (ROE%), nettotulos%, käyttökate%, omavaraisuusaste, quick ratio, current ratio, P/B luku sekä P/E luku, beta ja CAP-malli.

Kuten jo mainittu, regressioanalyysiin voidaan valita useita eri selittäviä muuttujia. Näistä lopulliseen malliin kuitenkin valikoituu yleensä vain osa. Tarkoituksena on päätyä lopputulokseen, jossa mahdollisimman suuri osa selitettävän muuttujan hajonnasta pystytään selittämään sellaisella selittävien muuttujien joukolla, mikä on ilmiön kannalta mahdollisimman olennainen ja merkitsevä. Tähän lopputulokseen pääsemiseksi kolme suosituinta metodologiaa ovat takaperin tapahtuva eliminointi (backwards elimination), askeltava menetelmä (stepwise) ja ennakoiva menettely (forward selection). Takaperin tapahtuva eliminointi pudottaa mallista pois ne muuttujat, joiden selitysvoima on kaikista pienin. Menetelmä ottaa huomioon vain tilastollisesti merkitsevimmät muuttujat ja sulkee pois muut, vaikka näiden joukossa voisi olla ilmiön kannalta relevantteja muuttujia. Yksi ongelma tässä menetelmässä on, että se ei poista tarkastelusta multikollineaarisia muuttujia, vaan ottaa myös nämä huomioon. Ennakoivassa menettelyssä valitaan ensimmäiseksi eniten selitettävän muuttujan hajontaa selittävä muuttuja, minkä jälkeen seuraavaksi muuttujaksi valitaan muuttuja, joka lisätynä ensimmäisen muuttujan kanssa malliin, nostaa eniten mallin selitysvoimaa. Uusia muuttujia lisätään niin kauan, kunnes uuden muuttujan lisääminen ei enää kasvata mallin selitysvoimaa. Multikollineaarisuus ei ole ennakoivassa metodissa ongelma sillä multikollineaarisen muuttujan lisääminen malliin ei todennäköisesti kasvata mallin selitysvoimaa, eikä täten tule valituksi malliin. Askeltava menettely on yhdistelmä ennakoivaa menettelyä ja takaperin eliminointia. Tässä menettelyssä muuttujat valitaan lähtökohtaisesti samaan tyyliin kuin ennakoivassa menettelyssä, mutta jokainen valittu muuttuja käydään myös jälkepäin läpi poistamalla se menettelystä ja katsomalla laskeeko se selitysvoimaa. (Metsämuuronen, 2017, s. 243–244) (Myers & Well, 1995, s. 518).

Halusimme valita tutkittavaksi ajankohdaksi periodin, jolloin Google hakujen määrä on ollut tavallista suurempi. Tällöin pystymme minimoimaan nollatulosten määrän. Olemme valinneet tarkasteltavaksi ajankohdaksi vuoden 2021 ensimmäisen neljänneksen. Tämä oli havaintojemme perusteella toiseksi suurimpien GT-hakuvolyymien kausi vuodesta 2019 vuoteen 2021. Eniten yhtiötä haettiin vuoden 2020 ensimmäisellä neljänneksellä, mutta emme halunneet ottaa kyseistä ajankohtaa tarkasteluun sillä kyseinen aika oli tavallisesta todella poikkeava juuri alkaneen Covid19 pandemian vuoksi. Vuoden 2021 ensimmäinen neljännes on mielenkiintoinen myös siinä suhteessa, että osakemarkkinoilla keskeiset indeksit nousivat reilusti.

Regressioanalyysin nollahypoteesi on, että regressiokertoimet saavat arvon nolla, jolloin malliin valitut muuttujat eivät selitä selitettävän muuttujan vaihtelua.

TAULUKKO 1 Tutkimuksessa käytetyt muuttujat

Selitettävät muuttujat	Selittävät GT muuttujat	Selittävät kontrollimuuttujat
<ul style="list-style-type: none"> <li>- Osakkeen 3kk volatilitteetti</li> <li>- Osakkeen 3kk tuotto</li> </ul>	<ul style="list-style-type: none"> <li>- GT luvun keskiarvo</li> <li>- GT luvun keskihajonta</li> <li>- GT luvun poikkeama pitkän ajan ka:sta</li> </ul>	<ul style="list-style-type: none"> <li>- ROI%</li> <li>- ROE%</li> <li>- Omavaraisuusaste</li> <li>- Beta</li> <li>- CAP-Malli</li> <li>- Nettotulos%</li> <li>- Käyttökate%</li> <li>- Quick ratio</li> <li>- Current ratio</li> <li>- P/E luku</li> <li>- P/B luku</li> </ul>

## 4 TUTKIMUKSEN TULOKSET

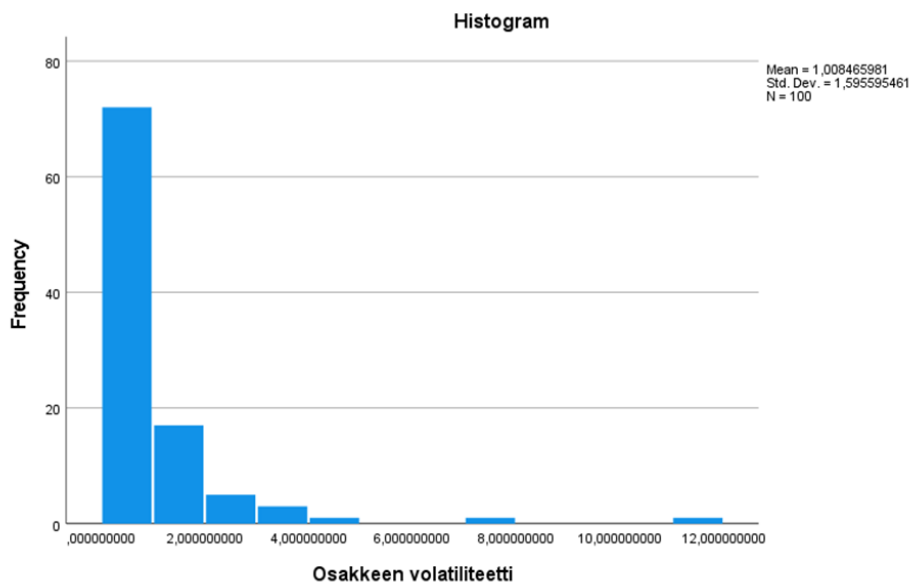
### 4.1 Tulokset

#### 4.1.1 Diagnostiset tarkastelut

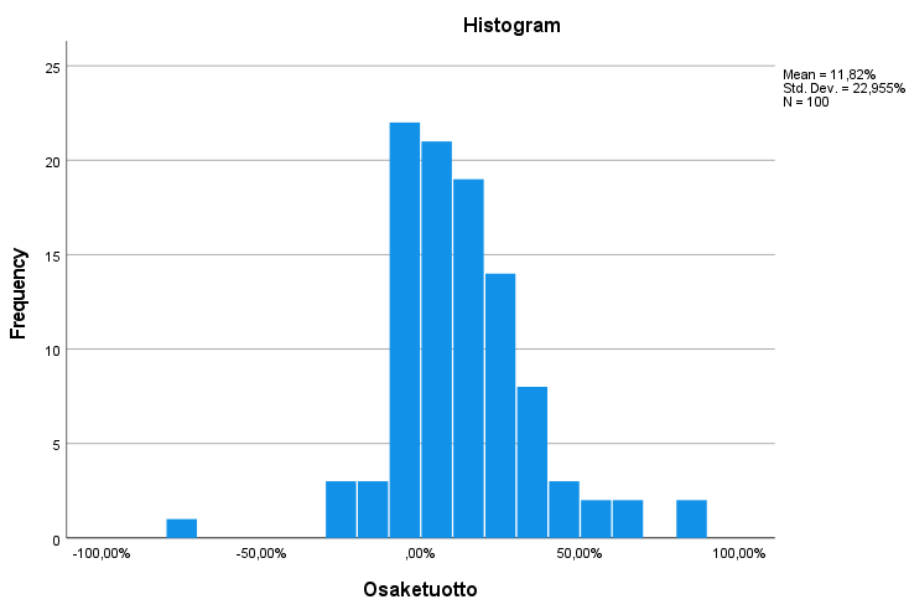
Selitettävien muuttujien ja selittävien muuttujien välillä tulisi olla tilastollisesti merkitsevä korrelaatio. Sen sijaan selittävien muuttujien välillä korrelaatiota ei tulisi olla. Muuttujien välisiä korrelaatiota on mahdollista selvittää SPSS:n avulla. Selittävien muuttujien korreloidessa keskenään voidaan tällaiset muuttujat lisätä malliin, mutta ainoastaan toinen valitaan selittäväksi muuttujaksi lopulliseen analyysiin ja toisen muuttujan selittävää voimaa ei huomioida. (Metsämuuronen, 2017, s. 233). Tutkimuksessamme tilastollisesti merkitseviä korrelaatioita löytyi selitettävien ja selittävien muuttujien väliltä. Myös selittävien muuttujien väliltä keskenään löytyi tilastollisesti merkittäviä muuttujia. Tosin, kuten näemme regressioanalyysin tuloksista jäljempänä, voidaan multikollineaarisuuden mahdollisuus sulkea tämän tutkimuksen regressiomallista pois, joten tämä ei muodostu ongelmaksi.

Osakkeiden volatilitteettien (kuvio 1) ja osaketuottojen (kuvio 2) frekvenssit paljastavat mielestämme kaksi selkeää ja yhden melko selkeän poikkeavan havainnon, jotka ovat Qt, Orthex ja Neste. Nämä yhtiöt on jätetty regressioanalyysin ulkopuolelle. Kuviot 1 ja 2 havainnollistavat poikkeavien havaintojen jakautumista. Kuvio 1 näyttää histogrammin oikeassa reunassa kolme yksittäisen yrityksen sisältämää palkkia, joista kaksi ovat merkittävästi erillään muista. Kuten nähdään, on näiden yhtiöiden volatilitteetit selkeästi poikkeavat muista yhtiöistä. Nämä havainnot on jätetty pois analyysistä. Kuviossa 2 on samanlainen jakauma osaketuotoista. Kuten nähdään, ei osaketuottojen kohdalla ole kuin yksi selkeästi muusta aineistosta poikkeava arvo vasemmalla alareunassa. Tämä havainto on jätetty analyysin ulkopuolelle. Yllä mainitut kolme yhtiötä aiheuttavat kaikki mainitut poikkeamat, joten ne on päätetty jättää tarkastelun ulkopuolelle. Lopulliseen tarkasteluun otetaan yhteensä 97 yhtiötä.

Osakkeen volatilitiitti



KUVIO 1 Histogrammi osakkeen volatilitiettien jakautumisesta



KUVIO 2 Histogrammi osaketuottojen jakautumisesta

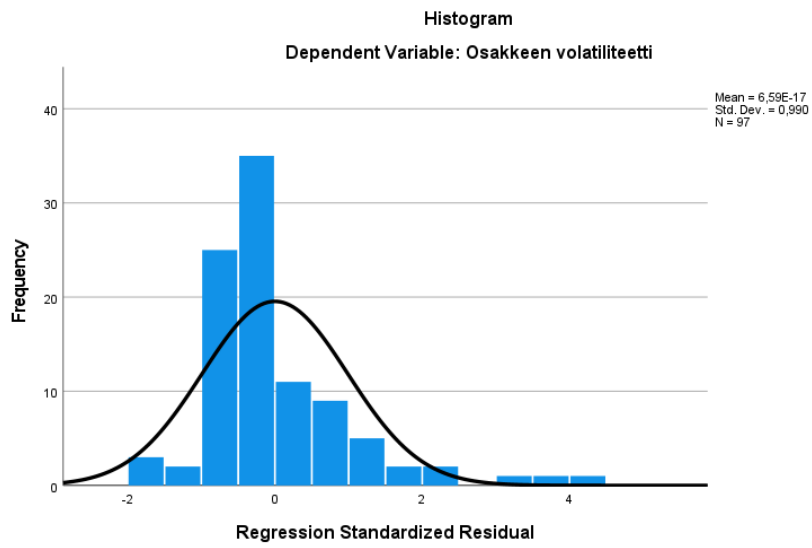
Suljettuamme tarkastelusta pois poikkeavat havainnot, selvitimme muuttujien väliset korrelaatiot. Jotta regressioanalyysin voi ylipäättään suorittaa, on tutkittavien muuttujien välillä oltava edes jonkinasteinen korrelaatio.

Liitteissä olevasta taulukosta (Liite 1) näemme muuttujien väliset korrelaatiot. Osakkeen volatilitietin ja GT-keskihajonnan välinen korrelaatio on tilastollisesti merkitsevä p-arvolla 0,05. Tilastollisesti merkitsevä korrelaatio p-


arvolla 0,01 löytyi osakkeen volatilitiitin sekä sijoitetun pääoman tuoton (ROI%), oman pääoman tuoton (ROE%) ja P/B-luvun kanssa. Osaketuoton kanssa korreloi nettotulos% p-arvolla 0,05. P-arvolla 0.01 korrelaatio löytyi GT vs KA sekä P/B luvun kanssa. Regressioanalyysin kannalta tärkeät korrelaatiot siis löytyvät aineiston muuttujien välillä. Hypoteesiemme kannalta erityisesti mielenkiintoista on nähdä korrelaatiot Google Trends -arvoihin perustuvien muuttujien ja osakkeen volatilitiitin sekä osaketuoton kanssa. Taulukosta huomataan lisäksi, että korrelaatioita löytyy selitettävien muuttujien väliltä useita. Esimerkiksi yhtiöiden tasearvojen pohjalta laskettavat vakavaraisuutta ja maksukykyä mittaavat muuttujat kuten omavaraisuusaste, quick ratio sekä current ratio korreloivat keskenään tilastollisesti merkitsevästi. Samoin yhtiön kannattavuutta ja tuloksentekeyttä mittaavat muuttujat kuten käyttökate%, nettotulos% sekä ROI% ja ROE% korreloivat tilastollisesti merkitsevästi keskenään. Muuttujien välillä on siis selkeästi havaittavissa multikollineaarisuutta, mikä tulee huomioida regressioanalyysin tuloksia analysoidessa. Tulemme käyttämään regressioanalyysissä stepwise menettelyä, jolloin keskenään korreloivien muuttujien ei tulisi päätyä samaan lopulliseen malliin. Multikollineaarisuutta tarkastellaan lisää myöhemmin taulukoihin 8 ja 13 perustuen.

Tässä kohtaa on hyvä mainita selitettävään muuttujaan (osaketuotto) liittyen, että olemme käyttäneet tässä tutkimuksessa pelkästään yhtiön osakkeen hinnan muutoksen tuomaa tuottoa, ja jättäneet huomioimatta osinkotuotot. Tämä rajaus on tehty aineiston keräämisen helpottamiseksi.

Kuten edellisessä kappaleessa mainitsimme, regressioanalyysin käyttöön liittyy tiettyjä oletuksia, joiden tulee täyttyä, että analyysia voidaan käyttää tarkoituksenmukaisesti. Yhtenä oletuksena on, että mallin selittämättä jäänyt osa eli residuaalit ovat normaalisti jakautuneita. Residuaalien on myös oltava hajautuneet tasaisesti eli hajonnan tulee olla homoskedastinen. Normaalisuutta voidaan tarkastella histogrammilla, jossa standardoituja residuaaleja verrataan normaalijakaumaan. Toinen tapa tarkastella normaalisuutta on normaalijakaumakuviot (normal probability plot). Alla olevista kuvioista (kuviot 3-6) nähdään, että residuaalit ovat riittävän normaalisti jakautuneet, jotta regressioanalyysia voidaan tarkoituksenmukaisesti hyödyntää. Tosin, varsinkin osakkeen volatiliisuuden kohdalla on normaalisuutta myös mahdollista jossain määrin kyseenalaistaa. Tämä pidettäkään mielessä analyysin tuloksia tulkittaessa.




KUVIO 3 Histogrammi osakkeen volatilitieetin normalisuudesta

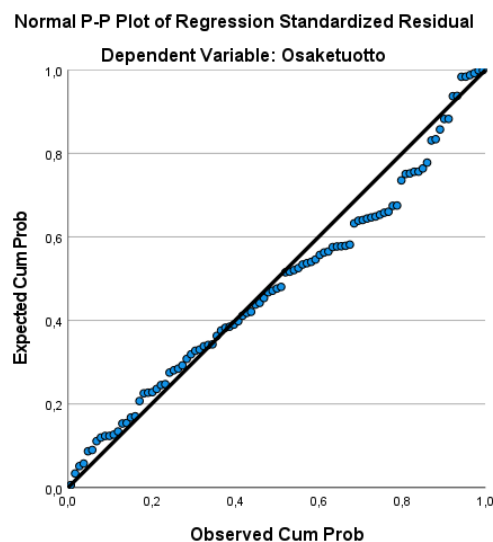


KUVIO 4 Normaalijakaumakuviio osakkeen volatilitieetista



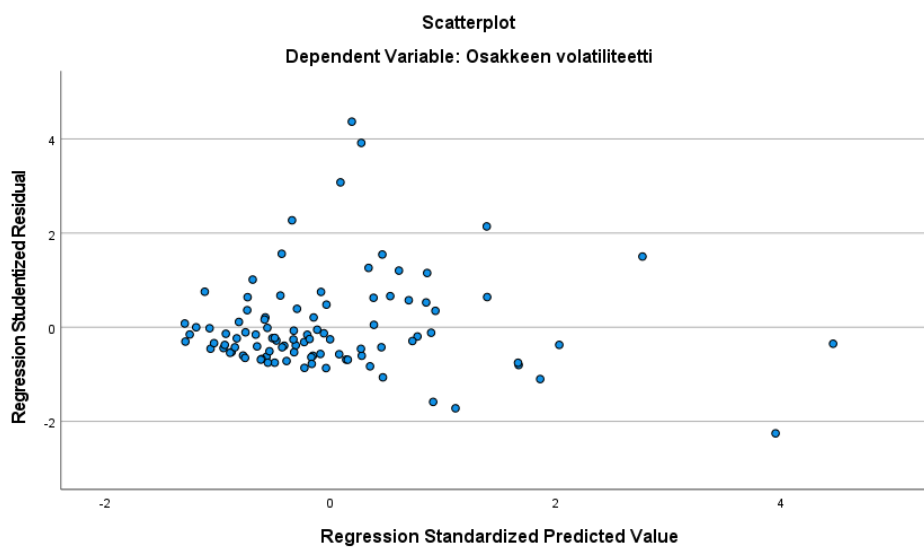


KUVIO 5 Histogrammi osaketuoton normalisuudesta

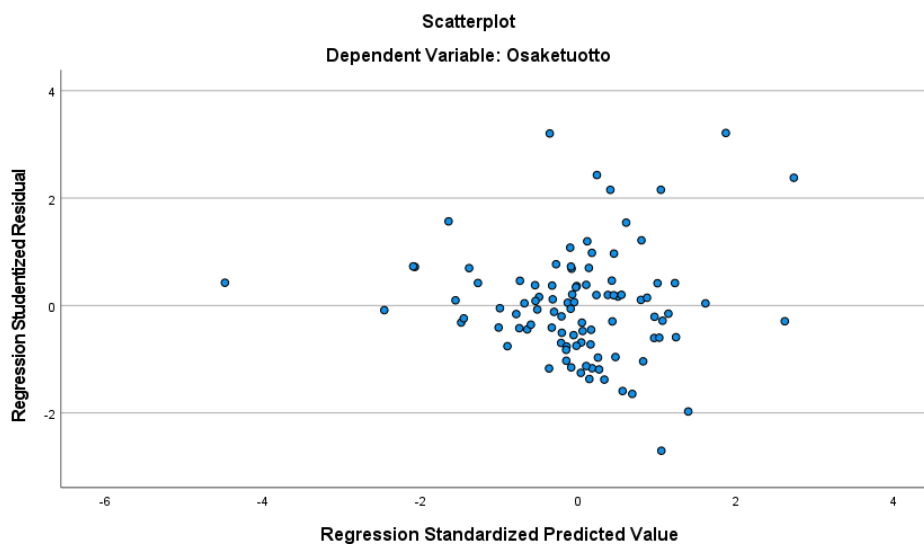


KUVIO 6 Normaalijakaumakuviokuva osaketuotosta

Seuraavaksi tarkastellaan residuaalien hajonnan homoskedastisuutta. Tätä voidaan tarkastella Hajontakuviosta (Scatterplot) avulla. Ihanteellisessa tapauksessa kuviosta ei voida tulkita selkeää säännönmukaisuutta vaan kuvion pisteiden tulisi olla tasaisesti jakautuneet. Kuten alla olevista kuvioista (kuvio 7 ja 8) nähdään ovat residuaalit melko tasaisesti hajautuneet. Osakkeen volatiliiteetin kohdalla on havaittavissa pientä säännönmukaisuutta, mutta tämän ei pitäisi olla esteenä regressioanalyysin käyttämiselle. Tämä myös on otettava huomioon regressioanalyysin tulosten analysoinnissa.



KUVIO 7 Hajontakuviio osakkeen volatilitiitti



KUVIO 8 Hajontakuviio osaketuotto

Aineistossa havaittiin kolme poikkeavaa havaintoa, jotka poistettiin ennen diagnostisten tarkastelujen tekemistä. Poikkeavien havaintojen määrä ei ole kovin suuri. Tosin, on huomattava, että pienikin poikkeavien havaintojen määrä voi vaikuttaa analyysin tuloksiin. Suuri osakkeen volatilitiitti kuten myös suuri osaketuotto ovat mahdollista varsinkin, jos kyseessä on esimerkiksi pieni pörssi-yhtiö, jonka markkinoiden tuotto-odotus on syystä tai toisesta muuttunut merkittävästi. Taulukoissa 2 ja 3 on analyysissä esiin nousseet poikkeavat havainnot. Taulukoissa ei ole otettu huomioon jo aineistosta poistettuja kolmea yhtiötä. Toisin kuin jo poistettujen kolmen yhtiön kohdalla, olemme päättäneet jättää kuvioiden 7 ja 8 poikkeavat havainnot eli taulukoiden 2 ja 3 havainnot analyysiin. Kyseiset yritykset eivät mielestämme poikkea kovin paljon muusta aineistosta toisin kuin edellä mainitut kolme yhtiötä. Aineistosta siis poistettiin poikkeavina havaintoina yhteensä kolme yhtiötä, jotka ovat Qt, Orthex ja Neste.

TAULUKKO 2 Poikkeavat havainnot osakkeen volatilitiitti

**Casewise Diagnostics<sup>a</sup>**

Case Number	Std. Residual	Osakkeen volatilitiitti	Predicted Value	Residual
7	4,316	3,960196392	,86806630415	3,0921300879
34	3,050	3,010380186	,82489379719	2,1854863888
89	3,833	3,650408103	,90402046931	2,7463876337

a. Dependent Variable: Osakkeen volatilitiitti

TAULUKKO 3 Poikkeavat havainnot osaketuotto

**Casewise Diagnostics<sup>a</sup>**

Case Number	Std. Residual	Osaketuotto	Predicted Value	Residual
68	3,067	88,40%	32,9877%	55,41228%
84	3,171	66,20%	8,9033%	57,29674%

a. Dependent Variable: Osaketuotto

**4.1.2 Lineaarinen regressioanalyysi osakkeen volatilitiitti**

Edellisen kappaleen perusteella voidaan todeta, että regressioanalyysin edellytykset täyttyvät. Tässä osiossa käydään läpi regressioanalyysin tulokset. Regressioanalyysi suoritettiin SPSS sovelluksella, johon aineisto vietiin taulukkolaskentasovelluksesta. Analyysissä käytettiin askeltavaa (Stepwise) menettelyä.

TAULUKKO 4 Regressioanalyysiin lisätyt muuttujat

Variables Entered/Removed<sup>a</sup>

Model	Variables Entered	Variables Removed	Method
1	P/B		Stepwise (Criteria: Probability-of- F-to-enter <= , 050, Probability-of- F-to-remove >= ,100).
2	Osaketuotto		Stepwise (Criteria: Probability-of- F-to-enter <= , 050, Probability-of- F-to-remove >= ,100).

a. Dependent Variable: Osakkeen volatilitteetti

Kuten taulukosta 4 nähdään, osakkeen volatilitteetin kanssa malliin tulee valituksi P/B luku sekä osaketuotto. Aikaisemmissa tutkimuksissa osakkeen volatilitteetin ja Google Trends volyyymiä kuvaavien muuttujien välillä on havaittu yhteys. Myös tässä tutkimuksessa havaitaan Google Trends arvojen ja osakkeen volatilitteetin välillä korrelaatio, mutta regressioanalyysissä GT-luvut eivät tule lisätyksi malliin. Osakkeen volatilitteettiä selittävään malliin tulee valituksi kaksi muuttujaa: P/B-luku ja osaketuotto. P/B-luvun selitysaste mallissa on 19,6 prosenttia ja korjattu selitysaste on 18,7 prosenttia. Tämä tarkoittaa, että 18,7 prosenttia osakkeen volatilitteetin vaihtelusta voidaan selittää P/B-luvulla.

Korjattu selitysaste on tavallista selitysastetta paremmin todellisuutta heijasteleva luku. Tavallinen selitysaste on laskettu regression otoksen perusteella. Selitysaste siis luonnollisesti kuvaa paremmin otoksen selitysastetta kuin koko selitettävän ilmiön selitysastetta. Korjattu selitysaste pyrkii ottamaan tämän vääristymän huomioon. (Myers & Well, 1995, s. 508)

## TAULUKKO 5 Regressioanalyysin yhteenveto

Model Summary <sup>c</sup>									
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	R Square Change	Change Statistics			
						F Change	df1	df2	Sig. F Change
1	,443 <sup>a</sup>	,196	,187	,74680200760	,196	23,148	1	95	<,001
2	,517 <sup>b</sup>	,268	,252	,71647613675	,072	9,212	1	94	,003

a. Predictors: (Constant), P/B

b. Predictors: (Constant), P/B, Osaketuotto

c. Dependent Variable: Osakkeen volatilitteetti

Selitysasteen tarkastamisen jälkeen otetaan tarkastelun kohteeksi, kuinka tilastollisesti merkitsevinä tuloksia voidaan pitää. Huomaamme taulukosta 6, että mallin p-arvo on alle 0,01. Yleisesti tilastollisesti merkitsevän tuloksen raja-arvona pidetään p-arvoa 0,05. Nollahypoteesi, että regressiokertoimet olisivat

arvoltaan nolla eli toisin sanoen, että malliin valitut muuttujat eivät selitä selitettävän muuttujan vaihtelua tilastollisesti merkittävästi, voidaan siis hylätä. Taulukosta nähdään myös, että koko mallin varianssista 65,893 selittää P/B-luku 12,910 ja muuttujat yhteensä 17,639.

TAULUKKO 6 Regressioanalyysin tilastollinen merkitsevyys

ANOVA <sup>a</sup>						
Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	12,910	1	12,910	23,148	<,001 <sup>b</sup>
	Residual	52,983	95	,558		
	Total	65,893	96			
2	Regression	17,639	2	8,820	17,181	<,001 <sup>c</sup>
	Residual	48,254	94	,513		
	Total	65,893	96			

a. Dependent Variable: Osakkeen volatiliiteetti

b. Predictors: (Constant), P/B

c. Predictors: (Constant), P/B, Osaketuotto

Seuraavaksi tarkastellaan regressioanalyysin multikollinearisuutta. Condition indexin tarkastaminen antaa käsityksen mallin multikollinearisuudesta. Condition index on pieni, jos se saa arvoksi 5–10. Jos arvo on yli 30 on syytä epäillä multikollinearisuutta. Kuten nähdään, mallin suurin arvo on 2,998, joten tämän perusteella ei ole syytä epäillä muuttujien korreloivan keskenään. (Belsley, 1998). Taulukon 7 VIF arvo kertoo myös mallin multikollinearisuudesta. Jos VIF arvo on lähellä yhtä ei ole syytä epäillä, että muuttujat korreloivat keskenään (Mansfield & Helms, 1981). Mallin arvoista vain yksi ylittää yhden ja sekin vain vähän (1,126), täten ei ole syytä epäillä multikollinearisuutta.

TAULUKKO 7 Regressiokertoimet

Coefficients <sup>a</sup>								
Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.	Collinearity Statistics	
		B	Std. Error	Beta			Tolerance	VIF
1	(Constant)	,457	,102		4,477	<,001		
	P/B	,105	,022	,443	4,811	<,001	1,000	1,000
2	(Constant)	,242	,121		1,999	,048		
	P/B	,127	,022	,538	5,742	<,001	,888	1,126
	Osaketuotto	,011	,004	,284	3,035	,003	,888	1,126

a. Dependent Variable: Osakkeen volatiliiteetti

TAULUKKO 8 Multikollinearisuus

**Collinearity Diagnostics<sup>a</sup>**

Model	Dimension	Eigenvalue	Condition Index	Variance Proportions		
				(Constant)	P/B	Osaketuotto
1	1	1,669	1,000	,17	,17	
	2	,331	2,246	,83	,83	
2	1	1,921	1,000	,09	,08	,07
	2	,865	1,490	,00	,21	,46
	3	,214	2,998	,91	,71	,46

a. Dependent Variable: Osakkeen volatilitteetti

**4.1.3 Lineaarinen regressioanalyysi osaketuotto**

Toisena selitettävänä muuttujana oli analyysissämme osaketuotto. Joissakin aikaisemmissa tutkimuksissa Google Trends hakuvolyymien ja osaketuoton välillä on havaittu yhteys. Tosin verrattuna osakkeen volatilitettiin, jonka yhteys on ollut melko selkeä, osaketuoton ja Google Trendsin yhteys ei ole aivan yhtä yksiselitteinen. Tämän tutkimuksen tulokset poikkeavat hieman aikaisempien tutkimuksien tuloksista. Vaikkakin yhteys GT-muuttujan sekä osakkeen volatilitettiin että osaketuoton väliltä löytyy, on yhteys selkeästi vahvempi osaketuoton osalta. Osaketuottoa näyttävät regressioanalyysissä selittävän P/B-luvun lisäksi myös GT vs KA muuttuja.

TAULUKKO 9 Regressioanalyysiin lisätyt muuttujat

Variables Entered/Removed<sup>a</sup>

Model	Variables Entered	Variables Removed	Method
1	P/B		Stepwise (Criteria: Probability-of- F-to-enter <= , 050, Probability-of- F-to-remove >= ,100).
2	Osakkeen volatiliteetti		Stepwise (Criteria: Probability-of- F-to-enter <= , 050, Probability-of- F-to-remove >= ,100).
3	GT vs KA		Stepwise (Criteria: Probability-of- F-to-enter <= , 050, Probability-of- F-to-remove >= ,100).

a. Dependent Variable: Osaketuotto

## TAULUKKO 10 Regressioanalyysin yhteenveto

Model Summary<sup>d</sup>

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	R Square Change	Change Statistics			
						F Change	df1	df2	Sig. F Change
1	,335 <sup>a</sup>	,112	,103	19,69913%	,112	12,010	1	95	<,001
2	,438 <sup>b</sup>	,191	,174	18,89919%	,079	9,212	1	94	,003
3	,519 <sup>c</sup>	,269	,245	18,06766%	,077	9,852	1	93	,002

a. Predictors: (Constant), P/B

b. Predictors: (Constant), P/B, Osakkeen volatiliteetti

c. Predictors: (Constant), P/B, Osakkeen volatiliteetti, GT vs KA

d. Dependent Variable: Osaketuotto

Taulukko 10 kertoo malliin valittujen muuttujien selitysasteet. Kuten osakkeen volatiliteetin kohdalla myös tässä tapauksessa suurin selitysvoima on P/B-luvulla, jonka selitysaste on 11,2 prosenttia ja korjattu selitysaste 10,3 prosenttia. Seuraavaksi korkeimmat selitysasteet ovat osakkeen volatiliteetilla ja GT vs KA-luvulla, joista ensimmäinen nostaa mallin selitysastetta 19,1 prosenttiin ja korjattua selitysastetta 17,4 prosenttiin. Jälkimmäinen taas nostaa mallin selitysasteen 26,9 prosenttiin ja korjatun selitysasteen 24,5 prosenttiin.

## TAULUKKO 11 Regressioanalyysin tilastollinen merkitsevyys

ANOVA<sup>a</sup>

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	4660,707	1	4660,707	12,010	<,001 <sup>b</sup>
	Residual	36865,292	95	388,056		
	Total	41525,999	96			
2	Regression	7951,122	2	3975,561	11,130	<,001 <sup>c</sup>
	Residual	33574,877	94	357,180		
	Total	41525,999	96			
3	Regression	11167,057	3	3722,352	11,403	<,001 <sup>d</sup>
	Residual	30358,943	93	326,440		
	Total	41525,999	96			

a. Dependent Variable: Osaketuotto

b. Predictors: (Constant), P/B

c. Predictors: (Constant), P/B, Osakkeen volatilitteetti

d. Predictors: (Constant), P/B, Osakkeen volatilitteetti, GT vs KA

Mallin tilastollista merkitsevyyttä voidaan arvioida taulukosta 11. Näemme, että mallin p-arvo on alle 0,01. Nollahypoteesi, että regressiokertoimet olisivat arvoltaan nolla eli toisin sanoen, että valitut muuttujat yhdessä eivät selitä selitettävän muuttujan vaihtelua voidaan siis tässäkin tapauksessa hylätä. Näemme myös, että koko osaketuoton varianssista regressio kaikkine muuttujineen selittää hieman yli neljänneksen. Kokonaisvarianssi on 41 525,999 ja regressio selittää tästä 11 167,057.

## TAULUKKO 12 Regressiokertoimet

Coefficients<sup>a</sup>

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.	Collinearity Statistics	
		B	Std. Error	Beta			Tolerance	VIF
1	(Constant)	18,997	2,691		7,058	<,001		
	P/B	-1,993	,575	-,335	-3,466	<,001	1,000	1,000
2	(Constant)	15,397	2,842		5,419	<,001		
	P/B	-2,820	,615	-,474	-4,583	<,001	,804	1,244
	Osakkeen volatilitteetti	7,881	2,596	,314	3,035	,003	,804	1,244
3	(Constant)	12,775	2,842		4,495	<,001		
	P/B	-2,808	,588	-,472	-4,774	<,001	,804	1,244
	Osakkeen volatilitteetti	7,806	2,482	,311	3,145	,002	,804	1,244
	GT vs KA	,232	,074	,278	3,139	,002	1,000	1,000

a. Dependent Variable: Osaketuotto

## TAULUKKO 13 Multikollinearisuus



**Collinearity Diagnostics<sup>a</sup>**

Model	Dimension	Eigenvalue	Condition Index	Variance Proportions			
				(Constant)	P/B	Osakkeen volatilitteetti	GT vs KA
1	1	1,669	1,000	,17	,17		
	2	,331	2,246	,83	,83		
2	1	2,373	1,000	,06	,06	,06	
	2	,332	2,674	,80	,53	,02	
	3	,296	2,833	,13	,40	,92	
3	1	2,579	1,000	,05	,05	,05	,04
	2	,816	1,777	,00	,05	,04	,85
	3	,313	2,872	,56	,75	,03	,08
	4	,292	2,972	,39	,16	,88	,03

a. Dependent Variable: Osaketuotto

Yllä olevasta taulukosta 13 näemme, että suurin Condition index on myös tämän mallin osalta todella pieni (2,972) eikä täten anna syytä epäillä multikollenaarisuutta. Taulukosta 12 näemme mallin VIF arvojen olevan lähellä yhtä, suurin arvo on 1,244, joten tämän perusteella voidaan todeta, ettei mallissa esiinny multikollenaarisuutta.

Ensimmäiseen regressioanalyysiin, jossa selitettävänä muuttujana oli osakkeen volatilitteetti, ei tullut valituksi GT-muuttujia. Osakkeen volatilitteettia selittivät P/B-luku ja osaketuotto. Silti, GT-keskihajonta -muuttujan ja osakkeen volatilitteetin väliltä löytyi tilastollisesti merkitsevä korrelaatio p-arvolla 0,05. Toiseen regressioanalyysiin, jossa selitettävänä muuttujana oli osaketuotto, valikoitui selittäviksi muuttujiksi P/B -luku, osakkeen volatilitteetti sekä GT vs. KA -muuttuja, joiden vastaavat korjatut selitysasteen ovat 10,3; 7,1 ja 7,1. Malli on tilastollisesti merkitsevä p-arvolla 0,01.

## 5 JOHTOPÄÄTÖKSET JA ARVIOINTI

### 5.1 Johtopäätökset

Tässä tutkimuksessa oli tarkoitus selvittää voiko Google Trends arvoilla, yhtiötä koskeviin taloudellisiin tunnuslukuihin yhdistettynä, ennustaa yhtiön osaketuttoa tai osakkeen volatilitteettia. Laadimme erikseen kaksi eri regressioanalyysiä, joissa selitettävänä muuttujana oli sekä osaketuotto että osakkeen volatilitteetti. Tutkimuksen regressioanalyysissä osakkeen volatilitteettia ennustavaan malliin tuli valituksi ainoastaan yhtiön P/B-luku, vaikka korrelaatio volatilitteetin kanssa löytyi sekä GT-luvun keskihajonnan että sijoitetun pääoman tuoton (ROI%) ja oman pääoman tuoton (ROE%) kanssa. Tämä on mielenkiintoinen tulos siinä mielessä, että aikaisemmissa tutkimuksissa yhteys Google Trendsin ja osakkeen volatilitteetin kanssa on ollut selkeä. Norjan osakemarkkinoita tutkinut tutkimus havaitsi, että Googlen hakuvolyymien kasvaessa yhtiön osakkeen volatilitteetti kasvaa (Kim ym. 2019). Osakkeen volatilitteettia koskeviin tuloksiin on myös suhtauduttava varauksella, sillä aineistoa koskevat diagnostiset tarkastelut antoivat aiheetta epäillä osakkeen volatilitteettia koskevan analyysin paikkaansa pitävyyttä. Silti, korrelaatiolaskelmien perusteella voidaan todeta, että tulokset indikoivat, että volatilitteetin ja GT-lukujen välillä on heikko positiivinen yhteys.

Tutkimuksen toinen regressioanalyysi koski osaketuoton ennustamista käyttäen Google Trends -lukuja sekä taloudellisia tunnuslukuja. Toisin kuin ensimmäisessä regressioanalyysissä, osaketuottoa ennustavassa mallissa regressioon tuli valituksi P/B-luvun (selitysaste 10,3; p-arvo 0,01) lisäksi myös GT vs KA muuttuja (selitysaste 7,1; p-arvolla 0,01), joka kuvaa Google Trends lukujen tarkasteluajankohdan muutosta pitkän aikavälin keskiarvoon. Tämän tuloksen perusteella yhtiön osaketuottoa on mahdollista ennustaa Google Trends arvojen avulla. Aikaisempi tutkimus, jossa aineistona käytettiin japanilaisia pörssiyrityksiä tukee edellä mainittuja tuloksia. Takeda ja Wakao (2014) havaitsivat, että Google Trends -hakuintensiteetti selitti mallista riippuen 38,62 %-46,94% osakkeen epänormaalista tuotosta (epänormaali tuotto oli laskettu Fama-French kolmen faktorin mallin perusteella). Vastaavasti myös Bijl ym. (2016) havaitsivat yhteyden Google Trends -hakuvolyymien sekä epänormaalien tuottojen välillä. Google Trends arvot selittivät 13% epänormaaleista tuotoista.

Tutkimuksen tulokset ovat jossain määrin linjassa aikaisempien tutkimusten kanssa. Yhteys osaketuoton, osakkeen volatilitteetin tai osakkeen kaupankäyntiaktiivisuuden sekä Google Trendsin kanssa on todettu aikaisemmissakin tutkimuksissa. Tosin aikaisemmissa tutkimuksissa yhteys osakkeen tuottoon ei ole ollut erityisen vahva. Takeda & Wakao (2014) havaitsivat tutkimuksessaan, että GT-volyymien kasvaessa, yhtiön osakkeella käydään aktiivisemmin kauppaa pörssissä. He havaitsivat myös yhteyden GT-

volyymien kasvun ja osaketuoton kanssa, tosin tämä yhteys ei ollut erityisen vahva. Meidän tutkimuksessamme yhteys osaketuoton ja Google Trends-arvojen välillä taas on vahvempi kuin osakkeen volatilitetin tapauksessa. Tutkimuksessamme yhteys on positiivinen, kun taas muilla markkinoilla (Filipiinit, Thaimaa, Vietnam) on havaittu kasvavien Google volyymien indikoivan osaketuoton laskua (Nguyen ym. 2019). Myös USA:n markkinoiden S&P 500 yhtiöitä vuosina 2008-2013 tarkastellut tutkimus havaitsi, että Googlen hakuvolyymien kasvaessa merkittävästi, todennäköisyys osaketuoton laskuun kasvaa (Bijl ym. 2016). Täytyy ottaa huomioon, että valitsimme tutkittavaksi ajankohdaksi nousumarkkinan, mikä saattaa osaltaan vaikuttaa tuloksiin. Jonain toisena ajanjaksona yhteys osaketuoton ja Google Trends lukujen välillä olisi voinut olla negatiivinen.

Käyttämästämme kolmesta GT-luvusta, ainoastaan yhden (GT vs KA) kanssa havaittiin tilastollisesti merkitseviä tuloksia sekä korrelaatiolaskelmien osalta että regressioanalyysissä. Mikäli olisimme jättäneet tämän muuttujan kokonaan pois analyysistä ja valikoineet mukaan ainoastaan GT-lukujen keskiarvon ja GT-lukujen keskihajonnan tutkittavalta ajanjaksolta, emme olisi saaneet tilastollisesti merkitseviä tuloksia lainkaan Google Trendsin ja osaketuottojen suhteen. GT vs KA muuttujan käyttökelpoisuus verrattuna muihin GT-muuttujiin ei tosin tullut täytenä yllätyksenä, sillä esimerkiksi GT-luvun keskiarvo tietyssä ajanjaksona ei vielä kerro hirveästi siitä, kuinka niin sanotusti ”trendaava” yhtiö on Googlen hakukoneessa. Esimerkiksi suurilla, vähittäiskaupan alalla toimivilla yhtiöillä, kuten Marimekolla, GT-luku on yleensä melko suuri päivästä toiseen, kun taas pienillä yhtiöillä, jotka ovat lähinnä B2B-markkinoilla, kuten esimerkiksi Keslalla Google hakuja on verrattain vähemmän ja viikoittainen tai kuukausittainen vaihtelu on suurta lukujen välillä. Tästä syystä esimerkiksi yksittäinen GT-keskiarvo ajankohdalta X ei anna selkeää indikaatiota yhtiön suosiosta hakukoneessa, koska luvulle ei ole vertailupohjaa. Jos taas tiedetään, että historiallisesti yhtiön GT-luku on ollut keskimäärin 20 % pienempi kuin mitä se on tarkasteluajankohtana, saa yhtiön sen hetkisestä suosiosta hakukoneessa jo paremman kuvan.

Tutkimuksen tulosten pohjalta väitämme, että Google Trends muuttujilla, jotka ottavat huomioon GT-luvun sen hetkisen suuruusluokan suhteessa kyseisen yhtiön historialliseen GT-lukujen suuruusluokkaan, on positiivinen yhteys osakkeen tuottoon.

## 5.2 Arviointi ja jatkotutkimusaiheet

On todettava, että käyttämämme aineisto voisi olla suurempi. Suomen osakemarkkinoiden mittakaavassa tämä on kuitenkin hankalaa, sillä osakeyhtiöitä on rajallinen määrä. Lisäksi tutkittava ajankohta saattaa vaikuttaa merkittävästi tutkimuksemme tuloksiin. Myös Googlen tarjoama data tuo omat rajoituksensa sillä se ei tarjoa absoluuttisia hakuvolyymeja. Valitsemanamme

aikana osakemarkkinan yleinen suunta oli ylöspäin. Mallia tulisi jatkossa testata myös aikana, jolloin markkinoiden suunta on alaspäin tai kun markkinoilla ei ole havaittavissa selkeää trendiä. Ylipäätään GT-muuttujien arvorelevanssia voisi tulevaisuudessa tutkia käyttäen eri ajankohtia ja aika intervaleja, kuten päivittäisiä aika hakuvolyymimuutoksia, sekä useampia maantieteellisiä alueita, kuten esimerkiksi Ruotsin osakemarkkinoita. Tutkimuksessamme osakkeen muutosta 3kk aikajänteellä. Tulevaisuudessa Googlen ja osakemarkkinan yhteyttä voisi tutkia käyttämällä useiden vuosien mittaista aikajännettä, esimerkiksi 2010-2020, jolloin ajanjaksolle mahtuisi sekä noususuhdanteita että laskusuhdanteita. Valittaessa pidempi ajanjakso, joudutaan tosin hieman joustamaan yhtiöiden määrässä, sillä aikajännettä venytettäessä, vähenee sellaisten yritysten määrä, jotka ovat olleet koko ajanjakson pörssissä.

## LÄHTEET

- Alkula, T., Pöntinen, A. & Ylöstalo, P. (1994). Sosiaalitutkimuksen kvantitatiiviset menetelmät. WSOY
- Andrei, D., & Hasler, M. (2015). Investor Attention and Stock Market Volatility. *The Review of financial studies*, 28(1), 33-72.
- Barth, M., Li, K., McClure, C. (2023). Evolution in Value Relevance of Accounting Information. *Accounting Review*, 98(1), 1-28.
- Belsley, D. (1991). A Guide to Using the Collinearity Diagnostics. *Computer Science in Economics and Management*, 4, 33-50.
- Berger, D. (2022). Investor sentiment a retail trader activity approach. School of Accounting, Finance and Information Systems.
- Bijl, L., Kringhaug, G. & Molnar, P. (2016). Google search and stock returns. *International Review of Financial Analysis*, 45, 150-156.
- Boehmer, E., Jones, C. M., Zhang, X. & Zhang, X. (2021). Tracking Retail Investor Activity. *The Journal of Finance*.
- Burton, E. T., Shah, S. N., & Shah, S. (2013). Behavioral finance: Understanding the social, cognitive, and economic debates. John Wiley & Sons, Incorporated.
- Black, F. (1986). Noise. *The Journal of Finance*
- Da, Z., Engelberg, J., & Gao, P. (2011). In Search of Attention. *The Journal of finance (New York)*, 66(5), 1461-1499.
- D'Hondt, C & Roger, P. (2017). Investor sentiment and stock return predictability. Publisher: Association Française de Finance.
- Dunham, L. M., & Grandstaff, J. L. (2022). The Value Relevance of Earnings, Book Values, and Other Accounting Information and the Role of Economic Conditions in Value Relevance: A Literature Review. *Accounting Perspectives*, 21(2), 237-272.
- Eskola, J. & Suoranta, J. (2005). Johdatus laadulliseen tutkimukseen. Tampere: Vastapaino.
- Golden-Biddle, K. & Locke, K. (1993). Appealing work: an investigation of how ethnographic texts convince. *Organization Science* 4 (4), 595-616.
- Google (2022). The homepage explained. <https://support.google.com/trends/answer/6248105?hl=en>

[GB&ref\\_topic=6248052#zippy=%2Chow-do-i-read-the-interest-over-time-chart-under-realtime-search-trends.](#)

- Hamid, A., & Heiden, M. (2015). Forecasting volatility with empirical similarity and Google Trends. *Journal of economic behavior & organization*, 117, 62-81.
- Heiberger, R. H. (2015). Collective attention and stock prices: Evidence from Google Trends data on Standard and Poor's 100. *PloS one*,
- Hsieh, S., Chan, C. & Wang, M. (2020). Retail investor attention and herding behavior. *Journal of Empirical Finance*.
- Humphrey, C. & Lukka, K. (2011). (Ac)counting research. The value of holistic understanding. Teoksessa Cassell, C. & Lee, B. (Toim.), *Challenges and Controversies in Management Research*. New York: Routledge, 190-208.
- Investopedia: Technical Analysis: What It Is and How to Use It in Investing <https://www.investopedia.com/terms/t/technicalanalysis.asp>
- Kim, N., Lučivjanská, K., Molnár, P., & Villa, R. (2019). Google searches and stock market activity: Evidence from Norway. *Finance research letters*, 28, 208-220.
- Kumar, A. & Lee, M, C. (2006). Retail Investor Sentiment and Return Comovements. *The Journal of Finance*.
- Lev, B. & Thiagarajan, R. (1993). Fundamental Information Analysis. *Journal of Accounting Research*. 31(2), 190-215.
- Mansfield, E. & Helms, B. (1981). Detecting Multicollinearity. *The American Statistician* 36, 158-160.
- Metsämuuronen, J. (2011). Tutkimuksen tekemisen perusteet ihmistieteissä. Gummerus ja Booky.fi. Jyväskylän yliopisto, e-kirja, opiskelijalaitos, <https://jykdok.linneanet.fi/vwebv/holdingsInfo?bibId=1183030>.
- Metsämuuronen, J. (2017). *Essentials of Research Methods in Human Sciences: Volume 2, Multivariate analysis*. SAGE Publications.
- Myers, J. & Well, A. (1995). *Research Design and Statistical Analysis*. Lawrence Erlbaum Associates cop. 1995
- Nguyen, C. P., Schinckus, C., & Hong Nguyen, T. V. (2019). Google search and stock returns in emerging markets. *Borsa Istanbul Review*, 19(4), 288-296.
- Vlastakis, N. & Markellos, R, N. (2012). Information Demand and Stock Market Volatility. *Journal of Banking and Finance*
- Nikiforos, T. Laopodis. (2013). *Understanding Investments: Theories and Strategies*. Routledge.
- Rautiainen, A. & Jokinen, J. (2022). The value-relevance of social media activity of Finnish listed companies. *International Journal of Accounting & Information Management*
- Rees, B. (1990). *Financial Analysis*. MAB Boekbespreking.
- Roll, R. (1977). A critique of the asset pricing theory's tests Part I: On past and potential testability of the theory. *Journal of Financial Economics* 4 (2) 129-176.

- Salisu, A. A., Ogbonna, A. E., & Adediran, I. (2021). Stock-induced Google trends and the predictability of sectoral stock returns. *Journal of forecasting*, 40(2), 327-345.
- Statcounter. (13.12.2022). Search engine market share Finland. <https://gs.statcounter.com/search-engine-market-share/all/finland>
- Takeda, F., & Wakao, T. (2014). Google search intensity and its relationship with returns and trading volume of Japanese stocks. *Pacific-Basin finance journal*, 27, 1-18.
- Zhang, X. Fuehres, H. & Gloor, P. (2011). Predicting Stock Market Indicators Through Twitter "I hope it is not as bad as I fear". *Procedia - Social and Behavioral Sciences* 26, 55-62

## LIITE

## Korrelaatiotaulukko kaikista tutkimuksen muuttujista.

		Correlations																
		Osakkeen volatiliteetti	Osakeutuoto	Beta	CAP-malli	GT vs KA	GT luku	GT Keskihajonta	Current ratio	Nettotulos%	Käyttökate%	Quick ratio	Omavaraisuusaste	ROI%	ROE%	PIE	P/B	GT keskiarvo
Osakkeen volatiliteetti	Pearson Correlation	1	,104	,070	,037	,008	,106	-.202*	-.070	,088	,021	-.066	,040	,316**	,283**	,010	,443**	,079
	Sig. (2-tailed)		,310	,493	,722	,941	,299	,047	,495	,389	,835	,518	,694	,002	,005	,919	<.001	,440
	N	97	97	97	97	97	97	97	97	97	97	97	97	97	97	97	97	97
Osakeutuoto	Pearson Correlation	,104	1	,139	,137	,282**	,054	,115	-.041	-.202*	-.162	-.029	-.104	-.101	,022	-.076	-.335**	-.068
	Sig. (2-tailed)	,310		,173	,182	,005	,603	,262	,692	,048	,113	,781	,311	,325	,827	,461	<.001	,510
	N	97	97	97	97	97	97	97	97	97	97	97	97	97	97	97	97	97
Beta	Pearson Correlation	,070	,139	1	,987**	,041	,155	-.075	-.090	-.136	-.124	-.109	-.179	-.001	,008	-.093	-.070	,132
	Sig. (2-tailed)	,493	,173		<.001	,693	,128	,467	,380	,185	,225	,287	,079	,992	,939	,366	,496	,199
	N	97	97	97	97	97	97	97	97	97	97	97	97	97	97	97	97	97
CAP-malli	Pearson Correlation	,037	,137	,987**	1	,015	,143	-.103	-.107	-.130	-.130	-.126	-.197	-.006	,001	-.078	-.079	,134
	Sig. (2-tailed)	,722	,182	<.001		,883	,162	,316	,297	,206	,205	,219	,054	,957	,993	,447	,443	,192
	N	97	97	97	97	97	97	97	97	97	97	97	97	97	97	97	97	97
GT vs KA	Pearson Correlation	,008	,282**	,041	,015	1	,163	,673**	,245*	,067	,188	,232*	,129	,056	,109	-.046	-.002	-.276**
	Sig. (2-tailed)	,941	,005	,693	,883		,112	<.001	,016	,513	,068	,022	,207	,585	,288	,655	,983	,006
	N	97	97	97	97	97	97	97	97	97	97	97	97	97	97	97	97	97
GT luku	Pearson Correlation	,106	,054	,155	,143	,163	1	-.077	-.112	,025	-.080	-.168	-.084	-.057	,064	-.120	-.100	,888**
	Sig. (2-tailed)	,299	,603	,128	,162	,112		,454	,273	,808	,560	,100	,413	,577	,536	,243	,327	<.001
	N	97	97	97	97	97	97	97	97	97	97	97	97	97	97	97	97	97
GT Keskihajonta	Pearson Correlation	-.202*	,115	-.075	-.103	,673**	-.077	1	,098	-.088	,017	,087	,034	-.143	-.087	-.070	-.170	-.368**
	Sig. (2-tailed)	,047	,262	,467	,316	<.001	,454		,340	,394	,870	,399	,738	,163	,398	,494	,095	<.001
	N	97	97	97	97	97	97	97	97	97	97	97	97	97	97	97	97	97
Current ratio	Pearson Correlation	-.070	-.041	-.090	-.107	,245*	-.112	,098	1	,639**	,817**	,983**	,510**	,151	,083	-.020	,030	-.200*
	Sig. (2-tailed)	,495	,692	,380	,297	,016	,273	,340		<.001	<.001	<.001	<.001	,140	,421	,849	,773	,050
	N	97	97	97	97	97	97	97	97	97	97	97	97	97	97	97	97	97
Nettotulos%	Pearson Correlation	,088	-.202*	-.136	-.130	,067	,025	-.088	,639**	1	,900**	,643**	,398**	,377**	,270**	,006	,214*	,003
	Sig. (2-tailed)	,389	,048	,185	,206	,513	,808	,394	<.001		<.001	<.001	<.001	<.001	,008	,954	,036	,977
	N	97	97	97	97	97	97	97	97	97	97	97	97	97	97	97	97	97
Käyttökate%	Pearson Correlation	,021	-.162	-.124	-.130	,188	-.060	,017	,817**	,900**	1	,825**	,414**	,312**	,214*	-.009	,169	-.115
	Sig. (2-tailed)	,835	,113	,225	,205	,066	,560	,870	<.001	<.001		<.001	<.001	,002	,036	,927	,098	,264
	N	97	97	97	97	97	97	97	97	97	97	97	97	97	97	97	97	97
Quick ratio	Pearson Correlation	-.066	-.029	-.109	-.126	,232*	-.168	,087	,983**	,643**	,825**	1	,499**	,155	,086	-.012	,036	-.248*
	Sig. (2-tailed)	,518	,781	,287	,219	,022	,100	,399	<.001	<.001	<.001		<.001	,129	,400	,906	,726	,014
	N	97	97	97	97	97	97	97	97	97	97	97	97	97	97	97	97	97
Omavaraisuusaste	Pearson Correlation	,040	-.104	-.179	-.197	,129	-.084	,034	,510**	,398**	,414**	,499**	1	,290**	,130	-.028	,204*	-.193
	Sig. (2-tailed)	,694	,311	,079	,054	,207	,413	,738	<.001	<.001	<.001	<.001		,004	,204	,787	,045	,059
	N	97	97	97	97	97	97	97	97	97	97	97	97	97	97	97	97	97
ROI%	Pearson Correlation	,316**	-.101	-.001	-.006	,056	-.057	-.143	,151	,377**	,312**	,155	,290**	1	,867**	,003	,582**	-.127
	Sig. (2-tailed)	,002	,325	,992	,957	,585	,577	,163	,140	<.001	,002	,129	,004		<.001	,978	<.001	,216
	N	97	97	97	97	97	97	97	97	97	97	97	97	97	97	97	97	97
ROE%	Pearson Correlation	,283**	,022	,008	,001	,109	,064	-.087	,083	,270**	,214*	,086	,130	,867**	1	-.008	,474**	-.031
	Sig. (2-tailed)	,005	,827	,939	,993	,288	,536	,398	,421	,008	,036	,400	,204	<.001		,935	<.001	,760
	N	97	97	97	97	97	97	97	97	97	97	97	97	97	97	97	97	97
PIE	Pearson Correlation	,010	-.076	-.093	-.078	-.046	-.120	-.070	-.020	,006	-.009	-.012	-.028	,003	-.008	1	,123	-.114
	Sig. (2-tailed)	,919	,461	,366	,447	,655	,243	,494	,849	,954	,927	,906	,787	,978	,935		,230	,265
	N	97	97	97	97	97	97	97	97	97	97	97	97	97	97	97	97	97
P/B	Pearson Correlation	,443**	-.335**	-.070	-.079	-.002	-.100	-.170	,030	,214*	,169	,036	,204*	,582**	,474**	,123	1	-.122
	Sig. (2-tailed)	<.001	<.001	,496	,443	,983	,327	,095	,773	,036	,098	,726	,045	<.001	<.001	,230		,234
	N	97	97	97	97	97	97	97	97	97	97	97	97	97	97	97	97	97
GT keskiarvo	Pearson Correlation	,079	-.068	,132	,134	-.276**	,888**	-.368**	-.200*	,003	-.115	-.248*	-.193	-.127	-.031	-.114	-.122	1
	Sig. (2-tailed)	,440	,510	,199	,192	,006	<.001	<.001	,050	,977	,264	,014	,059	,216	,760	,265	,234	
	N	97	97	97	97	97	97	97	97	97	97	97	97	97	97	97	97	97

\* Correlation is significant at the 0.05 level (2-tailed).

\*\* Correlation is significant at the 0.01 level (2-tailed).