

TALLINNA TEHNIKAÜLIKOOL

Majandusteaduskond

Dmitri Tšumakov

**OMX TALLINN GI INDEKSI KUISTE KALENDRIEFEKTIDE
ANALÜÜS**

Bakalaureusetöö

Õppekava TABB, peeriala ärirahandus

Juhendaja: Tõnn Talpsep

Tallinn 2024

Deklareerin, et olen koostanud lõputöö iseseisvalt ja olen viidanud kõikidele selle koostamisel kasutatud teiste autorite töödele, olulistele seisukohtadele ja andmetele, ning ei ole esitanud sama tööd varasemalt ainepunktide saamiseks.

Töö pikkuseks on 6224 sõna sissejuhatusest kuni kokkuvõtte lõpuni.

Dmitri Tšumakov 09.05.2024

SISUKORD

LÜHIKOKKUVÕTE	5
SISSEJUHATUS	6
1. SESOONSUS FINANTSTURUL	9
1.1. OMX Tallinn GI indeksi struktuur ja roll Eesti majanduses	9
1.2. Sesoonsuse mõiste ja efektiivse turu hüpotees	11
1.2.1 Kalendriefektid	12
1.3. Sesoonsuse modelleerimine.....	13
1.3.1. OLS mudel.....	13
1.3.2. GARCH (1,1) mudel	13
2. ANDMED JA METOODIKA	15
2.1. Andmed ja valim	15
2.2. Kirjeldav statistika.....	16
2.3. Metoodika.....	20
2.4. Mudeli ülesehitus.....	21
3. EMPIIRILINE ANALÜÜS JA JÄRELDUSED	23
3.1. OLS mudeli koostamine	23
3.1.1 Mudeli eeldused.....	23
3.1.2 OLS mudelid	26
3.2. GARCH mudeli koostamine.....	29
3.2. Järeldused	30
KOKKUVÕTE	31
SUMMARY	34
ANALYSIS OF OMX TALLINN GI INDEX MONTHLY CALENDAR EFFECTS	34
KASUTATUD ALLIKATE LOETELU	37
LISAD	39
Lisa 1. OMX Tallinn GI indeksi tootluse kirjeldav statistika	39
Lisa 2. Augmented Dickey-Fuller test perioodil 01.02.2000-31.12.2023	40
Lisa 3. Augmented Dickey-Fuller test perioodil 01.01.2000-31.12.2005	42
Lisa 4. Augmented Dickey-Fuller test perioodil 01.01.2006-31.12.2011	44
Lisa 5. Augmented Dickey-Fuller test perioodil 01.01.2012-31.12.2017	45

Lisa 6. Augmented Dickey-Fuller test perioodil 01.01.2018-31.12.2023	47
Lisa 7. OLS mudel perioodil 01.02.2000-31.12.2023	49
Lisa 8. OLS mudel perioodil 01.02.2000-31.12.2005	49
Lisa 9. OLS mudel perioodil 01.01.2006-31.12.2011	50
Lisa 10. OLS mudel perioodil 01.01.2012-31.12.2017	50
Lisa 11. OLS mudel perioodil 01.01.2018-31.12.2023	51
Lisa 12. ARCH test.....	52
Lisa 13. GARCH mudel	52
Lisa 14. Lihtlitsents	54

LÜHIKOKKUVÕTE

Antud lõputöö eesmärk on modelleerida sesoonsust OMX Tallinn GI indeksil tuginedes OLS ja GARCH(1,1) mudelitele ning jäädvustada kalendri efekte. Käesolevas töös kasutati OMX Tallinn GI indeksi kuiseid andmeid Nasdaq Baltic andmebaasist. Lisaks oli arvutatud logaritmiline tootlus, mis tagas statsionaarsust. Uurimisperioodiks on 01.01.2000-31.12.2023, samuti käesolev periood oli jaotatud neljaks: 01.02.2000-31.12.2005, 01.01.2006-31.12.2011, 01.01.2012-31.12.2017 ja 01.01.2018-31.12.2023. Töös autor kasutab kvantitatiivset uurimismeetodit ning pärast viiakse läbi empiiriline analüüs.

Käesolevas uurimistöös modelleeriti OLS ja GARCH(1,1) mudeleid kalendriefektide jäädvustamiseks. Empiirilises osas selgus, et OMX Tallinn GI indeksil esineb Jaanuari efekt igal perioodil. Kui vadelda koguperioodi, siis OLS mudelis lisaks Jaanuari efektile esines Veebruari- ja nõrk Aprilli efekt. GARCH(1,1) mudeli põhjal oli näha, et indeksil sarnaselt OLS mudeliga esineb tugev Jaanuari efekt ning nõrgad Aprilli ja Veebruari efektid, aga samal ajal esines nõrk Detsembri efekt. Kui analüüsida 4 kuueaastast perioodi, oli märgatav, et kalendriefektid varieerusid igal perioodil ja stabiilselt esines ainult Jaanuari efekt. OMX Tallinn GI indeksis tuvastatud kalendriefektid tõestavad Tallinna aktsiaturgude ebaefektiivsust, kuna aktsiahinnad ei ole juhuslikud, vaid neid saab prognoosida vastavalt teatavatele kuistele kalendriefektidele.

Võtmesõnad: Sesoonsus, OLS ja GARCH(1,1) tüüpi mudelid, kalendriefektid, aktsiaturg

SISSEJUHATUS

On hästi teada, et aktsiaturu liikumist on raske täpselt ennustada, sest iga päev ja iga minut mõjutab turgu erinevad tegurid: tehnoloogiline areng, valitsuse vahetus, investorite meeleolu või kriis. Kõik need ja muud tegurid võivad oluliselt mõjutada aktsiaturu käitumist, mis võib investeerimisel või portfelli koostamisel põhjustada suuri ebamugavusi. Selleks, et suurendada kasumliku positsiooni võimalust, tasub analüüsida turgu ja hinnata, kas on tegureid, mis aitavad valida hetke, millal investeerida või avada positsiooni.

Aktsiaturu analüüsimiseks on palju vahendeid ja näitajaid: mõned kasutavad indikaatoreid nagu suhtelise tugevuse indeks (*Relative strength index or RSI*) või libiseva keskmise lähenemine/erinevus (*Moving average convergence/divergence or MACD*), teised jälgivad uudiseid või suurettevõtete aruandeid ning analüüsivad äritsükleid või teadlikke artikleid. Igal juhul on kõiki neid vahendeid vaja selleks, et minimeerida kahjumlike otsuste tegemise riske ning võtta võidukat positsioon, et kaitsta ja suurendada oma portfeli. Üks ilming, mis aitab turu analüüsimisel ja portfelli haldamisel, on sesoonsus. Sesoonsus aktsiaturul on aktsiahindade kõikumine, mis toimub teatud ajavahemike järel kogu aasta jooksul. Finantsturu ebaühtlast ajalist jaotumist tuleks pidada oluliseks teabelemendiks, mida turuosalejad analüüsivad tehingute tegemiseks, mistõttu autori arvates on oluline võtta sesoonsust arvesse, kui soovitakse teha tehinguid või investeringuid. Täpsemalt öeldes pärast sesoonsuse modelleerimist käsitletakse käesolevas töös kalendriefekte, sest autorit huvitavad just kuiste perioodide mõju tootlusele.

Sesoonsuse analüüs annab ülevaate turu käitumise ajaloolistest mustritest teatud hooaegadel, käesolevas töös konkreetselt kuistel perioodidel. Korduvate suundumuste äratundmine võimaldab optimeeritud investeerimisstrateegiate väljatöötamisel, aidates turuosalistel vähendada riske. Investorid ja finantsanalüütikud saavad kalendriefektide analüüsi abil oma investeerimisotsuseid tõhusamalt planeerida. Teatud kuud võivad näidata järjepidevaid suundumusi turudünaamikas. Nende efektide mõistmine võimaldab investoritel strateegiliselt positsioonidesse siseneda või neist väljuda, maksimeerides kasumit ja minimeerides kahjumit.

Sesoonsuse analüüs aitab ka riskijuhtimist, tuvastades suurema volatiilsuse või turuturbulentsi perioodid. Investorid saavad nende perioodide jooksul kohandada oma riske, rakendades riskimaandamisstrateegiaid, et kaitsta oma portfelli võimalike negatiivsete mõjude ehk kahjumi saamise eest.

Finantsturgudel on täheldatud mitmeid kalendriefekte, millest igauks on mõjutatud erinevatest teguritest, majandustsüklitest ja investorite käitumisest. Kuigi need mustrid ei kordu igal aastal, pakuvad need ajaloolisi trende, mida investorid ja kauplejad otsuste tegemisel sageli arvestavad. Selles töös kasutab autor kuiseid andmeid ja igal kuul võib olla erinev efekt või mõju. Ühed populaarsed efektid on: jaanuari efekt, müü mais ja mine ära, Jõuluvana ralli, tuluhooaeg või suveralli. Autor analüüsib OMX Tallinn GI indeksit, mis esindab Tallinna Börsi tootlust, et tabada sesoonsuse mustreid, mis on ülaltoodud ja potentsiaalselt jäädvustada rohkem efekte. Sesoonsuse analüüsimiseks kasutatakse hariliku vähimruutude (OLS)- ja üldistatud autoregressiivse tingimusliku heteroskedastiivsuse (GARCH) meetodeid. Lõputöö eesmärk on modelleerida sesoonsust OMX Tallinn GI indeksil tuginedes OLS ja GARCH(1,1) mudelitele ning jäädvustada kalendriefekte.

Autor on püstitanud töö tegemiseks järgnevad uurimisküsimused, millele töö käigus leitakse vastused:

1. Kas OMX Tallinn GI indeksil esineb sesoonsus?
2. Millised kuised kalendriefektid seletavad OMX Tallinn GI indeksi sesoonsust?

Käesolevas töös on autor kasutanud ja läbi töötanud erinevaid artikleid, mis aitavad töö empiirilises ja teoreetilises osas. Artiklid puudutasid peamiselt aktsiaturu ja indeksite teemasid, samuti sesoonsust ja kalendriefekte. Töös on kasutatud OMX Tallinn GI indeksite kvantitatiivseid kuiseid andmeid ajavahemikul 2000-2023. Põhjalikumaks analüüsiks vaatleb autor lisaks neli kuueaastast perioodi. Kõik andmed oli võetud Nasdaq Baltic andmebaasist. OMX Tallinn GI indeksi kuised andmed hiljem transformeeriti ja töödeldi Excelis, kus pärast autor arvutas logariitmilist tootlust. Pärast andmete töötlemist ja analüüsimist Excelis kanti andmed edasiseks analüüsiks ja mudeli koostamiseks üle Gretl tarkvarasse. Gretlit kasutatakse OLS- ja GARCH(1,1) mudelite koostamiseks ning ADF- ja ARCH testide tegemiseks.

Töö koosneb kolmest peamisest peatükist. Esimeses peatükis kirjeldatakse OMX Tallinn GI indeksi struktuuri ja rolli Eesti majanduses. Käsitletakse sesoonsuse mõistet ja selle olemasolu

korral täheldatavaid kalendriefekte ja mõjusid. Samuti kirjeldatakse ja selgitatakse OLS- ja GARCH-mudeleid, mida kasutatakse sesoonsuse modelleerimisel ja kalendriefektide jäädvustamisel. Teises peatükis käsitletakse töö jaoks võetud andmeid, kirjeldavat statistikat, andmete jaoks valitud meetodikat ja mudeli enda konstrueerimist. Kolmas peatükk hõlmab mudeli enda modelleerimist, saadud mudelite analüüsimist ja nende tulemuste läbivaatamist ning tõlgendamist, mis annab autorile lõpuks piisavalt teavet järelduste tegemiseks. Empiirilise analüüsi teostamiseks kasutati ökonomeetriapaketti Gretl.

1. SESOONSUS FINANTSTURUL

Finantsturud on oma olemuselt kõikuvad, ja OMX Tallinn GI indeks ei ole siinkohal erand. Finantsturud muudavad sageli oma käitumist järsult. Kuigi mõned muutused võivad olla ajutised ja järsud, muutused varahindade käitumises püsivad sageli paljude perioodide jooksul. (Ang, A., & Timmermann, A., 2012) Sesoonsus viitab tuvastatavatele mustritele, suundumustele ja anomaaliatele, mis ilmnevad järjepidevalt konkreetsetel perioodidel. Nende mustrite uurimine on ülimalt oluline investorite ja finantsanalüütikute jaoks, kes soovivad Eesti aktsiaturgu põhjalikumalt mõista ning see annab väärtuslikku ülevaadet regionaalsest majandusdünaamikast ja investorite käitumisest. Sellised teadmised aitavad kaasa tõhusa finantspoliitika ja investeerimisstrateegiate väljatöötamisel. Autori arvates on väga oluline olla teadlik kõigist võimalikest muutujatest finantsturul nii kauplemisel, kui ka investeerimisel, mis annab võimalust suurendada oma portfelli ja teenida märkimisväärset kasumit.

1.1. OMX Tallinn GI indeksi struktuur ja roll Eesti majanduses

OMX Tallinn GI aktsiaindeks hõlmab kõiki aktsiaid, mis on kantud Tallinna vastava turu põhi- ja sekundaarnimekirjadesse, välja arvatud ettevõtted, kus üks aktsionär kontrollib 90% või rohkem käibelolevatest aktsiatest. Indeksi eesmärk on näidata aktsiate hetkeseisu ja liikumist igal kohalikul turul. (Nasdaq Baltic, 2024) Brutoindeks *GI* jälgib selles sisalduvate aktsiate brutotootlust. Teisisõnu, see kajastab mitte ainult nende hindade muutusi, vaid ka nende poolt makstavaid dividende, mis eeldatavasti reinvesteeritakse. Üldiselt peetakse seda turu tulemuslikkuse täielikumaks mõõduinstrumendiks kui hinnaindeksit. (Nasdaq Baltic, 2024) OMX Tallinn GI indeks on Eesti finantsturu baromeeter, mis hõlmab mitmesuguseid Tallinna börsil noteeritud ettevõtteid. Viimastel aastatel on finantsturgude dünaamika muutunud üsna keerulisemaks ja erinevatele välismõjudele tundlikumaks. Paljud tegurid võisid mõjutada nii turge kui ka nende sesoonsust.

Sesoonsuse kujunemisele aitavad kaasa paljud tegurid, näiteks mitmesugused majandussündmused, mis võivad selle kujunemist mõjutada. Kui me vaatame selles kontekstis

konkreetselt kriise, siis tuleb esimesena mainida 2007-2008. aasta kriisi. 2008. aasta finantskriis tõi kaasa tõsise majandusliku segaduse, millesse sattusid paljud riigid. Kriisile järgnesid päästemeetmed ja regulatiivsed muudatused. (Luchtenberg, K. F., & Vu, Q. V., 2014) Kui vaadata konkreetselt kriisi mõju OMX Tallinn GI indeksile, siis selle väärtus langes rohkem kui 66%. Sellise perioodi hooajalisust võib iseloomustada suurenenud volatiilsus ja investorite ettevaatlikkus, mis mõjutab kauplemismahte. Seda sündmust arvestades tasub ka volatiilsust arvesse võtta mudelite analüüsimisel, mille jaoks autor kasutab vajadusel efektiivseid meetodeid.

Euro kasutuselevõtt on samuti oluline sündmus nii indeksi kui ka Eesti jaoks tervikuna. Euro kasutuselevõtt Eestis krooni asemel võib avaldada positiivset mõju aktsiaturgudele. See üleminek võis suurendada usaldust Eesti majanduse vastu ja meelitada uusi investoreid. Sesoonsus võis sel perioodil muutuda tänu suurenenud investeerimisaktiivsusele, eriti välisinvestorite poolt. Kuid välisinvestorite sõnul ei olnud euro levik Vilniuse ja Tallinna NASDAQ OMX börsidel nii oluline kui uudised majandusliku ja poliitilise ebastabiilsuse kohta välismaal. Imselt jäeti kogemata kasutamata potentsiaalne võimalus meelitada Balti finantsturule rohkem investoreid. (Jakučionytė, 2011) See sündmus ei saanud kuidagi mõjutada OMX Tallinn GI indeksit ja selle sesoonsust.

COVID-19 pandeemia mõjutas tugevalt ka OMX Tallinn GI indeksit. See põhjustas aktsiate nõudluse märkimisväärse vähenemise ebakindluse ja piiravate meetmetega seotud majanduslike kahjude tõttu. COVID-19 oli finantsturgude jaoks katastroof, mis põhjustas suurt volatiilsust. Umbes 30% varadest kadus maailma börsidel 100 päevaga. (Ali et al., 2020) See tõi kaasa indeksis olevate kohalike ettevõtete aktsiahindade languse. See kriis on ka kõrge volatiilsuse põhjuseks, mis ajendab GARCH(1,1) mudeli kasutamist.

Eesti majandusmaastik on olnud tunnistajaks ümberkujundavatele majandusmuutustele. Finantsturgude dünaamilisel maastikul on aktsiaindeksite korduvate mustrite mõistmine oluline teadlike otsuste tegemiseks. OMX Tallinn GI indeksi kuisele sesoonsusele keskenduva teema valiku ajendiks on vajadus mõista Tallinna börsi tootlust mõjutavaid ajalisi muutusi. Kuna OMX Tallinn GI indeks hõlmab Tallinna suurimaid ettevõtteid, on selle analüüs väga huvitav investoritele, kes on huvitatud Eesti majandusest ja selle võimalikest arenguperspektiividest. Eesti majandusolukord on praegu keeruline, mis mõjutab kõiki elanikke ja tõenäoliselt investoreid, sest majanduslikel rasketel aegadel kannatavad peaaegu kõik inimesed kahjusid, kuid kriisid on ka parim aeg investeerimiseks, mitte hirmuks. Samuti tugev majanduskasv on põhjus mõelda oma positsioonide sulgemisele, sest igale kasvule järgneb langus.

1.2. Sesoonsuse mõiste ja efektiivse turu hüpotees

Sesoonsus on aegrea tunnus, mille puhul andmed muutuvad korrapäraselt ja prognoositavalt ning korduvad igal kalendriaastal. Efektiivse kapitalituru väärtpaperite hinnad peegeldavad täielikult nende investeerimisväärtust. Turul on võime antud teabekogumi koheselt hinnakujundusprotsessi sisse tõukama. Kui turud on efektiivsed, on võimatu saavutada järjepidevalt ebanormaalselt tulu, kasutades antud teabekogumil põhinevat kauplemisstrateegiat. Efektiivse turu hüpotees (*Efficient market hypothesis, EMH*) ennustab, et väärtpaperite hinnad järgivad juhuslikku protsessi; avalikult kättesaadava teabe põhjal peaks olema võimatu ennustada tulevast tootlust. Täpsemalt öeldes peaks olema võimatu ennustada aktsiahinna muutusi varasema hinnakäitumise põhjal. (Thaler, 1987) See hüpotees põhineb muidugi eeldusel, et kõigil investoritel on tasuta juurdepääs hetkel kättesaadavale teabele tuleviku kohta, nad on head analüütikud ja nad jälgivad tähelepanelikult turuprotsessi ja kohandavad oma osalusi asjakohaselt (Sarma, 2004). Sesoonsus ja turu efektiivsuse hüpotees on kaks finantsökonoomika võtmekontseptsiooni, mis kirjeldavad turuhindade käitumist ja turuprotsessi tõhusust. Kui hooajalisus keskendub perioodilistele ja korduvatele mustritele varahindade liikumises, siis efektiivse turu hüpotees (EMH) väidab, et turuhinnad peegeldavad kogu kättesaadavat teavet ja seetõttu on võimatu teenida kasumit tulevaste hinnaliikumiste prognoosimisega.

Sesoonsus kui statistiline nähtus avaldub tavaliselt konkreetsete ajavahemike, näiteks aastatsüklite, kuu- või nädalaefektide kaudu. Need efektid võivad olla põhjustatud erinevatest teguritest, nagu hooajalised muutused tarbijate eelistustes, muutused turupakkumises või isegi psühholoogilised mõjud nagu *seasonal affective disorder (SAD)*. Järelikult võivad investorid kasutada hooajalisust käsitlevat teavet investeerimisotsuste tegemiseks, näiteks ostes varasid perioodidel, mil nende hinnad on ajalooliselt madalad ja müüa, kui prognoositavalt varasid kohe hakkavad langema.

Teisest küljest väidab turu efektiivsuse hüpotees, et turuhinnad kajastavad kogu nende kujunemise ajal kättesaadavat teavet. Selle hüpoteesi väide tähendab see, et hinnad võtavad juba arvesse kogu olemasolevat varahinna kohta käivat varasemat teavet, sealhulgas sesooneid mustreid. Järelikult ei saa investorid saada kasu, kasutades ajaloolisi sesoonsuse andmeid, sest see on juba kajastatud jooksvates hindades. Konflikt sesoonsuse ja turu efektiivsuse hüpoteesi vahel väljendub selles, et kui sesoonsed mustrid ja kalendriefektid on tegelikult olemas ja neid on võimalik tuvastada, võib

see tähendada, et turud ei ole täielikult efektiivsed. Sellisel juhul võivad investorid, kellel on teavet sesoonsuse kohta, teenida märkimisväärset tulu, mis on vastuolus turu efektiivsuse hüpoteesiga.

1.2.1 Kalendriefektid

Kalendriefektid kujutavad endast finantsturgudel või konkreetsetes finantsinstrumentides täheldatavaid korduvaid mustreid või suundumusi, mis on täheldatud kindlate perioodide, näiteks päevade, kuude, kvartalite või aastate jooksul.

Kuine kalendriefekt on seotud aasta eri kuude keskmise tootluse märkimisväärse ebavõrdsusega ja turu ebaefektiivsusega, see tähendab, et üks konkreetne kuu annab oluliselt erinevat ehk kõrgemat või madalamat tootlust kui ülejäänud kuud aastas (Kumar & Jawa, 2017). Autorite Kamstra, M. J., Kramer, L. A., & Levi, M. D. (2003) tulemused toetavad tugevalt *seasonal affective disorder* (SAD) mõju aktsiatulude hooajalises tsüklis, mis on märkimisväärne, isegi pärast tuntud turuhooaja ja muude keskkonnategurite kontrollimist. See näitab, et turgu võivad mõjutada isegi sellised tegurid nagu ilm või aastaaeg, mis mõjutab investorite meeleolu ja mõtteviisi.

Sesoonsus viitab regulaarsetele ja prognoositavatele mustritele, mis esinevad teatud ajavahemikul, tavaliselt aasta jooksul, mis on tingitud korduvatest loodus- või kultuurinähtustest. Need mustrid korduvad sageli igal aastal ja on tingitud sellistest teguritest nagu ilm, pühad, kultuurisündmused või põllumajanduslikud tsüklid. Näiteks jaemüük kipub suurenema aasta lõpus toimuva pühade ajal ja jäätise müük kipub suurenema suvel. Kalendriefektid omakorda on konkreetsete anomaaliad või mustrid andmetes, mis tulenevad kalendri struktuurist, näiteks kauplemispäevade arvust, pühade ajast või nädalapäevade paigutusest kuu või aasta sees. Erinevalt sesoonsusest ei ole kalendriefektid tingimata seotud looduslike või kultuuriliste tsüklitega, vaid pigem aja suvalise korraldusega. Kui käesolevas töös räägitakse sesoonsusest, siis viidatakse aegrea omadusele, mille puhul andmed muutuvad korrapäraselt ja prognoositavalt, aga, kui räägitakse kalendriefektidest, siis viidatakse efektidele, mis sõltuvad kalendri struktuurist nagu Jaanuari efekt või Müü mais ja mine ära.

Finantsturul on väga palju kalendriefekte. Kõige populaarsem kalendriefekt on Jaanuari efekt. Jaanuairefekt kujutab endast väidet, et jaanuaris on süstemaatiliselt suurem tootlus kui aasta teistel kuudel, mis on üks kõige laialdasemalt tunnustatud anomaaliaid. (Moller, 2008). Ühes artiklis väidetakse, et OMX Tallinn GI indeksil on kalendriefekt, mis on suurim mõju jaanuaris ehk esineb

„Jaanuari efekt“ (Norvaisiene et al., 2015). Käesolevas töös tuleb uurida OMX Tallinn GI indeksi kalendriefektid, selgitades selle põhjuseid ja tähtsust.

1.3. Sesoonsuse modelleerimine

1.3.1. OLS mudel

Sesoonsuse modelleerimiseks kasutakse vähimruutude meetodi (OLS), kus luuakse fiktiivsed tunnused. Mõnikord ei saa majandusnähtust iseloomustada vaid kvantitatiivsete näitajatega. Väga tihti tuleb regressioonimudelites kasutada kvalitatiivseid näitajaid ning selleks tuleb kodeerida kvalitatiivseid näitajaid kvantitatiivseteks. Need andmed nimetatakse fiktiivseteks muutujateks. (Paas, 1995) Vähimruutude meetodi puhul regressioonimudeli parameetrite hinnangud leitakse nii, et jääkide ruutude summa on minimaalne, ning kuna andmed on kuised, siis sesoonsuse mudel on järgmine. (Sauga, 2020):

$$y_t = a_1 + \sum_{i=2}^{12} a_i D_{it} + u_t$$

kus

y_t - sõltuv muutuja perioodil t

D_{it} - fiktiivne tunnus ehk $D_{1t}=1$, kui kuu t on jaanuar ja muidu null; $D_{2t}=1$, kui kuu t on veebruar ja muidu null jne.

a_1 - konstant

a_2 kuni a_{12} - koefitsiendid

u_t - juhusliku vea komponent.

1.3.2. GARCH (1,1) mudel

ARCH-efekt, mis tähendab autoregressiivset tingimuslikku heteroskedastiivsust (Autoregressive conditional heteroskedasticity), viitab nähtusele, kus aegrea volatiilsus või varieeruvus ei ole ajas konstantne, vaid pigem varieerub see aegrida varasemate väärtuste põhjal. Seda efekti täheldatakse sageli finants aegridade andmetes, kus suure volatiilsuse perioodidele järgneb madala volatiilsuse perioodid ja vastupidi. ARIMA-tüüpi lihtsate spetsifikatsioonide parameetrid prognoositakse tavaliselt OLS-metoodika abil, kuid sellel on puudusi, kui esineb volatiilsuse või ARCH-efekt. Näiteks võib probleemiks olla veaterminite autokorrelatsioon. (Chand et al., 2012) OLS eeldab, et juhuslike vigade dispersioonid on konstantsed ehk esineb homoskedastiivsus, mis tähendab, et

jääkide jaotus peaks sõltumatute muutujate kõigil tasanditel olema ligikaudu sama. Kui konstantse dispersiooni eeldust rikutakse ja esineb heteroskedastiivsus, võib see viia valedele standardvigadele (Sauga, 2020). Sellisel juhul oleks mõstlik kasutada GARCH (1,1) mudelit:

$$\sigma_t^2 = \alpha_0 + \alpha_1 u_{t-1}^2 + \beta \sigma_{t-1}^2$$

Kus

σ_t^2 - tinglik dispersioon,

σ_{t-1}^2 - tinglik dispersioon eelmisel perioodil,

u_{t-1}^2 - jääkliikmete ruut eelmisel perioodil,

α, β - parameetrite hinnangud,

α_0 - konstant.

2. ANDMED JA METOODIKA

Käesolevas dokumendis kasutatakse OMX Tallinn GI indeksi kuised andmeid, järgmistes pealkirjades kirjeldatakse indeksi andmeid, kirjeldavat statistikat, metoodikat ja mudeli ülesehitust.

2.1. Andmed ja valim

Andmeanalüüsi jaoks kasutatakse Excel ja Gretl programme. Algandmed laaditi alla csv-formaadis ja teisendati edasi Exceli arvutusteks ja analüüsideks. Excelis viiakse läbi andmete ettevalmistamine ja normaliseerimine ning Gretlis teostatakse empiiriline analüüs ja mudelite loomine. Sõltuvateks muutujateks võetakse OMX Tallinn GI indeksi hinda. Kõik algandmed oli võetud Nasdaq Baltic kodulehelt. Vaatlusperioodiks on maksimaalne periood, nimelt see periood, mis oli maksimaalselt kättesaadav Nasdaq Baltic kodulehelt ehk 2000-2023. Töös kasutakse kuised andmed.

Ühes artiklis kuise sageduse korral ilmnes, et tootlus on kuigi näitasid mõningaid mitte-normaalsuse märke, olid need enamasti normaaljaotuse tunnused. Kui oli uuritud suuremaid sagedusi siis avastati märkimisväärse erinevuse normaaljaotusest. (Quigley, 2008) Tänu sellele artiklile on selge, et indeksi kuiste andmete puhul on tõenäosus, et nad ei allu normaaljaotusele, mis autor kontrollib järgmistes pealkirjades. Üheks ideeks oli võtta indeksi ühe aktsia andmeid ja kasutada neid sesoonsuse analüüsimiseks, et võrrelda tulemusi. Autor arvab, et sellisel juhul sesoonsus juba sõltub aktsia valdkonnast, ning sellisel juhul juba tasub kontrollida, kas valdkond mõjutab indeksi sesoonsust või mitte. Autorid Norvaisiene, R., & Stankeviciene, J. (2022) juba tegid sarnast analüüsi Balti indeksi puhul ja sellise töö puhul ilmnes, et aktsia valdkond võib mõjutada aktsia sesoonsust.

Autori arvates tasub kontrollida ka seda, kuidas sesoonsus on aja jooksul muutunud, et mõista selle kujunemist ja seda, millised sündmused võiksid seda mõjutada. On selge, et volatiilsed sündmused nagu kriisid või sõjad võiksid jätta oma jälje sesoonsusele, mis võib mõjutada erinevate kalendriefektide kujunemist. Autor soovib seda teooriat testida, jagades andmed 4 peaaegu

ühesuguseks 6-aastaseks perioodiks: 01.02.2000-31.12.2005, 01.01.2006-31.12.2011, 01.01.2012-31.12.2017 ja 01.01.2018-31.12.2023 Jaanuari esimene väärtus kaob logaritmilise tootluse arvutamise tõttu, seega esimesel perioodil on 71 vaatlust 72 asemel.

2.2. Kirjeldav statistika

Andmete esmakordsel hindamisel jäi silma, et OMX Tallinn GI indeksi sulgemishinnad olid mittestatsionaarsed, mis on suur probleem aegridade modelleerimisel ja analüüsimisel.


Mittestatsionaarsust on näha alljärgneval graafikul:



Joonis 1. OMX Tallinn GI indeksi sulgemishinnad perioodil (01.01.2000- 31.12.2023)

Allikas: Gretl statistikatarkvara

Statsionaarsus oli savutatud võttes kasutusele aegridade logaritmitud tulumäärade arvutusmetoodi, millest räägitakse rohkem järgmises peatükis.



Joonis 2. OMX Tallinn GI indeksi logaritmitud sulgemishindade muutus perioodil (01.01.2000-31.12.2023)

Allikas: Gretl statistikatarkvara

Samuti kasutab autor neli 6-aastast perioodi kalendriefektide ja nende muutuste täiendavaks analüüsiks, mida tasub samuti hinnata graafiku abil.



Joonis 3. OMX Tallinn GI indeksi väärtuse muutus erinevatel perioodidel (01.02.2000-31.12.2005; 01.01.2006-31.12.2011; 01.01.2012-31.12.2017; 01.01.2018-31.12.2023)

Allikas: Gretl statistikatarkvara

Kõigi perioodide graafikuid uurides on näha, et andmed on mittestatsionaarsed, mille puhul tasub kasutada ka logaritmilist tootlust, et muuta andmed edasiseks analüüsiks statsionaarseks. Samuti näitavad joonised, et esimene ja kolmas periood on turu jaoks üsna positiivsed, kui võrrelda neid kahe teise perioodiga. Teisel ja neljandal perioodil olid suured langused, mis võivad vihjata negatiivsetele uudistele või sündmustele aktsiaturu jaoks. Need sündmused on tõenäoliselt 2008. aasta kriis ja COVID-19 epideemia.



Joonis 4. OMX Tallinn GI indeksi logaritmitud sulgemishindade muutus erinevatel perioodidel (01.02.2000-31.12.2005; 01.01.2006-31.12.2011; 01.01.2012-31.12.2017; 01.01.2018-31.12.2023)

Allikas: Gretl statistikatarkvara

Statsionaarsus oli savutatud samamoodi võttes kasutusele aegridade logaritmitud tulumäärade arvutusmetoodi. Silmatorkav on tugevam volatiilsus teisel ja neljandal perioodil, kus tootluse väärtused langesid peaaegu -30% ja -20% protsendini.

Tabelis 1 on toodud kirjeldav statistika OMX Tallinn GI indeksi logaritmitud sulgemishindade muutuse kohta.

Tabel 1. OMX Tallinn GI indeksi kirjeldav statistika

OMX Tallinn GI	
Period: 01.01.2000-31.12.2023	
Aritmeetiline keskmine (%)	0,896
Mediaan (%)	0,712
Miinum (%)	-29,055
Maksimum (%)	21,762

Standardhälve (%)	5,457
Variatsioonikordaja	6,088
Asümmeetriakordaja	-0,717
Valimi maht	287

Allikas: koostatud lisa 1 alusel

Tabelist 1 selgub, et keskmine logaritmiline tootlus selle aja jooksul on ligikaudu 0,9%, mis viitab sellele, et tootlus on selle perioodi jooksul üldiselt positiivne. Logaritmilise tootluse mediaan, mis on umbes 0,71%, tähendab, et pooled vaatlused jäävad alla selle väärtuse, mis näitab, et tegemist on veidi vasakpoolse jaotusega. Minimaalne logaritmiline tootlus, mida vaadeldaval perioodil täheldati, on -29,06 %, mis näitab kõige ekstreemsemat negatiivset tootlust, ja maksimaalne logaritmiline tootlus oli 21,76 %, mis näitab kõige ekstreemsemat positiivset tootlust. Logaritmilise tootluse standardhälve on ligikaudu 5,48 %, mis näitab tootluse varieeruvust või hajuvust keskväärtuse ümber. Seda varieeruvust rõhutab veelgi variatsioonikoefitsient, mis on ligikaudu 6,088, mis näitab suhteliselt suurt varieeruvust võrreldes keskmisega, kuid see on eeldatav. Ligikaudu -0,72 suurune kalduvus viitab kergele vasakpoolsusele, mis tähendab, et jaotuse saba ulatub rohkem negatiivsete tulude suunas. Andmekogumis on 1 puuduv vaatlus 287 kehtivast vaatlusest, see tulenes logaritmilise tootluse arvutamisest.

OMX Tallinn GI index				
Statistilised näitajad	I period: 01.02.2000- 31.12.2005	II period: 01.01.2006- 31.12.2011	III period: 01.01.2012- 31.12.2017	IV period: 01.01.2018- 31.12.2023
Aritmeetiline keskmine (%)	2,229	-0,283	1,113	0,544
Mediaan (%)	3,199	-0,780	0,905	0,496
Miinum (%)	-11,949	-29,055	-3,359	-19,527
Maksimum (%)	12,953	21,762	8,027	9,697
Standardhälve (%)	5,181	8,221	2,466	4,055
Variatsioonikordaja	2,324	29,094	2,216	7,457
Asümmeetriakordaja	-0,408	-0,345	0,644	-1,302
Valimi maht	71	72	72	72

Allikas: Autori koostatud kasutades Gretl tarkvara

Kui me võrdleme kõiki 4 perioodi, siis kõige kasumlikum oli esimene periood, mille aritmeetiline keskmine oli 2,23% ja mediaan 3,19%, samuti esimesel perioodil puudub 1 vaatlus logaritmilise tootluse arvutamise tõttu, aga kui arvestada sellega, et aktsiaturul olid väga positiivsed tulemused ja tootlused, siis esimese jaanuari arvestamine võiks suurendada aritmeetilise keskmise ja tervikliku tootlust ja tugevdada Jaanuari efekti. Kõige suurem maksimaalne kasum 21,77% oli teisel perioodil, kuid sellel perioodil oli ka kõige suurem kahjum -29,01% ning keskmiselt see oli kõige ebatootlikum periood -0,28% aritmeetilise keskmisega. Variatsioonikordaja näitab, kui suure osa moodustab standardhälve aritmeetilisest keskmisest (Sauga, 2020) ning kõige suurem variatsioonikordaja oli ka teisel perioodil, mis tähendab, et aktsiaindeks näitab suurimaid kõikumisi oma keskmise väärtuse ümber just teisel perioodil. Selline suurenenud volatiilsus võib viidata suurtele hinnakõikumistele. Kalendriefektid, nagu Jaanuari efekt, viitavad aktsiate tootluse efektile, mis esinevad kalendriaasta jooksul konkreetsetel aegadel. Kõrge variatsioonikordaja võib neid mõjusid võimendada, muutes need tugevamaks. Näiteks kui Jaanuari efekt on tavaliselt täheldatav kui suurem tootlus just jaanuaris võrreldes teiste kuudega, võib kõrge variatsioonikordaja põhjustada veelgi suuremaid kõrvalekaldeid keskmisest jaanuaris. Kõige suurem variatsioonikordaja on teisel perioodil ning kõige vähem on kolmandal. Kui rääkida asümmeetriast, siis asümmeetria on jaotuskõvera maksimumi kõrvalekaldumine sümmeetriateljest. Kui jaotuskõvera maksimum (mood) on sümmeetriateljest (mediaan) paremal, on tegemist negatiivse ehk vasakkaldelise asümmeetriaga. Nimetus tuleneb sellest, et "saba" on vasakul pool. Kui maksimum on sümmeetriateljest vasakul pool, jääb saba paremale ja tegemist on positiivse ehk paremkaldelise asümmeetriaga. (Sauga, 2020, lk 106-107) Kõige suurem asümmeetriakordaja -1,3 on neljandal perioodil, mis tähendab, et andmed on vasakkaldelise asümmeetriaga. Vasakkaldelise asümmeetriaga neljas periood näitab, et ekstreemne negatiivne tootlus on tavalisem kui ekstreemne positiivne tootlus.

2.3. Metoodika

Selles peatükis antakse ülevaade käesolevas uuringus kasutatud andmetest ja kasutatud metoodikast. Käesoleva töö autor kasutab kvantitatiivset lähenemisviisi, kogudes vajalikud andmed Nasdaq Baltic andmebaasist. Kogutud andmete põhjal viib autor läbi empiirilise analüüsi. Sesoonsuse analüüsimisel kasutakse logaritmilist tootlust, mis arvutatakse järgmisena:

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

kus

r_i - logaritmiline tootlus,

\ln - naturaalloogarm,

P_t - väärtus perioodil t ,

$t-1$ - eelmine periood.

Logaritmiline tootlus kipub olema stabiilsema variatsiooni kordajaga võrreldes lihtsa tootlusega. Stabiliseerides dispersiooni, on logaritmilise tootluse abil lihtsam tuvastada andmetes mustreid, sealhulgas sesoonsuse kõikumisi ja kalendriefektid. Logaritmilisel tootlusel on lihtsa tootluse ees eelis, nimelt et mitme perioodi logaritmilist tootlust saab arvutada ühe perioodi logaritmilise tootluse summana, aga sama protseduur lihtsa tootlusega võib põhjustada arvutusprobleeme nullilähedaste väärtuste puhul. (Panna, 2017)

2.4. Mudeli ülesehitus

Lõputöö läbiviimiseks kasutatakse 2 erinevat mudelit: OLS ja GARCH(1,1), nende mudelite testimiseks ja ülesehitamiseks tuleks iga järgnev samm läbi töötada:

- Statsionaarsuse kontroll
- Mudeli identifitseerimine (ARCH efekt ja sesoonsuse modelleerimine)
- Parameetrite hindamine
- Mudeli kindlaksmääramine

Mudeli esimeseks etapiks on statsionaarsuse kontrollimine. Statsionaarsuse kontrollimiseks kasutatakse ADF (*Augmented Dickey-Fuller*) testi. Statsionaarsus viitab aegrea omadusele, mille puhul statistilised omadused, nagu keskmine, dispersioon ja autokorrelatsioonistruktuur, jäävad aja jooksul konstantseks. Sesoonsuse testimisel on oluline tagada, et andmed oleksid statsionaarsed, sest see mõjutab statistiliste testide kehtivust, modelleerimise täpsust, tulemuste tõlgendatavust ja sesoonsuse testimise meetodite tõhusust. Statsionaarsus lihtsustab modelleerimisprotsessi ja parandab prognooside täpsust. Mittestatsionaarsed andmed võivad põhjustada valesid korrelatsioone ja ebausaldusväärseid prognoose. Statsionaarsuse tagamine võimaldab paremini tagada andmete tegelikke kalendriefekte, sealhulgas sesoonsust, ja töötada välja usaldusväärsemaid prognoosimudeleid.

Sesoonsuse analüüsi läbiviimisel kasutavad teadlased ja analüütikud sageli nii tavalisi vähimruutude (OLS) kui ka üldistatud autoregressiivse tingimusliku heteroskedastiivsuse (GARCH) meetodi. Sellise kahekordse kasutamise põhjuseks on mõlema meetodi laialdane populaarsus ja hinnanguline tõhusus kalendriefektide kajastamisel. Need mudelid, mida iseloomustavad erinevad statistilised alused, annavad mõnikord sama andmestiku suhtes rakendades erinevaid tulemusi. Tulemuste erinevus võib olla tingitud OLS- ja GARCH-mudelitele omastest nüansidest ja eeldustest. Arvestades nende mudelite erinevaid komponente, parandab mõlema mudeli kaasamine sesoonsuse analüüsi usaldusväärset, andes terviklikuma pildi andmete ajalistest mustritest ja volatiilsuse dünaamikast. Norvaisiene, R., & Stankeviciene, J. (2022) ja Thushara, S. C., Perera, P. (2013) tegid sarnast analüüsi, kus kasutasid kahte erinevat mudelit (OLS ja GARCH) ning mõlemal mudelil olid erinevad tulemused, aga kui OLS mudelis esineb ARCH efekt tasub kasutada ja analüüsida GARCH (1,1) mudelit ka, mis võiks anda täpsemat tulemust. Mudeli koostamisel tuleb hinnata parameetrit. Käesoleva töö puhul hinnatakse kuiseid andmeid või täpsemalt kuised kalendriefektid. Tänu sellele, et vaadeldakse 5 erinevat ajavahemikku, on võimalik näha erinevaid kalendriefekte, mis ilmnevad andmetes. Selline andmete jaotus aitab ka mõista, millised kalendriefektid on stabiilsed ehk ilmnesid igal perioodil ja millised on ajutised ning tingitud erinevatest sündmustest ja uudistest. Viimane etapp on mudeli kindlaksmääramine, kui sesoonsuse mudelid on valmis ja neid tuleb tõlgendada. Sõltuvalt mudelitest võib tõlgendamismeetod erineda, mida tasub tulemuste analüüsimisel ja järelduste tegemisel arvesse võtta.

3. EMPIIRILINE ANALÜÜS JA JÄRELDUSED

3.1. OLS mudeli koostamine

3.1.1 Mudeli eeldused

Mittestatsionaarsus tekitab probleeme aegridade analüüsimisel, eriti kuna see omadus on levinud paljudes reaalses stsenaariumides (Salles et al., 2019). “Selliseid suurusi, mille aegread ei sisalda kindlaid trende, vaid kõiguvad keskmise taseme ümber, nimetatakse statsionaarseteks suurusteks. Suurused, mille aegread sisaldavad pikaajalisi trende, on mittestatsionaarsed suurused.” (Sauga, 2020, lk 581) Esimese mudeli eeldus on statsionaarsuse kontroll ning selleks kasutatakse *Augmented Dickey-Fulleri* (ADF) testi. Augmented Dickey-Fulleri test on lihtsa Dickey-Fulleri testi laiendatud versioon, milles autokorrelatsiooniprobleemi kõrvaldamiseks lisatakse sõltuvatele muutujatele täiendav viitaeg. (Mushtaq, 2011) Ühikjuure olemasolu näitab, et aegread on mittestatsionaarsed, mis tähendab, et nende statistilised omadused, nagu keskmine ja dispersioon, ei ole aja jooksul konstantsed. Töös analüseeritakse sesoonsust ning on väga oluline, et andmed oleksid statsionaarsed. ADF-test viidi läbi kolme stsenaariumi korral: konstant ja trend, ainult konstant ja ilma konstandita. Saadud p-väärtused olid iga stsenaariumi puhul järgmised: 0,438 koos konstandi ja trendiga, 0,118 ainult konstandiga ja $4,02 \cdot 10^{-15}$ ilma konstandita.

Neid tulemusi tõlgendades, kui mudelis võetakse arvesse nii konstanti kui ka trendi, p-väärtus on 0,438, mis näitab, et aegread on ilmselt mitte-statsionaarsed ning konstant ja trend ei ole statistiliselt oluline, järgnevalt kontrolitakse konstandiga mudelit. Samamoodi, kui arvestada ainult konstandiga mudelit, jääb p-väärtus 0,118 suhteliselt kõrgeks, mis toetab veelgi rea võimalikku mittestatsionaarsust ning konstant ei ole statistiliselt oluline, järgnevalt kontrolitakse ilma konstandita mudelit. Olukord muutub kui analüseerida mudelit ilma konstandita ja jätta konstandi mudelist välja. P-väärtus $4,02 \cdot 10^{-15}$ annab tugeva tõendusmaterjali nullhüpoteesi vastu, mis näitab, et aegrida on tõenäoliselt statsionaarne ilma konstandita. Asümptootiline p-väärtus ilma konstandita mudeli puhul on $6,519 \cdot 10^{-7}$, mis näitab, et sisukas hüpotees oli tõestatud ja nullhüpotes on tagasi lükatud. Ühikjuur puudub, mis toetab aegrea statsionaarsust. Seega võime ADF-testi tulemuste põhjal järeldada, et kui me jätame konstandi mudelist välja, see näitab parima tulemust ning statsionaarsus on savutatud.

Tabel 2. OMX Tallinn GI indeksi ADF testi olulise tõenäosused perioodil 01.02.2000-31.12.2023

ADF testi statsionaarsuse olulise tõenäosus			
Indeks	Konstandi ja trendiga	Konstandiga	Ilma konstandita
OMX Tallinn GI	0,438	0,118	$4,02 \cdot 10^{-15}$

Allikas: Autori koostatud kasutades Gretl tarkvara, Lisa 2

Tabelist 2 on näha, et aegrea jaoks tuleb võtta vastu sisukas hüpotees, ühikjuurt ei ole ning aegrida on statsionaarne. Olulisuse tõenäosus ilma konstandita mudeli põhjal on väiksem kui 0,05 ning asümptootiline p-väärtus ilma konstandita mudeli puhul on $6,519 \cdot 10^{-7}$, mis samuti vähem kui 0,05 ja tuleviku modelleerimisel kasutakse ilma konstandita mudelit


Tabel 3. OMX Tallinn GI indeksi ADF testi olulise tõenäosused erinevatel perioodidel

ADF testi statsionaarsuse olulise tõenäosus			
Perioodid	Konstandi ja trendiga	Konstandiga	Ilma konstandita
01.02.2000-31.12.2005	0,0228**	0,0408**	$6,40 \cdot 10^{-7}***$
01.01.2006-31.12.2011	0,922	0,845	0,0005***
01.01.2012-31.12.2017	0,449	0,0044***	$1,71 \cdot 10^{-9}***$
01.01.2018-31.12.2023	0,985	0,339	$1,63 \cdot 10^{-11}***$

Allikas: Autori koostatud kasutades Gretl tarkvara, Lisad 3,4,5,6

Tabel 3 juba näitab tulemusi erinevate perioodide kohta. Perioodi jagamisel 4 osaks tasub hinnata iga aegrea statsionaarsust. Esimene periood näitab statsionaarsust koos konstandi ja trendiga mudelis, kus olulise tõenäosus on 0,0228. Asümptootiline p-väärtus ehk ühikjuure testi olulise tõenäosus konstandi ja trendiga mudeli puhul on $6,052 \cdot 10^{-5}$, mis tähendab, et ühikjuurt ei ole ning statsionaarsus on saavutatud. Kui hinnata sama perioodi konstandiga mudelit, siis tulemused on liigikaudu samad – koos konstandiga mudeli olulise tõenäosus on 0,0408 ning asümptootiline p-väärtus on $8,993 \cdot 10^{-6}$, mis tähendab, et trendi lisamine ei mõjutanud statsionaarsust oluliselt.

Esimese perioodi põhjal kasutakse konstandiga mudelit. Teine periood näitab statsionaarsust ilma konstandita mudelis, kus olulise tõenäosus on 0,0005. Asümptootiline p-väärtus ehk ühikjuure testi olulise tõenäosus ilma konstandita mudeli puhul on 0.0005, mis tähendab, et ühikjuurt ei ole ning statsionaarsus on saavutatud. Teise perioodi kohta kasutakse ilma konstandita mudelit. Kolmas periood näitab statsionaarsust koos konstandiga mudelis, kus olulise tõenäosus on 0,0044. Ühikjuure testi olulise tõenäosus konstandiga mudeli puhul on $1.351 \cdot 10^{-10}$, mis tähendab, et ühikjuur puudub ning statsionaarsus on saavutatud. Kolmanda perioodi kohta kasutakse ilma konstandita mudelit. Neljas periood on statsionaarne ilma konstandita mudeli puhul, kus olulise tõenäosus on $1,63 \cdot 10^{-11}$. Ühikjuure testi olulise tõenäosus ilma konstandita mudeli puhul on $1,63 \cdot 10^{-11}$.



Joonis 5. OMX Tallinn GI indeksi normaaljaotus perioodil 01.02.2000-31.12.2023

Allikas: Autori koostatud kasutades Gretl tarkvara

Eelmistes pealkirjades esitatud põhjendustest selgus, et kuides andmed ei pruugi olla normaaljaotusega, kuid pärast analüüsi läbiviimist on näha, et see on tõestatud. Autorites Ullah, I., Ullah, S., & Ali, F. (2016) oli sarnane juhtum, kui andmed pärast logaritmilise tootluse arvutamist

näitasid mitte normaaljaotuse märke. See näitab, et esinevad kõrvalekaldeid, mis takistavad andmete normaaljaotust. Selliste kõrvalekallete väljajätmine võib viia ebaefektiivsete või eksitavate järelduste tegemiseni. (Ullah et al., 2016)

3.1.2 OLS mudelid

Järgmiseks etapiks on OLS mudelite koostamine. Vähimruutude meetodi (*Ordinary least squares*) korral regressioonmudeli parameetrite hinnangud leitakse nii, et jääkide ruutude summa on minimaalne (Sauga, 2020). See on väga populaarne meetod sesoonsuse analüüsimiseks, mida kasutati palju autoreid, sealhulgas on autorid Angelovska, J. (2014) või Ullah, I., Ullah, S., & Ali, F. (2016), kes said kasulikke ja vajalikke tulemusi.

Tabel 4. OMX Tallinn GI indeksi OLS koefitsiendid perioodil 01.02.2000-31.12.2023

Kuu	OLS mudeli tulemused	
	Koefitsient	Olulise tõenäosus
Jaauar	0.0451	$7.27 \cdot 10^{-5}$ ***
Veebruar	0.0246	0.0256 **
Märts	-0.00539	0.623
Aprill	0.0197	0.0729 *
Mai	-0.000957	0.930
Juuni	-0.00469	0.669
Juuli	0.00427	0.697
August	0.011	0.314
September	0.00604	0.582
November	-0.00992	0.366
Oktoober	0.00738	0.501
Detsember	0.0119	0.278

Allikas: Autori koostatud kasutades Gretl tarkvara, Lisa 3

OLS mudeli põhjal on ilmselgelt näha, et statistiliselt olulised kuud vähemalt 0.05 nivooga on Jaauar ja Veebruar, mis omakorda tõendab indeksi sesoonsuse olemasolu. Jaauari efekt on tavaliselt seotud sellega, et investorid müüvad detsembris maksukahjumi saamise eesmärgil kaotavad aktsiad ja ostavad need pärast uut aastat tagasi. OMX Tallinn GI indeksi andmete põhjal on selge, et tootlus on kõige suurem just jaauari kuul, kus koefitsient on 0.04507 ning olulise

tõenäosus on $7.27 \cdot 10^{-5}$, mis omakorda vähem kui olulise nivoo 0.01. Veebruar on ka statistiliselt oluline, vaid koefitsiendiga 0.0245 ja olulise tõenäosusega 0.0256. Veebruar näitab endiselt suundumust kõrgemale tootlusele, kuigi vähemal määral kui jaanuaris. Veebruar langeb sageli kokku paljude ettevõtete tulude aruannete avaldamisega. Kui märkimisväärne arv OMX Tallinn GI indeksisse kuuluvaid ettevõtteid teatab sel ajal positiivsetest tulemustest, võib see suurendada investorite optimismi ja viia indeksi tõusuni. Märtsist detsembrini ei avalda ükski koefitsient statistiliselt olulist mõju indeksi tootlusele, kusjuures olulise tõenäosus on vähemalt väiksem kui 0.05. Ainult aprillis on olulise tõenäosus 0.0729, vaid olulise nivoo 0.1, mis ei saa tõendada sesoonsust.. See tähendab, et nendel kuudel ei ole olulisi sesooneid mustreid, vähemalt praeguse mudeli põhjal.

Selleks, et võtta volatiivsust arvesse, Autor kasutas ARCH (*Autoregressive conditional heteroskedasticity*) testi, mille järgi ilmnes, et p-väärtus on $2.04464 \cdot 10^{-12}$, mis tähendab, et nullhüpotees (H_0) on tagasi lükatud ning sisukas hüpotees (H_1) oli vastu võetud (Lisa 4). Mudeli jääkide dispersioon ei ole aja jooksul konstantne, vaid sõltub jääkide varasematest väärtustest. Sellega tasub koostada ning analüüsida GARCH mudeli.

Tabel 5. OMX Tallinn GI indeksi OLS koefitsiendid erinevatel perioodidel

OLS mudeli tulemused				
Kuu	I periood: 01.02.2000- 31.12.2005	II periood: 01.01.2006- 31.12.2011	III periood: 01.01.2012- 31.12.2017	IV periood; 01.01.2018- 31.12.2023
Jaanuar	const 0.0467 (0.0519*)	0.0723 (0.0340**)	const 0.0259 (0.0082***)	0.0355 (0.0324 **)
Veebruar	0.00462 (0.885)	0.0186 (0.579)	-0.00396 (0.769)	0.00633 (0.697)
Märts	-0.0134 (0.677)	-0.0466 (0.168)	-0.000659 (0.961)	-0.0337 (0.0419 **)
Aprill	-0.0171 (0.593)	0.0232 (0.489)	-0.0108 (0.426)	0.0109 (0.504)
Mai	-0.0319 (0.320)	-0.0181 (0.589)	-0.0320 (0.0203**)	0.00557 (0.732)

Juuni	-0.0544 (0.0934*)	-0.0193 (0.565)	-0.0237 (0.0829 *)	0.00589 (0.717)
Juuli	-0.0465 (0.150)	-0.0105 (0.753)	-0.00479 (0.723)	0.00616 (0.705)
August	-0.0503 (0.120)	0.0167 (0.619)	-0.00531 (0.694)	0.0104 (0.525)
September	-0.0329 (0.306)	0.0267 (0.426)	-0.0348 (0.0121**)	-0.0076 (0.642)
November	-0.0245 (0.446)	-0.0402 (0.233)	-0.0305 (0.0269**)	-0.0173 (0.291)
Oktoober	-0.0149 (0.639)	-0.0340 (0.311)	-0.0140 (0.301)	0.0199 (0.225)
Detsember	-0.00769 (0.810)	-0.0227 (0.499)	-0.0179 (0.189)	0.0232 (0.158)

Allikas: Autori koostatud kasutades Gretl tarkvara, Lisad 8,9,10,11

OLS-mudelid koostati iga perioodi kohta. Esimene ja kolmas periood koostati koos konstandiga, teine ja neljas periood ilma konstandita, seega on mudelite analüüsimisel tulemuste tõlgendus võib erineda. Mudelite analüüsimisel on kõige märgatavam, et igal perioodil on Jaanuari efekt. Esimesel perioodil ei olnud Jaanuari efekt väga tugev, kus p-väärtus on ainult 0,0934 < 0,1, aga teistel kuudel on Jaanuari efekt sabiilselt tugev, eriti kolmandal perioodil kus p-väärtus on 0,0082 < 0,01. Kolmandal perioodil on kõige rohkem kalendriefekte. Olulisuse nivooga 0,01 esines kalendriefekt juunis, mida oli täheldatud ka esimesel perioodil. Olulise nivooga 0,05 kolmas perioodil täheldati kolme kalendriefekti: Mai-, Septembri- ja Novembri efekt. Jaanuari efekt on kolmandal perioodil kõige tugevamalt märgatav olulise nivooga 0.01. Kui vaadelda viimast ehk neljanda perioodi, siis on näha, et perioodil esineb tugev Jaanuari efekt olulise nivooga 0,05, aga samuti esineb Märtsi efekt olulise nivooga 0,05, kus on kõige negatiivsem koefitsient sellel perioodil -3.37%. Selline negatiivne mõju tõenäoliselt tekkis COVID-19 pandeemia tõttu.

3.2. GARCH mudeli koostamine

Kuna ilmnes, et OLS mudelis esineb ARCH efekt, Autor kasutab GARCH(1,1) (*Generalized AutoRegressive Conditional Heteroskedasticity*) mudeli, mida samuti kasutati palju autoreid sesoonsuse jäädvustamiseks erinevates riikides, näiteks autorid Obalade, A. A., & Muzindutsi, P. F. (2019) ja Seyyed, F. J., Abraham, A., & Al-Hajji, M. (2005), kes samuti said efektiivseid ja adekvaatseid tulemusi.

Tabel 6. OMX Tallinn GI indeksi GARCH(1,1) koefitsiendid

Kuu	GARCH(1,1) mudeli tulemused	
	Koefitsient	Olulise tõenäosus
Jaanuar	0.0363	0.0001 ***
Veebruar	0.0193	0.0518 *
Märts	-0.00130	0.872
Aprill	0.0157	0.0652 *
Mai	-0.00255	0.762
Juuni	-0.00171	0.843
Juuli	0.0129	0.124
August	0.0112	0.177
September	-0.00144	0.869
November	-0.00809	0.346
Oktoober	0.0134	0.121
Detsember	0.0167	0.0597 *
$\alpha (0)$	0.000132	0.0102 **
$\alpha (1)$	0.105	0.0036 ***
$\beta (0)$	0.839	$4.94 \cdot 10^{-70}$ ***

Allikas: Autori koostatud kasutades Gretl tarkvara, Lisa 5

GARCH(1,1) mudel näitab järgmiseid tulemusi: Jaanuari efekt samuti esineb olulise nivooga 0.01, aga veebruar juba ei ole sama olulisuse tõenäosusega. Veebruar, aprill ja detsember on olulise nivooga 0.1, mis ei näita tugevat kalendriefekti sellistes kuudes. Jaanuar ja Veebruar on kõige suurema tootlusega 0.0363 ja 0.0192 koefitsiendidega vastavalt. GARCH(1,1) mudel näitab, et OMX Tallinn GI indeksil esineb tugev Jaanuari efekt.

3.2. Järeldused

Enne mudelite koostamist oli autoril arvamus, et OMX Tallinn GI indeksil esineb sesoonsus ning on võimalik jäädvustada kalendriefekte. Töö käigus selgus, et OMX Tallinn GI indeksil esineb sesoonsus, mis on üsna sarnane teiste autorite uuringutega. Lõputöö eesmärk oli modelleerida sesoonsust OMX Tallinn GI indeksil tuginedes OLS ja GARCH(1,1) mudelitele ning hinnata mudelite tulemusi.

Mudelite tulemused näitavad, et indeksil esineb sesoonsus. OLS-mudelil tuvastati kalendriefekte jaanuaris ja veebruaris, kus oli ka suurim tootlus. Jaanuari kalendriefekt oli ootuspärane, sest paljude autorite Balti indeksi või Tallinna indeksi tööde puhul esineb Januari efekt. Kuu efekti uurimine Balti aktsiaturgudel näitas, et Eestis esinesid Jaanuari- ja Oktoobri efektid (Norvaisiene & Stankeviciene, 2022). Kuid käesolevas töös ei täheldatud sesoonsust oktoobris, vaid OLS mudeli puhul veebruaris, mis juba näitab, et sesoonsus on ajaga muutunud. Eelmised autorid on analüüsinud sesoonsust juba 5 või enam aastat tagasi. Selle perioodi jooksul oli COVID-19 pandeemia, mis raputas kogu maailma majandust, samuti finantsturge, mis omakorda tähendab suurenenud volatiilsust. Samuti ei tohiks unustada Venemaa ja Ukraina vahelist sõjalist konflikti, mis võis samuti mängida rolli indeksi käitumise ja selle sesoonsuse ja kalendriefektide muutmisel. Kõiki neid tegureid teades kahtlustas autor ARCH-efekti olemasolu, mis omakorda võib tähendada, et OLS-mudel on ebatäpne ja sesoonsust tasub analüüsida GARCH-mudeli abil. Pärast analüüsi selgus, et OLS-mudelil on tõepoolest ARCH-efekt olemas, mis omakorda õigustab GARCH-mudeli kasutamist. GARCH(1,1) mudel näitas, et indeksil esineb kalendriefekt ainult jaanuaris, kuid veebruar oli väga lähedal sellele, et näidata tugeva kalendriefektiit, sest veebruari koefitsient oli 0,518, mis on väga lähedal olulisuse nivoole 0,05.

Kui võrrelda kõike mudeleid, siis Jaanuari efekt esineb igas mudelis ning kõige suurem tootlus on just jaanuaris. Kogu perioodi OLS mudelis kõige kahjumlik kuu on märts, vaid GARCH(1,1) mudeli põhjal see on november. OMX Tallinn GI indeksis tuvastatud kalendriefektid tõestavad Tallinna aktsiaturgude ebaefektiivsust, kuna aktsiahinnad ei ole juhuslikud, vaid neid saab prognoosida vastavalt teatavatele kuistele kalendriefektidele. OMX Tallinn GI indeksi tootlus on sõltuvalt kuuajast järjepidevalt kõrgemad või madalamad.

KOKKUVÕTE

Kui on tegureid, mis mõjutavad turgu perioodiliselt ja stabiilselt, tasub need arvesse võtta, sest toovad need muutused kaasa ettearvamatuid tagajärgi. Turu kriiside või vastupidi eufooria ajal mõned inimesed ei suuda adekvaatselt hinnata aktsiate graafikut, kuna nad näevad rohelisi või punaseid küünlaid ja emotsioonid võtavad üle ilma enneaegse analüüsita. Emotsioonid on eriti võimsad ja kui need meie üle võimust ära võtavad, võivad nad hakata meie käitumist juhtima ning me võime kaotada selle üle kontrolli, mis põhjustab irratsionaalseid otsusi.

Aktsiaturgude paremaks mõistmiseks ja turul soodsama positsiooni võtmiseks tasub kaaluda sesoonsust ja selle tagajärgi nimelt kalendriefekte. Aja jooksul võivad turgude sesoonsust mõjutada paljud asjad, näiteks kriisid või sõjalised olukorrad. Sellistel aegadel tasub otsida enda jaoks võimalusi, mis aitavad oma portfeli veelgi paremini teostada. Sesoonsuse modellemiseks oli kasutatud OLS ja GARCH(1,1) mudeleid, et võtta arvesse volatiivsust ja anda täpsemat ülevaadet. Lõputöö eesmärk on modelleerida sesoonsust OMX Tallinn GI indeksil tuginedes OLS ja GARCH(1,1) mudelitele ning jäädvustada kalendriefekte. Autor püstitas lõputöö teostamiseks järgnevad uurimisküsimused, millele töö käigus leiti vastused:

1. Kas OMX Tallinn GI indeksil esineb sesoonsus?
2. Millised kuised kalendriefektid seletavad ja mõjutavad OMX Tallinn GI indeksi sesoonsust?

Käesolevas töös oli uuritud, kas OMX Tallinn GI indeksil esineb sesoonsus ja kui jah, siis millised kuised kalendriefektid esinevad indeksil. Töö läbiviimiseks oli võetud 01.01.2000-31.12.2023 periood. Esialgsed OMX Tallinn GI indeksi andmed olid sulgemishindade vormil. Kogu perioodi indeksi valim koosnes 288. sulgemishinnast. Töö käigus valiti ka täiendavaid ajavahemikke, et täpsemalt uurida sesoonsust ja kalendriefekte. Täiendavateks perioodideks oli valitud kuue aastased ajavahemikud ehk kokku on 4 perioodi: 01.02.2000-31.12.2005, 01.01.2006-31.12.2011, 01.01.2012-31.12.2017, 01.01.2018-31.12.2023. See võimaldab anda täpsemat ülevaadet indeksi sesoonsuse modelleerimisel erinevates turutingimustes ja majandustsüklites. Andmete jagamine

erinevateks perioodideks võib hõlmata erinevaid turufaase, nagu tõusu- ja langusfaase, majanduskasvu, majanduslanguse või stabiilsema majandusega perioode.

Andmed oli võetud Nasdaq Baltic andmebaasist. Pärast seda kanti andmed Excelisse, kus autor arvutas logaritmilist tootlust, et eemaldada mittestatsionaarsust ja seejärel olid andmed valmis Gretl'i töötlemiseks ja analüüsimiseks. Gretl'i programmis viis autor läbi ADF-testi, mille järel selgus, et kogu perioodi kohta tasub kasutada ilma konstandita mudelit. Kui vaadelda nelja kuue aastase perioodi, siis esimese ja kolmanda perioodi mudeleid koostati koos konstandiga, teist ja neljandat perioodi modelleeriti ilma konstandita. Järgmise sammuna analüüsiti kogu perioodi ehk 01.01.2000 kuni 31.12.2023 andmeid OLS-mudeli abil. OLS mudeli põhjal selgus, et OMX Tallinn GI indeksil esineb tugevad Jaanuari ja Veebruari efektid, samuti indeksil esineb nõrk Aprilli efekt. Teistel kuudel ei olnud võimalik jäädvustada rohkem kalendriefekte, aga ARCH efekti olemasolu kahtlustas mudeli täpsust ning autor otsustas kasutada GARCH(1,1) mudelit. GARCH(1,1) mudeli analüüsi käigus selgus, et OMX Tallinn GI indeksil esineb tugev Jaanuari efekt ning nõrgad Veebruari-, Aprilli- ja Detsembri efektid. Veebruari efekt ei esinenud mitte üheski nelja perioodi mudelites, kuid selle täielikku puudumist kogu perioodil kinnitada ei saa, kuna see esines kogu perioodi OLS ja GARCH(1,1) mudelites. Perioodilistes mudelites samuti ei esinenud Aprilli ja Detsembri kalendriefektid. Esimesel perioodil ehk 01.02.2000 kuni 31.12.2005 esinesid nõrgad Jaanuari ja Juuni efektid olulise nivooga 0,1, see oli üsna positiivne periood turul, kus oli väga suur tootlus. Jaanuari efekti olemus on loogiline, kuna see on tihti seotud suurema tootlusega. Teisel perioodil ehk 01.01.2006 kuni 31.12.2011 esineb ainult tugev Jaanuari efekt. Teine periood oli väga negatiivne või kahjumlik, sest sel ajal oli 2007-2008 kriis, aga sel perioodil ei õnnestunud märkida negatiivset kalendriefekte. Kolmandal perioodil ehk 01.01.2012 kuni 31.12.2017 oli kõige rohkem kalendriefekte nimelt väga tugev Jaanuari efekt olulise nivooga 0.1, tugevad Mai-, Septembri- ja Novembri efektid olulise nivooga 0.05 ja nõrk Juuni efekt nagu esimesel perioodil. Sellel perioodil on negatiivsed kalendriefektid nagu Mai efekt -0.6% tootlusega, Septembri efekt -0.8% tootlusega ja Novembri efekt -0.4% tootlusega. Viimane neljas periood ehk 01.01.2018 kuni 31.12.2023 hõlmab 2 kalendriefekti: Jaanuari- ja Märtsi efekt. Mõlemad kalendriefektid on olulise nivooga 0,05. Negatiivne Märtsi efekt -3,37% tootlusega on tõenäoliselt seotud COVID-19 pandeemia- ning Venemaa ja Ukraina sõjalise konfliktiga. Märtsi efekti ei saa vaadeldada koguperioodil.

OMX Tallinn GI indeksi puhul sesoonsuse ja kalendriefektide analüüsimisel oli võimalik täheldada Jaanuari efekti kõigidel perioodidel, mis võib viidata tugevale Jaanuari efekti tõendusele

ja turu ebaefektiivsusele. Muud kalendriefektid varieerusid väga oluliselt sõltuvalt perioodist ja võimalikult turufaasist.

Võimalike tulevaste tööde puhul tasub hinnata iganädalast või igapäevast OMX Tallinn GI indeksi sesoonsust, et täpsemalt analüüsida sesoonsust ja kalendriefekte, mis võivad indeksi puhul esineda. Samuti tasub uurida, kas kalendriefektid on erinevad sõltuvalt turufaasidest.

SUMMARY

ANALYSIS OF OMX TALLINN GI INDEX MONTHLY CALENDAR EFFECTS

Dmitri Tšumakov

If there are factors that affect the market in a periodic and stable way, it is worth taking them into account, because these changes can bring unexpected consequences. In times of crisis or, conversely, euphoria in the market, some investors are unable to rationally assess a stock chart because they see green or red candles and emotions take over without premature analysis. Emotions are particularly powerful and when they take over - they can start to drive our behaviour and we can lose control of them leading to irrational decisions.

In order to better understand stock markets and take a more favourable position in the market, it is worth considering seasonality and its consequences, namely calendar effects. Over time, the seasonality of markets can be affected by many things, such as crises or military situations. At such times, it is worth looking for opportunities that will help your portfolio perform even better. To model seasonality, OLS and GARCH(1,1) models were used to take volatility into account and provide a more accurate view. The aim of this thesis is to model seasonality in the OMX Tallinn GI index based on OLS and GARCH(1,1) models and capture calendar effects. The author set the following research questions for the thesis, which were answered in the course of the work:

1. Does the OMX Tallinn GI index exhibit seasonality?
2. What monthly calendar effects explain and influence the seasonality of the OMX Tallinn GI index?

In the present work it was investigated whether the OMX Tallinn GI index exhibits monthly seasonality and which calendar effects are present in the index. The period taken for the work was 01.01.2000-31.12.2023. Initial OMX Tallinn GI index data was in the form of closing prices. The sample for the whole period consisted of 288 values. During the work additional time periods were

selected to further investigate seasonality and calendar effects. Six-year periods were selected as additional periods, for a total of 4 periods: 01.02.2000-31.12.2005, 01.01.2006-31.12.2011, 01.01.2012-31.12.2017, 01.01.2018-31.12.2023. This allows for a more accurate insights into seasonality and calendar effects of the index under different market conditions and business cycles. Splitting the data into different periods can cover different market phases, such as bull and bear markets, growth, recession or more stable economic periods.

The data was taken from the Nasdaq Baltic database. The data was then entered into Excel, where the author calculated the logarithmic return to remove non-stationarity, and then the data was ready for Gretl processing and analysis. In the Gretl program, the author carried out an ADF test, after which it became clear that it was worthwhile to use a non-constant model for the whole period. Looking at the four six-year periods, the first and third periods were modelled with constants, while the second and fourth periods were modelled without constants. The next step was to analyse the data for the whole period from 01.01.2000 to 31.12.2023 using the OLS model. From the OLS model it was found that OMX Tallinn GI index has strong January and February effects, also the index has weak April effect. In other months it was not possible to capture calendar effects, but the presence of ARCH effect gives doubts on the accuracy of the model and the author decided to use GARCH(1,1) model. The analysis of the GARCH(1,1) model revealed that the OMX Tallinn GI index has a strong January effect and weak February, April and December effects. The February effect was not present in any of the four period models, but its complete absence cannot be confirmed for the whole period, as it was present in the OLS and GARCH(1,1) models for the whole period. The April and December calendar effects were also absent in the periodic models. In the first period, from 01.02.2000 to 31.12.2005, there were weak January and June effects with a significant level of 0.1, a rather positive period in a market with very high returns. The nature of the January effect is logical, as it is often associated with higher returns. In the second period, i.e. from 01.01.2006 to 31.12.2011, only a strong January effect occurs. The second period was very negative because of the 2007-2008 crisis, but no negative calendar effect could be observed in this period. In the third period, from 01.01.2012 to 31.12.2017, the highest number of calendar effects was found, namely a very strong January effect with a significant level of 0.01, strong May, September and November effects with a significant level of 0.05 and a weak June effect as in the first period. In this period there are negative calendar effects such as the May effect with -0.6% return, the September effect with -0.8% return and the November effect with -0.4% return. The last four periods, from 01.01.2018 to 31.12.2023, include 2 calendar effects: January and March effect. Both calendar effects have a significant level of 0.05. The negative March effect with -

3.37% return is probably related to the COVID-19 pandemic and the military conflict between Russia and Ukraine, but the March effect cannot be seen for the whole period. In the case of the OMX Tallinn GI index, when analysing seasonality and calendar effects, it was possible to observe the January effect in all periods, which may indicate strong evidence of the January effect and market inefficiency. The other calendar effects varied considerably depending on the period and possibly on the market phase.

For possible future work, it is worthwhile to assess the weekly or daily seasonality of the OMX Tallinn GI index to further analyse the seasonality and calendar effects that may be present in the index. It is also worth investigating whether calendar effects are different depending on market phases.

KASUTATUD ALLIKATE LOETELU

- Ali, M., Alam, N., & Rizvi, S. A. R. (2020). Coronavirus (COVID-19)—An epidemic or pandemic for financial markets. *Journal of Behavioral and Experimental Finance*, 27, 100341.
- Ang, A., & Timmermann, A. (2012). Regime changes and financial markets. *Annu. Rev. Financ. Econ.*, 4(1), 313-337.
- Angelovska, J. (2014). Month related seasonality on the Macedonian stock market. *Business and Economics Research Journal*, 5(1), 143-150.
- Chand, S., Kamal, S., & Ali, I. (2012). Modeling and volatility analysis of share prices using ARCH and GARCH models. *World Applied Sciences Journal*, 19(1), 77-82. DOI: 10.5829/idosi.wasj.2012.19.01.793
- Jakučionytė, E. (2011). The effect of euro adoption on NASDAQ OMX Baltic stock exchange: analysis by structural break tests. *Ekonomika*, 80(3), 73-92.
- Kamstra, M. J., Kramer, L. A., & Levi, M. D. (2003). Winter blues: A SAD stock market cycle. *American economic review*, 93(1), 324-343.
- Kumar, H., & Jawa, R. (2017). Efficient market hypothesis and calendar effects: Empirical evidences from the Indian stock markets. *Business Analyst*, 37(2), 145-160.
- Luchtenberg, K. F., & Vu, Q. V. (2015). The 2008 financial crisis: Stock market contagion and its determinants. *Research in International Business and Finance*, 33, 178-203.
- Moller, N., & Zilca, S. (2008). The evolution of the January effect. *Journal of Banking & Finance*, 32(3), 447-457.
- Mushtaq, R. (2011). Augmented dickey fuller test.
- Nasdaq Baltic. (2024) *About indexes*. Kättesaadav: <https://nasdaqbaltic.com/market-information/about-indexes/>
- Norvaisiene, R., & Stankeviciene, J. (2022). The month effect in the Baltic and Nordic stock markets at market-level and sector-level. *Inžinerinė ekonomika*, 33(5), 473-485.
- Norvaisiene, R., Stankeviciene, J., & Lakstutiene, A. (2015). Seasonality in the Baltic stock markets. *Procedia-Social and Behavioral Sciences*, 213, 468-473.

- Obalade, A. A., & Muzindutsi, P. F. (2019). Calendar Anomalies, Market Regimes, and the Adaptive Market Hypothesis in African Stock Markets. *Central European Management Journal*, 27(4).
- OMX Tallinn GI indeksi andmebaas. Kättesaadav: <https://nasdaqbaltic.com/statistics/en/charts>
- Paas, T. (1995). Sissejuhatus ökonomeetriasse. Tartu Ülikooli Kirjastus.
- Panna, M. (2017). Note on simple and logarithmic return. *AgEcon search: research in agricultural & applied economics*, 11, 127-136. 10.19041/APSTRACT/2017/1-2/16
- Quigley, L., (2008). Statistical analysis of the log returns of financial assets. *Financial mathematic, University of Limerick*, 32.
- Salles, R., Belloze, K., Porto, F., Gonzalez, P. H., & Ogasawara, E. (2019). Nonstationary time series transformation methods: An experimental review. *Knowledge-Based Systems*, 164, 274-291.
- Sarma, S. N. (2004). Stock market seasonality in an emerging market. *Vikalpa*, 29(3), 35-42.
- Sauga, A. (2020). Statistika õpik majanduseriala üliõpilastele. Tallinna Tehnikaülikooli Kirjastus.
- Seyyed, F. J., Abraham, A., & Al-Hajji, M. (2005). Seasonality in stock returns and volatility: The Ramadan effect. *Research in International Business and Finance*, 19(3), 374-383.
- Thaler, R. H. (1987). Anomalies: the January effect. *Journal of economic perspectives*, 1(1), 197-201.
- Thushara, S., Prabath, P.(2013) *The month of the year effect: empirical evidence from colombo stock exchange*.
- Ullah, I., Ullah, S., & Ali, F. (2016). Market Efficiency anomalies: A Study of january effect in Karachi stock market. *Journal of Managerial Sciences*, 10(1), 32-44.

LISAD

Lisa 1. OMX Tallinn GI indeksi tootluse kirjeldav statistika

Summary Statistics, using the observations 2000:01 - 2023:12
for the variable logreturn (287 valid observations)

Mean	Median	Minimum	Maximum
0.0089626	0.0071193	-0.29055	0.21762
Std. Dev.	C.V.	Skewness	Ex. kurtosis
0.054567	6.0884	-0.71711	4.8963
5% Perc.	95% Perc.	IQ range	Missing obs.
-0.066734	0.086838	0.055926	1

Lisa 2. Augmented Dickey-Fuller test periodil 01.02.2000-31.12.2023

k = 15: AIC = -859.958
 k = 14: AIC = -861.850
 k = 13: AIC = -863.500
 k = 12: AIC = -865.476
 k = 11: AIC = -867.176
 k = 10: AIC = -869.125
 k = 9: AIC = -867.964
 k = 8: AIC = -865.793
 k = 7: AIC = -867.126
 k = 6: AIC = -869.065
 k = 5: AIC = -862.792
 k = 4: AIC = -861.045
 k = 3: AIC = -859.864
 k = 2: AIC = -860.465
 k = 1: AIC = -854.840
 k = 0: AIC = -854.108

Augmented Dickey-Fuller test for logreturn
 testing down from 15 lags, criterion AIC
 sample size 276
 unit-root null hypothesis: $a = 1$

test without constant
 including 10 lags of (1-L)logreturn
 model: $(1-L)y = (a-1)y(-1) + \dots + e$
 estimated value of $(a - 1)$: -0.448682
 test statistic: $\tau_{nc}(1) = -4.11468$
 asymptotic p-value 4.023e-05
 1st-order autocorrelation coeff. for e: 0.009
 lagged differences: $F(10, 265) = 3.142 [0.0008]$

Augmented Dickey-Fuller regression
 OLS, using observations 2001:01-2023:12 (T = 276)
 Dependent variable: d_logreturn

	coefficient	std. error	t-ratio	p-value	
logreturn_1	-0.448682	0.109044	-4.115	4.02e-05	***
d_logreturn_1	-0.0712485	0.109284	-0.6520	0.5150	
d_logreturn_2	-0.253650	0.106734	-2.376	0.0182	**
d_logreturn_3	-0.0975777	0.104998	-0.9293	0.3536	
d_logreturn_4	-0.127094	0.102087	-1.245	0.2142	
d_logreturn_5	0.0726580	0.0967116	0.7513	0.4531	
d_logreturn_6	-0.106264	0.0936540	-1.135	0.2575	
d_logreturn_7	0.0459000	0.0867146	0.5293	0.5970	
d_logreturn_8	0.0509791	0.0796032	0.6404	0.5225	
d_logreturn_9	0.0518701	0.0671999	0.7719	0.4409	
d_logreturn_10	-0.0812632	0.0588521	-1.381	0.1685	

AIC: -879.303 BIC: -839.479 HQC: -863.322

k = 15: AIC = -860.800
 k = 14: AIC = -862.539
 k = 13: AIC = -863.975
 k = 12: AIC = -865.975
 k = 11: AIC = -867.506
 k = 10: AIC = -869.378
 k = 9: AIC = -868.778
 k = 8: AIC = -865.943

k = 7: AIC = -867.039
 k = 6: AIC = -868.904
 k = 5: AIC = -863.458
 k = 4: AIC = -861.118
 k = 3: AIC = -860.443
 k = 2: AIC = -861.426
 k = 1: AIC = -856.962
 k = 0: AIC = -855.398

test with constant
 including 10 lags of (1-L)logreturn
 model: $(1-L)y = b_0 + (a-1)y(-1) + \dots + e$
 estimated value of $(a - 1)$: -0.511566
 test statistic: $\tau_c(1) = -4.41379$
 asymptotic p-value 0.0002754
 1st-order autocorrelation coeff. for e: 0.009
 lagged differences: $F(10, 264) = 3.025 [0.0012]$

Augmented Dickey-Fuller regression
 OLS, using observations 2001:01-2023:12 (T = 276)
 Dependent variable: d_logreturn

	coefficient	std. error	t-ratio	p-value	
const	0.00484161	0.00308713	1.568	0.1180	
logreturn_1	-0.511566	0.115902	-4.414	0.0003	***
d_logreturn_1	-0.0177359	0.114200	-0.1553	0.8767	
d_logreturn_2	-0.204609	0.110939	-1.844	0.0663	*
d_logreturn_3	-0.0540197	0.108331	-0.4987	0.6184	
d_logreturn_4	-0.0885847	0.104727	-0.8459	0.3984	
d_logreturn_5	0.105036	0.0986312	1.065	0.2879	
d_logreturn_6	-0.0774121	0.0951918	-0.8132	0.4168	
d_logreturn_7	0.0690963	0.0877325	0.7876	0.4316	
d_logreturn_8	0.0695219	0.0802605	0.8662	0.3872	
d_logreturn_9	0.0656048	0.0675854	0.9707	0.3326	
d_logreturn_10	-0.0714147	0.0590257	-1.210	0.2274	

AIC: -879.863 BIC: -836.418 HQC: -862.429

k = 15: AIC = -859.383
 k = 14: AIC = -861.094
 k = 13: AIC = -862.500
 k = 12: AIC = -864.500
 k = 11: AIC = -866.004
 k = 10: AIC = -867.866
 k = 9: AIC = -867.352
 k = 8: AIC = -864.418
 k = 7: AIC = -865.474
 k = 6: AIC = -867.329
 k = 5: AIC = -862.020
 k = 4: AIC = -859.600
 k = 3: AIC = -859.008
 k = 2: AIC = -860.052
 k = 1: AIC = -855.795
 k = 0: AIC = -854.030

with constant and trend
 including 10 lags of (1-L)logreturn
 model: $(1-L)y = b_0 + b_1*t + (a-1)y(-1) + \dots + e$
 estimated value of $(a - 1)$: -0.521955
 test statistic: $\tau_{ct}(1) = -4.4704$
 asymptotic p-value 0.001631
 1st-order autocorrelation coeff. for e: 0.009
 lagged differences: $F(10, 263) = 3.004 [0.0013]$

Augmented Dickey-Fuller regression

OLS, using observations 2001:01-2023:12 (T = 276)

Dependent variable: d_logreturn

	coefficient	std. error	t-ratio	p-value	
const	0.00922210	0.00643160	1.434	0.1528	
logreturn_1	-0.521955	0.116758	-4.470	0.0016	***
d_logreturn_1	-0.00943405	0.114785	-0.08219	0.9346	
d_logreturn_2	-0.197770	0.111371	-1.776	0.0769	*
d_logreturn_3	-0.0482006	0.108671	-0.4435	0.6577	
d_logreturn_4	-0.0840647	0.104967	-0.8009	0.4239	
d_logreturn_5	0.108435	0.0988024	1.097	0.2734	
d_logreturn_6	-0.0747453	0.0953253	-0.7841	0.4337	
d_logreturn_7	0.0712550	0.0878425	0.8112	0.4180	
d_logreturn_8	0.0711549	0.0803484	0.8856	0.3767	
d_logreturn_9	0.0673948	0.0676755	0.9959	0.3202	
d_logreturn_10	-0.0698319	0.0591052	-1.181	0.2385	
time	-2.84643e-05	3.66549e-05	-0.7765	0.4381	

AIC: -878.495 BIC: -831.43 HQC: -859.608

Lisa 3. Augmented Dickey-Fuller test periodil 01.01.2000-31.12.2005

k = 11: AIC = -188.869
 k = 10: AIC = -189.031
 k = 9: AIC = -191.004
 k = 8: AIC = -192.938
 k = 7: AIC = -194.099
 k = 6: AIC = -192.185
 k = 5: AIC = -194.185
 k = 4: AIC = -194.972
 k = 3: AIC = -194.067
 k = 2: AIC = -195.709
 k = 1: AIC = -197.567
 k = 0: AIC = -198.220

Augmented Dickey-Fuller test for logreturn
 testing down from 11 lags, criterion AIC
 sample size 70
 unit-root null hypothesis: a = 1

test without constant
 including 0 lags of (1-L)logreturn
 model: $(1-L)y = (a-1)y(-1) + e$
 estimated value of (a - 1): -0.496656
 test statistic: $\tau_{nc}(1) = -5.03235$
 asymptotic p-value 6.398e-07
 1st-order autocorrelation coeff. for e: 0.030

Dickey-Fuller regression
 OLS, using observations 2000:03-2005:12 (T = 70)
 Dependent variable: d_logreturn

	coefficient	std. error	t-ratio	p-value	
logreturn_1	-0.496656	0.0986928	-5.032	6.40e-07	***

AIC: -229.576 BIC: -227.328 HQC: -228.683

k = 11: AIC = -191.958
 k = 10: AIC = -190.915
 k = 9: AIC = -192.915

k = 8: AIC = -194.896
 k = 7: AIC = -196.449
 k = 6: AIC = -196.211
 k = 5: AIC = -197.697
 k = 4: AIC = -199.572
 k = 3: AIC = -201.088
 k = 2: AIC = -200.677
 k = 1: AIC = -202.383
 k = 0: AIC = -200.799

test with constant
 including one lag of (1-L)logreturn
 model: $(1-L)y = b_0 + (a-1)y(-1) + \dots + e$
 estimated value of (a - 1): -0.66168
 test statistic: $\tau_c(1) = -5.17123$
 asymptotic p-value 8.993e-06
 1st-order autocorrelation coeff. for e: -0.018

Augmented Dickey-Fuller regression
 OLS, using observations 2000:04-2005:12 (T = 69)
 Dependent variable: d_logreturn

	coefficient	std. error	t-ratio	p-value	
const	0.0129857	0.00622479	2.086	0.0408	**
logreturn_1	-0.661680	0.127954	-5.171	8.99e-06	***
d_logreturn_1	0.138297	0.118379	1.168	0.2469	

AIC: -226.207 BIC: -219.504 HQC: -223.548

k = 11: AIC = -196.138
 k = 10: AIC = -191.727
 k = 9: AIC = -193.359
 k = 8: AIC = -195.149
 k = 7: AIC = -197.149
 k = 6: AIC = -198.802
 k = 5: AIC = -198.608
 k = 4: AIC = -200.545
 k = 3: AIC = -202.512
 k = 2: AIC = -200.559
 k = 1: AIC = -201.918
 k = 0: AIC = -199.417

with constant and trend
 including 3 lags of (1-L)logreturn
 model: $(1-L)y = b_0 + b_1*t + (a-1)y(-1) + \dots + e$
 estimated value of (a - 1): -1.01833
 test statistic: $\tau_{ct}(1) = -5.23726$
 asymptotic p-value 6.052e-05
 1st-order autocorrelation coeff. for e: -0.001
 lagged differences: $F(3, 61) = 2.522 [0.0661]$

Augmented Dickey-Fuller regression
 OLS, using observations 2000:06-2005:12 (T = 67)
 Dependent variable: d_logreturn

	coefficient	std. error	t-ratio	p-value	
const	-0.00633931	0.0120109	-0.5278	0.5996	
logreturn_1	-1.01833	0.194441	-5.237	6.05e-05	***
d_logreturn_1	0.377470	0.159955	2.360	0.0215	**
d_logreturn_2	0.344284	0.134642	2.557	0.0131	**
d_logreturn_3	0.149063	0.117777	1.266	0.2105	
time	0.000740919	0.000317254	2.335	0.0228	**

AIC: -226.607 BIC: -213.379 HQC: -221.373

Lisa 4. Augmented Dickey-Fuller test periodil 01.01.2006-31.12.2011

k = 11: AIC = -164.027
k = 10: AIC = -165.979
k = 9: AIC = -166.047
k = 8: AIC = -166.111
k = 7: AIC = -166.893
k = 6: AIC = -168.710
k = 5: AIC = -168.474
k = 4: AIC = -166.784
k = 3: AIC = -168.219
k = 2: AIC = -169.047
k = 1: AIC = -167.200
k = 0: AIC = -167.833

Augmented Dickey-Fuller test for logreturn
testing down from 11 lags, criterion AIC
sample size 72
unit-root null hypothesis: $a = 1$

test without constant
including 2 lags of (1-L)logreturn
model: $(1-L)y = (a-1)y(-1) + \dots + e$
estimated value of (a - 1): -0.51497
test statistic: $\tau_{nc}(1) = -3.47527$
asymptotic p-value 0.0005021
1st-order autocorrelation coeff. for e: -0.029
lagged differences: $F(2, 69) = 2.591 [0.0822]$

Augmented Dickey-Fuller regression
OLS, using observations 2006:01-2011:12 (T = 72)
Dependent variable: d_logreturn

	coefficient	std. error	t-ratio	p-value	
logreturn_1	-0.514970	0.148182	-3.475	0.0005	***
d_logreturn_1	0.0165271	0.131827	0.1254	0.9006	
d_logreturn_2	-0.227910	0.117112	-1.946	0.0557	*

AIC: -169.047 BIC: -162.217 HQC: -166.328

k = 11: AIC = -162.064
k = 10: AIC = -164.020
k = 9: AIC = -164.061
k = 8: AIC = -164.147
k = 7: AIC = -164.944
k = 6: AIC = -166.766
k = 5: AIC = -166.516
k = 4: AIC = -164.840
k = 3: AIC = -166.264
k = 2: AIC = -167.088
k = 1: AIC = -165.254
k = 0: AIC = -165.875

test with constant
including 2 lags of (1-L)logreturn
model: $(1-L)y = b_0 + (a-1)y(-1) + \dots + e$
estimated value of (a - 1): -0.516197
test statistic: $\tau_c(1) = -3.45614$
asymptotic p-value 0.009216
1st-order autocorrelation coeff. for e: -0.029
lagged differences: $F(2, 68) = 2.553 [0.0853]$

Augmented Dickey-Fuller regression
OLS, using observations 2006:01-2011:12 (T = 72)

Dependent variable: d_logreturn

	coefficient	std. error	t-ratio	p-value	
const	-0.00170428	0.00870647	-0.1957	0.8454	
logreturn_1	-0.516197	0.149357	-3.456	0.0092	***
d_logreturn_1	0.0172634	0.132809	0.1300	0.8970	
d_logreturn_2	-0.227476	0.117958	-1.928	0.0580	*

AIC: -167.088 BIC: -157.981 HQC: -163.462

k = 11: AIC = -160.079
k = 10: AIC = -162.037
k = 9: AIC = -162.076
k = 8: AIC = -162.155
k = 7: AIC = -162.947
k = 6: AIC = -164.767
k = 5: AIC = -164.527
k = 4: AIC = -162.843
k = 3: AIC = -164.271
k = 2: AIC = -165.098
k = 1: AIC = -163.266
k = 0: AIC = -163.882

with constant and trend
including 2 lags of (1-L)logreturn
model: $(1-L)y = b_0 + b_1*t + (a-1)*y(-1) + \dots + e$
estimated value of $(a - 1)$: -0.516785
test statistic: $\tau_{ct}(1) = -3.43209$
asymptotic p-value 0.04716
1st-order autocorrelation coeff. for e: -0.029
lagged differences: $F(2, 67) = 2.517 [0.0883]$

Augmented Dickey-Fuller regression
OLS, using observations 2006:01-2011:12 (T = 72)
Dependent variable: d_logreturn

	coefficient	std. error	t-ratio	p-value	
const	-0.00621715	0.0466382	-0.1333	0.8944	
logreturn_1	-0.516785	0.150574	-3.432	0.0472	**
d_logreturn_1	0.0175665	0.133822	0.1313	0.8960	
d_logreturn_2	-0.227406	0.118828	-1.914	0.0599	*
time	4.15794e-05	0.000422036	0.09852	0.9218	

AIC: -165.098 BIC: -153.715 HQC: -160.566

Lisa 5. Augmented Dickey-Fuller test periodil 01.01.2012-31.12.2017

k = 11: AIC = -309.586
k = 10: AIC = -311.543
k = 9: AIC = -311.810
k = 8: AIC = -313.137
k = 7: AIC = -314.296
k = 6: AIC = -315.233
k = 5: AIC = -314.608
k = 4: AIC = -315.934
k = 3: AIC = -317.905
k = 2: AIC = -319.902
k = 1: AIC = -319.786

k = 0: AIC = -321.778

Augmented Dickey-Fuller test for logreturn
testing down from 11 lags, criterion AIC
sample size 72
unit-root null hypothesis: a = 1

test without constant
including 0 lags of (1-L)logreturn
model: $(1-L)y = (a-1)y(-1) + e$
estimated value of (a - 1): -0.689487
test statistic: $\tau_{nc}(1) = -6.18493$
asymptotic p-value 1.71e-09
1st-order autocorrelation coeff. for e: 0.012

Dickey-Fuller regression
OLS, using observations 2012:01-2017:12 (T = 72)
Dependent variable: d_logreturn

	coefficient	std. error	t-ratio	p-value
logreturn_1	-0.689487	0.111479	-6.185	1.71e-09 ***

AIC: -321.778 BIC: -319.501 HQC: -320.872

k = 11: AIC = -316.818
k = 10: AIC = -318.543
k = 9: AIC = -317.771
k = 8: AIC = -318.994
k = 7: AIC = -320.525
k = 6: AIC = -320.900
k = 5: AIC = -321.099
k = 4: AIC = -321.590
k = 3: AIC = -323.579
k = 2: AIC = -325.185
k = 1: AIC = -326.967
k = 0: AIC = -328.175

test with constant
including 0 lags of (1-L)logreturn
model: $(1-L)y = b_0 + (a-1)y(-1) + e$
estimated value of (a - 1): -0.824211
test statistic: $\tau_c(1) = -7.14315$
asymptotic p-value 1.351e-10
1st-order autocorrelation coeff. for e: 0.025

Dickey-Fuller regression
OLS, using observations 2012:01-2017:12 (T = 72)
Dependent variable: d_logreturn

	coefficient	std. error	t-ratio	p-value
const	0.00923264	0.00313760	2.943	0.0044 ***
logreturn_1	-0.824211	0.115385	-7.143	1.35e-010 ***

AIC: -328.175 BIC: -323.622 HQC: -326.362

k = 11: AIC = -314.924
k = 10: AIC = -316.676
k = 9: AIC = -316.130
k = 8: AIC = -317.545
k = 7: AIC = -318.918
k = 6: AIC = -319.505
k = 5: AIC = -319.483
k = 4: AIC = -320.116
k = 3: AIC = -322.116

k = 2: AIC = -323.817
k = 1: AIC = -325.591
k = 0: AIC = -326.777

with constant and trend
including 0 lags of (1-L)logreturn
model: $(1-L)y = b_0 + b_1*t + (a-1)*y(-1) + e$
estimated value of (a - 1): -0.826601
test statistic: tau_ct(1) = -7.13968
asymptotic p-value 9.71e-10
1st-order autocorrelation coeff. for e: 0.021

Dickey-Fuller regression
OLS, using observations 2012:01-2017:12 (T = 72)
Dependent variable: d_logreturn

	coefficient	std. error	t-ratio	p-value
const	0.0283622	0.0253283	1.120	0.2667
logreturn_1	-0.826601	0.115776	-7.140	9.71e-010 ***
time	-0.000105838	0.000139048	-0.7612	0.4492

AIC: -326.777 BIC: -319.947 HQC: -324.058

Lisa 6. Augmented Dickey-Fuller test periodil 01.01.2018-31.12.2023

k = 11: AIC = -250.371
k = 10: AIC = -251.445
k = 9: AIC = -253.434
k = 8: AIC = -252.057
k = 7: AIC = -253.009
k = 6: AIC = -254.278
k = 5: AIC = -251.757
k = 4: AIC = -253.757
k = 3: AIC = -253.300
k = 2: AIC = -255.045
k = 1: AIC = -256.754
k = 0: AIC = -257.310

Augmented Dickey-Fuller test for logreturn
testing down from 11 lags, criterion AIC
sample size 72
unit-root null hypothesis: a = 1

test without constant
including 0 lags of (1-L)logreturn
model: $(1-L)y = (a-1)*y(-1) + e$
estimated value of (a - 1): -0.819907
test statistic: tau_nc(1) = -7.01397
asymptotic p-value 1.631e-11
1st-order autocorrelation coeff. for e: 0.031

Dickey-Fuller regression
OLS, using observations 2018:01-2023:12 (T = 72)
Dependent variable: d_logreturn

	coefficient	std. error	t-ratio	p-value
logreturn_1	-0.819907	0.116896	-7.014	1.63e-011 ***

AIC: -257.31 BIC: -255.033 HQC: -256.403

k = 11: AIC = -250.002
k = 10: AIC = -250.665
k = 9: AIC = -252.661
k = 8: AIC = -250.733
k = 7: AIC = -251.460
k = 6: AIC = -252.583
k = 5: AIC = -250.439
k = 4: AIC = -252.428
k = 3: AIC = -252.321
k = 2: AIC = -254.175
k = 1: AIC = -256.010
k = 0: AIC = -256.258

test with constant
including 0 lags of (1-L)logreturn
model: $(1-L)y = b_0 + (a-1)y(-1) + e$
estimated value of (a - 1): -0.833889
test statistic: $\tau_c(1) = -7.07568$
asymptotic p-value 2.064e-10
1st-order autocorrelation coeff. for e: 0.032

Dickey-Fuller regression
OLS, using observations 2018:01-2023:12 (T = 72)
Dependent variable: d_logreturn

	coefficient	std. error	t-ratio	p-value
const	0.00460671	0.00478203	0.9633	0.3387
logreturn_1	-0.833889	0.117853	-7.076	2.06e-010 ***

AIC: -256.258 BIC: -251.704 HQC: -254.445

k = 11: AIC = -248.003
k = 10: AIC = -248.667
k = 9: AIC = -250.662
k = 8: AIC = -248.740
k = 7: AIC = -249.476
k = 6: AIC = -250.606
k = 5: AIC = -248.449
k = 4: AIC = -250.438
k = 3: AIC = -250.324
k = 2: AIC = -252.176
k = 1: AIC = -254.011
k = 0: AIC = -254.258

with constant and trend
including 0 lags of (1-L)logreturn
model: $(1-L)y = b_0 + b_1*t + (a-1)y(-1) + e$
estimated value of (a - 1): -0.833893
test statistic: $\tau_{ct}(1) = -7.025$
asymptotic p-value 2.105e-09
1st-order autocorrelation coeff. for e: 0.032

Dickey-Fuller regression
OLS, using observations 2018:01-2023:12 (T = 72)
Dependent variable: d_logreturn

	coefficient	std. error	t-ratio	p-value
const	0.00567166	0.0582744	0.09733	0.9227
logreturn_1	-0.833893	0.118704	-7.025	2.10e-09 ***
time	-4.21753e-06	0.000229995	-0.01834	0.9854

AIC: -254.258 BIC: -247.428 HQC: -251.539

Lisa 7. OLS mudel periodil 01.02.2000-31.12.2023

OLS: OLS, using observations 2000:02-2023:12 (T = 287)

Dependent variable: logreturn

	<i>Coefficient</i>	<i>Std. Error</i>	<i>t-ratio</i>	<i>p-value</i>	
dm1	0.0450668	0.0111867	4.029	<0.0001	***
dm2	0.0245855	0.0109512	2.245	0.0256	**
dm3	-0.00538796	0.0109512	-0.4920	0.6231	
dm4	0.0197182	0.0109512	1.801	0.0729	*
dm5	-0.00095703	0.0109512	-0.08739	0.9304	
dm6	-0.00469437	0.0109512	-0.4287	0.6685	
dm7	0.00426670	0.0109512	0.3896	0.6971	
dm8	0.0110460	0.0109512	1.009	0.3140	
dm9	0.00603573	0.0109512	0.5511	0.5820	
dm10	-0.00992144	0.0109512	-0.9060	0.3657	
dm11	0.00738198	0.0109512	0.6741	0.5008	
dm12	0.0119152	0.0109512	1.088	0.2775	
Mean dependent var	0.008963	S.D. dependent var		0.054567	
Sum squared resid	0.791529	S.E. of regression		0.053650	
R-squared	0.070529	Adjusted R-squared		0.033351	
F(11, 275)	1.897030	P-value(F)		0.039667	
Log-likelihood	438.4491	Akaike criterion		-852.8982	
Schwarz criterion	-808.9844	Hannan-Quinn		-835.2982	
rho	0.405021	Durbin-Watson		1.176025	

Test for ARCH of order 12 -

Null hypothesis: no ARCH effect is present

Test statistic: LM = 81.5972

with p-value = $P(\text{Chi-square}(12) > 81.5972) = 2.04464e-12$

Lisa 8. OLS mudel periodil 01.02.2000-31.12.2005

OLS 2: OLS, using observations 2000:02-2005:12 (T = 71)

Dependent variable: logreturn

	<i>Coefficient</i>	<i>Std. Error</i>	<i>t-ratio</i>	<i>p-value</i>	
const	0.0467182	0.0235454	1.984	0.0519	*
dm2	0.00462487	0.0318807	0.1451	0.8852	
dm3	-0.0133622	0.0318807	-0.4191	0.6766	
dm4	-0.0171253	0.0318807	-0.5372	0.5932	
dm5	-0.0319756	0.0318807	-1.003	0.3200	
dm6	-0.0543598	0.0318807	-1.705	0.0934	*

dm7	-0.0464788	0.0318807	-1.458	0.1502
dm8	-0.0502528	0.0318807	-1.576	0.1203
dm9	-0.0329310	0.0318807	-1.033	0.3058
dm10	-0.0244548	0.0318807	-0.7671	0.4461
dm11	-0.0149921	0.0318807	-0.4703	0.6399
dm12	-0.00769946	0.0318807	-0.2415	0.8100
Mean dependent var	0.022295	S.D. dependent var	0.051814	
Sum squared resid	0.163544	S.E. of regression	0.052649	
R-squared	0.129761	Adjusted R-squared	-0.032487	
F(11, 59)	0.799770	P-value(F)	0.639630	
Log-likelihood	114.8593	Akaike criterion	-205.7186	
Schwarz criterion	-178.5665	Hannan-Quinn	-194.9211	
rho	0.379693	Durbin-Watson	1.199406	

Lisa 9. OLS model periodil 01.01.2006-31.12.2011

OLS 3: OLS, using observations 2006:01-2011:12 (T = 72)
Dependent variable: logreturn

	<i>Coefficient</i>	<i>Std. Error</i>	<i>t-ratio</i>	<i>p-value</i>	
dm1	0.0723408	0.0333415	2.170	0.0340	**
dm2	0.0186239	0.0333415	0.5586	0.5785	
dm3	-0.0465615	0.0333415	-1.397	0.1677	
dm4	0.0231649	0.0333415	0.6948	0.4899	
dm5	-0.0180853	0.0333415	-0.5424	0.5895	
dm6	-0.0193159	0.0333415	-0.5793	0.5645	
dm7	-0.0105403	0.0333415	-0.3161	0.7530	
dm8	0.0166754	0.0333415	0.5001	0.6188	
dm9	0.0267175	0.0333415	0.8013	0.4261	
dm10	-0.0401921	0.0333415	-1.205	0.2328	
dm11	-0.0340452	0.0333415	-1.021	0.3113	
dm12	-0.0226912	0.0333415	-0.6806	0.4988	
Mean dependent var	-0.002826	S.D. dependent var	0.082213		
Sum squared resid	0.400195	S.E. of regression	0.081670		
R-squared	0.166057	Adjusted R-squared	0.013168		
F(11, 60)	1.086127	P-value(F)	0.387664		
Log-likelihood	84.76529	Akaike criterion	-145.5306		
Schwarz criterion	-118.2106	Hannan-Quinn	-134.6544		
rho	0.504873	Durbin-Watson	0.974338		

Lisa 10. OLS model periodil 01.01.2012-31.12.2017

OLS 4: OLS, using observations 2012:01-2017:12 (T = 72)
Dependent variable: logreturn

	<i>Coefficient</i>	<i>Std. Error</i>	<i>t-ratio</i>	<i>p-value</i>	
const	0.0259976	0.00950668	2.735	0.0082	***
dm2	-0.00395692	0.0134445	-0.2943	0.7695	
dm3	-0.00065874	0.0134445	-0.04900	0.9611	
dm4	-0.0107806	0.0134445	-0.8019	0.4258	
dm5	-0.0320492	0.0134445	-2.384	0.0203	**
dm6	-0.0237116	0.0134445	-1.764	0.0829	*
dm7	-0.00478574	0.0134445	-0.3560	0.7231	
dm8	-0.00530966	0.0134445	-0.3949	0.6943	
dm9	-0.0347899	0.0134445	-2.588	0.0121	**
dm10	-0.0304924	0.0134445	-2.268	0.0269	**
dm11	-0.0140209	0.0134445	-1.043	0.3012	
dm12	-0.0178628	0.0134445	-1.329	0.1890	
Mean dependent var	0.011129	S.D. dependent var		0.024664	
Sum squared resid	0.032536	S.E. of regression		0.023287	
R-squared	0.246696	Adjusted R-squared		0.108591	
F(11, 60)	1.786286	P-value(F)		0.076604	
Log-likelihood	175.1114	Akaike criterion		-326.2229	
Schwarz criterion	-298.9029	Hannan-Quinn		-315.3467	
rho	0.135466	Durbin-Watson		1.712008	

Lisa 11. OLS mudel perioddil 01.01.2018-31.12.2023

OLS 5: OLS, using observations 2018:01-2023:12 (T = 72)
Dependent variable: logreturn

	<i>Coefficient</i>	<i>Std. Error</i>	<i>t-ratio</i>	<i>p-value</i>	
dm1	0.0354859	0.0162056	2.190	0.0324	**
dm2	0.00633419	0.0162056	0.3909	0.6973	
dm3	-0.0336851	0.0162056	-2.079	0.0419	**
dm4	0.0108978	0.0162056	0.6725	0.5039	
dm5	0.00556613	0.0162056	0.3435	0.7324	
dm6	0.00589405	0.0162056	0.3637	0.7174	
dm7	0.00615589	0.0162056	0.3799	0.7054	
dm8	0.0103553	0.0162056	0.6390	0.5253	
dm9	-0.00756945	0.0162056	-0.4671	0.6421	
dm10	-0.0172622	0.0162056	-1.065	0.2911	
dm11	0.0198704	0.0162056	1.226	0.2249	
dm12	0.0231984	0.0162056	1.432	0.1575	
Mean dependent var	0.005437	S.D. dependent var		0.040547	
Sum squared resid	0.094544	S.E. of regression		0.039695	
R-squared	0.190046	Adjusted R-squared		0.041554	

F(11, 60)	1.279841	P-value(F)	0.258152
Log-likelihood	136.7094	Akaike criterion	-249.4188
Schwarz criterion	-222.0988	Hannan-Quinn	-238.5426
rho	0.189387	Durbin-Watson	1.619587

Lisa 12. ARCH test

Test for ARCH of order 12

	coefficient	std. error	t-ratio	p-value	
alpha(0)	0.000907141	0.000482267	1.881	0.0611	*
alpha(1)	0.403975	0.0604615	6.682	1.41e-010	***
alpha(2)	-0.0960792	0.0639705	-1.502	0.1343	
alpha(3)	0.0894109	0.0637338	1.403	0.1618	
alpha(4)	0.0564653	0.0636697	0.8868	0.3760	
alpha(5)	0.0127702	0.0637556	0.2003	0.8414	
alpha(6)	-0.0144025	0.0637364	-0.2260	0.8214	
alpha(7)	-0.0259051	0.0636573	-0.4069	0.6844	
alpha(8)	-0.0174792	0.0635128	-0.2752	0.7834	
alpha(9)	0.101253	0.0633160	1.599	0.1110	
alpha(10)	0.132988	0.0633157	2.100	0.0367	**
alpha(11)	0.221261	0.0636129	3.478	0.0006	***
alpha(12)	-0.201394	0.0600861	-3.352	0.0009	***

Null hypothesis: no ARCH effect is present

Test statistic: LM = 81.5972

with p-value = P(Chi-square(12) > 81.5972) = 2.04464e-12

Lisa 13. GARCH model

GARCH: GARCH, using observations 2000:02-2023:12 (T = 287)

Dependent variable: logreturn

Standard errors based on Hessian

	Coefficient	Std. Error	z	p-value	
dm1	0.0363154	0.00939806	3.864	0.0001	***
dm2	0.0192740	0.00991000	1.945	0.0518	*
dm3	-0.00130195	0.00810259	-0.1607	0.8723	
dm4	0.0157411	0.00853617	1.844	0.0652	*
dm5	-0.00255447	0.00843187	-0.3030	0.7619	
dm6	-0.00171479	0.00862800	-0.1987	0.8425	
dm7	0.0129761	0.00843955	1.538	0.1242	
dm8	0.0112036	0.00830293	1.349	0.1772	
dm9	-0.00143615	0.00867908	-0.1655	0.8686	
dm10	-0.00809717	0.00859583	-0.9420	0.3462	
dm11	0.0134483	0.00867712	1.550	0.1212	
dm12	0.0166793	0.00885674	1.883	0.0597	*
alpha(0)	0.000132283	5.14981e-05	2.569	0.0102	**
alpha(1)	0.104501	0.0358947	2.911	0.0036	***

beta(1)	0.839115	0.0474323	17.69	<0.0001	***
Mean dependent var	0.008963	S.D. dependent var		0.054567	
Log-likelihood	472.5766	Akaike criterion		-913.1532	
Schwarz criterion	-854.6015	Hannan-Quinn		-889.6866	

Unconditional error variance = 0.00234609
with p-value = $P(\text{Chi-square}(12) > 5.52721) = 0.938018$

Lisa 14. Lihtlitsents

Lihtlitsents lõputöö reprodutseerimiseks ja lõputöö üldsusele kättesaadavaks tegemiseks¹

Mina Dmitri Tšumakov

1. Annan Tallinna Tehnikaülikoolile tasuta loa (lihtlitsentsi) enda loodud teose
OMX Tallinn GI indeksi kuiste kalendriefektide analüüs,

mille juhendaja on Tõnn Talpsepp,

1.1 reprodutseerimiseks lõputöö säilitamise ja elektroonse avaldamise eesmärgil, sh Tallinna
Tehnikaülikooli raamatukogu digikogusse lisamise eesmärgil kuni autoriõiguse kehtivuse
tähtaja lõppemiseni;

1.2 üldsusele kättesaadavaks tegemiseks Tallinna Tehnikaülikooli veebikeskkonna kaudu,
sealhulgas Tallinna Tehnikaülikooli raamatukogu digikogu kaudu kuni autoriõiguse
kehtivuse tähtaja lõppemiseni.

2. Olen teadlik, et käesoleva lihtlitsentsi punktis 1 nimetatud õigused jäävad alles ka autorile.

3. Kinnitan, et lihtlitsentsi andmisega ei rikuta teiste isikute intellektuaalomandi ega
isikuandmete kaitse seadusest ning muudest õigusaktidest tulenevaid õigusi.

09.05.2024

¹ Lihtlitsents ei kehti juurdepääsupiirangu kehtivuse ajal vastavalt üliõpilase taotlusele lõputööle juurdepääsupiirangu kehtestamiseks, mis on allkirjastatud teaduskonna dekaani poolt, välja arvatud ülikooli õigus lõputööd reprodutseerida üksnes säilitamise eesmärgil. Kui lõputöö on loonud kaks või enam isikut oma ühise loomingulise tegevusega ning lõputöö kaas- või ühisautor(id) ei ole andnud lõputööd kaitsvale üliõpilasele kindlaksmääratud tähtajaks nõusolekut lõputöö reprodutseerimiseks ja avalikustamiseks vastavalt lihtlitsentsi punktidele 1.1. jq 1.2, siis lihtlitsents nimetatud tähtaja jooksul ei kehti.