

TALLINNA TEHNIKAÜLIKOOL

Majandusteaduskond

Majandusarvestuse instituut

Juhtimisarvestuse õppetool

Natalja Nešumajeva

**MÜÜGITULU PROGNOOSIMISMUDELITE
KOOSTAMINE KVANTITATIIVSETE MEETODITE ABIL
(EESTI ENERGIA AS NÄITEL)**

Magistritöö

Juhendaja: lektor Paavo Siimann

Kaasjuhendaja: dotsent Ako Sauga

Tallinn 2016

Olen koostanud töö iseseisvalt.

Töö koostamisel kasutatud kõikidele teiste autorite töödele, olulistele seisukohtadele ja andmetele on viidatud.

Natalja Nešumajeva

(allkiri, kuupäev)

Üliõpilase kood: 095476TARMM

Üliõpilase e-posti aadress: neshumajeva@gmail.com

Juhendaja lektor Paavo Siimann:

Töö vastab magistritööle esitatud nõuetele

.....

(allkiri, kuupäev)

Juhendaja dotsent Ako Sauga:

Töö vastab magistritööle esitatud nõuetele

.....

(allkiri, kuupäev)

Kaitsmiskomisjoni esimees:

Lubatud kaitsmisele

.....

(ametikoht, nimi, allkiri, kuupäev)

SISUKORD

ABSTRAKT	5
SISSEJUHATUS	6
1. UURITAV ETTEVÕTE.....	9
1.1. Uuritava ettevõtte lühiülevaade	9
1.2. „Prognoos“ ja „eelarve“ mõistete erinevus.....	11
1.3. Eesti Energia viimaste aastate tähtsamad sündmused ja väliskeskkonda mõjutavad tegurid	14
2. PROGNOOSIMISMEETODID	18
2.1. Aegrea analüüs.....	18
2.2. Prognooside hindamine.....	21
2.3. Mitmene regressioon.....	23
2.3.1. Mitmese regressiooni analüüsi etapid	23
2.3.2. Mudeli koostamine.....	23
2.4. Aegridade kompleksanalüüs	26
2.5. Trendi ja sesoonsusega eksponentsiaalne silumine, Wintersi meetod.....	27
2.6. Autoregressiivne mudel (Box-Jenkins)	29
2.6.1. Sissejuhatus ARIMA-mudelitesse	29
2.6.2. Mudeli identifitseerimine.....	30
2.7. Naiivne meetod	31
3 . MÜÜGITULEMUSTE PROGNOOSIMINE.....	33
3.1.1. Mudeli hindamine	33
3.1.1.1. Mitmese regressioonmudeli eeldused.....	36
3.1.1.2. Mudeli võimalikud probleemid ja nende lahendused.....	40
3.1.1.3. Mudeli lõpphindamine/kinnitamine	41
3.1.2. Mitmene regressioon ja prognoosimine.....	41

3.2. Aegrea kompleksanalüüs	45
3.2.1. Aegrea kompleksanalüüsi mudeli koostamine.....	45
3.2.2. Aegrea kompleksanalüüsil põhinev prognoos	47
Aegrea kompleksanalüüsil põhineva prognoosi	48
3.3. Prognoosimine trendi ja sesoonsusega eksponentsiaalse silumismeetodiga, Wintersi meetod.....	49
3.4. ARIMA-mudel.....	51
3.4.1. ARIMA-mudeli lõplik kinnitamine	51
3.4.3. Mudeli adekvaatsuse hindamine. Mudeli kontroll.....	52
3.4.4. Prognoosimine ARIMA-mudeliga.....	54
3.5. Prognoosimine naiivse meetodiga	55
3.6. Prognoosimismudelite võrdlus	56
KOKKUVÕTE	60
VIIDATUD ALLIKAD.....	63
SUMMARY	66
LISAD	69
Lisa 1. Kasutatud lühendid, sõnastik ja mõisted.....	69
Lisa 2. Korrelatsioonimaatriks.....	71
Lisa 3. Elektrituru avatuse mõju hinnang	73
Lisa 4. Eesti Energia müügitulu andmete autokorrelatsiooni funktsioon	74
Lisa 5. Mitmese regressiooni mudeli parameetrite hinnangud	75
Lisa 6. Mudeli kirjeldusvõime analüüs.....	76
Lisa 7. Jääkliikmete statistilised parameetrid	77
Lisa 8. Jääkliikmete normaaljaotuse test	78
Lisa 9. Doornik-Hanseni test ja jääkide histogramm koos normaaljaotuskõveraga.....	79
Lisa 10. White'i heteroskedastiivsuse test.....	80
Lisa 11. Korrelatsioonianalüüs	81
Lisa 12. Dispersiooni inflatsioonitegur.....	82
Lisa 13. RESET-test	83
Lisa 14. Autokorrelatsiooni testimine Wintersi mudeli jääkide korral.....	84

Lisa 15. χ^2 kriitiline väärtus (Wintersi mudel)	85
Lisa 16. Müügitulu autokorrelatsiooni testimine pärast 1. järgu sesoonse ja mitteseseoonse diferentsi võtmist	86
Lisa 17. Logaritmitud müügitulu empiiriline analüüs pärast 1. järgu sesoonse ja mitteseseoonse diferentsi võtmist	87
Lisa 18. Dickey-Fulleri test	88
Lisa 19. Jääkliikmete autokorrelatsiooni graafiline kuju	89
Lisa 20. Normaaljaotuse testi tulemus	90
Lisa 21. Eesti Energia ASi müügitulu andmed aastatel 2002–2015	91
Lisa 22. Prognoositud müügitulu andmed ARIMA mudeli rakendamisel	92
Lisa 23. Prognoositud väärtused naiivse meetodiga ja võrdlus tegelike väärtustega	93
Lisa 24. Kvartaalsete õhutemperatuuride ja sademete keskmised väärtused	94
Lisa 25. KRT korrigeeritud, Elspot, Tööhõivemäär ja TTHI prognoositud argumentsuurused	95
Lisa 26. Prognoositud müügitulu (mitmene regressioon)	96
Lisa 27. Wintersi eksponentsilumismeetodi tulemused	97
Lisa 28. Müügitulu prognoos kompleksanalüüsi meetodiga	98
Lisa 29. Breusch-Godfrey test	99
Lisa 30. Ettevõtte tegelik ja modelleeritud müügitulu (ARIMA) aastatel 2002–2012	100

ABSTRAKT

Prognoosides tulevikku müüki ja muid olulisi majanduslikke või ärimuutujaid, ei ole enam õigustatud tuginedes üksnes intuitsioonile või kellegi „olukorra tundmisele“. Kvantitatiivsete meetodite abil on võimalik saada täpsemat prognoosi.

Töö põhieesmärk on erinevate kvantitatiivsete meetodite välja selgitamine Eesti Energia AS müügitulu prognoosimiseks, põhinedes eelnevate perioodide aegrea andmetel ning toetudes läbiviidud analüüsitulemustele; paremate prognoosimismeetodite valimine; paremaks osutunud prognoosimismeetodite eelistest ning võimalikest puudustest kokkuvõtte tegemine.

Autor on prognoosinud müügitulu, kasutades selleks mitmese regressiooni, aegridade kompleksanalüüsi, trendi ja sesoonsusega eksponentsiaalse silumise (Wintersi meetod), ARIMA ning naiivse meetodite abil leitud mudeleid.

Vastavalt prognooside ruutkeskmise vea väärtustele on Wintersi eksponentsiaalne silumise ning mitmese regressiooni prognoositud väärtused olnud kõige lähedasemad tegelikele väärtustele, prognoosi kõrvalekalde nihe on nende mudelite puhul kõige väiksem. Võrdselt mitmese regressiooniga ning Wintersi eksponentsiaalse silumismeetodiga on häid tulemusi näidanud ka ARIMA-mudel. ARIMA-mudeli vea tulemust on mõjutanud aastatel 2014–2015 toimunud müügitulu langus, mis on põhjustatud nii madalatest turuhindadest kui ka jaemüügi mahtude vähenemisest tingitud elektrituru avanemisest.

Võtmesõnad: Eesti Energia AS, kvantitatiivsed meetodid, prognoos, müügitulu, mitmese regressioon, aegrea kompleksanalüüs, eksponentsiaalne silumine, ARIMA-mudelid (Box-Jenkinsi meetod), naiivne meetod.

SISSEJUHATUS

Teema aktuaalsus ja valiku põhjus. Ettevõtte finantsseisundi ennustamiseks ning eesmärgipäraseks suunamiseks on vaja prognoosida majandusnäitajaid ja nendevahelisi seoseid. Organisatsioonid, kes ei reageeri kiiresti muutuvatele tingimustele ega kavanda tulevikku, on määratud hääbumisele.

Majandusnäitajate prognoosimist võib käsitleda kui majandusnähtust peegeldavate võimalike mõõtmismudelite kujunemise ja nende käitumise teaduslikku ettenägemist lähemas või kaugemas tulevikus. Piisavalt tõenäoliste prognooside olemasolu on olulise tähtsusega kompetentsete majandusotsuste tegemisel ning ettevõtte arengusuundade paikapanemisel.

Ettevõtted tegutsevad pidevalt ebakindluse ja riski olukorras. Majandusnäitajaid prognoosides saab otsuste vastuvõtmisel riske maandada. Äritegevuses on prognoosimine aluseks juhtkonna strateegia, võimsuse, tootmise, varude, tööjõu, müügi, turuosa, eelarve, uurimise, arendamise ja eelarvestamise planeerimisel.

Töö eesmärk ja püstitatud ülesanded eesmärgi lahendamiseks. Töö põhieesmärk on erinevate kvantitatiivsete meetodite välja selgitamine ettevõtte müügitulu prognoosimiseks, põhinedes eelnevate perioodide aegrea andmetel ning toetudes läbiviidud analüüsitulemustele; paremate prognoosimismeetodite valimine; paremaks osutunud prognoosimismeetodite eelistest ning võimalikest puudustest kokkuvõtte tegemine. Magistritöö oodatav tulemus seisneb sellise müügitulu ennustamiseks sobiliku prognoosimismeetodi leidmises, mida oleks ajalist ja veasuhet arvestades otstarbekas uuritud ettevõtte puhul edaspidi kasutada.

Võimalikult täpse prognoosi koostamiseks on vaja välja selgitada ettevõtte majandusnäitajatele mõju osutavad tegurid ning analüüsida ettevõtte tausta ja tegevuskeskkonda.

Parema prognoosimismeetodi valimiseks võrdleb autor meetodeid omavahel, võrreldes ettevõtte prognoositud tulemusi tegelike näitajatega. Suuremate kõrvalekallete puhul analüüsib autor põhjuseid ja teeb ettepanekud prognoosimismudelite täpsuse parandamiseks.

Uurimisobjekt ja ajaperiood. Uuritavaks ettevõtteks on AS Eesti Energia (*edaspidi* Eesti Energia). Uurimisobjekti valimise põhikriteeriumiteks oli vajalike andmete kättesaadavus ja ulatus. Valitud ettevõtte müügitulu andmetes esinevad sesoonsus ja mittestatsionaarsus, mis omakorda kitsendas ja sätestas kindlad kriteeriumid prognoosimismudelite valikuks.

Prognoosimisandmete perioodiks on valitud kvartaalsed andmed alates 2002. aasta algusest kuni 2015. aasta lõpuni. Prognoosi täpsuse hindamisel on kasutatud kvartaalseid andmeid 2012. aasta kolmandast kvartalist kuni 2015. aastani. Prognoosi täpsuse hindamiseks kasutati mudelite ruutkeskmiste vigade suurusi. Prognoosimiseks kasutatavaid mudeleid testiti valimist väljaspool (*out of sample*), st toimus ekstrapoleeritud andmete hindamine.

Magistritöö osad. Magistritöö koosneb kolmest peatükist. Esimeses peatükis teeb autor ettevõtte analüüsi ning põhjaliku uurimise järgel valib ettevõtte väliskeskkonna müügitulemusi enam mõjutanud tegurid. Samuti toob autor esile vahe prognoosi ja eelarve vahel ning selgitab müügitulu prognoosimise olulisuse tähtsust. Teises peatükis analüüsib autor Eesti Energia müügitulu aegrea andmeid, kasutades autokorrelatsioonianalüüsi. Autokorrelatsioonianalüüsi abil piiritleb autor prognoosi koostamiseks sobilikud mudelid, koostab mudelid ning analüüsib ka prognoosimismeetodeid eduka müügitulemusprognoosi koostamiseks. Kolmandas peatükis prognoosib autor müügitulemusi, kasutades selleks mitmese regressiooni, aegridade kompleksanalüüsi, trendi ja sesoonsusega eksponentsiaalse silumise (Wintersi meetod), ARIMA ning naiivse meetodite abil leitud mudeleid, ning tulemuste võrdlemise järel valib neist kõige täpsema. Autor analüüsib ka mudelite täpsuse põhjust ning toob mudelite täpsuse parandamiseks välja oma seisukohad.

Põhinedes eelnevalt prognoositud müügitulemusel ning majandusnäitajate seoste analüüsil, on võimalik koostada ettevõtte raamatupidamise põhjaruannete põhjal ka teiste näitajate prognoosi.

Andmeallikad kasutatud eesmärgi täitmiseks. Magistritöö kirjutamisel on kasutatud Eesti Energia majandusaastaruandeid, keskkonna- ja kvartaalsete majandustulemuste vahearuarandeid ning magistritöö teemaga seotud erialakirjandust (ökonomeetria, energeetika). Arvandmete allikateks on olnud Eesti ja Norra statistika andmebaasid, Eesti Energia majandusaasta ja kvartaalsete majandustulemuste vahearuanded. Andmete töötlemiseks on kasutatud ökonomeetriapaketti Gretl.

Autor soovib magistritöö juhendamise eest tänada Paavo Siimanni ja Ako Saugat.

1. UURITAV ETTEVÕTE

1.1. Uuritava ettevõtte lühiülevaade

Magistritöö uuritavaks ettevõtteks on Eesti Energia AS. Uurimisobjekti valimise põhikriteeriumid oli prognoosi koostamiseks, ettevõtte tegevuse analüüsiks ja ülevaate saamiseks vajalike andmete kättesaadavus ja ulatus.

Uuritava ettevõtte tausta ja tegevuse keskkonna analüüsimine on tingitud vajadusest selgitada välja ettevõtte majandusnäitajatele mõju avaldavad tegurid, et koostada võimalikult täpsed magistritöös käsitletud prognoosimismudelid.

Eesti Energia. Eesti Energia on rahvusvaheline energiaettevõtte, mis tegutseb Balti- ja Põhjamaade energiaturul. Eesti Energia asutati 1939. aastal. Sellest ajast on ettevõtte oluliselt laiendanud oma tegutsemisulatust – Eesti kohalikust elektrifirmast on saanud rahvusvaheline ja mitmekülgse tootevalikuga energiaettevõtte (Eesti Energia AS 2013. aasta majandusaasta aruanne), (Ülevaade Eesti Energiast).

Eesti Energia aktsiate omanik on 100% Eesti Vabariik. Ettevõtte pakub energialahendusi alates elektri, soojuse ja kütuste tootmisest kuni müügi, klienditeeninduse ja energiaga seotud lisateenusteni. Elektrimüüjana müüb ettevõtte elektrit Baltimaade jaeklientidele ja elektriturule. Eesti Energia kontserni kuuluv Elektrilevi pakub Eesti klientidele võrguteenust. Väljaspool Eestit tegutseb ettevõtte Enefiti kaubamärgi all. Maailmas on hinnas ettevõtte unikaalsed põlevkivi töötlemise teadmised, oskused ja tehnoloogia. Eesti Energia valduses Eestis, Jordaania ja USA-s leidub hinnanguliselt kuni 11 miljardit tonni põlevkivi. Ligi 7000 töötajaga on Eesti Energia üks suuremaid tööandjaid Eestis (*Ibid.*), (*Ibid.*).

Ressursikasutus. Eesti Energia toodab elektri- ja soojusenergiat peamiselt põlevkivist. Teiseks oluliseks energiaallikaks on saamas biomass (peamiselt puit), mille kasutamisel tekib vähem tuhka ja SO₂-heitmeid. (Keskkond. Eesti Energia)

Suuri võimalusi pakkuv kütuseliik on olmejäätmed. Eestis jõuab prügilatesse ligikaudu 200 000 – 300 000 tonni olmejäätmeid aastas. Selle ressursi kasutamiseks on ehitatud Iru elektri- jaama juurde jäätmeenergiaplokk. (*Ibid.*)

Ressursside kasutamist saab otstarbekamaks muuta põlevkivi suurema väärtustamisega. Eesti Energia strateegiline eesmärk on toota rohkem õli ja saavutada seeläbi ka madalama CO₂-sisaldusega ainete tekkimine elektri tootmisel. See on võimalik tänu õlitootmise kõrvalsaadusena tekkiva põlevkivigaasi ehk uttegaasi kasutamisele elektri tootmiseks (*Ibid.*).

Elektri ja soojuse tootmiseks on 2014. aastal kasutatud (Keskkonnaaruanne 2014. a):

- 17 miljonit tonni kaubapõlevkivi;
- 0,1 mln tonni biokütust;
- 43,7 mln m³ maagaasi;
- 221,4 tuhat t segaolmejäätmed.

Eesti Energia peamine energeetiline ressurss on endiselt põlevkivi. Elektri, soojuse ja vedelkütuse tootmiseks vajalikku põlevkivi on kaevandatud karjääridest ja maa-alustest kaevandustest. Lisaks oma tarbele on põlevkivi müüdud ka teistele Eesti vedelkütuste ja ehitusmaterjalide tootjatele (Keskkonnaaruanne 2010. a).

Õhusaaste. Eesti Energia elektri, soojuse ja vedelkütuste tootmine on seotud kütuste põletamisega. See on mõjutanud oluliselt Eesti Energia tootmisüksuste piirkonna õhu kvaliteeti, paisates õhku SO₂, NO_x, tahkeid osakesi ja CO₂. Väiksemates kogustes paisatakse heitgaasidega õhku ka raskemetalle, CO-d ning põlevkivist elektrienergia ja vedelkütuste tootmisel tekkivaid lenduvaid orgaanilisi ühendeid. Lisaks mõjutavad lokaalselt õhu kvaliteeti kaevandamise käigus toimuvad lõhkamised ning transpordivahendite heitgaasid (*Ibid.*).

Andmed keskkonnaheitmete kohta (vt tabel 1.1.):

Tabel 1.1. Keskkonnaheitmed 2011–2014

Õhuheitmed	ÜHIK	2011	2012	2013	2014
SO ₂	tuh t	56,8	23,2	20,9	24,2
sh Narva elektrijaamadest	tuh t	56,8	23,1	20,8	24,1
NO ₂	tuh t	12,8	9,7	8,8	8,5
Lendtuhk	tuh t	28,1	5,7	9,1	8,5
CO ₂	mln t	12,3	11,0	13,4	12,8

Allikas: (Keskkonnaaruanne 2014. a)

Üks Eesti Energia keskkonnaeesmärke lähiaastateks on põlevkivitööstuse õhuheitmete vähendamine ning tänapäevased tehnoloogiad on õhuheitmeid juba silmanähtavalt vähendanud (Keskkonnaaruanne 2014. a). Selle tõestuseks on õhuheitmete oluline vähenemine 2014. aastal võrreldes 2011. aasta õhuheitmete andmetega.

1.2. „Prognoos“ ja „eelarve“ mõistete erinevus

Magistritöö põhieesmärk on koostada Eesti Energia müügitulu lühiajaline prognoos, põhinedes kvantitatiivsetel meetoditel. Magistritöö edasise uurimise eel on vajalik kindlaks teha erinevus eelarve ja prognoosimise vahel. „Prognoos“ ja „eelarve“ on kaks eri mõistet ja siinses magistritöös on oluline nende mõistete tähendusi eristada.

Prognoosi ja eelarve vahe väljaselgitamisel käsitleb autor magistritöös prognoosi vajadust ja tähtsust tänapäeval ning prognoosimisetappide järgnevust.

Prognoosi ja eelarve erinevus. Prognoos (*forecast*) on piisava tõenäosusega tõseks osutada võiv ennustus sündmuste käigu ja tulemuste kohta. Prognoosimine on tegevus, mille eesmärk on ära arvata tuleviku sündmusi, olukordi, trende ja tulemusi organisatsiooni tegevuskeskkonnas (Karu, Zirnask 2004). Peamiselt kasutatakse müügitulu prognoosimiseks kolme ajavahe- mikku (Trehan 2010):

- lühiajalised (*short-term*) prognoosid on perioodiga alla aasta;
- keskmise pikkusega (*medium term*) prognoosid on tehtud 1–5 aastaks;
- pikaajalised (*long-term*) prognoosid on tehtud rohkem kui 5 aastaks.

Prognooside ajaline jaotus on suhteline ning eri allikad on käsitlenud seda jaotust erinevalt. Ülalpool toodud jaotus on autori seisukoha järgi siinse magistritöö raames sobilikum.

Magistritöös koostab autor keskmise pikkusega prognoosi ning meetodite võrdlemiseks on autor kasutanud samuti keskmise pikkusega perioodi (alates 2012. a III kvartalist).

Eelarve erinevus prognoosist seisneb eeldusel, et sooritatavad tegevused oleksid eelarvega vastavuses ja aitaksid saavutada eesmärgiks seatud tulemusi. Prognoos püüab ette aimata, mis tulevikus toimub. Võrreldes eelarvega ei vastuta prognoos tulemuste saavutamise eest, vaid prognoosi õigsuse eest, v.a kohanduval eelarvestamisel, kus prognoosi tähtsus on võrreldav eelarve tähtsusega (Karu, Zirnask 2004).

Prognoosi vajadus. Organisatsiooni kliima on keerulisem, kiiresti arenevam ja konkurentsivõimelisem kui kunagi varem. Organisatsioonid, kes ei reageeri kiiresti muutuvatele tingimustele ega kavanda tulevikku, on määratud hääbumisele (Hanke, Wichern 2005).

Eeltoodule on vaja juurde lisada, et prognoosides tulevikus müüki, varude vajadust, personali nõudmisi ja muid olulisi majanduslikke või ärimuutujaid, ei ole enam õigustatud tugineda üksnes intuitsioonile või kellegi „olukorra tundmisele“. Kvantitatiivsete meetodite abil on võimalik saada täpsemat prognoosi. Selleks on välja töötatud tarkvarapakette, võimaldades kvantitatiivsete meetodite kättesaadavust peaaegu kõikidele (Wilson, Keating 1994).

Vastavalt Makridakisele (1986) ei ole prognoosid, mis põhinevad ainult hinnangutel, nii täpsed kui prognoosid, mis on saadud kvantitatiivsete meetodite abil (*Ibid.*): inimesed omavad ainulaadseid teadmisi ja siseinfot, mis kvantitatiivsetes meetodites on puudu. Üllatavalt on empiirilised uurimused ja laboratoorsed katsed näidanud, et need prognoosid ei ole kvantitatiivsetest meetoditest täpsemad. Inimesed kipuvad olema optimistlikumad ja alahindavad tuleviku ebakindlust. Lisaks on kvalitatiivsete meetodite prognoosimiskulu sageli oluliselt kõrgem kvantitatiivsete meetodite omast (Hanke, Wichern 2005).

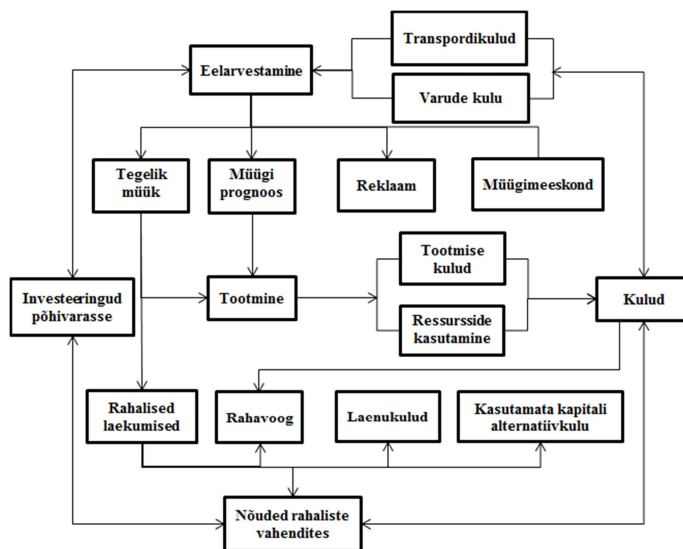
Magistritöös on autor uurinud erinevaid prognoosimismeetodeid, mis põhinevad ajalooliste andmete töötlemisel; need on meetodid, mis on võimalised täiendama juhtide otsustusvõimet

ja teadmisi (*Ibid.*), see annab omakorda tulemuseks täpsemaid prognoosimisandmeid (Holden, Peel, Thomson 1990).

Prognooside koostamise järgnevus. Peamine prognoos on müügiprognoos, millest sõltuvad teised prognoosid (Wilson, Keating 1994). Teiste kasumiaruannete ja bilansikirjete prognoos on seotud otseselt või kaudselt müügiprognoosi tulemustega (Fight 2006).

Prognoosimissüsteem peab looma omavahelisi seoseid eri juhtimisvaldkondade prognoosides. Eri osakondade prognoosides esineb suur omavaheline sõltuvus, mida eduka prognoosimise nimel ei saa ignoreerida. Näiteks võivad vead müügiprognoosides põhjustada hulga reaktsioone, mõjutades eelarveprognoose, tegevuskulude, rahakäibe, laovaru seisuga, hinnapoliitikat ja nii edasi. Sarnaselt mõjutavad iga osakonna käsutuses oleva rahasumma eelarvevead tootarendust, tehnoloogia uuendamist, töäjõu palkamist ja reklaamikulusid. See omakorda mõjutab või määrab müügitulemust, tegevuskulusid ja rahakäivet. On tõenäoline, et ettevõtte eri valdkondade prognoosides valitseb suur omavaheline seos (Makridakis, Wheelwright, McGee 1983).

Lihtsustatult on seos müügi ja muude ettevõtte prognooside koostamise etappide vahel esitatud joonisel 1.1. (*Ibid.*).



Joonis 1.1. Prognoosimise koostamise etapid
Allikas: (Makridakis, Wheelwright, McGee 1983)

Müügitulu prognoosimise olulisuse selgitamise järel on magistritöös vaja analüüsida uuritava ettevõtte väliskeskkonda mõjutavaid tegureid. Müügitulu mõjutavate tegurite väljaselgitamine võimaldab autoril koostada täpsema, kvantitatiivsetel meetoditel põhineva prognoosi.

1.3. Eesti Energia viimaste aastate tähtsamad sündmused ja väliskeskkonda mõjutavad tegurid

Iga prognoosi koostamisel peavad isiklikud hinnangud toetuma alati praktilistele kogemustele ja/või põhjalikele uurimistöodele (Wilson, Keating, 1994).

Kõiki ettevõtteid mõjutavad kolm tegevusvaldkonna tasandit: makromajandus, tööstusharu ja ettevõtte ise. Tavaliselt saab ettevõtte kontrollida ainult viimast. Seega on väga oluline, et ettevõtte oleks teadlik väljaspool ettevõtet toimuvast (Holden, Peel, Thompson, 1990).

Põhinedes ülaltoodule, toob autor oma töös esile Eesti Energia viimaste majandusaastate olulisemad sündmused, mida magistritöö raames on vajalik käsitleda, ning on samuti läbi vaadanud Eesti Energia müügitulemusi mõjutanud sündmused. Müügitulemustele mõju avaldavate sündmuste analüüs on olulise tähtsusega, mis on tingitud müügitulu prognoosimise olulisusest.

- 2013. aasta alguses toimus elektrituru täielik avanemine, mis põhjustas elektri jae-müügi mahtude vähenemise. Turu avanemisega kaasnes seni valdavalt monopoolses seisus olnud Eesti Energiale ootuspärane klientide arvu ja turuosa vähenemine (Eesti Energia AS 2013. aasta majandusaasta aruanne).
- Tulevikutehingute turuväärtuse liikumist mõjutavad kõige enam Põhja-Euroopa ilma-prognoosid, mis annavad märku tuleviku tarbimisest ning hüdroreservuaaride täitumise kiirusest. Rohked sademed ning vähene elektritarbimine Põhja-Euroopas hoiavad hüdroreservuaaride täituvust kõrgel tasemel, langetades tulevikutehingute hindu. Hüdroreservuaaridest pärineb enam kui pool Põhja-Euroopas toodetud elektrist (Vaarmann 2014).

Kõrgem õhutemperatuur tähendab üldiselt seda, et elektriga kütjad tarbivad elektrit vähem ning sellel on börsihinda alandav mõju (Vaarmann 2014). Börsihindade langust põhjustab ka tuulegeneraatorite kõrge tootlikkus. Tuulegeneraatorite toodetud elekter

paisatakse turule otsekohe ning üldiselt on sellel hindu alandav mõju (Vaarmann 2013).

2014. aasta veebruaris avati Eesti ja Soome vahel uus ülekandetrass EstLink-2, mis tõstis naaberriikide vahelist ülekandevõimsust. Seoses sellega püsisid Eesti ja Soome regiooni hinnad märtsis ühtsed ligi 94% tundidest. Suurem ühtsus Soome turupiirkonnaga avaldab Eesti börsihinnale üldjuhul langetavat mõju (Vaarmann 2014).

- Põlevkivil puudub turg (seega ka referentshind) Eestist väljaspool (Eesti elektrisüsteemi varustuskindluse aruanne .. 2013), kuid Eestis põlevkivist valmistatud vedelkütustel on kõrge ekspordipotentsiaal ning selle hind on seotud naftaproduktide hindadega maailmaturul (Elektrihinna mõjurid ... 2014).
- Toornafta maailmaturu hind mõjutab suures osas kas otseselt või kaudselt peaaegu kõiki kohalike kütuste hindu Eestis. Mõnede kütuste hindu, nagu biomass ja turvas, mõjutavad tootmiskulud, kus mootorikütus ja muud naftatooted hõlmavad märkimisväärse osa (Analyses of Energy Supply Options ... 2007).

Brenti toornafta keskmine hind mõjutab otseselt gaasikomponentide hinda esiteks läbi hinna indekseerimisklausli pikaajalistes tarnelepingutes ning teiseks läbi gaasi ja naftasaaduste vahelise kütusekonkurentsi elektrijaamades (*Ibid.*). Toornafta hinna volatiilsus on suuresti sõltuvuses poliitilistest konfliktidest.

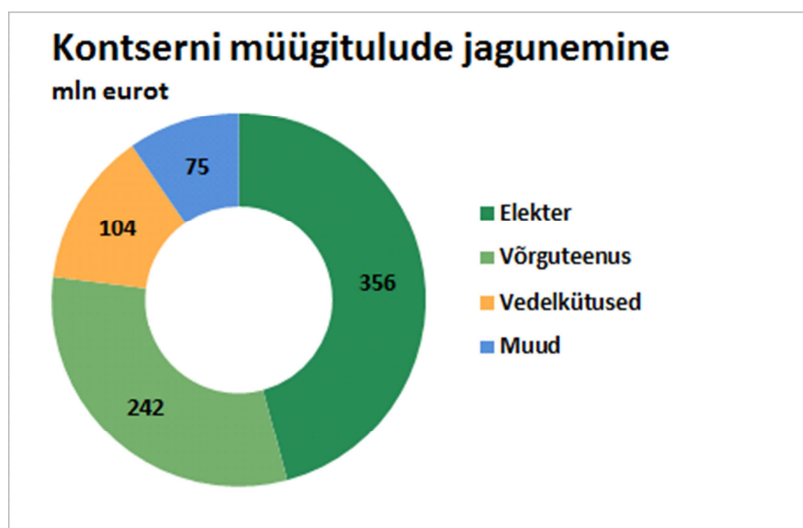
Olulisemaid hinda mõjutavaid komponente on ka euro ja dollari kurss (Vaarmann 2013). Dollari kursi üldine nõrgenemine on ajalooliselt tähendanud toornafta ning see läbi ka gaasikomponentide hinna tõusu (Vaarmann 2013).

- Müügitahu vähendamist mõjutab elektrihinna tõusuga kaasnev hinnatundlikumate klientide tarbimisharjumuste muutumine (Vaarmann 2013).
- Vastavalt Euroopa Liidu ja Eesti õigusaktidele peavad põlevkivikatelde välisõhku paisatavad heitmed vastama alates 2016. aastast karmistuvatele tööstusheitmete direktiivi nõuetele, millega piiratakse SO₂, NO_x ja tahkete osakeste sisaldust keskkonda juhitavares suitsugaasides ning mis kohustab Eesti Energiat praegust heidet oluliselt vähendama. SO₂ heitme oluliseks vähendamiseks koos sama ajal tootmisvõimsuste säilitamisega paigaldab Eesti Energia Narvas Eesti elektrijaama neljale 200 MW võimsusega energiaplokile väävlipuhastuse (DeSOX) seadmed. Puhastusseadmete kasutamine

võimaldab Eesti Energial vähendada nendest energiablokkidest õhku paisatavate suitsugaaside SO₂ sisaldust kuni kuus korda. Lisaks sellele väheneb ka tahkete osakeste sisaldus gaasides ning ühtlasi suureneb energiablokkide tööiga (Keskkonnanaruanne 2010).

- Selleks et leevendada kasvuhoonegaaside poolt tekitatavate kliimamuutuste mõju, on Euroopa Liit seadnud eesmärgi vähendada CO₂-heidet 2020. aastaks vähemalt 20%. Selle poliitika ellurakendamiseks kasutatav üleeuroopaline kvootide kauplemise süsteem avaldab suurt mõju ka Eesti Energia tegevusele (*Ibid.*).

Müügitulemustele mõju avaldavate sündmuste kokkuvõte. Järgnevalt on autor ära toonud müügitulu mõjutavad tegurid grupeeritult, lähtudes müügitulu jagunemisest (vt joonis 1.2). Muude müügitulude jagunemine hõlmab suuremas osas põlevkivi ja soojuse müüki.



Joonis 1.2. Müügitulu jagunemine 2015. a.

Allikas: (AS Eesti Energia 2015. a. majandusaasta aruanne)

Elektrienergia (osaliselt ka põlevkivi ja soojuse) müügitulu mõjutavad tegurid:

- hooajalised tegurid: õhutemperatuur, sademete hulk, tuulised ilmad (Eesti ja Skandinaavia);
- elektrisüsteemi arendus (Estlink);

- keskkonnaheitmete kogused (tööstusheitmete direktiivi nõuetele mittevastamine kaasaab tootmisvõimsuste mittedäilitamist);
- CO₂ turuhinnad (avaldavad mõju põlevkivist toodetud elektri mahule);
- elektrituru avatus;
- globaalsetel ja regionaalsetel turgudel valitsevad toorainehinnad (peamist mõju kontserni majandustulemustele avaldavad elektri hind Nord Pooli kauplemissüsteemis ning Nord Pooli Soome ja Eesti hinnapiirkondade hinnaerinevus võrreldes süsteemihinnaga).

Võrguteenuste müügitulu mõjutav tegur:

- elektrivõrgu töökindlust tagavad investeeringud.

Vedelkütuste müügitulu mõjutav tegur:

- Kontserni tulud sõltuvad vedelkütuste müügist olulises osas globaalsetel ja regionaalsetel turgudel valitsevatest toorainehindadest (põlevkiviõli referentstooteks oleva 1% väävlisisaldusega kütteõli hind maailmaturul).

Klientide tarbimisharjumustest tingitud mõjutavad tegurid ja nende muutused, mida autori seisukoha järgi on võimalik kirjeldada järgmiselt:

- töötuse määr;
- Eesti sisemajanduse koguprodukt (SKP);
- tarbijahinnaindeks.

2. PROGNOOSIMISMEETODID

Autor on magistritöö 1. peatükis kindlaks teinud, et müügiprognoos on olulise tähtsusega ja teiste majandusnäitajate prognoosimine põhineb omakorda müügitulu prognoositud andmetel. Prognoosimismudelite valiku tegemise eel on autor analüüsinud Eesti Energia müügitulu aegrea andmeid, kasutades selleks peamiselt autokorrelatsiooni analüüsi. Autokorrelatsiooni analüüs aitas piiritleda prognoosi koostamiseks sobilikud mudelid.

Sobivate prognoosimeetodite valimise järel annab autor mudelite lühituvustuse ning läbi vaatab prognoosimismudelite koostamisetappe. Seejärel teeb autor iga meetodi läbivaatamisel esialgse mudeli kuju valiku, millega alustatakse mudeli hindamist ja edaspidi ka müügitulemuste prognoosimist magistritöö kolmandas peatükis.


2.1. Aegrea analüüs

Müügitulu aegrea andmed. Andmete perioodiks on valitud kvartaalsed andmed 2002. aastast kuni 2015. aastani. Prognoosi täpsuse hindamisel on kasutatud kvartaalseid andmeid alates 2012. aasta teisest kvartalist kuni 2015. aasta neljanda kvartalini. Müügitulu andmed olid kogutud ettevõtte aasta- ja vahearuannetest (müügitulu andmed magistritöös on mln eurodes). Müügitulu prognoosimiseks kasutas autor Gretli ökonomeetriapaketti, mille abil tehti regressioonmudeli hindamine, aegridade analüüs ja mudelite testimine.

Aegrea andmete mustri uurimine ja prognoosimismetoodika valimine. Üks kõige olulisemaid aspekte aegrea andmetele sobiva prognoosimismeetodi valimiseks on eri tüüpi aegreamuustritega arvestamine. On neli põhitüüpi: horisontaalne, trend, sesoonne ja tsükliline (Hanke, Wichern 2005).

Eesti Energia müügitulu on olnud alates 2002. aastast kasvutrendis (vt joonis 2.1.). Joonis 2.1. näitab aegridade muutujates pikaajalist kasvutrendi. Lineaarne trendijoon on toodud joonisel

2.1., et illustreerida seda kasvu. Kuigi müügitulu ei kasvanud igas kvartalis, on üldine trend aastatel 2002–2012 olnud ülespoole.




Joonis 2.1. Eesti Energia müügitulu aastatel 2002–2012, miljonites eurodes (lisa 21)
Allikas: autori koostatud

Vaatlust on mõjutanud hooajalised tegurid, mis tähendab hooajalise mustris olemasolu. Se-soonne komponent viitab muutumise seaduspärale, mis kordub aastast aastasse. Kvartaalsete andmete kõikumine on tingitud müügitulu olulisest sõltuvusest Eesti keskmisest kvartaalsest õhutemperatuurist (*Ibid.*).

Aegrea andmete mustri uurimine autokorrelatsiooni analüüsi abil. Kui muutuja on mõõdetud pikema perioodi jooksul, on erineva ajaperioodi vaatlusandmed sageli seotud või korrelatsioonis. Sellist korrelatsiooni mõõdetakse autokorrelatsiooni kordaja abil (*Ibid.*).

Aegrea andmete mustrit, sealhulgas trendi ja hooajalisust, saab uurida autokorrelatsiooni abil. Erinevate ajavahemike autokorrelatsiooni koefitsiente kasutatakse aegrea andmete mustri kindlaksmääramiseks (*Ibid.*).



Joonis 2.2. Korrelogramm, Eesti Energia müügitulu autokorrelatsiooni graafiline kuju, viitaegade arv 16¹

Allikas: autori koostatud

Box-Ljung testib, kas vastava aegrea autokorrelatsioonide väärtused on nullist erinevad. Testi saab defineerida järgnevalt (Gujarati, Dawn 2009):

H_0 : andmed on hajutatud sõltumatult;

H_1 : andmetes esineb sõltuvus.

Testi tulemused on esitatud lisas 4 ning korrelogramm on esitatud joonisel 2.2. Olulisuse tõenäosus on väiksem kui valitud olulisuse nivoo, $p < 0,05$ ja kehtib sisukas hüpotees: esineb autokorrelatsioon. See tähendab, et Eesti Energia järjestikused kvartaalsed müügiandmed korreleeruvad omavahel. Autokorrelatsiooni analüüs annab põhjaliku ülevaate aegreast ja aitab valida sobiva prognoosimismeetodi.

Järgnevalt on toodud analüüsi andmed, mis on saadud tänu autokorrelatsiooni analüüsile:

- aegread ei ole juhuslikud, mis on tuvastatud autokorrelatsiooni olemasolu järgi;

¹ ACF-aegrea autokorrelatsioon
PACF-osaline autokorrelatsiooni funktsioon (vahepealsete väärtuste mõju on elimineeritud)
lag-viitaeg

- aegreas esineb trend: autokorrelatsiooni koefitsiendid on nullist erinevad esimeste ajavahemike jaoks ja vahemike järjekorranumbri suurenemisel langevad need järkjärgult nullile lähemale;
- aegreas esineb sesoonsus, kuna märgatavad autokorrelatsiooni koefitsiendid ilmnevad ajavahemikul 1 ja 4 ja 8 jne.

Detailsem autokorrelatsiooni analüüs on läbi viidud ARIMA-mudeli koostamise käigus (vt ptk 2.6.2).

Prognoosimismeetodid sesoonsuse esinemisel aegreas. Eesti Energia andmetes esineb trend ja sesoonsus. Järgnevalt on toodud meetodid, mida tuleb sesoonse kõikumisega aegrea prognoosimisel käsitleda (*Ibid.*):

- mitmene regressioon;
- klassikaline aegrea kompleksanalüüs;
- eksponentsiaalne silumine;
- ARIMA-mudel (Box-Jenkinksi meetod);
- naiivne;
- Census X-12;
- adaptiivne filtreerimine.

Autor otsustas jätta detailselt käsitlemata Census X-12 ja adaptiivse filtreerimise prognoosimismeetodi, kuna need meetodid põhinevad olulisel määral klassikalisel aegrea kompleksanalüüsil (Census X-12 puhul) ja eksponentsiaalse silumise meetoditel (adaptiivse filtreerimise puhul) (An Examination of the Use ..). Viimasena nimetatud meetodeid (klassikaline aegrea kompleksanalüüs ja eksponentsiaalne silumine meetod) on autor uurinud detailselt.

Müügitulu lühiajaliste prognoosimismeetodite ülevaadet ja hiljem ka prognoosi koostamist on autor otsustanud alustada mitmese regressiooni meetodist.

2.2. Prognooside hindamine

Järgnevalt esitab autor kriteeriumid, mida kasutati magistritöös prognoosimismudelite võrdlemisel ja hindamisel. Eristatakse kaks lähenemist:

- valimi sees (*in-sample*) prognoosimist (interpoleerimine);
- valimist väljaspool (*out-of-sample*) prognoosimist (ekstrapoleerimine).

Prognoosimine valimist väljastpoolt näitab seda, kui hästi saab kirjeldatavat mudelit kasutada prognoosimiseks. Selleks on kasutatud mitut kriteeriumit. Magistritöös on autor kasutanud järgmiseid kriteeriumeid:

- determinatsioonikordaja R^2 ;
- korrigeeritud determinatsioonikordaja R_a^2 ;
- Akaike informatsioonikriteerium (AIC);
- Schwarzi informatsioonikriteerium (SIC);
- χ^2 (chi-square).

Kõik need kriteeriumid seavad eesmärgiks vähendada vigade ruutude summat (RSS) (või suurendades R^2 väärtust). Välja arvatud esimene kriteerium, kehtestavad teised kriteeriumid trahvi suure numbri regressorite mudelisse kaasamise eest. Teisisõnu, prognoosijal on vaja leida tasakaal mudeli keerukuse (hinnatakse regressorite arvu järgi) ning mudeli kirjelduse vahel (Griffiths, Carter, Judge 1993).

Prognooside hindamiseks kasutab autor ka prognoosijääkide põhjal leitavaid suursi. Prognoosijääk u_t on tegeliku väärtuse y_t ja prognoositud väärtuse F_t vahe: $u_t = y_t - F_t$. Prognooside hindamiseks on autor kasutanud minimaalset ruutkeskmise viga (RMSE – *root mean square error*) ning keskmist suhtelist viga (MAPE – *mean absolute percent error*).

Ruutkeskmise viga (RMSE – *root mean square error*):

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{t=1}^n u_t^2} \quad (2.2.1)$$

Keskmine suhteline viga (*mean absolute percent error*):

$$\text{MAPE} = \frac{100\%}{n} \sum_{t=1}^n \left| \frac{u_t}{y_t} \right|, \quad (2.2.2)$$

kus n on prognoositavate väärtuste arv, st näitab prognoosi pikkust.

2.3. Mitmene regressioon

Müügitulu on näitaja, mis on liiga keeruline selle seletamiseks ühe muutuja poolt (Multiple regression ...). Hõlmamaks regressioonimudelisse kõiki võimalikke muutujaid, et arvestada müügitulu mõjutavate tegurite mitmekesisust, on vaja käsitleda mitmese regressiooni mudeli kasutamist.

Regressioonimudeli modelleerimisel seab autor eesmärgiks müügitulule suuremat mõju avaldavate seoste leidmise ja müügitulu lühiajalise prognoosi koostamise. Enamik Eesti Energia müügitulule mõju avaldavatest teguritest on tingitud makroökonomilistest suurustest ja ettevõtte tegevusest ning on ettevõtte kontrollipiirkonnast väljaspool. Mõju avaldavate tegurite väljaselgitamine võimaldab autoril koostada uuritava ettevõtte müügiprognoosi. Lühiajalise prognoosi koostamisel põhineb autor mõju avaldavate tegurite kindlate trendide olemasolul ja osaliselt tegurite ajalooliste aritmeetiliste keskmiste näitajatel.

2.3.1. Mitmese regressiooni analüüsi etapid

Mitmese regressiooni analüüsi korral tuleb läbida viis sammu (Hoang Diem Ngo 2012):

- 1) mudeli koostamine;
- 2) mudeli hindamine;
- 3) mudeli eeldused – jääkliikmete test ja diagnostika graafikud;
- 4) mudeli võimalikud probleemid ja nende lahendused;
- 5) mudeli lõpphindamine/kinnitamine.

Iga põhisammu all on omakorda allsammud, mis tuleb mudeli koostamisel läbida.

2.3.2. Mudeli koostamine

Mitmese regressiooni faktorite valik. Esimene samm mitmese regressioonimudeli koostamisel on sõltuva muutuja ja sellega seotud võimalike tegurite valimine. Eelneva analüüsi käigus leiti, et Eesti Energia müügitulule mõju avaldavad tegurid on järgmised:

- hooajalised tegurid: õhutemperatuur, sademete hulk, tuulised ilmad Eestis ja Skandinaavias (Skandinaavia sademete andmed on autor saanud Norra Angardsvatnet meteojaama kaudu);
- elektrisüsteemi arendus (Estlink), (kadude vähendamine);
- keskkonnaheitmete kogused (tööstusheitmete direktiivi nõuetele mittevastamine põhjustab tootmisvõimsuste alanemist);
- CO₂ turuhind (osutab mõju põlevkivist toodetud elektri mahule), (aruanne);
- elektrituru avatus;
- globaalsetel ja regionaalsetel turgudel valitsevad toorainehinnad (kontserni majandustulemustele avaldavad peamist mõju elektri hind Nord Pooli kauplemissüsteemis ning Nord Pooli Soome ja Eesti hinnapiirkondade hinnaerinevus võrreldes süsteemihinnaga);
- elektrivõrgu töökindlust tagavad investeeringud;
- kontserni tulud vedelkütuste müügist sõltuvad olulises osas globaalsetel ja regionaalsetel turgudel valitsevatest toorainehindadest (põlevkiviõli referentstooteks oleva 1% väävlisisaldusega kütteõli hind maailmaturul);
- töötuse määr;
- Eesti sisemajanduse koguprodukt (SKP);
- tarbijahinnaindeks.

Faktorite hindamine. Järgmine samm regressioonmudeli koostamisel on sõltumatute muutujate omavahelise seose uurimine. Selleks koostab autor korrelatsioonimaatriksi. Maatriksi analüüsi olid kaasatud faktorid, mille kohta oli autoril võimalik saada kvartaalseid statistilisi andmeid 42 perioodi kohta alates 2002. aastast kuni 2012. aastani, ja eelkõige selliseid, mille kindlat mõju oli autoril võimalik väljendada numbrites. Statistilised andmed koguti, kasutades Eesti statistika (Statistika andmebaas ...), Riigi Ilmateenistuse (Truhanov 2014), U.S. Energy Information Administrationi (Petroleum & Other Liquids) (Europe Brent Spot Price ...), Nord Pool Spot Trading Power Marketi (Elsport prices ...) ja Norra Meteoroloogia Instituudi andmebaasi andmeid.

Korrelatsioonianalüüsis osalesid järgmised muutujad (sulgudes on toodud lühendid, mida on kasutatud magistritöös edaspidi):

- Eesti keskmine õhutemperatuur (Ohutemperatuur) (Statistika andmebaas ...);
- Eesti keskmine sademete hulk (Sademed) (Statistika andmebaas ...);
- tuulekiiruse andmed (Kunda, Virtsu, Sõrve, Pakri keskmised andmed), (TuulekiirusKun, TuulekiirusVir, TuulekiirusSor, TuulekiirusPak), (Truhanov 2014);
- Norra Angardsvatneti järgi sademete hulk (SademedNorra), (The climate database ...);
- elektri hind Nord Pooli kauplemissüsteemis (Elspot price for area Finland), (Eestis on turg avatud alates 2013. aastast) (Elspot), (Elspot prices ...);
- Europe Brent Spot price (Brentspotprice), (Europe Brent Spot Price ...);
- töötuse määr (Eesti) (Tootusemaar), (Statistika andmebaas ...);
- Eesti sisemajanduse koguprodukt (korrigeeritud ja korrigeerimata), (Eesti) (SKPkorrigeerit, SKP), (Statistika andmebaas ...);
- kogurahvatulu jooksevhindades (korrigeeritud ja korrigeerimata), (Eesti) (Kogurahvatuluk, Kogurahvatulu), (Statistika andmebaas ...);
- tarbijahinnaindeks (THI) (Eesti), (Statistika andmebaas ...);
- tööstustoodangu tootjahinnaindeks (elektrienergia, gaasi, auru ja konditsioneeritud õhuga varustamine) (TTTHI), (Statistika andmebaas ...).

Korrelatsioonimaatriksis (vt lisa 2) on paariskorrelatsiooni kordajad arvutatud iga muutujate paari jaoks. Maatriksisse on kaasatud samuti \ln -müügitulu (logaritmitud müügitulu andmed).

Järgnevalt kontrollis autor otsustusmuutujate omavahelist sõltumatust. Tugevat korrelatsiooni otsustusmuutujate vahel nimetatakse multikollineaarsuseks. Üldjuhul peab korrelatsiooni-kordaja argumentide vahe olema absoluutväärtuselt märgatavalt väiksem mõlemast korrelatsioonikordajast sõltuvast muutujast. Vastavalt korrelatsioonianalüüsile käitusid reeglipäratult „THI“, „SKP“, „KRT“, „SKPkorrigeeritud“, „Töötusemäär“, „Brentspotprice“, „Sademed“, „TuulekiirusSorve“, „TuulekiirusPakri“, „TuulekiirusKeskmine“. Nende sõltumatute muutujate lisamine mudelisse ei aitaks müügitulu kõikumist selgitada. See asjaolu kinnitas hiljem ka determinatsioonikordaja, RESET-testi tulemus, multikollineaarsuse mõju hindamine (VIF-arvutus), ning ülejäänud faktorite tugevama olulisuse avaldumisel.

Vastavalt läbiviidud korrelatsioonianalüüsile valis autor regressioonimudeli kaasamiseks sõltuvalle muutujale kõige enam mõju avaldavad faktorid. Sellisteks faktoriteks osutusid järgmised:

- õhutemperatuuri andmed Eestis;
- kogurahvatulu (korrigeeritud) andmed;
- tööhõivemäär;
- tööstustoodangu tootjahinnaindeksi andmed;
- Elspoti hinnad;
- sademete andmed (Norra, Angardsvatneti meteojaam);
- tuulekiiruse andmed (Kunda, Virtsu).

Mudeli kuju valik. Mudeli parimaks kujuks osutus *log-lin*-mudel, see asjaolu sai kinnitatud müügitulu aegrea statsionaarsuse saavutamise käigus diferentsimise kaudu ning ka RESET-testi tulemustega (vt ptk 3.1.1.3).

2.4. Aegride kompleksanalüüs

Eesti Energia müügitulu aegride andmetes esinevad pikaajaline trend ja hooajalised kõikumised, mis eraldi läbi vaadates aitavad paremini mõista andmete muutust ja selle alusel paremaid prognoose teha. Aegride kompleksanalüüsi meetodit saab kasutada aluskomponentide identifitseerimiseks, jaotades aegread osadeks ja siis osad uuesti kokku pannes, koostades nii prognoosi (Wilson, Keating 1994).

Aegrea lahutamiseks on olemas mitu meetodit. Autor kasutab meetodit, mida nimetatakse klassikaliseks aegrea kompleksanalüüsiks. Hooajalisusega arvestatakse mudelis multiplikatiivsel viisil. Multiplikatiivse mudeli valik on põhjendatud erinevate absoluutsete kvartaalsete kõrvalekalletega trendist.

Sobiva trendi leidmiseks kasutatakse regressioonanalüüsi. Peale trendi leidmist leitakse sesoonsed komponendid valemist. Keskmiste sesoonsete komponentide leidmiseks kasutatakse geomeetrilist keskmist. Prognoosimiseks leitakse trend ja trendi komponent korrutatakse vastava

keskmise sesoonse komponendiga. Tsüklilised muutused ei olnud kompleksanalüüsi mudelis autori poolt arvestatud.

Põhiline aegridade kompleksanalüüsi meetodi mudel võib olla esitatud järgmise avaldise järgi (*Ibid.*):

$$Y = T \times S \times I, \quad (2.4)$$

kus

Y – prognoositav muutuja;

T – pikema aja jooksul ilmnev trend;

S – seaduspärased, sesoonsed muutused trendi ümbruses;

I – juhuslik komponent, mis on põhjustatud paljude tegurite koosmõjust vaadeldavale suurusele ja pole ette prognoositav.

Sesoonne tegur. Sesoone tegur on leitud vaatlusandmete ja trendi suhtena:

$$S_i = \frac{Y_i}{T_i} \quad (2.4.1)$$

2.5. Trendi ja sesoonsusega eksponentsiaalne silumine, Wintersi meetod

Eksponentsiaalne silumismeetod põhineb andmete keskmistamisel (silumisel) eksponentsiaalselt kahaneval moel (Wilson, Keating 1994). Wintersi eksponentsiaalne silumismudel on põhilise silumismudeli laiendus. Wintersi meetod arvestab trendi, sesoonsuse ja stationaarsusega. Järgnevalt toodud neli võrrandit on vajalikud Wintersi (multiplikatiivse) mudeli jaoks (*Ibid.*):

Silutud komponent:

$$E_t = \alpha X_t / S_{t-p} + (1-\alpha)(E_{t-1} + T_{t-1})$$

(valemite grupp 2.5)

Trendi komponent:

$$T_t = \gamma(F_t - F_{t-1}) + (1-\gamma)(T_{t-1})$$

Sesoonne komponent:

$$S_t = \beta X_t / F_t + (1-\beta) S_{t-p}$$

Prognoos:

$$F_{t+m} = (F_t + mT_t) S_t \quad ,$$

kus

E_t	silutud väärtus perioodil t ,
α	andmete silumiskonstant ($0 < \alpha < 1$),
X_t	tegelik väärtus (perioodil t),
T_{t+1}	trendi näitaja,
β	sesoonne silumiskonstant,
γ	trendi silumiskonstant,
m	perioodide arv sesoonses tsüklis,
F_{t+m}	Wintersi mudeli prognoos m perioodiks.

Mudeli initsialiseerimine/lähtestamine. Algväärtuste valimine eksponent-silumismudelites on olnud suure arutelu all, kuid empiirilisi tõendeid, mis soodustaksid kindlat lähenemist, ei ole leitud (*Ibid.*). Järgnevalt toob autor võimalikud lähenemised eksponent-silumismudeli algväärtuse valimiseks:

- Aegridade kompleksanalüüs (*Ibid.*);
- Kui andmetes esineb trend, kasutatakse mõnikord algväärtuse määratlemiseks trendi pikendamist (*Ibid.*);
- Teine lähenemine on seadistada silutud aegrea esimest näitajat võrdseks esimeste vaatlusandmetega. Trend on siis väärtustatud võrdseks nullile ja sesoonsed indeksid seatud ühele (Hanke, Wichern 2005);
- R. G. Brown pakub algväärtusena kasutamiseks aegrea keskmist, selline lähenemine on olnud üsna levinud (Wilson, Keating 1994);
- Teine meetod seisneb lineaarse regressioonimudeli võrrandi koostamisel, kasutades muutujat kui Y ja aega kui sõltumatu muutujat X . Lineaarse regressioonimudeli valemi konstant on silumisaegrea algväärtus ja regressiooni koefitsient on trendi komponendi algväärtusena (Hanke, Wichern 2005).

Mudeli algväärtustena on autor valinud lineaarse regressioonimudeli konstandi üldise silumise algväärtusena, keskmised sesoonsed komponendid (arvutatud kompleksanalüüsi jaoks, vt ptk 3.2.1) sesoonsusega silumise algväärtustena (kokku neli), nullväärtuse trendiga silumise algväärtusena.

Silumiskonstandid α , β ja γ peaksid võrduma väärtustega, mis vastaksid minimaalsele ruutkeskmise veale (RMSE – *root mean square error*) või keskmise suhtelisele veale (MAPE – *mean absolute percent error*). Vastavalt enamikule uuringutest, peavad silumiskonstantide väärtused olema vahemikus 0–1 (Gardner 1985). Meetod, mis aitaks leida silumiskonstantide väärtusi, on tavaliselt katse-eksitusmeetod, kuid optimaalsete väärtuste leidmiseks on samuti võimalik kasutada mittelinearseid optimeerimislogaritme (Makridakis, Forecasting). Autor kasutab silumiskonstantide väärtuste leidmiseks Microsoft Exceli vahendit Solver, mis kasutab mittelineaarset taandatud üldistatud gradiendi optimeerimiskoodi (About Solver ...).

2.6. Autoregressiivne mudel (Box-Jenkins)

2.6.1. Sissejuhatus ARIMA-mudelitesse

Autoregressiivsed integreeritud libiseva keskmisega (ARIMA) mudelid kuuluvad lineaarsete mudelite juurde, mis kirjeldavad nii statsionaarseid kui ka mittestatsionaarseid aegridu (Hanche, Wichern 2005).

ARIMA-mudelid ei sisalda sõltumatuid muutujaid. Mudel kasutab prognooside koostamiseks pigem aegreas sisalduvat informatsiooni (*Ibid.*)

Box-Jenkinsi prognoosimismetoodika erineb teistest meetoditest, sest see võimaldab analüüsida pea kõiksuguse kujuga prognoositavaid aegridu. Meetod kasutab võimaliku mudeli kindlakstegemiseks iteratiivset lähenemist. Mudeli täpsuse kirjeldamisel võrreldakse valitud mudelit ajaloolise aegrea andmetega. Mudeli kirjeldusvõime on suur, kui jääkliikmed on väikesed, juhuslikult jaotatud ning jääkliimete korral ei esine autokorrelatsiooni (jääkliikmed ei sisalda olulist infot). Kui mudel ei ole rahuldav, korratakse protsessi uue mudeli kasutamise kaudu, et täiustada eelmist mudelit. Sellist iteratiivset protseduuri kasutatakse kuni rahuldava mudeli leidmiseni. Sel juhul saab mudelit prognoosimiseks kasutada (*Ibid.*).

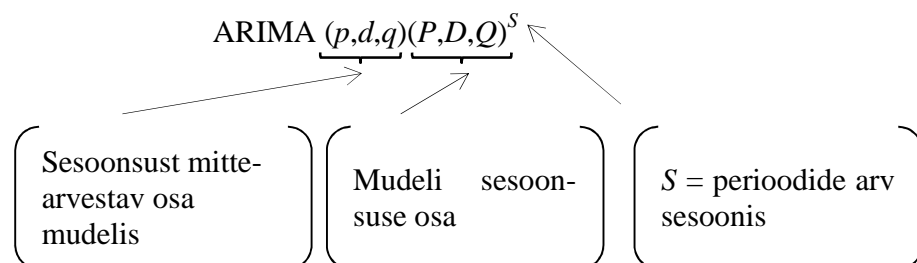
2.6.2. Mudeli identifitseerimine

Identifitseerimisprotsessi tuleb alustada aegrea uurimisest. Nagu eelnevalt on peatükis 2.1. kirjeldatud ja nagu on näha joonisel 2.2., omavad Eesti Energia müügiandmed kindlailmelist seosonset kuju koos kasvutrendiga, mis omakorda viitab aegrea mittestatsionaarsusele. Eesti Energia müügi aegrea andmeid saab kirjeldada kui mustrit, mis kordub iga nelja kvartali järel. Müügitulemused on kõrged talvel ja madalad suvel.


Järgmine identifitseerimissamm on uurida autokorrelatsiooni graafikut (vt joonis 2.2, peatükk 2.1). Joonis näitab, et autokorrelatsioonid kuni 12 viitajani olid suured ja vähenesid aeglaselt, tähistades trendi autokorrelatsioonides. See kinnitab omakorda väidet aegrea mittestatsionaarsuse kohta.

Viitajaga 4 võrdub autokorrelatsioon $r_4 = 0,8132$. See on suurem kui eelnevad kaks väärtust ja sarnaselt on r_8 suurem kui kaks eelmist väärtust. See kinnitab samuti seosonuse olemasolu (Makridakis, Wheelwright, McGee 1983).

ARIMA-mudelit, mis arvestab seosonusega, saab väljendada järgmiselt:



Statsionaarsuse saavutamine andmetes. Diferentsimine. Diferentsimise eesmärk on saavutada statsionaarsus. Pärast trendi ja seosonuse väljaselgitamist diferentsitakse aegread seosonuse ja regulaarse viitaja suhtes, kus diferentsitud aegrea autokorrelatsioonid on arvatud. Saadud tulemused on toodud lisa 16 (*Ibid.*). Diferentsitud andmed on statsionaarsed keskväärtsuhtes (vt joonis 2.3.), kuid dispersiooni osas konstantsus ei olnud saavutatud. (probleemi on käsitletud peatükis 3.4.1). Paljud dominantsed seosonused viitajad on kadunud.



Joonis 2.3. Müügitudu empiiriline analüüs pärast 1. järgu sesoonse ja mitteseseoonse diferentsi võtmist

Allikas: autori koostatud

Autor on identifitseerinud mudelit järgmises tähistuses: $ARIMA(p, I, g)(P, I, Q)^4$, kus väärtused p , g , P ja Q jaoks ei ole veel määratletud. Osalise autokorrelatsiooni funktsiooni korrelogrammist on autor täheldanud mitme esimese viitaja puhul eksponentsiaalset vähenemist, pakkumaks mitteseseoonset $MA(1)$ protsessi, mis omakorda pakub järkude määramiseks $q=1$ ja $p=0$. Autokorrelatsiooni diagrammil on r_1 väärtus suur, tugevdades sesoonset $MA(1)$ protsessi. Osalist autokorrelatsiooni funktsiooni saab kasutada sesoonse $MA(1)$ protsessi toetamiseks. Autor peatub järgneva esialgse mudeli valikul: (41, Makridakis)

$$ARIMA(0,1,1)(0,1,1)^4$$

2.7. Naiivne meetod

Naiivse prognoosi järgi on aegrea viimased perioodid parimad tulevikuennustajad. Lihtsaim mudel on järgmine:

$$\hat{Y}_{t+1} = Y_t,$$

kus \hat{Y}_{t+1} on prognoos koostatud ajahetkel t (prognoosimise algus) ajahetkeks $t+1$.

Naiivse prognoosimise korral on prognoosiks aegrea viimane väärtus. Sajaprotsendiline osakaal on antud jooksva aegrea väärtusele. Naiivset prognoosi nimetatakse mõnikord “muutuse-ta” prognoosiks.

Kuna naiivne prognoos heidab kõrvale kõik muud vaatlusandmed, kajastab selline meetod muutusi üsna kiirelt. Probleem seisneb aga selles, et sarnaselt teiste põhimuutustega on kajastatud juhuslikud kõikumised. Sesonsete kõikumiste ja trendi lisamiseks peavad kvartaalsete andmete suhtes olema prognoosi koostamisel rakendatud naiivne trend ja sesoonne mudel.

$$\hat{Y}_{t+1} = Y_{t-3} + \frac{Y_t - Y_{t-4}}{4}, \quad (2.6)$$

kus Y_{t-3} liige prognoosib sesoonsust ja ülejäänud valemi osa arvutab viimaste nelja kvartali keskmise ja annab hinnangu trendile (Hanke, Wichern 2005).

Autor on müügitulemuste prognoosimise jaoks läbi vaadanud mitmese regressiooni, aegridade kompleksanalüüsi, trendi ja sesoonsusega eksponentsiaalne silumise (Wintersi meetod), autoregressiivse mudeli (Box-Jenkins) ning naiivse meetodi. Iga meetodi kohta on tehtud esialgne mudeli kuju valik, millega alustatakse mudeli hindamist ja edaspidi ka müügitulemuste prognoosimist magistritöö kolmandas peatükis. Naiivne meetod on kaasatud magistritöösse teiste meetodite prognoosimistulemuste võrdluse aluseks.

3 . MÜÜGITULEMUSTE PROGNOOSIMINE

Kolmandas peatükis hindab autor teises peatükis vaadeldud mitmese regressiooni, aegridade kompleksanalüüsi, trendi ja sesoonsusega eksponentsiaalne silumise (Wintersi meetod), autoregressiivse mudeli (Box-Jenkins) ning naiivse meetodi valitud prognoosimismudeleid ning kinnitab need lõplikult. Pärast mudelite lõpphindamist prognoosib autor müügitulemusi. Seejärel võrdleb autor prognoosimismudeleid ning valib neist kõige täpsema. Autor analüüsib ka mudelite täpsuse põhjuseid ning toob esile oma seisukohad mudelite täpsuse parandamiseks.

3.1.1. Mudeli hindamine

Mudeli üldkuju:

$$\ln y = \alpha_0 + \alpha_1 x_1 - \alpha_2 x_2 + \alpha_3 x_3 - \alpha_4 x_4 + \alpha_5 x_5 + \alpha_6 x_6 + \alpha_7 x_7 + \alpha_8 x_8 \quad (3.1.)$$

Tabel 3.1. Regressioonmudeli (vt valem 3.1.) hindamise tulemused tabeli kujul

Vabaliige	4,35 ($36,76 \times 10^{-2}$)
x_1	$-1,12 \times 10^{-2}$ ($1,51 \times 10^{-3}$)
x_2	$3,05 \times 10^{-4}$ ($3,86 \times 10^{-5}$)
x_3	$-1,85 \times 10^{-2}$ ($6,53 \times 10^{-3}$)
x_4	$6,36 \times 10^{-3}$ ($1,21 \times 10^{-3}$)
x_5	$3,14 \times 10^{-3}$ ($7,56 \times 10^{-4}$)

x_6	$9,99 \times 10^{-4}$ ($3,61 \times 10^{-4}$)
x_7	$14,42 \times 10^{-2}$ ($4,3 \times 10^{-2}$)
x_8	$-10,86 \times 10^{-2}$ ($4,66 \times 10^{-2}$)
R^2	0,982
n	42


Allikas: Autori koostatud lisas 5 toodud andmete alusel (sulgudes on toodud mudeli parameetrite standardvead)

Müügitulumudel (vt tabel 3.1.) kasutatakse 8 argumenttunnust, kus

- y – müügitulu, miljonit eurot;
- x_1 – keskmine õhutemperatuur Eestis, °C;
- x_2 – kogurahvatulu jooksevhindades, miljonit eurot, sesoonselt, korrigeeritud tööpäevade arvuga;
- x_3 – tööhõive määr 15–69-aastaste hulgas, %-des;
- x_4 – tööstustoodangu tootjahinnaindeks, tegevusala: elektrienergia, gaasi, auru ja konditsioneeritud õhuga varustamine, andmed baasil 2010 = 100;
- x_5 – Elspot hind (Soome piirkond), €/MWh;
- x_6 – sademete hulk, mm, Norra Angardsvatneti meteojaama andmed;
- x_7 – tuulekiiruse andmed, Kunda rannikujaam;
- x_8 – tuulekiiruse andmed, Virtsu rannikujaam.

Parameetrite tõlgendus (tähtsad järeldused):

- temperatuuri tõusmisel müügitulu väheneb (temperatuuri langemisel müügitulu suureneb);
- kogurahvatulu tõusmisel müügitulu suureneb.



Joonis 3.1. Ettevõtte tegelik ja modelleeritud müügitulu aastatel 2002–2012

Allikas: autori koostatud

Järgnevad kriteeriumid on tähtsad mudeli otstarbekuse kontrollimisel:

- **Mudeli statistiline olulisus.** Mudeli statistilise olulisuse kontrollimiseks kontrollib autor vastavat hüpoteesi, milleks on välja arvatud olulisuse tõenäosus p .

$$F(8, 33) = 228,9798 \quad \text{olulisuse tõenäosus } p = 1,23 \times 10^{-26}$$

Sisukas hüpotees H_1 : Vähemalt üks kordaja $\alpha_i \neq 0$ ehk $r^2 \neq 0$.

Olulisuse tõenäosus on siinses mudelis olulisuse nivoost väiksem, $p < \alpha$. Kehtib sisukas hüpotees: mudel on statistiliselt oluline, funktsiooni Y ja argumentide X vahel eksisteerib seos ja Y sõltub vähemalt ühest argumenttunnusest X .

- **Parameetrite hinnangud.** Mudeli statistilise olulisuse korral on vähemalt üks regressioonmudeli parameetritest statistiliselt oluline. Järgnevalt kontrollib autor, kas üksikud regressioonmudeli parameetrid erinevad statistiliselt nullist, st kas selgitavate tunnuste hulgas pole üleaaruseid (andmed on toodud lisa 5).

Olulisuse tõenäosus on kõikidel parameetritel väiksem kui olulisuse nivoo $0,05$, $p < \alpha$. Parameetrite jaoks kehtib sisukas hüpotees. Mudeli parameetrite ja müügitulu vahel on statistiliselt oluline seos: parameetrite hinnangud erinevad oluliselt nullist.

- **Mudeli kirjeldusvõime.** Mudelite kirjeldatuse taseme saamiseks ehk selleks, kui suur osa sõltuvatest muutustest, kirjeldatakse mudeliga, arvutatakse determinatsioonikordaja R^2 (Gujarati, Dawn 2009). Analüüsi tulemused on toodud lisas 6. Mudeli determinatsioonikordaja $R^2=0,9823$ ehk u 98,23% müügitulu muutusest on seletatav mudeli parameetritega, ülejäänud varieerumine 1,77% on tingitud aga muudest põhjustest.

3.1.1.1. Mitmese regressioonmudeli eeldused

Jääkliikmete hinnang (kõrvalekalde hinnang) on mudeli olulisuse kontrollimisel väga oluline (Makridakis, Wheelwright, McGee 1983). Regressioonanalüüsi läbiviimisel eeldatakse jääkide kohta järgmist (Gujarati 1992):

- 1) juhuslike jääkliikmete keskväärts on 0, $E(u_i)=0$;
- 2) juhuslikud jääkliikmed alluvad normaaljaotusele, $u_i \sim N$;
- 3) juhuslike jääkliikmete dispersioon on konstantne (homoskedastiivsus), $\text{var}(u_i)=\sigma^2$;
- 4) juhuslikud jääkliikmed ei korreleeru omavahel, st nende kovariatsioon on null (autokorrelatsiooni puudumine) ja liikmed ei korreleeru seletavate tunnustega (Anderson, Sweeney, Williams 1996).

Järgnevalt on autor koostanud iga eelduse kohta detailse analüüsi ning vastava testi läbiviimisel on antud hinnang mudeli olulisuse kohta.

1) Juhuslike jääkliikmete keskväärts on 0, $E(u_i)=0$

Konstandi olemasolu mudelis tähendab eelduse täitmist. Autor otsustas eeldust siiski kontrollida, kasutades selleks veel z-testi.

- Hüpoteesi kontrollimiseks kasutab autor z-testi.
- Hüpoteesi püstitamine:
 $H_0: \mu=0$ Nullhüpotees on, et jääkliikmete kogumi keskväärts μ võrdub nulliga.

$H_1: \mu \neq 0$ Sisukas hüpotees on, et jääkliikmete kogumi keskvärtus μ ei võrdu nulliga.

- Valimi vaatluse põhjal saadud statistilised parameetrid: valimi maht $n=42$; valimi aritmeetiline keskmine $\bar{x} = -4,44089 \times 10^{-16}$ ja valimi standardhälve $s = 0,05$. Parameetri z empiiriline väärtus $z = -6,3551 \times 10^{-14}$. Valimi statistilised parameetrid on toodud lisas 7.
- Olulisuse nivoole 5% vastavad kriitilised väärtused on $-1,96$ ja $1,96$.
- $-1,96 < -6,3551e-014 < 1,96$ – järelikult parameeter ei lange kriitilisse piirkonda.
- Kuna z -testi parameeter ei lange kriitilisse piirkonda, pole alust nullhüpoteesi tagasi lükata. Vaatluse tulemus kinnitab mudeli jääkliikmete võrdlemist nulliga.

2) $u_i \sim N$ juhuslikud liikmed alluvad normaaljaotusele

Jääkliikmete allumine normaaljaotusele tähistab parameetrite hinnangute mõjusust. Kui jäägid ei allu normaaljaotusele, siis sõltuv muutuja või vähemalt üks seletavatest tunnustest võib omada valet funktsionaalset vormi või oluline tunnus võib olla mudelist välja jäänud.

Kui jäägid ei allu normaaljaotusele, siis muutuja või vähemalt üks selgitav muutuja võib olla vale toimival kujul või olulised muutujad võivad puududa jne (Gujarati, Dawn 2009). Jääkide diagrammi hoolikalt uurides saab öelda, kas hinnangud on olnud õiged ja kas mudeli kuju valik osutus õigeks.

Jääkliikmete jaotuse kuju võrdlemiseks normaaljaotuse kujuga kasutab autor Jarque-Bera ja Doornik-Hanseni testi. Testide põhimõte seisneb jääkliikmete jaotuse kuju võrdlemisel normaaljaotuse kujuga. Testi andmed on toodud lisas 8.

Jarque-Bera test: $JB = 0,94$ $p = 0,62 > 0,05$. Kehtib nullhüpotees, jäägid alluvad normaaljaotusele.


Doornik-Hanseni test ja jääkide histogramm koos normaaljaotuskõveraga: on esitatud lisas 9.

$p = 0,67 > 0,05$, kehtib nullhüpotees, regressioonmudeli jääkliikmed alluvad normaaljaotusele.

3) Juhuslike jääkliikmete dispersioon on konstantne (homoskedastiivsus)

Heteroskedastiivsus esineb, kui vealiikmete varieeruvus ei ole konstantne kogu vaatluse ulatuses. Heteroskedastiivsuse näiteks on aegrea jääkliikmete dispersiooni suurenemine ajaperioodi vältel. (Makridakis, Wheelwright, McGee 1983).

Heteroskedastiivsuse olemasolu kontrollimiseks ehk jääkide varieeruvuse uurimiseks kasutab autor graafilist analüüsi (vt joonis 3.2) formaalse testiga. Testi tulemused on toodud lisa 10.



Joonis 3.2. Jääkide aegrida

Allikas: autori koostatud

Graafiline analüüs: jääkliikmete paiknemises ei esine kindlat seaduspära. Jääkliikmete varieerumine on konstantne. Autor teeb järelduse, et jääkliikmed on homoskedastiivsed.

Formaalne test: formaalseks testiks valib autor White'i testi.

White'i test ei anna hinnangut heteroskedastiivsuse vormile (White 1980). Tänu oma üldistusastmele saab White'i testiga tuvastada peale heteroskedastiivsuse ka spetsifikatsiooni vigu (Thursby 1982). Seega võib White'i test osutada oluliseks, kui vead on homoskedastiivsed, kuid mudel on valesti määratud muul viisil (Heteroscedasticity ...).

$p = 0,58 > 0,05$, kehtib nullhüpotees, heteroskedastiivsust ei esine.

4) Juhuslikud liikmed on sõltumatud

$Cov(u_i, u_j)=0$ juhuslikud liikmed ei korreleeru omavahel, st nende kovariatsioon on null (autokorrelatsiooni puudumine)

Jääkliikmete autokorrelatsiooni olemasolu viitab regressioonimudeli puudulikkusele ja äärmuslik aegrea korrelatsioon viitab sageli valesti määratud mudelile.

Jääkliikmete vahelise autokorrelatsiooni testimiseks kasutab autor Durbin-Watsoni statistikut. Järgnevalt on toodud kaks väärtust: alumine (*lower*) väärtus dL ja ülemine (*upper*) väärtus dU , vaatlusandmete põhjal arvatud empiirilist väärtust d võrdleb autor kriitiliste väärtustega.

- empiiriline väärtus

Durbin-Watsoni statistik = 1,23157

$p = 0,000963359$

- kriitilised väärtused

Durbin-Watsoni statistiku kriitilised väärtused, 5% olulise nivoo puhul, $n=42$, $k=8$

$dL=1,0958$

$dU=1,9797$

- Kuna d langeb kriitiliste väärtuste vahelisse piirkonda, $dL < d < dU$, on otsuse vastuvõtmiseks vajalik vähendada olulisuse nivood α või suurendada aegrea pikkust, vaatluspunktide arvu n .

Autor vähendas olulisuse nivood 2,5%-ni. Vastavad kriitilised väärtused on toodud järgnevalt:

2,5% Durbin-Watsoni statistiku kriitilised väärtused, $n=42$, $k=8$

$dL = 1,28$

$dU = 1,63$

- $d < dL$, nullhüpotees tuleb tagasi lükata, autokorrelatsioon eksisteerib, kuid see ei ole tugev, kuna $d \neq 0$.

Kuna Durbin-Watsoni statistiku järgi eksisteerib juhuslike liikmete vahel omavaheline autokorrelatsioon, on autor otsustanud kasutada alternatiivtestina Breusch-Godfrey testi.

Breusch-Godfrey testi omadus seisneb selles, et testi kitsendusvaldkondi on võrreldes Durbin-Watsoni statistikuga vähem. Durbin-Watsoni statistik kontrollib ainult autokorrelatsiooni esimese

viitaja kohta, kuid Breusch-Godfrey test kontrollib autokorrelatsiooni mistahes viitaja kohta (Gujarati, Dawn 2009).

Breusch-Godfrey testi tulemused on toodud lisas 29.

p -value = 0,13 > 0,05, kehtib nullhüpotees, autokorrelatsioon ei eksisteeri.

Vastavalt Breusch-Godfrey testile teeb autor järelduse, et jääkliikmed on juhuslikud ning regressioonimudel on määratud õigesti.

3.1.1.2. Mudeli võimalikud probleemid ja nende lahendused

Mitmese regressioonimudeli koostamisel peavad analüütikud arvestama potentsiaalsete probleemidega, mis on põhjustatud eelduste rikkumistest. Osa probleemidest saab ainult minimeerida, samas kui teisi saab lahendada mudeli täpsuse parandamisega. (Hoang Diem Ngo 2012)

Multikollineaarsus. Sõltumatute tunnuste omavahelist korrelatsiooni (lineaarne sõltuvus) nimetatakse multikollineaarsuseks. Multikollineaarsuse põhjuseks on tavaliselt suure arvu sõltumatute muutujate sisselülitamine mudelisse, sest muutujad võivad kirjeldada (mõõta) samu käsitusi või nähtusi (Multicollinearity in regression models ...). Kui sõltumatud muutujad on suures korrelatsioonis, võivad t-testi ja F-testi tulemused olla omavahel vastuolus ja argumentsuurused võivad omada oodatust vastupidist väärtust (Hoang Diem Ngo 2012).

Multikollineaarsuse tugevuse hindamiseks arvutab autor välja korrelatsioonikordajad mudeli sõltumatute tunnuste iga paari jaoks. Suurte kordajate väärtuste avastamine saab olla põhjustatud tugeva multikollineaarsuse avaldumisest. Samuti teostab autor multikollineaarsuse tugevuse hindamiseks ka VIF-arvutuse.

- *Korrelatsioonianalüüs*

Korrelatsioonianalüüsi andmed on toodud lisas 11. Kõige suuremad korrelatsioonikordajad avaldusid ainult sõltumatute tunnuste ja sõltuva muutuja vahel. Esines seos TuulekiirusVir ja TuulekiirusKun, KRTkorrigeer ja TTTHI sõltumatute tunnuste vahel, kuid nende tunnuste mudelist väljajätmisel halveneb mudel oluliselt. Autor teeb järelduse, et vastavalt korrelatsiooni analüüsile on multikollineaarsuse mõju nõrk.

- *Dispersiooni inflatsioonitegur*

Testi tulemused on toodud lisas 12.

KRTkorrigeeritud näitaja on > 10 , mis võib viidata multikollineaarsusele, kuid kuna VIF teised näitajad on < 10 , teeb autor järelduse, et multikollineaarsus on nõrk.

3.1.1.3. Mudeli lõpphindamine/kinnitamine

Mudeli kuju testimiseks kasutab autor RESET-testi. Selle testiga lisatakse mudelisse ruute ning võimalikult ka kuupe tunnuse Y hinnatud väärtusi ning hinnatakse mudelit uuesti. Kasutatakse kas t - või F -statistikut. F -statistik annab hinnata, kas mudelis esineb spetsifikatsiooniviga (puuduolevad muutujad) või on mudelil vale funktsionaalne kuju (Griffiths, Carter, Judge 1993).

Testi tulemused on toodud lisas 13.


$p = 0,235 > 0,05$, kehtib nullhüpotees, vastavalt RESET-testile mudeli kuju on õige.

3.1.2. Mitmene regressioon ja prognoosimine

Mitmene regressioon võib olla kasulik prognoosimisvahend, kuid arvestada tuleb kahe etapiga. Esimene on mudeli koostamine ja kohandamine (mida on käsitletud peatükis 2.3. ja 3.1.1) ja teine on prognoosi koostamine mudeli abil (Makridakis, Wheelwright, McGee 1983). Siinses peatükis keskendub autor teisele etapile.

Prognoosi koostamiseks peavad argumentsuuruste väärtused olema teada. Argumentväärtused sisestatakse regressioonvalemisse ja saadakse prognoositud väärtus Y (*Ibid.*). Argumentsuuruste väärtuste leidmiseks on autor kasutanud kahekordset eksponentsiaalset silumist ehk Holtmeetodit (aegridades trendi olemasolu tõttu) (*Ibid.*) ja aritmeetilise keskmise meetodit.

Argument suurused x_1, x_6 : Õhutemperatuur ja SademedNorra

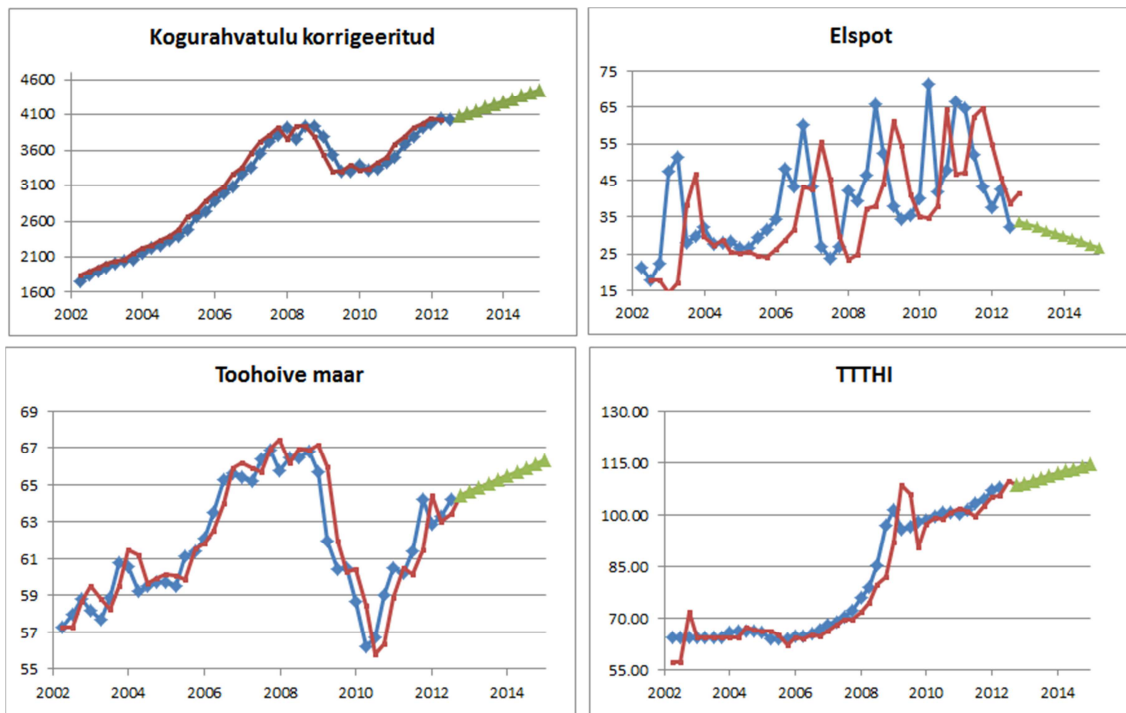


Joonis 3.3. Kvartaalsete õhutemperatuuride ja sademete trendid

Allikas: autori koostatud

Aritmeetilist keskmist meetodit on autor otsustanud kasutada kvartaalsete õhutemperatuuride, sademete hulga ja tuule kiiruse (Virsu ja Kunda) määramisel (vt joonis 3.3). Vastavad aasta kvartaalsed väärtused on toodud lisa 24.


Teiste argument suuruste leidmine. KRT korrigeeritud, Elspot, Tööhõivemäär ja TTHI argument suurused on leitud, kasutades kahekordse eksponentsilumise (Holt) meetodit (vt joonis 3.4), ja need on toodud lisa 25.



Joonis 3.4. Faktorite tegelikud andmed (sinine), silutud (Holt-meetod, punane) ja prognoositud (roheline)

Allikas: autori koostatud

Prognoosimine. Kasutades mudeli üldkuju (vt valem 3.1.) ja kordajate tabelit (vt tabel 3.1.) ning 14 kvartalit etteprognoositud faktorite väärtusi, saab autor arvutada vastava perioodi prognoositud müügitulu. Saadud andmed on näidatud lisa 26 ning joonisel 3.5.



Joonis 3.5. Prognoositud müügitulu (mitmene regressioon) ja tegelikud andmed
Allikas: autori koostatud

Järeldused. Kuna sõltumatud muutujad peavad sageli olema prognoositud enne sõltuvaid muutujaid, siis on tähtis, et sõltumatute muutujate kohta oleks saadud hea prognoos. Mitmed ettevõtted kasutavad erinevate prognooside ja ökonomeetriliste mudelite koostamiseks vastavate firmade teenust (Makridakis, Wheelwright, McGee 1983).

Regressioonanalüüs on võimas arvutusmeetod ja enamkasutatav prognoosimisviis (*Ibid.*). Regressioonmeetodi kasutamine eeldab aga ettevõtte tegevuse ning tegevusele mõju avaldavate faktorite kindlat teadmist. See tähendab, et peab olema ülevaade makromajanduse ning turunäitajate mõjust ettevõtte tegevusele. Regressioonmudeli kasutamise eelduseks on põhjalik teave ettevõtte väljaspool toimuvast ehk sellest, millised on ettevõttevälised mõjutegurid. Kõik kirjeldatav on aga üsna aega ja raha nõudev protsess, mille väljundiks on omakorda täpsete prognoosimisandmete kättesaamine. Regressioonmeetod ei ole sobilik ettevõtte majandusaasta aruande alamnäitajate prognoosimiseks, nagu näiteks varude süsteemsel prognoosimisel, mis võib sisaldada tuhat ühikunimetust.

3.2. Aegrea kompleksanalüüs

3.2.1. Aegrea kompleksanalüüsi mudeli koostamine

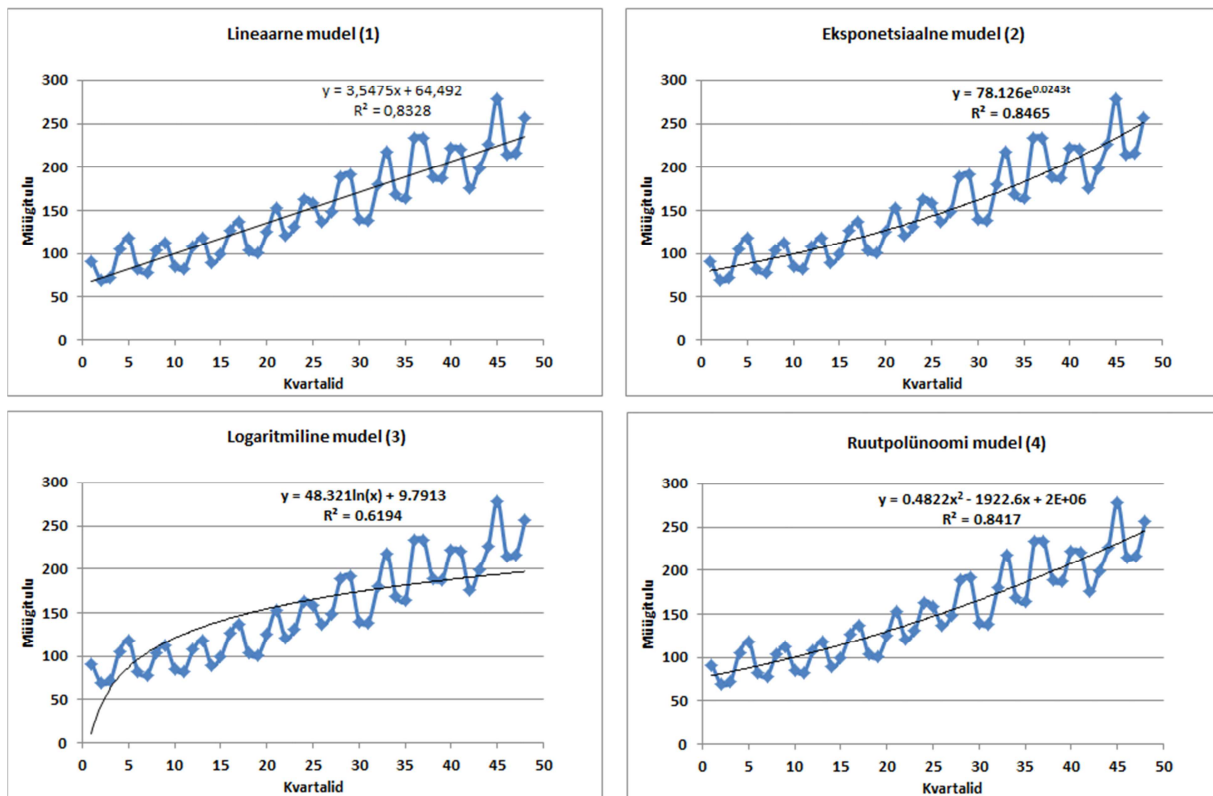
Põhiline aegridade kompleksanalüüsi meetodi mudeli avaldis on esitatud pt 2.4 (vt valem 2.4).

Tsükliline tegur kajastab majanduse või kindla tööstusharu langusi ja tõuse, tavaliselt esineb see rahvamajanduse koguprodukti, tööstustoodangu tootmise indeksi, eluaseme nõudluse, tööstuskaupade müügi (autod), aktsiahindade, võlakirjade intressimäärade, rahapakkumiste ja intressimäärade aegridades (*Ibid.*). Kuna tsükliline tegur ei olnud aegreas tuvastatud, eeldab autor, et C -tegur on võrdne 1-ga.

I - tegur on autori hinnangu järgi samuti võrdne 1-ga. I võib olla 1-st erinev kas kogu või osa prognoositava perioodi jooksul, kui on alust arvata šoki võimalust. Siinkohal võis šokina mõjuda elektrituru avanemine 2013. aastal. Elektrituru avanemine võib suuresti mõjutada ettevõtte müügitulu tulemust, kuid selle mõju väljendamist numbrites enne prognooside koostamist ei osanud autor teha.

Autori järgmine samm on jaotada aegread mitmeks komponendiks.

Pikaajaline trend. Trendi määramiseks kasutab autor regressioonanalüüsi ning leiab eksponentsiaalse, lineaarse, logaritmilise ja ruutpolünoomilise mudeli. Parema mudeli leidmiseks tehakse võrdlus. Mudeli sobivuse hindamiseks kasutab autor determinatsioonikoeffitsienti R^2 . Jooniselt 3.6. on näha, et eksponentsiaalne mudel sobib paremini, kuna determinatsioonikoeffitsient on suurem.



Joonis 3.6. Müügitulu aastatel 2002–2012 (miljonites eurodes, 1 - 2002. aasta I kvartal), silutud lineaarse (1), eksponentsiaalse (2), logaritmilise (3) ja ruutpolünoomilise regressioonjoonega (4)
Allikas: autori koostatud

Trendi valem on $T_i = 78,126e^{0,0243t}$, kus t on kvartali järjekorra number ($t=1$ 2002. aasta I kvartalil).

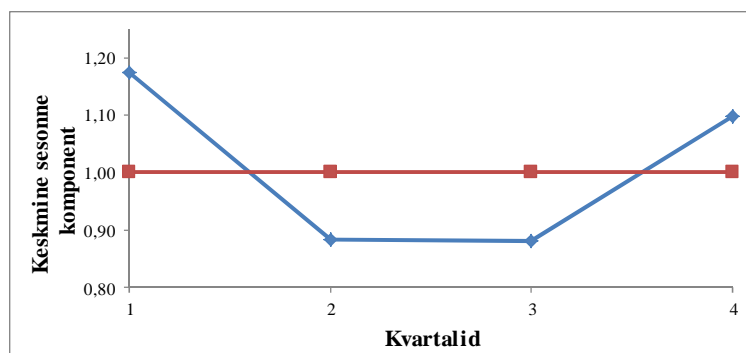
Keskmise sesoonse muutuse leidmiseks grupeerib autor sesoonsed tegurid kvartalite kaupa ja leiab iga kvartali jaoks geomeetrilise keskmise (vt tabel 3.2).

Tabel 3.2. Keskmise sesoonne komponent

Keskmine sesoonne komponent on geomeetriline keskmine	Suhteline erinevus trendist
1,16	16%
0,86	-14%
0,85	-15%
1,06	6%
1,004	

Allikas: Autori arvutused

Multiplikatiivse mudeli valiku õigsus on saanud kinnituse, kuna keskmiste sesoonsete komponentide korrutis, mis on leitud geomeetrilise keskmise abil, on ligikaudu üks.



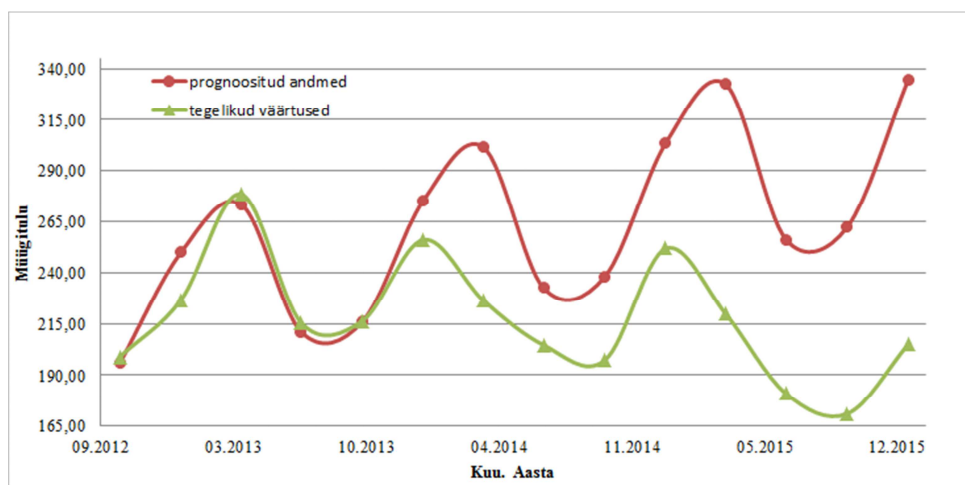
Joonis 3.7. Müügitulu sesoonne muutumine

Allikas: autori koostatud

2002.–2012 aasta kvartalite müügitulu sesoonne geomeetriline keskmine on esitatud Joonisel 3.7., kus müügitulu on kõrgem I ja IV kvartalis.

3.2.2. Aegrea kompleksanalüüsil põhinev prognoos

Peatükis 3.2.1. saadud tulemusi kasutab autor väärtuste prognoosimiseks (vt joonis 3.8 ning lisa 28). Prognoositud väärtuste saamiseks leiab autor algul eksponentsiaalse mudeli põhjal trendi väärtused T ja korrutab need keskmiste sesoonsete komponentidega S . Prognoositud andmed on toodud lisa 28.



Joonis 3.8. Müügitulu dünaamika prognoosimine ja võrdlus vaatlusandmetega
Allikas: autori koostatud

Aegrea kompleksanalüüsil põhineva prognoosi mudeli keskmine viga (ME – *mean error*) iseloomustab prognoosi nihet ning võrdub $-45,30$. Negatiivne väärtus tähendab, et tegelikud väärtused on keskmiselt väiksemad kui prognoositud väärtused, st prognoos ülehindab tegelikkust.

Järeldused. Kuigi mudel on laialt kasutatav, ei ole selle kasutamine soovitatav. Mudeliga seostatakse mõningaid probleeme ning need on järgmised:

- Kompleksanalüüsi meetod eeldab, et sesoonne komponent on igal aastal ühesugune. Paljude aegridade puhul on selline eeldus põhjendatud, kuid pikkade aegridade puhul enamasti mitte. Kompleksanalüüsi meetodi korral ei ole võimalik arvestada aja jooksul toimuvate muutustega sesoonsuses (Classical decomposition ...). Antud väide on kinnitust leidnud ka autori töös, ehk kompleksanalüüsi meetod ei olnud võimeline arvestama avatud turu ning turuhinna languse mõjuga: prognoositud andmed on jätkanud eelnevate aastate kasvu trendi. Kompleksmeetodiga prognoositud tulemused on tunduvalt nihkes tegelikest andmetest ning nihe on seda suurem, mida pikem on prognoositud periood.
- Aegridade väärtused lühikese perioodi väitel võivad olla üsna ebatavalised. Kompleksanalüüsi meetod ei suuda arvestada lühiajaliste äkiliste muudatustega aegreas. (*Ibid.*).

3.3. Prognoosimine trendi ja sesoonsusega eksponentsiaalse silumismeetodiga, Wintersi meetod


Algväärtused eksponent-silumismudelis. Autor sai silumiskonstantide α , β ja γ väärtusteks, mis vastavad minimaalsele keskmisele suhtelisele veale (MAPE – *mean absolute percent error*) järgmised: $\alpha = 0,99$, $\beta = 0,51$ ja $\gamma = 0,001$.

Mudeli algväärtustena on autor valinud:

- lineaarse regressioonimudeli konstandi väärtuses 64,5 – üldise silumise algväärtusena (vt joonis 3.6);
- keskmised sesoonsed komponendid (arvutatud kompleksanalüüsi jaoks, vaata ptk 3.2.1) väärtustes I kv – 1,16, II kv – 0,86, III kv – 0,85, IV kv – 1,06 – sesoonsusega silumise algväärtustena (kokku neli);
- nullväärtuse – trendiga silumise algväärtusena.

Detailsed Wintersi eksponentsilumismeetodi tulemused on toodud lisas 27.

Prognoosimine. Joonis 3.9. kajastab tegelikke ja prognoositud väärtusi. Mudel jälgib täpselt tegelikke väärtusi kuni 2012. aasta III kvartalini.



Joonis 3.9. Wintersi eksponentsiaalne silumine ($\alpha = 0,99$, $\beta = 0,51$ ja $\gamma = 0,001$)
Allikas: autori koostatud

Vigade analüüs. Vigade analüüs on tehtud 9. kuni 42. perioodini:

$$\alpha = 0,99; \beta = 0,51; \gamma = 0,001 \quad \text{RMSE} = 0,71 \quad \text{MAPE} = 2,11 \%$$

Lisas 14 esitatud joonisel on toodud autokorrelatsiooni funktsioon Wintersi eksponentsiaalse silumise jaoks. Ükski autokorrelatsiooni kordajatest ei ole nullist märgatavalt suurem, mis tähendab, et jääkide autokorrelatsioon puudub, jääkide muutused on juhuslikud.

Ljung-Box Q statistik (16 viitaegade jaoks) $< \chi^2$, $Q = 15,83 < 26,30$, kehtib nullhüpotees, autokorrelatsioon puudub (χ^2 kriitiline väärtus on toodud lisa 15, Q statistik – lisa 14).

Wintersi ekponentsiaalne silumismudel annab Eesti Energia müügiandmete jaoks asjakohase prognoosi. Wintersi mudeli keskmine viga (*ME – mean error*) iseloomustab prognoosi nihet ning võrdub 17,10. Positiivne väärtus tähendab, et tegelikud väärtused on keskmiselt suuremad kui prognoositud väärtused, st prognoos alahindab tegelikkust.

3.4. ARIMA-mudel

3.4.1. ARIMA-mudeli lõplik kinnitamine

Peatükis 2.6.2 peatus autor esialgse ARIMA-mudeli valikul:

ARIMA (0,1,1)(0,1,1)⁴ AIC=946 BIC=951

Selline mudel esitab 1. järgu sesoonset ja mittesesonset diferentsi viitajaga 4, mittesesonset libiseva keskmisega komponenti, sesoonset libiseva keskmisega komponenti, kuid autoregressiivsed (mittesesonne ja sesoonne) komponendid on puudu. Aegridade joonis pärast diferentsimist (vt joonis 3.10.) näitab varieerumist nulli ümber ja seetõttu ei olnud konstanti mudelisse kaasatud.

Kuna autor polnud piisavalt kindel mudeli identifitseerimise täpsuse suhtes, siis kasutati alternatiivsete mudelite leidmiseks informatsioonikriteeriumeid. Allpool on toodud mudelid, mis leiti Akaike ja Schwarzzi informatsioonikriteeriumite alusel:

ARIMA (0,1,0)(0,1,1)⁴ AIC 949 BIC 953


ARIMA (1,1,0)(0,1,1)⁴ AIC 948 BIC 954

Informatsioonikriteeriumite alusel on ARIMA (0,1,1)(0,1,1)⁴ mudel tõestatud paremaks, sest AIC ja BIC on väiksemad.

Aegrea statsionaarsuse saavutamine. Logaritmitud andmete diferentsimine. Pärast müügiandmete diferentsimist ei olnud statsionaarsus lõplikult saavutatud (vt joonis 2.3.). Statsionaarsus peab aga olema saavutatud enne ARIMA-mudeliga prognoosimise alustamist.

Peamine lähenemine statsionaarsuse saavutamiseks seisneb aegrea andmete logaritmitumises. Kui statsionaarsus on saavutatud, saab rakendada Box-Jenkinsi metodoloogiat. Juhul, kui see on tehtud enne statsionaarsuse saavutamist, võib saada eksitavaid tulemusi.

Vastavalt peatükis 2.6.2 toodud tulemustele esines diferentsitud mittelogaritmitud aegreas mittestatsionaarsus, kuigi statsionaarsus keskväärtuse suhtes oli saavutatud (vt joonis 2.3.). Joonis 3.10. näitab tulemust, mis on saavutatud, kui töötlemata müügiandmed on esialgselt logaritmitud ning seejärel on võetud sesoonse ja mittesesonse 1. järgu diferentsid (vt lisa 17). Teisendatud aegrida on nüüd statsionaarsem nii keskmise kui ka dispersiooni suhtes.



Joonis 3.10. Logaritmitud müügitulu aegrida pärast 1. järgu sesoonse ja mitteseseoonse diferentsi võtmist

Allikas: autori koostatud

Visuaalsel hinnangul diferentsitud aegrea statsionaarsuse kontrollimiseks viib autor läbi Dickey-Fulleri testi. Testi tulemused on toodud lisa 18.

Dickey-Fulleri test kinnitas, et aegrea jaoks kehtib sisukas hüpotees ($p=0$), aegrida on statsionaarne.

ARIMA-mudeli lõplik kinnitamine. Autor on identifitseerinud sesoonset MA (1) protsessi, kuna r_4 ja r_8 viitajaga koefitsiendid on suured ja määravad, ning esialgne mudeli identifitseerimine on järgmine:

ARIMA (0,1,0)(0,1,1)⁴, logaritmitud aegrea puhul (vaata lisa 30).

ARIMA-mudeli edasine adekvaatsuse hindamine on tehtud ainult Eesti Energia müügitulu logaritmitud andmetega.

3.4.3. Mudeli adekvaatsuse hindamine. Mudeli kontroll

Enne mudeli kasutamist on prognoosimisel oluline hinnata mudeli adekvaatsust:

- uurida jääkliikmeid, saamaks aru, kas on olemas muster, millega ei oldud arvestatud;
- uurida valimi statistikut identifitseeritud mudeli puhul, et uurida mudeli lihtsustamise võimalusi (Makridakis, Wheelwright, McGee 1983).


Jääkliikmete uurimine. Mudelit peetakse adekvaatseks, kui jääkliikmete analüüs ei anna põhjust prognoosi parandamiseks. Teiste sõnadega, jääkliikmed peavad olema juhuslikud (*Ibid.*).

- Üksikud jääkliikmete autokorrelatsioonid peavad olema väikesed ja tavaliselt nullist $\pm 2/\sqrt{n}$ piires. Jääkliikmete autokorrelatsioon viitab mudeli ebaadekvaatsusele ja valida tuleb uus või muudetud mudel.
- Jääkliikmete diagrammid võivad olla koostatud ARIMA-mudeli jaoks. Eriti kasulikud on histogramm ja normaaljaotuse graafik (normaaljaotuse hindamine) ning aegrea joonis (kõrvalekallete kontrolliks) (Hanke, Wichern, 2005).

Jääkide autokorrelatsiooni analüüs. Mudeli adekvaatsuse hindamiseks kasutab autor Ljung-Boxi statistikut, mis allub χ^2 jaotusele. Test uurib jääkide autokorrelatsioonide suurust kogumi lõikes (*Ibid.*).

Ljung-Box Q statistik (16 viitaegade jaoks) $< \chi^2$, $Q = 18,13 < 26,30$, kehtib nullhüpotees, autokorrelatsioon puudub (vt lisa 19).

Normaaljaotuse hindamine. $p = 0,2477 > 0,05$, kehtib nullhüpotees, jääkliikmed alluvad normaaljaotusele (vt joonis 3.11; testi tulemused on toodud lisa 20).



Joonis 3.11. Jääkliikmete normaaljaotuse graafiline analüüs
Allikas: autori koostatud

Järeldused. Jäägid on statsionaarsed keskvaartuse osas ja selles mudelis on statsionaarsed ka dispersiooni osas. Puuduvad suured püsivad amplituudid kogu aegrea sageduste ulatuses.

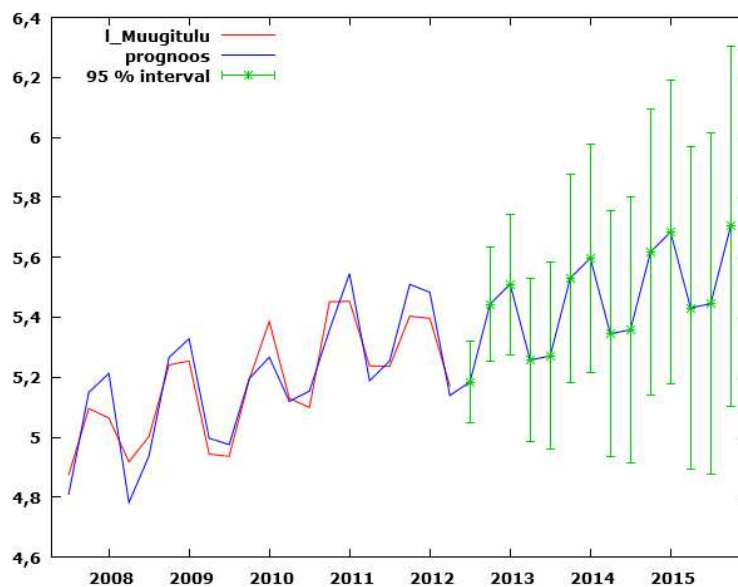
Tuginedes mudeli adekvaatsuse hindamise tulemustele, leidis autor, et mudel on täielikult adekvaatne, ja otsustas mudelil põhinevaid logaritmitud andmeid kasutada müügitulu prognoosimiseks.

3.4.4. Prognoosimine ARIMA-mudeliga

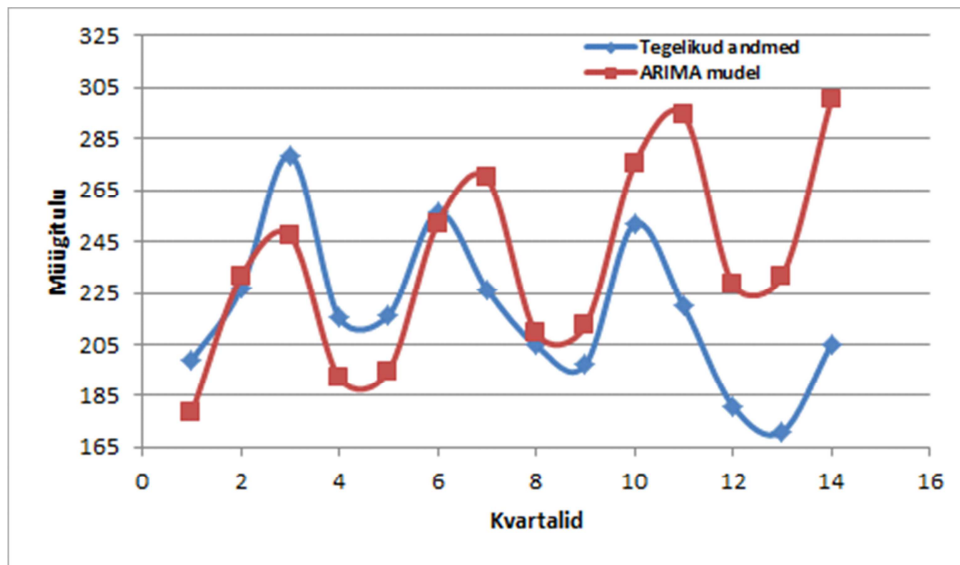
ARIMA (0,1,0)(0,1,1)⁴ logaritmitud andmete mudel on kirjeldatav järgmiselt:

$$(1 - B)(1 - B^4)X_t = (1 - 1_1B^4)e_t$$

Selleks, et kasutada võrrandit prognoosimiseks 1 periood ette, mis on, X_{t+1} , on indeksiks olevat ajamuutujat suurendatud ühe võrra (Makridakis, Wheelwright, McGee, 1983). Prognoositud andmed on toodud lisas 22.



Joonis 3.12. 14 kvartaliks prognoositud müügitulu andmed ARIMA-mudeli rakendamisel
Allikas: autori koostatud



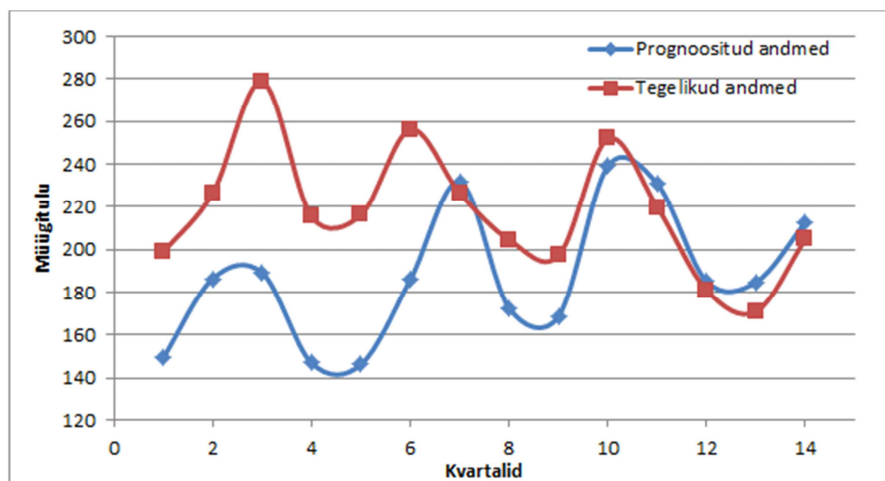
Joonis 3.8. ARIMA-mudeliga prognoositud aegrida (14 kvartalit) koos tegeliku müügitulu andmetega (mln eurot)
Allikas: autori koostatud

Järeldused. The Box-Jenkins on sageli parim prognoosimismeetod väiksemate prognoosimisvigadega paljudes keerulistes olukordades. Puuduseks on aga see, et kasutajalt on nõutav kogemus. Kui prognoositav protsess jääb otsuse tegijale täielikult mõistetamatuks, võib ettevõtte juhtkond prognoositulemusi eirata, sõltumata nende täpsusest (Hanke, Wichern, 2005). ARIMA-mudeli vea tulemust on mõjutanud aastatel 2014–2015 toimunud müügitulu langus, mis on põhjustatud nii madalatest turuhindadest kui ka jaemüügi mahtude vähendamisest tingitud elektrituru avanemisest.

3.5. Prognoosimine naiivse meetodiga

14 kvartali prognoosimiseks on autor kasutanud alusena valemit 2.6, mis omakorda kujunes järgmiseks (prognoositud andmed on toodud lisas 23):

$$\hat{Y}_{t+1} = Y_{t-15} + \frac{Y_{t-12} - Y_{t-16}}{4} \quad (3.5)$$



Joonis 3.9. Ettevõtte tegelik ja modelleeritud müügitulu (mln eurot) (naiivne meetod) aastatel 2012–2015 (14 kvartalit)

Allikas: autori koostatud

Naiivse meetodi kaasas autor võrdluse aluseks teiste prognoosimismeetoditega. Naiivse meetodi keskmine viga (ME – *mean error*) võrdub 29,90. Positiivne väärtus tähendab, et tegelikud väärtused on keskmiselt suuremad kui prognoositud väärtused, st prognoos alahindab tege likkust (vt joonis 3.9.).

3.6. Prognoosimismudelite võrdlus

Nüüd on 2012 aasta kolmanda kvartalist kuni 2015 aasta neljanda kvartalini olemas Eesti Energia viis eri müügi prognoosi. Kui koostatud on viis prognoosi, peab olema leitud mudelite prognoosimisvigade RMSE väärtus ja parim mudel on see, mis annab väiksema vigade summa (Granger 1980).

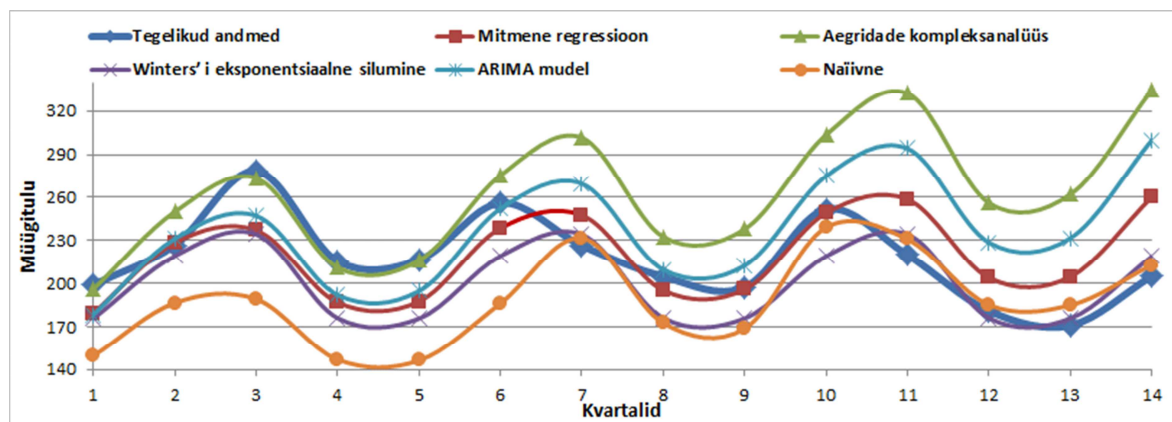
Viie mudeli sobivuse ja täpsuse hindamine on toodud allpool (vt tabel 3.3.):

Tabel 3.3. Prognosimismudelite RMSE

<i>Prognosimismudelid</i>	<i>2012Q3–2015Q4 Prognos (täpsus), Ruutkeskmine viga</i>
Mitmene regressioon	27,8
Aegridade kompleksanalüüs	62,8
Wintersi eksponentsiaalne silumine	26,8
ARIMA-mudel	42,8
Naiivne	45,5

Allikas: autori arvutused

Prognositud müügitulu koondandmetest ülevaate saamiseks on autor koostanud joonist (vt joonis 3.10.).



Joonis 3.10. Mudelite prognoositud koondandmed (müügitulu mln eurodes) aastatel 2012–2015 (14 kvartalit)

Allikas: autori koostatud

Tabel 3.4. Mudelite prognoositud koondandmed

Kvartaalsed andmed \ prognoosi meetodid	Tegelikud andmed	Mitmene regressioon	Aegridade kompleksanalüüs	Wintersi eksponentsiaalne silumine	ARIMA-mudel	Naiivne
III.2012	198,90	179,40	195,88	175,69	178,42	149,61
IV.2012	226,60	228,31	249,95	219,01	231,15	186,45
I.2013	278,60	237,07	273,68	234,20	247,22	189,08
II.2013	215,40	186,80	210,94	175,97	191,98	147,00
III.2013	216,30	187,41	215,88	175,69	194,63	146,38
IV.2013	256,10	238,50	275,47	218,95	252,14	186,09
I.2014	226,40	247,65	301,62	234,10	269,68	231,59
II.2014	204,60	195,14	232,48	176,02	209,42	172,60
III.2014	197,20	195,78	237,91	175,79	212,30	168,78
IV.2014	251,80	249,15	303,59	218,84	275,04	239,10
I.2015	219,80	258,71	332,41	234,26	294,17	230,78
II.2015	181,00	203,85	256,21	176,05	228,44	185,08
III.2015	171,00	204,52	262,20	175,80	231,58	184,83
IV.2015	204,90	260,27	334,58	218,78	300,02	212,63

Allikas: autori arvutused

2013. aastal soodustas elektri hulgemüügi mahu kasvu peamiselt kõrgem keskmine turuhind, mis kasvas võrreldes 2012. aastaga 9,6%. Elektri jaemüügi mahtude vähenemine tuleneb Eesti elektrituru täielikust avanemisest 2013. aasta alguses. Turu avanemisega kaasnes seni valdavalt monopoolses seisus olnud Eesti Energiale ootuspärane klientide arvu ja turuosa vähenemine (AS Eesti Energia 2013. a majandusaasta aruanne).

Kontserni 2014. aasta müügitulude langus tulenes peamiselt madalamast elektrienergia müügitulust, mille põhjuseks oli müügi mahu vähenemine. Elektri müügimaht langes peamiselt jaeturu vähenenud turuosa mõjul. Elektri müügile avaldasid mõju ka madalad turuhinnad (AS Eesti Energia 2014. a majandusaasta aruanne), mis on toonud kaasa väiksema elektritootmise (Vahearuanne 2014). Elektri jaemüügi mahtude vähenemine tuleneb 2014. aasta alguses toimunud muutustest Eesti suurklientide segmendis ning I kvartali tavapärasest soojematest ilmadest. Jaanuari alguses vahetasid oma elektrimüüjat mõned olulise elektritarbimisega ettevõtted, kelle aastane tarbimismaht moodustab olulise osa kogu Eesti elektri tarbimisest (Vahearuanne 2014).

Kontserni müügitulu mõjutasid 2015. aastal enim soojadest ilmadest tingitud väiksem elektritarbimine ja rekordmadalad elektri hinnad (Vahearuanne 2014).

Ülaltoodud informatsiooni alusel järeltab autor, et vastavalt mudelite ruutkeskmise vea tulemusele on mitmese regressiooni ning Wintersi eksponentsiaalse silumise prognoositud väärtused olnud kõige lähedasemad tegelikele väärtustele ning prognoosi kõrvalekalde nihe on nende mudelite puhul kõige väiksem.

Eesti Energia müügitulule aastatel 2014–2015 on osutanud negatiivset mõju nii madalad turuhinnad kui ka jaemüügi mahtude vähendamine, mis on tingitud elektrituru avanemisest. Elektrituru avanemise mõju müügitulemustele oli oodata, kuid selle mõju väljendamist numbrites enne prognooside koostamist ei osanud autor teha. Prognoosi koostamise abil on nii madalamate turuhindade kui ka elektrituru avanemise koosmõju numbriline väljend aga teada ja vastavalt lineaarse regressiooni analüüsile on see mõju olnud –10,83% trendi kahanemise muutuste tõttu aastatel 2013–2015 (vt lisa 3).

Võrdselt mitmese regressiooniga on häid tulemusi näidanud nii Wintersi eksponentsiaalne silumismeetod kui ka ARIMA-mudel.

Olukorras, kus on vaja koostada lühiajalist prognoosi mitme eri kirje jaoks, kasutatakse enam silumismeetodit. Meetodi suurim eelis on selle madal kulukus ja lihtsus. See võib olla mitte nii täpne kui kõrgetasemelised meetodid, nt ARIMA-mudel, kuid kui prognoosimised on vajalikud varude süsteemide jaoks, mis hõlmavad tuhat nimetust, on silumismeetod sageli ainus mõistlik lähenemine (Makridakis, Wheelwright, McGee 1983).

Box-Jenkinsi metodoloogia on võimas vahend täpsete ja lühiajaliste prognooside koostamiseks. Rahuldava ARIMA-mudeli koostamine Box-Jenkinsi meetodi järgi nõuab piisavalt pikalt aegrea andmeid ja analüütiku pikaajalist tööd (Hanke, Wichern, 2005).

Regressioonanalüüs on võimas ja mitmekülgne vahend, et uurida omavahelisi seoseid sõltuvate ja mitmete sõltumatute muutujate vahel. Sellise analüüsi eesmärk on paremini mõista ja kontrollida nii oleviku sündmusi kui ka paremini ennustada tuleviku sündmusi (Hanke, Wichern, 2005).

KOKKUVÕTE

Prognoosides tulevikku müüki ja muid olulisi majanduslikke või ärimuutujaid, ei ole enam õigustatud tuginedes üksnes intuitsioonile või kellegi „olukorra tundmisele“. Organisatsiooni kliima on keerulisem, kiiresti arenevam ja konkurentsivõimelisem kui kunagi varem. Organisatsioonid, kes ei reageeri kiiresti muutuvatele tingimustele ega kavanda tulevikku, on määratud hääbumisele.

Kõiki ettevõtteid mõjutavad kolm tegevusvaldkonna tasandit: makromajandus, oma tööstusharu ja ettevõtte ise. Tavaliselt saab ettevõtte kontrollida ainult viimast. Seega on väga oluline, et ettevõtte oleks teadlik väljaspool ettevõtet toimuvast.

Tugineda üksnes intuitsioonile või kellegi „olukorra tundmisele“, prognoosides tuleviku müüki, varude vajadust, personali nõudmisi ja muid olulisi majanduslikke või ärimuutujaid, ei ole enam õigustatud. Kvantitatiivsete meetodite abil on võimalik saada parem prognoositulemus.

Aegridade prognoosimine toetub eeldusele, et tulevik on sama mis olevik ning et mineviku aegrea mustrit on võimalik adekvaatselt kirjeldada. Aegrea prognoosimismeetodid on rohkem kasulikud muutujate prognoosimiseks, mis aja jooksul kõiguvad stabiilse mustri järgi.

Arvestades trendi ja sesoonsusega aegrea andmetes on autor kasutanud magistritöös Eesti Energia müügitulu prognoosimiseks järgmisi meetodeid:

- mitmene regressioon;
- aegrea kompleksanalüüs;
- eksponentsiaalne silumine;
- ARIMA-mudelid (Box-Jenkinksi meetod);
- naiivne prognoosimine.

Vastavalt prognooside ruutkeskmise vea väärtustele on Wintersi eksponentsiaalne silumise ning mitmese regressiooni prognoositud väärtused olnud kõige lähedasemad tegelikele väärtustele, prognoosi kõrvalekalde nihe on selle mudeli puhul kõige väiksem. Võrdselt mitmese reg-

ressiooniga ning Wintersi eksponentsiaalse silumismeetodiga on häid tulemusi näidanud ka ARIMA-mudel. ARIMA-mudeli vea tulemust on mõjutanud aastatel 2014–2015 toimunud müügitulu langus, mis on põhjustatud nii madalatest turuhindadest kui ka jaemüügi mahtude vähenemisest tingitud elektrituru avanemisest.

Regressioonanalüüs on tõhus arvutusmeetod ja enamkasutatav prognoosimisviis. Regressioonmeetodi kasutamine eeldab aga ettevõtte tegevuse ning tegevusele mõju avaldavate tegurite kindlat tundmist. Selleks peab olema ülevaade ettevõtte tegevuse makromajanduslike näitajate sõltuvusest ning ettevõtte opereeritavast turust. Regressioonmudeli kasutamise eeldus on põhjalik teadmine ettevõttest väljaspool toimuvast ehk mis on ettevõtte kontrollala väljastpoolt. Kõik kirjeldatav on aga üpris aega ja raha nõudev protsess, mille väljundiks on omakorda täpsete prognoosimisandmete kättesaamine. Regressioonmeetod ei sobi ettevõtte majandusaasta aruande alamnäitajate prognoosimiseks, nagu näiteks varude süsteemne prognoosimine, mis võib sisaldada tuhat ühikunimetust.

Box-Jenkinsi meetod on sageli parim prognoosimismeetod väiksemate prognoosimisvigadega paljudes keerulistes olukordades. Puudus on aga see, et kasutajal on vaja kogemust. Kui prognoosimisprotsess on otsuse tegijale täielikult mõistetamatu, võib ettevõtte juhtkond prognoositulemusi, sõltumata nende täpsusest, eirata.

Eksponeentsiaalse silumise meetod võib anda sama häid tulemusi kui autoregressiivsed mudelid ning see on ka võimeline võistleva ARIMA-meetoditega täpsuse poolest. Silumismeetodit kasutatakse enam olukorras, kus on vaja koostada lühiajalist prognoosi mitme eri kirje jaoks. Meetodi suurim eelis on selle madal kulukus ja lihtsus. See võib olla mitte nii täpne kui kõrgtasemelised meetodid, nagu näiteks ARIMA-mudelid. Kui prognoosimised on vajalikud varude süsteemide jaoks, mis hõlmavad tuhat nimetust, on silumismeetod sageli ainus mõistlik lähenemine.

Parima prognoosimismudeli valimine on erinevate olukordade ning paljude meetodite olemasolu tõttu raske ülesanne. Prognoosimismeetodi valimisel peetakse kõige olulisemaks kriteeriumiks täpsust. Üldiselt ei ole olemas otsest seost meetodi täpsuse ja keerukuse vahel. Lihtsad meetodid võivad anda paljudel juhtudel sama hea tulemuse. Prognoosi kasutajad ei pea kalduma kõige keerulisema või kõrgmatemaatilise meetodi poole, kuni nad on kindlad, et tulemused on paremad kui lihtsate meetodite puhul, mis on rakendamisel kergemad ning vähem kulukad.

Üks olulisi järeldusi, milleni autor töö kirjutamisel jõudis, on see, et parema prognoosi koostamiseks on vajalik kasutada juhtkonnapoolset hinnangut koos kvantitatiivsete meetoditega. Hea juhtkonna hinnang on tegelikkuses väga vajalik. Tõestuseks on selle magistritöö *ARIMA*-mudeli täpsus, mis koos juhtkonnapoolse hinnanguga oleks saavutanud palju parema täpsusega tulemuse.

Kui prognoosidest oodatakse täpsust, arusaadavust ning ettevõtte juhtide poolt kasutamist, tuleb tarvitada kvantitatiivseid meetodeid, toetudes seejuures tervele mõistusele.

VIIDATUD ALLIKAD

About Solver. <http://office.microsoft.com/en-us/excel-help/about-solver-HP005198368.aspx> (08.08.2014)

An Examination of the Use of Adaptive Filtering in Forecasting Steven C. Wheelwright and Spyros Makridakis.
<http://www.jstor.org/discover/10.2307/3008035?uid=2&uid=4&sid=21104653264983> (04.06.2014)

Analyses of Energy Supply Options and Security of Energy Supply in the Baltic States. (February 2007). International Atomic Energy Agency.
https://www.ttu.ee/public/m/Mehaanikateaduskond/Instituudid/soojustehnika-instituut/oppematerjalid/MST_9040_Analyses_Vienna_2007.pdf (11.08.2014)

Anderson D. R., Sweeney D. J., Williams T. A. (1996). Statistics for Business and Economics. United States of America: West Publishing Company.

Brooks C. (2008). Introductory Econometrics for Finance. United States of America: Cambridge University Press.

Classical decomposition. <https://www.otexts.org/fpp/6/3> (09.02.2016)

Europe Brent Spot Price FOB (Dollars per Barrel). U.S. Energy Information administration.
<http://www.eia.gov/dnav/pet/hist/LeafHandler.ashx?n=pet&s=rbrte&f=d> (11.08.2014)

Elsport prices. Nord Pool. <http://www.nordpoolspot.com/Market-data1/Elsport/Area-Prices/ALL1/Hourly/> (11.08.2014)

Elektrihinna mõjurid. Elering. <http://elering.ee/elektrihinna-mojurid/> (05.04.2014)

Eesti elektrisüsteemi varustuskindluse aruanne. (2013). Elering AS

Fight A. (2006). Cash flow forecasting. Great Britain: Elsevier Butterworth-Heinemann.

Gardner E. S. Exponential Smoothing: The State of the Art. Journal of Forecasting. Vol. 4. 1–28. (1985).

Granger C.W.J. (1980). *Forecasting in Business and Economics*. United Kingdom: Academic Press, Inc.

Griffiths W.W., Carter Hill R., Judge G.G. (1993), *Learning and practicing econometrics*. New York: John Wiley & Sons, Inc.

Global Europe Brent Spot Price. OANDA. <http://fxtrade.oanda.com/analysis/economic-indicators/global/commodities/europe-brent-spot-price> (11.08.2014)

Gujarati D. (1992). *Essentials of econometrics*. United States of America: McGraw-Hill.

Gujarati D.N., Dawn C.P. (2009). *Basic Econometrics*. 5th edition. United States of America: McGraw-Hill Companies.

Hanke J. E., Wichern D. W. (2005). *Business forecasting*. USA: Pearson Education.

Heteroscedasticity.

http://support.sas.com/documentation/cdl/en/etsug/60372/HTML/default/viewer.htm#etsug_model_sect043.htm (04.06.2014)

Heteroscedasticity. <http://www3.nd.edu/~rwilliam/stats2/l25.pdf> (04.06.2014)

Holden K., Peel D.A, Thompson J.L. (1990). *Economic forecasting: an introduction*. United Kingdom: Cambridge University Press.

Hoang Diem Ngo T. (2012) *The Steps to Follow in a Multiple Regression Analysis*. – *SAS Global Forum*, 2012, La Puente, CA, USA.

<http://support.sas.com/resources/papers/proceedings12/333-2012.pdf>

Karu S., Zirnask V. (2004). *Eelarvestamine – üks strateegilise controllingu juurutamise eeldusi organisatsioonis*. Tartu: Rafiko Kirjastus.

Keskkond. <https://www.energia.ee/keskkond> (11.08.2014)

Keskkonnaaruanne. (2010, 2014). Eesti Energia AS.

Majandusaasta aruanne. (2002-2015). AS Eesti Energia.

Multiple regression. <http://www.statstutor.ac.uk/resources/uploaded/multiple-regression.pdf> (01.05.2014)

Multicollinearity in Regression Models

<http://sites.stat.psu.edu/~ajw13/SpecialTopics/multicollinearity.pdf> (20.06.2014)

Makridakis S., Wheelwright S. C., McGee V. E. (1983). Forecasting: methods and applications. 2nd ed. United States of America: John Wiley & Sons.

Statistika andmebaas: <http://pub.stat.ee/px-web.2001/dialog/statfile2.asp>

KRT. Mõisted: <http://pub.stat.ee/px-web.2001/Database...012.htm>

TTTHI: http://pub.stat.ee/px-web.2001/database/Majandus/04Hinnad/IA_039.htm

THI: http://pub.stat.ee/px-web.2001/Database/Majandus/04Hinnad/IA_01.htm (11.08.2014)

Trehan M., Trehan R. (2010). Advertising and Sales Management. India: printed at: Neekunj Printers (published by: V.K. Enterprises).

Truhanov, Ave. Keskkonnaagentuuri teabeosakonna klienditeeninduse peaspetsialist. Meteoandmed. E-kiri koos excel failiga. (21.10.2014).

The climate database of the Norwegian Meteorological Institute, MET Norway, eklima.no, ÅNGÅRDSVATNET station, Precipitation (RR)

Vaarmann, M. Eesti Energia Elektrituru ülevaade, detsember (detsember) 2013.

https://www.energia.ee/-/doc/10187/pdf/services/turuylevaade_detsember2013.pdf (07.08.2014)

Vaarmann, M. Eesti Energia Elektrituru ülevaade, detsember (november) 2013.

https://www.energia.ee/-/doc/10187/pdf/services/turuylevaade_november2013.pdf (07.08.2014)

Vaarmann, M. Eesti Energia Elektrituru ülevaade, 2014.

https://www.energia.ee/-/doc/10187/pdf/services/turuylevaade_.....pdf (12.08.2015)

Vahearuaanded. (1. jaanuar 2012 – 30. september 2015). Eesti Energia AS.

Wilson J. H., Keating B. (1994). Business Forecasting. 2nd edition. United States of America: Richard D. Irwin.

Ülevaade Eesti Energiast. <https://www.energia.ee/et/organisatsioon> (11.08.2014)

SUMMARY

BUILDING SALES FORECASTING MODELS WITH USE OF QUANTITATIVE METHODS (ON EESTI ENERGIA AS EXAMPLE)

Natalja Nešumajeva

To rely solely on intuition, or one's „feel for the situation,“ in projecting future sales and other important economic or business variables is no longer reasonable. An organizational climate is more complex, fast-paced, and competitive than ever before. Organizations that cannot react quickly to changing conditions and cannot foresee the future with any degree of accuracy are doomed to extinction. Quantitative methods have been shown to be helpful in making better predictions about the future course of events.

The Master paper's object is to build a sales forecasting models for Eesti Energia AS, check of models adequacy, and based on the fit and accuracy of the models to choose the best forecasting model.

For building forecasting models were chosen a quater data starting from year 2002–2015. For evaluating the accuracy and fit of the models was used the period from third quarter 2012 till 2015 year end and the root mean square error estimator. By author was made out-of-sample models forecast evaluation.

Taking into account that sales series has trend and seasonal pattern, author have used following techniques for forecasting seasonal series:

- multiple regression;
- classical decomposition;
- Winter's exponential smoothing;

- ARIMA-model (Box-Jenkins methodology);
- Näive model.

According to root mean square error of forecasted data, Winter's exponential smoothing and multiple regression forecasted data are the closest to actual data, forecasting errors are the smallest for that methods. ARIMA model accuracy was affected by decline in sales on 2014–2015 years, what was due to low market prices and decrease in retail sales volume because of opening electricity market.

Multiple regression analysis is a powerful and most used forecasting method. Use of multiple regression assumes to possess the knowledge of company operations and knowledge of factors affecting its business. The main assumption of multiple regression is an overview of factors affecting company but what are outside of company's control area. Multiple regression is not appropriate for forecasts of inventory systems containing thousands of items.

The Box-Jenkins is often superior forecasting method, producing lower forecasting errors in many complex situations. The disadvantage is that some sophistication is required on the part of the user. If the process that generates the forecasts is totally mysterious to the decision maker, the forecasts may be disregarded in the management of the organization regardless of their precision.

Winters exponential smoothing method can give the same good results as autoregressive models, and can compete with accuracy of ARIMA-models. The techniques that are used most frequently in the situation, when there is a need to prepare a short-term forecasts for a number of different items – are the smoothing methods. The major advantage of exponential smoothing is its low cost and simplicity. It may not be as accurate as more sophisticated methods, such as general ARIMA modeling. However, when forecasts are needed for inventory systems containing thousands of items, smoothing methods are often the only reasonable approach.

Selecting an appropriate forecasting method is a difficult task due to the variety of situations and the large number of techniques available. The accuracy is considered the most important criteria in selecting forecasting method. In general, there is not a direct link between the sophistication of a forecasting method and its accuracy. Simple methods can do as well in a wide variety of cases. Forecasting users should not, therefore, opt for the most difficult or mathemati-

cally sophisticated methods before they are sure that the results are better than those of simpler methods which are easier to apply and much less costly to use.

One main conclusion to what the author has come to is that in order to achieve more accurate forecasts - a managerial evaluation is needed to be used when forecasting with quantitative methods. The evidence to that is the accuracy result of the ARIMA-model in the author's master work, that if used along with managerial estimation could have obtained the more better results.

LISAD

Lisa 1. Kasutatud lühendid, sõnastik ja mõisted

Sõnastik

adaptive filtering – adaptiivne filtreerimine

backcasting – lineaarse trendi pikendamine

building a model – mudeli koostamine

combination of pairs of variables – muutujate paarikombinatsioonid

decomposition method – aegridade kompleksanalüüs

faktor – sõltuv muutuja

generalized reduced gradient – Taandatud üldistatud gradient

lag – viitaeg

regressor – argumentsuurus

seasonal index – sesoonne komponent

seasonal factor – sesoonne faktor

simple correlation coefficients – lihtsad korrelatsioonikordajad

time series data – aegrida

variable – sõltumatu muutuja (tunnus)

variance – dispersioon

Mõisted

Elspot – töötab oksjonina, kus tunnilised turuhinnad kalkuleeritakse kell 12.00 CET energia kohaletoometamiseks järgmisel päeval (Elspot prices ...).

Euroopa “Brent Spot” hind – toornafta liik, mida kasutatakse nafta hindade mõõdepuuna. Seda kasutatakse maailma kahe kolmandiku rahvusvaheliselt kaubeldava toornafta varude hinnastamisel. (Global Europe Brent Spot Price ...).

Kogurahvatulu (KRT) – sisemajanduse koguprodukt pluss mitteresidentidelt saadud esmased tulud miinus mitteresidentidele makstavad esmased tulud. KRT on riigi majandussektorite kogu esmaste tulude bilansside summa mõõdetuna mingi perioodi (enamasti aasta) kohta (Statistika andmebaas ...).

Tarbijahinnaindeks – indeks, mis iseloomustab tarbekaupade ja tasuliste teenuste hindade muutust (Statistika andmebaas ...).

Tööstustoodangu tootjahinnaindeks – indeks, mis iseloomustab Eestis valmistatud tööstustoodete hindade muutust. Tootjahinnaindeks hõlmab nii kodumaisele turule kui ka mittekodumaisele turule valmistatud tööstustooteid (Statistika andmebaas ...).

Nomenklatuur

AIC	-	Akaike informatsioonikriteerium
ARIMA	-	autoregressiivne integreeritud libiseva kesmine mudel
R^2	-	determinatsioonikordaja
R_a^2	-	korrigeeritud determinatsioonikordaja
SIC	-	Schwarzi informatsioonikriteerium


Lisa 2. Korrelatsioonimaatriks

Correlation coefficients, using the observations 2002:1 - 2012:2
5% critical value (two-tailed) = 0,3044 for n = 42


Muugitulu	THI	Ohutempera- tuur	SKPkorri- geeritud	SKP	
1,0000	0,8905	-0,3800	0,7652	0,7279	Muugitulu
	1,0000	0,0097	0,8847	0,8768	THI
		1,0000	0,0365	0,1192	Ohutemperatuur
			1,0000	0,9897	SKPkorregeeritud
				1,0000	SKP
KRTkorri- geeritud	KRT	Tootusemaar	Toohoi- vemaar	Elspot	
0,7737	0,7312	0,3481	0,1620	0,6287	Muugitulu
0,8941	0,8835	0,2636	0,3169	0,5297	THI
0,0365	0,1293	-0,1523	0,1977	-0,2279	Ohutemperatuur
0,9977	0,9853	-0,1606	0,6743	0,4604	SKPkorregeeritud
0,9891	0,9972	-0,1683	0,6785	0,4425	SKP
1,0000	0,9893	-0,1421	0,6638	0,4716	KRTkorregeeritud
	1,0000	-0,1503	0,6684	0,4527	KRT
		1,0000	-0,8061	0,2318	Tootusemaar
			1,0000	0,1230	Toohoivemaar
				1,0000	Elspot
Brentspot- price	Sademed	TTTHI	Sademed- Norra	Tuul- ekiirusKun- da	
0,7301	0,0254	0,8678	0,1375	0,1276	Muugitulu
0,8700	0,1890	0,9383	0,1270	-0,1468	THI
0,0799	0,4563	-0,0327	0,1400	-0,5855	Ohutemperatuur
0,8936	0,1562	0,6863	0,1805	-0,0930	SKPkorregeeritud
0,8891	0,2085	0,6801	0,1477	-0,1158	SKP
0,8910	0,1641	0,7047	0,1745	-0,1069	KRTkorregeeritud
0,8837	0,2242	0,6956	0,1434	-0,1332	KRT
-0,0405	0,0159	0,5322	-0,0919	-0,1339	Tootusemaar
0,5188	0,1349	0,0260	0,1630	-0,0049	Toohoivemaar
0,5282	-0,0397	0,4833	-0,1245	-0,0792	Elspot
1,0000	0,1454	0,6849	0,1695	-0,2024	Brentspotprice
	1,0000	0,1856	0,3623	0,0715	Sademed
		1,0000	0,0817	-0,1586	TTTHI
			1,0000	0,1285	SademedNorra
				1,0000	TuulekiirusKunda

TuulekiirusVirtsu	Tuulekiirus-Sorve	Tuulekiirus-Pakri	TuulekiirusKeskmine	
0,0432	0,3263	0,4347	0,2955	Muugitulu
-0,1070	0,1087	0,2701	0,0743	THI
-0,3565	-0,4653	-0,4605	-0,5138	Ohutemperatuur
0,0001	0,1577	0,4304	0,1750	SKPkorreeritud
-0,0067	0,1405	0,4008	0,1529	SKP
-0,0224	0,1496	0,4174	0,1606	KRTkorreeritud
-0,0292	0,1286	0,3830	0,1348	KRT
-0,2907	-0,1210	-0,2884	-0,2194	Tootusemaar
0,1733	0,1581	0,4068	0,2187	Toohoivemaar
-0,1667	0,0409	0,1404	0,0120	Elspot
-0,0920	0,0724	0,2918	0,0582	Brentspotprice
0,1214	0,2324	0,1525	0,1724	Sademed
-0,1805	0,0525	0,1371	-0,0050	TTHI
0,1772	0,3089	0,2750	0,2626	SademedNorra
0,8864	0,8744	0,6992	0,9296	TuulekiirusKunda
1,0000	0,8204	0,6509	0,8897	TuulekiirusVirtsu
	1,0000	0,7591	0,9552	TuulekiirusSorve
		1,0000	0,8734	TuulekiirusPakri
			1,0000	TuulekiirusKeskmine

Lisa 3. Elektrituru avatuse mõju hinnang



Joonis 1. Eesti Energia müügitulu lineaarne regressioon 2012. aasta lõpuni.



Joonis 2. Eesti Energia müügitulu lineaarne regressioon 2015. aasta lõpuni.

Lisa 4. Eesti Energia müügitulu andmete autokorrelatsiooni funktsioon

Eesti Energia müügitulu andmete autokorrelatsiooni funktsioon

LAG	ACF		PACF		Q-stat.	[p-value]
1	0,836	***	0,836	***	40,5754	[0,000]
2	0,6845	***	-0,0478		68,2912	[0,000]
3	0,7422	***	0,6076	***	101,4989	[0,000]
4	0,8132	***	0,1616		142,149	[0,000]
5	0,6839	***	-0,3368	**	171,4779	[0,000]
6	0,5384	***	-0,1066		190,023	[0,000]
7	0,5997	***	0,2702	**	213,5128	[0,000]
8	0,6388	***	-0,2291	*	240,7287	[0,000]
9	0,4986	***	-0,1332		257,6703	[0,000]
10	0,3515	***	-0,1078		266,2776	[0,000]
11	0,3859	***	0,0198		276,888	[0,000]
12	0,4308	***	0,0185		290,4196	[0,000]
13	0,2813	**	-0,2085		296,326	[0,000]
14	0,1475		0,0408		297,9898	[0,000]
15	0,1819		0,0133		300,5837	[0,000]
16	0,2153		-0,0739		304,3099	[0,000]

Lisa 5. Mitmese regressiooni mudeli parameetrite hinnangud

Model 1: OLS, using observations 2002:1-2012:2 (T = 42)

Dependent variable: l_Muugitulu

	<i>Coefficient</i>	<i>Std. Error</i>	<i>t-ratio</i>	<i>p-value</i>
const	4,35214	0,367556	11,8407	<0,00001 ***
Ohutemperatuur	-0,0111597	0,00151079	-7,3866	<0,00001 ***
KRTkorrigeeritud	0,000304793	3,8562e-05	7,9040	<0,00001 ***
Toohoivemaar	-0,0184506	0,00653495	-2,8234	0,00799 ***
TTTHI	0,00635963	0,00120536	5,2761	<0,00001 ***
Elspot	0,00314399	0,000755542	4,1612	0,00021 ***
SademedNorra	0,000999463	0,000360931	2,7691	0,00915 ***
TuulekiirusKunda	0,144184	0,0429793	3,3547	0,00201 ***
TuulekiirusVirtsu	-0,108596	0,046643	-2,3282	0,02617 **
Mean dependent var	4,885226	S.D. dependent var		0,340436
Sum squared resid	0,084087	S.E. of regression		0,050479
R-squared	0,982304	Adjusted R-squared		0,978014
F(8, 33)	228,9798	P-value(F)		1,23e-26
Log-likelihood	70,88965	Akaike criterion		-123,7793
Schwarz criterion	-108,1403	Hannan-Quinn		-118,0470
rho	0,383876	Durbin-Watson		1,231574

Lisa 6. Mudeli kirjeldusvõime analüüs

Analysis of Variance:

	Sum of squares	df	Mean square
Regression	4,66768	8	0,58346
Residual	0,0840869	33	0,00254809
Total	4,75177	41	0,115897

$$R^2 = 4,66768 / 4,75177 = 0,982304$$

$$F(8, 33) = 0,58346 / 0,00254809 = 228,98 \text{ [p-value } 1,23e-026]$$

Lisa 7. Jääkliikmete statistilised parameetrid

Null hypothesis: population mean = 0

Sample size: $n = 42$

Sample mean = $-4,44089e-016$, std. deviation = $0,0452869$

Test statistic: $t(41) = (-4,44089e-016 - 0)/0,00698791 = -6,3551e-014$

Two-tailed p-value = 1

(one-tailed = 0,5)

Lisa 8. Jääkliikmete normaaljaotuse test

Test for normality of residuals:


Doornik-Hanseni test = 0,796215, with p-value 0,67159

Shapiro-Wilk W = 0,97597, with p-value 0,511599

Lillieforsi test = 0,113781, with p-value \approx 0,18

Jarque-Bera test = 0,935771, with p-value 0,626325

Lisa 9. Doornik-Hanseni test ja jääkide histogramm koos normaaljaotuskõvera



Tabel. Normaaljaotuse testi tulemused.

Test for normality of residual -

Null hypothesis: error is normally distributed

Test statistic: Chi-square(2) = 0,796215

with p-value = 0,67159

Lisa 10. White'i heteroskedastiivsuse test

White's test for heteroskedasticity -

Null hypothesis: heteroskedasticity not present

Test statistic: $LM = 14,2603$

with p-value = $P(\text{Chi-square}(16) > 14,2603) = 0,579328$

Lisa 11. Korrelatsioonianalüüs

Correlation coefficients, using the observations 2002:1 - 2012:2
5% critical value (two-tailed) = 0,3044 for n = 42

l_Muugitulu	Ohutemperatuur	KRTkorrigeeritud	Toohoivemaar	TTTHI	
1,0000	-0,3804	0,8156	0,2280	0,8463	l_Muugitulu
	1,0000	0,0365	0,1977	-0,0327	Ohutemperatuur
		1,0000	0,6638	0,7047	KRTkorrigeeritud
			1,0000	0,0260	Toohoivemaar
				1,0000	TTTHI
	Elspot	Sademed-Norra	TuulekiirusKunda	TuulekiirusVirtsu	
	0,6254	0,1364	0,1322	0,0427	l_Muugitulu
	-0,2279	0,1400	-0,5855	-0,3565	Ohutemperatuur
	0,4716	0,1745	-0,1069	-0,0224	KRTkorrigeeritud
	0,1230	0,1630	-0,0049	0,1733	Toohoivemaar
	0,4833	0,0817	-0,1586	-0,1805	TTTHI
	1,0000	-0,1245	-0,0792	-0,1667	Elspot
		1,0000	0,1285	0,1772	SademedNorra
			1,0000	0,8864	TuulekiirusKunda
				1,0000	TuulekiirusVirtsu

Lisa 12. Dispersiooni inflatsioonitegur

Variance Inflation Factors

Minimum possible value = 1.0

Values > 10.0 may indicate a collinearity problem

Ohutemperatuur	2,316
KRTkorrigeeritud	13,19
Toohoivemaar	6,88
TTTHI	6,831
Elspot	1,623
SademedNorra	1,182
TuulekiirusKunda	8,305
TuulekiirusVirtsu	6,566

$VIF(j) = 1/(1 - R(j)^2)$, where $R(j)$ is the multiple correlation coefficient

between variable j and the other independent variables

Properties of matrix $X'X$:

1-norm = 4,5512559e+008

Determinant = 6,9149959e+026

Reciprocal condition number = 4,0134369e-011

Lisa 13. RESET-test

Auxiliary regression for RESET specification test

OLS, using observations 2002:1-2012:2 (T = 42)

Dependent variable: l_Muugitulu

	coefficient	std. error	t-ratio	p-value

const	-5,95708	49,4122	-0,1206	0,9048
Ohutemperatuur	0,0252777	0,201465	0,1255	0,901
KRTkorrigeeritud	-0,000731511	0,00551507	-0,1326	0,8953
Toohoivemaar	0,0437503	0,333508	0,1312	0,8965
TTTHI	-0,0140137	0,115434	-0,1214	0,9042
Elspot	-0,00711623	0,0567134	-0,1255	0,901
SademedNorra	-0,00221737	0,0180039	-0,1232	0,9028
TuulekiirusKunda	-0,359302	2,61345	-0,1375	0,8915
TuulekiirusVirtsu	0,277903	1,9668	0,1413	0,8885
yhat^2	0,829582	3,71377	0,2234	0,8247
yhat^3	-0,0665797	0,253318	-0,2628	0,7944



Test statistic: $F = 1,517492$,

with p-value = $P(F(2,31) > 1,51749) = 0,235$

Lisa 14. Autokorrelatsiooni testimine Wintersi mudeli jääkide korral

Autocorrelation function for error

LAG	ACF	PACF	Q-stat.	[p-value]
1	-0,1628	-0,1628	0,9827	[0,322]
2	-0,1429	-0,174	1,7639	[0,414]
3	-0,039	-0,1003	1,824	[0,610]
4	-0,0609	-0,1209	1,9753	[0,740]
5	-0,1038	-0,1773	2,43	[0,787]
6	0,278	0,202	5,8079	[0,445]
7	-0,1529	-0,1342	6,8682	[0,443]
8	-0,1787	-0,2023	8,3718	[0,398]
9	0,0997	0,0045	8,8582	[0,450]
10	0,1267	0,1035	9,6763	[0,469]
11	0,0103	0,0804	9,682	[0,559]
12	0,1945	0,1775	11,7873	[0,463]
13	-0,1529	-0,015	13,1507	[0,436]
14	-0,1544	-0,0389	14,61	[0,405]
15	0,0893	0,0327	15,1235	[0,443]
16	0,102	0,0741	15,8309	[0,465]



Lisa 15. χ^2 kriitiline väärtus (Wintersi mudel)

Chi-square(16)

right-tail probability = 0,05

complementary probability = 0,95

Critical value = 26,2962

Lisa 16. Müügitulu autokorrelatsiooni testimine pärast 1. järgu sesoonse ja mittesoonse diferentsi võtmist

Autocorrelation function for d_sd_Muugitulu

LAG	ACF	PACF	Q-stat.	[p-value]
1	-0,3418 **	-0,3418 **	6,1976	[0,013]
2	0,0929	-0,0271	6,6652	[0,036]
3	-0,0101	0,0151	6,6708	[0,083]
4	-0,4202 ***	-0,4722 ***	16,653	[0,002]
5	0,1726	-0,1742	18,3752	[0,003]
6	-0,0948	-0,0864	18,906	[0,004]
7	0,1776	0,1019	20,8136	[0,004]
8	-0,2024	-0,4524 ***	23,3489	[0,003]
9	0,1811	-0,0401	25,4289	[0,003]
10	0,0161	0,1417	25,4457	[0,005]
11	-0,0858	0,0176	25,9369	[0,007]
12	0,3129 **	0,0381	32,6359	[0,001]
13	-0,2294	0,1293	36,3351	[0,001]
14	-0,0038	0,0258	36,3362	[0,001]
15	-0,0745	-0,0749	36,7484	[0,001]
16	-0,091	-0,028	37,3822	[0,002]

Lisa 17. Logaritmitud müügitulu empiiriline analüüs pärast 1. järgu sesoonse ja mitteseseoonse diferentsi võtmist

Autokorrelatsiooni d_sd_1_Muugitulu graafiline kuju

LAG	ACF	PACF	Q-stat.	[p-value]
1	-0,1834	-0,1834	1,7839	[0,182]
2	0,017	-0,0172	1,7995	[0,407]
3	-0,1149	-0,1189	2,5296	[0,470]
4	-0,4009 ***	-0,4658 ***	11,6128 ***	[0,020]
5	0,1849	-0,002	13,5871	[0,018]
6	-0,0076	-0,0025	13,5905	[0,035]
7	0,1376	0,0128	14,7352	[0,040]
8	-0,2328	-0,4642 ***	18,0894 ***	[0,021]
9	0,058	0,0167	18,3026	[0,032]
10	0,0322	0,1032	18,3699	[0,049]
11	0,0269	0,0146	18,418	[0,072]
12	0,3195 **	0,0487	25,4041	[0,013]
13	-0,1311	0,1434	26,6114	[0,014]
14	-0,0922	-0,0274	27,2249	[0,018]
15	-0,1769	-0,1625	29,5498	[0,014]
16	-0,0832	-0,0575	30,0786	[0,018]

Lisa 18. Dickey-Fulleri test

Augmented Dickey-Fuller test for d_sd_1_Muugitulu

including 7 lags of $(1-L)d_sd_1_Muugitulu$

sample size 42

unit-root null hypothesis: $a = 1$

test without constant

model: $(1-L)y = (a-1)*y(-1) + \dots + e$

1st-order autocorrelation coeff. for e: 0,015


lagged differences: $F(7, 34) = 5,732 [0,0002]$

estimated value of $(a - 1)$: -3,69877

test statistic: $\tau_nc(1) = -5,37051$

asymptotic p-value 1,213e-007

Lisa 19. Jääkliikmete autokorrelatsiooni graafiline kuju



Residual autocorrelation function

LAG	ACF	PACF	Q-stat.	[p-value]
1	0,0243	0,0243	0,0237	[0,878]
2	-0,2463	-0,247	2,5245	[0,283]
3	-0,1024	-0,0948	2,9698	[0,396]
4	-0,0425	-0,1071	3,0486	[0,550]
5	0,1621	0,1237	4,2329	[0,516]
6	0,1067	0,0648	4,7632	[0,575]
7	-0,1369	-0,0878	5,6644	[0,579]
8	-0,1033	-0,0465	6,1955	[0,625]
9	-0,0605	-0,0907	6,3842	[0,701]
10	-0,019	-0,0848	6,4035	[0,780]
11	0,0928	0,0116	6,8813	[0,809]
12	0,2915 *	0,3061 *	11,7851	[0,463]
13	-0,0228	0,0345	11,8165	[0,543]
14	-0,2927 *	-0,1787	17,1916	[0,246]
15	-0,1104	-0,0974	17,9918	[0,263]
16	0,0462	-0,0658	18,1386	[0,316]

Lisa 20. Normaaljaotuse testi tulemus

Test for null hypothesis of normal distribution:

Chi-square(2) = 2,791 with p-value 0,24774

Lisa 21. Eesti Energia ASi müügitulu andmed aastatel 2002–2015

2002.Ikv	91,704	2009.Ikv	191,307
2002.IIkv	69,46	2009.IIkv	140,248
2002.IIIkv	71,728	2009.IIIkv	139,238
2002.IVkv	105,848	2009.IVkv	179,924
2003.Ikv	118,626	2010.Ikv	218,3
2003.IIkv	82,003	2010.IIkv	168,8
2003.IIIkv	78,593	2010.IIIkv	163,9
2003.IVkv	103,937	2010.IVkv	233,1
2004.Ikv	112,581	2011.Ikv	233,5
2004.IIkv	85,597	2011.IIkv	188,3
2004.IIIkv	82,733	2011.IIIkv	187,9
2004.IVkv	107,782	2011.IVkv	222,2
2005.Ikv	118,615	2012.Ikv	220,6
2005.IIkv	89,317	2012.IIkv	176
2005.IIIkv	99,576	2012.IIIkv	198,9
2005.IVkv	126,488	2012.IVkv	226,6
2006.Ikv	137,48	2013.Ikv	278,6
2006.IIkv	103,605	2013.IIkv	215,4
2006.IIIkv	100,458	2013.IIIkv	216,3
2006.IVkv	124,928	2013.IVkv	256,1
2007.Ikv	152,559	2014.Ikv	226,4
2007.IIkv	121,929	2014.IIkv	204,6
2007.IIIkv	130,98	2014.IIIkv	197,2
2007.IVkv	163,303	2014.IVkv	251,8
2008.Ikv	158,233	2015.Ikv	219,8
2008.IIkv	136,647	2015.IIkv	181
2008.IIIkv	148,711	2015.IIIkv	171
2008.IVkv	188,815	2015.IVkv	204,9

Allikas: Majandusaasta aruanded, vahearuanded. (2002–2015). Eesti Energia AS.

Lisa 22. Prognoositud müügitulu andmed ARIMA mudeli rakendamisel

For 95% confidence intervals, $z(0,025) = 1,96$

Obs	l_Muugitulu	prediction	std. error	95% interval
2012:3	undefined	5,18415	0,0690376	(5,04884, 5,31946)
2012:4	undefined	5,44308	0,0976339	(5,25172, 5,63444)
2013:1	undefined	5,51029	0,119577	(5,27593, 5,74466)
2013:2	undefined	5,25741	0,138075	(4,98679, 5,52803)
2013:3	undefined	5,27108	0,158917	(4,95960, 5,58255)
2013:4	undefined	5,53000	0,177326	(5,18245, 5,87756)
2014:1	undefined	5,59722	0,193995	(5,21700, 5,97744)
2014:2	undefined	5,34434	0,209342	(4,93404, 5,75464)
2014:3	undefined	5,35800	0,227207	(4,91268, 5,80332)
2014:4	undefined	5,61693	0,243767	(5,13916, 6,09471)
2015:1	undefined	5,68415	0,259271	(5,17598, 6,19231)
2015:2	undefined	5,43126	0,273899	(4,89443, 5,96810)
2015:3	undefined	5,44493	0,290887	(4,87480, 6,01506)
2015:4	undefined	5,70386	0,306936	(5,10227, 6,30544)

Lisa 23. Prognoositud väärtused naiivse meetodiga ja võrdlus tegelike väärtustega

Aasta: kvartal	Tegelik müügitulu mln eurodes	Prognoositud andmed naiivse meetodiga	Kõrvalekalle %-des	Kõrvalekalle
2012:3	198,900	149,611	-24,78%	-49,289
2012:4	226,600	186,447	-17,72%	-40,153
2013:1	278,600	189,084	-32,13%	-89,516
2013:2	215,400	146,996	-31,76%	-68,404
2013:3	216,300	146,376	-32,33%	-69,924
2013:4	256,100	186,090	-27,34%	-70,011
2014:1	226,400	231,594	2,29%	5,194
2014:2	204,600	172,600	-15,64%	-32,000
2014:3	197,200	168,775	-14,41%	-28,425
2014:4	251,800	239,100	-5,04%	-12,700
2015:1	219,800	230,775	4,99%	10,975
2015:2	181,000	185,075	2,25%	4,075
2015:3	171,000	184,825	8,08%	13,825
2015:4	204,900	212,628	3,77%	7,728

Lisa 24. Kvartaalsete õhutemperatuuride ja sademete keskmised väärtused

Regressor\Kvartal	I	II	III	IV
Õhutemperatuur	-4.09	10.46	15.91	2.13
Sademed Norra	60.48	43.45	80.63	65.06
Tuule kiirus Kunda	3.69	3.06	3.04	4.22
Tuule kiirus Virtsu	3.62	3.44	3.26	3.98

**Lisa 25. KRT korrigeeritud, Elspot, Tööhõivemäär ja TTHI prognoositud ar-
gumentsuurused**

Kvar- tal.Aasta\Faktor	Kogurahvatulu korrigeeritud	Tööhõive määr	TTHI	Elspot
III. 2012	4075.50	64.4118	108.57	33.68
IV. 2012	4117.59	64.6235	109.27	32.91
I. 2013	4159.67	64.8353	109.96	32.14
II. 2013	4201.75	65.0471	110.66	31.36
III. 2013	4243.84	65.2588	111.36	30.59
IV. 2013	4285.92	65.4706	112.05	29.82
I. 2014	4328.01	65.6824	112.75	29.04
II. 2014	4370.09	65.8941	113.45	28.27
III. 2014	4412.17	66.1059	114.14	27.50
IV. 2014	4454.26	66.3177	114.84	26.72
I. 2015	4496.34	66.5294	115.54	25.95
II. 2015	4538.43	66.7412	116.23	25.18
III. 2015	4580.51	66.9530	116.93	24.40
IV. 2015	4622.59	67.1647	117.63	23.63

Lisa 26. Prognoositud müügitulu (mitmene regressioon)

III kvartal 2012:	$\ln y = 5.189630:$	$y = 179.4022$
IV kvartal 2012:	$\ln y = 5.430702:$	$y = 228.3094$
I kvartal 2013:	$\ln y = 5.468341:$	$y = 237.0667$
II kvartal 2013:	$\ln y = 5.230042:$	$y = 186.8007$
III kvartal 2013:	$\ln y = 5.233307:$	$y = 187.4116$
IV kvartal 2013:	$\ln y = 5.474379:$	$y = 238.5022$
I kvartal 2014:	$\ln y = 5.512019:$	$y = 247.6505$
II kvartal 2014:	$\ln y = 5.273719:$	$y = 195.1404$
III kvartal 2014:	$\ln y = 5.276985:$	$y = 195.7786$
IV kvartal 2014:	$\ln y = 5.518056:$	$y = 249.1502$
I kvartal 2015:	$\ln y = 5.555696:$	$y = 258.7069$
II kvartal 2015:	$\ln y = 5.317396:$	$y = 203.8524$
III kvartal 2015:	$\ln y = 5.320662:$	$y = 204.5192$
IV kvartal 2015:	$\ln y = 5.561733:$	$y = 260.2735$

Lisa 27. Wintersi eksponentsilumismeetodi tulemused

Period	Tegelikud andmed	F, Üldine silumine	Sesoonsuse ga silumine	T, Trendiga silumine	Prognosis m=1	Viga	Viga ruudus	
1	91,704			1,17				
2	69,46			0,88				
3	71,728			0,88				
4	105,848	64,500		1,10				
5	118,626	100,707		1,18	0,02			
6	82,003	92,956		0,88	0,02			
7	78,593	89,160		0,88	0,02			
8	103,937	94,581		1,10	0,02			
9	112,581	95,734		1,18	0,02	112,59	0,01	0,00
10	85,597	96,978		0,88	0,02	85,61	0,01	0,00
...
47	216,3	244,976		0,88	0,12	175,69	-40,61	1649,49
48	256,1	233,125		1,10	0,11	218,95	-37,15	1380,41
49	226,4				234,10	7,70	59,33	
50	204,6				176,02	-28,58	816,65	
51	197,2				175,79	-21,41	458,36	
52	251,8				218,84	-32,96	1086,21	
53	219,8				234,26	14,46	209,00	
54	181				176,05	-4,95	24,52	
55	171				175,80	4,80	23,00	
56	204,9				218,78	13,88	192,65	

Lisa 28. Müügitulu prognoos kompleksanalüüsi meetodiga

<i>Kuud</i>	<i>Kvartalid*</i>	<i>Sesoonne komponent S</i>	<i>Trend T</i>	<i>Prognoos y=T•S</i>	<i>Tegelik väärtus</i>	<i>Suhteline viga</i>
43	09.2012	0,88	222,12	195,88	198,90	-2%
44	12.2012	1,10	227,58	249,95	226,60	10%
45	03.2013	1,17	233,18	273,68	278,60	-2%
46	06.2013	0,88	238,92	210,94	215,40	-2%
47	09.2013	0,88	244,80	215,88	216,30	0%
48	12.2013	1,10	250,82	275,47	256,10	8%
49	03.2014	1,17	256,99	301,62	226,40	33%
50	06.2014	0,88	263,31	232,48	204,60	14%
51	09.2014	0,88	269,78	237,91	197,20	21%
52	12.2014	1,10	276,42	303,59	251,8	21%
53	03.2015	1,17	283,22	332,41	219,80	51%
54	06.2015	0,88	290,19	256,21	181,00	42%
55	09.2015	0,88	297,32	262,20	171,00	53%
56	12.2015	1,10	304,64	334,58	204,90	63%

Lisa 29. Breusch-Godfrey test

	coefficient	std. error	t-ratio	p-value	
const	-0,164362	0,400778	-0,4101	0,6847	
Ohutemperatuur	2,87e-05	0,001487	0,01932	0,9847	
KRTkorrigeeritud	-1,45916e-05	4,05e-05	-0,3602	0,7213	
Toohoivemaar	0,00217242	0,006963	0,312	0,7573	
TTTHI	0,000487052	0,001246	0,3909	0,6987	
Elspot	0,000127078	0,000769	0,1652	0,87	
SademedNorra	2,43e-05	0,00038	0,064	0,9494	
TuulekiirusKunda	-0,00995066	0,044991	-0,2212	0,8265	
TuulekiirusVirtsu	0,0179763	0,049619	0,3623	0,7198	
uhat_1	0,482508	0,190975	2,527	0,0172	**
uhat_2	-0,305492	0,255419	-1,196	0,2414	
uhat_3	-0,0568827	0,240132	-0,2369	0,8144	
uhat_4	0,0163151	0,236384	0,06902	0,9454	

Unadjusted R-squared = 0,211585

Test statistic: LMF = 1,945663,

with p-value = $P(F(4,29) > 1,94566) = 0,13$


Alternative statistic: $TR^2 = 8,886565$,

with p-value = $P(\text{Chi-square}(4) > 8,88657) = 0,064$

Ljung-Box $Q' = 8,34241$,

with p-value = $P(\text{Chi-square}(4) > 8,34241) = 0,0798$

Lisa 30. Ettevõtte tegelik ja modelleeritud müügitulu (ARIMA) aastatel 2002–2012



Model 3: ARIMA, using observations 2003:2-2012:2 (T = 37)

Dependent variable: $(1-L)(1-L_s) l_Muugitulu$

Standard errors based on Hessian

	<i>Coefficient</i>	<i>Std. Error</i>	<i>z</i>	<i>p-value</i>	
Theta_1	-0,860398	0,233811	-3,6799	0,00023	***
Mean dependent var	-0,008783	S.D. dependent var		0,094083	
Mean of innovations	-0,010944	S.D. of innovations		0,069038	
Log-likelihood	43,80248	Akaike criterion		-83,60496	
Schwarz criterion	-80,38312	Hannan-Quinn		-82,46911	

	<i>Real</i>	<i>Imaginary</i>	<i>Modulus</i>	<i>Frequency</i>
MA (seasonal)				
Root 1	1,1623	0,0000	1,1623	0,0000

Tabel 1. Logaritmitud aegrea Gretli tulemus ARIMA(0,1,0)(0,1,1)⁴ mudeli jaoks.