

TALLINNA TEHNIKAÜLIKOOL

Majandusteaduskond

Reela Rosin

EESTI INFLATSIOONI KIIRHINNANGU KOOSTAMISE

VÕIMALUSED

Magistritöö

Õppekava majandusanalüüs

Juhendaja: Peeter Luikmel, MA

Tallinn 2023

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

Töö pikkuseks on 11 851 sõna sissejuhatusest kuni kokkuvõtte lõpuni.

Reela Rosin 09. mai 2023
(kuupäev)

SISUKORD

LÜHIKOKKUVÕTE	4
SISSEJUHATUS	5
1. KIRJANDUSE ÜLEVAADE.....	8
1.1 Inflatsiooni olemus ja meetmed.....	8
1.2 Inflatsiooni prognoosimine.....	9
1.3 Andmete valik	13
2. ANDMED JA METOODIKA.....	15
2.1 Andmed	15
2.2 Mudelite prognoosimisvõimekuse võrdlemine	23
2.3 Autoregressiivse (ARIMA) mudeliga prognoosimine	24
2.4 Lassoregressioonid	25
2.4.1 Lassoregressioon (Lasso)	26
2.4.2 Adaptiivne lassoregressioon (adaLasso)	28
2.5 Juhuslik mets (RF).....	30
3. TULEMUSED.....	32
3.1 Parim meetod inflatsiooni kiirhinnangu koostamiseks.....	33
3.2 Tarbijahinnaindeksi kuju valik.....	35
3.3 Inflatsiooni prognoosivad tegurid.....	36
3.4 Tarbijahinnaindeksite prognoosimine põhikaubagruppide lõikes.....	43
3.5 Järeldused ja ettepanekud	44
KOKKUVÕTE	46
SUMMARY	50
KASUTATUD ALLIKATE LOETELU	53
LISAD	57
Lisa 1. Töös kasutatavad lühendid	57
Lisa 2. Andmed	58
Lisa 3. Korrelatsioonimaatriks	72
Lisa 4. ADF ja Box-Ljung testide tulemused.....	73
Lisa 5. Mudelite RMSE, MAE, MAD koguvalimis	74
Lisa 6. Mudelite RMSE, MAE, MAD järeltestimise perioodil.....	75
Lisa 7. Lassoregressioonide muutujate koefitsiendid.....	76
Lisa 8. Juhusliku metsa muutujate osatähtsus MSE-s.....	77
Lisa 9. Lihtlitsents	78

LÜHIKOKKUVÕTE

Lühiperioodi inflatsiooni prognoosi täpsus aitab paremini kujundada raha- ja eelarvepoliitikat ning parandada prognoosi alguspunkti mõju pikemate prognooside puhul. Käesoleva magistritöö eesmärk on leida alternatiivne meetodika Eesti inflatsiooni lühiajaliseks prognoosimiseks ning tegurid, mis aitavad parandada inflatsiooni lühiprognosi täpsust. Lisaks selgitatakse välja, kas täpsema tulemuse annab tarbijahinnaindeksi kasutamine avaldatud või desagregeeritud kujul. Meetodina kasutatakse senisest kirjandusest parimaid tulemusi andnud lassoregressioone ning juhuslikku metsa, võrdlusmudelina ARIMA mudeleid. Mudelite prognoosimisvõimekust hinnatakse kolme näitajaga: RMSE, MAE ja MAD.

Parim meetod inflatsiooni kiirhinnangu koostamiseks on juhuslik mets (*Random Forest*). Lassoregressioonid annavad paremaid tulemusi vaid siis, kui algoritm valib mudelisse väga palju erinevaid muutujaid. Juhusliku metsa prognoosimisvõimekus edestab ARIMA mudeleid vähemalt 47%, lassoregressiooni mudeleid 42% ja adaptiivse lasso mudeleid 50%. Lisaks sellele võimaldab tarbijahinnaindeksi kasutamine desagregeeritud kujul parandada prognoosimisvõimekust avaldatud kuju ees suhtena ARIMA mudeli prognoosimisvõimekusega vähemalt 19%. Inflatsiooni kiirhinnangut koostamisel on olulised tegurite grupid tööstus, sisekaubandus, väliskaubandus, hinnad, energeetika ja põllumajandus. Küsitlusandmete lisamine valimisse parandab prognoosimisvõimekust kuni 11,5%.

Võtmesõnad: Inflatsioon, kiirhinnang, lassoregressioon, juhuslik mets

SISSEJUHATUS

Inflatsioon reageerib rahapoliitika muutustele viitega, mistõttu rahapoliitikat kujundatakse alati prognoosi põhjal ja seetõttu on prognoosimise võimekus väga oluline. Samuti on inflatsiooni prognoosimine oluline ettevõtete jaoks, kuna ettevõtted soovivad selle põhjal teha oma investeerimisotsuseid, planeerida palgatõusud ja tõsta rendihinda. Kõrge inflatsiooni keskkonnas on inflatsioonist tingitud maksubaasi ning kulude kasvu täpsem prognoosimine omandanud otsustava tähtsuse ka riigi rahanduspoliitika kujundamisel. Pikemate prognooside seisukohalt on olulise tähtsusega prognoosi algpunkti ümbruse täpne hinnang, mille tagab hinnakasvu võimalikult täpne monitooring. See nn *nowcasting* ehk lühiperioodi kiirhinnang inflatsioonile suurendabki nii prognooside kui operatiivsete rahandusotsuste kvaliteeti. Kiirhinnang sisaldab endas hetke ja lähituleviku inflatsiooni kiirhinnangu andmist.

Inflatsiooni peetakse üheks keerulisemaks muutujaks, mille käitumist on keeruline prognoosida. Eriti viimasel kümnendil on inflatsiooni prognoosimist komplitseerinud ka energiahindade suur kõikumine. Pandeemia perioodil muutus oluliseks majandusnäitajate hetketrendide kiirhindamine uute meetodite ning alternatiivsete andmeallikate abil. Tänapäevased aegridade analüüsimeetodid pakuvad selleks rohkelt alternatiivseid võimalusi. Kiirhinnangute koostamisel on prioriteet võimalikult täpne lühiprognos, mis saavutatakse sageli ateoreetilistega meetoditega kui pikemate prognooside puhul.

Käesoleva töö eesmärk on leida alternatiivne meetoodika Eesti inflatsiooni lühiajaliseks prognoosimiseks ning tegurid, mis aitavad parandada inflatsiooni lühiprognosi täpsust. Selleks on kaks võimalust: kasutada indeksi avaldatud või desagregeeritud kujul. Nimelt, tarbijahinnaindeksis on kulutused jaotatud 12 kaubagrupi ning Statistikaamet ajakohastab indeksi kaalusid (kulutuste osatähtsus koguindeksis) ja esinduskaupade nimekirja igal aastal. Kaalud vastavad elanike eelmise aasta keskmisele kulutuste struktuurile. Eesti inflatsioon on euroalas üks kõrgemaid, mistõttu võimaldab uurimusest saadav info tulevased rahanduspoliitilised otsused ja meetmed suunata parima tulemuse tagamiseks.

Töös püstitatakse järgmised uurimisküsimused:

- 1) Missugune meetodika võimaldab Eesti inflatsiooni lühiperioodil kõige täpsemini prognoosida?
- 2) Kas täpsema tulemuse annab avaldatud agregeeritud tarbijahinnaindeksi kasutamine või indeksi prognoosimine põhikaubagruppide lõikes ehk disagregeeritud kujul?
- 3) Millised tegurid aitavad prognoosida tarbijahinnaindeksit?

Esimene peatükk annab ülevaate inflatsiooni olemusest ning varasemast asjakohasest kirjandusest. Inflatsiooni prognoositakse erinevate aegridade mudelite abil. Sageli kasutatakse selleks mitmesuguseid autoregressiivseid ARIMA mudelid (peamiselt ARMA(1,1), AR(p), Random Walk), aga ka teoreetilisi kontseptsioone nagu Phillipsi kõver ning tõhusaks on osutunud küsitlustel põhinevate informatsiooni mõõdikute kasutamine mudelis. Alternatiivselt kasutati faktormudeleid, populaarseim neist oli dünaamiline faktormudel. Üsna häid tulemusi on just lühiperioodi prognooside puhul saadud lassoregressioonide ja juhusliku metsa (*Random Forest*) kasutamine. Kuigi tarbijahinnaindeksit disagregeeritud kujul ei ole laialdaselt viimatinimetatud masinõppe meetodikate raames analüüsitud, on nende abil mõningastes varasemates töödes suudetud inflatsiooni prognoosimisvõimet parandada.

Teine peatükk kirjeldab analüüsis kasutatud andmeid ja meetodikat. Uurimisobjektina kasutatakse tarbijahinnaindeksit nii agregeerituna kui ka disagregeeritud kujul. Selgitavate muutujatena on valimis 212 Eesti Statistikaameti, Eurostati, Eesti Panga ja Euroopa Komisjoni poolt avaldatud kuupõhist majanduslikku muutujat. Prognoosimudelid koostatakse perioodi juuli 2006 kuni veebruar 2023 andmete põhjal. Andmete puhul on vaja arvestada avaldamise viitajaga ning selgitavate muutujate seas esineva tugeva korrelatsiooniga. Kõigepealt on vajalik andmeid töödelda: statsionaarsete aegridade saamiseks kasutatakse teisendamist ning lassoregressioonide jaoks viiakse andmed samasse skaalasse ehk normaliseeritakse. Lähtuvalt senistest kirjandusest kasutatakse ARIMA mudeleid, lassoregressioone ja juhuslikku metsa. Erinevates alapeatükkides tuuakse välja valitud meetodite positiivsed ja negatiivsed küljed, lihtsustatult nende toimimismudel ning eeldused. Analüüs viiakse läbi programmis R Studio.

Kolmandas peatükis esitatakse analüüsi tulemused. Kõigepealt kirjeldatakse andmetöötluste ja läbiviidud testide tulemusi. Esimeses kolmes alapeatükis antakse vastused püstitatud uurimisküsimustele. Kuna töös kasutatakse ateoreetilisemat lähenemist, siis selle puhul on kesksel kohal just hinnang, kas ja kui hästi on võimalik inflatsiooni kiirhinnangut koostada. Lassoregressioonide koefitsientide abil on võimalik hinnata teguri mõju suunda inflatsiooni prognoosimisel, kuid juhusliku määra kasutamisel saab tulemuste tõlgendamisel kasutada vaid teguri olulisuse määra keskmises ruutveas ning seeläbi arvutada mudelis teguri olulisuse osakaal kõikidest teguritest. Suurem osakaal tähistab olulisemat tegurit inflatsiooni kiirhinnangu koostamisel. Kuigi tegurite ja inflatsiooni vahelised seosed esinevad pigem varjatud kujul ning ateoreetiliste meetodite puhul ei oma need suuremat tähtsust, siis osaliselt robustsus-analüüsina selgitatakse lahti võimalik seos inflatsiooni majandusliku sisuga. Seejärel antakse ülevaade peamiste kauba ja teenusegruppide tarbijahinnaindeksite mudelite tulemustest. Viimasena on lisatud järeldused ja ettepanekud, kus kirjeldatakse lisaks töö panusele ka võimalikke töö edasiarendusi.

1. KIRJANDUSE ÜLEVAADE

Käesoleva peatüki eesmärk on anda ülevaade inflatsioonist ja prognoosimise võimalustest. Esimeses alapeatükis antakse ülevaade inflatsiooni olemusest ning hinnastabiilsuse tagamise meetmetest. Tutvustatakse mehhanisme, mille kaudu inflatsiooni keskpankade poolt juhitakse ning peamisi seoseid, mida inflatsiooni modelleerimisel rakendatakse. Inflatsiooni olemuse ja kontrolli all hoidmise meetmete mõistmine on oluline nii inflatsiooni hindamisel (eesmärk on hoida inflatsioon stabiilsena eesmärktasemel, mitte muuta ta olematuks), andmete valiku etapis (miks on intressimäärad senises kirjanduses olnud olulise tegurina välja toodud) kui ka tulemuste tõlgendamisel (eelkõige inflatsiooni erinevaid liike silmas pidades). Teises alapeatükis kirjeldatakse prognoosimise erinevaid võimalusi ning antakse ülevaade senistest töödest inflatsiooni prognoosimisel. Kolmandas alapeatükis kirjeldatakse analüüsi läbiviimiseks andmete valiku protsessi.

1.1 Inflatsiooni olemus ja meetmed

Inflatsioon kujutab endas laiaulatuslikku hinnatõusu, mille tulemusena inimese reaalne ostujõud väheneb, kuna ta saab sama summa eest osta varasemast vähem kaupu või tarbida teenust. Ehk siis sisuliselt raha väärtus langeb. (Euroopa Keskpank, 2022) Vastupidine olukord tähendab hindade langust, millega kaasneb ostujõu paranemine. Seda nimetatakse deflatsiooniks. Inflatsiooni peamised tüübid on nõudluse inflatsioon (*Demand-pull*) ja kuluinflatsioon (*Cost-push*). Nõudluse inflatsiooni korral on tarbijate nõudlus kõrgem kui majanduse tootmisvõimsus ehk pakkumine. Sellise olukorra võivad põhjustada ringluses olev liigne raha hulk, madalad intressimäärad või liiga suured reservid, mis võimaldavad pankadel anda rohkem krediiti. Kuluinflatsiooni korral on kõrge inflatsiooni põhjuseks suuri palgatõuse nõudnud kaubandusorganisatsioonid või kasumi suurendamise eesmärgil kaupade ja teenuste hindu tõstvad suurettevõtted. Need kõik suurendavad toote lõplikku hinda. Kuluinflatsiooni puhul on aga vaieldud, et kuluinflatsioon ei saa tekkida ilma nõudluse kasvuta ja ostujõu suurenemiseta. Kuid samamoodi on kahtluse alla seatud, kas nõudluse inflatsioon saab tekkida ilma eelneva kuluinflatsioonita. Täpsemalt, üldiselt tõusevad hinnad siis,

kui nõudlus ületab pakkumise. Ning hinnatõusu taga on tavaliselt ratsionaalsed otsused. (Machlup, 1990, 241–246)

Inflatsiooni seire ja vajalike rahapoliitiliste meetmete rakendamine keskpankade poolt on vajalik selleks, et oleks tagatud hinnastabiilsus. Euroopa Keskpank soovib inflatsioonimäära hoida 2% tasemel kahe kuni kolme aasta ettevaates. (Euroopa Keskpank, 2022) Peamised rahapoliitilised meetmed on intressimäärade kujundamine ning majanduses ringleva rahahulga kontrollimine, mõjutades seeläbi rahastamise tingimusi ja majanduse arengut. (Euroopa Keskpank, 2021; Eesti Pank, 2022a) Intresside tõstmisel muutub laen kallimaks, mis omakorda peaks vähendama igasugust laenuõudlust. Kõrgem intressimäär muudab olemasolevad laenud kallimaks, suurendades inimeste kohustusi ja jättes igapäevasteks kuludeks vähem vahendeid. See peaks omakorda vähendama nõudlust, võimaldades siis ka hindadel langeda. Majanduses ringleva rahahulga kontrollimiseks on võimalik teha vähem varaoste, müüa finantsvarasid või piirata kommertsbankadele laenuandmist. Kuid negatiivse poolena võib nende meetmete tulemusena kaasneda majanduslangus, kuna need sammud aeglustavad majanduskasvu. (Eesti Pank, 2022a)

1.2 Inflatsiooni prognoosimine

Selleks, et keskpangad saaksid teha rahapoliitilisi otsuseid, on olulisel kohal inflatsiooni prognoos. Prognoosid jagunevad aga kaheks: prognoos ja kiirhinnang ehk nowcasting. Kui prognoosi eesmärk on prognoosida tulevikku, siis kiirhinnangu eesmärk on objektiivselt hinnata trendi või trendi muutust reaalajas. Kui prognoosid tuginevad paljuski oletustele, siis kiirhinnang toetub faktidele ja teadmistele ning selle põhjal kujundatakse otsused. (Ineichen, 2015) Prognoosi ebatäpsuste tõttu on nüüdisajal eelistatud kiirhinnangu andmine, mis annab täpsema ennustuse olemasolevale olukorrale majanduses, eelkõige majanduskasvu ja inflatsiooni silmas pidades.

Kirjanduses esitatakse neli peamist inflatsiooni prognoosimise meetodit: kasutades varade hindu ehk intressimäärade tähtajalist struktuuri (tulukõverat), ARIMA mudel, Phillips kõver, ning küsitlustel põhinevate informatsiooni mõõdikute kasutamine. Varasemalt on identifitseeritud seos lühiajaliste intressimäärade ning inflatsiooni vahel. Ühest küljest on lühiajalised intressimäärad keskpankade peamiseks operatsiooniliseks instrumendiks – nende kaudu mõjutataksegi majandusaktiivsust, mis lõppkokkuvõttes kujundab inflatsiooni. Teisest küljest mõjutavad inflatsiooniootuste muutumine reaalsel intressimäära ka siis, kui nominaalsed intressimäärad

püsivad muutumatud. Fama analüüsis lühiajaliste intressimäärade mõju inflatsioonile. Inflatsioon käitub lühiajaliste intressimääradele vastupidiselt ning pikaajaliste intressimääradega seos puudub. (Fama, 1975) Inflatsiooni puhul ei ole ühist seisukohta leitud, kas ta omab ühikjuurt või on statsionaarne. Küllaltki viljakaks on lühiperioodi inflatsiooni prognoosimisel osutunud aeGRIDADE mudelid. Ang, Bekaert ja Wei töös kasutatakse kolme erinevat ARIMA mudelit: ARMA(1,1), AR(p) ning Random Walk (RW) ehk ARIMA(0,1,0). Kvartaalseid andmeid kasutades andis nendest parimaid tulemusi ARMA(1,1) mudel. Väga häid tulemusi andsid ka küsitlustel baseeruvad mudelid. Kui võrrelda professionaalsete majandusteadlaste küsitlusandmete kasutamist tarbijate või ettevõtjate küsitlusandmete kasutamisega, siis prognoosi täpsust suurendavad kõik variandid. Kuid ekspertide ja ettevõtjate inflatsiooniootuse kasutamine mudelis annab siiski väikese eelise tarbijate inflatsiooniootuse kasutamise ees. (Ang et al., 2007) Hilisemates töodes on näiteks Hiina inflatsiooni prognoosimisel tunnistanud ARIMA mudeli paremust, kasutades hooajalist ARIMA mudelit $(0,1,2) \times (1,0,1)^{12}$. Antud mudel oli parim kuni nelja kuu inflatsiooni prognoosimisel. (Funke et al., 2015) Üldjuhul on leitud, et paremini töötavad pigem lühemate viitaegadega mudelid.

Töötuse määra ja inflatsiooni seostel põhineva Phillips kõvera mudeli paremust ühemõõtmeliste autoregressiivsete ja RW mudelite ees tõestasid Stock ja Watson. Nende analüüsis kasutati 12-kuulist ajaraami ja Ameerika Ühendriikide inflatsiooni andmeid. Phillips kõvera võimaliku probleemina nimetati aga liigse sobitamise probleemi (kasutati väga palju mudeleid). (Stock & Watson, 1999) Viimastel kümnenditel on pigem kinnitust leidnud ateoreetilisemate mudelite eelised lühiajalisel prognoosimisel. Näiteks Ühendriikide inflatsiooni prognoosimisel nelja kvartali ajaraamis osutus, et Phillips kõver ei ole parim meetod inflatsiooni prognoosimiseks. Seda ka siis, kui kasutada töötuse määra asemel alternatiivseid tööturu näitajaid. Leiti, et paremaid tulemusi annab lihtne RW mudel (ARIMA (0,1,0)). (Atkeson & Ohanian, 2001)

Samas nähti vajadust kasutada prognoosimudelites suuremat valimit selgitavatest muutujatest, mille seast oleks võimalik valida välja üksikud muutujad, mis aitaksid prognoosida sõltuva muutuja käitumist kõige täpsemalt. Parameetrite omavaheliste seoste hindamiseks on kõige enam levinud viis faktoranalüüsi kasutamine, millest luuakse faktormudelid. Giannone, Reichlin ja Small uurisid Philadelphia inflatsiooni, kasutades faktoranalüüsi. Ka seal tõstatati küsitlusandmete oluline seos inflatsiooniga. Samuti andsid küllaltki täpseid tulemusi nominaalsete ja reaalsete muutujate kasutamine, varade hinnad. (Giannone et al., 2006) Kaks aastat hiljem kasutasid samad autorid sisemajanduse koguprodukti (SKP) kiirhinnangu koostamiseks dünaamilist faktormudelit

(*dynamic factor model*, DFM). See mudel sobib väga hästi suure muutujate arvu ning suure vaatluste arvu puhul. (Giannone et al., 2008) Antud mudeli head prognoosimisvõimet tõi välja ka Modugno, kasutades Ameerika Ühendriikide inflatsiooni andmeid ja kõrvutas tulemusi mitmesagedusliku regressiooniga (*mixed-data sampling*, MIDAS). DFM andis ühe kuu prognoosis paremaid tulemusi kui RW. Antud töö üheks lisaväärtuseks oli kõrgema sagedusega andmete kasutamine. Nimelt, mudeli prognoosimisvõimekust parendasid oluliselt päevaste energia ja toormaterjali hindade kasutamine. Samas finantsmuutujate kasutamine mudeli prognoosimisvõimekust oluliselt ei parandanud. (Modugno, 2013) Hilisemates töödes on ka faktormudelitest paremaid meetodikaid avastatud. Näiteks, kuni kaheksa kuu inflatsiooni ette prognoosides lassoregressioonidega. (Medeiros & Mendes, 2016)

Aja jooksul muutusid lühemaks prognoositavate kuude arv. Ning lühiajaliste kiirhinnangute koostamisel on teooria teisejärguline, olulisem on prognoosimise võimekus. Samuti keskenduti eeltoodust lähtuvalt edaspidi rohkem sellele, kuidas selgitavate muutujate struktuuri muuta paindlikumaks (mittelineaarsus) ja kuidas selekteerida mudelisse vaid need muutujad, mis aitavad prognoosida inflatsiooni. Eesmärgiks oli analüüsis läbi proovida maksimaalsel hulgal erinevaid muutujaid. Häid tulemusi on andnud ateoreetilisemate teooriate valdkonda kuuluva masinõppe kasutamine prognoosimudeli koostamisel. See on suurendanud analüüsimise võimsust, paindlikkust ja tõstnud kvaliteeti. Kuid masinõppe nõrkustena tuuakse välja tugevate ja kontrollitavate eelduste puudumise ning suutmatuse anda aluseks olevate parameetrite kohta stabiilseid hinnanguid. (Mullainathan & Spiess, 2017)

Muutujate selekteerimisel muutus populaarseks lassoregressioonide ehk vähima absoluutse kokkutõmbumise ja valiku operaatoriga (*Least Absolute Shrinkage & Selection Operator*, Lasso) regressioonide kasutamine, mis on edasiarendus hariliku vähimruudu regressioonidel (OLS) põhinevatest kantregressioonidest (*Ridge regression*). Selle meetodi eelis avaldub olukorras, kus muutujate arv on suurem kui vaatluste arv. Samuti on lõplik mudel lihtsam, kuna see muudab ebaoluliste muutujate koefitsiendid nulliks. See aga võib mõningatel juhtudel hoopis tõsta prognoosimisvõimekust. Lasso parameeter valitakse prognoosimisviga minimeerides. (Tibshirani, 1996) Meetod on hinnatud nii automaatse muutujate selekteerimise kui ka täpse prognoosimisvõime tõttu. Bai ja Ng uurisid inflatsiooni prognoosimist läbi suunatud ennustajate (*targeted predictors*), tuues sisse mittelineaarsuse logaritmid ja muutujate ristkorrutistega. Muutujate esmane valik põhines faktoranalüüsil, et valikusse jääksid vaid need muutujad, mis

tegelikult inflatsiooni mõjutavad, kuid mudeli loomisel andis väga häid tulemusi pehme lävi seadmine, sealhulgas kasutades lassoregressiooni. (Bai & Ng, 2008)

Lisaks muutujate valiku järjepidevuse probleemile on Lasso ühe vajaliku tingimusena hilisemates töödes nimetatud esindamatuse tingimus: mitteolulised muutujad ei tohi olla liigselt korreleeritud oluliste muutujatega. Samas on kinnitatud, et kõik olulised muutujad osutuvad siiski valituks. Samuti peaks Lasso väga hästi toimima väikse valimi korral, kuna väiksema valimi korral valib lasso regressioon mudelisse ka väiksema arvu muutujaid. (Zhao & Yu, 2006; Meinshausen & Yu, 2009) Selleks, et Lasso ei annaks suurtele koefitsientidele kallutatud väärtused ega jätaks mudelisse müra omadusi, pakkus Zou välja alternatiivse meetodi, mida nimetatakse adaptiivseks lassoregressiooniks (adaLasso). Kuigi lahendus põhineb samasugusel efektiivsel algoritmil, siis adaLasso puhul kasutatakse adaptiivseid kaalusid erinevate koefitsientide väljapraakimisel. (Zou, 2006) AdaLasso õigete muutujate valikut ja paremat ennustusvõimet kinnitati Medeiros ja Mendes töös Ameerika Ühendriikide kuupõhise inflatsiooni prognoosimisel. (Medeiros & Mendes, 2016) Medeiros uuris ka Brasiilia inflatsiooni ning järgmises töös tõestati jällegi adaLasso paremust. Lisaks sellele märgiti ära, et see meetod on parim just lühiajalise ehk nelja kuu prognoosi koostamiseks. (Medeiros et al., 2016) AdaLasso tulemused halvenesid vähesel määral siis, kui sõltuva muutuja protsess oli väga autokorreleeritud. (Medeiros & Mendes, 2017)

Kirjandusest ilmneb veel üks tõhus masinõppe meetod prognoosimudelite koostamiseks, mida just viimaste aastate töödes enam kasutatakse – juhuslik mets (*Random Forest*, RF). Juhuslikkus on sisse toodud vaatluste ja parameetrite valikul, mille tulemusel väheneb sõltuvus andmete muutumisest, andmetes olevast mürast ja erinditest. See meetod ei eelda andmete eeltöötlemist ega parameetrite valikut. (Masinõppe OÜ, 2023) Näiteks ületas RF mudeli kirjeldusvõime testvalimiga Lassot 39,1% ja OLS 37,8%, kuid välja jäetud valimi (*hold-out sample*) põhjal ületasid tulemused Lassot 2,2% ja OLS 3,8%. Ehk siis RF puhul on üheks probleemiks liigne sobitamine (*overfitting*), mis tähendab, et piiratud vaatluste arvu korral sobitatakse mudel olemasolevate vaatluste järgi. Selle tulemusena sobitub mudel küll algse andmestikuga, kuid ei pruugi sobituda andmetega valimist väljaspool. Probleemi lahendusena soovitatakse jätta osa andmetest valimist välja ning seda kasutada mudeli prognoosimisvõime testimiseks. (Mullainathan & Spiess, 2017) RF meetod andis parimaid tulemusi Ameerika Ühendriikide inflatsiooni kiirhinnangu koostamisel, kus muuhulgas kasutati ka RW, DFM, Lasso, adaLasso mudeleid. Meetodi head tulemused avaldusid just majanduskriisi ja suurt ebamäärasust sisaldavatel aastatel. (Medeiros et al., 2021) Olulise informatsiooni säilitamiseks mudeli koostamise andmetes on võimalik välja jäetud valimi asemel

mudeli valikuks kasutada järeltestimise (*backtesting*) tulemusi. Ehk siis valida periood, mille tulemusi kasutada mudelite prognoosimisvõimekuse testimisel ja parima mudeli valikul. Juhusliku metsa kasutamisel tuleb arvestada lisaks parameetrite stabiilsete hinnangute puudumisele ka sellega, et mudel ei anna tegurite koefitsiente ja mudeli statistilisi andmeid tavapärasel kujul, vaid tegurite olulisust uurimisobjekti prognoosimisel hinnatakse olulisuse määraga keskmises ruutveas - suurem osakaal tähistab olulisemat tegurit inflatsiooni kiirhinnangu koostamise mudelis. Viimastel aastatel on RF eelistatud meetod kiirhinnangu andmisel nii majandusele kui ka inflatsioonile. (Dauphin et al., 2022; Liu et al., 2022)

1.3 Andmete valik

Andmete valik sisaldab endas sõltuva ja sõltumatute muutujate valikut. Sõltuv muutuja on analüüsi uurimisobjekt, antud juhul inflatsioon ehk tarbijahinnaindeksi muutus ajas. (Fan, 2010, 592-594) Kuigi kirjanduse põhjal on levinud viis kasutada tarbijahinnaindeksit agregeeritud kujul, siis selle desagregeeritud kujul modelleerimine on kohati andnud paremaidki tulemusi. See võimaldab parendada mudeli prognoosimisvõimet ning tulemus on samaväärne mudelitega, mis põhinevad küsitlusandmetel. (Allon, 2015; Ibarra, 2012)

Kuigi tegurite ja inflatsiooni vahelised seosed esinevad pigem varjatud kujul, siis andmete valiku protsessis on oluline võimaliku seose hindamine inflatsiooni majandusliku sisuga. Selgitavate muutujate valikul tuleb lähtuda põhimõttest, kas sõltuv muutuja võib reageerida vastava selgitava muutuja käitumisele. Sealjuures on oluline vastupidise olukorra vältimine, kus vaatlusobjekt ise põhjustaks selgitava muutuja käitumise muutumist. (Fan, 2010, 592-594) Selgitavate muutujatena on senistes töodes peamiselt kasutatud kvantitatiivseid majanduslikke indikaatoreid. Ajaloos kasutati algselt eraldi ühekuulist intressimäära (Fama, 1975) või töötuse määra (Stock & Watson, 1999). Faktoranalüüsi kasutamisega inflatsiooni prognoosimisel hakati kasutama erinevaid muutujaid: rahandus, hinnad, tootmine/tööstus, tööturg, küsitlused, energeetika ning desagregeeritud inflatsiooni muutujad. Andmete valik sõltus peamiselt kättesaadavusest ja usaldusväärsusest. (Giannone et al., 2006; Modugno, 2013; Medeiros et al., 2016) Küsitlusandmed on sisuliselt hinnang eesolevale inflatsioonile, mõjutades palkasid ja hinnakujundust. (Ang et al., 2007; Giannone et al., 2006; Funke et al., 2015) Rahanduse muutujate osas on selgunud, et need ei aita inflatsiooni prognoosimisel (Modugno, 2013) või aitavad pigem keskmises või pikas perspektiivis. (Funke et al., 2015) Inflatsiooni prognoosimist on parandanud valitsuse võlg,

valuutakurss ja inimeste käes oleva raha (Medeiros et al., 2016) Hindade osas on olulised kaupade, (Funke et al., 2015) vara, (Giannone et al., 2006) transpordi, energia ja toorme hinnad. (Modugno, 2013) Inflatsiooni puhul on tähendatud mõningate riikide puhul hooajalisust, mistõttu on analüüsid kasutatud nii hooajaliselt kohendatud (Ang et al., 2007; Ibarra, 2012) kui ka kohendamata andmeid. (Medeiros et al., 2022)

2. ANDMED JA METOODIKA

Analüüsi metoodika sisaldab endas kirjanduse põhjal enim kasutust leidnud mudelite ülevaadet. Võrdlusmudelina kasutatakse ARIMA mudelit. Kiirhinnangu mudelitena kasutatakse lineaarseid Lasso ja adaLasso regressioone ning mittelineaarset RF. Sealjuures tuleb tähelepanu pöörata kirjanduse ülevaates esitatud võimalikele probleemidele, mis erinevate mudelite kasutamisel tekkida võivad ning leida neile lahendus. Lähemalt räägitakse nendest vastavate meetodite alapeatükkides.

Eesmärk on jõuda järgmise lihtsa ning kergesti rakendatava mudelini:

$$THI_t = a + b THI_{t-1} + c THI_{t-2} + d THI_{t-3} + e THI_{t-4} + f X_{t-1} + g X_{t-2} + h X_{t-3} + i X_{t-4} + \varepsilon_t, \quad (1)$$

kus THI_t on prognoositav tarbijahinnaindeks (avaldatud kujul või põhikaubagrupi tarbijahinnaindeks) ajahetkel $t = 1, \dots, T$. Valemis (1) on näha, kuidas selgitavate muutujate hulka kuuluvad nii vastava tarbijahinnaindeksi kui ka selgitavate muutujate $X_{t-1}, X_{t-2}, X_{t-3}$ ja X_{t-4} sobivaima viitajaga muutujad. ε_t tähistab vealiikmeid.


Analüüsi läbiviimiseks kasutatakse R Studio tarkvara. ARIMA mudelite puhul kasutatakse pakette stats ja forecast, lassoregressioonide puhul paketti glmnet ja juhusliku metsa puhul randomForest.

2.1 Andmed

Andmed põhinevad Eesti Statistikaameti, Eurostati, Euroopa Komisjoni ja Eesti Panga avaldatud kuise sagedusega andmetel. Lisas 2 on esitatud analüüsis kasutatavad muutujad koos täiendava informatsiooniga kasutatud teisenduste, avaldamise viitaja ja andmete päritolu osas. Algandmed hõlmavad endas vaatlusi 2006. aasta jaanuarist kuni 2023. aasta veebruarini. Lähtuvalt teisenduste rakendamise ja viitaegade kasutamisega on mudeli koostamisel periood alates 2006. aasta juulist kuni 2023. aasta veebruarini (vaatluste arv $T=200$). Ehk siis analüüsiv periood sisaldab kahte viimast tarbijahinnaindeksi tippu. Valim koosneb 13 tarbijahinnaindeksi näitajast ning 212 selgitavast tegurist. Kui andmete avaldamisel ei esineks viitaegu, siis vastavalt valemile (1) oleks

kuni neljandat järku viitaegade kasutamisega mudelis maksimaalne selgitavate muutujate *THI* ja *X* arv $n = (1 + 212) \times 4 = 852$, kuid arvestades andmete avaldamise viitaegadega kasutatakse igas mudelis ilma küsitlusandmeteta $n = 787$ ning koos küsitlusandmetega $n = 807$ erinevat selgitavat muutujat.

Tarbijahinnaindeks (THI) näitab keskmise tarbija regulaarselt ostetavate tarbekaupade ja teenuste ehk esinduskaupade hinna muutust. Statistikaamet avaldab THI muutuse võrreldes eelmise aasta sama kuuga igakuiselt, iga kuu viiendal tööpäeval. Indeks esitatakse nii agregeeritud kujul kui ka desagregeeritud kujul ehk põhikaubagruppide lõikes. (Eesti Statistikaamet, 2023a) Joonisel 1 on kujutatud tarbijahinnaindeksi muutus võrreldes eelneva aasta sama kuuga perioodil alates 1998. aasta jaanuarist kuni 2023. aasta veebruarini.



Joonis 1. Eesti tarbijahinnaindeksi muutus võrreldes eelmise aasta sama kuuga

Allikas: Autori koostatud, Statistikaamet, tabel IA02 baasil

Joonisel 1 võime märgata küll teatavat üldist stabiilsust, kuid silma jäävad ka tarbijahinnaindeksi suuremad muutused. Inflatsioon on sageli olnud tingitud Eesti majandust mõjutanud väliskeskkonnast. Näiteks 1998. aasta teisel poolaastal tõusis inflatsioon kuni 9,2%-ni detsembris. 1998. aasta suvel oli Venemaal finantskriis, mis tõi regioonis kaasa ka teiste riikide kaubavahetuse kiire vähenemise Venemaaga. Venemaal kiirenes sel perioodil hinnakasv, tõustes detsembriks 84,4%-ni. (Eesti Pank, 1999) Samas võib Eesti hinnakasvu mõjutada ka siseriiklik majandusaktiivsuse kasv. Näiteks oli hinnakasv kiire alates 2007. aasta viimasest kvartalist, saavutades tippu 11,4% 2008. aasta juunis. Seda perioodi iseloomustab majanduskasvu aeglustumine, mis päädis majanduskriisiga 2009. aastal. (Eesti Pank, 2008, 17–22) Kolmas inflatsiooni tipp 24,8% saavutati 2022. aasta augustis. Kasvu põhjuseks peetakse peamiselt Vene-Ukraina sõda, mis põhjustas energia kallinemise. Samuti kasvasid oluliselt toiduainete hinnad, viitega jaehindadesse jõudnud varasema toidutoormete hinnatõusu tõttu. (Eesti Pank, 2022b) Viimasele tipule eelnes enam kui aasta pikkune inflatsiooni kasv ning veel 2023. aasta

alguseks ei olnud inflatsioon stabiliseerunud. Samuti võib märgata, et vaatamata hinnataseme üldisele tõusule, mis peaks piirama nominaalset konvergenti, on aja jooksul inflatsiooni tippasemed olnud pigem järjest kõrgemad.


Desagregeeritud kujul on kulutused rahvusvahelise individuaaltarbimise klassifikaatori järgi jaotatud 12 kaubagruppi: toit ja mittealkohoolsed joogid, alkohoolse joogid ja tubakatooted, riietus ja jalatsid, eluase, majapidamine, tervishoid, transport, side, vaba aeg, haridus ja lasteasutused, söömine väljaspool kodu ja majutus, mitmesugused kaubad ja teenused. (Statistikaamet, 2023) THI kulutuste struktuur kaubagruppide kaaludega on alates 2023. aastast järgmine: (Eesti Statistikaamet, 2023b)

$$\begin{aligned} THI = & 0.224 \textit{Toit} + 0.0464 \textit{Alkohol} + 0,0485 \textit{Riided} + 0,1799 \textit{Eluase} \\ & + 0,0652 \textit{Majapidamine} + 0,0549 \textit{Tervis} + 0,1495 \textit{Transport} \\ & + 0,0436 \textit{Side} + 0,079 \textit{Vaba} + 0,0107 \textit{Haridus} + 0,0398 \textit{Majutus} \\ & + 0,0585 \textit{Mitmesugused}, \end{aligned} \quad (2)$$

kus

Toit – toit ja mittealkohoolsed joogid,
Alkohol - alkohoolsed joogid ja tubakatooted,
Riided - riietus ja jalatsid,
Eluase – eluase,
Majapidamine - majapidamine,
Tervis – tervishoid,
Transport – transport,
Side – side,
Vaba - vaba aeg,
Haridus - haridus ja lasteasutused,
Majutus - söömine väljaspool kodu ja majutus,
Mitmesugused - mitmesugused kaubad ja teenused.

Kui vaadelda tarbijahinnaindeksi keskmist muutust ja standardhälvet põhikaubagruppide lõikes võrreldes eelneva aasta sama kuuga perioodil alates 1998. aastast kuni 2023. aasta veebruarini (Joonis 2), on märgata erinevate tarbijahinnaindeksite erinevaid karakteristikuid.



Joonis 2. Desagregeeritud tarbijahinnaindeksite muutus võrreldes eelmise aasta sama kuuga, perioodi 1998 jaanuar kuni 2023 veebruar keskmine ja standardhälve

Allikas: Autori koostatud, Statistikaamet, tabel IA02 baasil

Joonisel 2 toodud statistika näitab, et suurima keskmise muutusega on eluaseme, majutuse ja alkoholiga seotud tarbijahinnaindeksid. Eluasemega seotud kulud on võrreldes eelmise aasta sama kuuga vaadeldaval perioodil 1998. aasta jaanuarist kuni 2023. aasta veebruarini suurenenud keskmiselt 7,8%, majutusega seotud kulud 5,7% ning alkohol 5,3%. Kõrge standardhälbe tulemus indikeerib aga suuremat kõikumist vaadeldava perioodi keskmisest. Varieeruvus ületab 5% eluaseme (11,5%), hariduse (8,8%), transpordi (7,9%), side (6,7%) ja toidu (6,1%) tarbijahinnaindeksite puhul.

Eesmärk on leida mudelisse sellised tegurid, mis aitavad prognoosida tarbijahinnaindeksit. Ehk siis tegurid, mille varasemate kuude käitumisele prognoositav tarbijahinnaindeks reageerib, sealjuures võivad sobivateks muutujateks olla ka sama tarbijahinnaindeksi kuni neljandat järku viitajaga tulemused. Sarnaselt varasematele töödele kasutatakse andmeid energeetikast, hindadest, tööstusest, tööturust, rahandusest ja küsitlusandmeid. Andmestik sisaldab ka kaubavahetuse statistikat Venemaaga, kuna nii 1998. aasta kui ka tänane inflatsiooni kasv on mingil määral seotud Venemaa kaubavahetusega. Samuti sisaldab andmestik järgmisi Eesti Statistikaameti kuupõhise sagedusega andmeid, mis võiksid mudeli prognoosimisvõimekust parendada: põllumajandus, sisekaubandus, transport, majutus. Selgitavaid muutujad on grupeeritud järgmiselt:

- 1) Energeetika (10 muutujat energia tootmisest, impordist ja ekspordist, tarbimisest),
- 2) Hinnad (21 hinnaindeksit tootmisest, ekspordist ja impordist, ehitusest),
- 3) Põllumajandus (14 muutujat piima hinnast ja tootmise kogusest, kokkuostetud loomade kogusest ja hinnast),
- 4) Sisekaubandus (30 muutujat müügitulust ja müügitulu mahuindeksist),

- 5) Transport (2 muutujat registreeritud sõiduautodest),
- 6) Majutus (1 muutuja, majutatute arv),
- 7) Tööstus (88 kalendaarselt ja sesoonselt korrigeeritud ja korrigeerimata muutujat tööstustoodangu mahuindeksitest),
- 8) Tööturg (4 sesoonselt korrigeeritud ja korrigeerimata muutujat töötute arvust ja töötuse määrast),
- 9) Rahandus (4 muutujat intressimäärast ja kodumajapidamiste hoiusejäägist),
- 10) Väliskaubandus (33 muutujat kaubavahetusest Venemaaga (eksport ja import)),
- 11) Küsitlusandmed (5 muutujat erinevatest hinnaootustest).

Energiasektorit iseloomustavate tegurite grupp sisaldab erinevate energia liikide toodangu suurust ja toodanguindeksit, aga ka elektrienergia impordi ja ekspordi ning ettevõtetele või kodutarbijatele müüdud elektrienergia osatähtsust lõpptarbimises. Energia tootmise maht on oluline, kuna mida rohkem suudab riik oma energiavajadusest ise ära katta, seda odavam on küllaltki piiratud riikidevaheliste ülekandevõimsuste tingimustes energiakandjate hind lõpptarbijale. Elektrienergia osatähtsus lõpptarbimises näitab, kuidas jaguneb elektrienergia tarbimine ettevõtete ja kodutarbijate vahel. Need tegurid on analüüsi valitud seetõttu, et ettevõtjatele kui suurtarbijatele võib eksisteerida parem elektrienergia hind võrreldes kodutarbijatega.

Hindade dünaamikat esindavate tegurite grupp sisaldab endas erinevaid hinnaindekseid: tootjahinnaindeksid, ekspordihinnaindeks, impordihinnaindeks, ehitushinnaindeksid, remondi- ja rekonstrueerimistöõde hinnaindeksid. Tootjahinnaindeks on üks olulisemaid komponente toote lõpliku hinna kujunemisel – tootjahinnaindeksi kasv suurendab tarbijahinnaindeksit, kuna toote lõpliku hinna kasv on pikemas perspektiivis paratamatu juhul, kui tootja ei vähenda oma kasumimarginaali. Ekspordi- ja impordihinnaindeks kujundavad rahvusvahelise kaubavahetuse hindasid ning võivad seeläbi mõjutada tarbijahindasid. Ettevõtjad valivad üldjuhul kasulikuma tee, kas müüa toode koduturule või ekspordida riigist välja. Samas sisetarbimise hinnaelastsuseid kujundab konkurents siseturul - tarbijad teevad endale kasulikuma valiku kodumaise ja imporditud toodete hindade vahel. Kui aga puudub odavam valik, siis tarbija maksab toote eest kõrgema hinna ja selle tulemusel suureneb ka tarbijahinnaindeks. Ehitus-, remondi- ja rekonstrueerimistöõde hinnaindeksite kasv suurendab eelkõige eluaseme tarbijahinnaindeksit, mis moodustab tarbijahinnaindeksist arvestatava osa (18%).

Põllumajandus on Eesti puhul tähtsal kohal, kuna peamised tarbitavad tooted on kohapeal toodetud. Siia gruppi kuuluvad tegurid üksikute toodete keskmise hinna kohta (piim, veised, sead, lambad ja kitsed) ning tootmise koguse või kokkuostetud loomade arvu kohta. Tegurid on valimisse lisatud eeldusel, et tootmise koguse hoidmisel vajalikul tasemel puudub vajadus nende põhiliste toidulaua komponentide sisseostmiseks ning sellisel juhul suudetakse hoida ka tarbijahinnaindeks madalamal tasemel. Igasugune kõrvalekalle võib aga tarbijahinnaindeksit suurendada olulisel määral. Ning toodete maksumus ehk keskmine hind mõjutab otseselt tarbijahinnaindeksit, kuna toidu osakaal tarbijahinnaindeksis on suurim (22,4%).

Sisekaubanduse tegurite grupp sisaldab endas erinevate valdkondade müügitulu suurust. Tegurite lisamisel valimisse arvestati võimaliku nõudluspoolsete inflatsiooni kujundavate teguritega. Nõudluse kasv võib põhjustada inflatsiooni kasvu. Samal põhimõttel on valimis ka transpordi tegurite gruppi kuuluvad registreeritud sõiduautode arvud. Nimelt, suurem registreeritud sõiduautode arv tähistab suuremat nõudlust sõiduautode järele ning see võib omakorda päädida sõiduautode hindade kasvuga. Kuid sageli peegeldab sõiduautode registreerimisstatistika ka üldisemaid trende nõudluskeskkonnas, sh tarbijate kindlustunnet, mis kõigub majandustsükliga sarnases rütmis.

Majutuse tegurite gruppi kuulub vaid üks muutuja, majutatute arv. Ka siin kehtib põhimõte, et kuni nõudlus on kõrge, ehk siis majutatute arv on suur, siis saavad ka hinnad olla kõrgemad. Kuid nõudluse vähenedes langeb majutatute arv ja käibe tagamiseks peavad ettevõtted hakkama hindu alla laskma. Seega, majutatute arvu vähenedes on võimalik tarbijahinnaindeksi vähenemine, kuid majutatute arvu kasv võib suurendada tarbijahinnaindeksit. Lisaks võivad sissetulevad turismivood mõjutada ka tavapäraselt mittekaubeldavateks loetud kaupade ja teenuste hindasid siseturul.

Tööstuse tegurite gruppi kuuluvad erinevad tööstustoodangu mahuindeksid, nii korrigeerimata kujul kui ka kalendaarselt ja sesoonselt korrigeeritud. Põhjus, miks analüüsis kasutatakse nii korrigeeritud kui ka korrigeerimata andmeid on olukord, et tarbijahinnaindeksis võib sisalduda teatav hooajalisus, sest tarbijahinnaindeksi algandmeid sesoonselt ei siluta ning isegi aastakasvude kasutamisel võib avalduda näiteks lihavõttepühade või allahindluskampaaniate kaudne mõju. Muutujate valik on sarnane varasematele töödele, kus lähtuti samuti eeldusest, et valitud tegurid võivad teataval määral kirjeldada tarbijahinnaindeksis sisalduva hooajalisuse. Võimalik seos tööstustoodangu mahuindeksi ja tarbijahinnaindeksi vahel on see, et kui tööstustoodangu

mahuindeks peaks mingil põhjusel olulisel määral vähenema siis võib see mõjutada ka inflatsiooni. Kui aga tootmise maht järsult kasvab, siis on võimalik, et hindu hoopis langetatakse.

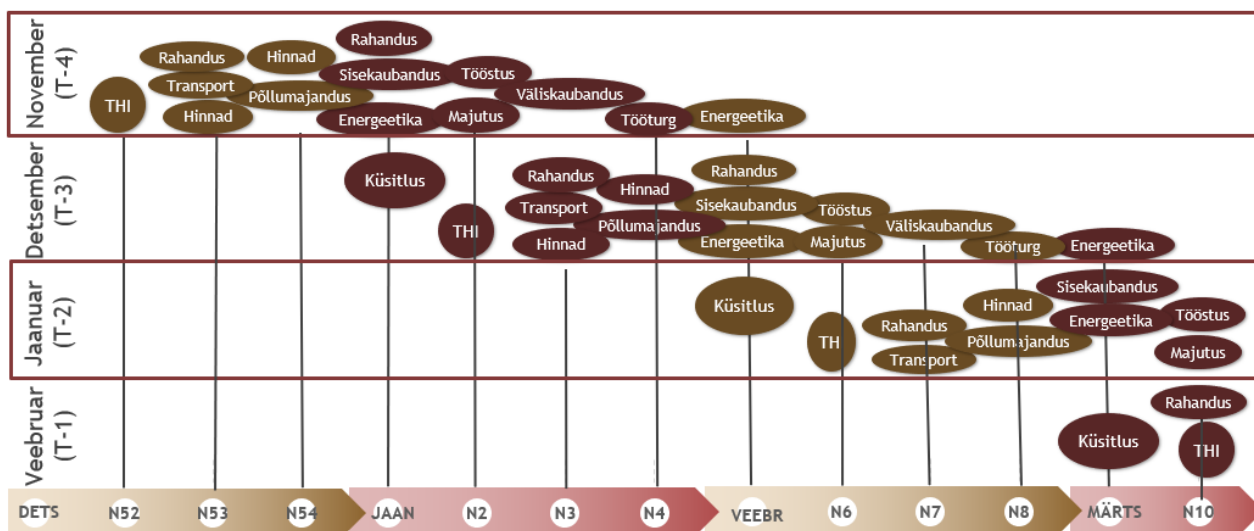
Tööturu tegurite gruppi kuuluvad registreeritud töötute arv ning töötuse määr. Ka siin on kasutatud lisaks sesoonselt korrigeeritud andmeid võimaliku hooajalisuse eksisteerimise tõttu. Kui registreeritud töötute arv kasvab ja sellega koos ka töötuse määr, siis üldjuhul kaob ära palgatõusu surve ja sellega koos ka palgatõusust tingitud tarbijahinnaindeksi kasv.

Finantssektorit iseloomustavate tegurite gruppi kuuluvad andmed intressimäära ning kodumajapidamiste hoiusejäägi kohta. Intressimäära puhul ei ole Eesti kohta andmeid, seetõttu kasutatakse euroala ühe- ja kolmekuulist intressimäära. Madalam intressimäär elavdab majandusaktiivsust. Sama põhimõte on kodumajapidamiste hoiusejäägiga – mida rohkem omavad kodumajapidamised rahalisi puhvreid, seda vähem tundlikuks võib osutada tarbimine väiksemate hinnakõikumiste tingimustes. Hoiuste vähenedes vähenevad tarbijate kulutused ning inflatsioon ei saa enam varasemas mahus suurened. Kuigi kirjanduses on üksikutes analüüsid häid tulemusi andnud valitsuse võlg, siis käesolevas analüüsis seda ei kasutata andmete hilise avaldamise tõttu. Nimelt, analüüsi koostamise hetkel on puudu nelja viimase kuu andmed, mis on ühtlasi maksimaalne viitaeg, mida muutujatele rakendatakse. Valuutakurssi ei kasutata, kuna vaadeldaval perioodil toimus riigis valuuta üleminek kroonilt eurole. Valuutakursside muutused on kajastatud seega pigem impordihinnaindeksi kaudu. Kõiki neid analüüsis mittekasutatavaid muutujaid ühendab ka asjaolu, et need muutujad on mudeli prognoosimisvõimekust suurendanud vaid üksikutel juhtudel.

Väliskaubanduse tegurite gruppi kuuluvad erinevate toodete Venemaale ekspordi ning impordi Venemaalt näitajad, mis ajalooliselt on teataval määral inflatsioonile mõju avaldanud. Venemaa on tuntud oma odavama hinnaklassiga toodete poolest, mistõttu suurem import Venemaalt annab tarbijatele võimaluse maksta sama toote eest vähem ehk siis võimaldab vähendada inflatsiooni. Kuid olukorras, kus hoopis eksport Venemaale suureneb, tähendab kohaliku tarbija jaoks vastupidist olukorda, kuna odavam toode müüakse riigist välja (kuna arvestada tuleb sihtturu võimalustega) ning valikusse jäävad kallimad hinnad. Sellisel juhul ekspordi kasv võib suurendada tarbijahinnaindeksit.

Küsitlusandmete tegurite grupp sisaldab endas erinevaid hinnaootusi kas järgneva 3 või 12 kuu jooksul. Sealjuures tuleb arvestada, et positiivne hinnaootus tähistab oodatavat tarbijahinnaindeksi kasvu ning negatiivne hinnaootus oodatava tarbijahinnaindeksi vähenemist. Nii antakse hinnang ehitushindadele (3 kuu ettevaade), hindadele tarbija vaatest (12 kuu ettevaade), toodangu müügihindadele (3 kuu ettevaade), kaupade hindadele (3 kuu ettevaade) ning teenuste hindadele (3 kuu ettevaade). Küsitlusandmete kasutamine hinnapoliitika kujundamisel on realistlik, kuna see annab edasi ettevõtjate ja tarbijate tunnetust eesoleva perioodi kohta. Kui asjaosalised ootavad hinnatõusu, siis on kergem see ootus realiseerida päris hinnatõusuks ning selle tulemusel tarbijahinnaindeks suureneb.

Joonisel 3 on kujutatud erinevate kuude andmete avaldamise ajatelg. Kuna andmed avaldatakse erineval ajal ning nagu ka jooniselt näha, siis märtsi esimestel nädalatel saame teada vaid veebruari tarbijahinnaindeksi, rahanduse näitajate andmed ning küsitlusandmed. Muu on veelgi suurema ajalise viitega. Sellisel juhul tuleb kasutada mudelis viitaegasid vastavalt andmete kättesaadavusele.



Joonis 3. Andmete avaldamise ajatelg

Allikas: Autori koostatud

Lisas 3 on toodud valimi korrelatsioonimaatriks. Metoodika valikul tuleb arvestada, et muutujate vahel esineb vähemalt mõningane korrelatsioon. Seda eelkõige hinnaindeksite puhul. Muude kategooriate puhul esineb korrelatsiooni üksikute muutujate seas.

Andmete osas seab tingimused peamiselt lassoregressioonide kasutamine. Selleks peavad paneelandmed olema tasakaalustatud ning aegread statsionaarsed. Kuna statistikat avaldatakse viitega, siis mõningate selgitavate muutujate puhul on puudu ühe või kahe kuu andmed. Aegrea statsionaarsuse testimiseks kasutatakse Dickey-Fuller ühikjuure testi (ADF). Vajadusel muudetakse aegrida statsionaarseks, kasutades transformatsiooni ehk teisendust. Enamlevinud teisenduse formaadid on esimest järku diferents Δx_t , teist järku diferents $\Delta^2 x_t$, logaritmine $\log x_t$, esimest järku diferents logaritmist $\Delta \log x_t$, teist järku diferents logaritmist $\Delta^2 \log x_t$ ning kasvumäära muut $\Delta(\frac{x_t}{x_{t-1}} - 1)$. (Bai & Ng, 2008; Medeiros et al., 2021)

Lassoregressioonid eeldavad ka sõltumatute muutujate standardiseerimist ehk väärtused peavad olema samas skaalas. Ning sarnaselt varasematele töödele kasutatakse mudelites nii sõltuva kui ka selgitavate muutujate viitaegasid, iga muutuja kohta esimest kuni neljandat järku viitaega (Medeiros & Mendes, 2016) nagu on kirjeldatud valemis (1).

2.2 Mudelite prognoosimisvõimekuse võrdlemine

Analüüsi eesmärk on valida parim meetodika inflatsiooni kiirhinnangu loomiseks selliselt, et kiirhinnangu või prognoosimise viga oleks minimaalne. Mudelite prognoosimisvõimekust hinnatakse valdavalt RMSE ehk keskmise ruutveaga (*root mean squared error*):

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}. \quad (3)$$

Ning MAE ehk keskmine absoluutne ruutviga (*mean absolute error*) on arvatav järgmiselt:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|. \quad (4)$$

RMSE sobib normaaljaotusega prognoosimisvigade puhul ning MAE pigem muu jaotuse puhul. (Hodson, 2022) Mõlema näitaja puuduseks on mõjutatavus erinditest (üksikud suured prognoosimisvead). Seetõttu soovitatakse kasutada MAD ehk mediaani absoluutset hälvet (*median absolute deviation*), mis on defineeritud järgmiselt:

$$MAD = \text{median}(|y_1 - \hat{y}_1|, \dots, |y_n - \hat{y}_n|), \quad (5)$$

kus y_i tähistab tarbijahinnaindeksi tegelikku väärtust ja \hat{y}_i on tarbijahinnaindeksi prognoos ajahetkel i . (Biecek & Burzykowski, 2021, 175–188) MAD kasutamise eelis tuleneb nii erindite kui ka asümmeetrilisuse esinemisel. Kõiki kolme näitajat kasutati ka Medeiros, Vasconcelos, Veiga ja Zilbermani 2021. aasta Ühendriikide inflatsiooni prognoosimisel. Nende kolme näitaja koos

kasutamine on oluline selleks, et tulemused ei oleks niivõrd sõltuvuses üksikutest suurtest prognoosimisvigadest. (Medeiros et al., 2021)

Kuna valitud meetodite puhul võib esineda liigse sobitamise probleem, siis käesolevas analüüsis arvutatakse RMSE, MAE ja MAD nii koguvälimi kui ka vaadeldava järetestimise perioodi valimi kohta. Viimasel juhul luuakse mudeli testimise valim, mis sisaldab viimase 14 kuu prognooside andmeid ehk perioodi 2022. aasta jaanuarist kuni 2023. aasta veebruarini. Mudelite võrdlemise järelduste jaoks kasutatakse analüüsi lihtsustamiseks kolme prognoosimisvõimekuse näitaja keskmist tulemust.

Desagregeeritud tarbijahinnaindeksi puhul raskendab tulemuste hindamist iga-aastaselt muutuvad põhikaubagruppide kaalud avaldatud tarbijahinnaindeksis. Seetõttu arvutatakse nii tegelikud kui ka prognoositavad desagregeeritud tarbijahinnaindeksi väärtused valemi (2) järgi ning seejärel arvutatakse vastava mudeli prognoosimisvõimekuse näitajad valemite (3), (4) ja (5) järgi.

2.3 Autoregressiivse (ARIMA) mudeliga prognoosimine

Inflatsiooni prognoosimudeli võrdlusmudelina kasutatakse enamasti ARIMA mudelit. Autoregressiivsete integreeritud liikuva keskmisega ehk ARIMA mudelid kombineerivad AR, MA ja I protsessid. AR tähistab autoregressiivset protsessi, millel on pikk mälu, kuna hetkeväärtus on korreleeritud varasemate perioodidega. MA tähistab libisevat keskmist, mis on kujunenud väikse arvu varasemate andmete kaalutud keskmiste abil ja on lühikese mäluga. Ning I tähistab integreeritud protsessi, mis tuleneb mittestatsionaarsest protsessist ja tema peamine omadus on keskmise pidev muutumine ajas. (Peña & Tsay, 2021, 37-102)

Inflatsiooni prognoosimisel või inflatsioonile kiirhinnangu andmisel on parimaid tulemusi andnud ARMA(1,1) ja ARIMA(0,1,0) ehk RW. Ühe või teise kasutamise valik sõltub vastava tarbijahinnaindeksi aegrea iseloomust ja otsustatakse Box-Ljung statistiku põhjal. RW puhul vastab aegrida valge müra tingimustele. (Peña & Tsay, 2021, 82-87)

Esimest järku autoregressiivne liikuva keskmisega ARMA(1,1) mudel on kombinatsioon AR ja MA protsessist. See kombinatsioon annab laialdase ja paindliku statsionaarse stohhastiliste protsesside perekonna, mis on vajalik empiiriliste aegridade esindamiseks. (Peña & Tsay, 2021, 37-102) Mudeli kohaselt on inflatsioon summa oodatavast inflatsioonist ja mürast. (Hamilton, 1985) ARMA(1,1) mudel on esitatav järgmiselt:

$$y_{t+1} = \phi y_t + \theta u_t + u_{t+1} \quad (6)$$

kus ϕ tähistab AR(1) parameetrit ja $|\phi| < 1$, θ tähistab MA(1) parameetrit ja $|\theta| < 1$, y_t on inflatsiooni väärtus ajahetkel t ja on statsionaarne protsess ning u_t on vastav juhuslik šokk ajahetkel t . Lisaks statsionaarsusele eeldatakse, et $\phi \neq \theta$. Sellega välditakse AR ja MA parameetrite tühistamist. (Peña & Tsay, 2021, 49-57; Laopodis, 2021, 87-91)

RW ehk ARIMA(0,1,0) vastab valgele mürale ja on integreeritud protsessile vastav mudel. RW mudel on esitatav järgmiselt:

$$y_{t+1} = y_t + u_{t+1}, \quad (7)$$

kus y_t on inflatsiooni väärtus ajahetkel t ja on statsionaarne protsess ning u_t on vastav juhuslik šokk ajahetkel t . Mudeli eelduseks on mittestatsionaarsuse esinemine. (Peña & Tsay, 2021, 49-57; Laopodis, 2021, 87-91)

2.4 Lassoregressioonid

Lasso ja adaLasso regressioonid on kokkutõmbumise meetodid (*shrinkage methods*), kus piiratakse või reguleeritakse koefitsientide hinnanguid nulli suunas. (Gareth et al., 2021, 237) Vähima absoluutse kokkutõmbumise ja valiku operaatoriga ehk lasso regressioon loodi OLS puuduste tõttu: prognoosi täpsus ja tõlgendamise raskus. Seni üritati OLS puudusi lahendada alamhulga valiku meetodi (*subset selection*) ja kantregressiooni (*Ridge regression*) abil, kuid nendel on oma puudused. Alamhulga valiku meetod on diskreetne protsess, mistõttu võib ta olla äärmiselt muutlik. Selgitavad muutujad kas jäetakse valimisse või siis arvatakse sealt välja. Andmete iga väiksema muutumine võib anda tulemiks väga erinevad mudelid ja see vähendab omakorda prognoosi täpsust. Kantregressioon on aga pidev protsess, mis kahandab koefitsiendid ja seetõttu on stabiilsem. Aga ta ei anna ühegi koefitsiendi väärtuseks nulli ja seetõttu ei ole mudel lihtsalt tõlgendatav. OLS puhul on iseloomulik väike kallutatatus, kuid suur varieeruvus. (Tibshirani, 1996)

Lasso kasutamisel ohverdame vähese kallutatuse, et suurendada prognoosimise täpsust. (Tibshirani, 1996) Seda siis, kui koefitsientide hinnangute kokkutõmbumine vähendab nende dispersiooni. (Gareth et al., 2021, 237) Tõlgendamine muutub lihtsamaks koefitsientide muutumisel nulliks, kuna suure arvu selgitavate muutujate korral saame sellega määratleda väiksema muutujate kogumi, mis sisaldab endas kõige olulisemaid tegureid. Tegemist on justkui alamhulga valiku meetodi ja kantregressiooni parimaid omadusi koondava mudeliga. (Tibshirani, 1996)

Kuna varasemalt on tõestatud, et Lasso on järjepidev ainult kindlates tingimustes ja teatud juhtumitel ei suuda õigeid selgitavaid muutujaid välja valida, pakutakse välja adaptiivse lasso meetodi. Erinevus lassoga on erinevate koefitsientide piiramisel l_1 -normiga adaptiivsete kaalude kasutamine. (Zou, 2006)

2.4.1 Lassoregressioon (Lasso)

Lasso on motiveeritud Breimani mittenegatiivsest garottist (*garotte*), mis kahandab OLS hinnangud mittenegatiivseteks faktoriteks, mille summa on piiratud. (Breiman, 1995) Garotti puuduseks on sõltuvus märgist ja OLS hinnangu suurusest. Ülesobitatud või suuresti korreleeritud tingimustes, kus OLS hinnangud võivad olla kallutatud, siis garott kannatab samuti selle tagajärjel. Kuid Lasso on OLS hinnangutest vähem sõltuvuses. (Tibshirani, 1996)

Olgu meil lineaarne regressioon selgitavate muutujatega x_{ij} ja sõltuva muutuja väärtused y_i , kus vastav vaatlus on $i = 1, \dots, n$ ja parameeter $j = 1, \dots, p$. Lasso koefitsiendid β_n minimeerivad:

$$\sum_{i=1}^n (y_i - \beta_0 - \sum_{j=1}^p \beta_j x_{ij})^2 + \lambda \sum_{j=1}^p |\beta_j| = RSS + \lambda \sum_{j=1}^p |\beta_j|, \quad (8)$$

kus λ on häälestamise parameeter. Lasso regressiooni kasutamise eeldused võiks kokku võtta järgmiselt (Tibshirani, 1996):


- 1) Vaatlused on sõltumatud või y_i on tingimuslikult sõltumatud x_{ij} suhtes;
- 2) x_{ij} on standardiseeritud nii, et $\sum_i x_{ij}/n = 0$, $\sum_i x_{ij}^2/n = 1$;
- 3) Paneelid peavad olema tasakaalustatud ehk siis ei tohi esineda puuduvaid väärtusi.

Lasso parameetrite leidmiseks kasutatakse parameetrite l_q -normi piirangut, mille on välja pakkunud Frank ja Friedman. Sealjuures $q \geq 0$ ning lasso regressioonis $q = 1$. (Frank & Friedman, 1993) Pehme kokkutõmbumise ja minimaalse l_1 -normi piirangu seose mittenegatiivsete parameetrite jaoks pakkusid algselt välja Donoho, Johnstone, Hoch ja Stern. (D. L. Donoho et al.,

1992) Kasutatav l_1 -normi piirang ehk koefitsiendivektori $\beta = \{\beta_j\}$ l_1 -norm on $\|\beta\|_1 = \sum |\beta_j|$, mis võimaldab osa koefitsientide hinnangutest võrdsustada nulliga juhul, kui λ on piisavalt suur. (Gareth et al., 2021, 241)

Häälestamise parameeter kontrollib kokkutõmbumise ulatust, mida hinnangutele rakendatakse. (Tibshirani, 1996) Õige λ väärtuse valimiseks kasutatakse ristvalideerimist. Kõigepealt valitakse λ väärtuste ruudustik ja arvutatakse iga väärtuse ristvalideerimise viga. Väikseimale ristvalideerimise veale vastab õige λ . Lõpuks kohandatakse mudel uuesti, kasutades kõiki vaatlusi ja valitud λ väärtust. (Gareth et al., 2021, 250) Kuid λ võib valida ka mudeli sobivust kajastava BIC ehk Bayesi informatsioonikriteeriumi järgi. (Medeiros et al., 2021) Käesolevas analüüsis rakendatakse mõlemat varianti mudeli puhul, kus sõltuv muutuja on THI agregeeritud kujul. Seejärel hinnatakse mudeli prognoosimisvõimekust RMSE, MAE ja MAD abil ning tehakse valik, kumba λ valiku meetodit lassoregressioonide puhul edaspidi analüüsis läbivalt kasutatakse.

Lasso ja kantregressiooni vea- ja piirangufunktsioonide kontuurid on esitatud Joonisel 4, kus piirangufunktsioonide alad on märgitud sinise värviga ning RSS ehk veafunktsioonide kontuurid punase värviga (kõik punktid vastaval ellipsil omavad sama RSS väärtust). Vähimruutude lahendus on $\hat{\beta}$ ja mida kaugemal asub ellips sellest, seda suurem on RSS. Koefitsientide hinnangud tulevad vea- ja piirangufunktsioonide kontuuride kokkupuutepunktist. Lasso puhul asuvad ruudu nurgad täpselt telgedel ning kui kokkupuutepunkt satub sinna, siis koefitsient võrdub nulliga. Kantregressiooni puhul ei satu kokkupuutepunkt üldjuhul teljele, kuna tema piirangufunktsioon on ringikujuline. Seetõttu ei saa esineda ka nullkoefitsiente. (Gareth et al., 2021, 244–245)



Joonis 4. Lasso (vasakpoolne) ja kantregressiooni (parempoolne) geometria
Allikas: (Gareth et al., 2021, 244)

Lasso on sobilik meetod olukorras, kus parameetrite arv ületab vaatluste arvu, ehk $p > n$. (Tibshirani, 1996) Samas tuleb silmas pidada, et Lasso annab häid tulemusi just siis, kui olulised koefitsiendid on vaid suhteliselt väiksel arvul selgitavatest muutujatest ning ülejäänute koefitsiendid on kas väga väikesed või võrdsustatud nulliga. Samuti olukorras, kui vähimruutude hinnangutel on liiga suur hajuvus. (Gareth et al., 2021, lk 246)

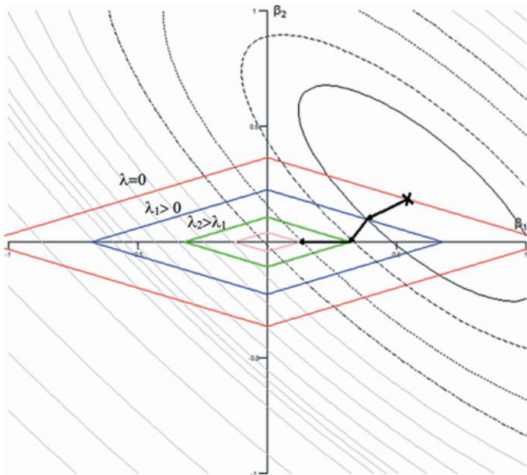
Lasso peamiseks probleemiks peetakse mudeli järjepidevuse probleemi ehk siis mudel on järjepidev ainult kindlates tingimustes ja teatud juhtudel ei suudeta sobivamaid selgitavaid muutujaid välja valida. Lahendusena on välja pakutud valimi suurenedes p ja β_n fikseerimist, (Fu & Knight, 2000) muutujate tihedusfunktsiooni vastavust Gaussi tõenäosuse tihedusfunktsioonile, (Meinshausen & Bühlmann, 2006) ortogonaalse disaini kasutamist (Leng et al., 2006) või hoopis l_2 -normi kasutamist. (Donoho et al., 2006) Kuigi Lasso puhul on tähelepanuväärne asjaolu, et koefitsiendi märk võib erineda OLS hinnangu omast ja Lasso hinnangud peaksid kehtima ka juhul, kui selgitavad muutujad on korreleeritud, (Tibshirani, 1996) siis üheks mudeli järjepidevuse probleemi põhjuseks peetakse muutujate seast mudelisse mitteoluliste muutujate valimist olukorras, kus mitteolulised on oluliste muutujatega korrelatsioonis. (Osborne et al., 1998) Seda nimetatakse esindamatuse tingimuseks ning probleem avaldub ülemääratletud lineaarse süsteemi korral, kui $p > n$. Samas on kinnitatud, et Lasso on siiski võimeline andma häid tulemusi olukorras, kus p suureneb oluliselt kiiremini kui n . Üheks lahenduseks on pakutud märgi järjepidavuse tingimuste rakendamist, kuid selle tulemusel katkeks Lasso piirangute kumerus. (Zhao & Yu, 2006) Praktikas enam rakendust saanud lahenduseks on aga adaLasso, kus erinevate koefitsientide piiramisel l_1 -normiga kasutatakse adaptiivseid kaalusid. (Zou, 2006)

2.4.2 Adaptiivne lassoregressioon (adaLasso)

Adaptiivne lasso (adaLasso) on lassoregressiooni edasiarendus, mis on disainitud selliselt, et vähendada hinnangute kallutatust ja parendada muutujate valiku protsessi täpsust. (Xie et al., 2020, 82) Lisaks häälestamise parameetritele λ rakendatakse igale parameetritele ka täiendavad parameetrite kaalud \widehat{w}_j . (Saleh et al., 2022, 38) Olgu selgitavad muutujad x_{ij} ja sõltuva muutuja väärtused y_i , kus $i = 1, \dots, n$ ja $j = 1, \dots, p$. AdaLasso koefitsiendid β_n minimeerivad (Zou, 2006):

$$\sum_{i=1}^n (y_i - \beta_0 - \sum_{j=1}^p \beta_j x_{ij})^2 + \lambda \sum_{j=1}^p |\beta_j| \widehat{w}_j = \text{RSS} + \lambda \sum_{j=1}^p |\beta_j| \widehat{w}_j. \quad (9)$$

Sarnaselt Lasso kasutatakse ka siin l_1 -normi piirangut ja võrrand (9) on kumer optimeerimise probleem. AdaLasso on kaheammuline meetod. Esimene samm on sama, mis Lasso puhul: andmete sobitamine Lassoga ja parameetrite hinnangute tuletamine nii, et häälestamise parameetri λ leidmiseks kasutatakse ristvalideerimist. Teise sammuna lisatakse Lasso parameetrite hinnangud võrrandisse (9), et leida adaLasso koefitsiendid. Siin tuleb lisaks valida $\gamma > 0$ ja määrateda kaalude vektor $w = (w_1, \dots, w_p)^T$. Zou soovib kaaludena kasutada $\hat{w} = 1/|\hat{\beta}|^\gamma$. (Zou, 2006; Xie et al., 2020, 82) Kuid hilisemates töödes inflatsiooni kiirhinnangu koostamisel on kasutatud $\hat{w} = \frac{1}{|\tilde{\beta}|^\gamma + 1/\sqrt{T}}$, kus $\tilde{\beta}$ on hinnang lassoregressioonist ning $1/\sqrt{T}$ annab esialgses hinnangus välistatud muutujatele uue võimaluse olla mudelisse kaasatud. (Medeiros et al., 2021) Samal eesmärgil kasutatakse ka käesolevas analüüsis viimast kaalude arvutamise meetodit. AdaLasso geometria on esitatud Joonisel 5.



Joonis 5. Adaptiivse lasso geometria

Allikas: (Saleh et al., 2022, 75)

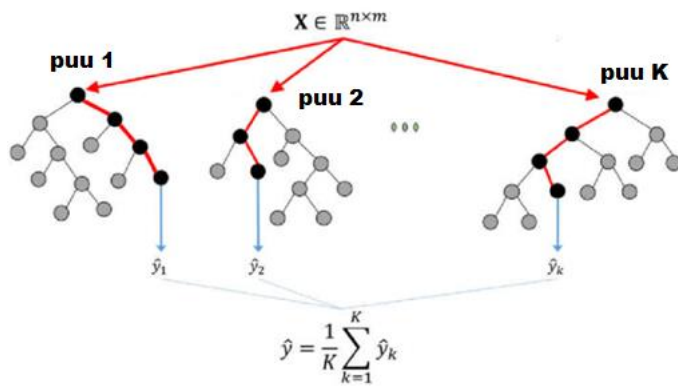
AdaLasso vea- ja piirangufunktsioonide kontuuride (Joonis 5) puhul ellipsid tähistavad jällegi veafunktsioone. Parameetritele kaalude rakendamine muudab piirangufunktsiooni Lasso sümmeetrilise ruudu kujust adaLasso puhul asümmeetriliseks. Täpsemalt tekitavad asümmeetriat kaalude erinevused.

2.5 Juhuslik mets (RF)

Juhuslik mets (*random forest*, RF) loodi selleks, et vähendada regressioonipuude varieeruvust läbi otsustuspuude keskmise võtmise ja ta põhineb juhuslikult loodud regressioonipuude bootstrapkoondamisel (*bootstrap aggregation*). (Breiman, 2001) Tegemist on mittelineaarse ja mitteparameetrilise puupõhise regressiooni- ja klassifitseerimismeetodiga, (Medeiros et al., 2022) mille eeliseks on paindlikkus. Kuigi tavaliselt ei ole masinõppe prognoosimisvõimekus nii hea, võib suure arvu puude kombineerimine parendada oluliselt prognoosimise täpsust, sealjuures tehes järelandmisi tõlgendamise osas. (Gareth et al., 2021, 327) RF kasutamisel on täheldatud prognoosimisvea vähenemist, kuid seda eelkõige suurte valimite puhul. Samuti suudetakse vähendada tulemuste kallutatust. (Breiman, 2001) RF puhul on positiivne ka asjaolu, et ta ei eelda andmete eeltöötlemist ega parameetrite eelvalikut. (Mullainathan & Spiess, 2017)

Juhusliku metsa eelis on mittekorreleeritud puude kasutamine. Juhusliku metsa diagramm on esitatud Joonisel 6. Otsustuspuud luuakse bootstrap treeningvalimis, kus iga otsustuspuu lahkne misel valitakse selgitavate muutujate koguvalimist (n) lahkne mis kandidaatide juhuslik valim m . Lahkne misel on lubatud kasutada ainult ühte valimi m muutujat ning igal lahkne misel võetakse uus valim m muutujast ja valitakse $m \approx \sqrt{n}$ muutujat (algoritm ei luba kasutada rohkem muutujaid). Seeläbi vähendatakse otsustuspuude vahel esinevat korrelatsiooni. Ning kui koguvalimis peaks esinema üks oluline muutuja, siis antud meetodi puhul keskmiselt $(n - m)/n$ lahkne mist isegi ei pruugi arvesse võtta seda ühte muutujat ja nii saavad ka teised muutujad võimaluse anda häid tulemusi. Bootstrap valimile k vastava otsustuspuu prognoosimise reeglid tähistatakse $g_{k(X)}$. Otsustuspuu loomise protseduuri korratakse kokku K korda, seejärel leitakse kõikide bootstrap valimite ennustusreeglite keskmine: (Gareth et al., 2021, lk 343–345; Medeiros et al., 2022)

$$g_{RF(X)} = 1/K \sum g_{k(X)}. \quad (10)$$



Joonis 6: Juhusliku metsa diagramm

Allikas: (Aldrich, 2020, lk 4)

Peamiseks RF probleemiks on ülesobitamine. Seetõttu on vajalik mudeli prognoosimisvõimekust hinnata kas välja jäetud valimi (*out-of-sample*) põhjal või järeltestimisega (*backtesting*). Teiseks probleemiks on asjaolu, et regressioonipuud ei saa luua äärmuslikumaid tulemusi kui need, mis olid treeningvalimis. Näiteks, kui valimis oli ülempiir 5%, siis ka regressioonipuu ülempiir on 5%. (Medeiros et al., 2021) Ehk siis meetod ei pruugi olla parim olukorras, kus tarbijahinnaindeks on tõusutrendis ning prognoositava indeksi suurus võib eelduste kohaselt ületada eelmisi tulemusi. Tänu juhuslikkusele ei ole mudelis stabiilseid koefitsiente, kuna mudeli tulemus võib olla igal algoritmi rakendamisel erinev.

Kuigi juhusliku metsa puhul ei ole võimalik välja tuua selgitavate muutujate koefitsiente, siis on võimalik hinnata tegurite olulisust mudeli keskmise ruutvea (MSE) kasvul. Tegemist on mõõdikuga, kus muutujate ennustusviga on normaliseeritud erinevuste standardhälbega. (Aldrich, 2020) Sisuliselt näitab see teguri panust MSE kasvu. Kehtib põhimõte, et suurem arv näitab suuremat olulisust mudelis ning negatiivne tulem märgib muutuja mitteolulisust (sellisel juhul andis juhuslik muutuja parema tulemuse). Parim viis RF muutujate tulemuste tõlgendamisel on kasutada normaliseerimist, kuid seda tehes on vajalik eelnevalt negatiivse olulisusega tulemused võrdsustada nulliga, kuna nad ei ole olulised ja tegelikult nad ei mõjuta prognoosi negatiivselt.

3. TULEMUSED

Diferentsitud andmete ADF ühikjuure testide tulemused (Lisa 4) kõikide viitaegade puhul kinnitavad andmete teisendamise rakendamise edukust, muutes aegread statsionaarseks. Info analüüsis kasutatud teisendustest sisalduvad Lisas 2 veerus Tr.: andmed on statsionaarsed ehk diferentsimata tasemetel (tähis (0)), kasutatakse esimest järku diferentsi Δx_t (1), teist järku diferentsi $\Delta^2 x_t$ (2) või kasvumäära muut $\Delta\left(\frac{x_t}{x_{t-1}} - 1\right)$ (3).

Teisendatud tarbijahinnaindeksite jääkliikmete iseseisvust testiti Box-Ljung testiga. Testi tulemused (Lisa 4) näitavad, et RW mudelit tuleks rakendada THI, riiete, eluaseme, majapidamise, tervise, side, hariduse, vaba aja, mitmesuguste kaupade ja teenuste tarbijahinnaindeksite puhul. ARMA(1,1) mudelit tuleks rakendada toidu, alkoholi, transpordi ja majutuse tarbijahinnaindeksite puhul. Ka seniseid töid vaadeldes ilmneb, et ARMA(1,1) mudel oli eelistatud ja see andis paremaid tulemusi pigem varasemate aastate töödes. (Hamilton, 1985; Ang et al., 2007) Hilisemates inflatsiooni kiirhinnangu töödes, kus uuriti peamiselt Ühendriikide ja globaalset inflatsiooni, kasutati võrdlusmudelina RW. (Modugno, 2013; Medeiros et al., 2021; Medeiros et al., 2022)

Lasso puhul rakendati tarbijahinnaindeksi mudelis kahte erinevat meetodit λ väärtuse valimiseks. Kuigi prognoosimisvõimekuse näitajaid arvestades andis paremaid tulemusi ristvalideerimine, siis mudeli koefitsiente vaadates ilmnes, et andmete tugev korrelatsioon siiski mõjutab selle meetodi tulemit. Meetod andis väljundiks mudeli, kus oli vaid konstant ning tarbijahinnaindeksi viitajaga liikme koefitsient 0. Seega sai analüüsis eelistatuks valida λ BIC informatsioonikriteeriumi järgi.

Järgnevates alapeatükkides käsitletakse analüüsi tulemusi erinevate tarbijahinnaindeksite lõikes, nii avaldatud kui ka desagregeeritud kujul, andes muuhulgas vastused püstitatud uurimisküsimustele. Esimeses alapeatükis kirjeldatakse parima meetodi valikut, teine alapeatükk tarbijahinnaindeksi kuju valikut ning kolmas alapeatükk annab ülevaate teguritest, mis aitavad prognoosida tarbijahinnaindeksit. Kuigi töös kasutatavate ateooretilisema lähenemise puhul on kesksel kohal just hinnang, kas ja kui hästi on võimalik inflatsiooni kiirhinnangut koostada, mitte

tegurite ja inflatsiooni vahelised seosed. Siis hoolimata seoste esinemisest pigem varjatud kujul kasutatakse tegurite ja inflatsiooni majandusliku sisu vahelist võimalikku seost osaliselt robustsus-analüüsina ja kirjeldatakse põhjuseid, milles antud teguri olulisus seisneda võib inflatsiooni kiirhinnangu koostamisel. Neljandas alapeatükis antakse ülevaade peamiste kauba- ja teenusegruppide tarbijahinnaindekseid prognoosivatest teguritest, kuna ka seal võib leiduda olulist infot tarbijahinnaindeksi paremaks prognoosimiseks. Kuna Eesti inflatsiooni kohta võrdlusuurimust kasutamiseks ei ole, siis tulemusi võrreldakse seniste tööde tulemustega teiste riikide inflatsiooni kiirhinnangu koostamisel. Viimasena on lisatud järeldused ja ettepanekud, kus kirjeldatakse lisaks töö panusele ka võimalikke töö edasiarendusi.

Kuna käesoleva analüüsi andmemahud on väga suured, siis enamus analüüsi tulemustest on pandud lisadesse Dropbox lingina originaalfaili nägemiseks. Selliselt on tegutsetud Lisade 3 (Korrelatsioonimaatriks), 4 (ADF ja Box-Ljung testide tulemused), 7 (Lassoregressioonide muutujate koefitsiendid) ja 8 (Juhusliku metsa muutujate osatähtsus MSE-s) puhul.

3.1 Parim meetod inflatsiooni kiirhinnangu koostamiseks

Kõikide loodud mudelite RMSE, MAE ja MAD prognoosimisvõimekuse näitajate jagatis ARIMA tulemustega järeltestimise perioodil on esitatud Tabelis 1 normaliseeritud kujul nii, et ARIMA tulemus on võrdsustatud ühega. Sellest madalam tulemus indikeerib paremat mudelit ning suurem tulemus tõestab võrdlusmudeli ARIMA paremust. Tumedam roheline märgib parimat prognoosivõimekuse näitaja RMSE tulemust ning heledama roheline tähistab parimaid MAE ja MAD tulemusi.

Tabel 1. Koos küsitlusandmetega loodud mudelite RMSE, MAE ja MAD tulemused suhtena võrdlusmudeli (ARIMA) tulemusega järeltestimise perioodil

Järeltestimine	Lasso			adaLasso			RF		
	RMSE	MAE	MAD	RMSE	MAE	MAD	RMSE	MAE	MAD
THI	0,91	1,16	3,52	1,09	1,36	3,74	0,39	0,49	0,96
THI desagr.	0,78	0,62	0,52	0,82	0,76	0,72	0,34	0,39	0,51
Kombineeritud							0,34	0,39	0,51
sh Toit	1,39	1,66	1,89	1,45	1,75	2,02	0,47	0,52	0,57
sh Alkohol	0,75	0,79	0,81	0,05	0,05	0,06	0,33	0,35	0,49
sh Riided	0,42	0,48	0,52	0,39	0,44	0,49	0,18	0,18	0,19
sh Eluase	0,56	0,58	0,64	0,50	0,51	0,59	0,31	0,28	0,16
sh Majapidamine	0,81	0,68	0,70	0,85	0,81	0,89	0,34	0,40	0,55
sh Tervis	0,80	0,77	0,72	0,80	0,77	0,72	0,27	0,28	0,27

sh Transport	1,02	0,95	0,67	1,02	0,95	0,67	0,40	0,36	0,26
sh Side	0,03	0,03	0,04	0,03	0,03	0,04	0,30	0,27	0,26
sh Vaba	0,02	0,02	0,01	0,02	0,02	0,01	0,28	0,26	0,24
sh Haridus	0,73	0,63	0,74	0,73	0,63	0,81	0,37	0,60	2,30
sh Majutus	0,95	0,91	0,88	0,94	0,90	0,84	0,39	0,39	0,48
sh Mitmesugused	0,03	0,03	0,03	0,03	0,03	0,03	0,40	0,38	0,33

Allikas: Autori koostatud, Lisa 6 põhjal

Tabelis 1 on esitatud mudelite prognoosimisvõimekuse tulemused järeltestimise perioodil. Sellest lähtuvalt on inflatsiooni prognoosimise meetodite võrdluses parim juhuslik mets (RF). Seda nii THI prognoosimisel kui ka suurema osa põhikaubagruppide tarbijahinnaindeksite prognoosimisel. Tulemus sarnaneb viimaste aastate inflatsiooni kiirhinnangu koostamise töödega ning põhjuseks peetakse nii tema muutujate selekteerimise mehhanismi kui ka mittelineaarsust. (Medeiros et al., 2021; Medeiros et al., 2022)

RF meetodist andsid paremaid tulemusi Lasso side ja vaba aja tarbijahinnaindeksite prognoosimudelites, adaLasso alkoholi ning mitmesuguste kaupade ja teenuste tarbijahinnaindeksite prognoosimudelites (vaata Tabel 1). Lassoregressioonide muutujate koefitsiente (Lisa 7) vaadates ilmneb, et lassoregressioonide eelis ilmnes vaid siis, kui meetod valis mudelisse väga palju erinevaid muutujaid.

RF meetodi tulemuste võrdlus teiste meetoditega on esitatud Tabelis 2. Võrdlus on koostatud nii, et RF meetodi kolme prognoosimisvõimekuse näitaja (RMSE, MAE, MAD) keskmine tulemus on võrreldud vastava meetodi (ARIMA, Lasso või adaLasso) näitajate keskmise tulemusega ehk siis on arvatud keskmiste protsentuaalne erinevus. Nii on tegutsetud agregeeritud ja disagregeeritud THI puhul. Tabelis 2 on esitatud agregeeritud ja disagregeeritud THI mudelite minimaalne protsent, mille võrra RF edestab muud meetodit.

Tabel 2. RF mudelite RMSE, MAE ja MAD võrdlus teiste meetoditega järeltestimise perioodil

	vs ARIMA	vs Lasso	vs adaLasso
RF, ilma küsitlusteta, koguvalim	69%	54%	55%
RF, ilma küsitlusteta, järeltestimine	47%	44%	52%
RF, küsitlustega, koguvalim	69%	53%	54%
RF, küsitlustega, järeltestimine	53%	42%	50%

Allikas: Autori koostatud, Lisade 5 ja 6 baasil

Kui võrrelda muude meetodite mudelite prognoosimisvõimekust RF mudelitega (vaata Tabel 2), siis RF mudeli prognoosimisvõimekus ületab koguvalimis ARIMA (THI puhul kasutati RW) mudelite tulemusi vähemalt 69%, Lassot 53% ja adaLassot 54%. Järeltestimise perioodil on RF prognoosimisvõimekuse paremus võrreldes teiste mudelitega madalam kui koguvalimis: RF edestab ARIMA mudeleid vähemalt 47%, Lassot 42% ja adaLassot 50%. Ka varasemates töödes on eristunud RF prognoosimisvõimekuse paremus võrreldes muude meetoditega. Kõiki kolme näitajat kasutades edestas RF RW mudelit peaaegu 30%. (Medeiros et al., 2021) RF mudeli üheks puuduseks on ülesobitamine, kuna ta on koguvalimis oluliselt täpsem kui järeltestimisel või välja jäetud valimi korral. Varasemalt on võrreldud mudelite kirjeldusvõimet ning siis oli RF paremus Lasso ees koguvalimis 39,1% ning välja jäetud valimi korral 2,2%. (Mullainathan & Spiess, 2017)

Üldiselt saab ära märkida, et analüüsi tulemused koguvalimis ja järeltestimise perioodil ühtisid, kuna parima meetodi määratlemisel erinevusi ei esinenud. Lisaks, kuigi RF meetodi puhul on analüüsi tulemus igal algoritmi rakendamisel veidi erinev, siis käesolevas analüüsis ilmnes, et ka lassoregressioonides on tegelikult võimalik olukord, kus mudel võib selekteerida kas väga vähe muutujaid või hoopis väga palju. Viimasel juhul on välja selekteeritud lisaks palju nullilähedaste koefitsientidega muutujaid.

3.2 Tarbijahinnaindeksi kuju valik

Kui võrrelda tarbijahinnaindeksit avaldatud kujul ja desagregeeritud kujul, siis tulemustest (vaata Tabel 1, Lisad 5 ja 6) lähtub, et oluliselt paremaid tulemusi annab desagregeeritud põhikaubagruppide tarbijahinnaindekseid sisaldav mudel. Desagregeeritud tarbijahinnaindeksi mudel edestab agregeeritud kuju mudeli prognoosimisvõimekust suhtena ARIMA mudeliga vähemalt 19% koguvalimis ning mõju on suurim just järeltestimise perioodil, kus desagregeeritud tarbijahinnaindeks on vähemalt 33% täpsem.

Analüüsis katsetati ka mudelite kombineerimist, kus iga põhikaubagrupi tarbijahinnaindeksi puhul kasutati desagregeeritud mudelis parimate prognoosimisvõimekuse näitajatega mudelit. Ehk siis antud juhul asendati alkoholi, mitmesuguste teenuste ja kaupade RF meetod adaLasso meetodi vastu, side ja vaba aja mudelites asendati RF meetod Lasso vastu. Küll aga ei andnud see arvestatavat muutust (mõju 0%), kuna antud gruppide osakaal valimis on väga väike ning prognoosimisvõimekuse erinevus RF mudelist samuti väga väike.

Tulemustest jääb silma ka see, et avaldatud kuju tarbijahinnaindeksi puhul on suhtena ARIMA võrdlusmodeliga MAD näitaja oluliselt kõrgem muudest näitajatest (Tabel 1). Põhjus on selles, et muutmata kujul mudelite tulemustes (Lisad 5 ja 6) on MAD tulemus oluliselt madalam kõikide mudelite puhul, sealhulgas ARIMA mudelis. Kui MAD tulemus on madalam kui RMSE, siis see viitab, et tulemused on tundlikud erindite suhtes. (Medeiros et al., 2022) Ehk siis kui RMSE ja MAD tulemused erinevad, siis RMSE võib näidata suuremat väärtust tänu üksikutele suurtele prognoosimisvigadele (erindid). Samas ei ole ka MAE nii tundlik erindite suhtes ja seetõttu tuleb neid kõiki ühiselt vaadata. (Medeiros et al., 2021)

3.3 Inflatsiooni prognoosivad tegurid

Inflatsiooni prognoosivate tegureid on oluline hinnata nii RF kui ka lassoregressioonide tulemustest lähtuvalt, kuna mudelid on erinevate omadustega: lassoregressioonid on lineaarsed ja RF mittelineaarne. (Medeiros et al., 2021) Infot saame lassoregressioonide muutujate koefitsientide tõlgendamisest (positiivne või negatiivne seose suund) ning juhusliku metsa tegurite olulisust mudeli keskmise ruutvea (MSE) kasvul (olulisuse osakaal) vastavalt Tabelis 3 esitletule. RF tulem on saadud mittenegatiivsete olulisuse osakaalude normaliseerimise ning tegurite tulemuste summeerimisega vastavas grupis. Suurem arv näitab suuremat olulisust kiirhinnangu koostamisel ning negatiivne tulem märgib muutuja mitteolulisust (sellisel juhul andis juhuslik muutuja parema tulemuse).

Tabel 3. Küsitlusandmete mõju tegurite olulisusele, valikule ning prognoosimisvõimekusele


Tegur	Ilma küsitlusandmeteta			Koos küsitlusandmetega		
	RF	Lasso	adaLasso	RF	Lasso	adaLasso
Tööstus	42,7%	3,9	9,6	43,0%	3,5	8,0
Sisekaubandus	16,1%	0,0	0,0	13,9%	0,0	0,0
Väliskaubandus	11,1%	-2,4	-2,4	11,3%	-2,6	-5,2
Hinnad	10,6%	-1,4	-4,1	8,0%	-1,5	-4,1
Energeetika	6,0%	0,0	0,0	7,2%	0,0	0,0
Põllumajandus	7,0%	0,0	0,0	7,1%	0,0	0,0
Küsitlusandmed	0,0%	0,0	0,0	2,4%	-1,8	-4,6
Transport	0,6%	0,0	0,0	1,9%	0,0	0,0
Rahandus	3,2%	0,0	0,0	1,9%	0,0	0,0
THI	0,4%	0,0	0,0	1,3%	0,0	0,0
Tööturg	1,8%	0,0	0,0	1,2%	0,0	0,0
Turism ja majutus	0,5%	0,0	0,0	0,6%	0,0	0,0
Küsitlusandmete mõju, koguvalim				-0,1%	0,0%	0,0%
Küsitlusandmete mõju, järeltestimine				11,5%	0,0%	0,0%

Allikas: Autori koostatud, Lisade 7 ja 8 baasil

Tabelis 3 on esitatud tegurite normaliseeritud olulisuse määra summad (RF) ja tegurite summeeritud koefitsiendid (Lasso, adaLasso). Kuigi meetodid erinevad üksteisest oluliselt ja muudes töödes ei ole erinevad meetodid nii sarnaseid tulemusi andnud (Medeiros et al., 2021), siis käesolevas analüüsis tulemused kattuvad arvestataval määral, kuna nii RF kui ka lassoregressioonid tõid välja 3 olulist tegurite gruppi, mis aitavad paremini prognoosida inflatsiooni: tööstus, väliskaubandus ja hinnad. RF mudeli järgi kuuluvad sinna gruppi veel sisekaubandus, energeetika ja põllumajandus. Lassoregressioonide tulemustes on olulisel kohal ka küsitlusandmed, kuid RF hindas selle grupi olulisuse määraks vaid 2,4%. Lassoregressioonide koefitsiendid täiendavad tulemusi seose suunaga: tööstuse tegurite grupp on positiivses seoses inflatsiooniga, samas kui väliskaubanduse ja hindade seos inflatsiooniga on negatiivne.

Sarnaselt varasematele töödele vaadeldi ka seda, kas küsitlusandmete kasutamine mudelites võimaldab parandada prognoosimisvõimekust. Kuigi koguvälimise nende kasutamine mõju ei avaldanud (vaata Tabel 3), siis järeltestimise perioodil võimaldas küsitlusandmete lisamine valimisse parandada RF meetodi prognoosimisvõimekust kuni 11,5%. Varasemates töödes on küsitlusandmete kasutamine läbivalt parandanud mudeli prognoosimisvõimekust. (Ang et al., 2007; Giannone et al., 2006; Funke et al., 2015) On tõsi, et hinnatõusu ootus ise võib põhjustada inflatsiooni kasvu, kuna selle põhjal kujundatakse tihtipeale hindasid. Või siis suurenevad kõrge hinnaootuse tulemusena inimeste palgasoodid, mis omakorda viivad üles toodete ja teenuste hinnad, kuna ettevõtted peavad tekkinud lünga eelarves kuidagi katma. Kuid hinnaootuse jälgimine on oluline ka rahanduspoliitikas üldiselt, kuna neid võetakse arvesse rahanduspoliitiliste otsuste tegemisel.


Kõigepealt analüüsitakse tulemusi koos küsitlusandmetega ja tegurite gruppide lõikes, summeerides gruppi kuuluvate tegurite normaliseeritud olulisuse määra RF mudelist ja lassoregressioonide koefitsiendid. Olulistes (RF mudeli järgi olulisuse määr vähemalt 5%) gruppides tuuakse välja suurima olulisuse määraga (vähemalt 1%) tegurid selliselt, et on summeeritud erinevate viitaegade normaliseeritud olulisuse määrad (vaata Joonis 8). Seejärel täiendatakse analüüsi lassoregressioonide tulemusega (vaata Joonis 9), võimaldades konkreetselt öelda, milline on tegurite grupi või teguri ja inflatsiooni seose suund (positiivne või negatiivne). Lisaks sellele antakse ülevaade, kuidas küsitlusandmete lisamine valimisse mõjutab RF prognoosimudelitesse valitud tegurite olulisuse määra. Nii on võimalik eristada, milliste muutujate gruppide olulisuse määr muutus suuremaks või väiksemaks.



Joonis 8. Olulise määraga tegurid inflatsiooni prognoosimisel (RF)

Allikas: Autori koostatud, Lisa 8 baasil

Joonisel 8 on esitatud RF mudeliga saadud suurima olulisuse määraga (alates 1%) muutujad. Arvuliselt on kõige enam esindatud tegureid tööstuse, energeetika ja sisekaubanduse gruppidest. Kuid nagu näha, kuuluvad siia ka tarbijahinnaindeksi varasemate kuude väärtused. Ning joonisel 9 on kujutatud lassoregressioonide muutujate koefitsiendid. Mudelitesse selekteeriti väga vähe muutujaid: siia kuuluvad vaid tööstuse, küsitlusandmete, hindade ja väliskaubanduse muutujad.



Joonis 9. Tarbijahinnaindeksit mõjutavate muutujate koefitsiendid (Lasso, adaLasso)

Allikas: Autori koostatud, Lisa 7 baasil

Tööstustoodangu mahuindeksid mõjutasid kõikide meetodite lõikes inflatsiooni kõige enam (grupipõhine osakaal 43%, ületades teisi grappe vähemalt 29%) ning küsitlusandmete lisamine valimisse suurendas tööstuse tegurite grupi olulisuse määra 0,3 protsendipunkti võrra. Lassoregressioonide tulemuste põhjal on seos positiivne, ehk siis tööstustoodangu mahuindeksi kasvu korral suureneb inflatsioon. Tööstuse olulisus inflatsiooni prognoosimisel on ka varasemalt tõestatud. (Giannone et al., 2006; Stock & Watson, 1999) Kui inflatsiooni olemuseks on tänasele sarnanev kõrge nõudluse jätkumine hindade tõusul, siis inflatsioonist tingitud kõrge hinnatase ei vähenda toodangut, vaid tootmine võib tõesti hoopis suurenedada. Lassoregressioonide tulemuste põhjal aitavad inflatsiooni prognoosida tegurid (vaata Joonis 9) põhifarmaatsiatoodete ja ravimpreparaatide tootmisest ning taimse ja loomse õli ja rasva tootmisest (vastavalt TO70 ja

TO11). RF mudeli järgi aitavad inflatsiooni paremini prognoosida järgmised tegurid (vaata Joonis 8):

- 1) Tekstiilitootmine (TO62, olulisus 1,3%);
- 2) Puu- ja köögivilja töötlemine ja säilitamine (TO10, olulisus 1,2%);
- 3) Põlevkivi kaevandamine ja toornafta tootmine (TO3, olulisus 1,2%);
- 4) Mootorsõidukite, haagiste ja poolhaagiste tootmine (TO79, olulisus 1,2%);
- 5) Liha töötlemine ja säilitamine ning lihatoodete tootmine (TO8, olulisus 1%);
- 6) Taimse ja loomse õli ja rasva tootmine (TO55, olulisuse määr 1%);
- 7) Mäetööstuses ja töötlevas tööstuses elektrienergia, gaasi, auru ja konditsioneeritud õhuga varustamine (TO45, olulisus 1%);
- 8) Muude toiduainete tootmine (TO15, olulisus 1%).

Kuigi lassoregressioonides sisekaubanduse muutujaid valituks ei osutunud, peab RF meetod seda siiski oluliseks inflatsiooni prognoosivaks muutujate grupiks, osakaaluga 13,9%. Küll aga vähendas küsitlusandmete lisamine valimisse sisekaubanduse tegurite grupi olulisuse määra 2,1 protsendipunkti võrra. See annab alust arvata, et paremate tegurite lisamisel valimisse võib antud grupi olulisuse määr veelgi väheneda. Kaubanduse müüginäitajate olulisus inflatsiooni prognoosimisel on samuti varasemalt tõestatud. (Stock & Watson, 1999) Ka sisekaubanduse ja inflatsiooni seose puhul on üheks faktoriks nõudlus. Kui hindade tõusust hoolimata nõudlus püsib, siis samal ajal kasvavad ka müüginumbrid. Teine põhjus võib olla senise rahatrüki tulemus, kuna inimestel on rohkem raha käes ning sellisel juhul tehakse ka oste rohkem. Kolmandaks, on käesoleva inflatsiooni jooksul korduvalt mainitud, et hinnatõusud ei pruugi niipea lõppeda. Selleks, et mitte maksta hiljem sama toote eest rohkem, soovivad inimesed toote osta pigem kohe, kui selleks on võimalus olemas. Oluliste müügitulu teguritena eristuvad (vaata Joonis 8): mootorsõidukite müük, mootorrataste müük, hooldus ja remont, mootorsõidukite osade ja lisaseadmete müük (SI18, olulisus 1,3%), kõikide tegevusalade müügitulu kokku (SI1, olulisus 1,2%) ning tekstiilitoodete, rõivaste, jalatsite ja nahktoodete jaemüük spetsialiseeritud kauplustes (SI11, olulisus 1%).

Väliskaubanduse tegurite olulisus inflatsiooni prognoosimisel on osakaaluga 11,3% (RF). Küsitlusandmete lisamine valimisse vähendas tegurite grupi olulisuse määra 0,2 protsendipunkti võrra, ehk siis grupi olulisuse määr inflatsiooni prognoosimisel on üsna stabiilne. Väliskaubanduse näitajate asemel on varasemalt kasutatud kauplemissummat, kus ekspordi ja impordi summa on jaotatud riigi SKP-ga vaadeldaval ajahetkel ning on tõestatud kauplemissumma positiivse seose

inflatsiooniga. (Medeiros et al., 2022) Samas eristub käesolevas analüüsis ainsa olulise tegurina inflatsiooni prognoosimisel (vaata Joonis 8) peamiselt eratarbimiseks toitude ja jookide, töödeldud toodete eksport Venemaale (VK14, olulisus 1,3%). Lassoregressioonide järgi on väliskaubanduse ja inflatsiooni seos negatiivne, ehk siis teatud väliskaubanduse muutujate vähenemine suurendab inflatsiooni. Negatiivse seose muutujana on välja selekteeritud (vaata Joonis 9) mujal spetsifitseerimata tarbekaupade ja kestvuskaua import Venemaalt (VK31), mille mõju vähendab vähesel määral positiivne seos masinate ja teiste kapitalikaupade (v.a transpordivahendid) ekspordiga Venemaale (VK3). See on ka loogiline, kuna teatavasti on Venemaa hinnatase madalam kui Eestis. Kaupade import võimaldab sisse tuua odavamad kaupa, mis viib hinnataseme alla. Ning olukorras, kus import mingil põhjusel väheneb, kuid nõudlus püsib, peavad inimesed ostma odavama Venemaa kauba asemel kallimaid tooteid ja seetõttu kasvab ka inflatsioon.

Järgmine oluline tegurite grupp inflatsiooni prognoosimisel on hindade dünaamikat esindavate tegurite grupp, olulisuse osakaaluga 8%. Ka selle grupi olulisuse määra vähendas küsitlusandmete lisamine valimisse, täpsemalt 2,6 protsendipunkti võrra. See annab alust arvata, et paremate tegurite lisamisel valimisse võib antud grupi olulisus veelgi väheneda. RF mudeli järgi on antud tegurite grupis kõige olulisem tegur inflatsiooni prognoosimisel (vaata Joonis 8) impordihinnaindeks (HI13, olulisus 1%). Lassoregressioonide järgi on hindade seos inflatsiooniga negatiivne ning selle põhjusena on välja selekteeritud (vaata Joonis 9) remondi- ja rekonstrueerimistööde tööjõu hinnaindeks (HI19). Ehk siis selle tööjõuhinna vähenemine võib suurendada inflatsiooni. Hindade dünaamika olulisus inflatsiooni prognoosimisel on samuti varasemalt tõestatud, (Medeiros et al., 2021) kuid senistes töödes on ära märgitud just varahindade, (Giannone et al., 2006) energia ja toormaterjali hindade (Modugno, 2013) ning toidu hindade olulisus (vilja hind). (Funke et al., 2015) Käesolevas analüüsis need tulemused tõestamist ei leidnud ning tulemused on kooskõlas teise tööga, mille kohaselt varahinnad ja kaupade hinnad ei aita paremini prognoosida inflatsiooni. (Stock & Watson, 1999) Kahjuks ei olnud analüüsis kasutada toitude hindasid sarnaselt tööga, kus tõestati, et kõrged toidu hinnad suurendavad inflatsiooni ootust ja see võib omakorda viia kulude pealesurumiseni ehk inflatsiooni kasvuni. Tegelikuses peaksid kaupade hinnad olema mõjutatud nõudlusega, misjuhul oleksid nad signaaliks majanduse ülekuumenemise algusest. (Funke et al., 2015) Hindade dünaamika ja inflatsiooni seos on muidugi ilmselge, küll aga peaks seos muidu olema positiivne – kõrgem hinnatase võrdub kõrgema inflatsiooniga. Lassoregressioonide tulem negatiivsest seosest inflatsiooni ning remondi- ja rekonstrueerimistööde tööjõu hinnaindeksi vahel on üllatav, kuna tavapäraselt tähendab kõrgem tööjõukulu ka kõrgemat inflatsiooni. Põhjuseks on ettevõtete

toimimise süsteem, kuna igasugune kulude kasv peadib tavaliselt toote või teenuse hinnatõusust. Samas kui mõelda ehitusvaldkonnas toimunule, kus toorme hinnad on tõusnud väga suurel määral, kohati lausa mitmekordselt, siis nii toorme kui ka tööjõukulu suurenemise lõplikku teenuse hinda lisamisel ei ole ka mõistlik. Liiga suur hinnakasv vähendab tellimuste arvu ning see ei ole kindlasti soovitud tulemus. Seetõttu on loogiline, et erinevate kulude samaaegsel kasvul peavad ka ettevõtted tegema mõõndusi ning osa kulude kasvust enda kanda võtma.

Inflatsiooni prognoosimisel mängivad olulist rolli ka energiasektorit iseloomustavate tegurite grupp, olulisuse osakaaluga 7,2%. Küsitlusandmete lisamine valimisse suurendas grupi olulisuse määra 1,2 protsendipunkti võrra. RF mudeli järgi on kõige olulisemad tegurid (vaata Joonis 8) tuuleenergiast toodetud elektrienergia (EN6, olulisus 1,6%), soojuse toodang (EN3, olulisus 1,1%) ning elektrienergia toodanguindeks (EN2, olulisus 1%). Energia komponendi olulisus THI prognoosimisel on ka varasemalt ilmnenu, küll aga kasutati sellistes töödes energia hindasid. (Modugno, 2013) Samuti on tõestatud, et energiahindade mudelist väljaarvamine halvendab kvartali esimeses pooles mudeli prognoosimisvõimekust (RMSE) 9-11% võrra. (Knotek & Zaman, 2017) Käesolevas analüüsis puudusid valimist energia hinnad, kuna Statistikaamet on nende maksumust kaardistanud alates 2007. aastast, kuid käesolev analüüs põhineb andmetel alates 2006. aastast. Ka energia toodangu seos inflatsiooniga on põhjendatud, kuna ise piisava elektrienergia tootmine tagab teatavasti odavama elektri hinna, kuna vajadus elektrienergiat turult juurde osta on väiksem. Eesti on oma külma kliimaga üks neist riikidest, kelle energiavajadus on suur ning on olnud palju arutelu, kas Eesti üldse suudaks oma energiavajaduse ise ära katta. Seni oleme näinud pidevaid alajaamade tõrkeid, kus alajaam läheb remonti ning sellest lähtuvalt on vaja elektrienergiat rohkem sisse osta. Mida suurem on sisseostetud energia vajadus, seda kallimaks on muutunud energia hind.

Viimane vähemalt 5%-lise olulise määraga tegurite grupp inflatsiooni prognoosimisel on põllumajandus, osakaaluga 7,1%. Ka selle tegurite grupi olulisuse määr on üsna stabiilne, kuna küsitlusandmete lisamine valimisse suurendas grupi olulisust vaid 0,1 protsendipunkti võrra. RF mudeli järgi eristub ainsa olulise tegurina (vaata Joonis 8) joogipiima tootmise kogus (PO2, olulisus 1%). Kuna toidu ja mittealkohoolsete jookide tarbijahinnaindeks moodustab avaldatud kujul tarbijahinnaindeksist suurima osa, 22,4%, siis on joogipiima tootmise koguse seos inflatsiooniga mõningal määral põhjendatud. Kohaliku toodangu mõju hindadele on vahetum, sest sellele lisandub vähem täiendavaid kulusid nagu näiteks transport.

Olulisuse määr on madal küsitlusandmete (2,4%), transpordi (1,9%, sh 1,3% moodustab sellest küsitlusandmete lisamisega suurenenud olulisuse määr), rahanduse (1,9%, mis oli enne küsitluste lisamist 1,3 protsendipunkti võrra kõrgem), tarbijahinnaindeksi väärtused kuni neljandat järku viitaegadega (1,3%, sh 1% moodustab sellest küsitlusandmete lisamisega suurenenud olulisuse määr), tööturu (1,2%, mis oli enne küsitluste lisamist 0,6 protsendipunkti võrra kõrgem) ning turismi ja majutuse (0,6%, sh 0,1% moodustab sellest küsitlusandmete lisamisega suurenenud olulisuse määr) tegurite gruppidel.

Kuigi transpordi tegurid grupina ei ole olulised inflatsiooni prognoosimisel ning sinna kuuluvad tegurid registreeritud sõidukite arvust ei ole ka varasemates töödes olulist rolli mänginud, siis RF mudeli kõrgema olulisuse määraga tegurite seas on registreeritud uute sõiduautode arv (1,4%). Kuid ilma küsitlusandmetega valimis ei ületanud ükski gruppi kuuluv tegur olulisuse määra 1% taset.

Seniste tööde kohaselt finantssektorit iseloomustavate tegurite grupi osas on selgunud, et need ei aita paremini prognoosida inflatsiooni (Modugno, 2013) või mõju on pigem keskmise või pika perspektiiviga. (Funke et al., 2015) Kuigi on tõestatud intressimäära (Hamilton, 1985) ja valuutakursi olulisus inflatsiooni prognoosimisel, (Medeiros et al., 2021) siis samuti on tõestatud, et intressimäärad avaldavad mõju pigem reaalsele SKP-le, mitte inflatsioonile. (Giannone et al., 2006; Stock & Watson, 1999) Samuti on täheldatud, et energia ja toormaterjali hindade lisamisel valimisse väheneb rahanduse näitajate olulisus inflatsiooni prognoosimisel. (Modugno, 2013) Rahanduse näitajad on olnud domineerivad ka muude meetodite (näiteks faktoranalüüs) kasutamisel. (Bai & Ng, 2008) Käesolev analüüs oli lühikese perspektiiviga ning kinnitab, et rahanduse näitajad ei aita paremini prognoosida inflatsiooni, kuna lisaks madalale RF olulisuse määrale (1,9%) ei ületa ükski näitaja RF mudeli olulisuse määra 1% ning lassoregressioonid rahanduse muutujaid mudelisse ei valinud.

Teine muutuja, mille olulisus inflatsiooni prognoosimisel on muutunud, on töötus. Töötuse määra kasutati varasemalt inflatsiooni prognoosimisel 12-kuulise ettevaatega Phillips kõveraga, kuid ka siis täheldati tööstuse ja kaubanduse muutujate paremust. (Stock & Watson, 1999) Hilisemalt on see teooria korduvalt ümber lükatud nii meetodi kui ka muutuja osas. (Atkeson & Ohanian, 2001; Medeiros et al., 2022) Samas on veel värskest tõestatud töötuse olulisus, (Medeiros et al., 2021) kuid see võib olla tingitud riigi eripärast, kuna muutuja on olnud oluline Brasiilia inflatsiooni kiirhinnangu koostamisel. (Medeiros et al., 2016) Käesolev analüüs kinnitab tööturu muutujate

mitteolulisust, kuna lisaks madalale RF mudeli olulisuse määrale (1,2%) ei ületa ükski töötuse tegur olulisuse määra 1% ning ka lassoregressioonid töötuse tegureid mudelisse ei valinud.

3.4 Tarbijahinnaindeksite prognoosimine põhikaubagruppide lõikes

Kuna tarbijahinnaindeksi prognoosimisel annab paremaid tulemusi indeksi kasutamine desagregeeritud kujul, antakse käesolevas alapeatükis lühike ülevaade, millised tegurite grupid on olulised erinevate põhikaubagruppide tarbijahinnaindeksite prognoosimisel. Peatükis käsitletakse vaid tegurite gruppide olulisuse määra inflatsiooni kiirhinnangu koostamisel (RF mudelite tulemused) koguvalimis ehk koos küsitlusandmetega. Sarnaselt avaldatud kuju tarbijahinnaindeksi tulemuste ülevaatele analüüsitakse tulemusi tegurite gruppide lõikes nii, et summeeritakse gruppi kuuluvate tegurite normaliseeritud olulisuse RF mudelist (vaata Tabel 4). Tulemustes nimetatakse vaid olulised (olulisuse määr vähemalt 5%) grupid, kuid lisaks nimetatakse ka tulemuste erinevused võrreldes agregeeritud tarbijahinnaindeksiga. Tabelis 4 tähistab THI vastava kaubarühma tarbijahinnaindeksit.

Tabel 4. Tegurite gruppide olulisus põhikaubagruppide tarbijahinnaindeksite prognoosimisel

GRUPP	Toit	Alkohol	Riided	Eluase	Majap.	Tervis	Transp.	Side	Vaba	Haridus	Majut.	Mitm.
Tööstus	39,3%	41,6%	41,3%	40,0%	47,1%	42,9%	40,7%	38,8%	43,6%	43,7%	39,9%	45,8%
Sisekaubandus	17,0%	21,9%	26,0%	15,7%	12,8%	18,6%	14,0%	16,5%	14,4%	17,6%	14,0%	16,0%
Väliskaubandus	9,5%	10,7%	7,8%	12,7%	12,3%	11,4%	13,2%	13,5%	11,2%	13,5%	8,7%	10,2%
Hinnad	8,1%	6,5%	3,8%	13,4%	7,4%	10,5%	9,6%	9,6%	9,3%	9,0%	7,8%	9,7%
Energeetika	7,4%	5,5%	3,8%	4,9%	6,6%	5,3%	4,0%	5,9%	5,6%	5,6%	8,9%	4,8%
Põllumajandus	7,6%	6,4%	6,2%	6,4%	4,9%	5,0%	8,0%	8,9%	8,7%	5,0%	7,1%	7,3%
Küsitlus-andmed	2,7%	1,7%	3,2%	1,7%	3,7%	1,8%	2,4%	2,4%	3,1%	1,0%	5,2%	2,2%
Transport	0,7%	1,2%	0,5%	1,8%	1,0%	0,7%	0,9%	1,0%	0,8%	0,4%	0,9%	1,3%
Rahandus	2,4%	2,6%	1,4%	1,8%	2,1%	1,8%	0,9%	1,3%	1,4%	1,4%	1,9%	1,5%
THI	2,1%	0,3%	2,5%	0,1%	0,0%	0,7%	0,6%	0,3%	1,1%	0,8%	1,0%	0,2%
Tööturg	1,9%	0,7%	0,6%	0,9%	1,4%	0,4%	3,6%	1,7%	0,8%	1,5%	1,5%	1,0%
Turism ja majutus	1,3%	1,0%	3,0%	0,5%	0,6%	0,9%	2,2%	0,1%	0,0%	0,5%	3,1%	0,1%

Allikas: Autori koostatud, Lisa 8 baasil

Kui vaadelda RF mudelitega leitud tegurite gruppide olulisust põhikaubagruppide lõikes (Tabel 4), on märgata üldist sarnasust avaldatud kuju tarbijahinnaindeksi tulemustega. Kõikide põhikaubagruppide puhul on läbivalt olulised nii tööstuse, sisekaubanduse kui ka väliskaubanduse tegurid. 5%-list olulisuse määra ei ületa hindade tegurid riietuse ja jalatsite tarbijahinnaindeksi

prognoosimisel ja põllumajanduse tegurid majapidamise tarbijahinnaindeksi prognoosimisel. Samas energeetika tegurite olulisuse määr on vähenenud mitme põhikaubagrupi lõikes: riietuse ja jalatsid, eluase, transport ning mitmesugused kaubad ja teenused. On igati põhjendatud, et põllumajanduse näitajad ei mängi rolli majapidamise tarbijahinnaindeksi puhul, kuna põllumajanduse tegurite hulka kuuluvad peamiselt toidu ja jooki iseloomustavad näitajad. Hindade puhul olid valimis peamiselt tootjahinnaindeksid, ekspordi- ja impordihinnaindeksid ning remonttööde hinnaindeksid. Ilmnes, et see ei ole nii oluline riietuse ja jalatsite puhul. Samuti on üllatav energeetika komponendi vähenemine olulisus nii mitmetes kategooriates, kuid nende puhul võinuks paremaid tulemusi anda hoopis energia hinnad, mida käesolevas analüüsis ei käsitletud.

3.5 Järeldused ja ettepanekud

Senised uurimused Eesti inflatsiooni kiirhinnangu koostamisest sellisel kujul puuduvad. Tegemist on esmakordse tööga, kus Eesti inflatsiooni kiirhinnangu koostamiseks kasutatakse masinõppe meetodeid. Lisaks ei ole kuigipalju uuritud agregeeritud ja disagregeeritud tarbijahinnaindeksi prognoosimist – kuigi eelistatakse kasutada agregeeritud kuju, siis tegelikult annab oluliselt paremaid tulemusi THI disagregeeritud kujul kasutamine. Täiendav panus avaldub ka töös kasutatavate uute tegurite kasutamises ning teguri seose inflatsiooni majandusliku sisuga analüüsimises.

Analüüsi tulemusest lähtuvalt on peamised tegurid, mis aitavad prognoosida inflatsiooni, seotud nõudlusega: tööstuse mahuindeksid, sisekaubanduse müüginäitajad, väliskaubandus (import). Ehk siis nõudluse vähenemisel võime alles loota hindade alanemisele ja sellest tulenevalt ka inflatsiooni vähenemisele. Samuti on töös nimetatud mitmed tootmisvõimekuse tegurid, mille piisaval tasemel hoidmine aitab ka hindu kontrolli all hoida. Oluline roll on kindlasti energeetikal, täpsemalt energia tootmise võimekusel. Kui riik suudab oma energiavajadust paremini katta, siis väheneb vajadus osta kallimalt energiat sisse.

Edaspidi võiks analüüsi täiendada erinevate muutujate lisamisega. Näiteks energeetika vallas on Statistikaamet kaardistanud energia maksumust alates 2007. aastast. Analüüsi tulemustest jäi ilmnes ka majapidamise tarbijahinnaindeksi halvemad prognoosimisvõimekuse näitajate tulemused, mistõttu võiks otsida tegureid selle tarbijahinnaindeksi paremaks prognoosimiseks. Järelduste ja ettepanekute kasutusvõimalused ning teema võimalikud edasiarendused.

Üks teema, mida käesolevas analüüsis ei ole käsitletud, kuid võib avaldada mõju inflatsiooni kiirhinnangu koostamisel, on maksude tõusust tingitud hinnatõus. Selliste diskretsionaalsete muutuste mõju prognoosimine maksupoliitikas on keeruline, kuna väiksemgi muudatus võib mõjutada tarbimisotsuseid olulisel määral. Näiteks saab tuua varasemalt rakendatud aktsiisimaksu tõusu, kus oodatud maksude laekumine ei vastanud prognoositud mahule, kuna tarbijatele oli kasulikum teha oma ostud teisel pool riigipiiri. Kuigi maksutõusud on reeglina pikalt ette teada, on raske määratleda piiri, kus tarbija teeb otsuse oma mugavusest või toote maksumuse baasilt. Kuid üks teema edasiuurimise variante oleks maksumuudatuste mõjust filtreeritud inflatsiooni kiirhinnangu koostamise võimaluste uurimine.

KOKKUVÕTE

Käesoleva magistritöö eesmärk oli leida alternatiivne meetodika Eesti inflatsiooni lühiajaliseks prognoosimiseks ning tegurid, mis aitavad parandada inflatsiooni lühiprognosi täpsust. Ateoreetilistest meetoditest kasutamisel on kesksel kohal just hinnang, kas ja kui hästi on võimalik inflatsiooni kiirhinnangut koostada ning üldiselt varjatud kujul esinevate tegurite ja inflatsiooni vahelised seosed pigem ei oma suuremat tähtsust. Lisaks selgitati välja, kas täpsema tulemuse annab tarbijahinnaindeksi kasutamine avaldatud kujul või põhikaubagruppide lõikes ehk disagregeritud kujul. Senised uurimused Eesti inflatsiooni kiirhinnangu koostamisest sellisel kujul puuduvad. Tegemist on esmakordse tööga, kus Eesti inflatsiooni kiirhinnangu koostamiseks kasutatakse masinõppe meetodeid. Lisaks ei ole kuigipalju töid, kus kasutatakse nii agregeeritud kui ka disagregeeritud tarbijahinnaindeksit. Täiendav panus avaldub ka töös kasutatavate uute tegurite kasutamises ning teguri seose inflatsiooni majandusliku sisuga analüüsimises.

Analüüsi läbiviimiseks kasutati 212 erinevat kuupõhist selgitavat muutujat erinevatest andmeallikatest: Eesti Statistikaamet, Eurostat, Eesti Pank ja Euroopa Komisjon. Koos kuni neljandat järku viitaegade rakendamisega kasutati igas loodud prognoosimudelil ilma küsitlusandmeteta 787 ning koos küsitlusandmetega 807 selgitavat muutujat. Tegurid olid grupeeritud järgmiselt: energeetika, hinnad, põllumajandus, sisekaubandus, transport, majutus, tööstus, tööturg, rahandus, väliskaubandus ja küsitlusandmed. Lähtuvalt andmete transformeerimise vajadusest statsionaarsuse saavutamiseks ning viitaegade rakendamisega loodi mudelid 200 vaatluse põhjal, hõlmates perioodi juulist 2006 kuni veebruarini 2023.

Meetodina kasutati senistest töödest parimaid tulemusi andnud lassoregressioone (Lasso ja adaLasso) ning juhuslikku metsa, võrdlusmodelina tulemuste paremaks tõlgendamiseks kasutati ARIMA mudeleid. Lassoregressioonide kasutamise tõttu eelnevalt andmed standardiseeriti. Meetodi tugevusteks on täpne prognoosimisvõime ning mudeli tõlgendamise lihtsus, kuna osa koefitsiente muutub tegurite selekteerimisel nulliks. Tema puuduseks on aga järjepidevuse probleem, kuna meetod ei ole nii efektiivne oluliste ja mitteoluliste selgitavate muutujate vahelise korrelatsiooni esinemisel. Lasso puuduste tõttu kasutati ka adaptiivset lassoregressiooni, mille

puhul on muutujate valiku protsess täpsem. Juhusliku metsa eelis on aga nii prognoosi täpsus, andmetes esineva korrelatsiooni mõju vähendamine läbi juhusliku selgitavate muutujate valiku. Tema puuduseks on aga ülesobitamine ning tegurite koefitsientide puudumine. Koefitsientide asemel kasutatakse teguri olulisuse määra keskmises ruutveas, mille abil on võimalik arvutada prognoosimise mudelis teguri olulisuse osakaal kõikidest teguritest. Suurem osakaal tähistab olulisemat tegurit inflatsiooni kiirhinnangu koostamisel. Meetodid täiendavad üksteist, kuna lassoregressioonide puhul on tegemist lineaarse ning juhusliku metsa puhul mittelineaarse meetodiga. Mudelite prognoosimisvõimekust hinnati 3 näitajaga: RMSE, MAE ja MAD.

Analüüsi tulemusena selgus, et parim meetod inflatsiooni kiirhinnangu koostamiseks on juhuslik mets. See sarnaneb viimastele töödele inflatsiooni prognoosimisel või kiirhinnangu koostamisel ning põhjuseks peetakse nii tema muutujate selekteerimise mehhanismi kui ka mittelineaarsust. Vaid üksikutel juhtudel andsid lassoregressioonid paremaid tulemusi: side ja vaba aja tarbijahinnaindeksite prognoosimisel lassoregressioon, alkoholi ning mitmesuguste kaupade ja teenuste tarbijahinnaindeksite prognoosimisel adaptiivne lassoregressioon. Kuid lassoregressioonide parem prognoosimisvõimekus avaldus vaid siis, kui meetod valis mudelisse väga palju erinevaid muutujaid. Juhusliku metsa eelis muu meetodi ees on tähelepanuväärne, kuna käesolevas analüüsis olid loodud tarbijahinnaindeksi prognoosimudelid edestasid ARIMA mudeleid vähemalt 47%, Lasso mudeleid 42% ja adaLasso mudeleid 50%. Koguväljund oli juhusliku metsa prognoosimisvõimekuse paremus teiste mudelite ees veelgi suurem.

Tarbijahinnaindeksi kuju valikul andis parimaid tulemusi indeks desagregeeritud kujul ehk siis mudel, mis sisaldab 12 põhikaubagrupi tarbijahinnaindeksite mudeleid. Antud juhul oli desagregeeritud kuju paremus avaldatud kuju ees suhtena ARIMA mudeli prognoosimisvõimekusega vähemalt 19% ning tulemused olid veelgi paremad järeltestimise perioodil.

Inflatsiooni prognoosimisel on oluline kasutada valimis küsitlusandmeid, mis andis just järeltestimise perioodil arvestatava mõju mudeli prognoosimisvõimekuse parandamisele (11,5%). Olulisemad tegurid inflatsiooni prognoosimisel on tööstuse, sisekaubanduse, väliskaubanduse, hindade, energeetika ja põllumajanduse gruppides:

- Tööstustoodangu mahuindeksite olulisuse määra (43%) suurendasid enam erinevad tegurid riidetuse, toidu, põlevkivi ja toornafta, mootorsõidukite ja energia tootmisest. Nii kaua kuni

- eksisteerib inimestel nõudlus, siis kasvavad tootmise mahud, hoolimata samaaegsest hinnatõusust.
- Sisekaubanduse tegurite olulisuse määra (13,9%) suurendasid enam üldine müügitulu, mootorsõidukitega seonduv müük, hooldus ja remont, rõivaste ja jalatsitega seonduv jaemüük. Sisekaubanduses müüginäitajate kasvu kõrge inflatsiooni olemasolul veab samuti nõudlus – nii kaua kuni püsib inimeste nõudlus, siis hoolimata kasvavatest hindadest jätkub ostmine ja kasvab müügitulu. Ostude põhjuseks võib olla ka senise rahatrüki tulemusel inimestel käes oleva raha hulk või hirm, et hinnatõusud ei pruugi lõppeda ning sellisel juhul on mõistlikum kulude tegemisega mitte oodata.
 - Venemaaga väliskaubanduse tegurite olulisuse määra (11,3%) puhul eristusid toitute ja jookide eksport Venemaale, tarbekaupade ja kestva kauba import Venemaalt ning masinate ja teiste kapitalikaupade eksport Venemaale. Kuna Venemaalt tulev kaup on tavapäraselt madalamate hindadega, siis impordi vähenemine võib kaasa tuua inflatsiooni kasvu. Seda põhjustab nõudluse püsimine, kuna inimesed on nõus maksma sama toote eest siis kõrgemat hinda. Samuti on varasemalt tõestatud kauplemise avatuse positiivne seos inflatsiooniga.
 - Hindade dünaamika olulisuse määra (8%) puhul eristusid impordihinnaindeks, remondi- ja rekonstrueerimistööde tööjõu hinnaindeks. Kõrgem hinnatase võrdub kõrgema inflatsiooniga, kuid üllatav oli negatiivne seos inflatsiooni ning remondi- ja rekonstrueerimistööde tööjõu hinnaindeksi vahel, kuna tavapäraselt tähendab kõrgem tööjõukulu ka kõrgemat inflatsiooni. Ehitusvaldkonnas on toorme hinnad tõusnud väga suurel määral, seega nii toorme kui ka tööjõukulu suurenemise lõplikku teenuse hinda lisamisel ei ole mõistlik. Liiga suur hinnakasv vähendab tellimuste arvu ning see mõjutab ettevõtte kasumlikkust. Seetõttu on vajalik ettevõttel osa kulude kasvust enda kanda võtta.
 - Energeetika tegurite grupi olulisuse määra (7,2%) puhul eristusid tuuleenergiast toodetud elektrienergia, soojuse toodang, elektrienergia toodanguindeks. Ise piisava elektrienergia tootmine tagab teatavasti odavama elektrihinna, kuna vajadus elektrienergiat turult juurde osta on väiksem.
 - Põllumajanduse tegurite grupi olulisuse määra (7,1%) puhul eristus joogipiima tootmise kogus. Piim mängib eestlaste toidulaul olulist rolli ning mida rohkem suudame ise toota, seda odavamad on hinnad ja madalam inflatsioon, kuna lõpliku toote hinnale lisandub vähem täiendavaid kulusid nagu näiteks transport.

Analüüsi tulemusest lähtuvalt on peamised tegurid, mis aitavad prognoosida inflatsiooni, seotud nõudlusega: tööstuse mahuindeksid, sisekaubanduse müüginäitajad, väliskaubandus (import). Ehk siis nõudluse vähenemisel võime alles loota hindade alanemisele ja sellest tulenevalt ka inflatsiooni vähenemisele. Sealjuures kattusid olulisemate tegurite nimetamisel samasid valdkondi hõlmavad tegurid nagu näiteks riietus, toit ja mootorsõidukid. Nii hindade kui ka väliskaubanduse puhul mängib olulist rolli just import.

Edaspidi võiks analüüsi täiendada erinevate muutujate lisamisega, näiteks energia maksumus. Analüüsi tulemustest jäi ilmnemisele ka majapidamise tarbijahinnaindeksi halvemad prognoosimisvõimekuse näitajate tulemused, mistõttu võiks otsida tegureid selle tarbijahinnaindeksi paremaks prognoosimiseks. Samuti ei ole käesolevas analüüsis käsitletud maksude tõusust tingitud hinnatõusu, mis võib mõju avaldada inflatsiooni kiirhinnangu kostamisel.

SUMMARY

NOWCASTING ESTONIAN INFLATION

Reela Rosin

Because inflation reacts to monetary policy changes with delay the monetary policy is always formed based on a forecast. This is why the ability to forecast inflation is so important. It is also important for the businesses who make their investment decisions, plan wage increases and raise rents based on a forecast. Also, in an environment of high inflation, more accurate forecast of the increase of tax base and costs are important when planning the state's financial policy. The most important part of the forecast is a precise assessment of the starting point, which is achieved by the most accurate monitoring of the price growth. It is called nowcasting, a short-term assessment of inflation, which increases the quality of the forecast and operational financial decisions.

It is hard to predict the behavior of inflation, especially in the last decade when energy prices have been constantly changing. Nowcasting has become more important during the pandemic, to assess important economic indicators with new methods and alternative data sources. The purpose of this work is to find an alternative methodology for short-term forecasting of inflation in Estonia and factors that help to improve the accuracy of the forecast. There are two possibilities to do that: to use aggregated Consumer Price Index (CPI) or to use disaggregated form. In the CPI the expenditures are divided into 12 commodity groups. The weigh of each group corresponds to the average expenditure structure of the residents of the previous year. Since Estonia's inflation is one of the highest in the euro area, the result of this research can potentially influence the monetary policy decisions and measures for a better result. Research questions are:

- 1) Which methodology helps to nowcast Estonias inflation most accurately?
- 2) Will the more accurate result be using a CPI as published or using the disaggregated form?
- 3) Which factors help to forecast the CPI?

In the past, various models have been used when forecasting inflation: using short-term interest rates, ARIMA models (mainly ARMA(1,1), AR(p) and Random Walk), Phillips curve, surveys. From the factor models the most popular and with best results was the dynamic factor model. But with technological improvements the best results have been achieved using lasso regressions and Random Forest. Although the disaggregated form of CPI has not been widely used in research, it has improved the forecast of inflation.

Both the aggregated and disaggregated CPI were used as the research object. There are 212 different economic variables used as explanatory variables, published by Estonian Statistical Office, Eurostat, Estonian Bank and the European Commission. It has to be taken into account that there exists strong correlation between the explanatory variables. All the nowcasting models were based on 200 observations, from July 2006 to February 2023. Using up to fourth-order lags, each model used 787 explanatory variables when survey data was not included and 807 variables with survey data included. The variables were grouped as follows: energy, prices, agriculture, domestic trade, transportation, accommodation, industry, labor market, finance, foreign trade and survey data.

Only the methods with best results from previous studies were used: lasso regressions (Lasso and adaptive lasso, adaLasso) which are linear, and non-linear Random Forest (RF). Lasso regression is best known for their accurate forecasting ability and ease of interpretation of the model, as some coefficients become zero in the variable selection process. But the method is not so effective when a correlation exists between significant and non-significant explanatory variables. Adaptive lasso regression should have more accurate variable selection process. The advantage of the RF is both the forecast accuracy and the reduction of the correlation in the data through a random selection of the variables. Its disadvantage is overfitting and this is why a backtesting (period from January 2022 to February 2023) is used in the research. ARIMA models were used as a reference model for better interpretation of the results. The forecasting ability is assessed with 3 indicators: RMSE, MAE and MAD.

As a result of the analysis the best method when nowcasting Estonia's inflation is Random Forest. Lasso regressions gave better results only with few disaggregated CPI indexes: communication, leisure, alcohol, various goods and services. However, the better predictive power appeared when method selected a large number of variables into the model. The advantage CPI nowcasting models

using RF over other methods is remarkable, as outperform ARIMA models by at least 47%, Lasso models by 42% and adaLasso models by 50%. When comparing the results of aggregated CPI and disaggregated form, the index gave better results in a disaggregated form. The advantage of using disaggregated form over aggregated was at least 19% in relation to the predictive ability of the ARIMA model. It was also proved that using survey data improves the forecasting ability up to 11,5%, but the effect was only in the backtesting period. The most important factors when nowcasting Estonia's inflation are industry, domestic trade, foreign trade, prices, energy and agriculture:

- The proportion of industrial production volume indexes accounted for 43% of all the factors. This is due to the production of clothing, food, oil shale and crude oil, motor vehicles and energy. It is also a group of factors that has been the most important factor by the recent studies.
- The proportion of internal trade factors accounted for 13,9%. This is due to the general sales revenue, sales related to motor vehicles, maintenance and repair, and retail sales related to clothing and footwear.
- The proportion of foreign trade factors with Russia accounted for 11,3%. This is due to the exports of food and beverages, imports of consumer goods and durable goods, and exports of machinery and other capital goods. Russia price level is known as being low.
- The proportion of prices accounted for 8%. This is due to the import price index, repair and reconstruction labor price index. It is obvious, that higher price level leads to higher inflation.
- The proportion of energy accounted for 7,2%. This is due to the electricity produced from wind energy, heat production, and the electricity production index. With Estonia's location in cold climate, the ability to produce energy to cover most of our needs is very important.
- The proportion of agriculture accounted for 7,1%. This is due to the quantity of drinking milk production, which is also an important component of the food CPI.

Based on the results of the analysis, the main factors that help to nowcast inflation are related to the demand of the consumers. Also, several production capacity factors were pointed out that should be held at a sufficient level for desired effect of CPI.

KASUTATUD ALLIKATE LOETELU

- Aldrich, C. (2020). Process Variable Importance Analysis by Use of Random Forests in a Shapley Regression Framework. *Minerals*, 10, 420. <https://doi.org/10.3390/min10050420>
- Allon, J. C. S. (2015). Forecasting Inflation: A Disaggregated Approach Using ARIMA Models. *Bangko Sentral NG Pilipinas Economic Newsletter*, 15(2).
- Ang, A., Bekaert, G., & Wei, M. (2007). Do macro variables, asset markets, or surveys forecast inflation better? *Journal of Monetary Economics*, 54(4), 1163–1212. <https://doi.org/10.1016/j.jmoneco.2006.04.006>
- Atkeson, A., & Ohanian, L. E. (2001). Are Phillips Curves Useful for Forecasting Inflation? *Federal Reserve Bank of Minneapolis Quarterly Review*, 25(1), 2–11. <https://doi.org/10.21034/qv.2511>
- Bai, J., & Ng, S. (2008). Forecasting economic time series using targeted predictors. *Journal of Econometrics*, 146(2), 304–317. <https://doi.org/10.1016/j.jeconom.2008.08.010>
- Biecek, P., & Burzykowski, T. (2021). *Explanatory Model Analysis: Explore, Explain, and Examine Predictive Models*. Chapman and Hall/CRC. <https://doi.org/10.1201/9780429027192>
- Breiman, L. (1995). Better Subset Regression Using the Nonnegative Garrote. *Technometrics*, 37(4), 373–384. <https://doi.org/10.1080/00401706.1995.10484371>
- Breiman, L. (2001). Random Forests. *Machine Learning*, 45(1), 5–32. <https://doi.org/10.1023/A:1010933404324>
- Dauphin, M. J.-F., Dybczak, M. K., Maneely, M., Sanjani, M. T., Suphaphiphat, M. N., Wang, Y., & Zhang, H. (2022). *Nowcasting GDP - A Scalable Approach Using DFM, Machine Learning and Novel Data, Applied to European Economies*. International Monetary Fund.
- Donoho, D., Elad, M., & Temlyakov, V. (2006). Stable recovery of sparse overcomplete representations in the presence of noise. *IEEE Transactions on Information Theory*, 52, 6–18.
- Donoho, D. L., Johnstone, I. M., Hoch, J. C., & Stern, A. S. (1992). Maximum Entropy and the Nearly Black Object. *Journal of the Royal Statistical Society: Series B (Methodological)*, 54(1), 41–67. <https://doi.org/10.1111/j.2517-6161.1992.tb01864.x>
- Eesti Pank. (1999, juuni 7). *Aastaaruanne 1998. Maailma majandus ja finantsturud 1998. Aastal*. Eesti Pank. <https://www.eestipank.ee/et/maailma-majandus-ja-finantsturud-1998-aastal>

- Eesti Pank. (2008). *Rahapoliitika ja Majandus: Hetkeseis ja ettevaade* (Nr 2/2008). <https://www.eestipank.ee/et/publikatsioonid/rahapoliitika-ja-majandus/2008/rahapoliitika-ja-majandus-22008>
- Eesti Pank. (2022a, august 26). *Hinnatõus – korduma kippuvad küsimused*. Eesti Pank. <https://www.eestipank.ee/et/rahapoliitika/hinnatous-kkk>
- Eesti Pank. (2022b). *Rahapoliitika ja Majandus* (Nr 3/2022). <https://www.eestipank.ee/et/publikatsioonid/rahapoliitika-ja-majandus/2022/rahapoliitika-ja-majandus-32022>
- Eesti Statistikaamet. (2023a). *Tarbijahinnaindeks*. *Tarbijahinnaindeks*. <https://www.stat.ee/et/avasta-statistikat/valdkonnad/rahandus/hinnad/tarbijahinnaindeks>
- Eesti Statistikaamet. (2023b). *Tarbijahinnaindeksi suurimaks mõjutajaks oli jaanuaris toit*. <https://www.stat.ee/et/uudised/tarbijahinnaindeksi-suurimaks-mojutajaks-oli-jaanuaris-toit>
- Euroopa Keskpank. (2021). *Monetary Policy: Introduction*. <https://www.ecb.europa.eu/mopo/intro/html/index.et.html>
- Euroopa Keskpank. (2022). *Mis on inflatsioon?* https://www.ecb.europa.eu/ecb/educational/explainers/tell-me-more/html/what_is_inflation.et.html
- Fama, E. F. (1975). Short-Term Interest Rates as Predictors of Inflation. *The American Economic Review*, 65(3), 269–282.
- Fan, S. (2010). *Encyclopedia of Research Design*. SAGE Publications, Inc. <https://doi.org/10.4135/9781412961288>
- Frank, Ildiko E., & Friedman, J. H. (1993). A Statistical View of Some Chemometrics Regression Tools. *Technometrics*, 35(2), 109–135. <https://doi.org/10.1080/00401706.1993.10485033>
- Fu, W., & Knight, K. (2000). Asymptotics for lasso-type estimators. *The Annals of Statistics*, 28(5), 1356–1378. <https://doi.org/10.1214/aos/1015957397>
- Funke, M., Mehrotra, A., & Yu, H. (2015). Tracking Chinese CPI inflation in real time. *Empirical Economics*, 48(4), 1619–1641. <https://doi.org/10.1007/s00181-014-0837-3>
- Gareth, J., Witten, D., Hastie, T., & Tibshirani, R. (2021). *An introduction to statistical learning with applications in R* (2nd Edition). Springer Science and Business Media. <https://www.tandfonline.com/doi/full/10.1080/24754269.2021.1980261>
- Giannone, D., Reichlin, L., & Small, D. (2008). Nowcasting: The real-time informational content of macroeconomic data. *Journal of Monetary Economics*, 55(4), 665–676. <https://doi.org/10.1016/j.jmoneco.2008.05.010>

- Giannone, D., Reichlin, L., & Small, D. H. (2006). *Nowcasting GDP and Inflation: The Real-Time Informational Content of Macroeconomic Data Releases*. ECB Working Paper No. 633. <https://papers.ssrn.com/abstract=873658>
- Hamilton, J. D. (1985). Uncovering Financial Market Expectations of Inflation. *Journal of Political Economy*, 93(6), 1224–1241. <https://doi.org/10.1086/261357>
- Hodson, T. O. (2022). Root-mean-square error (RMSE) or mean absolute error (MAE): When to use them or not. *Geoscientific Model Development*, 15(14), 5481–5487. <https://doi.org/10.5194/gmd-15-5481-2022>
- Ibarra, R. (2012). Do disaggregated CPI data improve the accuracy of inflation forecasts? *Economic Modelling*, 29(4), 1305–1313. <https://doi.org/10.1016/j.econmod.2012.04.017>
- Ineichen, A. (2015). Nowcasting: A Risk Management Tool. *Alternative Investment Analyst Review*, 4(2), 45–50.
- Knotek, E. S., & Zaman, S. (2017). Nowcasting U.S. Headline and Core Inflation. *Journal of Money, Credit and Banking*, 49(5), 931–968.
- Laopodis, N. T. (2021). *Financial Economics and Econometrics*. Routledge.
- Leng, C., Lin, Y., & Wahba, G. (2006). A Note on the Lasso and Related Procedures in Model Selection. *Statistica Sinica*, 16(4), 1273–1284.
- Liu, Y., Yang, D., & Zhao, M. Y. (2022). *Housing Boom and Headline Inflation: Insights from Machine Learning*. International Monetary Fund.
- Machlup, F. (1990). Another View of Cost-Push and Demand-Pull Inflation. *Economic Semantics* (2. tr). Routledge.
- Masinõpe OÜ. (2023). Masinõppimine. *Masinõpe*. <https://masinope.ee/masinoppimine/>
- Medeiros, M. C., & Mendes, E. F. (2016). ℓ_1 -regularization of high-dimensional time-series models with non-Gaussian and heteroskedastic errors. *Journal of Econometrics*, 191(1), 255–271.
- Medeiros, M. C., & Mendes, E. F. (2017). Adaptive LASSO estimation for ARDL models with GARCH innovations. *Econometric Reviews*, 36(6–9), 622–637. <https://doi.org/10.1080/07474938.2017.1307319>
- Medeiros, M. C., Schütte, E. C. M., & Soussi, T. S. (2022). *Global Inflation Forecasting: Benefits from Machine Learning Methods* (SSRN Scholarly Paper Nr 4145665). <https://doi.org/10.2139/ssrn.4145665>
- Medeiros, M. C., Vasconcelos, G. F. R., Veiga, Á., & Zilberman, E. (2021). Forecasting Inflation in a Data-Rich Environment: The Benefits of Machine Learning Methods. *Journal of Business & Economic Statistics*, 39(1), 98–119. <https://doi.org/10.1080/07350015.2019.1637745>

- Medeiros, M. C., Vasconcelos, G., & Freitas, E. (2016). Forecasting Brazilian Inflation with High-Dimensional Models. *Brazilian Review of Econometrics*, 36(2), Article 2. <https://doi.org/10.12660/bre.v99n992016.52273>
- Meinshausen, N., & Bühlmann, P. (2006). Consistent neighbourhood selection for sparse high-dimensional graphs with the Lasso. *Annals of Statistics*, 34(3), 1436–1462.
- Meinshausen, N., & Yu, B. (2009). Lasso-type recovery of sparse representations for high-dimensional data. *The Annals of Statistics*, 37(1), 246–270. <https://doi.org/10.1214/07-AOS582>
- Modugno, M. (2013). Now-casting inflation using high frequency data. *International Journal of Forecasting*, 29(4), 664–675. <https://doi.org/10.1016/j.ijforecast.2012.12.003>
- Mullainathan, S., & Spiess, J. (2017). Machine Learning: An Applied Econometric Approach. *Journal of Economic Perspectives*, 31(2), 87–106. <https://doi.org/10.1257/jep.31.2.87>
- Osborne, M., Presnell, B., & Turlach, B. (1998). Knot Selection for Regression Splines via the LASSO. *Computing Science and Statistics*, 30, 44–49.
- Peña, D., & Tsay, R. S. (2021). *Statistical Learning for Big Dependent Data*. John Wiley & Sons. <https://learning.oreilly.com/library/view/statistical-learning-for/9781119417385/>
- Saleh, A. K. Md. E., Arashi, M., Saleh, R. A., & Norouzirad, M. (2022). *Rank-Based Methods for Shrinkage and Selection With Application to Machine Learning*. John Wiley and Sons, Inc. <https://www.perlego.com/book/3284929/rankbased-methods-for-shrinkage-and-selection-with-application-to-machine-learning-pdf>
- Statistikaamet. (2023). *Tabel IA001*. PxWeb. https://andmed.stat.ee:443/pxweb/et/stat/stat__majandus__hinnad/IA001.px/
- Stock, J. H., & Watson, M. W. (1999). Forecasting inflation. *Journal of Monetary Economics*, 44(2), 293–335. [https://doi.org/10.1016/S0304-3932\(99\)00027-6](https://doi.org/10.1016/S0304-3932(99)00027-6)
- Zhao, P., & Yu, B. (2006). On Model Selection Consistency of Lasso. *Journal of Machine Learning Research*, 7, 2541–2563.
- Zou, H. (2006). The Adaptive Lasso and Its Oracle Properties. *Journal of the American Statistical Association*, 101(476), 1418–1429. <https://doi.org/10.1198/016214506000000735>
- Tibshirani, R. (1996). Regression Shrinkage and Selection Via the Lasso. *Journal of the Royal Statistical Society: Series B (Methodological)*, 58(1), 267–288. <https://doi.org/10.1111/j.2517-6161.1996.tb02080.x>
- Xie, T., Yu, J., & Zeng, T. (2020). Econometric methods and data Science techniques: A review of two strands of literature and an introduction to hybrid methods. *Research Collection School Of Economics*, 1–132.

LISAD

Lisa 1. Töös kasutatavad lühendid

Lühend	Pikk nimetus
RW	Random Walk
MIDAS	mitmesageduslik regressioon
DFM	dünaamiline faktormudel
Lasso	vähima absoluutse kokkutõmbumise ja valiku operaator
OLS	hariliku vähimruudu regressioon
adaLasso	adaptiivne lassoregressioon
RF	juhuslik mets
SKP	sisemajanduse koguprodukt
ADF	Dickey-Fuller ühikjuure test
BIC	Bayesi informatsioonikriteerium
RMSE	keskmise ruutviga
MAE	keskmise absoluutne ruutviga
MAD	mediaani absoluutne hälve
RSS	Ruutude jääksumma
MSE	Keskmine ruutviga

Lisa 2. Andmed

Nimetus	Selgitus	Tr.	Viitaeg	Avaldaja	Tabel
Tarbijahinnaindeks					
THI	Tarbijahinnaindeks	(2)		Statistikaamet	IA02
Toit	Toit ja mittealkohoolsed joogid	(1)		Statistikaamet	IA02
Alkohol	Alkohoolsed joogid ja tubakatooted	(1)		Statistikaamet	IA02
Riided	Riietus ja jalatsid	(1)		Statistikaamet	IA02
Eluase	Eluase	(1)		Statistikaamet	IA02
Majapidamine	Majapidamine	(2)		Statistikaamet	IA02
Tervis	Tervishoid	(1)		Statistikaamet	IA02
Transport	Transport	(1)		Statistikaamet	IA02
Side	Side	(1)		Statistikaamet	IA02
Vaba	Vaba aeg	(1)		Statistikaamet	IA02
Haridus	Haridus ja lasteasutused	(1)		Statistikaamet	IA02
Majutus	Söömine väljaspool kodu ja majutus	(1)		Statistikaamet	IA02
Mitmesugused	Mitmesugused kaubad ja teenused	(1)		Statistikaamet	IA02
1. Energeetika					
EN1	Elektrienergia toodang	(0)	-1	Statistikaamet	KE20
EN2	Elektrienergia toodanguindeks	(1)	-1	Statistikaamet	KE20
EN3	Soojuse toodang	(0)	-1	Statistikaamet	KE20
EN4	Soojuse toodanguindeks	(0)	-1	Statistikaamet	KE20
EN5	Hüdroenergiast toodetud elektrienergia	(0)	-1	Statistikaamet	KE21
EN6	Tuuleenergiast toodetud elektrienergia	(0)	-1	Statistikaamet	KE21
EN7	Elektrienergia import	(1)	-1	Statistikaamet	KE21
EN8	Elektrienergia eksport	(2)	-1	Statistikaamet	KE21

Lisa 2 järg

Nimetus	Selgitus	Tr.	Viitaeg	Avaldaja	Tabel
EN9	Ettevõtetele lõpptarbimiseks müüdüd elektrienergia osatähtsus lõpptarbimises, %	(0)	-1	Statistikaamet	KE21
EN10	Kodutarbijatele müüdüd elektrienergia osatähtsus lõpptarbimises, %	(0)	-1	Statistikaamet	KE21
2. Hinnad					
HI1	Tootjahinnaindeks mäetööstus	(1)	-1	Statistikaamet	IA039
HI2	Tootjahinnaindeks elektrienergia, gaasi, auru ja konditsioneeritud õhuga varustamine	(1)	-1	Statistikaamet	IA039
HI3	Tootjahinnaindeks veevarustus; kanalisatsioon, jäätme- ja saastekäitlus	(1)	-1	Statistikaamet	IA039
HI4	Tootjahinnaindeks töötlev tööstus	(1)	-1	Statistikaamet	IA039
HI5	Tootjahinnaindeks toiduainete tootmine	(2)	-1	Statistikaamet	IA039
HI6	Tootjahinnaindeks puidutöötlemine, puit- ja korktoodete, punutiste tootmine, v.a mööbel	(1)	-1	Statistikaamet	IA039
HI7	Tootjahinnaindeks kemikaalide ja keemiatoodete tootmine	(1)	-1	Statistikaamet	IA039
HI8	Tootjahinnaindeks kumm- ja plasttoodete tootmine	(1)	-1	Statistikaamet	IA039
HI9	Tootjahinnaindeks muude mittemetalletest mineraalidest toodete tootmine mittemetalsed mineraalid	(2)	-1	Statistikaamet	IA039
HI10	Tootjahinnaindeks elektriseadmete tootmine	(1)	-1	Statistikaamet	IA039
HI11	Tootjahinnaindeks mööblitootmine	(1)	-1	Statistikaamet	IA039
HI12	Ekspordihinnaindeks	(2)	-1	Statistikaamet	IA06
HI13	Impordihinnaindeks	(1)	-1	Statistikaamet	IA08
HI14	Ehitushinnaindeks	(2)	-2	Statistikaamet	IA11
HI15	Ehitushinnaindeks: tööjõud	(2)	-2	Statistikaamet	IA11
HI16	Ehitushinnaindeks: ehitusmasinad	(1)	-2	Statistikaamet	IA11
HI17	Ehitushinnaindeks: ehitusmaterjal	(2)	-2	Statistikaamet	IA11
HI18	Remondi- ja rekonstrueerimistööde hinnaindeks	(2)	-2	Statistikaamet	IA14
HI19	Remondi- ja rekonstrueerimistööde hinnaindeks: tööjõud	(2)	-2	Statistikaamet	IA14
HI20	Remondi- ja rekonstrueerimistööde hinnaindeks: ehitusmasinad	(2)	-2	Statistikaamet	IA14
HI21	Remondi- ja rekonstrueerimistööde hinnaindeks: ehitusmaterjal	(3)	-2	Statistikaamet	IA14

Lisa 2 järg

Nimetus	Selgitus	Tr.	Viitaeg	Avaldaja	Tabel
3. Põllumajandus					
PO1	Piima keskmine hind, eurot/t	(2)	-1	Statistikaamet	PM18
PO2	Tootmise kogus: Joogipiim	(1)	-1	Statistikaamet	PM19
PO3	Tootmise kogus: Koor	(0)	-1	Statistikaamet	PM19
PO4	Tootmise kogus: Hapendatud piim (jogurt, joogijogurt ja muud)	(0)	-1	Statistikaamet	PM19
PO5	Tootmise kogus: Või ja muud piimarasvatooted kokku (82%-lise või ekvivalendina)	(0)	-1	Statistikaamet	PM19
PO6	Tootmise kogus: Või, rasvasisaldus 80% - <90%	(0)	-1	Statistikaamet	PM19
PO7	Tootmise kogus: Juust, k.a kohupiim (värsk juust)	(0)	-1	Statistikaamet	PM19
PO8	Tootmise kogus: Kohupiim (värsk juust)	(2)	-1	Statistikaamet	PM19
PO9	Kokkuostetud loomade arv, tuhat: Veised	(0)	-1	Statistikaamet	PM192
PO10	Kokkuostetud loomade arv, tuhat: Sead	(1)	-1	Statistikaamet	PM192
PO11	Kokkuostetud loomade arv, tuhat: Lambad ja kitsed	(0)	-1	Statistikaamet	PM192
PO12	Kokkuostetud loomade liha keskmine hind: Veised	(1)	-1	Statistikaamet	PM192
PO13	Kokkuostetud loomade liha keskmine hind: Sead	(1)	-1	Statistikaamet	PM192
PO14	Kokkuostetud loomade liha keskmine hind: Lambad ja kitsed	(0)	-1	Statistikaamet	PM192
SI1	Müügitulu, miljonit eurot: Kokku – kõik tegevusalad	(1)	-1	Statistikaamet	KM020
SI2	Müügitulu, miljonit eurot: Mootorsõidukite ja mootorrattaste hulgi- ja jaemüük ning remont	(1)	-1	Statistikaamet	KM020
4. Sisekaubandus					
SI3	Müügitulu, miljonit eurot: Mootorsõidukite müük; mootorrattaste müük, hooldus ja remont; mootorsõidukite osade ja liseseadmete müük	(1)	-1	Statistikaamet	KM020
SI4	Müügitulu, miljonit eurot: Mootorsõidukite hooldus ja remont	(1)	-1	Statistikaamet	KM020
SI5	Müügitulu, miljonit eurot: Jaekaubandus, v.a mootorsõidukid ja mootorrattad	(1)	-1	Statistikaamet	KM020
SI6	Müügitulu, miljonit eurot: Jaemüük spetsialiseerimata kauplustes, kus on ülekaalus toidukaubad, joogid ja tubakatooted	(1)	-1	Statistikaamet	KM020
SI7	Müügitulu, miljonit eurot: Jaemüük muudes spetsialiseerimata kauplustes	(1)	-1	Statistikaamet	KM020

Lisa 2 järg

Nimetus	Selgitus	Tr.	Viitaeg	Avaldaja	Tabel
SI8	Müügitulu, miljonit eurot: Toidukaupade, jookide ja tubakatoodete jaemüük spetsialiseeritud kauplustes	(1)	-1	Statistikaamet	KM020
SI9	Müügitulu, miljonit eurot: Mootorikütuse jaemüük spetsialiseeritud kauplustes	(1)	-1	Statistikaamet	KM020
SI10	Müügitulu, miljonit eurot: Majatarvete, kodumasinade, rauakaupade ja ehitusmaterjali jaemüük spetsialiseeritud kauplustes	(1)	-1	Statistikaamet	KM020
SI11	Müügitulu, miljonit eurot: Tekstiiltoodete, rõivaste, jalatsite ja nahktoodete jaemüük spetsialiseeritud kauplustes	(0)	-1	Statistikaamet	KM020
SI12	Müügitulu, miljonit eurot: Apteekide tegevus; meditsiini- ja ortopeediakaupade jaemüük, kosmeetika ja tualetitarvete jaemüük spetsialiseeritud kauplustes	(1)	-1	Statistikaamet	KM020
SI13	Müügitulu, miljonit eurot: Jaemüük muudes spetsialiseeritud kauplustes	(1)	-1	Statistikaamet	KM020
SI14	Müügitulu, miljonit eurot: Jaemüük posti või interneti teel	(1)	-1	Statistikaamet	KM020
SI15	Müügitulu, miljonit eurot: Kasutatud kaupade jaemüük kauplustes, jaemüük kioskites ja turgudel, muu jaemüük väljaspool kauplusi, kioskeid ja turge	(1)	-1	Statistikaamet	KM020
SI16	Müügitulu mahuindeks, 2015 = 100: Kokku – kõik tegevusalad	(1)	-1	Statistikaamet	KM020
SI17	Müügitulu mahuindeks, 2015 = 100: Mootorsõidukite ja mootorrataste hulgi- ja jaemüük ning remont	(1)	-1	Statistikaamet	KM020
SI18	Müügitulu mahuindeks, 2015 = 100: Mootorsõidukite müük; mootorrataste müük, hooldus ja remont; mootorsõidukite osade ja liseseadmete müük	(1)	-1	Statistikaamet	KM020
SI19	Müügitulu mahuindeks, 2015 = 100: Mootorsõidukite hooldus ja remont	(1)	-1	Statistikaamet	KM020
SI20	Müügitulu mahuindeks, 2015 = 100: Jaekaubandus, v.a mootorsõidukid ja mootorrattad	(1)	-1	Statistikaamet	KM020
SI21	Müügitulu mahuindeks, 2015 = 100: Jaemüük spetsialiseerimata kauplustes, kus on ülekaalus toidukaubad, joogid ja tubakatooted	(1)	-1	Statistikaamet	KM020
SI22	Müügitulu mahuindeks, 2015 = 100: Jaemüük muudes spetsialiseerimata kauplustes	(1)	-1	Statistikaamet	KM020
SI23	Müügitulu mahuindeks, 2015 = 100: Toidukaupade, jookide ja tubakatoodete jaemüük spetsialiseeritud kauplustes	(1)	-1	Statistikaamet	KM020

Lisa 2 järg

Nimetus	Selgitus	Tr.	Viitaeg	Avaldaja	Tabel
SI24	Müügitulu mahuindeks, 2015 = 100: Mootorikütuse jaemüük spetsialiseeritud kauplustes	(1)	-1	Statistikaamet	KM020
SI25	Müügitulu mahuindeks, 2015 = 100: Majatarvete, kodumasinade, rauakaupade ja ehitusmaterjali jaemüük spetsialiseeritud kauplustes	(1)	-1	Statistikaamet	KM020
SI26	Müügitulu mahuindeks, 2015 = 100: Tekstiiltoodete, rõivaste, jalatsite ja nahktoodete jaemüük spetsialiseeritud kauplustes	(0)	-1	Statistikaamet	KM020
SI27	Müügitulu mahuindeks, 2015 = 100: Apteekide tegevus; meditsiini- ja ortopeediakaupade jaemüük, kosmeetika ja tualetitarvete jaemüük spetsialiseeritud kauplustes	(1)	-1	Statistikaamet	KM020
SI28	Müügitulu mahuindeks, 2015 = 100: Jaemüük muudes spetsialiseeritud kauplustes	(1)	-1	Statistikaamet	KM020
SI29	Müügitulu mahuindeks, 2015 = 100: Jaemüük posti või interneti teel	(1)	-1	Statistikaamet	KM020
SI30	Müügitulu mahuindeks, 2015 = 100: Kasutatud kaupade jaemüük kauplustes, jaemüük kioskites ja turgudel, muu jaemüük väljaspool kauplusi, kioskeid ja turge	(1)	-1	Statistikaamet	KM020
5. Transport					
TR1	Registreeritud sõiduautod	(1)	-1	Statistikaamet	TS322
TR2	Registreeritud uued sõiduautod	(1)	-1	Statistikaamet	TS322
6. Majutus					
TU1	Majutatute arv	(0)	-1	Statistikaamet	TU121
7. Tööstus					
TO1	Tööstustoodangu mahuindeks (2015=100, korrigeerimata): Mäetööstus; töötlev tööstus; elektrienergia, gaasi, auru ja konditsioneeritud õhuga varustamine	(1)	-1	Statistikaamet	TO0053
TO2	Tööstustoodangu mahuindeks (2015=100, korrigeerimata): Mäetööstus	(0)	-1	Statistikaamet	TO0053
TO3	Tööstustoodangu mahuindeks (2015=100, korrigeerimata): Põlevkivi kaevandamine ja toornafta tootmine	(1)	-1	Statistikaamet	TO0053
TO4	Tööstustoodangu mahuindeks (2015=100, korrigeerimata): Turbatootmine	(0)	-1	Statistikaamet	TO0053

Lisa 2 järg

Nimetus	Selgitus	Tr.	Viitaeg	Avaldaja	Tabel
TO5	Tööstustoodangu mahuindeks (2015=100, korrigeerimata): Muu kaevandamine ja kaevandamist abistavad tegevusalad	(0)	-1	Statistikaamet	TO0053
TO6	Tööstustoodangu mahuindeks (2015=100, korrigeerimata): Töötlev tööstus	(1)	-1	Statistikaamet	TO0053
TO7	Tööstustoodangu mahuindeks (2015=100, korrigeerimata): Toiduainete tootmine	(1)	-1	Statistikaamet	TO0053
TO8	Tööstustoodangu mahuindeks (2015=100, korrigeerimata): Liha töötlemine ja säilitamine ning lihatoodete tootmine	(1)	-1	Statistikaamet	TO0053
TO9	Tööstustoodangu mahuindeks (2015=100, korrigeerimata): Kala, vähilaadsete ja limuste töötlemine ja säilitamine	(1)	-1	Statistikaamet	TO0053
TO10	Tööstustoodangu mahuindeks (2015=100, korrigeerimata): Puu- ja köögivilja töötlemine ja säilitamine	(0)	-1	Statistikaamet	TO0053
TO11	Tööstustoodangu mahuindeks (2015=100, korrigeerimata): Taimse ja loomse õli ja rasva tootmine	(1)	-1	Statistikaamet	TO0053
TO12	Tööstustoodangu mahuindeks (2015=100, korrigeerimata): Piimatoodete tootmine	(0)	-1	Statistikaamet	TO0053
TO13	Tööstustoodangu mahuindeks (2015=100, korrigeerimata): Jahu ja tangainete, tärklise ja tärklisetoodete tootmine	(1)	-1	Statistikaamet	TO0053
TO14	Tööstustoodangu mahuindeks (2015=100, korrigeerimata): Pagari- ja makarontoodete tootmine	(0)	-1	Statistikaamet	TO0053
TO15	Tööstustoodangu mahuindeks (2015=100, korrigeerimata): Muude toiduainete tootmine	(0)	-1	Statistikaamet	TO0053
TO16	Tööstustoodangu mahuindeks (2015=100, korrigeerimata): Valmis loomasööda tootmine	(1)	-1	Statistikaamet	TO0053
TO17	Tööstustoodangu mahuindeks (2015=100, korrigeerimata): Joogitootmine	(0)	-1	Statistikaamet	TO0053
TO18	Tööstustoodangu mahuindeks (2015=100, korrigeerimata): Tekstiilitootmine	(1)	-1	Statistikaamet	TO0053
TO19	Tööstustoodangu mahuindeks (2015=100, korrigeerimata): Rõivatootmine	(1)	-1	Statistikaamet	TO0053
TO20	Tööstustoodangu mahuindeks (2015=100, korrigeerimata): Nahatöötlemine ja nahktoodete tootmine	(0)	-1	Statistikaamet	TO0053

Lisa 2 järg

Nimetus	Selgitus	Tr.	Viitaeg	Avaldaja	Tabel
TO21	Tööstustoodangu mahuindeks (2015=100, korrigeerimata): Puidutöötlemine ning puit- ja korktoodete tootmine, v.a mööbel; õlest ja punumismaterjalist toodete tootmine	(1)	-1	Statistikaamet	TO0053
TO22	Tööstustoodangu mahuindeks (2015=100, korrigeerimata): Paberi ja pabertoodete tootmine	(1)	-1	Statistikaamet	TO0053
TO23	Tööstustoodangu mahuindeks (2015=100, korrigeerimata): Trükindus ja salvestiste paljundus	(1)	-1	Statistikaamet	TO0053
TO24	Tööstustoodangu mahuindeks (2015=100, korrigeerimata): Koksi ja puhastatud naftatoodete tootmine	(0)	-1	Statistikaamet	TO0053
TO25	Tööstustoodangu mahuindeks (2015=100, korrigeerimata): Kemikaalide ja keemiatoodete tootmine	(0)	-1	Statistikaamet	TO0053
TO26	Tööstustoodangu mahuindeks (2015=100, korrigeerimata): Põhifarmaatsiatoodete ja ravimpreparaatide tootmine	(1)	-1	Statistikaamet	TO0053
TO27	Tööstustoodangu mahuindeks (2015=100, korrigeerimata): Kummi- ja plasttoodete tootmine	(1)	-1	Statistikaamet	TO0053
TO28	Tööstustoodangu mahuindeks (2015=100, korrigeerimata): Muude mittemetalletest mineraalidest toodete tootmine	(1)	-1	Statistikaamet	TO0053
TO29	Tööstustoodangu mahuindeks (2015=100, korrigeerimata): Metallitootmine	(1)	-1	Statistikaamet	TO0053
TO30	Tööstustoodangu mahuindeks (2015=100, korrigeerimata): Metalltoodete tootmine, v.a masinad ja seadmed	(1)	-1	Statistikaamet	TO0053
TO31	Tööstustoodangu mahuindeks (2015=100, korrigeerimata): Arvutite, elektroonika- ja optikaseadmete tootmine	(1)	-1	Statistikaamet	TO0053
TO32	Tööstustoodangu mahuindeks (2015=100, korrigeerimata): Arvutite ja arvuti välisseadmete tootmine	(1)	-1	Statistikaamet	TO0053
TO33	Tööstustoodangu mahuindeks (2015=100, korrigeerimata): Elektriseadmete tootmine	(1)	-1	Statistikaamet	TO0053
TO34	Tööstustoodangu mahuindeks (2015=100, korrigeerimata): Mujal liigitamata masinate ja seadmete tootmine	(1)	-1	Statistikaamet	TO0053

Lisa 2 järg

Nimetus	Selgitus	Tr.	Viitaeg	Avaldaja	Tabel
TO35	Tööstustoodangu mahuindeks (2015=100, korrigeerimata): Mootorsõidukite, haagiste ja poolhaagiste tootmine	(1)	-1	Statistikaamet	TO0053
TO36	Tööstustoodangu mahuindeks (2015=100, korrigeerimata): Mööblitootmine	(1)	-1	Statistikaamet	TO0053
TO37	Tööstustoodangu mahuindeks (2015=100, korrigeerimata): Muu tootmine	(1)	-1	Statistikaamet	TO0053
TO38	Tööstustoodangu mahuindeks (2015=100, korrigeerimata): Masinate ja seadmete remont ja paigaldus	(1)	-1	Statistikaamet	TO0053
TO39	Tööstustoodangu mahuindeks (2015=100, korrigeerimata): Elektrienergia, gaasi, auru ja konditsioneeritud õhuga varustamine	(0)	-1	Statistikaamet	TO0053
TO40	Tööstustoodangu mahuindeks (2015=100, korrigeerimata): Vahetoodete tootmine	(1)	-1	Statistikaamet	TO0053
TO41	Tööstustoodangu mahuindeks (2015=100, korrigeerimata): Kapitalikaupade tootmine	(1)	-1	Statistikaamet	TO0053
TO42	Tööstustoodangu mahuindeks (2015=100, korrigeerimata): Kestustarbekaupade tootmine	(1)	-1	Statistikaamet	TO0053
TO43	Tööstustoodangu mahuindeks (2015=100, korrigeerimata): Kulutarbekaupade tootmine	(1)	-1	Statistikaamet	TO0053
TO44	Tööstustoodangu mahuindeks (2015=100, korrigeerimata): Energiatoodete tootmine (v.a jagu E)	(0)	-1	Statistikaamet	TO0053
TO45	Tööstustoodangu mahuindeks (2015=100, kalendaarselt ja sesoonselt korrigeeritud): Mäetööstus; töötlev tööstus; elektrienergia, gaasi, auru ja konditsioneeritud õhuga varustamine	(1)	-1	Statistikaamet	TO0053
TO46	Tööstustoodangu mahuindeks (2015=100, kalendaarselt ja sesoonselt korrigeeritud): Mäetööstus	(0)	-1	Statistikaamet	TO0053
TO47	Tööstustoodangu mahuindeks (2015=100, kalendaarselt ja sesoonselt korrigeeritud): Põlevkivi kaevandamine ja toornafta tootmine	(1)	-1	Statistikaamet	TO0053
TO48	Tööstustoodangu mahuindeks (2015=100, kalendaarselt ja sesoonselt korrigeeritud): Turbatootmine	(0)	-1	Statistikaamet	TO0053
TO49	Tööstustoodangu mahuindeks (2015=100, kalendaarselt ja sesoonselt korrigeeritud): Muu kaevandamine ja kaevandamist abistavad tegevusalad	(1)	-1	Statistikaamet	TO0053

Lisa 2 järg

Nimetus	Selgitus	Tr.	Viitaeg	Avaldaja	Tabel
TO50	Tööstustoodangu mahuindeks (2015=100, kalendaarselt ja sesoonselt korrigeeritud): Töötlev tööstus	(1)	-1	Statistikaamet	TO0053
TO51	Tööstustoodangu mahuindeks (2015=100, kalendaarselt ja sesoonselt korrigeeritud): Toiduainete tootmine	(1)	-1	Statistikaamet	TO0053
TO52	Tööstustoodangu mahuindeks (2015=100, kalendaarselt ja sesoonselt korrigeeritud): Liha töötlemine ja säilitamine ning lihatoodete tootmine	(1)	-1	Statistikaamet	TO0053
TO53	Tööstustoodangu mahuindeks (2015=100, kalendaarselt ja sesoonselt korrigeeritud): Kala, vähilaadsete ja limuste töötlemine ja säilitamine	(1)	-1	Statistikaamet	TO0053
TO54	Tööstustoodangu mahuindeks (2015=100, kalendaarselt ja sesoonselt korrigeeritud): Puu- ja köögivilja töötlemine ja säilitamine	(1)	-1	Statistikaamet	TO0053
TO55	Tööstustoodangu mahuindeks (2015=100, kalendaarselt ja sesoonselt korrigeeritud): Taimse ja loomse õli ja rasva tootmine	(1)	-1	Statistikaamet	TO0053
TO56	Tööstustoodangu mahuindeks (2015=100, kalendaarselt ja sesoonselt korrigeeritud): Piimatoodete tootmine	(1)	-1	Statistikaamet	TO0053
TO57	Tööstustoodangu mahuindeks (2015=100, kalendaarselt ja sesoonselt korrigeeritud): Jahu ja tangainete, tärklise ja tärklisetoodete tootmine	(1)	-1	Statistikaamet	TO0053
TO58	Tööstustoodangu mahuindeks (2015=100, kalendaarselt ja sesoonselt korrigeeritud): Pagari- ja makarontoodete tootmine	(1)	-1	Statistikaamet	TO0053
TO59	Tööstustoodangu mahuindeks (2015=100, kalendaarselt ja sesoonselt korrigeeritud): Muude toiduainete tootmine	(1)	-1	Statistikaamet	TO0053
TO60	Tööstustoodangu mahuindeks (2015=100, kalendaarselt ja sesoonselt korrigeeritud): Valmis loomasööda tootmine	(1)	-1	Statistikaamet	TO0053
TO61	Tööstustoodangu mahuindeks (2015=100, kalendaarselt ja sesoonselt korrigeeritud): Joogitootmine	(1)	-1	Statistikaamet	TO0053
TO62	Tööstustoodangu mahuindeks (2015=100, kalendaarselt ja sesoonselt korrigeeritud): Tekstiilitootmine	(1)	-1	Statistikaamet	TO0053

Lisa 2 järg

Nimetus	Selgitus	Tr.	Viitaeg	Avaldaja	Tabel
TO63	Tööstustoodangu mahuindeks (2015=100, kalendaarselt ja sesoonselt korrigeeritud): Rõivatootmine	(1)	-1	Statistikaamet	TO0053
TO64	Tööstustoodangu mahuindeks (2015=100, kalendaarselt ja sesoonselt korrigeeritud): Nahatöötlemine ja nahktoodete tootmine	(1)	-1	Statistikaamet	TO0053
TO65	Tööstustoodangu mahuindeks (2015=100, kalendaarselt ja sesoonselt korrigeeritud): Puidutöötlemine ning puit- ja korktoodete tootmine, v.a mööbel; õlest ja punumismaterjalist toodete tootmine	(1)	-1	Statistikaamet	TO0053
TO66	Tööstustoodangu mahuindeks (2015=100, kalendaarselt ja sesoonselt korrigeeritud): Paberi ja pabertoodete tootmine	(1)	-1	Statistikaamet	TO0053
TO67	Tööstustoodangu mahuindeks (2015=100, kalendaarselt ja sesoonselt korrigeeritud): Trükindus ja salvestiste paljundus	(1)	-1	Statistikaamet	TO0053
TO68	Tööstustoodangu mahuindeks (2015=100, kalendaarselt ja sesoonselt korrigeeritud): Koksi ja puhastatud naftatoodete tootmine	(0)	-1	Statistikaamet	TO0053
TO69	Tööstustoodangu mahuindeks (2015=100, kalendaarselt ja sesoonselt korrigeeritud): Kemikaalide ja keemiatoodete tootmine	(1)	-1	Statistikaamet	TO0053
TO70	Tööstustoodangu mahuindeks (2015=100, kalendaarselt ja sesoonselt korrigeeritud): Põhifarmaatsiatoodete ja ravimpreparaatide tootmine	(1)	-1	Statistikaamet	TO0053
TO71	Tööstustoodangu mahuindeks (2015=100, kalendaarselt ja sesoonselt korrigeeritud): Kummi- ja plasttoodete tootmine	(1)	-1	Statistikaamet	TO0053
TO72	Tööstustoodangu mahuindeks (2015=100, kalendaarselt ja sesoonselt korrigeeritud): Muude mittemetalletest mineraalidest toodete tootmine	(1)	-1	Statistikaamet	TO0053
TO73	Tööstustoodangu mahuindeks (2015=100, kalendaarselt ja sesoonselt korrigeeritud): Metallitootmine	(1)	-1	Statistikaamet	TO0053
TO74	Tööstustoodangu mahuindeks (2015=100, kalendaarselt ja sesoonselt korrigeeritud): Metalltoodete tootmine, v.a masinad ja seadmed	(1)	-1	Statistikaamet	TO0053
TO75	Tööstustoodangu mahuindeks (2015=100, kalendaarselt ja sesoonselt korrigeeritud): Arvutite, elektroonika- ja optikaseadmete tootmine	(1)	-1	Statistikaamet	TO0053

Lisa 2 järg

Nimetus	Selgitus	Tr.	Viitaeg	Avaldaja	Tabel
TO76	Tööstustoodangu mahuindeks (2015=100, kalendaarselt ja sesoonselt korrigeeritud): Arvutite ja arvuti välisseadmete tootmine	(1)	-1	Statistikaamet	TO0053
TO77	Tööstustoodangu mahuindeks (2015=100, kalendaarselt ja sesoonselt korrigeeritud): Elektriseadmete tootmine	(1)	-1	Statistikaamet	TO0053
TO78	Tööstustoodangu mahuindeks (2015=100, kalendaarselt ja sesoonselt korrigeeritud): Mujal liigitamata masinate ja seadmete tootmine	(1)	-1	Statistikaamet	TO0053
TO79	Tööstustoodangu mahuindeks (2015=100, kalendaarselt ja sesoonselt korrigeeritud): Mootorsõidukite, haagiste ja poolhaagiste tootmine	(1)	-1	Statistikaamet	TO0053
TO80	Tööstustoodangu mahuindeks (2015=100, kalendaarselt ja sesoonselt korrigeeritud): Mööblitootmine	(1)	-1	Statistikaamet	TO0053
TO81	Tööstustoodangu mahuindeks (2015=100, kalendaarselt ja sesoonselt korrigeeritud): Muu tootmine	(1)	-1	Statistikaamet	TO0053
TO82	Tööstustoodangu mahuindeks (2015=100, kalendaarselt ja sesoonselt korrigeeritud): Masinate ja seadmete remont ja paigaldus	(1)	-1	Statistikaamet	TO0053
TO83	Tööstustoodangu mahuindeks (2015=100, kalendaarselt ja sesoonselt korrigeeritud): Elektrienergia, gaasi, auru ja konditsioneeritud õhuga varustamine	(1)	-1	Statistikaamet	TO0053
TO84	Tööstustoodangu mahuindeks (2015=100, kalendaarselt ja sesoonselt korrigeeritud): Vahetoodete tootmine	(1)	-1	Statistikaamet	TO0053
TO85	Tööstustoodangu mahuindeks (2015=100, kalendaarselt ja sesoonselt korrigeeritud): Kapitalikaupade tootmine	(1)	-1	Statistikaamet	TO0053
TO86	Tööstustoodangu mahuindeks (2015=100, kalendaarselt ja sesoonselt korrigeeritud): Kestustarbekaupade tootmine	(1)	-1	Statistikaamet	TO0053
TO87	Tööstustoodangu mahuindeks (2015=100, kalendaarselt ja sesoonselt korrigeeritud): Kulutarbekaupade tootmine	(1)	-1	Statistikaamet	TO0053
TO88	Tööstustoodangu mahuindeks (2015=100, kalendaarselt ja sesoonselt korrigeeritud): Energiatoodete tootmine (v.a jagu E)	(1)	-1	Statistikaamet	TO0053

Lisa 2 järg

Nimetus	Selgitus	Tr.	Viitaeg	Avaldaja	Tabel
8. Tööturg					
TOO1	Registreeritud töötute arv	(1)	-2	Eurostat	UNE_RT_M
TOO2	Registreeritud töötute arv (sesoonselt korrigeeritud)	(1)	-2	Eurostat	UNE_RT_M
TOO3	Töötuse määr	(1)	-2	Eurostat	UNE_RT_M
TOO4	Töötuse määr (sesoonselt korrigeeritud)	(1)	-2	Eurostat	UNE_RT_M
9. Rahandus					
RA1	1-kuuline intressimäär (euroala)	(1)		Eurostat	IRT_ST_M
RA2	3-kuuline intressimäär (euroala)	(1)		Eurostat	IRT_ST_M
RA3	Kodumajapidamiste hoiusejääk: residendid	(1)	-1	Eesti Pank	
RA4	Kodumajapidamiste hoiusejääk: mitteresidendid	(1)	-1	Eesti Pank	
10. Väliskaubandus					
VK1	Eksport Venemaale	(1)	-2	Statistikaamet	VKK16
VK2	Eksport Venemaale: Kapitalikaubad	(1)	-2	Statistikaamet	VKK16
VK3	Eksport Venemaale: Masinad ja teised kapitalikaubad (v.a transpordivahendid)	(1)	-2	Statistikaamet	VKK16
VK4	Eksport Venemaale: Transpordivahendid (v.a sõidua autod), tööstuslikud	(0)	-2	Statistikaamet	VKK16
VK5	Eksport Venemaale: Vahetarbekaubad	(1)	-2	Statistikaamet	VKK16
VK6	Eksport Venemaale: Toit ja joogid, töödeldud tooted, peamiselt tööstusele	(1)	-2	Statistikaamet	VKK16
VK7	Eksport Venemaale: Mujal spetsifitseerimata tööstuslik tooraine, toore	(1)	-2	Statistikaamet	VKK16
VK8	Eksport Venemaale: Mujal spetsifitseerimata tööstuslik tooraine, töödeldud tooted	(0)	-2	Statistikaamet	VKK16
VK9	Eksport Venemaale: Kütused ja määrdeained, töödeldud (v.a mootoribensiin)	(0)	-2	Statistikaamet	VKK16
VK10	Eksport Venemaale: Masinate ja teiste kapitalikaupade (v.a transpordivahendite) osad ja lisaseadmed	(1)	-2	Statistikaamet	VKK16
VK11	Eksport Venemaale: Transpordivahendite osad ja lisaseadmed	(1)	-2	Statistikaamet	VKK16
VK12	Eksport Venemaale: Tarbekaubad	(1)	-2	Statistikaamet	VKK16
VK13	Eksport Venemaale: Toit ja joogid, toore, peamiselt eratarbimiseks	(1)	-2	Statistikaamet	VKK16

Lisa 2 järg

Nimetus	Selgitus	Tr.	Viitaeg	Avaldaja	Tabel
VK14	Eksport Venemaale: C122 Toit ja joogid, töödeldud tooted, peamiselt eratarbimiseks	(0)	-2	Statistikaamet	VKK16
VK15	Eksport Venemaale: Mujal spetsifitseerimata tarbekaubad, kestvuskaup	(1)	-2	Statistikaamet	VKK16
VK16	Eksport Venemaale: Mujal spetsifitseerimata tarbekaubad, pool-kestvuskaup	(1)	-2	Statistikaamet	VKK16
VK17	Eksport Venemaale: Mujal spetsifitseerimata tarbekaubad, mitte-kestvuskaup	(1)	-2	Statistikaamet	VKK16
VK18	Import Venemaalt	(1)	-2	Statistikaamet	VKK16
VK19	Import Venemaalt: Kapitalikaubad	(0)	-2	Statistikaamet	VKK16
VK20	Import Venemaalt: Masinad ja teised kapitalikaubad (v.a transpordivahendid)	(0)	-2	Statistikaamet	VKK16
VK21	Import Venemaalt: Vahetarbekaubad	(1)	-2	Statistikaamet	VKK16
VK22	Import Venemaalt: Mujal spetsifitseerimata tööstuslik tooraine, toore	(1)	-2	Statistikaamet	VKK16
VK23	Import Venemaalt: Mujal spetsifitseerimata tööstuslik tooraine, töödeldud tooted	(0)	-2	Statistikaamet	VKK16
VK24	Import Venemaalt: Kütused ja määrdeained, toore	(0)	-2	Statistikaamet	VKK16
VK25	Import Venemaalt: Kütused ja määrdeained, töödeldud (v.a mootoribensiin)	(1)	-2	Statistikaamet	VKK16
VK26	Import Venemaalt: Masinate ja teiste kapitalikaupade (v.a transpordivahendite) osad ja lisaseadmed	(0)	-2	Statistikaamet	VKK16
VK27	Import Venemaalt: Transpordivahendite osad ja lisaseadmed	(0)	-2	Statistikaamet	VKK16
VK28	Import Venemaalt: Tarbekaubad	(1)	-2	Statistikaamet	VKK16
VK29	Import Venemaalt: Toit ja joogid, toore, peamiselt eratarbimiseks	(0)	-2	Statistikaamet	VKK16
VK30	Import Venemaalt: Toit ja joogid, töödeldud tooted, peamiselt eratarbimiseks	(1)	-2	Statistikaamet	VKK16
VK31	Import Venemaalt: Mujal spetsifitseerimata tarbekaubad, kestvuskaup	(2)	-2	Statistikaamet	VKK16
VK32	Import Venemaalt: Mujal spetsifitseerimata tarbekaubad, pool-kestvuskaup	(1)	-2	Statistikaamet	VKK16
VK33	Import Venemaalt: Mujal spetsifitseerimata tarbekaubad, mitte-kestvuskaup	(1)	-2	Statistikaamet	VKK16

Lisa 2 järg

Nimetus	Selgitus	Tr.	Viitaeg	Avaldaja	Tabel
10. Küsitlusandmed					
SUR1	Hinnaootus: ehitushinnad järgneval 3 kuul (ehitusbaromeeter)	(1)		Euroopa Komisjon	Business and consumer survey
SUR2	Hinnaootus: hinnad järgneval 12 kuul (tarbijabaromeeter)	(1)		Euroopa Komisjon	Business and consumer survey
SUR3	Hinnaootus: toodangu müügihinnad järgneva 3 kuu jooksul (tööstusbaromeeter)	(0)		Euroopa Komisjon	Business and consumer survey
SUR4	Hinnaootus: kaupade hinnad järgneva 3 kuu jooksul (kaubandusbaromeeter)	(1)		Euroopa Komisjon	Business and consumer survey
SUR5	Hinnaootus: teenuste hinnad järgneva 3 kuu jooksul (teenindusbaromeeter)	(1)		Euroopa Komisjon	Business and consumer survey

Allikas: Autori koostatud

Lisa 3. Korrelatsioonimaatriks

Kättesaadav lingilt: <https://www.dropbox.com/scl/fi/g4jyaloulnqif21qkd7t3/Lisa-3.-Korrelatsioonimaatriks.xlsx?dl=0&rlkey=tm9kfqrwe5jwbfyadfsbumnz>

Allikas: Autori arvutused

Lisa 4. ADF ja Box-Ljung testide tulemused

Kättesaadav lingilt: <https://www.dropbox.com/scl/fi/5rpd81ksymshh9ulyafn6/Lisa-4.-ADF-ja-Box-Ljung-testide-tulemused.xlsx?dl=0&rlkey=n4yn1qg165axb7vawcq7ifqo1>

Allikas: Autori arvutused

Lisa 5. Mudelite RMSE, MAE, MAD koguvalimis

	Ilma küsitlusandmeteta												Koos küsitlusandmetega								
	ARIMA			Lasso			adaLasso			RF			Lasso			adaLasso			RF		
Järeltestimine	RMSE	MAE	MAD	RMSE	MAE	MAD	RMSE	MAE	MAD	RMSE	MAE	MAD	RMSE	MAE	MAD	RMSE	MAE	MAD	RMSE	MAE	MAD
THI	27,77	9,48	2,09	17,12	6,55	2,96	15,85	8,38	4,59	8,20	2,95	1,05	17,12	6,55	2,96	15,85	8,38	4,59	8,23	2,98	1,00
THI desagr.	0,93	0,39	0,16	0,57	0,24	0,12	0,55	0,26	0,14	0,27	0,11	0,05	0,57	0,24	0,12	0,55	0,26	0,14	0,28	0,11	0,05
Kombineeritud	0,93	0,39	0,16							0,27	0,11	0,05							0,28	0,11	0,05
sh Toit	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,00	0,00	0,00	0,01	0,01	0,01	0,01	0,01	0,01	0,00	0,00	0,00
sh Alkohol	0,01	0,01	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,01	0,01	0,01	0,00	0,00	0,00	0,00	0,00	0,00
sh Riided	0,03	0,03	0,02	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,00	0,00	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,00	0,00
sh Eluase	0,04	0,02	0,01	0,02	0,01	0,01	0,02	0,01	0,01	0,01	0,00	0,00	0,02	0,01	0,01	0,02	0,01	0,01	0,01	0,00	0,00
sh Majapidamine	14,26	5,99	2,48	8,77	3,75	1,93	8,45	4,05	2,11	4,21	1,72	0,71	8,77	3,75	1,93	8,45	4,05	2,11	4,23	1,70	0,76
sh Tervis	0,01	0,01	0,00	0,01	0,00	0,00	0,01	0,00	0,00	0,00	0,00	0,00	0,01	0,00	0,00	0,01	0,00	0,00	0,00	0,00	0,00
sh Transport	0,02	0,01	0,01	0,02	0,01	0,01	0,02	0,01	0,01	0,01	0,00	0,00	0,02	0,01	0,01	0,02	0,01	0,01	0,01	0,00	0,00
sh Side	0,02	0,01	0,00	0,00	0,00	0,00	0,01	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,01	0,01	0,00	0,00	0,00	0,00
sh Vaba	0,01	0,01	0,01	0,01	0,01	0,00	0,01	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
sh Haridus	0,05	0,02	0,00	0,04	0,01	0,00	0,04	0,01	0,00	0,02	0,01	0,00	0,04	0,01	0,00	0,04	0,01	0,00	0,02	0,01	0,00
sh Majutus	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,00	0,00	0,00	0,01	0,01	0,01	0,01	0,01	0,01	0,00	0,00	0,00
sh Mitmesugused	0,01	0,01	0,01	0,01	0,01	0,00	0,01	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00

Allikas: Autori arvutused

Lisa 6. Mudelite RMSE, MAE, MAD järeltestimise perioodil

Järeltestimine	Ilma küsitlusandmeteta												Koos küsitlusandmetega								
	ARIMA			Lasso			adaLasso			RF			Lasso			adaLasso			RF		
	RMSE	MAE	MAD	RMSE	MAE	MAD	RMSE	MAE	MAD	RMSE	MAE	MAD	RMSE	MAE	MAD	RMSE	MAE	MAD	RMSE	MAE	MAD
THI	6,92	4,14	0,97	6,33	4,81	3,41	7,54	5,64	3,62	3,00	2,23	1,19	6,33	4,81	3,41	7,54	5,64	3,62	2,70	2,04	0,93
THI desagr.	0,20	0,15	0,10	0,15	0,09	0,05	0,16	0,12	0,07	0,07	0,06	0,03	0,15	0,09	0,05	0,16	0,12	0,07	0,07	0,06	0,05
Kombineeritud	0,20	0,15	0,10							0,07	0,06	0,04							0,07	0,06	0,05
sh Toit	0,01	0,01	0,01	0,02	0,01	0,01	0,02	0,02	0,01	0,01	0,00	0,00	0,02	0,01	0,01	0,02	0,02	0,01	0,01	0,00	0,00
sh Alkohol	0,01	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
sh Riided	0,04	0,03	0,02	0,02	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,00	0,02	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,00
sh Eluase	0,08	0,06	0,04	0,04	0,03	0,02	0,04	0,03	0,02	0,03	0,02	0,01	0,04	0,04	0,02	0,04	0,03	0,02	0,02	0,02	0,01
sh Majapidamine	2,95	2,21	1,34	2,40	1,50	0,94	2,51	1,78	1,20	1,13	0,86	0,53	2,40	1,50	0,94	2,51	1,78	1,20	1,01	0,88	0,74
sh Tervis	0,01	0,01	0,01	0,01	0,01	0,00	0,01	0,01	0,00	0,00	0,00	0,00	0,01	0,01	0,00	0,01	0,01	0,00	0,00	0,00	0,00
sh Transport	0,03	0,02	0,02	0,03	0,02	0,01	0,03	0,02	0,01	0,01	0,01	0,01	0,03	0,02	0,01	0,03	0,02	0,01	0,01	0,01	0,01
sh Side	0,02	0,02	0,01	0,00	0,00	0,00	0,01	0,01	0,01	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,01	0,00	0,00
sh Vaba	0,02	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
sh Haridus	0,03	0,01	0,00	0,02	0,01	0,00	0,02	0,01	0,00	0,01	0,01	0,00	0,02	0,01	0,00	0,02	0,01	0,00	0,01	0,01	0,00
sh Majutus	0,03	0,02	0,01	0,03	0,02	0,01	0,03	0,02	0,01	0,01	0,01	0,00	0,03	0,02	0,01	0,03	0,02	0,01	0,01	0,01	0,01
sh Mitmesugused	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00

Allikas: Autori arvutused

Lisa 7. Lassoregressioonide muutujate koefitsiendid

Kättesaadav lingilt: <https://www.dropbox.com/scl/fi/xtwhdtp4vskgbl6hle8mb/Lisa-7.-Lassoregressioonide-muutujate-koefitsiendid.xlsx?dl=0&rlkey=daloe851d5jbcgza33zdordqt>

Allikas: Autori arvutused

Lisa 8. Juhusliku metsa muutujate osatähtsus MSE-s

Kättesaadav lingilt: <https://www.dropbox.com/scl/fi/2au9ar5426d7hej94iyn6/Lisa-8.-RF-muutujate-osat-htsus-MSE.xlsx?dl=0&rlkey=6lxdxvqj3ziadytfaxp7v77w8>

Allikas: Autori arvutused

Lisa 9. Lihtlitsents

Lihtlitsents lõputöö reprodutseerimiseks ja lõputöö üldsusele kättesaadavaks tegemiseks¹

Mina, Reela Rosin (autori nimi)

1. Annan Tallinna Tehnikaülikoolile tasuta loa (lihtlitsentsi) enda loodud teose

Eesti inflatsiooni kiirhinnangu koostamise võimalused,
(lõputöö pealkiri)

mille juhendaja on Peeter Luikmel,
(juhendaja nimi)

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

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

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

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

09. mai 2023 (kuupäev)

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