

TARTU ÜLIKOOL
Sotsiaalteaduste valdkond
Majandusteaduskond

Marleen Mändul

HAIGLAS VIIBIMISE KESTUS KUI EFEKTIIVSUSE MÕÕTMISE VAHEND

Bakalaureusetöö

Juhendaja: nooremlektor Andres Võrk

Tartu 2026

Olen koostanud töö iseseisvalt. Kõik töö koostamisel kasutatud teiste autorite tööd, põhimõttelised seisukohad, kirjandusallikatest ja mujalt pärinevad andmed on viidatud.

Sisukord

Sissejuhatus	4
1. Haiglate efektiivsuse mõõtmise võimalused	6
1.1 Efektiivsuse olemus ja selle mõõdikud tervishoius	6
1.2 Efektiivsuse mõõtmine tervishoius statistiliste mudelitega	7
1.3 Haiglas viibimise aeg kui efektiivsuse mõõdik	11
1.4 Varasemad uuringud haiglas viibimise ajast	13
2. Eesti haiglates voodiravil viibimise aja hindamine	17
2.1 Ülevaade Eesti haiglatest	17
2.2 Haiglate analüüsimisel kasutatavad andmed	18
2.3 Uurimismetoodika	21
2.4 Empiirilise analüüsi tulemused	24
2.4.1 Kirjeldav analüüs	24
2.4.2 Analüüsi tulemused kardioloogias	28
2.4.3 Analüüsi tulemused pulmonoloogias	30
2.4.4 Analüüsi tulemused nefrooloogias	33
2.4.5 Analüüsi tulemused üle kolme eriala	36
2.4.6 Järeldused	40
Kokkuvõte	44
Kasutatud allikad	45
Lisad	51
Lisa A	51
Lisa B	52
Lisa C	53
Lisa D	54
Lisa E	56
Lisa F	58
Lisa G	59
Lisa H	61
Summary	62

Sissejuhatus

Tänapäeva tervishoiusüsteemid seisavad silmitsi vajadusega pidevalt areneda ja koheneda kasvava nõudlusega, mida survestavad nii elanikkonna vananemine kui ka tehnoloogia kiire areng. Rahvusvahelised organisatsioonid nagu Majanduskoostöö ja Arengu Organisatsioon (OECD) ja Maailma Tervishoiuorganisatsioon (WHO) rõhutavad, et tervishoiusektori jätkusuutlikkus ei sõltu mitte ainult investeringute mahust, vaid sellest, kui tõhusalt suudetakse olemasolevaid vahendeid tervisetulemiteks kasutada. Efektiivsuse mõõtmine tervishoius on viimaste aastatega kasvanud ja muutunud tervishoiusüsteemi korraldamisel ökonomistidele järjest olulisemaks näitajaks, kuna WHO 2010. aastal koostatud raportis on hinnatud, et 20–40% kõigist tervishoiukuludest läheb raisku ebaefektiivse töö tõttu. Kõige parem viis ülemaailmse ühtlase ravikindlustuse tagamiseks on aga just efektiivsuse suurendamine. (World Health Organization, 2010)

Ressursside säästlik kasutamine ei ole mitte ainult omaette eesmärk, vaid konkreetne tööriist parimate patsiendikesksete tulemuste saavutamiseks. 2000. aastal on WHO raporteerinud, et tervishoiusüsteemi ei tohiks hinnata ainult arstide arvu, haiglate või raha järgi, vaid läheneda sellele patsiendi nurga alt ja keskenduda sellele, milliseid tulemusi süsteem inimestele annab. See tähendab, et esikohale tuleb seada inimeste ootustele vastava õiglase ja efektiivse süsteemi loomine. Efektiivne süsteem peab tagama patsientide väärikuse, privaatsuse ja õiglase teenuste kättesaadavuse, sõltumata inimese maksevõimekusest. (WHO, 2000) 2008. aastal kirjutas Hollingsworth, et pakkumine tervishoiu efektiivsuse uurimisele on suur, kuid nõudlus sellele madal. Sealt tekkis tal ka küsimus, mida tervishoiuökonomidid efektiivsuse all tegelikult mõtlevad ning kas kõigil on sellest ühine arusaam. (Hollingsworth, 2008, lk 1107–1128)

Efektiivsust võib tervishoius mõõta mitmel tasandil: tervisesüsteemi tasand, näiteks milline ravitav suremus võrreldes süsteemi ressurssidega; sektortasand, näiteks haiglaravi, perearstiabi, ravimite sektori efektiivsus, haiguse tasand, nt kui efektiivne on südameveresoonekonna haiguste ennetus ja ravi. Efektiivsuse all mõistetakse üldiselt kasutegurit, mis tekib võimalikult suure tootmise korral või kui eesmärk saavutatakse võimalikult minimaalsete kulude või vahenditega. Kui ettevõtte on täielikult efektiivne, on tema tehniline efektiivsus 1 ehk 100%. See aga ei püsi kunagi pikalt stabiilsena, sest juurde tuleb arvestada näiteks ka tootmise hinda ja tööjõukulusid. Oma efektiivsuse parandamiseks peab ettevõtte leidma tasakaalu, kus kulud on minimeeritud ja tulud maksimeeritud. (Farrell, 1957)

Hollingsworth ja Peacock (2008) on jaganud efektiivsuse tehniliseks ja alloktiivseks efektiivsuseks. Tehniline efektiivsus on „asjade õigesti tegemine“ olemasolevate sisenditega, saavutades maksimaalne võimalik väljund või sama väljund toodetakse minimaalse sisendikuluga. Näiteks kui Eesti haiglad kasutavad sama arvu arste, õdesid ja seadmeid kui mõne teise riigi haiglad, kuid ravivad sealjuures vähem patsiente, on tehniline efektiivsus madalam. Alloktiivne efektiivsus tähendab aga „õigete asjade tegemist“, suunates ressursse selliste teenuste juurde, kus need annaksid suurima ühiskondliku kasu, olgu selleks siis tervisevõit või raha-

line kaitse tervisekulude eest. Näiteks kui Tervisekassa jaotab lisaraha selliselt, et see tagab võimalikult suure tervisekasu kogu elanikkonna jaoks, on saavutatud allokatiivne efektiivsus.

Haiglate efektiivsus peegeldab suuresti kogu riigi tervishoiusüsteemi ning olulise rolli teenuste pakkumisel moodustavad haiglad. 2024. aastal oli Eestis kokku 27 806 tervishoiutöötajat, kellest 68% töötasid haiglates. Haiglate panus kogu riigi tervishoiuteenuste tuludesse oli samal aastal 62%, kusjuures haiglate osakaal Tervisekassa poolt laekunud tuludest moodustas 72%. Võrreldes 2023. aastaga kasvasid 2024. aastal Põhja-Eesti Regionaalhaigla tegevuskulud 8,7%, Tartu Ülikooli Kliinikumis oli tegevuskulude kasv 9,2%. (Tervise Arengu Instituut, 2025) Seega on haiglatel väga suur roll tervishoiusektoris.

Haiglaravis on üheks efektiivsuse mõõdikuks kasutatakse patsientide haiglas viibimise aega. 2024. aastal oli keskmine ravikestus Eestis 8,6 päeva. Keskmine ravikestus on voodipäevade arv ühe statsionaarselt või päevaravilt lahkunud või väljakirjutatud patsiendi kohta aastas haiglaravi põhjuse järgi. Haiglas viibimise aeg on oluline mõõdik haiglajuhtidele, kellel see aitab planeerida voodikohti ja prognoosida täituvust. Haigla tõhusaks toimimiseks on tähtis arvestada nii patsientide vajadustega kui ka olemasolevate ressursidega, seal hulgas töötajatega. Haiglas viibimise aja prognoosimisel on oluline prognoosi usaldusväärsus ja ka arusaam tagamaast, mis seda mõjutavad. (Stone *et al.*, 2022)

Töö empiirilises osas rakendatakse teoreetilisi raamistikke Eesti Tervisekassa avaandmetele, et selgitada välja peamised tegurid, mis mõjutavad patsientide haiglas viibimise aega Eesti haiglates.

Bakalaureusetöös püstitatakse järgmised ülesanded:

1. süstematiseerida tervishoiuökonomika teoreetilisi aluseid efektiivsuse mõistmiseks ja kirjeldada peamisi meetodeid tervishoiu efektiivsuse hindamisel;
2. tutvustada ja analüüsida varasemaid empiirilisi uuringuid haiglate efektiivsuse mõõtmise ja haiglas viibimise aja teemadel;
3. teostada empiiriline analüüs Tervisekassa 2024. ja 2025. aasta avaandmete põhjal ja selgitada välja oluliseimad haiglas viibimise kestust mõjutavad tegurid;
4. esitada analüüsi tulemused ja teha järeldused Eesti haiglate efektiivsuse tõstmise võimaluste kohta.

Tulenevalt töö ülesannetest, on töö üles ehitatud kahepeatükilisena. Esimene peatükk annab esmalt ülevaate teoreetilistest mõistetest ja seejärel varasematest empiirilistest töödest. Teine peatükk sisaldab empiirilist analüüsi ja järeldusi. Töös kasutatavate lühenditega on võimalik tutvuda lisa A.

1. Haiglate efektiivsuse mõõtmise võimalused

1.1. Efektiivsuse olemus ja selle mõõdikud tervishoius

Käesolev peatükk keskendub haiglate efektiivsuse mõõtmiseks mõeldud indikaatoritele ja nende kasutusalaadele. Eesti keele instituut defineerib efektiivsust kui millegi toimel või mõjul soovitud, heade või vajalike tulemuste andmine, töö (kulutuste) ja tulemuste suhe ning kvaliteeti kui omadused, mis näitavad millegi headust või halbust, kõrget või madalat väärtust, lähtudes millegi otstarbest (EKI, 2025). Tervishoius on kvaliteet üldiselt seotud patsiendi ja ravitööga. Kvaliteeti saab kirjeldada tervishoiuteenuste kättesaadavuse, efektiivsuse, ravitöö võrdsuse ja tõhususe kaudu. Haiglate ja ravitöö efektiivsus on aga sagedamini kirjeldatud rahaliste näitajate kaudu: haigla kulud ja tulud, rahalised toetajad ning tõhusa töö tegemine võimalikult väheste kuludega. (Navarro-Espigares ja Torres, 2011) Majanduskoostöö ja Arengu Organisatsioon liigitab efektiivsuse mõõtmise tervishoius kolmele tasandile: süsteemiülene tasand, allsektori tasand ja haiguspõhine tasand. Tabelis 1 on toodud ülevaade OECD tasandite liigitusest ja sealsetest efektiivsusmõõdikust.

Tabel 1: Efektiivsuse mõõtmise võimalused tervishoius

Tasand	Indikaatorid
Süsteemiülene efektiivsus	• Oodatav eluiga vs. tervishoiukulud • Ravitav/välditav suremus vs. tervishoiukulud • Oodatav eluiga vs. tervishoiutöötajad • Ravitav/välditav suremus vs. tervishoiutöötajad
Haiglaravi efektiivsus	• Haiglas viibimise kestus • Päevakirurgia osakaal • Tulemusnäitajad (nt ägedate haigusseisundite 30-päevane suremus) vs sisendandmed (kulud, tööjõud jne)
Esmatasandi arstiabi efektiivsus	• Vastuvõttude arv arsti kohta • Patsientide osakaal, kes külastasid erakorralise meditsiini osakonda, kuna perearst polnud saadaval • Välditavad hospitaliseerimised ambulatoorse ravi tundlike seisundite tõttu vs. sisendandmed (kulud, tööjõud jne)
Farmaatsiaspektori efektiivsus	• Geneetiliste ravimite osakaal kogu farmaatsiaturul • Ravimite hinnavõrdlused • Antibiootikumide tarbimine • Jälgimine (nt püsiv ravimite kasutamise määr hüpertensiooni ja diabeedi korral) • E-retsepti tarkvara kasutavate arstide osakaal

Allikas: OECD, 2024

Süsteemiülese lähenemisviisi peamiseks eeliseks on koodandmete kättesaadavus, näiteks tervishoiukulude ja inimressursside kohta. Olulisteks puudusteks on aga tervishoiutöö-

tajate kontrolli alt väljas olevad tegurid, mis mõjutavad inimeste tervist. Lisaks ei anna süsteemiülene analüüs poliitikakujundajatele sageli praktilist teavet konkreetsete ebaefektiivsete valdkondade kohta, vaid pigem üle-üldist informatsiooni. Selliste murekohtade lahenduseks on näiteks keskenduda ravitavatele surmadele, et saavutada sihipärasem lähenemisviis efektiivsuse hindamiseks.

Alamsektori lähenemisviisi eeliseks on võimalus minna rohkem süvitsi konkreetsete tegevuste analüüsis ning anda täpsemaid poliitilis soovitusi efektiivsuse parandamiseks. Suure osa tervishoiusüsteemist moodustavad haiglad ning nende andmed ressursside kohta on tihtipeale lihtsasti kättesaadavad. Peamiselt kasutatakse mõõdikutena näiteks haiglas viibimise kestust ja päevakirurgia (samal päeval tehtud operatsioonide) osakaalu ja keskendutakse nende suurendamisele või vähendamisele efektiivsema töö tagamiseks. Esmatasandi arstiabi efektiivsust analüüsitakse inimressursside põhjal, näiteks patsientide või vastuvõttude arv töötaja kohta. Eraldi analüüsitakse ka farmaatsiaspektori efektiivsust, seal hulgas ravimite hindu ja kvaliteeti ning jälgitakse ravimite tõhusust patsientide seas. (OECD, 2024)

Üksikmõõdikute kaudu ei pruugi aga alati saada eriti palju infot indikaatorite põhjuste ja tagamaade kohta. Seetõttu on efektiivsuse mõõtmiseks tervishoius arendatud välja ka statistilisi mudeleid. Järgnev alapeatükk keskendubki nendele meetoditele.

1.2. Efektiivsuse mõõtmine tervishoius statistiliste mudelitega

Efektiivsust mõõdetakse tervishoius lisaks lihtsatele mõõdikutele ka statistiliste mudelite abil, kus kasutatakse erinevaid sisend- ja väljundmuutujaid, et mudeldada näiteks haigla tehnilist efektiivsust. Seda saab teha nii parameetriliste kui ka mitteparameetriliste meetoditega. Kõige tavalisemad nendeks on DEA meetod (ingl *Data Envelope Analysis*) (mitteparameetriline) ja SFA meetod (ingl *Stochastic Frontier Analysis*) (parameetriline). Varem mõõdeti efektiivsust tihti ka lineaarse regressioonimudeliga, mida hinnati vähim-ruutude meetodil. See meetod tähendab jääkide kui efektiivsuse mõõdiku tõlgendamist. Kui haigla jääk on null, toodab ta keskmiselt efektiivselt võrreldes teiste haiglatega selles valimis. Negatiivne jääk tähendab madalamat efektiivsust ning positiivne jääk keskmisest kõrgemat efektiivsust. Selline mudel ei anna aga tegelikult teavet, kui kaugel haigla on tootmispiirist ehk maksimaalsest tootmiskogusest, mida on võimalik toota olemasolevate ressursside ja tehnoloogia juures. Lisaks on jääkide seas ka mudeli teised juhuslikud vead, näiteks mõõtmisvead, mis on väljaspool haigla kontrolli. (Feldstein, 1967) DEA ja SFA meetodite võrdlus on toodud tabelis 2 ning põhineb Lampe ja Hilgers (2015) metaanalüüsil.

Tabel 2: DEA ja SFA meetodite võrdlus

Võrdlusalus	DEA meetod	SFA meetod
Mudeli elemendid	Mitu väljund- ja sisendmuutajat	Üks sisendmuutuja ja mitu väljundmuutajat
Algoritm	Lineaarne programmeerimine	Regressioonanalüüs (nt suurima tõepära meetodil)
Juhusliku müra arvestamine	Müra on arvestatud efektiivsuskoores, seda ei eristata otseselt	Müraga on arvestatud
Funktsionaalne kuju	Ei ole üheselt määratletud	Määratletud (nt lineaarne, log-lineaarne)
Parameetiline vs mitteparameetiline	Mitteparameetiline	Parameetiline

Allikas: Lampe ja Hilgers, 2015

DEA meetod kasutab erinevaid sisend- ja väljundmuutujaid, et tekitada haigla tootmispiir. Analüüsi tulemuseks on suhteline efektiivsus. Haiglate efektiivsuse analüüsimisel tuvastab DEA meetod haiglate hulga, mis on tootnud vähemalt sama palju toodangut vähemate sisenditega kui uuritav haigla. Tulemus esitatakse vahemikus nullist üheni, kus 0 tähistab efektiivsuse puudumist ja 1 täielikku tehnilist efektiivsust. DEA meetodisse on aga keeruline kaasata patsientidega seotud tegureid, sest see läheb vastuollu majandusteooriaga, kus sisendid aitavad kaasa mingisuguse lõpptootte valmimisele. Patsiente aga sisenditena seetõttu kasutada ei saa, sest nemad ei ole osa mingisugusest lõpptootest. Haiglate efektiivsuse mõõtmisel on tavaks teha esmane analüüs DEA mudeliga ning arvutada efektiivsuskoorid. Saadud skoori ja nende koosmõjusid saab kasutada regressioonanalüüsis, kuhu saab kaasata ka patsientide sotsiaal-demograafilised näitajad. Et efektiivsuskoorid on tsentreeritud ülalt ja alt (ehk piiratud mingisuguse väärtusega, praegusel juhul 0 ja 1), kasutatakse tsentreeritud muutujatele sobivaid mudeleid, näiteks Tobit-mudelit. (Hollingsworth ja Peacock, 2008)

Kuna DEA mudel ei arvesta efektiivsuse muutumist ajas, on tihti kasutatud juurde ka Malmquisti indeksi. Indeksi saab jagada kaheks komponendiks: esimene komponent näitab suhtelise efektiivsuse muutust efektiivsuspiiri suhtes. Kuna ei saa eeldada, et ajaperioodidel püsib kõik konstantsena, siis Malmquisti indeksi esimene komponent vaatllebki, kuidas aja jooksul suhteline efektiivsus liigub. Kui efektiivsus läheneb piirile, siis tulemused paranevad, kui see liigub kaugemale, siis efektiivsus väheneb. Indeksi teine komponent kaasab võimalikud arengud tehnoloogias, näiteks on toimunud arenguid, siis läheb suhteline efektiivsus lähemale oma piirile. Kogu indeks on kahe komponendi korrutis ning seda tõlgendatakse nagu teisigi indekseid: kui indeksi väärtus on suurem kui 1, on efektiivsus ajas paranenud, kui indeks on võrdne ühega, pole muutust toimunud, ning väiksem kui 1 viitab efektiivsuse regresseerumisele. (Stefko, Gavurova, ja Korony, 2016)

SFA meetod ehk stohhastiline piiranalüüs võtab lineaarse regressioonimudeli vealiikme ja jagab selle kaheks osaks: esimene kirjeldab ebaefektiivsust ja teine juhuslikke vigu andmestikus. Meetodi eeliseks on võime modelleerida mitut väljundmuutujat, näiteks ka haig-

la kulusid. Siiski nõuab SFA meetod, et väljundeid oleks võimalik koondada ühte indeksisse. SFA meetodi peamiseks kriitikaks on kindla jaotuse puudumine: kasutatud on nii poolnormaaljaotust kui ka eksponentjaotust. Lisaks tuleb arvestada, et efektiivsus ei pruugi olla ajas konstantne. Analüüsi läbi viies tuleks DEA ja SFA efektiivsusskoore omavahel võrrelda, kasutades samu sisend- ja väljundmuutujaid. Võrdluse käigus tuleb hinnata tulemuste tundlikust kasutatava meetodi suhtes ning tagada efektiivsusskooride usaldusväärsus. Peale seda saab teostada meetodi valiku. (Varabyova ja Schreyögg, 2013)

Haiglate efektiivsuse mõõtmise puhul on oluline täheldada, kas mõõdetud on ainult tehnilist efektiivsust või kombinatsiooni tehnilisest ja alloktiivsest efektiivsusest. Alloktiivne efektiivsus uurib, kuidas ressursse jaotada selliselt, et ühiskondlik kasu oleks maksimaalne. Tehniline efektiivsus on aga maksimaalse tulemi saavutamine minimaalsete kuludega. Üldine efektiivsus mõõdab kahe koosmõju. (Kirigia *et al.*, 2002) Tervishoius kasutatakse tihti alloktiivset efektiivsust ehk kuluefektiivsust. Kui aga fookuseks on ainult üks kindel haigla, mille efektiivsust soovitakse parandada, on hea tava esmalt selgitada välja ebaefektiivsus. See nõuab tihti kas hinnakirja fikseerimist või mingisuguse vahemiku kasutamist, kuhu hinnakiri kuulub. Kui aga haiglale või haiglatele rakendada ühesugune hinnakiri, ei kajastu sageli tegelikud kulud, vaid on loodud fiktiivne maailm, kus hinnad on fikseeritud. See annab majandusliku poole pealt efektiivsuse kohta väga vähe infot. (O'Neill *et al.*, 2008)

Nii DEA kui ka SFA meetodite puhul on oluline sisendmuutujate valik. Enimkasutatud on tööjõukulud, haigla üldkulud ja investeeringud. Levinuim mõõdik on voodikohtade arv, mida 2008. aasta O'Neill *et al.* metaanalüüsi põhjal kasutati 55 uuringus 79-st. Vabade voodite ja kasutuses olevate voodite arvu suhe aitab haiglatel prognoosida kulusid, vajaminevat tööjõudu ja planeerida ravitööd. Teine kõige kasutatud indikaator on kliiniline personal, ehk arstid, õed ja hooldustöötajad. Kuna ligikaudu kaks kolmandikku haigla kuludest on seotud palgakuludega, näitab see samuti haigla rahalist valmidust ja ka seda, kas igale patsiendile on piisavalt abi osutavaid töötajaid. Väljundmuutujatena kasutatakse nii ambulatoorseid kui ka statsionaarseid vastuvõtte kui ka protseduuride arvu ja haiglas viibimise aega. Ambulatoorne vastuvõtt tähendab, et patsiendile ei ole vajalik haiglas viibimine ning vastuvõtt võib toimuda ja näiteks perearstikeskuses või veebis. Statsionaarne vastuvõtt tähendab, et ravi on läbimõeldud protsess ning eeldab, et patsient viibib raviasutuses vähemalt ühe öö või kauem. (Tervisekassa, 2024) Voodikohtade arv ja kliiniline personal aitavad sisendmuutujatena prognoosida vastuvõttude ja protseduuride arvu ja ka haiglas viibimise aega. Sobivate sisend- ja väljundmuutujate valik on keeruline ja ebaselge protsess, mis takistab ka efektiivsuse uurimise edasiarengut. Seetõttu on ka just DEA meetodiga tegelikult keeruline korrektselt prognoosida haigla juhtimisstrateegiaid ja ravitööd. (O'Neill *et al.*, 2008)

Worthington (2004) on kritiseerinud ka efektiivsuse mõõtmisel teatavate tegurite väljajätmist. Näiteks on 1994. aastal uuritud Hollandi hooldekodude efektiivsust, kuid asutuste rahalist võimekust ei ole sisse arvestatud ja on uuritud ainult tööjõudu. Autor põhjendas seda sellega, et tööjõud on hooldekodu kontrollida, kuid rahaline toetus on sageli riigipoolne ning

asutusel selle suuruse osas sõnaõigust pole. See aga võib viia ekslike järeldusteni ja arvutusvigadeni. Kapitali asemel kasutavad mitmed uuringud ka hoopis materjalide varu, sh voodikohtade ja ruutmeetrite arvu. Kapitali kaasamisel efektiivsuse analüüsimisse on oht, et see on kaasatud liiga suure kaaluga ning siis on lihtne teha valejäreldus, et kapitalitaseme vähendamine toob kaasa efektiivsuse kasvu. (Worthington, 2004)

Kuigi DEA ja SFA meetodeid on kritiseeritud, on need siiski väga levinud meetodid efektiivsuse analüüsimiseks tervishoius. Eesti haiglate efektiivsust on DEA ja SFA meetoditega varem uuritud kahes lõputöös, millest üks on Tallinna Tehnikaülikoolis tehtud bakalaureusetöö ja teine Tartu Ülikoolis tehtud magistritöö. Mõlemas töös on keskendutud ambulatoorsetele ja statsionaarsetele vastuvõttudele. Nagu eelnevalt mainitud, on efektiivsuse mõõtmisel oluline sisend- ja väljundmuutujate valik. Esnar (2005) on oma magistritöös kasutanud sisendinäitajana voodikohtade arvu ning ravitöötajate arvu, mis on ülemaailmselt kõige tavapärasemad indikaatorid efektiivsuse mõõtmisel. Väljundnäitajana on kasutatud ambulatoorsete vastuvõttude, operatsioonide, statsionaarsete ravipäevade ja ambulatoorsete ja statsionaarsete ravijuhtide arvu. Juurde on uuritud ka ravikindlustust ja haiglate liike. Töö keskendub haigla liikide efektiivsuse erinevusele. Haiglatüübid vastavad Eesti haiglavõrgu arengukavale (Sotsiaalministeerium, 2002). Töös tulevad välja olulised erinevused haigla liikide lõikes, kuid töö on 20 aastat vana ning tehtud krooni ajal, seega rahalised näitajad praegust olukorda Eestis ei peegelda. Uurimismeetodina on autor kasutanud nii DEA kui ka SFA meetodit. Esnar leidis mõlema meetodiga, et haiglate tehniline efektiivsus (ehk maksimaalse tulemi saavutamine minimaalsete kuludega) ei ole uurimisperioodi (2001–2003) jooksul oluliselt muutunud. Küll aga on efektiivsus kasvanud haigla liikide lõikes aastate 2002 ja 2003 vahel. (Esnar, 2005)

Suumann (2025) on oma bakalaureusetöös samuti lähtunud Eesti haiglavõrgu arengukavast. Uuritavateks aastateks on 2018–2023 ning on arvestatud ka COVID-19 kriisiga. Ka selles töös on kasutatud DEA meetodit, kus sarnaselt Esnari tööle on sisendnäitajateks valitud ravivoodite ja arstide-õdede arv ning väljundnäitajateks ambulatoorseid ja statsionaarseid vastuvõtte. Autor uurib tulemusi pikemalt kahe mudeliga: CCR mudel (Charnes, Cooper ja Rhodes), millega hinnatakse üldist tehnilist efektiivsust ning BCC mudel, mis hindab puhast tehnilist efektiivsust. CCR mudeliga täielikult tehniliselt efektiivseks loetakse neid haiglaid, mille efektiivsusskoor on 1. Suumann toob välja, et täielikult efektiivsed on vaatlusperioodil olnud ainult Tallinna Lastehaigla ja Ida-Tallinna Keskhaigla. BCC mudeliga leitud haiglate efektiivsus oli aga parem, täielikult efektiivsed olid üle kogu vaatlusperioodi neli haiglat: Tartu Ülikooli Kliinikum, Tallinna Lastehaigla, Ida-Tallinna Keskhaigla ja Rakvere haigla. Kuna kahe mudeliga tulid tulemused üsna erinevad, jagas autor CCR-ga leitud tulemused läbi BCC mudeli tulemustega ning leidis suhtelise efektiivsuse. Nii jäid täielikult tehniliselt efektiivseks läbi aja Tallinna Lastehaigla ja Ida-Tallinna Keskhaigla. (Suumann, 2025)

1.3. Haiglas viibimise aeg kui efektiivsuse mõõdik

Üheks levinuimaks efektiivsuse mõõtmise võimaluseks tervishoius on haiglas viibimise aeg. Selle mõõtmine ja analüüsimine aitab paremini ennustada voodikohtade arvu, planeerida töökoormust ja kontrollida kulusid. Haiglas viibimise aeg (edaspidi HLOS, ingl *hospital length of stay*) on tugevalt seotud ka suremuse ennustamisega, kus liiga pikk haiglas viibimine võib viia lisanakkusteni ja kahjustada patsiendi tervist. Erinevad meetodid haiglas viibimise aja mõõtmiseks on kokkuvõtvalt toodud tabelis 3.

Tabel 3: Meetodid haiglas viibimise aja mõõtmiseks ja analüüsimiseks

Meetod	Meetodi kasutamine	Allikas
Keskmine haiglas viibimise aeg	Mõõdetakse keskmist HLOS-i mingil perioodil ja selle põhjal ennustatakse voodikohtade arvu	Stone <i>et al.</i> , 2022
Kompartmentaalsed süsteemid	Fikseeritud süsteemis simuleeritakse patsiente ja nendega seotud tegevusi, lisaks simuleeritakse seisund, kus on kindlal ajahetkel saadaolevate voodite ja järjekorras olevate patsientide arv. Simulatsioonide kaudu uuritakse, mis muudatusi süsteemis teha saaks	Stone <i>et al.</i> , 2022
Markovi mudelid	Eeldatakse, et sündmused (hospitaliseerimised) toimuvad võrdsete ajavahemike tagant ning nende põhjal ennustatakse patsiendi käitumist ja modelleeritakse patsientide voogu. Aitab märgata kitsaskohti, näiteks pikki järjekordi	Standfield <i>et al.</i> , 2014
Faasitüüpi jaotusega Makrovi mudelid	Lõpliku ajaga Markovi ahelad, kus neeldumine tähendab ravi lõppemist, lühike neeldumisaeg viitab kiirele ravile	Castillo, 2012
Statistilised mudelid	Sõltuvaks tunnuseks on haiglas viibimise aeg ja vaadeldakse, kuidas see on mõjutatud patsiendiga seotud ja välistest teguritest	Garg <i>et al.</i> , 2011

Allikas: autori koostatud

Kõige tavapärasem viis HLOSi mõõtmiseks on mõõta keskmist haiglas viibimise aeg. Seda on lihtne arvutada ja analüüsida ka inimestel, kelle puuduvad sügavamad teadmised statistilisest analüüsist. Keskmine HLOS arvutatakse jagades statsionaarsete voodipäevade summa läbi sama diagnoosiga seotud patsientide arvuga vaadeldaval perioodil. Keskmine haiglas viibimise aeg ei peegelda aga sageli täpselt kogu valimit ning tulemused võivad olla moonutatud. (Stone *et al.*, 2022) Costa *et al.* leidsid 2003 aastal, et voodikohtade arvu ennustamiseks ei sobi kõige paremini keskmise haiglas viibimise aja kasutamine. Kui artikli autorid arvutasid keskmise haiglas viibimise aja põhjal 95% usaldusintervalli voodikohtade arvule käsitsi ja mudeliga, osutasid tulemused väga erinevateks. Käsitsi arvutatud usaldusintervalliga saadud tulemused olid ligikaudu 2 korda kõrgemad kui mudeliga arvutatud vajaminevate voodikohtade arv. Keskmise haiglas viibimise aja kasutamine teeb analüüsimise küll lihtsaks, kuid selline arvutusviis ei suuda tabada näiteks näiteks kriitiliste haigusjuhtude arvu ja seda, kui

palju tööjõudu sellistele patsientidele kulub kui voodikohad täis saavad. Seetõttu kasutatakse voodikohtade planeerimisel pigem simulatsioonimudeleid, mis vastavad tegelikule haiglas viibimise kestuse jaotusele. (Costa *et al.*, 2003)

Simulatsioonimudelite kasutamiseks on haiglas viibimise aega mõõdetud ka kompartmentaalsete süsteemidega (ingl *compartmental systems*), mis on defineeritud kui süsteemid, mis koosnevad lõplikust arvust homogeensetest, hästi segunenud alamsüsteemidest (Godfrey, 1983). Kuigi mudelid võivad olla nii lineaarsed, deterministlikud, mittelineaarsed kui ka stohastilised, kombineeritakse neid praktikas tihti järjekorrateooriaga (ingl *queueing theory*), sest mudelid ise ei arvesta vastuvõtu ja väljakirjutamise tsüklilisi mõjusid ja andmete hooajalisust. Järjekorrasüsteemis kasutavad simulatsioonid ka ajalisi mõõdikuid, nagu süsteemis ja järjekorras veedetud aeg. Kompartmentaalses süsteemis simuleeritakse ka üksikelemente (patsiente) ja nendega seotud tegevusi, mis võivad mõjutada süsteemi üldseisundit (näiteks vabade voodikohtade arv). Üldseisundiks nimetatakse kogu süsteemi kirjeldust mingil kindlal ajahetkel. Sellised simulatsioonid võimaldavad testida süsteemis muutuste tegemist ja uurida süsteemi paindlikkust. (Stone *et al.*, 2022)

Järjekorrasüsteemide alla kuuluvad ka Markovi ahelad ja Markovi mudelid. Markovi ja pool-Markovi mudelid eeldavad patsientide alamrühmade homogeensust (ühtlast jaotumist) ja sündmuste toimumist võrdsete ajavahemike tagant. Kuna mudelid on seotud patsientide tõenäosusliku käitumisega süsteemis, saab nendega kujutada väga realistlikke olukordi tervishoiusüsteemis. Markovi mudelid on usaldusväärsed patsientide voo mõõtmisel ja modelleerimisel, sest need kajastavad patsiendi teekonda mingis tervishoiusüsteemis ja annavad ekspertidele ja haiglate juhtidele võimaluse näha ette süsteemis peituvaid ohte ja kitsaskohti. Küll aga ei suuda Markovi mudelid arvestada seotust patsientide ja ressursside vahel, näiteks olukordi, kus piiratud ressursid tähendavad, et ühe patsiendi ravi mõjutab otseselt ka kellegi teise ravi. (Standfield *et al.*, 2014)

Markovi mudelite parandamiseks on kasutusele võetud ka faasitüüpi jaotused, mille eesmärk on kirjeldada lõpliku neeldumisega pidevas ajas Markovi ahelaid. Idee seisneb selles, et eksisteerib ainult üks neeldumisseisund ja protsess on mööduv. HLOSi jaoks tähendab see, et neeldumine tähendab ravi lõppemist. Seega pikem neeldumisaeg võib viidata raskemale haigusele, mille ravimisega läks kauem aega. Lühem neeldumisaeg viitab kiirele ravile ja kergemale haigusjuhule. (Castillo, 2012)

Üks levinumaid meetodeid haiglas viibimise aja põhjuste analüüsimiseks on lihtsad statistilised meetodid nagu lineaarne regressioon ja log-lineaarne regressioon. Tunnusteks võetakse patsientide omadused ja nendega seotud välised tegurid, mis võivad mõjutada nende haiglas viibimise aega ning aidata seda ennustada. Kõige tavapärasemad tunnused, mida mudelites kasutatakse, on patsiendi diagnoos, protseduurid, sugu ja vanus (Garg *et al.*, 2011). Uuringutes on leitud, et näiteks vanus ja haigla tüüp on tugevalt seotud HLOSi suurte väärtustega, kuid samas patsiendi majanduslik kindlustatus seda nii tugevalt ei mõjuta. Aastal 2018 tehti uuring ühes Ühendkuningriigi psühhiaatriaiglas, kus kasutati mitmest regressiooni

ja mitmest imputeerimist (puuduvate andmete asendamine), et uurida haiglas viibimise aega. Tulemuseks saadi, et pikema HLOS-i suurimad mõjutegurid olid sugu, etniline päritolu, psühhooosi esimene diagnoos ja haiglas viibinud hooldustöötajate arv. (Newman *et al.*, 2018) Regressioonimudelid on väga levinud haiglas viibimise aja analüüsimiseks, sest nendega saab otseselt uurida erinevate tegurite mõju. Küll aga nõuavad regressioonimudelid tihtipeale täpsemaid statistilisi teadmiseid ja analüüsioskust. (Stone *et al.*, 2022)

Haiglas viibimise kestus ei ole lihtsalt kalendripäevade arv, vaid oluline indikaator, mis peegeldab nii ravi kvaliteeti kui ka raviasutuse ressursside kasutamise efektiivsust. HLOS ei ole ka monotoonselt tõlgendatav, sest see, kas pikem haiglas viibimise aeg on patsiendile hea või halb, oleneb paljugi sellest, kuidas seda on mõõdetud ning millise valimiga on tegu. Järgnev peatükk annab ülevaate varasematest uuringutest haiglas viibimise aja kohta.

1.4. Varasemad uuringud haiglas viibimise ajast

Mitmed haiglas viibimise kestusega seotud uuringud on teostatud haiglasiseselt ning analüüsitud sealsete patsientide haiglas viibimise aega. Enamasti on uuringud teostatud kindla haigus- või vigastusrühma põhjal, et valimis olevad patsiendid oleksid sattunud haiglasse samadel põhjustel, ja et tulemusi oleks lihtsam analüüsida. Sageli on kitsendatud näiteks ka vanusegruppe, sest lapsed ja täiskasvanud ei ole meditsiiniliselt võrreldavad ning lapsi peaks vaatlema eraldi, kusjuures lapsi ei saa lihtsalt uurida kui „mitte-täiskasvanuid“, vaid eraldada tuleks ka lapsed, noorukid ja imikud (European Medicines Agency, 2022).

Rootsis uuriti 2006–2012. aastal haiglas viibimise aega puusaluummurruga patsientide seas. Kaasatud patsiendid olid vanuses 50 või vanemad ning uuringu peamine eesmärk oli tuvastada, kas haiglas viibimise aeg on seotud patsientide surmaga 30 päeva pärast haiglast välja kirjutamist, seejuures haiglas surnud patsiendid jäeti uuringust välja. Analüüsiks koostati neli erinevat logistilist regressioonimudelit, millest esimene mudel kaasas ainult patsiendi vanuse ja soo, teine mudel lisas juurde abielustaatuse ja haridustaseme, kolmas mudel lisas luumurrutüübi ja operatsioonitüübi ning neljas mudel lisas juurde kaasuvad haigused, mis esinesid kuni väljakirjutamiseni ning kas binaarse tunnuseks, kas patsiendile tehti vereülekanne. Mudelite uuritavaks tunnuseks oli patsiendi surm 30 päeva jooksul pärast haiglast välja kirjutamist (binaarne tunnus) ning kõigi nelja mudeliga oli tulemuseks surma esinemine. Töö autorid said tulemuseks, et patsientidel, kelle haiglas viibimise kestus oli 1–5 päeva, oli surmarisk 30 päeva jooksul pärast väljakirjutamist 2 korda suurem võrreldes patsientidega, kelle HLOS oli 15 päeva või rohkem. Tööst ilmnes ka, et patsientidel, kes olid haiglas 10 päeva või vähem, seostus iga ühe päeva võrra lühemalt haiglas viibimine 8% suurema suremusriskiga. Autorid rõhustasid tulemusele, et lühem haiglas viibimise aeg pärast puusaluummurdu on seotud kõrgema surmariskiga 30 päeva jooksul pärast haiglast välja kirjutamist. Seitsme vaatlusaasta jooksul tugevnes see seos iga aastaga ja samal ajal lühenes ka keskmine haiglas viibimise aeg kokku umbes 20%. (Nordström *et al.*, 2015)

Aastatel 2019–2023 viidi Saksamaal läbi ristlõikeline uuring, kus kasutati 30 haig-

la andmeid üle 18-aastastest depressiooni diagnoosiga patsientidest ja uuriti nende haiglas viibimise aega. Tulemusi analüüsiti lineaarse regressioonimudeliga ning sisenditeks kasutati vanust, sugu, depressioonitast (mõõdukas või raske) ning kaasuvaid haiguseid. Analüüsist selgus, et pikem haiglas viibimise aeg on seotud kaasuvate haigustega, millest kolm kõige sagedasemat olid hüpertensioon, kilpnäärme häired ja D-vitamiini puudus. Lisaks pikenes haiglas viibimise aeg patsientide seas depressiooni raskusastme ja vanuse kasvades. Töö autorid soovitasid neid tegureid hooldusstrateegiatesse rohkem kaasata, et optimeerida haiglaravi kestust ja parandada patsientide tervislikku seisundit. (Kaur *et al.*, 2024)

Ecuadoris uuriti epilepsiahaigate hospitaliseerimist ja suremust aastatel 2015–2023. Perioodi jooksul vaadeldi kokku üle 40 tuhande patsiendi, kes olid sattunud haiglasse kas epilepsiahoo või epilepsiadiagnoosi tõttu. Analüüsiti, kas pikenenud haiglas viibimise aeg ja suremus on seotud patsientide soo, vanuse, rahvuse (ingl *ethnicity*), elukoha (maal või linnas), epilepsiatüübi ja ravisutusetüübiga (avalik või eraasutus). Pikenenud haiglas viibimise ajaks loeti ≥ 6 päeva. Kuna pidevad väärtused ei olnud normaaljaotusega, kasutati analüüsimisel mitteparameetrilisi teste, näiteks Mann-Whitney U-testi. Logistilise mudeliga analüüsiti šansse haiglas suremisele (0 ja 1 tunnus, kus 1 vastas suremisele) ja šansse pikemale hospitaliseerimisele (kas patsient oli kauem kui 6 päeva haiglas). Tulemusteks saadi, et meeste ja naiste vahel ei olnud statistiliselt olulist erinevust, kuid erinevused tekkisid vanuserühmades. 70-aastastel ja vanematel patsientidel olid 61% kõrgemad šansid olla pikemalt haiglaravil võrreldes teiste vanusegruppidega, neil olid ka kõige kõrgemad šansid haiglaravil surra. Erinevate aastate vahel statistiliselt olulist erinevust ei esinenud, küll aga olid patsiendid COVID-19 perioodidel (aastatel 2020–2022) haiglaravil lühemalt ülemaailmsete piirangute tõttu. Töö autorid rõhutasid, et kuna epilepsia väljendub inimestel erinevalt ja valimis olid erineva raskusastmega patsiendid, ei saa tulemuste pealt teha otseseid järeldusi epilepsiapatsientide haiglas viibimise aja kohta ning tulemusi ei tohiks üldistada kõigi epilepsiapatsientide kohta. (Lapo-Talledo *et al.*, 2026)

Nagu eelpool mainitud, on haiglas viibimise aega peamiselt uuritud kindlate diagnoosirühmade seas. 2026. aasta aprillis publitseeritud artiklis on autorid uurinud toitumisalaste sõeluuringute seost haiglas viibimise ajaga vanemaealiste patsientide seas. Uuringusse kaasati 565 patsiendi andmed, kes olid olnud ühes Brasiilia ülikoolihaiglas. Patsiendid olid kõik vanemad või vähemalt 65-aastased ning olid haiglaravil olnud üle 24 tunni. HLOS-i analüüsimisse kaasati patsientide sugu, vanus, operatsiooni toimumine (binaarne tunnus, kas toimus või mitte), kas patsient suri ning neoplaasia (kudede ebanormaalne kasv) olemasolu. Mõju haiglas viibimise ajale analüüsiti Poissoni mudeliga, mida kohandati vastavalt haiguse klassifikatsioonile (kasvajatega ja ilma). Tulemustest ilmnes, et peamised haiglas viibimise aega mõjutavad tegurid olid toitumisriski klassifikatsioonid (alatoitunud, hästi toitunud, toitainete rikas dieet). Haiglas viibimise kestus oli rühmades üldjoontes sarnane, kuid patsientidel, kellel ei olnud kasvajaid, olid haiglas pikemalt muude haiguste tõttu, näiteks luumurrud, traumas jms. Kõik kolm toitumisriski klassifikatsiooni osutusid olulisteks näitajateks, mille abil saab

prognoosida selliste patsientide haiglas viibimise kestust. Autorid leidsid, et uuringu tugevuseks oli valimi suurus ja ka juhuvaliku alus (ehk kaasati ainult eakad patsiendid). Lisaks olid kõik uuritavad patsiendid kaasatud kõiki kolme toitumisalasessse söeluuringusse, mille riske analüüsiti (alatoitunud, hästi toitunud, toitainete rikas dieet). Küll aga viidi uuring läbi konkreetses haiglas ning seetõttu ei ole võimalik tulemusi üldistada suuremale populatsioonile. (Leandro-Merhi *et al.*, 2026)

Kuna haiglas viibimise kestuse näol on tegemist loendusandmetega (loetakse päevi), kasutatakse selle analüüsimiseks sageli loendusandmete mudeleid. 2025. aastal publitseeriti uuring, kus oli teostatud juhuvalim Monterali ülikooli andmetele ja analüüsitud psühhiaatriapatsientide haiglas viibimise aega ja insuliini, IL-6 ja TNF- α mõju sellele. IL-6 ja TNF- α on peamised põletikke soodustavad tsütogeenid. Kaasatud patsientide andmed pärinesid 2012. aasta novembrist 2020. aasta märtsini. Uuringusse kutsuti need patsiendid, kes olid terve mõistuse juures ja olid võimelised andma nõusolekut enda andmete kasutamiseks. Patsientidelt võeti bioloogilised proovid neljal ajahetkel: psühhiaatrilise erakorralise meditsiini osakonda või haiglasse värbamisel, haiglast väljakirjutamisel, ambulatoorse järelkontrolli ajal ja 12-kuuse järelkontrolli ajal. Sõltuv muutuja ehk haiglas viibimise aeg oli mõõdetud psühhiaatriaosakondades veedetud ööde arvuna. Gelberg-Anderseni käitumismudeli põhjal kaasati sõltumatute muutujatena eeldsoodumus-, vajadus- ja soodustavad tegurid. Vajadustegurid viitavad diagnoosidele ja terviseseisunditele (näiteks narkootiliste ainete kasutamine, unehäired), eeldsoodumustegurid on seotud sotsiaal-demograafiliste omadustega (näiteks vanus ja sugu) ning soodustavad tegurid on seotud ressursside ja oskustega, mis hõlbustavad või takistavad patsiendi juurdepääsu tervishoiuteenustele (näiteks sissetulek, eluase) (Gelberg *et al.*, 2000). Artikli autorid kasutasid eeldsoodumusteguritena patsientide vanuserühma, sünnil määratud sugu, etnilist kuuluvust (nt valgenahalised vs. muu), kodakondsust, haridustaset, tööalast staatust ja enesetapukatsete esinemist perekonnas. Vajadusteguritena kasutati haiglasse vastuvõtmise ajal esmaseid ja teisejärgulisi diagnoose, mis klassifitseeriti vastavalt WHO rahvusvahelisele haiguste klassifikatsioonile (ehk RHK-10). Soodustavate tegurite hulka valiti aastane sissetulek, perekonnaseis (abielus, lesk jms), elutingimused (nt üks elaine) ja elukeskkond viimase kuu jooksul (nt korter või eramaja). Kaasati ka binaarsete tunnustena religiooni olulisust (0 – pole oluline, 1 – oluline) ja haiglaeelset staatust ehk kas enne haiglasse tulekut käis patsient näiteks uuringutel või perearsti juures. Sõltuv muutuja (HLOS) oli käsitletud loendusmuutujana vahemikus 2 kuni 557 päeva ning seda analüüsiti negatiivse binoommudeliga. Tehti ka alammudelid, mis olid liigitatud diagnostiliste kategooriate kaupa (nt psühhootilised häired, meeleoluhäired). Tulemustest ilmnes, et 60-aastastel ja vanematel patsientidel olid 38% kõrgemad šansid olla haiglaravil pikemalt võrreldes 17–29-aastastega. Kõige kauem olid ravil psühhootiliste häiretega patsiendid ning isikud, kellel diagnoositi vastuvõtul isiksusehäire, olid 1,75 korda suurema tõenäosusega haiglaravil pikemalt kui need, kellel seda ei diagnoositud. Patsiendid, kelle TNF- α või insuliini tase olid kriitilisel piiril, olid suurema tõenäosusega haiglas lühemalt kui need, kelle näitajad olid normalsel tasemel. Selgus

ka, et patsientidel, kes olid viimase kahe aasta jooksul haiglaravil olnud, oli suurem tõenäosus pikemaks haiglas viibimise ajaks. Täheldati ka seoseid unehäiretega, kus unepuuduse all kannatavad patsiendid olid suurema tõenäosusega haiglas pikemalt. Autorid soovivad psühhiaatriapatsientide haiglas viibimise lühendamiseks alternatiivini intensiivsed koduhooldust ja kriisimeeskonna valmisolekut, kes saaksid aidata neid patsiente, kellel esinevad tavapäraseid vaimse tervise sümptomid (näiteks ärevus) või enesetapumõtted. Lisaks soovivad autorid uurida põhjalikumalt biomarkerite mõju haiglas viibimise ajale, kuid nende poolt tuvastatud tulemusi tuleks tõlgendada teatava ettevaatusega. (Armoon *et al.*, 2025)

Üheks kõige uuemaks haiglas viibimise aja võimalikuks analüüsimeetodiks on masinõpe. Rootsis teostati 2015–2019. aastatel uuring raskete vigastustega täiskasvanud traumapatsientide seas, kus kasutati masinõppe meetodit ja võrreldi tulemusi üldistatud lineaarse mudeli ja otsustuspuu (ingl *random forrest*) tulemustega. Uuringu eesmärgiks oli teada saada, kas masinõpet oleks võimalik kasutada haiglas viibimise kestuse ja intensiivraviosakonna vajaduste hindamiseks. Selline mudel aitaks planeerida voodikohti ja ka triaazi. Kokku kaasati pilootuuringusse 6706 patsiendi andmed aastatest 2015–2018 ning valideerimisandmestikku kaasati kõigi 2019. aasta traumapatsientide andmed, keda oli kokku 2350. Ajaraam valiti selliselt, et COVID-19 pandeemia tulemusi ei mõjutaks. Kaasatud patsiendid olid kõik vanemad kui 18. Kirjeldavate tunnustena kaasati uuringusse esimene teostatud erakorraline protseduur, haiglasse saabumiseks kasutatud transpordivahend, intubatsiooni toimumine (jah/ei), patsiendi vanus, osakond, kus patsient ravil oli ja vigastuste raskusaste. Uuringu tulemuseks oli, et vigastuste raskusastme ja HLOS-i vahel ei olnud lineaarset seost, kõrgem vigastuse raskusaste oli patsientidel, kes viibisid haiglas kauem kui 10 päeva, kuid 1–2 ja 3–9-päevaste viibimiste korral oli NISS-i (ingl *New Injury Severity Score* ehk vigastuse raskusaste) mediaanväärtus gruppide vahel sarnane. Tulemus viitab sellele, et pikaajaline haiglas viibimine on seotud raskemate vigastustega, kuid lühemalt haiglas viibinud patsientide seas on nii kergemete kui ka raskete vigastustega patsiente. Seega ei ole vigastuse raskusastme mõju HLOS-ile monotoonne. Selgus ka, et lühema HLOS-iga patsientidel oli kõrgem suremus, kuigi pikemalt haiglas viibinud patsiendid olid üldiselt raskemate vigastustega. Autorid järeldasid tulemustest, et kõige täpsema ennustusvõimega oli XGB (ingl *Extreme Gradient Boost*) ehk masinõppe mudel, sest HLOS-i ja intensiivravipatsientide vajadusi mõjutavad tegurid olid mittelineaarses seoses. Otsustuspuu osutus üldistatud lineaarsest mudelist (ingl *Generalized Linear Model* ehk GLM) paremaks, kuid jäi siiski all XGB mudelile. Autorid rõhutavad, et tõusva tehisintellekti ja masinõppe arenguga tuleb meditsiinivaldkonnal sammu pidada ja õppida tehnoloogiat enda jaoks ära kasutama, sest sellised tööriistad, nagu käesolevas uuringus kasutatud mudel, võivad olla väga suureks abiks dünaamiliste protsesside ja ettearvamatute olukordade planeerimisel. (Mosfeldt *et al.*, 2026)

Haiglas viibimise aega on ülemaailmselt uuritud palju ning selleks on kasutatud mitmeid erinevaid lähenemisi, kõige levinumaks meetodiks on statistilised mudelid. Järgnevalt rakendab töö autor tutvustatud meetodeid Tervisekassa avaandmetel.

2. Eesti haiglates voodiravil viibimise aja hindamine

2.1. Ülevaade Eesti haiglatest

Eesti riigi tervisesüsteem on suuresti üles ehitatud ravikindlustuse seadusele, mis on üks viiest õigusaktist, millele süsteem tugineb. Peaaegu kogu tervishoiuteenuste rahastamine toimub Tervisekassa kaudu. (Habicht *et al.*, 2018) Tervise Arengu Instituudi andmete põhjal on Eestis 2024. aasta seisuga kokku 48 haiglat, millest vaid 21 kuuluvad haiglavõrgu arengukava liigitusse. Haiglate jaotus on toodud tabelis 4.

Tabel 4: Eesti haiglate arvuline jaotus

Haigla liik	Haiglate arv
Piirkondlik haigla	3
Keskhaigla	4
Üldhaigla	11
Taastusravi haigla	1
Õendushaigla	18
Erihaigla	9
Kohalik haigla	2

Allikas: Tervise Arengu Instituut, 2026

Eestis on 2003. aastal jõustunud haiglavõrgu arengukava järgi kokku 21 haiglat. Haiglavõrgu arengukava jaotab haiglad viite erinevasse liiki: piirkondlikud haiglad, keskhaiglad, üldhaiglad, kohalikud haiglad ja taastusravihaiglad. Haiglate jaotus on toodud tabelis 5. Hetkel kehtiv haiglavõrgu arengukava loodi 2003. aastal ning viimased parandused on sisse viidud 2023. aastal. (Haiglavõrgu arengukava, 2023)

Liigid on määratud haigla teeninduspiirkonna põhjal. Piirkondlikud haiglad peavad suutma teenindada 0,5 kuni 1 miljon inimest. Keskhaiglate teeninduspiirkond on 100 000 kuni 200 000 inimest. Üldhaiglate teeninduspiirkonnaks on 50 000 kuni 100 000 inimest, mis on piisav suurus, et kindlustada ka ööpäevaringset erakorralist abi. Kohalikud haiglad teenindavad kuni 40 000 inimest ning on vajalikud keskustesse, kus kõrgema etapi haigla on kaugemal kui 70 kilomeetrit. Eestis nimetatakse üldhaiglaid ja kohalikke haiglaid ka maakonnahaiglateks. Geograafiliselt paiknevad haiglavõrgu haiglad selliselt, et igas maakonnas oleks vähemalt üks haiglavõrgu haiglatest, suurema populatsiooniga maakondades (näiteks Harjumaal) ka mitu. (Sotsiaalministeerium, 2002)

Tabel 5: Eesti haiglad haiglavõrgu arengukava järgi

Haigla liik	Liigitusse kuuluvad haiglad
Piirkondlik haigla	SA Tartu Ülikooli Kliinikum, SA Põhja-Eesti Regionaalhaigla, SA Tallinna Lastehaigla
Keskhaigla	AS Ida-Tallinna Keskhaigla, AS Lääne-Tallinna Keskhaigla, SA Ida-Viru keskhaigla, SA Pärnu Haigla
Üldhaigla	AS Järvamaa Haigla, Kuressaare Haigla SA, SA Läänemaa Haigla, AS Rakvere Haigla, AS Lõuna-Eesti Haigla, SA Narva Haigla, SA Viljandi Haigla, AS Valga Haigla, SA Hiiumaa Haigla, AS Põlva Haigla, SA Raplamaa Haigla
Kohalik haigla	SA Jõgeva Haigla
Taastusravi haigla	SA Haapsalu Neuroloogiline Rehabilitatsioonikeskus

Allikas: Haiglavõrgu arengukava, 2023

Haiglate liikide nõuete seaduses on paragrahvis 2 toodud tervishoiuteenused, mida osutavad üldhaiglad. Nende alla kuuluvad kohustuslike teenustena erakorraline meditsiin, sisehaiguste ravi, üldkirurgia, anestesioloogia, laborimeditiin ja radioloogia. Ühe või mitme teenuse puudumisel ei saa haiglat üldhaiglaks nimetada. Soovituslikud ambulatoorsed ja statsionaarsed teenused üldhaiglates on pediaatria, sünnitusabi ja günekoloogia ja patoloogia. Üldhaiglates on alates 2008. aastast kohustus ööpäevaringselt töötada kahel arstil, kellest vähemalt üks on erakorralise meditsiini arst või vastava täiendusõppe läbinud. Lisaks on vajalik, et palatiosakondades oleksid olemas üldõed, anesteesia-intensiivravi õed ja ämmaemand. Vajalik on ka vähemalt kahe erakorralise meditsiini õe või üldõe olemasolu erakorralise meditsiini osakonnas. (Haigla liikide nõuded, 2023, § 2)

Keskhaiglates on kohustuslik osutada kuuteteist statsionaarset ja ambulatoorset teenust. Nende alla kuuluvad erakorraline meditsiin, sisehaiguste ravi, kardioloogia, neuroloogia, üldkirurgia, uroloogia, ortopeedia, sünnitusabi ja günekoloogia, anestesioloogia, taastusravi, infektsioonhaigused, psühhiaatria, pediaatria, laborimeditiin, radioloogia ja patoloogia. Eri-nevalt üldhaiglatest on keskhaiglates soovituslikud teenused kohustuslikud, sest nende teeninduspiirkond on samuti suurem. Keskhaiglas peavad ööpäevaringselt töötama erakorralise meditsiini arst või selle täiendusõppe läbinud arst, sisemeditiini eriala arst, pediaater, kirurgilise eriala arst, ortopeed, günekoloog, anestesioloog, psühhiaater, infektsioonhaiguste arst. Infektsioonhaiguste arst peab keskhaiglas töötama ööpäevaringselt, kui haigla teeninduspiirkonnas ei ole ka piirkondlikku haiglat, kus ööpäevaringsel valvel oleks olemas infektsioonhaiguste arst. Lisaks arstidele peavad töötama ööpäevaringselt ka õed palatiosakondades, ämmaemand, vähemalt kolm erakorralise meditsiini õde ning üks õde kuni kuue haige kohta akuutpsühhiaatria osakonnas. (Haigla liikide nõuded, 2023, § 13)

2.2. Haiglate analüüsimisel kasutatavad andmed

Töös kasutatavad andmed pärinevad Tervisekassa avalike andmete kogust, kus on raviarved, mis on Tervisekassa poolt kinni makstud. Aasta, kvartal ja kuu põhinevad maksmise

kuupäeval, mitte teenuse osutamise kuupäeval ning seetõttu arvel olevat kuud andmete analüüsimisse ei kaasatud. (Tervisekassa, 2026) Sõltuva tunnuseks kasutati haiglaravi kestuse summat ehk summarset voodipäevade arvu. Andmed võeti 2024. ja 2025. aasta kohta, et tuvastada, kas erinevatel aastatel on mõju voodipäeva pikkusele sarnane. Et vältida erialadest tingitud kõrvalekaldeid andmetes, koostas töö autor eraldi mudelid kardioloogia eriala, pulmonoloogia eriala ja nefroloogia eriala patsientide jaoks. Erialad valiti selliselt, et need oleksid ka omavahel võrreldavad. Kardioloogia, pulmonoloogia ja nefroloogia on omavahel tihedalt seotud ning on tuntud ka kui kardiopulmonaal-neerude interaktsioonidena (ingl *Cardio-Pulmonary-Renal Interactions* ehk CPRI). Tihti surevad ühe organi kahjustusega patsiendid (nt krooniline neeruhaigus) teisest organist (nt südamepuudulikkus) tingitud tüsistustesse enne, kui algne probleem jõuab saavutada oma haripunkti. Igal haigel organil on võime halvendada ka teise organi tööd. (Husain-Syed *et al.*, 2015) Lisaks oli valitud erialade andmemah autori hinnangul piisav ning raviasutuste seas oli ka varieeruvust. Siiski olid kõigi erialade puhul kaasatud raviasutustena kaks Eesti piirkondlikku haiglat (Põhja-Eesti Regionaalhaigla ja Tartu Ülikooli Kliinikum), mis võimaldas analüüsida, kas nende haiglate mõju on kõigi erialade lõikes sarnane.

Ravi tüübina kasutati ainult statsionaarset ravi ning teenuste grupist valiti ainult voodipäevad. Raviasutuste alla sattusid kardioloogia jaoks loodud filtritega kaks piirkondlikku haiglat ja neli keskhaiglat: Põhja-Eesti Regionaalhaigla, Tartu Ülikooli Kliinikum, Ida-Tallinna Keskhaigla, Lääne-Tallinna Keskhaigla, Pärnu Haigla ja Ida-Viru keskhaigla. Pulmonoloogia eriala jaoks olid raviasutustena andmestikus Ida-Tallinna Keskhaigla, Põhja-Eesti Regionaalhaigla, Ida-Viru Keskhaigla, Tartu Ülikooli Kliinikum ja Viljandi Haigla, nefroloogia patsientide kohta leidsid andmeid Lääne-Tallinna Keskhaigla, Põhja-Eesti Regionaalhaigla ja Tartu Ülikooli Kliinikumi kohta. Selgitavate tunnustena kaasati veel patsiendi maakond, sugu, teenus, diagnoos ja vanusegrupp, mis oli 5-aastaste intervallide kaupa. Vanuserühmadest filtreeriti välja alla 20-aastased isikud ning seega olid vanusegrupid 20–24 ja kuni vanuseni 85+. Lõpliku andmestiku tunnuste kirjeldus on nähtav tabelis 6. Mudelite väljundites kasutatud teenuste koodide tähendused on toodud lisas B.

Tabel 6: Töös kasutatava andmestiku kirjeldus

Tunnus	Tunnuse tüüp	Väärtused
eriala	nominaaltunnus	kardioloogia, plumonoloogia, nefroloogia
ravi tüüp	nominaaltunnus	statsionaarne
teenus	nominaaltunnus	2047 – järelravi ...
teenuse grupp	nominaaltunnus	voodipäevad
diagnoos	nominaaltunnus	diagnoosA01 ...
raviasutus	nominaaltunnus	Ida-Tallinna Keskhaigla AS, Lääne-Tallinna Keskhaigla AS, Pärnu Haigla SA, Põhja-Eesti Regionaalhaigla SA, SA Ida-Viru Keskhaigla, TÜ Kliinikum SA, Viljandi Haigla SA
patsiendi maakond	nominaaltunnus	kõik 15 Eesti maakonda
sugu	faktortunnus	mees, naine
vanuserühm	järjestustunnus	20–24, 25–29, ... 85+
aasta	faktortunnus	2024, 2025
isikute arv	diskreetne arvtunnus	0 kuni 13
haiglaravi kestus summa	diskreetne arvtunnus	0 kuni 331 päeva
maakonna keskuse kaugus raviasutusest	pidev tunnus	0 kuni 316,7 kilomeetrit

Allikas: Eesti Tervisekassa, autori koostatud

Teenuse alla kuulub 11 erinevat raviliiki, mida patsientidele osutati ning mis tulenevad Tervisekassa poolt määratud raviteenuste liigitusest. Kasutatavas andmestikus esinevad teenustena järelravi, sisehaigused, kirurgia, I, II ja III intensiivravi, indsuldiravi voodipäev, covid-19 statsionaarse ravi voodipäev ja covid-19 II ja III astme intensiivravi voodipäev.

Patsiendi maakonna kaudu arvutati välja ka haigla kaugus maakonna keskusest. Selleks kasutatas autor rakendustarkvara R-is pakette *tidygeocoder* ja *geosphere*, mis lisasid maakonna keskused ja raviasutused Eesti kaardile ning arvutasid nende vahelise kauguse kilomeetrites. Need patsiendid, kelle maakond oli teadmata, eemaldati andmestikust. Tunnusele anti nimi `kaugus_km` ning seda kasutati logaritmitud skaalal. Kuna kasutatava mudeli oodatav väärtus on juba ise logaritmitud, on seosekordaja tõlgendatav kui suhteline mõju, ehk iga lisakilomeeter ei avalda täpselt samasugust mõju. Logaritmitud skaalat kasutatakse, et vähendada andmete suurt varieeruvust ja lähendada seda normaaljaotusele (Feng *et al.*, 2014).

Isikud, kes olid arvuliselt märgitud kujul < 5 , arvutati manuaalselt välja, jagades voodipäevade summa keskmise voodipäevade summaga selles grupis, et saada täpne isikute arv. Keskmise voodipäevade summa on arvutatud kui voodipäevade summa perioodil jagatud isikute arvuga sellel perioodil (Tervise Arengu Instituut, 2025). Tuginedes Stone'i (2022) öeldule, et keskmine haiglas viibimise aeg ei peegelda sageli täpselt kogu valimit, otsustas töö autor kasutada uuritava tunnusena haiglas viibimise päevade summat, mitte keskmist HLOS-i.

Jooniste loetavuse parandamiseks lisati andmestikku ka iga raviasutuse lühend, mis on

leitavad lisast A. Algandmed laeti alla *Exceli* failina ning nende töötlemisel kasutati rakendus-tarkvara R. Kõik järevalt toodud tulemused ja joonised on samuti loodud tarkvara R abil.

2.3. Uurimismetoodika

Algandmestikus oli kokku 44 483 rida, millest 22 238 olid 2024. aasta andmed ning 22 245 olid 2025. aasta andmed. Töö autor alustas andmestiku kirjeldava statistikaga, uurides tunnuste jaotust ja võimalikke anomaaliaid andmetes. Patsientide sooline jaotus oli 24 774 meest ja 19 709 naist, mille autor hindas sobivaks. Sõltuva tunnuse (haiglaravi_kestus_summa) jaotus on nähtav tabelis 7. Arvutatud on ka kvartiilide väärtused, mis on tulpades $q_{0,25}$ ja $q_{0,75}$ ehk ülemise neljandiku ja alumise neljandiku piir. Täpselt 25% andmetest on nendest väärtus-test väiksemad ja suuremad.

Tabel 7: Voodipäevade arvu jaotus aastate ja erialade lõikes

Eriala	Aasta	Miinumum	$q_{0,25}$	Mediaan	Keskmine	$q_{0,75}$	Maksimum
Kokku	2024	1,00	4,00	8,00	11,61	14,00	331,00
Kokku	2025	1,00	4,00	8,00	11,73	14,00	213,00
Kardioloogia	2024	1,00	3,00	6,00	9,36	12,00	132,00
Kardioloogia	2025	1,00	3,00	7,00	9,61	12,00	150,00
Pulmonoloogia	2024	1,00	6,00	11,00	17,75	20,00	331,00
Pulmonoloogia	2025	1,00	6,00	11,00	16,43	19,00	213,00
Nefroloogia	2024	1,00	6,00	12,00	14,40	18,00	90,00
Nefroloogia	2025	1,00	6,00	12,00	15,77	21,00	98,00

Allikas: Eesti Tervisekassa, autori koostatud

Madalaim väärtus oli toorandmetes mõlemal aastal 1 päev ning kõrgeim väärtus kogu andmestikus esines 2024. aastal, 331 päeva ehk peaaegu 11 kuud. Keskmine summaarne voodipäevade arv oli mõlemal aastal veidi all 12 päeva ja mediaan 8 päeva. Kardioloogia eriala patsientide seas oli kõrgeim voodipäevade arv 150 päeva, keskmine oli mõlemal aastal ligikaudu 9 päeva. Mediaan oli 2025. aastal üks päev pikem võrreldes eelneva aastaga, kuid jäi alla kogu andmestiku mediaanile. Kardioloogia patsientide mõlema aasta maksimaalne voodipäevade summa oli väiksem kogu andmestiku maksimaalsetest väärtustest. Pulmonoloogia eriala patsientide seas olid nii mediaan kui ka keskmine voodipäevade summa kõrgemad andmestiku üldtulemustest. Toorandmete maksimaalne voodipäevade summa, 331 päeva esines pulmonoloogia patsientide seas 2024. aastal. 2025. aastal oli maksimaalne väärtus 118 päeva lühem, kusjuures mediaan oli aastate lõikes sama ja keskmiste erinevus oli veidi üle 1 päeva. Nefroloogia patsientidel oli kõige kõrgem voodipäevade arvu mediaan, kuigi keskmine voodipäevade arv jäi pulmonoloogia patsientide omast madalamale. Maksimaalne voodipäevade summa nefroloogia patsientide seas jäi ainsana alla 100 päeva mõlemal aastal.

Autor analüüsis sõltuvat muutuja seost selgitavate tunnustega kõigepealt lineaarse regressiooniga, kuid mudeli eedlused ei olnud täidetud. Jääkide hajuvus ei vastanud normaaljaotusele ei histogrami ega ka Shapiro-Wilki testi põhjal, mis andis p -väärtuseks nullilähedase tulemuse. Nullhüpotees oli, et jäägid on normaaljaotusega ning see kummutati. (Käärrik,

2013) Kuna sõltuv tunnus ehk haiglaravi kestuse summa on loenduv tunnus, kasutas autor järgmiseks Poissoni mudelit, kuid selgus, et andmetes esines tugev ülehajuvus, mis tähendab, et dispersioon on suurem valimikeskmisest. Kui ülehajuvuse test annab tulemuseks suurema väärtuse kui 5, on põhjust arvata, et kasutama peaks mingit teist mudelit (Käärrik, 2013). Ülehajuvust testitakse ka dispersioonitestiga, kus nullhüpoteesiks on, et ülehajuvus eksisteerib. Dispersioonitest on arvutatud kujul

$$\text{Var}(y_i|x) = (1 + \alpha)E(y_i|x) = (1 + \alpha)\lambda_i, \quad (1)$$

kus $(1 + \alpha)$ on skalaarparameeter, mis ülehajuvuse puudumisel võrdub ühega ja tagab, et dispersioon on võrdne keskvaartusega. Autor testis algselt loodud Poissoni mudeli ülehajuvust ning skalaarparameetri väärtus tuli suurem kui 5, mis viitab sellele, et mõistlik on kasutada mingit muud mudelit. Tulemus on nähtav joonisel 1.

Overdispersion test

```
data: glmmudel
z = 24.88, p-value < 0.00000000000000022
alternative hypothesis: true dispersion is greater than 1
sample estimates:
dispersion
5.397055
```

Joonis 1: Dispersioonitest Poissoni mudelile, autori koostatud.

Poissoni ja NB mudeleid võrreldakse ka tõepärasuhte testiga (ingl *likelihood ratio test* ehk LR test), mille üldkuju on

$$LR = -2 \ln \left(\frac{L(\tilde{\theta})}{L(\hat{\theta})} \right), \quad (2)$$

kus $L(\tilde{\theta})$ on algse mudeli maksimaalne tõepärahinnang ja $L(\hat{\theta})$ on alternatiivse mudeli maksimaalne tõepärahinnang (Vörk, 2012). Kui testi tulemuseks on p -väärtus, mis on alla olulisuse nivoo $\alpha = 0,05$, peaks otsustama alternatiivse mudeli kasuks. Kui p -väärtus tuleb suur, jääme nullhüpoteesi juurde ehk sobib ka esialgne mudel. Joonisel 2 on näha Poissoni mudeli ja negatiivse binoommudeli jaoks teostatud LR-test, mille p -väärtus tuli madal. Mudel 1 (Model 1) on Poissoni mudel ja mudel 2 (Model 2) on negatiivne binoommudel. Testi tulemus kinnitas, et negatiivne binoommudel sobib andmete analüüsimiseks paremini.

Likelihood ratio test

```
Model 1: haiglaravi_kestus_summa ~ ravidasutus_lyhend + teenus + diagnoos +
  log(kaugus_km) + vanuseruhm + sugu + factor(aasta) + offset(log(isikute_arv2))
Model 2: haiglaravi_kestus_summa ~ ravidasutus_lyhend + teenus + diagnoos +
  log(kaugus_km) + vanuseruhm + sugu + factor(aasta) + offset(log(isikute_arv2))
#Df  LogLik Df Chisq          Pr(>Chisq)
1 344 -118254
2 345 -89692  1 57123 < 0.00000000000000022 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

Joonis 2: LR test Poissoni ja Negatiivse binoommudeli võrdlemiseks, autori koostatud.

Negatiivne binoommudel (lühendatult NB mudel) on loendusandmete mudel, mis on üldistatud lineaarsete mudelite alamliik. Tavaliselt kasutatakse loendusandmete jaoks Poissoni mudeleid, kuid kui andmetes tekib probleem ülehajuvusega, on lahenduseks negatiivne binoomjaotus või kvaasi-Poissoni mudel. Kvaasi-Poissoni mudel eeldab, et dispersioon ja keskväärus on lineaarses seoses, negatiivne binoommudel aga eeldab, et dispersioon kasvab kiiremini kui keskväärus, mis üldiselt sobib suure dispersiooniga andmetele paremini. Lisaks ei ole kvaasi-Poissoni mudelile võimalik arvutada akaike informatsioonikriteeriumit (AIC), millega saaks mudeleid omavahel võrrelda. (Ver Hoef ja Boveng, 2007) Seega otsustas autor jätkata negatiivse binoommudeliga.

Negatiivse binoomjaotusega regressioonmudeli tõenäosusfunktsiooni üldkuju on

$$f(y_i|x_i, u_i) = \frac{e^{-\lambda_i u_i} (\lambda_i u_i)^{y_i}}{y_i!}, \lambda_i > 0 \quad (3)$$

kus y_i on sõltumatu tunnus, mille esinemise tõenäosus avaldub selgitavate muutujate x_i ja inimese iseloomuliku liikme u_i korra. Keskmise y -st tingimusel u avaldub Poissoni tingliku keskvääruse ja dispersiooni kaudu. Kuna meid huvitab $f(y_i|x_i)$ üle kõikide u_i väärtuste, siis

$$P(y_i|x_i) = f(y_i|x_i) = \int_0^\infty \frac{e^{-\lambda_i u_i} (\lambda_i u_i)^{y_i}}{y_i!} g(u_i) du_i, \quad (4)$$

kus eeldame, et $g(u_i)$ on Gamma jaotusega. (Hilbe, 2007) Oodatav väärtus avaldub kujul

$$E(y_i|x_i) = \lambda_i = e^{\beta x_i} \quad (5)$$

ning dispersioon avaldub

$$Var(y_i|x_i) = \lambda_i + k \lambda_i^p, \quad (6)$$

kus k on hinnatav parameeter, mis iseloomustab ülehajuvust ja p on väärtus, mis määrab mudeli tüübi kas I tüüpi või II tüüpi NB mudeliks. NB mudeli tulemusi tõlgendatakse kui riskide suhet, võttes mudeli parameetritest eksponent. Kui selgitav muutuja x_k suureneb ühe ühiku võrra, siis eksponent hinnatud kordajast näitab oodatavate sündmuste arvu suhtelist muutust.

(Vörk, 2012)

$$E(y_i|x_{1i}, \dots, x_{ki} + 1) = e^{\beta_0 + \beta_1 x_{1i} + \dots + \beta_k (x_{ik} + 1)} \quad (7)$$

Negatiivse binoomimudeli eeldusteks on jääkide homogeenne hajuvus ja üledispersioon (Bolker *et al.*, 2009).


Jääkide homogeensust ehk ühtlast hajuvust vaadatakse histogrammilt ja punktdiagrammilt. Antud töös loodud mudelite jääkide homogeensuse graafikud on leitavad lisast G.

Kui mudeli y -tunnuseks on mingisugune summa või agregeeritud väärtus, on mudelis mõistlik kasutada ka *offset*'i ehk nihet. Nihkemuutuja esindab vaatlusüksuse suurust, aega või populatsiooni suurust. Nihkemuutuja koefitsendi väärtuseks saab 1, et see mõjutaks igat vaatlust samamoodi. Nihke kasutamisel eeldatakse, et mõõteühiku (näiteks isikute arvu) kahekordistamine viib ka loendusandmete kahekordistamiseni. (Parry, 2022) Sellised tunnused lisatakse mudelisse logaritmitult ning mudelis käituvad nad konstandina. Antud töös kasutati mudelites nihkemuutujana isikute arvu.

2.4. Empiirilise analüüsi tulemused


2.4.1. Kirjeldav analüüs

Autor alustas enne mudelite loomist kirjeldavast statistikast, kus esmalt vaadeldi haiglapäevade tunnuse jaotust. Maksimaalne voodipäevade summa kogu andmestikus oli 331 päeva ning minimaalne 0 päeva. Jaotus on näha joonisel 3. Joonise loetavuse prandamiseks on x -telg logaritmitud. Kõige rohkem vaatluseid langeb umbes 7 ja 15 päeva vahele, kusjuures keskmine summaarne voodipäevade arv oli 11,7 päeva ja mediaan 8 päeva. Palju vaatluseid on ka 1, 2 ja 3 päeva ümbruses, pikemate perioodide juures on vaatluseid vähem.




Joonis 3: Voodipäevade pikkuse jaotus. Allikas: Eesti Tervisekassa, autori koostatud.

Üheks oluliseks tunnuseks oli patsiendi maakonnakeskuse kaugus haiglast, kus ta ravil oli. Seost ravipikkuse ja kauguse vahel vaadati punktdiagrammilt, kuhu joonistati peale lineaarne sirge, mida on näha joonisel 4. Loetavuse parandamiseks on y-telg logaritmitud. Osutub, et ravipikkus ja kaugus patsiendi kodumaakonnast on omavahel negatiivses seoses: mida suurem on kaugus, seda lühem on voodipäevade arv. See võib viidata sellele, et kaugemalt tulevad patsiendid tulevad suurhaiglatesse harvem ja on seal lühemalt. Näiteks saarte elanikud tegelevad mandril oma tervisemuredega ilmselt harvem ning veedavad haiglas seetõttu aega lühemalt. Kusjuures kõige pikem distantis patsiendi maakonna ja raviastuse vahel on patsientidel, kes sõitsid Saaremaalt Ida-Viru Keskhaiglasse, vahemaa on ligikaudu 316 kilomeetrit. Kõrgemas otsas on veel kaugus Hiiumaalt Ida-Viru Keskhaiglasse (272 kilomeetrit) ning Saaremaalt Tartu Ülikooli Kliinikumi (259 kilomeetrit).



Joonis 4: Seos maakonna keskuse kaugusest haiglast ja voodipäevade pikkuse vahel. Allikas: Eesti Tervisekassa, autori koostatud.

Järgmiseks vaatles autor patsientide soolist jaotust erialade vahel, mis on kujutatud joonisel 5, kus y-teljel on keskmine voodipäevade summa. Kõige pikem keskmine voodipäev on pulmonoloogias, natuke alla 20 päeva. See viitab sealsetele raskematele haigusjuhtudele ja vajadusele patsiente pikemalt hospitaliseerida võrreldes teiste erialadega. See on ka ainus eriala, kus meeste keskmine voodipäevade pikkus on pikem kui naistel, ligikaudu nädal aega pikem. Kõige lühemad voodipäevad on keskmiselt kardioloogias, kus päevade keskmine haiglas viibimise aeg jääb umbes 9 ja 10 päeva vahele, kusjuures naised on haiglas pikemalt kui mehed. Kardioloogia eriala patsientide kohta on andmestikus ka kõige rohkem andmeid, mistõttu on andmetes suurem hajuvus ja keskmine madalam, kuigi maksimaalne voodipäevade summa võib olla kõrgem. Nefroloogia patsientide seas on sooline erinevus kõige väiksem, kuid naiste keskmine voodipäevade summa on siiski pikem kui meestel.



Joonis 5: Voodipäeva pikkuse jaotus soo järgi erialade lõikes. Allikas: Eesti Tervisekassa, autori koostatud.

Autor uuris ka, kas sooline erinevus esineb ka aastate lõikes. Tabelist 8 nähtub, et aastate lõikes on naiste keskmine voodipäevade summa lühem, kui meeste oma, kusjuures naiste voodipäevade summa varieeruvus on samuti väiksem, kui meeste oma. Kuna andmestik on rohkem andmeid meeste kohta, võib see olla mõjutegur meeste tulemuste suuremas varieeruvuses ning soo kohta ühest järeldust teha ei saa. Voodipäevade summat mõjutavad nii eriala, sugu kui ka aasta ja ka nende tunnuste kombinatsioonid. Kõige kõrgem voodipäevade summa esines mõlemal aastal samuti meeste seas, 2024. aastal 331 päeva ning 2025. aastal 213 päeva. Mediaan püsib soo ja aastate lõikes 8 päeva juures.


Tabel 8: Sooline voodipäevade summa jaotus aastate lõikes

Aasta	Sugu	Miinimum	Mediaan	Keskmine	Standardhälve	Maksimum
2024	mees	1,00	8,00	11,90	16,10	331,00
2024	naine	1,00	8,00	11,20	11,50	214,00
2025	mees	1,00	8,00	11,90	14,60	213,00
2025	naine	1,00	8,00	11,50	12,30	183,00

Allikas: Tervisekassa, autori koostatud


Patsientide vanuseline jaotus on nähtav jooniselt 6. Keskmine voodipäevade summa on üsna monotoonselt kasvav koos vanusega, vanuserühmades 55–59 ja 60–64 on väike langus ning siis tõuseb voodipäevade pikkus uuesti kõrgemale. Kõige kõrgem keskmine voodipäev on vanimas vanuserühmas ehk 85+ aastaste seas, ligikaudu 2 nädalat.

Vanuseline jaotus erialade lõikes on üsna sarnane üle-üldisele jaotusele, kõige sarnasemad on tulemused nooremates vanuserühmades. Kõige kõrgem tulp joonistub välja 50–54-aastaste pulmonoloogia patsientide seas, kus keskmine haiglas viibimise aeg on ligikaudu 25 päeva. Kõige madalam keskmine voodipäevade pikkus on 20–24-aastaste kardioloogia patsientide seas, kus tulemus jääb umbes 3 päeva kanti.



Joonis 6: Patsientide vanuseline jaotus toorandmetes ja erialade lõikes. Allikas: Eesti Tervisekassa, autori koostatud

Voodipäevade kestus raviastutuste lõikes on kujutatud joonisel 7 karpdiagrammina, kus y-telg on logaritmitud tulemustest parema ülevaate saamiseks.



Joonis 7: Voodipäeva pikkuse jaotus raviastutuste lõikes. Allikas: Eesti Tervisekassa, autori koostatud.

Kõige suurem varieeruvus on Tartu Ülikooli Kliinikumis, kus voodipäevade pikkus varieerub ühest päevast 331 päevani. 50% vaatlustest langeb peaaegu kõigis haiglates umbes 4 ja 17 päeva vahele, kuid Ida-Tallinna Keskhaiglas on 0,25 ja 0,75 kvartiilideks 2 ja 10. Suurimaks erindiks on Viljandi Haigla, kus voodipäevade pikkus varieerub kahest päevast 177ni,

kuid 50% vaatlustest langeb 59 ja 60 päeva vahele. Viljandi Haigla tulemused on ka ainult pulmonoloogia eriala kohta, mis võib seega viidata rasketele kopsuhaigustele ning nefroloogia ja kardioloogia probleemidega sõidavad Viljandi elanikud kaugematesse haiglatesse. Mediaan ja keskmine on raviasutuste lõikes sarnased, ainult Põhja-Eesti Regionaalhaiglas on parempoolne asümmeetria, kus tõenäoliselt üksikud pikaajalised patsiendid tõstavad keskmist kõrgemale mediaanist. Kuigi kõige kõrgem voodipäevade summa on TÜK-is, on seal ka varieeruvus suurem ning seetõttu jääb keskmine mediaanist allapoole.

2.4.2. Analüüsi tulemused kardioloogias

Autor uuris esmalt voodipäevade pikkuse mõjutegureid kardioloogia erialas ravitud patsientide seas. Selgitavate tunnustena kasutati raviasutust, logaritmitud skaalal maakonna keskuse kaugust haiglast, patsiendi diagnoose, voodipäeva teenust, vanusrühma, sugu, aastat ning *offset*-ina isikute arvu. Tabelis 9 on näha kõigi lisatud muutujate *p*-väärtused, lahtris „Df“ on vabadusastmed ehk tasemete arv miinus üks. Lisaks on toodud Hii-ruut teststatistiku väärtus.

Tabel 9: Kardioloogia eriala mudel


Tunnus	χ^2	Df	p-väärtus
raviasutus	1199,4	5	< 0,0000
teenus	4102,3	10	< 0,0000
diagnoos	7987,1	312	< 0,0000
log(kaugus_km)	317,6	1	< 0,0000
vanuseruhm	1360,1	13	< 0,0000
sugu	22,0	1	< 0,0000
factor(aasta)	9,6	1	0,0019

Allikas: Eesti Tervisekassa, autori koostatud

Tabelist 9 nähtub, et kõik lisatud tunnused ise osutusid statistiliselt oluliseks olulisuse nivool $\alpha = 0,05$, mida kasutatakse ka edaspidi. Raviasutusi on mudelis kokku 6, teenuseid 11, diagnoose 313, vanuserühmi 14 ja sugusid 2 (mees ja naine). Aastaid on samuti 2 ehk 2024 ja 2025. Mudeli väljund nende tunnuste tasemetega, mis osutusid statistiliselt oluliseks, on nähtaval lisas C.

Rakendustarkvara R võtab referentstunnueks tähestikuliselt või arvuliselt esimese tunnuse. Vabaliikmest avaldub oodatav voodipäevade arv referentsgrupis, siin mudelis 20–24-aastane mees Ida-Tallinna Keskhaiglas 2024. aastal järelravil keskmiselt 5,69 päeva ehk peaaegu 6 päeva.

Statistiliselt oluliste mõjutajate suhtelise riski koefitsendid (e^{β}) koos 95% usaldusintervallidega on toodud joonisel 8, loetavuse lihtsustamise jaoks on diagnooside tulemused toodud paremal ning vanuserühmadest on võetud suhtelise riski kordaja põhjal 10 kõige suuremat mõjutajat. Kui joonisel olevad punktid jäävad alla 1 (märgitud ka punase punktiirjoonega), on vastava näitaja mõju haiglas viibimise aega vähendav tegur.



Joonis 8: Suhtelise riski koefitsendid koos usalduspiiridega kardioloogia eriala patsientide seas. Allikas: Eesti Tervisekassa, autori koostatud

Diagnoosi puhul oli baastasemeks A02 ehk muud salmonellanakkused ehk salmonelloosid. Võrreldes diagnoosiga A02 tõstavad 4 diagnoosi haiglas viibimise aega statistiliselt olulisel määral. Kõige rohkem teeb seda diagnoos B99 (nakkushaigus), mis pikendab haiglas viibimise aega 8,42 korda. Kõige väiksem mõju on diagnoosil I33 (endokardiit), mis pikendab haiglas viibimise aega 5,32 korda eeldusel, et teised tunnused hoitakse fikseeritud. Diagnoosid K56 (halvatussoolesulgus) ja I97 (vereringeelundite klassifitseerimata haigusseisundid) tõstavad voodipäevade summat võrreldes baastasemega vastavalt 6,79 ja 8,21 korda. 2016. aastal leiti USA-s läbiviidud uuringu käigus, et salmonelloosi patsiendid, kellel on ka muud kaasuvad haigused, näiteks südamehaigused, on haiglas keskmiselt pikemalt kui need patsiendid, kes on haiglasse sattunud ainult salmonelloosi tõttu (Cummings *et al.*, 2016).

Aastaga 2024 võrreldes on 2025. aastal kardioloogia patsiendid haiglas voodipäevadel olnud umbes 2,5% pikemalt, mis võib olla tingitud rohkematest andmetest 2025. aasta kohta. Lisaks on näha tabelist 7, et 2025. aastal oli kõrgeim voodipäevade summa kardioloogias 150 päeva, 2024. aastal aga 132 päeva.

Patsiendi maakonna kaugus raviasutusest mõjutas voodipäevade pikkust negatiivselt: mida kaugemal on patsiendi elukoht raviasutusest, seda vähem voodipäevi ta raviasutuses veetma peab. Kui kaugus suureneb 1% võrra, väheneb voodipäevade kogusumma keskmiselt 0,053%. Tulemus viitab sellele, et kaugemalt tulevad inimesed satuvad haiglasse harvemini või lühemaks ajaks. Seda tulemust kinnitab ka joonis 3.

Võrreldes Ida-Tallinna Keskhaiglaga, on kõigis teistes raviasutustes voodipäeva pikkus pikem, kõige rohkem Pärnu haiglas, kus voodipäevade arv isiku kohta on ligikaudu 83% ehk 4,7 päeva pikem kui ITK-l eeldusel, et kõik teised tegurid on konstantsed. Tulemus päevades on arvutatud kujul

$$y_i = e^{\beta_0} \cdot e^{\beta_{PH}} = e^{1,739} \cdot e^{0,603} \approx 10,4, \quad (8)$$

kus β_0 ja β_{PH} on vabaliikme ja Pärnu Haigla β -koefitsendid. Muutuja y_i on keskmine oodatav voodipäevade arv sellistel tingimustel. Et leida erinevust päevades, on saadud päevade arvust

arvutatud maha keskmine oodatav voodipäevade arv referentstasemel ehk vabaliikme korra. Sama arvutuskäiku kasutatakse ka edaspidi.

Kõige väiksem mõju oli Ida-Viru Keskhaiglal, kuid ka see mõju oli positiivne, voodipäevade arv on umbes 21,3% pikem võrreldes ITK-ga, mis teeb ligikaudu 6,9 päeva ehk umbes 1 päeva kauem kui keskmisel ITK patsiendil (vt valemit (8)). Lääne-Tallinna Keskhaigla, Tartu Ülikooli Kliinikum ja Põhja-Eesti Regionaalhaiglas viibivad patsiendid 31–37% kauem kui Ida-Tallinna Keskhaiglas. Tulemust toetab ka joonis 7, kust on näha, et Ida-Tallinna Keskhaiglas oli maksimaalne voodipäevade summa ainult 58 päeva, kusjuures 50% vaatlustest langes 2 ja 10 päeva vahele.

Kui võrrelda tulemusi soo tasandil, on naised haiglaravil 4% lühemalt kui mehed, mis võib viidata sellele, et naised on terviseteadlikumad kui mehed ja saavad oma muredele kiiremini jaole, kuid see vajaks lähemat uurimist, kus võetakse arvesse ka eelnev raviteekond. See tulemus on küll vastuolus joonisega 4, kus kardioloogias on naiste keskmine haiglaravi pikkus pikem kui meestel. Küll aga nähtub tabelist 8, et aastate lõikes on naiste keskmine haiglas viibimise aeg lühem kui meestel ning järelikut kajastub aasta mõju ka mudelis.

Teenuste puhul on referentstunnuseks järelravi. Võrreldes järelraviga on kõigi intensiivravi ja sisehaiguste teenuste puhul voodipäevade summa madalam, kusjuures sisehaiguste (kood 2065) puhul kuni 57,8% (ca 3,3 päeva) madalam. COVID-19 koodid ei osutunud statistiliselt oluliseks, seega ei saa väita, et COVID-19 patsientide voodipäevade arv erineks oluliselt järelravi patsientide omast.

Vanuserühmades on võrreldes baastasemega, milleks on vanus 20–24, statistiliselt oluline erinevus üheteistkümnes vanuserühmas, kusjuures kordajad kasvasid üsna järjekindlalt koos vanusega. Kõige suurem mõju oli rühmadel 80–84 ja 85+. Nendes vanuserühmades olevad patsiendid veetsid haiglas aega võrreldes baastasemega ligikaudu 2 korda kauem. Kõige vähem erinesid baastasemest vanusegrupis 45–49 olevad patsiendid, kes viibisid voodiravil umbes 24,6% kauem.

Kirjeldatud mudeli determinatsioonikordaja tuli 0,593 ehk selle mudeliga sai kirjeldatud ligikaudu 59% kardioloogia patsientide voodipäeva pikkuse mõjuteguritest. Determinatsioonikordaja on arvutatud paketiga *performance*, mis arvutab R^2 väärtuse üldistatud lineaarsetele mudelitele, mida on ka negatiivne binoomimudel. Dispersioonitest andis p -väärtuseks 0,832, mis kinnitab, et negatiivne binoomimudel on sobiv nende andmete analüüsiks. Dispersioonitest tehti paketi *DHARMA* abil, kus kõigepealt simuleeriti mudeli jäägid ja loodud simulatsioonidel tehti dispersioonitest, mis kontrollib ülehajuvuse olemasolu ja lisab joonisele simuleeritud jääkide histogrammi ja punase joonena mudeli tegeliku dispersiooni. Kui p -väärtus annab tulemuseks suurema väärtuse kui kui 0,05, on mudeli sobivus andmetega hea.

2.4.3. Analüüsi tulemused pulmonoloogias

Pulmonoloogia erialas ravitud patsientide andmestik tuli 9073 rida, millest 4392 rida olid 2024. aasta andmed ning 4681 olid 2025. aasta andmed. Raviasutustena olid andmestikus

Ida-Tallinna Keskhaigla, Põhja-Eesti Regionaalhaigla, Ida-Viru Keskhaigla, Tartu Ülikooli Kliinikum ja Viljandi Haigla. Taaskord kasutati mudelis nihkeliikmena isikute arvu ning mudelisse kaasati ka vanuse ja soo koosmõju, mis osutus statistiliselt oluliseks. Küll aga ei olnud pulmonoloogia erialal oluline aasta mõju, mis viitab sellele, et voodipäeva pikkus ja seda mõjutavad tegurid olid eri aastatel sarnased. Samuti mõjutasid võrreldes kardioloogiaga voodipäeva pikkust pulmonoloogias palju rohkemad diagnoosid. Tabelis 10 on toodud muutujate p -väärtused, Hii-ruut teststatistikud ja vabadusastmed. Tabelis on mudeli lõppkuju ehk aasta on sealt juba eemaldatud.


Tabel 10: Pulmonoloogia eriala mudel

Tunnus	χ^2	Df	p-väärtus
raviasutus	215,9	4	< 0,0000
teenus	1191,0	11	< 0,0000
diagnoos	4931,4	241	< 0,0000
log(kaugus_km)	14,3	1	0,0002
vanuseruhm	198,2	13	< 0,0000
sugu	25,1	1	< 0,0000
vanuseruhm:sugu	68,6	13	< 0,0000

Allikas: Eesti Tervisekassa, autori koostatud

Tabelist 10 on näha, et raviasutus, teenus, patsiendi diagnoos, vanuserühm ja sugu olid kõik statistiliselt olulised. Samuti olid olulised patsiendi maakonnakeskuse kaugus raviasutusest ning soo ja vanuserühma koosmõju. Raviasutusi on kaasatud 5, vanuserühmasid 14 ja sugu 2 taset. Teenuseid on kaasatud üks rohkem kui kardioloogia eriala mudelis ning diagnoose on kaasatud vähem, kokku 242. Statistiliselt olulised muutujate tasemed (kokku 72) on ära toodud lisas D.

Statistiliselt oluliste mõjutajate suhtelise riski koefitsendid (e^{β}) koos 95% usaldusintervallidega on toodud joonisel 9, loetavuse lihtsustamise jaoks on diagnooside tulemused toodud eraldi ja valitud on 10 kõige tugevamat mõjutajat vastavalt koefitsendi suurusele. Vanuse ja soo koosmõjudest on samuti toodud 10 kõige tugevamat mõjutajat.



Joonis 9: Suhtelise riski koefitsendid koos usalduspiiridega pulmonoloogia eriala patsientide seas. Allikas: Eesti Tervisekassa, autori koostatud

Mudeli tulemustest selgub, et keskmiselt on 20–24-aastane mees Ida-Tallinna Keskhaiglas pulmonoloogias järelravil umbes 14,2 päeva, mis on peaaegu 2,5 korda suurem kui keskmine raviaeg kardioloogias. Seda eeldusel, et kõik teised muutujad on fikseeritud.

Statistiliselt olulised mõjutajad olid pulmonoloogia erialas 47 diagnoosi, neist 12 olid nakkus- ja parasiithaigused. Rahvusvahelisel haiguste klassifikatseerimisel põhinev diagnooside liigitamine on leitav lisast H.

Pulmonoloogia patsientide seas esines ka näiteks reieluumurru ja koljusisese vigastuse diagnoose, mis võivad tähendada, et patsient saabus haiglasse mitme vigastusega (näiteks õnnetuse tõttu) ja oli järelravil pulmonoloogias. Kõige tugevamateks mõjutajateks olid diagnoosid A19 (miliaarttuberkuloos), A18 (muude elundite tuberkuloos) ja B20 (HIV-tõbi), mis pikendasid haiglas viibimise aega vastavalt 14,2, 10,5 ja 8,5 kordselt. Kõik need diagnoosid klassifitseeritakse nakkus- ja parasiithaigusteks. Tuberkuloosid on otsesed kopsuhaigused ning HIV-tõbi on immuunsüsteemi nõrgendav haigus, seega nende diagnooside mõju haiglas viibimise pikkusele on ootuspärane. Tuberkuloosid on kopsuhaigete patsientide kõige tugevamad haiglas viibimise aja mõjutegurid, 2020. aasta uuringus leiti, et selliste patsientide keskmine haiglas viibimise aeg võib ulatuda umbes 62 päevani. (Tamirat, Andargie ja Babel, 2020)

Ka J-kategooria ja K-kategooria diagnoosid olid tugevad mõjutavad, mõlemast kategooriast esines 6 diagnoosi. J-kategooria diagnooside alla lähevad hingamiseldundite haigused ja K-kategooria alla kuuluvad seedeelundite haigused. Pulmonoloogia patsientide seas oli J-kategooria diagnoosidest tugevaimaks mõjutajaks diagnoos J36 ehk mandliümbrusmädanik. Mandliümbrusmädanik on tuntud ka kui tonsilliit ehk krooniline kurgumandlite põletik. Põletik võib raskendada hingamist ja neelamist ning võib levida edasi ka neerudesse, kopsudesse, südamesse ja mujale kehasse. (Ravindran *et al.*, 2021) Tonsilliit suurendas keskmiselt patsientide haiglas viibimise aega 4,1 korda eeldusel, et teised tunnused on fikseeritud. Päevades on see ligikaudu 43 päeva pikem kui salmonelloosi (baastase) patsientide seas. Seedeelundite haiguste diagnoosidest oli tugevaimaks mõjuteguriks K10 ehk muud lõualuuhaigused. Nagu mandliümbrusmädanik, viitab ka lõualuuhaiguste olemasolu võimelikele põletikele, mis võivad levida kopsudesse. Lõualuuhaigustega pulmonoloogia patsiendid olid haiglas peaaegu kaheksa korda kauem ehk umbes 96 päeva pikemalt, mis on üle kolme kuu.

Diagnoosid C92 (müeloidne leukeemia) ja D12 (healoomuline soolekasvaja) ainsana vähendasid voodipäeva pikkust, vastavalt 78,1% ja 80,9%. Mõlemad diagnoosid klassifitseeritakse kasvajate alla. See võib viidata sellele, et selliste diagnoosidega patsientide hospitaliseerimised on pikemalt planeeritud või seotud lühiajaliste raviprotseduuridega, näiteks haiguse kulgemise kontrollimine.

Ka pulmonoloogia puhul on patsiendi kodumaakonna keskuse ja raviasutuse vaheline kaugus voodipäevi vähendav tegur, ligikaudu 0,021%.

Võrreldes Ida-Tallinna Keskhaiglaga, on Põhja-Eesti Regionaalhaigla ja Viljandi Haigla patsientide voodipäevad lühemad. PERH-is on patsiendid umbes 16% lühemalt, Viljandi Haiglas umbes 13% lühemalt. See tulemus näitab, et raviasutusel on erialadele erinev mõju,

sest kardioloogias olid patsiendid võrreldes ITK-ga kõigis teistes haiglates keskmiselt kauem ravil. Ida-Viru Keskhaiglas on patsientide voodipäevad pikemad umbes 7,6%, Tartu Ülikooli Kliinikumis peaaegu 9%. Tasub ka tähele panna, et pulmonoloogia patsientide seas ei olnud aasta statistiliselt oluline mõjutegur ning ravisutuse mõjud on patsientidele sarnased aastast sõltumata.

Naised on meestega võrreldes haiglas umbes 43% lühemalt, mis on kardioloogia eriala võrreldes peaaegu 40%-line erinevus. See joonistub välja ka graafikult 5, kus meeste tulp on naiste omast peaaegu kolmandiku pikem. Kuna pulmonoloogia ei olnud aasta mõju statistiliselt oluline tegur, on mudeli tulemused ja joonis 5 omavahel kooskõlas.

Võrreldes järelraviga on sisehaiguste, kirurgia, I astme intensiivravi ja II astme intensiivravi patsiendid kõik haiglas lühemalt, seal hulgas sisehaiguste patsiendid peaaegu 44% lühemalt. Kui järelravi ajal jälgitakse patsiente pikemalt, et vältida edasisi komplikatsioone, siis kirurgiapatsiendid saavad tõenäoliselt haiglasse ainult mõned päevad enne operatsiooni.

Vanuserühmade ja soo koosmõju vahel tekkisid huvitavad kontrastid. 25–29-aastased patsiendid on võrreldes baastasemega (20–24) haiglas ligikaudu 48% lühemalt, kuid 25–29-aastased naised on haiglas peaaegu 2 korda (ca 28 päeva) kauem. See viitab soo mõju mitte-konstantsusele ning näitab, et meeste ja naiste haiglas viibimise aeg sõltub ka vanusest. Vanuserühma ja soo koosmõju näitab, et naiste risk kasvab meeste omast kiiremini. Vanuserühmas 55–59 on naised võrreldes meestega haiglas rohkem kui 2 korda pikemalt. Alla 45-aastased meespatsiendid erinevad referentstasemest statistiliselt olulisel määral ning on haiglas ligikaudu 4 päeva lühemalt.

Kirjeldatud mudeli determinatsioonikordaja tuli 0,749 ehk selle mudeliga sai kirjeldatud peaaegu 75% pulmonoloogia patsientide voodipäeva pikkusest ja seda mõjutavatest teguritest. Dispersioonitest andis p -väärtuseks 0,248, mis kinnitab, et ka selle andmestiku jaoks on negatiivne binoommudel sobiv. Headusnäitajate arvutuskäigud on selgitatud põhjalikumalt eelmises alapeatükis.

2.4.4. Analüüsi tulemused nefroloogias

Nefroloogia eriala patsientide haiglas viibimise aega analüüsides olid ravisutusteks Lääne-Tallinna Keskhaigla, Põhja-Eesti Regionaalhaigla ja Tartu Ülikooli Kliinikum. Ridu oli andmestikus 5073, neist 2024. aasta andmeid 2589 rida ning 2025. aasta andmeid 2484 rida. Tabelis 11 on toodud nefroloogia eriala mudelisse lisatud muutujate p -väärtused, Hii-ruut teststatistikud ja vabadusastmed.


Tabel 11: Nefroloogia eriala mudel

Tunnus	χ^2	Df	p-väärtus
raviastutus	180,87	2	< 0,0000
teenus	921,55	9	< 0,0000
diagnoos	1015,7	267	< 0,0000
log(kaugus_km)	18,06	1	0,0002
vanuseruhm	167,32	13	< 0,0000
sugu	1,88	1	0,1698
vanuseruhm:sugu	67,47	13	< 0,0000
factor(aasta)	8,36	1	0,0038

Allikas: Eesti Tervisekassa, autori koostatud

Nefroloogia eriala mudelit koostades olid statistiliselt olulised mõjutajad raviastutus (kokku 3), teenused (kokku 10), diagnoosid (kokku 268), maakonnakeskuse kaugus raviastu- sest, vanuserühm (kokku 14), aasta ja soo ja vanuse koosmõju. Sugu ise statistiliselt oluline mõjutaja ei olnud. Seda toetab ka joonis 5, kust on näha, et nefroloogia eriala patsientide seas oli meeste ja naiste vahel kõige minimaalsem erinevus keskmises voodipäevade pikkuses. Aasta oli taas statistiliselt oluline, mis näitab, et nefroloogia patsientide seas on kahel aastal voodipäevade pikkuses statistiliselt oluline erinevus. Raviteenus ise osutus statistiliselt oluli- seks muutujaks, kuid ükski tase ei erinenud teisest statistiliselt olulisel määral. Kõik statistili- selt olulised muutujate tasemed on toodud lisas E.

Statistiliselt oluliste mõjutajate suhtelise riski koefitsendid (e^{β}) koos 95% usaldusin- tervallidega on toodud joonisel 10, loetavuse lihtsustamise jaoks on diagnooside tulemused toodud eraldi ja valitud on 10 kõige tugevamat mõjutajat vastavalt koefitsendi suurusele. Va- nuse ja soo koosmõjudest on samuti toodud 10 kõige tugevamat mõjutajat.



Joonis 10: Suhtelise riski koefitsendid koos usalduspiiridega nefroloogia eriala patsientide seas. Allikas: Eesti Tervisekassa, autori koostatud

Mudeliga selgus, et 2024. aastal oli 20–24-aastane patsient Lääne-Tallinna Keskhaig- las nefroloogias keskmiselt 5,8 päeva, mis on üsna sarnane tulemus kardioloogiale.

Kõige rohkem pikendasid nefroloogia patsientide seas haiglas viibimise aega võrrel- des baastasemega põletikulised spondülopaatiad (diagnoos M46), ämblikuvõrkkesta-alused verevalumid (diagnoos I60) ja soole talitushäired (diagnoos K59). Neist diagnoosid M46

ja I60 tõtsid haiglas viibimise aega umbes 6,1 korda, diagnoos K59 ligikaudu 4,8 korda. Ämblikuvõrkkesta-alune verevalum on neuroloogiline seisund, mis on tõenäoliselt tekkinud trauma tagajärjel ja vajab kirurgilist sekkumist. Kui patsient pärast operatsiooni pikalt taastub, võivad organid, seal hulgas neerud, lakata ajutrauma tõttu töötamast. (Snow *et al.*, 2024) Kõige väiksem mõju haiglas viibimise ajale oli insuliinisõltuva suhkrutõvega patsientidel (diagnoos E10), kes olid võrreldes baastasemega (A02) haiglas ligikaudu 78,5% pikemalt.

Diagnoosidest A-, B-, C-, I-, M-, N-, O-, S- ja T-kategooria diagnoosid kõik pikemad nefroloogia patsientide haiglas viibimise aega rohkem kui 2 korda. Kõige suuremad mõjud olid I- ja M-kategooria diagnooside hulgas, kus mõjud ulatusid kuuekordseteks. I-kategooria diagnooside alla kuuluvad vereringeelundite haigused ning M-kategooria alla lihasluukonna ja sidekoehaigused. 2008. aastal kirjutasid Ronco *et al.* oma artiklis, et südame- ja veresoonkonnahaigused on tugevalt seotud ka neerude tööga ning halvenenud südame töö vähendab ka neerufunktsiooni, näiteks soodustab vedelikupuudust. Sageli viivad südame- ja neeruhaigused pikema hospitaliseerimiseni, et ennetada võimalikke tüsistusi, mis võivad tekkida ühest või teisest haigusest. (Ronco *et al.*, 2008)

2025. aastal olid nefroloogia patsiendid võrreldes eelmise aastaga haiglas umbes 6,1% pikemalt. Võrreldes kardioloogia patsientidega, on nefroloogia patsientide seas kahe aasta jooksul haiglas viibimise aeg tõusnud rohkem. Vahe kahe eriala patsientide voodipäevade pikenemise vahel on umbes 3,6%.

Nefroloogia erialas ei olnud maakonna keskuse kaugus raviasutusest enam negatiivse suunaga mõjutegur. Kui kaugus suureneb 1% võrra, suureneb patsientide voodipäevade kogusumma keskmiselt 0,025%. Kui kaugus suureneks topelt (ehk 100%), pikeneks voodipäevade arv umbes 2,5%. Tabelis 12 on toodud tunnuse kaugus_km jaotus erialade lõikes.

Tabel 12: Tunnuse kaugus_km jaotus erialade lõikes

Eriala	Miinum	1. kvart.	Mediaan	Keskmine	2. kvart.	Maksimum
kardioloogia	2,20	2,30	3,70	32,19	61,40	316,70
pulmonoloogia	2,20	2,30	3,70	22,15	8,90	316,70
nefroloogia	2,20	2,30	2,30	36,95	68,70	258,80

Allikas: Eesti Tervisekassa, autori koostatud

Tabelist on näha, et erialade vahel on maakonna keskuse kaugus raviasutusest üsna erineva varieeruvusega. Kõige märgatavam erinevus on maksimaalse väärtuse juures, mis nefroloogia erialal erineb teistest. Kaugus 316,7 kilomeetrit on kaugus Saaremaa ja Ida-Viru Keskhaigla vahel ning Ida-Viru Keskhaiglat raviasutusena nefroloogia patsientide andmestikus pole. Seal on suurim distant Saaremaa ja Tartu Ülikooli Kliinikumi vahel, mis on ligikaudu 259 kilomeetrit. Nefroloogia erialal oli Saaremaalt ja Hiiumaalt tulevate patsientide osakaal andmestikus ligikaudu 3,1%, kardioloogias aga 2,9% ning pulmonoloogias 0,8%. Tulemused on arvutatud kui Saaremaalt ja Hiiumaalt tulnud patsientide arv jagatuna kogu Eesti patsientide arvuga vastavas erialas. Tabelis 13 on toodud võrdlused saartelt tulevate ja patsientide ja kogu Eesti vahel. Kardioloogia patsientide seas on Hiiumaa ja Saaremaa elanike

keskmise haiglas viibimise aeg umbes 5,4 päeva, mis on umbes 4 päeva lühem üle-üldisest kardioloogia patsientide keskmisest voodipäevade pikkusest. Pulmonoloogia patsientide seas, kes on pärit Saaremaalt ja Hiiumalt on keskmine raviaeg umbes 23 päeva, mis on umbes 6 päeva pikem võrreldes pulmonoloogia üldise keskmisega. Nefroloogia patsiendid, kes on pärit saartelt, on keskmiselt haiglas umbes 1 päeva lühemalt, kui teistest kogu Eesti patsiendid.

Tabel 13: Voodipäeva pikkuse võrdlus saarte elanike ja kogu Eesti vahel erialade lõikes

Eriala	Asukoht	Min.	$q_{0,25}$	Mediaan	Keskmine	$q_{0,75}$	Max.
kardioloogia	saared	1,00	2,00	4,00	5,35	7,00	47,00
kardioloogia	kogu Eesti	1,00	3,00	7,00	9,49	12,00	150,00
pulmonoloogia	saared	1,00	4,75	11,00	22,59	25,00	120,00
pulmonoloogia	kogu Eesti	1,00	6,00	11,00	17,07	20,00	331,00
nefroloogia	saared	1,00	4,00	9,50	14,12	22,00	48,00
nefroloogia	kogu Eesti	1,00	6,00	12,00	15,07	20,00	98,00

Allikas: Eesti Tervisekassa, autori koostatud

See toetab autori üldist väidet, et saartelt tulevad patsiendid viibivad haiglas lühemalt. Kuigi pulmonoloogia patsientide seas on keskmine haiglas viibimise aeg saarlaste jaoks pikem kui üldine keskmine, on maksimaalne voodipäevade summa üle 200 päeva ehk rohkem kui 7 kuud pikem kogu Eestis. Tasub ka märkida, et pulmonoloogia patsientide seas on Saaremaa ja Hiiumaa elanike osakaal alla 1 protsendi, mis võib tuua kaasa suurema varieeruvuse.

Lääne-Tallinna Keskhaiglaga võrreldes olid nefroloogia patsiendid nii PERH-is kui ka TÜK-is kauem ravil. Põhja-Eesti Regionaalhaiglas oli voodipäevade pikkus umbes 6,1% pikem, Tartu Ülikooli Kliinikum umbes 43,5% pikem kui Lääne-Tallinna Keskhaiglas.

Võrreldes 20–24-aastaste nefroloogia patsientidega olid peaaegu kõik vanuserühmad pikemalt haiglas, kusjuures 70–74 patsiendid umbes 74% pikemalt ning 75–79-aastased patsiendid umbes 81% pikemalt. Päevades on see erinevus umbes 10 päeva. 40–44-aastane naine oli aga võrreldes 20–24-aastase mehega haiglas ligikaudu 34% lühemalt, mis teeb tema voodipäevade pikkuseks umbes 3 ja pool päeva.

Mudeli determinatsioonikordaja tuli 0,581 ehk selle mudeliga sai kirjeldatud umbes 58% nefroloogia patsientide haiglaravi pikkusest ja seda mõjutavatest teguritest aastatel 2024 ja 2025. Dispersioonitest andis p -väärtuseks 0,808, mis kinnitab, et negatiivne binoomimudel sobis andmetega.

2.4.5. Analüüsi tulemused üle kolme eriala


Kuna kõige suuremaks mõjutajaks kõigil kolmel mudelil olid kaasuvad diagnoosid, otustas autor uurida haiglas viibimise aega ka ilma diagnoosi mõju kaasamata, et näha, kas sarnased mustrid joonistuvad välja ka ilma nendeta. Selleks filtreeriti üldandmestikku selliselt, et kaasatud oleks ainult need haiglad, kus oli kõigi kolme eriala patsiente. Nendeks ravisustusteks osutusid Põhja-Eesti Regionaalhaigla ja Tartu Ülikooli Kliinikum. Andmestikku tuli kokku 27 673 rida, neist 13 725 olid aasta 2024 kohta ning 13 948 aasta 2025 kohta.

Algselt koostas autor taas negatiivse binoommodeli, kuid dispersioonitest simuleeritud mudeli jääkidele andis p -väärtuseks 0, mis viitas, et mudel ei sobi nende andmetega. Seetõttu otsustas autor kasutada hoopis log-lineaarset mudelit, kus voodipäevade summa viidi logaritmitud skaalale. Loendusandmete jaoks sobib koefitsientide mõju hindamiseks pigem multiplikatiivne lähenemine, sest siis vaadatakse erinevust kordades või protsentides, mitte mõõtühikus, näiteks päevades. Logaritmiline seosefunktsioon tagab, et mõjud on proportsionaalsed sündmuste esinemise arvuga. Log-lineaarne mudel avaldub kujul

$$E(Y) = \exp(\beta_0 + \beta_1 x_1 + \dots + \beta_k x_k, \quad (9)$$

kus e^{β_j} vastab tunnuse x_j muutuse multiplikatiivsele mõjule ehk x_j muutus 1 ühiku võrra suurendab (või vähendab) keskväärtuse mõju e^{β_j} korda. Tulemused on tõlgendatud kui šansside suhe. (Käärrik, 2013)

Mudelisse kaasati sõltuva tunnusena eriala, et uurida otsest erinevust kardioloogia, pulmonoloogia ja nefroloogia patsientide vahel. Välja jäeti diagnoosid. Kõik tunnused peale aasta osutused statistiliselt oluliseks ehk diagnoosi mõju kõrvale jättes ei ole erialade vahel aastate lõikes statistiliselt olulisi erinevusi. Mudeli väljund statistiliselt oluliste muutujatega on leitav lisast F. Statistiliselt oluliste mõjutajate šansside suhte koefitsendid (e^{β}) koos 95% usaldusintervalliga on nähtavad joonisel 11.



Joonis 11: Šansside suhte koefitsendid koos usalduspiiridega diagnoosi mõju arvestamata. Allikas: Eesti Tervisekassa, autori koostatud

Keskmine patsient selle mudeliga oli meessoost, 20–24-aastane ja Põhja-Eesti Regionaalhaigla kardioloogias järelravil. Sellise patsiendi keskmine haiglas viibimise aeg on umbes 9,6 päeva.

Nefroloogia patsiendid olid võrreldes kardioloogia patsientidega keskmiselt 95,5%

pikemalt ravil. Pulmonoloogia patsiendid olid võrreldes kardioloogia patsientidega umbes 70,5% pikemalt haiglas eeldusel, et ülejäänud tunnused on fikseeritud. Kuigi jooniselt 5 nähtub, et kardioloogia patsiendid olid võrreldes teiste eriala patsientidega keskmiselt ravil kõige lühemalt, annab mudel teistsuguseid tulemusi. See kinnitab, et haiglas viibimise aeg ei sõltu ainult erialast, vaid ka soost, vanusest ja muudest teguritest. Lisaks on jooniselt 5 toodud keskmine haiglas viibimise aeg, kuid mudelis on sõltuva tunnuseks kasutatud voodipäevade summat. Kardioloogia patsientide kohta on ka andmestikus kõige rohkem infot, mis ilmselt aitab selgitada selle eriala patsientide haiglas viibimise aja varieeruvust.

Mida kaugemal on patsiendi elukoht raviasutusest, seda vähem voodipäevi ta raviasutuses veetma peab. Kui kaugus suureneb 1% võrra, väheneb voodipäevade kogusumma keskmiselt 0,05%. Kuna baastasemeks on kardioloogia patsiendid, on tulemus kooskõlas peatükis 2.4.2 loodud mudeliga, kus kardioloogia patsientide haiglas 1% võrra kaugemal elamine suurendas voodipäevade kogusummat keskmiselt 0,053%.

Tartu Ülikooli Kliinikumi patsiendid olid võrreldes Põhja-Eesti Regionaalhaigla patsientide ravil umbes 2,5% pikemalt. Kui võrrelda tulemust eelneva kolme mudeliga, on haigla mõju mõnevõrra erinev. Kardioloogia eriala patsiendid olid Põhja-Eesti Regionaalhaiglas ravil keskmiselt 7,8 päeva ning Tartu Ülikooli Kliinikumis keskmiselt 7,5 päeva. Pulmonoloogia patsiendid olid PERH-is ravil keskmiselt 11,9 päeva ning TÜK-is keskmiselt 15,4 päeva. Nefroloogia patsiendid olid PERH-is keskmiselt 6,1 päeva ning TÜK-is keskmiselt 8,2 päeva. Tulemused on arvutatud valemi (8) põhjal. Tulemustest nähtub, et haigla mõju on erialati erinev ning ei saa väita, et Põhja-Eesti Regionaalhaigla patsiendid on alati pikemalt ravil kui Tartu Ülikooli Kliinikumi patsiendid või vastupidi. Tasub ka märkida, et nii antud mudelis kui ka pulmonoloogia patsientide jaoks koostatud mudelis ei olnud aasta statistiliselt oluline mõjutegur.

Tabel 14: Voodipäevade pikkuse võrdlus TÜK-i ja PERH-i vahel aastate ja erialade lõikes

Eriala	Aasta	Raviasutus	Min.	Mediaan	Keskmine	sd.	Max.
Kardioloogia	2024	PERH	1,00	6,00	9,71	11,00	132,00
Kardioloogia	2024	TÜK	1,00	6,00	8,96	10,00	112,00
Kardioloogia	2025	PERH	1,00	6,00	10,20	11,90	145,00
Kardioloogia	2024	TÜK	1,00	6,00	9,45	11,20	150,00
Pulmonoloogia	2024	PERH	1,00	10,00	15,00	17,60	120,00
Pulmonoloogia	2024	TÜK	1,00	12,00	18,70	28,70	331,00
Pulmonoloogia	2025	PERH	1,00	9,00	14,40	19,90	165,00
Pulmonoloogia	2025	TÜK	1,00	12,00	16,50	18,90	213,00
Nefroloogia	2024	PERH	1,00	12,00	13,80	11,20	68,00
Nefroloogia	2024	TÜK	1,00	13,00	17,30	15,50	90,00
Nefroloogia	2025	PERH	1,00	12,00	15,30	14,20	84,00
Nefroloogia	2025	TÜK	1,00	13,00	19,50	19,20	98,00

Allikas: Eesti Tervisekassa, autori koostatud

Tabelis 14 on toodud kokkuvõtte haiglas viibimise ajast Põhja-Eesti Regionaalhaig-

las ja Tartu Ülikooli Kliinikumis erialade ja aastate lõikes. Tabeli päises on lühendatud kolme nimetust: miinimumväärtuse nimetus on lühendatud kujule „Min.“, standardhälve on lühendatud kujule „sd.“ ja maksimaalne väärtus on lühendatud kujule „Max.“.

Kõige pikemad haiglas viibimise ajad olid pulmonoloogia erialas ning mõlemal aastal on Tartu Ülikooli Kliinikumis viibinud patsientide voodipäevade summa olnud pikem kui PERH-is. See kinnitab, et pulmonoloogia patsiendid on keskmiselt kauem ravil just Tartu Ülikooli Kliinikumis ning seda olenemata aastast.

Kardioloogia patsientide seas oli varieeruvus aastate, erialade ja raviasutuste lõikes kõige stabiilsem, standardhälve jäi kõigil neljal juhul alla 12 päeva. Ka mediaan oli kardioloogia patsientidel püsivalt 6 päeva ning keskmine haiglas viibimise aeg oli umbes 9 ja 10 päeva vahel, mida kinnitab ka joonis 5. Maksimaalne voodipäevade summa oli 2024. aastal kõrgem Põhja-Eesti Regionaalhaiglas ning 2025. aastal oli see kõrgem Tartu Ülikooli Kliinikumis. See toetab kardioloogia mudeli tulemusi, et aasta on statistiliselt oluline, sest mõlemas haiglas oli voodipäevade arv 2025. aastal kõrgem kui 2024. aastal.

Nefroloogia patsientide seas oli haiglas viibimise aja summa kõige madalam ja jäi üle aastate alla 100 päeva. Samas kasvas ka varieeruvus hüppeliselt, mõlemas haiglas on kahe aasta vaheline standardhälve suurenenud 3 ja 4 päeva vahel. Nefroloogia patsiendid olid 2024. aastal Põhja-Eesti Regionaalhaiglas ravil keskmiselt 13,8 päeva, samal aastal olid nad Tartu Ülikooli Kliinikumis ravil keskmiselt 15,3 päeva. Aasta hiljem olid mõlemas haiglas patsiendid pikemalt, PERH-is keskmiselt 17,3 päeva ning TÜK-is keskmiselt 19,5 päeva. Ka voodipäevade summa tõusis mõlemas haiglas kahe aasta vahel, PERH-is umbes 16-päevane tõus ning TÜK-is umbes 8-päevane tõus. Siit järeldas autor, et kuigi Tartu Ülikooli Kliinikumis on nefroloogia patsiendid mõlemal aastal olnud ravil pikemalt, on seal ravikestus olnud stabiilsem, sest kahe aasta vaheline tõus päevades on kaks korda väiksem võrreldes Põhja-Eesti Regionaalhaiglaga. Tabelis 14 toodud tulemused kinnitavad, et haiglas viibimise aeg ei sõltu ainult raviasutusest, vaid ka aastast, millal patsient ravil oli. Kuigi pulmonoloogia patsientide seas ei olnud aastate vahel statistiliselt olulist erinevust, erinevad selle eriala tulemused siiski tugevalt kardioloogia ja nefroloogia patsientidest. Patsiendi haiglas viibimise aega mõjutab ka see, mis erialal ta ravil on.

Järeldravi patsientidega võrreldes olid sisehaiguste patsiendid peaaegu 70% lühemalt haiglas, I ja II astme intensiivravi umbes poole lühemalt. Tulemus on sarnane ka varasemalt loodud mudelitega ning kinnitab, et järeldravi patsiendid on haiglas kõige pikemalt.

Võrreldes 20–24-aastastega olid kõik vanuserühmad pikemalt haiglas, kusjuures 85+ patsiendid kuni 81% pikemalt. Kõige väiksem vahe baastasemega oli 50–54-aastasetel patsientidel, kes olid haiglas 20% kauem, mis teeb ligikaudu 2 päeva kauem. Oluline koosmõju tuli 30–34-aastaste naiste seas, kes olid võrreldes 20–24-aastaste meestega haiglas umbes 27% ehk 2 päeva lühemalt.

Mudeli determinatsioonikordaja R^2 tuli 0,2826 ehk selle mudeliga saab kirjeldatud ligikaudu 28% Tartu Ülikooli Kliinikumi ja Põhja-Eesti Regionaalhaigla kardioloogia, pulm-

nonoloogia ja nefroloogia patsientide haiglas viibimise ajast 2024. ja 2025. aastal ja seda mõjutavatest teguritest diagnoosi mõjust sõltumata. Tulemusest järeldas autor, et tegelikult on diagnoosi mõju vajalik ning aitab parandada andmete kirjeldavust, sest kõigi eelmiste mudelite kirjeldavus oli kõrgem. Dispersioonitest andis p -väärtuseks 0,728 ning seega saab väita, et mudel sobis andmetega.

2.4.6. Järeldused

Koostatud neljast mudelist kõige parema kirjeldavusega oli pulmonoloogia eriala patsientide mudel. Selle determinatsioonikordaja andis tulemuseks $R^2 = 0,749$ ehk kaks kolmandikku pulmonoloogia patsientide haiglas viibimise aega mõjutavatest teguritest sai kirjeldatud. Üldjoontes jäid mudelites statistiliselt oluliseks samad asjad. Erialadele kitsendatud mudelites mõjutasid haiglas viibimise aega statistiliselt olulisel määral kaasuvad haigused, ravitüüp, patsiendi sugu, vanus ja soo ja vanuse koosmõju, ravisutus, kus patsient ravil oli ning ka patsienti elukoha kaugus ravisutusest. Kardioloogia ja nefroloogia patsientide seas oli oluliseks mõjuteguriks ka aasta. Mõlema eriala patsiendid olid 2025. aastal pikemalt haiglas kui 2024. aastal.

Keskmiselt olid kõige kauem voodiravil pulmonoloogia patsiendid, kus keskmine patsient oli 20–24-aastane mees, kes viibis Ida-Tallinna Keskhaiglas pulmonoloogias järelravil salmonelloosi diagnoosiga umbes 14 päeva ehk 2 nädalat. Nii kardioloogia kui ka nefroloogia patsiendid olid haiglas keskmiselt alla nädala eeldusel, et kõik teised tunnused on fikseeritud. Keskmine kardioloogia patsient oli 20–24-aastane mees, kes oli 2024. aastal Ida-Tallinna Keskhaiglas järelravil umbes 5,7 päeva. Nefroloogia erialas oli keskmine patsient 20–24-aastane patsient, kes oli järelravil Lääne-Tallinna Keskhaiglas 2024. aastal umbes 5,8 päeva.

Kõigi kolme eriala puhul joonistus välja, et naised viibisid ravil keskmiselt lühemalt kui mehed. Küll aga oli nefroloogia ja pulmonoloogia patsientide seas oluliseks mõjutajaks ka soo ja vanuse koosmõju. Pulmonoloogia patsientide seas olid naiste riskid kõrgemad kui meeste omad vanuserühmades 25–29, 30–34 ja vanemad kui 40-aastased patsiendid. Sellest järeldub, et mingites vanuserühmades kasvab pulmonoloogia naissoost patsientide risk kiiremini kui meeste oma.

Diagnooside mõjud olid erialati erinevad, kuid olulisteks mõjutajateks olid nii kardioloogia, pulmonoloogia kui ka nefroloogia patsientide puhul nakkus- ja parasiithaigused, mis tõstsid haiglas viibimise aega kaks kuni kaheksa korda. Üksikud diagnoosid vähendasid haiglas viibimise aega, ainult pulmonoloogia patsientide seas vähendasid haiglas viibimise aega kasvajad. Teiste erialade patsientide seas kõik kaasuvad diagnoosid tõstsid haiglas viibimise aega. Kui tulevikus sarnast uuringut korrata, peaks erilist tähelepanu pöörama just nakkus- ja parasiithaiguste mõjule ja võiks ka teostada eraldi uuringu just nende patsientide seas.

Nii kardioloogia kui ka nefroloogia patsientide haiglas viibimise aeg tõusis ajaga, 2024. aastal olid patsiendid haiglas lühemalt kui 2025. aastal.

Kõige lühemalt olid kardioloogia patsiendid ravil Ida-Tallinna Keskhaiglas, teistes

haiglates olid nad 21% kuni 83% pikemalt, kõige pikemalt just Pärnu Haiglas. Pulmonoloogia patsiendid olid võrreldes Ida-Tallinna Keskhaiglaga pikemalt ravil Ida-Viru Keskhaiglas ja Tartu Ülikooli Kliinikumis, vastavalt 7,6% ja 8,9% pikemalt. Küll aga olid pulmonoloogia patsiendid võrreldes baastasemega lühemalt ravil Põhja-Eesti Regionaalhaiglas ja Viljandi Haiglas, vastavalt ligikaudu 16% ja 13% lühemalt. Nefroloogia patsiendid olid kõige lühemalt ravil Lääne-Tallinna Keskhaiglas, Põhja-Eesti Regionaalhaiglas olid nad 6,1% pikemalt ning Tartu Ülikooli Kliinikumis 43,5% pikemalt. Tulemustest saab järeldada, et raviasutuse mõju ei ole üle erialada patsientidele sarnane, lisaks tasub märkida, et pulmonoloogia patsientide seas oli haiglas viibimise aeg aastate lõikes sarnane, kardioloogia ja nefroloogia patsientide seas aga olid kahe aasta tulemused statistiliselt oluliselt erinevad.

Diagnoosi mõju kaasamata olid Tartu Ülikooli Kliinikumi patsiendid ravil 2,5% pikemalt kui Põhja-Eesti Regionaalhaigla patsiendid üle kõigi kolme eriala, kusjuures nii nefroloogia kui ka pulmonoloogia patsiendid olid võrreldes kardioloogia patsientidega ravil pikemalt, vastavalt 99,5% ja 70,5%. Kuna andmestikus oli kõige rohkem andmeid kardioloogia patsientide kohta, on kardioloogia patsientide voodipäevade summa kõrgem kui teiste erialade oma ning seetõttu on mõistlikum erialasid vaadelda eraldi.

Kõige kauem viibisid haiglas järelravi patsiendid. Kardioloogia patsientide seas ulatusid erinevused võrreldes järelraviga kuni 58 protsendini. Lühemalt olid ravil statistiliselt olulisel määral kirurgia-, sisehaiguste- ja intensiivravipatsiendid, kõige suurem erinevus ilmnis järelravi ja sisehaiguste patsientide vahel. Pulmonoloogia patsientide seas olid erinevused väiksemad, kuid siiski olid sisehaiguste, kirurgia ja intensiivravi patsiendid võrreldes järelraviga voodiravil lühemalt umbes 20% ja 44% vahel. Nefroloogia patsientide haiglas viibimise aega mõjutas raviteenus küll statistiliselt olulisel määral, kuid tasemete vahel ei ilmnenud statistiliselt olulist erinevust olulisuse nivool $\alpha = 0,05$. Üheski mudelis ei olnud olulised mõjutegurid COVID-19 teenused, mis on ilmselt tingitud andmete uudsusest ja COVID-19 suuremast teadlikusest ja ravist, näiteks vaktsineerimisest.

Raviasutused kirjeldavad iga eriala mudelis kogu variatsioonist ära vastavalt 3,3%, 1,4% ja 3%. Kirjeldavus on arvutatud determinatsioonikordaja kaudu, kus algselt arvutati kogu mudeli determinatsioonikordaja ja siis arvutati see mudelile, kuhu raviasutust ei kaasatud ja leiti kahe suuruse vahe. Tabelis 15 on toodud raviasutuste suhtelise riski skoorid koos usaldusintervallidega kõigis mudelites.

Tabel 15: Raviastutuse mõju haiglas viibimise ajale koos usaldusintervallidega

Mudel	Raviastutus	Suhteline risk	95% usaldusintervall
Kardioloogia	Võrdlusbaas: Ida-Tallinna Keskhaigla		
Kardioloogia	Pärnu Haigla	1,83	1,76 ... 1,90
Kardioloogia	Põhja-Eesti Regionaalhaigla	1,37	1,34 ... 1,41
Kardioloogia	Tartu Ülikooli Kliinikum	1,32	1,28 ... 1,35
Kardioloogia	Lääne-Tallinna Keskhaigla	1,31	1,26 ... 1,36
Kardioloogia	Ida-Viru Keskhaigla	1,21	1,17 ... 1,25
Pulmonoloogia	Võrdlusbaas: Ida-Tallinna Keskhaigla		
Pulmonoloogia	Tartu Ülikooli Kliinikum	1,09	1,03 ... 1,15
Pulmonoloogia	Ida-Viru Keskhaigla	1,08	1,01 ... 1,14
Pulmonoloogia	Viljandi Haigla	0,87	0,77 ... 0,97
Pulmonoloogia	Põhja-Eesti Regionaalhaigla	0,84	0,80 ... 0,89
Nefroloogia	Võrdlusbaas: Lääne-Tallinna Keskhaigla		
Nefroloogia	Tartu Ülikooli Kliinikum	1,43	1,35 ... 1,52
Nefroloogia	Põhja-Eesti Regionaalhaigla	1,06	1,01 ... 1,12

Allikas: Eesti Tervisekassa, autori koostatud

Raviastutus kirjeldab koguhajuvusest küll vähe, kuid raviastutuste mõju on erialade lõikes küllaltki erinev ning ei saa väita, et haiglas viibimise aeg oleks monotoonselt seotud raviastutusega, kus patsient viibib. Olenevalt erialast on raviastutusel HLOS-ile positiivne või negatiivne mõju. Näiteks pulmonoloogia patsiendid, kes on ravil Põhja-Eesti Regionaalhaiglas, on voodiravil keskmiselt 16% lühemalt kui Ida-Tallinna Keskhaiglas ja maksimaalselt kuni 20% lühemalt. Kuid kardioloogia patsiendid on Ida-Viru Keskhaiglas keskmiselt 21% pikemalt ravil võrreldes Ida-Tallinna Keskhaiglaga ning maksimaalselt kuni 25% pikemalt. Seetõttu ei saa ka väita, et üks või teine raviastutus oleks teistest rohkem või vähem efektiivsem, vaid raviastutus on küll oluline mõjutegur haiglas viibimise ajale, kuid see sõltub ka ravijuhtumitest ja muudest näitajatest.

Tasub märkida, et kui tulevikus sarnast analüüsi uuesti läbi viia, oleks mõistlik kasutada diagnoosikoodide asemel RHK-10 alamliigitust, et mudelitesse ei satuks nii palju erinevaid tasemeid, sest see võib põhjustada ebavajalikku müra. See lihtsustaks analüüsi ja parandaks ka mudelite loetavust. Lisaks oleks mõistlik kasutada näiteks teenuste ja diagnooside juures referentsväärtusena midagi muud kui tähestikuliselt esimest väärtust, näiteks diagnooside juures oleks referentsväärtuseks olnud mõistlik võtta diagnoos, mida esines patsientidel kõige rohkem. Eraldi tuleks jälgida just nakkus- ja parasiithaiguste diagnoosidega patsiente, sest need diagnoosid mõjustasid haiglas viibimise aega kõigis mudelites üsna tugevalt. Lisaks puudub käesolevas töös kasutatavates andmetes teadmine, kas patsient suri haiglaravil või mitte. Kuna raviarvetel olevad kuupäevad on lisatud sinna arve tasumise kuupäevaga, ei saa ka kindlalt väita, et kõik 2024. aastal makstud raviarvete patsiendid olid ravil just 2024. aastal,

sama kehtib ka 2025. aasta kohta. Täpsemad tulemused saaks, kui oleks teada täpselt patsiendi sisse- ja väljakirjutamise aeg, nii saaks analüüsida ka näiteks nädalapäevade ja aastaaegade mõju.

Kokkuvõte

Bakalaureusetöö eesmärgiks oli anda ülevaade haiglate efektiivsuse uurimisest mujal maailmas ja Eestis, kasutades selgitamiseks varasemaid sarnasel teemal loodud töid. Peamine suunitlus oli haiglas viibimise ajal ja seda mõjutavatel teguritel. Saadud teadmisi rakendati Eesti Tervisekassa andmetel, et uurida kolme erineva eriala patsientide haiglas viibimise kestust ja seda mõjutavaid tegureid.

Haiglate efektiivsuse all mõistetakse nii haigla kui ka patsiendiga seotud tegureid, näiteks voodikohtade arv, ambulatoorsete vastuvõttude arv, haridus- ja teadustöö, kulude ja tulude tasakaal. Kõige laialdasemalt kasutatud meetodid haiglate efektiivsuse uurimiseks on aegridade analüüs (DEA meetod) ja stohhastiline piiranalüüs (SFA meetod), millest üks on mitteparameetiline ja teine parameetiline. Valdavalt on uuringutes kasutatud mõlemat meetodit ning võrreldud nende tulemusi, sest erinevalt SFA meetodist, ei arvesta DEA meetod sellega, et andmetes võib olla vigu. Mõlema meetodi juures on oluline sisend- ja väljundmuutujate valik, mis on samuti valdavalt sarnane. Peamisteks sisendmuutujateks on voodikohtade ja personali arv ning väljundmuutujateks ambulatoorsed ja statsionaarsed vastuvõttud.

Haiglas viibimise aega uuritakse mitmete statistiliste meetoditega, millest levinuimad on statistilised mudelid, kus sõltuva muutujana kasutatakse haiglas viibimise aega ja sisendmuutujatena erinevaid patsiendiga seotud tegureid või muid näitajaid.

Töö autor kasutas Eesti Tervisekassa andmete analüüsimisel negatiivset binoommudelit, et uurida haiglas viibimise aega ja seda mõjutavad tegureid 2024. ja 2025. aastal. Koostati kolm mudelit, mis olid kitsendatud meditsiini erialade järgi: kardioloogia, pulmonoloogia ja nefroloogia eriala patsiendid. Kõigis mudelites olid olulisteks haiglas viibimise aja mõjutajateks patsiendi sugu, vanuserühm, diagnoosid, teenuseliik, raviasutus ja patsiendi maakonnakeskuse kaugus raviasutusest. Diagnoosid olid kõige tugevamad mõjutajad ja tõstsid haiglas viibimise aega peaaegu igas mudelis kuni 2 korda, kardioloogia erialas kuni 8 korda. Naised viibisid haiglaravil meestest lühemalt ja vanuse kasvades kasvas ka HLOS. Raviasutused mõjutasid erinevate erialade patsientide seas haiglas viibimise aega erinevalt, kuid siiski statistiliselt olulisel määral. Tulevikus võiks sarnast uuringut läbi viies kasutada andmeid, kus on teada täpselt kuupäev, millal patsient ravile saabus ning millal ta sealt lahkus. Lisaks võiks mudelites müra vähendamiseks kasutada diagnooside asemel rahvusvaheliste haiguste klassifikatsiooni koodi ning uurida lähemalt spetsiifiliste diagnooside gruppe.

Haiglas viibimise aeg on oluline efektiivsust näitav indikaator, mida mõjutavad ka mitmed patsiendiga seotud sotsiaal-demograafilised näitajad. Haiglas viibimise kestuse jälgimine on vajalik, et tuvastada süsteemi kitsaskohti ja planeerida ravitööd selliselt, et see oleks võimalikult kasulik nii raviasutusele kui ka patsientidele.

Kasutatud allikad

1. Armoon, B., Lesage, A., Giguère, C. É., Perry, K., Consortium, S., Juster, R. P., & Guay, S. (2025). Factors influencing length of hospital stay among psychiatric inpatients in Montreal, Canada: The role of insulin, IL-6 and TNF-Alpha. *Psychoneuroendocrinology*, 182, 107627. <https://doi.org/10.1016/j.psyneuen.2025.107627>
2. Bolker, B. M., Brooks, M. E., Clark, C. J., Geange, S. W., Poulsen, J. R., Stevens, M. H. H., & White, J.-S. S. (2009). Generalized linear mixed models: A practical guide for ecology and evolution. *Trends in Ecology & Evolution*, 24(3), 127–135. <https://doi.org/10.1016/j.tree.2008.10.008>
3. Castillo, M. d. L. G. (2012). *Modelling patient length of stay in public hospitals in Mexico* (Doktoritöö). University of Southampton. https://eprints.soton.ac.uk/345554/1/Final_PhD_thesis_-_Maria_Castillo.pdf
4. Costa, A.X., Ridley, S.A., Shahani, A.K., Harper, P.R., De Senna, V. and Nielsen, M.S. (2003). Mathematical modelling and simulation for planning critical care capacity. *Anaesthesia*, 58 320-327. <https://doi.org/10.1046/j.1365-2044.2003.03042.x>
5. Cummings, P. L., Kuo, T., Javanbakht, M., Shafir, S., Wang, M., & Sorvillo, F. (2016). Salmonellosis hospitalizations in the United States: Associated chronic conditions, costs, and hospital outcomes, 2011, trends 2000–2011. *Foodborne Pathogens and Disease*, 13(1), 40–48. <https://doi.org/10.1089/fpd.2015.1969>
6. Eesti haiglavõrgu arengukava (2002). Sotsiaalministeerium. https://sm.ee/sites/default/files/content-editors/eesmargid_ja_tegevused/Tervis/Tervishoiususteem/hva2002_1_.pdf
7. efektiivsus. EKI ühendsõnastik 2025. Eesti Keele Instituut, Sõnaveeb 2025. <https://sonaveeb.ee/search/unif/dlall/eki/efektiivsus/1/est>
8. Esnar, K. (2005). *Haiglate efektiivsuse hindamine Eesti näitel*. (Magistritöö, Tartu Ülikool). <https://dspace.ut.ee/server/api/core/bitstreams/3d765003-9920-44d4-a692-fd3b52a75ee9/content>
9. European Medicines Agency. (2022). ICH guideline E11A on pediatric extrapolation (EMA/CHMP/ICH/414561/2022). https://www.ema.europa.eu/en/documents/scientific-guideline/ich-guideline-e11a-pediatric-extrapolation-step-5_en.pdf
10. Farrell, M. J. (1957). The Measurement of Productive Efficiency. *Journal of the Royal Statistical Society. Series A (General)*, 120(3), 253–290. <https://doi.org/10.2307/2343100>

11. Feldstein, Martin S. (1967). *Economic analysis for health service efficiency : econometric studies of the British National Health Service*
12. Feng, C., Wang, H., Lu, N., Chen, T., He, H., Lu, Y., & Tu, X. M. (2014). Log-transformation and its implications for data analysis. *Shanghai archives of psychiatry*, 26(2), 105–109. <https://doi.org/10.3969/j.issn.1002-0829.2014.02.009>
13. Garg, L., McClean, S., Meenan, B. J., & Millard, P. (2011). *Phase-Type survival trees and mixed distribution survival trees for clustering patients' hospital length of stay*. Informatica, 22(1). <https://doi.org/10.15388/Informatica.2011.314>
14. Gelberg, L., Andersen, R. M., & Leake, B. D. (2000). The Behavioral Model for Vulnerable Populations: application to medical care use and outcomes for homeless people. *Health services research*, 34(6), 1273–1302. <https://pmc.ncbi.nlm.nih.gov/articles/PMC1089079/>
15. Godfrey, K. (1983). *Compartmental models and their application*. London ; New York : Academic Press.
16. Habicht, T., Reinap, M., Kasekamp, K., Sikkut, R., Aaben, L., Van Ginneken, E. (2018). Eesti: tervisesüsteemi ülevaade. Maaailma Terviseorganisatsioon. Euroopa Regionaalbüroo. *European Observatory on Health Systems and Policies*, 20(1) <https://iris.who.int/handle/10665/332472>
17. Haigla liikide nõuded. (2023). Riigi Teataja. <https://www.riigiteataja.ee/akt/101062016007>
18. Haiglavõrgu arengukava (2023). Riigi Teataja. <https://www.riigiteataja.ee/akt/105042023014>
19. Hilbe, M. J. (2007). *Negative Binomial Regression*. Cambridge University Press.
20. Hollingsworth, B. (2008). The measurement of efficiency and productivity of health care delivery. *Health economics*, 17(10), 1107–1128. <https://doi.org/10.1002/hec.1391>
21. Hollingsworth, B., & Peacock, S. J. (2008). *Efficiency Measurement in Health and Health Care*. Routledge International Studies in Health Economics.
22. Husain-Syed, F., McCullough, P. A., Birk, H. W., Renker, M., Brocca, A., Seeger, W., & Ronco, C. (2015). Cardio-Pulmonary-Renal Interactions: A Multidisciplinary Approach. *Journal of the American College of Cardiology*, 65(22), 2433–2448. <https://doi.org/10.1016/j.jacc.2015.04.024>

23. Kaur, N., Konrad, M., Hajek, A., Smith, L., & Kostev, K. (2024). Hospital Length of Stay and Associated Factors in Adult Patients with Depression in Germany: A Cross-Sectional Study. *Journal of clinical medicine*, 13(15), 4331. <https://doi.org/10.3390/jcm13154331>
24. Kirigia, J. M., Emrouznejad, A., & Sambo, L. G. (2002). Measurement of technical efficiency of public hospitals in Kenya: using Data Envelopment Analysis. *Journal of medical systems*, 26(1), 39–45. <https://doi.org/10.1023/a:1013090804067>
25. kvaliteet. EKI ühendsõnastik 2025. Eesti Keele Instituut, Sõnaveeb 2025. <https://sonaveeb.ee/search/unif/dlall/eki/kvaliteet/1/est>
26. Käärrik, E. Andmeanalüüs II. (2013). Tartu Ülikool. <https://dspace.ut.ee/server/api/core/bitstreams/76953a28-1622-440b-b286-889dcbb7d68e/content>
27. Lampe, H., Hilgers, D. (2015). Trajectories of efficiency measurement: A bibliometric analysis of DEA and SFA. *European Journal of Operational Research*, 240(1), 1-21. <https://doi.org/10.1016/j.ejor.2014.04.041>
28. Lapo-Talledo, G. J., Vera-Vera, M. N., Montes-Escobar, K., Ortiz, V. P., Siteneski, A. (2026). In-hospital mortality and prolonged length of stay of epilepsy and status epilepticus in Ecuador. *Journal of Clinical Neuroscience*, 150. <https://doi.org/10.1016/j.jocn.2026.112050>
29. Leandro-Merhi, V. A., Silva de Resende, A. M., Stopiglia, L. S., Mazzini, L. R., Braga de Aquino, J. L. (2026). Application of nutritional screening instruments and their relationship with length of hospital stay of older adult in-patients: model adjusted for the type of disease. *Geriatric Nursing*, 69 <https://doi.org/10.1016/j.gerinurse.2026.103814>
30. Mosfeldt, M., Holtenius, J., Berg, H. E., Enocson, A. (2026). Development of a new tool for prediction of hospital length of stay and intensive care needs in trauma patients using Maschine Learning. *Injury*, 57(5). <https://doi.org/10.1016/j.injury.2026.113047>
31. Navarro-Espigares, J. L., & Torres, E. H. (2011). Efficiency and quality in health services: a crucial link. *The Service Industries Journal*, 31(3), 385–403. <https://doi.org/10.1080/02642060802712798>
32. Newman, L., Harris, V., Evans, L. J., & Beck, A. (2018). Factors Associated with Length of Stay in Psychiatric Inpatient Services in London, UK. *The Psychiatric quarterly*, 89(1), 33–43. <https://doi.org/10.1007/s11126-017-9498-7>
33. Nordström, P., Gustafson, Y., Michaëlsson, K., & Nordström, A. (2015). Length of hospital stay after hip fracture and short term risk of death after discharge: a total cohort

- study in Sweden. *BMJ (Clinical research ed.)*, 350, h696. <https://doi.org/10.1136/bmj.h696>
34. OECD. (2024). *Rethinking Health System Performance Assessment: A Renewed Framework*, *OECD Health Policy Studies*. OECD Publishing. <https://doi.org/10.1787/107182c8-en>
35. O'Neill, L., Rauner, M., Heidenberger, K., & Kraus, M. (2008). A cross-national comparison and taxonomy of DEA-based hospital efficiency studies. *Socio-Economic Planning Sciences*, 42(3). <https://doi.org/10.1016>
36. Ravindran, B., Korandiarkunnel Paul, F., & Vyakarnam, P. (2021). Acute upper airway obstruction due to tonsillitis necessitating emergency cricothyroidotomy. *BMJ case reports*, 14(7), e242500. <https://doi.org/10.1136/bcr-2021-242500>
37. Ronco, C., Haapio, M., House, A. A., Anavekar, N., & Bellomo, R. (2008). Cardiorenal syndrome. *Journal of the American College of Cardiology*, 52(19), 1527–1539. <https://doi.org/10.1016/j.jacc.2008.07.051>
38. Parry, S. 2022. *To Offset or Not: Using Offsets in Count Models*. <https://cscu.cornell.edu/wp-content/uploads/offsets.pdf>
39. Snow, R., Shamshad, A., Helliwell, A., Wendell, L. C., Thompson, B. B., Furie, K. L., Reznik, M. E., & Mahta, A. (2024). Predictors of hospital length of stay and long-term care facility placement in aneurysmal subarachnoid hemorrhage. *World Neurosurgery*: X, 22, 100320. <https://doi.org/10.1016/j.wnsx.2024.100320>
40. Standfield, L., Comans, T., & Scuffham, P. (2014). Markov modeling and discrete event simulation in health care: a systematic comparison. *International journal of technology assessment in health care*, 30(2), 165–172. <https://doi.org/10.1017/S0266462314000117>
41. Stefko, R., Gavurova, B., & Korony, S. (2016). Efficiency Measurement In Healthcare Work Management Using Malmquist Indices. *Polish Journal of Management Studies*, 13(1), 168-180. <https://doi.org/10.17512/pjms.2016.13.1.16>
42. Stone, K., Zwiggelaar, R., Jones, P., & Mac Parthaláin, N. (2022). A systematic review of the prediction of hospital length of stay: Towards a unified framework. *PLOS digital health*, 1(4), e0000017. <https://doi.org/10.1371/journal.pdig.0000017>
43. Suumann, K. (2025). *Eesti haiglavõrgu arengukava haiglase tehnilise efektiivsuse hindamine COVID-19 taustal*. (Bakalaureusetöö, Tallinna Tehnikaülikool)

44. Tamirat, K.S., Andargie, G. & Babel, Y.A. (2020). Factors influencing the length of hospital stay during the intensive phase of multidrug-resistant tuberculosis treatment at Amhara regional state hospitals, Ethiopia: a retrospective follow up study. *BMC Public Health* 20, 1217. <https://doi.org/10.1186/s12889-020-09324-x>
45. Tervise Arengu Instituut. Haiglavõrgu arengukava haiglad. Mõisted. (2025). <https://statistika.tai.ee/Resources/PX/Databases/Andmebaas/04THressursid/11HAHaiglad/HHinfo.htm>
46. Tervise ja Heaolu Infosüsteemide Keskus. (2026). RHK (rahvusvaheline haiguste klassifikatsioon). Teabekeskus. <https://teabekeskus.tehik.ee/et/terminoloogiastandardid/rhk>
47. Tervisekassa. Kõik teenused. (2026). <https://tervisekassa.ee/koik-teenused>
48. Tervisestatistika ja terviseuuringute andmebaas. (2025). *HH03: Haiglase kulud*. Tervise Arengu Instituut. https://statistika.tai.ee/pxweb/et/Andmebaas/Andmebaas__04THressursid__11HAHaiglad/HH03.px/table/tableViewLayout2/
49. Tervisestatistika ja terviseuuringute andmebaas. (2025). *RV50: Ravivoodite kasutamine haigla liigi järgi*. Tervise Arengu Instituut. https://statistika.tai.ee/pxweb/et/Andmebaas/Andmebaas__04THressursid__02Ravivoodid__01Aastastatistika/RV50.px/table/tableViewLayout2/
50. Tervisestatistika ja terviseuuringute andmebaas. (2025). *THT013: Tervishoiuasutuste kõik töötajad ja tervishoiutöötajad tervishoiuteenuse osutaja ja omaniku liigi järgi*. Tervise Arengu Instituut. https://statistika.tai.ee/pxweb/et/Andmebaas/Andmebaas__04THressursid__05Tootajad/THT013.px/table/tableViewLayout2/
51. Tervisestatistika ja terviseuuringute andmebaas. (2025). *TK111: Tervishoiuteenuse osutajate tulud tervishoiuteenuse osutaja liigi järgi (tuhat eurot)*. Tervise Arengu Instituut. https://statistika.tai.ee/pxweb/et/Andmebaas/Andmebaas__04THressursid__08MajandusTegevus__08TTOtuludKulud/TK111.px/table/tableViewLayout2/
52. Tervisestatistika ja terviseuuringute andmebaas. (2026). *TTO20: Haiglad omaniku liigi, haigla liigi ja maakonna järgi*. Tervise Arengu Instituut. https://statistika.tai.ee/pxweb/et/Andmebaas/Andmebaas__04THressursid__01TTOsutajad/TTO20.px/table/tableViewLayout2/
53. Varabyova, Y., & Schreyögg, J. (2013). International comparisons of the technical efficiency of the hospital sector: Panel data analysis of OECD countries using parametric and non-parametric approaches. *Health Policy*, 112(1-2). <https://doi.org/10.1016>

54. Ver Hoef, J.M. ja Boveng, P.L. (2007). QUASI-POISSON VS. NEGATIVE BINOMIAL REGRESSION: HOW SHOULD WE MODEL OVERDISPERSED COUNT DATA?. *Ecology*, 88, 2766-2772. <https://doi.org/10.1890/07-0043.1>
55. Võrk, A. Mikroökonomieetria loengumaterjal. (2012). Tartu Ülikool. https://www.researchgate.net/publication/280012070_Mikroökonomieetria_konspekt
56. World Health Organization. (2000). *The World Health Report 2000: Health Systems: Improving Performance*. <https://www.who.int/publications/i/item/924156198X>
57. World Health Organization. (2010). *The World Health Report 2010: Health Systems Financing: The path to universal coverage*. <https://www.who.int/publications/i/item/9789241564021>
58. Worthington A. C. (2004). Frontier efficiency measurement in health care: a review of empirical techniques and selected applications. *Medical care research and review: MCRR*, 61(2), 135–170. <https://doi.org/10.1177/1077558704263796>

Lisad

Lisa A

Töös kasutatud mõisted ja nende lühendid

Mõiste	Lühend
Tartu Ülikooli Kliinikum	TÜK
Põhja-Eesti Regionaalhaigla	PERH
Ida-Tallinna Keskhaigla	ITK
Lääne-Tallinna Keskhaigla	LTK
Ida-Viru Keskhaigla	IVKH
Pärnu Haigla	PH
Viljandi Haigla	VH
<i>Data Envelopment Analysis</i> ehk andmeraja analüüs	DEA
<i>Stochastic Frontier Analysis</i> ehk stohhastiline piiranalüüs	SFA
<i>Hospital lenght of stay</i> ehk haiglas viibimise aeg	HLOS

Allikas: autori koostatud

Lisa B*Teenuste koodid ja nende tähendused*

teenuse kood	tähendus
2047	järeldravi
2065	sisehaigused
2066	kirurgia
2070	i astme intensiivravi
2071	ii astme intensiivravi
2072	iii astme intensiivravi
2073	iii a astme intensiivravi
2075	insuldiravi voodipäev
4326	covid-19 statsionaarse ravi voodipäev
4327	covid-19 ii astme intensiivravi voodipäev
4328	covid-19 iii või iiia astme intensiivravi
2026	sünnitusabi
2058	akuutpsühhiaatria (tahtest olenematu ravi)

Allikas: Eesti Tervisekassa, 2026

Lisa C

Haiglas viibimise kestus kardioloogia eriala patsientide seas negatiivse binoomudeliga.

x_i	β_i	std.error	p-väärtus	e^β
vabaliige	1,737	0,815	0,033	5,682
diagnoosB99	2,131	0,873	0,015	8,423
diagnoosI33	1,672	0,822	0,042	5,325
diagnoosI97	2,105	0,922	0,022	8,210
diagnoosK56	1,899	0,864	0,028	6,678
aasta2025	0,025	0,008	0,002	1,025
log(kaugus_km)	-0,053	0,003	0,000	0,949
raviasutusLTK	0,269	0,020	0,000	1,308
raviasutusPH	0,604	0,018	0,000	1,829
raviasutusPERH	0,315	0,013	0,000	1,371
raviasutusIVKH	0,193	0,017	0,000	1,213
raviasutusTÜK	0,274	0,014	0,000	1,316
suguNaine	-0,040	0,009	0,000	0,960
teenus2065	-0,864	0,016	0,000	0,422
teenus2066	-0,144	0,071	0,044	0,866
teenus2070	-0,685	0,018	0,000	0,504
teenus2071	-0,634	0,018	0,000	0,530
teenus2072	-0,501	0,021	0,000	0,606
teenus2073	-0,149	0,033	0,000	0,862
vanuseruhm30-34	0,396	0,119	0,001	1,485
vanuseruhm40-44	0,311	0,111	0,005	1,364
vanuseruhm45-49	0,220	0,110	0,046	1,246
vanuseruhm50-54	0,240	0,109	0,027	1,272
vanuseruhm55-59	0,274	0,109	0,012	1,315
vanuseruhm60-64	0,381	0,108	0,000	1,464
vanuseruhm65-69	0,481	0,108	0,000	1,618
vanuseruhm70-74	0,575	0,108	0,000	1,777
vanuseruhm75-79	0,626	0,108	0,000	1,870
vanuseruhm80-84	0,693	0,108	0,000	1,999
vanuseruhm85+	0,732	0,108	0,000	2,079

Allikas: Eesti Tervisekassa, autori koostatud

Lisa D

Haiglas viibimise kestus pulmonoloogia eriala patsientide seas negatiivse binoommudeliga.

x_i	β_i	std.error	p-väärtus	e^{β}
vabaliige	2,650	0,290	0,000	14,157
diagnoosA15	2,137	0,275	0,000	8,471
diagnoosA16	1,778	0,280	0,000	5,918
diagnoosA18	2,355	0,319	0,000	10,534
diagnoosA19	2,656	0,368	0,000	14,245
diagnoosA31	0,925	0,301	0,002	2,522
diagnoosA40	1,080	0,290	0,000	2,946
diagnoosA42	1,058	0,444	0,017	2,882
diagnoosA48	0,688	0,289	0,017	1,991
diagnoosB20	2,142	0,301	0,000	8,515
diagnoosB44	0,684	0,329	0,038	1,981
diagnoosB59	0,737	0,308	0,017	2,090
diagnoosB90	1,076	0,293	0,000	2,933
diagnoosC48	0,844	0,420	0,044	2,326
diagnoosC56	0,679	0,328	0,038	1,972
diagnoosC92	-1,516	0,500	0,002	0,219
diagnoosD12	-1,655	0,758	0,029	0,191
diagnoosD71	1,714	0,447	0,000	5,551
diagnoosE84	0,600	0,299	0,045	1,823
diagnoosF11	1,915	0,446	0,000	6,784
diagnoosG06	1,419	0,367	0,000	4,134
diagnoosG23	1,535	0,408	0,000	4,642
diagnoosI63	0,635	0,287	0,027	1,887
diagnoosI70	1,045	0,370	0,005	2,844
diagnoosJ13	0,547	0,274	0,046	1,729
diagnoosJ36	1,401	0,401	0,000	4,058
diagnoosJ67	0,779	0,321	0,015	2,180
diagnoosJ85	1,034	0,284	0,000	2,814
diagnoosJ86	1,069	0,285	0,000	2,913
diagnoosJ95	0,998	0,335	0,003	2,712
diagnoosK10	2,054	0,502	0,000	7,798
diagnoosK21	0,938	0,380	0,013	2,557
diagnoosK26	0,874	0,362	0,016	2,396
diagnoosK70	0,953	0,449	0,034	2,595
diagnoosK81	1,726	0,339	0,000	5,618
diagnoosK90	1,248	0,534	0,019	3,484
diagnoosL73	1,388	0,535	0,010	4,007
diagnoosL97	1,011	0,449	0,024	2,749
diagnoosM34	1,091	0,326	0,001	2,977
diagnoosM46	1,058	0,429	0,014	2,881
diagnoosN45	0,875	0,412	0,034	2,400
diagnoosS06	1,121	0,319	0,000	3,069
diagnoosS72	1,538	0,300	0,000	4,656

x_i	β_i	std.error	p-väärtus	e^β
diagnoosT27	0,689	0,305	0,024	1,993
diagnoosT28	0,923	0,326	0,005	2,516
diagnoosT80	1,088	0,318	0,035	2,969
diagnoosZ03	1,560	0,285	0,000	4,761
diagnoosZ51	1,640	0,413	0,000	5,155
log(kaugus_km)	-0,021	0,006	0,000	0,979
raviasutusPERH	-0,172	0,029	0,000	0,841
raviasutusIVKH	0,073	0,030	0,014	1,076
raviasutusTÜK	0,085	0,029	0,003	1,089
raviasutusVH	-0,144	0,060	0,017	0,866
suguNaine	-0,568	0,154	0,000	0,567
teenus2065	-0,580	0,021	0,000	0,560
teenus2066	-0,221	0,071	0,002	0,802
teenus2070	-0,305	0,028	0,000	0,737
teenus2071	-0,242	0,027	0,000	0,785
vanuseruhm25-29	-0,646	0,137	0,000	0,524
vanuseruhm25-29:suguNaine	0,665	0,212	0,002	1,944
vanuseruhm30-34	-0,463	0,130	0,000	0,630
vanuseruhm30-34:suguNaine	0,450	0,212	0,034	1,568
vanuseruhm35-39	-0,412	0,112	0,000	0,662
vanuseruhm40-44	-0,376	0,110	0,001	0,686
vanuseruhm40-44:suguNaine	0,418	0,184	0,023	1,518
vanuseruhm50-54:suguNaine	0,559	0,171	0,001	1,749
vanuseruhm55-59:suguNaine	0,756	0,165	0,000	2,129
vanuseruhm60-64:suguNaine	0,408	0,163	0,012	1,504
vanuseruhm65-69:suguNaine	0,432	0,160	0,007	1,541
vanuseruhm70-74:suguNaine	0,447	0,159	0,005	1,564
vanuseruhm75-79:suguNaine	0,639	0,159	0,000	1,895
vanuseruhm80-84:suguNaine	0,510	0,160	0,001	1,665
vanuseruhm85+:suguNaine	0,449	0,159	0,005	1,566

Allikas: Eesti Tervisekassa, autori koostatud

Lisa E

Haiglas viibimise kestus nefroloogia eriala patsientide seas negatiivse binoomudeliga

x_i	β_i	std.error	p-väärtus	e^{β}
vabaliige	1,749	0,757	0,021	5,750
diagnoosA41	0,845	0,292	0,004	2,329
diagnoosA46	0,794	0,310	0,011	2,212
diagnoosB23	1,038	0,348	0,003	2,823
diagnoosB44	1,386	0,463	0,003	3,998
diagnoosC22	1,137	0,429	0,008	3,116
diagnoosC90	0,757	0,306	0,013	2,133
diagnoosE10	0,580	0,293	0,048	1,785
diagnoosE83	1,259	0,464	0,007	3,520
diagnoosE85	0,632	0,306	0,039	1,881
diagnoosI15	0,963	0,382	0,012	2,620
diagnoosI33	1,180	0,333	0,000	3,256
diagnoosI60	1,803	0,389	0,000	6,067
diagnoosI67	1,425	0,434	0,001	4,158
diagnoosI70	0,728	0,307	0,018	2,072
diagnoosJ10	1,091	0,322	0,001	2,978
diagnoosJ12	0,757	0,373	0,043	2,132
diagnoosJ15	0,614	0,305	0,044	1,847
diagnoosJ32	1,278	0,465	0,006	3,589
diagnoosJ85	1,331	0,427	0,002	3,784
diagnoosK27	0,978	0,419	0,020	2,658
diagnoosK57	1,078	0,359	0,003	2,938
diagnoosK59	1,561	0,471	0,001	4,762
diagnoosK70	0,732	0,356	0,040	2,079
diagnoosK80	0,660	0,313	0,035	1,934
diagnoosK85	1,354	0,320	0,000	3,872
diagnoosK90	0,890	0,449	0,047	2,434
diagnoosM05	0,897	0,324	0,006	2,453
diagnoosM46	1,810	0,402	0,000	6,112
diagnoosM70	0,720	0,311	0,020	2,054
diagnoosM71	1,263	0,430	0,003	3,535
diagnoosM86	1,119	0,537	0,037	3,062
diagnoosN05	1,078	0,426	0,011	2,938
diagnoosN07	1,049	0,383	0,006	2,856
diagnoosN21	1,031	0,367	0,005	2,805
diagnoosN99	1,330	0,429	0,002	3,780
diagnoosO14	1,245	0,397	0,002	3,473
diagnoosQ05	1,197	0,565	0,034	3,310
diagnoosS42	1,025	0,407	0,012	2,787
diagnoosS72	1,137	0,405	0,005	3,117
diagnoosT39	1,541	0,367	0,000	4,667
diagnoosT75	1,122	0,428	0,009	3,072
diagnoosT79	0,913	0,317	0,004	2,493

x_i	β_i	std.error	p-väärtus	e^β
diagnoosT85	0,885	0,378	0,019	2,423
aasta2025	0,059	0,020	0,003	1,061
log(kaugus_km)	0,025	0,006	0,000	1,026
raviasutusPERH	0,059	0,027	0,026	1,061
raviasutusTÜK	0,361	0,029	0,000	1,435
vanuserühm35–39	0,321	0,154	0,037	1,379
vanuserühm40–44	0,367	0,144	0,011	1,443
vanuserühm40–44:suguNaine	-0,419	0,203	0,038	0,657
vanuserühm45–49	0,319	0,148	0,031	1,376
vanuserühm55–59	0,402	0,140	0,004	1,495
vanuserühm60–64	0,470	0,136	0,001	1,600
vanuserühm65–69	0,369	0,138	0,007	1,447
vanuserühm70–74	0,552	0,136	0,000	1,736
vanuserühm75–79	0,595	0,136	0,000	1,813
vanuserühm80–84	0,435	0,139	0,002	1,544
vanuserühm85+	0,507	0,140	0,000	1,660

Allikas: Eesti Tervisekassa, autori koostatud


Lisa F

Haiglas viibimise kestus diagnoosi mõju arvestamata log-lineaarse mudeliga


x_i	β_i	std.error	p-väärtus	e^{β}
vabaliige	2,261	0,087	0,000	9,588
erialaNefroloogia	0,691	0,015	0,000	1,995
erialaPulmonoloogia	0,533	0,013	0,000	1,705
log(kaugus_km)	-0,050	0,003	0,000	0,951
raviasutusTÜK	0,025	0,010	0,013	1,025
teenus2065	-1,186	0,019	0,000	0,305
teenus2066	-0,392	0,067	0,000	0,676
teenus2070	-0,819	0,022	0,000	0,441
teenus2071	-0,775	0,022	0,000	0,461
teenus2072	-0,625	0,025	0,000	0,535
teenus2073	-0,331	0,037	0,000	0,718
vanuserühm30–34	0,287	0,103	0,006	1,332
vanuserühm30–34:suguNaine	-0,312	0,153	0,042	0,732
vanuserühm35–39	0,251	0,096	0,009	1,285
vanuserühm40–44	0,229	0,091	0,012	1,257
vanuserühm45–49	0,260	0,090	0,004	1,296
vanuserühm50–54	0,184	0,088	0,036	1,202
vanuserühm55–59	0,239	0,087	0,006	1,270
vanuserühm60–64	0,359	0,086	0,000	1,432
vanuserühm65–69	0,417	0,086	0,000	1,517
vanuserühm70–74	0,498	0,086	0,000	1,645
vanuserühm75–79	0,519	0,086	0,000	1,681
vanuserühm80–84	0,551	0,087	0,000	1,735
vanuserühm85+	0,595	0,087	0,000	1,813

Allikas: Eesti Tervisekassa, autori koostatud


Lisa G



Kardioloogia eriala negatiivse binoommudeli jääkide hajuvuse histogram. Allikas: Eesti Tervisekassa, autori koostatud




Pulmonoloogia eriala negatiivse binoommudeli jääkide hajuvuse histogram. Allikas: Eesti Tervisekassa, autori koostatud



Simulated values, red line = fitted model. p-value (two.sided) = 0.808

Nefroloogia eriala negatiivse binoommodeli jääkide hajuvuse histogram. Allikas: Eesti Tervisekassa, autori koostatud



Simulated values, red line = fitted model. p-value (two.sided) = 0.728

Ilma diagnoosi mõjuta log-lineaarse mudeli jääkide hajuvuse histogram. Allikas: Eesti Tervisekassa, autori koostatud

Lisa H

RHK-10 ehk rahvusvaheliste haiguste klassifikatsioon

Diagnoosid	Klassifikatsioon
A00–B99	Teatavad nakkus- ja parasiithaigused
C00–D48	Kasvajad
D50–D89	Vere- ja vereloomeelundite haigused ning teatavad immuunmehhanismidega seotud haigusseisundid
E00–E90	Siseseretsiooni-, toitumis- ja ainevahetushaigused
F00–F99	Psüühika- ja käitumishäired
G00–G99	Närvisüsteemihaigused
H00–H69	Silma- ja silmamanuste haigused
H60–H95	Kõrva- ja nibujätkehaigused
I00–I99	Vereringeelundite haigused
J00–J99	Hingamiselundite haigused
K00–K93	Seedeelundite haigused
L00–L99	Naha- ja nahaaluskoe haigused
M00–M99	Lihaskonna ja sidekoehaigused
N00–N99	Kuse-suguelundite haigused
O00–O99	Rasedus, sünnitus ja sünnitusjärgne periood
P00–P96	Sünniperioodis tekkivad teatavad seisundid
Q00–Q99	Kaasasündinud väärarendid, deformatsioonid ja kromosoomianomaaliad
R00–R99	Mujal klassifitseerimata sümptomid, tunnused ja kliiniliste ning laboratoorsete leidude hálbed
S00–T98	Vigastused, mürgistused ja teatavad muud välispõhjuste toime tagajärjed
V01–Y98	Haigestumise ja surma välispõhjused
Z00–Z99	Tervise seisundit mõjustavad tegurid ja kontaktid terviseteenistusega

Allikas: TEHIKu teabekeskus, 2026

Summary

HOSPITAL LENGTH OF STAY AS A MEASURE OF EFFICIENCY

Marleen Mändul

The aim of this bachelor's thesis was to provide an overview of the research on hospital efficiency in other parts of the world and in Estonia, using previous works on a similar topic for explanation. The main focus was on the hospital length stay and the factors affecting it. The knowledge gained during the research was applied to the data of the Estonian Health Insurance Fund to study the length of stay in three different specialties and the factors affecting it.

Hospital efficiency is understood as factors related to both the hospital and the patient, such as the number of beds, the number of outpatient appointments, education and research, and the balance of costs and revenues. The most widely used methods for studying hospital efficiency are time series analysis (DEA method) and stochastic frontier analysis (SFA method), one of which is non-parametric and the other parametric. Most studies have used both methods and compared their results, because unlike the SFA method, the DEA method does not take into account the possibility of errors in the data. The choice of input and output variables is important in both methods, which are also largely similar. The main input variables are the number of beds and staff, and the output variables are outpatient and inpatient admissions.

Hospital length of stay is studied using several statistical methods, the most common of which are statistical models, where the length of stay in the hospital is used as the dependent variable and various patient-related factors or other indicators are used as input variables.

The author of the paper used a negative binomial model on the data from the Estonian Health Insurance Fund to study the length of stay in hospitals and the factors affecting it amongst cardiology, pulmonology, and nephrology patients in 2024–2025.. In all models, the patient's gender, age group, diagnoses, type of service, treatment hospital, and the distance of the patient's county center to the hospital were statistically significant factors affecting the hospital length of stay. Diagnoses were the strongest factors and increased the length of stay up to 2 times in almost every model, and up to 8 times in the cardiology specialty. Women had shorter hospital stays than men, and HLOS increased with age. Hospitals affected length of stay differently among patients of different specialties, but still to a statistically significant extent. In the future, the author suggests using data which also includes the patient's admission and discharge time. To avoid unnecessary noise in the models, the ICD-10 codes should be used instead of the diagnosis codes.

Hospital length of stay is an important indicator of efficiency, which is also influenced by several socio-demographic indicators related to the patient. Monitoring the length of hospital stay is necessary to identify bottlenecks in the system and plan treatment in a way that would be as beneficial as possible for both the hospital and the patients.

Lihtlitsents lõputöö reprodutseerimiseks ja üldsusele kättesaadavaks tegemiseks

Mina, Marleen Mändul,

1. annan Tartu Ülikoolile tasuta loa (lihtlitsentsi) minu loodud teose Haiglas viibimise kestus kui efektiivsuse mõõtmise vahend, mille juhendaja on Andres Vörk, reprodutseerimiseks eesmärgiga seda säilitada, sealhulgas lisada digitaalarhiivi DSpace kuni autoriõiguse kehtivuse lõppemiseni.
2. Annan Tartu Ülikoolile loa teha punktis 1 nimetatud teos üldsusele kättesaadavaks Tartu Ülikooli veebikeskkonna, sealhulgas digitaalarhiivi DSpace kaudu Creative Commons'i litsentsiga CC BY NC ND 3.0, mis lubab autorile viidates teost reprodutseerida, levitada ja üldsusele suunata ning keelab luua tuletatud teost ja kasutada teost ärieesmärgil, kuni autoriõiguse kehtivuse lõppemiseni.
3. Olen teadlik, et punktides 1 ja 2 nimetatud õigused jäävad alles ka autorile.
4. Kinnitan, et lihtlitsentsi andmisega ei riku ma teiste isikute intellektuaalomandi ega isikuandmete kaitse õigusaktidest tulenevaid õigusi.

Marleen Mändul

14.05.2026