

TARTU ÜLIKOOL

LOODUS- JA TÄPPISTEADUSTE VALDKOND

MATEMAATIKA JA STATISTIKA INSTITUUT

Lotta-Lorette Kalmaru

**Mullatemperatuuride hindamine
meteoroloogiliste ja kaugseire andmete põhjal**

Matemaatiline statistika

Bakalaureusetöö (9 EAP)

Juhendajad: MSc Tiit Sepp, knd Toomas Raus

TARTU 2024

MULLATEMPERATUURIDE HINDAMINE METEOROLOOGILISTE JA KAUGSEIRE ANDMETE PÕHJAL

Bakalaureusetöö

Lotta-Lorette Kalmaru

Lühikokkuvõte

Mullatemperatuur on oluline keskkonnaparameter informeeritud otsuste tegemiseks agronomias ja mitmes teises valdkonnas. Bakalaureusetöö eesmärk on luua Eestis mullatemperatuuri prognoosimise mudel teiste keskkonnaparametrite alusel. Lisaks võrreldakse töö käigus olemasolevaid mullatemperatuuride hindamise lahendusi lokaalsete mõõtmisseadmete kaudu kogutud mullatemperatuuridega.

Olemasolevate lahenduste analüüsis selgus, et satelliitide kaugseire andmetes olid suured puudujäägid. Järelanalüüsi andmestiku mullatemperatuurid olid see-eest mõõtmistele üsna sarnased, kuid kättesaadavad kolmekuuse viiteajaga. Töö tulemusena loodi lineaarsed regressioonimudelid, mis õhutemperatuurist, lumikatte olemasolust ja sesoonsusest lähtuvalt leiavad mullatemperatuuri 5 cm sügavusel maapinnast. Mudeldamine jagati vastavalt õhutemperatuurile kaheks, kusjuures plusskraadide korral hinnati lineaarse regressioonimudeli kordajad heteroskedastilisuse tõttu kaalutud vähimruutude meetodiga.

CERCS teaduseriala: P160 Statistika, operatsioonanalüüs, programmeerimine, finants- ja kindlustusmatemaatika. P180 Metroloogia, instrumentatsioon. B390 Taimekasvatus, aiandus, taimekaitsevahendid, taimehaigused.

Märksõnad: Mullatemperatuur, maapinnatemperatuur, agronomia, meteoroloogia, kaugseire, järelanalüüs, regressioonanalüüs.

PREDICTING SOIL TEMPERATURES BASED ON METEOROLOGICAL AND REMOTE SENSING DATA

Bachelor thesis

Lotta-Lorette Kalmaru

Abstract

Soil temperature is an important environmental parameter for making informed decisions in agronomy and several other fields. The bachelor's thesis aims to create a model for predicting soil temperature in Estonia based on other environmental parameters. In addition, existing solutions for assessing soil temperatures are compared with soil temperatures collected from local measuring devices.

The analysis of existing solutions uncovered flaws in remote sensing satellite data. The soil temperatures from a reanalysis dataset were similar to the local measurements. However, they were available with a three-month delay. As a result of the work, linear regression models were created, which, based on air temperature, the presence of snow cover, and seasonality, estimate the soil temperature at a depth of 5 cm from the ground surface. Modelling was divided according to air temperature and the coefficients of the model for positive temperatures were evaluated using the weighted least squares method due to heteroscedasticity.

CERCS research specialisation: P160 Statistics, operation research, programming, actuarial mathematics. P180 Metrology, physical instrumentation. B390 Phytotechny, horticulture, crop protection, phytopathology.

Key Words: Soil temperature, ground temperature, agronomy, meteorology, remote sensing, reanalysis, regression analysis.

Sisukord

Sissejuhatus	5
1 Mullatemperatuur ja selle mõõtmine	7
1.1 Mullatemperatuuri lokaalne mõõtmine	7
1.2 Mullatemperatuuri mõõtmine kaugseire abil	7
1.3 Mullatemperatuur järelanalüüsi andmestikes	8
2 Lineaarne regressioonimudel	10
2.1 Mitme muutujaga lineaarne regressioon	11
2.2 Mudeli eelduste kontrollimine	12
2.3 Kaalutud vähimruutude meetod	13
3 Mullatemperatuuri andmestikkude ülevaade ja võrdlus	15
3.1 Ülevaade andmetest	15
3.1.1 Mullatemperatuuri jaotus alusandmestiku põhjal	18
3.2 Olemasolevate mullatemperatuuri hindamise lahenduste analüüs . .	20
4 Mullatemperatuuri mudeldamine	25
4.1 Mullatemperatuuri mudeldamine meteoroloogiliste andmete põhjal	26
4.1.1 Mudeli argumenttunnuste valik	27
4.1.2 Mudeli arendus	29
4.1.3 Mudeli lõplik kuju	32
4.1.4 Mudeli valideerimine	36
4.2 Mudelid mullatemperatuuri tuletamiseks maapinnatemperatuurist .	38

Kokkuvõte	42
Kasutatud allikad	44
Lisa 1. Alusandmestiku mõõtepunktid	47
Lisa 2. Mudeli argumenttunnuste multikollineaarsuse näitajad	48
Lisa 3. Temperatuuride autokorrelatsioonid	49

Sissejuhatus

Mullatemperatuur on oluline sisend informeeritud otsuste tegemiseks erinevates valdkondades. Eriti oluline on see agronoomia ja taimekasvatusega seotud tegevusaladel, kus mullatemperatuurist lähtuvalt leitakse taimekultuuridele sobivat külvi- ja künniaega ning hinnatakse taimede kasvutingimusi. Agronoomias on vaja, et mullatemperatuuri hinnangud arvestaks konkreetse põllu asukohast mõjutatud teiste keskkonnaparameetritega. Samuti on oluline, et need hinnangud oleks kättesaadavad iga päeva jaoks.

Mullatemperatuuri hinnanguid saab näiteks lokaalsete mõõtmisseadmete, satelliitide seireandmete või mudelite põhjal tehtud prognooside kaudu. Lokaalsete mõõtmisseadmete paigaldamine, hooldus ja järelevalve võib aga osutada ressursikulukaks. Lisaks on varasemad uuringud näidanud, et seireandmed ei ole igapäevaste temperatuuri hinnangute jaoks alati piisavalt kvaliteetsed (Maanus Kullamaa, 2015).

Seega on vajadus mudelile, mis suudab igapäevaselt prognoosida mullatemperatuuri. Käesoleva töö peamine eesmärk on välja töötada sobiv mudel, mille abil anda keskkonnaparameetrite põhjal hinnang mullatemperatuurile 5 cm sügavusel Eesti piires. Mullatemperatuuri mudeldamisel tuleb arvestada piirangutega, et hiljem prognoositavas asukohas tegeliku mullatemperatuuri harilikult mõõta ei saa ja mudelis kasutatavad teised argumenttunnused peavad olema võimalikult lihtsalt kättesaadavad. Need piirangud tulenevad mudeli kasutusvõimalustest agronoomias.

Varasemad uuringud on näidanud, et õhu- ja mullatemperatuuri vahel on tugev lineaarne seos (Zheng, Hunt ja Running, 1993; Hu *et al.*, 2020) ja seetõttu kasutatakse mullatemperatuuri mudeldamiseks lineaarseid regressioonimudeleid. Mudelit luues tuleb arvesse võtta ka mulla- ja õhutemperatuuri seose erinevusi talve- ja suveperioodidel. Seega on vaja teha eraldi lineaarne regressioonimudel mõlema perioodi jaoks. Mudeli argumenttunnuste kordajate hindamiseks kasutatakse töös kümne Eesti piires asuva lokaalse mõõtmisseadme andmeid, mis on kogutud

põldudele asetatud mullasensorite ja ilmajaamade mõõtmisseadmetega.

Esimeses peatükis antakse täpsem ülevaade mullatemperatuuri mõõtmiste võimalusest. Teises peatükis tutvustatakse antud töös kasutatavat statistilist metoodikat. Töö kolmandas peatükis on kajastatud kasutatud andmete ülevaade ja lisaks antakse hinnang olemasolevatele mullatemperatuuri hindamise lahendustele. Töö viimases peatükis on kirjeldatud mullatemperatuuri prognoosimise mudelite arendust ja lõpptulemusi.

Bakalaurusetööd koostades tehti koostööd ettevõtetega STACC OÜ¹ ja eAgronom². Antud uurimist oli võimalik läbi viia tänu andmeteaduse agentuuri STACC OÜ ressurssidele ja suunistele. Tänu väärrib samuti täppispõllumajandusega tegelev ettevõtte eAgronom, kes jagas mullasensoritega kogutud andmeid ja pakkus eksperitiisi agronoomiaga seotud küsimuste korral. Nende abi oli käesoleva töö koostamisel olulise tähtsusega.

¹<https://stacc.ee/>

²<https://www.eagronom.com/>

1 Mullatemperatuur ja selle mõõtmine

Käesolev töö keskendub mullatemperatuurile agronoomiaga seotud kasutusvõimalusi aluseks võttes. Vestluses Eesti täppispõllumajanduse ettevõtte eAgronom³ agronoomide juhi Piibe Vaheriga selgus, et suurem osa põllukultuuridest külvatakse Eestis mulda umbes 5 cm sügavusele ja seetõttu käsitletakse ka antud töös ainult mulla pealmiste kihtide temperatuuri sügavustel 0 kuni 5 sentimeetrit (autori intervjuu, August, 2023).

1.1 Mullatemperatuuri lokaalne mõõtmine

Eesti Keskkonnaagentuuri ilmajaamades mõõdetakse mullatemperatuuri maaga pidevas kontaktis olevate termomeetrite ja andurite abil. Need mõõtmisseaded on paigutatud ettenähtud mõõtmisväljakul sinna, kuhu ei lange varje. Mõõtmised on olemas ka päevadel, kui maapinnal on lumikate. (Keskkonnaagentuur, kuupäev puudub[c])

Teine levinud meetod mullatemperatuuri mõõtmiseks konkreetsetes asukohtades on spetsiaalsed mullasensordid. Põllumajanduses analüüsitakse mullasensoreid mõõdetud tulemusi eesmärgiga saagikust suurendada ja selle kvaliteeti parandada. (Singh ja Singh, 2020). Kahjuks on selline lähenemine kulukas suurte piirkondade monitoorimiseks, sest paigaldada oleks vaja rohkelt sensoreid.

1.2 Mullatemperatuuri mõõtmine kaugseire abil

Mullatemperatuuri mõõtmine lokaalsete seadmetega suurel alal on ressursikulukas. Seetõttu on päikese-sünkroonsete ning peaagu polaar-orbiidil asuvate satelliitide vaatlused levinud viis suuremal alal mõõtmiste korraldamiseks, kuna sellised satelliidid katavad suuri alasid hea resolutsiooniga ja on maapinna suhtes regulaar-

³<https://www.eagronom.com/>

sete intervallidega ühe ja sama punkti kohal (Zhao ja Li, 2013, lk. 3315). Satelliidid ei mõõda otseselt mullatemperatuuri, vaid maapinnalt peegeldunud soojuskiirgust ehk infrapunakiirgust, millest tuletatakse mudeldamise teel mullatemperatuur maapinna peal (Biferno ja NASA, 30.08.2023).

Alates 1960. aastatest kannavad eri satelliidid mitmeid termilise infrapuna seadmeid, mida sellel eesmärgil kasutatakse. (Li *et al.*, 2023) Näiteks on sellised seadmed Euroopa Kosmoseagentuuri ja Euroopa Meteoroloogiasatelliitide Kasutamise Organisatsiooni (EUMETSAT) ühismissiooni Sentinel-3 satelliitidel ning Ameerika Ühendriikide Geoloogiakeskuse (USGS) ja NASA ühise maavaatlusseeria Landsat satelliitidel. Satelliitide puuduseks on see, et näiteks Eestis on mõõtmised sageda pilvisuse ja satelliitide ülelendude harva sageduse tõttu kohati puudulikud, kuna optiliselt instrumentidel ei ole võimalik soovitud alal seiret teostada (Maanus Kullamaa, 2015). Samuti esineb andmetes suuremaid anomaaliaid, mille tõttu ei saa mõõtmisi usaldada. Anomaaliad tekivad näiteks satelliidi manöövritest mõõtmise ajal või muudest tehnilistest rikestest (Euroopa Kosmoseagentuur, kuupäev puudub).

1.3 Mullatemperatuur järelanalüüsi andmestikes

Lisaks mullatemperatuuri otsestele mõõtmistulemustele kasutatakse temperatuuri hinnangute andmiseks sageli ka järelanalüüsi andmestikke. Need andmestikud on saadud ilmavaatluste, kaugseire ja ilmaennustuse mudelite kombineerimisel. Seetõttu on järelanalüüside andmestikud mingi mõõtmisaja kohta kättesaadavad ajalise viitega.

Yanga *et al.* (2020) töös analüüsiti Qinghai-Tiibeti platool erinevate järelanalüüsi andmestike mullatemperatuuri vastavust reaalsele mõõtmistele. Selle analüüsi tulemusena leiti, et kuigi sarnaste andmestike temperatuurid järgisid reaalse temperatuuride trende üsna hästi, olid mullatemperatuurid enamasti ülehinnatud (Yanga *et al.*, 2020). Tartu Ülikoolis tehtud Annika Annika Velt (2016) bakalaureusetöö

tulemusena leiti, et populaarne järelanalüüsi mudel NCEP-CFSR alahindab Tõraveres mõõdetud maapinnatemperatuure (Annika Velt, 2016). Seega kokkuvõttes ei ole järelanalüüsi mudelite tulemused alati täpsed ja võivad olla mõjutatud regioonile spetsiifilistest teguritest.

2 Lineaarne regressioonimudel

Mullatemperatuuri mudeldamiseks lähtuvalt õhutemperatuurist ja teistest keskkonna parameetritest kasutatakse lineaarset regressiooni. Varasemad uuringud on näidanud, et vähemalt õhu- ja mullatemperatuuri vahel on tugev lineaarne seos (Zheng, Hunt ja Running, 1993; Hu *et al.*, 2020) ja seetõttu peaks regressioonimudel olema sobiv valik selle lineaarse seose põhjal prognooside tegemiseks.

Mudeldamise juures tuleb arvestada teatud kitsenduste ja taustainfoga, mis tulevad vajadusest mudelit kasutada igapäevaste prognooside tegemiseks kogu Eesti piires. Samuti on oluline märkida, et mudeli tehtud prognoose hakkavad kasutama agronoomid ja põllumehed informeeritud otsuse tegemiseks. Arvestada tuleb järgnevate asjaoludega:

- Mudeli eesmärk on leida mullatemperatuuri prognoose samaks päevaks ja vajalike argumenttunnuste kogumise võimalusel ka 1-2 päeva ette.
- Mudel peab olema täpne kevad-, suve- ja sügisperioodidel, kuna sellel ajal toimub suurem osa põllutöid. Talveperioodi täpsus pole tegelikult oluline, kuna siis on maapind niikuinii lume all, kuid antud töös käsitletakse tervikliku ülevaate andmiseks ka talve.
- Mudelit peab olema võimalik kasutada olukorras, kui prognoositavas asukohas tegelikku mullatemperatuuri mõõta ei saa.
- Mudelis kasutatavaid teisi argumenttunnuseid peab olema võimalik hinnata eemalt (ehk asukohas kohapeal mingeid mõõtmiseid ei korraldata).

Nendest kitsendustes tulenevalt välistatakse näiteks olukord, kus mudeli argumenttunnuste hulka kaasatakse eelnevate päevade tegelik mullatemperatuur.

2.1 Mitme muutujaga lineaarne regressioon

Lineaarse regressiooni korral modelleeritakse uuritav tunnus Y argumenttunnuste X_1, X_1, \dots, X_m lineaarse funktsioonina. Edasine lineaarse regressiooni tutvustus on kirjeldatud Ryan, Thomas P. (2009) põhjal.

Lineaarse regressiooni mudeli kuju on

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_m X_m + \epsilon, \quad (1)$$

kus β_0 tähistab vabaliiget ning $\beta_j, j = 1, 2, \dots, m$ tähistavad argumenttunnustele vastavaid kordajaid. Suurus ϵ tähistab mudeli juhuslikku viga.

Lineaarse regressioonimudeli (1) korral hinnatakse mudeli kordajad $\beta_j, j \in 0, 1, 2, \dots, m$ vähimruutude meetodiga, ehk minimiseeritakse avaldist

$$L = \sum_{i=1}^n (Y_i - \beta_0 - \sum_{j=1}^m \beta_j X_{i,j})^2 \quad (2)$$

kordajate β_i kaudu.

Siinkohal tähistab n mudeli parameetrite hindamiseks teadaolevate andmepunktide arvu, i on vastava andmepunkti indeks. Suurus m tähistab argumenttunnuste arvu ning j vastavat argumenttunnust.

Sellele mudelile vastav mudel ennustamiseks on

$$\hat{Y} = \hat{\beta}_0 + \hat{\beta}_1 X_1 + \hat{\beta}_2 X_2 + \dots + \hat{\beta}_m X_m,$$

kus $\hat{\beta}_j, j = 0, 1, 2, \dots, m$ on vähimruutude meetodil hinnatud suurused kordajatele ning \hat{Y} on mudeli hinnang uuritavale tunnusele.

Mudeli jääk i -nda mõõtmise hinnangu \hat{Y}_i , $i \in 0, 1, 2, \dots, n$ korral on suurus

$$\hat{\epsilon}_i = Y_i - \hat{Y}_i,$$

mis on hinnang mudeli juhuslikule veale ϵ .

Mudeli argumenttunnused peavad olema kvantitatiivsed ehk arvulised, kuid ka kvalitatiivseid tunnuseid on võimalik transformatsioonide abil mudelisse kaasata. Kvantitatiivsetest tunnustest tuleb teisendada arvulised binaarsed tunnused. Kui muutujal X on kokku k erinevat võimalikku väärtust, siis tuleb mudelisse kaasata $k - 1$ vastavat binaarset indikaatorit valemiga

$$I_{X=x} = \begin{cases} 1, & \text{kui tegu on kvalitatiivse muutuja } X \text{ väärtusega } x \\ 0, & \text{muidu} \end{cases} .$$

Parameetrite statistilise olulisuse kontrollimiseks kasutatakse kõikjal töös olulisuse nivood $\alpha = 0,05$, kui just ei ole mainitud teisiti.

2.2 Mudeli eelduste kontrollimine

Lineaarse regressioonimudeli koostamisel tuleb arvestada mitme eeldusega. Eeldused on, et

- argumenttunnused või nende kombinatsioonid on uuritava tunnusega lineaarselt seotud,
- mudeli juhuslikud vead ei korreleeru omavahel ehk mudelis puudub autokorrelatsioon,
- mudeli juhuslikud vead on kõikide argumenttunnuste suhtes ühtlase hajuvusega ehk mudelis puudub heteroskedastilisus,

- mudeli juhuslikud vead on normaaljaotusega, mille keskväärtus on 0 ja hajuvus konstantne,
- mudeli argumenttunnuste vahel ei esine multikollineaarsust.

Viimast tingimust, ehk multikollineaarsuse mitteesinemist on lubatud ennustava mudeli korral võtta soovitusena. See tähendab, et mudel, mille ainuke eesmärk on leida hinnanguid või prognoose uuritavale tunnusele, võib sisaldada ka multikollineaarsust. Küll aga ei tohi sellisel juhul mudeli argumenttunnustega seotud kordajat enam tavapäraselt interpreteerida, kuna see võib olla mõjutatud teiste argumenttunnuste kordajatest.

Juhul kui mudelis on autokorrelatsioon või heteroskedastilisus, siis standardtsed valemid parameerite standardvigade arvutamiseks ei sobi ning parameetrite usalduspiirid ei pruugi olla korrektsed.

Jääkide mittekorreleerituse eeldust kontrollitakse Durbin-Watsoni teststatistiku abil. Mudeli jääkide ühtlast hajuvust kontrollitakse hajuvusgraafikutelt, kus on kujutatud mudeli jääke ja uuritavale tunnusele tehtud prognoose.

Mudeli jääkide normaaljaotust kontrollitakse graafikult valimi ja normaaljaotuse kvantiile võrreldes. Kui normaaljaotuse eeldus kehtib, peaksid joonisel kujutatud punktid asuma kõik ühel sirgel.

2.3 Kaalutud vähimruutude meetod

Lineaarse regressiooni kasutamise üheks eelduseks on mudeli jääkide ühtlane hajuvus. Kui see eeldus on rikutud, tuleb mudelis parameetrite hindamisel jääkide erinevaid hajuvusi arvesse võtta. See on saavutatav kaalutud vähimruutude meetodiga, kus mudeli kordajate hindamisel antakse vähem kaalu vaatlustele, kus mudeli jäägid on väga suured.

Kaalitud vähimruutude meetodi korral minimeeritakse avaldise (2) asemel funktsiooni

$$W = \sum_{i=1}^n w_i (Y_i - \beta_0 - \sum_{j=1}^m \beta_j X_{i,j})^2,$$

kus w_i on vaatlusele i vastav kaal, ning need on iga vaatluse mudeli jäägile vastava variatsiooni vastandsuurused ehk

$$w_i = \frac{1}{\sigma_{\hat{\epsilon}_i}^2}.$$

Selleks, et hinnata suuruseid $\sigma_{\hat{\epsilon}_i}^2$ kasutatakse erinevaid lähenemisi. Antud töös on kasutatud teadmist, et kui lineaarse regressiooni korral mudeli jääkide $\hat{\epsilon}_i$ hajuvus kasvab mudeli ennustatud väärtuste \hat{Y}_i kasvades, siis saab $\sigma_{\hat{\epsilon}_i}^2$ hinnata järgnevalt (Penn State Ülikooli Statistikaosakond, 2021):

1. Hinnatakse mitme muutujaga lineaarset regressioonimudel (1).
2. Luuakse uus lihtne lineaarne regressioonimudel, kus mudeli hinnatavaks tunnuseks on eelneva mudeli jääkide absoluutväärtused $|\hat{\epsilon}_i|$ ning argumenttunnuseks eelneva mudeli põhjal saadud hinnangud \hat{Y}_i . Vastava mudeli kuju on seega

$$|\hat{\epsilon}_i| = \alpha_0 + \alpha_1 \hat{Y}_i + v_i,$$

kus v_i tähistab juhuslikku viga ja $i \in 0, 1, 2, \dots, n$.

3. Nüüd leitakse suurused $\sigma_{\hat{\epsilon}_i}^2$ vastavalt valemile

$$\sigma_{\hat{\epsilon}_i}^2 = (\hat{\alpha}_0 + \hat{\alpha}_1 \hat{Y}_i)^2.$$

3 Mullatemperatuuri andmestikkude ülevaade ja võrdlus

Analüüsi peatükis antakse ülevaade töös kasutatud andmetest ja nende omadustest. Samuti analüüsitakse olemasolevate mullatemperatuuri hindamise lahenduste kvaliteeti Eesti piires.

3.1 Ülevaade andmetest

Töö põhineb järgnevatel andmestikel:

1. maapinnaga pidevas kontaktis olevate mullasensorite kaudu mõõdetud pinnatemperatuurid erinevatelt põldudelt Eestis (andmed pärinevad erakogust),
2. Eesti Keskkonnaagentuuri ilmajaamde maapinnatemperatuuri mõõtmistulemused (Keskkonnaagentuur, kuupäev puudub[a]),
3. ERA5-Land globaalse kliima ja ilmastiku järelanalüüsi andmestik (Copernicus, kuupäev puudub),
4. Landsat 8 kaugseire mõõtmiste põhjal arvutatud maapinnatemperatuuri andmestik (Ameerika Ühendriikide Geoloogiakeskus, 24.01.2024a).

Kõik andmed on kogutud vahemikus 2022 juuli kuni 2023 august, kokku 396 päeva, kuid selle perioodi kohta ei ole kõigis lokaalsetes mõõtmispunktides alati andmeid saada. Näiteks viidi osad mullasensorid talveks tuppa või paigaldati põllule ainult mõneks kuuks (Lisa 1. Alusandmestiku mõõtepunktid).

Kõik andmed on kogutud intervalliga üks punkt päevas, vahemikust kell 9:00 kuni 10:00 maailmaaja järgi (UTC - *Universal Time Coordinated*). Need mõõtmised vastavad kellaaajaliselt satelliidi andmete seire ajale, mis on ligikaudu kell 9:30 UTC järgi. Kusjuures ilmajaamadest on igal päeval igas asukohas kaks mõõtmist - nii 5 cm

sügavusel maapinnast kui ka maapinnal (tabelis 1 märgitud vastavalt Ilmajaamad₁ ja Ilmajaamad₂). Tabelis 1 on välja toodud kokkuvõtlik ülevaade kasutatud andmeallikate eripäradest.

Tabel 1: Erinevate andmeallikate mullatemperatuurid.

Andmeallikas	Andmete kogumisviis	Mõõtmisügavus maapinnast (cm)	Kasutatud mõõtmisaeg UTC
Mullasensorid	mõõtmisseadmed	5	9:00-10:00
Ilmajaamad ₁	mõõtmisseadmed	5	9:00-10:00
Ilmajaamad ₂	mõõtmisseadmed	0	9:00-10:00
Landsat 8	satelliidiseire	0	9:30
ERA5-Land	järelanalüüs	0-7	9:00-10:00

Kümnest Eestis asuvast lokaalsest mõõtmispunktist (mullasensorid ja ilmajaamad₁) pandi kokku ühtne andmestik. Nendest lokaalsetest andmeallikatest seitse olid mullasensorid ja kolm Keskkonnaagentuuri ilmajaamad. Mullasensorite ja ilmajaamade asukohtade nimetused ja maakonnad on välja toodud lisades (Lisa 1. Alusandmestiku mõõtepunktid).

Edaspidi on nendest kümnest allikast ühendatud andmestikku nimetatud alusandmestikuks. Alusandmestikus on kokku 396 päeva vahemikus 2022 juuli kuni 2023 august, kuid kõikides asukohtades pole kõikidel päevadel mõõtmiseid. Alusandmestikku kasutati analüüsis nii olemasolevate mullatemperatuuri andmestike võrdlemiseks kui ka mullatemperatuuri mudeldamiseks.

Mullasensorite andmed

Täpsete lokaalsete mõõtmiste jaoks on analüüsimiseks kogutud seitsmes erinevas asukohas Eesti põldudele paigutatud mullasensorite andmeid. Kõik kasutatud mullasensorid pärinevad Eesti ettevõttelt Superhands⁴ ning seadmed mõõdavad pinna temperatuuri, mulla niiskust, õhutemperatuuri, niiskust, tuule suunda ja kiirust ning sademeid. Andmed on kogutud 10-minutiliste intervallidega, kuid analüüsis

⁴<https://superhands.ee/en/iot-devices/>

kasutatakse ainult viimast mõõtmist kella 9:00 ja 10:00 UTC vahel.

Keskkonnaagentuuri ilmajaamade andmed

Keskkonnaagentuuri ajalooliste vaatlusandmete kogust on kättesaadavad mullatemperatuuri andmete mõõtmised erinevatel sügavustel. Antud analüüsis on kasutatud maapinna temperatuuri mõõtmisi, mida on saada ainult Vilsandi, Tooma, Tallinn-Harku ja Tartu-Tõravere ilmajaamadest. Vilsandi mõõtmised jäid analüüsist välja, kuna olid mõõdetud ranniku äärselt alalt, kus agronoomia vaatenurgast mullatemperatuuri hinnanguid niikuinii ei ole vaja. Samuti on kasutuses mullatemperatuuri mõõtmised 5 cm sügavusel maapinnast ning need andmed pärinevad Tooma, Tallinn-Harku ja Tartu-Tõravere ilmajaamadest (Keskkonnaagentuur, kuupäev puudub[b]).

Kaugseire andmed

Landsat 8 on Maa vaatluse programmi Landsat kaheksas satelliit, mis kannab kahte sensorit. Satelliidilt kogutud andmete põhjal genereeritakse Ameerika Ühendriikide Geoloogiakeskuses EROS (Earth Resources Observation and Science) 30-meetrise ruumilise eraldusvõimega pinnatemperatuuride andmestik. Genereerimiseks kasutatakse satelliidilt mõõdetud termilisi infrapuna kiirguse tugevust ja muid atmosfääriga seotud parameetreid (Ameerika Ühendriikide Geoloogiakeskus, 24.01.2024a). Satelliit tiirleb ümber Maa 705 kilomeetri kõrgusel ja teeb tiiru ümber maakera umbes 99 minutiga. Satelliit tiirleb päikese-sünkroonsel polaar-orbiidil ja liikudes põhjast lõunasse on satelliit maakera päikesepoolsel küljel. Ülelennu sagedus maakera samast punktist on 16 päeva (Ameerika Ühendriikide Geoloogiakeskus, 24.01.2024b).

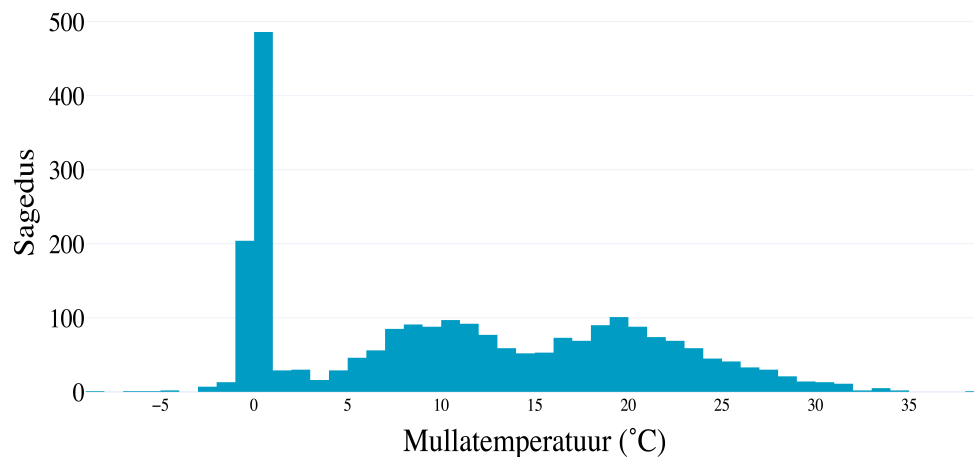
ERA5-Land järelanalüüsi andmed

ERA5-Land on Euroopa Liidu kaugseire programmi Copernicuse poolt koostatud ilmaandmestik. Tegu on järelanalüüsi andmestikuga, kus kombineeritakse erinevad mõõtmistulemused ja ilmamudelid üle kogu maakera. Seega on tegu ilmaparameetrite hinnangutega, kusjuures selle andmestiku korral on hinnangud kättesaadavad

kolmekuuse viiteajaga. Andmeid on võimalik vaadata alates aastast 1950 kuni tänase päevani ja need on kajastatud tunniajase sammuga. Analüüsis on kasutuses selle andmestiku maapinnatemperatuuri hinnangud 0 – 7 cm sügavustel. Samuti on kasutuses õhutemperatuurid ja lumikatte esinemise hinnangud kogu Eesti ulatuses. Andmepunktid katavad Eestit ruudustikuna, kus punktide vahe on ligikaudu 9 kilomeetrit. Lumikatte esinemise hinnang on andmestikus antud kui protsent, mis näitab kui suurel osal vastavast ruudust esines lumi. Sellest tekitati käesoleva töö jaoks binaarne tunnus, kus 1 tähistab olukordasid, kus andmestikus oli lumikatte protsent suurem kui 0. (Copernicus, kuupäev puudub)


3.1.1 Mullatemperatuuri jaotus alusandmestiku põhjal

Alusandmestikus on kokku 10 mõõtepunkti Eestist. Kõik mõõtmised on tehtud 5 cm sügavusel kella 9:00 ja 10:00 vahel UTC järgi. Selle andmestiku põhjal ei ole Eestis mullatemperatuuri jaotus sümmeetriline. Jaotusel on kolm tippu: 0 ° C, 10 ° C ja 20 ° C juures (vt joonis 1). Keskmine temperatuur on 10,9 ° C ja mediaan 10,4 ° C. Temperatuurid on vahemikus –8,4 ° C kuni 38,6 ° C.



Joonis 1: Mullatemperatuuri jaotus alusandmestikus.

Eri mõõtmiskohtade lõikes on mullatemperatuuri jaotused erinevad, kuid suurim erinevus tekib just asukohas tehtud mõõteperioodist ning selle pikkusest (Lisa 1. Alusandmestiku mõõtepunktid). Temperatuuri mediaanid jäävad alati 10 ° C ümbrusesse. Kõige laiemat mullatemperatuuri väärtuste vahemikuga on Tallinn-Harku ilmajaama mõõtmised ja kõige kitsama vahemikuga Niitsku lähedal asuva mullasensori mõõtmised. Need jaotused on kuvatud joonisel 2 iga lokaalse mõõtmiskohta jaoks karpdiagrammina, kus karbi vurrude otspunktid näitavad jaotuse maksimumi ja miinimumi. Nagu varem mainitud, tulenevad jaotuste erinevused mõõtmisperioodide erinevustest. Näiteks on Vaos mullasensorid kahel kõrvuti asetseval põllul, kuid esimese mõõtmisperiood oli ainult aasta 2022 augustist oktoobri keskpaigani ja teisel aasta 2023 veebruarist juuli lõpuni. Seega on esimese mõõtmisperiood palju lühem kui teisel ja sellest tulenevalt on ka jaotuste väärtuste vahemik kitsam. Mõõtmiskohad, kus koguti andmeid ligikaudu terve ühe aasta jaoks, olid Tartu-Tõravere ilmajaam, Tooma ilmajaam, Jäneda mullasensor, Tallinn-Harku ilmajaam ja ka Võnnu mullasensor. Viimases asukohas oli mullasensor siiski talveks tupp viidud ja seega puudusid selle perioodi kohta mõõtmised. Teiste asukohtade mõõtmiseadmete põhjal olid mõõtmisperioodid erineva pikkusega, kuid kõik olid ajavahemikus 2022 juuli kuni 2023 august.



Joonis 2: Mullatemperatuuri jaotused eri mõõtmiskohtades.

3.2 Olemasolevate mullatemperatuuri hindamise lahenduste analüüs


Mullatemperatuur on levinud ilmastikuparameeter ning seetõttu on vastavaid andmeid võimalik saada nii lokaalsete mõõtmisseademetega kaudu kui ka muudest andmeallikatest. Eestis kajastatakse neid andmeid näiteks Keskkonnaagentuuri kodulehel, kuid mullatemperatuuri 5 sentimeetri sügavusel mõõdeti töö kirjutamise ajal ainult kolmes eri ilmajaamas. Seetõttu ei ole need andmed sageli kõige paremad infoallikad, kuna mõõtmiseid ei pruugi olla huvipakkuva piirkonna läheduses. Täiendavate mullasensorite kaudu on samuti võimalik saada lokaalseid mõõtmisi, kuid nende sensorite paigutamine, hooldus ja järelevalve on aja- ning ressursikulukas. Suuremate alade pealt on andmeid võimalik saada järelanalüüsi ja kaugseire andmestikkudest. Järgnevalt võrreldi järelanalüüsi ja kaugseire andmeid 10 erineva lokaalse mõõtmise andmeallikaga (alusandmestikuga), et anda hinnang suure alakatvusega andmestikkude täpsusele.

Landsat 8 kaugseire mõõtmiste võrdlus

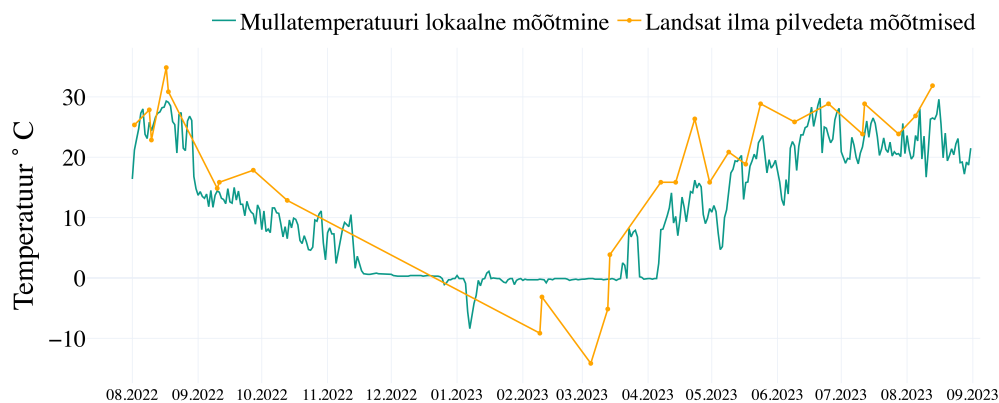
Landsat 8 satelliidi mõõtmiste suurimaks takistuseks on pilved, mis blokeerivad satelliidi sensorite vaatevälja. Samuti tuleb arvestada sellega, et satelliit mõõdab temperatuuri samas kohas ainult iga 16 päeva tagant. Võrreldi alusandmestikku ja samal perioodil samades asukohtades alla laetud Landsat 8 satelliidi andmeid. Siinkohal tuleb veel mainida, et esialgu on võrreldud lokaalselt mõõdetud mullatemperatuure 5 cm sügavusel maapinnast ning satelliidimõõtmiseid, mis kajastavad ainult temperatuuri maapinnal. Siiski on need satelliidi andmed vajadusel võimalik kooskõlla viia ka mullatemperatuuriga, kasutades selleks näiteks peatükis 4.2 välja töötatud mudeleid.

Leiti, et keskmiselt ligikaudu 21% päevadest ehk 84 päeval 396-st oli asukohas olemas mullatemperatuuri mõõtmine. Nendest mõõtmistest keskmiselt 33 olid tehtud pilvitu ilmaga päevadel, mis tähendab, et need mõõtmised peaksid olema antud töös kasutamiseks usaldusväärsed. Seega ainult 8%-l päevadest oli andmestik

olemas kasutatav mullatemperatuuri mõõtmine. Kui vaadelda ainult pilvkatteta päevade mõõtmisi, siis järgivad Landsati temperatuurid lokaalsete temperatuuri mõõtmise trende. Näitena on joonistel 3 ja 4 toodud selline olukord kahes alusandmestiku asukohas, kus roheline joon tähistab lokaalseid mõõtmisi ning kollane satelliidi pilvedeta päevade mõõtmisi. Joonisel 3 on näha aastal 2023 juulis ja augustis mõõtmised, mis peaksid eelduste kohaselt olema küll kasutatavad, kuid ilmselt on tegu anomaaliatega, kuna maapinna temperatuur Landsat andmetes on vastavalt -55°C ja -38°C . Sarnaseid anomaaliaid leidis ka teistes alusandmestiku asukohtades.



Joonis 3: Landsat satelliidi ja Jänedal asuva mullasensori mõõtmiste võrdlus.




Joonis 4: Landsat satelliidi ja Tartu-Tõravere ilmajaama mõõtmiste võrdlus.

Kokkuvõttes pole Landsati mõõtmised üksi piisavad mullatemperatuuri igapäevaste hinnangute andmiseks, kuna kasutatavaid andmeid saab koguda kokku ainult ligikaudu kuu aja jaoks aastas. Samuti ei ole need andmed alati usaldusväärsed, kuna esineb palju anomaaliaid.


ERA5-Land järelanalüüsi andmete võrdlus

ERA5-Land andmestiku korral on tegu järelanalüüsi andmestikuga, kus on antud hinnangud mullatemperatuurile erinevate allikate põhjal, seega oli iga huvipakkuva päeva jaoks olemas andmepunkt. Siiski olid need andmepunktid saadaval alles kolmekuuse viitejaga. Vaadeldes mullatemperatuure eri asukohtades aegridadena, on järelandmestiku hinnangud lokaalsetele mõõtmistele üsna sarnased. Seda on näha näiteks joonisel 5.



Joonis 5: ERA5-Land ja Tooma ilmajaama mõõtmiste võrdlus.

ERA5-Land andmete võrdlemiseks alusandmestikuga vaadeldi sama asukoha sama aja mõõtmiste erinevusi. Kui ERA5-Land andmete jaotus ühtiks alusandmestiku mõõtmiste jaotusega, peaks eelduste kohaselt selliste erinevuste jaotus olema normaaljaotus. Võrreldes erinevuste kvantiile normaaljaotuse teoreetiliste kvantiilidega selgus, et normaaljaotuse eeldus ei kehti. Seda on näha jooniselt 6, kus on välja toodud erinevuste kvantiilide ja normaaljaotuse kvantiilide võrdlus hooegade kaupa. Kõige sarnasemad on jaotused talvel ning kõige suurem erinevus tuleb sisse suvekuudel. Neid kvantiile vaadeldi eraldi ka asukohtade kaupa, kusjuures siis tuli iga asukoha korral erinevus normaaljaotusest samuti selgelt välja.



Joonis 6: ERA5-Land ja alusandmestiku mõõtmiste erinevuste kvantiilide võrdlus normaaljaotuse kvantiilidega hooegade kaupa.

Eelnevast mõõtmiste erinevuste analüüsist selgus, et ERA5-Land hinnangud ja lokaalsete mõõtmiste jaotused erinevad. Samas on ERA5-Land hinnangud järjepidevad ning lokaalsete mõõtmiste aegridasid vaadeldes ka üsna sarnased alusandmes- tikule. Seega on ERA5-Land ligikaudse mulla temperatuuri hinnangu andmiseks hea allikas, kuid samas on nende hinnangute kättesaadavusel pikk viiteaeg.

4 Mullatemperatuuri mudeldamine


Varasemad uuringud on näidanud, et õhu- ja pinnatemperatuuri vahel on tugev lineaarne seos. Seda kinnitab nii Zheng, Hunt ja Running (1993) uuring Ameerika pinnatemperatuuri mudeldamiseks kui ka Hu *et al.* (2020) sama teemaline uuring Qinghai-Tiibeti platool. Zheng, Hunt ja Running (1993) toovad oma uuringus välja, et lumistel ajaperioodidel muutub õhu- ja pinnatemperatuuri vaheline seos võrreldes ilma lumeta perioodidega. Seetõttu oleks tõhus luua kaks eraldi mudelit, mida kasutada vastavalt lumikatte olemasolule. Samuti on uuringu tulemuseks, et erineva pinnase ja geograafiliste asukohtade jaoks on kliima eripärade tõttu vaja eraldi mudeleid (Zheng, Hunt ja Running, 1993). See asjaolu on ka sisendiks käesolevale uuringule, mille tulemusena luuakse Eesti geograafilist asukohta arvestav mudel pinnatemperatuuri prognoosimiseks.

Hu *et al.* (2020) töös võrreldakse lisaks õhu- ja maapinnatemperatuuri otsese seose mudelile ka mudelit, kus on arvesse võetud eelnevate päevade õhutemperatuure. Sellist omadust, kus otsitav väärtus sõltub lisaks otsesele sisendile ka viitega sisendi ajaloolistest väärtustest, nimetatakse meteoroloogias hüstereesiks. Hüsteresi tõttu järgib maapinnatemperatuur õhutemperatuuri trende väikese ajalise viivitusega. Qinghai-Tiibeti platool arvutatud mudelid kinnitavad, et hüsterees mõjutab oluliselt maapinna temperatuuri ja seda ei tohiks maapinna temperatuuriga seotud arvutustes tähelepanuta jätta. Hüsteresipäevade arv määrati õhu- ja maapinnatemperatuuri muutuste korrelatsiooni kaudu (Hu *et al.*, 2020). Võttes arvesse neid kahte uuringut, on antud töös maapinnatemperatuuri mudeldamisel õhutemperatuurist lisatud ka lumikatte ja hüstereesiga seotud argumenttunnused.

4.1 Mullatemperatuuri mudeldamine meteoroloogiliste andmete põhjal

Mudeli eesmärk on võimalikult väikese absoluutse veaga anda hinnang mullatemperatuurile, kasutades selleks võimalikult lihtsalt kogutavaid argumenttunnuseid. Mudel peab olema võimeline hindama mullatemperatuuri suvalises asukohas Eesti piires, kasutades selleks teisi sellele asukohale omaseid parameetreid. Eelneva analüüsi tulemusena otsustati mullatemperatuuri mudeldada ainult meteoroloogiliste tunnuste põhjal. Mudeldamise aluseks võeti varasemate uuringute tõdemus, et mulla- ja õhutemperatuuri vahel on lineaarne seos ja seega valiti mudeliks lineaarne regressioonimudel (Zheng, Hunt ja Running, 1993; Hu *et al.*, 2020).

Analüüsidest õhu- ja mullatemperatuuri seost leiti sarnaselt varasematele uuringutele, et talvekuudel on see seos erinev muust ajast. Nimelt on negatiivsete õhutemperatuuride korral mullatemperatuur enamasti kõrgem õhutemperatuurist, kuid muul ajal kehtib vastupidine seos. Seega otsustati, et mullatemperatuuri ennustamine tuleks õhutemperatuuri põhjal jagada kahe eraldi mudeli vahel. Selleks piiriks valiti joonise 7 põhjal 0°C . Edaspidi on nendele mudelitele viidatud kui miinuskraadide mudel (siinkohal kuulub õhutemperatuur 0°C ka miinuskraadide mudeli juurde) ja plusskraadide mudel.



Joonis 7: Seos mullatemperatuuri ja õhutemperatuuri vahel.

Mudeli treenimiseks ja valideerimiseks kasutati alusandmestikku seitsme mullasensori ja kolme ilmajaama poolt mõõdetud mullatemperatuuriga. Plusskraadide mudeli korral oli parameetrite kordajate hindamisel valimi maht 1405 ja miinuskraadide mudeli korral 297. Töö autori valikul kasutati mudeli valideerimiseks Jäneda lähedal asuva mullasensori ja Tartu-Tõravere ilmajaama andmeid. Need andmeallikad valiti valideerimiseks, sest mõlemast kohast olid saadaval terve analüüsi kaasatud perioodi, 2022 juuli - 2023 august, andmed. Samuti kajastasid need mõõtepunktid olemasolevatest andmetest geograafiliselt ja andmete kogumise viisilt kahte piisavalt erinevat kohta.


Niisiis treeniti mudel kaheksa erineva mõõtmiskoha andmetega. Nendest kaheksast kuus olid mullasensorid, mis kogusid andmeid vastavalt Antsla, Niitsiku, Tõravere, Võnnu ning Vao lähedal asuvatelt põldudelt. Viimasest asukohast olid mõõtmised kahelt erinevalt põllult. Samuti olid treeningandmestikus Tallinn-Harku ilmajaama ja Tooma ilmajaama mullatemperatuuri mõõtmised.

4.1.1 Mudeli argumenttunnuste valik

Enne mudeldamist valiti välja hulk potentsiaalselt olulisi argumenttunnuseid meteoroloogiliste andmete seast. Mudeldamiseks olid olemas õhutemperatuur ja lu-

mikatte esinemist indikeeriv tunnus igast mõõtmiskohast. Lumikatte kohta loodi mudeli jaoks binaarne tunnus I_{lumi} , mille korral 1 tähistab lume esinemist mõõtmiskoha läheduses.

Õhutemperatuuri põhjal loodi mitu argumenttunnust. Hüstereesi mudelisse kaasamise jaoks analüüsiti esmalt mullatemperatuuride korrelatsioone eelnevate päevade õhutemperatuuriga. Analüüsis leiti, et Pearsoni korrelatsioonikordaja mullatemperatuuriga oli peaaegu kõikides mõõtmiskohtades alati kõige kõrgem sama päeva õhutemperatuuriga ning langes iga eelneva päeva korral (vt joonis 8). Erandiks oli ainult Niitsiku lähedal asuva mullasensori mõõtmiste korrelatsioon, kus kõige tugevam seos oli mõõtmisele eelnenud päeva õhutemperatuuriga.



Joonis 8: Korrelatsioonid mullatemperatuuri ja mõõtmisele eelnevate päevade õhutemperatuuriga.

Siiski oli isegi näiteks 9 päevase viiteaja korral korrelatsioon kõikides asukohtades suurem kui 0,7. Seega otsustati argumenttunnusena mudelisse kaasata ka ennustatavale päevale eelnenud päeva õhutemperatuur, mis on edaspidi tähistatud kui $T_{\text{õhkE}}$. Mudeldamise käigus katsetati ka suurema viiteajaga õhutemperatuuride lisamist, kuid sellised argumenttunnused ei osutunud statistiliselt oluliseks. Siiski lisati mudelisse tunnus, mis väljendab kolme eelnenud päeva keskmist õhutemperatuuri ja on edaspidi tähistatud $T_{\text{õhk3Ek}}$.

Mullatemperatuuri perioodilisusega arvestamiseks loodi tunnused, millega väljendada temperatuuri perioodilisust aasta lõikes. Selleks teisendati päeva numbrit aastas vahemikus 1 kuni 365 (antud andmestikus pole liigaastaid) siinuse ja koosinuse abil. Edaspidi on päeva number aastas tähistatud sümboliga d . Uued tunnused arvutati järgnevalt:

$$\begin{aligned} d_{\text{sin}} &= \sin\left(2\pi \cdot \frac{d}{365}\right), \\ d_{\text{cos}} &= \cos\left(2\pi \cdot \frac{d}{365}\right). \end{aligned} \tag{3}$$

Aastaaegade eripärasid kaasatakse mudelisse indikaatortunnustega

$$I_x = \begin{cases} 1, & \text{kui tegu on aastaaajaga } x \\ 0, & \text{muidu} \end{cases} . \tag{4}$$

Neid indikaatortunnuseid on mudelis kokku kolm - suve, kevade ja sügise kohta. Kuude detsember kuni veebruar korral võetakse vaatluse aastaaajaks talv, märts kuni mai on võetud kevadkuudeks, juuni kuni august suveks ja ülejäänud sügiseks.

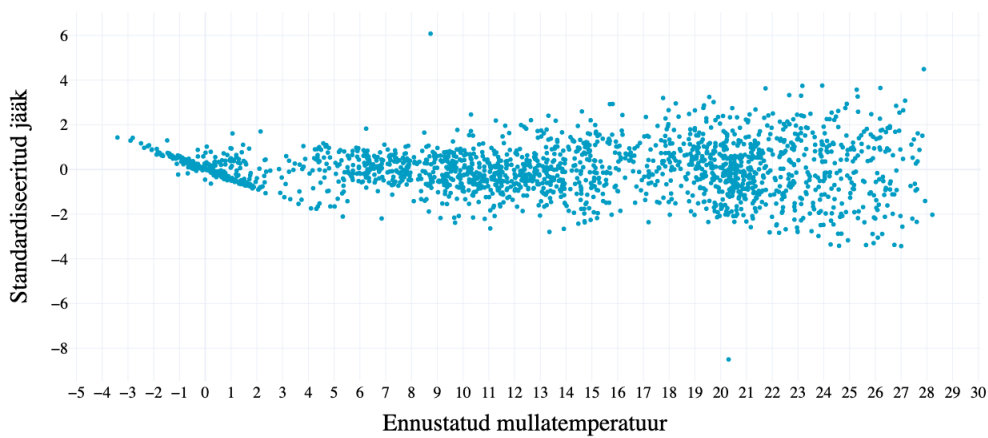
4.1.2 Mudeli arendus

Mudeldamiseks kasutati esmalt lineaarset regressioonimudelit meteoroloogiliste ja perioodilisust arvestavate argumenttunnustega. Mullatemperatuuri andmeid ana-

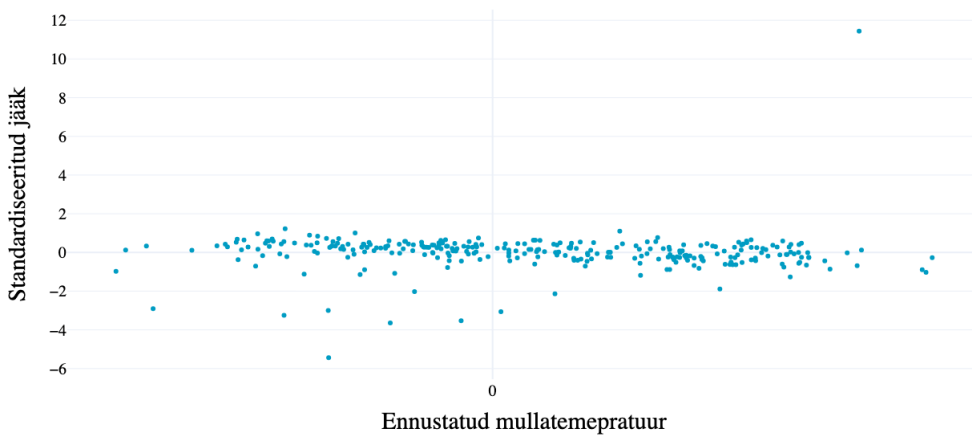
liiüsid selgus, et väärtused sõltuvad selgelt eelmiste päevade mullatemperatuurist. Näiteks Jäneda mullasensori mõõtmiste autokorrelatsiooni funktsiooni joonistelt tuleb selgelt välja, et mullatemperatuur sõltub terve eelneva aasta mullatemperatuuridest, kusjuures see seos on positiivne suvel ja negatiivne talve perioodil (Lisa 3. Temperatuuride autokorrelatsioonid). Teistes asukohtades olid tulemused sarnased. Peaaegu identne olukord autokorrelatsiooniga on eri asukohtades õhutemperatuuri korral. Kusjuures mullatemperatuuri osaaautokorrelatsiooni funktsioonist järeldub, et mudelisse piisaks eelmise päeva temperatuuri lisamisest, kuna hilisemad päevad enam selgitust ei pranda (Lisa 3. Temperatuuride autokorrelatsioonid).

Seega oleks hea mudelisse kaasata ka eelmise päeva tegelik mullatemperatuur. Kuid reaalsuses ei ole võimalik eesmärgipäraselt mudeliga ennustades kunagi ennustatava asukoha jaoks tegelikku mullatemperatuuri mõõta. Samas, kui kaasata mudelisse eelmiste päevade mullatemperatuuri ennustused, on suure veaga ennustuse korral ka kõik järgnevad ennustused sellest mõjutatud. Nendel põhjusel otsustati, et mudelisse ei saa kaasata eelnevate päevade mullatemperatuure. Kuna varasemalt leiti, et õhu- ja mullatemperatuuri vahel on selge lineaarne seos (vt joonis 7), siis oli lootus mullatemperatuuri sõltuvust eelmiste päevade temperatuuridest mudelisse kaasata õhutemperatuuri kaudu.

Kõikide argumenttunnuse regressioonimudelisse kaasamise kombinatsioonide korral oli plusskraadide mudeli jäägid heteroskedastilised. Seda on näha jooniselt 9, kus plusskraadide mudelis mullatemperatuuri kasvades suurenevad ka mudeli vead. Miinuskraadide mudeli korral pole jooniselt 10 sellist seost silmaga näha.



Joonis 9: Plusskraadide regressioonimudeli jääkide hajuvusgraafik.



Joonis 10: Miinuskraadide regressioonimudeli jääkide hajuvusgraafik.

Jääkide heteroskedastilisuse vähendamiseks kasutati mudeli kordajate hindamisel kaalutud vähimruutude meetodit. Sobivate kaalude leidmine toimus peatükis 2.3 kirjeldatud meetodil. Plusskraadide mudeli korral sai kaalude hindamise mudel kuju

$$|\hat{\epsilon}_i| = 0,76 + 0,09 \cdot \hat{Y}_i.$$

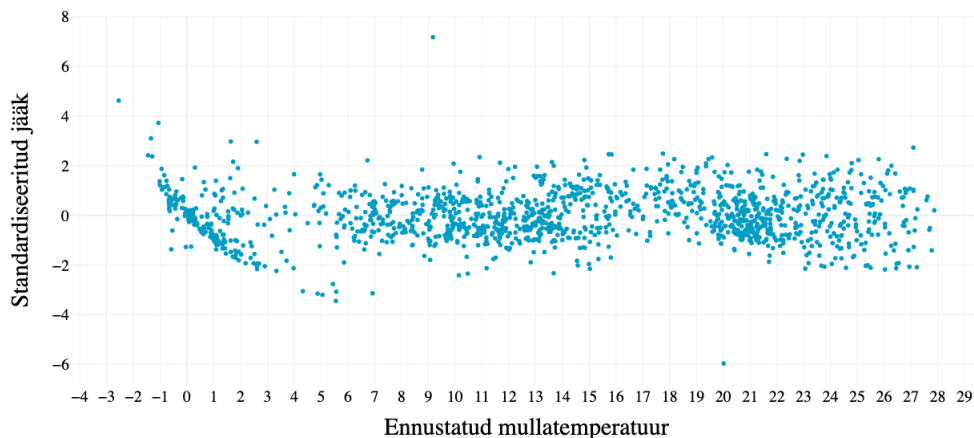
Kusjuures selle mudeli mõlema kordaja olulisuse tõenäosus oli peaaegu 0 ja seega olulisuse nivoo $\alpha = 0,05$ juures oli mudel statistiliselt oluline. See viitab sellele, et kaalutud vähimruutude meetodi kasutamisel oli ka sisuline vajadus.

Miinuskraadide mudeli korral sai kaalude hindamise mudel kuju

$$|\hat{\epsilon}_i| = 0,04 + 0,12 \cdot \hat{Y}_i.$$

Selle mudeli korral oli Y_i kordaja p -väärtus ligikaudu 0,823. Seega ei ole olulisuse nivoo $\alpha = 0,05$ juures miinuskraadide mudeli jaoks kaalutud vähimruutude meetodi rakendamine tegelikult vajalik ja mudeli kordajate hindamiseks kasutati lõppkokkuvõttes tavalist vähimruutude meetodit.

Hinnates hajuvusgraafikul plusskraadide mudeli jääke kaalutud lineaarse regressiooni korral leiti, et jääkide hajuvus on mudeli eesmärgipäraseks kasutamiseks piisavalt väikese varieeruvusega. Hindamiseks kasutatud hajuvusgraafik on välja toodud joonisel 11, kus on kujutatud plusskraadide mudeli jääkide ja ennustuste suhet.



Joonis 11: Kaalutud vähimruutude meetodil hinnatud plusskraadide mudeli jääkide hajuvusgraafik.

4.1.3 Mudeli lõplik kuju

Mullatempeatuuride mudeldamiseks kasutati regressiooni mitme argumenttunnusega. Loodi eraldi mudelid positiivsete õhutemperatuuride ja sellest madalamate temperatuuride jaoks. Plusskraadide mudeli korral kasutati kordajate hinnangute

leidmisel kaalutud vähimruutude meetodit ja miinuskraadide mudeli korral tavalist vähimruutude meetodit. Lõppkokkuvõttes oli plusskraadide mudeli kuju

$$T_{\text{muld}} = \beta_0 + \beta_1 T_{\text{õhk}} + \beta_2 T_{\text{õhkE}} + \beta_4 I_{\text{lumi}} + \beta_5 d_{\text{sin}} + \beta_6 d_{\text{cos}} + \beta_7 I_{\text{Kevad}} + \beta_8 I_{\text{Suvi}} + \beta_9 I_{\text{Sügis}} \quad (5)$$

ja miinuskraadide mudeli kuju

$$T_{\text{muld}} = \beta_0 + \beta_2 T_{\text{õhkE}} + \beta_3 T_{\text{õhk3Ek}} + \beta_5 d_{\text{sin}} + \beta_6 d_{\text{cos}}. \quad (6)$$

Mudelite (5) ja (6) korral tähistab T temperatuuri, d päeva numbrit aastas vastava teisendusega ning I tähistab indikaatortunnust. Kordajate β_i alamindeksite väärtused ei vasta mitte mudelis olevate argumenttunnuste arvule, vaid konkreetne β_i on mõlemas mudelis seotud sama argumenttunnusega.

Seega sõltuvad β_0, \dots, β_9 väärtused sellest, kas mudeldati õhutemperatuuriga, mis oli üle 0°C või mitte ja on toodud välja tabelis 2. Sümbol ‘–’ viitab tabelis sellele, et kordajale vastav argumenttunnus ei olnud statistiliselt oluline. Statistiliselt ebaolulised tunnused eemaldati mudelitest ükshaaval. Allesjäänud muutujad osutusid statistiliselt oluliseks olulisuse nivoo $\alpha = 0,01$ juures.

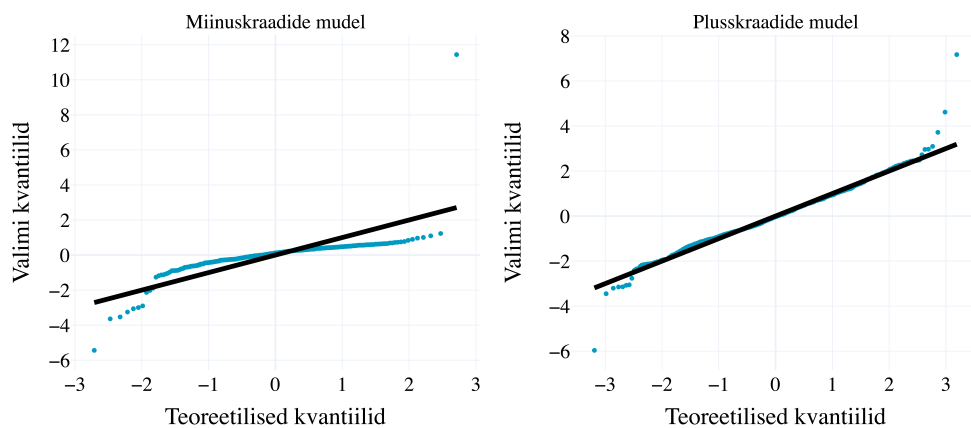
Tabel 2: Regressioonimudelite kordajad.

	Miinuskraadide mudel	Plusskraadide mudel
β_0	1,01	4,88
β_1	-	0,65
β_2	0,09	0,09
β_3	-0,08	-
β_4	-	-2,12
β_5	-0,52	-0,75
β_6	-1,06	-3,64
β_7	-	-2,05
β_8	-	-1,72
β_9	-	2,74

Mõlema mudeli puhul tuvastati mudeli argumenttunnuste vahel multikollineaarsus (Lisa 2. Mudeli argumenttunnuste multikollineaarsuse näitajad), kuna varieeruvu-
sindeks VIF (*Variance Inflation Factor*) tuli kahel tunnusel suurem kui 10. See oli
oodatav, kuna vastavad tunnused olid seotud õhutemperatuuriga, olgugi et need
olid erineval kujul.

Mudeli jäägid olid mõlema mudeli korral autori hinnangul piisavalt väikese haju-
vusega. Sellest on lähemalt räägitud peatükis 4.1.2. Plusskraadide mudeli korral
kasutati jääkide heteroskedastilisuse vähendamiseks parameetrite hindamisel kaa-
lutud vähimruutude meetodit. Lõpliku mudeli jääkide hajuvus on toodud välja
joonisel 11 ja miinuskraadide mudeli jääkide hajuvus joonisel 10.

Jooniselt 12 on näha, et plusskraadide mudeli korral on mudeli jääkide jaotus vaata-
mata paarile erindile väga sarnane normaaljaotusega. Miinuskraadide mudeli korral
pole olukord nii hea, kuid nagu mainitud peatüki 2 alguses, ei ole talviste tempe-
ratuuride mudel töö eesmärgi koha pealt tegelikult nii oluline.



Joonis 12: Mudelite vigade kvantiilide graafik.

Peatükis 4.1.2 mainitud probleem mullatemperatuuri autokorrelatsiooniga kajastus ka lõplikus mudelis. Nimelt oli jääkide esimest järku autokorrelatsiooni tuvastava Durbin-Watson statistiku väärtus plusskraadide mudeli korral 0,84 ja miinuskraadide mudeli korral 1,5. Antud statistiku väärtused jäävad vahemikku 0 kuni 4, kus väärtusele 2 lähedased näitavad autokorrelatsiooni puudumist. Seega esineb plusskraadide mudeldamiseks kasutatud andmetes selgelt tugev autokorrelatsioon, mida peaks regressioonimudelites ideaalis vältima. Siiski on peatükis 4.1.2 käsitletud juba ka põhjused, miks selline olukord oli oodatav ja mis põhjustel ei ole võimalik seda parandada.

Tulevikus võiks seda probleemi lahendada paigutades ühtlaselt üle Eesti eri asukohtadesse pidevalt maapinnaga kontaktis olevad mullasensorid, mis edastaksid mõõtmisi igapäevselt. Nende andmete põhjal oleks võimalik mõõtmiskohtade jaoks luua prognoosiv mudel, mis arvestab ka eelmise päeva mullatemperatuuriga. Seejärel saaks iga muu asukoha jaoks Eestis interpoleerida mullatemperatuuri nende mõõtepunktide andmete põhjal.

Plusskraadide mudeli kohandatud R^2 treeningandmestikul tuli 0,94 ja miinuskraadide mudeli korral 0,12. Miinuskraadide korral on madal kohandatud R^2 väärtus oodatav, kuna ennustatava tunnuse varieeruvus on väike.

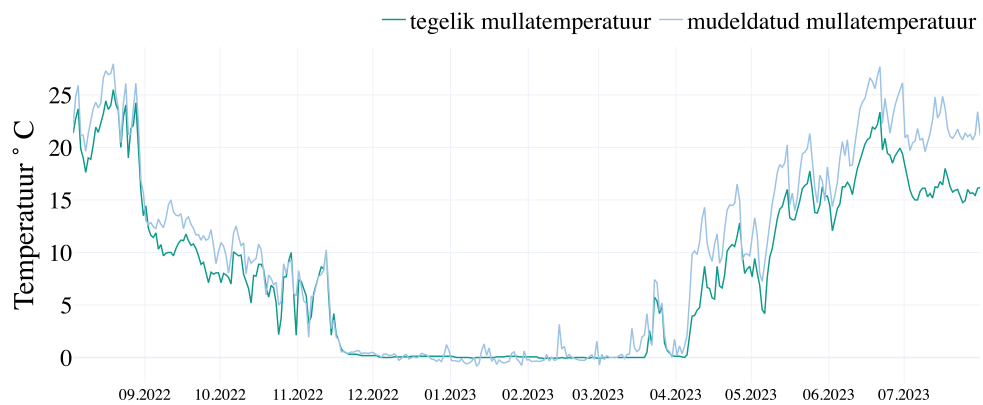
4.1.4 Mudeli valideerimine

Mudeli treenimiseks kasutati saadavast alusandmestikust kaheksa mõõtmispunkti andmeid. Mudelit valideeriti Jäneda lähedal asuva mullasensori ja Tartu-Tõravere ilmajaama andmetega, kusjuures neid mõõtmiskohti mudeli treenimisel ei kaasatud. Mudelitele vastavad keskmise absoluutse vea väärtused (MAE) on välja toodud tabelis 3. Nii treening- kui ka valideerimisandmestiku korral oli plusskraadide mudeliga tehtud ennustuste keskmine absoluutne viga ligikaudu 2°C . Miinuskraadide korral oli viga mõlemas andmestikus ainult ligikaudu $0,4^{\circ}\text{C}$, mis oli ka oodatav, arvestades et tegelik ja prognoositud väärtus oli alati ligikaudu 0°C .


Tabel 3: Mudelite täpsused.

Andmestik	Mudel	MAE
Treeningandmestik	Plusskraadid	2,00
Treeningandmestik	Miinuskraadid	0,38
Valideerimisandmestik	Plusskraadid	1,93
Valideerimisandmestik	Miinuskraadid	0,40

Joonistel 13 ja 14 on välja toodud mudeldatud ja tegelikud mullatempreatuurid valideerimisandmestiku mõõtmiskohtades. Mudeldades kasutati vastavalt õhutemperatuurile kas plusskraadide või miinuskraadide mudelit.



Joonis 13: Mullatemperatuur Jämeda lähedal mullasensori või mudeli põhjal.



Joonis 14: Mullatemperatuur Tartu-Tõravere ilmajaama mõõtmiste või mudeli põhjal.

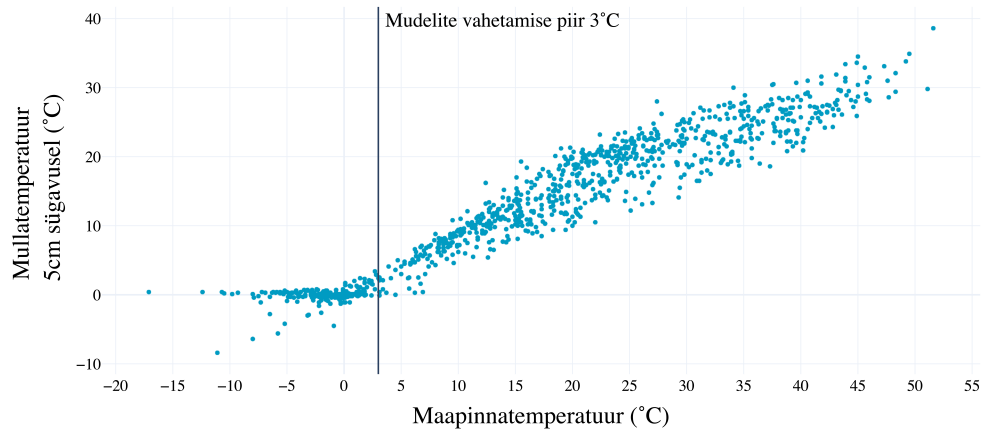
Tartu-Tõravere ilmajaama mõõtmistes esineb ilmselt 2023 aasta jaanuaris üks anomaalia, kus mullatemperatuur on alla -5°C . Käesoleva töö käigus loodud mudel annab selle päeva jaoks hinnangu, mis jääb 0°C lähedusse. Võrreldes tulemust jaanuari mullatempreatuuride jaotusega alusandmestikus on mudeli ennustus realistlikum kui ilmajaama mõõtmine, kuna ainult üksikud tegelikud mõõtmised jäävad alla -1°C .

4.2 Mudelid mullatemperatuuri tuletamiseks maapinnatemperatuurist

Antud töös on analüüsitud kaugseire võimaluste kasutamist mullatemperatuuri hindamiseks. Töös ollakse huvitatud just mullatemperatuurist 5 cm sügavusel, kuid satelliitide tulemused on hinnatud seirepiltidelt ning kajastavad temperatuure maapinnalt. Sellest tulenevalt tekkis vajadus mudelile, mille abil viia satelliitide mõõtmised vastavusse temperatuuridega 5 cm sügavusel.

Seose hindamise alusandmesikuna kasutati kolme Eesti ilmajaama - Tooma, Tallinn-Harku ja Tartu-Tõravere - mõõtmisandmeid vahemikus 2022 juuli - 2023 august. Nendes jaamades on saadaval mõõtmised nii maapinnalt kui ka 5 cm sügavuselt. Neid andmeid vaadeldi seose hindamisel ühe valimina, mis tähendab, et asukoht seose hindamisel rolli ei mänginud.

Kuna varasemad uuringud on õhu- ja mullatemperatuuri vahel tuvastanud lineaarse seose (Zheng, Hunt ja Running, 1993; Hu *et al.*, 2020), siis oli alust arvata, et maapinnal ja 5 cm sügavusel see seose tüüp drastiliselt ei muutu. Seetõttu kasutati seose hindamiseks lineaarset regressiooni. Analüüsi käigus tuli välja, et novembrist märtsini on 5 cm sügavusel temperatuurid enamasti kõrgemad kui maapinnal ning muul ajal on seos pigem vastupidine. Seetõttu jagati mudeldamine kaheks, loodi eraldi mudel seose hindamiseks kui temperatuurid on kuni 3°C ja mudel, kui temperatuurid on sellest piirist kõrgemad. Temperatuuri piir mudelite vaheta-



Joonis 15: Seos 5cm mullatemperatuuri ja maapinnatemperatuuri vahel.

miseks valiti õhu ja maapinnatemperatuuri seost väljendava hajuvusgraafiku abil (vt Joonis 15).

Enne mudeldamist loodi argumenttunnused sarnaselt peatükis 4.1.1 kirjeldatud protsessile ja valemitele. Kordajate hindamiseks kasutati vähimruutude meetodit ja soojemate kraadide mudelis oli hinnangu tegemise valimi maht 987 ja külmemate kraadide korral 524. Lõppkokkuvõttes oli üle 3 ° C õhutemperatuuri mudeli lõppkuju

$$T_{\text{muld}} = 5,07 + 0,47 \cdot T_{\text{maapind}} - 2,24 \cdot d_{\text{sin}} - 2,91 \cdot d_{\text{cos}} - 1,36 \cdot I_{\text{Kevad}} + 0,26 \cdot I_{\text{Suvi}} - 2,76 \cdot I_{\text{Sügis}} \quad (7)$$

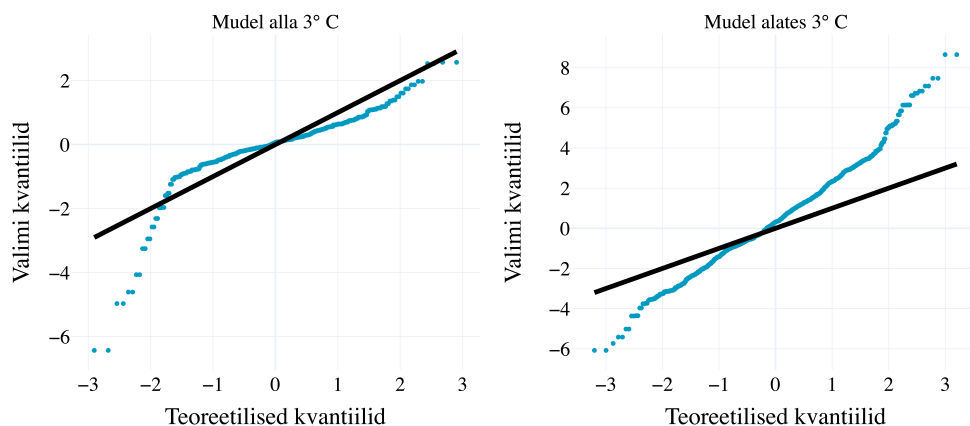
ja kuni 3 ° C õhutemperatuuri mudeli lõppkuju

$$T_{\text{muld}} = 2,56 + 0,18 \cdot T_{\text{maapind}} - 1,57 \cdot d_{\text{sin}} - 2,35 \cdot d_{\text{cos}} - 0,44 \cdot I_{\text{Kevad}} - 0,78 \cdot I_{\text{Sügis}}. \quad (8)$$

Mudelite (7) ja (8) korral tähistab T temperatuuri, d päeva numbrit aastas vastava teisendusega ning I tähistab indikaatortunnust aastaaja kohta. Katsetati erinevaid argumenttunnuseid, mis olid seotud maapinnatemperatuuri või prognoosimise ajaga. Statistiliselt ebaolulised tunnused eemaldati mudelitest ükshaaval. Allesjäänud muutujad osutusid statistiliselt oluliseks olulisuse nivoo $\alpha = 0,01$ juures. Mudelis (8) ei ole aastaaja indikaatortunnust suve kohta, kuna talviste temperatuuridega andmetes suvekuude andmeid ilmselgelt ei esine.


Mudelitele vastavad kohandatud R^2 väärtused tulid vastavalt 0,95 ja 0,28.

Mudelite eelduste kontrollis selgus, et vead ei olnud normaaljaotusega (vt Joonis 16). Sellel joonisel ühtiksid eelduse kehtimise korral mudeli standardiseeritud vigade kvantiilid normaaljaotuse kvantiilidega. Antud olukorras ei kattu need kvantiilid aga kumbagi mudeli korral. Mudeli jäägid olid mõlema mudeli korral konstantse hajuvusega.



Joonis 16: Mudelite vigade kvantiilide graafik.

Võrreldes mudeli hinnanguid tegelike mullatemperatuuridega olid tulemused üsna sarnased. Üks näide sellest on välja toodud joonisel 17. Mudelite keskmised absoluutsed vead vastavalt maapinnatemperatuurile soojemate kraadide mudeli korral 1,54 ja külmemate kraadide mudeli korral 0,57.



Joonis 17: Mullatemperatuur Tallinna-Harku ilmajaamas.

Olemasolevate lahenduste analüüsis (peatükk 3.2) selgus, et kuigi seireandmed järgivad mullatemperatuuri trende üsna hästi, on andmetes suured lüngad. Seetõttu ei ole seirelahendused antud hetkel hinnangute tegemiseks rakendatavad. Kui tulevikus peaks seireandmete kvaliteet paranema, on antud peatükis kirjeldatud mudelit või selle edasiarendusi võimalik kasutada nendest seireandmetest mullatemperatuuri tuletamiseks.

Kokkuvõte

Bakalaureusetöö eesmärk oli luua mudel mullatemperatuuri prognoosimiseks teiste keskkonnaparameetrite põhjal Eestis. Samuti oli eesmärk anda ülevaade ja hinnang olemasolevatele mullatemperatuuri hindamise lahendustele. Töös käsitleti mullatemperatuuride andmeid 5 cm sügavusel perioodil 2022 juuli kuni 2023 august. Nende andmete põhjal teostati nii analüüs kui ka loodi mudelid.

Levinud lahendused mullatemperatuuri hindamiseks on lokaalsed mõõtmisseadmed, kaugseireandmed ja järelanalüüsi andmestikud. Asukohapõhiselt kõige täpsemaid mõõtmisi annaksid lokaalsed mõõtmisseadmed, milleks on näiteks mullasensordid. Kuid suuremate alade mõõtmiseks ei ole selline lahendus ressursi kulukuse tõttu kergesti rakendatav. Antud töös võrreldi kümne Eesti põllul või ilmajaamas asuva lokaalse mõõtmisseadme kaudu kogutud mullatemperatuuri teiste hindamise lahenduste andmetega.

Kaugseire andmestikus olid võrreldava andmestiku 396 päevast mõõtmised ainult 21%-l päevadest, millest kokku ainult 33 päeva ehk koguandmestikust 8% oli reaalset kasutatav. Seega ei ole kaugseire lahendused Eesti jaoks rakendatav lahendus igapäevaste mullatemperatuuri hinnangute tegemiseks. Võrreldes populaarse järelanalüüsi andmestiku ERA5-Land hinnanguid lokaalsete mõõtmistega, oli andmestiku ajaline katvus palju parem ja samuti olid hinnangud tegelikele mõõtmistele üsna sarnased. Võttes arvesse eelnevaid asjaolusid ning nende järelanalüüsi andmete head kättesaadavust, on andmestik autori hinnangul kvaliteetne lahendus mullatemperatuuri hindamiseks, kuid kahjuks on sellised andmed kättesaadavad kolmekuuse viiteajaga.

Töö käigus loodi igapäevaste mullatemperatuuride prognoosimise mudel. Mudeli argumenttunnuseid valides tuli arvestada kitsendusega, et mudelit peab olema võimalik kasutada ka siis, kui prognoositava asukoha tegelikku mullatemperatuuri kunagi mõõta ei saa. Samuti pidid kõik argumenttunnused olema võimalikult lihtsalt kättesaadavad. Varasemate uuringute tulemusel on leitud, et mullatemperatuur on

tugevas lineaarses seoses õhutemperatuuriga (Zheng, Hunt ja Running, 1993; Hu *et al.*, 2020). Seega kasutati mudeldamiseks lineaarseid regressioonimudeleid. Töö käigus selgus, seos mulla- ja õhutemperatuuri vahel on talvistel temperatuuridel muust ajast erinev. Seega jaotati prognoosimine õhutemperatuuri põhjal kahe mudeli vahel, üks miinuskraadide ja teine plusskraadide jaoks.

Mudelitesse kaasati argumenttunnused, mis väljendasid õhutemperatuuri, lumikatte olemasolu ja mullatemperatuuri perioodilisust. Mudelid arendati kaheksa lokaalse mõõtmiskoha andmetel ning valideeriti ülejäänud kahe peal. Lineaarset regressiooni kasutades olid jäägid plusskraadide mudeli korral heteroskedastilised ning seega rikkusid mudeli eeldust. Sellel põhjusel kasutati mudeldamiseks kaalutud lineaarset regressiooni, mis arvestab kordajate hindamisel mudeli jäägi suurusega. Saadud mudelite täpsus keskmise absoluutse vea järgi valideerimisandmestikus oli plusskraadide mudelil $1,93^\circ$ ja miinuskraadide mudelil $0,40^\circ$. Lisaks eelnevalt kirjeldatud mudelitele vaadeldi töös ka mudelid, et hinnata mullatemperatuuri 5 cm sügavusel maapinnatemperatuuri kaudu. Viimase mudeli vajadus tekkis seireandmete analüüsis, kuna vastavad mõõtmised olid tehtud maapinnalt.

Tulevikus on võimalik antud töös välja arendatud mudeleid kasutada õhutemperatuuri, lumikatte olemasolu ja ajaga seotud argumentide põhjal mullatemperatuuri prognoosimiseks. See tähendab, et kui soovitakse mullatemperatuuri hinnangut näiteks mõnele Eesti põllule, on vaja koguda eelmainitud andmed ning siis on võimalik leida mudeli põhjal vastav hinnang. Kuna mudelisse kaasatud andmed on autori hinnangul piisavalt kergesti kogutavad, on mudeliga võimalik teha prognoose erinevate põldude jaoks üle kogu Eesti.

Kasutatud allikad

- Ameerika Ühendriikide Geoloogiakeskus (24.01.2024a). *Landsat 8-9 OLI/TIRS kollektsoon 2 2.taseme teadustoodet*. Accessed: 24.01.2024. URL: <https://www.usgs.gov/centers/eros/science/usgs-eros-archive-landsat-archives-landsat-8-9-olirts-collection-2-level-2>.
- (24.01.2024b). *Millised on Landsati satelliitide seireajad?* Accessed: 24.01.2024. URL: <https://www.usgs.gov/faqs/what-are-acquisition-schedules-landsat-satellites>.
- Annika Velt (2016). “NCEP-CFSR järelanalüüsimudeli kiirgusparameetrite valideerimine tõravere mõõtmisandmetega”. Tartu Ülikool.
- Biferno, Anya ja NASA (30.08.2023). *Climate Change: Vital Signs of the Planet - NASA*. Accessed: 20.10.2023. URL: <https://climate.nasa.gov/faq/49/which-measurement-is-more-accurate-taking-earths-surface-temperature-from-the-ground-or-from-space/>.
- Copernicus (kuupäev puudub). *ERA5-Land hourly data from 1950 to present*. Accessed: 02.11.2023. URL: <https://cds.climate.copernicus.eu/cdsapp#!/dataset/reanalysis-era5-land?tab=overview>.
- Euroopa Kosmoseagentuur (kuupäev puudub). *Sentinel-3 SLSTR Anomalies and Events*. Accessed: 02.11.2023. URL: <https://sentinels.copernicus.eu/web/sentinel/technical-guides/sentinel-3-slstr/anomalies-and-events>.
- Hu, G., L. Zhao, R. Li, X. Wu, T. Wu, Q. Pang, G. Liu ja C Xie (juuni 2020). “A model for obtaining ground temperature from air temperature in permafrost regions on the Qinghai-Tibetan Plateau”. *CATENA* 189.2, lk. 104470.

- Keskonnaagentuur (kuupäev puudub[a]). *Ajaloolised ilmaandmed*. Accessed: 02.11.2023. URL: <https://www.ilmateenistus.ee/kliima/ajaloolised-ilmaandmed/>.
- (kuupäev puudub[b]). *Ajaloolised vaatlusandmed*. Accessed: 16.11.2023. URL: <https://www.ilmateenistus.ee/meri/ajaloolised-vaatlusandmed/>.
- (kuupäev puudub[c]). *Keskonnaagentuur mõõtmistehnika maapinnal*. Accessed: 02.11.2023. URL: <https://www.ilmateenistus.ee/ilmatarkus/mootetehnika/mootmised-maapinnal/>.
- Li, Zhao-Liang, Hua Wu, Si-Bo Duan, Wei Zhao, Huazhong Ren, Xiangyang Liu¹, Pei Leng, Ronglin Tang, Xin Ye, Jinshun Zhu, Yingwei Sun, Menglin Si, Meng Liu, Jiahao Li, Xia Zhang, Guofei Shang, Bo-Hui Tang, Guangjian Yan ja Chenghu Zhou (2023). “Satellite Remote Sensing of Global Land Surface Temperature: Definition, Methods, Products, and Applications”. *Reviews of Geophysics* 61.
- Maanus Kullamaa (2015). *Maapinna ja vee optiliseks kaugseireks sobivate aastaegade analüüs Eesti alal Meteosat satelliitpilvisuse andmete põhjal*.
- Penn State Ülikooli Statistikaosakond (2021). *Weighted Least Squares and Robust Regression*. Accessed: 18.02.2024. URL: <https://online.stat.psu.edu/stat501/lesson/13>.
- Ryan, Thomas P. (2009). *Modern Regression Methods (2nd Edition)*. John Wiley ja Sons. ISBN: 978-0-470-08186-0.
- Singh, Nivedita ja Aditya Narayan Singh (2020). “Odysseys of agriculture sensors: Current challenges and forthcoming T prospects”. *Computers and Electronics in Agriculture* 171.
- Yanga, S., R. Lia, T. Wua, G. Hua, Y. Xiaoa, Y. Dua, X. Zhua, J. Nia, J. Maa, Y. Zhanga, J. Shia ja Y. Qiaoa (2020). “Evaluation of reanalysis

- soil temperature and soil moisture products in permafrost regions on the Qinghai-Tibetan Plateau”. *Geoderma* 277, lk. 114583.
- Zhao, W. ja Z.-L. Li (2013). “Sensitivity study of soil moisture on the temporal evolution of surface temperature over bare surfaces”. *International Journal of Remote Sensing* 34.9,10, lk. 3314–3331.
- Zheng, D., Jr. E. R. Hunt ja S. W. Running (1993). “A daily soil temperature model based on air temperature and precipitation for continental applications”. *Climate Research* 2, lk. 183–191.

Lisa 1. Alusandmestiku mõõtepunktid

Tabel 4: Alusandmestiku mõõtepunktidele asukohad.

Nr	Andmeallikas	Maakond	Mõõtmisperiood
1	Tooma ilmajaam	Jõgevamaa	03.08.2022 - 31.08.2023
2	Tallinn-Harku ilmajaam	Harjumaa	03.08.2022 - 08.31.2023
3	Tartu-Tõravere ilmajaam	Tartumaa	07.08.2022 - 31.08.2023
4	Tõravere mullasensor	Tartumaa	03.08.2022 - 01.11.2022
5	Niitsiku mullasensor	Põlvamaa	03.08.2022 - 28.10.2022
6	Antsla mullasensor	Võrumaa	15.10.2022 - 01.08.2023
7	Vao1 mullasensor	Järvamaa	03.08.2022 - 11.10.2022
8	Vao2 mullasensor	Järvamaa	04.02.2023 - 01.08.2023
9	Jänedä mullasensor	Lääne-Virumaa	03.08.2022 - 01.08.2023
10	Võnnu mullasensor	Tartumaa	03.08.2022 - 18.12.2022 ja 31.03.2023 - 27.07.2023

Lisa 2. Mudeli argumenttunnuste multikollineaaruse näitajad

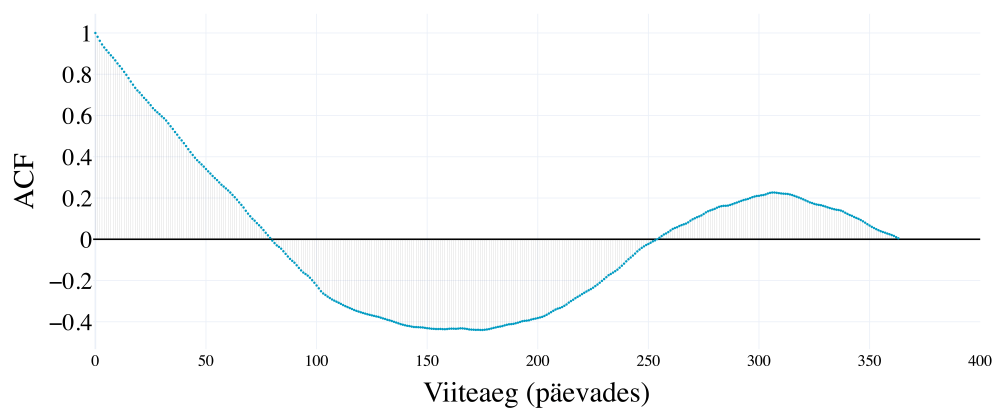
Tabel 5: Plusskraadide mudeli argumenttunnuste multikollineaaruse näitajad.

Argumenttunnus	VIF
$T_{\text{õhk}}$	28,72
$T_{\text{õhkE}}$	29,10
I_{lumi}	5,04
d_{sin}	5,80
d_{cos}	8,62
I_{Kevad}	4,83
I_{Suvi}	9,90
$I_{\text{Sügis}}$	4,29


Tabel 6: Miinuskraadide mudeli argumenttunnuste multikollineaaruse näitajad.

Argumenttunnus	VIF
$T_{\text{õhkE}}$	49,75
$T_{\text{õhk3Ek}}$	50,85
d_{sin}	1,13
d_{cos}	2,02

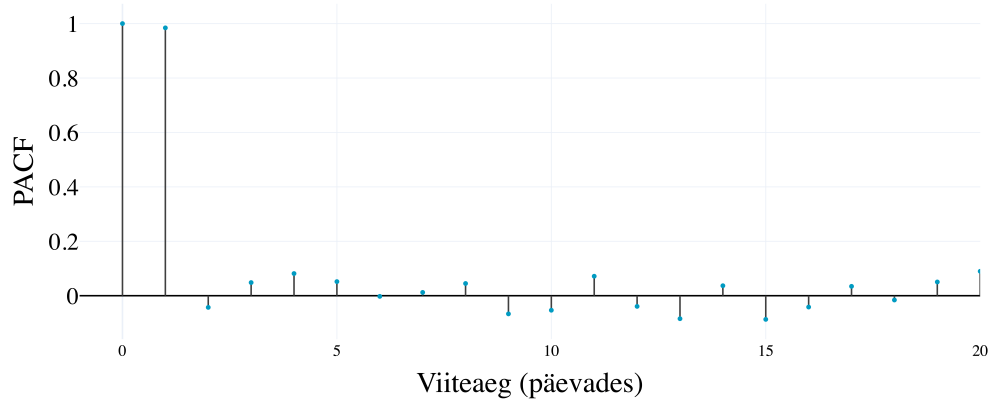
Lisa 3. Temperatuuride autokorrelatsioonid



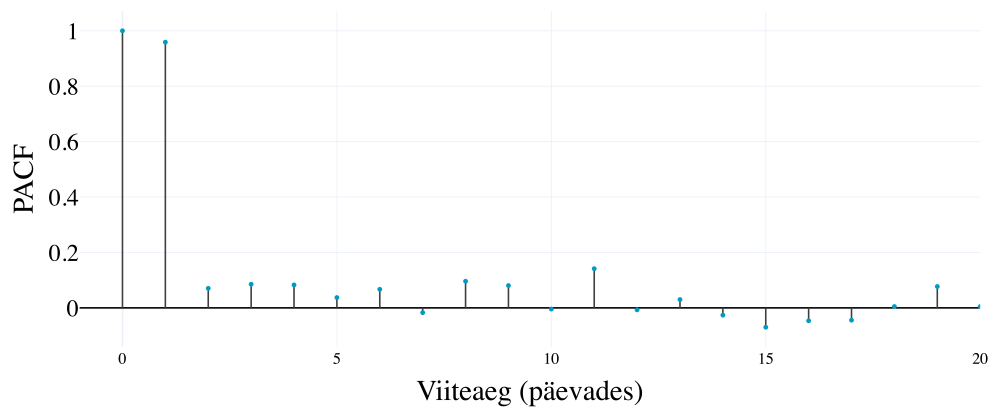
Joonis 18: Mullatemperatuuri autokorrelatsioonifunktsioon Jänedas mullasensori andmete põhjal.



Joonis 19: Õhutemperatuuri autokorrelatsioonifunktsioon Jänedas mullasensori asukohas.



Joonis 20: Mullatemperatuuri osaautokorrelatsiooni funktsioon Jäneda mullasensori andmete põhjal.



Joonis 21: Õhutemperatuuri osaautokorrelatsiooni funktsioon Jäneda mullasensori asukohas.

Lihtlitsents lõputöö reprodutseerimiseks ja üldsusele kättesaadavaks tegemiseks

Mina, Lotta-Lorette Kalmaru,

1. annan Tartu Ülikoolile tasuta loa (lihtlitsentsi) minu loodud teose „Mulla-temperatuuride hindamine meteoroloogiliste ja kaugseire andmete põhjal“, mille juhendajad on Tiit Sepp ja Toomas Raus, 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 4.0, 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.

Lotta-Lorette Kalmaru

30.04.2024