

Tartu Ülikool  
Loodus- ja täppisteaduste valdkond  
Ökoloogia ja maateaduste instituut  
Geograafia osakond

Magistritöö geograafias  
Põuasuse sesoonne, territoriaalne ja pikaajaline muutlikkus Eestis

**Lauri Leinus**

Juhendajad: prof Jaak Jaagus, kaasprof Ain Kull

Tartu 2024

# Põuasuse sesoonne, territoriaalne ja pikaajaline muutlikkus Eestis

## Annotatsioon

Sademed on teraviljade ja teiste põllukultuuride kasvatamiseks väga olulised. Vajalikke niiskuselusi saab hinnata erinevate põuasuse indeksitega, mille positiivsed väärtused näitavad keskmisest niiskemaid ilmaolusi ja negatiivsed väärtused kuivemaid tingimusi. Põuasuse hindamiseks on kasutatud standardiseeritud sademete indeksit (SPI) ja standardiseeritud sademete-evapotranspiratsiooni indeksit (SPEI). Käesolevas uurimistöös on kasutatud Eesti 23 ilmajaama ööpäeva keskmise õhutemperatuuri andmeid ajaperioodil 1951–2023 ja ööpäeva sademete summasid ajaperioodil 1948–2023. Leitud on kõigi ilmajaamade SPI ja SPEI ööpäevased väärtused perioodil 1. mai kuni 30. september, kusjuures antud päeva indeksi arvutamisel on arvesse võetud eelneva 30 päeva andmeid. Teostatud on SPI ja SPEI aegridade trendianalüüs, seejuures on muutuste olulisust hinnatud p-väärtuste alusel. SPI ja SPEI piirkondlikud keskmised väärtused on arvutatud eraldi Põhja-Eesti, Lõuna-Eesti, Kesk-Eesti, Lääne-Eesti, Lääne-Eesti saarte ja Jõgeva maakonna ilmajaamade kohta. Muutuste graafikutel on kaks perioodi, mil põuasus on vähenenud. SPI kohaselt on keskmisest kuivemad tingimused olnud mai algusest kuni 24. maini, 22. juulist kuni 3. augustini ja 22. kuni 30. septembril. SPEI kohaselt on keskmisest kuivemad tingimused olnud mai algusest 12. juunini, 12. juulist kuni 25. augustini ja 11. kuni 30. septembril. Arvutused näitasid, et sademed on kõige rohkem suurenenud Kihnus ja kõige vähem Valgas.

Võtmesõnad: kliimamuutused, põuasuse indeksid

CERCS kood: P510 – füüsiline geograafia, geomorfoloogia, mullateadus, kartograafia, klimatoloogia

## Seasonal, territorial, and long-term variability of drought in Estonia

Precipitation is very important for growing cereals and other crops. The necessary humidity conditions can be estimated with different drought indices, with positive values indicating wetter than average weather conditions and negative values indicating drier conditions. Standardized Precipitation Index (SPI) and Standardized Precipitation-Evapotranspiration Index (SPEI) have been used to assess droughts. In this study, daily average temperature data from 23 weather stations in Estonia in the period from 1951 to 2023 and the daily precipitation totals in the period from 1948 to 2023 have been used. The daily values of SPI and SPEI for all weather stations have been found in the period from May 1 to September 30, while the data of the previous 30 days have been considered when calculating the index for a given day. A trend analysis of SPI and SPEI time series has been performed, in which the significance of changes has been assessed on the basis of p-values. The regional average values of the SPI and SPEI indices have been calculated separately for weather stations in North Estonia, South Estonia, Central Estonia, Western Estonia, on the islands of Western Estonia and in Jõgeva County. The graphs of the changes show two periods where the drought has decreased. According to SPI, drier than average conditions have been experienced from early May to May 24, July 22 to August 3, and September 22 to September 30. According to SPEI, on average, the drier than average conditions have prevailed from the beginning of May until June 12, from July 12 to August 25, and from September 11 to September 30. Calculations showed that precipitation has increased the most in Kihnu and the least in Valga.

Keywords: climate change, drought indices

CERCS code: P510 – physical geography, geomorphology, pedology, cartography, climatology

# Sisukord

1	Sissejuhatus .....	5
2	Teooria ja varasem uuritus.....	8
2.1	Standardiseeritud sademete indeks ( <i>Standardized Precipitation Index, SPI</i> ).....	15
2.2	Standardiseeritud sademete- <i>evapotranspiratsiooni</i> indeks ( <i>Standardised Precipitation-Evapotranspiration Index, SPEI</i> ) .....	16
2.3	Palmeri põua tugevuse indeks ( <i>Palmer Drought Severity Index, PDSI</i> ) .....	17
2.4	Saagi niiskuse indeks ( <i>Crop Moisture Index, CMI</i> ).....	18
2.5	Pinnavee varustatuse indeks ( <i>Surface Water Supply Index, SWSI</i> ).....	18
2.6	Detsiilid.....	18
2.7	Vegetatsioonitingimuste indeks ( <i>Vegetation Condition Index, VCI</i> ) .....	18
2.8	Bhalme-Mooley põuaindeks ( <i>Bhalme-Mooley Drought Index, BMDI</i> ) .....	19
2.9	Põua raskusastme indeks ( <i>Drought severity index, DSI</i> ).....	19
2.10	Efekttiivne põuaindeks ( <i>Effective Drought Index, EDI</i> ) .....	20
2.11	Mullaniiskuse põuaindeks ( <i>Soil Moisture Drought Index, SMDI</i> ) .....	20
2.12	Konkreetses põllukultuuri põuaindeks ( <i>Crop Specific Drought Index, CSDI</i> ) .....	21
2.13	Evapotranspiratsiooni defitsiidi indeks ( <i>Evapotranspiration Deficit Index, ETDI</i> ).....	21
2.14	Maapinna temperatuuri hinnang ( <i>Land surface temperature estimates, LST</i> ) .....	22
2.15	Tempertuuringimuste indeks ( <i>Temperature Condition Index, TCI</i> ) .....	22
2.16	Vegetatsiooni põuavastuse indeks ( <i>Vegetation Drought Response Index, VegDRI</i> ).....	23
2.17	Vegetatsiooni kuivuse temperatuuriindeks ( <i>Temperature Vegetation Dryness Index, TVDI</i> )	23
2.18	Seljaninovi hüdrotermiline koefitsient.....	24
3	Andmed ja meetodika.....	25
3.1	Andmed väliuuringute uurimisalade paiknemise kohta koos alade iseloomustusega ..	25
3.2	Valimi koostamise põhimõtted ja valimi asjakohane kirjeldus.....	26
3.3	Andmete päritolu, struktuur, kasutatavus jm vajalikud iseloomustused.....	27
3.4	Ilmajaamade grupeerimine piirkonniti.....	27
3.5	SPI indeksi arvutuskäik.....	28
3.6	SPEI arvutamine kalkulaatoriga ETCalc .....	29
3.7	Ilmastikuindeksite arvutamine programmeerimiskeeles R.....	30
3.8	Ilmastikuindeksite arvutamine MS EXCEL-is .....	32
3.9	Ilmastikuindeksite muutuste väärtused .....	33

3.10	Ilmastikuindeksite p-väärtuste koondtabel MS EXCEL-is.....	33
3.11	Mann-Kendalli test.....	34
4	Tulemused.....	35
4.1	Keskmiised sademed.....	35
4.2	Sademetete muutuste analüüs .....	36
4.3	Põuasuse indeksi pikaajalised muutused, varieeruvus ja äärmusväärtused .....	37
4.3.1	Standardiseeritud sademete indeks (SPI).....	37
4.3.2	Standardiseeritud sademete-auramise indeks ( <i>Standardized Precipitation-Evapotranspiration Index</i> , SPEI) .....	45
4.3.3	P-väärtused, SPI.....	51
4.3.4	P-väärtused, SPEI .....	53
5	Arutelu ja järeldused.....	55
6	Kokkuvõte .....	60
	Summary .....	62
	Kasutatud kirjandus .....	64
	Lisad.....	74

# 1 Sissejuhatus

Viimastel aastatel on väga laialdaselt käsitletud kliimamuutustest tingitud põudasid taimekasvuperioodi vältel ning ulatuslikke maastikupõlenguid (Gray et al., 2016; Prichard et al., 2017). Eestis on täheldatud, et hiliskevadel ja suvel külvatud kultuurid on saanud põuast ja kõrgetest temperatuuridest kahjustusi. Temperatuuri tõusu tõttu kahaneb sajandi lõpuks teraviljasaak üleilmselt (Supit et al., 2012). Vegetatsiooniperiood pikeneb, aga samas võib põudade tõttu lüheneda aeg biomassi moodustumiseks (Setianingsih et al., 2020).

Sõltuvalt kultuuri tüübist võib saagikus lähiaastatel kas kahaneda, kasvada või muutumatuks jääda. Näiteks kahaneb maisi saagikus peaaegu kõikjal Euroopas. Erinevate trendiarvutuste kohaselt saab sama väita ka suhkruroo kohta. Ennustuste kohaselt Eesti lähiümbruses trend puudub (Moravec et al., 2021).

Selleks, et hinnata taimede kasvu ja tootlikkust, kasutatakse biofüüsikalisi mudeleid. Hea näitena rahvusvahelisest koostööst võib tuua prantslaste, jaapanlaste ja sakslaste koostatud taimekasvu ja sademete vahelisi seoseid käsitlevaid mudeleid, mille sisendandmed koosnevad peaaesjalikult maksimum- ja miinimumtemperatuurist, tuule kiirusest, summaarsest päikesekiirgusest ja sademetest. Seejuures tuletatakse juurte sügavus, kuivenduse tingimused, soolsus ja aluselisis kõik peamistest mulla omadustest (Supit et al., 2012).

Käesolevas töös kasutatud uurimustööde tulemused näitavad, et kliimaatilised tegurid põhjustavad ajalise nihke. Taimekasvu esimesed fenoloogilised faasid esinevad varem, sest kliima on muutunud soojemaks. Kui põud ja öökülmad langevad samale ajale, siis saavad taimed eriti suuri kahjustusi (Põiklik, 1964).

Ilmastiku ja taimekasvu seotus sõltub kasvu- ja vananemisfaasidest, kuna temperatuuri, energia ja toitainete vahel on seos. Seesugune mõju sõltub suuresti ilmastikulistest teguritest (temperatuur, päikesekiirgus ja sademed), taimestiku tüübist ja asupaigast. Sellise mõju arvutuste juures kasutatakse pikaajalise üleilmse kliima ja vegetatsiooni indeksi andmeid ning ka taimestiku klassifitseerimist (Ding et al., 2020).

Põhjalikult on käsitletud põudade ja taimekasvu vahelisi seoseid Eric Lichtfouse et al. (2009). Autorid leiavad, et veepuudus piirab oluliselt taimede kasvu ja saagikust ning põuast põhjustatud

saagi vähenemine ületab kõiki teisi kadusid. Käsitatud on ka põuastressi mõju taimekasvule, fenoloogiale, taimede vee ja toitainete omastamisele, fotosünteesi häiritust ja taimehingamist (Farooq et al., 2009; Zlatev ja Lidon, 2012).

Selleks, et katta inimkonna vajadust põllukultuuridest saadud toitainete järele, on vajalik tõsta põllukultuuride vastupidavust kliimamuutustele. Siinkohal on abiks täienevad teadmised põllukultuuride aretamisel. Kliimamuutuste suure mõju tõttu on vaja ka hinnata hetketeadmisi ja kaaluda, kuidas tuleks tegutseda, selleks et jõuda soovitava põllumajandusliku tootmiseni (Benitez-Alfonso et al., 2023).

Metsapõlengute laialdane levik 21. sajandi põudade ajal viitab mustriks, mis võib kujuneda välja sagedaseks (Brando et al., 2020). Kergemini süttiva maastiku tõttu tuleb vähendada süttimise allikaid ja lageraiet, selleks et säästa metsi. Põudade mõju hindamiseks kasutatakse üleilmselt erinevaid põudadega kaasnevaid tegureid, mis põhinevad satelliitide MODIS (*Moderate Resolution Imaging Spectroradiometer*), Landsat ja TRMM (*Tropical Rainfall Measuring Mission*) andmetel.

Ilmaandmeid, sealhulgas sademete andmeid, on võimalik saada Copernicuse programmi satelliitide abil. Nendeks on Sentinel-1 ja Sentinel-2 põlvkonna satelliidid. Sentinel-1 satelliidipiltide peamine eelis on suur vaatluse ulatus, mis pakub võimalust saada ülevaatlikke andmeid ja ilmasündmuse kindlat sünoptilist kuva, mida ei saa saavutada koha peal suure ajasammuga tehtavate mõõtmistega (Lopez et al., 2020).

Käesolevas uurimistöös kasutatakse põuasuse hindamiseks peajasalikult SPI ja SPEI indekseid, mis on lahti seletatud töö teooria osas. Sellest tulenevalt on tehtud järeldused, kuidas on põuasus Eestis muutunud ajaperioodil 1948–2023. Töö teooria osas on mainitud ka rahvusvaheliselt kasutatavaid, kuid mitte nii tuntud põuasuse indekseid.

Meteoroloogiline põud on seotud hooajaliselt tavapärasest väiksemate sademetega. Võrreldakse ühe kindla ala päevaseid, ühes kuus või aasta jooksul langevaid sademeid kindla baasi suhtes. Käesolevas uurimistöös ongi kesksel kohal meteoroloogiline põud. Kasutatakse ka hüdroloogilise põua mõistet, mille puhul on jõgede, põhjavee, järvede ja veereservuaaride veevaru tavapärasest väiksem. Põllumajanduslik põud tähendab olukorda, kus meteoroloogiline ja hüdroloogiline põud

mõjutavad põllumajanduslike saaduste ja kariloomade tootlust. Oluline on märkida, et taime veevajadus sõltub taime tüübist, kasvu kiirusest ja mulla omadustest (Setianingsih et al., 2020).

Käesoleva magistritöö eesmärk on välja selgitada põuasuse sesoonne muutlikkus, võttes arvesse territoriaalset komponenti ehk kuidas esinevad põuad erinevates asupaikades Eestis, ja teha kindlaks põuasuse pikaajalised kõikumised. Täiendavaks eesmärk on selgitada, kas pikaajaline trend on olemas ja milline on põuasus kuude kaupa. Trendiarvutused on teostatud päevade kaupa. SPI ja SPEI muutude väärtused on leitud päevade lõikes ning sellest lähtuvalt on tehtud järeldused selle kohta, kuidas sademeterežiimi ja auramise muutused muudavad taimekasvu.

Uurimisküsimused on järgnevad:

1. Kas taimede kasvuperioodi ajal langevate sademete puhul esineb kindel sesoonne muutlikkus?
2. Kas põuad erinevad territoriaalselt Eesti erinevates asupaikades?
3. Millised on olnud põuasuse indeksite pikaajalised trendid?

Magistritöö hüpoteesid on järgnevad:

1. Sademete andmete põhjal on maikuu terviklikult, juulikuu lõpp ja september muutunud kuivemaks.
2. Taimedele reaalselt kättesaadav niiskus on oluliselt väiksem, kui seda näitavad ainult sademete andmed.
3. Lääne-Eesti saarte ilmastikuolud on lisaks sademete andmetele auramise andmeid kasutades muutunud kuivemaks.

Magistritöö esimeseks osas antakse ülevaade teooriast ja esitatakse võrdlev analüüs analoogiliste uurimistöödega. Sellele järgneb andmete ja meetodika kirjeldus. MS EXCEL-is leitud SPI ja SPEI muudud kajastuvad töö tulemuste osas, nii nagu ka MS EXCEL-is ja programmeerimiskeeles R Thornthwaite'i meetodil leitud SPEI. Tulemusi on kontrollitud veebis kalkulaatoriga ETCalc. SPI ja SPEI tulemusi võrreldakse magistritöös omavahel. Viimases töö etapis arutletakse tulemuste üle ning tehakse järeldused vastavalt koostatud teooriale. Magistritöö lisas on esitatud kaks programmeerimiskeeles R koostatud programmi (Lisa 1, Lisa 2). Esimesega neist on leitud ilmastikuindeksite muutuste graafikud ja p-väärtused iga kuupäeva jaoks ajavahemikus 1. mai kuni 30. september. Teisega neist on leitud Mann-Kendalli testiga Seni tõusu hinnangud.

## 2 Teooria ja varasem uuritus

ÜRO Valitsustevahelise Kliimamuutuste Paneeli (IPCC) raportis AR6 jõuti tulemuseni, et viimased kolm kümnendit on olnud varasematest soojemad. Selle raporti kohaselt on troposfäär alates 1950. aastatest soojenenud ning stratosfäär jahenenud. Need muutused põhjustavad muutusi veeringluses ja see omakorda põhjustab üleujutusi, põudasiid ja muid Maa pinnal esinevaid anomaaliad. Seetõttu muutuvad ka keskmised ja äärmuslikud sademed, auramine ja vee äravool (IPCC, 2021).

Üha sagedasemad kuumalained, põuad ja üleujutused mõjutavad teraviljade saagikust. Heaks näiteks on 2018. aastal Euroopat tabanud kuumalaine, mille vältel olid ilmastikutingimused äärmuslikud (Alfonso et al., 2023). Selle tulemusel vähenes teravilja saagikus isegi kuni 40%.

Samuti võivad põllul samaaegselt esineda põud, liigne valgus ja kuumus ning teisedki stressitegurid, millele taimed reageerivad. Farooq et al. (2009) on põuale vastupidavust defineeritud kui võimekust kasvada, õitseda ja anda majanduslikult kasulikku saaki optimaalsest väiksema vee olemasolul.

Seni tehtud teadusuuringutest selgub, et põud põhjustab lehtede väiksema pindala, piirab taime varte kasvu ja pärsib juurte arengut. Süsihappegaasi omastamine keskkonnast on raskendatud, sest õhulõhed on sulgunud, membraan võib olla kahjustunud ja takistatud on ka erinevate ensüümide toime (Eric Lichtfouse et al., 2009).

Erinevad põllukultuurid vajavad vastavalt kasvufaasile suuremal või vähemal määral vett. Sellest lähtuvalt saab tuletada erinevate kultuuride puhul mitmesuguseid efektiivseid sademete koguse väärtusi (Asadi et al., 2019). Sademed on eriti olulised teravilja kõrsumise faasis. Seevastu mõjuvad sademed enne vilja koristust saagile halvasti või on ebaefektiivsed. Igasuguse teravilja tootmise aastase muutuse juures on kõige olulisem aastane sademete summa ja see, et sademed langeksid ühtlaselt kogu kasvuperioodi vältel. Kuna erinevad taimed reageerivad sademetele erinevalt, siis Asadi et al. (2019) hinnangul on nisu saagikus tundlik sademetele tundliku kasvufaasi ajal, samas kui maisi tootlikkus on tundlik sademetele ainult kriitiliste kasvufaaside ajal.

Juuni on teraviljade valmimise seisukohalt kriitilise tähtsusega. Sel ajal on veestress teraviljadele väga kahjulik (Kolář et al., 2014). Ingver jt. (2010) toovad välja, et põuastel aastatel ja varase

juunikuu põua ajal on katsealuste põllukultuuride saagikus madal. Tšehhi Vabariigi näitel viisid äärmuslikult kuivad tingimused kevadodra saagikuse vähenemiseni (Ingver jt., 2010). Kaera saagikus väheneb lamandumise ja põua tõttu. Juunikuu veebilanss on tähtis odra saagikusele. Kaera ja odra saagikus on juunikuu puhul negatiivses korrelatsioonis päikesepaiste kestusega. Nisu puhul statistiliselt olulist korrelatsiooni ei esine (Ingver jt., 2010). Juunikuus aset leidev põud põhjustab tavapäraselt märgatava viljakate õisikute vähenemise (Hollins et al., 2004).

Põllukultuuride kasvuks on väga olulised ka juulikuu sademed. Maitah et al. (2021) kohaselt on juulikuu sademed peaaegu kõigis Tšehhi Vabariigi regioonides positiivses korrelatsioonis maisi saagikusega ja kõigis regioonides esineb madal kuni mõõdukas positiivne korrelatsioon silomaisi saagikuse ja sademete vahel. Veedefitsiit on negatiivses korrelatsioonis maisi saagikusega.

Põllumajandustootjate kasum teramaisist on mõjutatud saagikuse määrast, temperatuurist, sademetest ja veedefitsiidist. Kasvav nõudlus maisi järele võib suurendada 2050. aastaks maisi importi arengumaadesse kolm korda. Kui keskmine õhutemperatuur tõuseb üleilmselt 2°C võrra, siis on maisi kasvatuses tegelevad piirkonnad järjest enam mõjutatud varasemast soojematest ilmadest ja põuast. Selliste oludega peavad toime tulema peamised suuremad ja väiksemad maisi kasvatuses tegelevad piirkonnad. Kuna silomaisi kasvatatakse Eestiski üha enam, siis on see ka Eesti põllumajanduse seisukohast oluline (Aus, 2015).

Kliimamuutustest tingitult muutub veeringlus. Muutub vee kogus, äravoolu sagedus ja maapinnale langevate sademete intensiivsus. Kliimamuutustest tulenevaid põua- ja sademeterohkemaid perioode on raske täpselt ennustada. Sellest lähtuvalt on oluline uurida sadememustreid kogu vegetatsiooniperioodi vältel. Sademete andmed lähiminevikust võivad pakkuda olulist teavet tuleviku kohta. Oluline on märkida, et kõrgemad temperatuurid põhjustavad suuremat pinnavee aurumist (Dahal et al., 2018).

Lobelli ja Asneri (2003) uurimuses kasutati regressioonil põhinevaid statistikuid, et uurida, kuidas on Ameerika Ühendriikides seotud kliimamuutused ja põllukultuuride saagikus. Selgus, et maisi ja sojaoa saagikus on sõltub tugevalt temperatuurist, samas kui sademetel ja päikesekiirgusel on väike mõju (Lobell ja Asner 2003 *cit.* Chen et al. 2013). Samas on põual siiski suur mõju saagikusele. Seda ei saa alahinnata.

Ainuüksi põud põhjustab rohkem aastaajalist teravilja saagikuse langust kui mistahes patogeenid kokku. Mulla niiskuse gradiendiga kohastumiseks muudavad taimed oma füsioloogiat, juurte kasvu ja paigutust ning sulgevad maapealsete segmentide õhulõhed. Koepõhised muutused reguleerivad rakusignaale, mis põhjustab varast õitsemist ja sageli ka väiksemat saagikust (Gupta et al., 2020). Taimel tasemel põhjustab põud tavaliselt väiksemat kasvu ja väiksemat süsiniku kasutamist fotosünteesis (Zlatev et al., 2012).

Varasemalt on tõestatud, et taimedel on tekkinud hulk kohanemismehhanisme, mis aitavad biokeemilistel süsteemidel toime tulla veedefitsiidiga. Väga tähtsal kohal on rakkude ainevahetuse paindlikkus ja nende kiire kohanemine muutuvates keskkonnatingimustes, mille korral avaldub taimede stress (Basu et al., 2016).

Levitt (1982) defineerib stressi kui mistahes keskkonnategurit, mille tõttu tekkib elusorganismis vigastus. Orgaanilise aine kogunemine sõltub väga suurel määral taimede lehtede pindalast. Näiteks assimileerib väikse lehepinnaga taim, mille fotosünteesi kiirus on suur, sama palju orgaanilist ainet, kui taim, millel on suur lehe pindala, kuid väike fotosünteesi kiirus.

Selleks, et jääda ellu ka veedefitsiidi tingimustes, hoiavad taimed põua ajal raku turgori piisavalt kõrgena. Mitmete uurimistööde tulemused viitavad taimede ainevahetusprotsessidele, mille kohaselt on nad tundlikumad turgorile ja rakkude ruumalale, nii nagu ka absoluutsele õhuniiskusele (Basu et al., 2016; Farrell et al., 2017).

Mullad pakuvad tähtsaid ökosüsteemi teenuseid: nad annavad taimede kasvuks toitaineid, süsinikku ja lämmastikku. Ökosüsteemi teenused on vajalikud, kindlustamaks jätkuvat Maa rahvastiku toitmist. Mitmed eksperimendid on näidanud, et seenepõhised toiduahelad on paremini võimelised seisma vastu põuale ja hoidma kinni süsinikku ja lämmastikku, kui bakteripõhised toiduahelad, mida on võimalik seostada intensiivsema põllumajandusega (de Vries et al., 2012).

Enneolematult äärmuslikud ilmastikunähtused mõjutavad taimede kasvu, koosluste struktuuri ja ökosüsteemi funktsioone ja teenuseid erinevatel viisidel. Mitmetes uurimustes kasutatakse tõendeid sellest, kuidas mõjuvad äärmuslikud sündmused taimede tootlikkusele ja nende suremusele. Omavahel seostatakse füsioloogilisi, molekulaarseid ja ökoloogilisi mehhanisme ja antakse soovitusi edasiseks uurimistööks, mille abil õpitakse tundma taimede ja ökosüsteemi reageerimist äärmuslikele kliimasündmustele (Niu et al., 2014).

Põllukultuuride saagikus on fotosünteesi ja teiste seotud füsioloogiliste protsesside lõpp-produkt. Põuast põhjustatud väiksem taimekasv ja produktiivsus on peamiselt põhjustatud taimede muutunud veevahetusest, vähenenud fotosünteesist, rakkude oksüdatiivsest stressist, membraani kahjustustest ja mõnel juhul piiratud ensüümide tegevusest. Kultuuride majandamine parandab vastupidavust rasketele tingimustele ja pakub võimalust leevendada selliseid mõjusid ja saagikuse kadu. Siinkohal tuleks veel mainida taimekasvu soodustavaid baktereid, mis esinevad loomulikult mullas ja mis on tuntud kui taime kasvu stiimul (Batool et al., 2020).

Peamised abiootilised stressiallikad, millega taimed peavad vastamisi seisma, on põud, üleujutused, pinnase sooldumine, tavapärasest kõrgemad ja madalamad temperatuurid ning raskmetallid. Leidub mitmeid morfoloogilisi, füsioloogilisi ja biokeemilisi parameetreid, mis on põhjustatud põuastressist, lehtede kolletumisest, vähenenud lehe pindalast ja klorofüllisisaldusest, juurte pikenemisest ja reaktiivse hapniku tekkimisest. Mitmed uurimistööd viitavad sellele, et mitmete põllukultuuride puhul leevendavad kasvu soodustavad risobakterid põuastressi. Selle heaks näiteks on tomati, pipra, herne, maisi, nisu, mungoa ja kikerherne taimkatsete tulemused. Põuastressist tingitult väheneb põllukultuuride saagikus, sest taimedel on piiratud veevahetus, mis muudab omakorda füsioloogilisi ja biokeemilisi protsesse. (Gontia et al., 2016).

Dhanda et al. (2002) uurimuses hinnati 30 nisusorti. Hinnatavateks parameetriteks olid seemnete kvaliteedi indeks, idanemise protsent, juurte pikkus, võrsete pikkus, juurte ja võrsete pikkuse suhe ja membraani osmootiline stabiilsus. Avastati olulised erinevused nende parameetrite osas. Kõige tundlikumaks parameetriks oli seemnete kvaliteedi indeks, millele järgnes võrsete pikkus, idanemise protsent ja juurte pikkus.

Saagikust mõjutavad mitmesugused muutujad nagu ebasobiv põllutöömasinate kasutamine, haritava maa vähesus ning biotilised ja abiootilised tegurid (Akhtar et al., 2021). Põllumajandusliku tootmise kasvu tingimustes on äärmiselt oluline säästa loodusressursse ja kaitsta keskkonda, et taimed saaksid paremini toime tulla veepuudusega. Kui on kindlaks tehtud taimestressi olemasolu, siis saab vastavalt kujunenud olukorrale kasutusele võtta täiendavaid meetmeid põllukultuuride saagikuse parandamiseks. Hinnangute järgi toidab nisu viiendiku planeedist Maa. Seejuures peab nisu vastu pidama järjest süvenevatele põuaperioodidele, mis on osaliselt põhjustatud kliimamuutustest (Camillo et al., 2021).

Seisame 21. sajandil olulise väljakutse ees: meil tuleb mõista, millist mõju avaldab põud põllukultuuridele, ja töötada välja targad strateegiad nende mõjudega toimetulemiseks. Üks võimalik lahendus on niisutamine, kuid üleilmne põllumajanduse veevajadus suureneb 2050. aastaks 60%, millele vastab rohkem kui kaks kolmandikku globaalsest magevee vajadusest. Seetõttu ei pruugi niisutamine tegelikult kõikjal lahenduseks olla (Camaille et al., 2021).

Mõned uurimused on näidanud, et vabalt elavad taime risobakterid võivad aidata kaasa taime vastupanuvõimele veepuuduse suhtes. Kasvuhoone tingimustes on läbi viidud uurimused, et hinnata taime kasvu edendavate risobakterite mõju, juurte arenguks olulisi väetisi ning maisi biomassi tootlikkust (Lin et al., 2019). Viimast mõju on hinnatud põua puhul varaste kasvufaaside tingimustes.

Viimastel kümnenditel on järjest täienenud majandusuuringute andmed, mis ennustavad, et kliimamuutustel on mõju üldisele heaolule, sealhulgas põllumajandusele, tööstusele, inimeste tervisele, energianõudlusele ja majanduse kasvule. Võttes arvesse kliimategureid ja taimekasvu, uuritakse põhjalikult põllumajandussektorit (Zhang et al., 2017). Enamik majandust käsitlevaid uurimusi keskendub temperatuurile ja sademetele, ignoreerides suuremalt jaolt selliseid kliimamuutujaid nagu niiskus, tuule kiirus, päikesepaiste kestus ja aurumine.

Kui tähelepanuta on jäetud täiendavad kliimamuutujad lisaks temperatuurile ja aurumisele, siis võib see mõjutada hinnangut tulevasele saagikusele. Eelkõige mõjutab see kliimamuutujate jaotust. Samuti võivad täiendavad kliimamuutujad osutada vajalikuks põllukultuuride kasvu hindamisel. Kliimamuutujate vahelisest korrelatsioonist tingituna võib täiendavate kliimamuutujate eiramine mõjutada temperatuuri ja sademete koefitsiente (Chen et al., 2013; Ling et al., 2023).

Varasemates teadustöödes on uuritud ka õhuniiskust, tuule kiirust, päikesepaiste kestust ja aurumist. Uurimuste kohaselt tõstab 1% suurune keskmise niiskuse kasv vegetatsiooniperioodi jooksul riisi, nisu ja maisi saagikust vastavalt 0,75%, 0,96% ja 0,61%. Kui keskmine tuule kiirus kasvab vegetatsiooniperioodi jooksul 1 m/s, siis riisi ja nisu saagikus väheneb vastavalt 14,51% ja 13,91%. Kui keskmine päikesepaiste kestus kasvuhooajal kasvab ühe tunni võrra, siis riisi ja maisi saagikus kasvab hinnanguliselt vastavalt 6,10% ja 3,84%. Aurumisel ei ole suuremat mõju. Olenevalt kultuurist on ilmal väga erinev mõju saagikusele. Näiteks võib riisi saagikus väheneda

31,90%, samas kui nisu saagikus võib väheneda 11,85% või suurenda kuni 3,14%, maisi saagikus võib väheneda 42,59% kuni 47,10% (Zhang et al., 2017).

Kõrgem temperatuur ja suurem kogus sademeid on tulevikus palju sagedasemad. Oluline on seegi, kuidas on erinevad kliimaatilised muutujad korreleeritud, sest see mõjutab otseselt taime kasvu vegetatsiooniperioodi kestel. Näiteks on temperatuur positiivses korrelatsioonis sademete ja suhtelise õhuniiskusega, samas kui negatiivne korrelatsioon esineb temperatuuri ning tuule kiiruse, ja auramise vahel (Hatfield et al., 2015; Zeppel et al., 2014).

Erinevad uurimused näitavad, et vähenenud sademed põhjustavad kõrvalekaldeid auramise, mulla niiskuse, vooluvee ja veetaseme juures. Seejuures on temperatuurist ja pinnakatte häiringutest põhjustatud kõrvalekalded väiksema tähtsusega. Need tegurid ei ole lineaarses seoses, kui neid vaadelda üheskoos. Mitme teguri koosmõju võib tuleneda koosmõjust temperatuuri, sademete ja pinnakatte vahel. Parem arusaam põuast on tähtis, et majandada ressursse säästlikult ja on üleilmselt otsustava tähtsusega põllumajandusliku tootmise juures (Hein et al., 2019).

Kuna kliima soojeneb inimtegevuse käigus atmosfääri paisatavate kasvuhoonegaaside tõttu, siis muutuvad meteoroloogilised põuad järjest sagedasemaks ja nende raskusaste on suurem. Sellised meteoroloogilised põuad muutuvad hüdrooloogilisteks põudadeks, kuna veelahkmed on järjest enam põudadest mõjutatud. Parem arusaamine meteoroloogilisest põuast ja selle tulemusel tekkinud hüdrooloogilise põua mudelid on väärtuslikud, aidates tulevikus täita säästva arengu tingimusi (Hein et al., 2019).

Põllumajandus, mis saab vajaliku vee sademetest, on väga tundlik äärmuslike kliimatingimuste suhtes ja seetõttu ei taga see põllukultuuride saagikuse stabiilsust. Me ei saa arvestada, et üksikule ajamomendile langeb põud ja see põhjustab kohese saagi hävimise, sest põllumajandus sõltub ka niisutamisest. Kui sademeid langeb näiteks ebareeglipäraselt, siis peavad põllukultuurid tulema toime lühiajalise veedefitsiidiga, mis põhjustab põllukultuuride saagikuse vähenemise (Sohoulande et al., 2019).

Ingver jt. (2010) hinnangul määravad põllukultuuri aastase saagikuse ja kvaliteedi paljud tegurid: ilm, põllukultuuri geneetiline mitmekesisus, väetised, mulla tingimused, kahjurite olemasolu ja haigused. Kui kultuur saab kätte piisavalt toitaineid, siis sõltuvad saagikus ja kvaliteet peamiselt

ilmastikutingimustest. Põllukultuuri saagikus sõltub aastast. Saagikus erineb erinevatel aastatel rohkem kui kolm korda kaera ja odra puhul ning kaks korda nisu puhul (Ingver et al., 2010).

Shen et al. (2019) uurimuse tulemused näitavad, et põua mudelid on hästi rakendatavad meteoroloogilise ja põllumajandusliku põua uurimisel. Selliste arvutuste juures kasutatakse enamasti otsustusmetsa meetodit (Shen 2019, *cit.* Wang 2018). Tegemist on masinõppe tehnikaga, mis on mõeldud nii klassifitseerimis- kui ka regressiooniülesannete lahendamiseks. See põhineb mitme otsustuspuu loomisel ja nende tulemuste kombineerimisel, et saada täpsemaid ja stabiilsemaid ennustusi. Otsustuspuu puhul kasutatakse lihtsaid otsustusreegleid, mis põhinevad andmete tunnustel. Iga otsustuspuu on koostatud juhuslikult valitud alamhulkade treeningandmetest ning kasutab ennustamiseks juhuslikult valitud tunnuseid. Otsustusmetsa meetod annab täpseid tulemusi ning aitab selgitada, millised kliima- või muud tunnused on põua ennustamisel kõige olulisemad (Dikshit et al., 2020).

Kui Indias on sademete hulk ja vihmaste päevade arv püsinud sisuliselt muutumatuna (esinenud on väike kahanemistrend kõigi sademete ja suvise mussooni sademete puhul), siis Itaalias on need kahanenud ja Hiinas seevastu kasvanud (Kulkarni et al., 2020; Caporali et al., 2021; Wu et al., 2016). Samuti on ilmavaatlused näidanud, et ekstreemsete sademete ja üleujutuste sagedus on Euroopas ja Ameerika Ühendriikides kasvanud. Teadlaste võimekus ennustada sademete ja temperatuuri muutust piirkondlikult on piiratud, sest kliima on mõjutatud erinevatest keerukatest ja dünaamilistest süsteemidest. Sealhulgas on olulise tähtsusega atmosfääri, ookeani ja maapinna koosmõju. Nende süsteemide täpne ennustamine nõuab keerukaid, kõrge lahutusvõimega mudeleid, mis suudaksid simuleerida paljusid väikseid ja sageli ettearvamatuid muutujaid (Mangini et al., 2018; Saharia et al., 2017).

Kuumalainete ajal valitsevad tingimused võivad erinevates Euroopa osades olla väga erinevad. Näitena saab tuua 2018. aasta, mil Põhja-, Kesk- ja Ida-Euroopas valitsesid märtsist augustini äärmuslikult kuivad tingimused, samas kui Edela-Euroopas sadas tavapärasest rohkem sademeid. Ebaharilikud ilmastikutingimused tegid 2018. aastast ilma mõttes eriti huvitava aasta. 2018. aastal tehtud ilmavaatlused aitavad mõista ekstreemsete ilmastikunähtuste mõju põllumajanduslikule saagikusele Euroopas tervikuna. Beillouin et al. (2020) kasutasid oma uurimistöö analüüsi osas andmeid odra, maisi, kaera, rapsi, kartuli, rukki, suhkruroo ja nisu kohta. Teravilja saagikus Lõuna-Euroopas oli üldjuhul mõjutatud vähestest talvistest ja kevadistest sademetest või siis ka kõrgetest

kevadistest temperatuuridest. Seevastu kippus talvine kõrge temperatuur saagikust kasvatama. Optimaalsed suvised temperatuurid jäid vahemikku 26°C kuni 32°C. Lääne-Euroopas oli ootuspärasest madalam rapsi, rukki ja kartuli saagikus. Isegi riigisiselt erines saagikus väga suures ulatuses (Beillouin et al., 2020).

Aastane sademete hulk on Läänemere piirkonnas üldjoontes suurenenud, kuid kindlat trendi siiski ei ole esinenud. Sademete režiimi juures on täheldatavad siiski mõned kindlad järsud muutused, millest võiks mainida talvist sademete hulga kasvu ja seda eelkõige jaanuaris ja veebruaris. Sellised muutused on täheldatavad eelkõige 1990. aastatest alates. Kõige suurem muutus on toimunud Lätis ja kõige väiksem muutus on toimunud Leedus (Jaagus et al., 2016). Üldised tsirkulatsioonimudelid ennustavad, et Põhja-Euroopas on oodata sademete hulga kasvu ning Lõuna-Euroopas nende vähenemist. Nende regioonide vahel asub avar vöönd, kus muutusi ei saa ette näha.

Läänemere piirkonnas suureneb sademete hulk mõõdukalt sajandi lõpuks ja seda eriti külma poolaasta jooksul. 20. sajandil suurenes laiuskraadi suhtes arvatud keskmine sademete hulk laiuskraadide vahemikus 30°N ja 85°N (IPCC, 2001). Selline trend on Euroopas esinenud eelkõige talvel, sügisel ja kevadel, kuid mitte suvel. Oluline on seegi, et kõige suurem sademete hulga kasv on toimunud Rootsis. Sademete hulk on kasvanud seal talvel ja kevadel (Bengtsson et al., 2014). Samas ei ole Soomes kindlat sademete muutuse trendi tuvastatud (Irannezhad et al., 2016). Poola puhul on esinenud väike sademete hulga kasv. Märkimisväärne on, et sademete hulga kasv on toimunud külmal aastaajal (Szwed et al., 2019). Lumikate on oluline taliviljade arengu seisukohast, kuna pakub kaitset külma eest. Kõige sellega peab arvestama, sest sademed on selges korrelatsioonis saagikusega.

## 2.1 Standardiseeritud sademete indeks (*Standardized Precipitation Index, SPI*)

Standardiseeritud sademete indeksit kasutatakse sademete defitsiidi hindamiseks mitmete ajaskaalade puhul. Nende põhjal tehakse kindlaks veeressursside kättesaadavus. Mullavee tingimused vastavad väikse ajaskaala sademete anomaaliale, samas kui põhjavee, vooluvee ja reservuaarides talletatava vee tingimused vastavad pikaajaliste sademete anomaaliale. SPI arvutus põhineb pikaajaliste sademete andmetel kindlas asupaigas. Pikaajaliste sademete puhul kasutatakse tõenäosusjaotust, mis teisendatakse normaaljaotuseks. Positiivsed väärtused

tähistavad mediaanist suuremat sademete hulka. Negatiivsed väärtused viitavad mediaanist väiksematele sademete väärtustele. Põud esineb siis, kui SPI on pidevalt negatiivne ja muutub intensiivseks kui SPI on -1,0 või väiksem. Põud lõpeb, kui SPI muutub positiivseks. SPI arvutatakse antud ajaperioodi sademete, sademete keskväärtuse ja sademete standardhälbe kaudu.  $SPI = (P - P^*) / ST_p$ , kus P on sademed, P\* on sademete keskväärtus ja ST<sub>p</sub> on sademete standardhälve (Hayes et al., 2007; Heim et al., 2002).

Tabel 1. SPI indeksi väärtuste vahemikud

SPI väärtused	
2,0 ja kõrgem	äärmuslikult märg
1,5 kuni 1,99	väga märg
1,0 kuni 1,49	mõõdukalt märg
-0,99 kuni 0,99	lähedane tavapärasele
-1,0 kuni -1,49	mõõdukalt kuiv
-1,5 kuni -1,99	tugevalt kuiv
-2,0 ja väiksem	äärmuslikult kuiv

## 2.2 Standardiseeritud sademete-*evapotranspiratsiooni indeks* (*Standardised Precipitation-Evapotranspiration Index, SPEI*)

Standardiseeritud sademete-*evapotranspiratsiooni* indeksiga saab hinnata põua tõsidust vastavalt põua intensiivsusele ja kestusele. Samuti saab teha kindlaks põua algust ja lõppu. SPEI võimaldab võrrelda põudasid ajas ja ruumis, kuna seda saab arvutada erinevate kliimatingimuste puhul. Keyantash ja Dracup viitavad sellele, et põua indeksid peaksid olema statistiliselt lihtsalt arvutatavad ja arvutus peaks iseenesest olema arusaadav. SPEI täidab neid tingimusi. SPEI arvutamisel kasutatakse sademete ja potentsiaalse *evapotranspiratsiooni* vahet. Kõige suuremat võimalikku *evapotranspiratsiooni* võrreldakse hetkel kättesaadava vee hulgaga. SPEI arvutamiseks kasutatakse Penman-Monteith või Hargreaves'i võrrandeid. SPEI kasutab igakuist (või iganädalast) sademete ja potentsiaalse *evapotranspiratsiooni* vahet. See kujutab endast kliimaatilist veebilanssi, mis arvutatakse erinevatel skaaladel, selleks et saada teada SPEI väärtus. Sisendparameetrid on igakuised sademed ja temperatuuri andmed. Vaja läheb olemasolevaid igakuiseid aegridade andmeid (Hayes et al., 2007; Hernandez et al., 2014).

Tabel 2. SPEI indeksi väärtuste vahemikud

SPEI väärtused	
2,0 ja kõrgem	äärmuslikult märg
1,0 kuni 1,9	mõõdukalt märg
-0,9 kuni 0,9	lähedane tavapärasele
-1,0 kuni -1,9	mõõdukalt kuiv
-2,0 kuni -2,9	tugevalt kuiv
-3,0 ja väiksem	äärmuslikult kuiv

### 2.3 Palmeri põua tugevuse indeks (*Palmer Drought Severity Index*, PDSI)

Palmeri põua tugevuse indeks loodi selleks, et saada teada standardiseeritud niiskuse tingimusi ja võrrelda omavahel kindlaid asupaiku ja kuid. PDSI on meteoroloogiline põuaindeks, mis on tundlik tavapärasest kuivematele või märjematele ilmastikutingimustele. PDSI arvutatakse sademete ja temperatuuri andmete ja mullas kättesaadava vee andmete põhjal. Indeksi loomisel on arvestatud sellega, et tavapärasest suurem sademete hulk võib langeda pikaajalise põua perioodile. See ei tohiks mõjutada märgatavalt PDSI väärtust.

Palmeri indeksi väärtus on ligikaudu vahemikus -6,0 kuni +6,0. Seda indeksit arvutatakse tavaliselt kuude lõikes. Vegetatsiooniperioodide ajal arvutatakse ka nädalaajalisi Palmeri indeksi väärtusi. Palmeri indeks on kasulik põua monitoorimiseks: esiteks pakub see võimalust tavapärasest erinevate tingimuste mõõtmiseks; teiseks annab see võimaluse võrrelda hetketingimusi ajalooliste andmetega; kolmandaks pakub see võimalust kujutada ajaloolisi põudasid ruumiliselt ja ajaliselt.

Indeksisse ei kaasata lumena langevaid sademeid, lumikatet ega külmunud maad. Kõiki sademeid käsitletakse vihmamana. Nii on indeksi väärtused ebatäpsed talvel ja kevadkuudel. Loomulikku viiteaega sademete ja nende äravoolu vahel ei arvestata. Selle mudeli kohaselt ei toimu täiendavat äravoolu seni, kuni pinnase veemahutavus on täis või maa-alused mullakihid on küllastunud. Potentsiaalseid sademeid arvutatakse Thornthwaite'i meetodiga. See meetod on üksnes lähendus (Hayes et al., 2007; Heim et al., 2002).

## 2.4 Saagi niiskuse indeks (*Crop Moisture Index, CMI*)

Saagi niiskuse indeksi puhul vaadeldakse nädalast nädalasse võimaliku saagi seisukorda. CMI on mõeldud kasutamiseks lühiajaliste tingimuste vaatlemiseks. See põhineb keskmisel temperatuuril ja sademetel. CMI on tundlik muutuvate tingimuste suhtes ja seda kaalutakse asupaiga ja ajaga. Vastavat indeksit saab kasutada koos kaartidega, et võrrelda niiskused erinevates asupaikades. Sisendparameetriteks on nädalased sademed, nädalane keskmine temperatuur ja eelmise nädala CMI väärtus.

Arvutatakse tegeliku evapotranspiratsiooni ja potentsiaalse evapotranspiratsiooni vahe. Tegelik evapotranspiratsioon põhineb temperatuuril ja sademetel, mis esinevad nädala jooksul. Leitakse ka pealmiste ja alumiste mullakihtide niiskus (Hayes et al., 2007; Venter et al. 2015).

## 2.5 Pinnavee varustatuse indeks (*Surface Water Supply Index, SWSI*)

Selle indeksi arendasid välja Shafer ja Dezman (1982). Nad löid selle pinnavee tingimuste hindamiseks. SWSI kaasab nii hüdroloogilisi kui klimatoloogilisi näitajaid. Need väärtused standardiseeritakse, et võrrelda erinevaid valgalsid. Vaja läheb lumikatte, vooluvee, sademete ja reservuaarides talletuva vee andmeid.

Igakused andmed kogutakse ja summeeritakse kõigi sademete, veekogude ja lumikatte/vooluvee mõõtejaamade puhul. SWSI väärtused on vahemikus -4,2 ja +4,2 (Hayes et al., 2007).

## 2.6 Detsiilid

Selle indeksi töötasid välja Gibbs ja Maher, et vältida nõrkusi, mis kujutab endast protsendi leidmine tavapära sademetest. Igakuised sademete andmed viiakse detsiilide kujule. Vastav meetod jagab pikaajaliste sademete jaotuse detsiilidesse. Esimeseks detsiiliks on sademete hulk, mida ei ületa 10% kõige väiksema sademete hulga katsepunktid. Teiseks detsiiliks on sademete hulk, mida ei ületa 20% kõige väiksema sademete hulga katsepunktid. Kümnennda detsiili puhul on tegemist kõige suurema sademete hulga (Hayes et al., 2007).

## 2.7 Vegetatsioonitingimuste indeks (*Vegetation Condition Index, VCI*)

Ajaloolisi normaliseeritud taimestiku indeksi (NDVI) väärtusi võrreldakse omavahel, kusjuures iga perioodi võrreldakse sellele eelnenud aasta sama perioodiga. Eelmise aasta sama perioodi võrreldakse käesoleva aastaga. Indeksit VCI väljendatakse protsentides ja see indeks annab aimu, millised on väärtused eelmiste aastate ekstreemsete väärtuste suhtes (Jiao et al., 2016).

$$VCI = (NDVI_j - NDVI_{min}) / (NDVI_{max} - NDVI_{min}) * 100$$

kus  $NDVI_i$  on normaliseeritud taimeistiku indeksi  $i$ -ndas väärtus,  $NDVI_{min}$  vastava indeksi minimaalne väärtus ja  $NDVI_{max}$  vastava indeksi maksimaalne väärtus.

## 2.8 Bhalme-Mooley põuaindeks (*Bhalme-Mooley Drought Index, BMDI*)

Bhalme-Mooley põuaindeks on loodud pikaajaliste kuivade tingimuste raskusastme ja sageduse hindamiseks. Vaja läheb punktmõõtmiste võrku ja igakuiste sademete pikaajalist keskmist. Seejärel kasutatakse igakuiste sademete protsentuaalset erinevust pikaajalisest keskmisest, et hinnata niiskuse indeksit (Sabău et al., 2015).

Tabel 3. Bhalme-Mooley põuaindeksi väärtuste vahemikud

<b>BDMI</b>	<b>Iseloomustus</b>
4 või suurem	äärmuslikult märg
3 kuni 3,99	väga märg
2 kuni 2,99	mõõdukalt märg
1 kuni 1,99	vähesel määral märg
0,99 kuni -0,99	tavapärase taseme lähedane
-1 kuni -1,99	kerge põud
-2 kuni -2,99	mõõdukas põud
-3 kuni -3,99	karm põud
-4 kuni väiksem	äärmuslik põud

## 2.9 Põua raskusastme indeks (*Drought severity index, DSI*)

Tegemist on võrdlemisi uue indeksiga, mis kätkeb endas spektroradiomeetri MODISe (*Moderate-resolution Imaging Spectroradiometer*) abil kindlaks tehtud evapotranspiratsiooni/potentsiaalse evapotraspiratsiooni (ET/PET) ja NDVI andmeid, selleks et monitoorida suure lahutusega ulatuslikke maismaa põudasid. DSI abil saab tuvastada suuremaid põudasid. Oluline on valideerida DSI globaalsed tulemused regionaalsel skaalal, enne kui rakendada seda juhtumiuuringuks, kasutades koha peal mõõdetud põuaindekseid ja vaatlustega saadud andmeid (Zhang et al., 2014; Khan et al., 2021; Haroon et al., 2016).

## 2.10 Efektiivne põuaindeks (*Effective Drought Index, EDI*)

EDI arvutatakse ööpäevaste andmete kohta. Seda indeksit kasutatakse lühiajalise ja kestva põua monitoorimiseks. Tegemist on intensiivse põua indeksiga, mis võtab arvesse päevaste sademete kogunemist funktsiooniga, mis kaalub tulemusi ja rakendub päevaste sademete andmetele. Veepuudusega perioodi statistiline analüüs viiakse läbi selliselt, et on võimalik teha kindlaks põua algus, mille puhul EDI väärtus on väiksem nullist.

$$EP_i = \sum_{n=1}^i \left[ \left( \sum_{m=1}^n P_m \right) / n \right]$$

$$DEP = EP - MEP$$

$$EDI = DEP / ST(DEP)$$

Ülaltoodud valemis tähistab EP efektiivseid sademeid,  $P_m$  m-inda kuu sademeid,  $n$  eelnenud perioodi kestust ja  $i$  kogu sademete kestus. MEP tähistab keskmiseid efektiivseid sademeid. MEP arvutatakse iga kalendrikuu  $i$ -nda väärtuse järgi. Näiteks on jaanuari MEP efektiivsete sademete jaanuarikuu väärtuste keskmine. EP (DEP) määratakse MEP-st. Negatiivne DEP viitab keskmisest kliimast kuivematele oludele. Kui DEP on pidevalt negatiivne, siis  $i$  suureneb kuude lõikes, mille puhul DEP on negatiivne (Deo et al., 2017; Kamruzzaman et al., 2019; Mondol et al., 2021).

## 2.11 Mullaniiskuse põuaindeks (*Soil Moisture Drought Index, SMDI*)

Päevased mudeli väljundid keskmistatakse juurte piirkonnas seitsmepäevase perioodina, selleks et saada teada iga 52 nädala mullavee näitajaid. Indeksit arvutatakse mulla veedefitsiidi, põua kestuse, juurte piirkonna mullaniiskuse ja selle standardhälbe põhjal, kasutades üldjuhul viie päeva libisevat keskmist.

$$SD_{i,j} = \frac{SW_{i,j} - MSW_j}{MSW_j - \min SW_j} \times 100, \text{ kui } SW_{i,j} = MSW_j$$

$$SD_{i,j} = \frac{SW_{i,j} - MSW_j}{\max SW_j - MSW_j} \times 100, \text{ kui } SW_{i,j} = MSW_j$$

kus  $SD_{i,j}$  on mulla veedefitsiit (%),  $SW_{i,j}$  keskmine nädalane mullaprofiilis kättesaadav mullavesi,  $MSW_j$  pikaajaliselt mullaprofiilis kättesaadava vee mediaan (mm),  $maxSW_j$  pikaajaliselt mullaprofiilis kättesaadava mullavee maksimum (mm) ja  $minSW_j$  pikaajaliselt mullaprofiilis kättesaadava mullavee miinimum (mm) ( $i = 1901-1998$  ja  $j = 1-52$  nädalat).

$$SMDI_j = \frac{\sum_{t=1}^j SD_t}{25t + 25}$$

kus  $t$  on aeg nädalates (Narasimhan et al., 2005).

## 2.12 Konkreetse põllukultuuri põuaindeks (*Crop Specific Drought Index, CSDI*)

Meyer et al. (1993) töötasid CSDI funktsiooni välja põua monitoorimiseks ja hindamiseks. CSDI hõlmab kolme peamist faktorit: põua, mulla ja ilma spetsiifilisust. Kolm peamist faktorit on taime tarbitud vee ja potentsiaalse vee tarbimise vahe ning taime tundlikkus kasvufaaside ajal, mil esinevad rasked veetingimused. CSDI on parametrizeeritud maisi, soja ja sorgo jaoks. Mudelit kalibreeritakse perioodiliselt, kasutades viimaseid värskeid andmeid. CSDI on võrdne tegeliku kultuuri saagikuse ja potentsiaalse saagikuse jagatisega. Võetakse arvesse kasvufaaside arvu. Täiendavalt kasutatakse CSDI arvutamiseks eksponenti, viidates kultuuri tundlikkusele veepuuduse suhtes. Kultuuri kasvufaasid määratakse kogunenud efektiivsete temperatuuride summaga ja nende vastavate eksponentide väärtustega.

$$CSDI = Y/Y_p = \prod_{n=1}^n \left[ \frac{ET_i}{ET_{pci}} \right]^{\lambda_i}$$

kus  $Y$  on tegelik kultuuri saagikus,  $Y_p$  on potentsiaalne kultuuri saagikus ning  $ET_i$  ja  $ET_{pci}$  tegelik ja potentsiaalne kultuuri  $i$ -nda kasvufaasi evapotranspiratsioon (Niemeyer et al., 2008).

## 2.13 Evapotranspiratsiooni defitsiidi indeks (*Evapotranspiration Deficit Index, ETDI*)

ETDI kätkeb endas kolme sammu, millest esimene on veepuuduse hinnang, teine veepuuduse anomaalia hinnang ja viimane ETDI arvutamine (Wambura et al., 2021).

$$WSA_{i,j} = \frac{MWS_j - WS_{i,j}}{MWS_j - \min WS_j} \times 100, \text{ kui } WS_{i,j} = MWS_j$$

$$WSA_{i,j} = \frac{MWS_j - WS_{i,j}}{\max WS_j - MWS_j} \times 100, \text{ kui } WS_{i,j} = MWS_j$$

kus WSA on nädalane veepuudusest tuleneva stressi anomaalia, MWS<sub>j</sub> on pikaajaline j-nda nädala veestressi mediaan, maxWS<sub>j</sub> on pikaajaline j-nda nädala veestressi maksimum, minWS<sub>j</sub> on j-nda nädala pikaajaline veestressi miinimum ja WS on nädalane veestressi määr (i = 1901–1988 ja j = 1–52 nädalat).

$$ETDI_j = 0,5 \times ETDI_{j-1} + \frac{WSA_j}{50}$$

## 2.14 Maapinna temperatuuri hinnang (*Land surface temperature estimates, LST*)

Landsat 5, 7 ja 8 satelliidi pardal on infrapunase piirkonna radiomeetrid ja seetõttu on nende andmed sobilikud maapinna temperatuuri hinnanguks. Viimastel aastakümnetel on tekkinud vajadus mõõta satelliitidega maapinna temperatuuri. Landsatiga mõõdetud maapinna temperatuur on laialdaselt kasutatud linnade temperatuuri uuringutes ja eriti linna soojussaarte uuringutes (EarthExplorer).

## 2.15 Tempertuuritingimuste indeks (*Temperature Condition Index, TCI*)

Vastav indeks lähtub kaugseire andmetest ja seda kasutatakse laialdaselt põudade uurimisel. Kasutatakse VIUPD meetodit (i.k. *vegetation index based on the universal pattern decomposition*). TCI arvutatakse iga piksli jaoks ja kindlal alal kümne päeva kiirgusliku temperatuuri, selle maksimumi ja miinimumi järgi. TCI leitakse maapinna temperatuuri, maapinna temperatuuri maksimumi ja miinimumi kaudu.  $TCI = 100 \cdot (BT_{\max} - BT) / (BT_{\max} - BT_{\min})$ , kus BT on heleduse temperatuur (i.k. *brightness temperature*), BT<sub>max</sub> on maksimaalne heleduse temperatuur ja BT<sub>min</sub> minimaalne heleduse temperatuur (Tsiros et al., 2004).

## 2.16 Vegetatsiooni põuavastuse indeks (*Vegetation Drought Response Index, VegDRI*)

VegDRI eesmärgiks on mõõta põua mõju taimestikule, analüüsides üldisi taimkatte tingimusi satelliidiandmete põhjal ja kuivuse astet, mis väljenduvad kindla asupaiga jaoks kliimapõhiste põuaindeksitena. Täiendavaid biofüüsikalisi / keskkonnale iseloomulikke jooni, nagu ökoregioon, kõrgus, maakasutus / maakatte tüüp ning mulla tüüp võetakse arvesse, kuna nad mõjutavad kliima ja taimkatte omavahelist mõju. Selline integreeritud lähenemisviis võeti kasutusele, et võtta arvesse nii satelliidi- kui ka kliimapõhiseid indekseid, mida on traditsiooniliselt kasutatud põua monitoorimisel. VegDRI arvutamiseks kasutatud sisendid võib kategoriseerida kolmeks peamiseks komponendiks: satelliidi-, kliima- ja biofüüsikalised andmed. Satelliidi komponent pakub ruumiliselt täpseid andmeid selle kohta, kuidas taimkate on jaotunud ja milline on taimkatte üldine seisund, kasutades 1 km AVHRR (i.k. *Advanced Very-High-Resolution Radiometer*) NDVI andmeid. Kliima komponent koosneb kahest üldkasutatavast põuaindeksist: PSDI ja SPI. Need annavad ülevaate kuivuse astmest. Metoodika koosneb neljast peamisest sammust: ajaloolise sisendmuutujate andmebaasi loomine; kahenädalaste empiiriliste VegDRI mudelite loomine; reaalarajale lähendatava andmete sisendi loomine; mudeli rakendamine sisenditele, selleks et koostada 1 km VegDRI kaarte (Wardlow et al., 2012).

## 2.17 Vegetatsiooni kuivuse temperatuurindeks (*Temperature Vegetation Dryness Index, TVDI*)

Evapotranspiratsiooni määr on tõestanud ennast hea maapinna vee seisundi näitajana ja seda saab teoreetiliselt hinnata pinna energiabilansi võrrandi kaudu.  $R_n = G + H + LE$ , kus  $R_n$  on kiirgusvoog,  $G$  pinna soojusvoog,  $H$  tajutava soojuse voog,  $L$  aurumise latentne voog ja  $E$  evapotranspiratsioon (Chen et al., 2015).

## 2.18 Seljaninovi hüdrotermiline koefitsient

Tegemist on niiskusrežiimi kirjeldava näitajaga, mis leitakse järgnevalt:

$HTK = \frac{\sum p}{0.1 \sum t}$ , kus  $p$  tähistab sademeid ja  $t$  temperatuuri. See koefitsient väljendab sademete summa suhet sama perioodi kümme korda vähendatud õhutemperatuuri summasse. Kuu loetakse kuivaks, kui HTK võrdub 1,0–0,6 ning põuaseks kui HTK on 0,5 või väiksem. Liigniiskuse puhul on HTK väärtus üle 2,0. HTK väärtusi kõrvutatakse produktiivse veevaru andmetega.

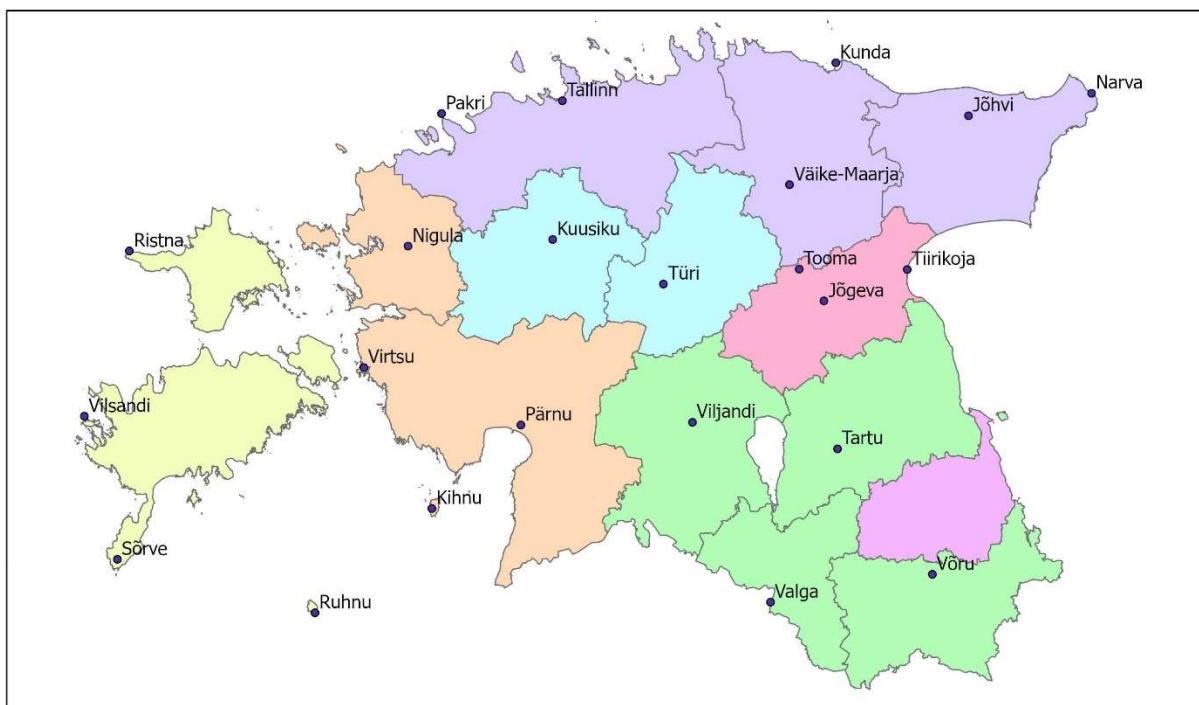
### 3 Andmed ja meetodika

#### 3.1 Andmed väliuuringute uurimisalade paiknemise kohta koos alade iseloomustusega


SPI ja SPEI arvutuste jaoks kasutati 23 jaama ööpäevaseid keskmise õhutemperatuuri ja sademete andmeid aastatel 1951–2023 (tabel 4, joonis 1).

Tabel 4. Ilmajaamade koordinaadid

Ilmajaam	Laiuskraad	Pikkuskraad
Jõgeva	N 58°44'59''	E 26°24'54''
Jõhvi	N 59°19'44''	E 27°23'54''
Kihnu	N 58°05'55''	E 23°58'13''
Kunda	N 59°31'17''	E 26°32'29''
Kuusiku	N 58°58'23''	E 24°44'02''
Narva	N 59°23'22''	E 28°06'33''
Nigula	N 58°57'04''	E 23°48'56''
Pakri	N 59°23'22''	E 24°02'24''
Pärnu	N 58°23'4''	E 24°29'7''
Ristna	N 58°55'15''	E 22°03'59''
Ruhnu	N 57°47'00''	E 23°15'32''
Sõrve	N 57°54'49''	E 22°03'29''
Tallinn	N 59°23'53''	E 24°36'10''
Tartu	N 58°15'51''	E 26°27'41''
Tiirikoja	N 58°51'55''	E 26°57'08''
Tooma	N 58°52'22''	E 26°16'22''
Türi	N 58°48'31''	E 25°24'33''
Väike-Maarja	N 59°08'29''	E 26°13'51''
Valga	N 57°47'24''	E 26°02'16''
Viljandi	N 58°22'40''	E 25°36'01''
Vilsandi	N 58°22'58''	E 21°48'51''
Virtsu	N 58°34'22''	E 23°30'49''
Võru	N 57°50'47''	E 27°01'10''



### Ilmajaamade grupeerimine



Joonis 1. Ilmajaamade paiknemine ja grupeerimine.

Kõige suurem sademete intensiivsus 3 minuti jooksul on mõõdetud Toomal 23. juulil 1957. aastal, mil sadas 3,6 mm/min. Suurim sademete intensiivsus 10 min jooksul on mõõdetud samuti Toomal 23. juulil 1957. Kõige suurem ööpäevane sademete hulk on registreeritud Metsküläs, kus sadas 148 mm. Kõige sajusem kuu oli 1987. aasta august Haanjas, kus sademete väärtus oli 351 mm. Kõige kuivem kuu on olnud seni mitmel pool Lõuna-Eestis 2002. aasta august, mil sadas 0 mm. Kõige sajusem aasta oli 1990. Sel aastal registreeriti Raplamaal Nääris maksimaalseks sademete hulgaks 1157 mm. Kõige kuivemaks aastaks osutus 1941, kui Pärnus sadas ainult 309 mm. Suurimad raheterad esinesid 2023. aasta 7. augustil Torgu-Mõisakülas Sõrve poolsaarel, kus sadas alla 80 mm diameetriga rahetera (Keskkonnaagentuuri Ilmateenistus).

## 3.2 Valimi koostamise põhimõtted ja valimi asjakohane kirjeldus

Uurimistöösse on kaasatud aegrida 1948–2023 ööpäevaste sademete andmetega ja aegrida 1951–2023 ööpäevaste keskmiste temperatuuride andmetega. Väga oluline on teha kindlaks, milline kultuur millistes tingimustes kõige paremini kasvab. Seejuures annab pikem aegrida hea võimaluse

analüüsida sademetest tulenevaid trende ja nende põhjustatud muutuste mõju ulatust taimekasvule. Antud uurimistööga proovitakse täita lünki viimase aja teadmistes. Puuduvad põhipanevad uurimused, mis käsitlevad antud valdkonnas temperatuuri ja sademete vahelisi seoseid. Uuritaval perioodil võib täheldada suuri muutusi sademete indeksite juures.

### 3.3 Andmete päritolu, struktuur, kasutatavus jm vajalikud iseloomustused

Andmed pärinevad Keskkonnaagentuuri ilmateenistuse andmebaasist. Aastate 1948–2023 kohta on iga ilmajaama kohta olemas ööpäeva sademete andmed ja aastate 1951–2023 kohta ööpäeva keskmise temperatuuri andmed. Ööpäevaste sademete andmete põhjal arvutati SPI ning sademete ja temperatuuri andmete põhjal arvutati SPEI. Kuna pöud kujuneb välja pika aja jooksul, siis SPI ja SPEI arvutati antud päeva ja 29 eelneva päeva andmete põhjal.

SPEI on leitud Thornthwaite'i meetodil, mille puhul läheb vaja ööpäeva keskmise temperatuuri andmeid ja valge aja pikkust. Indeksi arvutamiseks on kõigi ilmajaamade puhul kasutatud ööpäeva keskmise temperatuuri andmeid ajaperioodil 1951–2023. Erandiks on Jõgeva, Väike-Maarja ja Nigula ilmajaamad. Kasutatud on Jõgeva ilmajaamas alates 1992. aasta 1. jaanuarist registreeritud andmeid. Väike-Maarja ilmajaama andmed on kättesaadavad ajaperioodi kohta, mis algab 1962. aasta 1. augustil. Kuna Väike-Maarja 1962. aasta andmete puhul puudub siiski oluline osa vegetatsiooniperioodist, on Väike-Maarja puhul kasutatud andmeid alates 1963. aasta 1. jaanuarist. Nigula ilmajaama puhul on andmete aegrida 1964–2023.

Ülalnimetatud indeksite arvutamise perioodiks on seatud iga aasta puhul 1. mai kuni 30. september, kuna sel perioodil toimub kõige intensiivsem taimede kasv. Vastavad indeksid on arvutatud MS EXCEL-is ja programmeerimiskeeles R.

### 3.4 Ilmajaamade grupeerimine piirkonniti

Eesti ilmajaamad on grupeeritud selliselt, et kogu riigi erinevad kliimaatilised tingimused oleksid esindatud. Oluliselt erinevad sademete mustrid Soome lahe ääres ja Mandri-Eestis. Eesti sademed on jaotunud üsna ebaühtlaselt, nii nagu tuleb välja käesoleva uurimistöö osast „Tulemused“. Hinnatud on SPI ja SPEI positiivselt muutuselt üleminekuid negatiivsetele muutuse väärtustele. Negatiivne muutus tähendab seda, et olud on muutunud kuivemaks ehk põuasuse indeksi väärtus on muutunud väiksemaks, ja positiivne muutus tähendab, et olud on muutunud niiskemaks ehk põuasuse indeksi väärtus on muutunud suuremaks. Selle põhjal on ilmajaamad grupeeritud Põhja-

ja Lõuna-Eesti ilmajaamadeks. Arvesse on võetud põuaste tingimuste kestust. Lisaks on graafikuid hinnatud visuaalselt. Nende kriteeriumite kohaselt osutusid sarnaseks ka Kesk-Eesti ilmajaamad. Sama grupi moodustavad Jõgeva, Tiirikoja ja Tooma ilmajaam, sest need paiknevad üksteise vahetus läheduses ning põuad langevad nende piirkondade puhul lähedasele ajale. Täiendavalt kuuluvad samasse gruppi Lääne-Eesti saarte ilmajaamad, kuna nende SPI ja SPEI muudu väärtused on sarnased. Selline klassifitseerimine on täiendavalt tehtud, põhinedes erinevatele kasvuperioodi pikkustele Lõuna- ja Põhja-Eestis ning Lääne-Eesti saartel (Saue ja Kadaja, 2011, 2014, 2016). Samuti on lähtutud Eesti kohta tehtud keskmiste ja maksimaalsete sademete uurimustest (Tammets ja Jaagus, 2013; Alber jt., 2015). Järgnevas tabelis on esitatud ilmajaamad piirkonniti.

Tabel 5. Ilmajaamade grupeerimine piirkonniti

Eesti piirkond	Ilmajaamad
Põhja-Eesti	Tallinn, Pakri, Kunda, Jõhvi, Narva
Lõuna-Eesti	Tartu, Valga, Võru, Viljandi
Kesk-Eesti	Kuusiku, Türi, Väike-Maarja
Lääne-Eesti	Pärnu, Virtsu, Nigula
Lääne-Eesti saared	Vilsandi, Sõrve, Ristna
Jõgeva maakond	Jõgeva, Tiirikoja, Tooma

### 3.5 SPI indeksi arvutuskäik

SPI on leitud esmalt iga kuupäeva jaoks selliselt, et summeeritud on selle päeva ja sellele eelnenud 29 päeva sademed. Tulemuseks on saadud 30 päeva sademete summad. Järgmise etapina on arvatud iga kuupäeva jaoks 30 päeva sademete summa keskväärtused ajaperioodil 1948–2023. Seejuures on lahutatud 30 päeva sademete summast 30 päeva sademete summa keskväärtus ajaperioodil 1948–2023. Järgnevalt on leitud iga kuupäeva jaoks 30 päeva sademete summa standardhälbed ajaperioodil 1948–2023. 30 päeva sademete summa ja selle keskväärtuse vahe on jagatud läbi selle standardhälbega. Täiendavalt on leitud iga kuupäeva jaoks SPI tõusud ja muudud.

### 3.6 SPEI arvutamine kalkulaatoriga ETCalc

Andmed on kontrolli eesmärgil ette valmistatud veebis ligipääsetava ETCalc põuasuse indeksite kalkulaatori jaoks. Selle abil on kontrollitud hiljem R-is ja MS EXCEL-is arvutatud ilmastiku indeksite vahetulemusi.

Iga ilmajaama puhul on andmed viidud üle laiast formaadist pikka formaati. Selleks on kasutatud R-i skripti, mille puhul on andmetest tehtud eraldi failid, nii et andmekirjete arv ei ületaks 7500 rida, sest ETCalc kalkulaator võimaldab korraga arvutada kuni 7500 andmekirjet. Andmekirjeid on iga ilmajaama kohta ligikaudu 27 000. Erandiks on Jõgeva, Väike-Maarja ja Nigula, mille puhul aegrida erineb aegreast 1951–2023. Seega on koostatud iga ilmajaama kohta neli faili, millest kolmes esimeses failis on 18 aasta pikkune aegrida ning viimases neljandas failis 15 aasta pikkune aegrida.

Thornthwaite'i meetod nõuab algandmetena tegelikku keskmist temperatuuri. Tegelikku keskmise temperatuuri leidmiseks on kasutatud Keskkonnaagentuuri ilmateenistusest saadud ööpäevaseid keskmise temperatuuri andmeid. Leitud on erinevate kuude keskmised temperatuurid vastavalt iga üksiku ilmajaama aegreale. Pärast seda on leitud vastava aegrea puhul aprilli, mai, juuni, juuli, augusti ja septembri keskmised temperatuurid.

Teine oluline sisendparameeter on fotoperioodi pikkus, milleks on võetud valge aja pikkus aprillis mais, juunis, juulis, augustis ja septembris. Kuna taimed on väga tundlikud valge aja pikkuse suhtes, siis on ka käesolevas töös leitud valge aja pikkus võimalikult täpselt. Vastavad andmed on saadud veebilehelt <https://www.astronoomia.ee/tahistaevas/efemeriidid/>. Sellel veebilehel on valitud välja „tõus ja loojumine“. Täiendavalt on ridade arvuks seatud 183 ehk periood 1. aprill kuni 30. september, mis vastab kogule vaadeldavale perioodile. Andmed on viidud MS EXCEL-i töölehele ning seal on leitud vastava perioodi keskmine valge aja pikkus. Pärast seda on leitud aprilli, mai, juuni, juuli, augusti ja septembri keskmine valge aja pikkus. Kasutatud on üksnes Tartu andmeid, kuna päeva pikkus Eesti siseselt varieerub kümne minuti piires, kuid ETCalc kalkulaator võimaldab sisendina määrata päeva pikkuse üksnes tunni täpsusega.

Thornthwaite'i meetodi jaoks on leitud Wilmotti parandus, mis vähendab meetodi kallutatust, kui temperatuur on üle 26°C. Kuigi selle meetodi puhul kasutati algselt igakuiseid sademete andmeid, võimaldab Wilmotti parand kasutada igapäevaseid andmeid.

Thornthwaite'i meetodi arvutused on kontrolli eesmärgil tehtud ETCalc kalkulaatoriga. Pärast aurumise igapäevaste väärtuste allalaadimist veebilehelt <https://etcalc.hydrotools.tech> on andmeid töödeldud R-is kirjutatud programmidega. Iga ilmajaama jaoks on ETCalc kalkulaatoriga koostatud kuus faili: aprilli, mai, juuni, juuli, augusti ja septembri kohta. R-is koostatud programm võtab aprilli andmed esimesest vastava ilmajaama failist, mai andmed teisest vastava ilmajaama failist, juuni andmed kolmandast vastava ilmajaama failist jne. Pärast seda ühendab programm failid kokku üheks failiks.

Kuna iga ETCalc kalkulaatori jaoks oli varasemalt leitud iga ilmajaama puhul 18 aasta pikkuse aegreaga ilmajaama failid ja faile oli kokku neli, siis tuli pärast seda andmed R-is koostatud programmiga taas ühteks kronoloogilises järjestuses olevaks aegreaks kokku ühendada. Tulemusena saadi iga ilmajaama kohta kronoloogilises järjestuses olev koondfail, milles olid iga aasta puhul (1951–2023) andmed aprillist kuni septembri lõpuni. Vastavaid aurumise kohta koostatud faile on kasutatud edaspidi R-is koostatud programmi ja MS EXCEL-is leitud vahetulemuste kontrollimiseks.

### 3.7 Ilmastikuindeksite arvutamine programmeerimiskeeles R

Programmeerimiskeeles R kirjutati valmis skript, mille koostamisel juhinduti järgnevast:

1. Loeti kõigi ilmajaamade andmed sisse.
2. Eraldiseisvad andmetabelid ühendati kokku üheks andmetabeliks „combined\_data“.
3. Lisati identifikaator iga ilmajaama jaoks, põhinedes faili nimele.
4. Kuupäeva veerg muudeti kuupäeva tüüpi veeruks ja jaama veerg muudeti tekstiväärtuseks.
5. Kokku ühendatud andmetabel viidi laiast formaadist pikka formaati.
6. „combined\_data“ kujundati ümber nii, et uues andmetabelis on veerud „Station“, „Data“, „Month“, „Year“ ja „Temperature“. Uue andmetabeli nimeks pandi „reshaped\_data“.
7. „reshaped\_data“ põhjal leiti ajaperioodi 1948–2023 keskmised kuised temperatuurid. Vastava muutuja nimetati „average\_temperatures“.
8. Leiti soojusindeksi väärtused. Selleks lisati „average\_temperatures\_pivot“ muutujale veerg „Thermal\_Index“.
9. Andmetabeli „average\_temperatures\_pivot“ all arvutati välja eksponent „a“ väärtused.
10. Loeti R-i sisse fotoperioodi pikkuste ja konstandi C väärtuste andmefail.

11. Seejärel ühendati „combined\_data“ ja „photoperiod\_length“ andmefail inner\_join käsuga üheks andmetabeliks.
12. Muudeti fotoperioodi andmetabeli kuupäeva vormingut ja muudeti ka „long\_data“ vormingut.
13. Ühendati andmetabelid „long\_data“ ja „photoperiod\_length“ veeru „Monthday“ järgi kokku. Tulemuseks saadi andmetabel „joined\_data2“.
14. Loodi uus andmetabel „combined\_data2“, mis saadi andmetabelite „average\_temperatures\_pivot“ ja „joined\_data2“ kokku ühendamisel veeru „Station“ järgi.
15. Selekteeriti andmetabelis „combined\_data2“ veerud „Date.x“, „Station“, „Data“, „Photoperiod\_length“, „C“, „Thermal\_Index“ ja „Exponent“.
16. Loodi uus andmetabel „PET“, põhinedes „combined\_data2“ väärtustele.
17. Loeti sadememete andmed sisse ja moodustati nimekiri „precip“.
18. Pärast seda viidi listi „precip“ andmed laiast formaadist pikka formaati ja selleks moodustatud andmetabel „precip\_long“.
19. Loodi uus andmetabel „precip\_long2“, mille jaoks loodi veerud „Year“ ja „Date“.
20. Pärast seda sorteeriti andmetabeli „precip\_long2“ andmed kuupäeva järgi.
21. Moodustati uus andmetabel „PET2“, milles ilmajaamade nimed muudeti samaks kui need olid andmetabelis „precip\_long2“.
22. Andmetabelid „precip\_long2“ ja „PET2“ ühendati kokku üheks andmetabeliks „joined\_df“.
23. Andmetabeli „joined\_df“ jaoks leiti veebilansi veerg „water\_balance“, kus iga kirje on igale kuupäevale eelneva 30 päeva keskmine veebilanss.
24. Loodi andmetabel „across\_years“, mille puhul leiti iga kuupäeva jaoks keskmine veebilanss ajaperioodi 1948–2023 kohta.
25. Leiti andmetabeli „across\_years“ jaoks iga kuupäeva jaoks veebilansi standardhälve.
26. Arvutati iga kuupäeva jaoks SPEI indeksi väärtused. Kindla kuupäeva veebilansist lahutati keskmine veebilanss ning viimane tulemus jagati veebilansi standardhällbega.
27. Loodi muutuja „joined\_df\_filtered“, millele omistati „across\_years“ väärtused ning filtrina kasutati kuupäeva alates 1951. aasta 1. maist.
28. Pärast seda filtreeriti andmetabelist „joined\_df\_filtered“ välja 30. aprill.

29. Iga ilmajaama jaoks moodustati eraldi failid.
30. Pärast seda söödeti need p-väärtusi leidvale meetodile ette ja salvestati need andmetabelina „list\_of\_p\_values“.
31. Seejärel leiti iga kuupäeva jaoks tõusud ja salvestati need andmetabelina „slope\_df“.
32. Iga ilmajaama puhul võeti arvesse erinevaid ajaperioode.
33. Loodi andmetabel „slope\_df\_filtered“, mille puhul kasutati vormingut „%m-%d“. Välja selekteeriti üleliigsed kuupäevad (30. aprill).
34. Tõusude põhjal leiti iga ilmajaama jaoks muudud. Tulemused kirjutati eraldi failidesse.
35. Tulemuste graafiliseks kujutamiseks muudeti ilmajaama nimed tegelikeks kohanimedeks.
36. Graafikutel kasutati kuude eestikeelseid lühendeid.
37. Pärast muutude leidmist koostati kõigile ilmajaamade jaoks SPEI indeksi muutude graafikud.
38. Leiti SPEI indeksi muudu koondgraafik, mille puhul koostati andmetabel „change\_values“, kus on keskmised muudu väärtused iga ilmajaama puhul, ja andmetabel „average\_change“, kus on keskmised ilmajaamade muudu väärtused.

### 3.8 Ilmastikuindeksite arvutamine MS EXCEL-is

R-i skriptiga leitud tulemusi on kontrollitud MS EXCEL-is leitud tulemustega. MS EXCEL-is on kasutatud ööpäevase keskmise temperatuuri andmeid. Eraldi on veel töölehele sisestatud fotoperioodi pikkuse ja konstandi C veerg. Leitud on soojusindeksi ja eksponendi väärtused. Nende põhjal on leitud kõigile kuupäevadele vastavad auramise väärtused. Nende leidmiseks on sisestatud ööpäevase keskmise temperatuuri andmete all paiknevatesse lahtrisse arvutusvalem  $=IF(B93 < 0, 0, IF(B93 > 26, $BP93*(-415.85 + 32.24*B93 - 0.43*B93^2), 16*$BP93*(10*B93/$BO$369)^$BP$369))$ . Siin tähistab B93 esimest lahtrit, mille jaoks on leitud auramise väärtus. Pärast auramise indeksite leidmist on tehtud eraldi töölehtedel SPEI indeksi arvutused. Selleks on MS EXCEL-i töölehele sisestatud sademete andmed ja nende alla auramise andmed. Sademete andmetest on lahutatud lahtrite kaupa auramise andmed. Selle tulemuse põhjal on leitud 30 päeva veebilanss. Seejärel on leitud iga kuupäeva jaoks keskmised veebilansid ja veebilansi standardhälbed. Lõplik SPEI tulemus on leitud nii, et 30 päeva veebilansist on lahutatud iga kuupäeva jaoks keskmine veebilanss ning see tulemus on läbi jagatud veebilansi standardhällbega. Tulemuseks ongi SPEI indeksi väärtused Thornthwaite'i meetodil.

### 3.9 Ilmastikuindeksite muutuste väärtused

Programmeerimiskeeles R on kontrollitud kõigi ilmjaamade puhul kõigi aastate päevaste SPI ja SPEI väärtuste normaaljaotusele vastavust. Analüüsi käigus tuli välja, et enamikul aastatel ei vasta SPI ja SPEI normaaljaotusele. Seetõttu on kasutatud trendianalüüsiks Mann-Kendalli testi. Ilmastikuindeksite muutuste väärtuste leidmiseks Mann-Kendalli Seni tõusu hinnang korrutatud ilmajaamale vastava ajaperioodi pikkusega. Seni tõusu hinnang on leitud programmeerimiskeeles R koostatud koodilõiguga. Tulemusi on kõrvutatud ka MS EXCEL-is vähimruutude meetodil leitud regressioonianalüüsi tulemustega.

Regressioonianalüüsi käigus on iga ilmajaama puhul leitud kindla kuupäeva jaoks tõusu väärtused ning need on korrutatud läbi ilmajaamale vastava ajaperioodi pikkusega. Tõusud on leitud MS EXCEL-is SPI arvutuste töölehtedel ajaperioodi 1948–2023 kohta ning SPEI arvutuste töölehtedel ajaperioodi 1951–2023 kohta.

### 3.10 Ilmastikuindeksite p-väärtuste koondtabel MS EXCEL-is

Käesolevas uurimistöös on p-väärtused SPI jaoks leitud Mann-Kendalli testiga. SPEI jaoks on p-väärtused leitud vähimruutude meetodil regressioonianalüüsi ja Mann-Kendalli testiga, et teha kindlaks Thornthwaite'i meetodil leitud indeksi muutuste statistilist olulisust. Kuna Jõgeva, Kuusiku, Tartu, Türi, Väike-Maarja, Viljandi ja Võru ilmajaama SPEI aegrea aastatest vastavad ligikaudu pooled normaaljaotusele, siis on kasutatud SPEI p-väärtuste leidmiseks nii lineaarset regressioonianalüüsi kui ka Mann-Kendall testi. Tulemused on kirjutatud iga ilmajaama jaoks eraldi faili ja koostatud on kõigi ilmajaamade p-väärtuste koondtabel, kus esimeses veerus on vastav kuupäev ning järgnevate veergude päistes ilmajaama nimi ning päiste all vastavad p-väärtuste tulemused. Pärast seda on teostatud p-väärtuste kohta analüüs, et selgitada välja kindlad mustrid, et veenduda selles, kas statistiliselt oluliste tulemuste puhul joonistub kuupäevade osas välja kindel kokkulangemine või see puudub. P-väärtustest ülevaate saamiseks on MS EXCEL-is kasutatud tingimuslikku vormingut, kus kõik 0,05-st väiksemate p-väärtustega lahtrid on värvitud punaseks.

### 3.11 Mann-Kendalli test

Mann-Kendalli meetodil on leitud erinevate ilmajaamade keskmiste sademete trendi statistiline olulisus. Selleks on kasutatud Keskkonnaagentuuri ilmateenistusest saadud ööpäevaste sademete andmeid ajaperioodi 1948–2023 kohta ja Soome Meteoroloogia Instituudi 2002. aastal välja töötatud MS EXCEL-i makrot Makesens 1.0. Samuti on leitud Makesens 1.0 abil Seni tõusu hinnang.

Mann-Kendalli testiga on leitud ka põuasuse indeksite muutused, kasutades selleks eelnevas alapunktis kirjeldatud töövõtteid.

## 4 Tulemused

### 4.1 Keskmised sademed

Kõige rohkem sademeid langeb ühe aasta jooksul Viljandis, Türis ja Kuusikus. Selle näitaja poolest keskmiste hulka kuuluvad Jõgeva, Narva ja Võru ilmajaam. Kõige vähem sademeid langeb Ruhnul, Kihnul ja Kundas (tabel 6).

Kõige rohkem langeb aprillist septembrini sademeid Türil, Vilsandil ja Jõhvis, keskmiste hulka kuuluvad Jõgeva, Tartu ja Pärnu ning kõige vähem langeb sademeid Ristnas, Sõrves ja Vilsandil (tabel 6). Järgnevas tabelis on esitatud jaamade keskmised sademed aasta lõikes ja perioodil aprill kuni september.

Tabel 6. Aasta jooksul langenud keskmised sademed ja aprilli algusest kuni septembri lõpuni langenud sademed ajaperioodil 1948–2023.

Ilmajaam	Aasta	Aprill-september
Türi	701	395
Viljandi	710	394
Jõhvi	678	392
Valga	684	390
Tooma	664	380
Võru	627	380
Kuusiku	698	375
Väike-Maarja	652	374
Narva	630	373
Jõgeva	637	372
Tartu	613	369
Pärnu	687	361
Tallinn	659	357
Nigula	674	354
Tiirikoja	591	346
Kunda	544	326
Virtsu	606	308
Pakri	582	305
Ruhnu	546	298
Kihnu	545	298
Ristna	616	296
Sõrve	554	288
Vilsandi	562	279

## 4.2 Sademete muutuste analüüs

Perioodil 1948–2023 võib peaaegu kõikjal Eestis täheldada sademete hulga tõusu. Ainukeseks ilmajaamaks, mille puhul on esinenud sademete vähenemine on olnud Valga ilmajaam. Sisuliselt muutumatuna on sademed püsinud Ristnas. Samale perioodile langeb kindlam temperatuuri tõus. Sademete hulga tõusu trend ei ole nii selge.

Erinevate ilmajaamade sademete trendi leidmiseks on kasutatud Mann-Kendalli meetodit. Kõige suurem Seni tõusu hinnang on Kihnu ilmajaama puhul ja kõige väiksem Seni tõusu hinnang Valga ilmajaama puhul. Tartu puhul võib sademete näitaja sõltuda mõõtmistulemuste erinevustest, sest varasemal perioodil paiknes ilmajaam Ülenurme lennuväljal ja alates 1997. aastast Tõraveres.

Kindlat territoriaalselt mustrit sademete muutuste osas ei esine (tabel 6). Kõige suurem sademete tõusu hinnang on Kihnul, Tallinnas ja Tartus. Vastavad ilmajaamad paiknevad Eesti erinevates piirkondades. Üllatavalt erineb oluliselt ka sademete Seni tõusu hinnang üksteise vahetus läheduses paiknevates ilmajaamades: Jõgeval, Tiirikojas ja Toomal. Kihnu ilmajaama suur Seni tõusu hinnang on põhjustatud sellest, et Kihnu on väike saar: see paikneb Liivi lahes, mis mõjutab sademete hulka. Lisaks sellele mõjutavad kliimamuutused sademete mustreid ja intensiivsust erinevates piirkondades erinevalt. See illustreerib oluliselt sademete langemise eripärasid ja seda, et sademed sõltuvad väga olulisel määral kindlast asupaigast. Näiteks ei pruugi Pärnu ilmajaama andmed täielikult reaalsust peegeldada, sest Pärnu ilmajaam on asunud erinevates kohtades: alguses rannas, hiljem kesklinnas ja seejärel Sauga lennuväljal.

Mann-Kendalli trendi testi Z-väärtus on sisuliselt kõigi ilmajaamade puhul kõrgem kui kriitiline väärtus 1,96. See tähendab, et trend on statistiliselt olulisel  $p < 0,05$  tasemel. Kui Mann-Kendalli trendi testi Z-väärtus ületab positiivselt valitud kriitilist väärtust, siis võib järeldada, et andmehulgas on täheldatav statistiliselt oluline tõusutrend. Kui Z-väärtus on negatiivne ja selle absoluutväärtus ületab kriitilist väärtust, siis võib järeldada, et andmehulgas on statistiliselt oluline langustrend. Seega: selge tõusutrend on Tallinna, Tartu, Narva, Pärnu, Võru, Viljandi, Jõhvi, Türi, Jõgeva, Tiirikoja, Pakri, Kunda, Sõrve, Vilsandi, Kihnu ja Ruhnu ilmajaama puhul (tabel 7).

Tabel 7. Ilmajaamade Seni tõusu hinnangud ja Mann-Kendalli testi Z-väärtus


Ilmajaam	Seni tõusu hinnang	Sademetete muutus mm	Mann-Kendalli trendi testi Z-väärtus
Kihnu	2.56	187	4.27
Tallinn	2.44	186	3.74
Tartu	2.37	180	3.71
Tiirikoja	2.26	172	3.79
Pärnu	2.17	165	3.28
Pakri	2.20	141	3.11
Ruhnu	1.84	140	3.40
Jõgeva	1.70	129	2.55
Sõrve	1.63	122	2.90
Jõhvi	1.82	116	2.05
Narva	1.53	116	2.50
Kunda	1.49	113	2.77
Türi	1.44	109	2.46
Viljandi	1.34	102	2.26
Väike-Maarja	1.46	90	1.60
Võru	1.16	88	2.28
Vilsandi	1.13	82	2.27
Tooma	1.00	76	1.86
Kuusiku	0.96	70	1.28
Nigula	1.17	70	1.49
Virtsu	0.91	58	1.40
Ristna	0.35	27	0.68
Valga	-0.24	-18	-0.52

### 4.3 Põuasuse indeksite pikaajalised muutused, varieeruvus ja äärmusväärtused


#### 4.3.1 Standardiseeritud sademete indeks (SPI)

SPI on leitud kõigi ilmajaamade andmete põhjal, milleks on ööpäevased sademete väärtused (vt „Andmed ja meetodika“). Kõigi ilmajaamade puhul on arvatud iga kuupäeva jaoks indeksi tõusud ja selle põhjal iga ilmajaama SPI muutused, võttes arvesse ajaperioodi, mida on vastava indeksi arvutamisel kasutatud. Töö tulemusena selgus, et maikuu on Eestis siinsete ilmajaamade andmete põhjal tingimused muutunud kuivemaks (joonis 2 ja joonis 3). Sademete muutus muutub positiivseks 23. mail, st tingimused muutuvad niiskemaks alates sellest kuupäevast, ja muutub jälle

negatiivseks 22. juulil, st tingimused muutuvad kuivemaks alates sellest kuupäevast. Pärast seda püsib sademete muutus negatiivseks 3. augustini. Pärast 6. augustit on sademete muutus positiivne kuni 22. septemberini. Sellest kuupäevast alates on sademete muutusel kuni vaadeldava ajaperioodi (1. mai kuni 30. september) lõpuni negatiivne väärtus. Andmete töötamise tulemusest nähtub, et vegetatsiooniperioodi jooksul on üksnes juuliku viimasel perioodil ja septembri lõpus tingimused muutunud kuivemaks. Muul ajal on põuasus vähenenud. Augustikuu tingimused on pigem muutunud niiskemaks, kuid ei esine nii suurt muutust, kui teiste suvekuude puhul. See on väga olulise mõjuga Eesti teravilja- ja kartulikasvatusele, kuna enne viljakoristust võib suur vihmavaling rikkuda olulise osa saagist. Allpool saab näha graafikut sademete muudu kohta, mis kaasab kõik Eesti ilmajaamad. Graafikut vaadates tuleb arvestada, et seal ei ole tegu pideva näitajaga, mis suureneb ja langeb. Iga tulp näitab selle kuupäeva muutuse suurust kogu vaatlusperioodi jooksul (joonis 2).




Joonis 2. Jaamade keskmise SPI muutuse sesoonne jaotumine ajaperioodi 1948–2023 kohta.



Joonis 3. Jaamade keskmise SPI muutus ning maksimaalse ja minimaalse SPI väärtuse sesoonne jaotumine ajaperioodi 1948–2023 kohta.

#### 4.3.1.1 Lõuna-Eesti

SPI muutus on Lõuna-Eesti jaamade keskmisena negatiivne alates 1. maist kuni 22. maini (joonis 4). Alates 23. maist on muutus positiivne. Selline olukord kestab 20. juulini. 21. juulil omandab SPI muutus negatiivse väärtuse ja selline olukord kestab kuni 24. augustini. Pärast seda püsib indeks positiivseks kuni 21. septembrini. Seejärel on SPI indeksi muutusel järjekordselt negatiivsed väärtused. Sellest võib järeldada, et Lõuna-Eestis on põuasus vähenenud maikuu viimastest päevadest kuni juuli viimase kolmandikuni. Juuli lõpus ja suuremal jaolt augustis on tingimused muutunud kuivemaks. Augusti lõpust kuni septembri keskpaigani on tingimused muutunud niiskemaks ja sealt edasi kuivemaks.




Joonis 4. Lõuna-Eesti SPI muutuse koondgraafik.

Statistiliselt olulised p-väärtused esinevad Tartu ilmajaama puhul juuni neljandal nädalal ja juuli esimesel nädalal. Täiendavalt esineb statistiliselt olulisi tulemusi Valga puhul septembri lõpus.

#### 4.3.1.2 Jõgeva maakond

Alates 1. maist kuni 20. maini on SPI muutus negatiivne (joonis 5). Pärast seda on muutus paar päeva nõrgalt positiivne, misjärel muutub muutus jälle negatiivseks. Alates 30. maist on SPI muutuse väärtus positiivne ja see püsib sellisena kuni 20. juulini. Seejärel püsib muutus negatiivseks kuni 23. augustini. Vahepeal muutub muutus positiivseks, misjärel taas negatiivseks. Alates 24. augustist kuni 24. septembrini on muutus nõrgalt positiivne. Pärast seda muutub muutus negatiivseks. Sellest lähtuvalt saame järeldada, et aastane Jõgeva, Tooma ja Tiirikoja sademete muutuse koondtulemus on võrdlemisi sarnane Tartu, Valga, Viljandi ja Võru koondtulemusega. Erinevus seisneb selles, et Jõgeva, Tooma ja Tiirikoja keskmine SPI muutus muutub mais positiivseks nädala võrra hiljem ja periood, mil olud on kuivemaks muutunud, püsib Jõgeva ümbruskonnas väiksema ajaperioodi. Samuti on muutunud tingimused Jõgeva ümbruskonnas varem niiskemaks, võrreldes Lõuna-Eesti kohta saadud tulemusega. Septembri lõpus kuivemaks muutunud tingimused ei võimendu Jõgeva puhul ka nii selgelt.




Joonis 5. Jõgeva maakonna SPI muutuse koondgraafik.

Statistiliselt olulisi p-väärtusi esineb Toomal maikuu algusest kuni maikuu teise nädala keskpaigani. Jõgeval esinevad statistiliselt olulised tulemused juunikuu keskpaigas ja juunikuu kolmandast nädalast kuni juunikuu lõpuni, seevastu Tiirikojal juuni teise nädala algusest kuni juuni lõpuni.

#### 4.3.1.3 Põhja-Eesti

Alates 1. maist kuni 22. maini on SPI muutus olnud negatiivne (joonis 6). Pärast seda on vastav muutus olnud 23. maist kuni 3. juunini nullilähedane ja alates 4. juunist kuni 23. juulini positiivne. Sealt edasi on indeksi muutus kuni 12. augustini negatiivne. Seejärel püsib põuasuse indeksi muutus kuni 23. septembrini positiivseks. Septembrikuu viimased päevad on muutunud kuivemaks. Allolevalt graafikult on näha, Põhja-Eesti muutuse graafik näeb võrdlemisi sarnane välja Jõgeva ümbruskonna graafikuga. Võrreldes Lõuna-Eestiga on Põhja-Eestis põuased tingimused lõppenud hiljem, samas kui positiivse muutuse lõpp langeb juulikuus enam-vähem samale ajale. Lisaks sellele ei saa Põhja-Eestis täheldada tingimuste olulist kuivemaks muutumist juulikuu lõpus. Kui Lõuna-Eestis on augustikuu muutunud kuivemaks, siis Põhja-Eestis sellist suundumust täheldada ei saa, pigem on muutunud august niiskemaks. Põhja-Eestis on tingimused muutunud septembrikuu viimasel perioodil kuivemaks, nii nagu ka Lõuna-Eestis ja Jõgeva ümbruskonnas. Allpool on esitatud graafik Põhja-Eesti SPI põuasuse indeksi muutuse kohta, võttes arvesse igaüksiku kuupäeva.




Joonis 6. Põhja-Eesti SPI muutuse koondgraafik.

Põhja-Eesti piirkonda kuuluva Jõhvi jaama puhul esineb statistiliselt oluliste tulemustega periood juunikuu keskpaigast kuni juunikuu lõpuni. Teiste Põhja-Eesti ilmajaamade puhul statistiliselt olulisi tulemusi ei esine.

#### 4.3.1.4 Lääne-Eesti

Alates 1. maist kuni 30. maini on tingimused muutunud kuivemaks (joonis 7). Seejärel on põuasus 31. maist kuni 5. august vähenenud. Augusti teisel nädalal on põuasuse muutus nullilähedane. Seejärel on tingimused kuni 12. septembrini muutnud niiskemaks. Alates 13. septembrist kuni 17. septembrini on muutus olnud nullilähedane. Alates 18. septembrist on põuasus suurenenud.




Joonis 7. Lääne-Eesti SPI muutuse koondgraafik.

Nigula jaama puhul esinevad statistiliselt olulised tulemused juuniku neljanda nädala algusest kuni juuliku teise nädala keskpaigani. Pärnu jaama puhul esinevad statistiliselt olulised tulemused juuniku neljanda nädala algusest kuni keskpaigani ning juuliku esimese nädala keskpaigas.

#### 4.3.1.5 Lääne-Eesti saared

Alates mai algusest kuni 23. maini on põuasuse indeksi SPI muutus vähenenud (joonis 8). Märkimisväärne on see, et mai esimesel nädalal on muutus märkimisväärselt suurenenud. Pärast 22. maikuu päeva püsib muutus positiivseks kuni 20. septembrini. Sealt edasi alates 21. septembrist muutub indeksi muutus negatiivseks. Oluline on see, et suve jooksul on indeksi muutusel maksimaalsed väärtused juuniku viimases kolmandikus, mil tingimused on muutunud kõige enam niiskemaks. Märkimisväärne on ka tingimuste kuivemaks muutumine juuliku lõpus. Täiendavalt on oluline ka see, et augustiku lõpus esinevad muutusel võrdlemisi kõrged väärtused. Sellele vaatamata on juuniku lõpu muutuse maksimaalsed väärtused tunduvalt suuremad kui augustiku puhul. Sarnaselt kõigile teistele ilmajaamadele on tingimused muutunud Lääne-Eesti saartel põuasemaks septembri lõpus. Järgnevalt on esitatud Lääne-Eesti saarte muutuse tulpdiaagramm.




Joonis 8. Lääne-Eesti saarte SPI muutuse koondgraafik.

Vilsandi ilmajaama puhul esineb statistiliselt olulisi tulemusi juuni keskpaigas ja juuni neljanda nädala algusest kuni sama nädala lõpuni. Sõrve ilmajaama puhul esinevad statistiliselt olulised tulemused juuni teise nädala alguses, juuni neljanda nädala alguses, augusti neljanda nädala alguses ja augusti lõpus.

#### 4.3.1.6 Kesk-Eesti

Alates 1. maist kuni 16. maini on Kesk-Eesti ilmajaamade kohta arvatud SPI põhjal tingimused muutunud kuivemaks (joonis 9). Pärast seda omandab põuasuse indeksi muutus positiivsed väärtused, mis tähendab seda, et tingimused on muutunud niiskemaks. Selline olukord kestab kuni 13. juulini. Pärast seda alates 19. juulist on põuasuse indeksi muutuse väärtused negatiivsed kuni 22. augustini. Nõrgalt positiivsed on põuasuse indeksi muutuse väärtused kuni 12. septembrini. Sealt edasi on põuasuse indeksi muutusel negatiivsed väärtused. See on oluline erinevus kõigi teiste ilmajaamade suhtes. Kui SPI muutus teistes Eesti piirkondades negatiivseks alles septembri lõpus, siis võib seda täheldada Kesk-Eesti ilmajaamade puhul juba enne septembri keskpaika. Oluline on ka see, et Mandri-Eesti ilmajaamade SPI muutuse graafikud on positiivsetelt väärtustelt negatiivsetele väärtustele üleminekul sarnased.



Joonis 9. Kesk-Eesti SPI muutuse koondgraafik.


Väike-Maarja puhul esinevad statistiliselt olulised tulemused juunikuu keskpaigast kuni juuli esimese nädala keskpaigani. Samuti esineb statistiliselt olulisi p-väärtusi Kuusikul septembri lõpus.

#### 4.3.2 Standardiseeritud sademete-auramise indeks (*Standardized Precipitation-Evapotranspiration Index, SPEI*)


1. maist kuni 12. juunini on tingimused taimekasvatuse seisukohast muutunud kuivemaks (joonis 10 ja joonis 11). Alates 12. juunist muutub SPEI muudu väärtus positiivseks, st tingimused on muutunud niiskemaks, ja püsib sellisena 11. juulini. Pärast seda esineb pikk periood, mil põuasuse indeksi muutuse väärtus on negatiivne, st tingimused on muutunud kuivemaks. Alles 25. augustil lõpeb periood, mil tingimused on muutunud kuivemaks. Seejärel algab periood, mil tingimused on muutunud niiskemaks, ja see kestab 10. septembrini. Järgnevalt on põuasuse indeksi väärtused kuni vaadeldava ajaperioodi lõpuni negatiivsed.

Kuna soojemate ilmade tõttu suureneb aurumine, siis taimedele kättesaadav niiskuse hulk tegelikult väheneb märkimisväärselt. SPEI on sarnane SPI indeksiga, kuid erineb sellest järgnevalt: kui SPI indeksi puhul on kasutatud ainult sademete andmeid, siis SPEI puhul leitakse 30 päeva veebilanss sademete ja aurumise vahena. Seetõttu on SPEI graafik nihkega x-telje suhtes, kõrvutades seda SPI graafikuga. Oma väljanägemiselt on SPEI koondgraafik muidu väga sarnane SPI koondgraafikuga. Käesolevast uurimistööst selgub, et väga oluline on arvestada ka aurumisega, kuna see on soojematel suvekuudel väga intensiivne. Temperatuuri andmetel on

olemas selge tõusutendents, mis tähendab aurumise suurenemist. Seetõttu ongi SPEI muutused rohkem negatiivsemad kui SPI puhul. Arvestada tuleb ka seda, et graafikutel on indeksi muutused standardhälbe ühikutes.




Joonis 10. Jaamade keskmise SPEI muutuse sesoonne jaotumine ajaperioodi 1948–2023 kohta.



Joonis 11. Jaamade keskmise SPEI muutuse ning maksimaalse ja minimaalse SPEI väärtuse sesoonne jaotumine ajaperioodi 1948–2023 kohta.

#### 4.3.2.1 Lõuna-Eesti

1. maist kuni 12. juuni püsib SPEI indeksi muutus negatiivseks (joonis 12). Seega on tegemist tingimuste muutusega kuivemaks. 12. juunist kuni 10. juulini on muutunud tingimused märjemaks. Alates 11. juulist on tingimused muutunud kuivemaks. Eriti palju kuivemaks on tingimused muutunud juuliku lõpust kuni augustikuu keskpaigani. Pärast seda on SPEI muutus nõrgalt negatiivne. 17. septembril on SPEI muutus väga lähedal nullile ja muutub korraks nõrgalt positiivseks, kuid pärast seda püsib see negatiivne. Septembri lõpus on muutus juba tugevalt negatiivne. Tingimused on muutunud septembri lõpus tunduvalt põuasemaks.



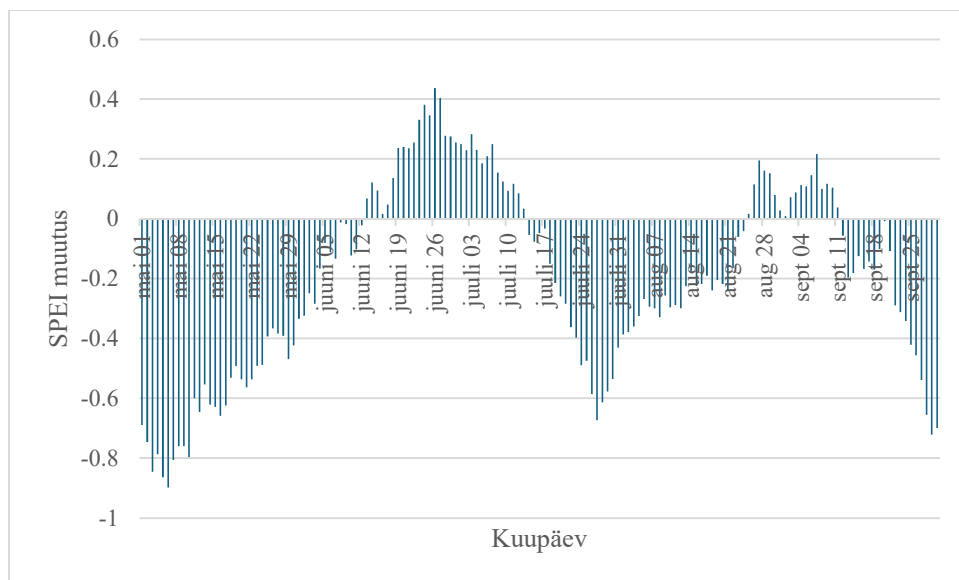
Joonis 12. Lõuna-Eesti SPEI muutuse koondgraafik.

Lõuna-Eesti ilmajaamade puhul langevad statistiliselt olulised p-väärtused küllaltki lähedasele perioodile. Kui Tartu ja Võru puhul statistiliselt oluliste p-väärtustega perioodi ei esine, siis Valga ilmajaama puhul on sellised väärtused maikuu algusest kuni maikuu keskpaigani. Täiendavalt esinevad statistiliselt olulised väärtused Valga puhul juuliku lõpus ja augustikuu esimesel nädalal ning septembri lõpus. Viljandi puhul esineb statistiliselt olulisi tulemusi juuliku kolmandal nädalal.

#### 4.3.2.2 Põhja-Eesti

Alates 1. maist kuni 12. juunini on tegemist tingimuste kuivamaks muutumisega (joonis 13). 13. juunist kuni 13. juulini on tingimused muutunud niiskemaks. 14. juulist kuni 24. augustini on SPEI muutus negatiivne. 25. augustist kuni 11. septembrini on vastav muutus positiivne. Pärast seda

kuupäeva muutub muutus negatiivseks. Alguses püsib muutus negatiivsena kindlal niivool, kuid septembri viimasel nädal muutub muutus märkimisväärselt negatiivseks. Seega nähtub siit, et maist kuni juuli keskpaigani on tingimused muutunud kuivemaks. Juuni keskpaigast kuni juuli keskpaigani on tingimused seevastu muutunud niiskemaks. Juuli keskpaigast kuni augusti lõpuni on tingimused muutunud kuivemaks. Augusti lõpp on muutunud pisut märjemaks. Septembri esimesel nädalal on tingimused muutnud märjemaks ning sealt edasi alates septembri teisest nädalast on tingimused muutunud kuivemaks, mis saagi koristuse seisukohast ei ole sugugi halb. Probleeme võivad tekitada augusti lõpu märjemad tingimused, kuna sel ajal koristatakse saaki.




Joonis 13. Põhja-Eesti ilmajaamade SPEI muutuse koondgraafik.

Statistiliselt olulised tulemused langevad Põhja-Eesti ilmajaamade puhul maikuu esimestele nädalatele. Natuke pikem statistiliselt oluliste tulemustega periood on Kunda ilmajaama puhul. Selle ilmajaama statistiliselt oluliste tulemustega periood lõpeb alles maikuu kolmanda nädala lõpus. Erandiks on Narva jaam, mille puhul sel perioodil statistiliselt olulisi tulemusi ei esine. Täiendavalt on statistiliselt olulisi tulemusi Tallinna ja Pakri ilmajaama puhul maikuu neljandal nädalal. Lisaks esineb Jõhvi ilmajaama puhul statistiliselt olulisi tulemusi juunikuu keskpaigas ja lõpus. Veel on statistiliselt oluliste tulemustega periood Kunda ilmajaama puhul juulikuu lõpus. Praktiliselt kõigi ilmajaamade puhul esinevad statistiliselt olulised tulemused septembri lõpus (va Narva jaam).

### 4.3.2.3 Lääne-Eesti

Alates 1. maist kuni 12. juunini on tingimused muutunud kuivemaks (joonis 14). 13. juunist kuni 13. juulini on tingimused muutunud niiskemaks. Sellele järgneval perioodil on tingimused kuni 28. augustini muutunud kuivemaks. Ajaperioodil 1. september kuni 10. september on tingimused muutunud niiskemaks. Alates 11. septembrist on tingimused muutunud kuivemaks.




Joonis 14. Lääne-Eesti ilmajaamade SPEI muutuse koondgraafik.

Statistiliselt olulised tulemused esinevad kõigi Lääne-Eesti ilmajaamade puhul maikuu alguses. Virtsu jaama puhul esinevad statistiliselt olulised tulemused kuni maikuu lõpuni. Virtsus esineb statistiliselt olulisi tulemusi ka juuli ja septembri lõpus.

### 4.3.2.4 Lääne-Eesti saared

Alates 1. maist kuni 22. juunini on tingimused muutunud kuivemaks (joonis 13). Alates 23. juunist kuni 4. juulini on tingimused muutunud niiskemaks. Sellele järgneb periood kuni 16. juulini, mil tingimused on mõnedel kuupäevadel muutunud niiskemaks, kuid esineb ka päevi, mil tingimused on muutunud kuivemaks. 17. juulist kuni 22. augustini on tingimused muutunud kuivemaks. 23. augustist kuni 7. septembrini on tingimused muutunud keskmisest pisut niiskemaks. Alates septembri teisest nädalast on tingimused muutunud keskmisest kuivemaks.




Joonis 14. Lääne-Eesti saarte SPEI muutuse koondgraafik.

Statistiliselt olulised tulemused esinevad olenevalt ilmajaamast maikuu kolmanda või neljanda nädala lõpuni. Ristna ilmajaama puhul esineb statistiliselt olulisi tulemusi ka juulikuu lõpus. Vilsandi ilmajaama puhul on statistiliselt olulisi tulemusi ka septembri lõpus.

#### 4.3.2.5 Kesk-Eesti

Alates 1. maist kuni 12. juunini on SPEI muut negatiivne (joonis 15). Pärast seda 13. juunist kuni 7. juulini omandab põuasuse indeksi muutus positiivsed väärtused. Alates 8. juulist on indeksi muutusel negatiivsed väärtused. Augustikuu lõpus on indeksil nullilähedased väärtused, kuid pärast seda suurenevad negatiivsed muutuse väärtused päev-päevalt. Negatiivsetel väärtustel on maikuu esimese nädala lõpus ja teise nädala alguses ligikaudu sama suured väärtused kui juulikuu lõpus ning septembri lõpus. Tingimused on kõige rohkem niiskemaks muutunud juunikuu kolmandal nädalal ja kõige rohkem kuivemaks muutunud juulikuu lõpus.



Joonis 15. Kesk-Eesti SPEI muutuse koondgraafik.

Statistiliselt olulisi tulemusi esineb maikuu alguses Türil ja Väike-Maarjas. Lisaks esineb seal statistiliselt olulisi tulemusi ka juulikuu neljanda nädala algusest kuni augustikuu lõpuni. Kuusiku ilmajaama puhul esinevad statistiliselt olulised tulemused septembri neljanda nädala keskpaigast kuni septembri lõpuni.

#### 4.3.3 P-väärtused, SPI

Mann-Kendalli testiga leitud statistiliselt olulised tulemused esinevad erinevates Eesti piirkondades suuremalt jaolt juuni teise nädala algusest kuni juuli teise nädala keskpaigani. Tingimused on sel ajal muutunud statistiliselt oluliselt niiskemaks. Erandiks on Sõrve ilmajaam, mille puhul esinevad statistiliselt olulised tulemused augusti neljanda nädala keskpaigast kuni septembri esimese nädala alguseni. Sel ajal on seal tingimused muutunud statistiliselt oluliselt niiskemaks.

Andmetest ülevaate saamiseks on järgnevalt esitatud Mann-Kendalli testiga leitud statistiliselt oluliste tulemuste tabel.

Tabel 8. SPI statistiliselt olulised tulemused erinevates Eesti ilmajaamades ( $p < 0,05$ )

Ilmajaam	Statistiliselt oluliste tulemuste esinemise aeg
Jõgeva	Juuni keskpaik, juuni kolmas nädal kuni juuni neljanda nädala lõpp
Jõhvi	Juuni keskpaik kuni juuni neljanda nädala lõpp
Kihnu	Juuni keskpaik kuni juuli esimese nädala keskpaik
Kunda	Statistiliselt olulisi tulemusi ei esine.
Kuusiku	Septembri lõpp
Narva	Statistiliselt olulisi tulemusi ei esine.
Nigula	Juuni neljanda nädala algus kuni juuli teise nädala keskpaik
Pärnu	Juuni neljanda nädala algus kuni keskpaik, juuli esimese nädala keskpaik
Ristna	Juuli teise nädala keskpaik
Ruhnu	Juuni teise nädala algus kuni juuni neljanda nädala keskpaik
Sõrve	Juuni esimese nädala algus ja keskpaik, juuni neljanda nädala algus, augusti neljanda nädala keskpaik kuni septembri esimese nädala algus
Tallinn	Statistiliselt olulisi tulemusi ei esine.
Tartu	Juuni kolmanda nädala lõpp, juuli esimese nädala algus
Tiirikoja	Juuni teise nädala algus kuni juuni neljanda nädala lõpp
Tooma	Mai esimene nädal, juuni kolmanda nädala algus kuni keskpaik
Türi	Statistiliselt olulisi tulemusi ei esine.
Valga	Septembri lõpp
Viljandi	Statistiliselt olulisi tulemusi ei esine.
Vilsandi	Juuni kolmanda nädala keskpaik, juuni neljanda nädala algus kuni lõpp
Virtsu	Statistiliselt olulisi tulemusi ei esine.
Väike-Maarja	Juuni keskpaik kuni juuli esimese nädala keskpaik
Võru	Statistiliselt olulisi tulemusi ei esine.

#### 4.3.4 P-väärtused, SPEI

Lineaarse regressioonianalüüsi alusel Jõgeva ilmajaama puhul ei esine statistiliselt olulisi p-väärtusi (tabel 8). Üheks põhjuseks on see, et Jõgeva ilmajaama aegrida on võrdlemisi lühike (1992–2023). Jõhvi, Kihnu, Kunda, Pärnu, Ristna, Sõrve, Tallinna, Tiirikoja, Väike-Maarja, Valga, Vilsandi ja Virtsu ilmajaama puhul esineb statistiliselt olulisi p-väärtusi maikuu esimeses pooles. Statistiliselt oluliselt on tingimused muutunud kuivemaks. Osade ilmajaamade puhul, nagu näiteks Kihnu, Ristna, Sõrve, Valga, Vilsandi ja Virtsu, esinevad statistiliselt olulised p-väärtused kolmel esimesel maikuu nädalal või isegi pikemalt (Vilsandi ja Virtsu). Need p-väärtused tähistavad olude kuivemaks muutumist. Pisteliselt esineb olulisi p-väärtusi veel maikuu lõpus (Kihnu, Pakri, Ristna ja Tallinn). Statistiliselt oluliselt on tingimused muutunud kuivemaks. Jõhvi ilmajaama puhul esinevad statistiliselt olulised tulemused ka juuni keskpaigas ja neljanda nädala alguses. Tingimused on muutunud statistiliselt oluliselt niiskemaks. Täiendavalt esineb statistiliselt olulisi tulemusi juulikuu lõpus (Kunda, Ristna, Türi, Valga, Viljandi ja Virtsu ilmajaamade puhul), mil tingimused on muutunud kuivemaks. Statistiliselt olulisi tulemusi esineb ka augusti alguses. Samuti on statistiliselt olulisi tulemusi septembri lõpus: Jõhvi, Kunda, Kuusiku, Nigula, Pakri, Tallinn, Tiirikoja, Valga, Vilsandi, Virtsu ja Võru ilmajaamas. Sel ajal on tingimused muutunud statistiliselt oluliselt kuivemaks. Eriti paistab selle poolest silma Kuusiku ja Valga ilmajaam. Mainida tuleks ka Vilsandi, Virtsu ja Võru ilmajaama, mille puhul statistiliselt oluliste tulemustega ajaperiood kestab septembris mitu päeva. Sel perioodil on olud muutunud statistiliselt oluliselt kuivemaks. Järgnevalt on esitatud lineaarse regressioonianalüüsiga leitud statistiliselt oluliste tulemuste tabel.

Tabel 9. SPEI statistiliselt olulised tulemused erinevates Eesti ilmajaamades ( $p < 0,05$ )

Ilmajaam	Statistiliselt oluliste tulemuste esinemise aeg
Jõgeva	Statistiliselt olulisi tulemusi ei esine.
Jõhvi	Mai esimene nädal kuni mai teise nädala keskpaik
Kihnu	Mai esimene nädal kuni mai neljanda nädala keskpaik
Kunda	Mai esimene nädal kuni mai kolmanda nädala lõpp, juuli kolmanda nädala keskpaik kuni augusti esimesed päevad
Kuusiku	Septembri neljanda nädala algus kuni septembri lõpp
Narva	Statistiliselt olulisi tulemusi ei esine.

Ilmajaam	Statistiliselt oluliste tulemuste esinemise aeg
Nigula	Mai esimene nädal
Pakri	Mai esimese nädala lõpp kuni teise nädala keskpaik, mai neljanda nädala algus kuni neljanda nädala keskpaik, mai viimased päevad
Pärnu	Mai esimene nädal kuni mai teise nädala keskpaik
Ristna	Mai esimene nädal kuni mai neljanda nädala algus
Sõrve	Mai esimene nädal kuni mai kolmanda nädala lõpp
Tallinn	Mai esimene nädal kuni mai teise nädala keskpaik; pisteliselt esines statistiliselt olulisi tulemusi mai neljanda nädala alguses ja mai lõpus
Tartu	Juuni viimased päevad
Tiirikoja	Mai esimene nädal kuni mai teise nädala alguspäevad
Türi	Mai teise nädala keskpaik, juuli neljanda nädala algus kuni augusti esimese nädala algus
Väike-Maarja	Mai esimese nädala algus
Valga	Mai esimene nädal kuni mai kolmanda nädala lõpp, septembri lõpp
Viljandi	Juuli kolmanda nädala lõpp kuni neljanda nädala keskpaik
Vilsandi	Mai algus kuni mai neljanda nädala keskpaik, septembri lõpp
Virtsu	Maikuu algus kuni mai neljanda nädala lõpp, septembri lõpp
Võru	Septembri lõpp

Mann-Kendalli testiga leitud statistilised olulised tulemused jäävad Kihnu, Kunda, Pakri, Sõrve ja Vilsandi ilmajaama puhul mai algusesse. Kõigi ilmajaamade puhul langevad statistiliselt olulised tulemused mai kolmandale nädalale, juuli esimese nädala lõppu, juuli neljandale nädalale, augusti esimese nädala lõppu ja teise nädala algusesse, augusti kolmanda nädala lõppu ning septembrisse.

## 5 Arutelu ja järeldused

SPI ja SPEI tugevus põuasuse näitajatena seisneb nende lihtsuses ja arusaadavuses ning nad on kergesti tõlgendatavad. SPEI pakub kasulikku teavet sademete ja aurumise vahelise tasakaalu kohta. Mõlemad indeksid on paindlikud – neid saab arvutada päevade, kuude ja aastate kaupa. See annabki võimaluse kliimaanalüüsiks erinevatel ajaskaaladel. Käesoleva uurimistöö puhul pakuvad need indeksid täpset teavet selle kohta, millised on olnud sademete ja aurumise mustrid erinevate kuude kestel, kuna need hõlmavad üksikute kuupäevade arvutusi. Kui teha arvutused ainult iga kuu kohta, siis võib palju olulist teavet välja jääda. Kui kuu jooksul oli tugev põud ja viimastel päevadel sadas palju, siis sademete andmed ei näita üldse põuda.

SPI ja SPEI loovad võimaluse Eesti kliima võrdlemiseks teiste riikide ja regioonidega. Näiteks järeldatakse Slovakkias tehtud uurimuses, et SPEI ja maisi kasvu vahel on suur korrelatsioon (Labudová et al., 2017). Samasugune seos taimekasvu ja SPEI vahel on leitud ka Portugalis (Pablo 2012, *cit.* Labudová 2017). Sellest lähtuvalt on võimalik SPEI alusel võrrelda kaugel paiknevaid piirkondi. SPEI on eriti kasulik veevarude haldamisel, aidates hinnata veetarbimist ja -varusid ning ennustada võimalikke kuivaperioode (Ojha et al., 2021; Tirivarombo et al., 2018; Lorenzo-Lacruz et al., 2010).

Nendel mudelitel on ka mõned puudused, kuna nende arvutamisel on kasutatud lihtsustatud mudeleid, mis ei pruugi arvestada kõiki kliimaprotsesse. Näiteks ei arvestata SPEI arvutamisel Thornthwaite'i meetodil suhtelise õhuniiskuse ja maapinnale jõudva päikesekiirgusega. Seejuures on tegemist taimekasvu seisukohast väga oluliste parameetritega (<https://etcalc.hydrotools.tech/pageMain.php>). SPI ja SPEI on tundlikud andmekvaliteedi ja andmete olemasolu suhtes. Käesoleva uurimistöö puhul ei olnud võimalik kogu ajaperioodi 1948–2023 puhul Tartu ja Tiirikoja indeksit välja arvutada, kuna varasemal ajal tehti ainult pistelisi sademete mõõtmisi. Täielikud andmed iga kuupäeva jaoks olid olemas ainult varasematel aastatel (1948–1959) ja pärast jaamade automatiseerimist.

Käesoleva uurimistööga luuakse ka tulevikuperspektiiv. Kliimamuutuste prognoosid ennustavad põudade sageduse ja intensiivsuse suurenemist mitmel pool maailmas (Luhamaa jt., 2014). Seevastu võib Eestis ennustada kõigil aastaegadel sademete kasvu. Aastatel 2041–2070 peaksid sademed suurenema kõige enam kevadel ja suvel, mis on ka peamine taimekasvuperiood. Selle

taustal kasvab ööpäevane keskmine temperatuur. Temperatuuri tõus suurendab aurumist, mis omakorda vähendab SPEI väärtusi.

Kliimamuutuste tagajärjel on oodata SPI ja SPEI päevaste väärtuste suuremat kõikumist (Azizi et al., 2022). Kõik see toob kaasa sagedasemaid ja äärmuslikumaid niiskustingimusi. Niiskuse puudujääk viib põllukultuuride saagikuse ja veevarude vähenemiseni, metsatulekahjude ohu suurenemiseni ning ökosüsteemide ja elupaikade hävimiseni. Sellisel juhul on üheks lahenduseks kasvatada põuakindlaid põllukultuure (Cooper et al., 2023), kaitsta metsi ja taastada neid.

Talved muutuvad soojemaks ja lumikate väheneb, mis mõjutab teraviljade talisorte, sest puudub lumikate, mis kaitseks külma eest. Vähenenud lumikate toob kaasa kevadise sulavee voolu vähenemise ja suvel pinnase niiskuse vähenemise (<https://www.kliimamuutused.ee/pohjused-ja-tagajarjed/tagajarjed/moju-naiteid-eestis>).

SPI ja SPEI aitavad hinnata kliimariske Eestis ja neid saab kasutada kohanemismeetmete väljatöötamisel ja elluviimisel, et leevendada negatiivseid mõjusid sademete äärmuslike muutuste korral. Näiteks võib negatiivsete SPI või SPEI väärtuste esinemine viidata pikaajalisele kuivaperioodile. Sellised äärmuslikud ilmastikunähtused suurendavad kliimariske, mis võivad mõjutada põllumajandust. Mõlemad indeksid võimaldavad tuvastada piirkondi ja ajaperioode, kus võivad esineda äärmuslikud sademed. Selle teabe põhjal saavad kohalikud ja riiklikud ametiasutused välja töötada kohanemisstrateegiad ja -meetmed.

Eestis on kättesaadav sademete andmete ulatuslik ja kvaliteetne võrgustik. Andmeid koguvad ja haldavad mitmed asutused: Eesti Meteoroloogia- ja Hüdroloogiainstituut, Keskkonnaamet ja Maaeluministerium. Eesti sademete andmete kvaliteet on üldiselt hea, kuna neid kogutakse ja kontrollitakse rangelt ning need on kättesaadavas vormingus ja neid on kerge analüüsida. Sademete hulk varieerub suuresti lühikestel vahemaadel, mis teeb raskeks täpsete andmete saamise. Andmete ajalooline ulatus ei ole kõikides jaamades ühtlane.

Kui SPI näitab, et tingimused on sademeid arvesse võttes märjemaks muutunud, siis SPEI näitab hoopis teistsugust olukorda. Selle indeksi järgi tuleb välja, et soojematest ilmadest põhjustatud suurem aurumine muudab üldist pilti suurel määral. Kindlalt tuleb SPEI kohaselt välja see, et maikuu algusest kuni juunikuu keskpaigani on tingimused muutunud kuivemaks.

Maikuu sademed on teravilja kasvuks väga olulised, sest maikuu on teraviljade kasvuperioodi algusfaas. Sellel perioodil vajavad taimed idanemiseks ja kasvuks optimaalset niiskustaset. Nii SPI kui ka SPEI näitavad maikuu vähenenud sademete hulka. Kuna mais on sademete hulk vähenenud, võivad teraviljad kogeda veestressi. Veestress pärsib taimede kasvu ja arengut, mis viib omakorda saagikuse vähenemiseni (Martyniak et al., 2008; Chmielewski et al., 1999; Kolář et al., 2014).

Teiseks väga oluliseks teguriks on see, et mais võivad ööd olla jahedad ja esineda võib öökülma. Seetõttu võivad taimed saada külmakahjustusi. Piisav mulla niiskusetase aitab kaitsta taimi külmakahjustuste eest, kuna vesi juhib võrdlemisi halvasti soojust ja toimib seetõttu mullas soojusisolatsioonina (Põiklik, 1964). Kuna SPEI järgi on maikuu valdavalt kuivad tingimused, siis selline kaitse kipub taimedel maikuu puuduma.

Lisaks on SPI ja SPEI kohaselt taimedel raske kätte saada toitaineid, sest sademed aitavad neid mullas lahustada, mis teeb need taimede jaoks omastatavamaks (Farooq et al., 2009). See on eriti oluline teraviljade kasvu algfaasis.

Mõõdukas sademete hulk maikuu aitab ka luua tasakaalustatud keskkonna, mis vähendab haiguste ja kahjurite leviku riski. Sellest lähtuvalt suureneb SPI ja SPEI kohaselt vastav risk Eestis märgatavalt. Tähelepanu tuleb pöörata sellele, et erinevad teraviljakultuurid on veestressi suhtes tundlikud erineval määral. Näiteks on nisu ja oder kuuma ja kuiva ilma suhtes tundlikumad kui kaer ja rukis (Chmielewski et al., 1999; Havrlentová et al., 2021). Tuleks kasutusele võtta hulk leevendusmeetmeid, nagu näiteks põuakindlad sordid ja mullaniiskuse säilitamine.

Juuni on teraviljade kasvuperioodi kriitiline faas, kui veestress on eriti kahjulik (Kolář et al., 2014). Veestress pärsib fotosünteesi, taimede kasvu ja arengut (Farooq et al., 2009). SPI koondindeksi järgi on juuniku muutunud märjemaks. SPEI koondindeksi kohaselt on juuni esimesed nädalad muutunud kuivemaks. Kuna SPEI võtab arvesse ka aurumist, siis peegeldab see indeks paremini juuniku alguse taimikasvu tingimusi. Juuni on Eestis tavaliselt soe kuu ja vähenenud sademete ja kõrgemate temperatuuride koosmõju tekitab kuumastressi, mis kahjustab taimede fotosünteesi ja vähendab saagikust (Farooq et al., 2009). Kuiv ja soe ilm soodustab seenhaiguste ja kahjurputukate levikut (Hakala et al., 2011). SPEI-d arvesse võttes peaksid taimekasvavad viimasele asjaolule tähelepanu pöörama. Nõrgenenud taimed on haiguste ja kahjurite suhtes vastuvõtlikumad, mis omakorda võib kaasa tuua saagi vähenemise (Paull et al., 2007).



2018), mis võib põhjustada saagikahjustusi, sest peab ootama, seni kuni maa on raskete põllumasinatena jaoks piisavalt tahke. Erinevad teraviljad taluvad niiskust erinevalt. Näiteks talub oder niiskust paremini kui nisu (Rane et al., 2021). Kindlasti tuleb järgida kohalikke ilmastikuprognose ja võtta vajadusel kasutusele meetmeid, et leevendada võimalikke negatiivseid mõjusid saagikusele.

Alates septembrikuu teisest nädalast näitab SPEI koondindeks olude kuivemaks muutumist, mis on analoogne SPI koondindeksiga. Kuivemad olud võivad viia mulla niiskusesisalduse vähenemiseni, kuna sademeid on vähem. See võib põhjustada stressi kasvavatele teraviljataimedele (Farooq et al., 2009). Vaja võib minna taimekaitsemeetmeid, et kaitsta teraviljakultuure haiguste ja kahjurite eest. Halvenenud saagikus võib mõjutada ka teraviljaturgu, põhjustades võimalikku teraviljatoodete hinnatõusu. See võib mõjutada nii põllumajandustootjaid kui ka tarbijaid (Popescu et al., 2022). Kuna suviteravili on Eestis septembri lõpuks juba koristatud, siis suviteraviljade kasvu vähenenud septembrikuu sademed ei mõjuta (Maracchi et al., 2005).

Eelnevat arvesse võttes saab väita, et erinevad teraviljad taluvad kuuma ja kuiva ilma erinevalt. Seega saaksid teraviljakasvatavad ühe lahendusena valida sorte, mis on aretatud taluma kuuma ja kuiva ilma. Seejuures sõltub saagikus täiendavalt veel teraviljakultuuri tüübist ja taimede kasvuks vajalikest leevendusmeetmetest.

Väga oluliseks Eestis kasvatatavaks kultuuriks on kartul. Kartul kasvab kõige paremini parasvöötme kliimatingimustes. Temperatuuri tõusuga käib üldjuhul kaasas saagi vähenemine, kuid Eesti puhul see nii ei ole, kuna Eesti tingimustes pikeneb oluliselt kasvuperiood. Parasvöötmes väheneb saagikus nii vee ülejäägi kui ka puudujäägi tõttu. Pidev liigne mullavesi koos äärmuslike sademetega võib põhjustada saagi vähenemist. Kui muld püsib liigniiskena ning mugulate ja juurte hapnikuvajadus ei ole rahuldatud, siis saagikus väheneb. Mõõdukas sademete hulk septembri lõpus aitab vältida mugulate mädanemist ja patogeenide levikut. Paraneb kartuli kvaliteet. Seda iseloomustab mugulate suurem säilivus. Kuiv ilm soodustab kartulikoristust, kuna selle tulemusena on muld kuivem ja mugulaid on kergem koristada (Saue ja Kadaja, 2011, 2014 ja 2016).

## 6 Kokkuvõte

SPI ja SPEI viitavad sellele, et põuasus on maikuu vaatlusperioodi jooksul suurenenud. Hiljem on põuasus juunis vähenenud. Graafikutelt saab näha eelkõige just seda tendentsi. Ülejäänud kuude lõikes on põuasuse muutuse osas lahknevusi, sest need kaks indeksit erinevad järgnevalt: SPI kasutab ainult sademete andmeid, samas kui SPEI kasutab sademete kõrval ka keskmise ööpäevase temperatuuri andmeid. Juunikuu teisest poolest kuni juuli keskpaigani näitab SPEI niiskemaid tingimusi, samas kui SPI näitab niiskemaid tingimusi juba maikuu lõpust kuni juuli viimaste nädalateni.

Juulikuu sademed on teraviljade kasvuks väga olulised. Käesoleva uurimistöö kohaselt näitab SPI olude niiskemaks muutumise tendentsi, kuid SPEI näitab seevastu olude kuivemaks muutumise tendentsi. Taimede küpsedes augustikuu on sademed kahjulikud või ebaefektiivsed ja suurte vihmavalingute tõttu võib saak oluliselt kahjustada saada. Mõlemate indeksite väärtustest tuleb välja probleemkoht: augustikuu on sademete hulk suurenenud.

SPI ja SPEI on põuasuse hindamisel Eesti kliimas usaldusväärsed ja olulised indeksid. Need võimaldavad objektiivset ja kvalitatiivset hinnangut põua raskustasemele ning pakuvad head võrdlusmomenti ajalooliste keskmistega.

Käesolevas uurimistöös on Eesti jagatud põudade hindamiseks Põhja-Eestiks, Lõuna-Eestiks, Kesk-Eestiks, Lääne-Eestiks ja Lääne-Eesti saarteks. Igas erinevas piirkonnas omandavad põuaindeksid neile iseloomulikud väärtused ja graafiliselt on piirkonnad hästi äratuntavad, sest põuaindeksite muutuste väärtused muutuvad kindla seaduspärasuse järgi. Täiendavalt on loodud võrdluselement maksimaalsete ja minimaalsete SPI ja SPEI väärtuste ning keskmise SPI ja SPEI muutuse vahel.

Graafikud näitavad põuasuse pikaajalise muutuse tendentsi sesoonset muutust. Algul on valdavalt tegu muutusega kuivenemise poole, hiljem juunis suurema niiskuse poole. Keset suve on jälle põuasus valdavalt suurenenud, augustis vähenenud ja septembri lõpu poole jälle suurenenud.

SPI põhjal on kasvuperioodi jooksul tingimused muutunud nii Põhja- kui ka Lõuna-Eestis niiskemaks. Olude kuivemaks muutumine tuleb paremini välja SPEI põhjal Mandri-Eestis, võrreldes seda piirkonda Põhja-Eesti rannikuga. Kui Põhja-Eestis on juulikuu lõpus täheldatav põuasuse suurenemine, siis Lõuna-Eestis olude kuivemaks muutumine juuli lõpust kuni augusti

viimase nädalani. Oma kujult on Lõuna-Eesti SPI graafik võrdlemisi sarnane Kesk-Eesti SPI graafikuga. SPEI puhul on Lõuna-Eesti ja Põhja-Eesti graafikud samuti sarnased. Erinevusena võib välja tuua, et Põhja-Eestis on augustis märjemad tingimused. Seejuures selgub Lääne-Eesti saarte graafikult, et tingimused on sisuliselt terve vegetatsiooniperioodi jooksul kuivemaks muutunud.

Edaspidi on vaja läbi viia täiendavaid uuringuid ja koostada tegevuskavasid, selleks et oleks võimalik arendada põuale vastupidavaid sorte. Lisaks on vaja täiendavaid teadmisi põudade mõjust Eesti kliimale, mis aitaks kaasa paremate kohanemisstrateegiate väljatöötamisele ja rakendamisele tulevikus. Nendes uurimustes tuleks kaasata ka erinevate teraviljasortide saagikuse andmed ja leida korrelatsioon põudade ning saagikuse vahel. Kasutada võiks veel hüdroloogilisi ja metsanduse andmeid. Edaspidistesse uurimistöödesse võiks kaasata ka Palmeri ja Keetch-Byrami põuaindeksid.

# Seasonal, territorial, and long-term variability of drought in Estonia

Lauri Leinus

## Summary

The SPI and SPEI indicate that drought has increased in May over the observation period. Later in June, the drought has decreased. In this master's thesis, this tendency can be seen from the graphs. There are discrepancies regarding the change in aridity across the remaining months because the two indices differ as follows: SPI uses only precipitation data, while SPEI uses mean daily temperature data in addition to precipitation. From the second half of June to mid-July, the SPEI shows wetter conditions, while the SPI shows wetter conditions already from the end of May until the last weeks of July.

Rainfall in July is particularly important for the growth of cereals. According to the analysis conducted in this thesis, SPI shows a trend of wetter conditions, but SPEI, on the other hand, shows a trend of drier conditions. As the plants mature in August, rainfall is detrimental or ineffective, and heavy downpours can severely damage crops. A problem point emerges from the values of both indices: precipitation has increased in August.

The SPI and SPEI are reliable and important indices for assessing drought in the Estonian climate. They allow an objective and qualitative assessment of drought severity and provide a good point of comparison with historical averages.

In this thesis, Estonia has been divided into North Estonia, South Estonia, Central Estonia, Western Estonia and Western Estonian islands for drought assessment. In each different region, the drought indices acquire their characteristic values, and graphically, the regions are easily recognizable, because the values of the changes in the drought indices change according to a specific regularity. In addition, a comparison element has been created between the maximum and minimum SPI and SPEI values, and the average SPI and SPEI values.

The graphs show the seasonal change in the long-term trend of drought. At first, there is mainly a change towards drying, then, later in June towards higher humidity. In the middle of the summer,

the drought has mostly increased again. However, it has decreased in August and increased again towards the end of September.

Based on the SPI, conditions have become wetter in both North and South Estonia during the growing season. According to the SPEI, drier conditions are more vivid in mainland Estonia, comparing this region with the coast of northern Estonia. Whereas there is an increase in drought in northern Estonia at the end of July, drier conditions have been observed in southern Estonia from the end of July to the last week of August. The shape of the South Estonian SPI graph is relatively similar to the Central Estonian SPI graph. In the case of the SPEI, the graphs of South Estonia and North Estonia are also similar. As a difference, it can be pointed out that in the case of Northern Estonia, the conditions are wetter in August. At the same time, it is clear from the graph of the Western Estonian islands that the conditions have become essentially drier during the entire vegetation period.

In the future, it is necessary to conduct further research and draw up action plans in order to be able to develop drought-resistant varieties. Besides, additional knowledge about the impact of droughts on the Estonian climate is needed to contribute to the development and implementation of better adaptation strategies in the future. Data on the yield of different grain varieties should also be included in the future research, and a correlation between droughts and yield should be found. Hydrological and forestry data could also be used. Palmer and Keetch-Byram drought indices could be included in future research.

## Kasutatud kirjandus

- Akhtar, N., Ilyas, N., Hayat, R., Yasmin, H., Noureldeen, A., & Ahmad, P. (2021). Synergistic effects of plant growth promoting rhizobacteria and silicon dioxide nano-particles for amelioration of drought stress in wheat. *Plant Physiology and Biochemistry*, 166, 160-176.
- Alber, R., Jaagus, J., & Oja, P. (2015). Diurnal cycle of precipitation in Estonia. *Estonian Journal of Earth Sciences*, 64(4), 305.
- Asadi, S., Bannayan, M., & Monti, A. (2019). The association of crop production and precipitation; a comparison of two methodologies. *Arid Land Research and Management*, 33(2), 155-176.
- Azizi, H., & Nejatian, N. (2022). Evaluation of the climate change impact on the intensity and return period for drought indices of SPI and SPEI (study area: Varamin plain). *Water Supply*, 22(4), 4373-4386.
- Aus, A. (2015). Silomaisi kasvatamise tasuvus Eesti piimakarjakasvatuses. Eesti Maaülikool. Majandus- ja sotsiaalinstituut.
- Basu, S., Ramegowda, V., Kumar, A., & Pereira, A. (2016). Plant adaptation to drought stress. *F1000Research*, 5.
- Batool, T., Ali, S., Seleiman, M. F., Naveed, N. H., Ali, A., Ahmed, K., ... & Mubushar, M. (2020). Plant growth promoting rhizobacteria alleviates drought stress in potato in response to suppressive oxidative stress and antioxidant enzymes activities. *Scientific Reports*, 10(1), 16975.
- Beillouin, D., Schauburger, B., Bastos, A., Ciais, P., & Makowski, D. (2020). Impact of extreme weather conditions on European crop production in 2018. *Philosophical Transactions of the Royal Society B*, 375(1810), 20190510.
- Bengtsson, L., & Rana, A. (2014). Long-term change of daily and multi-daily precipitation in southern Sweden. *Hydrological processes*, 28(6), 2897-2911.
- Benitez-Alfonso, Y., Soanes, B. K., Zimba, S., Sinanaj, B., German, L., Sharma, V., ... & Foyer, C. H. (2023). Enhancing climate change resilience in agricultural crops. *Current biology*, 33(23), R1246-R1261.

- Brando, P., Macedo, M., Silvério, D., Rattis, L., Paolucci, L., Alencar, A., ... & Amorim, C. (2020). Amazon wildfires: Scenes from a foreseeable disaster. *Flora*, *268*, 151609.
- Burn, D. H., & Whitfield, P. H. (2016). Changes in floods and flood regimes in Canada. *Canadian Water Resources Journal/Revue canadienne des ressources hydriques*, *41*(1-2), 139-150.
- Camaille, M., Fabre, N., Clément, C., & Ait Barka, E. (2021). Advances in wheat physiology in response to drought and the role of plant growth promoting rhizobacteria to trigger drought tolerance. *Microorganisms*, *9*(4), 687.
- Caporali, E., Lompi, M., Pacetti, T., Chiarello, V., & Fatichi, S. (2021). A review of studies on observed precipitation trends in Italy. *International Journal of Climatology*, *41*, E1-E25.
- Chen, C., Baethgen, W. E., & Robertson, A. (2013). Contributions of individual variation in temperature, solar radiation and precipitation to crop yield in the North China Plain, 1961–2003. *Climatic change*, *116*, 767-788.
- Chen, S., Wen, Z., Jiang, H., Zhao, Q., Zhang, X., & Chen, Y. (2015). Temperature vegetation dryness index estimation of soil moisture under different tree species. *Sustainability*, *7*(9), 11401-11417.
- Chmielewski, F. M., & Köhn, W. (1999). Impact of weather on yield components of spring cereals over 30 years. *Agricultural and Forest Meteorology*, *96*(1-3), 49-58.
- Cooper, M., & Messina, C. D. (2023). Breeding crops for drought-affected environments and improved climate resilience. *The Plant Cell*, *35*(1), 162-186.
- Dahal, V., Gautam, S., & Bhattarai, R. (2018). Analysis of the long-term precipitation trend in Illinois and its implications for agricultural production. *Water*, *10*(4), 433.
- Daryanto, S., Wang, L., & Jacinthe, P. A. (2017). Global synthesis of drought effects on cereal, legume, tuber and root crops production: A review. *Agricultural Water Management*, *179*, 18-33.
- de Vries, F. T., Liiri, M. E., Bjørnlund, L., Setälä, H. M., Christensen, S., & Bardgett, R. D. (2012). Legacy effects of drought on plant growth and the soil food web. *Oecologia*, *170*, 821-833.

- Deo, R. C., Byun, H. R., Adamowski, J. F., & Begum, K. (2017). Application of effective drought index for quantification of meteorological drought events: a case study in Australia. *Theoretical and Applied Climatology*, 128, 359-379.
- Dhanda, S. S., Sethi, G. S., & Behl, R. K. (2004). Indices of drought tolerance in wheat genotypes at early stages of plant growth. *Journal of agronomy and crop science*, 190(1), 6-12.
- Dikshit, A., Pradhan, B., & Alamri, A. M. (2020). Short-term spatio-temporal drought forecasting using random forests model at New South Wales, Australia. *Applied Sciences*, 10(12), 4254.
- Ding, Y., Li, Z., & Peng, S. (2020). Global analysis of time-lag and-accumulation effects of climate on vegetation growth. *International Journal of Applied Earth Observation and Geoinformation*, 92, 102179.
- Eastburn, D. M., McElrone, A. J., & Bilgin, D. D. (2011). Influence of atmospheric and climatic change on plant–pathogen interactions. *Plant pathology*, 60(1), 54-69.
- Farooq, M., Wahid, A., Kobayashi, N. S. M. A., Fujita, D. B. S. M. A., & Basra, S. M. (2009). Plant drought stress: effects, mechanisms and management. *Sustainable agriculture*, 153-188.
- Farrell, C., Szota, C., & Arndt, S. K. (2017). Does the turgor loss point characterize drought response in dryland plants?. *Plant, Cell & Environment*, 40(8), 1500-1511.
- Ghorbani, R., Wilcockson, S., Koocheki, A., & Leifert, C. (2008). Soil management for sustainable crop disease control: a review. *Environmental Chemistry Letters*, 6, 149-162.
- Gontia-Mishra, I., Sapre, S., Sharma, A., & Tiwari, S. (2016). Amelioration of drought tolerance in wheat by the interaction of plant growth-promoting rhizobacteria. *Plant Biology*, 18(6), 992-1000.
- Gray, S. B., & Brady, S. M. (2016). Plant developmental responses to climate change. *Developmental biology*, 419(1), 64-77.
- Gupta, A., Rico-Medina, A., & Caño-Delgado, A. I. (2020). The physiology of plant responses to drought. *Science*, 368(6488), 266-269.

- Hakala, K., Hannukkala, A., Huusela-Veistola, E., Jalli, M., & Peltonen-Sainio, P. (2011). Pests and diseases in a changing climate a major challenge for Finnish crop production. *Agricultural and food science*, 20(1), 3-14.
- Haroon, M. A., Zhang, J., & Yao, F. (2016). Drought monitoring and performance evaluation of MODIS-based drought severity index (DSI) over Pakistan. *Natural Hazards*, 84, 1349-1366.
- Hatfield, J. L., Boote, K. J., Kimball, B. A., Ziska, L. H., Izaurralde, R. C., Ort, D., ... & Wolfe, D. (2011). Climate impacts on agriculture: implications for crop production. *Agronomy journal*, 103(2), 351-370.
- Hatfield, J. L., & Prueger, J. H. (2015). Temperature extremes: Effect on plant growth and development. *Weather and climate extremes*, 10, 4-10
- Havrlentová, M., Kraic, J., Gregusová, V., & Kováčsová, B. (2021). Drought stress in cereals—a review. *Agriculture (Pol'nohospodárstvo)*, 67(2), 47-60.
- Hayes, M. J., Alvord, C., & Lowrey, J. (2007). Drought indices. *Intermountain west climate summary*, 3(6), 2-6.
- Heim Jr, R. R. (2002). A review of twentieth-century drought indices used in the United States. *Bulletin of the American Meteorological Society*, 83(8), 1149-1166.
- Hein, A., Condon, L., & Maxwell, R. (2019). Evaluating the relative importance of precipitation, temperature and land-cover change in the hydrologic response to extreme meteorological drought conditions over the North American High Plains. *Hydrology and Earth System Sciences*, 23(4), 1931-1950.
- Hernandez, E. A., & Uddameri, V. (2014). Standardized precipitation evaporation index (SPEI)-based drought assessment in semi-arid south Texas. *Environmental Earth Sciences*, 71, 2491-2501.
- Hollins, P. D., Kettlewell, P. S., & Peltonen-Sainio, P. (2004). Relationships between climate and winter cereal grain quality in Finland and their potential for forecasting. *Agricultural and food science*, 13(3), 295-308.
- Ingver, A., Tamm, I., Tamm, Ü., Kangor, T., & Koppel, R. (2010). The characteristics of spring cereals in changing weather in Estonia. *Agronomy Research*, 8(Special III), 553-562.

- Irannezhad, M., Marttila, H., Chen, D., & Kløve, B. (2016). Century-long variability and trends in daily precipitation characteristics at three Finnish stations. *Advances in Climate Change Research*, 7(1-2), 54-69.
- Jaagus, J., Briede, A., Rimkus, E., & Sepp, M. (2018). Changes in precipitation regime in the Baltic countries in 1966–2015. *Theoretical and Applied Climatology*, 131, 433-443.
- Jiao, W., Zhang, L., Chang, Q., Fu, D., Cen, Y., & Tong, Q. (2016). Evaluating an enhanced vegetation condition index (VCI) based on VIUPD for drought monitoring in the continental United States. *Remote Sensing*, 8(3), 224.
- Kadaja, J., & Saue, T. (2016). Potential effects of different irrigation and drainage regimes on yield and water productivity of two potato varieties under Estonian temperate climate. *Agricultural Water Management*, 165, 61-71.
- Kamruzzaman, M., Hwang, S., Cho, J., Jang, M. W., & Jeong, H. (2019). Evaluating the spatiotemporal characteristics of agricultural drought in Bangladesh using effective drought index. *Water*, 11(12), 2437.
- Keskkonnaagentuuri ilmateenistus (2024). Kliima > Rekordid > Sademed. Kasutatud aadressi <https://www.ilmateenistus.ee/kliima/rekordid/sademed> (viimati vaadatud 23.05.2023).
- Khan, R., & Gilani, H. (2021). Global drought monitoring with drought severity index (DSI) using Google Earth Engine. *Theoretical and Applied Climatology*, 146(1-2), 411-427.
- Kim, K., Wang, M. C., Ranjitkar, S., Liu, S. H., Xu, J. C., & Zomer, R. J. (2017). Using leaf area index (LAI) to assess vegetation response to drought in Yunnan province of China. *Journal of Mountain Science*, 14(9), 1863-1872.
- Kolář, P., Trnka, M., Brázdil, R., & Hlavinka, P. (2014). Influence of climatic factors on the low yields of spring barley and winter wheat in Southern Moravia (Czech Republic) during the 1961–2007 period. *Theoretical and applied climatology*, 117, 707-721.
- Kriauciuniene, J., Meilutyte-Barauskiene, D., Reihan, A., Koltsova, T., Lizuma, L., & Sarauskiene, D. (2012). Variability in temperature, precipitation and river discharge in the Baltic States.

- Kulkarni, A., Sabin, T. P., Chowdary, J. S., Rao, K. K., Priya, P., Gandhi, N., ... & Rajeevan, M. (2020). Precipitation changes in India. Assessment of climate change over the Indian region: a report of the ministry of earth sciences (MoES), Government of India, 47-72.
- Labudová, L., Labuda, M., & Takáč, J. (2017). Comparison of SPI and SPEI applicability for drought impact assessment on crop production in the Danubian Lowland and the East Slovakian Lowland. *Theoretical and applied climatology*, *128*, 491-506.
- Lin, Y., Watts, D. B., Kloepper, J. W., Feng, Y., & Torbert, H. A. (2020). Influence of plant growth-promoting rhizobacteria on corn growth under drought stress. *Communications in Soil Science and Plant Analysis*, *51*(2), 250-264.
- Ling, M., Han, H., Hu, X., Xia, Q., & Guo, X. (2023). Drought characteristics and causes during summer maize growth period on Huang-Huai-Hai Plain based on daily scale SPEI. *Agricultural Water Management*, *280*, 108198.
- Lopez, T., Al Bitar, A., Biancamaria, S., Güntner, A., & Jäggi, A. (2020). On the use of satellite remote sensing to detect floods and droughts at large scales. *Surveys in Geophysics*, *41*, 1461-1487.
- Lorenzo-Lacruz, J., Vicente-Serrano, S. M., López-Moreno, J. I., Beguería, S., García-Ruiz, J. M., & Cuadrat, J. M. (2010). The impact of droughts and water management on various hydrological systems in the headwaters of the Tagus River (central Spain). *Journal of Hydrology*, *386*(1-4), 13-26.
- Maitah, M., Malec, K., & Maitah, K. (2021). Influence of precipitation and temperature on maize production in the Czech Republic from 2002 to 2019. *Scientific Reports*, *11*(1), 10467.
- Mangini, W., Viglione, A., Hall, J., Hundecha, Y., Ceola, S., Montanari, A., ... & Parajka, J. (2018). Detection of trends in magnitude and frequency of flood peaks across Europe. *Hydrological Sciences Journal*, *63*(4), 493-512.
- Maracchi, G., Sirotenko, O., & Bindi, M. (2005). Impacts of present and future climate variability on agriculture and forestry in the temperate regions: Europe. *Climatic change*, *70*(1), 117-135.

- Martyniak, L. (2008). Response of spring cereals to a deficit of atmospheric precipitation in the particular stages of plant growth and development. *Agricultural water management*, 95(3), 171-178.
- Mondol, M. A. H., Zhu, X., Dunkerley, D., & Henley, B. J. (2021). Observed meteorological drought trends in Bangladesh identified with the Effective Drought Index (EDI). *Agricultural Water Management*, 255, 107001.
- Moravec, V., Markonis, Y., Rakovec, O., Svoboda, M., Trnka, M., Kumar, R., & Hanel, M. (2021). Europe under multi-year droughts: how severe was the 2014–2018 drought period?. *Environmental Research Letters*, 16(3), 034062.
- Narasimhan, B., & Srinivasan, R. (2005). Development and evaluation of Soil Moisture Deficit Index (SMDI) and Evapotranspiration Deficit Index (ETDI) for agricultural drought monitoring. *Agricultural and forest meteorology*, 133(1-4), 69-88.
- Niemeyer, S. (2008). New drought indices. *Options Méditerranéennes. Série A: Séminaires Méditerranéens*, 80, 267-274.
- Niu, S., Luo, Y., Li, D., Cao, S., Xia, J., Li, J., & Smith, M. D. (2014). Plant growth and mortality under climatic extremes: an overview. *Environmental and Experimental Botany*, 98, 13-19.
- Norton, M. R., Malinowski, D. P., & Volaire, F. (2016). Plant drought survival under climate change and strategies to improve perennial grasses. A review. *Agronomy for Sustainable Development*, 36, 1-15.
- Ojha, S. S., Singh, V., & Roshni, T. (2021). Comparison of meteorological drought using SPI and SPEI. *Civ. Eng. J*, 7, 2130-2149.
- Paull, J. (2007). Trophobiosis Theory: A pest starves on a healthy plant. *Elementals-Journal of Biodynamics Tasmania*, 88, 20-24.
- Peltonen-Sainio, P., Palosuo, T., Ruosteenoja, K., Jauhiainen, L., & Ojanen, H. (2018). Warming autumns at high latitudes of Europe: an opportunity to lose or gain in cereal production?. *Regional Environmental Change*, 18, 1453-1465.

- Philipp, M., Wegmann, M., & Kübert-Flock, C. (2021). Quantifying the response of German forests to drought events via Satellite imagery. *Remote Sensing*, 13(9), 1845.
- Popescu, A., Stanciu, M., Şerban, V., & Ciocan, H. N. (2022). Cereals production and price in the European Union.
- Prichard, S. J., Stevens-Rumann, C. S., & Hessburg, P. F. (2017). Tamm Review: Shifting global fire regimes: Lessons from reburns and research needs. *Forest Ecology and Management*, 396, 217-233.
- Põiklik, K. (1964). „Üld- ja agrometeoroloogia“. Tallinn: Eesti Raamat
- Rane, J., Singh, A. K., Kumar, M., Boraiah, K. M., Meena, K. K., Pradhan, A., & Prasad, P. V. (2021). The adaptation and tolerance of major cereals and legumes to important abiotic stresses. *International Journal of Molecular Sciences*, 22(23), 12970.
- Sabău, N. C., Man, T. E., Armaş, A., Balaj, C., & Giru, M. (2015). Characterization of agricultural droughts using Standardized Precipitation Index (SPI) and Bhalme-Mooley Drought Index (BDMI). *Environmental Engineering & Management Journal (EEMJ)*, 14(6).
- Saharia, M., Kirstetter, P. E., Vergara, H., Gourley, J. J., & Hong, Y. (2017). Characterization of floods in the United States. *Journal of hydrology*, 548, 524-535.
- Saue, T., & Kadaja, J. (2014). Water limitations on potato yield in Estonia assessed by crop modelling. *Agricultural and forest meteorology*, 194, 20-28.
- Saue, T., & Kadaja, J. (2011). Possible effects of climate change on potato crops in Estonia. *Boreal environment research*, 16(3), 203.
- Setianingsih, A. I., Jalaludin, M., & Warnadi, W. (2020, February). Analysis droughts index by Standardized Precipitation Index (SPI) and productivity of rain-fed rice fields in Indramayu West Java. In *Journal of Physics: Conference Series* (Vol. 1469, No. 1, p. 012111). IOP Publishing.
- Shen, R., Huang, A., Li, B., & Guo, J. (2019). Construction of a drought monitoring model using deep learning based on multi-source remote sensing data. *International Journal of Applied Earth Observation and Geoinformation*, 79, 48-57.

- Sohoulande, C. D., Stone, K., Szogi, A., & Bauer, P. (2019). An investigation of seasonal precipitation patterns for rainfed agriculture in the Southeastern region of the United States. *Agricultural Water Management*, 223, 105728.
- Supit, I., Van Diepen, C. A., De Wit, A. J. W., Wolf, J., Kabat, P., Baruth, B., & Ludwig, F. (2012). Assessing climate change effects on European crop yields using the Crop Growth Monitoring System and a weather generator. *Agricultural and Forest Meteorology*, 164, 96-111.
- Szwed, M. (2019). Variability of precipitation in Poland under climate change. *Theoretical and Applied Climatology*, 135(3), 1003-1015
- Zeppel, M. J. B., Wilks, J. V., & Lewis, J. D. (2014). Impacts of extreme precipitation and seasonal changes in precipitation on plants. *Biogeosciences*, 11(11), 3083-3093.
- Zhang, P., Zhang, J., & Chen, M. (2017). Economic impacts of climate change on agriculture: The importance of additional climatic variables other than temperature and precipitation. *Journal of Environmental Economics and Management*, 83, 8-31
- Zhang, X. Q., & Yamaguchi, Y. (2014). Characterization and evaluation of MODIS-derived Drought Severity Index (DSI) for monitoring the 2009/2010 drought over southwestern China. *Natural Hazards*, 74, 2129-2145.
- Zlatev, Z., & Lidon, F. C. (2012). An overview on drought induced changes in plant growth, water relations and photosynthesis. *Emirates Journal of Food and Agriculture*, 57-72.
- Tammets, T., & Jaagus, J. (2013). Climatology of precipitation extremes in Estonia using the method of moving precipitation totals. *Theoretical and Applied Climatology*, 111, 623-639.
- Tirivarombo, S. O. D. E., Osupile, D., & Eliasson, P. (2018). Drought monitoring and analysis: standardised precipitation evapotranspiration index (SPEI) and standardised precipitation index (SPI). *Physics and Chemistry of the Earth, Parts A/B/C*, 106, 1-10.
- Tsiros, E., Domenikiotis, C., Spiliotopoulos, M., & Dalezios, N. R. (2004, September). Use of NOAA/AVHRR-based vegetation condition index (VCI) and temperature condition index (TCI) for drought monitoring in Thessaly, Greece. In *EWRA Symposium on water resources management: risks and challenges for the 21st century*, Izmir, Turkey (pp. 2-4).

Venteris, E. R., Tagestad, J. D., Downs, J. L., & Murray, C. J. (2015). Detection of anomalous crop condition and soil variability mapping using a 26 year Landsat record and the Palmer crop moisture index. *International journal of applied earth observation and geoinformation*, 39, 160-170.

Wambura, F. J. (2021). Sensitivity of the evapotranspiration deficit index to its parameters and different temporal scales. *Hydrology*, 8(1), 26.

Wardlow, B. D., Tadesse, T., Brown, J. F., Callahan, K., Swain, S., & Hunt, E. (2012). Vegetation Drought Response Index an Integration of Satellite, Climate, and Biophysical Data.

Wu, Y., Wu, S. Y., Wen, J., Xu, M., & Tan, J. (2016). Changing characteristics of precipitation in China during 1960–2012. *International Journal of Climatology*, 36(3), 1387-1402.

# Lisad

## Lisa 1. Programm muutuste graafikute ja p-väärtuste leidmiseks

```
# Töökausta seadmine
setwd("C:/Users/lauri/Documents/Magistritoo/Andmed2/ilmaandmed")
getwd()

# Teekide 'tidyverse' ja 'readxl' lisamine
library(tidyverse)
library(readxl)

# Funktsioon, mis loeb ja puhastab iga faili.
read_and_clean <- function(file_path) {
  df <- read_excel(file_path)

  # Kuupäeva 'Date' muutmine kuupäeva tüübiks, juhul kui seda läheb vaja.
  df$Date <- as.Date(df$Date, format = "%m-%d")

  # Veendutakse, kas kõik temperatuuri väärtused on numbrilised.
  df[-1] <- lapply(df[-1], function(x) as.numeric(as.character(x)))

  return(df)
}

# Samm 1: Loetakse erinevate failide andmed erinevatesse andmetabelitesse.
file_paths <- list.files(path = "C:/Users/lauri/Documents/Magistritoo/SPEI_andmed", pattern =
  "*.xlsx", full.names = TRUE)
data_list <- lapply(file_paths, read_and_clean)

# Samm 2: Ühendatakse andmetabelid ühtseks andmetabeliks.
combined_data <- bind_rows(data_list, .id = "Station")

# Lisatakse iga ilmajaama jaoks identifikaator, põhinedes faili nimel ja teel.
station_ids <- sapply(file_paths, function(x) basename(x))
station_ids
data_list <- Map(cbind, Station = station_ids, data_list)

# Samm 2: Muudetakse puhastatud andmetabel üheks andmetabeliks.
combined_data <- bind_rows(data_list)
combined_data

# Samm 3: Muudetakse veerg 'Date' tüüp kuupäevaks.
combined_data$Date <- as.Date(combined_data$Date, format = "%m-%d")

# Step 4: Saadakse kätte kuupäeva teave veerust 'Date'.
```

```

combined_data$Month <- format(combined_data$Date, "%m")

# Kasutatakse teekke 'dplyr', 'tidyr' ja 'lubridate'.
library(dplyr)
library(tidyr)
library(lubridate)

combined_data$Date <- as.Date(combined_data$Date)
combined_data$Station <- as.character(combined_data$Station)

# Luuakse andmetabel 'long_data', mis on viidud laia formaadist pikka formaati.
long_data <- combined_data %>%
  pivot_longer(
    cols = -c(Date, Station, Month),
    names_to = "Year",
    values_to = "Data"
  ) %>%
  mutate(
    Year = as.integer(Year),
    Date = make_date(Year, month(Date), day(Date)),
    Date = if_else(Date >= as.Date("1951-01-01") & Date <= as.Date("2023-12-31"), Date,
as.Date(NA))
  ) %>%
  drop_na(Date) %>%
  dplyr::select(Date, Station, Data) %>%
  arrange(Date)

print(long_data)

# Samm 5: Muudetakse andmetabelit 'combined_data'.
reshaped_data <- combined_data %>%
  pivot_longer(cols = -c(Station, Date, Month),
    names_to = "Year",
    values_to = "Temperature",
    values_drop_na = TRUE)

reshaped_data

# Samm 6: Arvutatakse keskmise temperatuur iga kuu jaoks ajaperioodi 1948-2023 ja ilmajaama
#kohta.
average_temperatures <- reshaped_data %>%
  group_by(Station, Month) %>%
  summarise(Avg_Temperature = mean(Temperature, na.rm = TRUE))

# Valikuliselt viiakse keskmise temperatuuri andmed üle laia formaati, kasutades andmetabeli
#veerge 'Month' ja 'Avg_Temperature'.

```

```

average_temperatures_pivot <- average_temperatures %>%
  pivot_wider(names_from = Month, values_from = Avg_Temperature)

# Vaadatakse tulemusi.
average_temperatures_pivot

# Järgnevalt luuakse 'average_temperatures_pivot' andmetabeli jaoks andmeveerg
#'Thermal_Index', mis tähistab eesti keeles soojusindeksit.
average_temperatures_pivot <- average_temperatures_pivot %>%
  rowwise() %>%
  mutate(Thermal_Index = sum(
    ((pmax(c_across(`01`:`12`), 0) / 5) ^ 1.514), na.rm = TRUE
  ))

# Vaadatakse tulemusi.
print(average_temperatures_pivot)

# Järgnevalt leitakse 'average_temperatures_pivot' andmetabeli jaoks andmeveerg 'Eksponent',
#mis tähistab eesti keeles eksponendi väärtust, mida kasutatakse auramise arvutuses.
average_temperatures_pivot <- average_temperatures_pivot %>%
  mutate(Exponent = (6.75e-7 * Thermal_Index^3) - (7.71e-5 * Thermal_Index^2) + (1.792e-2 *
Thermal_Index) + 0.49239)

# Vaadatakse tulemusi.
print(average_temperatures_pivot)

# Siinkohal loetakse sisse fotoperioodi pikkuse andmed.
photoperiod_length <-
read_excel("C:/Users/lauri/Documents/Magistritöö/Andmed3/Photoperiod_length.xlsx")
photoperiod_length

# Muudetakse andmetabeli 'combined_data' andmeveeru 'Date' kuupäevaks. Sama tehakse
#andmetabeli 'photoperiod_length' puhul.
combined_data$Date <- as.Date(combined_data$Date)
photoperiod_length$Date <- as.Date(photoperiod_length$Date)

# Vaadatakse andmetabelite 'combined_data' ja 'photoperiod_length' veergude nimesid.
names(combined_data)
names(photoperiod_length)

# Omavahel ühendatakse andmetabelid 'combined_data' ja 'photoperiod_length'.
joined_data <- inner_join(combined_data, photoperiod_length, by = "Date")
# Vaadatakse andmetabelit 'joined_data'.
joined_data

# Mõlemasse andmetabelisse lisatakse kuupäeva võti.

```

```

photoperiod_length <- photoperiod_length %>%
  mutate(MonthDay = format(Date, "%m-%d"))

long_data <- long_data %>%
  mutate(MonthDay = format(Date, "%m-%d"))

# Ühendatakse andmetabelid 'long_data' ja 'photoperiod_length' omavahel veeru 'MonthDay'
#järgi.
joined_data2 <- long_data %>%
  inner_join(photoperiod_length, by = "MonthDay")
# Vaadatakse andmetabelit 'joined_data2'.
joined_data2

# Kontrollitakse esimesi andmetabeli ridu.
head(joined_data)

# Luuakse uus andmetabel 'combined_data2', põhinedes andmetabelil
#'average_temperatures_pivot' ja võtmena kasutatakse 'Station' veergu.
combined_data2 <- joined_data2 %>%
  left_join(average_temperatures_pivot, by = c("Station"))
combined_data2
# Vaadatakse andmetabeli veergude nimesid.
names(combined_data2)
# Jäetakse alles andmeveerud 'Date.x', 'Station', 'Data', 'Photoperiod_length', 'C',
#'Thermal_Index', 'Exponent'.
combined_data2 <- combined_data2 %>%
  dplyr::select(Date.x, Station, Data, Photoperiod_length, C, Thermal_Index, Exponent)
# Vaadatakse andmetabelit 'combined_data2'.
combined_data2

# Lisatakse teek 'purrr'.
library(purrr)

# Määratakse kaust, kust loeme andmed sisse.
folder_path <- "C:/Users/lauri/Documents/Magistritoo/SPEI_andmed2"

# Samm 1: Arvutatakse potentsiaalse evapotranspiratsiooni väärtused.
PET <- combined_data2 %>%
  mutate(Evaporation = case_when(
    Data < 0 ~ 0,
    Data > 26 ~ C * (-415.85 + 32.24 * Data - 0.43 * Data^2),
    TRUE ~ 16 * C * ((10 * Data / Thermal_Index)^Exponent)
  )) %>%
  dplyr::select(Date = Date.x, Station, Evaporation)

# Samm 2: Tükeldatakse andmetabel 'PET' veeru 'Station' järgi.

```

```

PET_by_station <- PET %>%
  group_split(Station)

# Samm 3: Andmed iga ilmajaama kohta kirjutatakse eraldi failidesse määratud kausta.
walk(PET_by_station, function(df) {
  # Create the filename with the folder path
  file_name <- paste0(folder_path, "/PET_", df$Station[1], ".csv")

  # Write the file
  write.csv(df, file_name, row.names = FALSE)
})

# Viiakse andmed tagasi laia formaati.

# Siin omistatakse andmetabelile 'PET_long' andmetabeli 'PET' väärtused.
PET_long <- PET
PET_long
PET_long <- PET_long %>%
  mutate(Date = format(as.Date(Date), "%m-%d"))

PET_long <- PET_long %>%
  mutate(Year = year(ymd(substring(DateTime, start = 6))),
         Date = mdY(paste("1900", substring(DateTime, start = 6)))) %>%
  dplyr::select(-DateTime)

# Loetakse sademete andmed sisse.
# Juhul, kui varasemalt ei ole intalleeritud, siis intalleeritakse teek 'readxl'.
if (!requireNamespace("readxl", quietly = TRUE)) install.packages("readxl")
library(readxl)

# Seatakse kausta tee, kus asuvad ilmajaama andmete failid (.xls).
directory_path <- "C:/Users/lauri/Documents/Magistritoo/SPEI_andmed3"

# Kõik .xls-failid pannakse nimekirja. Selleks kasutatakse kausta teed.
files <- list.files(directory_path, pattern = "\\.xls$", full.names = TRUE)

# Initsialiseeritakse nimekiri 'precip'.
precip <- list()

# Tsükliga käiakse läbi kõigist xls-failidest.
for (file in files) {
  # Loetakse andmed failist.
  data <- read_excel(file)

  # Tehakse kindlaks algus- ja lõppaasta, põhinedes olemasolevatele andmetele.
  start_year <- min(as.integer(colnames(data)[grepl("^\\d{4}$", colnames(data))]))

```

```

end_year <- max(as.integer(colnames(data)[grepl("^\\d{4}$", colnames(data))]))

# Valitakse välja vajalikud veerud (kuupäeva ja aasta veerud).
required_columns <- c("Date", as.character(start_year:end_year))
data <- data[, required_columns, drop = FALSE]

# Eraldatakse andmed, et kaasata ainult read 1-366.
data <- data[1:366, ]

# Hangitakse faili nimest ilmajaama nimi, et määrata väljundfaili nime.
station_name <- tools::file_path_sans_ext(basename(file))

# Talletatakse läbi töödeldud andmetabel nimekirjana 'precip'.
precip[[station_name]] <- data

# Defineeritakse väljundfaili nime.
output_file_path <- file.path(directory_path, paste0(station_name, "_processed.csv"))

# Kirjutatakse läbi töötatud andmed CSV-faili.
write.csv(data, file = output_file_path, row.names = FALSE, na = "")

# Prinditaks sõnum, mis annab teada, et kindla ilmajaama andmed on töödeldud.
cat("Processed data for", station_name, "saved to", output_file_path, "\n")
}

# Vaadatakse nimekirja 'precip' ja andmetabelit 'PET'.
precip
PET

# Kasutatakse teeki 'purrr'.
library(purrr)

# Muudetakse andmetabelite nimekiri üheks pikas formaadis andmetabeliks.
precip_long <- bind_rows(lapply(names(precip), function(station_name) {
  data <- precip[[station_name]]

# Muudetakse andmetabel 'data' pikka formaati ja salvestatakse see andmetabelina 'data_long'.
data_long <- data %>%
  pivot_longer(cols = -Date, names_to = "Year", values_to = "Precipitation") %>%
  mutate(Station = station_name) %>%
  dplyr::select(Date, Station, Year, Precipitation) %>%
  arrange(Date, Station)

return(data_long)
}), .id = "Station_ID") %>% dplyr::select(-Station_ID)

```

```

# Prinditakse funktsiooni tulemusena saadud pikas formaadis olev sademete andmetabel.
print(precip_long)

# Luuakse uus kuupäeva veerg.
precip_long2 <- precip_long %>%
  mutate(Date = as.Date(paste(Year, Date, sep = "-"), format = "%Y-%j"))

# Vaadatakse uuendatud andmetabelit.
print(precip_long2)

# Andmekirjed järjestatakse kuupäeva järgi.
precip_long2 <- precip_long2 %>%
  arrange(Date)

# Vaadatakse andmetabelit 'precip_long2'.
precip_long2

# Seatakse alguskuupäevaks 1970. aasta 1. jaanuar.
precip_long2 <- precip_long2 %>%
  mutate(Date = as.Date(Date, origin = "1970-01-01"))

# Kuvatakse uuendatud andmetabel.
print(precip_long2)

# Hangitakse andmetabelist 'PET' kõik unikaalsed ilmajaamad.
unique_stations <- unique(PET$Station)

# Prinditakse kõik unikaalsed ilmajaama väärtused.
print(unique_stations)

# Muudetakse 'PET2' väärtused selliseks, et 'PET2' ja 'precip_long2' andmetabeleid oleks
#võimalik ühendada.
PET2 <- PET %>%
  mutate(Station = case_when(
    Station == "johvi_SPEI.xlsx" ~ "Johvidp",
    Station == "kihnu_SPEI.xlsx" ~ "Kihnudp",
    Station == "kunda_SPEI.xlsx" ~ "Kundadp",
    Station == "kuusiku_SPEI.xlsx" ~ "Kuusikdp",
    Station == "narva_SPEI.xlsx" ~ "Narvadp",
    Station == "nigula_SPEI.xlsx" ~ "Niguladp",
    Station == "pakri_SPEI.xlsx" ~ "Pakridp",
    Station == "parnu_SPEI.xlsx" ~ "Parnudp",
    Station == "ristna_SPEI.xlsx" ~ "Ristnadp",
    Station == "sorve_SPEI.xlsx" ~ "Sorvedp",
    Station == "tallinn_SPEI.xlsx" ~ "Tallindp",
    Station == "tartu_SPEI.xlsx" ~ "Tartudp",
  ))

```

```

Station == "tiiriko_SPEI.xlsx" ~ "Tiirikdp",
Station == "tyri_SPEI.xlsx" ~ "Tyridp",
Station == "vaikemaarja_SPEI.xlsx" ~ "Vmaardp",
Station == "valga_SPEI.xlsx" ~ "Valgadp",
Station == "viljandi_SPEI.xlsx" ~ "Viljandp",
Station == "vilsandi_SPEI.xlsx" ~ "Vilsandp",
Station == "virtsu_SPEI.xlsx" ~ "Virtsudp",
Station == "voru_SPEI.xlsx" ~ "Vorudp"

TRUE ~ Station
))

# Vaadatakse andmetabelit 'PET2'.
PET2

# Viiakse kuupäeva numbrilisele kujule, väärtused ümmardatakse lähima integer tüüpi muutuja
#väärtuseni ja kuupäeva arvutusel kasutatakse lähtepunktina 1970. aasta 1. jaanuari.
precip_long2 <- precip_long2 %>%
  mutate(Date = as.Date(round(as.numeric(Date)), origin = "1970-01-01"))

PET2 <- PET2 %>%
  mutate(Date = as.Date(round(as.numeric(Date)), origin = "1970-01-01"))

# Sademete veeru andmeid nihutatakse ühe rea võrra edasi.
precip_long2 <- precip_long2 %>%
  group_by(Station) %>%
  mutate(Precipitation = lead(Precipitation)) %>%
  ungroup()

# Vaadatakse andmetabelit 'precip_long2'.
precip_long2

# Muudetakse 'PET2' väärtused selliseks, et 'PET2' ja 'precip_long2' andmetabeleid oleks
#võimalik ühendada.
joined_df <- inner_join(precip_long2, PET2, by = c("Date", "Station"))

# Prinditakse esimesed paar rida, et kontrollida tulemusi.
head(joined_df)

# Siin arvutatakse veebilanss 30 päeva keskmisena.
library(zoo)
library(fitdistrplus)

# Arvutatakse sademete ja aurumise väärtuste 30 päeva summad ja nende põhjal veebilanss.
joined_df <- joined_df %>%
  group_by(Station) %>%

```

```

mutate(
  roll_precip = rollapply(Precipitation, 30, sum, partial = TRUE, align = 'right'),
  roll_evap = rollapply(Evaporation, 30, sum, partial = TRUE, align = 'right'),
  water_balance = roll_precip - roll_evap
) %>%
ungroup()

# Leitakse kuu ja päeva.
across_years <- joined_df %>%
  mutate(
    Month = format(Date, "%m"),
    Day = format(Date, "%d")
  )

# Vaadatakse andmetabelit 'across_years'.
across_years

# Grupeeritakse andmetabel andmeveergude 'Station', 'Month' ja 'Day' järgi ning arvutatakse
#keskmise veebilanssi.
across_years <- across_years %>%
  group_by(Station, Month, Day) %>%
  mutate(mean_balance = mean(water_balance, na.rm = TRUE)) %>%
  ungroup()

# Grupeeritakse andmeveergude 'Station', 'Month' ja 'Day' järgi ning arvutatakse veebilansi
#standardhälve.
across_years <- across_years %>%
  group_by(Station, Month, Day) %>%
  mutate(sd_balance = sd(water_balance, na.rm = TRUE)) %>%
  ungroup()

# Kuvatakse andmetabel 'across_years'.
across_years

# Arvutatakse SPEI väärtused.
across_years$SPEI <- (across_years$water_balance - across_years$mean_balance) /
across_years$sd_balance

# Filtreeritakse andmetabel 'across_years', nii et oleksid kaasatud
#kuupäevad pärast 1951. aasta 1. maid.
joined_df_filtered <- across_years %>%
  filter(Date >= as.Date("1951-05-01"))

# Filtreeritakse välja kõigi aastate aprillikuud.
joined_df_filtered <- joined_df_filtered %>%
  filter(!(month(Date) == 4 & day(Date) <= 30))

```

```

# Vaadatakse andmetabelit 'joined_df_filtered'.
print(joined_df_filtered)

# Filtreeritakse andmetabelit, et kaasata kuupäevad algusega 1951. aasta 5. mai.
filtered_df <- joined_df_filtered %>%
  filter(Date >= as.Date("1960-05-01"))

# Sorteeritakse andmed kuupäeva ja ilmajaama järgi.
arranged_df <- filtered_df %>%
  arrange(Date, Station)

# Vaadatakse tulemusena saadud andmetabelit.
print(arranged_df)

# Ilmajaamade jaoks koostatakse eraldi failid, et need hiljem meetodile ette sööta.
# Defineeritakse väljundkaust.
output_directory <- "C:/Users/lauri/Documents/Magistritoo/SPEI_andmed4"

# Kontrollitakse, kas väljundkaust on olemas, juhul kui mitte, siis luuakse see.
if (!dir.exists(output_directory)) {
  dir.create(output_directory, recursive = TRUE)
}

# Tsükliga käiakse läbi kõik ilmajaamad.
for (station_name in unique(joined_df_filtered$Station)) {
  # Filteeri andmed hektel töödeldavad ilmajaama jaoks.
  station_data <- joined_df_filtered[joined_df_filtered$Station == station_name, ]

  # Defineeritakse faili nimi.
  file_name <- paste0(output_directory, "/", gsub("[^A-Za-z0-9._]", "", station_name),
    "_data.csv")

  # Kirjutatakse andmed CSV-faili.
  tryCatch(
    {
      write.csv(station_data, file = file_name, row.names = FALSE)
      cat("File", file_name, "edukalt loodud.\n")
    },
    error = function(e) {
      cat("Faili loomisel esines viga", file_name, ":", conditionMessage(e), "\n")
    }
  )
}

# Siin luuakse eraldi failidesse kirjutatud andmed uuesti sisse.

```

```

# Kasutatakse teeke 'readr' ja 'stringr'.
library(readr)
library(stringr)

# Defineeritakse kaust, mis sisaldab vajalikke CSV-faile.
input_directory_path <- "C:/Users/lauri/Documents/Magistritoo/SPEI_andmed4"
output_directory_path <- "C:/Users/lauri/Documents/Magistritoo/SPEI_andmed5"

# Luuakse väljundkaust, kui seda veel ei ole loodud.
if (!dir.exists(output_directory_path)) {
  dir.create(output_directory_path)
}

# Pannakse nimekirja kõik vastava kausta CSV-failid.
file_paths <- list.files(input_directory_path, pattern = "\\*.csv$", full.names = TRUE)

# Initsialiseeritakse tühi nimekiri, et talletada iga ilmajaama p-väärtusi.
list_of_p_values <- list()

# Käiakse tsükliga läbi kõik CSV-failid.
for (file_path in file_paths) {
  # Hangi ilmajaama nimi failist
  file_name <- basename(file_path)
  station_name <- str_extract(file_name, "^[^_]+")

  # Laaditakse CSV-fail.
  data <- read.csv(file_path)

  # Töödeldakse ja filtreeritakse andmed.
  data <- data %>%
    mutate(
      Date = as.Date(Date),
      Year = year(Date),
      DayMonth = format(Date, "%m-%d")
    ) %>%
    filter(month(Date) >= 5 & month(Date) <= 9)

  # Arvutatakse iga kuupäeva jaoks p-väärtused.
  p_values <- data %>%
    group_by(DayMonth) %>%
    summarize(
      P_Value = cor.test(SPEI, Year, method = "pearson")$p.value,
      .groups = 'drop'
    )

  # Muudetakse P-väärtuse veeru nime, et võtta arvesse ka ilmajaama nime.

```

```

p_values <- p_values %>%
  rename(!paste0(station_name, "_P_Value") := P_Value)

# Lisatakse vastava ilmajaama p-väärtused nimekirja.
list_of_p_values[[station_name]] <- p_values
}

# Vaadatakse nimekirja 'list_of_p_values'.
list_of_p_values
# Ühendatakse kõik p-väärtuse andmetabelid kuupäeva veeru järgi.
all_p_values_df <- reduce(list_of_p_values, full_join, by = "DayMonth")

# Kirjutatakse tulemuseks saadud tabel CSV-faili.
write.csv(all_p_values_df, file.path(output_directory_path, "all_stations_pvalues_final2.csv"),
row.names = FALSE)

# Määratakse andmekaust, kuhu failid salvestatakse.
output_directory <- "C:/Users/lauri/Documents/Magistritoo/Andmed6"

# Luuakse väljundkaust, kui seda veel ei ole tehtud.
if (!dir.exists(output_directory)) {
  dir.create(output_directory)
}

# Hangitakse ilmajaamade nimed.
station_names <- unique(joined_df$Station)

# Käiakse tsükliga läbi kõik ilmajaamad.
for (station in station_names) {
  # Filtreeritakse vastava ilmajaama andmed.
  station_data <- filter(joined_df, Station == station)

  # Defineeritakse faili nime koos kausta teega.
  file_name <- paste0(output_directory, "/", station, ".csv")

  # Kirjutatakse filtreeritud andmed CSV-faili.
  write.csv(station_data, file = file_name, row.names = FALSE)

  # Prinditakse sõnum, mis viitab faili loomisele.
  cat("Ilmajaama", station, "andmed on kirjutatud faili", file_name, "\n")
}

# Leitakse tõusud.

# Initsialiseeritakse tühi andmetabel, et talletada tõusu väärtusi.

```

```

slope_df <- data.frame(Station = character(), DoY = integer(), Slope = numeric(),
stringsAsFactors = FALSE)

for (station in unique(joined_df_filtered$Station)) {
# Luuakse hetkel töödeldava ilmajaama jaoks andmete alamhulk.
station_data <- joined_df_filtered %>% filter(Station == station)

# Arvutatakse tõusud iga kuupäeva jaoks - 1. aprill kuni 30. september.
slopes <- station_data %>%
mutate(Date = as.Date(Date),
Year = year(Date),
DoY = yday(Date)) %>%
filter(month(Date) >= 5 & month(Date) <= 9) %>%
group_by(DoY) %>%
summarize(Slope = if(n() > 1 && sum(!is.na(SPEI)) > 1) {
spei_lm <- lm(SPEI ~ Year, data = cur_data())
if(all(!is.na(coef(spei_lm)))) coef(spei_lm)[["Year"]] else NA_real_
} else NA_real_,
.groups = 'drop')

# Lisatakse ilmajaama andmed tõusu andmetabelisse.
slopes$Station <- station

# Lisatakse vastava ilmajaama tõusu andmed tõusu andmetabelisse.
slope_df <- bind_rows(slope_df, slopes)
}

# Vaadatakse tulemusena saadud tõusu andmetabelit.
print(slope_df)

# Siin leitakse tõusu muutused aastate lõikes, mis vastab ilmajaama käigus oleku ajale.

# Arvutatakse iga ilmajaama jaoks aegrea pikkus.
year_range <- joined_df_filtered %>%
group_by(Station) %>%
summarise(min_date = min(Date),
max_date = max(Date)) %>%
mutate(year_range = round(as.numeric(difftime(max_date, min_date, units = "days") / 365)))

# Ühendatakse andmetabel 'slope_df' andmetabeliga 'year_range'.
slope_df <- slope_df %>%
left_join(year_range, by = "Station")

# Arvutatakse muutuse väärtus.
slope_df <- slope_df %>%
mutate(change = ifelse(!is.na(year_range), Slope * year_range, NA))

```

```

slope_df

# Kirjutatakse andmed CSV-faili.
write.csv(slope_df,
"C:/Users/lauri/Documents/Magistritoo/Andmed2/Ilmaandmed2/Koondandmed9/slope_results.c
sv", row.names = FALSE)

# Samm 1: Filtreeritakse välja read, mille DoY (kuupäeva järjenumbr) väärtus on 121.
slope_df_filtered <- slope_df

# Samm 2: Muudetakse DoY soovitavas formaadis tegelikuks kuupäevaks.
slope_df_filtered <- slope_df_filtered %>%
  mutate(Date = format(ymd("1951-01-01") + days(DoY - 1), "%m-%d"))

# Samm 3: Eemaldatakse esialgne veerg 'DoY'.
slope_df_filtered <- slope_df_filtered %>%
  dplyr::select(-DoY)

# Kuvatakse andmetabeli 'slope_df_filtered'.
slope_df_filtered
# Muudetakse veerg 'Date' kuupäeva tüübiks.
slope_df_filtered$Date <- as.Date(slope_df_filtered$Date, format = "%m-%d")

# Filtreeritakse välja kirjed, mis vastavad 30. aprillile.
slope_df_filtered <- slope_df_filtered %>%
  filter(!(format(Date, "%m-%d") == "04-30"))

# Prinditakse muudetud andmetabel.
print(slope_df_filtered)

# Kontrollitakse, kas esineb ridu, mis on võrdsed 30. aprilliga.
april_1_count <- slope_df_filtered %>%
  filter(format(Date, "%m-%d") == "04-30") %>%
  nrow()

if (april_1_count > 0) {
  print("30. aprill on andmetabelis 'slope_df_filtered' olemas.")
} else {
  print("30. aprilli ei ole andmetabelis 'slope_df_filtered'.")
}

slope_df_filtered$Date <- format(slope_df_filtered$Date, "%m-%d")
print(slope_df_filtered)

# Tõusu väärtused kirjutatakse eraldi faili.

```

```

write.csv(slope_df_filtered,
"C:/Users/lauri/Documents/Magistritoo/Andmed2/Ilmaandmed2/Koondandmed9/slope_results_f
inal2.csv", row.names = FALSE)

# Eestikeelsed graafikud
# Kasutatakse teeki 'ggplot2'.
library(ggplot2)

# Määratakse väljundkaust.
output_dir2 <- "C:/Users/lauri/Documents/Magistritoo/SPEI_andmed5"

# Koostatakse Eesti kohanimedega vektor.
estonian_month_abbreviations <- c("jaan", "veeb", "märts", "apr", "mai", "juuni", "juuli", "aug",
"sept", "okt", "nov", "dets")
# Defineeritakse funktsioon, millega muudetakse kuupäeva järjekorranumber kuu nimetusega
kuupäevaks.
doy_to_date <- function(doy) {
  # Defineerime alguskuupäeva.
  start_date <- as.Date("1951-01-01")

  # Lisatakse kuupäeva järjenumber alguskuupäevale.
  date <- start_date + (doy - 1)

  # Vormindatakse lühendatud kuu nime ja kuupäeva.
  formatted_date <- format(date, "%d-%b")

  return(formatted_date)
}

# Selle funktsiooniga on leitakse graafikule kuud mai, juuli, september.
# Defineeritakse funktsiooni, millega muudame kuupäeva lühendatud kuu nimetustega
#kuupäevadeks.
doy_to_date <- function(doy) {
  # Defineeritakse alguskuupäev.
  start_date <- as.Date("1951-01-01")

  # Lisatakse alguskuupäevale kuupäeva järjenumber.
  date <- start_date + (doy - 1)

  # Vormindatakse lühendatud kuu nimetusega kuupäev ja kuupäeva järjenumber.
  formatted_date <- format(date, "%d-")
  month_index <- as.numeric(format(date, "%m"))
  formatted_date <- paste0(formatted_date, estonian_month_abbreviations[month_index])

  return(formatted_date)
}

```

```

# Meetod kuupäevade leidmiseks
# Tegemist on vektoriga, milles on salvestatud õiged ilmajaamade nimed, mis vastavad
#kohanimedele.
station_name_mapping <- c("Johvidp" = "Jõhvi",
    "Kihnudp" = "Kihnu",
    "Kundadp" = "Kunda",
    "Kuusikdp" = "Kuusiku",
    "Narvadp" = "Narva",
    "Niguladp" = "Nigula",
    "Pakridp" = "Pakri",
    "Parnudp" = "Pärnu",
    "Ristnadp" = "Ristna",
    "Sorvedp" = "Sõrve",
    "Tallindp" = "Tallinn",
    "Tartudp" = "Tartu",
    "Tiirikdp" = "Tiirikoja",
    "Tyridp" = "Türi",
    "Valgadp" = "Valga",
    "Viljandp" = "Viljandi",
    "Vilsandp" = "Vilsandi",
    "Virtsudp" = "Virtsu",
    "Vmaardp" = "Väike-Maarja",
    "Vorudp" = "Võru"
)

# Tsükliga käiakse läbi kõik ilmajaamad.
for (station in unique(slope_df$Station)) {

    # Koostatakse eraldi andmehulk vastava ilmajaama jaoks.
    station_data <- subset(slope_df, Station == station)

    # Koostatakse vastava ilmajaama jaoks graafik.
    p <- ggplot(station_data, aes(x = DoY, y = change)) +
        geom_line() +
        labs(title = paste("SPEI indeksi muutuse graafik", station, "ilmajaama jaoks"),
            x = "Kuupäev",
            y = "SPEI indeksi muutus") +
        scale_x_continuous(labels = function(x) doy_to_date(x)) + # Rakendatakse muudetud x-telje
#silte.
        theme_minimal() +
        theme(panel.background = element_rect(fill = "white"), # Taust muudetakse valgeks.
            plot.background = element_rect(fill = "white")) # Graafiku taust muudetakse valgeks.

    # Salvestatakse graafik kindlaks määratud kausta.
    ggsave(filename = file.path(output_dir2, paste0(station, "_change_plot.png")), plot = p)
}

```

```

}

# Siin on lõplik versioon eestikeelsest graafikust.

# Defineeritakse iga kuu jaoks intervallid.
breaks <- seq(0, 365, by = 30)

# Kärbitakse vektorit 'estonian_month_abbreviations', et see vastaks murdepunktide arvule.
estonian_month_abbreviations <- estonian_month_abbreviations[1:length(breaks)]

# Tsükliga käiakse läbi kõik ilmajaamad.
for (station in unique(slope_df$Station)) {
  # Asendatakse tegelik ilmajaama nimi, kui see on vektoris 'station_name_mapping' olemas,
  #muidu kasutakse eelnevat nime.
  real_station_name <- ifelse(station %in% names(station_name_mapping),
station_name_mapping[station], station)

  # Luuakse vastava ilmajaama jaoks alamandmehulk.
  station_data <- subset(slope_df, Station == station)

  # Koostatakse vastava ilmajaama jaoks graafik.
  p <- ggplot(station_data, aes(x = DoY, y = change)) +
    geom_line() +
    labs(title = paste("SPEI indeksi muutus", real_station_name, "ilmajaama andmetel"),
      x = "Kuupäev",
      y = "Väärtuse muutus") +
    scale_x_continuous(breaks = breaks, labels = estonian_month_abbreviations) +
  #Rakendatakse valikulisi x-telje silte.
  theme_minimal() +
  theme(panel.background = element_rect(fill = "white"),
    plot.background = element_rect(fill = "white"))

  # Salvestatakse graafik kindlaks määratud kausta.
  ggsave(filename = file.path(output_dir2, paste0(real_station_name, "_change_plot.png")), plot
= p)
}

# Leitakse koondgraafik.

# Samm 1: Arvutatakse muutuste väärtused iga kuupäeva jaoks iga ilmajaama puhul.
change_values <- slope_df %>%
  group_by(Station, DoY) %>%
  summarise(change = mean(change, na.rm = TRUE))

# Samm 2: Kasutatakse keskmisi muutuste väärtusi iga kuupäeva ja ilmajaama puhul.
average_change <- change_values %>%

```

```

group_by(DoY) %>%
summarise(average_change = mean(change, na.rm = TRUE))

output_dir_plot <- "C:/Users/lauri/Documents/Magistritoo/SPEI_andmed5"

# Samm 3: Koostatakse graafik.
plot <- ggplot(average_change, aes(x = DoY, y = average_change)) +
  geom_line() +
  labs(title = "Keskmine muutuse väärtus kõigi ilmajaamade lõikes",
        x = "Kuupäev",
        y = "Keskmine muutuse väärtus") +
  scale_x_continuous(labels = function(x) doy_to_date(x)) +
  theme_minimal() +
  theme(panel.background = element_rect(fill = "white"),
        plot.background = element_rect(fill = "white"))

ggsave(filename = file.path(output_dir_plot, "average_change_plot.png"), plot = plot)

```

## Lisa 2. Programm Mann-Kendalli testi jaoks

```
# Töökausta seadmine
setwd("C:/Users/lauri/Documents/Magistritoo/Andmed2/ilmaandmed")
getwd()

# Andmete sisse lugemine
spi_data <-
read_excel("C:/Users/lauri/Documents/Magistritoo/Andmed2/johvi_SPEI_normal.xlsx")

# Vajalikud teegid
library(tidyverse)
library(lubridate)
library(tidyr)

# Andmete laiast formaadist pikka formaati üle viimine
long_data <- spi_data %>%
  pivot_longer(-Date, names_to = "Year", values_to = "Data") %>%
  mutate(Date = make_date(as.integer(Year), month(Date), day(Date)),
         Date = if_else(Date >= as.Date("1960-01-01") & Date <= as.Date("2023-12-31"), Date,
as.Date(NA))) %>%
  drop_na(Date) %>%
  select(Date, Data) %>%
  arrange(Date)

# Luuakse eraldi aasta veerg.
long_data <- long_data %>% mutate(Year = format(Date, "%Y"))

# Filtreeritakse andmeid.
filtered_data <- long_data %>% filter(Year >= 1960 & Year <= 2023)

# Initsialiseeritakse andmetabel 'results'.
results <- data.frame(Year = integer(), P_Value = numeric())

# Tsükliga käiakse läbi iga aasta ja teostatakse normaaljaotusele vastavuse kontrollimiseks
#Lillieforsi test.
for (year in 1960:2023) {
  # Filtreeritakse aasta järgi.
  year_data <- filtered_data %>% filter(Year == year)

  # Viiakse läbi Lillieforsi test
  test_result <- lillie.test(year_data$Data)
```

```

# Talletatakse aasta ja p-väärtused.
results <- rbind(results, data.frame(Year = year, P_Value = test_result$p.value))
}

# Leitakse p-väärtusest 0,05 väiksemate ridade arv.
num_significant <- sum(results$P_Value < 0.05)

# Leitakse andmetabeli kogu ridade arv.
total_rows <- nrow(results)

# Leitakse normaaljaotusele mitte vastavate tulemuste protsent.
percentage_significant <- (num_significant / total_rows) * 100

# Luuakse andmetabelile 'long_data' uus andmeveerg 'Month_Day'.
long_data$Month_Day <- format(long_data$Date, "%m-%d")
long_data

# Lisatakse vajalikud teegid.
library(trend)
library(dplyr)

# Mann-Kendalli testiga leitakse p-väärtused ja Seni tõusu hinnangud.
Results <- long_data %>%
  group_by(Month_Day) %>%
  filter(n() >= 3) %>% # Veendutakse, et igas grupis on vähemalt kolm andmepunkti.
  summarise(
    MK_Test = list(MannKendall(Data)),
    Sen_Slope = list(sens.slope(Data)$estimates), # Arvutatakse Seni tõusu hinnang.
    .groups = 'drop'
  ) %>%
  mutate(
    Tau = sapply(MK_Test, function(x) x$tau),
    P_value = sapply(MK_Test, function(x) x$sl),
    Z_score = sapply(MK_Test, function(x) qnorm(1 - x$sl / 2)), # Arvutatakse p-väärtustest Z-
    skoorid.
    Sen_Slope = sapply(Sen_Slope, function(x) x) # Seni tõusu hinnang
  )

```

# Lihtlitsents lõputöö reprodutseerimiseks ja üldsusele kättesaadavaks tegemiseks

Mina, Lauri Leinus

*(autori nimi),*

1. annan Tartu Ülikoolile tasuta loa (lihtlitsentsi) minu loodud teose „Põuasuse sesoonne, territoriaalne ja pikaajaline muutlikkus Eestis“,

*(lõputöö pealkiri)*

mille juhendajad on Jaak Jaagus ja Ain Kull,

*(juhendajate nimed)*

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.

*Lauri Leinus*

**27.05.2024**