

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

Bakalaureusetöö geograafias (12 EAP)

**Metsa- ja maastikupõlengute ohu ennetamisest Eestis
meteoroloogiliste andmete abil**

Risto Merdenson

Juhendaja: Prof. Tõnu Oja

Tartu 2024

Annotatsioon

Metsa- ja maastikupõlengute ohu ennetamisest Eestis meteoroloogiliste andmete abil

Metsa- ja maastikutulekahjud mängivad aegade algusest peale olulist rolli inimeste eludes. 1850ndate aastate algusest on kiirgusbilanss hakanud kiiremini kasvama, mistõttu sagenevad looduspõlengud. Iga aasta põleb 2.5% kogu maailma maismaa pindalast ning kahjud ulatuvad miljarditesse.

Käesolevas töös uuriti metsa- ja maastikupõlengute teket ning levikut. Töö eesmärgiks püstitati luua Pythoni programm, mis kasutades IDW interpoleerimismeetodit, suudab arvutada Päästeametis registreeritud metsa- ja maastikupõlengute koordinaatidele meteoroloogiliste tegurite väärtuseid. Arvutatud andmeid saab edasi kasutada minevikus toimunud metsa- ja maastikupõlengute uurimiseks.

Märksõnad: tuleohu ennetamine, meteoroloogia, ruumiline paiknemine, interpoleerimine, metsatulekahju, maastikutulekahju, looduspõleng

CERCS kood: T181 Kaugseire

Abstract

Assessing the risk of forest and landscape fires in Estonia with meteorological data

Forest and landscape fires have played a significant role in people's lives since ancient times. Since the early 1850s, the radiation balance has been increasing more rapidly, leading to a rise in natural fires. Every year, 2.5% of the world's land area burns, resulting in damages reaching into the billions.

This study investigated the occurrence and spread of forest and landscape fires. The aim was to develop a Python program capable of calculating meteorological values for forest and landscape fire coordinates registered by the Rescue Board using IDW interpolation. The computed data can be further used to study past forest and landscape fires.

Keywords: fire danger prediction, meteorology, spatial distribution, interpolation, forest fire, landscape fire, wildfire

CERCS code: T181 Remote sensing

Sisukord

Kasutatud lühendid.....	5
Sissejuhatus.....	6
1. Metsa- ja maastikupõlengute teoreetiline ülevaade.....	8
1.1 Uurimustest Eestis.....	8
1.2 Põlengute olemus ja definitsioonid.....	10
1.3 Põlengute suurust ja teket mõjutavad tegurid.....	12
1.4 Põlengute ennetamine ja vältimine.....	14
2. Materjal ja meetodika.....	18
2.1 Metsa- ja maastikupõlengute andmed.....	18
2.2 Meteoroloogiliste andmete töötlemine.....	22
2.2.1 Temperatuur.....	23
2.2.2 Sademed.....	24
2.2.3 Õhuniiskus.....	26
2.2.4 Päikesekiirgus.....	28
2.2.5 Keskmine tuule kiirus.....	30
2.3 Programmi kirjeldus ja struktuur.....	31
3. Tulemused ja arutelu.....	34
3.1 IDW programm.....	34
3.2 Interpoleeritud metsa- ja maastikupõlengute andmed.....	35
Kokkuvõte.....	39
Summary.....	40
Tänuavaldused.....	41
Kasutatud kirjandus.....	42
LISAD.....	49

Kasutatud lühendid

Mõiste	Lühend	Tähendus	Selgitus
IDW	Inverse Distance Weighting	Kauguse pöördväärtusega kaalutud mood	Deterministlik interpoleerimise meetod, kus ruumiliselt kaugemal asuvatel väärtusel on väiksem mõju tundmatule.
Hüdromeetriaajaam	hmj	-	Veemõõtejaam, kasutati töös sademete vaatlusandmete jaoks

Sissejuhatus

Põlengud on looduses kujundanud Maa ökosüsteemide kujunemist sadu miljoneid aastaid, mõjutades nii taimede, loomade kui ka biokeemiliste protsesside evolutsiooni (Bowman et al., 2020). Põlemisel paiskub õhku hulgaliselt veeauru, peenosakekest süsihappegaasi (CO₂), vingugaasi (CO), metaani (CH₄), diämmastikoksiidi (N₂O) ja aerosoole. Põlemisel eralduvate osakeste hulk ja tüüp sõltuvad otseselt lähtematerjalist ja selle kogusest, mis on maailmas piirkonniti erinev (Bowman et al., 2009; Urbanski et al., 2008). 1850ndate aastate tööstusrevolutsioonist peale on kiirgusbilanss tulekahjude mõjul kasvanud 0.5W/m² ning kliima soojenemise tulemusena on veelgi oodata ülemaailmselt põlengute intensiivsuse kasvu (Ward et al., 2012).

Kulu- ja maastikupõlengutel on keskkonnale ja inimesele märkimisväärne mõju, seda enam väiksemate laiuskraadide soojema ja kuivema kliimaga aladel. Ühelt poolt aitavad tulekahjud looduses kaasa haiguste leviku takistamisele ja ökoloogilisele mitmekesisusele, mis on suurim vahetult pärast põlengut. Pikemalt tajutava mõjuna avanevad ökosüsteemis uued ökoloogilised nišid, mille hõivavad järgmised sobiva kohastumisega liigid (He et al., 2019). Teisalt hävivad põlengus ka kaitse all olevate liikide populatsioonid ja neile eluks vajalik keskkond. Üle maailma on põlengute tiheda režiimi tõttu punasesse raamatusse kantud rohkem kui 4400 taksonit ja elupaika (Kelly et al., 2020; Hirschberger, 2016).

Uuringud on näidanud, et inimene on otseselt või kaudselt vastutav rohkem kui 90% tulekahjude eest paljudes enamuses piirkondades (Hirschberger, 2016; Robinne, 2021). Euroopas kannavad iga aasta 13-21 miljardi euro väärtuses põlengute tõttu majanduslikku kahju Vahemere ümbruses olevad riigid Hispaania, Itaalia ja Kreeka (Meier et al., 2023). Iga-aastane maastikutulekahjude üldpindala maailmas on 350 miljonit hektarit, ehk 2.5% kogu maismaa pindalast (Karoles, 2020). Probleemi on aidanud leevendada eriti soojema kliimaga riikides inimeste harimine ja teavitustöö tulega ringi käimisel (Rowell, A., Moore, P. F., 2022).

Eestis oli 2011-2020 perioodil keskmiselt 74 metsapõlengut aastas, kahjustada saanud ala suuruseks kujunes 1138 ha. Majandusele läksid metsatulekahjud 1999. ja 2020. aasta vahelisel perioodil maksma suurusjärgus 20 miljonit eurot. Perioodi viimastel aastatel on need arvud olnud kahanevas trendis. Perioodi kõige keerulisem aasta oli suvise põuaperioodi

tõttu 2018 kui Eestis oli 230 metsatulekahju. Võrdluseks oli aastatel 2016 ja 2017 vastavalt 84 ja 64 metsatulekahju. See aasta oli ütlemissi raske kogu Euroopa jaoks (San-Miguel-Ayanz et al., 2022; Valgepea et al., 2020). Teadaolevalt oli 2014-2023 vahemikus kokku peaaegu 11000 metsa- ja maastikupõlengut (Päästeamet, 2023).

Maailmas alustati tuleohu ennetamisega läbi matemaatiliste meetodite 20. sajandil. Palju on võimalik veebist leida teadusalast kirjandust, mis läbi erinevate sisendite ja arvutusmetoodika püüavad ennetada põlengute ajalisruumilist paiknemist, intensiivsust ja levikut. Levinum meetod tänapäeval on tulekahjude ennetamiseks tuleohuindeksite rakendamine. Tegemist on kompleksnäitajatega, mis võimaldavad enamasti kvantitatiivseid sisendeid arvesse võttes hinnata piirkonna tuleohuriski. Selleks, et võtta kasutusele või luua vajamineva keskkonna tarbeks parim põlenguid ennustav mudel, on parim praktika katsetada erinevaid meetodeid ja jõuda sobiva lahenduseni (Torres et al., 2017).

Käesoleva töö üldisem eesmärk on kaasa aidata meteoroloogiliste tegurite koosmõju uurimisele Eesti metsa- ja maastikupõlengute süttimisohu ja leviku juures. Tegemist on Eesti kontekstis vähem uuritud lähenemisviisiga põlengute tekkepõhjuste ennetamisel. Antud uurimise käigus ei ole eesmärgiks ümber lükata inimtegevuse domineerivat mõju põlengute tekkele. Tegemist on valdkonna tõekspidamisega ja autorile teadaolevalt pole siiani suudetud vastupidist tõestada. Siinkohal püstitatakse antud töös alljärgnev eesmärk:

1. Sobivas vormis lähteandmete puudumist arvesse võttes uurimaks minevikus toimunud ilmastiku ja põlengute omavahelisi seoseid, on vaja välja töötada programm ja ette valmistada toorandmed, mis võimaldaksid korraga interpoleerida rakendades IDWd Keskkonnaagentuuri vaatlusjaamade võrgustiku seireandmed metsa- ja maastikupõlengu koordinaatidele aastatel 2014-2022. Ilmastiku elementide ja aset leidnud põlengute seoste edasine analüüsimine võimaldab paremini mõista probleemi olemust ja kaasa aidata tulevaste kahjude vähendamisele.

1. Metsa- ja maastikupõlengute teoreetiline ülevaade

1.1 Uurimustest Eestis

Maastiku mõiste on geograafilises käsitluses ruum, kus toimub nii sotsiaalne kui majanduslik tegevus, millega pannakse alus emotsioonide ja taju raamistikule. Seda võib ühtaegu vaadata kui kõikehõlmavat tundelist ja füüsilist keskkonda (Arold, 2005). Metsaks loetakse maatükki pindalaga vähemalt 0.1 hektarit, millel kasvavad puittaimed kõrgusega vähemalt 1.3m ning puuvõrade liitus on rohkem kui 30% (Metsaseadus 2020, § 3).

Oluline on märkida, et inglise keeles kasutatakse Oxfordi Ülikooli sõnastiku andmetel mõistet *wildfire* kirjeldamiseks eesti keele tähenduses nii kulu-, metsa- ja maastikupõlenguid. Maastikupõlengute jaoks kasutatakse sageli ka sõna *landscape fire*. Eesti Keele Instituudi sõnastiku alusel tähendab *wildfire* otseselt kulutulud, kuigi eestikeelses erialases teaduslikus kirjanduses on kasutusele võetud vähemlevinud mõiste “looduspõleng”.

Varasemalt on Eestis metsa- ja maastikutulekahjude tekkepõhjuste seoseid kvantitatiivselt analüüsitud võrdlemisi vähesel määral, aga teemat üldisemalt on uuritud palju ning kogemustele tuginevast olukorda kirjeldavast kirjandusest puudust ei ole. Tartu Ülikooli geograafia osakonnas on viimastel aastatel sel teemal kaitstud kaks magistritööd ning Maailikoolis üks bakalaureusetöö:

1. „Risk Assessment of Landscape Fires in Estonia“ magistritöö aastal 2020, autoriks on K. A. Koranteng;
2. „Mapping Wildfire Susceptibility of Sardinia Island, Italy“ magistritöö aastal 2020, autoriks Behzad Valipur Shokouhi.
3. „Tartumaa metsa- ja maastikutulekahjud 2014-2022“ bakalaureusetöö aastal 2023, autoriks Daria Gabriela Orr.

Orr (2023) uuris oma bakalaureusetöös metsa- ja maastikupõlengute paiknemise ajalis-ruumilist jaotust Tartumaal ja võrdles kogutud andmeid ülejäänud Eestiga. Uuritavaks perioodiks olid aastad 2014 kuni 2022. Ruumilises analüüsis püstitati hüpotees, et metsa- ja maastikupõlengute asukohad võivad jääda RMK puhkerajatiste ja lõkkekohtade lähedusse. See kinnitust ei leidnud ning lõkkekohtade suhtes võib olla tendents hoopis vastupidine. Selgus, et Tartumaal jäid 46% põlengutest teedale lähemale kui 25m, mis viitas inimtegevuse

tugevale mõjule. Töö teoreetilises osas kirjeldati Eestist lähtuvalt tulekahjude süttimis põhjuseid, ajaloolist tausta ja mõju kooslustele, metsa uuenemisele

„Mapping Wildfire Susceptibility of Sardinia Island, Italy“ on tuleohu ennetamise teemal kaitstud magistritöö, mis võttis arvesse nii antropogeenseid, ilmastiku ja topograafilisi elemente põlengute ennetamiseks. Töö käigus jõuti järeldusele, et sealse pinnase niiskusel, õhutemperatuuril, tuule suunal, suhtelisel õhuniiskusel ja paiknemisel teedest ning nõlvakutest on oluline mõju põlengute toimumise tõenäosusele. Kõige olulisemate muutujate abil koostati logistilise regressiooni ja otsustusmetsa mudelitel metsatulekahjude esinemistõenäosuse kaardid, mis tõid välja saare kõige tuleohtlikumad piirkonnad.

Koranteng (2020) uuris Eesti maastikupõlenguid peamiselt läbi inimtegevuse ning maakattetüüpide. Ilmastiku mõjusid temperatuuri, suhtelist õhuniiskust, tuule kiirust ja sademeid arvutati jagades aasta keskmised kumulatiivsed väärtused ajavahemike peale laiali. Seejärel analüüsiti kõiki andmeid lineaarse ja Pearsoni korrelatsiooni abil. Lõpuks teostati mitmene regressioonanalüüs maastikutüüpide ja põlengute vahel. Tulemused näitasid olulist korrelatsiooni ($p < 0.05$) turvasmuldade süttimisohule, kuid ilmastikuandmete seas korrelatsiooni ei täheldatud. Ühtlasi tuli välja, et 80% põlengutest jäid maksimaalselt 500m kaugusele sõiduteest. Kõnealuse töö lõpptulemuseks jõuti järeldusele, et Eestis vastutab põlengute eest inimene ja tõenäoliselt mitte ilmastik.

Eelnevalt väljatoodud töö tulemused lähevad teatud määral vastuollu Kitenberga et al. (2018) läbi viidud uurimusega, kus hinnati Atlandi, Põhjamere ja Läänemere veepinna temperatuuri mõju Eesti ja Läti metsatulekahjudele riigiti vastavalt aastatel 1921-2013 ja 1922-2014. Saadi teada, et Lääne- ja Põhjamere veepinna temperatuur on suviti mõõdukas positiivses korrelatsioonis ($p < 10\%$) tulekahjude esinemise ja põlenud ala suurusega. Kevadeti tuvastati mõõdukas korrelatsioon ($p < 10\%$) Atlandi ookeani keskmiste laiuskraadide ja ka suviti rannikualade veetemperatuuri vahel. Antud tulemustest lähtuvalt võib olla alust eeldada teatavat seost Eesti kliima ja põlengute tekke vahel.

1.2 Põlengute olemus ja definitsioonid

Erinevaid põlenguid kirjeldavad suurused on lihtsamal tähenduses ajalises ruumilises, st. antud nähtuste põhiomadusi kirjeldatakse kahesuunaliselt (Moritz et al., 2006; Robinne 2021):

1. Esimene väiksem aste on tuleleek – definitsiooni kohaselt mõõdetav sekundites, minutites ja tundides, suurusjärk on paiga täpsusega. Vajab esmaseks süttimiseks oksüdanti, põlevmaterjali ja soojust, mille tulemusel tekivad oksüdatsioonireaktsioon ja pürolüüs. Põleva ala maht võib olla kuni sadades ruutmeetrites. Väiksema suurusega tulekahju levik sõltub ligipääsust hapnikule ja piisavale hulgale põlevmaterjalile. Levimist takistavad märkimisväärselt ümbritseva keskkonna temperatuur, põlevmaterjali veesisaldus ja suhteline õhuniiskus. Sellest saavad alguse kõik põlengud;
2. Teine aste on põleng – võib kesta nii päevi, nädalaid ja kuid. Põleva ala suurusjärk võib olla sadadest ruutmeetritest kuni kümnete ruutkilomeetriteni. Põlenguid mõjutavad peamised tegurid on ilm, ümbritseva keskkonna topograafia ja biomassi hulk/paiknemine keskkonnas. Hõlmab kõiki atmosfääri osasid, mis mõjutavad tule käitumist maapinnast konvektsioonisamba tipuni;
3. Kolmas ja kõige kõrgem aste on põlengute režiim (tulekliima) - aega saab arvestada aastakümnete vältel, mõjutatava ala suurusjärk võib ulatuda regionaalselt kümnetesse tuhandetesse hektaritesse. Siinkohal ei määratleta põlenguid üksikult, vaid kogumina. Nähtuste kirjeldamisel vaadatakse süttimisohtu peale inimõjude ka kliima ja taimestiku järgi. Režiim järgib keskkonnast lähtuvalt kvantitatiivset seaduspära.

Metsatulekahjud jagatakse liigiti pinnatuleks, ladvatuleks ja maatuleks, sealjuures võib korraga esineda kaks põlengutüüpi korraga. Pinnatuli põleb kuni 1.3m kõrgusel maapinnast, kuid selle alla loetakse ka üksikute kõrgemate puude, põõsaste ja rohttaimede põlemist. 90-95% metsapõlemiste juhtudest on tegemist pinnasepõlenguga. Liikumiskiirus jääb umbes 3-30 cm/sek juurde, tuli kipub edasi liikuma hüppeliselt ja põlemine ei ole täielik. Kui liikumiskiirus jääb alla 3 cm /sek, siis on tegemist püsiva pinnatulega. Siis põlevad taimed ja pinnas sügavamalt, mistõttu suureneb puude hukkumise tõenäosus ja kahju antud ala taimestikule (Õunap & Hanso 2016).

Kõikidest tulekahju liikidest on ladvatuli kõige laastavam (Government of Canada, 2021). See võib kiiresti levida suurele maa-alale, on ohtlik päästjatele ning põhjustab metsa

hävimise. Ladvatuli levib puude võrade kaudu, mida alati saadab mööda maad liikuv pinnatuli. See on oluline, sest pinnatuli aitab konvektsiooni tulemusena tõsta kõrgemal metsarindes keskkonna temperatuuri, vähendada niiskusesisaldust ja põlevate osakeste lendumine suurendab naabertaimede süttimisohtu. Kõige ohustatumad puistud on täiusega 0.7-0.8, mis on ühtlasi Eestis kõige levinumad (Alton & Kiil 2003).

Maatuli tekib pinna ja/või ladvatule tagajärjena enamasti muldades, mis on turba ja huumuserikkad. Sellist laadi tuli võib terve talve mullas hõõguda ja kevadel soojemate temperatuuridega uuesti pinnale tõusta (Government of Canada, 2021). Maatule põlemise intensiivust ei eristata mitte leviku, vaid sügavuse järgi (vt. Tabel 1.)

Tabel 1. Maatule intensiivsuse kategooriad (Alton & Kiil 2003)

Maatule intensiivsus	Põlemise sügavus	Tagajärjed
Nõrk	Puujuurte alt: 30-40 cm Mujalt: 7 cm	Jäävad alles mõningad 3-200 m põlemata laigud. Puud jäävad püsti.
Keskmine	Puujuurte alt: mineraalmaani või põhjaveeni Mujalt: 25 cm	Tuulevaikse ilmaga kukuvad üksikud puud. Tormiga tuuleheiteoht.
Suur	Kõikjalt mineraalmaani või põhjaveeni	Paljud puud langevad.

Kulupõlenguid eristatakse Eestis ja välismaal metsa- ja maastikupõlengutest oma tekkepõhjuse tõttu sageli eraldi. Käesoleva töö autor toob siinkohal välja, et Eestis tehakse vahet kulu- ja maastikupõlengul pigem süttimise põhjuse ja põlevmaterjali alusel. Seevastu ingliskeelses kirjanduses võidakse vahel lugeda kulupõlengut ka inimese kontrolli alt väljunud tulekahjuks, mis ei ole kasulik kohalikele ökosüsteemidele (vt. Tabel 2) (United Nations Environment Programme, 2022). Tagantjärele on erinevate põlengute klassifitseerimine keeruline ning piirid nende vahel raskesti eristatavad. Näiteks märgib Eestis Päästeamet toimunud tulekahjude andmetes põlengu liigi lahtrisse sageli kulu ja maastikupõlengu korraga. Samas võib kulupõlengust saada maastikupõleng ja vastupidi.

Tabel 2. Maastiku- ja kulupõlengute erinevus (United Nations Environment Programme, 2022)

	Maastikupõlengud	Kulupõlengud
Sagedus	Hooajaline, raskesti ennetatav ja inimesest sõltuv	Sagedane ekstreemse tuleohuga päevadel
Põlengu intensiivsus ja levik	Väike kuni mõõdukas, hetkeliselt suur	Suur, hetkeliselt võib olla mõõdukas
Kustutatavus	Kergem, tavalised kustutusmeetmed	Raske, võib muutuda kiiresti kontrollimatuks
Mõju loodusele ja inimesele	Pigem madal, osadele liikidele ka kasulik	Suur, võib ulatuslikult mõjutada sotsiaalseid, keskkondlikke ja majanduslikke aspekte

1.3 Põlengute suurust ja teket mõjutavad tegurid

Põlengu tekkimiseks on vaja kolme komponenti: 1. põlevmaterjali, milleks on looduses leiduv biomass (puud, lehed, oksad); 2. oksüdanti, mis on atmosfääris; 3. esmast soojust kandvat elementi, milleks on rohkem kui 90% juhtudest inimene (Robinne, 2021). Hispaanias Kataloonias põhjustas 1994-2009 aastatel äike 11% kulu põlengutest, kuid see on maailmas piirkonniti väga erinev (Pineda et al., 2014). Eestis oli see näitaja aastatel 1999-2020 vaid 1.3% (Valgepea et al., 2021). Näiteks Kanadas põhjustab äike iga aasta veidi vähem kui poole kogu riigi põlengutest, kuid on samas vastutav 67% kogu põlenud ala eest. Kanada puhul on põhjus inimeste väheses paiknemises paljudes piirkondades – kui põleng ei ohusta elanike vara ega maad, siis jäetakse see kustutamata. Kuna äikese poolt põhjustatud põlenguid on palju, siis ei jagu ka piisavalt ressursse nende piiramiseks (Government of Canada, 2021).

Viise, kuidas inimene ja loodus piirkonna tule levikut mõjutavad on palju (vt. Tabel 3). Tulekahjude intensiivsusel ja tõsidusel on antud teemas oma tähendus. Tulekahju tõsidus viitab biomassi lagunemise või hukkunud isendite hulga. Põlengut ei loeta oluliseks kui antud piirkonna taimedel ja loomadel on selleks vajalik kohastumus ning see ei kahjusta

elanikkonna huve. Intensiivsus viitab põlengu füüsikalistele omadustele, nagu kestus, ulatus ja paiknemine (Taillie et al., 2018).

Tabel 3. Looduslikud ja inimtegevuse mõjud põlengute levikule (Bowman et al., 2011; United Nations Environment Programme, 2022).

Põlengu levikut mõjutav tegur	Looduslikud mõjud	Inimtegevuse mõjud	Mõju tule füüsilistele omadustele
Tuule kiirus	Aastaaeg, ilm, topograafia, maakate	Kliimamuutus	Tule leviku kiirus
Põlevmaterjali paiknemine	Maastikutüüp (kallakud, kivisus), veekogud, taimestik	Tehislikud tõkked (teed), Maakasutus, Põlengute tõkestamine	Tule leviku füüsilised piirid
Põlevmaterjali hulk	Puud, põõsad, looduslikud häiringud (tuulemurd), aastaaeg, mulla viljakus	Karjatamine, metsaraie, istandused, põllumajandus, põlengute tõkestamine	Tulekahjude intensiivsus ja mõju keskkonnale
Niiskuse hulk põlevmaterjalis	Aastaaeg, sademed, suhteline õhuniiskus, temperatuur, mulla veesisaldus	Kliimamuutus, alepõllundus, taimestiku koosseis ja struktuur	Põlengu tekkimise tõenäosus ja selle ulatuslikkus
Süttimise põhjus	Välg, vulkanism	Rahvaarv, maahaldus, teedevõrk, kellaeg, aastaaeg,	Põlengute ajalisruumiline jaotus

Nagu eelnevalt mainitud, siis põlengud on olemuselt ajalisruumilised. Teadaolevalt on põlengute teke ja levik tugevas korrelatsioonis erinevate seda mõjutavate teguritega.

Olulisemad põlengu leviku kiirust mõjutavad meteoroloogilised komponendid on tuule kiirus, sademed ja õhuniiskus. Need mõjutavad lisaks lähtuvalt maakattetüübi iseärasustest rohkemal või vähemal määral biomassi kujunemist potentsiaalseks põlevmaterjaliks. Tulekliima pikema aja mõjusid seostatakse eelkõige sademete ja temperatuuride keskmiste näitajatega (Kiil, 2001).

1.4 Põlengute ennetamine ja vältimine

Metsapõlemistest saadakse teada mitmel erineval moel (Alton & Kiil 2003):

- Kõige sagedamini märkab seda juhuslik mööduja ja teavitatakse Päästeametit;
- Patrullimisel jalgsi või autodega;
- Satelliitidelt kogutud info põhjal;
- Patrull-lendude korraldamise tulemusena.

Eestis tegelevad inimeste tuleohuteadlikkuse tõstmisega Päästeamet ning Keskkonnaagentuur. Päästeamet määrab iga aasta umbes aprilli algusest kuni oktoobri lõpuni tuleohtliku aja tuleohutuse seaduse (TuOS) § 16 lõike 3 alusel. Selle alusel võib Päästeamet keelata (Tuleohutuse seadus 2020, § 16):

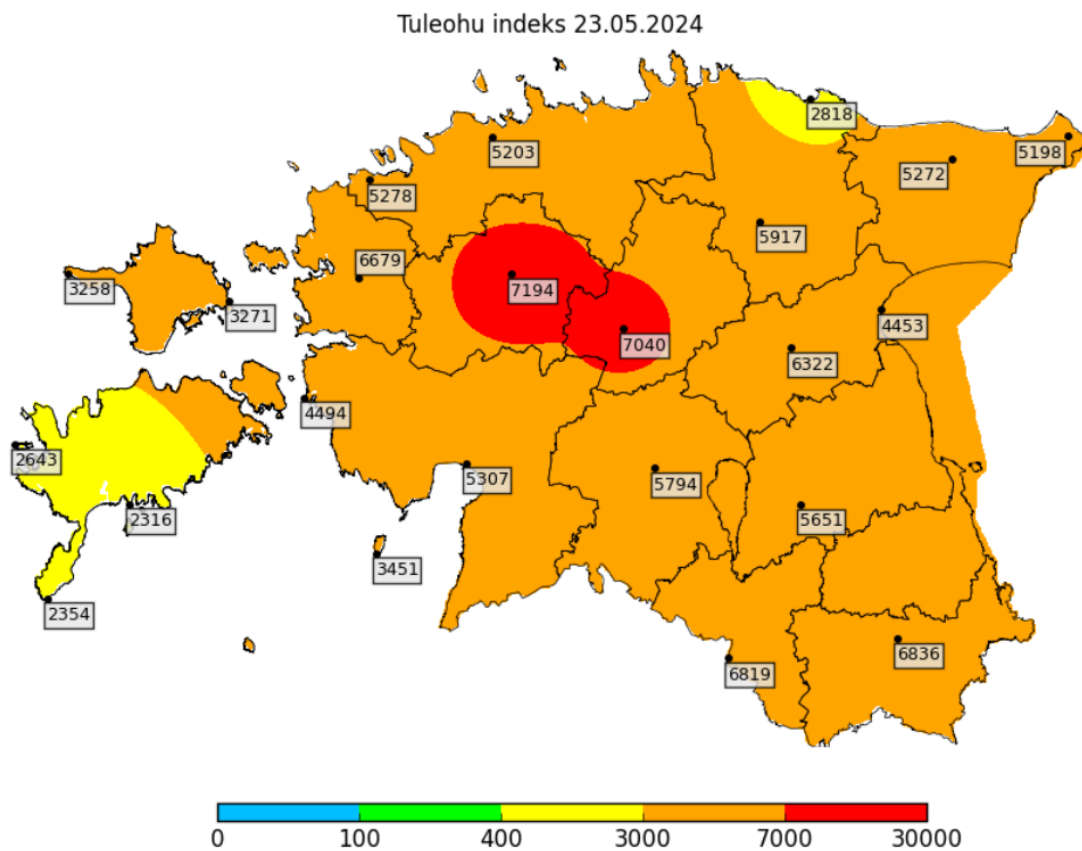
- küttekoldevälise tule tegemise;
- grillseadme kasutamise;
- suitsetamise;
- muu tegevuse, mis võib põhjustada tulekahju;
- viibimise, kui see võib ohustada inimese elu ja tervist.

Lisaks avaldab Keskkonnaagentuur oma Ilmateenistuse lehel iga päev uuendatud kujul tuleohukaart, mis põhineb Nesterovi tuleohuindeksi alusel ning kasutab valemit (Tammets & Kallis 2012)

$$I = \sum_{n=1}^N T_n (T_n - T_{dn})$$

kus I on tuleohu indeks, T_n on õhutemperatuur antud päeval kell 3, T_{dn} kastepunkti temperatuur päeval kell 3 kohaliku aja järgi, N kuivade päevade arv (*ibid.*). Antud tuleohu indeksit arvutatakse lumikatte kadumisest sügiste vihmaste ilmade saabumiseni, mis kattub

Päästeameti ametlike teadaannete korraldusega. Päästeameti metsa- ja maastikutulekahjude avaandmete alusel on süttimisohu kõige kõrgem just aprillis (42%), millele järgnevad mai (20%), juuni (10%), juuli (8%) ning august (5%) (Päästeamet, i.a). Kevadisel perioodil on tuleohu otseselt seotud kuluheina rohke leidmisega looduses, millele pole uus taimestik jõudnud peale kasvada (Alton & Kiil 2003).



Joonis 1. Näide tuleohukaardist. Tuleohu 23.05.2024 (Keskkonnaagentuur, 2024)

Eestis on täiendavalt jagatud puistud tuleohuklassidesse (Lisa 3). Reeglina on okasmetsad kõige ohtlikumad, kusjuures männikud on kuusikutest ohtlikumad. Selle põhjuseks on valguse ligipääs alustaimestikule, mis ei lase kergestisüttival alustaimestikul metsades kasvada. Seevastu võivad metsade tuleohuklassid periooditi muutuda - näiteks kevadel on kuiva kuluheinaga lehtmetsad oluliselt suurema tuleohtlikkusega pohla- või samblikumännikutest (Alton & Kiil 2003).

Regioonide kliimatiliste iseärasuste tõttu otsustatakse tuleohuindeksi kalkuleerimise meetodika üle riiklikul tasandil. Seetõttu hindavad sageli naaberriigid tuleohtu üksteisest erinevalt. Eesti naaberriikidest Soomes on kasutusel 1995. aastal välja töötatud Soome tuleohuindeks (Finnish Fire Index - FFI) (Vajda et al., 2014), Rootsis Kanada tuleohuindeks (Pagnon Eriksson & Johansson, 2020). Eestil endal on kasutuses aga 1949. aastal välja töötatud Nesterovi indeks (Oja et al., 2020) sarnaselt Venemaaga (Standartinform, 2000, viidatud Ostapenko et al., 2019 kaudu).

Euroopa Liidu metsatulekahjude avastamise ja tuleohu ennustamise portaali EFFIS (*European Forest Fire Information System*) kasutab Kanada tuleohuindeksit (FWI). See matemaatiline lähenemine tulekahjude ennetamiseks on kogumas populaarsust nii Euroopas kui mujal maailmas (Oja et al., 2020). Riigid otsivad oma vajadustest lähtuvalt võimalusi olemasolevate ennetusmeetodite täpsuse tõstmiseks. Seetõttu kuvatakse EFFISi kodulehel ka austraallaste McArthuri Mark-5 metsade (*Forest Fire Danger Index - FFDI*), Ameerika riikliku tuleohu määra (*National Fire-Danger Rating System - NFDRS*) indekseid ja ameeriklaste Keetch-Byrami põuaindeksit (EFFIS, i.a). FWI'd on laialdaselt ka kasutusel Ameerika Ühendriikides, Kanadas, Mehhikos, Indoneesias, Malaisias, Portugalis, Uus-Meremaal ja mujal (Amiro et al., 2004).

Mõned suurriigid kasutavad kõrvuti mitmeid erinevaid ennetusmeetmeid ning vastavalt vajadusele seovad neid. Seda näiteks nagu eelnevalt välja toodud Ühendriikides NFDRS ja FWI puhul, kus FWI on kasutusel Alaskal hõredama (vähem meteoroloogilisi andmeid) ning NFDRS tihedama asustusega aladel (Ziel et al., 2020). Hiinas on kasutusel ja testimisel bioloogiliste, maastikuliste ja kliimatiliste erinevuste tõttu palju mitmesuguseid tuleohu ennetamise viise (tuntumatest FFDI, NFDRS, FWI), mille sisendeid ja arvutuskäike korrigeeritakse kohalikele tingimustele sobivaks (Li et al., 2014).

Näiteks viisid Constantino *et al.* (2018) läbi 2018. aastal statistilise analüüsi, mille käigus võrdlesid kaheksa tuleohu indeksi tulemusi põlengu ennetamisel Itaalias Sardiinias. Aluseks võeti 2000-2007 aset leidnud põlengute aeg-ruumilised andmed, mida võrreldi indeksite prognoosivate tulemustega.

Nendeks olid (*ibid.*):

1. Kanada tuleohuindeks (Canadian FWI);

2. Keetch-Byrami põuaindeks (KBDI);
3. McArthuri Mark 5 metsade (FFDI) ja Mark 4 rohtlate tuleohuindeks (GFDI);
4. Fosbergi tuleohuindeks (FFWI);
5. Sharplesi tuleohuindeks (F);
6. Nesterovi tuleohuindeks;
7. Paljundusindeks (IPi);
8. Integreeritud tuleohuindeks (IFI).

Teostati Spearmani korrelatsioonanalüüs. Selle tulemusel saadi teada, et parima tulemuse saavutas IFI indeks, mis on välja töötatud spetsiaalselt Sardiinia jaoks. Teisele kohale jäi Kanada tuleohuindeks. Peale IFI ei vajanud teised arvutusmudelid põlevmaterjali struktuuri ja sisalduva niiskuse sisendit, mida võib pidada tulemuste erinevuse üheks põhjuseks. Süttimisohu ennetamisega tuli peaaegu sama edukalt toime ka Kanada tuleohuindeks, mis samuti võttis arvesse arvutuste tegemisel põlevmaterjali omadusi. Enamus teistest tuleohu ennetamiseks mõeldud kalkulatsioonid põhinesid ainult meteoroloogiliste tegurite arvesse võtmisele (*ibid.*). Siit tuleb välja, et kindlale regioonile välja töötatud matemaatiliselt lihtsam tuleohuindeks võib olla parema tulemuslikkusega keerulisematest indeksitest (Lisa 1). Samas ei ole mõistlik tugineda ainult meteoroloogiliste tegurite arvesse võtmisele kui olukorda reaalsuses mõjutavaid elemente on rohkem.

2. Materjal ja metoodika

Sissejuhatuses eelnevalt kirjeldatuna püstitati töö eesmärgiks arvutada Keskkonnaagentuuri vaatlusjaamade võrgustiku andmed metsa- ja maastikupõlengu koordinaatidele aastatel 2014-2022. Arvestades vaatlusjaamade võrgustiku suurust ning töötlemist vajava andmehulga mahtu loodi Pythoni programmeerimiskeele abil programm, millega oleks võimalik interpoleerida vajaminevatele koordinaatidele meteoroloogilised vaatlusandmed põlengule eelnenud 1 kuni 30 päeva jooksul. Arvutamiseks vajalike toorandmete kogumise ja ettevalmistamise etapid ning viimaks ka programmi ülesehitus on välja toodud järgnevates alapeatükkides.

2.1 Metsa- ja maastikupõlengute andmed

Uuritavad metsa- ja maastikutulekahjude andmed pärinevad aastatest 2014-2022. Need on .csv vormingus kõigile avalikult kättesaadavad Päästeameti kodulehelt (<https://www.rescue.ee/et/juhend/avaandmed>) “Metsa- ja maastikutulekahjud” kategooria alt. Avaandmetega on kaasas ka “Metsa- ja maastikutulekahjude avaandmete seletuskiri”, mis hõlmab andmebaasi kirjete elemente, kirjeldusi ja tüüpe. 2024. aasta seisuga on olemas põlengute andmed aastatest 2014-2023 ning eraldi failina jooksva aasta andmed, mida uuendatakse kord ööpäevas. Jooksva aasta andmed liidetakse 2014 kuni eelmise aasta andmefaili andmetega aasta lõppedes (Heinoja, 2022).

Oluline on märkida, et Päästeameti metsa- ja maastikutulekahjude andmed erinevad riiklikust ning tegemist on seepärast ametkondliku statistikaga. Probleem seisneb metsaseadusest tulevas keerulises definitsioonis ning tööprotsesside käigus on keeruline jõuda järeltule, milline tulekahjus toimus nüüd metsas ja milline maastikul (*ibid.*).

Orr (2023) tõi oma töös välja, et suuremate põlengute puhul saab ETAK andmestiku abil eristada umbes 85% maastikupõlenguid metsade omadest, kuid eristatavus väheneb “Pääste 1” ja “1A” kirjega põlengute kaasamisel. ETAKi andmekirjete vastavuse osakaal puhaste metsapõlengute puhul jäi Päästeameti andmetega võrreldes 55% juurde. Põhjuseid tõi ta välja mitmeid. Ühelt poolt on talletatud põlengu koordinaadid WGS84 koordinaatsüsteemis tuhandiku täpsusega, mis teeb Eestis asukoha veaks kuni 60 meetrit. Teiseks on tõenäoliselt päästjate poolt registreeritud juhtumi asukoht tegeliku põlengu servaala. Olukorda mõjutab

seegi, et lähenetakse on mööda juurdepääsuteed. Neljandaks on ETAK piirkonna kõlvikumääratlus sageli maastikutüübi muutumise tõttu vananenud.

Andmetes kajastatavad elemendid on järgnevad (Heinoja, 2022):


- Sündmuse number - sündmuse unikaalne tunnus (bigint);
- Sündmuse kuupäev (toimumise kuupäev (date));
- Tulekahju liik - kõigil märgitud “metsa- ja maastikupõleng” (text);
- Sündmuse alamliik (kuni 25.05.2021) - menetlejapoolne märkus eristamaks peamiselt maastiku- ja kulupõlenguid (text);
- WGS laius- ja pikkuskraad. Täpsusaste on tuhandikes, koordinaatsüsteem WGS84. Asukohatäpsus on Eestis sellest tulenevalt kuni 60 meetrit (double precision).
- Maakond ja kohalik omavalitsus - tulekahju maakonna ja valla/linna nimetused (text);
- Sündmuse kõrgeim aste - sündmuse keerukuse ja suuruse aste selle tipphetkel, kus “Pääste 1” on kõige madalam ja “Pääste 4” kõige kõrgem (text);
- Häirekeskuses registreerimine, esimene alarmeerimine, väljasõit, esmane kohalejõudmise aeg, tulekahju lokaliseerimise aeg, tulekahju likvideerimise aeg, viimase ressursi lahkumise aeg - kirjeldavad kõik erinevate väljakutse etappide ajalisi kirjeid (timestamp without time zone);
- Sündmuse kestvus - valem on (viimase ressursi lahkumise aeg - häirekeskuses registreerimine) (text) ;
- Väljasõiduks antud korralduste arv (kuni 25.05.2021), tegelikult väljasõitnud ressurside arv, annulleeritud ressurside arv (kuni 25.05.2021), kohal ressurside arv - sisaldavad suurusjärgulisi kirjeid väljakutsel osalenud ressurside kohta (integer);
- Kulu põlemise olemasolu - valikuvariandid “Ei” või “Jah” (text);
- Metsa ja maastiku põlenud pind ruutmeetrites (alates 25.05.2021 - ühikud ruutmeetrites (integer);

2014-2022 perioodil on Päästeameti avaandmetes registreeritud 10130 metsa- ja maastikutulekahju. Andmete üldise mahukuse, vaatlusjaamade ebaühtlase paiknemise, andmete aegrea lünklikkuse ja programmi arvutusaegade tõttu tuli seada mõningad piirangud uuritavate põlengute hulga kohta.

Kokkuleppeliselt kaasati antud töösse ainult need põlengud, mis jäid piirkondadesse, kus rahvastikuregistri 1km x 1km ruutkaardi ruudul elas andmete järgi vähem kui 22 inimest. Ruumiandmete kogumiseks ja töötlemiseks kasutati QGIS 3.30.1 versiooni. Antud arvu suurusjärk on sarnane Eestis hõredamalt asustatud alevike keskmise rahvastikutihedusega. Kuna andmed uuenevad kord aastas, siis kasutati 2018. aasta rahvastiku andmeid, mis jäävad uuritava perioodi keskmesse. Andmed on kogutud elanike sissekirjutuste georeferentseerimisel hoone täpsusega, kus ruutudesse agregeerimisel võeti aluseks hoone tsentroid. Kui andmeid polnud võimalik seostada hoonega (näiteks kodutute puhul), siis lisati väärtused loendusjaoskonna keskele. Kasutatud andmekihi koordinaatsüsteem on WGS84, mis ühtis Päästeameti metsa- ja maastikupõlengute koordinaatsüsteemiga. Alla nelja elanikuga ruutudes (andmetabelis sõne “<4”) on tähistatud elanike arv nulliga (Statistikaamet, 2021).

Käesolevas töös kasutatud andmed on alla laetud Statistikaameti kaardirakendusest, mis 30. juuni 2023. aasta seisuga suleti. Hiljem on võimalik Statistikaametist ruumiandmeid tellida kirjutades selleks avalduse (Statistikaamet, 2023).

Veelgi piiratakse põlengute valimit kaasates arvutustesse ainult mandri Eestis toimunud metsa- ja maastikupõlenguid, mis leidsid aset aprillist oktoobrini. Paljudes Keskkonnaagentuuri tugivõrgu vaatlusjaamades pole piisavalt suurel hulgal andmeid uurimaks sellest perioodist välja jäävaid juhtumeid. Lisaks võib aprillikuu alguse kalkulatsioonideks vaja minna märtsi alguses kogutud andmeid kui hilisem kasutaja soovib arvesse võtta tervet kuud. Lõpetuseks ei võta arvesse programmis kasutatav ruumilise interpoleerimise meetod Läänemerest tingitud kliimaatilisi mõjusid kui kasutada saartel toimunud põlengute jaoks mandri Eesti vaatlusjaamade näitusid. Nendest piirangutest lähtuvalt arvutatakse antud töös 3429 metsa- ja maastikupõlengu andmed (vt. Joonis 2).



Joonis 2. Töösse kaasatud 3429 metsa- ja maastikupõlengu paiknemine. Punaste kolmnurkadega on tähistatud põlengud.

Programmi sisestavate metsa- ja maastikupõlengute failis on esindatud järgnevad veerud (järjekord ei pea olema sama, aga kõik veerud peavad olema esindatud):

- Põlengu toimumise aasta - Aasta (integer);
- Põlengu kuu- Kuu (integer);
- Põlengu päev - Päev (integer);
- Põlengu alguse kellaaeg - Kell (UTC). Alguses sõne, programm teisaldab arvuks (integer). Võetud arvutamiseks Päästeameti esimese alarmeerimise kellaaeg ja teisaldatud lähima täistunnini;
- Põlengu laiuskraad (WGS84) - Poleng_lat. Tuhandiku täpsusega, aga programm võtab vajadusel rohkem komakohti arvesse (double);
- Põlengu pikkuskraad (WGS84) - Poleng_lon. Tuhandiku täpsusega, aga programm võtab vajadusel rohkem komakohti arvesse (double);
- Sündmuse number - Sundmuse_n. Sündmuse unikaalne registreeritud number Päästeametis. Sellega saab analüütik hiljem lamedaid andmetabeleid juhtumite põhiselt omavahel siduda (integer).


2.2 Meteoroloogiliste andmete töötlemine

Kõik andmed on vaja üle viia programmi jaoks ühtsele standardile, et nendega saaks ridade ja veergude kaupa vajalikke kalkulatsioone teostada:

1. Iga vaatlusjaam peab olema eraldi .csv failis, kus veergude eraldajateks on koma;
2. Iga vaatlusjaama lähteandmete fail sisaldab ainult eelneva alapeatüki lõpus välja toodud veergusid;
3. Kõikides failides on olemas igal real vaatlusjaama pikkus- ja laiuskraad (soovitavalt WGS84 koordinaatsüsteemis);
4. Vaatlusjaamade lugemite read on tunnipõhised ning sisaldavad kõiki tunde märtsist oktoobri lõpuni;
5. Vaatlusjaama andmete lugemist alustatakse teiselt realt, kus esimene lugem on tehtud vastavalt 1. märts 2014 aastal südaööl kell 12 ning viimane 31. oktoobril 2014 kell 23:00. Vaatlused liiguvad ühe tunniste sammudega. Järgmise aasta vaatlusperiood on samuti kuupõhiselt samades vahemikes. Programm on kirjutatud kalkuleerima aastaid 2014-2022. Ridasisid peab lähtefailis kokku olema 52921 (52920 vaatlust). Kui ridasisid on vähem, siis on aegreast mõni tund puudu. Kui puuduoleva rea tunni andmeid läheb tarvis ning vajamineva aasta, kuu, päeva ja kellaga rida ei leita, lõpetab programm töö;
6. Juhul kui kalkuleeritaval tunnil andmed puuduvad, jätta andmete ettevalmistamisel lahter tühjaks. Seda tõlgendatakse kui andmete puudumist;
7. Märkikodeeringu standard peaks failidel olema täpitahtede tõttu *UTF-8*. Programm ei suuda faile ilma selleta üldjuhul lugeda;
8. Faili nimi peab ühtima "stationname" veeruga programmis (näiteks Korela hüdroomeetriaajaama nimi on failis Korela.csv). Sellega kontrollitakse, et mitu korda üht ja sama faili sisse ei loeta;
9. Programmi väljundfailis on liidetud üksteisele põlengu failide veerud "Aasta", "Kuu", "Päev", "Kell (UTC)", "Poleng_long", "Poleng_lat", "Sundmuse_n" koos jaamadest interpoleeritud asjakohaste andmetega. Asjakohastele andmetele väljundfailides lisatud veerud tuuakse iga järgneva alapeatüki juures välja.

2.2.1 Temperatuur

Kõikide jaamade koordinaadid ja nende otstarve on leitavad Keskkonnagaentoori meteoroloogilise seire allprogrammist. Temperatuuride interpoleerimiseks kaasati 33 vaatlusjaama üle Eesti (vt. Joonis 3). Üldiselt võib temperatuuri mõõtvate jaamade katvust Eestis interpoleerimise tarbeks pidada heaks. Andmete aegrida on jaamades võrdlemisi püsiv, mõõteriistade täpsus on 0.1 °C. Eraldi tuleb välja tuua Mõntu, kus puudub terviklikult 2018. aasta ning aegridade hulk failis on märgatavalt lühem (Keskkonnagaentoor, 2019).



Joonis 3. Kasutatud vaatlusjaamad temperatuuride jaoks. Punaste kolmnurkadega on tähistatud põlengud, kollased rombid on temperatuuride vaatlusjaamad.

Temperatuuride jaoks mõeldud sisendfailides kajastatavad veerud on järgnevad:

- Vaatluse toimumise aasta - Aasta (integer);
- Vaatluse kuu - Kuu (integer);
- Vaatluse päev - Päev (integer);
- Vaatluse kellaeg - Kell (UTC). Alguses sõne, programm teisaldab arvuks (integer);
- Täistunnil mõõdetud õhutemperatuur - Õhutemperatuur °C (float);

- Viimase tunni jooksul mõõdetud miinimumtemperatuur - Tunni miinimum õhutemperatuur °C (float);
- Tunni jooksul mõõdetud maksimumtemperatuur - Tunni maksimum õhutemperatuur °C (float);
- Jaama nimi - stationname (text);
- Jaama pikkuskraad Wgs84 süsteemis - station.longitude (double);
- Jaama pikkuskraad Wgs84 süsteemis - station.latitude (double).

Ning väljundfailis on eelnevalt mainitud põlengu failide veergudele juurde liidetud:

- “Eelneva [kasutaja sisestatud päevade arvu] keskmine temperatuur. Lubatud puudujääk [kasutaja sisestatud arv]%. Tuletamisel kasutatud [kasutaja sisestatud päevade arvu] jaama.” - jutumärkides on kogu veeru pealkiri (double);
- “Eelneva 1 päeva keskmine kõrgeima ja madalaima temperatuuri vahe. Lubatud puudujääk [kasutaja sisestatud arv]%. Tuletamisel kasutatud [kasutaja sisestatud päevade arvu] jaama.” - Tuletamisel kasutatud [kasutaja sisestatud päevade arvu] jaama.” - jutumärkides on kogu veeru pealkiri (double);
- “Puuduvate andmete protsent” - puuduolevate andmete hulk, mida keskmistati. Jääb alla kasutaja sisestatud protsendi väärtuse (float);
- “Jaamade keskmine kaugus” - kasutaja sisestatud jaamade kaugus põlengust kilomeetrites (float);
- “Lähima jaama kaugus” - programmi valitud lähima jaama kaugus;
- “Viimase tunni väärtus” - põlengule eelnenud viimase tunni keskmine temperatuuri väärtus vaatlusjaamadest arvutatuna. Kui andmed viimasest tunnist puuduvad, jääb tühjaks (double).

2.2.2 Sademed

Sademe suure aegruumilise varieeruvuse tõttu võeti lisaks peamistele sademeid mõõtvatele jaamadele ka täiendavalt kasutusele hüdromeetriaajaamades mõõdetud sademete näidud (vt. Joonis 4), mis saadi Keskkonnaagentuuri suletud andmekogust. Ühtekokku kasutati siinkohal 68 vaatlusjaama. Kuigi vaatlusjaamade võrgustik on siinkohal kõige tihedam, on vaatlusandmete perioodiline puudujääk eriti tugijaamades perioodiliselt kõige kõrgem. Kuna


- Jaama pikkuskraad Wgs84 süsteemis - station.longitude (double).
- Jaama pikkuskraad Wgs84 süsteemis - station.latitude (double);

Ning väljundfailis on eelnevalt mainitud põlengu failide veergudele juurde liidetud:

- “Eelneva [kasutaja sisestatud päevade arvu] keskmine sademete summa. Lubatud puudujääk [kasutaja sisestatud arv]%. Tuletamisel kasutatud [kasutaja sisestatud päevade arvu] jaama.” - jutumärkides on kogu veeru pealkiri (double);
- “Eelneva [kasutaja sisestatud päevade arvu] päeva kuivade päevade arv. Lubatud puudujääk [kasutaja sisestatud arv]%. [kasutaja sisestatud päevade arvu]” - jutumärkides on kogu veeru pealkiri (double);
- “Eelneva [kasutaja sisestatud päevade arvu] päeva märgade päevade arv. Lubatud puudujääk [kasutaja sisestatud arv]%. [kasutaja sisestatud päevade arvu] jaama” - jutumärkides on kogu veeru pealkiri (double);
- Eelneva [kasutaja sisestatud päevade arvu] päeva kõige pikem märgade päevade jada. Lubatud puudujääk [kasutaja sisestatud arv]%;
- “Puuduvate andmete protsent” - puuduolevate andmete hulk, mida keskmistati. Jääb alla kasutaja sisestatud protsendi väärtuse (float);
- “Jaamade keskmine kaugus” - kasutaja sisestatud jaamade kaugus põlengust kilomeetrites (float);
- “Lähima jaama kaugus” - programmi valitud lähima jaama kaugus;
- “Viimase tunni väärtus” - põlengule eelnenud viimase tunni keskmine sademete summa väärtus vaatlusjaamadest arvutatuna. Kui andmed viimasest tunnist puuduvad, jääb tühjaks (double).

2.2.3 Õhuniiskus

Õhuniiskuse andmete arvutamise jaoks kasutati 26 jaama (vt. Joonis 5) ning töös kasutatud seiratud parameetriks oli suhteline õhuniiskus. Mõõtmismeetod on anduriga, sagedus üks kord iga tunni järel. Täpsusaste on mõõtmistel 1% (Keskkonnaagentuur, 2019).



Joonis 5. Kasutatud vaatlusjaamad õhuniiskuse jaoks. Vaatlusjaamad on sinised ringid, punased kolmnurgad tähistavad antud töösse kaasatud põlenguid.

Õhuniiskuse jaoks mõeldud sisendfailides kajastatavad veerud on järgnevad:

- Vaatluse toimumise aasta - Aasta (integer);
- Vaatluse kuu- Kuu (integer);
- Vaatluse päev - Päev (integer);
- Vaatluse kellaaeg - Kell (UTC). Alguses sõne, programm teisaldab arvuks (integer);
- Täistunnil mõõdetud suhteline õhuniiskus - Suhteline õhuniiskus % (double);
- Jaama nimi - stationname (text);
- Jaama pikkuskraad Wgs84 süsteemis - station.longitude (double);
- Jaama laiuskraad Wgs84 süsteemis - station.latitude (double).


Ning väljundfailis on eelnevalt mainitud põlengu failide veergudele juurde liidetud:

- “Eelneva [kasutaja sisestatud päevade arvu] keskmine suhteline õhuniiskus. Lubatud puudujääk [kasutaja sisestatud arv]%. Tuletamisel kasutatud [kasutaja sisestatud päevade arvu] jaama.” - jutumärkides on kogu veeru pealkiri (double);

- “Puuduvate andmete protsent” - puuduolevate andmete hulk, mida keskmistati. Jääb alla kasutaja sisestatud protsendi väärtuse (float);
- “Jaamade keskmine kaugus” - kasutaja sisestatud jaamade kaugus põlengust kilomeetrites (float);
- “Lähima jaama kaugus” - programmi valitud lähima jaama kaugus;
- “Viimase tunni väärtus” - põlengule eelnenud viimase tunni keskmine õhuniiskuse väärtus vaatlusjaamadest arvatuna. Kui andmed viimasest tunnist puuduvad, jääb tühjaks (double).

2.2.4 Päikesekiirgus

Päikesekiirguse andmete arvutamisel kasutatakse 8 vaatlusjaama seiratud parameetreid ning arvesse võetakse ainult summaarne kiirgus. Andmete olemasolu aastate lõikes on kõikides jaamades hea. Summaarne kiirgus on kogu tunni jooksul anduri pinnale langenud kiirgus W/m^2 ühikutes ning mõõtmistäpsus on $1W/m^2$ (Keskkonnaagentuur, 2019). Osadel tulpadel on mõõdetud tunni summaarseks kiirguseks nulli asemel -1. Keskkonnaagentuuri peaspetsialist Epp Juust kommenteeris nähtust nõnda: *“Õiseid negatiivseid väärtuseid nimetatakse zero offset’ks, ehk summaarse kiirguse mõõtmisel võib esineda püranomeetris tehislikku kiirguse (zero offset) registreerimist öistel kellaaegadel. Nähtus tekib, kui anduri temperatuuri kõikumistest tekkinud soojuse liikumine (tingitud temperatuuride vahest anduri sees ja selle kohal olevas õhukihis) põhjustab tundlikus elemendis tehislikku kiirgust, mille tõttu registreerib andur väikeseid positiivseid või negatiivseid väärtuseid”*. Seetõttu oleks soovitatav need väärtused teisaldada andmete töötlemisel nulliks.



Joonis 6. Kasutatud vaatlusjaamad päikesekiirguse jaoks. Kiirguse vaatlusjaamad on kollased ringid, punased kolmnurgad tähistavad põlenguid.

Päikesekiirguse jaoks mõeldud sisendfailides kajastatavad veerud on järgnevad:

- Vaatluse toimumise aasta - Aasta (integer);
- Vaatluse kuu- Kuu (integer);
- Vaatluse päev - Päev (integer);
- Vaatluse kellaeg - Kell (UTC). Alguses sõne, programm teisaldab arvuks (integer);
- Tunni keskmine summaarne kiirgus W/m^2 - Tunni jooksul mõõdetud päikesekiirguse koguhulk (int);
- Jaama nimi - stationname (text);
- Jaama pikkuskraad Wgs84 süsteemis - station.longitude (double);
- Jaama pikkuskraad Wgs84 süsteemis - station.latitude (double).

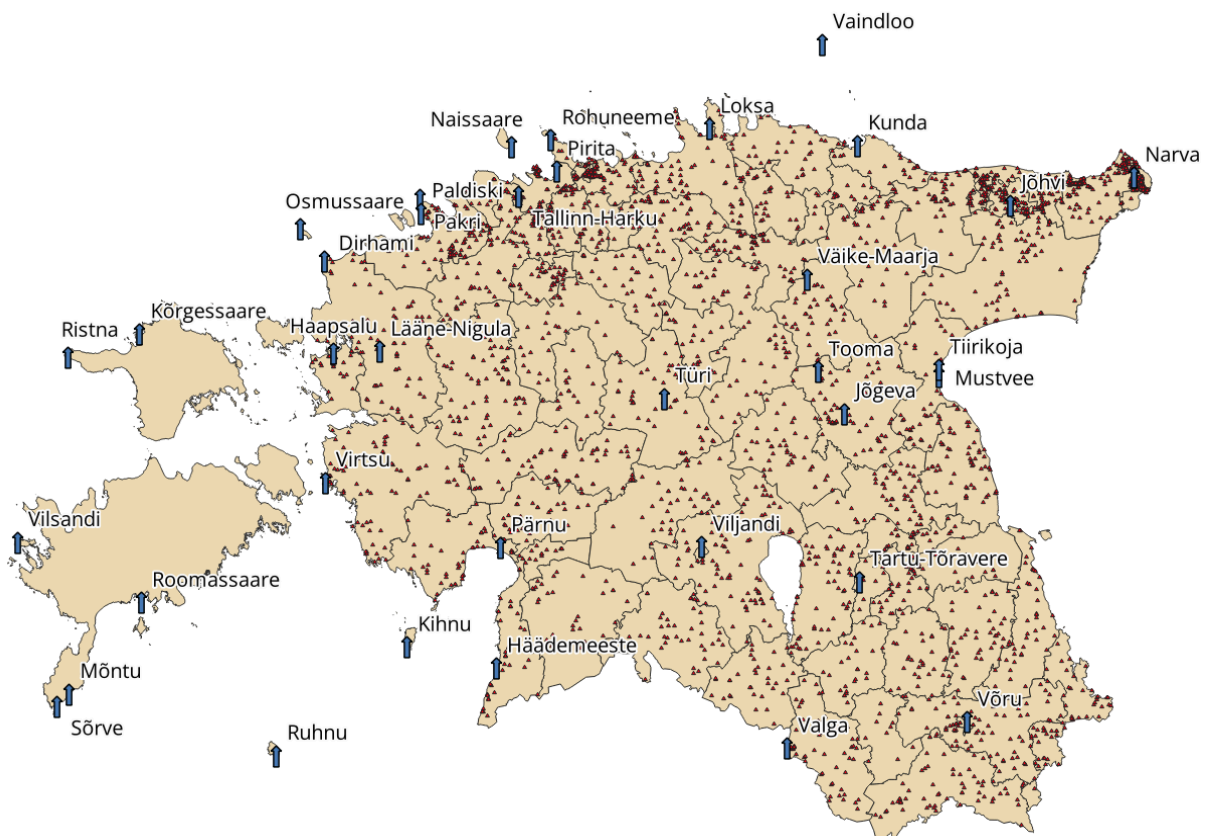
Ning väljundfailis on eelnevalt mainitud põlengu failide veergudele juurde liidetud:

- “Eelneva [kasutaja sisestatud päevade arvu] summaarne kiirgus.. Lubatud puudujääk [kasutaja sisestatud arv]%. Tuletamisel kasutatud [kasutaja sisestatud päevade arvu] jaama.” - jutumärkides on kogu veeru pealkiri (double);

- “Puuduvate andmete protsent” - puuduolevate andmete hulk, mida keskmistati. Jäeb alla kasutaja sisestatud protsendi väärtuse (float);
- “Jaamade keskmine kaugus” - kasutaja sisestatud jaamade kaugus põlengust kilomeetrites (float);
- “Lähima jaama kaugus” - programmi valitud lähima jaama kaugus;
- “Viimase tunni väärtus” - põlengule eelnenud viimase tunni summaarne kiirguse väärtus vaatlusjaamadest arvatuna. Kui andmed viimasest tunnist puuduvad, jääb tühjaks (double).

2.2.5 Keskmine tuule kiirus

Keskmise tuule kiiruse arvutamiseks on töös kaasatud 37 vaatlusjaama (Joonis 7). Andmete aegread on eriti saarte vaatlusjaamades väga puudulikud. Tuule kiiruse mõõtmiseks kasutatakse vaatlusjaamades anemomeetrit või akustilist tuulesensorit. Mõõtühikud on m/s ning täpsus 0.1 m/s (Keskkonnaagentuur, 2019).



Joonis 7. Kasutatud vaatlusjaamad keskmise tuule kiirguse jaoks. Vaatlusjaamad on sinised nooled, punased kolmnurgad tähistavad antud töösse kaasatud põlenguid.

Tuule kiiruse jaoks mõeldud sisendfailides kajastatavad veerud on järgnevad:

- Vaatluse toimumise aasta - Aasta (integer);
- Vaatluse kuu- Kuu (integer);
- Vaatluse päev - Päev (integer);
- Vaatluse kellaaeg - Kell (UTC). Alguses sõne, programm teisaldab arvuks (integer);
- 10 minuti keskmine tuule kiirus m/s - 10 minuti jooksul mõõdetud tuule kiirus (double);
- Jaama nimi - stationname (text);
- Jaama pikkuskraad Wgs84 süsteemis - station.longitude (double);
- Jaama pikkuskraad Wgs84 süsteemis - station.latitude (double).

Ning väljundfailis on eelnevalt mainitud põlengu failide veergudele juurde liidetud:

- “Eelneva [kasutaja sisestatud päevade arvu] tuule kiirus. Lubatud puudujääk [kasutaja sisestatud arv]%. Tuletamisel kasutatud [kasutaja sisestatud päevade arvu] jaama.” - jutumärkides on kogu veeru pealkiri (double);
- “Puuduvate andmete protsent” - puuduolevate andmete hulk, mida keskmistati. Jääb alla kasutaja sisestatud protsendi väärtuse (float);
- “Jaamade keskmine kaugus” - kasutaja sisestatud jaamade kaugus põlengust kilomeetrites (float);
- “Lähima jaama kaugus” - Programmi valitud lähima jaama kaugus;
- “Viimase tunni väärtus” - põlengule eelnenud viimase tunni summaarne kiirguse väärtus vaatlusjaamadest arvutatuna. Kui andmed viimasest tunnist puuduvad, jääb tühjaks (double).

2.3 Programmi kirjeldus ja struktuur

Programmi tööstruktuuri elemendid on välja toodud joonisel 8 ning see peab suutma lahendada oma töövooga järgnevaid probleeme:

1. Suutma muuta ja lugeda olemasolevaid faile eelnevas alapeatükis kehtestatud reeglite järgi;
2. Leiab ise üles Pythoni arenduskeskkonda paigutatud failid ja kaustad
3. Kõigib kasutajalt järgnevaid sisendeid:

- a. Mida kalkuleeritakse (Temperatuur, Sademed, Õhuniiskus, Päikesekiirgus, Keskmine tuule kiirus);
 - b. Kaasatavate jaamade arvu;
 - c. Lubatud protsenti puuduolevaid andmeid kaasatud jaamades;
 - d. Suutma interpoleerida 1-30 päevase ajavahemiku ulatuses põlengutele vaatlusandmeid;
 - e. Küsib muumisele kuuluva faili nime.
4. Leidma põlengule lähimad vajalikud jaamad;
 5. Lähtuvalt punkti 3c ülesandest välja vahetama kaasatavat jaama järgmise vastu kui puuduolevate andmete künnis ületab kasutaja lubatud määra. Puuduolevatele tundidele arvutatakse ülejäänud olemasolevate andmete perioodi keskmine väärtus;
 6. Arvutama interpoleerimiseks mõeldud IDW valemiga jaamade perioodide väärtused edasi põlengu koordinaatidele.

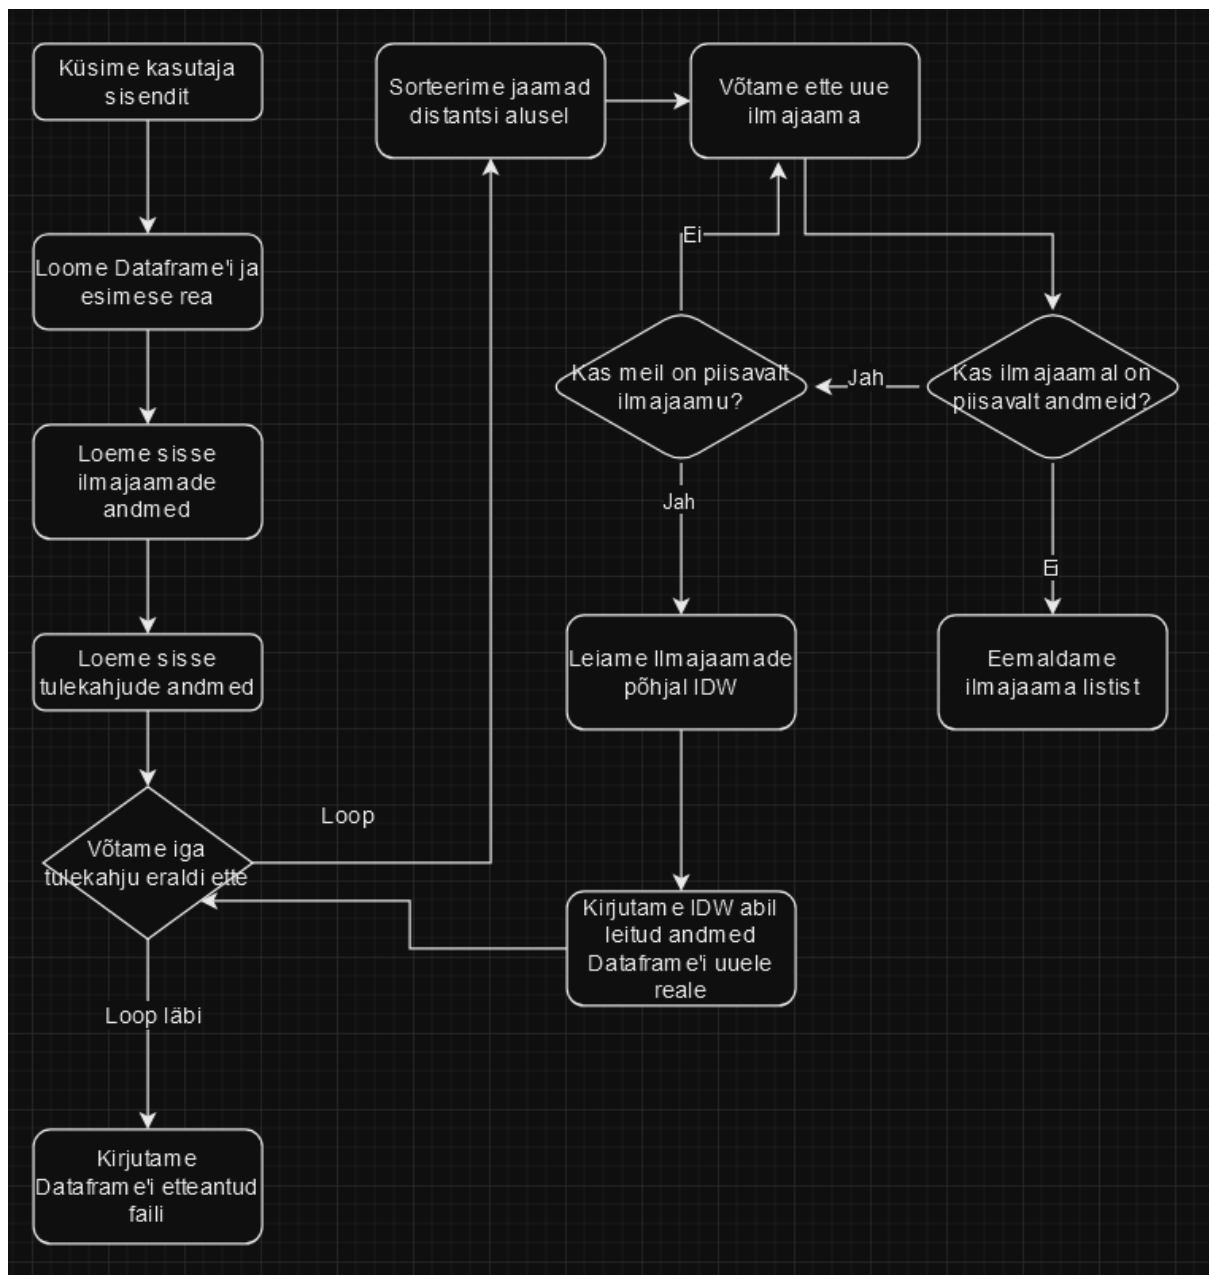
Programmis rakendatav IDW on matemaatiliselt lihtne deterministlik interpoleerimise meetod, mis kasutab valemit

$$Z = \frac{\sum_i^n \left(\frac{z_i}{d_i^\beta} \right)}{\sum_i^n \left(\frac{z_i}{d_i^\beta} \right)},$$

kus Z on interpoleeritav väärtus, n kaasatavate jaamade arv, z_i interpoleerimisele kuuluv väärtus vaatlusjaamas ja d_i kaugus põlengu ja vaatlusjaama vahel. β on aga aste, mis määrab kui suur mõju on kõige lähemal asuvatel jaamadel põlengute punktide väärtustele. Üldjuhul on selle väärtus 2. Kui väärtus oleks 1, siis oleks lähemal asuvatel jaamadel väiksem mõju põlengute väärtustele (GISGeography, 2016).

Valemist on näha, et kalkuleerimisel on oluline mõju ainult vaatlusjaama kaugusel põlengu punktist. Seetõttu on eelistatav, et vaatlusjaamad asuksid põlengute punktidele lähemal täpsemate väärtuste saamiseks. Interpoleeritud tulemusi mõjutab ka peale ilmastiku ümbritsev keskkond. Kuna antud interpoleerimise meetod on deterministlik, poleks mõistlik arvutada saartel asuvaid tundmatuid väärtusi Võru ja Tartu vaatlusandmete järgi. Seetõttu ei arvestata

antud töös saartel toimunud põlenguid, kuna tulemused oleksid ebatäpsed. Lisaks on saartel asuvates vaatlusjaamades andmetes suured lüngad (Gentile et al., 2012).



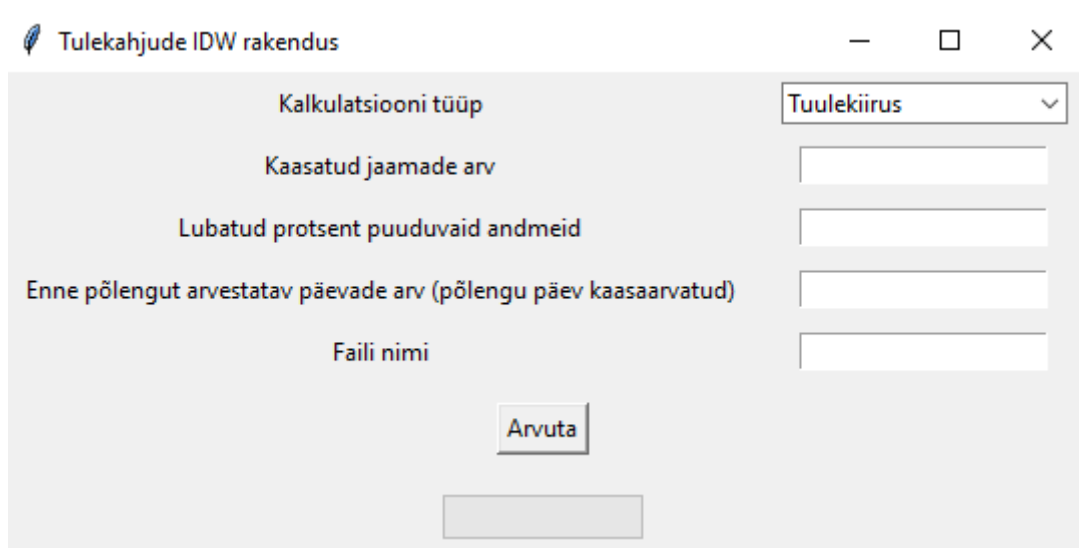
Joonis 8. IDW programmi tööstruktuur.

3. Tulemused ja arutelu

3.1 IDW programm

Töö tulemusena valmis meteoroloogiliste andmete interpoleerimise programm (Lisa 4), mis vastab eelnevas peatükis kehtestatud eesmärkidele. Kommentaarid rakenduse tööst on lisatud #-tähistega koodi juurde ning on osaks dokumentatsioonist. Seetõttu rakenduse tehnilist osa siin lahti ei selgitata.

Programmi käivitamisel avaneb Tkinter mooduli abil lihtne kasutajaliides koos laadimisribaga (Joonis 7). Kõikidesse tühjadesse lahtritesse peale “Faili nimi” tuleb lisada täisarvuline väärtus. Lahtrisse kirjutatav fail peab sisaldama vajaminevat informatsiooni põlengute kohta. “Arvuta” nupu vajutamisel käivitub programm ja töö edenemist näitab selle all olev rohelisteks muutuv laadimisriba.



The screenshot shows a graphical user interface for the IDW application. The window title is "Tulekahjude IDW rakendus". The interface includes the following elements:

- Kalkulatsiooni tüüp:** A dropdown menu currently set to "Tuulekiirus".
- Kaasatud jaamade arv:** An empty text input field.
- Lubatud protsent puuduvaid andmeid:** An empty text input field.
- Enne põlengut arvestatav päevade arv (põlengu päev kaasaarvatud):** An empty text input field.
- Faili nimi:** An empty text input field.
- Arvuta:** A button to initiate the calculation.
- Progress bar:** A horizontal bar at the bottom, currently empty, used to show the progress of the calculation.

Joonis 7. IDW programmi kasutajaliides.

Programmi paremaks muutmiseks on veel võimalusi. Hetkel võtab rohkem kui kolme tuhande põlengu arvutamine 14 päeva jooksul keskklassi arvutil umbes 10 minutit ning vanemal seadmel aeglasema kõvaketta ja mäluga kuni pool tundi. Kui soovitakse arvutada mitmeid elemente, siis võtavad kalkulatsioonid palju kauem aega. Näiteks saaks koodi paremaks muuta järgnevatel viisidel:

1. Funktsioonid tuleks üle viia Pythoni klassidesse. Siis kutsutakse funktsioone välja klassidest, mitte teistest funktsioonidest. See parandaks oluliselt loetavust ja hilisemate muudatuste läbiviimist;
2. Kasutades Pythoni Pandasi teeki on võimalik muuta .csv failid ümber parquet tüüpi failideks, mis muudaksid andmehulkade töötlemise oluliselt kiiremaks;
3. Lisaks kasutajaliidesele eeldatava aja protsessi lõpuni ning muudaks kasutajaliidese kasutajasõbralikumaks lisades drag-and-drop funktsionaalsuse failide lisamiseks;
4. Programmile variogrammi implementeerimine andmete usaldusväärsuse paremaks hindamiseks.

Programm võimaldab erinevalt eelnevalt kirjeldatust tegelikult kalkuleerida väärtuseid ka varasematel ja hilisematel aastatel. Peamiseks takistuseks on antud juhul 2014 varasematel aastatel andmete suurem puudumine. Aprilli-oktoobri välisel perioodil paljud tugi vaatlusjaamade andurid ei tööta, mistõttu on andmed pikema kauguse arvutuse tõttu ebatäpsemad. Kui ära kustutada programmist read “years = start_date.year - 2014” ning “station_df2 = station_df2[years * 5880:]”, siis muutub protsess aeglasemaks, aga suudab varasemaid perioode kalkuleerida. Hilisematega aastatega probleeme pole, vaja on ainult sisendandmeid.

3.2 Interpoleeritud metsa- ja maastikupõlengute andmed

Programmi abil arvutati metoodika katsetusena kolm andmegruppi, mille tulemusel saadi neljale ajaperioodile vastavad andmed (vt. Tabel 4). Igale põlengule kalkuleeriti väärtused kasutades kolme jaama ning lubatud andmete puudujäägiks perioodi jooksul märgiti 30%.

Tabel 4. Metoodika katsetusena arvutatud andmete perioodid. Nende põlengute arv on sulgudes, millel puuduvate andmete protsent oli nullist suurem.

	Sademed 1 tund (0 põlengut)	Sademed 1 päev (3 põlengut)	Sademed 7 päeva (251 põlengut)	Sademed 14 päeva (512 põlengut)
Andmete puudujääk	0%	0.0024%	0.0033%	0.0054%
Põlengute keskmine kaugus	10.07km 22.75km	10.07km 22.75km	10.05km 22.88km	10.02km 22.88km

lähimast/kõigist kolmest vaatlusjaamast				
	Tuulekiirus 1 tund (0 põlengut)	Tuulekiirus 1 päev (18 põlengut)	Tuulekiirus 7 päeva (87 põlengut)	Tuulekiirus 14 päeva (118 põlengut)
Andmete puudujääk	0%	0.0138%	0.054%	0.47%
Põlengute keskmine kaugus lähimast/kõigist kolmest vaatlusjaamast	15.08km 34.98km	15.08km 34.98km	15.08km 34.86km	14.71km 34.87km
	Temperatuur 1 tund (0 põlengut)	Temperatuur 1 päev (2 põlengut)	Temperatuur 7 päeva (20 põlengut)	Temperatuur 14 päeva (17 põlengut)
Andmete puudujääk	0%	0.0068%	0.051%	0.037%
Põlengute keskmine kaugus lähimast/kõigist kolmest vaatlusjaamast	14.76km 35.43km	14.76km 35.43km	14.43km 35.11km	14.44km 35.02km
	Õhuniiskus 1 tund (0 põlengut)	Õhuniiskus 1 päev (3 põlengut)	Õhuniiskus 7 päeva (39 põlengut)	Õhuniiskus 14 päeva (44 põlengut)
Andmete puudujääk	0%	0.0036%	0.049%	0.03%
Põlengute keskmine kaugus lähimast/kõigist kolmest vaatlusjaamast	19.52km 36.85km	19.52km 36.85km	19.44km 39.33km	19.44km 39.33km
	Kiirgus 1 tund (0 põlengut)	Kiirgus 1 päev (2 põlengut)	Kiirgus 7 päeva (20 põlengut)	Kiirgus 14 päeva (44 põlengut)

Andmete puudujääk	0%	0.0036%	0.0023%	0.028%
Põlengute keskmine kaugus lähimast/kõigist kolmest vaatlusjaamast	43.03km 77.67km	43.03km 77.67km	42.92km 77.67km	43.03km 77.67km

Meteoroloogiliste andmete kalkuleerimisel tekkiv protsentuaalne puudujääk vastab ülaltoodud tabelis ootuspärasusele. Pikemate perioodide juhul tõuseb tõenäosus, et andmeid on ühest või teisest vaatlusjaamast puudu. See suurendab andmete keskmistamisest tulenevaid vigasid hilisemal andmeanalüüsil, mistõttu poleks olnud mõistlik kaasata saartel asunud põlenguid töö valimisse.

Kauguste vahemaade muutused viitavad andmete puudusele põlengule eelnenud perioodi ulatuses, mistõttu vahetati lähedalasuv jaam kaugema vastu. Samas tuleb tabelist välja juhtumeid, kus pikema vaatlusperioodi jooksul lubati programmil keskmistada rohkemal arvul tunde kui lühema kalkuleeritava perioodi ulatuses.

Tuleb rõhutada, et kasutajalt sisendina küsitud parameetri väärtus, mis antud juhul määrati kõikide perioodide jooksul 30% peale, on jaamapõhine. See tähendab, et jaam vahetatakse välja järgmise kaugema vastu kui tuleks keskmistada jaama enda andmeid selle enda omadega rohkem kui 30% ulatuses. Väljundfailis on välja toodud iga põlengu real kõikide jaamade tundide väärtuste puudused keskmistatuna. Näiteks kui esimeses seirejaamas on olemas kõik perioodi andmed, teises puudu 10% ning kolmandas 2%, siis tabelisse on kirjutatud puuduolevalt kolme jaama peale 4%.

Mandri-Eestis on piisavalt tihe vaatlusjaamade võrk, et kalkuleerida IDW abil rahuldava tulemusega väärtusi põlengu koordinaatidele, kuid sademete jaoks oleks parem siiski kasutada Tallinn-Harku ja Sürgavere ilmaradari andmeid või alternatiivina rakendada IDW asemel Gaussi protsessi regressiooni (tuntud ka kui Kriging) (Beek, 1991).

Keskkonnaagentuuri erineva otstarbega vaatlusjaamad paiknevad Eestis optimaalse katvuse põhimõttel erinevate ilmastiku parameetrite seiramiseks:

- Õhutemperatuuri seirejaamade paiknemise raadius üksteisest on 50km;
- Tuule kiiruse ja suuna seirejaamade paiknemise raadius üksteisest on 50km;
- Sademete seirejaamade paiknemise raadius üksteisest on 30km;
- Õhuniiskuse seirejaamade paiknemise raadius üksteisest on 50km;
- Päikesepaiste kestust mõõtvate seirejaamade paiknemise raadius üksteisest on 100km.

Töödeldud andmeid saaks edasi analüüsida mitmel viisil. Nüüdseks on tõestatud erinevate kasvukohatüüpide ja meteoroloogiliste parameetrite kvantitatiivsed seosed, kuid Eestis on hetkel nende rakenduslik väljund veel lahendatud meteoroloogilistele sisenditele tugineva Nesterovi indeksi sidumisel täiendavate maakattetüüpide tuleohuklassiga (Lisa 2 ja 3). Need ei ole omavahel otseses kvantitatiivses seoses, viimane on vaid välja töötatud silumaks Nesterovi indeksi puudujääke. Oja et al. (2020) püüdsid antud probleemi lahendada laialt levinud Kanada tuleohu indeksite perekonna rakendamisega Eestis, mis andis soovitud tulemusi. Antud lahendust takistavad piisava täpsusega vajalike maakattetüüpide kaardistatuse puudumine. Siiski on mainitavale süsteemile üleminek soovitatav, kuna see võimaldaks süsteemi standardiseerimist teiste ELi riikidega (EFFIS, i.a).

Olemasolevate andmetega saab programmi paindlikkust arvesse võttes uurida käesolevaid probleeme edasi mitmel viisil. Ühelt poolt annaks edasi uurida olemasolevate andmetega spetsiifiliste maakattetüüpide ja meteoroloogiliste näitajate omavahelisi seoseid. Teisalt saaks proovida analüüsida parameetreid omavahel läbi peakomponentide, vähimruutude meetodi regressioon- ja VIP-analüüsi, kuna see võib anda ka Eestis tulemusi (Guo et al., 2023).

Kokkuvõte

Käesoleva töö eesmärgiks oli kirjutada Pythoni programmeerimiskeelt kasutades rakendus, mis oleks võimeline kalkuleerima IDW interpoleerimise abil Keskkonnaagentuuri vaatlusjaamade võrgustiku andmed Päästeameti registreeritud metsa- ja maastikupõlengute koordinaatidele.

Töö esimeses pooles keskenduti põlenguid põhjustavate karakteristikute kirjeldamisele ning Eesti ja välismaa kogemuste omavahelisele sidumisele. Võeti kokku Eestis viimastel aastatel avaldatud teadusalane kirjandus ning nende suunitlused. Edasi uuriti ning kirjeldati, kuidas käsitlevad Päästeamet ning Keskkonnagentuur põlengutega seotud teemasid.

Teises osas alustati toorandmete töötlemisega. Meteoroloogilised parameetrid jagati vaatlusjaamade toorandmetest eraldi failidesse ning kaustadesse. Kirjeldati programmile kehtestatud eesmärgid ning töödeldavate andmete laadi.

Töö lõpuks valmis rakendus, mis vastas kõikidele arvutamise meetodika tingimustele. Vaadati üle programmi head ja halvad küljed ning tehti ettepanekuid nende muutmiseks. Toorandmete kvaliteedi osas jõuti järeldusele, et mõjutavaid tegureid silmas pidades peaksid olema need piisavalt hea kvaliteediga edasiseks uurimiseks.

Käesolevas töös loodud programm ja hõlpsasti kalkuleeritavad andmed loovad vajalikud eeldused koos ettevalmistatud toorandmete ja töödeldud andmetega teema edasiseks uurimiseks. Programmi kasutaja saab määrata vastavalt oma eesmärgile, milliseid põlenguid ajalisruumiselt kaasatakse ning milliste andmetega edasiselt programmi väljundfaili andmed uurimiseks seostatakse.

Assessing the risk of forest and landscape fires in Estonia with meteorological data

Risto Merdenson

Summary

The aim of this work was to develop an application using the Python programming language that would be capable of calculating the data from the Environmental Agency's network of observation stations for the coordinates of forest and wildland fires registered by the Rescue Board using IDW interpolation method.

In the first part of the work, the focus was on describing the characteristics that cause fires and linking the experiences of Estonia and foreign countries. A summary of the scientific literature published in Estonia in recent years and their orientations was provided. Additionally, it was examined and described how the Rescue Board and the Environmental Agency handle topics related to fires.

In the second part, the processing of raw data was initiated. Meteorological parameters were separated from the raw data of observation stations into individual files and folders. The objectives set for the program and the nature of the data to be processed were described.

By the end of the work, an application that met all the conditions of the calculation methodology was completed. The strengths and weaknesses of the program were reviewed, and suggestions for changes were made. Regarding the quality of the raw data, it was concluded that, considering the influencing factors, the data should be of sufficiently good quality for further research.

The program created during this work and the easily calculable data provide the necessary prerequisites for further research on the topic along with the prepared raw data and processed data. The end user of this program can select the required wildfires according to their goals, calculate the necessary meteorological data for them, and determine appropriate ways for further research.

Tänuavaldused

Soovin eelkõige tänada oma juhendajat Tõnu Oja tema abivalmi nõustamise ja kannatuse eest minu juhendamisel. Lisaks olen väga tänulik inimestele Keskkonnaagentuurist, kes olid nõus saatma mulle vaatlusjaamade toorandmeid ning vastama minu sademete ilmaradariga seotud küsimustele. Lõpetuseks tänan ka oma sõpru ja vanemaid moraalse toe eest töö kirjutamisel.

Kasutatud kirjandus

Arold, I., (2005). Eesti Maastikud. Tartu Ülikooli Kirjastus. Tartu.

Alton, H., Kiil, A. D (2003). Metsatulekahjud. Eesti Metsaselts.

Amiro, Logan, Wotton, M., Flannigan, M., Todd, Stocks, B., & Martell, D. (2004). Fire weather index system components of large fires in the Canadian boreal forest. *International Journal of Wildland Fire*, 13, 391–400.

Beek, E. G. (1991). *Spatial interpolation of daily meteorological data: Theoretical evaluation of available techniques*. Wageningen, The Netherlands: DLO The Winand Staring Centre.

Bowman, D., Kolden, C., Abatzoglou, J., Johnston, F., Werf, G., & Flannigan, M. (2020). Vegetation fires in the Anthropocene. *Nature Reviews Earth & Environment*, 1, 1–16. <https://doi.org/10.1038/s43017-020-0085-3>

Bowman, D. M. J. S., Balch, J., Artaxo, P., Bond, W. J., Cochrane, M. A., D'Antonio, C. M., DeFries, R., Johnston, F. H., Keeley, J. E., Krawchuk, M. A., Kull, C. A., Mack, M., Moritz, M. A., Pyne, S., Roos, C. I., Scott, A. C., Sodhi, N. S., & Swetnam, T. W. (2011). The human dimension of fire regimes on Earth. *Journal of Biogeography*, 38(12), 2223–2236. <https://doi.org/10.1111/j.1365-2699.2011.02595.x>

Bowman, D. M. J. S., Balch, J. K., Artaxo, P., Bond, W. J., Carlson, J. M., Cochrane, M. A., D'Antonio, C. M., DeFries, R. S., Doyle, J. C., Harrison, S. P., Johnston, F. H., Keeley, J. E., Krawchuk, M. A., Kull, C. A., Marston, J. B., Moritz, M. A., Prentice, I. C., Roos, C. I., Scott, A. C., ... Pyne, S. J. (2009). Fire in the Earth System. *Science*, 324(5926), 481–484. <https://doi.org/10.1126/science.1163886>

Costantino, S., Salis, M., Arca, B., Duce, P., & Spano, D. (2018). Assessing the performance of fire danger indexes in a Mediterranean area. *IForest - Biogeosciences and Forestry*, 11, 563–571. <https://doi.org/10.3832/ifor2679-011>

Fire Weather Indices Wiki (i.a). Fire Weather Indices. <https://wikifire.wsl.ch/tiki-index.html> (vaadatud 22.05.2024)

European Forest Fire Information System (EFFIS). i.a.
<https://forest-fire.emergency.copernicus.eu/> (23.05.2024)

Government of Canada. (2021). Fire Behaviour. <https://www.canada.ca/en.html> (21.05.2024)

GISGeography. 2016. “Inverse Distance Weighting (IDW) Interpolation.”
<https://gisgeography.com/inverse-distance-weighting-idw-interpolation/> (22.05.2024)

Gentile, M., Courbin, F., & Meylan, G. (2012). Interpolating point spread function anisotropy. *Astronomy and Astrophysics*, 549, Article A1.
<https://doi.org/10.1051/0004-6361/201219739>

Guo, M., Yao, Q., Suo, H., Xu, X., Li, J., He, H., Yin, S., & Li, J. (2023). The importance degree of weather elements in driving wildfire occurrence in mainland China. *Ecological Indicators*, 148, 110152. <https://doi.org/10.1016/j.ecolind.2023.110152>

He, T., Lamont, B. B., & Pausas, J. G. (2019). Fire as a key driver of Earth’s biodiversity. *Biological Reviews of the Cambridge Philosophical Society*, 94(6), 1983–2010.
<https://doi.org/10.1111/brv.12544>

Heinoja, L., PÄÄ arendusosakond. (2022). Metsa- ja maastikutulekahjude avaandmete seletuskiri. Tallinn. <https://www.rescue.ee/files/2022-09/metsa-ja-maastiku-tulekahjude-avaandmete-seletuskiri-2022vaelisveebiversioon.pdf> (22.05.2024)

Hirschberger, P. (2016). Forests Ablaze: causes and effects of global forest fires. Berlin: WWF Deutschland

Kelly, L. T., Giljohann, K. M., Duane, A., Aquilué, N., Archibald, S., Batllori, E., Bennett, A. F., Buckland, S. T., Canelles, Q., Clarke, M. F., Fortin, M.-J., Hermoso, V., Herrando, S., Keane, R. E., Lake, F. K., McCarthy, M. A., Morán-Ordóñez, A., Parr, C. L., Pausas, J. G.,

Kiil, A.D., (2001) Forest fire behaviour and management. Canada. Käsikiri.

Kitenberga, M., Matisons, R., Jansons, Ā., & Donis, J. (2018). Teleconnection between the Atlantic sea surface temperature and forest fires in Latvia and Estonia. *Silva Fennica*, 52(1), 7771. <https://doi.org/10.14214/sf.7771>

Brotons, L. (2020). Fire and biodiversity in the Anthropocene. *Science*, 370(6519), eabb0355. <https://doi.org/10.1126/science.abb0355>

Karoles, K. (2020). Maailma metsad põlevad - trendid, põhjused ja tagajärjed. Eesti Mets. <http://eesti-mets-arhiiv.horisont.ee/Eesti-Mets-3-2020.pdf> (23.05.2024)

Keskkonnaagentuur. 2024. Tuleohukaart. (23.05.2024) <https://www.ilmateenistus.ee/ilm/proгноosisid/tuleohukaart/>

Keskkonnaamet. 2019. Lisa 1.1 Meteoroloogilise seire allprogramm. Tallinn. <https://keskkonnaagentuur.ee/keskkonnaseire-ja-analuusid/keskkonnaseire> (22.05.2024)

Koranteng, A. K. (2020). Risk Assessment of Landscape Fires in Estonia. University of Tartu.

United Nations Environment Programme. (2022). *Spreading like wildfire: The rising threat of extraordinary landscape fires*. A UNEP Rapid Response Assessment. Nairobi.

Li, X., Zhao, G., Yu, X., & Yu, Q. (2014). A comparison of forest fire indices for predicting fire risk in contrasting climates in China. *Natural Hazards*, 70(2), Article 2. <https://doi.org/10.1007/s11069-013-0877-6>

Meier, S., Elliott, R. J. R., & Strobl, E. (2023). The regional economic impact of wildfires: Evidence from Southern Europe. *Journal of Environmental Economics and Management*, 118, 102787. <https://doi.org/10.1016/j.jeem.2023.102787>

Metsaseadus. (2023). Üldsätted (vastu võetud 07.06.2006, muudetud, täiendatud, viimati jõustunud 01.07.2023) <https://www.riigiteataja.ee/akt/127052022014?leiaKehtiv>

Metsa korraldamise juhend. (2022). Metsa tuleohuklassid. (vastu võetud 16.01.2009, muudetud, täiendatud, viimati jõustunud 10.10.2022) – Riigi Teataja <https://www.riigiteataja.ee/akt/107102022003?leiaKehtiv> (24.05.2023)

Orr, D. (2023). Tartumaa metsa- ja maastikutulekahjud 2014-2022. EMÜ DSpace. <https://dspace.emu.ee/items/204320ba-6e75-44eb-8964-acdaf77b99c4> (23.05.2024)

Oja, T., Sagris, V., Muru, M., Sepp, E., Lang, M., Post, P., Rahu, J., Toll, V., & Voormansik, T. (2020). *Metsa- ja maastikutulekahjude ennetamine ja likvideerimine*.

Pagnon Eriksson, C., & Johansson, N. (2020). *Review of wildfire indices*. Division of Fire Safety Engineering.

Pineda, N., Montanyà, J., & van der Velde, O. A. (2014). Characteristics of lightning related to wildfire ignitions in Catalonia. *Atmospheric Research*, 135–136, 380–387. <https://doi.org/10.1016/j.atmosres.2012.07.011>

Päästeamet. (i.a). Metsa- ja maastikutulekahjude avaandmed. Päästeamet. <https://www.rescue.ee/et/juhend/avaandmed/metsa-ja-maastikutulekahjud> (17.03.2023)

Robinne, F. (2021). Impacts of disasters on forests, in particular forest fires. United Nations Forum on Forests.

Rowell, A., Moore, P. F. (2020). Global Review of Forest Fires. IUCN.

San-Miguel-Ayanz, J., Durrant, T., Boca, R., Maianti, P., Libertá, G., Artés-Vivancos, T., Oom, D., Branco, A., de Rigo, D., Ferrari, D., Pfeiffer, H., Grecchi, R., Onida, M., Löffler, P. (2022). Forest Fires in Europe, Middle East and North Africa 2021. Luxembourg: Publications Office of the European Union. doi:10.2760/34094

Statistikaamet. (2023). 1km x 1km rahvastikutiheduse andmed 2018. aastal. <https://www.stat.ee/et/uudised/statistikaamet-sulgeb-kaardirakenduse> (22.05.2024)

Statistikaamet. (2021) INSPIRE (PD) - Eesti rahvastiku tihedus 1x1km (WFS). Ruumiandmete kataloog. <https://metadata.geoportaal.ee/geonetwork/srv/api/records/935e7890-f673-43b8-ad58-22f5b941f63b/formatters/xsl-view?output=pdf&language=est&approved=true> (22.05.2024)

Shokouhi, B. V. (2020). Risk Assessment of Landscape Fires in Estonia. University of Tartu. University of Tartu.

Tammets, T., Kallis, A. (2012). Eesti ilma riskid. Metsade tuleoht. Eesti Meteoroloogia ja Hüdroloogia Instituut. Tallinn.

https://www.ilmateenistus.ee/wp-content/uploads/2013/01/eesti_ilma_riskid_2012_metsadetu_leoht.pdf (19.01.2024)

Taillie, P. J., Burnett, R. D., Roberts, L. J., Campos, B. R., Peterson, M. N., & Moorman, C. E. (2018). Interacting and non-linear avian responses to mixed-severity wildfire and time since fire. *Ecosphere*, *9*(6), e02291. <https://doi.org/10.1002/ecs2.2291>

Torres, F., Lima, G., Martins, S., & Valverde, S. (2017). Analysis of efficiency of fire danger indices in forest fire prediction. *Revista Árvore*, *41*. <https://doi.org/10.1590/1806-90882017000200009>

Tuleohutuse seadus. (2022). Tuleohutusnõuded, tuleohtlik aeg. (vastu võetud 05.05.2010, muudetud, täiendatud, viimati jõustunud 01.01.2023). Riigi Teataja. <https://www.riigiteataja.ee/akt/13314859> (21.05.2024)

Tuleohutuse seadus. 2022. Tuleohutusnõuded, tuleohtlik aeg. (redaktsioon vastu võetud 05.05.2010, muudetud, täiendatud, viimati jõustunud 01.01.2023). Riigi Teataja. <https://www.riigiteataja.ee/akt/13314859> (21.05.2024)

Urbanski, S. P., Hao, W. M., & Baker, S. (2008). Chapter 4 Chemical Composition of Wildland Fire Emissions. In A. Bytnerowicz, M. J. Arbaugh, A. R. Riebau, & C. Andersen (Eds.), *Wildland Fires and Air Pollution* (Vol. 8, pp. 79–107). Elsevier. [https://doi.org/10.1016/S1474-8177\(08\)00004-1](https://doi.org/10.1016/S1474-8177(08)00004-1)

Vajda, A., Venäläinen, A., Suomi, I., Junila, P., & Mäkelä, H. M. (2014). Assessment of forest fire danger in a boreal forest environment: Description and evaluation of the operational system applied in Finland. *Meteorological Applications*, *21*(4), Article 4. <https://doi.org/10.1002/met.1425>

Valgepea, M., Sirkas, F., Timmusk, T., Pärt, E., Suursild, E., Matson, T., Maamets, L., Raudsaar, M., Tetlov, E., Apuhtin, V., Veeroja, R., Tamm, U., & Laigu, R. (2021). Aastaraamat Mets 2020. Keskkonnaagentuur. ISSN: 2382-7068.

Ward, D., Kloster, S., Mahowald, N., Rogers, B., Randerson, J., & Hess, P. (2012). The changing radiative forcing of fires: Global model estimates for past, present and future. *Atmos. Chem. Phys.*, *12*, 10857–10886. <https://doi.org/10.5194/acp-12-10857-2012>

Ziel, R., Bieniek, P., Bhatt, U., Strader, H., Rupp, T., & York, A. (2020). A Comparison of Fire Weather Indices with MODIS Fire Days for the Natural Regions of Alaska. *Forests, 11*, 516. <https://doi.org/10.3390/f11050516>

Õunap, H., Hanso, M (2016). Olulisemad metsakahjustused ja nende vältimine. / SA Eramaetsakeskus. EMÜ DSpace. <https://dspace.emu.ee/handle/10492/4610> (21.05.2024)

Lihtlitsents lõputöö reprodutseerimiseks ja üldsusele kättesaadavaks tegemiseks

Mina, Risto Merdenson

1. annan Tartu Ülikoolile tasuta loa (lihtlitsentsi) minu loodud teose „Metsa- ja maastikupõlengute ohu ennetamisest Eestis meteoroloogiliste andmete abil“, mille juhendaja on Tõnu Oja, 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.

Risto Merdenson

23.05.2024

LISAD

Lisa 1. Olulisemad tuleohuindeksid ja nende alamklassid (Constantino *et al.* 2018; Fire Weather Indices Wiki, i.a)

Tuleohuindeks eesti keeles	Tuleohuindeks inglise keeles	Tähis	Indeksi allkomponendid
Riikliku tuleohu määra indeks	National Fire-Danger Rating System	NFDRS	IC, SC, ERC, BI, LOI, MCOI, FLI, KBDI
Soome tuleohuindeks	Finnish Fire Risk Index	FFI	-
Kanada tuleohuindeks	(Canadian) Fire Weather Index	Canadian FWI	FFMC, DMC, DC, ISI, BUI
Keetch-Byrami põuaindeks	Keetch-Byram drought index	KBDI	-
McArthuri Mark 5 metsade tuleohuindeks	McArthur Mk5 Forest Fire Danger Rating Index	FFDI	+KBDI
McArthuri Mark 4 rohulate tuleohuindeks	McArthur Mk4 Grassland Fire Danger Rating Index	GFDI	-
Fosbergi tuleohuindeks	Fosberg Fire Weather Index	FFWI	-
Nesterovi tuleohuindeks	Nesterov Ignition Index	-	-
Paljundusindeks	IPi Propagation Index	IPi	-
Integreeritud tuleohuindeks	Integrated Fire Index	IFI	-
Tule potentsiaali indeks	Fire Potential Index	FPI	LR, TNf

Lisa 2. Metsade tuleohuklassid (Metsa korraldamise juhend, 2022)

Metsakasvukohatüüp	Puuliik	Arenguklass	Tuleohuklass
Leesikaloo, kastikuloo, sambliku, kanarbiku	Kõik okaspuud	Kõik arenguklassid	I tuleohuklass
	Lehtpuud	Lagedad alad kuni latimetsad	II tuleohuklass
		Keskealised metsad ja vanemad	III tuleohuklass
Pohla, sinilille, jänese kapsa, jänese kapsa-pohla, jänese kapsa-mustika, mustika, sinika	Kõik okaspuud	Lagedad alad kuni latimetsad	I tuleohuklass
	Mänd, lehis	Keskealised metsad ja vanemad	II tuleohuklass
	Kuusk, ebatsuuga, nulg	Keskealised metsad ja vanemad	III tuleohuklass
	Lehtpuud	Lagedad alad kuni latimetsad	III tuleohuklass
		Keskealised metsad ja vanemad	IV tuleohuklass
Naadi	Mänd, lehis	Kõik arenguklassid	III tuleohuklass
	Kuusk, ebatsuuga, nulg	Lagedad alad kuni latimetsad	III tuleohuklass
		Keskealised metsad ja vanemad	IV tuleohuklass
	Lehpuud	Lagedad alad kuni latimetsad	III tuleohuklass
		Keskealised metsad ja vanemad	IV tuleohuklass
Karusambla-mustika, karusambla, osja, tarna, lubikaloo	Kõik okaspuud	Kõik arenguklassid	III tuleohuklass
	Lehtpuud	Kõik arenguklassid	V tuleohuklass

Kuivendatud - karusambla-mustika, karusambla, osja, tarna, lubikaloo	Kõik okaspuud	Kõik arenguklassid	II tuleohuklass
	Lehtpuud	Kõik arenguklassid	IV tuleohuklass
Sõnajala, angervaksa, tarna-angervaksa, lodu, kõdusood, madal-soo, siirdesoo, raba	Kõik okaspuud	Lagedad alad kuni latimetsad	III tuleohuklass
		Keskealised metsad ja vanemad	IV tuleohuklass
	Lehtpuud	Kõik arenguklassid	V tuleohuklass
Kuivendatud – sõnajala, angervaksa, tarna-angervaksa, lodu, kõdusood, madal-soo, siirdesoo, raba	Kõik okaspuud	Lagedad alad kuni latimetsad	II tuleohuklass
			III tuleohuklass
	Lehtpuud	Keskealised metsad ja vanemad	IV tuleohuklass
Mineraalne puistang	Kõik puuliigid	Kõik arenguklassid	II tuleohuklass
Turbane puistang	Kõik puuliigid	Kõik arenguklassid	I tuleohuklass

Lisa 3. Metsade tuleohu suurused (Alton & Kiil 2003)

Kood	Nimetus	Kirjeldus
1	I tuleohuklass	Väga suur tuleoht
2	II tuleohuklass	Suur tuleoht
3	III tuleohuklass	Keskmine tuleoht
4	IV tuleohuklass	Väga tuleoht

5	V tuleohuklass	Väga väike tuleoht
---	----------------	--------------------

Lisa 4. IDW programm

```

import pandas as pd
import numpy as np
from haversine import haversine
import os
from datetime import datetime, timedelta
import geopandas as gpd
from shapely.geometry import Point
from progress.bar import IncrementalBar
import tkinter as tk
from tkinter import ttk
import threading

calculation_type = 0
station_count = 0
missing_data_limit = 0
number_of_days = 0
file_to_write = ""

directory = ""
wildfires_df = None
station_dict = {}
missing_data_count = 0
average_station_distance = 0
shortest_station_distance = 0
last_hour_idw = 0
df_value_column = 4
csv_files = []
new_column = pd.DataFrame

year = None
month = None
day = None
time = None
date_index = None
stat_time = 0

# Fast distance calc
def calculate_distance(x_lat, x_lon, y_lat, y_lon):
    return haversine((x_lat, x_lon), (y_lat, y_lon), unit="km")

# Precise distance calc using geodata

```

```

def calc_distance(x_lat, x_lon, y_lat, y_lon):
    # Create a GeoDataFrame for the points you want to compare
    point1 = Point(x_lat, x_lon)
    point2 = Point(y_lat, y_lon)

    points_df = gpd.GeoDataFrame({'geometry': [point1, point2]}, crs='EPSG:4326')
    points_df = points_df.to_crs('EPSG:3301')
    points_df2 = points_df.shift() # We shift the dataframe by 1 to align pnt1 with pnt2
    return points_df.distance(points_df2)[1]

# Calculate the IDW
def idw(distances, values, power=2):
    weights = (1.0 / distances)**power
    weighted_values = values * weights
    return np.sum(weighted_values) / np.sum(weights)

# If the station doesn't have enough data for the given fire, select the new closest station
def station_selection(available_stations, all_stations):
    missing_station_count = 0
    i = 0
    # The list to return that holds the selected stations data
    stations_df_list = list()
    while i < len(available_stations):
        station = available_stations[i]
        station_name, distance = station
        station_df = find_data_rows(station_name)

        # Find out if the data is fit for usage, if not remove it
        unfit, station_df = missing_values_count(station_df)
        if unfit:
            available_stations.remove(station)
            if len(available_stations) + 1 + missing_station_count >= len(all_stations):
                return []
            available_stations.append(all_stations[len(available_stations) + 1 +
missing_station_count])
            missing_station_count += 1
        i -= 1
    else:
        # Store the distance of the stations
        global average_station_distance
        average_station_distance += distance
        # Store the distance of the closest station
        global shortest_station_distance
        if shortest_station_distance == 0 or shortest_station_distance > distance:
            shortest_station_distance = distance
        stations_df_list.append(station_df)
        i += 1

```

```

return stations_df_list

# Return the stations values in the given timeframe
# If the starting dates for the stations are different, the code can be modified to not store
date_index
def find_data_rows(station_name):
    global date_index
    station_df2 = read_station(station_name)
    if date_index == -1:
        wildfire_date = datetime(year, month, day)
        start_date = wildfire_date - timedelta(days=number_of_days)
        date_index = find_date_index(start_date, station_df2)

    station_df2 = station_df2[date_index:date_index + (number_of_days * 24) + 1]
    return station_df2

# Find the amount of missing data, if it is more than allowed return true
# If the percentage of missing data is less than the allowed percentage fill the missing values
with the average for the timeframe
def missing_values_count(station_df):
    count = 0
    missing_count = 0
    average_value = 0
    average_value_2 = 0
    average_value_3 = 0

    # Find the percentage of missing values
    for _, row in station_df.iterrows():
        count += 1
        if pd.isnull(row[df_value_column]):
            missing_count += 1
        elif calculation_type == 2:
            if pd.isnull(row[df_value_column + 1]):
                missing_count += 1
            else:
                average_value += row[df_value_column]
            if calculation_type == 2:
                average_value_2 += row[df_value_column + 1]
                average_value_3 += row[df_value_column + 2]

    missing_percentage = 0
    if count > 0:
        if missing_count > 0:
            missing_percentage = (missing_count / count) * 100
        else:
            missing_percentage = 100

```

```

middleman = 0
# If the percentage of missing data is less than the specified amount fill the missing
values with the average for the timeframe
if missing_percentage <= missing_data_limit and missing_count > 0:
# Find the average value/values
average_value = average_value / (count - missing_count)
if calculation_type == 2:
average_value_2 = average_value_2 / (count - missing_count)
average_value_3 = average_value_3 / (count - missing_count)
# Add the values to rows missing them
for i, row in station_df.iterrows():
if pd.isnull(row[df_value_column]):
station_df.at[i, station_df.columns[df_value_column]] = average_value
middleman += 1
if calculation_type == 2:
if pd.isnull(row[df_value_column + 1]):
station_df.at[i, station_df.columns[df_value_column + 1]] = average_value_2
station_df.at[i, station_df.columns[df_value_column + 2]] = average_value_3
middleman += 1
# missing_data_count holds the count of missing data values
global missing_data_count
missing_data_count += middleman

return missing_percentage > missing_data_limit, station_df

```

```

# Find out if the station is already read in
# If not, add it into the dictionary
def read_station(station_name):
if station_name in station_dict:
return station_dict[station_name]

```

```

# Find the wildfire date and time index for the stations
def find_date_index(start_date, station_df2):
stat_time_str = str(stat_time).zfill(2)
years = start_date.year - 2014 # The start date of weather data for our dataframe's
# Start the search from the right year
station_df2 = station_df2[years * 5880:]
return station_df2.loc[(station_df2['datetime'] == start_date) & (station_df2['Kell
(UTC)'].str.replace(r':00', '').str.zfill(2) == stat_time_str)].iloc[0].name

```

```

# Get the wildfire IDW daily values
def create_value_column(type_value, stations_df, lat, lon):
value_list = []
distance_list = []
hour_count = 0

```

```

full_day_value_list = []
last_hour_value_list = []
global last_hour_idw
last_hour_idw = 0

# Loop over the hours
# Group the data from different stations together
# Create the day_values numpy array, that holds the data of all stations for the day
# Create day_distances numpy array, that holds the distance for the stations
# Every station's value and distance is on the same index in both the day_values and
day_distances lista
for i in range(len(stations_df[0])):
    hour_count += 1
    day_distances_list = []
    day_values_list = []
    index = 0
    # Loop through the stations to find the hourly value for each station
    for station in stations_df:
        # Find the distance for the station on the first hour of the day
        if i == 0:
            middleman = calc_distance(lat, lon, station.iloc[i]['station.latitude'],
station.iloc[i]['station.longitude'])
            distance_list.append(middleman)
            full_day_value_list.append(0.0)
        # Add every hour into the full day value list for the day
        full_day_value_list[index] = full_day_value_list[index] + station.iloc[i][type_value]

    # Add the days IDW values into a list
    if hour_count == 24:
        day_distances_list.append(distance_list[index])
        if calculation_type == 3 or calculation_type == 5:
            # IDW from the days total value
            day_values_list.append(full_day_value_list[index])
        else:
            # IDW from the days average value
            day_values_list.append(full_day_value_list[index] / 24)
        full_day_value_list[index] = 0

# Add the last hour before the wildfire into a list
if i == len(stations_df[0]) - 1:
    last_hour_value_list.append(station.iloc[i][type_value])

index += 1

# Find the IDW for every day
if hour_count == 24:
    hour_count = 0
    day_distances = np.array(day_distances_list)
    day_values = np.array(day_values_list)

```

```

idw_value = idw(day_distances, day_values)
value_list.append(idw_value)

# Find the IDW of the last hour
last_hour_idw = idw(np.array(distance_list), np.array(last_hour_value_list))
return value_list

# Choose the correct function to handle the data
def choose_data_type(type, stations_df, lat, lon):

    if type == 1:
        type_value = "10 minuti keskmine tuule kiirus m/s"
        return wind_speed(create_value_column(type_value, stations_df, lat, lon))
    elif type == 2:
        return temperature(create_value_column("Õhutamperatuur °C", stations_df, lat, lon),
create_value_column("Tunni miinimum õhutamperatuur °C", stations_df, lat, lon),
create_value_column("Tunni maksimum õhutamperatuur °C", stations_df, lat, lon))
    elif type == 3:
        type_value = "Tunni sademete summa mm"
        return precipitation(create_value_column(type_value, stations_df, lat, lon))
    elif type == 4:
        type_value = "Suhteline õhuniiskus %"
        return humidity(create_value_column(type_value, stations_df, lat, lon))
    elif type == 5:
        type_value = "Tunni keskmine summaarne kiirgus W/m²"
        return radiation_total(create_value_column(type_value, stations_df, lat, lon))

# Return the average wind speed
def wind_speed(wind_value):
    wind_total = sum(wind_value)
    if wind_total == 0:
        return 0
    return wind_total / len(wind_value)

# Return the average temperature and the difference between the minimum and maximum
temperatures
def temperature(temp, min_temp, max_temp):
    diff = []
    for i, j in zip(min_temp, max_temp):
        diff.append(j - i)

    sum_temp = sum(temp)
    sum_diff = sum(diff)
    if sum_temp == 0 and sum_diff == 0:
        return 0, 0
    if sum_temp == 0:

```

```

return 0, sum(diff)
if sum_diff == 0:
return sum_temp, 0

return sum_temp / len(temp), sum_diff

# Return the precipitation total in mm, the dry and wet day counts and wet day streak
def precipitation(precipitation_values):
    dry_count = 0
    wet_count = 0
    wet_counter = 0
    wet_in_a_row_count = 0
    for i in precipitation_values:
        if i == 0:
            dry_count += 1
            if wet_in_a_row_count < wet_counter:
                wet_in_a_row_count = wet_counter
            wet_counter = 0
        else:
            wet_count += 1
            wet_counter += 1

    return sum(precipitation_values), dry_count, wet_count, wet_in_a_row_count

# Return the average humidity
def humidity(humidity_values):
    humidity_sum = sum(humidity_values)
    if humidity_sum == 0:
        return 0
    return humidity_sum / len(humidity_values)

# Return the sum of radiation
def radiation_total(radiation):
    return sum(radiation)

# -----

# Find the weather stations and loop over every wildfire.
# calculate IDW values and write the values into the given .csv file for every wildfire
def calc_data():
    existing_df = pd.read_csv(file_to_write)
    global wildfires_df
    wildfires_df = pd.read_csv(file_to_write, encoding='utf-8', delimiter=',')
    bar = IncrementalBar('Progress', suffix='% (percent)d%%', max=100)
    progress = 0

```

```

# Read weather data from the relevant directory
csv_stations = []
for csv_file in csv_files:
    csv_file_path = os.path.join(directory, csv_file)
    csv_station_temp = pd.read_csv(csv_file_path, encoding='utf-8', delimiter=',',
engine="pyarrow", dtype={"Aasta": "int32", "Kuu": "int8", "Päev": "int8", "Kell (UTC)":
"string"})
    csv_stations.append(csv_station_temp)
    station_row = csv_station_temp.iloc[0]
    station_name = station_row['stationname']
    station_dict[station_name] = csv_station_temp
    station_dict[station_name].rename(columns={'Aasta': 'year', 'Kuu': 'month', 'Päev':
'day'}, inplace=True)
    station_dict[station_name]['datetime'] =
pd.to_datetime(station_dict[station_name][['year', 'month', 'day']])

```

```

# Loop over all wildfires
for index, wildfire_row in wildfires_df.iterrows():
    wildfire_lat = wildfire_row['Poleng_lat']
    wildfire_lon = wildfire_row['Poleng_lon']
    global year
    year = wildfire_row['Aasta']
    global month
    month = wildfire_row['Kuu']
    global day
    day = wildfire_row['Päev']
    global time
    time = wildfire_row['Kell (UTC)'].split(':')[0]
    global date_index
    date_index = -1
    close_station_count = 0
    closest_ava_stations = []
    available_stations = []
    global stat_time
    stat_time = int(wildfire_row['Kell (UTC)'].split(':')[0])
    global missing_data_count
    global number_of_days
    global shortest_station_distance
    # Loop over all stations found in the relevant directory
    for station_df in csv_stations:

```

```

    station_row = station_df.iloc[0]
    station_lat = station_row['station.latitude']
    station_lon = station_row['station.longitude']
    station_name = station_row['stationname']

```

```

# use the faster distance calculation using Haversine to find the stations distance from
the wildfire
distance = calculate_distance(wildfire_lat, wildfire_lon, station_lat, station_lon)

```

```

# Add the distances to respective lists
# Distances under 50km are prioritized
if distance <= 50:
    closest_ava_stations.append([station_name, distance])
    close_station_count += 1
else:
    available_stations.append([station_name, distance])
stations_df_list = list()
# Create an all_stations list and a list with the best stations, based on the number of
stations under 50km
# The chosen stations are filtered based on missing data in the station_selection
function
if close_station_count >= station_count: # If there's enough close stations
closest_ava_stations.sort(key=lambda x: x[1])
available_stations = available_stations + closest_ava_stations
available_stations.sort(key=lambda x: x[1])
all_stations = available_stations
closest_ava_stations = closest_ava_stations[:station_count]
stations_df_list = station_selection(closest_ava_stations, all_stations)
elif close_station_count == 0: # If there's no close stations
available_stations.sort(key=lambda x: x[1])
all_stations = available_stations
available_stations = available_stations[:station_count]
stations_df_list = station_selection(available_stations, all_stations)
elif close_station_count < station_count: # If there's some close stations
available_stations = available_stations + closest_ava_stations
available_stations.sort(key=lambda x: x[1])
all_stations = available_stations
available_stations = available_stations[:station_count]
stations_df_list = station_selection(available_stations, all_stations)

global average_station_distance
average_station_distance = average_station_distance / station_count
# Add the gained data to the dataframe
if calculation_type == 2:
new_value_1, new_value_2 = choose_data_type(calculation_type, stations_df_list,
wildfire_lat, wildfire_lon)
new_column.loc[len(new_column.index)] = [new_value_1, new_value_2,
(str((missing_data_count / (number_of_days * 24 * station_count)) * 100) + "%"),
average_station_distance, shortest_station_distance, last_hour_idw]
elif calculation_type == 3:

new_value_1, new_value_2, new_value_3, new_value_4 =
choose_data_type(calculation_type, stations_df_list, wildfire_lat, wildfire_lon)
new_column.loc[len(new_column.index)] = [new_value_1, new_value_2,
new_value_3, new_value_4, (str((missing_data_count / (number_of_days * 24 *
station_count)) * 100) + "%"), average_station_distance, shortest_station_distance,
last_hour_idw]

```

```

else:
    new_value = choose_data_type(calculation_type, stations_df_list, wildfire_lat,
wildfire_lon)
    new_column.loc[len(new_column.index)] = [new_value, (str((missing_data_count /
(number_of_days * 24 * station_count)) * 100) + "%"), average_station_distance,
shortest_station_distance, last_hour_idw]

missing_data_count = 0
average_station_distance = 0

shortest_station_distance = 0
# Convert wildfires calculated into percentage based progress
if int((index / int(wildfires_df.shape[0])) * 100) > progress:
    progress = int((index / wildfires_df.shape[0]) * 100)
    progress_UI.step(1)
    # Update the GUI
    root.update_idletasks()
    bar.next()
    # Write the created dataframe into the given csv file
    result = pd.concat([existing_df, new_column], axis=1)
    result.to_csv(file_to_write, index=False)
    bar.next()
    bar.finish()

# Create a dataframe with columns based on the calculation type
def create_columns():
    global directory
    global new_column
    missing_data = "Puuduvate andmete protsent"
    station_distance_column = "Jaamde keskmine kaugus"
    shortest_distance_column = "Lähima jaama kaugus"
    last_hour_idw_column = "Viimase tunni väärtus"

    # Create a dataframe with column names based on the calculation type
    if calculation_type == 1:
        column_name = ("Eelneva " + str(number_of_days) + " päeva keskmine tuule kiirus.
Lubatud puudujääk " + str(int(missing_data_limit)) + "%. Tuletamisel kasutatud " +
str(station_count) + " jaama.")
        new_column = pd.DataFrame({column_name: [], missing_data: [],
station_distance_column: [], shortest_distance_column: [], last_hour_idw_column: []})
        directory = "Tuulekiirus"
    elif calculation_type == 2:
        column_name = ("Eelneva " + str(number_of_days) + " päeva keskmine temperatuur.
Lubatud puudujääk " + str(int(missing_data_limit)) + "%. Tuletamisel kasutatud " +
str(station_count) + " jaama.")
        column_name_1 = ("Eelneva " + str(number_of_days) + " päeva kõrgeima ja
madalaima temperatuuri vahe. Lubatud puudujääk " + str(missing_data_limit) + "%.
Tuletamisel kasutatud " + str(station_count) + " jaama.")

```

```

        new_column = pd.DataFrame({column_name: [], column_name_1: [], missing_data:
[], station_distance_column: [], shortest_distance_column: [], last_hour_idw_column: []})
        directory = "Temperatuur"
        elif calculation_type == 3:
            column_name = ("Eelneva " + str(number_of_days) + " päeva sademete summa.
Lubatud puudujääk " + str(int(missing_data_limit)) + "%. Tuletamisel kasutatud " +
str(station_count) + " jaama.")
            column_name_1 = ("Eelneva " + str(number_of_days) + " päeva kuivade päevade arv.
Lubatud puudujääk " + str(int(missing_data_limit)) + "%. Tuletamisel kasutatud " +
str(station_count) + " jaama.")
            column_name_2 = ("Eelneva " + str(number_of_days) + " päeva märgade päevade
arv. Lubatud puudujääk " + str(int(missing_data_limit)) + "%. Tuletamisel kasutatud " +
str(station_count) + " jaama.")
            column_name_3 = ("Eelneva " + str(number_of_days) + " päeva kõige pikkem
märgade päevade jada. Lubatud puudujääk " + str(int(missing_data_limit)) + "%. Tuletamisel
kasutatud " + str(station_count) + " jaama.")
            new_column = pd.DataFrame({column_name: [], column_name_1: [],
column_name_2: [], column_name_3: [], missing_data: [], station_distance_column: [],
shortest_distance_column: [], last_hour_idw_column: []})
            directory = "Sademed"
            elif calculation_type == 4:
                column_name = ("Eelneva " + str(number_of_days) + " päeva keskmine suhteline
õhuniiskus. Lubatud puudujääk " + str(int(missing_data_limit)) + "%. Tuletamisel kasutatud "
+ str(station_count) + " jaama.")
                new_column = pd.DataFrame({column_name: [], missing_data: [],
station_distance_column: [], shortest_distance_column: [], last_hour_idw_column: []})
                directory = "Ohuniiskus"
                elif calculation_type == 5:
                    column_name = ("Eelneva " + str(number_of_days) + " päeva summaarne kiirgus
W/m². Lubatud puudujääk " + str(int(missing_data_limit)) + "%. Tuletamisel kasutatud " +
str(station_count) + " jaama.")
                    new_column = pd.DataFrame({column_name: [], missing_data: [],
station_distance_column: [], shortest_distance_column: [], last_hour_idw_column: []})
                    directory = "Kiirgus"

global csv_files
csv_files = []
for file in os.listdir(directory):
    if file.endswith('.csv'):
        csv_files.append(file)
        calc_data()

```

```

# Submit the data in the UI
def submit():
    # Convert the chosen option from the drop-down list into an integer
    global calculation_type
    calculation_type_map = {
'Tuulekiirus': 1,

```

```

'Temperatuur': 2,
'Sademed': 3,
'Õhuniiskus': 4,
'Kiirgus': 5
}
calculation_type_str = calculation_type_var.get()
calculation_type = int(calculation_type_map.get(calculation_type_str, None))
global station_count
station_count = int(station_count_entry.get())
global missing_data_limit
missing_data_limit = int(missing_data_limit_entry.get())
global number_of_days
number_of_days = int(number_of_days_entry.get())
global file_to_write
file_to_write = file_to_write_entry.get()

print(f"Calculation Type: {calculation_type}")
print(f"Station Count: {station_count}")
print(f"Missing Data Limit: {missing_data_limit}")
print(f"Number of Days: {number_of_days}")
print(f"File Name: {file_to_write}")
# Set the progress bar to the beginning
progress_UI.step(0.2)
threading.Thread(target=create_columns).start()

```

```
# Create the main window
```

```
root = tk.Tk()
root.title("Tulekahjude IDW rakendus")
```

```
# Dropdown menu for calculation_type
```

```
calculation_type_label = tk.Label(root, text="Kalkulatsiooni tüüp")
calculation_type_label.grid(row=0, column=0, padx=10, pady=5)
```

```
calculation_type_var = tk.StringVar()
calculation_type_menu = ttk.Combobox(root, textvariable=calculation_type_var)
calculation_type_menu['values'] = ('Tuulekiirus', 'Temperatuur', 'Sademed', 'Õhuniiskus',
'Kiirgus')
calculation_type_menu.grid(row=0, column=1, padx=10, pady=5)
calculation_type_menu.current(0) # Default value
```

```
# Textbox for station_count
```

```
station_count_label = tk.Label(root, text="Kaasatud jaamade arv")
station_count_label.grid(row=1, column=0, padx=10, pady=5)
```

```
station_count_entry = tk.Entry(root)
station_count_entry.grid(row=1, column=1, padx=10, pady=5)
```

```
# Textbox for missing_data_limit
```

```

missing_data_limit_label = tk.Label(root, text="Lubatud protsent puuduvaid andmeid")
missing_data_limit_label.grid(row=2, column=0, padx=10, pady=5)

missing_data_limit_entry = tk.Entry(root)
missing_data_limit_entry.grid(row=2, column=1, padx=10, pady=5)

# Textbox for number_of_days
number_of_days_label = tk.Label(root, text="Enne põlengut arvestatav päevade arv (põlengu
päev kaasaarvatud)")
number_of_days_label.grid(row=3, column=0, padx=10, pady=5)

number_of_days_entry = tk.Entry(root)
number_of_days_entry.grid(row=3, column=1, padx=10, pady=5)

# Textbox for file name
file_to_write_label = tk.Label(root, text="Faili nimi")
file_to_write_label.grid(row=4, column=0, padx=10, pady=5)

file_to_write_entry = tk.Entry(root)
file_to_write_entry.grid(row=4, column=1, padx=10, pady=5)

# Submit button
submit_button = tk.Button(root, text="Arvuta", command=submit)
submit_button.grid(row=5, column=0, columnspan=2, pady=10)

# Create a progressbar widget
progress_UI = ttk.Progressbar(root, orient="horizontal", length=160, maximum=100)
progress_UI.grid(row=6, column=0, columnspan=2, pady=10)

root.mainloop()

```