



EESTI MAAÜLIKOOL
Metsanduse- ja inseneeria instituut

Gerli Kangur

**TALLINNA KÜLMASAARTE KAARDISTAMINE
KAUGSEIRE ANDMETE PÕHJAL**

MAPPING URBAN COLD ISLANDS IN TALLINN USING
REMOTE SENSING DATA

Magistritöö
Geodeesia, kinnisvara- ja maakorralduse õppekava

Juhendaja: kaasprofessor Aive Liibusk, *PhD*

Tartu 2026

Eesti Maaülikool Kreutzwaldi 1, Tartu 51006		Magistritöö lühikokkuvõte	
Autor: Gerli Kangur		Õppekava: Geodeesia, kinnisvara- ja maakorraldus	
Pealkiri: Tallinna külmasaarte kaardistamine kaugseire andmete põhjal			
Lehekülgi: 84	Jooniseid: 12	Tabeleid: 3	Lisasid: 7
ETIS-e valdkond ja CERCs-i kood: 4.15. Ehitus- ja kommunaaltehnika (maakorraldus); Linna ja maa planeerimine S240 Juhendaja: Aive Liibusk, PhD Osakond või õppetool: Maakorralduse ja geodeesia õppetool Kaitsmiskoht ja -aasta: Tartu, 2026			
Linnade laienedes muutuvad linnaruumi mikrokliima tingimused, eriti tiheasustusega aladel üha olulisemaks. Arvestatakse nende otsest mõju inimeste heaolule ja elukeskkonna kvaliteedile. Linnakeskkonnas põhjustab linnasoojussaare efekt kõrgemaid maapinna temperatuure tihedalt hoonestatud piirkondades, samas kui rohealade ja veekogude ümbruses võivad kujuneda jahedamad piirkonnad ehk külmasaared. Varasemad uuringud on näidanud, et taimestik ja veekogud mõjutavad linnakeskkonna temperatuuritingimusi ning võivad aidata leevendada linnasoojenemise mõju. Magistritöö eesmärk oli kaardistada Tallinna külmasaared kaugseire andmete põhjal ning teha järeldusi nende seoste kohta taimestiku ja maakasutusega. Uuringus kasutati <i>Landsat 8</i> satelliitandmetest saadud pinnatemperatuuri (LST) ning <i>Sentinel-2</i> andmetest arvatud normaliseeritud erinevuse taimkatte indeksit (NDVI). Analüüs viidi läbi <i>Google Earth Engine</i>’i ja <i>ArcGIS Pro</i> keskkondades, kus külmasaared määrati <i>z-skoori</i> meetodi abil ning ruumilist seost hinnati taimkatte ja katastriüksuste maakasutuse sihtotstarvete põhjal. Tulemused kinnitasid, et Tallinna külmasaared paiknevad peamiselt rohealadel, metsasemates piirkondades ning veekogude läheduses. Kõige selgemini eristusid Ülemiste järve, Pirita ja Tallinna läänerranniku ümbruse alad. Tihedalt hoonestatud kesklinnas esines külmasaari vähem ning need olid üldjuhul väiksema ulatusega. Samuti ilmnes, et suurema taimkatte osakaaluga aladel kujunesid tugevamad ja ulatuslikumad külmasaared. Lisaks selgus, et külmemate temperatuuride kujunemist mõjutavad koos taimkattega ka hoonestuse tihedus, pinnakatted ja veekogud. <i>Downscaling</i>-meetod osutus ebaefektiivseks ning modelleeritud temperatuurirastrid ei võimaldanud usaldusväärselt määrata statistiliselt olulisi külmasaari. Uuringu tulemused kinnitavad kaugseire andmete rakendatavust linnakeskkonna temperatuurimustrite hindamisel ning näitavad, et külmasaarte analüüsi saab kasutada sisendina linnakliimaga kohanemise ja ruumilise planeerimise protsessides. Tulevikus võiks külmasaarte analüüsi täiendada temperatuuri kontaktmõõtmistega, et valideerida kaugseire põhjal saadud tulemusi ning hinnata täpsemalt linnaruumi erinevate elementide mõju temperatuurimustrite kujunemisele.			
Võtmesõnad: külmasaared, kaugseire, maapinna temperatuur (LST), NDVI, z-skoor			

Estonian University of Life Sciences Kreutzwaldi 1, Tartu 51006		Abstract of Master's Thesis	
Author: Gerli Kangur		Curriculum: Land Surveying, Property and Land Management	
Title: Mapping urban cold islands in Tallinn using remote sensing data			
Pages: 84	Figures: 12	Tables: 3	Appendices: 7
ETIS research field and (CERCS) code: 4.15. Construction and Municipal Engineering (land management); Town and country planning S240 Supervisor: Aive Liibusk, PhD Department / Chair: Chair of Land Management and Geodesy Place and year of defence: Tartu, 2026			
As cities expand, urban microclimatic conditions, especially in densely populated areas, are becoming increasingly important due to their direct impact on human well-being and the quality of the living environment. In urban areas, the urban heat island effect causes higher land surface temperatures in densely built-up areas, while cooler areas, known as urban cold islands, may develop around green spaces and water bodies. Previous studies have shown that vegetation and water bodies influence urban temperature conditions and may help mitigate the effects of urban warming. The aim of this master's thesis was to map urban cold islands in Tallinn using remote sensing data and to analyse their relationships with vegetation and land use. The study used land surface temperature (LST) derived from Landsat 8 satellite data, as well as the Normalized Difference Vegetation Index (NDVI) calculated from Sentinel-2 data. The analysis was carried out in the Google Earth Engine and ArcGIS Pro environments, where cold islands were identified using the z-score method and their spatial relationships were assessed based on vegetation and cadastral land-use purposes. The results showed that Tallinn's urban cold islands are mainly located in green areas, forested regions, and near water bodies. The most distinct cold islands were identified around Lake Ülemiste, Pirita, and the western coastal areas of Tallinn. In the densely built-up city centre, cold islands occurred less frequently and were generally smaller in extent. The results also indicated that areas with a higher proportion of vegetation tended to form stronger and more extensive cold islands. In addition, the formation of cooler temperature conditions was influenced not only by vegetation, but also by building density, surface materials, and water bodies. The downscaling method proved to be ineffective, and the modelled temperature rasters did not allow reliable identification of statistically significant cold islands. The results of the study confirm the applicability of remote sensing data for assessing urban temperature patterns and demonstrate that cold island analysis can serve as an input for urban climate adaptation and spatial planning processes. In the future, the analysis of urban cool islands could be enhanced by incorporating local temperature measurements to validate results obtained from remote sensing and to more accurately assess the influence of different urban spatial elements on the formation of temperature patterns.			
Keywords: urban cold islands, remote sensing, land surface temperature (LST), NDVI			

SISUKORD

SISSEJUHATUS	6
1. KIRJANDUSE ÜLEVAADE	8
1.1. Linnakliima ja külmasaare mõiste	8
1.2. Külmasaared ruumilises planeerimises.....	9
1.3. Kaugseire andmete kasutamine linnakliima uurimisel	11
1.3.1. Optilised sensorid külmasaarte tuvastamisel	11
1.3.2. Termilised sensorid külmasaarte tuvastamisel	11
1.3.3. Kaugseireandmete töötlemine pilvepõhistes keskkondades ja nende integreerimine GIS-süsteemidega.....	13
1.4. Satelliitandmed linnakliima analüüsimisel	13
1.5. Temperatuuri ja taimekatte näitajad	15
1.5.1. Maapinna temperatuur linnakeskkonnas	15
1.5.2. Normaliseeritud vegetatsiooniindeksi ja maapinna temperatuuri vaheline seos	16
1.6. Külmasaarte kaardistamise meetodid varasemates uuringutes.....	18
2. METOODIKA	21
2.1. Uurimispiirkond.....	21
2.2. Kasutatud andmed	21
2.2.1. Maapinnatemperatuuri arvutamine.....	21
2.2.2. NDVI arvutamine	23
2.3. Külmasaarte tuvastamine	23
2.4. Maapinnatemperatuuri ruumilise lahutuse parandamine (<i>downscaling</i>).....	24
2.5. Külmasaarte ja NDVI võrdlus	24
2.6. Statistiline analüüs	25
3. TULEMUSED JA ARUTELU	26
3.1. Maapinna temperatuuri põhjal määratud külmasaared Tallinnas	26
3.2. Maapinna temperatuuri standardiseeritud hälvete põhjal määratud külmasaared Tallinnas	30
3.3. Normaliseeritud taimkatte indeksi ja külmasaarte vaheline seos	37
3.4. <i>Downscaling</i> -analüüsi tulemused	40
3.5. Külmasaarte seos katastriüksuste sihtotstarvetega	41
KOKKUVÕTE	45
ALLIKALOEND.....	47
LISAD	51
Lisa 1. <i>Google Earth Engine</i> (GEE) skript Tallinna maapinnatemperatuuri (LST), külmasaarte ja NDVI analüüsiks 2025. aasta suveperioodil	52
Lisa 2. <i>ArcGIS Pro</i> keskkonnas koostatud regressioonianalüüsi (<i>OLS</i>) väljundid 2021. aasta kohta	54
Lisa 3. <i>ArcGIS Pro</i> keskkonnas koostatud regressioonianalüüsi (<i>OLS</i>) väljundid 2022. aasta kohta	60
Lisa 4. <i>ArcGIS Pro</i> keskkonnas koostatud regressioonianalüüsi (<i>OLS</i>) väljundid 2023. aasta kohta	66
Lisa 5. <i>ArcGIS Pro</i> keskkonnas koostatud regressioonianalüüsi (<i>OLS</i>) väljundid 2024. aasta kohta	72

Lisa 6. <i>ArcGIS Pro</i> keskkonnas koostatud regressioonianalüüsi (<i>OLS</i>) väljundid 2025. aasta kohta	78
Lisa 7. Lihtlitsents lõputöö salvestamiseks ja üldsusele kättesaadavaks tegemiseks ning juhendaja(te) kinnitus lõputöö kaitsmisele lubamise kohta	84

SISSEJUHATUS

Linnade tihenedes muutub järjest olulisemaks see, millised on linnaruumi mikrokliima tingimused, sest need mõjutavad otseselt inimeste igapäevast elukeskkonda ja heaolu. Linnapiirkondades esineb sageli linnalise soojussaare efekt, mille puhul on temperatuur tihedalt hoonestatud aladest ümbritsevatest piirkondadest kõrgem. Samal ajal leidub linnas ka jahedamaid alasid ehk külmasaari, kus maapinna temperatuur on ümbritsevast linnakeskkonnast madalam. Sellised piirkonnad paiknevad enamasti rohealade, veekogude või hõredama hoonestusega aladel ning aitavad vähendada kuumusest tingitud mõju linnakeskkonnas.

Külmasaared aitavad leevendada linnades soojussaare efekti ning parandada linnakeskkonna mikrokliimat. Eestis on külmasaari uuritud pigem vähe ning ka ruumilises planeerimises neid tavaliselt ei käsitleta. Viimastel aastatel on erinevates riikides külmasaarte kaardistamisel üha enam kasutatud kaugseireandmeid ja geoinfosüsteeme, mis võimaldavad analüüsida linnaruumi temperatuuriandmeid ning nende seoseid taimkatte ja maakasutusega.

Magistritöö eesmärk on kaardistada Tallinna linnas esinevaid külmasaari kaugseireandmete põhjal ning hinnata nende seoseid taimkatte ja maakasutusega. Töö keskendub külmasaarte ruumilise paiknemise, neid mõjutavate tegurite ning nende võimaliku rakendatavuse analüüsimisele linnaplaneerimises. Töös kasutatakse *Landsat 8* ja satelliitandmete põhjal arvutatud maapinna temperatuuri (LST) ning *Sentinel-2* andmetest tuletatud NDVI väärtusi. Analüüs viiakse läbi *Google Earth Engine*'i ja *ArcGIS Pro* keskkondades, et hinnata, millised linnaruumi elemendid on seotud jahedamate piirkondade kujunemisega.

Magistritöös otsitakse vastuseid järgmistele uurimisküsimustele:

Kus paiknevad Tallinna linnas peamised külmasaared ning millised on nende ruumilised mustrid?

Milline on külmasaarte seos taimkatte (NDVI) ja maakasutusega?

Kuidas võimaldavad kaugseireandmed ja kasutatud analüüsimeetodid toetada külmasaarte arvestamist ruumilises planeerimises?

Töö tulemuste paremaks visualiseerimiseks loodi veebirakendus, mis võimaldab kasutajal interaktiivselt vaadelda Tallinna külmasaarte paiknemist ja uuringus kasutatud ruumiandmeid. Veebirakendus on kättesaadav aadressil: <https://experience.arcgis.com/template/5c4c9a70bcd74b7996f9092b0513265b>.

Magistritöös on kasutatud rahvusvahelist APA 7. viitamisstiili. Töö keelelisel toimetamisel ja tekstiliste sõnastuste parandamisel kasutati tehisaru põhiseid tööriistu. Kõik töö sisulised analüüsid, tulemused ja järeldused koostas töö autor iseseisvalt.

1. KIRJANDUSE ÜLEVAADE

1.1. Linnakliima ja külmasaare mõiste


Kõige väiksemaks linnakliima tasandiks peetakse mikrokliimat, mis kirjeldab kohalikke temperatuuri-, niiskus- ja tuuleolusid näiteks tänava või kvartali kaupa (J. Li et al., 2022). Kuna hoonestus, teekatted ja vähene taimkate muudavad õhu liikumist linnakeskkonnas, siis temperatuur ja õhuniiskus võivad erineda ümbritsevatest aladest. Uuringud on näidanud, et linnaruumi struktuur mõjutab oluliselt välisõhu temperatuuri ja kohaliku mikrokliima kujunemist (Dyce & Voogt, 2018; Xiang et al., 2023).

Üks tuntuim linnakliima avaldumise vorm on kuumasaare efekt, mis tähendab, et selles piirkonnas on pinnatemperatuur kõrgem ülejäänud piirkonnas ja see tähendab, et seda on ka õhutemperatuur (Abimbola et al., 2025). Lisaks kuumasaartele on oluline tähelepanu pöörata ka jahedamatele osadele ehk külmasaartele, need on seotud avatud ruumide ja rohealadega, millel on linnakeskkonnas jahutav mõju (Aram et al., 2019).

Linna külmasaare efekt kirjeldab nähtust, kus pargid, rohealad ja muud suurema taimkattega alad on ümbritsevast linnakeskkonnast madalama temperatuuriga ning need toimivad seetõttu jahutavate piirkondadena (J. Wang et al., 2025). Külmasaarte kujunemist mõjutavad taimkate, haljastus ja peegeldusvõime muutused (Bowler et al., 2010). Külmasaared on otseselt seotud soojusaare efektiga, mis kirjeldab linnade kõrgemat temperatuuri võrreldes ümbritseva piirkonnaga (Stewart & Oke, 2012). Soojusaared tekivad peamiselt hoonestuse, tiheasustuse ja soojuse akumulatsiooni tulemusena, aga külmasaared on vastupidine nähtus, kus looduslikud või poollooduslikud alad toimivad jahutavate elementidena linnakeskkonnas (Bowler et al., 2010; *Soojusaarte kaardirakendus*, s.a.). Seega aitavad külmasaared ühtlustada linnakeskkonna temperatuuri ning parandada elukeskkonna mugavust.

Linnakeskkonnas kujunevad külmasaared erinevate tegurite koosmõjul, mille hulka kuuluvad taimkate, veekogud, linnaruumi ülesehitus ja kohalikud mikrokliima tingimused (Bouketta, 2023). Rohealad, mis on suurem pindalaga on pigem madalama pinnatemperatuuriga, kuid keerukas ruumiline kuju võib jahutavat efekti vähendada, samuti mõjub ka killustunud kujuga haljasalad (Cai et al., 2023). Lisaks on leitud, et veekogudel on

võrreldes rohealadega tugevam ja ulatuslikum jahutav mõju, seega on need külmasaarte kujundamisel olulised elemendid (Liu et al., 2025).



Joonis 1. Külmasaare efekti kujunemine linnakeskkonnas. *Allikas:* Kohandatud (Zhang et al., 2025) põhjal.

Joonisel 1 kujutatud skeem illustreerib külmasaare efekti kujunemise üldpõhimõtteid linnakeskkonnas. Külmasaared tekivad piirkondades, kus taimkatte ja veekogude osakaal on suurem ning kus aurumise, varjutuse ja väiksema soojussalvestuse tõttu on maapinna temperatuur madalam. Seevastu tihedalt hoonestatud aladel ja suure tehispindade osakaaluga piirkondades akumuleerub rohkem soojust, mistõttu kujunevad kõrgema temperatuuriga alad ehk soojussaared.

1.2. Külmasaared ruumilises planeerimises

Rohealad, mis on hästi ühendatud pakuvad tõhusamat jahutust kui eraldatud või killustunud rohkealad ehk rohealade sidusus toetab jahutava mõju efekti (Han et al., 2023; Kicovic et al., 2019). Seetõttu ei ole ruumilises planeerimises oluline ainult üksikute rohealade olemasolu, vaid ka nende ruumiline paiknemine ja et nad oleks omavahel ühendatud linnastruktuuris. Omavahel seotud külmasaared ja rohealad saavad moodustada jahutuskoridore, mille kaudu jahedam õhk liigub tihedamalt hoonestatud alade suunas ning

aitab vähendada temperatuuride erinevusi linnaruumi eri osade vahel (Bowler et al., 2010; Stewart & Oke, 2012).

Külmasaarte efektiivsus sõltub külmasaare morfoloogilistest omadustest, näiteks pindalast, kujust ja paiknemisest. Efektiivsema jahutava efekti suudavad tekitada suuremad ja kompaktsemad alad (Sun et al., 2020). Jahutava mõju tugevust mõjutab ka ümbritsev linnastruktuur, sest tihe hoonestus ja suur kõvakatte osakaal võivad suurendada soojuse akumulatsiooni ning seetõttu ei ole rohealade jahutav mõju eriti efektiivne (Ouyang et al., 2025). Seetõttu tuleb planeerimisel arvestada lisaks rohealade olemasolule ka nende seost ümbritseva linnaruumiga. Biofüüsikalised omadused mõjutavad külmasaarte kujunemist, eelkõige vee aurustumine ja varjutus. Taimkate vähendab pinnatemperatuuri vee aurustumise kaudu ning piirab päikese kiirguse otsest mõju maapinnale. Puud ja kõrgem haljastus loovad varju ning aitavad vähendada soojuse akumulatsiooni linnakeskkonnas (Bowler et al., 2010; J. Li et al., 2022). Lisaks võivad veekogud soodustada lokaalsete jahedamate tsoonide kujunemist ning mõjutada ümbritseva ala termilisi tingimusi (Sun et al., 2020).

Ruumilises planeerimises peetakse külmasaari üheks oluliseks linnade kliimakohanemise meetmeks. Nende sidumine rohevõrgustikuga aitab vähendada linnasoojussaare mõju ning parandada linnakeskkonna kvaliteeti, eriti kuumadel perioodidel, mil väliruumi termiline mugavus muutub oluliseks (Abimbola et al., 2025). Rohe- ja sinivõrgustiku elemente ei käsitleta enam eraldiseisvate objektidena. Üha rohkem rõhutatakse nende omavahelist ühendatust ja ruumilist sidusust, sest hästi seotud rohealad ja veekogud suudavad linnakeskkonda tõhusamalt jahutada (Kong et al., 2014; Sun et al., 2020). Külmasaarte hindamine ja planeerimisotsustesse integreerimine põhineb üha enam kaugseireandmete ja geoinfosüsteemide kasutamisel. Maapinna temperatuuri (LST – *land surface temperature*) ja taimkatte (NDVI – *Normalized Difference Vegetation Index*) analüüs võimaldab hinnata jahedamate alade paiknemist ning nende seoseid maakasutuse ja linnastruktuuriga (Ermida et al., 2020). Magistritöös kasutatakse seda lähenemist Tallinna külmasaarte tuvastamiseks ning nende rolli analüüsimiseks linnaruumi kliimakohanemises ja ruumilises planeerimises.

1.3. Kaugseire andmete kasutamine linnakliima uurimisel

1.3.1. Optilised sensorid külmasaarte tuvastamisel

Optilised kaugseiresensorid registreerivad maapinnalt peegelduvat elektromagnetilist kiirgust erinevates spektripiirkondades, eelkõige nähtava valguse, lähi-infrapuna (NIR – *near-infrared*) ja lühilainelise infrapuna (SWIR – *Short-Wave Infrared*) vahemikus. Kuna erinevatel pinnakatetel on iseloomulikud spektraalsed omadused, saab nende andmete põhjal eristada taimkatet, maakasutust ja linnaruumi struktuuri (Amani et al., 2020).

Enamik optilisi sensoreid toimib passiivsete kaugseiresüsteemidena, registreerides Maa pinnalt peegelduvat päikesekiirgust erinevates spektrikanalites (Phiri et al., 2020). Optiliste kaugseireandmete abil on võimalik analüüsida linnaruumi struktuuri, maakasutust ja erinevaid pinnakatte tüüpe, mille pärast kasutatakse neid andmeid linnakeskkonna ruumilistes analüüsides (Xue & Su, 2017). Paljud optilised satelliitsensorid on ühtlasi multispektraalsed, kuna need salvestavad andmeid mitmes erinevas spektrikanalis korraga. Sellised multispektraalsed andmed võimaldavad samaaegselt hinnata nii pinnakatte omadusi kui ka linnakeskkonna biofüüsikalisi näitajaid (Amani et al., 2020).

Multispektraalsete andmete põhjal arvutatakse sageli erinevaid vegetatsiooniindekseid, millest üks levinumaid on normaliseeritud vegetatsiooniindeks ehk NDVI, mis põhineb punase ja lähi-infrapuna spektri peegelduste suhtel (Xue & Su, 2017). NDVI võimaldab hinnata taimkatte olemasolu, tihedust ja seisundit ning seda kasutatakse laialdaselt linnakeskkonna kaugseireanalüüsides (Phiri et al., 2020). Varasemad teadustööd on näidanud, et kõrgemad NDVI väärtused on üldjuhul seotud madalama maapinna temperatuuriga, kuna taimestik mõjutab linnaruumi temperatuuri tingimusi evapotranspiratsiooni ja varjutuse kaudu (Guha et al., 2020).

1.3.2. Termilised sensorid külmasaarte tuvastamisel

Lisaks optilistele andmetele kasutatakse linnade termiliste omaduste ja külmasaarte uurimisel termilise infrapuna sensoreid, mis mõõdavad Maa pinnalt kiirguvat soojusenergiat ning võimaldavad arvutada maapinna temperatuuri ehk LST (Roy et al., 2014, (Z. Li et al., 2023)). Satelliitkaugseire võimaldab mõõta Maa pinnalt kiirguvat soojusenergiat termilise infrapuna spektri kaudu ning hinnata pinnatemperatuuri ruumilist jaotust erinevatel ruumilistel ja ajalistel skaaladel (Z. Li et al., 2023).

Linnakeskkonnas kujunevad temperatuurimustrid erinevate pinnakatete termiliste omaduste tõttu. Kõvakattega ja tihedalt hoonestatud alad salvestavad ja kiirgavad soojust erinevalt võrreldes rohealade ja veekogudega, mille tulemusena tekivad linnades ruumilised temperatuurierinevused (Bowler et al., 2010). Urbaniseerumine muudab pinnakatte omadusi ning vähendab vee aurumist, mis omakorda mõjutab linnade termilist keskkonda ja soodustab kuumasaarte kujunemist (Zhou et al., 2018). Vegetatsioon mõjutab linnakeskkonna temperatuuri peamiselt varjutuse ja vee aurumise ehk evapotranspiratsiooni kaudu. Taimkate kasutab osa päikese kiirgusest vee aurustamiseks ning vähendab seeläbi maapinna kuumenemist (Bowler et al., 2010). Mitmed uuringud on näidanud negatiivset seost NDVI ja maapinna temperatuuri vahel, mille kohaselt suurema taimkatte osakaaluga aladel esineb üldjuhul madalam pinnatemperatuur (Anand et al., 2025). Anand jt (2025) leidsid Landsat 8 andmete põhjal statistiliselt olulise pöördvõrdelise seose NDVI ja LST vahel, kus korrelatsioonikordajad olid 2013. aastal $-0,481$ ja 2022. aastal $-0,426$, mis viitab sellele, et taimkatte vähenemine ja linnastumise intensiivistumine võivad kaasa aidata maapinna temperatuuri tõusule ning linnade termilise keskkonna muutumisele.

Satelliitpõhised termilised kaugseireandmed võimaldavad uurida linnade termilist keskkonda erinevatel ruumilistel ja ajalistel skaaladel. Kõige sagedamini kasutatakse selleks Landsat ja MODIS andmestikke, kuna need võimaldavad hinnata maapinna temperatuuri ning analüüsida linnade termiliste mustrite muutusi ajas (Zhou et al., 2018). Landsat andmestik on linnauuringutes laialdaselt kasutatav tänu selle suhteliselt kõrgele ruumilisele lahutusvõimele, mis võimaldab detailsemalt analüüsida linnaruumi termilisi erinevusi (D. Zhou et al., 2018, Roy et al., 2014).

Külmasaarte uuringutes kombineeritakse sageli optilisi ja termilisi kaugseireandmeid GIS-põhiste ruumianalüüsi meetoditega. (Amani et al., 2020) Sellise analüüsi abil saab siduda temperatuurimustrid maakasutuse, rohealade, veekogude ja hoonestusega ning hinnata nende mõju linnade termilistele omadustele (Chen et al., 2025). Optiliste ja termiliste satelliitandmete integreeritud kasutamine võimaldab tuvastada piirkondi, kus taimkate ja rohealad aitavad maapinna temperatuuri vähendada ning kujundavad linnakeskkonnas külmasaari (Q. Wang et al., 2024). LST-d käsitletakse olulise näitajana maa-atmosfääri energiavahetuse ja pinnaprotsesside uurimisel ning seda kasutatakse laialdaselt linnade termilise keskkonna ja linnade kuumasaarte analüüsimisel (Z. Li et al., 2023).

1.3.3. Kaugseireandmete töötlemine pilvepõhistes keskkondades ja nende integreerimine GIS-süsteemidega

Kaugseireandmete analüüsil kasutatav on oluline kasutada geoinfosüsteemi (GIS), sest selle abil saab satelliitidelt kogutud andmed muuta ruumiandmeteks, mida on võimalik analüüsida ja kasutada nii planeerimises kui ka keskkonna uurimisel (Singh & Bhadauria, 2024). Kaugseire tehnoloogiad võimaldavad koguda suure ruumilise ulatusega andmeid, mis annavad ülevaate linna ruumilisest jaotusest ning toetavad nende edasist analüüsi GIS-keskkonnas (Zhao et al., 2025). Selliselt kogutud andmed sisaldavad infot näiteks taimkatte, maakatte, niiskuse, temperatuuri ja muude näitajate kohta, mis on olulised linnakeskkonna analüüsimisel (Singh & Bhadauria, 2024).

Google Earth Engine (GEE) võimaldab töödelda suuri kaugseireandmete kogumeid pilvekeskkonnas, kasutades erinevaid satelliidiandmeid ning teostades analüüsi ilma arvutusressurssi kasutamata (Singh & Bhadauria, 2024). GEE keskkonnas on võimalik arvutada maapinna temperatuuri (LST) Landsati andmete põhjal, kasutades selleks avatud lähtekoodiga algoritme, näiteks Ermida et al. (2020) poolt välja töötatud lahendust (Ermida et al., 2020; *Google Earth Engine*, s.a.).

1.4. Satelliitandmed linnakliima analüüsimisel

Satelliitandmetel on käesolevas magistritöös oluline roll Tallinna linnakliima analüüsimisel, kuna need aitavad hinnata linnaruumi termilisi ja biofüüsikalisi omadusi kogu linna ulatuses ja ühtsel viisil. Erinevalt üksikutest maapealsetest mõõtepunktidest võimaldavad satelliitandmed analüüsida pinnatemperatuuri ja taimkatte ruumilist varieeruvust terviklikult, mis on vajalik külmasaarte tuvastamiseks ning nende seostamiseks linnaruumi struktuuri ja maakasutusega. Linnakeskkonnas ei jaotu temperatuur ühtlaselt, vaid sõltub muu hulgas hoonestuse tihedusest, maakatte omadustest, rohealade paiknemisest, veekogude olemasolust ning linnaruumi morfoloogiast (Stewart & Oke, 2012; Zhou et al., 2014).

Magistritöös kasutatakse külmasaarte kaardistamiseks satelliitandmete põhjal saadud LST ning NDVI väärtusi. LST abil saab hinnata linnaruumi termilisi erinevusi ning tuvastada piirkondi, kus pinnatemperatuur on ümbritsevast keskkonnast kõrgem või madalam (Weng et al., 2004). NDVI kirjeldab taimkatte olemasolu ja tihedust ning võimaldab hinnata vegetatsiooni mõju linnaruumi temperatuurimustritele (Hatfield et al., 2019). Nende

näitajate koosanalüüs võimaldab hinnata, kas jahedamad alad kattuvad suurema taimkattega piirkondadega, näiteks parkide, metsade või muude rohealadega. Varasemates uuringutes on leitud, et suurema vegetatsiooniosakaaluga aladel on üldjuhul madalam pinnatemperatuur, kuna taimkate mõjutab linnakliimat varjutuse ja evapotranspiratsiooni kaudu (Bowler et al., 2010; Guha et al., 2020; Weng et al., 2004).

Satelliitandmete kasutamine aitab analüüsida pikemaajalisi temperatuurimustreid ning vähendada üksikute ilmastikutingimuste mõju analüüsitulemustele. Käesolevas magistritöös kasutatakse Tallinna külmasaarte hindamiseks suveperioodi satelliitandmeid aastatest 2021–2025. Mitmeaastane lähenemine võimaldab hinnata korduvaid ruumilisi mustreid ning eristada püsivamaid külmasaari ajutistest temperatuurianomaaliatest. See lähenemine annab usaldusväärsema aluse külmasaarte paiknemise ja püsivuse hindamiseks ning võimaldab võrrelda linnaruumi termilisi omadusi erinevatel aastatel. Linnakliima uuringutes on mitmeaastaste satelliitandmete kasutamine oluline, kuna temperatuurimustrid võivad muutuda nii ilmastikutingimuste, maakasutuse muutuste kui ka taimkatte seisundi tõttu (Guha et al., 2020; Zhou et al., 2014). *Landsat*-seeria satelliitandmed võimaldavad seejuures pikaajalist ja võrreldavat maapinna temperatuuri analüüsi erinevatel ajaperioodidel (Ermida et al., 2020).

Kaugseireandmete kasutamine on oluline ka ruumilise planeerimise seisukohalt. Kõrgema pinnatemperatuuriga alade tuvastamine võimaldab hinnata piirkondi, kus võib olla vajadus täiendavate kliimakohanemise meetmete järele, näiteks haljastuse suurendamiseks, varjutuse parandamiseks või sinivõrgustiku tugevdamiseks (Santamouris, 2014). Püsivalt jahedamad piirkonnad võivad seevastu toimida linnaruumi külmasaarte ja jahutusaladena, mille säilitamine ja sidumine rohevõrgustikuga aitab parandada linnakeskkonna kliimakindlust (Bowler et al., 2010). Kaugseireandmete ja geoinfosüsteemide kasutamine võimaldab hinnata linnaruumi termilisi ja biofüüsikalisi omadusi ruumiliselt võrreldaval viisil ning toetab andmepõhist ruumilist planeerimist ja kliimakohanemise strateegiate kavandamist (Zhou et al., 2014).

Satelliitandmete kasutamisel tuleb arvestada ka teatud piirangutega. Termiliste andmete kvaliteeti mõjutavad pilvisus, atmosfääritingimused, satelliidi ülelennu aeg ning andmete ruumiline lahutusvõime (Ermida et al., 2020). Lisaks kirjeldab LST maapinna temperatuuri, mitte otseselt inimese tajutavat õhutemperatuuri, mistõttu ei saa seda käsitleda samaväärsena meteoroloogiliste õhutemperatuuri mõõtmistega (Weng et al., 2004). Samuti mõjutavad

termiliste andmete täpsust emissiivsuse määramine ja atmosfäärilised korrektsioonid, mis võivad põhjustada erinevusi satelliitpõhiste temperatuurihinnangute vahel (Z.-L. Li et al., 2013). Sellest hoolimata on LST linnakliima uuringutes laialdaselt kasutatav näitaja, kuna see võimaldab hinnata erinevate pinnakatete soojenemist ning nende mõju linnaruumi termilistele muistritele (Zhou et al., 2014).

1.5. Temperatuuri ja taimekatte näitajad

1.5.1. Maapinna temperatuur linnakeskkonnas

Maapinna temperatuur (LST) on oluline näitaja linnakeskkonna temperatuurimuistrite ja soojusprotsesside hindamisel, mida mõjutavad samaaegselt nii looduslikud kui ka inimtegevusest tulenevad tegurid. Linnades kujuneb temperatuurijaotus pinnakatte omaduste, maakasutuse, taimkatte, veekogude ning linnaruumi morfoloogia koostmõjul. Urbaniseerumise käigus asendatakse looduslikud ja läbilaskvad pinnad asfalt-, betoon- ja teiste kõvakattega materjalidega, mis neelavad ja salvestavad rohkem soojust kui looduslikud pinnad. Selle tulemusena suureneb soojuse akumulatsioon ning väheneb evapotranspiratsioon, mis omakorda soodustab linnasoojussaare (UHI) efekti kujunemist (Cetin et al., 2024; Liu et al., 2025).

LST ruumiline jaotus on tugevalt seotud maakasutuse ja pinnakatte tüübiga. Vegetatsiooniga aladel on pinnatemperatuur üldjuhul madalam kui tihedalt hoonestatud või suure kõvakatte osakaaluga piirkondades, kuna taimestik vähendab temperatuuri varjutuse ja evapotranspiratsiooni kaudu. Uuringud on näidanud, et rohealade jahutav mõju sõltub lisaks nende olemasolule ka taimkatte tihedusest, suurusest, ruumilisest paiknemisest ning ümbritsevast linnastruktuurist (Aram et al., 2019; Yang et al., 2017). Lisaks mõjutavad linnade termilist keskkonda veekogud, mille aurustumisprotsessid ja soojusenergia sidumise võime aitavad temperatuuri stabiliseerida ning vähendada äärmuslikke temperatuurikõikumisi (Gunawardena et al., 2017).

Lisaks rohelinele ja sinisele infrastruktuurile mõjutavad maapinna temperatuuri ka ehitatud keskkonna omadused. Kõrge albeedoga materjalid, näiteks heledad katuse- ja teekattematerjalid, peegeldavad suurema osa päikese kiirgusest tagasi atmosfääri ning vähendavad seeläbi pinnatemperatuuri tõusu. Selliseid lahendusi kasutatakse linnade kliimakohanemise meetmetena, et leevendada linnasoojussaare mõju ning parandada termilist mugavust linnakeskkonnas (Santamouris, 2014; Williams, 2016). Uuringud on

näidanud, et jahutavate materjalide ja kõrge albeedoga pindade mõju sõltub lisaks materjalide omadustele ka linnaruumi morfoloogiast, hoonestuse tihedusest, õhu liikumisest ning nende ruumilisest paiknemisest linnakeskkonnas (Santamouris, 2014; Xiang et al., 2023).

Linnakeskkonna temperatuuritingimusi mõjutab olulisel määral ka hoonestuse ruumiline ülesehitus. Hoonete kõrgus, tihedus ning tänavaruumi geomeetria määravad, kuidas linnas toimub kiirgusvahetus ja õhu liikumine. Tihedalt hoonestatud piirkondades, kus tänavakanjonid on kitsad ja taeva nähtavust iseloomustav näitaja (SVF – *sky view factor*) madal, salvestub soojus tõhusamalt ning selle hajumine atmosfääri on aeglasem. Seevastu avatumates piirkondades võimaldab parem õhuringlus ja suurem rohealade osakaal efektiivsemat soojusvahetust, mistõttu on pinnatemperatuurid sageli madalamad. Linnamorfoloogia mõju tõttu võivad temperatuurierinevused kujuneda märkimisväärseks isegi lühikeste vahemaade ulatuses, mistõttu tuleb ruumilises planeerimises arvestada nii hoonestuse struktuuri kui ka rohealade paiknemisega (Quan & Bansal, 2021; Sun et al., 2020).

Maapinna temperatuuri tõusu mõjutab lisaks ka inimtegevusest tulenev soojuskoormus. Liiklus, energiatarbimine, tööstus ning hoonete soojusheide suurendavad soojuse hulka linnakeskkonnas ning võimendavad linnasoojussaare (UHI – *urban heat island*) efekti. Eriti oluline on antropogeense soojuse roll tihedalt hoonestatud piirkondades, kus suur energiatarbimine ja piiratud õhuringlus soodustavad soojuse akumulatsiooni linnakeskkonnas. Linnasoojussaare mõju võib kuumalainete ajal veelgi tugevneda, kuna antropogeense soojuse emissioonid ja jahutusvajadus suurenevad samaaegselt (Zhao et al., 2018). Kõrgemad temperatuurid mõjutavad omakorda inimeste heaolu, suurendavad hoonete jahutusvajadust ning tõstavad energiatarbimist linnades (Litardo et al., 2020). Seetõttu käsitletakse linnasoojussaare leevendamist üha enam olulise kliimakohanemise meetmena, mille eesmärk on parandada linnade termilist keskkonda ja vastupanuvõimet kliimamuutustele.

1.5.2. Normaliseeritud vegetatsiooniindeksi ja maapinna temperatuuri vaheline seos

NDVI on üks kõige rohkem kasutatud kaugseireindekseid taimkatte tiheduse hindamiseks. NDVI arvutatakse punase ja lähi-infrapuna spektri peegelduste suhtena ning selle eesmärk on rõhutada vegetatsiooni spektraalseid omadusi võrreldes teiste maapinnakatetega (Huang

et al., 2021). Vegetatsiooniindeksite kasutamine võimaldab hinnata taimkatte biomassi, lehepindala, klorofüllis sisaldust ja vegetatsiooni üldist seisundit erinevate satelliitsensorite abil (Hatfield et al., 2019). NDVI on laialdaselt kasutatav, sest seda saab rakendada erinevate multispektraalsete sensorite puhul, sealhulgas *Landsat*, MODIS ja Sentinel andmestikel (Huang et al., 2021). Tänapäeval kasutatakse NDVI indeksit ulatuslikult linnakeskkonna analüüsides, kuna vegetatsioon mõjutab otseselt maapinna energiabilanssi ja termilisi protsesse (Anand et al., 2025). Linnades aitab taimkate vähendada maapinna kuumenemist läbi varjutuse ning evapotranspiratsiooni protsesside, mille käigus kasutatakse osa soojusenergiast vee aurustamiseks (Norton et al., 2015).

Maapinna temperatuuri ja NDVI vaheline seos on kaugseire uuringutes üks enim käsitletud linnakliima teemasid. Mitmed uuringud on näidanud, et kõrgemate NDVI väärtustega piirkondades esinevad üldjuhul madalamad pinnatemperatuurid, mis viitab vegetatsiooni jahutavale mõjule linnakeskkonnas (Anand et al., 2025). Vegetatsioon vähendab päikesekiirguse otsest mõju maapinnale ning parandab niiskusraja, mille tulemusena kujunevad rohealadel sageli ümbritsevast linnakeskkonnast madalama temperatuuriga piirkonnad (Norton et al., 2015). Anand jt (2025) analüüsisid *Landsat 8* andmete põhjal NDVI ja LST vahelist seost India Mohali piirkonnas ning tuvastasid statistiliselt olulise negatiivse korrelatsiooni NDVI ja maapinna temperatuuri vahel. Uuringus saadud korrelatsioonikordajad olid 2013. aastal $-0,481$ ja 2022. aastal $-0,426$, mis näitasid, et taimkatte vähenemine oli seotud kõrgemate pinnatemperatuuridega (Anand et al., 2025). Autorid rõhutasid, et rohealade säilitamine ja suurendamine on oluline linnade termilise keskkonna stabiliseerimiseks ning kliimamuutustega kohanemiseks.

Vegetatsiooni mõju linnade termilistele tingimustele on oluline nii mikrokliima kujunemisel kui ka inimeste soojusliku heaolu parandamisel (Anand et al., 2025). Lisaks linnakliima uuringutele kasutatakse NDVI-d laialdaselt ka põllumajanduses, metsanduses ja ökosüsteemide seires, kuna indeks võimaldab hinnata vegetatsiooni ruumilist ja ajalist dünaamikat (Hatfield et al., 2019). NDVI populaarsus tuleneb selle lihtsusest, heast võrreldavusest erinevate sensorite vahel ning võimalusest analüüsida suuri alasid ajas muutuvate satelliitandmete põhjal (Huang et al., 2021). Kuigi NDVI on üks enim kasutatavaid vegetatsiooniindekseid, kaasnevad selle kasutamisega ka teatud piirangud. Huang jt (Huang et al., 2021) toovad välja, et NDVI väärtusi võivad mõjutada atmosfäärilised tingimused, sensorite kalibreerimine ning küllastumise efekt suure biomassiga piirkondades. Samuti võib tiheda taimkatte korral väheneda NDVI tundlikkus vegetatsiooni

muutuste suhtes, mistõttu tuleb tulemuste tõlgendamisel arvestada kasutatud andmete ja meetoodika eripäradega (Huang et al., 2021).

1.6. Külmasaarte kaardistamise meetodid varasemates uuringutes

Külmasaarte kaardistamise meetodid on arenenud koos satelliitkaugseire ja geoinfosüsteemide tehnoloogilise arenguga. Esialgsed linnade termiliste omaduste uuringud keskendusid peamiselt kuumasaare efektile (UHI) nähtusele, kuid hilisemates uuringutes hakati enam tähelepanu pöörama ka madalama temperatuuriga piirkondade ehk külmasaarte tuvastamisele (Rasul et al., 2017). Külmasaarte uuringutes kasutatakse peamiselt termilise infrapuna kaugseireandmeid, maapinna temperatuuri analüüsi, vegetatsiooniindekseid ning GIS-põhiseid ruumianalüüsi meetodeid (Zhou et al., 2018). Üheks enim kasutatud meetodiks külmasaarte kaardistamisel on LST arvutamine termiliste satelliitandmete põhjal. Selleks kasutatakse peamiselt *Landsati*, MODIS-e ja ASTER-i andmestikke, mille termilised kanalid mõõdavad Maa pinnalt kiirguvat infrapunakiirgust. (Z. Li et al., 2023) *Landsati* andmestik on linnauuringutes eriti levinud tänu selle suhteliselt kõrgele ruumilisele lahutusvõimele, mis võimaldab detailsemalt hinnata linnasiseseid temperatuurierinevusi (Zhou et al., 2018). *Landsat Collection 2 Level-2* andmestik sisaldab atmosfäärikorreksiooniga pinnatemperatuuri andmeid, mida kasutatakse laialdaselt linnade termiliste omaduste analüüsimisel (United States Geological Survey, s.a.).

Temperatuurianomaaliade hindamiseks standardiseeritakse LST-väärtusi sageli z-koori meetodi abil, mis näitab iga piksli kõrvalekallet uurimisala keskmisest temperatuurist (Guerri et al., 2021). Selline meetod võimaldab objektiivsemalt tuvastada piirkondi, mille temperatuur erineb oluliselt ümbritsevast linnakeskkonnast. Jimenez jt (Jimenez et al., 2018) kasutasid temperatuurianomaaliade tuvastamiseks standardiseeritud temperatuuriväärtusi (z-skoor), mille abil klassifitseeriti termilised anomaaliad mõõdukateks, tugevateks ja ekstreemseteks. Külmasaarte puhul viitavad negatiivsed z-skoori väärtused keskmisest madalama temperatuuriga piirkondadele ning suurema absoluutväärtusega negatiivne z-skoor osutab tugevamale temperatuurianomaaliale. *Getis-Ord Gi** statistika tõlgendamisel kasutatakse sageli standardnormaaljaotuse kriitilisi väärtusi, kus z-väärtused $-1,65$, $-1,96$ ja $-2,58$ vastavad vastavalt 90%, 95% ja 99% usaldusnivoo piiridele. Mida negatiivsem on z-skoori väärtus, seda suurema statistilise olulisusega on madala temperatuuriga piirkond. (Azmi et al., 2021; Zargari et al., 2024)

Lisaks maapinna temperatuuri analüüsile kasutatakse külmasaarte kaardistamisel sageli vegetatsiooniindekseid, eriti NDVI-d. NDVI põhineb punase ja lähi-infrapuna spektri peegelduste suhtel ning võimaldab hinnata taimkatte olemasolu, seisundit ja tihedust satelliitandmete põhjal (Huang et al., 2021). Varasemates uuringutes kasutatakse NDVI ja LST ühendanalüüsi taimkatte jahutava mõju hindamiseks. Guha jt (Guha et al., 2020) rakendasid *Landsat 8* andmete põhjal NDVI ja LST korrelatsioonianalüüsi Firenze ja Napoli linnades ning leidsid statistiliselt olulise negatiivse seose taimkatte ja maapinna temperatuuri vahel. Anand jt (2025) kasutasid samuti NDVI ja LST ühendanalüüsi ning leidsid, et kõrgemate NDVI väärtustega piirkondades esinesid üldjuhul madalamad temperatuurid.

Maapinna temperatuuri detailsuse parandamiseks kasutatakse statistilist *downscaling*-meetodit, mille eesmärk oli suurendada temperatuurianalüüsi ruumilist lahutusvõimet ning võimaldada detailsemalt hinnata linnakeskkonna temperatuurimustreid (Lu et al., 2025). Meetodi kasutamine oli vajalik, kuna *Landsati* termiliste andmete ruumiline lahutusvõime ei pruugi olla piisav väiksemate temperatuurimustrite ja lokaalsete külmasaarte eristamiseks (Ermida et al., 2020). Meetod põhineb NDVI ja maapinna temperatuuri vahelisel statistilisel seosel, mida on laialdaselt kasutatud linnaliste termiliste mustrite ja kuumasaare efekti analüüsimisel (Chen et al., 2025; Rahimi et al., 2025). Mitmes uuringus on täheldatud, et NDVI ja LST vahel esineb üldjuhul negatiivne korrelatsioon, mille järgi kõrgema taimkattega aladel on madalam maapinna temperatuur (Guha et al., 2020; Rahimi et al., 2025).

Külmasaarte kaardistamisel kasutatakse sageli ka maakasutuse ja pinnakatte klassifitseerimist. Sellistes uuringutes ühendatakse termilised satelliitandmed maakasutuse andmetega, et hinnata erinevate linnaruumi elementide mõju temperatuurile. Ahmad jt (2024) kasutasid *Landsat 9* andmeid koos maakasutuse klassifitseerimisega Delhi linnapiirkonna termiliste mustrite analüüsimiseks. Uuringus võrreldi hoonestatud alade, rohealade, veekogude ja teiste pinnakattetüüpide temperatuurilisi erinevusi ning hinnati urbaniseerumise mõju maapinna temperatuurile. Mitmetes uuringutes kasutatakse GIS-põhiseid ruumianalüüsi meetodeid külmasaarte ruumilise paiknemise ja jahutava mõju hindamiseks. GIS võimaldab ühendada termilisi kaugseireandmeid rohealade, veekogude, hoonestuse ja transpordivõrgustiku andmetega ning analüüsida nende mõju linnade termilistele omadustele. Na jt (2024) uurisid rohealade jahutavat mõju GIS-põhise ruumianalüüsi abil ning leidsid, et rohealade jahutav efekt sõltub nende suurusel, ruumilisest paigutusest ja taimkatte omadustest. Song jt (2025) kasutasid Wuhanis

linnaparkide külmasaare efekti hindamisel *kernel density* analüüsi ja *Thiesseni* polügoone, et määrata parkide jahutava mõju ulatus linnakeskkonnas.

Ajaseeria analüüs on samuti üks levinud külmasaarte kaardistamise meetodeid. Mitmeaastaste satelliitandmete kasutamine võimaldab hinnata temperatuurimuutuste muutumist ajas ning analüüsida urbaniseerumise mõju linnade termilistele omadustele. Šamanović jt kasutasid aastate 2014–2024 *Landsati* andmeid NDVI, NDBI ja LST muutuste analüüsimiseks ning hindasid urbaniseerumise mõju Varaždini piirkonna (Horvaatia) temperatuurimuutustele (Šamanović et al., 2025). Sellised ajaseeria uuringud võimaldavad hinnata rohealade vähenemise, hoonestuse laienemise ja kliimamuutuste mõju linnakeskkonna jahutavale võimekusele. (Šamanović et al., 2025) Viimastel aastatel on külmasaarte kaardistamisel järjest enam kasutatud pilvepõhiseid kaugseireplatvorme, näiteks *Google Earth Engine*'it. Ermida jt töötasid välja *Google Earth Engine*'i põhise avatud lähtekoodiga lahenduse *Landsati* maapinna temperatuuri arvutamiseks. Pilvepõhised platvormid võimaldavad automatiseerida temperatuuride arvutamist ja kombineerida erinevaid satelliitandmeid ning töödelda suuri ajaseeria andmestikke ilma võimsa arvutita (Ermida et al., 2020).

2. METOODIKA

2.1. Uurimispiirkond


Magistritöö eesmärk on kaardistada Tallinna linnas esinevaid külmasaari kaugseireandmete põhjal ning hinnata nende seoseid taimkatte ja maakasutusega. Külmasaared peaksid aitama vähendada soojussaare efekti, mida põhjustavad näiteks hoonestus, kõvakattega pinnad ja vähene haljastus. Tallinnas on piirkondi, kus on rohealad ja veekogud, mis aitavad maapinna temperatuuri madalamana hoida. Selliste piirkondade kaardistamine on oluline, kuna selle abil saab hinnata külmasaarte mõju ning teha ka paremaid otsuseid ruumilises planeerimises.

Uurimisala hõlmab Tallinna mandriosa. Analüüsist jäeti välja Aegna saar, kuna selle hõre hoonestus ning metsane ala erineb oluliselt Tallinna linnalisest keskkonnas. Saare kaasamine oleks võinud mõjutada uurimisala keskmist maapinna temperatuuri ning moonutada z-skoori põhiste külmasaarte tuvastamist

2.2. Kasutatud andmed

2.2.1. Maapinnatemperatuuri arvutamine

Maapinna temperatuuri arvutamiseks kasutati *Landsat 8* termilisi kanaleid. Töö põhines atmosfäärikorreksiooniga *Landsat Collection 2 Level-2* toodetel (2021-2025), mis sisaldavad juba atmosfääriliselt korrigeeritud temperatuuriväärtusi (USGS, 2024). Maapinna temperatuur arvutati *Google Earth Engine*'i keskkonnas. *Google Earth Engine*'is kasutatud skripti näidis 2025. aasta põhjal on Lisas 1 ning kogu töötluse struktuurne skeem joonisel 2.



Joonis 2. Tallinna külmasaarte analüüsis kasutatud *Landsat 8* ja *Sentinel-2* andmete töötlemise etapid *Google Earth Engine*’i keskkonnas.

Maapinna temperatuur teisendati Kelvinist Celsiuse kraadidesse järgmise valemi abil (Ermida et al., 2020):

$$LST(^{\circ}C) = LST(K) - 273.15 \quad (1)$$

Pärast temperatuuriväärtuste arvutamist piirati rasterandmed Tallinna piiri järgi ning eksporditi edasiseks analüüsiks *ArcGIS Pro* keskkonda. Saadud rasterandmete põhjal analüüsiti maapinna temperatuuri ruumilist jaotust ning tuvastati madalama temperatuuriga piirkonnad. Satelliitpõhised LST andmed võimaldavad hinnata linnasiseseid temperatuurierinevusi ning analüüsida erinevate pinnakatete mõju temperatuurile (Cetin et al., 2024).

Analüüsi kaasati suveperioodi (juuni–august) pilvevabad või vähese pilvisusega *Landsat 8* satelliidipildid aastatest 2021–2025. *Landsat 8* LST andmete puhul kasutati moodulis sisalduvat pilvede ja kvaliteedimaski, *Sentinel-2* NDVI andmete puhul rakendati pilvisuse filtrit alla 10%. Kõik rasterandmed reprojekteeriti Eesti riiklikku koordinaatsüsteemi L-EST97 (EPSG:3301), et tagada ruumiandmete omavaheline vastavus ja võrreldavus.

Landsati andmete ruumiline lahutusvõime (30 m) võimaldab analüüsida temperatuurierinevusi linnakeskkonnas detailsemalt ning hinnata rohealade, hoonestatud alade ja teiste pinnakatete mõju maapinna temperatuurile.

2.2.2. NDVI arvutamine

NDVI arvutati *Google Earth Engine*'i keskkonnas, kasutades *Sentinel-2 Level-2A* andmeid. Analüüsis kasutati suveperioodi mediaanpilti, mille põhjal arvutati NDVI Sentinel-2 lähi-infrapunase kanali B8 ja punase kanali B4 alusel. Saadud NDVI raster lõigati Tallinna uurimisala piiriga ning eksporditi edasiseks analüüsiks *ArcGIS Pro* keskkonda. Kasutatud *Google Earth Engine*'i skript on esitatud lisa 7.

$$NDVI = \frac{NIR-RED}{NIR+RED} \quad (2)$$

Valemis tähistab *NIR* lähi-infrapuna kanalit (Sentinel-2 B8), mis on tundlik taimkatte struktuuri ja biomassi peegeldusomaduste suhtes ning *RED* punast kanalit (Sentinel-2 B4), mille kiirgust taimkate fotosünteesi käigus suurel määral neelab.

NDVI väärtused jäävad vahemikku -1 kuni $+1$. Kõrgemad positiivsed väärtused viitavad tihedale ja tervislikule taimkattele ning madalad või negatiivsed väärtused viitavad vähesele vegetatsioonile, hoonestatud aladele, paljale pinnasele või veealadele (Huang et al., 2021). Andmed reprojekteeriti Eesti riiklikku koordinaatsüsteemi L-EST97.

2.3. Külmasaarte tuvastamine

Tallinna külmasaarte tuvastamiseks kasutati LST rasterandmeid, mille põhjal hinnati Tallinna linnas esinevaid temperatuuri anomaaliaid. LST on linnakliima uuringutes laialdaselt kasutatav näitaja, kuna see võimaldab hinnata linnaruumi termilisi erinevusi ning seostada neid maakasutuse, taimkatte, albeedo ja hoonestuse intensiivsusega. (Zhou et al., 2014; Weng et al., 2004) Külmasaarte määramiseks kasutati standardiseeritud temperatuurihälbeid ehk z-skoori väärtusi, mis võimaldavad hinnata temperatuuride statistilist kõrvalekallet uurimisala keskmisest temperatuurist. Klassifikatsiooni piirväärtused põhinesid statistilise olulisuse tasemetel, mida kasutatakse ruumiliste temperatuurianomaaliade analüüsis. Z-skoori väärtused alla $-1,65$ viitavad statistiliselt jahedamatele piirkondadele, kusjuures madalamad väärtused tähistavad tugevamat külmasaare efekti.

$$Z = \frac{X - \mu}{\sigma}, \quad (3)$$

kus X tähistab konkreetse piksli maapinna temperatuuri, μ uuritava piirkonna keskmist maapinna temperatuuri ning σ maapinna temperatuuride standardhälvet. Z-skoori väärtused võimaldavad eristada statistiliselt olulisemaid külmasaari. Negatiivsed z-skoori väärtused viitavad statistiliselt jahedamatele piirkondadele (Zargari et al., 2024).

2.4. Maapinnatemperatuuri ruumilise lahutuse parandamine (*downscaling*)

Analüüsis kasutati *Landsat 8* satelliitandmete põhjal arvutatud LST kihte ning *Sentinel-2* andmete põhjal koostatud 10 m ruumilise lahutusega NDVI rastrit (Ermida et al., 2020). Enne analüüsi reprojekteeriti ühtsesse L-EST97 ristkoordinaatide süsteemi ning interpoleeriti ühtsele pikslisuurusele, et tagada rastrite vastavus ja võrreldavus. Reprojeksiooni tulemusena kujunes NDVI rasteri ruumilahutuseks ligikaudu 7,2 m, mida kasutati ka modelleeritud maapinna temperatuurirastrite koostamisel. NDVI ja maapinna temperatuuri vahelise seose hindamiseks viidi *ArcGIS Pro* keskkonnas läbi regressioonianalüüs, mille sõltuvaks muutujaks oli maapinna temperatuur ning seletavaks muutujaks NDVI raster. Külmasaarte määramiseks arvutati maapinna temperatuuri (LST) rasterite põhjal standardiseeritud temperatuurihälbed ehk z-skoori väärtused, kasutades iga rastri keskmist väärtust ja standardhälvet. Z-skoori analüüsi kasutati temperatuuride kõrvalekallete hindamiseks ning keskmisest madalama temperatuuriga piirkondade ehk külmasaarte tuvastamiseks. Täiendava analüüsina testiti ka *downscaling* meetodit, kuid selle põhjal modelleeritud temperatuurirastrid ei võimaldanud usaldusväärselt määrata statistiliselt olulisi külmasaari.

2.5. Külmasaarte ja NDVI võrdlus

Külmasaarte ja taimkatte vahelise seose hindamiseks võrreldi maapinna temperatuuri Z-skooride põhjal määratud külmasaarte klasse NDVI klassidega. Analüüsi eesmärk oli hinnata, millise taimkatte intensiivsusega piirkondades külmasaared peamiselt paiknesid ning kas kõrgema NDVI väärtusega aladel esines rohkem külmasaari. NDVI väärtused klassifitseeriti madala, mõõduka ja kõrge taimkatte klassidesse. Seejärel võrreldi NDVI klasse külmasaarte klassidega *ArcGIS Pro* keskkonnas, selleks kasutati tööriista *Tabulate Area*. Analüüs võimaldas arvutada, kui suur osa külmasaarte pindalast paiknes erineva taimkatte intensiivsusega piirkondades.

Uuringutes on leitud, et kõrgema NDVI väärtusega aladel esineb üldjuhul madalam maapinna temperatuur ning tugevam jahutav mõju (Guha et al., 2020; Rahimi et al., 2025). Käesolevas töös kasutati seda lähenemist taimkatte mõju hindamiseks Tallinna külmasaarte kujunemisel.


2.6. Statistiline analüüs

Külmasaarte ja maakasutuse vaheliste seoste hindamiseks võrreldi külmasaarte paiknemist Tallinna katastriüksuste sihtotstarvetega. Analüüsi eesmärk oli välja selgitada, millistel sihtotstarvetel esineb külmasaari rohkem ning kuidas erinevad maakasutusviisid võivad mõjutada linnakeskkonna temperatuurierinevusi. Analüüsi käigus võrreldi külmasaarte alasid Tallinna katastriüksuste sihtotstarvetega ning arvutati külmasaarte pindalad erinevate sihtotstarvete lõikes. Lisaks võrreldi külmasaarte pindalasid vastavate sihtotstarvete kogupindaladega, et hinnata külmasaarte osakaalu erinevatel maakasutusliikidel.

3. TULEMUSED JA ARUTELU

3.1. Maapinna temperatuuri põhjal määratud külmasaared Tallinnas

Külmasaarte ruumilise jaotuse analüüsimiseks kaardistati Landsat 8 maapinna temperatuuri andmete põhjal Tallinna linnapiirkonnas esinevad madalama temperatuuriga alad aastatel 2021–2024. Külmasaarte määratlemisel lähtuti maapinna temperatuuride ruumilisest varieeruvusest, et hinnata nende paiknemist ning muutusi eri aastatel. Joonisel 3 on kujutatud Tallinna külmasaarte ruumiline jaotus 2021. – 2024. aasta suviste LST andmete põhjal.




Joonis 3. Tallinna külmasaarte ruumiline jaotus 2021. – 2024. aasta suvise maapinna temperatuuri (LST) põhjal. Külmasaared on ümbritsevast alast vähemalt 2°C madalama temperatuuriga.

Jooniselt 3 on näha, et külmasaarte paiknemine oli aastate lõikes üldjoontes sarnane. Need erinevused võivad olla seotud ilmastikutingimuste, eelkõige õhutemperatuuri, kuumalainete kestuse ning suvise soojusrežiimi muutustega. Külmasaarte määratlemisel käsitleti külmasaarteks piirkondi, mille maapinna temperatuur oli vähemalt 2 °C madalam võrreldes

ümbritsevate alade keskmise temperatuuriga. Külmasaarte suurem koondumine esines valdavalt Tallinna äärealadel ja piirkondades, kus leidub rohkem rohealasid ning veekogusid. Mitmete uuringute järgi suureneb rohealade jahutav mõju nende pindala kasvades, kuid mõju ei sõltu ainult suurusest, vaid ka rohealade ruumilisest paigutusest ja taimkatte omadustest.

Aastate võrdluses võib täheldada, et külmasaarte pindala ja paiknemine varieerusid mõõdukalt. Suuremad külmasaarte alad ilmnesisid eelkõige linna põhja-, ida- ja lõunaosas, samas kui kesketes linnapiirkondades olid külmasaarte alad killustatumad. Tulemused viitavad sellele, et külmasaarte kujunemist mõjutavad eeskätt maakasutuse iseloom, taimkatte olemasolu ning linnaruumi struktuur. Maakasutuse iseloomu all peetakse siin silmas erinevate pinnakasutusviiside jaotust linnakeskkonnas, näiteks tihedalt hoonestatud alasid, rohealasid, metsastunud piirkondi ja veekogude ümbrust. Taimkattega ja looduslike pindadega aladel ilmnesisid külmasaared sagedamini, samas kui tihedama hoonestusega piirkondades oli neid vähem. Näiteks ilmnesisid suuremad külmasaare alad Pirita piirkonnas, Nõmme metsasemates osades ning Harku järve ümbruses, kus ulatuslikum taimkate ja looduslikud pinnad võivad soodustada jahutavat mõju.

Külmasaarte ruumilise paiknemise ning taimkatte võimaliku mõju täpsemaks hindamiseks võrreldi aastatel 2021–2024 määratud külmasaarte paiknemist NDVI põhjal määratud taimkatte klassidega. Taimkate jaotati vähese, mõõduka ja tugeva taimkatte klassidesse, et hinnata, kas külmasaarte paiknemine langeb kokku suurema haljastuse ja rohealadega piirkondades. Joonisel 4 on esitatud külmasaarte paiknemine Tallinnas võrrelduna taimkatte klassidega aastatel 2021–2024.




Joonis 4. 2021.–2024. aasta külmasaarte paiknemine Tallinna linnas võrrelduna NDVI põhjal määratud taimkatte klassidega.

Jooniselt 4 on näha, et külmasaared paiknesid kõigil aastatel valdavalt piirkondades, kus domineeris mõõdukas või tugev taimkate. Kõige ulatuslikumad külmasaarte alad esinesid linna äärealadel ning suuremate rohealade läheduses, samas kui kesklinna ja tihedamalt hoonestatud piirkondades oli külmasaari vähem. Aastate lõikes püsis külmasaarte üldine ruumiline jaotus suhteliselt sarnane, mis viitab sellele, et nende kujunemist mõjutavad eelkõige püsivad linnastruktuuri ja maakasutuse omadused. Samas esines mõningaid erinevusi külmasaarte ulatuses ja paiknemises, mis võivad olla seotud konkreetsete aastate meteoroloogiliste tingimuste ning temperatuurijaotuse erinevustega.

Täiendavalt analüüsiti 2025. aasta tulemusi detailsemalt, et hinnata, kas varasematel aastatel täheldatud ruumilised mustrid on püsivad. 2025. aasta valiti detailsemaks käsitlemiseks, kuna see oli uurimisperioodi viimane aasta ning võimaldas võrrelda pikaajalise analüüsi tulemusi kõige ajakohasemate andmetega. Aastal 2025 suvise maapinna temperatuuri analüüsi põhjal olid külmasaared jätkuvalt koondunud suuremate rohealade ja veekogude ümbrusse. Selgemalt väljendus see Pirita jõe ümbruses, Harku järve lähedastel aladel, Ülemiste järve piirkonnas ning suuremate rohe- ja puhkealade juures. Külmasaarte paiknemine kattus hästi

ka suurema taimkattega aladega, näiteks Kadrioru pargi, Pirita metsasemate alade ning Nõmme–Pääsküla piirkonnaga, kus hoonestus on hõredam ja taimkatte osakaal suurem. Joonisel 5 on esitatud 2025. aasta külmasaarte paiknemine Tallinnas võrrelduna NDVI põhjal määratud taimkatte klassidega.



Joonis 5. Külmasaarte paiknemine Tallinna linnas 2025. aastal võrrelduna NDVI põhjal määratud taimkatte klassidega.


Jooniselt 5 on näha, et külmasaared paiknesid valdavalt Tallinna äärealadel ning piirkondades, kus esineb rohkem rohealasid ja veekogusid. Suuremad külmasaarte alad koondusid peamiselt linna põhja-, lääne- ja lõunaossa, samas kui kesklinna ja tihedamalt hoonestatud piirkondades esines neid vähem. Kogu uurimisala (15 360 ha ilma Aegna saareta) külmasaarte keskmine pindala oli 13,17 ha, kuid kesksetes linnapiirkondades esinenud külmasaared olid üldjuhul väiksemad, jäädes alla 0,5 ha kui äärealadel paiknevad külmasaarte alad.

Tulemused viitavad sellele, et külmasaarte kujunemine on seotud linnaruumi struktuuri, maakasutuse ning taimkatte olemasoluga. Suurema haljastuse ja looduslike aladega

piirkondades avaldus jahutav mõju tugevamalt, samas kui tihedalt hoonestatud aladel oli selline mõju väiksem. Samuti on kõigi aastate külmasaared pigem sarnased.

3.2. Maapinna temperatuuri standardiseeritud hälvete põhjal määratud külmasaared Tallinnas


Maapinna temperatuuri standardiseeritud hälvete ehk z-skoori väärtuste põhjal määrati piirkonnad, kus temperatuur erines ümbritsevast linnaruumist statistiliselt madalama väärtuse poolest. Maapinna temperatuuri ruumiliste klastrite määramiseks kasutati *Getis-Ord Gi** statistikat. Külmasaared määratleti negatiivsete z-skoori väärtustega piirkondadena, mis viitavad statistiliselt olulistele madala temperatuuriga aladele. Külmasaared jaotati kolme kategooriasse: nõrgad külmasaared (z-skoor vahemikus $-1,65$ kuni $-1,96$), mõõdukad külmasaared (z-skoor vahemikus $-1,96$ kuni $-2,58$) ning tugevad külmasaared (z-skoor $< -2,58$). Mida negatiivsem on z-skoori väärtus, seda tugevam ja statistiliselt olulisem on külmasaare efekt. Joonisel 6 on esitatud Tallinna külmasaarte ruumiline jaotus 2021. – 2024. aastal.



Joonis 6. Tallinna külmasaarte ruumiline jaotus 2021. – 2024. aastal LST ja NDVI põhise z-skoori analüüsi tulemusena.

Jooniselt 6 on võimalik näha, et z-skoori põhjal määratud külmasaarte paiknemine varieerus aastate lõikes märkimisväärselt. Analüüsis jäeti välja veekogud, selleks et keskenduda maismaal esinevatele temperatuurierinevustele ning vältida veepindade tugeva jahutava mõju domineerimist tulemustes. Külmasaared esinesid valdavalt Tallinna äärealadel ning piirkondades, kus leidub rohkem rohealasid ja looduslikku taimkatet. Kõige ulatuslikum külmasaarte levik ilmnis 2023. aastal, mil nii nõrgad kui ka mõõdukad külmasaared koondusid suurematele aladele linna põhja- ja lääneosas. Kloostrimetsa piirkonnas tuvastati külmasaari ebaühtlaselt erinevatel aastatel. Kui 2024. aastal eristus piirkonnas selgelt väljendunud külmasaar, siis ülejäänud vaadeldud aastatel oli selle esinemine nõrgem või puudus märgatav temperatuurianomaalia. See viitab sellele, et Kloostrimetsa jahutav mõju ei olnud uuringuperioodil püsiv ning võis sõltuda aastati muutuvatest tingimustest, näiteks taimkatte seisundist või ilmastikutingimustest. Haabersti läänerannikul metsases piirkonnas ilmnisid külmasaared erineva ulatusega. Kõige selgemalt eristusid need 2021. ja 2023. aastal, mil külmasaar hõlmas suurema osa piirkonnast, samas kui 2022. ja 2024. aastal piirdus see peamiselt põhjapoolse osaga. Külmasaar eristus ka Paljassaare poolsaare tipus, kus jahedama temperatuuriga ala ilmnis enamikul vaadeldud aastatest. Ühel aastal külmasaar selles piirkonnas siiski selgelt ei avaldunud. Sellised erinevused viitavad aastati muutuvale külmasaarte ruumilisele ulatusele. Sellised erinevused võivad olla mõjutatud ilmastikutingimustega satelliidi ülendlennu ajal. Seevastu 2022. ja 2024. aastal olid külmasaared ruumiliselt piiratumad ning esinesid väiksemate, hajusate aladena. Tulemused viitavad sellele, et suurema taimkatte osakaaluga piirkondades avaldub tugevam jahutav mõju, samas kui tihedalt hoonestatud aladel oli külmasaarte esinemine väiksem. Kuna Z-skoori meetod põhineb suhtelistel temperatuurierinevustel, võimaldab see hinnata külmasaarte tugevust kogu uuringuala temperatuurijaotuse kontekstis ning tuua esile ka vähem väljendunud jahutavaid piirkondi.

Täiendavalt analüüsiti 2025. aasta tulemusi eraldi, kuna tegemist oli kõige uuema analüüsiaastaga, mis võimaldas hinnata varasemate aastate ruumiliste mustrite jätkumist. Joonisel 7 on kujutatud Tallinna külmasaarte ruumiline jaotus 2025. aastal, mis on saadud aastal LST ja NDVI põhise z-skoori analüüsi tulemusena.




Joonis 7. Tallinna külmasaarte ruumiline jaotus 2025. aastal LST ja NDVI põhise z-skoori analüüsi tulemusena.

2025. aasta külmasaarte ruumiline jaotus erines mõnevõrra eelnevatest aastatest. Nõrgad külmasaared moodustasid suurima osa tuvastatud aladest ning paiknesid hajusalt peamiselt linna äärealadel. Mõõdukad külmasaared esinesid väiksemate koondunud aladena, samas kui tugevad külmasaared olid ruumiliselt kõige piiratumad ning paiknesid üksikutes piirkondades. Võrreldes aastate 2021–2024 tulemustega ilmnes 2025. aastal tugevamate külmasaarte selgem eristumine. See viitab sellele, et külmasaarte kujunemine võib olla seotud aastate vaheliste erinevustega maapinna temperatuuris ning taimkatte jaotuses. Külmasaared eristusid ka rannikualadel ja suuremate rohealade ümbruses. Külmasaared eristusid Paljassaare poolsaarel, Rocca al Mare Vabaõhumuuseumi piirkonnas ning Ülemiste järve lõuna- ja idapoolsetes piirkondades. Samuti ilmnemiseid väiksemad ja hajusamad külmasaared linna äärealadel, kus nende ulatus oli võrreldes suuremate rohealadega tagasihoidlikum. Tulemused viitavad sellele, et külmasaared paiknesid peamiselt suurema taimkatte osakaaluga või veekogude läheduses asuvatel aladel. Lennuväljal on 2025. aastal märgata tugeva külmasaare esinemist, mis ei kajastu eelnevates aastates. Tulemusi võis mõjutada piirkonna keerukas maakate ning Landsati andmete ruumiline lahutusvõime, mille tõttu võivad üksikud pikslid sisaldada erinevaid pinnatüüpe. Kuna sarnane

temperatuurimuster ei kordunud uuringuperioodi jooksul järjepidevalt, ei saa piirkonda käsitleda püsiva külmasaare alana.


Külmasaarte püsivuse hindamiseks toodi välja ka mitme aasta külmasaared, selle eesmärk on tuvastada piirkonnad, kus külmasaared kordusid uuringuperioodi jooksul kõige sagedamini. Analüüs põhines *Google Earth Engine*'i keskkonnas määratud külmasaarte aladel, mis defineeriti piirkondlikust keskmisest vähemalt 2 °C madalama maapinna temperatuuriga piirkondadena. Analüüs on näha joonisel 8.



Joonis 8. Tallinna külmasaarte ruumiline püsivus aastatel 2021–2025, kus külmasaared määrati piirkondlikust keskmisest vähemalt 2 °C madalama maapinna temperatuuri alusel.

Jooniselt 8 on näha, millised külmasaared esinesid näiteks kõigil viiel aastal, neid saab lugeda püsivateks külmasaarteks. Kõige paremini eristusid Ülemist järve ümbrus, Pirita, Paljassaare poolsaar ja Haabersti rannikuala. Püsivad külmasaared paiknevad pigem veekogude ääres või kõrghaljastusega kaetud alal. Ühe kuni kolme aasta jooksul esinenud külmasaared on väiksemad ja paiknevad hajusalt. Sellised alad on näha just väikestel rohealadel või tihedalt hoonestatud alade kõrval. Suurema tähtsusega on siiski igal aastal esinevad külmasaared, kuna need on püsivad, tänu millele, saab nende mõjuga ka paremini arvestada.

Lisaks üksikute aastate külmasaarte paiknemise analüüsile hinnati ka z-skoori põhjal määratud külmasaarte ruumilist püsivust uuringuperioodi jooksul. Selle eesmärk oli tuvastada piirkonnad, kus statistiliselt olulised külmasaared kordusid aastatel 2021–2025. Kattuvusanalüüs viidi läbi nõrkade ja mõõdukate külmasaarte jaoks eraldi, et hinnata nende ajalist stabiilsust ja ruumilist korduvust, need on välja toodud joonisel 9. Kattuvusanalüüsis ei ole eraldi kujutatud tugevaid külmasaari, kuna need esinesid ainult ühel aastal.




Joonis 9. Z-skoori põhjal määratud nõrkade ja mõõdukate külmasaarte ruumiline püsivus Tallinnas aastatel 2021–2025.

Kattuvusanalüüsi tulemused näitasid, et z-skoori põhjal määratud nõrkade ja mõõdukate külmasaarte püsivus erines uuringuperioodi jooksul märkimisväärselt. Nõrgad külmasaared olid ulatuslikumad ning kordusid sagedamini erinevatel aastael samades piirkondades. Kõige püsivamad nõrgad külmasaared paiknesid peamiselt Tallinna rannikualadel, Paljassaare poolsaarel ning Piritä piirkonnas. Mõõdukad külmasaared olid väiksema ulatusega ning nende ruumiline püsivus oli madalam. Analüüs näitas, et mõõdukad külmasaared esinesid peamiselt ühe kuni kolme aasta jooksul ning neljal või viiel aastal korduvaid piirkondi ei tuvastatud. Samuti olid need alad ruumiliselt hajusamad ning väiksema pindalaga.

Kahe meetodi võrdlus näitas, et Tallinna külmasaarte ruumiline paiknemine oli üldjoontes sarnane, kuna mõlema lähenemise puhul koondusid külmemad piirkonnad peamiselt suuremate rohealade, metsasemate alade ning veekogude lähedusse. Samas ilmnesid meetodite vahel erinevused tuvastatud alade ulatuses, püsivuses ja ruumilistes mustrites. Piirkondliku temperatuurilävendi meetod, mille puhul määratleti külmasaared piirkondadeks, mille maapinna temperatuur oli vähemalt 2 °C madalam keskmisest, tuvastas ulatuslikumaid külmasaari ning kirjeldas paremini külmemate piirkondade üldist levikut linnas. Z-skoori põhjal määratud külmasaared võimaldasid seevastu tuvastada statistiliselt olulisemaid ja selgemini eristuvaid külmemaid piirkondi. Kattuvusanalüüs näitas, et nõrgad külmasaared olid ruumiliselt ulatuslikumad ja kordusid sagedamini mitmel uuringuaastal, samas kui mõõdukad ja tugevad külmasaared olid väiksema ulatusega ning vähem püsivad. Tugevaid külmasaari tuvastati ainult 2025. aastal, mis viitab sellele, et statistiliselt tugevasti väljendunud külmasaared ei kujutanud uuringuperioodi jooksul endast püsivat nähtust. Kahe meetodi analüüsi järel saab väita meetodid täiendavad üksteist, kuna temperatuurilävend võimaldab kirjeldada külmemate alade üldist ruumilist jaotust, samas kui z-skoori põhine lähenemine aitab esile tuua statistiliselt olulisemaid ruumilisi mustreid ning hinnata nende püsivust ajas.

Külmasaarte klassifitseerimiseks standardiseeriti maapinna temperatuuri väärtused Z-skooride abil. Z-skoor võimaldab hinnata, kui palju konkreetse piirkonna temperatuur erineb uuringuala keskmisest väärtusest standardhälbe ühikutes. Negatiivsed väärtused viitavad keskmisest madalamale temperatuurile, positiivsed väärtused aga kõrgemale temperatuurile. Z-skooride jaotuse analüüsimine võimaldab hinnata andmete üldist struktuuri ning määrata külmasaarte klasside piirväärtused. 2025 aasta jaotus on näha joonisel 10.




Joonis 10. *Getis-Ord Gi** analüüsi põhjal saadud 2025. aasta maapinna temperatuuri z-skoori väärtuste histogramm.

Joonisel 10 kujutatud histogramm näitab *Getis-Ord Gi** analüüsi tulemusena saadud z-skooride jaotust. Meetodiga arvutatakse igale pikslile z-skoori väärtus, mis väljendab, kui tugevasti erineb konkreetse asukoha ja selle naabruses temperatuuriväärtus kogu uurimisala keskmisest. Keskmise z-skoori väärtus oli ligikaudu 0,01 ning mediaan 0,11, mis näitab väärtuste suhteliselt tasakaalustatud jaotust. Standardhälve oli 3,28, viidates temperatuuriväärtuste märkimisväärsel ruumilisele varieeruvusele uuringualal. Negatiivsete väärtustega piirkonnad esindavad suhteliselt madalama temperatuuriga alasid ning nende põhjal määratleti külmasaarte klassid. Positiivsete z-skoori väärtuste ulatumine kuni 12,7 viitab tugevasti väljendunud kõrge temperatuuriga piirkondade ruumilistele klastritele, kus kõrged maapinna temperatuurid koonduvad suuremateks aladeks.

Enamik maapinna temperatuuri z-skoori väärtusi koondus siiski keskmise lähedale, mis viitab sellele, et suurem osa Tallinna uuringualast ei erinenud temperatuurilt märkimisväärselt linna keskmisest tasemest. Jaotusel esines parempoolne pikenenud saba, mis osutab üksikutele kõrgema temperatuuriga piirkondadele, kuid väga kõrgete z-skooride osakaal jäi suhteliselt väikeseks. See viitab sellele, et ulatuslikke ja tugevalt väljendunud kuumsaari Tallinnas esines piiratud ulatuses ning kõrgema temperatuuriga alad olid pigem lokaalse iseloomuga.

Aastate 2021–2024 *Getis-Ord Gi** analüüsi tulemuste võrdlemiseks koostati z-skooride histogrammid. Histogrammid võimaldavad hinnata, kuidas z-skooride väärtused aastate lõikes jaotusid ning kas mõnel aastal esines tugevamaid ruumilisi temperatuurierinevusi, need on kujutatud joonisel 6.



Joonis 11. *Getis-Ord Gi** analüüsi põhjal saadud z-skoori väärtuste histogrammid aastatel 2021–2024.

Joonisel 11 histogrammide võrdlus näitas, et z-skooride üldine jaotus oli aastate lõikes sarnane ning keskmised väärtused jäid nulli lähedale. Võrreldes 2023. aastaga erines ka 2025. aasta, mille puhul esines madalamaid negatiivseid z-skoori väärtusi (z-skoor min = $-3,422$), mis näitab, et 2025. aastal ilmneseid statistiliselt tugevamad ja selgemalt eristuvad külmasaared. Kuna tugevaid positiivseid või negatiivseid kõrvalekaldeid esines suhteliselt vähe, siis see viitab sellele, et Tallinna linnaruumi temperatuurimustrid olid aastate lõikes üldiselt stabiilsed ning külmasaared kujunesid pigem lokaalsete ruumiliste erisuste kui kogu linna ulatuses toimunud temperatuurimuutuste tulemusena.

3.3. Normaliseeritud taimkatte indeksi ja külmasaarte vaheline seos

Aastate 2021–2025 suviste LST andmete põhjal tuvastatud külmasaari võrreldi erineva taimkatte osakaaluga aladega, et hinnata taimkatte mõju külmasaarte kujunemisele Tallinnas. Analüüsi käigus jaotati NDVI väärtused kolme klassi: vähene taimkate (NDVI 0–0,2), mõõdukas taimkate (NDVI 0,2–0,6) ja tugev taimkate (NDVI 0,6–1,0). Klasside piirid valiti lähtuvalt magistritöö eesmärgist ja üldtunnustatud NDVI väärtuste tõlgenduste põhjal. See võimaldas hinnata, millistes taimkatte tingimustes paiknesid tuvastatud külmasaared kõige sagedamini ning milline oli taimkatte seos külmasaarte ruumilise jaotusega.

Tabel 1. Landsat 8 maapinna temperatuuri andmete (LST) põhjal määratud külmasaarte jaotus erineva taimkattega aladel aastatel 2021–2025 (%)

Aasta	Vähene taimkate	Mõõdukas taimkate	Tugev taimkate
2021	0,96	5,54	93,50
2022	1,02	5,68	93,30
2023	1,13	7,27	91,60
2024	0,76	3,03	96,21
2025	2,81	7,34	89,85

Tabel 1 väärtused näitavad, kui suur osa kõigist vastava aasta külmasaartest paiknes vähese, mõõduka või tugeva taimkattega aladel. Näiteks 2021. aastal paiknes 93,50% kõigist külmasaarte aladest tugeva taimkattega piirkondades, samas kui vaid 0,96% külmasaartest esines vähese taimkattega aladel. Seega ei näita tabel taimkatte üldist osakaalu Tallinnas, vaid külmasaarte jaotust erineva taimkattega piirkondade vahel. Tabelis on näha ka seos külmasaarte ja taimkatte intensiivsuse vahel. Kõigil analüüsitud aastatel paiknes valdav osa külmasaartest tugeva taimkattega aladel, kus osakaal jäi vahemikku 89,85–96,21%. Kõige suurem tugevama taimkatte osakaal esines 2024. aastal (96,21%), samas kui madalaim väärtus ilmnes 2025. aastal (89,85%).

Vähese taimkattega piirkondades jäi külmasaarte osakaal kõigil aastatel väga väikeseks (0,76–2,81%), mis viitab sellele, et vähese haljustusega alad ei soodusta külmasaarte kujunemist. Mõõduka taimkattega aladel oli osakaal mõnevõrra suurem (3,03–7,34%), kuid jäi siiski oluliselt väiksemaks võrreldes tugeva taimkattega piirkondadega. Kõige selgemini on märgatav, et 2025. aastal vähenes tugeva taimkatte osakaal ning suurenes samaaegselt vähese ja mõõduka taimkatte osakaal. See võib viidata sellele, et külmasaarte paiknemine oli sel aastal mõnevõrra hajusam ega olnud seotud ainult kõige tihedama taimkattega piirkondadega.

Külmasaarte ja taimkatte vahelise seose hindamiseks võrreldi z-skoori analüüsi põhjal määratud külmasaarte erineva taimkattega aladega. Tabelis 2 on esitatud, kui suur osa erinevate külmasaarte klassidest paiknes vähese, mõõduka või tugeva taimkattega aladel aastatel 2021–2025.

Tabel 2. Z-skoori põhjal määratud külmasaarte jaotus erineva taimkattega aladel aastatel 2021–2025 (%)

Aasta	Külmasaare klass	Vähene taimkate	Mõõdukas taimkate	Tugev taimkate
2021	Nõrk külmasaar	0	0	100
2022	Mõõdukas külmasaar	0	0	100
	Nõrk külmasaar	0	0	100
2023	Mõõdukas külmasaar	0	0	100
	Nõrk külmasaar	0	0	100
2024	Mõõdukas külmasaar	0	0	100
	Nõrk külmasaar	0	0	100
2025	Mõõdukas külmasaar	0	0	100%
	Nõrk külmasaar	0	8	92
	Tugev külmasaar	0	3	97

Tabelis on esitatud z-skoori analüüsi põhjal määratud külmasaarte klasside jaotus erineva taimkatte intensiivsusega aladel aastatel 2021–2025. Tabeli väärtused näitavad, kui suur osa vastava külmasaare klassi pindalast paiknes vähese, mõõduka või tugeva taimkattega piirkondades. Näiteks 2021. aastal paiknesid kõik tuvastatud nõrgad külmasaared tugeva taimkattega aladel, mistõttu tugeva taimkatte osakaal oli 100%. Tulemused näitavad, et aastatel 2021–2024 paiknesid kõik tuvastatud külmasaared sõltumata klassist täielikult tugeva taimkattega aladel. See viitab väga selgele seosele külmasaarte kujunemise ja suurema taimkatte olemasolu vahel. Vähese ja mõõduka taimkattega aladel külmasaari neil aastatel ei esinenud.

Mõningaid erinevusi ilmnes 2025. aastal, mil külmasaarte paiknemine muutus mõnevõrra mitmekesisemaks. Nõrkadest külmasaartest paiknes 92% tugeva taimkattega aladel, samas kui 8% esines mõõduka taimkattega piirkondades. Tugevate külmasaarte puhul paiknes 97% tugeva taimkattega aladel ning 3% mõõduka taimkattega piirkondades. Vähese taimkattega aladel külmasaari ei esinenud ka 2025. aastal. Tulemused viitavad sellele, et külmasaarte kujunemine oli kõige tugevamalt seotud suurema taimkatte olemasoluga. Samas näitasid 2025. aasta tulemused, et üksikjuhtudel võisid külmasaared kujuneda ka mõõduka taimkattega piirkondades, mis võib viidata teiste tegurite, näiteks veekogude, linnaruumi struktuuri või kohalike maakasutuse eripärade mõjule.

3.4. Downscaling-analüüsi tulemused

Downscaling-analüüsi tulemuste hindamiseks võrreldi NDVI ja maapinna temperatuuri vahelisi regressioonianalüüsi tulemusi ning modelleeritud temperatuurirastrite z-skoori statistikat aastatel 2021–2025. Vähimruutude meetodi (*Ordinary Least Squares* - OLS) regressioonianalüüsi aruanded aastate 2021–2025 kohta on esitatud lisades 2–6. Tabelis 3 on esitatud regressioonivõrrandid, regressioonimodelite determinatsioonikordajad (R^2), standardhälbed ning z-skoori miinimum- ja maksimumväärtused.

Tabel 3. NDVI-põhiste *downscaled* LST rastrite regressioonianalüüsi tulemused ja z-skoori statistika aastatel 2021–2025

Aasta	Regressioonivõrrand	R^2	Standardhälve	Z-skoor miinimum	Z-skoor maksimum
2021	$32,304 - 10,170 \times \text{NDVI}$	0,553	1,000	-1,951	3,023
2022	$33,270 - 9,575 \times \text{NDVI}$	0,542	0,535	-1,961	3,378
2023	$31,352 - 11,086 \times \text{NDVI}$	0,554	0,706	-2,259	3,624
2024	$30,104 - 8,381 \times \text{NDVI}$	0,559	0,473	-2,098	3,318
2025	$29,373 - 8,135 \times \text{NDVI}$	0,384	0,569	-3,422	3,112


Regressioonianalüüsi tulemused näitasid, et NDVI ja maapinna temperatuuri vahel on negatiivne seos, mis tähendab, et tugevama taimkattega aladel oli üldjuhul madalam maapinna temperatuur. NDVI kordajad olid negatiivsed kõikidel aastatel, millest saab järeldada, et taimkate mõjutab linnakeskkonda jahutavalt. Tulemused on kooskõlas varasemate uuringutega, mille kohaselt vähendavad suurema taimkattega alad maapinna temperatuuri aurumise, varjutuse ja väiksema soojuse salvestumise tõttu. Regressioonianalüüsi R^2 väärtused näitavad, et maapinna temperatuuri ja NDVI statistiline seos oli mõõdukas, kuna R^2 väärtused jäid vahemikku 0,384–0,559, millest kõige kõrgem väärtus esines 2024. aastal ($R^2 = 0,559$). 2025. aastal oli R^2 väärtus võrreldes eelnevate aastatega mõnevõrra madalam ($R^2 = 0,384$), mis viitab nõrgemale seosele NDVI ja maapinna temperatuuri vahel. Kasutatud *Landsat* ja *Sentinel-2* piltide arv ei erinenud võrreldes teiste aastatega oluliselt, mistõttu ei ole tõenäoline, et erinevus oleks tingitud üksnes väiksemast andmehulgast. Tulemusi võisid mõjutada 2025. aasta suvised meteoroloogilised tingimused või kohalike temperatuurimustrite suurem ruumiline varieeruvus. Samuti võis mõju avaldada avatud alade ja veekogude, näiteks Ülemiste järve ümbruse, lokaalne jahutav mõju. Tulemused näitasid, et NDVI selgitas ligikaudu 38–56% maapinna temperatuuri

erinevustest, mis viitab sellele, et taimkate on oluline maapinna temperatuuri mõjutav tegur, kuid ei kirjelda temperatuurijaotust täielikult. Tulemused näitasid, et Tallinna linnakeskkonnas ei mõjuta maapinna temperatuuri üksnes taimkate, vaid ka näiteks hoonestustihedus, tehiskad pinnakatted, transporditaristu või veekogud.

Downscaling-meetodi hindamiseks analüüsiti modelleeritud temperatuurirastrite statistilisi omadusi ning nende põhjal arvutatud z-skoori väärtusi. Tulemused näitasid, et kuigi NDVI põhjal oli võimalik koostada detailsemaid temperatuurimudeleid, ei võimaldanud saadud temperatuurirastrid statistiliselt olulisi külmasaari selgelt tuvastada. Enamikul juhtudel ei eristunud külmasaarte piirkonnad piisavalt ümbritsevast linnakeskkonnast ning saadud temperatuurijaotus ei peegeldanud algetel *Landsat 8* LST andmetel põhinevaid temperatuurimustreid. Seetõttu ei kasutatud *downscaling*-meetodi tulemusi külmasaarte lõplikuks määramiseks ning lõplik analüüs põhines algetel maapinna temperatuuri (LST) andmetel ja nende z-skoori standardiseerimisel. Veekogud eemaldati analüüsist, kuna nende temperatuurid erinevad oluliselt maismaa temperatuuridest ning võivad mõjutada z-skoori põhise külmasaarte määramist.

3.5. Külmasaarte seos katastriüksuste sihtotstarvetega

Külmasaarte ja katastriüksuste sihtotstarvete vaheliste seoste hindamiseks võrreldi külmasaarte pindalasid Tallinna erinevate sihtotstarvete kogupindaladega. Joonisel 12 on esitatud ülevaade, kui suure osa iga sihtotstarbe kogupindalast moodustavad külmasaared. Protsendid näitavad, kui suur osa konkreetse sihtotstarbe kogupindalast kattus külmasaartega.



Joonis 12. Külmasaarte osakaal erinevatel sihtotstarvetel Tallinnas 2025. aastal.

Jooniselt 12 on näha, et kõige suurem külmasaarte osakaal esines sihtotstarbeta maal, kus külmasaared katsid 12,21% kogu vastava sihtotstarbega katastriüksuste pindalast. Suurem külmasaarte osakaal esines ka maatulundusmaal (11,42%), üldkasutataval maal (5,67%) ning ühiskondlike ehitiste maal (5,38%). Väiksem külmasaarte osakaal oli elamumaal (0,65%), tootmismaal (0,65%) ja muul maal (0,26%), kus külmasaared moodustasid alla 1% vastava sihtotstarbe pindalast.

Sellest saab järeldada, et tulemused on kõige rohkem seotud suurema taimkattega aladega. Suurem külmasaarte osakaal maatulundusmaal ja üldkasutataval maal viitab sellele, et haljastus ja looduslikud alad mõjutavad linnakeskkonna jahutamist. Samuti ilmnes märkimisväärne külmasaarte osakaal sihtotstarbeta maal, mis võib olla seotud vähem hoonestatud või kasutamata aladega. Väiksem külmasaarte osakaal oli elamu-, tootmis- ja osaliselt transpordimaal, kus üldiselt esineb tihedam hoonestus ning suurem tehislise pinnakatete osakaal. Need piirkonnad salvestavad rohkem soojust ning seetõttu on seal külmasaarte kujunemine vähem tõenäoline. Planeerimise seisukohalt on jahedamad piirkonnad olulised, kuna need aitavad vähendada linna soojussaare mõju ning parandada mikrokliimat. Linna tihenedes suureneb kõvakattega pindade osakaal ning väheneb looduslike jahutavate elementide hulk, mistõttu võivad kõrged temperatuurid mõjutada nii

inimeste heaolu kui ka väliruumi kasutatavust. Magistritöö põhjal võib järeldada, et Tallinna puhul täidavad jahutavat rolli eelkõige suuremad rohealad, metsasemad piirkonnad ja veekogude ümbrused. Sealhulgas näiteks Pirita jõe ümbrus, Nõmme metsaalad ning Harku järve lähedased rohealad.

Selliste alade säilitamine võiks olla oluline osa linnade kliimakohanemise meetmetest. Analüüsist selgus, et jahutav mõju ei sõltu ainult haljastuse olemasolust, vaid ka selle ruumilisest sidususest. Suuremad ja kompaktsemad rohealad olid seotud tugevamate külmasaartega, samas kui väiksemate või killustunud haljasalade mõju jäi tagasihoidlikumaks. See viitab sellele, et suuremate ja omavahel seotud haljasalade mõju oli analüüsis paremini tuvastatav tulenevalt ka kasutatud satelliitide andmete ruumilisest resolutsioonist (30 m). Rohealade ühendatus võimaldab kujuneda jahutuskoridoridel, mille kaudu liigub jahedam õhk tihedamalt hoonestatud linnapiirkondadesse. Tallinna puhul võiks suuremat tähelepanu pöörata näiteks Pirita jõe ümbrusele, Harku järve lähedastele aladele ning Ülemiste järve ümbrusele, kus paiknesid ulatuslikumad jahedamad piirkonnad. Nende alade killustamine või ulatuslik täisehitamine võib vähendada jahutavat mõju ning muuta ümbritseva linnaruumi temperatuuritingimusi. Seetõttu võiks planeeringute koostamisel arvestada olemasolevate rohe- ja sinivõrgustiku elementide säilitamisega ning vältida olukordi, kus olulised rohekoridorid katkestatakse. NDVI ja maapinna temperatuuri võrdlus näitas küll üldist seost taimkatte ja madalama temperatuuri vahel, kuid kõrgem NDVI väärtus ei tähendanud alati tugevama külmasaare olemasolu. Temperatuuritingimusi mõjutasid samaaegselt ka hoonestuse tihedus, pinnakatte materjalid, varjutus ning veekogude lähedus. Sellest võib järeldada, et linnaruumi termiliste omaduste hindamisel ei piisa ainult haljastuse pindala analüüsimisest. Oluline on hinnata ka seda, kuidas rohealasid ümbritsev linnastruktuur mõjutab nende jahutavat mõju.

Kesklinna piirkondades, kus jahedamaid alasid esines vähem, võiks suuremat tähelepanu pöörata kuumenevate kõvakattega pindade vähendamisele ning varjutuse suurendamisele. Võimalike lahendustena võiks kasutada suurema haljastusega tänavaruumi, puuderidu, rohekatuseid ja haljastatud sisehoove. Samuti võiks suuremate parkimisalade ja asfaltkattega pindade planeerimisel eelistada vett läbilaskvaid materjale või lahendusi, mis aitavad vähendada soojuse akumulatsiooni. Kuigi sellised meetmed ei pruugi kujundada suuri külmasaari, võivad need parandada kohalikke temperatuuritingimusi ja vähendada kuumaperioodide mõju. Külmasaarte ruumiline paiknemine oli üldjoontes vastupidine soojussaarte ruumilisele jaotusele. Soojussaared koondusid peamiselt tihedama hoonestuse

ja suurema kõvakattega pindade osakaaluga piirkondadesse, nagu Kesklinn, Lasnamäe ja Põhja-Tallinna osad, samas kui külmasaared paiknesid sagedamini suurema taimkatte osakaaluga piirkondades ning veekogude läheduses. Selgemini ilmnesis külmasaared Nõmme metsasemates piirkondades, Pirita ümbruses, Ülemiste järve läheduses ning Harku järve ümbruses. See viitab sellele, et Tallinna linnaruumis kujunevad soojus- ja külmasaared suuresti vastandlike ruumiliste tingimuste mõjul. Samas ei olnud tegemist täielikult vastanduvate nähtustega, kuna mõnes piirkonnas võis esineda väiksemaid lokaalseid kõrvalekaldeid.

KOKKUVÕTE

Magistritöö eesmärk oli kaardistada Tallinna linnas esinevaid külmasaari kaugseireandmete põhjal ning hinnata nende seoseid taimkatte ja maakasutusega. Kaugseireandmed ja kasutatud analüüsimeetodid võimaldasid tuvastada Tallinna linnas külmasaarte ruumilisi mustreid ning hinnata nende seoseid taimkatte ja maakasutusega. Töös kasutati *Landsat 8* satelliitandmete põhjal arvutatud maapinna temperatuuri (LST) ning *Sentinel-2* andmetest arvutatud normaliseeritud taimkatte indeksit (NDVI). Analüüs viidi läbi *Google Earth Engine*'i ja *ArcGIS Pro* keskkondades. Magistritöö tulemuste paremaks visualiseerimiseks koostati ArcGIS Online'i keskkonnas veebikaart, mille põhjal loodi ArcGIS Experience Builderis interaktiivne veebirakendus. <https://experience.arcgis.com/template/5c4c9a70bcd74b7996f9092b0513265b>.

Downscaling-meetod osutus ebaefektiivseks ning modelleeritud temperatuurirastrid ei võimaldanud usaldusväärselt määrata statistiliselt olulisi külmasaari. Külmasaarte määramiseks kasutati maapinna temperatuuri ning z-skoori põhist statistilist lähenemist. Lisaks hinnati külmasaarte seoseid taimkatte ja maakasutuse sihtotstarvetega. Tulemused näitasid, et kaugseire andmete põhjal määratud Tallinna külmasaared paiknesid ootuspäraselt peamiselt rohealadel, metsasemates piirkondades ja suuremate veekogude läheduses. Kõige selgemini eristusid Ülemiste järve, Pirita piirkonna ja Tallinna läänepoolsete alade ümbruses paiknevad jahedamad piirkonnad. Tihedalt hoonestatud kesklinna piirkonnas esines külmasaari vähem ning need olid üldiselt väiksema pindalaga (alla 450 m²) ja ruumiliselt killustunud. See viitab sellele, et külmasaarte paiknemine sõltub linnaruumi struktuurist ning erinevate pinnakatete ruumilisest jaotusest.

Kahe külmasaarte määramise meetodi võrdlus näitas, et mõlemad lähenemised tuvastasid külmemad piirkonnad peamiselt suuremate rohealade, metsasemate alade ja veekogude läheduses, kuid erinesid tuvastatud alade ulatuse ja ruumiliste mustrite osas. Piirkondliku temperatuurilävendi meetod tõi esile ulatuslikuma külmasaarte leviku, samas kui z-skoori põhine lähenemine võimaldas tuvastada statistiliselt olulisemaid ja ruumiliselt selgemini eristuvaid piirkondi. Tulemused näitasid, et meetodid täiendavad üksteist ning nende kombineerimine võimaldab saada terviklikuma ülevaate Tallinna külmasaarte kujunemisest ja ruumilisest püsivusest.

Taimkatte ja külmasaarte seose analüüs näitas, et suurema taimkatte osakaaluga aladel esines külmasaari kõige rohkem. Sentinel-2 andmete põhjal leitud NDVI klasside võrdlus näitas, et suurem osa külmasaarte pindalast paiknes tugeva taimkattega piirkondades. Samas näitas regressioonianalüüs küll negatiivset seost NDVI ja maapinna temperatuuri vahel, kuid R^2 väärtused olid madalad, mis viitab sellele, et taimkate selgitas vaid väikest osa maapinna temperatuuri varieeruvusest. Seega mõjutavad linnakeskkonna temperatuure lisaks taimkattele ka teised tegurid, näiteks hoonestustihedus, tehislikud pinnakatted, veekogud ning linnaruumi struktuur.

Külmasaarte ja maakasutuse sihtotstarvete võrdlus näitas, et suurem külmasaarte osakaal esines maatulundusmaal, üldkasutataval maal ning vähese hoonestusega piirkondades, kus taimkatte osakaal on suurem. Tihedamalt hoonestatud piirkondades, näiteks elamu- ja tootmismaal, oli külmasaarte osakaal väiksem. See viitab sellele, et maakasutuse iseloom mõjutab oluliselt linnaruumi termilisi omadusi.

Edasistes uuringutes võiks külmasaarte analüüsi läbi viia detailsemalt ning kasutada suurema ruumilise lahutusvõimega andmeid. Lisaks satelliitandmetele võiks analüüsi kaasata maapealseid temperatuuriandurite andmeid, meteoroloogilisi mõõtmisi ning täpsemaid maakasutuse ja linnaruumi andmeid. Selline lähenemine võimaldaks saada täpsema ja operatiivsema ülevaate Tallinna külmasaarte dünaamikast ning nende võimalikust rollist linnakeskkonna kliimatingimuste kujundamisel. Tulevikus võiks kaaluda automatiseeritud andmetöötluslahenduste kasutamist, näiteks FME (*Feature Manipulation Engine*) tarkvara abil.

ALLIKALOEND

- Abimbola, O. J., Adewumi, T., & Abubakar, M. (2025). *Dynamics of Urban Heat Island in Lafia, Nasarawa State of Nigeria: A Remote Sensing Analysis of Land Surface Temperature, Urban Development and Vegetation Change* (Version 1). arXiv. <https://doi.org/10.48550/ARXIV.2503.17052>
- Amani, M., Ghorbanian, A., Ahmadi, S. A., Kakooei, M., Moghimi, A., Mirmazloumi, S. M., Moghaddam, S. H. A., Mahdavi, S., Ghahremanloo, M., Parsian, S., Wu, Q., & Brisco, B. (2020). Google Earth Engine Cloud Computing Platform for Remote Sensing Big Data Applications: A Comprehensive Review. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13, 5326–5350. <https://doi.org/10.1109/JSTARS.2020.3021052>
- Anand, V., Kaur, S., Rajput, V. D., Minkina, T., Mandzhieva, S., Kumar, S., Sharma, A., & Kumar, S. (2025). Analyzing the spatial relationship between land surface temperature and normalized difference vegetation index using remote sensing and GIS. *Discover Geoscience*, 3(1), 65. <https://doi.org/10.1007/s44288-025-00167-w>
- Aram, F., Higuera García, E., Solgi, E., & Mansournia, S. (2019). Urban green space cooling effect in cities. *Heliyon*, 5(4), e01339. <https://doi.org/10.1016/j.heliyon.2019.e01339>
- Azmi, R., Tekouabou Koumetio, C. S., Diop, E. B., & Chenal, J. (2021). Exploring the relationship between urban form and land surface temperature (LST) in a semi-arid region case study of Ben Guerir city—Morocco. *Environmental Challenges*, 5, 100229. <https://doi.org/10.1016/j.envc.2021.100229>
- Bouketta, S. (2023). Urban Cool Island as a sustainable passive cooling strategy of urban spaces under summer conditions in Mediterranean climate. *Sustainable Cities and Society*, 99, 104956. <https://doi.org/10.1016/j.scs.2023.104956>
- Bowler, D. E., Buyung-Ali, L., Knight, T. M., & Pullin, A. S. (2010). Urban greening to cool towns and cities: A systematic review of the empirical evidence. *Landscape and Urban Planning*, 97(3), 147–155. <https://doi.org/10.1016/j.landurbplan.2010.05.006>
- Cai, X., Yang, J., Zhang, Y., Xiao, X., & Xia, J. (2023). Cooling island effect in urban parks from the perspective of internal park landscape. *Humanities and Social Sciences Communications*, 10(1), 674. <https://doi.org/10.1057/s41599-023-02209-5>
- Cetin, M., Ozenen Kavlak, M., Senyel Kurkcuoglu, M. A., Bilge Ozturk, G., Cabuk, S. N., & Cabuk, A. (2024). Determination of land surface temperature and urban heat island effects with remote sensing capabilities: The case of Kayseri, Türkiye. *Natural Hazards*, 120(6), 5509–5536. <https://doi.org/10.1007/s11069-024-06431-5>
- Chen, M., Samat, N., Maghsoodi Tilaki, M. J., & Duan, L. (2025). Land use/cover change simulation research: A system literature review based on bibliometric analyses. *Ecological Indicators*, 170, 112991. <https://doi.org/10.1016/j.ecolind.2024.112991>
- Dyce, D. R., & Voogt, J. A. (2018). The influence of tree crowns on urban thermal effective anisotropy. *Urban Climate*, 23, 91–113. <https://doi.org/10.1016/j.uclim.2017.02.006>
- Ermida, S. L., Soares, P., Mantas, V., Göttsche, F.-M., & Trigo, I. F. (2020). Google Earth Engine Open-Source Code for Land Surface Temperature Estimation from the Landsat Series. *Remote Sensing*, 12(9), 1471. <https://doi.org/10.3390/rs12091471>
- Google Earth Engine. (s.a.). [Software]. Salvatutud <https://earthengine.google.com/>
- Guerri, G., Crisci, A., Messeri, A., Congedo, L., Munafò, M., & Morabito, M. (2021). Thermal Summer Diurnal Hot-Spot Analysis: The Role of Local Urban Features Layers. *Remote Sensing*, 13(3), 538. <https://doi.org/10.3390/rs13030538>

- Guha, S., Govil, H., Gill, N., & Dey, A. (2020). Analytical study on the relationship between land surface temperature and land use/land cover indices. *Annals of GIS*, 26(2), 201–216. <https://doi.org/10.1080/19475683.2020.1754291>
- Gunawardena, K. R., Wells, M. J., & Kershaw, T. (2017). Utilising green and bluespace to mitigate urban heat island intensity. *Science of The Total Environment*, 584–585, 1040–1055. <https://doi.org/10.1016/j.scitotenv.2017.01.158>
- Han, Y., Zhong, T., Yeh, A. G. O., Zhong, X., Chen, M., & Lü, G. (2023). Mapping seasonal changes of street greenery using multi-temporal street-view images. *Sustainable Cities and Society*, 92, 104498. <https://doi.org/10.1016/j.scs.2023.104498>
- Hatfield, J. L., Prueger, J. H., Sauer, T. J., Dold, C., O'Brien, P., & Wacha, K. (2019). Applications of Vegetative Indices from Remote Sensing to Agriculture: Past and Future. *Inventions*, 4(4), 71. <https://doi.org/10.3390/inventions4040071>
- Huang, S., Tang, L., Hupy, J. P., Wang, Y., & Shao, G. (2021). A commentary review on the use of normalized difference vegetation index (NDVI) in the era of popular remote sensing. *Journal of Forestry Research*, 32(1), 1–6. <https://doi.org/10.1007/s11676-020-01155-1>
- Jimenez, J. C., Barichivich, J., Mattar, C., Takahashi, K., Santamaría-Artigas, A., Sobrino, J. A., & Malhi, Y. (2018). Spatio-temporal patterns of thermal anomalies and drought over tropical forests driven by recent extreme climatic anomalies. *Philosophical Transactions of the Royal Society B: Biological Sciences*, 373(1760), 20170300. <https://doi.org/10.1098/rstb.2017.0300>
- Kicovic, D., Vuckovic, D., Markovic, D., & Jovic, S. (2019). Assessment of visitors' thermal comfort based on physiologically equivalent temperature in open urban areas. *Urban Climate*, 28, 100466. <https://doi.org/10.1016/j.uclim.2019.100466>
- Kong, F., Yin, H., James, P., Hutya, L. R., & He, H. S. (2014). Effects of spatial pattern of greenspace on urban cooling in a large metropolitan area of eastern China. *Landscape and Urban Planning*, 128, 35–47. <https://doi.org/10.1016/j.landurbplan.2014.04.018>
- Li, J., Mao, Y., Ouyang, J., & Zheng, S. (2022). A Review of Urban Microclimate Research Based on CiteSpace and VOSviewer Analysis. *International Journal of Environmental Research and Public Health*, 19(8), 4741. <https://doi.org/10.3390/ijerph19084741>
- Li, Z., Wu, H., Duan, S., Zhao, W., Ren, H., Liu, X., Leng, P., Tang, R., Ye, X., Zhu, J., Sun, Y., Si, M., Liu, M., Li, J., Zhang, X., Shang, G., Tang, B., Yan, G., & Zhou, C. (2023). Satellite Remote Sensing of Global Land Surface Temperature: Definition, Methods, Products, and Applications. *Reviews of Geophysics*, 61(1), e2022RG000777. <https://doi.org/10.1029/2022RG000777>
- Li, Z.-L., Tang, B.-H., Wu, H., Ren, H., Yan, G., Wan, Z., Trigo, I. F., & Sobrino, J. A. (2013). Satellite-derived land surface temperature: Current status and perspectives. *Remote Sensing of Environment*, 131, 14–37. <https://doi.org/10.1016/j.rse.2012.12.008>
- Litardo, J., Palme, M., Borbor-Cordova, M., Caiza, R., Macias, J., Hidalgo-Leon, R., & Soriano, G. (2020). Urban Heat Island intensity and buildings' energy needs in Duran, Ecuador: Simulation studies and proposal of mitigation strategies. *Sustainable Cities and Society*, 62, 102387. <https://doi.org/10.1016/j.scs.2020.102387>
- Liu, Q., Zhang, H., Peng, J., Li, Q., Liu, T., Hu, F., Huang, H., Shen, Y., Ye, B., Guo, Y., & Wang, H. (2025). Mitigation strategies for regional heat island effects: Integrated network construction of cold and heat islands. *Ecological Indicators*, 176, 113703. <https://doi.org/10.1016/j.ecolind.2025.113703>

- Na, N., Lou, D., Xu, D., Ni, X., Liu, Y., & Wang, H. (2024). Measuring the cooling effects of green cover on urban heat island effects using Landsat satellite imagery. *International Journal of Digital Earth*, 17(1), 2358867. <https://doi.org/10.1080/17538947.2024.2358867>
- Norton, B. A., Coutts, A. M., Livesley, S. J., Harris, R. J., Hunter, A. M., & Williams, N. S. G. (2015). Planning for cooler cities: A framework to prioritise green infrastructure to mitigate high temperatures in urban landscapes. *Landscape and Urban Planning*, 134, 127–138. <https://doi.org/10.1016/j.landurbplan.2014.10.018>
- OpenAI (2025). ChatGPT 5.5 [suur keelemudel]. <https://chat.openai.com/chat>
- Ouyang, Q., Zheng, B., Liu, J., Luo, X., Wu, S., & Sun, Z. (2025). Construction of a Cold Island Spatial Pattern from the Perspective of Landscape Connectivity to Alleviate the Urban Heat Island Effect. *ISPRS International Journal of Geo-Information*, 14(6), 209. <https://doi.org/10.3390/ijgi14060209>
- Phiri, D., Simwanda, M., Salekin, S., Nyirenda, V., Murayama, Y., & Ranagalage, M. (2020). Sentinel-2 Data for Land Cover/Use Mapping: A Review. *Remote Sensing*, 12(14), 2291. <https://doi.org/10.3390/rs12142291>
- Quan, S. J., & Bansal, P. (2021). A systematic review of GIS-based local climate zone mapping studies. *Building and Environment*, 196, 107791. <https://doi.org/10.1016/j.buildenv.2021.107791>
- Rasul, A., Balzter, H., Smith, C., Remedios, J., Adamu, B., Sobrino, J., Srivani, M., & Weng, Q. (2017). A Review on Remote Sensing of Urban Heat and Cool Islands. *Land*, 6(2), 38. <https://doi.org/10.3390/land6020038>
- Roy, D. P., Wulder, M. A., Loveland, T. R., C.E., W., Allen, R. G., Anderson, M. C., Helder, D., Irons, J. R., Johnson, D. M., Kennedy, R., Scambos, T. A., Schaaf, C. B., Schott, J. R., Sheng, Y., Vermote, E. F., Belward, A. S., Bindschadler, R., Cohen, W. B., Gao, F., ... Zhu, Z. (2014). Landsat-8: Science and product vision for terrestrial global change research. *Remote Sensing of Environment*, 145, 154–172. <https://doi.org/10.1016/j.rse.2014.02.001>
- Santamouris, M. (2014). Cooling the cities – A review of reflective and green roof mitigation technologies to fight heat island and improve comfort in urban environments. *Solar Energy*, 103, 682–703. <https://doi.org/10.1016/j.solener.2012.07.003>
- Singh, A., & Bhadauria, S. S. (2024). *Integration of Remote Sensing and GIS for Environmental Assessment*.
- Song, J., Qiao, Y., & Liu, Y. (2025). Evaluation of the cold island effect of the urban parks in the main urban area of Wuhan from the perspective of supply and demand. *Frontiers in Public Health*, 13, 1523210. <https://doi.org/10.3389/fpubh.2025.1523210>
- Soojussaarte kaadirakendus. (s.a.). [Map]. Salvestatud <https://geoportaal.maaamet.ee/est/kaadirakendus/soojussaare/soojussaarte-kaadirakendus-kirjeldus-p724.html>
- Stewart, I. D., & Oke, T. R. (2012). Local Climate Zones for Urban Temperature Studies. *Bulletin of the American Meteorological Society*, 93(12), 1879–1900. <https://doi.org/10.1175/BAMS-D-11-00019.1>
- Sun, X., Tan, X., Chen, K., Song, S., Zhu, X., & Hou, D. (2020). Quantifying landscape-metrics impacts on urban green-spaces and water-bodies cooling effect: The study of Nanjing, China. *Urban Forestry & Urban Greening*, 55, 126838. <https://doi.org/10.1016/j.ufug.2020.126838>
- Šamanović, S., Bjelotomić Oršulić, O., Krajina, T., & Markovinović, D. (2025). Tracking Urban Heat Island Dynamics Using Open Source Tools and Free Data. *The International Archives of the Photogrammetry, Remote Sensing and Spatial*

- Information Sciences*, XLVIII-4/W13-2025, 217–224. <https://doi.org/10.5194/isprs-archives-XLVIII-4-W13-2025-217-2025>
- Zargari, M., Mofidi, A., Entezari, A., & Baaghdeh, M. (2024). Climatic comparison of surface urban heat island using satellite remote sensing in Tehran and suburbs. *Scientific Reports*, 14(1), 643. <https://doi.org/10.1038/s41598-023-50757-2>
- Zhang, K., Liu, Q., Fang, B., Zhang, Z., Liu, T., & Yuan, J. (2025). Research on the cool island effect of green spaces in megacity cores: A case study of the main urban area of Xi'an, China. *Sustainable Cities and Society*, 122, 106255. <https://doi.org/10.1016/j.scs.2025.106255>
- Zhao, L., Fan, X., & Hong, T. (2025). Urban Heat Island Effect: Remote Sensing Monitoring and Assessment—Methods, Applications, and Future Directions. *Atmosphere*, 16(7), 791. <https://doi.org/10.3390/atmos16070791>
- Zhao, L., Oppenheimer, M., Zhu, Q., Baldwin, J. W., Ebi, K. L., Bou-Zeid, E., Guan, K., & Liu, X. (2018). Interactions between urban heat islands and heat waves. *Environmental Research Letters*, 13(3), 034003. <https://doi.org/10.1088/1748-9326/aa9f73>
- Zhou, D., Zhao, S., Liu, S., Zhang, L., & Zhu, C. (2014). Surface urban heat island in China's 32 major cities: Spatial patterns and drivers. *Remote Sensing of Environment*, 152, 51–61. <https://doi.org/10.1016/j.rse.2014.05.017>
- Zhou, D., Xiao, J., Bonafoni, S., Berger, C., Deilami, K., Zhou, Y., Frolking, S., Yao, R., Qiao, Z., & Sobrino, J. A. (2018). Satellite Remote Sensing of Surface Urban Heat Islands: Progress, Challenges, and Perspectives. *Remote Sensing*, 11(1), 48. <https://doi.org/10.3390/rs11010048>
- United States Geological Survey. (s.a.). *Landsat Collection 2 Surface Temperature Product Guide*. Salvstatud https://www.usgs.gov/landsat-missions/landsat-collection-2-surface-temperature?utm_source
- Wang, J., Wu, Y., Li, J., Zhu, Z., Fu, W., Ding, G., & Xu, X. (2025). Exploring the Diurnal Dynamics Mechanism of the Cold Island Effect in Urban Parks of Island Cities: A Three-Dimensional Spatial Morphology Perspective. *Atmosphere*, 16(10), 1202. <https://doi.org/10.3390/atmos16101202>
- Wang, Q., Peng, L. L. H., Jiang, W., Yin, S., Feng, N., & Yao, L. (2024). Urban form affects the cool island effect of urban greenery via building shadows. *Building and Environment*, 254, 111398. <https://doi.org/10.1016/j.buildenv.2024.111398>
- Weng, Q., Lu, D., & Schubring, J. (2004). Estimation of land surface temperature–vegetation abundance relationship for urban heat island studies. *Remote Sensing of Environment*, 89(4), 467–483. <https://doi.org/10.1016/j.rse.2003.11.005>
- Williams, P. D. (2016). Transatlantic flight times and climate change. *Environmental Research Letters*, 11(2), 024008. <https://doi.org/10.1088/1748-9326/11/2/024008>
- Xiang, Y., Chang, D., & Cheng, J. (2023). *Exploring the Correlation between Urban Microclimate Simulation and Urban Morphology: A Case Study in Yeongdeungpo-gu, Seoul* (Version 1). arXiv. <https://doi.org/10.48550/ARXIV.2310.09779>
- Xue, J., & Su, B. (2017). Significant Remote Sensing Vegetation Indices: A Review of Developments and Applications. *Journal of Sensors*, 2017, 1–17. <https://doi.org/10.1155/2017/1353691>
- Yang, C., He, X., Wang, R., Yan, F., Yu, L., Bu, K., Yang, J., Chang, L., & Zhang, S. (2017). The Effect of Urban Green Spaces on the Urban Thermal Environment and Its Seasonal Variations. *Forests*, 8(5), 153. <https://doi.org/10.3390/f8050153>

LISAD

Lisa 1. *Google Earth Engine* (GEE) skript Tallinna maapinnatemperatuuri (LST), külmasaarte ja NDVI analüüsiks 2025. aasta suveperioodil

```
// 1. Uurimisala: Tallinn ilma Aegna saareta (kasutaja GEE asset)
var tallinn = ee.FeatureCollection(
  'projects/ee-gerlikangur98/assets/tln_ilma_aegnata'
);

// 2. SMW algoritmil põhinev Landsat 8 LST moodul (Sofia Ermida)
var LandsatLST = require(
  'users/sofiaermida/landsat_smw_lst:modules/Landsat_LST.js'
);

// 3. Landsat 8 LST kollektsioon suvehooajaks 2025, pilvefilter sees
var lstCollection = LandsatLST.collection(
  'L8',
  '2025-06-01',
  '2025-08-31',
  tallinn,
  true
);

// 4. Temporaalne keskmine, Kelvin → Celsius, lõikamine uurimisalaga
var lst = lstCollection
  .select('LST')
  .mean()
  .subtract(273.15)
  .clip(tallinn);

// 5. Kogu uurimisala pikslite aritmeetiline keskmine LST (skalaar, 30 m piksel)
var meanDict = lst.reduceRegion({
  reducer: ee.Reducer.mean(),
  geometry: tallinn,
  scale: 30,
  maxPixels: 1e13
});
var meanLST = ee.Number(
  meanDict.get('LST')
);

// 6. Külmasaared: pikslid, mille LST on üle 2°C alla ala keskmise
var coldIslands = lst.lt(
  meanLST.subtract(2)
).selfMask();

// 7. Kaardi tsentreerimine ja LST visualiseerimine sinisest punaseni (10–35°C)
Map.centerObject(tallinn, 10);
var vis = {
  min: 10,
  max: 35,
  palette: ['blue', 'cyan', 'green', 'yellow', 'orange', 'red']
};
Map.addLayer(lst, vis, 'Tallinn LST 2025');

// 8. Külmasaared kuvatud ühtlase sinisena
Map.addLayer(
  coldIslands,
```

```

    {palette: ['0000ff']},
    'Külmasaared 2025'
  );

// 9. Sentinel-2 SR kollektsoon: asukoha-, aja- ja pilvisusfilter (<10%)
var s2 = ee.ImageCollection('COPERNICUS/S2_SR_HARMONIZED')
  .filterBounds(tallinn)
  .filterDate('2025-06-01', '2025-08-31')
  .filter(ee.Filter.lt('CLOUDY_PIXEL_PERCENTAGE', 10));

// 10. NDVI: temporaalne mediaan, normaliseeritud erinevus (B8-B4)/(B8+B4), 10 m
var ndvi = s2
  .median()
  .normalizedDifference(['B8', 'B4'])
  .rename('NDVI')
  .clip(tallinn);

// 11. NDVI visualiseerimine valge-kollane-roheline skaalal (-1 kuni 1)
var ndviVis = {
  min: -1,
  max: 1,
  palette: ['white', 'yellow', 'green', 'darkgreen']
};
Map.addLayer(ndvi, ndviVis, 'NDVI 2025');

// 12. Eksport Google Drive'i: LST (30 m), NDVI (10 m), külmasaared (30 m)
Export.image.toDrive({
  image: lst,
  description: 'Tallinn_LST_2025',
  folder: 'GEE',
  region: tallinn.geometry(),
  scale: 30,
  maxPixels: 1e13
});
Export.image.toDrive({
  image: ndvi,
  description: 'Tallinn_NDVI_2025',
  folder: 'GEE',
  region: tallinn.geometry(),
  scale: 10,
  maxPixels: 1e13
});
Export.image.toDrive({
  image: coldIslands,
  description: 'Tallinn_Cold_Islands_2025',
  folder: 'GEE',
  region: tallinn.geometry(),
  scale: 30,
  maxPixels: 1e13
});

```

Lisa 2. *ArcGIS Pro* keskkonnas koostatud regressioonianalüüsi (OLS) väljundid 2021. aasta kohta

Summary of OLS Results - Model Variables

Variable	Coefficient [a]	StdError	t-Statistic	Probability [b]	Robust_SE	Robust_t	Robust_Pr [b]
Intercept	32,304113	0,079309	407,319798	0,000000*	0,087350	369,823343	0,000000*
NDVI_2021_MA	-10,170055	0,129527	-78,516672	0,000000*	0,136927	-74,273743	0,000000*

OLS Diagnostics

Input Features	downscale_points _202_uus	Dependent Variable	LST_2021_MASK
Number of Observations	4995	Akaike's Information Criterion (AICc)['d']	23271,731088
Multiple R-Squared['d']	0,552513	Adjusted R-Squared['d']	0,552423
Joint F-Statistic['e']	6164,867721	Prob(>F), (1,4993) degrees of freedom	0,000000*
Joint Wald Statistic['e']	5516,588839	Prob(>chi-squared), (1) degrees of freedom	0,000000*
Koenker (BP) Statistic['f']	49,260197	Prob(>chi-squared), (1) degrees of freedom	0,000000*
Jarque-Bera Statistic['g']	81,673834	Prob(>chi-squared), (2) degrees of freedom	0,000000*

Notes on Interpretation

* An asterisk next to a number indicates a statistically significant p-value ($p < 0,01$).

[a] Coefficient: Represents the strength and type of relationship between each explanatory variable and the dependent variable.

[b] Probability and Robust Probability (Robust_Pr): Asterisk (*) indicates a coefficient is statistically significant ($p < 0,01$); if the Koenker (BP) Statistic [f] is statistically significant, use the Robust Probability column (Robust_Pr) to determine coefficient significance.

[c] Variance Inflation Factor (VIF): Large Variance Inflation Factor (VIF) values ($> 7,5$) indicate redundancy among explanatory variables.


[d] R-Squared and Akaike's Information Criterion (AICc): Measures of model fit/performance.

[e] Joint F and Wald Statistics: Asterisk (*) indicates overall model significance ($p < 0,01$); if the Koenker (BP) Statistic [f] is statistically significant, use the Wald Statistic to determine overall model significance.

[f] Koenker (BP) Statistic: When this test is statistically significant ($p < 0,01$), the relationships modeled are not consistent (either due to non-stationarity or heteroskedasticity). You should rely on the Robust Probabilities (Robust_Pr) to determine coefficient significance and on the Wald Statistic to determine overall model significance.


[g] Jarque-Bera Statistic: When this test is statistically significant ($p < 0,01$) model predictions are biased (the residuals are not normally distributed).

Variable Distributions and Relationships




The above graphs are Histograms and Scatterplots for each explanatory variable and the dependent variable. The histograms show how each variable is distributed. OLS does not require variables to be normally distributed. However, if you are having trouble finding a properly-specified model, you can try transforming strongly skewed variables to see if you get a better result.

Each scatterplot depicts the relationship between an explanatory variable and the dependent variable. Strong relationships appear as diagonals and the direction of the slant indicates if the relationship is positive or negative. Try transforming your variables if you detect any non-linear relationships. For more information see the Regression Analysis Basics documentation.




Ideally the histogram of your residuals would match the normal curve, indicated above in blue. If the histogram looks very different from the normal curve, you may have a biased model. If this bias is significant it will also be represented by a statistically significant Jarque-Bera p-value (*).

Residual vs. Predicted Plot



This is a graph of residuals (model over and under predictions) in relation to predicted dependent variable values. For a properly specified model, this scatterplot will have little structure, and look random (see graph on the right). If there is a structure to this plot, the type of structure may be a valuable clue to help you figure out what's going on.



Ordinary Least Squares Parameters

Parameter Name	Input Value
Input Features	downscale_points_202_uus
Unique ID Field	UID
Output Feature Class	C:\Users\Gerli.Kangur\Documents\ArcGIS\Projects\makatöö2021\makatöö2021.gdb\d
Dependent Variable	LST_2021_MASK
Explanatory Variables	NDVI_2021_MASK
Selection Set	False

Lisa 3. *ArcGIS Pro* keskkonnas koostatud regressioonianalüüsi (*OLS*) väljundid 2022. aasta kohta

Summary of OLS Results - Model Variables

Variable	Coefficient [a]	StdError	t-Statistic	Probability [b]	Robust_SE	Robust_t	Robust_Pr [b]
Intercept	33,269599	0,078276	425,030765	0,000000*	0,083249	399,641962	0,000000*
NDVI_2022_MA	-9,574819	0,124539	-76,882357	0,000000*	0,128674	-74,411165	0,000000*

OLS Diagnostics

Input Features	downscale_points _202_uus 4995	Dependent Variable	LST_2022_MASK
Number of Observations	4995	Akaike's Information Criterion (AICc)['d']	23155,460164
Multiple R-Squared['d']	0,542090	Adjusted R-Squared['d']	0,541999
Joint F-Statistic['e']	5910,896806	Prob(>F), (1,4993) degrees of freedom	0,000000*
Joint Wald Statistic['e']	5537,021474	Prob(>chi-squared), (1) degrees of freedom	0,000000*
Koenker (BP) Statistic['f']	21,847341	Prob(>chi-squared), (1) degrees of freedom	0,000003*
Jarque-Bera Statistic['g']	16,633426	Prob(>chi-squared), (2) degrees of freedom	0,000244*

Notes on Interpretation

* An asterisk next to a number indicates a statistically significant p-value ($p < 0,01$).

[a] Coefficient: Represents the strength and type of relationship between each explanatory variable and the dependent variable.

[b] Probability and Robust Probability (Robust_Pr): Asterisk (*) indicates a coefficient is statistically significant ($p < 0,01$); if the Koenker (BP) Statistic [f] is statistically significant, use the Robust Probability column (Robust_Pr) to determine coefficient significance.

[c] Variance Inflation Factor (VIF): Large Variance Inflation Factor (VIF) values ($> 7,5$) indicate redundancy among explanatory variables.


[d] R-Squared and Akaike's Information Criterion (AICc): Measures of model fit/performance.

[e] Joint F and Wald Statistics: Asterisk (*) indicates overall model significance ($p < 0,01$); if the Koenker (BP) Statistic [f] is statistically significant, use the Wald Statistic to determine overall model significance.

[f] Koenker (BP) Statistic: When this test is statistically significant ($p < 0,01$), the relationships modeled are not consistent (either due to non-stationarity or heteroskedasticity). You should rely on the Robust Probabilities (Robust_Pr) to determine coefficient significance and on the Wald Statistic to determine overall model significance.

[g] Jarque-Bera Statistic: When this test is statistically significant ($p < 0,01$) model predictions are biased (the residuals are not normally distributed).


Variable Distributions and Relationships




The above graphs are Histograms and Scatterplots for each explanatory variable and the dependent variable. The histograms show how each variable is distributed. OLS does not require variables to be normally distributed. However, if you are having trouble finding a properly-specified model, you can try transforming strongly skewed variables to see if you get a better result.

Each scatterplot depicts the relationship between an explanatory variable and the dependent variable. Strong relationships appear as diagonals and the direction of the slant indicates if the relationship is positive or negative. Try transforming your variables if you detect any non-linear relationships. For more information see the Regression Analysis Basics documentation.


Histogram of Standardized Residuals



Ideally the histogram of your residuals would match the normal curve, indicated above in blue. If the histogram looks very different from the normal curve, you may have a biased model. If this bias is significant it will also be represented by a statistically significant Jarque-Bera p-value (*).

Residual vs. Predicted Plot

This is a graph of residuals (model over and under predictions) in relation to predicted dependent variable values. For a properly specified model, this scatterplot will have little structure, and look random (see graph on the right). If there is a structure to this plot, the type of structure may be a valuable clue to help you figure out what's going on.



Ordinary Least Squares Parameters

Parameter Name	Input Value
Input Features	downscale_points_202_uus
Unique ID Field	UID
Output Feature Class	C:\Users\Gerli.Kangur\Documents\ArcGIS\Projects\makatöö2022\makatöö2022.gdb\do
Dependent Variable	LST_2022_MASK
Explanatory Variables	NDVI_2022_MASK
Selection Set	False

Lisa 4. *ArcGIS Pro* keskkonnas koostatud regressioonianalüüsi (OLS) väljundid 2023. aasta kohta

Summary of OLS Results - Model Variables

Variable	Coefficient [a]	StdError	t-Statistic	Probability [b]	Robust_SE	Robust_t	Robust_Pr [b]
Intercept	31,352153	0,084050	373,018582	0,000000*	0,082741	378,918844	0,000000*
NDVI_2023_MA	-11,086154	0,140767	-78,755280	0,000000*	0,142265	-77,925993	0,000000*

OLS Diagnostics

Input Features	downscale_points _202_uus	Dependent Variable	LST_2023_MASK
Number of Observations	4995	Akaike's Information Criterion (AICc)['d']	24021,061063
Multiple R-Squared['d']	0,554013	Adjusted R-Squared['d']	0,553924
Joint F-Statistic['e']	6202,394113	Prob(>F), (1,4993) degrees of freedom	0,000000*
Joint Wald Statistic['e']	6072,460428	Prob(>chi-squared), (1) degrees of freedom	0,000000*
Koenker (BP) Statistic['f']	8,785452	Prob(>chi-squared), (1) degrees of freedom	0,003036*
Jarque-Bera Statistic['g']	6,679497	Prob(>chi-squared), (2) degrees of freedom	0,035446*

Notes on Interpretation

* An asterisk next to a number indicates a statistically significant p-value ($p < 0,01$).

[a] Coefficient: Represents the strength and type of relationship between each explanatory variable and the dependent variable.

[b] Probability and Robust Probability (Robust_Pr): Asterisk (*) indicates a coefficient is statistically significant ($p < 0,01$); if the Koenker (BP) Statistic [f] is statistically significant, use the Robust Probability column (Robust_Pr) to determine coefficient significance.

[c] Variance Inflation Factor (VIF): Large Variance Inflation Factor (VIF) values ($> 7,5$) indicate redundancy among explanatory variables.


[d] R-Squared and Akaike's Information Criterion (AICc): Measures of model fit/performance.

[e] Joint F and Wald Statistics: Asterisk (*) indicates overall model significance ($p < 0,01$); if the Koenker (BP) Statistic [f] is statistically significant, use the Wald Statistic to determine overall model significance.

[f] Koenker (BP) Statistic: When this test is statistically significant ($p < 0,01$), the relationships modeled are not consistent (either due to non-stationarity or heteroskedasticity). You should rely on the Robust Probabilities (Robust_Pr) to determine coefficient significance and on the Wald Statistic to determine overall model significance.


[g] Jarque-Bera Statistic: When this test is statistically significant ($p < 0,01$) model predictions are biased (the residuals are not normally distributed).

Variable Distributions and Relationships




The above graphs are Histograms and Scatterplots for each explanatory variable and the dependent variable. The histograms show how each variable is distributed. OLS does not require variables to be normally distributed. However, if you are having trouble finding a properly-specified model, you can try transforming strongly skewed variables to see if you get a better result.


Each scatterplot depicts the relationship between an explanatory variable and the dependent variable. Strong relationships appear as diagonals and the direction of the slant indicates if the relationship is positive or negative. Try transforming your variables if you detect any non-linear relationships. For more information see the Regression Analysis Basics documentation.



Ideally the histogram of your residuals would match the normal curve, indicated above in blue. If the histogram looks very different from the normal curve, you may have a biased model. If this bias is significant it will also be represented by a statistically significant Jarque-Bera p-value (*).

Residual vs. Predicted Plot

This is a graph of residuals (model over and under predictions) in relation to predicted dependent variable values. For a properly specified model, this scatterplot will have little structure, and look random (see graph on the right). If there is a structure to this plot, the type of structure may be a valuable clue to help you figure out what's going on.



Ordinary Least Squares Parameters

Parameter Name	Input Value
Input Features	downscale_points_202_uus
Unique ID Field	UID
Output Feature Class	C:\Users\Gerli.Kangur\Documents\ArcGIS\Projects\makatöö2023\makatöö2023.gdb\di
Dependent Variable	LST_2023_MASK
Explanatory Variables	NDVI_2023_MASK
Selection Set	False

Lisa 5. *ArcGIS Pro* keskkonnas koostatud regressioonianalüüsi (*OLS*) väljundid 2024. aasta kohta

Summary of OLS Results - Model Variables

Variable	Coefficient [a]	StdError	t-Statistic	Probability [b]	Robust_SE	Robust_t	Robust_Pr [b]
Intercept	30,103941	0,068384	440,219091	0,000000*	0,075360	399,469413	0,000000*
NDVI_2024_MA	-8,380853	0,105378	-79,531005	0,000000*	0,112246	-74,665246	0,000000*

OLS Diagnostics

Input Features	downscale_points _2024_uus	Dependent Variable	LST_2024_MASK
Number of Observations	4995	Akaike's Information Criterion (AICc)['d']	21712,411559
Multiple R-Squared['d']	0,558851	Adjusted R-Squared['d']	0,558763
Joint F-Statistic['e']	6325,180799	Prob(>F), (1,4993) degrees of freedom	0,000000*
Joint Wald Statistic['e']	5574,898907	Prob(>chi-squared), (1) degrees of freedom	0,000000*
Koenker (BP) Statistic['f']	40,137035	Prob(>chi-squared), (1) degrees of freedom	0,000000*
Jarque-Bera Statistic['g']	65,116664	Prob(>chi-squared), (2) degrees of freedom	0,000000*

Notes on Interpretation

* An asterisk next to a number indicates a statistically significant p-value ($p < 0,01$).

[a] Coefficient: Represents the strength and type of relationship between each explanatory variable and the dependent variable.

[b] Probability and Robust Probability (Robust_Pr): Asterisk (*) indicates a coefficient is statistically significant ($p < 0,01$); if the Koenker (BP) Statistic [f] is statistically significant, use the Robust Probability column (Robust_Pr) to determine coefficient significance.

[c] Variance Inflation Factor (VIF): Large Variance Inflation Factor (VIF) values ($> 7,5$) indicate redundancy among explanatory variables.


[d] R-Squared and Akaike's Information Criterion (AICc): Measures of model fit/performance.

[e] Joint F and Wald Statistics: Asterisk (*) indicates overall model significance ($p < 0,01$); if the Koenker (BP) Statistic [f] is statistically significant, use the Wald Statistic to determine overall model significance.

[f] Koenker (BP) Statistic: When this test is statistically significant ($p < 0,01$), the relationships modeled are not consistent (either due to non-stationarity or heteroskedasticity). You should rely on the Robust Probabilities (Robust_Pr) to determine coefficient significance and on the Wald Statistic to determine overall model significance.


[g] Jarque-Bera Statistic: When this test is statistically significant ($p < 0,01$) model predictions are biased (the residuals are not normally distributed).

Variable Distributions and Relationships




The above graphs are Histograms and Scatterplots for each explanatory variable and the dependent variable. The histograms show how each variable is distributed. OLS does not require variables to be normally distributed. However, if you are having trouble finding a properly-specified model, you can try transforming strongly skewed variables to see if you get a better result.


Each scatterplot depicts the relationship between an explanatory variable and the dependent variable. Strong relationships appear as diagonals and the direction of the slant indicates if the relationship is positive or negative. Try transforming your variables if you detect any non-linear relationships. For more information see the Regression Analysis Basics documentation.



Ideally the histogram of your residuals would match the normal curve, indicated above in blue. If the histogram looks very different from the normal curve, you may have a biased model. If this bias is significant it will also be represented by a statistically significant Jarque-Bera p-value (*).

Residual vs. Predicted Plot

This is a graph of residuals (model over and under predictions) in relation to predicted dependent variable values. For a properly specified model, this scatterplot will have little structure, and look random (see graph on the right). If there is a structure to this plot, the type of structure may be a valuable clue to help you figure out what's going on.



Ordinary Least Squares Parameters

Parameter Name	Input Value
Input Features	downscale_points_2024_uus
Unique ID Field	UID
Output Feature Class	C:\Users\Gerli.Kangur\Documents\ArcGIS\Projects\makatöö2024\makatöö2024.gdb\
Dependent Variable	LST_2024_MASK
Explanatory Variables	NDVI_2024_MASK
Selection Set	False

Lisa 6. *ArcGIS Pro* keskkonnas koostatud regressioonianalüüsi (OLS) väljundid 2025. aasta kohta

Summary of OLS Results - Model Variables

Variable	Coefficient [a]	StdError	t-Statistic	Probability [b]	Robust_SE	Robust_t	Robust_Pr [b]
Intercept	29,373262	0,092656	317,013926	0,000000*	0,103050	285,038600	0,000000*
NDVI_2025_MA	-8,134992	0,145899	-55,757743	0,000000*	0,159297	-51,068230	0,000000*

OLS Diagnostics

Input Features	downscale_points _202_uus	Dependent Variable	LST_2025_MASK_VI IMANE
Number of Observations	4995	Akaike's Information Criterion (AICc)['d']	24289,560411
Multiple R-Squared['d']	0,383727	Adjusted R-Squared['d']	0,383603
Joint F-Statistic['e']	3108,925934	Prob(>F), (1,4993) degrees of freedom	0,000000*
Joint Wald Statistic['e']	2607,964108	Prob(>chi-squared), (1) degrees of freedom	0,000000*
Koenker (BP) Statistic['f']	19,808049	Prob(>chi-squared), (1) degrees of freedom	0,000009*
Jarque-Bera Statistic['g']	176,326471	Prob(>chi-squared), (2) degrees of freedom	0,000000*

Notes on Interpretation

* An asterisk next to a number indicates a statistically significant p-value ($p < 0,01$).

[a] Coefficient: Represents the strength and type of relationship between each explanatory variable and the dependent variable.

[b] Probability and Robust Probability (Robust_Pr): Asterisk (*) indicates a coefficient is statistically significant ($p < 0,01$); if the Koenker (BP) Statistic [f] is statistically significant, use the Robust Probability column (Robust_Pr) to determine coefficient significance.

[c] Variance Inflation Factor (VIF): Large Variance Inflation Factor (VIF) values ($> 7,5$) indicate redundancy among explanatory variables.


[d] R-Squared and Akaike's Information Criterion (AICc): Measures of model fit/performance.

[e] Joint F and Wald Statistics: Asterisk (*) indicates overall model significance ($p < 0,01$); if the Koenker (BP) Statistic [f] is statistically significant, use the Wald Statistic to determine overall model significance.

[f] Koenker (BP) Statistic: When this test is statistically significant ($p < 0,01$), the relationships modeled are not consistent (either due to non-stationarity or heteroskedasticity). You should rely on the Robust Probabilities (Robust_Pr) to determine coefficient significance and on the Wald Statistic to determine overall model significance.


[g] Jarque-Bera Statistic: When this test is statistically significant ($p < 0,01$) model predictions are biased (the residuals are not normally distributed).

Variable Distributions and Relationships




The above graphs are Histograms and Scatterplots for each explanatory variable and the dependent variable. The histograms show how each variable is distributed. OLS does not require variables to be normally distributed. However, if you are having trouble finding a properly-specified model, you can try transforming strongly skewed variables to see if you get a better result.


Each scatterplot depicts the relationship between an explanatory variable and the dependent variable. Strong relationships appear as diagonals and the direction of the slant indicates if the relationship is positive or negative. Try transforming your variables if you detect any non-linear relationships. For more information see the Regression Analysis Basics documentation.



Ideally the histogram of your residuals would match the normal curve, indicated above in blue. If the histogram looks very different from the normal curve, you may have a biased model. If this bias is significant it will also be represented by a statistically significant Jarque-Bera p-value (*).

Residual vs. Predicted Plot

This is a graph of residuals (model over and under predictions) in relation to predicted dependent variable values. For a properly specified model, this scatterplot will have little structure, and look random (see graph on the right). If there is a structure to this plot, the type of structure may be a valuable clue to help you figure out what's going on.



Ordinary Least Squares Parameters

Parameter Name	Input Value
Input Features	downscale_points_202_uus
Unique ID Field	UID
Output Feature Class	C:\Users\Gerli.Kangur\Documents\ArcGIS\Projects\makatoo\makatoo.gdb\downscal
Dependent Variable	LST_2025_MASK_VIIMANE
Explanatory Variables	NDVI_2025_MASK_VIIMANE
Selection Set	False

Lisa 7. Lihtlitsents lõputöö salvestamiseks ja üldsusele kättesaadavaks tegemiseks ning juhendaja(te) kinnitus lõputöö kaitsmisele lubamise kohta

Mina, Gerli Kangur,

(autori nimi)

sünniaeg 01.12.1998,

1. annan Eesti Maaülikoolile tasuta loa (lihtlitsentsi) enda koostatud lõputöö

Tallinna külmasaarte kaardistamine kaugseire andmete põhjal,

(lõputöö pealkiri)

mille juhendaja(d) on _____ Aive Liibusk _____,

(juhendaja(te) nimi)

salvestamiseks säilitamise eesmärgil, sealhulgas digitaalarhiivi EMU DSpace lisamiseks ja Creative Commons'i litsentsiga CC BY NC ND 4.0, mis lubab autorile viidates lõputööd reprodutseerida, levitada ja üldsusele suunata ning keelab luua tuletatud teost ja kasutada teost ärieesmärgil, üldsusele kättesaadavaks tegemiseks kuni autoriõiguse kehtivuse lõppemiseni;

2. olen teadlik, et lihtlitsentsiga antavad õigused jäävad alles ka mulle;
3. kinnitan, et lihtlitsentsi andmisega ei rikuta teiste isikute intellektuaalomandi ega isikuandmete kaitse seadusest tulenevaid õigusi.

Lõputöö autor (allkirjastatud digitaalselt, kuupäev digitaalallkirjas)

Juhendaja kinnitus lõputöö kaitsmisele lubamise kohta

Luban lõputöö kaitsmisele.

Juhendaja (allkirjastatud digitaalselt, kuupäev digitaalallkirjas)